T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

İNŞAAT MÜHENDİSLİĞİ ANA BİLİM DALI

KARAYOLU TÜNELLERİNDE SÜRÜCÜ DAVRANIŞLARININ SİMÜLATÖR DESTEKLİ ANALİZİ VE YAPAY ZEKÂ TEKNİKLERİYLE İNCELENMESİ

DOKTORA

Ömer Faruk ÖZTÜRK

ARALIK-2024
GÜMÜŞHANE

T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

İNŞAAT MÜHENDİSLİĞİ ANA BİLİM DALI

KARAYOLU TÜNELLERİNDE SÜRÜCÜ DAVRANIŞLARININ SİMÜLATÖR DESTEKLİ ANALİZİ VE YAPAY ZEKÂ TEKNİKLERİYLE İNCELENMESİ

SIMULATOR-BASED ANALYSIS AND ARTIFICIAL INTELLIGENCE EXAMINATION OF DRIVER BEHAVIORS IN ROAD TUNNELS

DOKTORA

Ömer Faruk ÖZTÜRK

ARALIK-2024
GÜMÜŞHANE

T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

İNŞAAT MÜHENDİSLİĞİ ANA BİLİM DALI

KARAYOLU TÜNELLERİNDE SÜRÜCÜ DAVRANIŞLARININ SİMÜLATÖR DESTEKLİ ANALİZİ VE YAPAY ZEKÂ TEKNİKLERİYLE İNCELENMESİ

SIMULATOR-BASED ANALYSIS AND ARTIFICIAL INTELLIGENCE EXAMINATION OF DRIVER BEHAVIORS IN ROAD TUNNELS

DOKTORA

Ömer Faruk ÖZTÜRK

Danışman: Dr. Öğr. Üyesi Emine ÇORUH

ARALIK-2024
GÜMÜŞHANE

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Doktora Tezi olarak hazırlamış olduğum "**Karayolu Tünellerinde Sürücü Davranışlarının Simülatör Destekli Analizi ve Yapay Zekâ Teknikleriyle İncelenmesi"** isimli bu tezimin, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi, alıntı yaptığım tüm çalışmaları kaynakçada belirtiğimi ve Gümüşhane Üniversitesi'nin lisanslı kullanıcısı olduğu intihal yazılım programı ile Lisansüstü Eğitim Enstitüsü'nün belirlediği kıstaslara uygun olarak raporladığımı taahhüt ederim. Tezimin kâğıt ve elektronik kopyalarının Gümüşhane Üniversitesi Lisansüstü Eğitim Enstitüsü arşivinde saklanmasına izin verdiğimi onaylarım.

Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

25/12/2024

…….

Ömer Faruk ÖZTÜRK

TEŞEKKÜR

Bu doktora tezi çalışmasının planlanması, yürütülmesi ve sonuçlandırılması sürecindeki değerli akademik rehberlikleri ve bilimsel katkıları için tez danışmanlarım Sayın Dr. Öğr. Üyesi Emine ÇORUH ve Sayın Doç. Dr. Metin Mutlu AYDIN'a en derin şükranlarımı sunarım. Çalışmanın yürütülmesinde kritik öneme sahip laboratuvar altyapısını sağlayan, deneysel çalışmaların gerçekleştirilmesine imkân tanıyan ve akademik bilgi ve deneyimleriyle katkı veren Sayın Doç. Dr. Halim Ferit BAYATA'ya, tez izleme sürecindeki yapıcı değerlendirmeleri ve destekleri için tez izleme komitesi üyelerine ve tezin nihai halini almasında değerli görüşlerini paylaşan jüri üyelerine içten teşekkürlerimi sunarım.

Bu araştırmanın gerçekleştirilmesinde sağladıkları finansal desteklerle çalışmanın kapsamını genişleten TÜBİTAK'a (Proje No: 1002/123M190), Gümüşhane Üniversitesi BAP Koordinatörlüğü'ne (GÜBAP02/22.F5110.02.01 ve GÜBAP07/22.E0111.07.01) ve Erzincan Binali Yıldırım Üniversitesi BAP Koordinatörlüğü'ne (FBA-2022-813) teşekkürlerimi sunarım. Laboratuvar çalışmalarındaki değerli iş birliği ve akademik dayanışması için araştırma arkadaşım Öğr. Gör. Yusuf MAZLUM'a özel teşekkürlerimi iletmek isterim.

Maddi ve manevi tüm destekleriyle bu günlere gelmemde büyük katkısı olan ve mühendislik konusunda kendime örnek aldığım çok kıymetli babam Rıfat ÖZTÜRK'e annem Ayşe ÖZTÜRK'e, bilgi ve tecrübelerinden hayatımın her aşamasında faydalanacağım çok değerli abim Gabil POLAT'a, kardeşlerim Betül, Bünyamin ve Muhammed ÖZTÜRK'e, bu akademik yolculukta gösterdiği sonsuz anlayış, sabır ve destek için sevgili eşim Kübra ÖZTÜRK'e oğlum Ömer Ali ve kızım Ayşe Kübra'ya tüm kalbimle teşekkür ederim. Onların varlığı, bu akademik başarıya ulaşmamda en büyük motivasyon kaynağım olmuştur.

Ömer Faruk ÖZTÜRK
GÜMÜŞHANE-2024

ÖZET

Günümüz ulaşım ağlarının önemli bileşeni olan karayolu tünelleri, özellikle artan nüfus ve ticaret hacmiyle birlikte stratejik önem kazanmaktadır. Tüneller, engebeli coğrafya ve iklim koşullarında güvenli ulaşım sağlarken şehir içi geçişlerde yol genişletmeye alternatif olarak çevresel tahribatı ve kamulaştırma maliyetlerini azaltmaktadır. Bu yapılar, trafik akışını hızlandırarak hem şehir içi hem de şehirlerarası ulaşımın verimliliğini artırmakta ve çevresel sürdürülebilirliğe katkı sağlamaktadır. Araştırmalar, tünellerde kaza sıklığının açık yollara göre daha düşük olmasına rağmen meydana gelen kazaların şiddetinin daha yüksek olduğunu göstermektedir. Bu durum, tünellerde daha kapsamlı güvenlik önlemleri alınmasını gerektirmektedir.

Bu çalışmada, simülatör tabanlı bir deney yapılmış, sürücü davranışları analiz edilmiş ve yapay zekâ teknikleriyle incelenmiştir. Araştırma, 134 katılımcının 12 senaryoda test edildiği, üç aşamalı bir veri toplama sürecini içermektedir. İlk aşamada demografik bilgiler toplanmış, ikinci aşamada simülatör sürüşleri yaptırılarak sürüş metrikleri toplanmış ve üçüncü aşamada sürücülerin performansları simülatör performans ölçeği anketiyle ölçülmüştür. Bu çalışma kapsamında geliştirilen InTunn.Ai yazılımıyla tüm veri analizleri ve risk değerlendirmesi gerçekleştirilmiştir. Boyut indirgeme analizi sonucunda, toplam varyansın %91.2'sini açıklayan 6 temel bileşen tespit edilmiştir. Daha sonra, hiperparametre optimizasyonu uygulanarak %92.31 doğruluk oranına sahip bir sınıflandırma modeli geliştirilmiştir. Bu model, sürücüleri risksiz, orta riskli ve riskli olmak üzere 3 kategoriye ayırmaktadır. Elde edilen bulgular, ani hızlanma ve frenleme, şerit değiştirme sıklığı, hız limiti uyumu ve yanal şerit sapmalarını başlıca ayırt edici risk faktörleri olarak öne çıkmıştır.

Sonuç olarak, bu çalışmanın, karayolu trafik güvenliği alanında literatüre önemli katkılar sunacağı ve gelecekteki araştırmalarda sürücü davranışlarının daha etkin analiz edilmesine ve risk sınıflandırma modellerinin geliştirilmesine sağlam bir temel oluşturacağı düşünülmektedir.

Anahtar Kelimeler: Karayolu tünelleri, Sürücü davranışları, Sürüş simülatörü, Yapay zekâ

SUMMARY

Road tunnels, a critical component of modern transportation networks, have gained strategic importance, particularly with the increasing population and trade volume. Tunnels provide safe transportation in challenging topographies and climatic conditions, while also offering an alternative to road widening in urban areas by reducing environmental degradation and expropriation costs. These structures enhance traffic flow, thereby improving the efficiency of both urban and intercity transportation and contributing to environmental sustainability. Research shows that although the frequency of accidents in tunnels is lower compared to open roads, the severity of accidents tends to be higher, necessitating more comprehensive safety measures in tunnels.

In this study, a simulator-based experiment was conducted to analyze driver behaviors and investigate them using artificial intelligence techniques. The research involved a three-stage data collection process, where 134 participants were tested across 12 scenarios. In the first stage, demographic data were collected; in the second stage, driving metrics were gathered through simulator drives; and in the third stage, driver performance was assessed using a simulator performance scale questionnaire. All data analysis and risk assessment processes were carried out using the InTunn.Ai software developed within this study. Through dimensionality reduction analysis, six key components explaining 91.2% of the total variance were identified. Subsequently, a classification model with a 92.31% accuracy rate was developed using hyperparameter optimization. This model categorizes drivers into risk-free, moderate-risk, and high-risk groups. The findings identified abrupt acceleration and braking, lane-changing frequency, compliance with speed limits, and lateral lane deviations as primary distinguishing risk factors.

In conclusion, this study not only contributes to the literature on road traffic safety but also serves as a foundation for future research to analyze driver behaviors more effectively and develop advanced risk classification models.

Keywords: Highway tunnel, Driver behaviors, Driving simulator, Artificial intelligence

İÇİNDEKİLER

KABUL VE ONAY III
BİLİMSEL ETİĞE UYGUNLUK BEYANI IV
TEŞEKKÜR V
ÖZET VI
SUMMARY VII
İÇİNDEKİLER VIII
TABLOLAR DİZİNİ X
ŞEKİLLER DİZİNİ XII
EKLER DİZİNİ XV
SİMGELER VE KISALTMALAR DİZİNİ XVI
1. GİRİŞ 1
1.1. Ulaştırma Sektörü ve Karayolu Tünelleri 1
1.2. Türkiye'nin Karayolu Tünel Envanteri 2
1.3. Tünel Güvenliği 4
1.4. Simülatör Teknikleri ve Yapay Zekâ Uygulamaları 6
1.5. Problemin Tanımı 7
1.6. Çalışmanın Amacı, Kapsamı ve Hedefleri 8
1.7. Akıllı Ulaşım Sistemleri, Yapay Zekâ ve Ulusal Stratejiler 9
1.7.1. Akıllı Ulaşım Sistemleri 9
1.7.2. Ulusal AUS Strateji Belgesi 11
1.7.3. Ulusal Yapay Zekâ Stratejisi 12
1.8. Tahmin, Sınıflandırma ve Kümeleme Yöntemleri 13
2. LİTERATÜR TARAMASI 15
3. MATERYAL ve YÖNTEM 25
3.1. Deneysel Ortam ve Simülatör Sistemi 25
3.2. Katılımcılar ve Model Tasarımı 29
3.2.1. Katılımcılar 29
3.2.2. Model Tasarımı 29
3.2.3. Sürüş Senaryoları 33
3.3. InTunn.Ai Yazılımı 45
3.4. Veri Toplama Yöntemleri 49
3.4.1. Anket Verilerinin Toplanması 49

3.4.2. Simülatör Verilerinin Toplanması 50
3.5. Makine Öğrenmesinin Tanımı ve Uygulama Alanları 51
3.5.1. Denetimli Öğrenme 52
3.5.2. Denetimsiz Öğrenme 53
3.5.3. Pekiştirmeli Öğrenme 54
3.6. Denetimli Öğrenme Yöntemiyle Sınıflandırma 55
3.6.1. Veri Etiketleme 55
3.6.2. Veri Ön İşleme 59
3.6.3. Öznitelik Mühendisliği 63
3.6.4. Boyut İndirgeme 64
3.6.5. Sınıflandırma 66
3.6.6. Hiperparametre Optimizasyonu 69
3.6.7. Model Performans Değerlendirmesi 70
3.6.8. Model Karşılaştırması 73
3.6.9. SHAP Analizi 74
4. BULGULAR ve TARTIŞMA 75
4.1. Anket Sonuçları 75
4.2. Veri Keşfi 80
4.3. Etiketleme Sistemine Dayalı Sınıflandırma Sonuçları 88
4.4. Simülatör Verilerinin İrdelenmesi 90
4.5. Denetimli Öğrenme Yöntemiyle Sınıflandırma 106
4.5.1. Öznitelik Seçimi 106
4.5.2. Veri Standardizasyonu 112
4.5.3. Boyut İndirgeme 113
4.5.4. Sınıflandırma Performanslarının Değerlendirilmesi 119
4.5.5. Hiperparametre Optimizasyonu 123
4.5.6. Hiperparametre Optimizasyonu Sonrası Performans Değerlendirmesi 124
4.5.7. Karar Sınırları ve Tahmin Güvenilirliği 134
4.5.8. Özniteliklerin Model Üzerindeki Etkisinin İrdelenmesi 139
5. SONUÇLAR ve ÖNERİLER 144
KAYNAKÇA 145
EKLER 157
ETİK KURUL KARARI 166
ÖZGEÇMİŞ 167

TABLOLAR DİZİNİ

Tablo 1. Türkiye yol ağı ve tünel envanteri (KGM, 2024) 3
Tablo 2. Tünellerde aydınlatma ortamını etkileyen faktör ağırlıkları (Niu vd., 2022) ... 15
Tablo 3. İndirgeme sonrasında elde edilen kategoriler (Abdelrahman vd., 2022) 23
Tablo 4. Model performans sonuçları (Abdelrahman vd., 2022) 23
Tablo 5. İncelenen temel konular ve modeldeki yerleri 33
Tablo 6. Yazılım tarafından kaydedilen sürüş verisi örneği 50
Tablo 7. İlgili kanun ve yönetmeliklerden hız ve şerit disiplini ile ilgili olan kriterler .. 56
Tablo 8. Sürücü puanlama sistemi 58
Tablo 9. Farklı boyut indirgeme tekniklerinin karşılaştırılması 65
Tablo 10. Katılımcıların cinsiyet, yaş, ehliyet yılı ve kaza geçmişine göre dağılımı 75
Tablo 11. Yaş ve ehliyet yılı ile ilgili bilgiler 76
Tablo 12. Sürücülerin gerçek koşullardaki görüşleri 76
Tablo 13. Simülatör performans ölçeği bulguları 78
Tablo 14. Simülatör verilerine ilişkin tanımlayıcı istatistikler 81
Tablo 15. Farklı tünel kesimlerindeki ortalama hızların Saphiro-Wilk normallik testi sonuçları 82
Tablo 16. Her bir senaryo için giriş, merkez, çıkış hızlarının tanımlayıcı istatistik sonuçları 82
Tablo 17. Her bir senaryo için giriş, merkez, çıkış hızlarının Saphiro-Wilk normallik testi sonuçları 84
Tablo 18. Senaryo bazlı ortalama hız değişimlerinin Friedman test sonuçları 86
Tablo 19. Spearman korelasyon testi sonuçları 87
Tablo 20. Çevre yolu tünelleri ve Zigana tüneli ortalama hızlarına ilişkin tanımlayıcı istatistikler 92
Tablo 21. Özniteliklere ilişkin tanımlayıcı istatistikler 107
Tablo 22. Öznitelikler arası korelasyon değerleri 109
Tablo 23. VIF analizi sonuçları 110
Tablo 24. Özniteliklerin Saphiro-Wilk normallik testi sonuçları 111
Tablo 25. Standardizasyon öncesi ve sonrası tanımlayıcı istatistikler 113
Tablo 26. Optimum bileşen sayısının belirlenmesi için hesaplanan metrikler 116
Tablo 27. Elde edilen bileşenlerin eski özniteliklerle ilişkisi 117
Tablo 28. Oluşturulan yeni bileşenlerin tanımlanması ve isimlendirilmesi 119

Tablo 29. Modellerin temel hiperparametrelerle elde edilen performans metrikleri 121
Tablo 30. Modeller için en iyi hiperparametreler 123
Tablo 31. Modellerin optimizasyon sonrası performans metrikleri 126
Tablo 32. Hiperparametre optimizasyonunun modeller üzerindeki etkisi 133

ŞEKİLLER DİZİNİ

Şekil 1. Uzunluklarına göre tünel sayıları (KGM, 2024).....2
Şekil 2. Zigana ve Ovit tünellerinin coğrafi konumları 4
Şekil 3. AUS'un temel unsurları 10
Şekil 4. Tünellerin konumları ve yerleşim planları (H. Zheng vd., 2024).....16
Şekil 5. Çin'de inşa edilen karayolu tünelleri için örnek modeller (Su vd., 2023).....17
Şekil 6. Chongqing Baomao otoyolunda bulunan farklı uzunluktaki tünellerin konumları (Shang vd., 2024).....19
Şekil 7. Tünel yan duvar desenleri (Zhao vd., 2022).....20
Şekil 8. Laboratuvara ait görüntü (Zhao vd., 2022).....20
Şekil 9. Farklı kıvrımlama tasarımlarının hız azaltma etkileri (Akgöl vd., 2022).....21
Şekil 10. Araştırma konusuyla alakalı makalelerin anahtar kelime bulutu.....22
Şekil 11. XGBoost modelinin her iki sınıfı için SHAP değerlerinin özet grafiği (Ullah vd., 2023) 24
Şekil 12. Laboratuvar ortamının şematik gösterimi.....26
Şekil 13. Otonom sürüş teknikleri ve sürücü davranışları tespit laboratuvarı 26
Şekil 14. Projeksiyon cihazlarının görüntü aktarım örneği.....28
Şekil 15. Projeksiyon perdesi.....28
Şekil 16. Simülasyon başlangıç ekranı.....29
Şekil 17. Model için seçilen tünellerin konumları 30
Şekil 18. Gümüşhane çevre yolu tünellerinin konumları.....30
Şekil 19. İlgili tünellerin modeldeki şematik gösterimi 31
Şekil 20. Zigana Tüneli model tasarımı 31
Şekil 21. Zigana Tüneli model tasarımı 32
Şekil 22. T4 Tüneli model tasarımı.....32
Şekil 23. T3 Tüneli model tasarımı.....32
Şekil 24. T2 Tüneli model tasarımı.....33
Şekil 25. Aydınlatma senaryosunun gerçek koşullardaki durumu.....34
Şekil 26. Aydınlatma senaryosunun şematik gösterimi 35
Şekil 27. Düşük aydınlatmalı tünelden yüksek gün ışığı koşullarına çıkış.....35
Şekil 28. Yüksek gün ışığı koşulundan düşük aydınlatmalı tünele giriş.....35
Şekil 29. Ağır taşıt senaryosunun gerçek koşullardaki durumu.....36
Şekil 30. Ağır taşıt senaryosunun şematik gösterimi 36

Şekil 31. Tünel içinde ağır taşıt ile karşılaşma 37
Şekil 32. Tünel girişinde ağır taşıt ile karşılaşma 37
Şekil 33. Uzun tünel sürüşü senaryosunun şematik gösterimi 38
Şekil 34. Kesikli tünel senaryosunun gerçek koşullardaki durumu 38
Şekil 35. Kesikli tünel senaryosunun şematik gösterimi 39
Şekil 36. Kesikli tünel senaryosunun modeldeki durumu 39
Şekil 37. Geçiş manevrası senaryosunun şematik gösterimi 39
Şekil 38. Geçiş manevrası senaryosunun modeldeki durumu 40
Şekil 39. Mevcut durumdaki mavi tavan aydınlatması uygulaması 41
Şekil 40. Modeldeki mavi tavan uygulaması 41
Şekil 41. Kırmızı tavan aydınlatması senaryosunun şematik gösterimi 42
Şekil 42. Kırmızı tavan aydınlatması uygulaması 42
Şekil 43. Sağ şeritte duran bakım aracı uygulaması 43
Şekil 44. Yeşil tavan aydınlatması uygulaması 43
Şekil 45. Tünel içi LED tabanlı trafik uyarı sisteminin şematik gösterimi 44
Şekil 46. Tünel içi LED tabanlı trafik uyarı sisteminin modeldeki uygulaması 44
Şekil 47. Kırmızı tavan aydınlatmasının modeldeki durumu 44
Şekil 48. Şerit kapatma uygulamasının modeldeki durumu 45
Şekil 49. Şerit açma ve yeşil tavan aydınlatması uygulamasının modeldeki durumu 45
Şekil 50. InTunn.Ai programının arayüzü 46
Şekil 51. İstatistiksel veri analizi modülü 47
Şekil 52. Yapay zekâ tabanlı analizler modülü 47
Şekil 53. Araç entegrasyon modülü 48
Şekil 54. Yapay zekâ tabanlı dinamik yönetim sistemi modülü 49
Şekil 55. Sürüş seviyesi ve sürüş tarzı dağılımı 77
Şekil 56. Aykırı değer gözlemlenen değişkenlerin dağılımı 80
Şekil 57. Puanlama sistemine dayalı sonuçlar 89
Şekil 58. Sürücülerin ortalama hız dağılımı 90
Şekil 59. Sürücülerin çevre yolu tünellerindeki hız dağılımı 91
Şekil 60. Sürücülerin Zigana Tünelindeki hız dağılımı 92
Şekil 61. Farklı uzunluktaki tünellerin ortalama hız dağılımları 93
Şekil 62. Tünellerin farklı kesimlerindeki ortalama hız dağılımı 94
Şekil 63. Senaryoların (1-6) giriş-merkez-çıkış hızlarının dağılımı 95
Şekil 64. Senaryoların (7-12) giriş-merkez-çıkış hızlarının dağılımı 97
Şekil 65. Tüneller ve açık yollardaki hızların ilişkisi 99

Şekil 66. Ortalama hız, ani hızlanma ve sert frenleme arasındaki ilişki 101
Şekil 67. Ortalama hız ve şerit değişim sayısı arasındaki ilişki 102
Şekil 68. Ortalama hız ile YMSS arasındaki ilişki 103
Şekil 69. Sürücülerin cinsiyet ile tünel ortalama hızları arasındaki ilişki 104
Şekil 70. Sürücülerin ehliyet yılı ile tünel ortalama hızları arasındaki ilişki 104
Şekil 71. Sürücülerin güzergâh tecrübesi ile ortalama hızları arasındaki ilişki 105
Şekil 72. Sürücülerin kaza geçmişi ile ortalama hızları arasındaki ilişki 106
Şekil 73. Öznitelikler arası dağılımlar 111
Şekil 74. Bileşen sayısına göre AIC ve BIC değerleri 114
Şekil 75. Bileşen sayısına göre rekonstrüksiyon hatası 115
Şekil 76. Bileşen sayısına göre kümülatif açıklanan varyans 115
Şekil 77. Çekirdek matrisinin özdeğerleri 116
Şekil 78. Modellerin temel hiperparametrelerle elde edilen karmaşıklık matrisleri 120
Şekil 79. Modellerin eğitim-test doğruluğu karşılaştırması 123
Şekil 80. Optimizasyon sonrası karmaşıklık matrisleri 125
Şekil 81. LR modeli ROC eğrisi 128
Şekil 82. RF modeli ROC eğrisi 128
Şekil 83. NB modeli ROC eğrisi 129
Şekil 84. KNN modeli ROC eğrisi 129
Şekil 85. SVM modeli ROC eğrisi 130
Şekil 86. Modellerin eğitim-test doğruluğu karşılaştırması 131
Şekil 87. Modellerin öğrenme eğrileri 132
Şekil 88. HSI ve GI1 karar sınırları 135
Şekil 89. HSI ve SHI karar sınırları 136
Şekil 90. HSI ve GI1 karar sınırları ve tahmin güvenilirliği 137
Şekil 91. HSI ve SHI karar sınırları ve tahmin güvenilirliği 138
Şekil 92. Özniteliklerin risksiz sınıfı ayırmadaki etkisi 140
Şekil 93. Özniteliklerin orta riskli sınıfı ayırmadaki etkisi 140
Şekil 94. Özniteliklerin riskli sınıfı ayırmadaki etkisi 140
Şekil 95. Tüm sınıflar için SHAP özet grafiği 141

EKLER DİZİNİ

Ek 1. Sürüş öncesi anket formu 157
Ek 2. Sürüş sonrası anket formu 159

SİMGELER VE KISALTMALAR DİZİNİ

AUS : Akıllı Ulaşım Sistemleri
FN : Karmaşıklık matrisi, yanlış negatif
FP : Karmaşıklık matrisi, yanlış pozitif
GI1 : Genel indeks 1
GI2 : Genel indeks 2
HDI : Hız disiplini indeksi
HSI : Hız ve şerit disiplini indeksi
IMI : İvmelenme indeksi
KDA : Çekirdek fonksiyonlu lineer diskriminant analizi
KGM : Karayolları Genel Müdürlüğü
KNN : k-En yakın komşu algoritması
LDA : Lineer diskriminant analizi
LR : Lojistik regresyon algoritması
NB : Naive bayes algoritması
PCA : Temel bileşen analizi
RF : Rastgele orman algoritması
ROC : Alıcı işletim karakteristiği eğrisi
SHI : Senaryolar hız indeksi
SVM : Destek vektör makineleri algoritması
TN : Karmaşıklık matrisi, doğru negatif
TP : Karmaşıklık matrisi doğru pozitif
UYZS : Ulusal yapay zekâ stratejisi
YMSS : Yanal mesafe standart sapması
z : Standardize edilmiş veri.
μ : Veri kümesinin ortalaması.
σ : Veri kümesinin standart sapması.

1. GİRİŞ

1.1. Ulaştırma Sektörü ve Karayolu Tünelleri

Ulaştırma sektörü, ekonomik kalkınmanın itici gücü olarak işlev görmekte olup devletin düzenleyici rolü bu alanda büyük önem taşımaktadır (Bayliss, 1998). Gelişmiş ulaşım altyapısı, ticaretin ve sanayileşmenin hızlanmasına olanak tanımakta ve bu da nüfusun ihtiyaç duyduğu hizmetlere erişimini artırarak yaşam kalitesini yükseltmektedir (Rezvani vd., 2015). Dünya nüfusunun 7.8 milyarı aştığı günümüzde, ulaşım sistemlerine olan talep önemli ölçüde artmış ve bu sistemlerin sürdürülebilir şekilde geliştirilmesini zorunlu kılmıştır (Erdoğan, 2016). Bu durum ulaştırma hizmetlerinin kalitesinin, hızının ve etkinliğinin iyileştirilmesini de gerekli kılmaktadır. Ulaştırma sektörünün sosyal ve ekonomik işlevleri, şehirlerin büyümesine ve kırsal alanların kalkınmasına katkı sağlayarak toplumsal dengeyi ve refahı da artırmaktadır (Erdoğan, 2016).

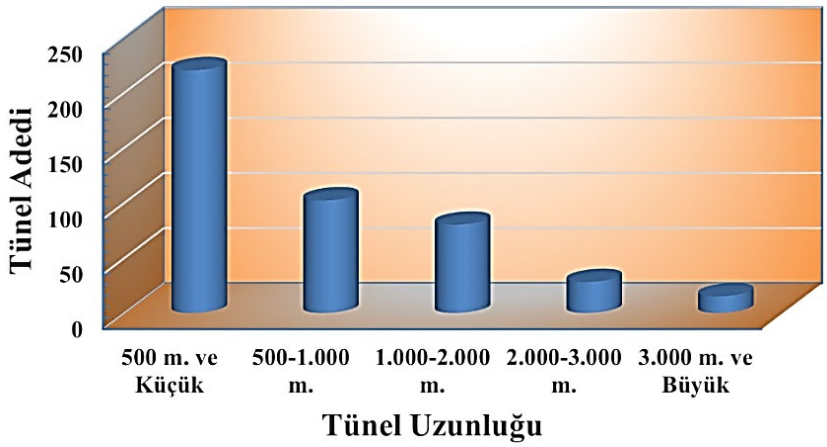
Karayolu tünelleri, modern ulaşım ağlarının kritik ve vazgeçilmez bileşenleri arasında yer almaktadır. Dünya nüfusundaki hızlı artış ve uluslararası ticari faaliyetlerin genişlemesi karayolu ağlarının yaygınlaşmasını ve kapasite artışına olan ihtiyacı önemli ölçüde artırmıştır (Koçhan, 2021). Bu gelişmeler özellikle engebeli ve dağlık coğrafi bölgelerdeki ulaşımın sağlanmasında karayolu tünellerinin stratejik bir rol üstlenmesine neden olmuştur. Ayrıca olumsuz iklim koşullarının yol güvenliği ve sürekliliği üzerindeki etkilerini minimize etmesi nedeniyle karayolu tünellerinin önemi giderek artmaktadır. Bu yönleriyle karayolu tünelleri, coğrafi ve iklimsel zorluklara karşı etkili çözümler getirerek karayolu taşımacılığının güvenilirliğini ve verimliliğini artırmaktadır (Koçhan, 2021).

Ulaşım planlamasında maliyet, güvenlik ve çevresel etkiler gibi temel kavramlar kritik bir rol oynamaktadır. Şehirlerarası ulaşım ihtiyacının artmasıyla birlikte şehir içi ulaşım ağlarında da trafik yükü önemli ölçüde artmaktadır. Bu yükü hafifletmek amacıyla şehir içi yolların genişletilmesi sıklıkla başvurulan bir yöntemdir. Ancak bu tür yol genişletme projelerinin çevreye olumsuz etkileri bulunmakta ve kamulaştırma maliyetlerini de önemli ölçüde artırmaktadır (Aydınoğlu vd., 2024). Bu bağlamda, şehirlerarası ulaşımın güvenliğini ve konforunu artırmak amacıyla şehir içi yolların genişletilmesi yerine çevresel etkileri en aza indiren tünelli geçişlerin tercih edilmesi daha uygun bir yaklaşım olarak değerlendirilmektedir (Ceci vd., 2013).

Tünelli geçişlerin tercih edilmesi çevresel tahribatı minimize ederken mevcut şehir dokusunu koruma ve kamulaştırma maliyetlerini azaltma konusunda da avantaj sağlamaktadır (Lopez vd., 2014). Ayrıca tünellerin trafik akışını hızlandırarak yolculuk süresini kısaltması hem şehir içi hem de şehirlerarası ulaşımın verimliliğini artırmakta ve genel ulaşım kapasitesine olumlu katkılarda bulunmaktadır. Bu tür altyapı yatırımları uzun vadede ekonomik ve çevresel sürdürülebilirliği destekleyen stratejik bir çözüm olarak öne çıkmaktadır (Namin vd., 2014).

1.2. Türkiye'nin Karayolu Tünel Envanteri

Son yıllarda tünel yapım teknolojisindeki gelişmeler ve tünellerin sağladığı avantajlar sayesinde Avrupa'da ve özellikle Türkiye'de tünel inşaatlarında büyük bir ivme gözlenmektedir. Modern tünel inşaatları, gelişmiş mühendislik teknikleri ve malzemeleri kullanılarak gerçekleştirilmekte bu da daha uzun ve daha güvenli tünellerin inşa edilmesine olanak tanımaktadır (Koçhan, 2021). Türkiye'nin karayolu tünel envanterine ilişkin veriler Şekil 1'de sunulmaktadır. Bu görselde, tüneller uzunluklarına göre sınıflandırılmış ve her bir uzunluk kategorisine karşılık gelen tünel sayıları belirtilmiştir.



Şekil 1. Uzunluklarına göre tünel sayıları (KGM, 2024).

Türkiye'deki karayolu tünellerinin uzunluklarına göre dağılımı incelendiğinde, tünellerin büyük bir kısmının 500 metre ve daha küçük uzunluk kategorisinde yer aldığı görülmektedir. Karayolları Genel Müdürlüğü (KGM) verilerine göre Türkiye'nin yol ağı ve tünel envanterine ait bilgiler Tablo 1'de verilmiştir. Doğu Karadeniz Bölgesi'nde yer alan Trabzon, Gümüşhane, Artvin, Rize, Giresun ve Bayburt illeri, KGM 10. Bölge

Müdürlüğü'nün sorumluluğundadır. Bölgedeki toplam yol ağı Türkiye genelindeki toplam yol ağının %5.43'ünü oluşturmaktadır.

Tablo 1. Türkiye yol ağı ve tünel envanteri (KGM, 2024)

Bölge Müdürlüğü	Yol Ağı (km)				Toplam Tünel Adedi	Toplam Uzunluk	Bölge Tünel Uzunluğunun Bölge Yol Ağına Oranı
	Otoyol	Devlet Yolu	İl Yolu	Toplam			
1.	1143	2023.80	1055.20	4222.00	8	10.68	0.25%
2.	629	2478.00	2610.60	5717.60	4	14.50	0.25%
3.		2456.60	3040.60	5497.20	3	1.87	0.03%
4.	486	1892.10	1673.40	4051.50	2	4.02	0.01%
5.	640	2149.40	2657.40	5446.80	28	56.91	1.05%
6.	354	1790.60	2290.10	4434.70	0	0.00	0.00%
7.		2227.00	2323.30	4550.30	58	65.67	1.44%
8.		1450.40	2514.60	3965.00	16	21.06	0.53%
9.	146	2045.00	2653.00	4844.00	9	6.67	0.14%
10.		**1445.00**	**2283.40**	**3728.40**	**200**	**295.06**	**7.91%**
11.		1386.00	2239.00	3625.00	17	12.56	0.35%
12.		1518.20	690.00	2208.20	20	22.75	1.03%
13.		1919.00	1571.00	3490.00	22	29.91	0.86%
14.	328	2416.70	2483.40	4958.10	5	18.55	0.37%
15.		1473.60	1522.20	2995.80	46	41.96	1.40%
16.		1512.90	1918.60	3431.50	7	5.16	0.15%
18.		949.00	539.00	1488.00	0	0.00	0.00%
Toplam	**3726**	**31133.30**	**34064.80**	**68654.10**	**445**	**607.33**	**0.89%**

Toplam tünel uzunluğu 607.33 kilometre (km) olup bu uzunluk Türkiye genelindeki toplam yol ağına oranlandığında %0.89'luk bir değer ortaya çıkmaktadır. 10. Bölge Müdürlüğü, 200 tünel ve 295.06 km toplam tünel uzunluğu ile diğer bölge müdürlüklerinden belirgin şekilde ayrılmaktadır. Toplam yol ağına göre tünel uzunluğunun en yüksek oranına sahip olan bölge yine 10. Bölge Müdürlüğü olup bu oran %7.91 olarak hesaplanmıştır. Bu durum, bölgenin tünel kullanımına dayalı bir yol altyapısına ağırlık verdiğini göstermektedir. Bölgenin dağlık ve geçişi zor arazi yapısı nedeniyle önemli tünel projeleri bu bölgede yoğunlaşmıştır (Şekil 2).



Şekil 2. Zigana ve Ovit tünellerinin coğrafi konumları

Trabzon Gümüşhane il sınırları içinde kalan Yeni Zigana Tüneli, tek tüp 14476 metre uzunluğuyla Avrupa'nın birinci, dünyanın ise üçüncü en uzun çift tüp tüneli olarak bu bölgede bulunmaktadır. Rize Erzurum il sınırları içinde kalan Ovit Tüneli ise, 14300 metre uzunluğuyla Avrupa'nın ikinci, dünyanın ise dördüncü en uzun tünelidir ve yine bu bölgede yer almaktadır.

1.3. Tünel Güvenliği

Türkiye'nin, ulaşımının büyük bir bölümünü karayolları üzerinden sağladığı göz önüne alındığında tünel güvenliği konusuna daha fazla odaklanılması gerektiği ortaya çıkmaktadır. Karayollarında tünel güvenliğini sağlamak, yalnızca altyapı tedbirleriyle sınırlı kalmayıp güvenlik ekipmanlarının temini ve kamu bilincinin artırılmasına yönelik geniş kapsamlı bir yaklaşımı zorunlu kılmaktadır (Erdem, 1994). Tünel güvenliğinin fiziksel yapılar ve teknolojik donanımların yanı sıra yasal düzenlemeler ve toplumun bilinçlendirilmesiyle de desteklenmesi gerekmektedir. Bu bağlamda Türkiye'nin tünel güvenliği konusunda bütüncül bir strateji geliştirerek uluslararası standartlarla uyumlu hale gelmesi büyük önem arz etmektedir (Sinoplu, 2007).

Tünellerin tasarım ve inşasında sürücü güvenliği ile ulaşım konforu ön planda tutulmaktadır. Ancak tünellerin kapalı alanlar olması ve aydınlatma sistemlerinin iyi ayarlanmış olmaması sürücülerde stres ve görsel-işitsel sorunlara yol açabilmektedir. Bu durum sürüş güvenliğini doğrudan olumsuz etkileyen bir faktör olarak karşımıza

çıkmaktadır. Tünel içindeki trafik kazaları genellikle zincirleme şekilde meydana gelmekte, sınırlı kaçış alanları ve düşük görüş mesafesi nedeniyle daha ciddi sonuçlar doğurabilmektedir (Manseer vd., 2014). Bu nedenle, karayolu tünellerinde meydana gelen trafik kazalarının nedenlerini tespit etmek, tünel güvenliği açısından büyük bir öneme sahiptir. Tünel kazaları, açık yollarda meydana gelen kazalardan farklı dinamiklere sahiptir ve bu farklılıklar tünel tasarımında özel güvenlik önlemlerinin alınmasını zorunlu kılmaktadır. Özellikle tünel içinde meydana gelen kazalar, sınırlı alan, yetersiz havalandırma ve acil durumlara müdahale imkânlarının kısıtlı olması nedeniyle daha büyük riskler taşımaktadır (Çubuk vd., 2008). Bu nedenle tünel güvenliğini artırmak için kazaların nedenlerine dair kapsamlı bir araştırma ve analiz yapılması gerekmektedir.

Karayolu tünellerinde meydana gelen trafik kazalarının gerçekleşme türleri oldukça karmaşıktır. Kaza nedensellik teorisine göre karayolu tünel trafik sistemi, insanlar, araçlar, yollar, çevre ve yönetimden oluşan karmaşık bir sistem olarak tanımlanmaktadır (Danišovič vd., 2015). Bu beş faktör birbirleriyle uyum içinde ve sürekli etkileşim halindedir. Eğer bu faktörlerden herhangi birinde potansiyel bir tehlike mevcutsa sistemin güvenliği olumsuz etkilenerek kazalara neden olabilmektedir (Hu ve Lei, 2016). Dolayısıyla tünel trafik kazaları bu faktörlerin dengesizleştiği bir süreç olarak ortaya çıkmaktadır. Bu faktörler arasında insan faktörü, kazaların yaklaşık %80'ini oluşturmaktadır. Tehlikeli insan davranışları belirli bir zaman ve mekânda insanın yeteneklerinin sistemin gereksinimlerini karşılayamaması durumunda ortaya çıkan davranış özellikleri olarak tanımlanmaktadır (Hu ve Lei, 2016). Sürücülerin hız, dikkat ve manevra kabiliyetlerindeki yetersizlikler gibi nedenler kazalara yol açabilmektedir. Tünel kazalarının karmaşık yapısı sürücülerin tünel ortamına uyum sağlayamadığı anlarda daha belirgin hale gelmektedir. Özellikle tünel içindeki düşük görüş mesafesi, dar alanlar ve kapalı ortamların yarattığı stres, sürücü hatalarını artırarak kazalara neden olabilmektedir (Rudin Brown vd., 2013).

Tarihte yaşanan büyük tünel kazaları, insan davranışlarının kazalara etkisini açıkça göstermektedir (X. Zhou vd., 2022). Örneğin 1999 yılında meydana gelen Mont Blanc Tüneli Yangını, bir kamyon sürücüsünün yanıcı maddeler taşıyan aracını kontrol edememesi ve yangını fark ettikten sonra uygun müdahaleyi yapamaması sonucu 39 kişinin hayatını kaybettiği bir felakete dönüşmüştür (URL-1, 2023). Bu olay insan hatalarının tünel kazalarında ne denli kritik rol oynayabileceğinin trajik bir örneğidir. Benzer şekilde Gotthard Tüneli Kazası (2001), bir kamyon sürücüsünün dikkat eksikliği sonucu tünel içinde şerit ihlali yapmasıyla başlamış ve çıkan yangın 11 kişinin ölümüne neden olmuştur (URL-2, 2023). Bu kaza, sürücülerin tünel içindeki davranışlarının

önemini bir kez daha gözler önüne sermektedir. İnsan faktörlerinin yanı sıra Kaprun Tüneli Yangını (2000) gibi kazalar sadece sürücü davranışlarıyla sınırlı kalmamakta, aynı zamanda tünel içindeki yolcuların acil durumlarda nasıl hareket etmeleri gerektiğine dair bilgi eksikliğinin de önemli bir faktör olduğunu göstermektedir. Kaprun'da yangın çıktığında yolcuların hızlı bir şekilde tahliye edilememesi ve kaçış yollarının yetersizliği, felaketin boyutlarını artırarak 155 kişinin hayatını kaybetmesine neden olmuştur (URL-3, 2023). Tünel yangınları nadir gerçekleşmekle birlikte ciddi sonuçlar doğurabilen olaylar arasında yer almakta ve büyük ölçekli doğal afetler, sanayi kazaları ve terörist saldırıları gibi düşük olasılıklı fakat yüksek etkiye sahip olaylar arasında değerlendirilmektedir (Larson vd., 2006).

Geçmişten günümüze meydana gelen trafik kazası verileri trafik güvenliği konusundaki yetersizliklerin ve potansiyel iyileştirme alanlarının belirlenmesi için bir fırsat niteliğindedir. Özellikle tüneller gibi kapalı ve yüksek risk barındıran ortamlarda yaşanan kazalar, trafik yönetim sistemlerinin zayıf yönlerini ortaya koyarak bu alanlardaki güvenlik önlemlerinin daha etkin hale getirilmesi gerektiğini göstermektedir. Geçmiş kazalardan elde edilen veriler ve yapılan analizler, gelecekte benzer kazaların önlenmesine yönelik sistematik iyileştirmelerin yapılmasına olanak tanımaktadır (Du vd., 2023). Bu bağlamda, yaşanması muhtemel olayları önceden tahmin etmek veya simüle etmek daha önleyici bir yaklaşım olarak değerlendirilmektedir. Önleyici yaklaşım, potansiyel riskleri tespit ederek bu olaylar sonucunda ortaya çıkabilecek can ve mal kayıplarını en aza indirmeyi mümkün kılmaktadır. Simülasyonlar ve tahmin sistemleri, olası tehlikeli senaryoların modellenmesiyle güvenlik stratejilerinin daha etkin hale getirilmesine katkı sağlamaktadır (Manigandan, 2024).

1.4. Simülatör Teknikleri ve Yapay Zekâ Uygulamaları

Simülatörler, değişen veya değiştirilmesi planlanan trafik koşullarını güvenli ve kontrollü bir ortamda test etme imkânı sunarak yüksek riskli senaryoların gerçek hayatta tehlikeye neden olmadan incelenmesine olanak sağlamaktadır (Y. Wang vd., 2007). Bu özellikleri nedeniyle simülatör teknolojisi son yıllarda araştırmacıların sürüş performansını nesnel ve tutarlı bir şekilde analiz etmek amacıyla sıkça başvurdukları bir araç haline gelmiştir (Thorslund vd., 2024). Özellikle, tünellerde karşılaşılabilecek tehlikelere sürücülerin nasıl tepki verdiğini incelemek ve alınan önlemlerin etkinliğini değerlendirmek, simülatör çalışmalarının önemli bir odak noktasıdır. Bu analizler, tünel güvenliğini artırmaya ve gelecekteki tünel projelerinde daha güvenli tasarımlar yapılmasına yönelik önemli bilgiler sağlamaktadır. Bu çalışmada, tünellerde değişen

işletim özellikleri ve trafik koşulları gibi farklılıkların sürücü davranışları üzerindeki etkileri simülatör ortamında incelenmiştir. Yüksek riskli sürüş senaryolarını güvenli bir ortamda test etme imkânı sunması sebebiyle literatüre önemli bir katkı sağlaması beklenen bu çalışmada, tünel içi aydınlatma, ağır taşıtlarla karşılaşma ve şerit kapatma gibi faktörlerin sürücü davranışları üzerindeki etkileri irdelenerek yapay zekâ teknikleriyle sürücü sınıflandırması yapılmıştır.

Yapay zekâ teknolojilerinin özellikle dinamik ve tehlikeli sürüş ortamları içeren simülatör çalışmalarında önemli bir rol oynayacağı düşünülmektedir. Yapay zekâ, büyük miktarda veriyi hızlı bir şekilde analiz edebilme ve karmaşık sorunlara yönelik çözümler geliştirme kapasitesiyle sürücü davranışlarının daha kapsamlı bir şekilde incelenmesine olanak tanımaktadır (Adar ve Altan, 2024). Bu teknolojilerin simülatörlerden elde edilen verilerin analizinde kullanılması, sürücülerin belirli senaryolara verdikleri tepkilerin modellenmesine ve gelecekteki sürüş koşullarına yönelik tahminlerin yapılmasına olanak tanımaktadır (Hynes, 2012). Yapay zekâ tabanlı simülasyonlar, sürücü davranışlarının modellenmesi ve tahmin edilmesi açısından önemli avantajlar sunmakta olup bu süreçte elde edilen bulguların, güvenlik standartlarının daha nesnel ve bilimsel temellere dayalı bir şekilde geliştirilmesine katkıda bulunacağı düşünülmektedir.

Bu çalışmada, tünellerdeki sürücü davranışları simülatör ortamında test edilmiş ve makine öğrenmesi yöntemleri kullanılarak sürücü sınıflandırması gerçekleştirilmiştir. Farklı sürüş senaryoları altında, sürücülerin risk alma eğilimleri ve sürüş tarzları gibi değişkenler değerlendirilerek riskli davranışlar tespit edilmiştir. Elde edilen bulguların, güvenlik stratejilerinin ve tünel yönetim sistemlerinin geliştirilmesinde önemli bir rol oynayacağı ve gelecekteki tünel projelerinde güvenlik standartlarının artırılmasına yönelik katkı sağlayacağı öngörülmektedir.

1.5. Problemin Tanımı

Literatürde, tünellerde kaza riskinin açık karayollarına kıyasla daha düşük olduğu ancak meydana gelen kazaların şiddetinin açık yol kazalarına göre daha yüksek olduğu ortaya konulmuştur (Caliendo vd., 2013). Bu durum, tünel kazalarının daha ciddi sonuçlar doğurması nedeniyle daha yüksek düzeyde yapısal ve operasyonel tedbirler alınmasını zorunlu kılmaktadır (Kircher ve Ahlstrom, 2012).

Türkiye'de tünel inşaatlarının sayısındaki hızlı artış, tünel güvenliği konusunu daha da önemli bir hale getirmektedir. Artan tünel sayısıyla birlikte farklı özelliklere sahip tünel uygulamaları ve işletim sistemleri gelişmekte, bu tür yol kesimlerinde güvenliğin sağlanması büyük bir öncelik haline gelmektedir (Koçhan vd., 2023). Tünel trafik

kazalarında sürücü davranışlarının en önemli faktör olduğu göz önüne alındığında, sürücülerin belirli değişkenlere göre kaza risklerinin tahmin edilmesi ve sınıflandırılması, alınacak güvenlik önlemlerinin etkinliğini artırabilecektir.

Bu çalışmada, özellikle dağlık arazi yapısı nedeniyle tünel sayısının hızla arttığı Doğu Karadeniz Bölgesi'ndeki Yeni Zigana Tüneli ve Gümüşhane Çevreyolu Tünelleri seçilmiştir. Bu tünellerde karşılaşılabilecek potansiyel tehlikeleri içeren 12 farklı senaryo oluşturularak simülatör ortamında sürücü tepkileri analiz edilmiştir. Senaryolar arasında ağır taşıtlarla karşılaşma, tünel içi aydınlatma değişiklikleri ve hız ihlalleri gibi durumlar yer almakta, bu analizler ile sürücülerin sınıflandırılması ve güvenlik önlemlerinin daha stratejik bir şekilde planlanması amaçlanmaktadır.

Dünya genelinde ve Türkiye'de Akıllı Ulaşım Sistemlerine (AUS) olan ilgi giderek artmaktadır. Bu sistemler, trafik güvenliğini artırmanın yanı sıra ulaşım verimliliğini optimize etmek ve çevresel etkileri en aza indirmek gibi çok yönlü hedeflere hizmet etmektedir (Ramanathan vd., 2023). Bu kapsamda, AUS'un önemli bir bileşenini yapay zekâ tabanlı uygulamalar oluşturmakta olup bu teknolojiler son yıllarda çeşitli ulaşım sorunlarına yenilikçi çözümler sunma potansiyeli ile öne çıkmaktadır. Yapay zekâ tabanlı tahmin modellerinin, trafik kazalarını önlemeye yönelik önceden tedbir alınmasını sağlayarak güvenlik önlemlerinin daha etkili hale getirilmesine olanak tanıyacağı öngörülmektedir. Bu yenilikçi yaklaşımların, sürdürülebilir ve güvenli bir ulaşım altyapısının oluşturulmasında kritik bir rol oynayacağı ve gelecekteki akıllı şehir kavramlarının temel bileşenlerinden biri haline geleceği düşünülmektedir.

1.6. Çalışmanın Amacı, Kapsamı ve Hedefleri

Bu çalışmanın amacı, farklı işletim özelliklerine ve trafik koşullarına sahip karayolu tünellerinde sürücülerin belirlenen senaryolar karşısında sergiledikleri davranışları ölçmek ve bu davranışları yapay zekâ teknikleri kullanarak analiz etmektir. Literatürde tünel içi sürüş dinamiklerine ilişkin çeşitli araştırmalar bulunmakla birlikte, özellikle tünel inşaatlarının hızla arttığı Türkiye gibi ülkelerde bu alandaki çalışmaların sınırlı kaldığı gözlemlenmiştir. Bu çalışma kapsamında geliştirilen sürüş senaryolarının, uluslararası literatüre yenilikçi bir katkı sağlayacağı ve tünel güvenliği konusunda yeni standartların oluşturulmasına önemli bir temel oluşturacağı düşünülmektedir. Çalışma, riskli sürüş senaryolarını simülatör teknolojisi kullanarak güvenli ve kontrollü bir ortamda test etmeyi ve toplanan veriler doğrultusunda sürücüleri risk düzeylerine göre, yapay zekâ tekniklerinden olan makine öğrenmesi yöntemleriyle sınıflandırmayı

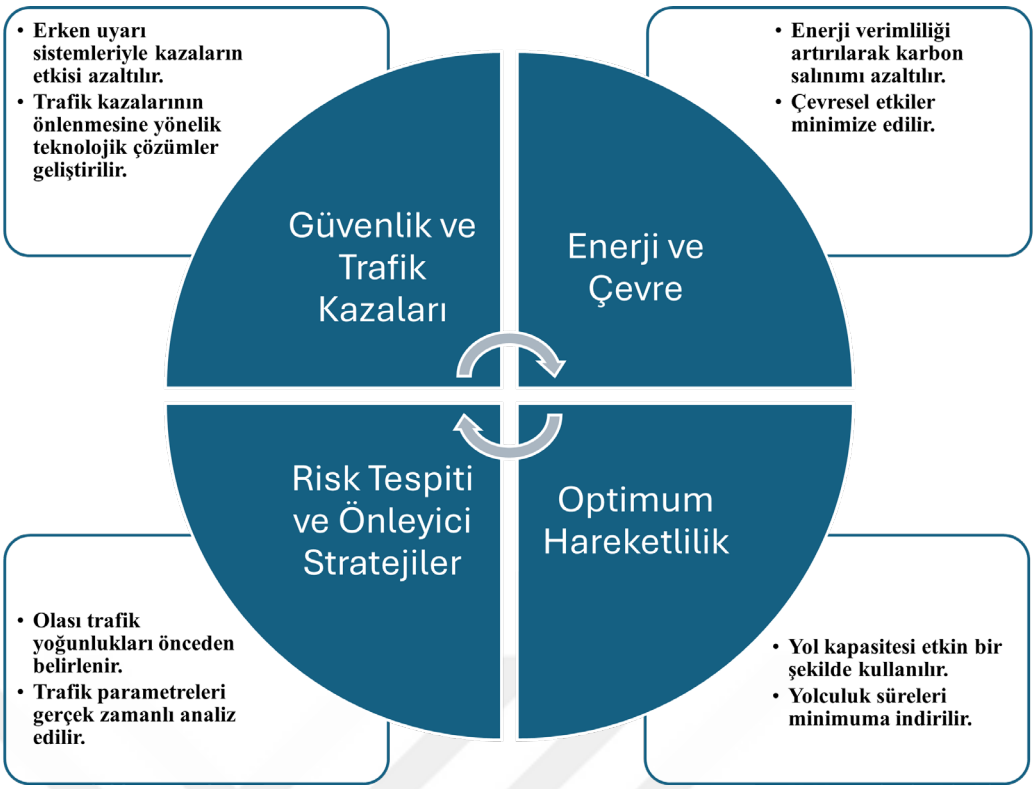
hedeflemektedir. Bu yaklaşımla, tünel güvenliği konusunda veri odaklı çözümler geliştirilmesi amaçlanmaktadır.

Çalışma dört aşamada gerçekleştirilmiştir. İlk aşamada, Erzincan Binali Yıldırım Üniversitesi Mühendislik Fakültesi bünyesinde Otonom Sürüş Teknikleri ve Sürücü Davranışları Tespit Laboratuvarı kurulmuş ve burada test edilmesi planlanan sürüş senaryoları için bir simülatör sistemi oluşturulmuştur. İkinci aşamada, sürücüler için düşük aydınlatmalı tünelden yüksek gün ışığı olan açık yola çıkış, tünel içi ağır taşıtlarla karşılaşma ve kesikli (ara ara açık alanlarla bölünen) tünellerde sürüş gibi toplam 12 farklı sürüş senaryosu geliştirilmiştir. Üçüncü aşamada, katılımcılar belirlenen bu senaryolar kapsamında simülatör ortamında sürüş gerçekleştirmiş ve bu süreçte hız, ivme, şerit değiştirme gibi parametreler simülatör yazılımı aracılığıyla kaydedilmiştir. Ayrıca, sürücülere sürüş öncesi ve sonrası anketler uygulanarak demografik bilgiler ve simülatör deneyimleriyle ilgili veriler toplanmıştır. Son aşamada, toplanan veriler ve anket sonuçları analiz edilerek tünellerin işletim özelliklerindeki, trafik koşullarındaki ve geometrik parametrelerindeki farklılıkların sürücü davranışları üzerindeki etkileri incelenmiş ve makine öğrenmesi yöntemleriyle sürücü sınıflandırması yapılmıştır. Bu analizler doğrultusunda, sürücü ve tünel güvenliğini artırmaya yönelik mühendislik önerilerinde bulunulmuştur.

1.7. Akıllı Ulaşım Sistemleri, Yapay Zekâ ve Ulusal Stratejiler

1.7.1. Akıllı Ulaşım Sistemleri

Akıllı Ulaşım Sistemleri (AUS), seyahat sürelerini kısaltmak, trafik güvenliğini artırmak, mevcut yol kapasitelerini daha verimli kullanmak, hareketliliği optimize etmek, enerji tüketimini iyileştirmek ve çevresel etkileri en aza indirmek amacıyla geliştirilen entegre bilgi ve iletişim teknolojilerine dayalı sistemlerdir (URL-4, 2024). AUS, kullanıcılar, araçlar, altyapı ve kontrol merkezleri arasında çok yönlü veri alışverişi sağlayarak izleme, ölçme, analiz ve kontrol süreçlerini bir araya getirmektedir. Bu sistemler, trafik akışını daha verimli hale getirirken, sürücü ve yolcu güvenliğini artırmayı hedefleyen ileri teknolojilerle donatılmıştır (URL-4, 2024). Şekil 3'te, AUS'un temel unsurları ve bu unsurların sağlayabileceği katkılar görselleştirilmiştir.



Şekil 3. AUS'un temel unsurları

AUS, kullanıcılar, altyapı ve kontrol merkezleri arasında çok yönlü veri alışverişi sağlayarak trafik yönetiminde etkin çözümler sunmaktadır (Tufan, 2014). Bu sistemler, güvenlik, çevre, hareketlilik ve risk yönetimi gibi kritik alanlarda ileri teknolojilerle desteklenmiştir. AUS'un güvenlik ve trafik kazaları başlığı altında, erken uyarı sistemleri sayesinde trafik kazalarının etkisi azaltılmakta ve kazaların önlenmesine yönelik teknolojik çözümler geliştirilmektedir. Enerji ve çevre kapsamında, enerji verimliliği artırılarak karbon salınımı azaltılmakta ve çevresel etkiler en aza indirilmektedir. Risk tespiti ve önleyici stratejiler ile trafik yoğunlukları önceden tahmin edilerek dinamik çözümler sunulmakta, trafik parametreleri gerçek zamanlı olarak analiz edilmektedir. optimum hareketlilik çerçevesinde ise yol kapasitelerinin etkin kullanımı sağlanmakta ve seyahat süreleri minimuma indirilmektedir (URL-4, 2024). Bu sistemler, bireylerin ulaşım deneyimlerini iyileştirmenin yanı sıra toplumsal fayda sağlamada önemli bir rol oynamaktadır.

Motorlu taşıtların trafikteki hareketlerinden kaynaklanan trafik kazaları, sürücü, altyapı ve araç faktörleriyle ilişkilidir. Özellikle gelişmekte olan ülkelerde, nüfus artışı, kentleşme ve motorlu araç sayısındaki artışla birlikte bu kazaların sayısında son yıllarda önemli bir artış gözlenmiştir (Elliott ve Gosselin, 2016). Bu kazalar genellikle ölüm, yaralanma veya maddi hasarla sonuçlanmakta ve ülkelerin ekonomileri üzerinde ciddi kayıplara neden olmaktadır. Bununla birlikte, trafik kazalarının yol açtığı can kayıpları

ve yaralanmalar yalnızca ekonomik değil, aynı zamanda toplumsal açıdan da ciddi zararlara sebep olmaktadır. Bu durum, trafik güvenliğinin iyileştirilmesine yönelik önlemlerin alınmasının ve etkin politikaların uygulanmasının gerekliliğini bir kez daha ortaya koymaktadır (Tufan, 2014).

AUS' un sunduğu imkânlar doğrultusunda tünellerde trafik güvenliğinin dinamik olarak yönetilebilmesi büyük önem taşımaktadır. Tünel içi trafik akışının ve sürücü davranışlarının gerçek zamanlı olarak izlenebilmesi ve kontrol edilebilmesi güvenlik açısından kritik bir gereklilik haline gelmiştir (H. Zheng vd., 2024). Yapay zekâ tabanlı sistemler tünel içindeki trafik akışını sürekli analiz ederek olası tehlikeleri erken tespit edebilecek ve gerekli önlemlerin alınmasını sağlayabilecek potansiyele sahiptir (Mirzarazi vd., 2024). Yapay zekâ, özellikle sürücü davranışlarının analizi ve sınıflandırılmasında önemli bir rol oynamaktadır. Farklı sürücü profillerinin ve sürüş alışkanlıklarının incelenmesi tünel içinde potansiyel risk oluşturan sürücülerin önceden tespit edilmesine olanak tanımaktadır. Agresif, dikkatsiz veya aşırı temkinli sürücüler gibi farklı kategorilerde sınıflandırılabilen sürücü davranışları, yapay zekâ teknikleriyle modellenebilmektedir. Özellikle riskli sürücülerin belirlenmesi ve bu sürücüler için önleyici tedbirlerin alınması, tünel içi güvenlik stratejilerinin daha etkin ve önleyici bir yapıya kavuşmasını sağlamaktadır (Bouhsissin vd., 2023).

1.7.2. Ulusal AUS Strateji Belgesi

Ulusal Akıllı Ulaşım Sistemleri Strateji Belgesi ve Eylem Planı, Türkiye'nin ulaşım sektöründe dijital dönüşüm sürecini hızlandırmak ve güvenli, verimli, çevre dostu bir ulaşım ağı oluşturmak amacıyla hazırlanmıştır. Bu strateji, ileri teknolojiler ve yapay zekâ destekli sistemler kullanılarak ulaşım modlarının optimize edilmesini ve bu sistemlerin entegrasyonunun sağlanmasını hedeflemektedir (AUS Strateji Belgesi, 2019). AUS, veri temelli bir yönetim anlayışıyla ulaşım süreçlerinin iyileştirilmesini, trafik güvenliğinin artırılmasını, enerji verimliliğinin sağlanmasını ve çevresel etkilerin azaltılmasını temel amaçlar olarak belirlemiştir. Ayrıca, strateji kapsamında Türkiye'nin sürdürülebilir kalkınma hedeflerine paralel olarak, ulaşım sistemlerinin daha çevreci ve kullanıcı dostu bir yapıya dönüştürülmesi hedeflenmektedir. Bununla birlikte modern teknolojilerin etkin kullanımıyla, ulaşım altyapısının daha verimli ve güvenli hale getirilmesi amaçlanmaktadır (AUS Strateji Belgesi, 2019). Bu kapsamda, akıllı trafik yönetim sistemleri, otonom ve bağlantılı araç teknolojileri, büyük veri analitiği, bulut bilişim ve yapay zekâ gibi yenilikçi teknolojiler, ulaşımın dijitalleşmesinde önemli bir rol oynamaktadır (Dimitrov, 2024). AUS, ulaşım altyapısının hem şehir içi hem de

şehirlerarası düzeyde modernize edilmesini ve bu sistemlerin birbirleriyle entegre hale getirilmesini hedeflemektedir (Tufan, 2014). AUS'un sunduğu yenilikçi çözümler, seyahat sürelerinin kısaltılması, yol güvenliğinin artırılması ve trafik yoğunluğunun azaltılması gibi somut faydalar sağlamaktadır. Bunun yanı sıra, strateji yalnızca ulaşım sistemlerinin dijital dönüşümünü desteklemekle kalmayıp, enerji tüketiminin azaltılması ve çevresel sürdürülebilirliğin sağlanmasına yönelik politikaları da içermektedir. Bu yenilikler, daha verimli ve çevre dostu bir ulaşım altyapısının oluşturulmasına katkı sağlamaktadır.

Dünya genelinde ve Türkiye'de yapay zekâya yönelik ilgi ve yatırımlar hızla artmaktadır. Yapay zekâ, sağlık, eğitim, sanayi, tarım, ulaşım ve savunma gibi birçok sektörde devrim niteliğinde yenilikler sunmakta ve bu sektörlerde verimlilik artışı, maliyet azaltma, karar alma süreçlerinde iyileştirme ve öngörü kabiliyeti gibi avantajlar sağlamaktadır. Küresel ölçekte ülkeler, yapay zekâdan en üst düzeyde faydalanmak için stratejik planlar oluşturmakta ve bu alana yönelik yatırımlarını artırmaktadır.

1.7.3. Ulusal Yapay Zekâ Stratejisi

Türkiye'nin yapay zekâ teknolojileri alanındaki yetkinliğini artırmak, dijital dönüşüm sürecini hızlandırmak ve küresel rekabet gücünü yükseltmek amacıyla Ulusal Yapay Zekâ Stratejisi (UYZS) 2021-2025 Eylem Planı yayınlanmıştır. Bu strateji, yapay zekâ teknolojilerinin ekonomik büyümeye, sosyal refaha ve teknolojik bağımsızlığa katkı sağlamasını hedeflemektedir. UYZS kapsamında, yerli yapay zekâ çözümlerinin geliştirilmesi, milli teknolojilerle inovasyonun teşvik edilmesi ve nitelikli insan kaynağının yetiştirilmesi temel öncelikler arasında yer almaktadır (UYZS, 2021). Strateji ayrıca, yapay zekâ teknolojilerinin özellikle AUS, kamu hizmetleri ve sanayi üretimi gibi alanlarda yaygınlaştırılmasını ve bu sektörlerde verimlilik ile yenilikçiliği artırmayı amaçlamaktadır. Türkiye'nin dijital altyapısını güçlendirmeyi hedefleyen UYZS, yapay zekâ uygulamalarının etik, hukuki ve toplumsal boyutlarını gözeterek hayata geçirilmesini öngörmektedir. Bu strateji, Türkiye'yi teknoloji üreten bir ülke konumuna yükseltmeyi ve yapay zekâ alanındaki küresel gelişmeleri yönlendiren bir aktör haline getirmeyi amaçlamaktadır (UYZS, 2021). UYZS, yapay zekâ teknolojilerinin benimsenmesini hızlandırarak geniş bir uygulama alanını kapsamaktadır. Kamu, özel sektör, akademi ve sivil toplum iş birliğiyle hazırlanan strateji, AUS başta olmak üzere eğitim, sağlık, sanayi, tarım ve savunma gibi kritik sektörlerde yapay zekâ çözümlerinin yaygınlaştırılmasını hedeflemektedir. AUS, trafikte verimliliği artırmak, güvenliği sağlamak ve çevresel etkileri minimize etmek gibi hedeflerle stratejinin önemli bir

bileşeni olarak yer almaktadır. Sensörler, veri analitiği ve yapay zekâ teknikleriyle desteklenen AUS; trafik yönetimi, optimizasyon ve otonom sürüş gibi alanlarda etkin çözümler sağlamayı amaçlamaktadır (UYZS, 2021). Yapay zekâ tekniklerinden makine öğrenmesi ve derin öğrenme yöntemleri, sürücü davranışlarını analiz etme, tünel içindeki sürüş koşullarını modelleme ve risk faktörlerini tespit etme konusunda güçlü bir araç olarak öne çıkmaktadır. Bu yöntemler, simülatör verilerini kullanarak sürücülerin tünel içindeki hız, şerit değiştirme ve reaksiyon sürelerini analiz edebilmekte ve bu da sürücü ve tünel güvenliğini artırmaya yönelik stratejilerin geliştirilmesine olanak tanımaktadır (Bouhsissin vd., 2023).

Bu çalışmada, yapay zekâ tekniklerinin tercih edilmesinin temel nedeni, çok sayıda parametreyle çalışırken insan gözlemlerinin ötesinde daha hassas, yüksek doğruluklu ve hızlı sonuçlar elde etmektir. Makine öğrenmesi yöntemleri, simülatörlerden elde edilen verilerle sürücü davranışlarını sınıflandırmaya ve tünellerin trafik koşullarındaki farklılıkların bu davranışlara etkisini belirlemeye imkân sağlamaktadır. Bu analizlerin, daha güvenli tünel tasarımları, denetimleri ve sürücü destek sistemlerinin geliştirilmesine önemli katkılar sağlayacağı düşünülmektedir. Bunun yanı sıra, tünel içi ve tünel dışı sürüş koşullarındaki hız ve reaksiyon farklılıklarının analiz edilmesinin AUS stratejileri çerçevesinde güvenli sürüş koşullarının sağlanmasına destek olacağı düşünülmektedir. Özellikle sürüş güvenliği ve risk yönetimi hedeflerini destekleyen bu tür yapay zekâ uygulamaları, AUS eylem planlarıyla uyumlu şekilde sürücü destek sistemlerinin geliştirilmesine ve optimize edilmesine katkı sağlanması hedeflenmektedir.

1.8. Tahmin, Sınıflandırma ve Kümeleme Yöntemleri

Tahmin yöntemleri, sürücülerin gelecekte sergileyebileceği tehlikeli davranışları modelleyerek potansiyel risklerin önceden belirlenmesini sağlamaktadır (Debbarma vd., 2024). Bu yöntemler, özellikle trafik güvenliği açısından kritik öneme sahip davranışsal öngörüler sunarak, kazaların önlenmesine ve sürücülerin daha güvenli bir şekilde hareket etmelerine katkıda bulunmaktadır (Gorzelańczyk ve Tylicki, 2024). Dar ve kapalı alanlarda, özellikle tüneller gibi yüksek risk taşıyan koşullarda, tahmin yöntemlerinin uygulanması büyük önem taşımaktadır. Bu yöntemler, trafik akışının düzenlenmesine katkıda bulunmakta ve sürücü davranışlarının risk faktörleri doğrultusunda değerlendirilmesini sağlayarak güvenlik seviyesinin artırılmasına olanak tanımaktadır. Böylece, bu alanlardaki potansiyel tehlikelerin önlenmesi ve trafik yönetiminin daha etkili bir şekilde gerçekleştirilmesi mümkün hale gelmektedir (Debbarma vd., 2024).

Sınıflandırma yöntemleri, sürücü davranışlarının analiziyle bireyleri farklı kategorilere ayırmak için kullanılmaktadır. Bu kategoriler genellikle agresif, temkinli ve güvenli sürücülerden oluşmaktadır (Bouhsissin vd., 2023). Sınıflandırma, bireysel farklılıkları göz önünde bulundurarak hedefe yönelik müdahale stratejilerinin geliştirilmesine olanak tanımaktadır (Kummetha vd., 2023). Ayrıca, sınıflandırma sonuçları trafik yönetimi ve eğitim programları için güçlü bir temel oluşturarak, sürücülerin davranışlarını değiştirmeye yönelik daha etkili çözümlerin geliştirilmesine olanak sağlayabilmektedir.

Kümeleme yöntemleri ise sürücülerin ortak davranışsal eğilimlerini belirlemek amacıyla kullanılmaktadır (Yao vd., 1990). Bu yöntemler, sürücüleri benzer davranışlara sahip alt gruplara ayırarak, her bir grup için özelleştirilmiş güvenlik önlemleri ve politikalar geliştirilmesine olanak tanımaktadır. Örneğin, agresif sürücülerin oluşturduğu bir küme için geliştirilen müdahaleler, güvenli sürücüler için önerilen politikalardan farklı olabilmektedir (Yao vd., 1990).

Yapay zekâ tekniklerinin büyük veri setleri üzerindeki analitik gücü, tahmin, sınıflandırma ve kümeleme süreçlerini hızlandırmakta ve doğruluğunu artırmaktadır. Bu sayede, özellikle trafik güvenliğinin kritik olduğu tünel gibi alanlarda olası tehlikelerin erken tespit edilmesi ve zamanında müdahale edilmesi mümkün hale gelebilmektedir. Bu sistemlerin uygulanması, trafik güvenliğini artırarak kazaların önlenmesine ve sürücülerin güvenliğinin sağlanmasına doğrudan katkı sağlayabilmektedir.

2. LİTERATÜR TARAMASI

Yapılan literatür araştırmasında, karayolu tünellerindeki sürücü davranışlarının incelenmesi üzerine birçok araştırmacının çalışma yaptığı görülmektedir. Bu çalışmaların genellikle tünel girişindeki trafik uyarı çeşitlerinin, tünel yan duvarlarına yapılan işaretlemelerin, tünel tavanında uygulanan farklı aydınlatma yöntemlerinin, çeşitli uzunluklardaki tünellerin ve düşük aydınlatmalı (karanlık) tünellerin sürücü davranışları üzerindeki etkilerinin simülatör ortamında incelenmesi üzerine yoğunlaştığı görülmektedir. Literatürde bu alanda yapılmış karayolu tüneli, sürücü davranışı ve simülatör tabanlı bazı örnek çalışmalar şu şekildedir:

Niu ve arkadaşları (2022) tarafından gerçekleştirilen çalışma, uzun tünellerde (2 km ve üzeri) aydınlatma koşullarını iyileştirmeye odaklanmıştır. Uzun tüneller, trafik akışını ve yol güvenliğini artırmada önemli avantajlar sağlasa da yetersiz aydınlatma koşulları, sürücülerin görüş mesafesini olumsuz etkileyerek sürüş güvenliğini tehlikeye atabilmektedir. Bu problem, özellikle yol yüzeyindeki parlaklık farkları ve düşük görüş mesafesi gibi durumlarda daha belirgin hale gelmektedir (Niu vd., 2022). Çalışmanın temel amacı, güvenli sürüş standartlarına uygun bir aydınlatma ortamı sağlayarak sürüş güvenliğini artırmak ve aynı zamanda enerji verimliliğini optimize etmektir. Araştırmacılar, aydınlatma ortamını etkileyen ana faktörlerin önem derecelerini belirleyerek, bu faktörlerin ağırlıklarını Tablo 2'deki gibi belirlemişlerdir.

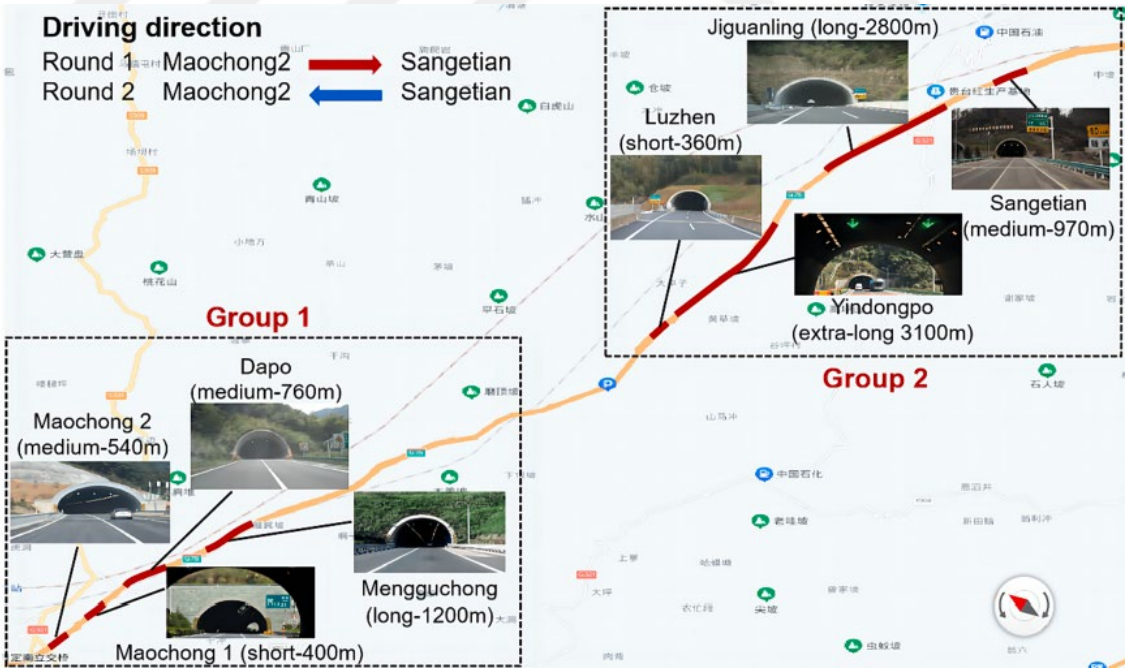
Tablo 2. Tünellerde aydınlatma ortamını etkileyen faktör ağırlıkları (Niu vd., 2022)

Ortak Faktör Numarası	Etkileyen Faktör	Ağırlık Değeri	Ortak Faktördeki Oran (%)
1	Görüş Seviyesi	0.3414	79.86
	NO_2 Konsantrasyonu	0.0570	13.33
	Sıcaklık	0.0291	6.81
2	Trafik Akışı	0.2361	78.88
	Duman Konsantrasyonu	0.0632	21.12
3	İç Bölge Aydınlatması	0.1525	79.59
	Komşu Aydınlatma Bölgelerinin Ortalama Aydınlatma Farkı	0.0391	20.41
4	Araç Hızı	0.0816	100.00

Tablo 2'de farklı faktörlerin gruplandırılarak yapıldığı kıyaslamaya göre, özellikle görüş seviyesinin %79.86 ile en etkili faktör olduğu, trafik akışının %78.88 ve iç bölge aydınlatmasının %79.59 oranında önemli katkılar sağladığı belirlenmiştir. Bu faktörler, tünel içindeki trafik yoğunluğu ve aydınlatma seviyelerinin sürücü davranışlarına olan etkilerini açıkça ortaya koymaktadır. Araç hızının sürüş güvenliğini doğrudan etkilediği

vurgulanmış, ayrıca tünel içindeki duman, NO_2 konsantrasyonu ve sıcaklık gibi çevresel faktörlerin de aydınlatma optimizasyonunda dikkate alınması gerektiği ifade edilmiştir. Çalışmanın sonuçları, farklı hava koşullarında aydınlatma sistemlerinin dinamik olarak optimize edilmesi durumunda sürüş güvenliğinin artırılabileceğini ve enerji tasarrufunun %33.03'e kadar çıkarılabileceğini göstermektedir (Niu vd., 2022).

Zheng ve arkadaşları (2024) tarafından gerçekleştirilen çalışmada, ardışık olarak yer alan farklı uzunluk ve geometrilere sahip karayolu tünellerinde (Şekil 4) sürüş risklerinin dinamik değişimlerini analiz etmek amaçlanmıştır. Bu kapsamda, sürücülerin gözbebeği dalgalanmaları incelenmiş ve yüksek riskli bölgeler ile bu riskleri etkileyen temel faktörler belirlenmiştir. Araştırma bulguları doğrultusunda, tünel güvenliğini artırmaya yönelik iyileştirme önerileri sunulmuştur. Çalışmada, gerçek dünya sürüş deneyleri gerçekleştirilmiş ve sürücülerin gözbebeği büyüklüğündeki dalgalanmalar, gözbebeği alanı yüzde değişkeni metriği kullanılarak ölçülmüştür. Bu veriler, göz takip cihazları ile toplanmıştır. Tünel gruplarının farklı bölümlerindeki sürüş risklerindeki değişimlerin analizi için istatistiksel yöntemler ve korelasyon testleri uygulanmıştır. Elde edilen bulgular, tünel yapısının ve geometrik özelliklerin sürüş riskleri üzerindeki etkilerini detaylı bir şekilde ortaya koymuştur (H. Zheng vd., 2024).



Şekil 4. Tünellerin konumları ve yerleşim planları (H. Zheng vd., 2024)

Çalışmanın sonuçları, tünel gruplarındaki sürüş risklerinin tünel sonlarına doğru belirgin bir şekilde arttığını ve gözbebeği dalgalanmalarının bu risklerin tespitinde önemli bir gösterge olduğunu ortaya koymuştur. Risk seviyelerinin, tünel uzunluğu, sürüş

mesafesi ve açık alanların uzunluğu gibi faktörlerle anlamlı bir ilişkiye sahip olduğu belirlenmiştir. Elde edilen bulgular, daha uzun tünellerin ve daha uzun sürüş mesafelerinin sürüş riskini artırdığına, buna karşın açık alanların uzunluğundaki artışın bu riskleri azalttığına işaret etmektedir (H. Zheng vd., 2024).

Su ve arkadaşları (2023), uzun karayolu tünellerinde sürücülerin görsel dikkatini artırmak ve yorgunluklarını azaltmak amacıyla farklı yönlerde ve uzunluklarda kademeli aydınlatma bölgelerini modellemiş ve bu bölgelerin sürücüler üzerindeki etkilerini simülatör ortamında incelemişlerdir. Araştırma, Çin'de inşa edilen 31 karayolu tünelinde (bazı örnekleri Şekil 5'te verilmiştir) yapılan incelemelerden elde edilen verilere dayandırılmıştır. Modelleme çalışmasında kullanılan tünelin toplam uzunluğu 7 km, peyzaj bölgesinin uzunluğu ise 300 metre olarak belirlenmiştir. Peyzaj bölgeleri, 'mavi gökyüzü ve beyaz bulutlar' temasıyla tasarlanmış ve bu bölgelere geçişi sağlamak amacıyla kademeli aydınlatma geçişleri uygulanmıştır. Araştırmacılar, peyzaj bölgesine yaklaşma ve ayrılma yönlerinde farklı uzunluklarda (50 m, 100 m, 150 m, 200 m, 250 m) kademeli geçişler içeren 12 farklı peyzaj senaryosu oluşturmuşlardır. Bu senaryolar, sürücü davranışlarının ve görsel dikkat değişimlerinin değerlendirilmesi amacıyla tasarlanmıştır (Su vd., 2023).



Şekil 5. Çin'de inşa edilen karayolu tünelleri için örnek modeller (Su vd., 2023)

Araştırmanın sonuçları, 'mavi gökyüzü ve beyaz bulutlar' temalı aydınlatma bölgelerinin sürücülerde aşırı dikkat dağılmasına yol açmadığını ve dikkatlerinin ağırlıklı

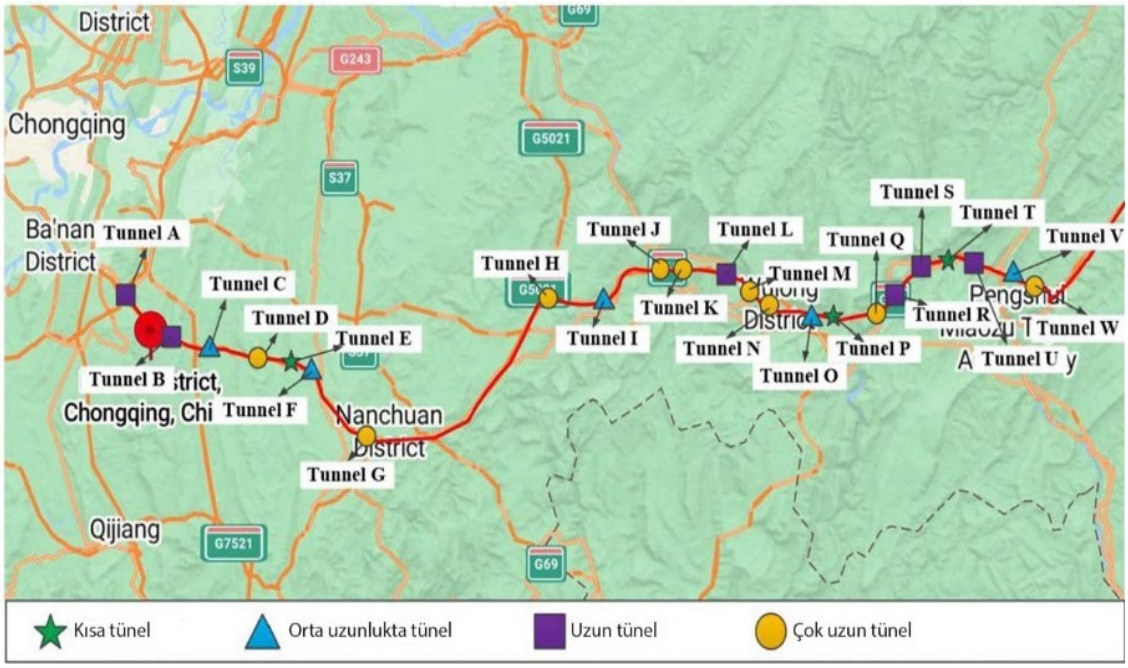
olarak yol ve merkezi bölgeye yöneldiğini ortaya koymuştur. Ayrıca, peyzaj bölgesine yaklaşma yönünde kullanılan kademeli geçişlerin, sürücülerin ana aydınlatma bölgesine ulaşmadan önce çevresel değişimlere uyum sağlamalarına yardımcı olduğu belirlenmiştir (Su vd., 2023).

Qin ve arkadaşları (2021) gerçekleştirdikleri çalışmada, Çin'deki karayolu tünellerini uzunluklarına göre sınıflandırmış ve 10 km'yi aşan tünelleri 'ekstra uzun tünel' olarak tanımlamışlardır. Bu kapsamda, 9410 metre uzunluğundaki Yanglin Tüneli modellenmiş ve mevcut aydınlatma sistemine 150 metre uzunluğunda led kemer şeklinde bir ışık bandı eklenmiştir. Araştırmacılar, mavi ve yeşil-sarı ışık bantlarını farklı aydınlatma seviyelerinde tasarlayarak bu uygulamanın sürücülerin yorgunluk seviyelerine etkisini değerlendirmişlerdir. Çalışmanın sonuçları, uzun ve monoton tünel ortamlarının sürücü yorgunluğunu belirgin bir şekilde artırdığını ortaya koymuştur. Sürücülerin tünelde geçirdikleri süre boyunca yorgunluk belirtileri gösterdiği ve bu durumun EKG ölçümleri ile doğrulandığı belirtilmiştir. Bununla birlikte, özel ışık bandının kullanıldığı tünel ortamında sürücü yorgunluğunda anlamlı bir azalma gözlemlenmiştir. Araştırmacılar, ışık bandının sürücülere görsel ve psikolojik uyarılar sağlayarak yorgunluk belirtilerini azalttığını ve dikkat seviyelerini artırdığını ifade etmişlerdir (Qin vd., 2021).

Kirytopoulos ve arkadaşları (2017) tarafından yapılan çalışmada, karayolu tüneli kullanan sürücülerin tünel güvenliğine ilişkin davranışları ve farkındalık düzeyleri incelenmiştir. Araştırma kapsamında, sürücülerin tünel içinde hem normal hem de acil durumlarda sergiledikleri davranışları değerlendirmek amacıyla internet tabanlı bir anket uygulanmıştır. Çalışma, özellikle yangın gibi acil durumlara sürücülerin nasıl tepki verdiklerini analiz ederek bilgi eksikliklerini tespit etmeyi amaçlamıştır. Araştırma sonuçları, katılımcıların yalnızca %38.7'sinin yangın durumunda tüneli hızlı bir şekilde terk etmenin en güvenli davranış olduğunu bildiğini göstermiştir. Bunun yanı sıra, katılımcıların %72.3'ü kırmızı uyarı ışığı yandığında tünelde sürüş yapmaya devam edeceğini belirtmiş ve bu davranış tehlikeli bir eğilim olarak değerlendirilmiştir. Ayrıca, birçok katılımcının acil bir durumda aracı terk ederken kişisel eşyalarını toplama eğiliminde olduğu tespit edilmiştir. Bu davranışın, tünel güvenliği açısından ciddi zaman kayıplarına yol açabileceği vurgulanmıştır. Araştırmacılar, sürücülerin acil durumlarda doğru ve hızlı tepki vermelerini sağlamak için farkındalık artırıcı eğitim programlarının gerekliliğine dikkat çekmişlerdir (Kirytopoulos vd., 2017).

Shang ve arkadaşları (2024), araç takip mesafesinin tünel güvenliği açısından doğrudan bir tehdit oluşturduğu hipotezinden hareketle, sürücülerin öndeki aracı takip

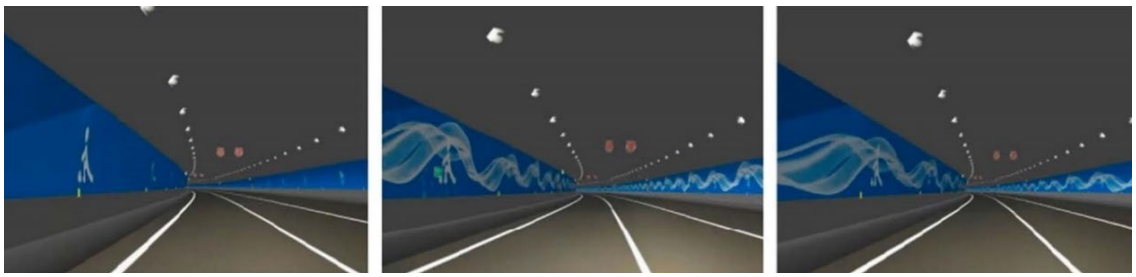
etme davranışlarını incelemek amacıyla gerçek araçlardan elde edilen sürüş verilerini kullanmışlardır. Araştırma, Çin'in Chongqing şehrindeki Baomao otoyolunda gerçekleştirilmiş ve güzergâh boyunca 3 kısa, 5 orta uzunlukta, 6 uzun ve 9 çok uzun tüneli kapsayan kapsamlı bir saha çalışması yapılmıştır (Şekil 6). Çalışma alanında iki yönlü, dört şeritli bir yol kesimi incelenmiş, bu yolda maksimum hız sınırı 100 km/sa olarak belirlenmiş ancak tünel bölgelerinde bu sınır 80 km/sa'e düşürülmüştür.



Şekil 6. Chongqing Baomao otoyolunda bulunan farklı uzunluktaki tünellerin konumları (Shang vd., 2024)

Araştırmacılar, gerçek bir araca sensörler bağlayarak sürücülerin takip mesafelerini analiz etmek amacıyla veri toplamışlardır. Çalışma sonucunda, katılımcıların yalnızca %12.6'sının güvenli kabul edilen 10 metreden fazla mesafeyi koruduğu, %53.8'inin 2-10 metre arasında mesafe bıraktığı ve %13'ünün iki metreden daha az mesafe bıraktığı belirlenmiştir. Ayrıca, erkek sürücülerin trafik sıkışıklıklarında kadın sürücülere kıyasla daha fazla mesafe bıraktığı, deneyimli sürücülerin genellikle daha güvenli takip mesafelerini koruma eğiliminde olduğu ve tünelleri sık kullanan sürücülerin hız sınırlarına daha az uyum sağladığı gözlemlenmiştir (Shang vd., 2024).

Zhao ve arkadaşları (2022), karayolu tünellerinde yan duvarların dekoratif desen özelliklerinin sürücü davranışları üzerindeki etkilerini simülatör ortamında incelemişlerdir. Çalışmada, tünel yan duvarları için üç farklı dekoratif desen modeli tasarlanmış (Şekil 7) ve bu desenlerin sürüş deneyimi üzerindeki etkileri simülatör ortamında (Şekil 8) test edilmiştir.



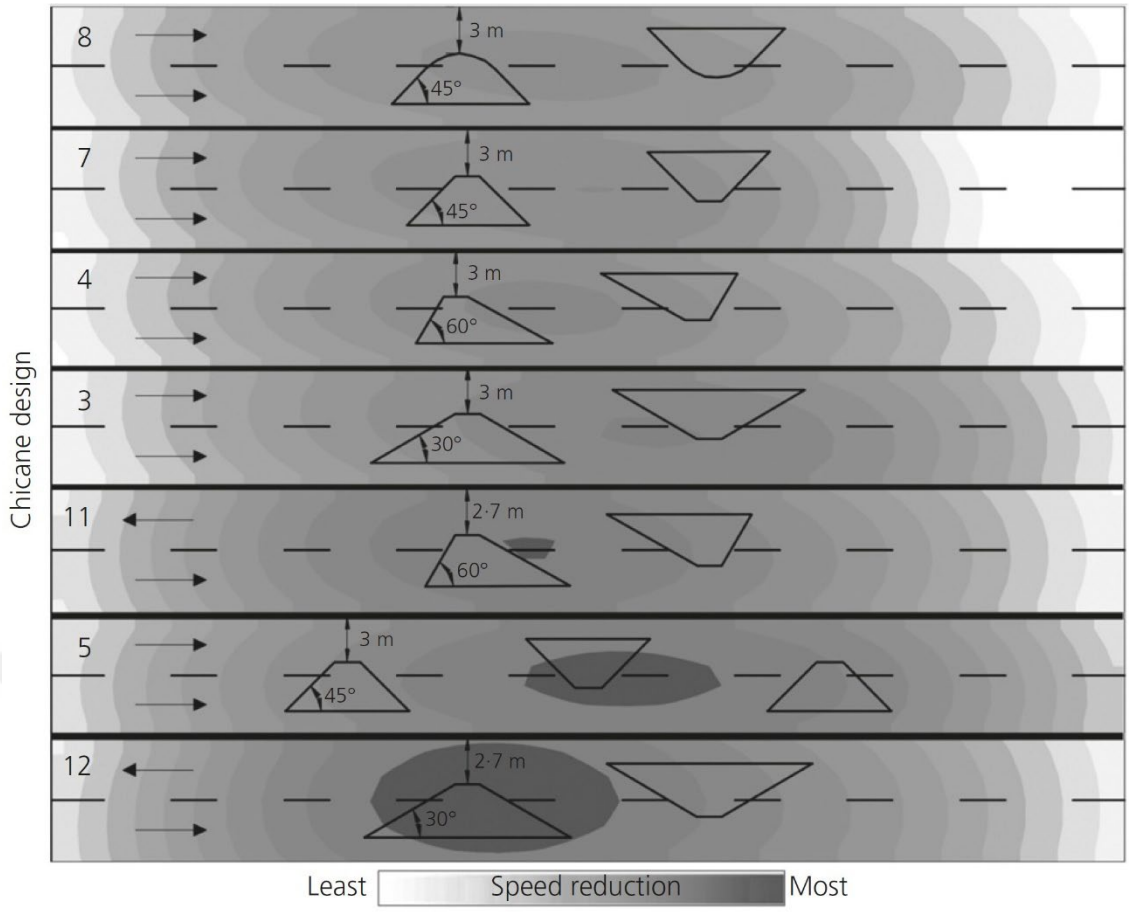
Şekil 7. Tünel yan duvar desenleri (Zhao vd., 2022)



Şekil 8. Laboratuvara ait görüntü (Zhao vd., 2022)

Çalışmanın sonuçları, tünel yan duvar dekorasyonlarının sürüş davranışları üzerinde önemli etkiler yarattığını ortaya koymuştur (Zhao vd., 2022). Araştırmada, hız kontrolü, sürüş kararlılığı ve dikkatli sürüş gibi kritik faktörlerin, yan duvar dekorasyonlarının karmaşıklık düzeyine bağlı olarak belirgin şekilde değiştiği tespit edilmiştir. Daha az karmaşık tasarıma sahip dekorasyonların, sürüş güvenliğini artırıcı ve dikkat dağınıklığını azaltıcı etkiler sağladığı belirlenmiştir. Bu tür dekorasyonlar, sürücülerin daha düşük hızlarda seyretmelerine ve daha kararlı bir sürüş gerçekleştirmelerine katkıda bulunmuştur (Zhao vd., 2022).

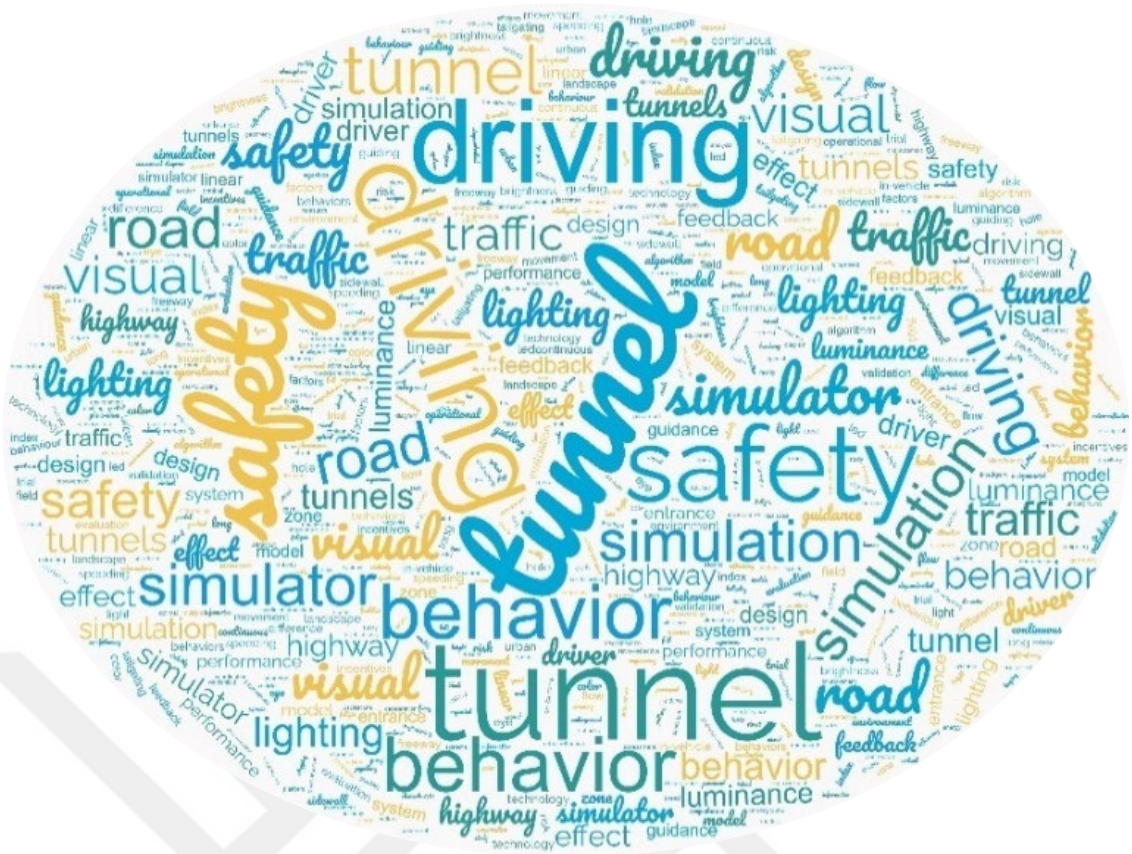
Akgöl ve arkadaşları (2019), sürüş simülatörü kullanarak Türkiye'de henüz yaygın olarak uygulanmayan kıvrımlama (chicane) tipi yatay trafik sakinleştirme önlemlerinin etkilerini incelemişlerdir. Araştırmada, Şekil 9'da gösterilen farklı kıvrımlama türlerinin hız azaltma ve yol güvenliği üzerindeki etkileri, Türk sürücülerinin karakteristik sürüş özellikleri göz önünde bulundurularak değerlendirilmiştir. Pilot bölge olarak Akdeniz Üniversitesi kampüs yolları üç boyutlu olarak modellenmiş ve bu model üzerinden simülasyon testleri gerçekleştirilmiştir.



Şekil 9. Farklı kıvrımlama tasarımlarının hız azaltma etkileri (Akgöl vd., 2022)

Araştırmanın amacı, yerleşim bölgelerindeki yollarda kullanılabilecek en uygun kıvrımlama tasarımlarını belirlemektir. Çalışmada, farklı geometrilere sahip kıvrımlamaların sürücü hızları üzerindeki etkileri incelenmiş ve elde edilen analiz sonuçlarına göre, şerit disiplini ve hız azaltma açısından en etkili kıvrımlamaların 2.7 metre veya daha dar etkin genişliğe (açık şerit genişliği) sahip olduğu belirlenmiştir. Özellikle, 30° ön açılı ve iki adalı kıvrımlama tasarımlarının hız azaltmada en başarılı sonuçları sağladığı tespit edilmiştir. Şerit disiplini açısından ise geniş girişli olmayan ve dar şerit genişliği sunan kıvrımlamaların sürücüler üzerinde daha etkili olduğu ortaya konulmuştur (Akgöl vd., 2022).

Özetle, simülatör tabanlı araştırmalar, sürücülerin tünel içindeki hız tercihleri, şerit değiştirme alışkanlıkları ve görüş mesafesinin etkilerini analiz etmek için etkili bir yöntem olarak öne çıkmaktadır. Bu tür çalışmalar, tünellerde güvenli sürüş koşullarının oluşturulmasına katkı sağlamakla birlikte, sürücülerin algısal yeteneklerini ve olası tehlikeli durumlara karşı verecekleri tepkileri önceden tahmin etme açısından büyük bir öneme sahiptir. Çalışma kapsamında konuyla ilgili çok sayıda makale arşivlenmiş, elde edilen anahtar kelimeler bir bulut grafik halinde derlenerek Şekil 10'da sunulmuştur.



Şekil 10. Araştırma konusuyla alakalı makalelerin anahtar kelime bulutu

Günümüzde tünel tasarımı ve sürücü davranışlarının analizi sürecinde geleneksel yöntemlerin yanı sıra, yapay zekâ teknikleri giderek daha fazla önem kazanmaktadır. Özellikle tünel ortamlarında sürücü davranışlarının analizi büyük miktarda veri içeren ve çok boyutlu yapısal özelliklere sahip bir problem olduğu için geleneksel analiz yöntemleri bu tür karmaşık veri kümelerinin yönetiminde yetersiz kalabilmektedir. Bu bağlamda yapay zekâ teknikleri kullanarak sürücü sınıflandırması üzerine yapılan araştırmalardan bazıları şunlardır:

Abdelrahman ve arkadaşları (2022), sürücü davranışlarının analizinde makine öğrenmesi yöntemlerine dayalı bir çalışma gerçekleştirmiştir. Araştırmada, SHRP2 veri setindeki davranış kategorileri üzerinden sürücü risk profilleri oluşturulmuştur. Veri setinde başlangıçta 54 farklı davranış kategorisi yer almakta olup bu davranışlar daha anlamlı bir analiz sağlamak ve sınıflandırma modellerinin performansını artırmak amacıyla 13 kategoriye indirgenmiştir (Tablo 3).

Tablo 3. İndirgeme sonrasında elde edilen kategoriler (Abdelrahman vd., 2022)

Davranış İndeksi	Davranış	Açıklama
1	Hız Aşımı	Güvenli hız sınırını veya yasal hız limitini aşma.
2	Deneyimsizlik veya Yetersizlik	Araç veya yol hakkında genel deneyimsizlik ya da yetersizlik gösterme.
3	Nesnelerden Kaçınma	Araç, yaya veya bir nesneden kaçınma davranışı.
4	Ani Frenleme	Yolda ani veya uygunsuz şekilde durma veya fren yapma.
5	Geçiş Hakkı Hatası	Karar veya algılama hatası nedeniyle geçiş hakkı hatası yapma.
6	Yavaş Sürüş	Trafiğe göre yavaş ya da hız sınırının altında sürüş yapma.
7	Uygunsuz Geri Sürüş	Dikkatsizlik veya başka nedenlerle uygunsuz şekilde geri gitme.
8	Güvensiz Şerit Değişimi	Kurallara aykırı veya güvensiz şerit değiştirme veya dönüş yapma.
9	Agresif Sürüş	Agresif hızlanma veya agresif şerit değiştirme gibi davranışlar.
10	Sinyal veya İşaret İhlali	Trafik işaretlerine veya sinyallerine uymama.
11	Güvenli Sürüş	Riskli davranışlara dair hiçbir belirti göstermeyen güvenli sürüş.
12	Yorgunluk	Yorgunluk, uyuklama veya dikkat eksikliği durumu.
13	İhmalkârlık	Sinyal vermeme, gece far açmama gibi ihmalkâr sürüş davranışları.

Çalışma kapsamında, sürücü davranışlarının sınıflandırılması ve risk profillerinin oluşturulmasında Rastgele Orman (RF), Destek Vektör Makineleri (SVM), Derin Sinir Ağları (DNN), k-En Yakın Komşu (KNN) ve Karar Ağaçları (DT) gibi makine öğrenmesi algoritmaları kullanılmıştır. Araştırmada, bu algoritmaların sınıflandırma doğruluğu, hassasiyet, F1 skoru ve işlem süreleri gibi metrikler açısından performansları karşılaştırılmıştır. Analiz sonuçları, algoritmaların çeşitli veri özellikleri ve sınıflandırma problemleri için farklı performans düzeyleri sergilediğini göstermektedir (Abdelrahman vd., 2022). Performans değerlendirmesi ile ilgili sonuçlar Tablo 4'te sunulmuştur.

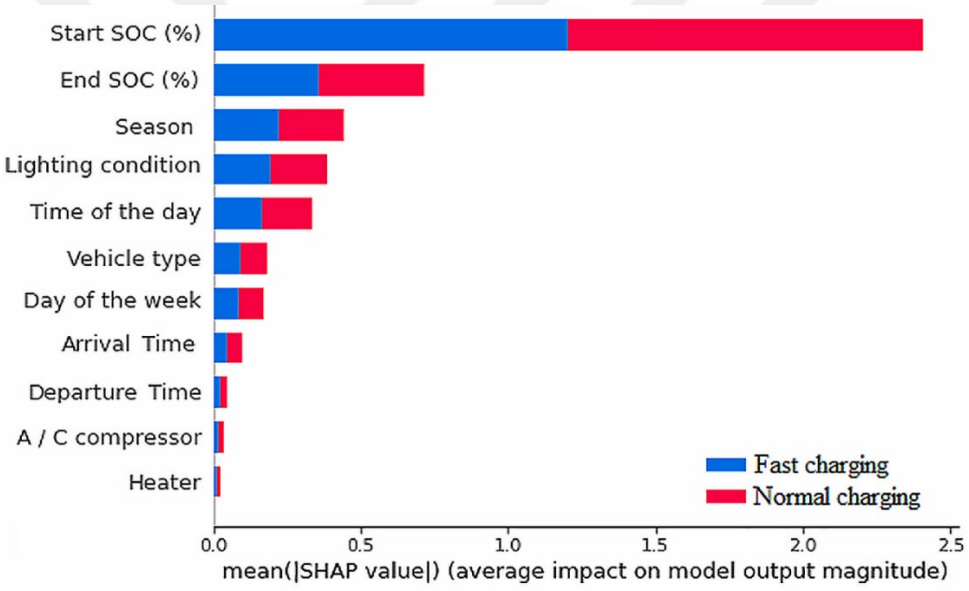
Tablo 4. Model performans sonuçları (Abdelrahman vd., 2022)

Algoritma	Ortalama Doğruluk (%)	Ortalama F1 Skoru	Ortalama ROC Eğrisi AUC (%)
DT	86.60	0.926	78.60
SVM	84.00	0.910	75.00
DNN	88.80	0.938	85.40
KNN	85.50	0.920	80.00
RF	90.00	0.945	87.50

Sonuçlar, RF modelinin diğer yöntemlere kıyasla daha yüksek doğruluk gösterdiğini ortaya koymuştur. RF modeli, sürücü davranışlarının sınıflandırılması probleminde %90 doğruluk ve 0.945 F1 skoru ile en başarılı sonuçları elde etmiştir.

Ayrıca, ROC eğrisi altındaki alan (AUC) değerine göre de %87.50 oranına ulaşarak diğer modellere göre üstün performans sergilemiştir. Bu sonuçlar, RF algoritmasının, sürücü davranışlarının analizinde genel sınıflandırma başarısı açısından etkili bir yöntem olduğunu göstermektedir (Abdelrahman vd., 2022).

Ullah ve arkadaşları (2023) yaptıkları çalışmada, elektrikli araç kullanıcılarının şarj istasyonu seçim davranışlarını ve bu davranışları etkileyen faktörleri incelemişlerdir. Araştırma kapsamında, Japonya'daki 500 elektrikli araçtan iki yıl boyunca toplanan şarj verileri analiz edilmiştir. Veri seti, araçların şarj başlangıcı ve bitişindeki pil doluluk oranı (SOC), konum ve şarj süresi gibi bilgileri içermektedir. Çalışmada, XGBoost, RF, Naive Bayes (NB) ve Lojistik Regresyon (LR) algoritmaları kullanılmış ve bu algoritmalarla şarj durumuna göre davranışları tahmin edilmiştir. Ayrıca SHAP yöntemi kullanılarak model sonuçları (Şekil 11) yorumlanmış ve modellerin performansı değerlendirilmiştir.



Şekil 11. XGBoost modelinin her iki sınıfı için SHAP değerlerinin özet grafiği (Ullah vd., 2023)

Çalışmanın sonuçlarına göre, XGBoost algoritması %97.80 doğruluk yüzdesiyle diğer modelleri geride bırakmış ve elektrikli araç kullanıcılarının şarj istasyonu seçim davranışlarını tahmin etmede en etkili yöntem olarak belirlenmiştir. Başlangıç pil doluluk oranının %30'un altında olduğu durumlarda hızlı şarj tercihinin arttığı, %80'in üzerinde olduğu durumlarda ise normal şarj tercih edildiği gözlemlenmiştir (Ullah vd., 2023).

3. MATERYAL ve YÖNTEM

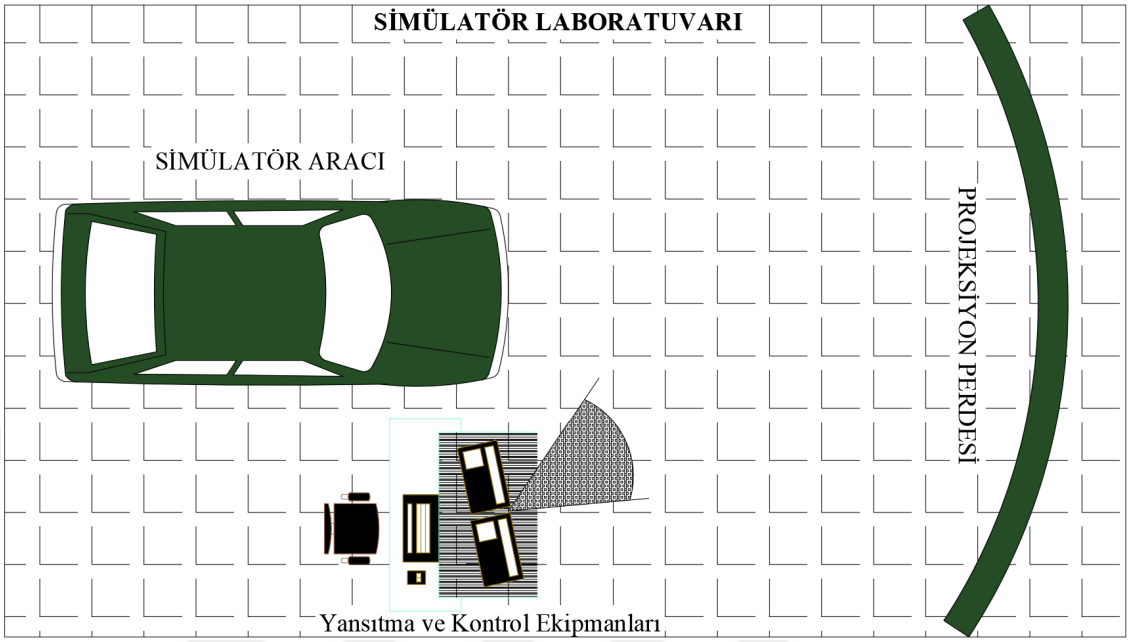
Bu çalışmada, tünellerde sürücü davranışlarının incelenmesi, bu davranışların trafik güvenliği üzerindeki etkilerinin değerlendirilmesi ve yapılan inceleme ve değerlendirme neticesinde sürücülerin makine öğrenmesi yöntemleriyle sınıflandırılması amaçlanmıştır. Çalışma kapsamında Erzincan Binali Yıldırım Üniversitesi Mühendislik Fakültesi bünyesinde 'Otonom Sürüş Teknikleri ve Sürücü Davranışları Tespit Laboratuvarı' isimli bir simülatör laboratuvarı kurulmuştur. Çalışmanın giderlerini karşılamak amacıyla TÜBİTAK, Gümüşhane Üniversitesi, Erzincan Binali Yıldırım Üniversitesi ve FIAT şirketinden şu destekler alınmıştır:

- **TÜBİTAK 1002 (Proje No: 1002/123M190):** Sürücülerin farklı yol ve trafik özellikleri karşısındaki davranışlarının simülatör ortamında incelenmesi.
- **GÜBAP02 (Proje No: 22.F5110.02.01):** Karayolu tünellerindeki trafik güvenliği üzerine bir çalışma: Trabzon-Gümüşhane karayolu örneği (Gümüşhane Üniversitesi BAP Koordinatörlüğü).
- **GÜBAP07 (Proje No: 22.E0111.07.01):** Gelişmekte olan ülkelerde sürücülerin farklı yol ve trafik özellikleri karşısındaki davranışlarının simülatör ortamında incelenmesi.
- **Erzincan BAP Koordinatörlüğü (FBA-2022-813):** Sürücülerin farklı yol ve trafik özellikleri karşısındaki davranışlarının simülatör ortamında incelenmesi.
- **TOFAŞ Türk Otomobil. A.Ş**.: Fiat Egea model araç desteği.

3.1. Deneysel Ortam ve Simülatör Sistemi

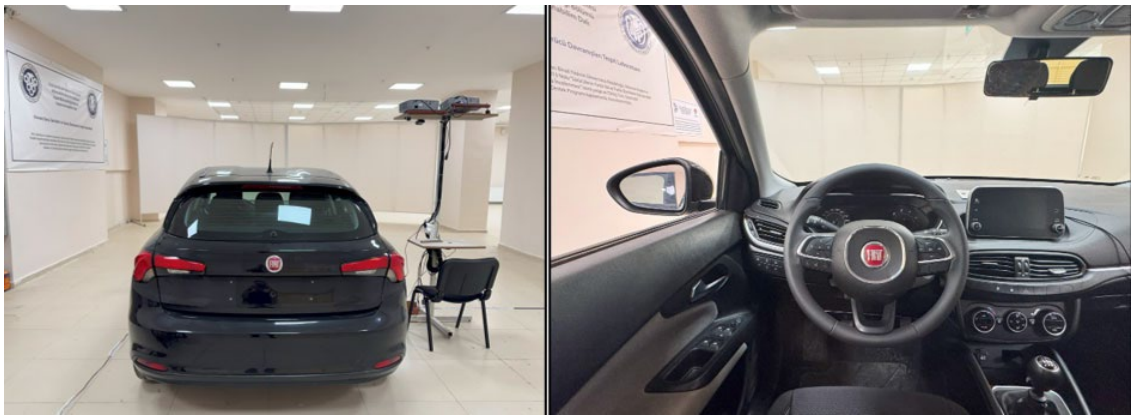
Erzincan Binali Yıldırım Üniversitesi'nde kurulan Otonom Sürüş Teknikleri ve Sürücü Davranışları Tespit Laboratuvarı, kontrollü ve optimize edilmiş bir araştırma alanı olarak tasarlanmıştır. Laboratuvar, gerçek sürüş koşullarını en iyi şekilde simüle etmek ve güvenilir veriler elde etmek amacıyla özenle düzenlenmiştir (şematik gösterimi Şekil 12'de verilmiştir). Geniş ve ferah bir alan sunan laboratuvar, simülasyon aracı ve projeksiyon sisteminin rahat bir şekilde yerleştirilmesine olanak sağlamaktadır. Işıklandırma, projeksiyon görüntülerinin netliğini artırmak ve sürücünün dikkatini dağıtabilecek çevresel faktörleri minimuma indirmek için özel olarak ayarlanmıştır.

Yansıma ve parlama etkileri azaltılarak deney sırasında dış etkenlerin sürüş üzerindeki etkileri en aza indirgenmiştir. Şekil 13'te gösterilen simülasyon laboratuvarında, gerçek bir araç kullanılarak sürüş deneyimi daha gerçekçi hale getirilmiştir.



Şekil 12**.** Laboratuvar ortamının şematik gösterimi

Projeksiyon sistemi, aracın sağ tarafına yerleştirilmiş ve geniş açılı, kavisli bir perdeye yansıtılarak sürücünün çevresel algısını artıran panoramik bir görüntü sunacak şekilde tasarlanmıştır. Laboratuvar ortamında gerçekleştirilen deneyler sırasında dış ortamdan gelen dikkat dağıtıcı unsurlar (gürültü ve ışık gibi) titizlikle kontrol altına alınmıştır. Bu düzenlemeler, deneylerin daha kontrollü ve güvenilir bir ortamda gerçekleştirilmesine olanak sağlamaktadır.



Şekil 13. Otonom sürüş teknikleri ve sürücü davranışları tespit laboratuvarı

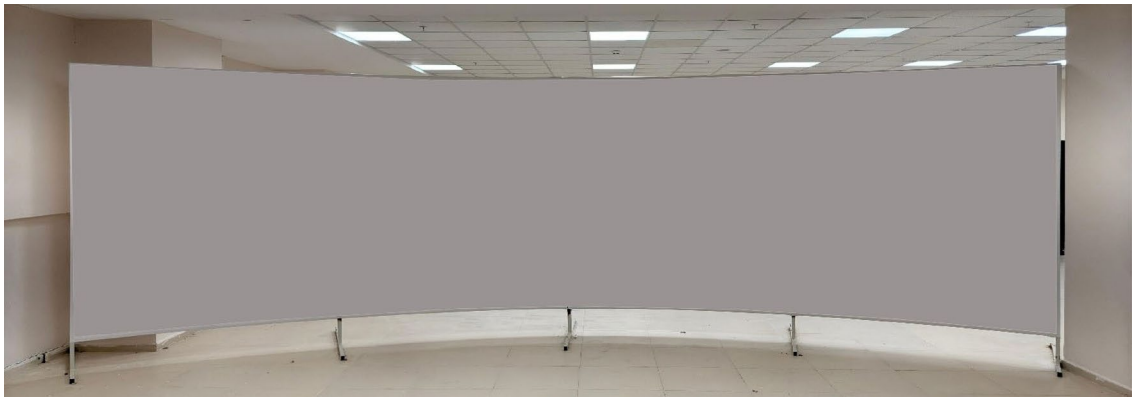
Laboratuvarda kullanılan araç, FIAT Egea model gerçek bir otomobil olup simülasyon sistemine entegre edilerek bir simülatör haline dönüştürülmüştür. Geleneksel simülatör kabinlerinden farklı olarak gerçek dünya sürüş deneyimini sunmak amacıyla aracın direksiyon sistemi ve pedalları doğrudan simülasyon sistemine bağlanmıştır. Direksiyon hareketlerinin ve direksiyon açısının simülatör sistemine doğru ve gecikmesiz aktarılabilmesi için aracın ön lastiklerine metal yönlendirme çubukları ve çelik halatlı bir makara sistemi entegre edilmiştir. Bu sistem, sürücünün direksiyon hareketlerini hassas bir şekilde algılayarak eş zamanlı olarak simülasyona iletmektedir. Bu teknoloji, direksiyon kontrolünün eksiksiz bir şekilde yansıtılmasını ve sürücünün yol koşullarına verdiği tepkilerin gerçek zamanlı olarak analiz edilmesini mümkün kılmaktadır. Söz konusu entegrasyon, geleneksel simülatör sistemlerine kıyasla daha kapsamlı bir sürüş dinamiği sunmayı hedefleyerek, sürücü davranışlarının gerçek dünyadaki sürüş koşullarına daha yakın şekilde test edilmesine olanak tanımaktadır.

Görüntü aktarımı, sürüş deneyimini daha gerçekçi hale getirmek amacıyla aracın sağ yanına uygun yükseklikte konumlandırılan iki projeksiyon cihazı aracılığıyla sağlanmıştır (Şekil 14). Kullanılan projeksiyon cihazları, 1920x1080 doğal çözünürlük, 3500 ANSI lümen parlaklık, 20,000:1 FOFO kontrast oranı ve 1,07 milyar renk desteği gibi yüksek performans özelliklerine sahiptir. Doğal en boy oranı 16:9 olan bu cihazlar, 200W gücünde ışık kaynağı ve 1.49-1.64 optik yansıtma mesafesi oranına sahiptir. Ek olarak, yatay frekans aralığı 15K-102KHz, dikey tarama hızı ise 23-120KHz arasında değişmektedir. Cihazlar, projeksiyon perdesine geniş boyutlu görüntü aktarımı yaparak gerçekçi ve etkileyici bir sürüş deneyimi sunmaktadır.



Şekil 14. Projeksiyon cihazlarının görüntü aktarım örneği

Projeksiyon perdesi, görsel deneyimin kalitesini artırmak amacıyla tasarlanmış önemli bir ekipmandır. Geniş ölçülere sahip olması, sürücülere geniş bir görüş alanı sunarak görsel içeriklerin etkileyici bir şekilde algılanmasını sağlamaktadır. 8.5 metre genişlik ve 2.5 metre yükseklik ölçülerine sahip olan perde, geniş ölçekli görüntüleme ihtiyaçlarını başarıyla karşılamıştır. Projeksiyon perdesinin 120 derece geniş açısı ve 1.30 metre içbükey derinliği, sürücülere panoramik bir görüntü deneyimi sunmuş ve bu özellik sayesinde derinlik algısını artırarak simülasyon modelinin gerçekçiliğini artırmıştır (Şekil 15).



Şekil 15. Projeksiyon perdesi

Simülatör sistemi, yüksek performanslı bilgisayar donanımı ve ileri düzey yazılım platformları ile yapılandırılmıştır. Bilgisayar donanımı; Intel® Core™ i7-11800H işlemci, Nvidia RTX3060 grafik kartı, 16GB DDR4 RAM ve 500GB PCIe M.2 SSD gibi

bileşenlerden oluşmaktadır. Bu donanımlar simülasyonun yüksek çözünürlüklü grafiklerle ve kesintisiz bir performansla çalışmasını sağlamıştır. Model ve senaryo tasarımları için Unreal Engine 5 (UE5) oyun motoru tercih edilmiştir. UE5, yüksek kaliteli grafikler ve gelişmiş özellikleriyle öne çıkan bir platformdur. Özellikle Nanite teknolojisi, film kalitesindeki tasarımların performans kaybı yaşanmadan kullanılmasına olanak tanımaktadır. Ayrıca, Lümen dinamik aydınlatma sistemi, gerçek zamanlı ışıklandırma ayarları ile sanal ortamların gerçekçiliğini artırmaktadır. Bu özellikler, simülatör ortamının daha etkileyici ve gerçekçi bir şekilde sunulmasını sağlamaktadır (URL-5, 2024).

3.2. Katılımcılar ve Model Tasarımı

3.2.1. Katılımcılar

Deneyde yer alan katılımcılar, gönüllülük esasına dayalı olarak seçilmiş ve çalışmanın niteliğini artırmak amacıyla farklı demografik özelliklere sahip bireylerden oluşan bir örneklem grubu oluşturulmuştur. Katılımcıların seçiminde yaş, cinsiyet, eğitim durumu ve sürüş deneyimi gibi demografik değişkenler dikkate alınmıştır. Sürüş alışkanlıkları ve tünel sürüşüne ilişkin deneyimleri farklı olan katılımcı gruplarının tercih edilmesi, tünel içi sürüş davranışlarının daha geniş bir perspektiften değerlendirilmesine olanak tanımıştır. Örneklem grubu, farklı demografik ve sosyo-ekonomik özelliklere sahip bireylerden oluşmaktadır. Bu demografik çeşitlilik, sürücülerin tünel algılarının ve sürüş deneyimlerinin sürüş davranışları üzerindeki etkilerini incelemek açısından önemli bir katkı sağlamaktadır.

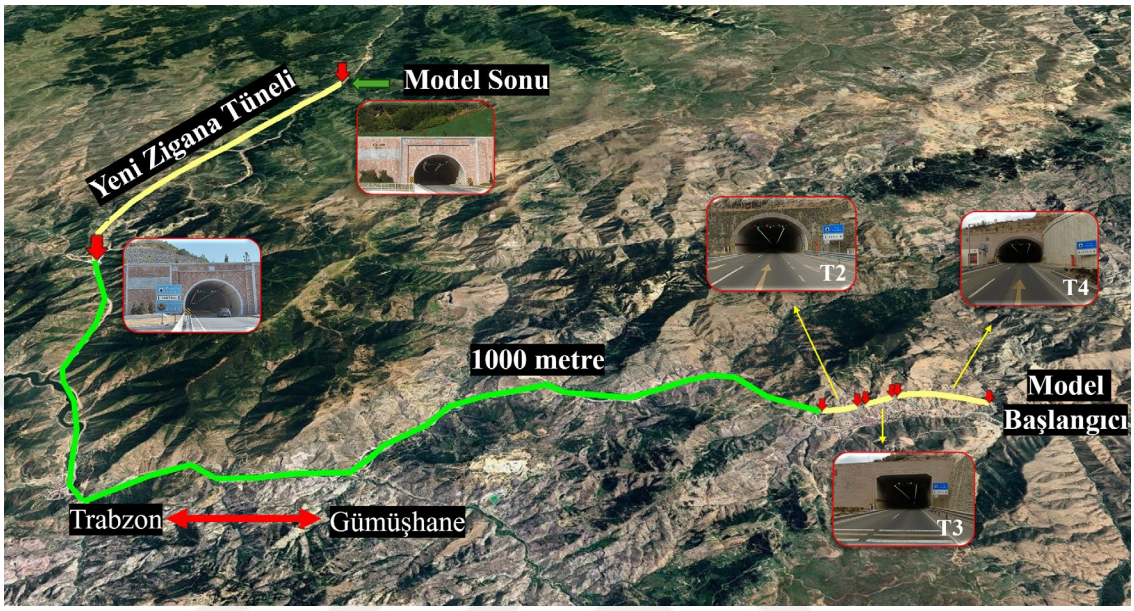
3.2.2. Model Tasarımı

Sürücü davranışlarının analizinde kullanılacak değişkenleri ölçebilmek amacıyla bir simülasyon modeli geliştirilmiştir (Şekil 16).

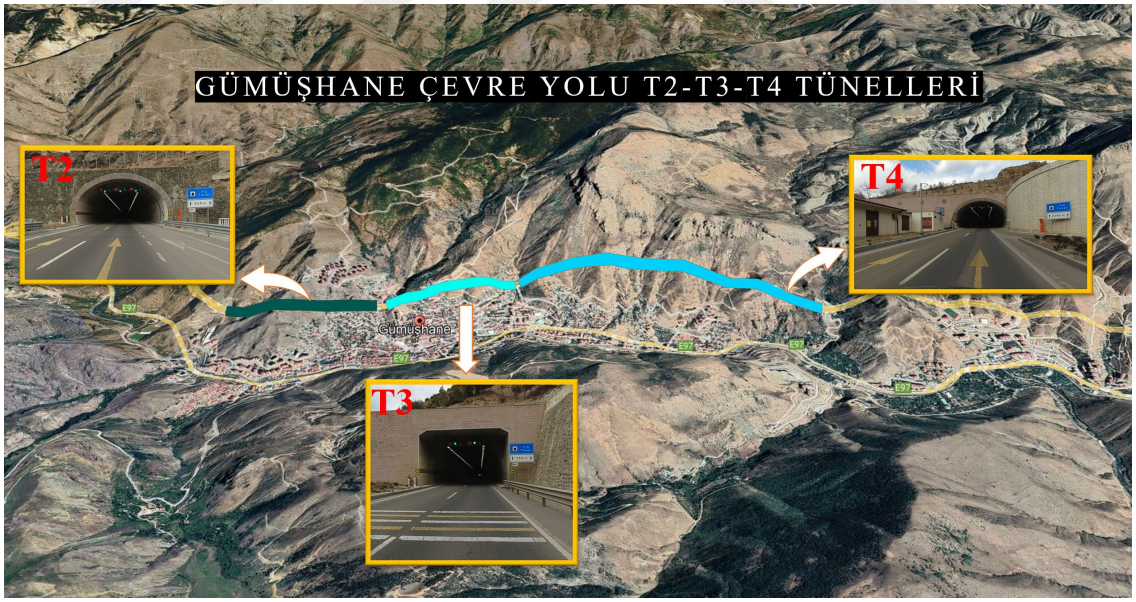


Şekil 16. Simülasyon başlangıç ekranı

Model kapsamında farklı trafik koşullarına ve geometrik özelliklere sahip 4 adet tünel tasarlanmıştır. Tüneller, Gümüşhane ili çevre yolunda bulunan ve uzunlukları sırasıyla 929, 754, 2255 ve 14476 metre olan T2, T3, T4 tünelleri ile Yeni Zigana Tüneli'nden oluşmaktadır. Tünellerin konumları Şekil 17 ve 18'de gösterilmektedir.



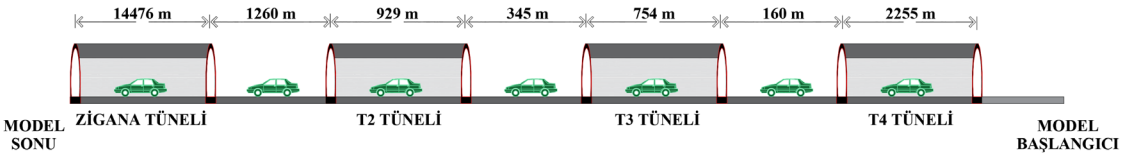
Şekil 17. Model için seçilen tünellerin konumları



Şekil 18. Gümüşhane çevre yolu tünellerinin konumları

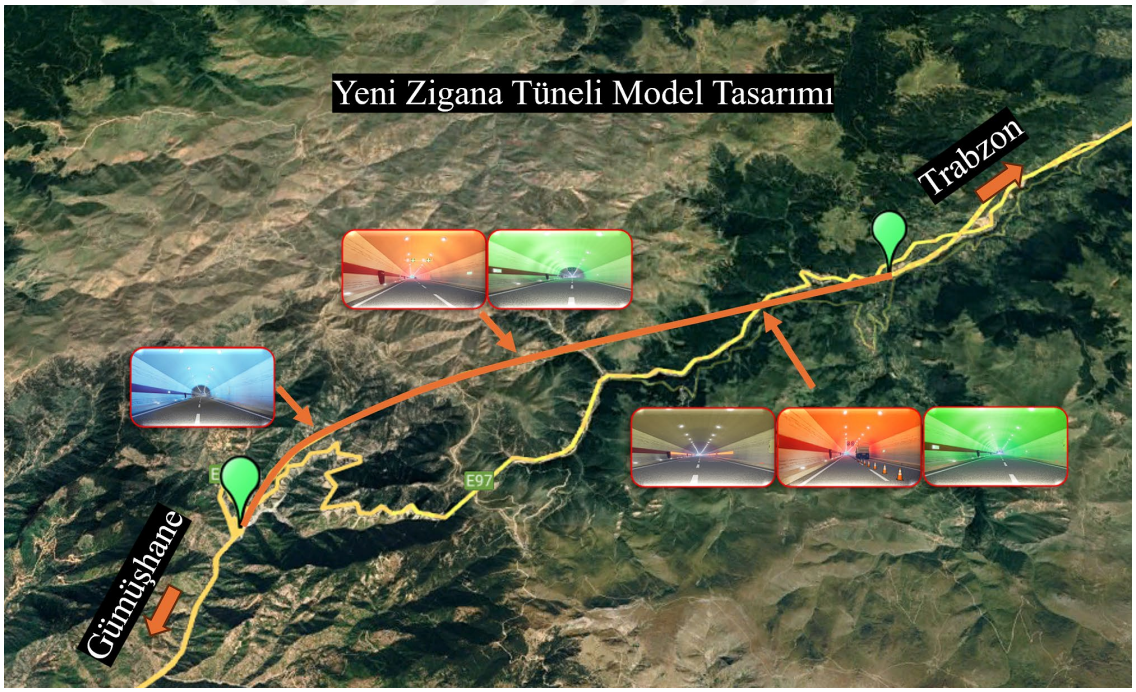
Tünellerin seçilme nedenleri arasında, bölgedeki tünelli geçişlerin fazlalığı ve bu yolların uluslararası karayolu niteliği taşıması önemli bir etken olarak öne çıkmaktadır. Ayrıca, tünellerde karşılaşılabilecek olumsuz durumlara yönelik olarak tasarlanan senaryoların uygulanabilirliği açısından bu yapıların en uygun seçenekler olduğu

değerlendirilmiştir. Bu tüneller, Şekil 19'da şematik olarak gösterildiği şekilde tasarlanmış ve sayısal modelleme çalışmaları Autocad, Netcad ve SketchUp programları kullanılarak gerçekleştirilmiştir.



Şekil 19. İlgili tünellerin modeldeki şematik gösterimi

Yapılan ölçüm ve çizimler sonucunda, tünellerin geometrik özellikleri birebir korunarak sayısal ortama aktarılmıştır. Sayısal ortamda oluşturulan bu veriler, UE5 programı için bir altlık olarak kullanılmış ve bu veriler aşağıdaki şekillerde (Şekil 20-24) görüldüğü gibi modellenmiştir.



Şekil 20. Zigana Tüneli model tasarımı



Şekil 21. Zigana Tüneli model tasarımı



Şekil 22. T4 Tüneli model tasarımı



Şekil 23. T3 Tüneli model tasarımı



Şekil 24. T2 Tüneli model tasarımı

3.2.3. Sürüş Senaryoları

Model kapsamında tasarlanan 12 senaryo, çeşitli sürücü davranışlarını ve güvenlik parametrelerini incelemeyi hedefleyerek, tünel sistemlerinde sürücü-çevre etkileşiminin değerlendirilmesini amaçlamaktadır. Araştırma modeli, tünel giriş-çıkış dinamikleri, ağır taşıt etkileşimleri ve çevresel faktörlerin sürücü davranışlarına etkisini sistematik bir yaklaşımla ele almaktadır. Tablo 5, tasarlanan senaryoları, incelenen temel konuları, modeldeki yerlerini ve senaryo numaralarını içermektedir. Sürücülerin sürüş boyunca toplanan verileriyle yapılan incelemelere senaryo numarası verilmemiştir.

Tablo 5. İncelenen temel konular ve modeldeki yerleri

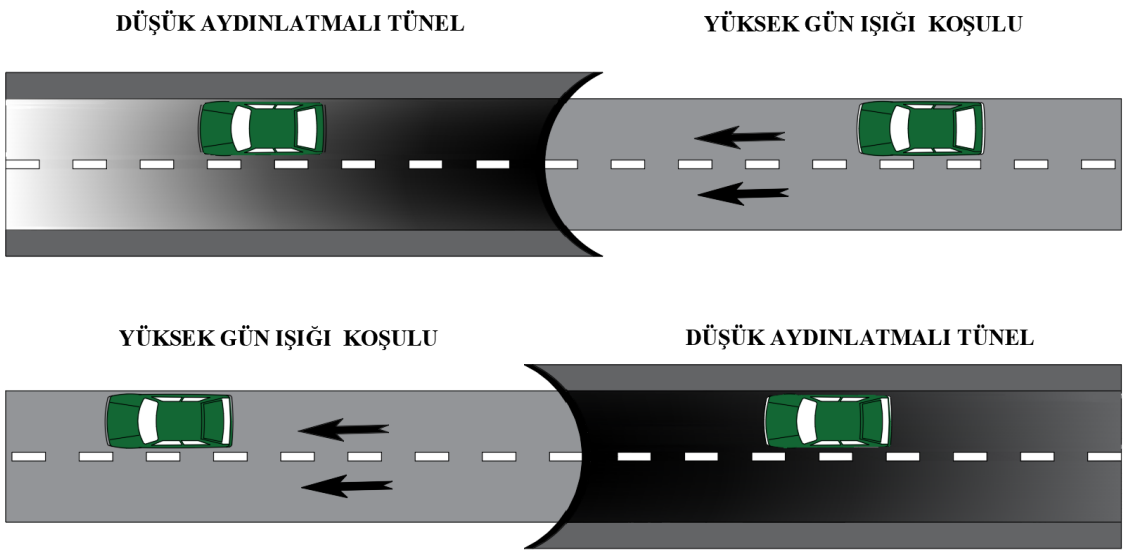
İncelenen Temel Konular	Modeldeki Yeri	Senaryo Numarası
Aydınlatma Değişimlerinde Sürücü Davranışlarının İncelenmesi	T4 tünel girişi	Senaryo 1
	T4 tünel çıkışı	Senaryo 3
	T3 tünel çıkışı	Senaryo 5
	T2 tünel girişi	Senaryo 6
	T2 tünel çıkışı	Senaryo 7
	Zigana Tüneli girişi	Senaryo 8
Ağır Taşıtlarla Karşılaşmada Sürücülerin Şerit Disiplini ve Hız Davranışlarının İncelenmesi	T4 tünel içi	Senaryo 2
	T3 tünel girişi	Senaryo 4
	Zigana Tüneli içi	Senaryo 9
Uzun Tünel Sürüşlerinde Sürücü Yorgunluğu ve Hız Davranışlarının İncelenmesi	Zigana Tüneli içi	Senaryo 10
Kesikli Tünellerde Hız ve Şerit Disiplininin İncelenmesi	T4-T3-T2 tünelleri ve tünelsiz kesimlerdeki sürüş metrikleri	
Geçiş Manevralarının İncelenmesi	Bu veriler tüm sürüş süresince ölçüldüğünden senaryo numarası verilmemiştir	
Kırmızı Tavan Aydınlatması Altında Tehlike Algılanabilirliği ve Hız Değişiminin İncelenmesi	Zigana Tüneli içi	Senaryo 11
Şerit Kapatma ve Kırmızı Tavan Aydınlatmasında Sürücü Tepkilerinin İncelenmesi	Zigana Tüneli içi	Senaryo 12

Aydınlatma değişimlerinin sürücü davranışları üzerindeki etkisi, T4, T3 ve T2 tünellerinde yapılan analizlerle ortaya konmuştur. T4 tünel girişi (Senaryo 1), T4 tünel çıkışı (Senaryo 3), T3 tünel çıkışı (Senaryo 5), T2 tünel girişi (Senaryo 6) ve T2 tünel çıkışı (Senaryo 7) koşullarında sürücülerin hız ve tepki süreleri ölçülmüştür. Zigana tüneli girişi için de ayrı bir senaryo (Senaryo 8) oluşturulmuştur. Ağır taşıtlarla karşılaşmada şerit disiplini ve hız davranışları, T4 tünel içi (Senaryo 2), T3 tünel girişi (Senaryo 4) ve Zigana tüneli içi (Senaryo 9) kapsamında analiz edilmiştir. Uzun tünel sürüşlerindeki sürücü yorgunluğu ve hız davranışları, Zigana tüneli içi için oluşturulan Senaryo 10 üzerinden incelenmiştir. Kesikli tünellerde hız ve şerit disiplini, T4, T3 ve T2 tünelleri ile tünelsiz kesimlerde elde edilen sürüş metrikleri üzerinden karşılaştırmalı olarak analiz edilmiştir. Geçiş manevraları, süreklilik arz eden bir veri toplama süreci gerektirdiğinden ve model içerisinde karşılaşılan araçların konumu sürekli değişiklik gösterdiğinden ilgili araçla karşılaştıkları andaki davranışları incelenmiştir. Kırmızı tavan aydınlatması altında tehlike algısı ve hız değişimi, Zigana tüneli içi için Senaryo 11'de analiz edilmiştir. Ayrıca, şerit kapatma, Ledli uyarıcı ve kırmızı tavan aydınlatması altında sürücü tepkileri Senaryo 12 ile incelenmiştir. Ele alınan 7 temel konu şu şekildedir:

1-Aydınlatma Değişimlerinde Sürücü Davranışlarının İncelenmesi: Bu şartlardaki tünel sürüş ortamında, sürücülerin açık yolda yüksek gün ışığı koşullarından düşük aydınlatmalı bir tünele girişleri ve düşük aydınlatmalı bir tünelden yüksek gün ışığı koşullarına çıkışlarındaki davranışları incelenmiştir. Gerçek koşullar Şekil 25'te, şematik çizim Şekil 26'da ve senaryo tasarımı ise Şekil 27 ve 28'de gösterilmektedir.



Şekil 25. Aydınlatma senaryosunun gerçek koşullardaki durumu



Şekil 26. Aydınlatma senaryosunun şematik gösterimi



Şekil 27. Düşük aydınlatmalı tünelden yüksek gün ışığı koşullarına çıkış



Şekil 28. Yüksek gün ışığı koşulundan düşük aydınlatmalı tünele giriş

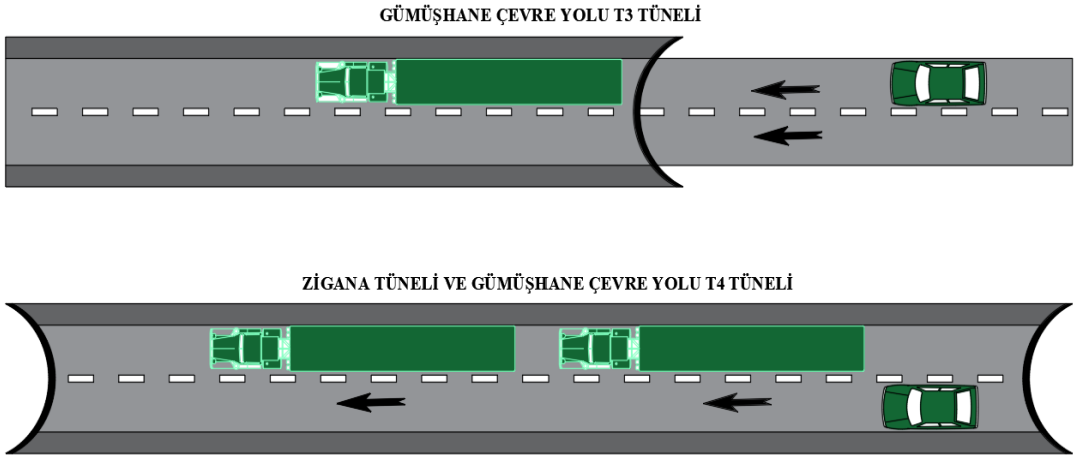
Yüksek gün ışığı koşullarına sahip karayolundan düşük aydınlatmalı bir tünele geçiş sırasında sürücülerin gözlerinin değişen aydınlatma seviyelerine uyum süreci, görme yetisinin geçici olarak azalması ve buna bağlı hız değişiklikleri incelenmiştir. Benzer şekilde, düşük aydınlatmalı bir tünelden yüksek gün ışığı koşullarına sahip

karayoluna çıkışta, görme yetisinin azalması sonucu oluşabilecek riskli sürüş davranışları, örneğin ani hızlanma veya frenleme eğilimleri değerlendirilmiştir. Bu senaryo, tünel giriş-çıkış bölgelerindeki ani aydınlatma değişikliklerinin sürücü davranışları üzerindeki etkilerini ve bu değişikliklerin sürüş güvenliği açısından oluşturabileceği risk faktörlerini belirlemeyi amaçlamaktadır. Elde edilen veriler, sürücü sınıflandırma sürecinde öznitelik olarak kullanılmıştır

2-Ağır Taşıtlarla Karşılaşmada Sürücülerin Şerit Disiplini ve Hız Davranışlarının İncelenmesi: Sürücülerin tünel içinde ve tünel girişinde ağır taşıtlarla karşılaştıklarında sergiledikleri davranışlar incelenmiştir. Tünel gibi sınırlı manevra alanına sahip ortamlarda ağır taşıtlarla karşılaşmak sürücüler üzerinde stres yaratabilmekte ve bu durum sürüş güvenliğini doğrudan etkileyebilmektedir. Ağır taşıtların varlığı, sürücülerin hızlanma veya yavaşlama eğilimlerini ve şerit disiplinini önemli ölçüde etkileyebilmektedir. Gerçek koşullarda gözlemlenen durum Şekil 29'da, modellenen senaryonun şematik gösterimi Şekil 30'da ve model üzerinde oluşturulan senaryonun görselleri ise Şekil 31 ve 32'de sunulmaktadır.



Şekil 29. Ağır taşıt senaryosunun gerçek koşullardaki durumu



Şekil 30. Ağır taşıt senaryosunun şematik gösterimi



Şekil 31. Tünel içinde ağır taşıt ile karşılaşma



Şekil 32. Tünel girişinde ağır taşıt ile karşılaşma

Senaryo kapsamında, ağır taşıtlarla karşılaşan sürücülerin şerit disiplinini nasıl korudukları, hızlarını nasıl ayarladıkları ve gerektiğinde şerit değiştirme gibi davranışları gözlemlenmiştir. Bunun yanı sıra, sürücülerin hızlarında ani değişiklik yapıp yapmadıkları ve takip mesafesini ne ölçüde koruyabildikleri incelenmiştir. Bu gözlemler, ağır taşıtların varlığının sürüş güvenliği üzerindeki etkilerini değerlendirmek ve sürücü davranışlarındaki potansiyel risk faktörlerini belirlemek için gerçekleştirilmiştir.

3-Uzun Tünel Sürüşlerinde Sürücü Yorgunluğu ve Hız Davranışlarının İncelenmesi: Bu senaryoda, sürücülerin uzun tünellerde sürüş sırasında yaşadığı yorgunluk, sıkılma ve dikkat kaybı gibi durumların hız ve sürüş davranışları üzerindeki etkileri değerlendirilmiştir. Senaryonun şematik gösterimi Şekil 33'te verilmiştir. Uzun tüneller, monoton sürüş koşulları oluşturarak sürücülerde dikkat dağılması, yorgunluk ve sürüş motivasyonunda azalma gibi etkiler meydana getirebilmektedir. Bu durum, sürücülerin hız sınırlarını aşmalarına veya tehlikeli sürüş davranışları sergilemelerine neden olabilmektedir.



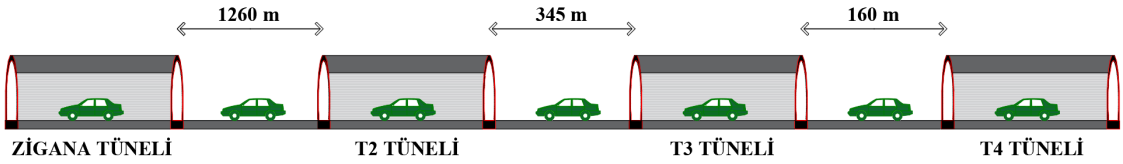
Şekil 33. Uzun tünel sürüşü senaryosunun şematik gösterimi

Senaryo kapsamında, sürücülerin uzun tünellerde hız ihlali yapma eğilimleri, hızlanma veya yavaşlama davranışları, şerit disiplini ve sürüş motivasyonlarındaki değişiklikler incelenmiştir. Bu senaryo, uzun tünellerde yorgunluk ve sıkılma gibi psikolojik faktörlerin sürüş performansı üzerindeki etkilerini ele almakta ve bu davranışların trafik güvenliği açısından yaratabileceği potansiyel riskleri ortaya koymayı amaçlamaktadır. Ayrıca, sürücülerin uzun tünellerin belirli kesimlerinde sergilediği tehlikeli davranışların tespiti, bu verilere dayanarak tünel güvenliğini artırmaya yönelik alınabilecek önlemlere katkıda bulunmayı hedeflemektedir.

4-Kesikli Tünellerde Hız ve Şerit Disiplininin İncelenmesi: Bu senaryoda, sürücülerin farklı uzunluklara sahip kesikli tünellerde (ara ara açık alanlarla bölünen) sergiledikleri hız ve şerit disiplini davranışları incelenmiştir. Kesikli tüneller, sürücülere bir tünelden çıkıp kısa bir açık alan geçtikten sonra tekrar tünele girme deneyimi sunduğundan, bu tür kesintilerin hız ve şerit değiştirme davranışları üzerinde etkili olabileceği değerlendirilmiştir (Şekil 34). Senaryo kapsamında, sürücülerin kesikli tünellere giriş ve çıkışlarında hız değişimleri, şerit disiplini ve ani hızlanma veya yavaşlama eğilimleri analiz edilmiştir. Senaryonun şematik gösterimi Şekil 35'te sunulmuştur.



Şekil 34. Kesikli tünel senaryosunun gerçek koşullardaki durumu



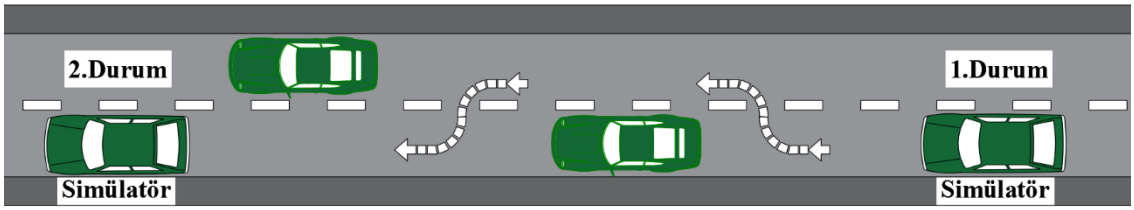
Şekil 35. Kesikli tünel senaryosunun şematik gösterimi

Toplanan veriler, sürücülerin kesikli tünel yapılarına nasıl uyum sağladıklarını, hızlarını nasıl ayarladıklarını ve şerit disiplinini nasıl koruduklarını anlamak amacıyla değerlendirilmiştir. Senaryonun model üzerindeki durumu Şekil 36'da sunulmuştur. Bu senaryo, kesikli ve uzun tünel yapılarına yönelik sürüş güvenliğini artıracak stratejiler geliştirmeyi ve bu iki yapı arasındaki farkların sürüş davranışları üzerindeki etkilerini tespit etmeyi hedeflemektedir.



Şekil 36. Kesikli tünel senaryosunun modeldeki durumu

5-Geçiş Manevralarının İncelenmesi: Bu senaryoda, sürücülerin sol şeritte hız limitine uyan bir araçla karşılaştıklarında sergiledikleri davranışlar ve sağ şeritte ilerlerken sollama davranışlarını emniyetli geçiş görüş mesafesi kurallarına uygun şekilde yapıp yapmadıkları incelenmiştir. Senaryonun şematik gösterimi Şekil 37'de, model üzerindeki durumu ise Şekil 38'de sunulmuştur. Bu senaryo, sürücülerin şerit değiştirme ve sollama kararlarının trafik güvenliği açısından değerlendirilmesini amaçlamaktadır.



Şekil 37. Geçiş manevrası senaryosunun şematik gösterimi

Tünel ve dar yol koşullarında sollama yapmak, ciddi riskler taşıyan bir davranış olarak değerlendirilmektedir (Yeung ve Wong, 2014). Özellikle, hız limitine uymayan

sürücülerin, sol şeritte hız limitine uyan bir araçla karşılaştıklarında sağdan geçme ya da ani fren yapma gibi hatalı davranışlar sergileme eğiliminde olabilirler. Bu senaryoda, sürücülerin sollama kararı verme süreçleri, hız değişimleri ve bu süreçte ani frenleme ya da hatalı sollama yapma eğilimleri analiz edilmiştir. Ayrıca, sürücülerin sol şeridi doğru şekilde kullanıp kullanmadıkları ve bu davranışların trafik güvenliği üzerindeki etkileri değerlendirilmiştir. Şekil 38'deki gibi modellenen bu senaryodan elde edilen veriler, sürücü sınıflandırma sürecinde öznitelikler olarak kullanılmıştır.



Şekil 38. Geçiş manevrası senaryosunun modeldeki durumu

6-Kırmızı Tavan Aydınlatması Altında Tehlike Algılanabilirliği ve Hız Değişiminin İncelenmesi: Mevcut durumda Yeni Zigana Tüneli'nde uygulanan ve sürücülere açık ortamdaymış hissi veren mavi tavan aydınlatmasına (Şekil 39) alternatif olarak, bu senaryoda tünel içinde uygulanan kırmızı tavan aydınlatmasının sürücüler tarafından bir tehlike veya problem olarak algılanıp algılanmadığı değerlendirilmiştir. Çalışmada Zigana Tüneli birebir modellendiğinden mavi tavan aydınlatması uygulaması da model içerisinde yer almış (Şekil 40) ancak analizlere dahil edilmemiştir.

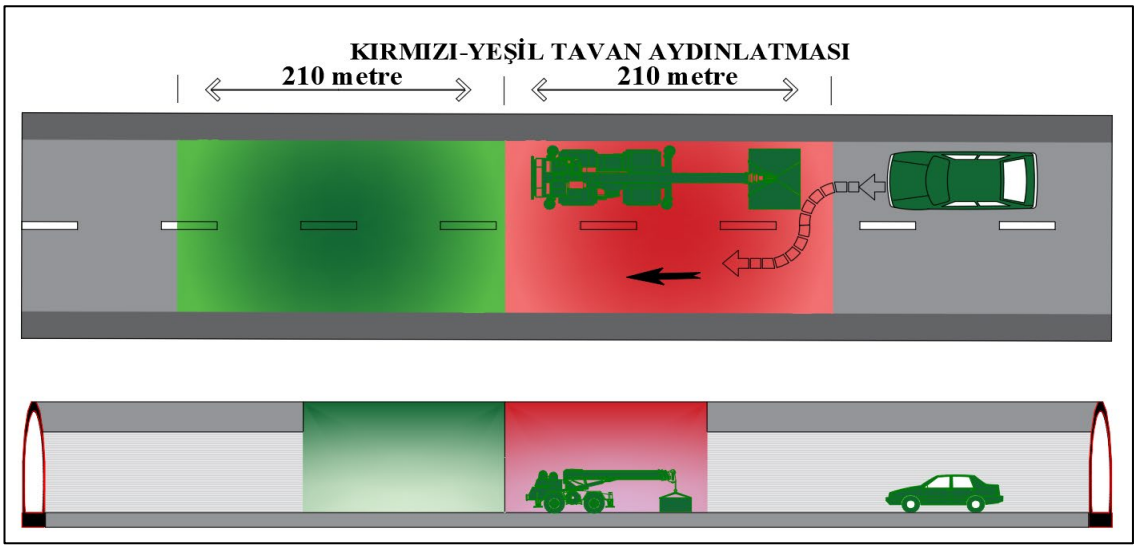


Şekil 39. Mevcut durumdaki mavi tavan aydınlatması uygulaması



Şekil 40. Modeldeki mavi tavan uygulaması

Kırmızı renk, genellikle tehlike ve aciliyeti simgelediği için tünel gibi kapalı ortamlarda kırmızı tavan aydınlatmasının sürücüler üzerinde tehlike sinyali etkisi yaratabileceği düşünülmektedir. Bu senaryo kapsamında, şematik gösterimi Şekil 41'de, modeldeki durumu Şekil 42'de sunulan, tünelin iç kesiminde kırmızı tavan aydınlatması uygulanmış ve bu aydınlatma boyunca sürücülerin hız, şerit disiplini ve genel sürüş davranışlarında meydana gelen değişiklikler gözlemlenmiştir.



Şekil 41. Kırmızı tavan aydınlatması senaryosunun şematik gösterimi



Şekil 42. Kırmızı tavan aydınlatması uygulaması

Ayrıca, bu senaryoda, sağ şeritte duran bir aracın varlığı (Şekil 43) karşısında sürücülerin sergiledikleri yavaşlama, şerit değiştirme, frenleme veya kaza yapma gibi tepkiler gözlemlenmiştir. Kırmızı tavan aydınlatması, tehlikeli veya problemli bir bölgeyi işaret etmekte, bu bölgenin ardından gelen yeşil tavan aydınlatması (Şekil 44) ise tehlikenin sona erdiğini ifade etmektedir. Her iki aydınlatma türünün, sürücülerin tehlike algısı ve dikkat düzeyi üzerindeki etkileri incelenmiş, ayrıca sürücülerin bu tür görsel ve işitsel uyarıcılara verdikleri tepkiler değerlendirilmiştir.

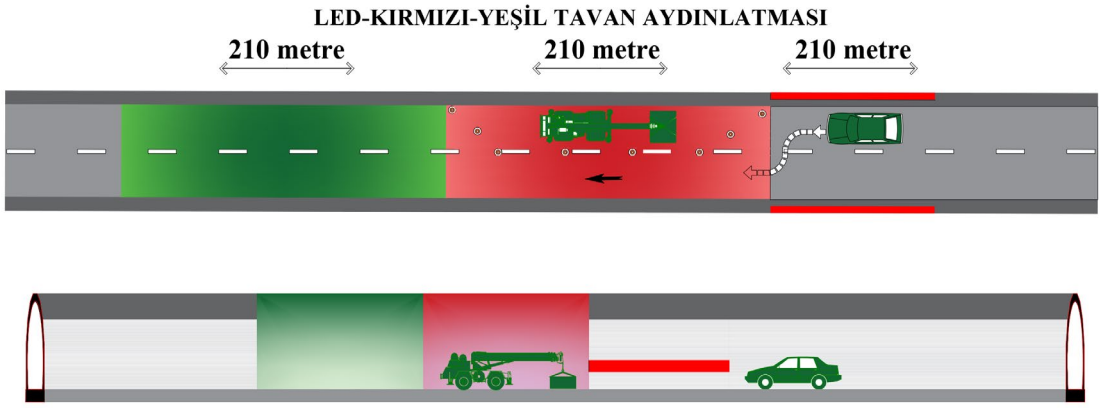


Şekil 43. Sağ şeritte duran bakım aracı uygulaması



Şekil 44. Yeşil tavan aydınlatması uygulaması

7-Şerit Kapatma ve Kırmızı Tavan Aydınlatmasında Sürücü Tepkilerinin İncelenmesi: Bu senaryoda, tünel içinde uygulanan şerit kapatma, kırmızı tavan aydınlatması, yeşil tavan aydınlatması ve yan duvarlardaki kırmızı LED şerit uyarıcılarının sürücü davranışları üzerindeki etkileri değerlendirilmiştir. Şerit kapatma, sürücüler için ani manevra gerekliliği oluşturabilmekte ve bu durumlarda hız ile şerit değiştirme davranışları büyük önem taşımaktadır. LED uyarıcılar, sürücülere tehlike sinyali vererek dikkat seviyelerini artırmayı hedeflemektedir. Bu senaryoda, LED'li uyarının başladığı noktadan itibaren sürücülerin hızlanma, yavaşlama, ani şerit değiştirme ve şerit disiplini gibi davranışları incelenmiştir. Senaryonun şematik gösterimi Şekil 45'te, model içindeki durumu ise Şekil 46, 47, 48 ve 49'da sunulmuştur. Bu uyarıların, sürücülerin tehlikeyi algılama düzeyine ve hız ile şerit değiştirme davranışlarına olan etkileri analiz edilmiştir. Toplanan veriler, sürücü sınıflandırma sürecinde öznitelik olarak kullanılmış ve aynı zamanda bu veriler, daha güvenli tünel tasarımları geliştirme amacıyla değerlendirilmiştir.



Şekil 45. Tünel içi LED tabanlı trafik uyarı sisteminin şematik gösterimi



Şekil 46. Tünel içi LED tabanlı trafik uyarı sisteminin modeldeki uygulaması



Şekil 47. Kırmızı tavan aydınlatmasının modeldeki durumu



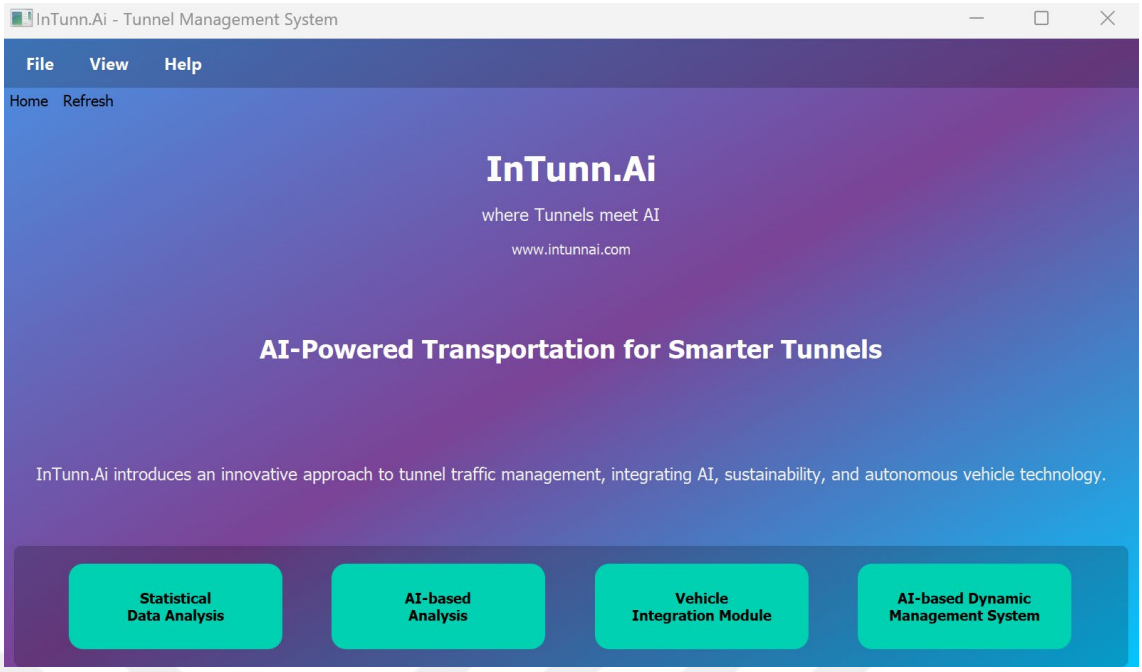
Şekil 48. Şerit kapatma uygulamasının modeldeki durumu



Şekil 49. Şerit açma ve yeşil tavan aydınlatması uygulamasının modeldeki durumu

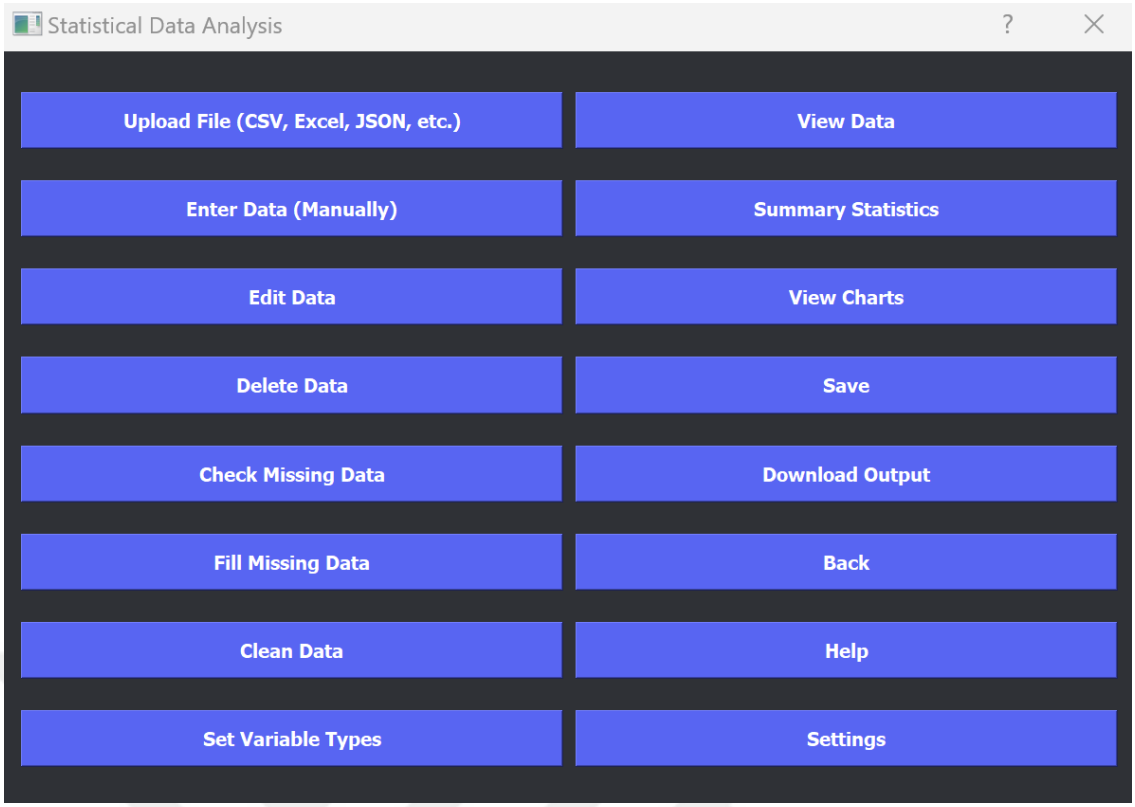
3.3. InTunn.Ai Yazılımı

Çalışma kapsamında, veri analitiği ve yapay zekâ tabanlı analizler gerçekleştirebilen InTunn.Ai isimli bir yazılım geliştirilmiştir. Yazılım, tünel trafik yönetiminde veri analitiği, yapay zekâ destekli analizler, araç entegrasyonu ve tam otomatik tünel yönetimi gibi işlevleri gerçekleştirebilecek modüllerden oluşmaktadır. Python programlama dili ile geliştirilen yazılımın kullanıcı ihtiyaçlarına yönelik olarak tasarlanmış arayüzü (Şekil 50), kolay ve etkili bir kullanım sağlamaktadır. Çalışma kapsamında InTunn.Ai yazılımının istatistiksel veri analizi modülü ve yapay zekâ tabanlı analiz modülü kullanılmıştır.

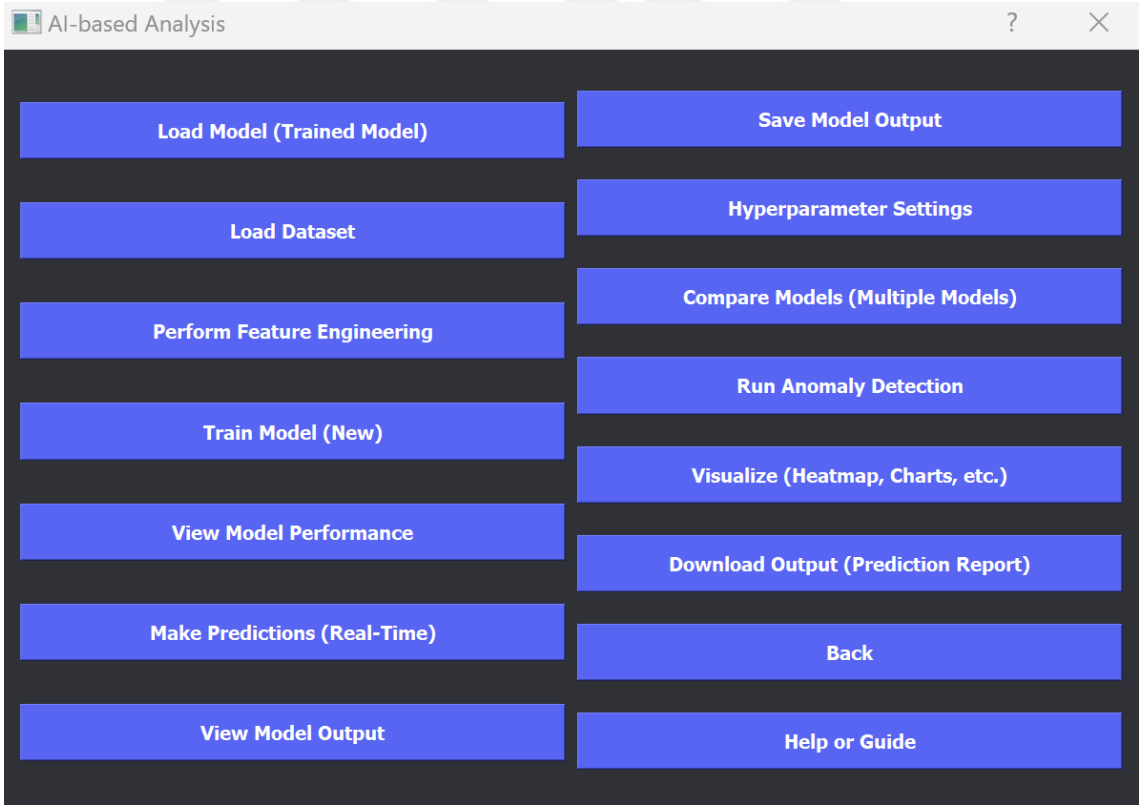


Şekil 50. InTunn.Ai programının arayüzü

Yazılım, istatistiksel veri analizi, yapay zekâ tabanlı analizler, araç entegrasyonu ve yapay zekâ destekli dinamik yönetim sistemi modüllerini içermektedir. İstatistiksel veri analizi modülü, tünel trafiğine ilişkin analizlerin gerçekleştirilmesi amacıyla tasarlanmış olup, kullanıcıların CSV, Excel ve diğer veri formatlarında yükleme yaparak veri düzenleme, temizleme, eksik veri tespiti, özet istatistikler oluşturma ve görselleştirme işlemlerini gerçekleştirmesine olanak sağlamaktadır. Yapay zekâ tabanlı analiz modülü, trafik dinamiklerini anlamak ve modellemek için çeşitli algoritmaları kullanmakta; kullanıcıların mevcut modelleri yüklemesine, yeni modeller oluşturmasına ve hiperparametre optimizasyonu yapmasına imkân vermektedir. Anomali tespiti ve veri görselleştirme araçları, analiz sürecinin kapsamlı bir şekilde değerlendirilmesini desteklemektedir. Modüllere ait görüntüler Şekil 51 ve 52'de sunulmuştur.



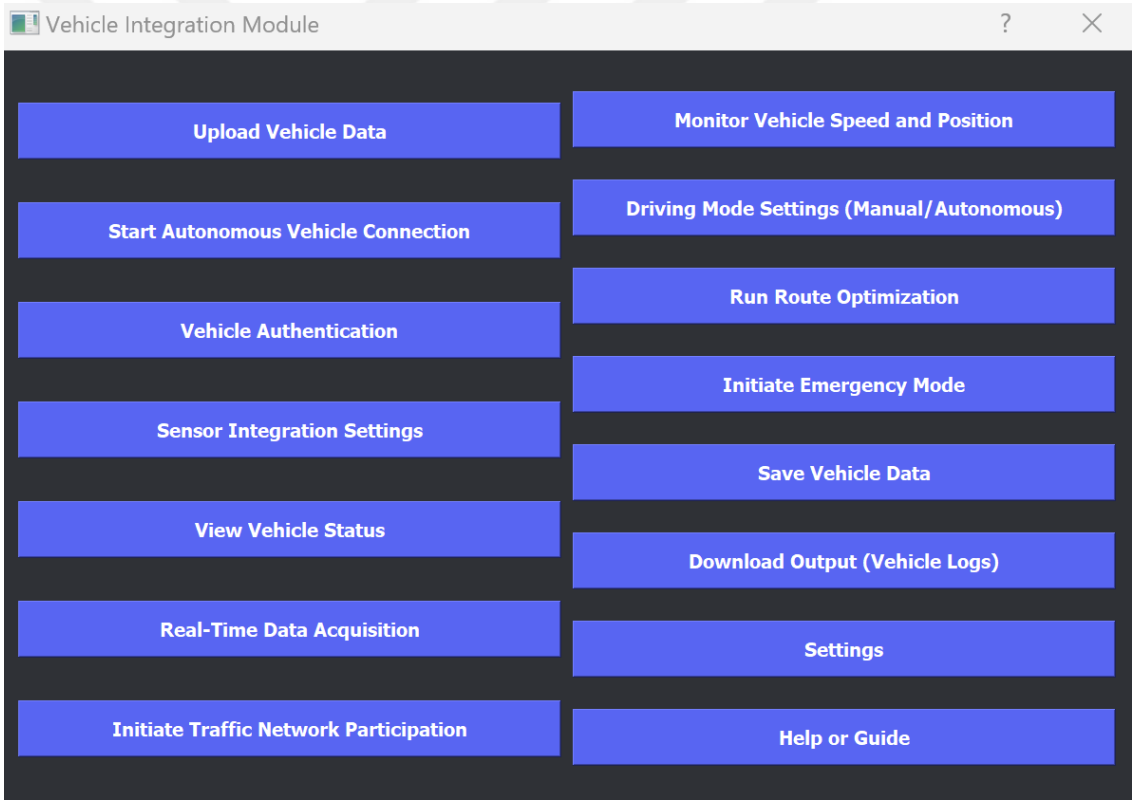
Şekil 51. İstatistiksel veri analizi modülü



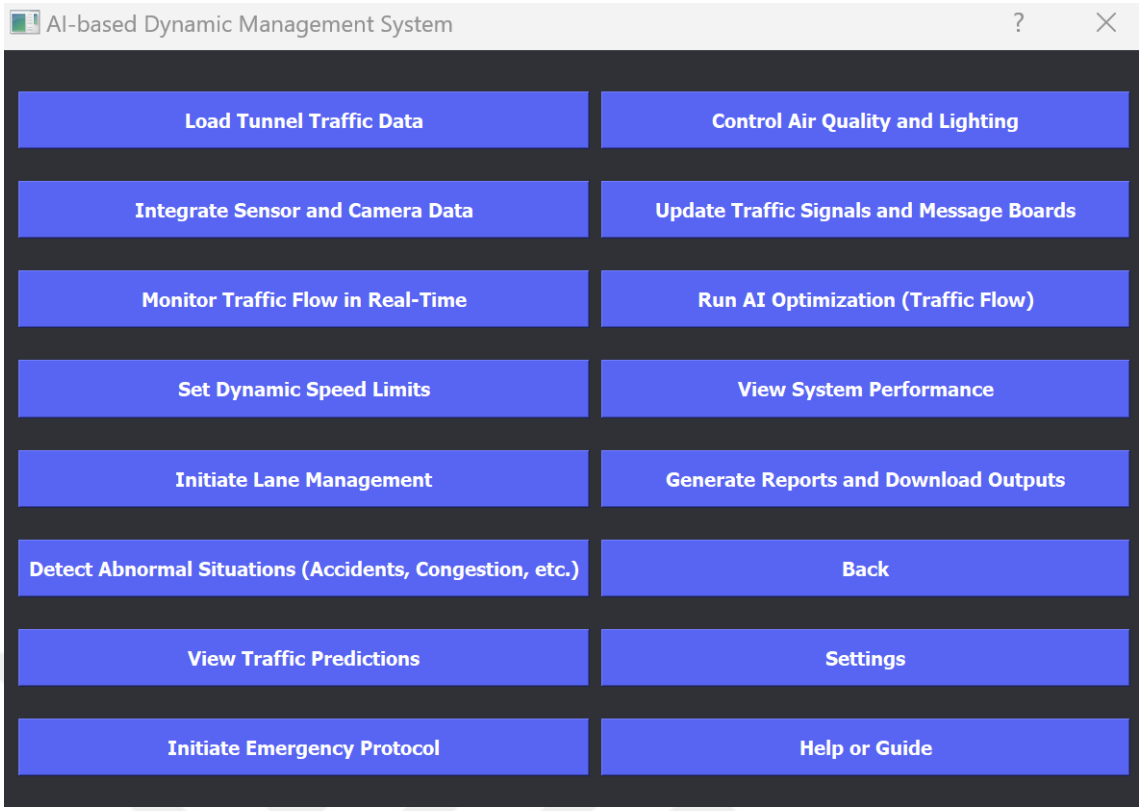
Şekil 52. Yapay zekâ tabanlı analizler modülü

Araç entegrasyon modülü, otonom ve klasik araçların tünel trafik yönetim sistemlerine entegrasyonunu hedeflemektedir. Bu modül, araç bilgilerinin yüklenmesi,

sensör entegrasyonu, gerçek zamanlı veri akışı ve sürüş modlarının izlenmesi gibi işlevlere sahiptir. Ayrıca, rota optimizasyonu ve acil durum senaryolarında güvenli trafik akışının sağlanması için çözümler geliştirmektedir. Henüz geliştirme aşamasında olan bu modül, ilerleyen süreçlerde daha kapsamlı işlevler sunacak şekilde genişletilecektir. Yapay zekâ tabanlı dinamik trafik yönetim sistemi modülü ise, tünel içi trafik akışını optimize etmeye yönelik olarak geliştirilmiş olup, pekiştirmeli öğrenme algoritmalarını kullanmaktadır. Modül, gerçek zamanlı veri akışına dayalı hız sınırlarının dinamik olarak belirlenmesi, şerit yönetimi, acil durum protokollerinin uygulanması ve çevresel faktörlerin, örneğin hava kalitesi ve aydınlatmanın, yönetimini içermektedir. Bu modül de geliştirme aşamasındadır ve gelecekte trafik yoğunluğu, güvenlik ve enerji verimliliği açısından daha etkili çözümler sunacak şekilde genişletilmesi planlanmaktadır. Modüllere ait görseller Şekil 53 ve 54'te sunulmuştur.



Şekil 53. Araç entegrasyon modülü



Şekil 54. Yapay zekâ tabanlı dinamik yönetim sistemi modülü

3.4.Veri Toplama Yöntemleri

3.4.1. Anket Verilerinin Toplanması

Simülatör deneylerinden önce ve sonra katılımcılardan anket verileri toplanmıştır. Sürüş öncesi uygulanan anket, katılımcıların demografik özelliklerini, araç kullanma alışkanlıklarını ve gerçek tünel sürüşlerine ilişkin deneyimlerini belirlemek amacıyla hazırlanmıştır. Sürüş sonrası uygulanan anket (simülatör performans ölçeği) ise katılımcıların simülatör deneyimine yönelik algılarını ve tepkilerini değerlendirmeyi hedeflemiştir. Anketler, dijital erişim kolaylığı ve hızlı veri toplama avantajı sağladığı için Google Forms platformu üzerinden uygulanmıştır. Sürüş öncesi anket formu, katılımcıların yaş, cinsiyet, sürücülük tecrübesi, tünel sürüşü geçmişi ve trafik güvenliği algısı gibi demografik ve deneyimsel bilgileri toplamak için tasarlanmıştır. Aynı zamanda, katılımcıların tünel sürüşüne ilişkin tedirginlik seviyelerine dair sorular da bu ankette yer almıştır. Sürüş sonrası ankette ise simülatör deneyiminin gerçekçiliği, katılımcıların tünel koşullarına verdikleri tepkiler (örneğin, hız kontrolü ve stres seviyeleri) ve genel sürüş deneyimi değerlendirilmiştir. Anketlerin dijital ortamda uygulanması, verilerin eş zamanlı toplanmasını ve analiz sürecinin hızlanmasını sağlamıştır. Sürüş öncesi anket formu ve sürüş sonrası simülatör performans ölçeği,

sırasıyla EK-1 ve EK-2'de sunulmuştur. Ayrıca, anketlerin uygulanması için Gümüşhane Üniversitesi Bilimsel Araştırma ve Yayın Etiği Kurulu tarafından verilen E-95674917-108.99-253421 sayılı onay yazısı EK-3'te yer almaktadır.

3.4.2. Simülatör Verilerinin Toplanması

Simülatör yazılımı, sürücünün hızını (m/sn), X ve Y koordinatlarını (metre cinsinden; çalışma kapsamında lokal koordinat sistemi tanımlanmıştır) ve sürüş saatini saniyede yaklaşık 9 adet veri noktası olacak şekilde ölçmekte ve elde edilen verileri metin dosyası formatında kaydetmektedir. Tablo 6'da yazılım tarafından kaydedilen veriler, örnek olarak iki sürücü için sunulmuştur. Ortalama bir sürüş süresinin 15 dakika olduğu dikkate alındığında her bir sürüşte yaklaşık 8.000-9.000 veri noktası kaydedilmektedir. Daha düşük hızlarla gerçekleştirilen sürüşlerde bu sayı artmaktadır.

Tablo 6. Yazılım tarafından kaydedilen sürüş verisi örneği

Sürücü No: T25				**Sürücü No: T61**			
X (m)	Y (m)	Hız (m/sn)	Saat	X (m)	Y (m)	Hız (m/sn)	Saat
750.704	2717.942	19.85	16:07:24	753.147	2716.760	16.69	14:47:59
750.217	2720.484	19.82	16:07:24	752.916	2718.467	16.75	14:47:59
749.814	2722.623	19.80	16:07:24	752.656	2720.388	16.83	14:47:59
749.350	2725.115	19.77	16:07:24	752.381	2722.418	16.91	14:47:59
748.987	2727.104	19.75	16:07:24	752.089	2724.581	16.99	14:47:59
748.586	2729.334	19.72	16:07:24	751.856	2726.304	17.06	14:47:59
748.208	2731.491	19.70	16:07:24	751.595	2728.243	17.12	14:47:59
747.848	2733.592	19.68	16:07:24	751.306	2730.387	17.20	14:47:59
747.511	2735.616	19.67	16:07:24	751.044	2732.327	17.27	14:47:59
747.158	2737.788	19.69	16:07:25	750.753	2734.487	17.35	14:48:00
746.849	2739.744	19.72	16:07:25	750.518	2736.233	17.41	14:48:00
746.523	2741.864	19.75	16:07:25	750.261	2738.148	17.47	14:48:00
746.196	2744.053	19.78	16:07:25	750.020	2739.939	17.54	14:48:00
745.897	2746.118	19.82	16:07:25	749.773	2741.782	17.60	14:48:00
745.600	2748.232	19.85	16:07:25	749.534	2743.559	17.66	14:48:00
745.288	2750.526	19.89	16:07:25	749.282	2745.437	17.73	14:48:00
745,022	2752.546	19.92	16:07:25	749.022	2747.377	17.79	14:48:00
744.727	2754.870	19.96	16:07:25	748.761	2749.329	17.86	14:48:00

Kaydedilen veriler, sürücünün hız, ivme, yatay yer değiştirme, ani frenleme ve ani hızlanma gibi sürüş davranışlarını analiz etmek için kullanılmıştır. Ayrıca, modellenen karayolunun eksen koordinatlarının aynı lokal koordinat sisteminde tanımlanmış olması sürücülerin şerit disiplini davranışlarının incelenmesine olanak tanımaktadır. Bunun yanı sıra hız ve zaman verilerinin mevcut olması, ivmelenme, ani frenleme ve ani hızlanma gibi davranışsal göstergelerin değerlendirilmesine imkân tanımıştır.

3.5. Makine Öğrenmesinin Tanımı ve Uygulama Alanları

Makine öğrenmesi, yapay zekânın temel alt disiplinlerinden biri olup sistemlerin verilerden öğrenme yeteneğini ve bu öğrenmeyi kullanarak performanslarını geliştirme sürecini ele almaktadır (Mariani vd., 2023). Geleneksel programlama yaklaşımlarından farklı olarak makine öğrenmesi, açıkça tanımlanmış kurallar yerine verilerdeki örüntüleri otomatik olarak öğrenme prensibine dayanmaktadır (Mariani vd., 2023). Günümüzde modern teknolojinin vazgeçilmez bir bileşeni haline gelen bu alan farklı sektörlerde yenilikçi uygulamalara olanak tanımaktadır (Rane vd., 2024). Makine öğrenmesi alanındaki ilerlemeler, son on yılda üç temel faktörün etkisiyle hız kazanmıştır. Dijital dönüşüm sürecinin tetiklediği eksponansiyel veri artışı, makine öğrenmesi modellerinin daha karmaşık örüntüleri öğrenebilmesini mümkün kılmıştır. Sensör teknolojilerindeki gelişmeler ve internet kullanımının yaygınlaşması, çeşitli disiplinlerde zengin veri kaynaklarının oluşumunu desteklemiştir (Solanki, 2024). Bunun yanı sıra, GPU ve TPU gibi özelleştirilmiş işlemcilerin geliştirilmesi, karmaşık modellerin eğitilmesini kolaylaştırmış ve eğitim sürelerini önemli ölçüde azaltmıştır. Bu modern donanım katkıları makine öğrenmesi uygulamalarının hızla yaygınlaşmasına önemli bir ivme kazandırmıştır (Zou, 2024).

Yeni optimizasyon teknikleri ve model mimarilerindeki gelişmeler, makine öğrenmesi süreçlerinin etkinliğini önemli ölçüde artırmıştır. Özellikle derin öğrenme alanındaki yenilikler, görüntü işleme ve doğal dil işleme gibi karmaşık görevlerde çığır açan sonuçların elde edilmesine olanak tanımıştır. Bu gelişmeler, sağlık bilimlerinde hastalık teşhisi ve ilaç geliştirme süreçlerinde yüksek doğruluk oranlarının yakalanmasını sağlamış, finans sektöründe ise risk analizi ve sahtekârlık tespitinde geleneksel yöntemlere kıyasla daha üstün performans sergilenmesine zemin hazırlamıştır (Mehmood vd., 2023). Üretim sektöründe, kalite kontrol ve bakım planlama süreçlerinde makine öğrenmesi uygulamaları, maliyetlerin düşürülmesine ve süreçlerin optimize edilmesine önemli katkılar sağlamaktadır. Sosyal medya platformlarında ise kişiselleştirilmiş içerik önerileri ve trend analizi gibi uygulamalar, kullanıcı deneyimini iyileştiren yaygın araçlar haline gelmiştir. Son dönem araştırmalar, makine öğrenmesi sistemlerinin güvenilirliği ve etik kullanımına odaklanmaktadır. Bu bağlamda, model yorumlanabilirliği ve adil öğrenme gibi konuların önemi giderek artmaktadır (Raheem Alzaidi ve Author, 2024).

Ulaştırma sektöründe, makine öğrenmesi uygulamaları operasyonel verimliliği artırmak ve güvenlik standartlarını geliştirmek adına önemli bir rol oynamaktadır (Azad vd., 2024). Öngörücü bakım sistemleri, taşıtların arıza risklerini analiz ederek bakım süreçlerini optimize etmekte ve maliyetleri düşürmektedir. Trafik yönetimi ve rota

optimizasyonu gibi alanlarda, gerçek zamanlı veri analizi sayesinde daha akıcı ve çevre dostu ulaşım çözümleri sunulmaktadır. Ayrıca, otonom araç teknolojilerinde makine öğrenmesi, çevresel algılama, karar verme ve hareket planlama gibi kritik görevlerde önemli bir bileşen olarak öne çıkmaktadır (Azad vd., 2024). Bu gelişmeler hem bireysel hem de toplu taşıma sistemlerinde yolcu deneyimini iyileştirmekte ve sürdürülebilir ulaşım hedeflerine katkıda bulunmaktadır.

3.5.1. Denetimli Öğrenme

Denetimli öğrenme, etiketli veriler kullanılarak modellerin girdi özelliklerine dayalı sonuçları tahmin etmesini mümkün kılan temel bir makine öğrenmesi yöntemidir. Bu yaklaşım, modelin öğrenme sürecini desteklemek ve doğru tahminler yapmasını sağlamak amacıyla, girdi ve çıktı çiftlerinden oluşan bir eğitim setine dayanmaktadır (Musicant vd., 2007). Denetimli öğrenmenin birincil amacı, eğitim verilerinden elde edilen bilgilerle, yeni ve görünmeyen örneklere genelleme yapabilecek bir hipotez geliştirmektir (Aiolli, 2016). Denetimli öğrenmede iki temel görev öne çıkmaktadır: sınıflandırma ve regresyon. Sınıflandırma, kategorik sonuçların tahmin edilmesini, giriş verilerine belirli sınıf etiketlerinin atanmasını içerirken, regresyon, sürekli sayısal değerlerin tahmin edilmesine odaklanmaktadır (Nasteski, 2017). Görev türü, çıktı değişkeninin niteliğine ve ele alınan problemin gereksinimlerine bağlı olarak belirlenmektedir. Denetimli öğrenmede başarı, genellikle ampirik risk minimizasyonu (ERM) ilkesine dayalı optimizasyon süreçleriyle elde edilmektedir. Bu yaklaşım, eğitim setindeki ortalama kaybı en aza indirmeyi amaçlayarak modelin tahmine dayalı performansını iyileştirmeye odaklanmaktadır (Aiolli, 2016).

Bir modelin performansı, tahmin edilen ve gerçek sonuçlar arasındaki farkı ölçen maliyet fonksiyonları kullanılarak değerlendirilmektedir (Steyerberg, 2008). Kayıp fonksiyonları, yanlış tahminlerin etkisini ölçerek optimizasyon sürecine rehberlik etmekte ve modelin daha yüksek performansa ulaşmasına katkı sağlamaktadır (Miller, 1993). Ancak, bu süreçler bazı zorlukları da beraberinde getirmektedir. Önemli bir sorun, eğitim verilerini çok iyi öğrenen modelin altta yatan kalıplar yerine veri gürültüsünü öğrenmesiyle ortaya çıkan aşırı uyum (overfitting) problemidir. Bu durum, modelin yeni veriler üzerindeki genelleme performansının düşmesine neden olabilmektedir (W. Wang vd., 2005). Bu riski azaltmak için çapraz doğrulama gibi yöntemler kullanılmaktadır. Çapraz doğrulama, veriyi eğitim ve doğrulama alt kümelerine ayırarak modelin genelleme kapasitesini değerlendirmekte ve performansın güvenilir bir şekilde

ölçülmesini sağlamaktadır (Vallejo, 2008). Bu teknik, aşırı uyum riskini azaltarak modelin sağlamlığını artırmaktadır.

Sonuç olarak, denetimli öğrenme, etiketli veri setlerini kullanarak tahmine dayalı görevler için güçlü bir makine öğrenimi yaklaşımı sunmaktadır. Eğitim setlerinin kalitesi, hipotez oluşturma süreçleri, optimizasyon yöntemleri ve doğrulama tekniklerinin etkili bir şekilde yönetilmesi, modelin karmaşık problemleri çözme yeteneğini önemli ölçüde artırmaktadır. Bu unsurlar, denetimli öğrenmenin farklı uygulama alanlarındaki başarısını desteklemekte ve yöntemi modern veri bilimi projelerinde vazgeçilmez bir araç haline getirmektedir.

3.5.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, makine öğrenmesinin temel yöntemlerinden biri olup, etiketli veriye ihtiyaç duymadan çalışmaktadır. Bu yöntem, giriş verilerini kullanarak veri setindeki gizli örüntüleri ve ilişkileri ortaya çıkarmayı hedeflemektedir (Nelles, 2001). Model, verileri gruplamak veya ortak özellikleri belirlemek için çalışırken, süreçte belirli bir hedef değişken bulunmamaktadır. Denetimsiz öğrenme, veri setinin yapısal özelliklerini keşfetmek ve anlamak için sıklıkla tercih edilmektedir (Nelles, 2001). Bu yöntemin öne çıkan uygulama alanlarından biri de kümeleme problemleridir. Kümeleme, veri setindeki verilerin ortak özelliklerine göre gruplara ayrılmasını sağlayan bir yöntemdir ve müşteri segmentasyonu, kullanıcı davranışlarına dayalı ürün önerileri veya genetik veri analizi gibi alanlarda yaygın olarak kullanılmaktadır. Bir diğer önemli uygulama alanı ise boyut indirgeme yöntemleridir (Ma ve Li, 2009). Boyut indirgeme, yüksek boyutlu veri setlerindeki temel özellikleri belirleyerek veriyi daha yönetilebilir bir forma dönüştürmektedir. Bu teknik, görüntü işleme, metin analizi ve veri görselleştirme gibi çeşitli alanlarda uygulanmaktadır (Anaissi vd., 2010).

Denetimsiz öğrenme süreci, veri setinin doğrudan analiz edilmesiyle başlamaktadır. Bu aşamada, model, veri içindeki gizli yapıları keşfetmek için çeşitli istatistiksel yöntemler ve algoritmalar kullanmaktadır (Zhang vd., 2006). Kümeleme uygulamaları için sıklıkla k-means, hiyerarşik kümeleme veya yoğunluk tabanlı yöntemler tercih edilmektedir. Model, veriler arasındaki benzerlikleri ve farklılıkları analiz ederek gruplama işlemini gerçekleştirmektedir (Singh ve Rajmani, 1996). Boyut indirgeme için temel bileşen analizi (PCA) ve t-SNE gibi yöntemler uygulanmakta ve veri daha basit bir yapıya dönüştürülmektedir. Denetimsiz öğrenme süreci sonucunda elde edilen çıktılar, yeni özelliklerin oluşturulması, veri setinin daha iyi anlaşılması ve sonraki analizlere hazırlık gibi çeşitli amaçlarla kullanılmaktadır. Denetimsiz öğrenme, özellikle

etiketlenmiş veri bulunmadığında ya da etiketleme maliyetlerinin yüksek olduğu durumlarda önemli avantajlar sağlamaktadır (Nelles, 2001). Bu yöntem, büyük ve karmaşık veri setlerinin işlenmesinde güçlü bir araç olarak öne çıkmakta ve veri analizi, örüntü tanıma ile bilgi keşfi gibi birçok alanda yaygın olarak uygulanmaktadır. Sağladığı esneklik ve maliyet avantajları nedeniyle, makine öğrenmesi projelerinde sıklıkla tercih edilmektedir.

3.5.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, makine öğrenmesinin önemli bir dalı olarak, bir ajan (model) ile çevre arasındaki etkileşim yoluyla öğrenmeyi ifade etmektedir. Bu yöntemde, ajan çevreden aldığı durum bilgisine dayanarak bir eylem seçmekte ve bu eylem sonucunda bir ödül veya ceza ile karşılaşmaktadır (Onat vd., 1997). Amaç, zaman içinde en yüksek toplam ödülü elde edecek bir politika öğrenmektir. Pekiştirmeli öğrenme, dinamik ve sürekli değişen çevrelerde etkili kararlar alabilen sistemlerin geliştirilmesinde yaygın olarak kullanılmaktadır. Bu yöntemin temelini ödül ve ceza mekanizması oluşturmaktadır (Onat vd., 1997). Ajan, doğru kararlar verdiğinde ödül alarak bu kararların tercih edilmesi gerektiğini öğrenmekte; ceza aldığında ise ilgili seçimin istenmeyen bir durumla sonuçlandığını anlamaktadır. Bu süreç, uzun vadeli sonuçların dikkate alındığı bir optimizasyon problemine dayanmaktadır. Ajan, ‘deneme ve yanılma’ yoluyla öğrenmekte ve bu süreçte uzun vadede daha iyi sonuçlar elde edecek şekilde davranışını geliştirmektedir (Onat vd., 1997).

Pekiştirmeli öğrenmenin çeşitli uygulama alanları bulunmaktadır. Oyun teorisi ve yapay zekâ oyun motorları bu yöntemin öne çıkan kullanım alanlarından biridir. Örneğin, Go veya satranç gibi karmaşık strateji oyunlarında yüksek performans gösteren sistemler, pekiştirmeli öğrenme algoritmalarına dayanmaktadır (Barakat vd., 2023). Robotikte, fiziksel çevrede etkileşim yoluyla hareket planlama ve kontrol problemleri bu yöntemle çözülebilmektedir. Ayrıca, otonom araçların geliştirilmesi, trafik düzenlemeleri ve adaptif sistemlerin tasarımı gibi birçok alanda pekiştirmeli öğrenme önemli bir rol oynamaktadır. Pekiştirmeli öğrenme süreci, birbiriyle ilişkili birkaç temel bileşenden oluşmaktadır. Ajan, çevre, durum, eylem, ödül ve politika bu bileşenlerin başlıcalarıdır. Ajan, mevcut durumuna dayanarak bir eylem seçmekte ve bu eylemi çevrede gerçekleştirmektedir (Escobar-Naranjo vd., 2023). Çevre, bu eylemin sonucunda ajanı yeni bir duruma taşımakta ve ödül ya da ceza sağlamaktadır. Ajan, aldığı ödül sinyallerine dayanarak politikasını güncellemekte ve daha etkili kararlar almayı öğrenmektedir. Bu süreç, genellikle Markov Karar Süreci (MDP) çerçevesinde modellenmekte ve Q-

öğrenme veya derin pekiştirmeli öğrenme gibi algoritmalarla uygulanmaktadır. Pekiştirmeli öğrenme, dinamik ve karmaşık problemlerin çözümünde güçlü bir yöntemdir. Ödül ve ceza mekanizması, ajanların bağımsız olarak öğrenmesini ve çevresel koşullara uyum sağlamasını mümkün kılmaktadır (Z. Zhou vd., 2024). Bu özellikler, pekiştirmeli öğrenmeyi veri bilimi ve yapay zekâ alanlarında güçlü bir araç haline getirmektedir.

3.6. Denetimli Öğrenme Yöntemiyle Sınıflandırma

Denetimli öğrenme yöntemleriyle sınıflandırma süreci, model performansının optimize edilmesi ve doğruluk düzeyinin artırılması amacıyla sistematik bir çerçeveye dayandırılmıştır. İlk aşamada, veri etiketleme işlemleri gerçekleştirilmiş ve sınıflar ile bu sınıflara karşılık gelen etiketler tanımlanmıştır. Ardından, veri ön işleme aşamasında veri setindeki eksik ya da hatalı veriler düzenlenerek standardize edilmiştir. Sonrasında, öznitelik mühendisliği süreci kapsamında, veri setinde yer alan önemli öznitelikler belirlenmiş, bazı öznitelikler dönüştürülmüş ve yeni öznitelikler oluşturulmuştur. Yüksek boyutlu veri setlerinin işlem maliyetlerini azaltmak ve modelin genelleştirme kapasitesini geliştirmek amacıyla boyut indirgeme teknikleri uygulanmıştır. Sınıflandırma aşamasında ise belirlenen sınıflandırma algoritmaları kullanılarak modeller eğitilmiş ve tahmin sonuçları elde edilmiştir. Modelin performansını artırmak amacıyla hiperparametre optimizasyonu gerçekleştirilmiş ve en uygun parametrelerin belirlenmesi sağlanmıştır. Performans değerlendirme sürecinde doğruluk, kesinlik, duyarlılık ve F1 skoru gibi değerlendirme metrikleri kullanılarak modellerin performansı analiz edilmiştir.

Son aşamada, model tahminlerinde özniteliklerin etkilerini belirlemek ve modelin yorumlanabilirliğini artırmak amacıyla SHAP (Shapley Additive Explanations) analizi uygulanmıştır.

3.6.1. Veri Etiketleme

Denetimli öğrenme yöntemlerinin temel gereksinimlerinden biri, verilerin doğru ve güvenilir bir şekilde etiketlenmesidir (Pelkmann vd., 2020). Bu çalışmada, sürücülerin risk seviyelerini belirlemek amacıyla kapsamlı bir puanlama sistemi geliştirilmiş ve simülatör yazılımına entegre edilmiştir. Sistem, belirlenen kriterler ışığında sürücü davranışlarını ‘Riskli’, ‘Orta’ ve ‘Risksiz’ olarak sınıflandırabilmektedir. Bu yöntemde trafik kurallarına uyum, güvenli sürüş parametreleri ve senaryo bazlı performans değerlendirmeleri esas alınmıştır. Sürücülerin etiketlenmesi sürecinde, ilgili yasal düzenlemelerden faydalanılmıştır. Bu bağlamda, Karayolları Trafik Kanunu’nun (URL-

6) 108. maddesinde yer alan '*Bu Kanunun suç saydığı bir fiilden dolayı haklarında ceza uygulanan sürücülere, aldıkları her ceza için esasları yönetmelikte belirlenen ceza puanları verilir*' hükmü ve Karayolları Trafik Yönetmeliği'nin (URL-7) '*Karayolları Trafik Kanunu'nun kural ihlali saydığı fiilden dolayı haklarında ceza uygulanan sürücülere, aldıkları her ceza için Sürücülere Uygulanacak Ceza Puanı Cetvelinde belirlenen ceza puanları verilir*' ifadesi dikkate alınmıştır. Ayrıca, Millî Eğitim Bakanlığı Özel Motorlu Taşıt Sürücüleri Kursu Yönetmeliği'nde (URL-8) yer alan '*Direksiyon Eğitimi Dersi Sınav Değerlendirme Formu*'ndaki kriterler de değerlendirme sürecine dahil edilmiştir. Sistem geliştirilirken, hız ve şerit disiplini gibi sürüş davranışlarıyla doğrudan veya dolaylı şekilde ilişkili olan ceza puan rehberi kriterleri ile direksiyon eğitimi sınav değerlendirme formundaki ilgili kriterler dikkate alınmıştır. Tablo 7'de puanlama sistemine dahil edilen ceza puan rehberi maddeleri (URL-9) ve direksiyon eğitimi sınav değerlendirme formu (URL-10) kriterleri sunulmuştur.

Tablo 7. İlgili kanun ve yönetmeliklerden hız ve şerit disiplini ile ilgili olan kriterler

Madde	İhlal	Ceza Puanı/Rengi
46/2-a	Aksine bir işaret bulunmadıkça sürücülerin, araçlarını, gidiş yönüne göre yolun sağından, çok şeritli yollarda ise yol ve trafik durumuna göre hızının gerektirdiği şeritten sürmemesi	20
46/2-b	Aksine bir işaret bulunmadıkça sürücülerin, şerit değiştirmeden önce gireceği şeritte sürülen araçların emniyetle geçişini beklememesi	20
46/2-c	Aksine bir işaret bulunmadıkça sürücülerin, trafiği aksatacak veya tehlikeye düşürecek şekilde şerit değiştirmesi,	20
46/2-d	Aksine bir işaret bulunmadıkça sürücülerin, gidişe ayrılan en soldaki şeridi sürekli olarak işgal etmesi,	20
46/2-e	Aksine bir işaret bulunmadıkça sürücülerin; iki veya daha fazla şeritli yollarda motosiklet, otomobil, kamyonet, panelvan, minibüs ve otobüs dışındaki araçları kullanırken, geçme ve dönme dışında en sağ şeridi izlememeleri	20
46/2-g	Aksine bir işaret bulunmadıkça sürücülerin; trafiği aksatacak veya tehlikeye sokacak şekilde ardı ardına birden fazla şerit değiştirmeleri,	20
47/1-d	Trafik işaret levhaları, cihazları ve yer işaretlemeleri ile belirtilen veya gösterilen hususlara uymamak	20
51/2-a/b/c	Yönetmelikte belirlenen hız sınırlarını aşmak (%10-%30, %30-%50, %50+)	10-15-15
52/1-a	Aracın hızını, kavşaklara yaklaşırken, dönemeçlere girerken, tepe üstlerine yaklaşırken, dönemeçli yollarda ilerlerken, yaya geçitlerine, hemzemin geçitlere, tünellere, dar köprü ve menfezlere yaklaşırken, yapım ve onarım alanlarına girerken azaltmamak	15
54/1-a	Öndeki aracı geçerken geçme kurallarına riayet etmemek	20
56/1-a	Şerit izleme ve değiştirme kurallarına uymamak	20
1 (Form)	Hız limitlerini aşma davranışı	Kırmızı
2 (Form)	Yol için belirlenen azami hız sınırına uyulmaması	Kırmızı
3 (Form)	Hız levhalarına uyulmaması	Kırmızı
4 (Form)	Hızlanma ve yavaşlamalarda aracın hızını ayarlayamama	Kırmızı
5 (Form)	Şerit çizgilerinin içinde araç kullanmama	Kırmızı
6 (Form)	Şerit değiştirirken çizgilerin anlamına uygun hareket etmeme (kesik/sürekli çizgiler)	Kırmızı

Tablo 7, sürücülerin trafik kurallarına uyumuna ilişkin belirli ihlalleri, bu ihlallerin ceza puanlarını ve sürüş risk seviyelerini değerlendiren kriterleri içermektedir. Tablo, trafik ihlallerine dayalı ceza puanları ve direksiyon sınav değerlendirme formu kriterleri şeklinde iki ana bölüme ayrılmaktadır. Tablonun ilk bölümü, Karayolları Trafik Kanunu ve Trafik Yönetmeliği'nde belirtilen trafik ihlallerine dayanmaktadır. Bu ihlaller, şerit disiplini, hız kontrolü ve trafik işaretlerine uyum gibi sürüş güvenliğini etkileyen temel parametreleri kapsamaktadır;

Şerit Disiplini İhlalleri (46/2-a, 46/2-b, 46/2-c, vb.): Sürücülerin şerit değiştirme kurallarını ihlal etmesi, gidiş yönüne göre uygun şeritte ilerlememesi ve sürekli olarak soldaki şeridi işgal etmesi gibi davranışlardır ve her biri için sürücüye 20 ceza puanı verilmektedir.

Hız Kontrolü (51/2-a/b/c, 52/1-a): Hız sınırlarını %10'dan %50'ye kadar aşan ihlaller veya hızın uygun koşullara düşürülmemesi gibi durumlar, 10-15 arasında değişen ceza puanları ile sınıflandırılmıştır. Özellikle tüneller, kavşaklar ve dar köprü gibi alanlarda hızın aşırı düşürülmesinin kritik ihlaller arasında yer aldığı düşünülmektedir.

Trafik İşaretlerine Uyumama (47/1-d): Trafik işaret levhalarına, cihazlara veya yol işaretlemelerine uymayan sürücülere 20 ceza puanı verilmektedir ve bu puanlar, ihlallerin ciddiyetini ve risk seviyesini belirlemek için kullanılmıştır. Tablonun ikinci kısmı, Millî Eğitim Bakanlığı Direksiyon Eğitimi Dersi Sınav Değerlendirme Formuna dayanmaktadır. Bu bölüm, sürücülerin hız kontrolü ve şerit disiplini gibi davranışlarını değerlendiren renk kodlarıyla risk seviyelerini belirten kriterleri içermektedir (hız ve şerit disiplinini ilgilendirmeyen mavi ve sarı renk kodları değerlendirme dışı bırakılmıştır).

Hız Davranışı (Kırmızı): Yol için belirlenen azami hız sınırlarına uymamak, hız levhalarına dikkat etmemek veya hızlanma ve yavaşlama sırasında aracın hızını ayarlayamamak gibi davranışlar yüksek risk grubunda yer almaktadır ve bu kuralara uymayan adaylar başarısız sayılmaktadır.

Şerit Disiplini (Kırmızı): Şerit çizgileri içinde araç kullanmama veya şerit değiştirirken çizgilerin anlamına uygun hareket etmeme gibi ihlaller, sürüş güvenliği açısından ciddi riskler arasında sayılmakta ve bu durumdaki adaylar başarısız kabul edilmektedir. Bu kriterlerden hareketle, özellikle hız ve şerit disiplini ile ilgili olanların en önemli kriterler olduğu belirlenmiştir. Bu doğrultuda, geliştirilen puanlama sisteminde genel hız ve şerit disiplinine ilişkin metrikler 4.25 puan, senaryolar bazında ölçülen metrikler ise 3 puan üzerinden değerlendirilmiştir (Tablo 8).

Tablo 8. Sürücü puanlama sistemi

Puanlama Sınıfı	Puan	Puan Sınıfı	Puan
Çevre Yolu Hız Limitine Uyma Oranı	4.25	Senaryo 4- Şerit Değişim Puanı	3
Zigana Tüneli Hız Limitine Uyma Oranı	4.25	Senaryo 5- Hız Puanı	3
Ani Hızlanma Puanı	4.25	Senaryo 5- Şerit Değişim Puanı	3
Sert Frenleme Puanı	4.25	Senaryo 6- Hız Puanı	3
Sağ Şerit Yanal Mesafe Puanı	4.25	Senaryo 6- Şerit Değişim Puanı	3
Sol Şerit Yanal Mesafe Puanı	4.25	Senaryo 7- Hız Puanı	3
Şerit Değişim Sayısı Puanı	4.25	Senaryo 7- Şerit Değişim Puanı	3
Emniyetli Geçiş Görüş Mesafesi Puanı	4.25	Senaryo 8- Hız Puanı	3
Senaryo 1- Hız Puanı	3	Senaryo 8- Şerit Değişim Puanı	3
Senaryo 1- Şerit Değişim Puanı	3	Senaryo 9- Hız Puanı	3
Senaryo 2- Hız Puanı	3	Senaryo 9- Şerit Değişim Puanı	3
Senaryo 2- Şerit Değişim Puanı	3	Senaryo 10- Hız Puanı	3
Senaryo 3- Hız Puanı	3	Senaryo 10- Şerit Değişim Puanı	3
Senaryo 3- Şerit Değişim Puanı	3	Senaryo 11- Hız Puanı	3
Senaryo 4- Hız Puanı	3	Senaryo 12- Hız Puanı	3

Bu puanlama sistemi, hem sürüş parametreleri (hız, yanal mesafe, ani hızlanma gibi) hem de senaryo bazlı davranışları dikkate alarak sürücüler için toplam bir puan hesaplamaktadır. Her bir puanlama kriteri ve bu kriterlerin belirlenmesinde kullanılan yöntemler şu şekildedir;

- **Çevre Yolu Hız Limitine Uyma Oranı:** Çevre yolunda hız limiti 70 km/sa olarak belirlenmiştir. Hız limitini 40-77 km/sa aralığında tutan sürücülere tam puan (4.25) verilmiştir. Bu sınırların dışına çıkan sürücüler için puanlama lineer şekilde azaltılmıştır.
- **Zigana Tüneli Hız Limitine Uyma Oranı:** Zigana Tüneli'nde hız limiti 80 km/sa olarak belirlenmiştir. Hız sınırını 50-88 km/sa aralığında tutan sürücüler tam puan (4.25) almış, limit dışı hızlarda ise lineer azalan puanlama uygulanmıştır.
- **Ani Hızlanma Puanı:** Sürüş sırasında, ivmelenmesi 2 m/s²'nin üzerine çıkmayan sürücülere tam puan verilmiştir.
- **Sert Frenleme Puanı:** Sert frenleme davranışı (ivme < -2 m/s²) sergilemeyen sürücüler tam puan almıştır.
- **Sağ Şerit Yanal Mesafe Puanı:** Sağ şerit genişliği 3.50 metre olup şerit ekseninin yol eksenine olan mesafesi 1.75 metredir. 1.60-1.90 metre aralığında araç kullanan sürücüler tam puan almıştır.
- **Sol Şerit Yanal Mesafe Puanı:** Sol şerit için de benzer bir mesafe değerlendirmesi yapılmıştır. Şerit içinde güvenli bir şekilde araç kullanan sürücülere tam puan verilmiştir.

- **Şerit Değişim Sayısı Puanı:** Sürücüler sağ şeritte düşük hızda (60 km/sa) seyreden araçları (sürüş boyunca 45 adet) sollama konusunda serbest bırakılmıştır. 45 şerit değişim sayısını aşan sürücülere puan verilmemiştir.
- **Emniyetli Geçiş Görüş Mesafesi:** Sürücüler sollama yaparken emniyetli geçiş görüş mesafesi kuralına uymak zorundadır. Sollama sırasında bu kurala uygun hareket eden sürücülere tam puan verilmiştir.
- **Senaryolar Bazında Hız Puanlama:** Her bir senaryoda sürücülerden hızlarını sabit tutmaları ya da güvenli şekilde azaltmaları beklenmiştir. Ani frenleme yapmadan bu kurallara uyan sürücüler, 12 senaryonun her birinde 3'er puan alarak toplamda 36 puan alabilecektir.
- **Senaryolar Bazında Şerit Değişimi Puanlama:** 10 senaryoda, sürücülerin güvenli şekilde şerit değiştirmeleri ya da şeritlerini korumaları beklenmiştir (Senaryo 11 ve 12'de sağ şerit kapalı olduğundan puanlama dışı bırakılmıştır). Güvenli şerit değiştiren veya şeritlerini koruyan sürücüler, 10 senaryonun her birinde 3'er puan alarak toplamda 30 puan alabilecektir.

Ani hızlanma, sert frenleme, hız limitine uyma ve yanal mesafe kontrolü gibi kriterler, sürücünün doğrudan kanun ve yönetmeliklerle düzenlenen temel sürüş davranışlarına dayanmaktadır. Bu kriterler de Karayolları Trafik Kanunu, Trafik Yönetmeliği ve Millî Eğitim Bakanlığı Direksiyon Eğitimi Dersi Sınav Değerlendirme Formu gibi yasal düzenlemelerde daha sık yer almakta ve trafik güvenliği açısından kritik önem taşımaktadır. Bu nedenle bu kriterlerin her biri için 4.25 puanlık bir ağırlıklandırma yapılmıştır. Senaryolar, belirli sürüş durumlarında sürücünün hız kontrolü ve şerit değiştirme davranışlarını ölçmek için tasarlanmıştır. Her bir senaryo, sürücünün trafik kurallarına uyumunu uygulamalı olarak değerlendirmeyi amaçlamaktadır. Ancak bu senaryoların amacı, yasal ihlallerden ziyade sürüş alışkanlıklarının analizi olduğundan, diğer kriterlere kıyasla daha düşük bir ağırlıkla (3 puan) değerlendirilmiştir. Bu ağırlıklandırma yaklaşımı, puanlama sisteminin hem yasal düzenlemelere uyumunu hem de uygulamalı sürüş değerlendirmelerine katkısını dengelemeyi amaçlamaktadır. Böylece, sürücünün trafik güvenliği açısından tüm davranışlarının kapsamlı bir şekilde analiz edilmesi sağlanmıştır.

3.6.2. Veri Ön İşleme

Veri ön işleme, makine öğrenmesi modellerinin başarısını doğrudan etkileyen önemli bir süreç olarak karşımıza çıkmaktadır (Bala ve Behal, 2024a). Ham verinin modelleme için uygun hale getirilmesi, analiz sonuçlarının güvenilirliği ve model

performansı açısından kritik bir öneme sahiptir. Bu süreçte, verilerin temizlenmesi, dönüştürülmesi ve düzenlenmesi gibi çeşitli işlemler sistematik bir şekilde gerçekleştirilmektedir (Chicco vd., 2022). Veri ön işleme, yapay zekâ modelleme süreçlerini optimize etmek ve modellere sağlanan verilerin gürültüsüz, alakalı ve tutarlı olmasını sağlamak için büyük bir öneme sahiptir. Veri kalitesini ve model verimliliğini artırmak amacıyla uygulanan bu süreç, veri temizleme, normalleştirme, öznitelik seçimi ve boyut indirgeme gibi bir dizi teknik içermektedir (Bala ve Behal, 2024b).

Veri analizi süreçlerinde aykırı değerler, veri setindeki diğer gözlemlerle uyumsuz olan veya belirgin şekilde farklılık gösteren veri noktalarıdır (Hou ve Su, 2024). Bu değerler, veri analizi ve modelleme aşamalarında sonuçların doğruluğunu ve güvenilirliğini olumsuz etkileyebilmektedir. Aykırı değerlerin doğru bir şekilde tespiti, analizlerin sağlamlığını artırmak ve yanlılığı en aza indirmek açısından kritik bir öneme sahiptir. Bu doğrultuda, aykırı değerlerin tespiti için çeşitli yöntemler geliştirilmiştir ve bu yöntemlerden biri de kutu grafiği analizidir (Aschepkov, 2024). Kutu grafiği, bir veri setinin dağılımını beş temel istatistiksel ölçü ile özetlemektedir: minimum değer, birinci çeyrek (Q1), medyan, üçüncü çeyrek (Q3) ve maksimum değer. Çeyrekler arası aralık (IQR = Q3 - Q1) yardımıyla belirlenen eşik değerler, aykırı değerlerin tespit edilmesinde kullanılmaktadır (Zhang vd., 2023). Bu yöntemde, Q1 - 1.5×IQR'den küçük veya Q3 + 1.5×IQR'den büyük olan değerler aykırı değer olarak sınıflandırılmaktadır (Montgomery, 2024).

Veri standardizasyonu, farklı ölçeklerdeki verileri ortak bir ölçekte ifade ederek, makine öğrenmesi modellerinin performansını artırmayı ve öğrenme süreçlerini iyileştirmeyi amaçlayan bir süreçtir (Abdelouahed vd., 2024). Bu süreç, özellikle özniteliklerin farklı büyüklüklerde olduğu veri setlerinde büyük bir öneme sahiptir. Standardizasyon, model parametrelerinin daha hızlı optimize edilmesini sağlamanın yanı sıra hesaplama süreçlerini daha istikrarlı hale getirmektedir. Veri standardizasyonunda yaygın olarak kullanılan yöntemler arasında ölçekleme ve normalizasyon teknikleri bulunmaktadır (Abdelouahed vd., 2024) .

Ölçekleme, veri setindeki özniteliklerin değer aralıklarını birbirine uyumlu hale getirmek amacıyla uygulanan bir tekniktir. Bu yaklaşım, özellikle mesafeye dayalı algoritmalarda (örneğin, k-En Yakın Komşu ve Destek Vektör Makineleri) büyük bir öneme sahiptir (Pagan vd., 2023). Başlıca ölçekleme yöntemleri şunlardır;

- Min-Max Ölçekleme: Veriyi 0 ile 1 arasındaki bir aralığa dönüştüren bir yöntemdir. Bu yaklaşım, verideki tüm değerleri aynı aralıkta ifade etmektedir ve şu şekilde hesaplanır (Eşitlik 1):

$$x' = \frac{x - x_{max}}{x_{max} - x_{min}} \quad \text{(Eşitlik 1)}$$

Bu eşitlikte:

x': Ölçeklenmiş veriyi,

x: Orijinal veriyi,

x_{min}: Veri kümesindeki minimum değeri,

x_{max}: Veri kümesindeki maksimum değeri ifade etmektedir.

- Z-Skor Ölçekleme (Standardizasyon): Veriyi ortalama etrafında standart sapmaya göre ölçeklendiren bir yöntemdir. Bu teknik, veriyi sıfır ortalamaya ve birim standart sapmaya dönüştürerek istatistiksel analizlerde ve makine öğrenmesi modellerinde yaygın olarak kullanılmaktadır. Şu şekilde hesaplanmaktadır (Eşitlik 2):

$$z = \frac{x - \mu}{\sigma} \quad \text{(Eşitlik 2)}$$

Bu eşitlikte:

x: Ölçekleme yapılacak orijinal veri değerini,

z: Standardize edilmiş veriyi,

μ: Veri kümesinin ortalamasını,

σ: Veri kümesinin standart sapmasını ifade etmektedir.

Normalizasyon, verilerin farklı büyüklük ve birimlerinden kaynaklanan farklılıklarını gidermek amacıyla uygulanan bir tekniktir. Özellikle doğrusal olmayan modellerde (örneğin, yapay sinir ağları), veri değerlerinin sınırlı bir aralığa indirgenmesi öğrenme sürecini iyileştirmektedir (Benatti vd., 2024). Başlıca normalizasyon teknikleri şunlardır;

- L1 Normalizasyonu: Her bir veri noktasını, o veri noktasındaki özniteliklerin toplamına bölerek normalizasyon sağlamaktadır. Bu yöntem şu şekilde ifade edilmektedir (Eşitlik 3):

$$x_i^{(L1)} = \frac{x_i}{L1_{norm}} = \frac{x_i}{\sum_{i=1}^{n} |x_i|} \quad \text{(Eşitlik 3)}$$

Bu eşitlikte:

x_i: Orijinal veri bileşenini,

$x_i^{(L1)}$: L1 normalizasyonu sonrası elde edilen normalleştirilmiş veri bileşenini ifade etmektedir.

- L2 Normalizasyonu: Veriyi, öklid normuna göre normalize eden bir tekniktir ve her bir veri noktası, özniteliklerin karelerinin toplamının karekköüne bölünerek şu şekilde normalize edilmektedir (Eşitlik 4):

$$x_i^{(L2)} = \frac{x_i}{L2_{norm}} = \frac{x_i}{\sqrt{\sum_{i=1}^{n} x_i^2}} \quad \text{(Eşitlik 4)}$$

Bu eşitlikte:

x_i: Orijinal veri bileşenini,

$x_i^{(L2)}$: L2 normalizasyonu sonrası elde edilen normalleştirilmiş veri bileşenini ifade etmektedir.

- Logaritmik Normalizasyon: Verinin yayılımını azaltmak ve uç değerlerin etkisini hafifletmek amacıyla kullanılan bir yöntemdir ve şu şekilde ifade edilmektedir (Eşitlik 5):

$$x' = log_b\left(x + c\right) \quad \text{(Eşitlik 5)}$$

Bu eşitikle:

x': Logaritmik normalizasyon işlemi sonrası elde edilen ölçeklenmiş veri değerini,

x: Normalizasyona tabi tutulacak orijinal veri değerini,

b: Logaritma tabanını,

c: negatif veya sıfır değerlerin işlenebilmesi için eklenen pozitif bir sabiti ifade etmektedir.

Veri standardizasyonu, ölçekleme ve normalizasyon gibi tekniklerle, veri setindeki özniteliklerin birbirine uyumlu hale getirilmesini sağlamaktadır. Ölçekleme, özniteliklerin büyüklüklerini dengeleyerek önemli bir rol oynarken; normalizasyon, veri dağılımını düzenleyerek öğrenme süreçlerini iyileştirmektedir. Doğru standardizasyon

yöntemi seçimi, veri setinin yapısına ve modelin ihtiyaçlarına bağlı olmaktadır (Bala ve Behal, 2024b).

3.6.3. Öznitelik Mühendisliği

Öznitelik mühendisliği, ham veriden anlamlı ve modelin öğrenme performansını artırabilecek öznitelikler oluşturma sürecidir (Li, 2024). Bu süreç, makine öğrenmesi modellerinin başarısında kritik bir rol oynamakta ve veri bilimi projelerinin en önemli aşamalarından biri olarak değerlendirilmektedir. Etkili bir öznitelik mühendisliği süreci, model performansını belirgin bir şekilde artırma potansiyeline sahiptir (Uddin vd., 2018). Öznitelik mühendisliği, alan bilgisi ile teknik uzmanlığın bir araya geldiği karmaşık bir süreç olarak ifade edilmektedir. Bu süreçte, mevcut özniteliklerin dönüştürülmesi, yeni özniteliklerin türetilmesi ve öznitelikler arası etkileşimlerin analiz edilmesi gibi çeşitli teknikler uygulanmaktadır. Özellikle yüksek boyutlu veri setlerinde, öznitelik mühendisliği yalnızca modelin eğitim performansını artırmakla kalmayıp, hesaplama verimliliğini de önemli ölçüde iyileştirebilmektedir (Uddin vd., 2018). Modern öznitelik mühendisliği yaklaşımları, geleneksel yöntemlerin yanı sıra otomatik öznitelik çıkarım tekniklerini de içermektedir. Derin öğrenme modelleri, ham veriden otomatik olarak karmaşık öznitelikler öğrenme yeteneğine sahiptir. Bununla birlikte, alan bilgisine dayalı öznitelik mühendisliği, özellikle yapılandırılmış veri setlerinde yaygın olarak kullanılmaktadır (Abe, 2018).

Başarılı bir öznitelik mühendisliği stratejisi, veri setinin özelliklerini, problem tipini ve hedef değişkenle olan ilişkilerini dikkate almalıdır. Ayrıca, özniteliklerin ölçeklenebilirliği, yorumlanabilirliği ve hesaplama maliyeti gibi faktörler de göz önünde bulundurulmalıdır (C. Zheng vd., 2023). Öznitelik seçimi ve boyut indirgeme teknikleri, öznitelik uzayının optimize edilmesinde önemli bir rol oynamaktadır. Öznitelik seçimi, gereksiz veya alakasız öznitelikleri ortadan kaldırırken, model performansını artırmaya yönelik en alakalı özelliklerin belirlenmesi ve korunmasını amaçlayan, makine öğrenmesi ve veri analizinde kritik bir süreçtir. Bu süreç, yalnızca modelin genelleme yeteneğini geliştirmekle kalmamakta aynı zamanda hesaplama verimliliğini de artırmaktadır.

- Filtre Yöntemleri: İstatistiksel ölçütlere dayanarak özniteliklerin uygunluğunu değerlendiren yöntemlerdir. Bu yöntemde, ki-kare testi, bilgi kazancı ve korelasyon analizi gibi tekniklerden yaygın olarak yararlanılmaktadır (Cherrington vd., 2019).
- Sarmalayıcı Yöntemler: Farklı öznitelik alt kümelerini deneyerek, model performansını en üst düzeye çıkaran kombinasyonu belirlemeyi amaçlayan yöntemlerdir (Patel vd., 2024).

- Gömülü Yöntemler: Model eğitimi sırasında öznitelik seçimini entegre bir şekilde gerçekleştiren bir yöntemdir (Patel vd., 2024).

Yeni öznitelik oluşturma, mevcut özniteliklerden veya dış kaynaklardan yararlanarak veri setini zenginleştirme sürecidir. Bu süreçte, matematiksel dönüşümler (örneğin, logaritmik ve polinom dönüşümler), öznitelik birleştirme, tarih-zaman manipülasyonları ve alan bilgisine dayalı türetmeler gibi teknikler uygulanmaktadır. Doğru tasarlanmış yeni öznitelikler, model performansını belirgin bir şekilde artırma potansiyeline sahiptir (Bouajjani vd., 2022).

Öznitelik birleştirme, benzer veya ilişkili özniteliklerin tek bir anlamlı öznitelik haline getirilmesi sürecidir. Bu yaklaşım, veri boyutunu azaltırken bilgi kaybını minimum seviyede tutmayı ve veri içerisindeki gürültüyü azaltmayı hedeflemektedir. Öznitelik birleştirme yöntemleri genel olarak şu şekilde sınıflandırılmaktadır;

- İstatistiksel Birleştirme: Ortalama, medyan, minimum/maksimum değer seçimi veya standart sapma hesaplama gibi teknikleri içermektedir.
- Zaman Serisi Birleştirme: Hareketli ortalamalar, üssel hareketli ortalamalar ve zaman penceresi bazlı toplama işlemleri gibi yöntemleri kapsamaktadır.
- Kategorik Öznitelik Birleştirme: Birden fazla kategorik değişkeni daha anlamlı bir değişken oluşturmak amacıyla birleştirme işlemidir. Bu işlem, veri modelleme süreçlerinde uygulanmaktadır.

Doğru birleştirme stratejileri, model performansını artırırken aynı zamanda eğitim süresini kısaltabilmektedir (Murata vd., 2024).

3.6.4. Boyut İndirgeme

Boyut indirgeme, yüksek boyutlu veri setlerindeki öznitelik sayısını azaltarak, analizi daha kolay hale getirmeyi ve modelleme süreçlerini optimize etmeyi amaçlayan bir tekniktir (Wibbeke vd., 2022). Özellikle büyük veri setlerinde, boyut indirgeme hem hesaplama maliyetlerini düşürmek hem de modelin genelleme performansını artırmak için kritik bir adım olarak değerlendirilmektedir. Yüksek boyutlu veri setlerinde her bir özniteliğin model için anlamlı olmayabileceği göz önüne alındığında, gereksiz veya düşük etkili özniteliklerin çıkarılması önemli avantajlar sağlamaktadır (Jia vd., 2022). Bunun yanı sıra, boyut indirgeme, veri görselleştirmesi, sınıflandırma ve regresyon gibi birçok uygulamada yaygın olarak kullanılmaktadır. Ancak, bu süreç sırasında veri setinin bilgi içeriğinin bir kısmının kaybolabileceği unutulmamalıdır. Boyut indirgeme yöntemleri arasında en yaygın kullanılanlar PCA (Principal Component Analysis), Kernel PCA ve LDA (Linear Discriminant Analysis) teknikleridir. Bu yöntemler, veri setlerinin

yapısına göre farklı avantajlar sunmakta ve çeşitli uygulama alanlarında tercih edilmektedir (Bakar vd., 2021).

Temel Bileşen Analizi (PCA), veri setindeki varyansı en iyi temsil eden yeni bir alt uzay oluşturarak boyut indirgeme işlemi gerçekleştiren bir yöntemdir. Bu süreç, kovaryans matrisinden elde edilen özdeğer ve özvektörlerin analizi ile uygulanmaktadır. PCA, doğrusal ilişkilerin baskın olduğu veri setlerinde etkili bir şekilde çalışmakta ve genellikle görselleştirme, gürültü azaltma ve veri sıkıştırma gibi alanlarda kullanılmaktadır (Groth vd., 2013).

Kernel PCA, PCA'nın doğrusal olmayan ilişkileri açıklamakta yetersiz kaldığı durumlar için geliştirilmiş bir yöntemdir. Kernel fonksiyonları kullanarak veriyi yüksek boyutlu bir uzaya dönüştürmekte ve bu uzayda PCA işlemini gerçekleştirmektedir. Kernel PCA, karmaşık desenlerin bulunduğu veri setlerinde etkili bir şekilde kullanılmaktadır. Ancak, çekirdek seçiminden kaynaklanan hiperparametre optimizasyonu gereksinimi ve yüksek hesaplama maliyetleri bu yöntemin dezavantajları arasında yer almaktadır (Paiva vd., 2006).

LDA (Linear Discriminant Analysis), sınıflar arasındaki ayrımı maksimize eden bir boyut indirgeme yöntemidir. Bu yöntem, verinin sınıflar arası ve sınıf içi varyanslarını hesaplayarak, sınıflar arasındaki farkı en iyi şekilde temsil eden yeni bir alt uzay oluşturmaktadır. LDA, özellikle sınıflandırma problemleri için uygun bir yöntemdir. Ancak, sınıf ayrımlarının belirgin olmadığı veri setlerinde etkili sonuçlar vermemektedir (Yang ve Chen, 2014). PCA, Kernel PCA ve LDA tekniklerinin hangi tip veri setlerinde kullanıldığı, varsayımları, ölçekleme gereksinimleri ve diğer önemli kriterlere göre karşılaştırması, Tablo 9'da sunulmaktadır.

Tablo 9. Farklı boyut indirgeme tekniklerinin karşılaştırılması

Özellik	PCA	Kernel PCA	LDA
Amaç	Verilerdeki doğrusal ilişkileri keşfetmek	Doğrusal olmayan ilişkileri keşfetmek	Sınıflar arası ayrımı maksimize etmek
Lineerlik Varsayımı	Verilerin doğrusal olduğu varsayılır	Doğrusal olmayan ilişkileri modelleyebilir	Verilerin doğrusal ayrılabilir olduğu varsayılır
Veri Dağılımı	Normal dağılıma yakın veri önerilir	Normal dağılım gerekmez	Sınıf ayrımları belirgin olmalıdır
Boyut İndirgeme	Doğrusal boyut indirgeme	Doğrusal olmayan boyut indirgeme	Sınıflara dayalı boyut indirgeme
Kernel Kullanımı	Kernel kullanılmaz	Çeşitli kernel fonksiyonları kullanılabilir (RBF, polinom vb.)	Kernel kullanılmaz
Avantajlı Olduğu Durumlar	Lineer ilişkilerin baskın olduğu veri setleri	Karmaşık, doğrusal olmayan veri setleri	Sınıflandırma problemleri

Tablo 9. (Devamı)

Bilgi Kaybı	Minimum (lineer verilerde)	Kernel dönüşümü sonucu bazı bilgi kayıpları olabilir	Sınıf ayrımı dışındaki varyans kaybolabilir
Varyans Açıklama Oranı	Doğrudan yorumlanabilir	Doğrudan yorumlanamaz	Varyans oranı sınıflar arası ayrım üzerinden değerlendirilir
Ölçekleme Gereksinimi	Standartlaştırma önerilir	Standartlaştırma önerilir	Standartlaştırma önerilir
Model Karmaşıklığı	Basit ve hızlı	Kernel matrisi nedeniyle daha karmaşık	Orta düzeyde
Kullanım Alanları	Görselleştirme, gürültü azaltma	Doğrusal olmayan ilişkilerde modelleme	Sınıflandırma, yüz tanıma
Boyut Seçimi	Varyans açıklama oranlarına dayanır	Deneysel olarak belirlenir	Sınıf sayısına bağlıdır
Çıktının Yorumu	Veri öznitelikleriyle ilişkilendirilebilir	Kernel dönüşümü nedeniyle doğrudan yorumlanamaz	Yorumlama sınıflar üzerinden yapılır

Tablo, PCA, Kernel PCA ve LDA yöntemlerinin avantajlarını ve sınırlamalarını açıkça ortaya koymaktadır. PCA, doğrusal ilişkilerin baskın olduğu durumlarda hızlı ve etkili bir çözüm sunarken, Kernel PCA doğrusal olmayan karmaşık veri yapılarını daha iyi temsil etmektedir. LDA ise sınıflandırma problemleri için özelleştirilmiş bir yaklaşımdır. Her bir yöntem, veri setinin yapısına ve problemin gereksinimlerine göre seçilmelidir (Kempfert vd., 2019).

Boyut indirgeme sırasında meydana gelen bilgi kaybı, kullanılan yönteme ve veri setinin yapısına bağlıdır (Torrecilla vd., 2012). PCA, veri setindeki varyansın büyük bir kısmını koruyarak bilgi kaybını minimumda tutmayı amaçlamaktadır. Kernel PCA, doğrusal olmayan ilişkileri başarılı bir şekilde koruyabilmesine rağmen, çekirdek dönüşümünden kaynaklanan ek bilgi kayıplarına yol açabilmektedir. LDA, yalnızca sınıflar arası ayrımı dikkate aldığı için sınıf dışı varyansın kaybolmasına neden olabilmektedir. Bilgi kaybını en aza indirmek için veri setinin yapısına uygun bir yöntem seçilmeli ve kullanılan özniteliklerin model performansına katkısı dikkatlice değerlendirilmelidir (Schmitt vd., 2024).

3.6.5. Sınıflandırma

Sınıflandırma, makine öğrenmesinde bir veri kümesindeki örnekleri önceden belirlenmiş sınıflara atama süreci olarak tanımlanmaktadır (Raymaekers vd., 2021). Bu süreç, tahmin, karar verme ve desen tanıma gibi birçok alanda yaygın olarak kullanılmaktadır. Sınıflandırma algoritmaları, veri kümesinden öğrenilen kurallar ve özellikler aracılığıyla yeni gelen verileri doğru bir şekilde sınıflandırmayı amaçlamaktadır (Nurwinto vd., 2024).

Sınıflandırma modellerinin etkinliği, doğru bir eğitim ve test veri ayrımı yapılarak değerlendirilmektedir. Eğitim ve test veri seti ayrımı, modelin doğruluğunu ölçmek ve

aşırı uyum (overfitting) gibi sorunların önüne geçmek için önemli bir adımdır. Genellikle veri setinin %70-80'i eğitim için, kalan %20-30'u ise test için ayrılmaktadır. Eğitim veri seti, modeli eğitmek için kullanılırken, test veri seti modelin yeni ve görülmemiş verilere karşı genelleme yapma yeteneğini değerlendirmektedir. Bu işlem sırasında, çapraz doğrulama teknikleri modelin farklı veri bölümlerinde tutarlılığını kontrol etmek için sıklıkla tercih edilmektedir (Beram ve El-Kotory, 2024).

Sınıflandırma algoritmaları, veri setinin yapısına, problem tanımlama gereksinimlerine ve doğruluk hedeflerine bağlı olarak seçilmektedir. Bu algoritmalar arasında Lojistik Regresyon (LR), Rastgele Orman (RF), Naive Bayes (NB), k- En yakın komşu (KNN) ve Destek Vektör Makineleri (SVM) gibi yaygın kullanılan algoritmalar bulunmaktadır. Her bir algoritma, farklı veri türleri ve problem yapılarına uygun avantajlar ve sınırlamalar sunmaktadır (Khujaev vd., 2023).

Lojistik Regresyon (LR): Lojistik regresyon, genellikle iki sınıflı (binary) problemler için kullanılan doğrusal bir sınıflandırma algoritmasıdır. Bununla birlikte, çok sınıflı problemlere yönelik genelleştirilmiş versiyonları da bulunmaktadır. Bu algoritma, sigmoid fonksiyonu aracılığıyla çıktı değerlerini 0 ile 1 arasında sınırlandırarak, bir veri noktasının belirli bir sınıfa ait olma olasılığını tahmin etmektedir. Basit yapısı nedeniyle hızlı ve hesaplama açısından verimli bir yöntemdir. Ancak, doğrusal olmayan ilişkiler içeren veri setlerinde yetersiz kalabilmekte ve bu durumda veri dönüşümleri gibi ön işlemler gerektirmektedir (Sperandei, 2014).

Rastgele Orman (RF): RF, birden fazla karar ağacından oluşan ve topluluk öğrenme yöntemleri kapsamında değerlendirilen bir algoritmadır. Her bir ağaç, veri setinin rastgele bir alt kümesi üzerinde eğitilmekte ve sınıflandırma sonucunda çoğunluk oyu prensibiyle karar verilmektedir. Bootstrap örnekleme ve rastgele öznitelik seçimi teknikleri, Random Forest'ın aşırı uyuma (overfitting) karşı dayanıklı olmasını sağlamaktadır. Bu yöntem, yüksek boyutlu ve doğrusal olmayan veri setlerinde etkili bir şekilde çalışmakta ve öznitelik önemini belirleme kabiliyeti ile veri analizi süreçlerinde sıklıkla tercih edilmektedir. Ancak, büyük veri setlerinde hesaplama maliyetlerinin artması, yöntemin sınırlamaları arasında yer almaktadır (Khoshgoftaar vd., 2015).

Naive Bayes (NB): Naive Bayes, Bayes Teoremi'ne dayalı, olasılık tabanlı bir sınıflandırma algoritmasıdır. Bu yöntem, öznitelikler arasındaki bağımsızlık varsayımı ile çalışmakta ve bu nedenle hızlı ve düşük maliyetli bir çözüm sunmaktadır. Özellikle metin sınıflandırma, spam tespiti ve duygu analizi gibi uygulamalarda yaygın olarak kullanılmaktadır. Ancak, özniteliklerin bağımsız olmadığı veri setlerinde performansı

düşebilmekte ve karmaşık veri ilişkilerini modelleme kapasitesi sınırlı kalmaktadır (Huang ve Li, 2011).

k-En Yakın Komşular (KNN): k-En Yakın Komşular, komşuluk tabanlı bir sınıflandırma algoritmasıdır. Bu yöntem, bir veri noktasının sınıfını belirlemek için K sayıda en yakın komşunun sınıflarını dikkate almaktadır. Parametrik bir model olmaması nedeniyle, uygulanması basit ve esnek bir algoritmadır. Küçük ve düşük boyutlu veri setlerinde etkili bir şekilde çalışmakta, ancak yüksek boyutlu veri setlerinde hesaplama maliyetleri artmakta ve performansı düşebilmektedir. Ayrıca, uygun 'k' değerinin seçimi modelin başarısını doğrudan etkilemekte ve bu nedenle çapraz doğrulama gibi tekniklerle belirlenmesi önerilmektedir (Kramer, 2013).

Destek Vektör Makineleri (SVM): SVM, sınıflar arasındaki ayrımı maksimize eden bir hiper düzlem oluşturarak sınıflandırma yapan güçlü bir algoritmadır. Doğrusal olmayan veri setleri için, kernel fonksiyonları kullanılarak veriler daha yüksek boyutlu bir uzaya dönüştürülmekte ve bu uzayda daha iyi sınıflar oluşturulmaktadır. SVM, özellikle küçük ve karmaşık veri setlerinde yüksek doğruluk sağlamaktadır. Bununla birlikte, büyük veri setlerinde hesaplama maliyetleri artmakta ve hiperparametre optimizasyonu gerektirmektedir (Cleophas ve Zwinderman, 2013).

Model seçimi, veri setinin yapısına, problemin doğasına ve performans gereksinimlerine göre belirlenen önemli bir adımdır. Doğru model seçimi hem eğitim sürecinin başarısını hem de test verisi üzerindeki genelleme yeteneğini doğrudan etkilemektedir (Latha vd., 2024). Model seçiminde dikkate alınması gereken başlıca faktörler şunlardır;

- **Veri Setinin Boyutu ve Özellikleri:** Yüksek boyutlu veya karmaşık veri setlerinde, RF veya SVM gibi daha esnek modeller tercih edilmektedir. Buna karşılık, daha basit veri setlerinde LR gibi doğrusal yöntemler yeterli olabilmektedir.
- **Modelin Hız ve Verimlilik Gereksinimi:** NB, hızlı ve düşük hesaplama maliyetine sahip bir model olarak öne çıkmaktadır. Ancak, doğruluk gereksinimi yüksek olan problemler RF veya SVM gibi daha karmaşık yöntemler daha uygun olabilmektedir.
- **Doğruluk ve Genelleme Performansı:** Küçük veri setlerinde KNN etkili olabilmektedir. Ancak, doğrusal olmayan ilişkilerin baskın olduğu veri setlerinde Kernel SVM üstün performans sergileyebilmektedir.
- **Aşırı Uyum Riskine Dayanıklılık:** RF gibi topluluk öğrenme (ensemble learning) yöntemleri, aşırı uyuma (overfitting) karşı daha dayanıklı yapılarıyla ön plana çıkmaktadır.

Model seçimi sırasında çapraz doğrulama teknikleri kullanılarak modelin farklı veri alt kümelerinde tutarlılığı değerlendirilmeli ve nihai karar buna göre verilmelidir (Kärkkäinen, 2014). Ayrıca, hiperparametre optimizasyonu, modelin performansını artırmak için önemli bir süreçtir. Bu yöntem, modelin genel başarısını ve farklı veri setlerinde gösterdiği tahmin performansını belirgin ölçüde geliştirebilmektedir (Latha vd., 2024). Hiperparametrelerin doğru bir şekilde ayarlanması, modelin daha etkili tahminler yapmasını ve aşırı uyum gibi sorunların önlenmesini sağlamaktadır.

3.6.6. Hiperparametre Optimizasyonu

Hiperparametre optimizasyonu, makine öğrenmesi modelinin performansını artırmak amacıyla modelin öğrenme sürecini kontrol eden hiperparametrelerin en uygun değerlerini belirleme süreci olarak ifade edilmektedir (Wolpert ve Macready, 1997). Hiperparametreler, model eğitimi başlamadan önce ayarlanması gereken ve modelin öğrenme biçimini şekillendiren değişkenlerdir. Örneğin, karar ağacı modelinde maksimum derinlik, KNN algoritmasında komşu sayısı, SVM'de kernel tipi veya düzenleme parametresi gibi ayarlar hiperparametreler arasında yer almaktadır. Bu süreç, modelin genelleme yeteneğini artırmak ve aşırı uyum ya da eksik uyum (underfitting) gibi sorunların önüne geçmek açısından önemlidir (Wolpert ve Macready, 1997). Hiperparametre optimizasyonu sırasında, eğitim verisi üzerinde farklı hiperparametre kombinasyonları test edilmekte ve doğrulama verisi üzerinde en iyi performansı sağlayan kombinasyon seçilebilmektedir. Grid Search yöntemi, tüm olası hiperparametre kombinasyonlarını sistematik olarak deneyerek en iyi sonucu bulmayı hedefleyen bir yöntemdir (Esmaeili vd., 2023). Ancak, bu yöntem tüm kombinasyonların değerlendirilmesini gerektirdiğinden hesaplama maliyeti oldukça yüksektir. Daha az hesaplama maliyeti gerektiren Random Search yöntemi, hiperparametre uzayından rastgele seçilen kombinasyonları deneyerek optimizasyon yapmaktadır. Özellikle büyük hiperparametre uzaylarında, Grid Search'e kıyasla daha pratik bir çözüm sunmaktadır (Esmaeili vd., 2023).

Hiperparametre optimizasyonu, çapraz doğrulama teknikleriyle birleştirilerek daha güvenilir sonuçlar elde edilmektedir. Çapraz doğrulama, hiperparametre kombinasyonlarının farklı veri alt kümeleri üzerindeki tutarlılığını kontrol etmeye olanak tanımaktadır. Böylece, modelin performansı yalnızca optimize edilmekle kalmamakta, aynı zamanda genelleme yeteneği de güvenilir bir şekilde değerlendirilmektedir (VanderVeen vd., 2021). Hiperparametre optimizasyonunun başarısı, modelin yapısına,

veri setinin özelliklerine ve problem türüne bağlıdır. Doğru bir optimizasyon süreci, bir sınıflandırma modelinin başarısında belirleyici bir faktör olarak öne çıkmaktadır.

3.6.7. Model Performans Değerlendirmesi

Sınıflandırma modellerinin performansını değerlendirmek, modelin başarısını ve genelleme yeteneğini ölçmek için önemli bir adımdır. Bu süreç, modelin doğru tahminlerde bulunma kapasitesini ve yanlış tahminlerin etkilerini analiz ederek, modelin iyileştirilmesi için gereken adımları belirlemektedir. Performans değerlendirme metrikleri, problemin türüne (sınıflandırma, regresyon, kümeleme) bağlı olarak değişiklik göstermektedir. Sınıflandırma problemlerinde kullanılan metrikler, modelin sınıflar arasındaki ayrımı ne kadar iyi gerçekleştirdiğini değerlendirirken; regresyon problemlerinde, modelin sürekli değerleri tahmin etme başarısını ölçmektedir. Çok sınıflı sınıflandırma problemlerinde, performans değerlendirme metrikleri genellikle iki sınıflı sınıflandırmada kullanılan temel metriklerin genelleştirilmesi yoluyla hesaplanmaktadır. Bu metrikler, modelin başarısını hem her bir sınıf özelinde hem de genel düzeyde ölçmek için uyarlanmıştır. Aşağıda çok kategorili sınıflandırma (3 veya daha fazla sınıf) için kullanılan metrikler ve hesaplama yöntemleri açıklanmaktadır;

Çok kategorili sınıflandırma problemlerinde k sınıf için k x k boyutunda bir karmaşıklık matrisi oluşturulmaktadır. Bu matrisin (i, j) hücresi, gerçek sınıfı i olan örneklerin model tarafından sınıf j olarak tahmin edildiği sayıyı ifade etmektedir. İlgili metrikler, bu matris üzerinden şu şekilde tanımlanmaktadır;

Doğruluk (Accuracy): Tüm sınıflar için doğru tahmin edilen örneklerin toplam veri setine oranını ifade eden doğruluk (accuracy) metriği, sınıflandırma modellerinin genel başarı düzeyini ölçmek için kullanılmaktadır. Bu metrik, modelin hem doğru pozitif (TP) hem de doğru negatif (TN) tahminlerinin tüm tahminlere oranını temsil etmektedir (Eşitlik 6). Doğruluk, sınıflar arasındaki dengenin nispeten iyi olduğu veri setlerinde model performansını değerlendirmek için etkili bir ölçüm yöntemidir. Ancak, dengesiz veri setlerinde yanıltıcı olabileceği için tek başına kullanılması yerine diğer metriklerle desteklenmesi önerilmektedir.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \quad \text{(Eşitlik 6)}$$

Kesinlik (Precision): sınıflandırma modellerinde pozitif tahminlerin ne kadarının doğru olduğunu ölçen bir metriktir. Doğru pozitif tahminlerin, modelin pozitif olarak

tahmin ettiği tüm örneklere oranı ile hesaplanmaktadır (Eşitlik 7). Bu metrik, özellikle yanlış pozitiflerin maliyetinin yüksek olduğu durumlarda önemli olmaktadır ve modelin pozitif sınıfa yönelik güvenilirliğini değerlendirmek için kullanılmaktadır.

$$Kesinlik = \frac{TP}{TP + FP} \quad \text{(Eşitlik 7)}$$

Mikro Ortalama (Micro Average): Mikro ortalama, tüm sınıflar için doğru pozitif (TP) ve yanlış pozitif (FP) değerlerinin toplamları üzerinden hesaplanmaktadır. Bu yöntem, sınıflar arasındaki örnek sayısı dağılımını dikkate alarak genel performansın değerlendirilmesini sağlamaktadır. Mikro ortalama, dengesiz veri setlerinde küçük sınıfların etkisinin azaldığı, ancak büyük sınıfların etkisinin daha belirgin olduğu bir sonuç sunmaktadır. Bu nedenle, veri setindeki genel başarının ölçülmesi amacıyla mikro ortalama sıklıkla tercih edilmektedir.

Makro Ortalama (Macro Average): Makro ortalama, her bir sınıf için hesaplanan kesinlik değerlerinin aritmetik ortalamasının alınmasıyla elde edilmektedir. Bu yaklaşım, tüm sınıflara eşit önem atfederek performansın değerlendirilmesini mümkün kılmaktadır. Ancak, az sayıda örneğe sahip sınıfların, büyük sınıflarla aynı ağırlıkta değerlendirilmesi nedeniyle, sınıf dağılımının dengesiz olduğu durumlarda yanıltıcı sonuçlar ortaya çıkabilmektedir. Bu durum göz önüne alındığında, makro ortalama, tüm sınıfların eşit öneme sahip olduğu problemler için daha uygun bir yöntem olarak kullanılmaktadır.

Ağırlıklı Ortalama (Weighted Average): Ağırlıklı ortalama, her bir sınıfın kesinlik değerlerinin, o sınıfın veri setindeki örnek sayısına göre ağırlıklandırılarak hesaplanmasını içermektedir. Bu yöntem, sınıflar arasındaki dengesiz veri dağılımını dikkate almakta ve daha gerçekçi bir performans değerlendirmesi yapılmasını sağlamaktadır. Ağırlıklı ortalama, büyük sınıfların performansını daha belirgin hale getirirken, küçük sınıfların etkisi sınırlı kalmaktadır. Bu nedenle, sınıf dağılımının dengesiz olduğu veri setlerinde, modelin genel performansını değerlendirmek için tercih edilmektedir.

Duyarlılık (Recall): Duyarlılık, modelin ilgili sınıfa ait örnekleri doğru bir şekilde tahmin edebilme oranını ifade etmektedir. Bu metrik, her bir sınıf için doğru tahmin edilen pozitif örneklerin, o sınıfa ait toplam gerçek örnek sayısına oranı olarak hesaplanmaktadır. Duyarlılık, modelin ilgili sınıfa ait örnekleri tanıma kapasitesini ölçmekte ve özellikle yanlış negatiflerin (FN) önemli olduğu problemlerde değerlendirilmektedir. Eşitlik 8 ile hesaplanmaktadır.

$$Duyarlılık = \frac{TP}{TP + FN} \quad \text{(Eşitlik 8)}$$

Bu eşitliklerde;

TP (True Positive): Gerçek pozitifler, modelin doğru bir şekilde ilgili sınıfı tahmin ettiği durumlardır.

TN (True Negative): Gerçek negatifler, modelin doğru bir şekilde ilgili sınıf dışındaki sınıfları tahmin ettiği durumlardır.

FP (False Positive): Yanlış pozitifler, modelin yanlış bir şekilde ilgili sınıfı tahmin ettiği durumlardır.

FN (False Negative): Yanlış negatifler, modelin ilgili sınıfı tahmin edemediği durumlardır.

F1 Skoru (F1 Score): F1-Skoru, kesinlik (precision) ve duyarlılığın (recall) harmonik ortalaması olarak tanımlanmaktadır. Bu metrik, özellikle dengesiz veri setlerinde modelin genel performansını değerlendirmek için kullanılmaktadır. Kesinlik ve duyarlılık arasında bir denge kurmayı amaçlayan F1-Skoru, bu iki metriğin aynı anda optimize edilmesinin önemli olduğu durumlarda tercih edilmektedir. Eşitlik 9'a göre hesaplanmaktadır;

$$F1\ Skoru = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad \text{(Eşitlik 9)}$$

ROC ve AUC: ROC (Receiver Operating Characteristic) eğrisi, modelin farklı eşik değerleri üzerinden pozitif sınıfları ne kadar iyi ayırdığını görselleştiren bir grafiksel araçtır. AUC (Area Under the Curve), bu eğrinin altında kalan alanı ifade etmekte olup, modelin genel performansını değerlendirmek için kullanılmaktadır. AUC, 0.5 ile 1 arasında bir değer alır ve bu değerin 1'e yakın olması, modelin üstün performans sergilediğini göstermektedir.

Öğrenme Eğrisi: Öğrenme eğrisi, makine öğrenmesi modellerinin genelleme yeteneğini değerlendiren önemli bir görselleştirme aracıdır. Modelin farklı miktarlarda eğitim verisiyle eğitildiğinde nasıl performans gösterdiğini analiz etmeye olanak tanımaktadır. Genellikle iki bileşen içermektedir;

- Eğitim Skoru: Modelin eğitim veri setindeki performansını gösterir.
- Doğrulama Skoru: Modelin doğrulama veri setindeki başarısını ifade eder.

Eğitim verisi miktarına göre hata oranlarını görselleştirerek, aşırı uyum (overfitting) ve yetersiz uyum (underfitting) gibi sorunların tespitine yardımcı olmaktadır.

3.6.8. Model Karşılaştırması

Makine öğrenmesi modellerinin performansını değerlendirmek ve en uygun modeli belirlemek için yalnızca metriklere dayalı analizlerin yapılması değil, aynı zamanda modellerin karar sınırları ile tahmin güvenilirliği gibi özelliklerinin detaylı bir şekilde incelenmesi gerekmektedir (Gaudreault vd., 2021). Doğrusal ve doğrusal olmayan modellerin karşılaştırılması, bu kapsamda, modelin veri setindeki sınıflar arasında nasıl bir ayrım gerçekleştirdiğini anlamak açısından önemli görülmektedir (Hadjiiski vd., 1999). Doğrusal modeller, sınıflar arasında doğrusal bir ayrım sınırı oluşturan algoritmalar olarak tanımlanmaktadır. LR ve doğrusal SVM gibi sınıflandırıcılar, veri seti doğrusal olarak ayrılabilir bir yapıya sahip olduğunda hızlı ve etkili bir şekilde çalışmaktadır (Clarke, 2008). Bu modeller, genelleştirme yetenekleri ve hesaplama verimlilikleri açısından avantaj sunmaktadır. Bununla birlikte, doğrusal olmayan ilişkilerin bulunduğu veri setlerinde, bu tür modellerin performansı sınırlı kalmakta ve sınıflar arasında yeterli bir ayrım oluşturulamamaktadır (Jan, 2023).

Doğrusal olmayan modeller, sınıflar arasında karmaşık ve doğrusal olmayan sınırlar çizebilme kapasitesine sahip olmaları nedeniyle daha esnek bir yapı sunmaktadır (Hubin vd., 2020). Kernel SVM, doğrusal olmayan ilişkileri öğrenmek amacıyla çekirdek fonksiyonlarını kullanırken, RF gibi modeller, karar ağacı tabanlı yaklaşımlarla esnek karar sınırları oluşturmaktadır. Bu modeller, doğrusal olmayan veri setlerinde yüksek performans göstermektedir. Ancak, karmaşık karar sınırlarının aşırı uyuma, basit karar sınırlarının ise yetersiz uyuma neden olabileceği göz önünde bulundurulmalıdır. Karar sınırlarının görselleştirilmesi, modelin sınıf ayrımını ne ölçüde başarılı bir şekilde gerçekleştirdiğini anlamak açısından önemli bir yöntem olarak değerlendirilmektedir (Lu vd., 2007).

Tahmin güvenilirliği, modelin tahminlerinin arkasındaki olasılık veya güven düzeyini ifade eden bir ölçüt olarak ele alınmaktadır. Olasılık tabanlı modeller, tahminlerine olasılık değerleri ekleyerek bu güvenilirliği sağlamaktadır (Bröcker, 2008). Örneğin, LR modeli, bir veri noktasının belirli bir sınıfa ait olma olasılığını yüzde değerleriyle ifade etmektedir. Bu yaklaşım, modelin yalnızca doğru tahmin yapma başarısını değil, aynı zamanda tahminlerine duyulan güveni değerlendirme imkânı sunmaktadır. Karar ağacı tabanlı modeller ise tahmin edilen sınıfa ait örneklerin oranına dayalı olarak güvenilirlik değerlendirmesi yapmaktadır. Örneğin, bir RF modeli, birden

fazla ağacın aynı sınıfı tahmin etmesi durumunda güvenilirlik düzeyini artırmaktadır. SVM modellerinde güvenilirlik, karar sınırından uzaklık ölçütüne göre değerlendirilirken, KNN algoritmasında bu güvenilirlik, en yakın komşuların çoğunluk oranına dayanmaktadır (S. Wang vd., 2018). Model karşılaştırmasının yalnızca metrik temelli analizlerle sınırlı kalmaması gerekmektedir. Karar sınırlarının basitlik ve açıklığı ile tahmin güvenilirliğinin istikrarını bir arada değerlendiren yaklaşımlar, doğru model seçimi açısından belirleyici olmaktadır. Özellikle karmaşık veri setlerinde, modellerin genelleme yeteneklerinin karşılaştırılması ve problem yapısına en uygun modelin belirlenmesi, bu sürecin temel bir parçası olarak değerlendirilmektedir. Model seçiminde bu tür kapsamlı bir değerlendirme, uzun vadede daha tutarlı ve güvenilir sonuçların elde edilmesine katkı sağlamaktadır (Vivanco ve Jin, 2008).

3.6.9. SHAP Analizi

SHAP, makine öğrenmesi modellerinin öznitelik önemini ve bireysel tahminlerde özniteliklerin etkilerini açıklamak için kullanılan oyun teorisi tabanlı bir yöntemdir (Xi vd., 2014). SHAP analizi, her bir özniteliğin modele ve tahmin edilen sonuca olan katkısını ölçerek modellerin daha şeffaf ve açıklanabilir hale gelmesine katkıda bulunmaktadır. Bu yöntem, modelin karar süreçlerini anlamayı kolaylaştırmak ve özniteliklerin ayrıştırma gücünü değerlendirmek için etkili bir araç olarak görülmektedir (Ullah vd., 2023). SHAP, özniteliklerin modele olan katkılarını hesaplamak için Shapley değerlerinden yararlanmaktadır. Shapley değerleri, bir özniteliğin model çıktısına olan etkisini adil bir şekilde dağıtarak öznitelik önemini belirlemektedir. Yüksek Shapley değerleri, özniteliğin tahmin üzerindeki etkisinin büyük olduğunu gösterirken, düşük veya negatif değerler, ilgili özniteliğin etkisinin sınırlı ya da olumsuz olduğunu ifade etmektedir (Takeishi, 2019). Bu analiz, yalnızca genel öznitelik önemlerini değil, aynı zamanda belirli bir tahminde özniteliklerin nasıl bir etkiye sahip olduğunu da ortaya koymaktadır. Örneğin, bir sınıflandırma modelinde SHAP analizi, belirli bir veri noktasının tahminine hangi özniteliklerin ne ölçüde katkı sağladığını görselleştirme imkânı sunmaktadır. Bu özelliği sayesinde SHAP, model geliştirme süreçlerinde hata analizlerini desteklemekte, model doğruluğunu artırmakta ve açıklanabilirliği güçlendirmektedir. Aynı zamanda, karar destek sistemlerinde özniteliklerin etkilerini şeffaf bir şekilde ortaya koyarak daha güvenilir ve etik modellerin oluşturulmasına olanak tanımaktadır. Bu yönüyle SHAP hem teknik analizlerde hem de uygulama temelli süreçlerde, makine öğrenmesi modellerinin daha anlaşılır ve etkili hale getirilmesine önemli bir katkı sağlamaktadır (Xi vd., 2014).

4. BULGULAR ve TARTIŞMA

Bu bölümde, araştırma sorularına ilişkin bulgular detaylı bir şekilde açıklanırken, analiz sonuçlarının açıklanabilir ve genellenebilir bir çerçevede ele alınması amaçlanmaktadır. Verilerin analizinden elde edilen anlamlı sonuçlar, araştırma konusuna ilişkin özgün katkılar sağlamaktadır. Bulguların sunumu sırasında görselleştirme araçlarından (ör. tablolar, grafikler) yararlanılarak sonuçların daha anlaşılır hale getirilmesine özen gösterilmiştir. Bu sayede, araştırmanın ortaya koyduğu temel ilişkiler ve eğilimler açık bir şekilde ifade edilmekte ve bulguların tartışmaya olan katkısı güçlendirilmektedir.

4.1. Anket Sonuçları

Katılımcıların demografik özellikleri incelendiğinde (Tablo 10), cinsiyet dağılımında erkeklerin %72.39, kadınların ise %27.61 oranında temsil edildiği görülmektedir. Yaş dağılımı incelendiğinde, 31-45 yaş aralığındaki katılımcılar %50.00 ile en büyük grubu oluştururken genç sürücüler (18-30 yaş aralığı) %25.37, 46 yaş ve üzerindeki sürücüler ise %24.63 oranında yer almaktadır. Ehliyet yılı dağılımında katılımcıların %35.08'inin 0-10 yıl arası deneyime, %35.82'sinin 11-20 yıl arası deneyime, %29.10'unun ise 21 yıl ve üzeri sürüş deneyimine sahip olduğu görülmektedir. Kaza geçmişi bilgilerine bakıldığında ise katılımcıların %34.33'ünün geçmişte bir kazaya karıştığı, %65.67'sinin ise kaza yapmadığı anlaşılmaktadır.

Tablo 10. Katılımcıların cinsiyet, yaş, ehliyet yılı ve kaza geçmişine göre dağılımı

Kategori	Katılımcı Sayısı	Toplam	Yüzde (%)
Cinsiyet (Kadın)	37	134	27.61
Cinsiyet (Erkek)	97		72.39
Yaş (18-30)	34	134	25.37
Yaş (31-45)	67		50.00
Yaş (46+)	33		24.63
Ehliyet Yılı (0-10)	47	134	35.08
Ehliyet Yılı (11-20)	48		35.82
Ehliyet Yılı (21+)	39		29.10
Kaza Geçmişi (Evet)	46	134	34.33
Kaza Geçmişi (Hayır)	88		65.67

Katılımcıların yaş ve ehliyet yılına ilişkin veriler incelendiğinde geniş bir dağılıma sahip olduğu görülmektedir (Tablo 11). Yaş ortalaması 37.87 (SS=10.60) olarak belirlenmiştir ve yaşlar 18 ile 62 arasında değişim göstermektedir. Yaş dağılımına dair

çeyreklik değerler incelendiğinde katılımcıların %25'inin 30.25 yaşından küçük, %50'sinin 38 yaşından küçük ve %75'inin 45 yaşından küçük olduğu sonucuna ulaşılmıştır. Ehliyet yılının ortalaması ise 15.95 (SS=9.67) olarak hesaplanmıştır ve ehliyet yılı 1 ile 38 yıl arasında değişmektedir. Ehliyet deneyimi değişkeninin çeyreklik değerleri dikkate alındığında katılımcıların %25'inin 8 yıldan az, %50'sinin 16 yıldan az ve %75'inin 22.75 yıldan az sürüş deneyimine sahip olduğu anlaşılmaktadır. Yaş değişkeninde ortalama (37.87) ile medyan (38) değerlerinin birbirine yakın olması, yaş dağılımının göreceli olarak (tam simetrik olmasa da belirgin bir asimetri göstermediği ve yaklaşık olarak dengeli bir yapıya sahip olduğu) simetrik bir yapıya sahip olduğunu göstermektedir.

Tablo 11. Yaş ve ehliyet yılı ile ilgili bilgiler

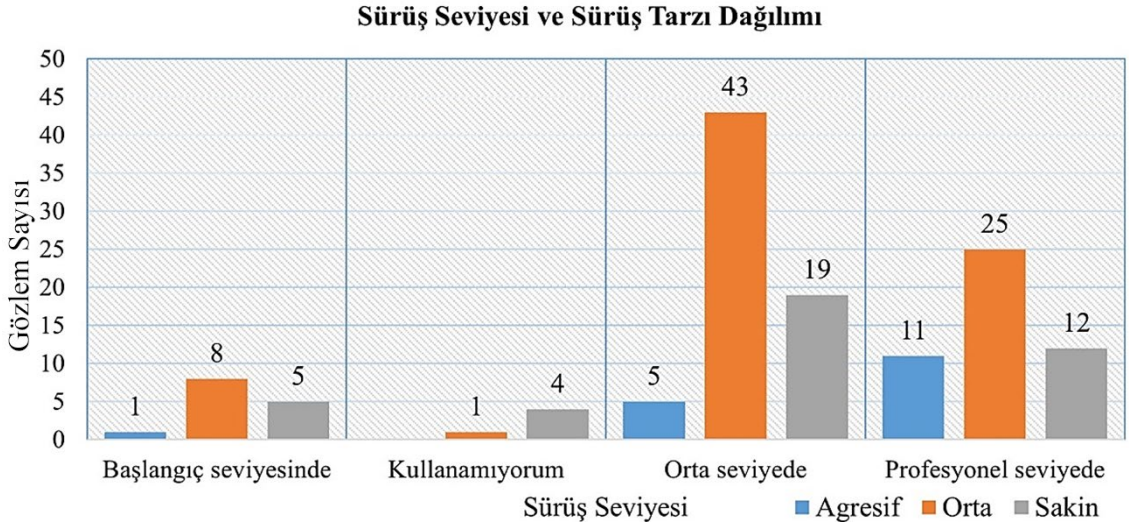
	N	Ort.	SS	Min.	25%	50%	75%	Maks.
Yaş	134	37.87	10.60	18	30.25	38	45	62
Ehliyet Yılı	134	15.95	9.67	1	8	16	22.75	38

Ayrıca çalışma kapsamında sürücülerin tünel sürüşlerine yönelik deneyim ve algıları 5'li likert ölçeği kullanılarak değerlendirilmiştir. Anket soruları, sürücülerin tünel içindeki tedirginlik düzeyi, trafik güvenliği algısı, tehlikeli bölgelerin bildirimi, aydınlatma yeterliliği, kaza riski algısı, uzun tünel sürüşüne yönelik davranışları ve dijital uyarıcıların etkisi gibi çeşitli konuları kapsamaktadır. Tablo 12'de her bir kategoriye verilen yanıtların dağılımı verilmiştir.

Tablo 12. Sürücülerin gerçek koşullardaki görüşleri

Kategori	**1**	**2**	**3**	**4**	**5**	**Toplam**
Tünelli sürüşteki tedirginlik düzeyi	41	58	19	9	7	134
Mevcut tünellerin trafik güvenliği açısından değerlendirmesi	7	20	40	62	5	134
Tehlikeli bölgenin önceden sürücüye bildirilmesi yeterliliği	8	31	48	43	4	134
Tehlikeli bölgenin önceden sürücüye bildirilmesi gerekliliği	2	23	25	71	13	134
Tünel aydınlatmalarının yeterliliği (Giriş-Çıkış noktaları)	5	18	43	66	2	134
Tünellerde açık yola nazaran kaza riskinin fazla olması düşüncesi	27	38	26	34	9	134
Uzun tünellerde sürüş sıkıcılığı	26	48	20	27	13	134
Uzun tünelden daha hızlı çıkmak için hız artırma eğilimi	32	43	27	27	5	134
Ağır taşıtı geçmek için hız artırma eğilimi	13	38	26	54	3	134
Tünel giriş ve çıkışlarında hız artırma/azaltma eğilimi	5	45	20	61	3	134
Dijital uyarıcıların dikkat çekiciliği	3	18	30	76	7	134
Hiç=1, Biraz=2, Orta=3, Kısmen=4, Çok=5						

Tünelli sürüşteki tedirginlik düzeyi değerlendirmesinde katılımcıların önemli bir kısmının (n=99, %73.88) hiç veya biraz tedirgin olduğu görülmektedir. Buna karşın mevcut tünellerin trafik güvenliği açısından değerlendirmesinde katılımcıların çoğunluğu (n=107, %79.85) orta düzey ve üzerinde olumlu görüş bildirmiştir. Tehlikeli bölgenin önceden sürücüye bildirilmesi konusunda katılımcıların hem yeterlilik hem de gereklilik algıları incelenmiştir. Tehlikeli bölgelerin önceden sürücüye bildirilmesi gerekliliği konusunda yüksek bir farkındalık gözlemlenirken (n=84, %62.69 kısmen ve çok gerekli görmekte), mevcut bildirimlerin yeterliliği konusunda daha düşük bir memnuniyet seviyesi tespit edilmiştir. Tünel içi güvenlik faktörleri değerlendirildiğinde dijital uyarıcıların dikkat çekiciliği konusunda olumlu bir algı (n=83, %61.94 kısmen ve çok dikkat çekici) bulunmaktadır. Ancak tünellerde açık yollara (tünel dışı) nazaran kaza riskinin fazla olması düşüncesi ve uzun tünellerde sürüş sıkıcılığı konularında katılımcılar arasında daha heterojen bir görüş dağılımı gözlemlenmiştir. Sürücü davranışları açısından tünel giriş ve çıkışlarında hız artırma/azaltma eğilimi (n=64, %47.76 kısmen ve çok) ile ağır taşıtı geçmek için hız artırma eğilimi (n=57, %42.54 kısmen ve çok) incelendiğinde benzer dağılıma sahip oldukları sonucuna ulaşılmıştır. Sürücülerin sürüş seviyesi ve sürüş tarzı incelendiğinde (Şekil 55) farklı yeterlilik düzeylerindeki sürücülerin davranış eğilimleri hakkında önemli bulgular elde edilmiştir. Başlangıç seviyesinde kendini tanımlayan sürücülerde ‘orta düzeyde riskli’ ve ‘risksiz’ profil (8 ve 5 kişi) öne çıkarken, profesyonel seviyede kendini tanımlayan grupta ‘orta düzeyde riskli’ (25 kişi) profilin yanı sıra ‘riskli’ (11 kişi) ve ‘risksiz’ (12 kişi) profiller de görülmektedir. Orta seviyede kendini değerlendiren sürücüler arasında ‘orta’ profil (43 kişi) ve ‘risksiz’ profil (19 kişi) tanımlamaları dikkat çekmektedir.



Şekil 55. Sürüş seviyesi ve sürüş tarzı dağılımı

Simülatör performans ölçeği, sürücülerin simülasyon sırasında ve sonrasında hissettikleri fiziksel ve psikolojik durumları, simülasyonun gerçekçiliği ve sürüş senaryolarına verilen tepkileri ölçmek amacıyla yapılmıştır. Ayrıca tünel içindeki trafik akışı, ağır taşıt yoğunluğu, aydınlatma koşulları ve dijital uyarıcıların sürüş davranışı üzerindeki etkileri de değerlendirilmiştir. Tablo 13, katılımcıların bu faktörler karşısında verdikleri yanıtların dağılımını göstermektedir.

Tablo 13. Simülatör performans ölçeği bulguları

Anket Soruları	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**Toplam**
Sorunsuz bir sürüş testi gerçekleştirdim	3	11	7	3	21	51	38	134
Araç simülatöründe kendimi gerçek bir araç kullanıyormuş gibi hissettim	1	2	7	4	17	50	53	134
Test için hazırlanan 3D modellemeler oldukça gerçekçidir	0	1	6	0	16	62	49	134
Hazırlanan sürüş senaryoları ile kendimi senaryonun içinde hissettim ve gerçek bir sürüşteki gibi davranmaya çalıştım	0	3	3	3	13	56	56	134
Senaryo içindeki trafik akımı oldukça gerçekçidir	0	0	4	1	24	64	41	134
Tünel içindeki ağır araç yoğunluğu araç kullanım hızımı önemli derecede etkiledi	5	8	5	3	28	62	23	134
Tünel içinde ağır taşıt ile karşılaşmak hızımı azaltmama ve şerit disiplinimin artmasına sebep oldu	0	4	10	4	31	56	29	134
Ağır taşıt ile yan yana hareket etmek stresli sürüş yapmama sebep oldu	3	13	8	7	37	47	19	134
Ağır taşıtı bir an önce geçmek için hızımı arttırdım	2	5	8	5	26	59	29	134
Tünel içindeki dijital hız uyarı levhaları ve değişken mesaj sistemleri sürüş davranışım üzerinde etkilidir	1	4	4	4	27	71	23	134
Bu senaryoda kaza yapma olasılığım oldukça fazlaydı (ağır taşıt ile karşılaşma)	6	12	5	14	46	32	19	134
Tehlikeli bölge öncesi ışıklı uyarıcılar hızımı azaltmama neden oldu	2	6	6	7	35	58	20	134
1: Kesinlikle katılmıyorum 2: Katılmıyorum 3: Biraz katılmıyorum 4: Kararsızım								
5: Biraz katılıyorum 6: Katılıyorum 7: Kesinlikle katılıyorum								

Performans ölçeği anketinin ilk sorusu olan ‘Sorunsuz bir sürüş testi gerçekleştirdim’ sorusuna katılımcıların büyük çoğunluğu (%38.06) ‘katılıyorum’ cevabını verirken, %28.36’sı ‘kesinlikle katılıyorum’ şeklinde yanıt vermiştir. Bu, simülatör deneyiminin genel olarak sorunsuz ve başarılı bir şekilde gerçekleştiğine dair bir kanı oluşturmaktadır. Katılımcıların, simülatörün gerçekçiliği ile ilgili algılarının da olumlu olduğu görülmüştür. ‘Araç simülatöründe kendimi gerçek bir araç kullanıyormuş gibi hissettim’ sorusuna katılımcıların %39.55’i ‘kesinlikle katılıyorum’ ve %37.31’i ‘katılıyorum’ şeklinde yanıtlar vermiştir. Bu durum simülatörün sürüş deneyiminin

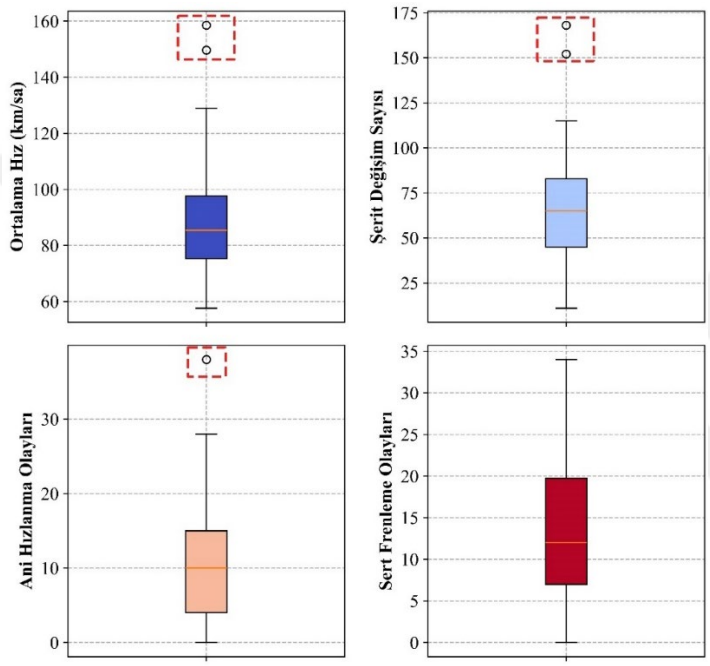
gerçek sürüş koşullarını başarılı bir şekilde yansıttığını göstermektedir. Benzer şekilde, 'Test için hazırlanan 3D modellemeler oldukça gerçekçidir' sorusuna %36.57 oranında 'kesinlikle katılıyorum' ve %46.27 oranında 'katılıyorum' cevabı verilmiştir. Bu bulgu modeldeki görsel unsurların da sürücüler tarafından olumlu değerlendirildiğini ortaya koymaktadır. Sürüş sırasında senaryoların gerçekçiliği, 'Hazırlanan sürüş senaryoları ile kendimi senaryonun içinde hissettim ve gerçek bir sürüşteki gibi davranmaya çalıştım' sorusuyla ölçülmüştür. Katılımcıların %83.58'i bu soruya 'kesinlikle katılıyorum' ve 'katılıyorum' cevabını vermiştir. Bu bulgular, hazırlanan senaryoların gerçek bir sürüş deneyimi hissi uyandırma başarısını vurgulamaktadır. 'Senaryo içindeki trafik akımı oldukça gerçekçidir' sorusuna ise katılımcıların %47.76'sı 'katılıyorum' ve %30.60'ı 'kesinlikle katılıyorum' yanıtını vermiştir; bu durum, trafik akışının modelde başarılı bir şekilde yansıtıldığını göstermektedir.

Tünel içi sürüş deneyimleri incelendiğinde, 'Tünel içindeki ağır araç yoğunluğu araç kullanım hızımı önemli derecede etkiledi' sorusuna katılımcıların %46.27'si 'katılıyorum' ve %17.16'sı 'kesinlikle katılıyorum' yanıtını vermiştir. Bu durum, ağır taşıtların tünel içinde sürüş dinamikleri üzerinde belirgin bir etkisi olduğunu göstermektedir. Benzer şekilde, 'Tünel içinde ağır taşıt ile karşılaşmak hızımı azaltmama ve şerit disiplinimin artmasına sebep oldu' ifadesine katılımcıların %41.79'u 'katılıyorum' ve %21.64'ü 'kesinlikle katılıyorum' şeklinde yanıt vermiştir. Ağır taşıt ile karşılaşma senaryosunun kaza riski değerlendirmesinde, 'Bu senaryoda kaza yapma olasılığım oldukça fazlaydı' ifadesine %33.32 oranında 'biraz katılıyorum', %23.88 oranında 'katılıyorum' ve %14.18 oranında 'kesinlikle katılıyorum' yanıtı verilmiştir. Bu bulgu, senaryonun belirli bir tehlike hissi uyandırdığını ve risk faktörlerini etkili bir şekilde yansıttığını göstermektedir. Son olarak, 'Tehlikeli bölge öncesi ışıklı uyarıcılar hızımı azaltmama neden oldu' ifadesine verilen yanıtlar, ışıklı uyarıcıların sürüş hızı üzerinde bir etkisi olduğunu göstermektedir. Katılımcıların %43.28'i 'katılıyorum' ve %14.93'ü 'kesinlikle katılıyorum' yanıtı vermiştir. Bu, sürücülerin tehlike öncesi uyarılara beklenen bir şekilde adapte olduğunu göstermektedir.

Özetle, anket sonuçları, simülatör çalışmasının gerçekçi ve etkileyici bir deneyim sunduğunu ve ayrıca çeşitli sürüş dinamiklerinin katılımcılar üzerinde anlamlı bir etki yarattığını göstermektedir.

4.2. Veri Keşfi

Veri setinde tespit edilen aykırı değerlerin çıkarılması istatistiksel analizlerin güvenilirliği ve veri kalitesi açısından kritik öneme sahiptir. Bu aykırı değerler, ortalama ve standart sapma gibi temel istatistiksel ölçümleri önemli ölçüde etkileyebilmekte, özellikle sürüş davranışını yansıtan metriklerde gerçekçi olmayan sonuçlara yol açabilmektedir. Şekil 56'dan gözlemlendiği üzere; söz konusu değerler genel dağılımdan belirgin şekilde sapma göstermektedir ve potansiyel ölçüm hatası veya sensör arızası kaynaklı olabilecekleri değerlendirilmektedir.



Şekil 56. Aykırı değer gözlemlenen değişkenlerin dağılımı

Bu bağlamda veri setinin makine öğrenmesi modellemesinde kullanılması durumunda aykırı değerlerin modelin öğrenme sürecini olumsuz etkileme potansiyeli bulunmaktadır. Model, bu aykırı değerlere uyum sağlamaya çalışarak genelleme yeteneğini kaybedebilmektedir. Mevcut grafiklerde gözlemlenen aykırı değerlerin veri setinin genel yapısından kayda değer ölçüde sapma göstermesi nedeniyle bunların elimine edilmesinin analiz sonuçlarının güvenilirliği açısından daha uygun olacağı değerlendirilmiştir. Dolayısıyla aykırı değer oluşturan dört sürücü veri setinden çıkarılarak sonraki analizlere 130 sürücüye ait verilerle ile devam edilmiştir.

130 sürücünün farklı yol kesimlerindeki sürüş performansları ve davranış parametreleri incelenmiştir. Veri setinde yer alan değişkenlerin genel dağılımını anlamak ve temel özelliklerini ortaya koymak amacıyla ortalama, standart sapma, minimum ve maksimum değerler hesaplanmıştır. Tablo 14'te sunulan bu istatistikler sürücülerin genel

sürüş performanslarını ve güzergâh üzerindeki farklı kesimlerdeki davranış özelliklerini yansıtmaktadır.

Tablo 14. Simülatör verilerine ilişkin tanımlayıcı istatistikler

Değişken Adı	**N**	**Ort.**	**Std. S.**	**Min.**	**Maks.**
Ortalama Hız (km/sa)	130	87.07	15.54	57.61	128.91
Şerit Değişim Sayısı	130	62.37	26.57	11.00	115.00
Ortalama İvme (m/s²)	130	0.12	0.04	0.03	0.21
Geçerli Hız Limitine Uyma Oranı	130	0.44	0.25	0.02	1.00
T4 Tüneli Ort. Hız (km/sa)	130	75.16	16.62	38.44	119.92
T3 Tüneli Ort. Hız (km/sa)	130	72.53	16.12	38.47	112.16
T2 Tüneli Ort. Hız (km/sa)	130	81.17	17.82	50.66	125.93
Zigana Tüneli Ort. Hız (km/sa)	130	98.90	22.43	57.76	149.03
Çevre Yolu Ort. Hız (km/sa)	130	78.78	16.50	48.17	126.68
T4-T3 Arası Ort. Hız (km/sa)	130	84.60	22.31	46.36	141.13
T3-T2 Arası Ort. Hız (km/sa)	130	87.03	22.60	47.13	135.26
T2-Zigana Arası Ort. Hız (km/sa)	130	88.45	24.13	54.02	146.08

Sürücülerin ortalama hızının 87.07 km/sa olduğu ve bu değerin 15.54 km/sa'lik bir standart sapma ile değişkenlik gösterdiği görülmektedir. En düşük ortalama hız 57.61 km/sa iken en yüksek değer 128.91 km/sa olarak ölçülmüştür. Güzergâh üzerindeki farklı tünel kesimlerinde ortalama hızların değişkenlik gösterdiği ve özellikle Zigana Tüneli'nde ortalama hızın (98.90 km/sa) diğer tünellere göre daha yüksek olduğu sonucuna ulaşılmıştır. Şerit değişim sayıları incelendiğinde ortalama 62.37 şerit değişimi gerçekleştiği ve bu değerin oldukça geniş bir aralıkta (11 ile 115 arasında) değişim gösterdiği gözlemlenmiştir. Geçerli hız limitine uyma oranının ortalama 0.44 olması, sürücülerin yaklaşık yarı zamanında hız limitlerinin üzerinde sürüş yaptıklarına işaret etmektedir. Bu bulgular sürücülerin farklı yol kesimlerinde değişken hız davranışları sergilediklerini ve özellikle tünel geçişlerinde hız profillerinin belirgin şekilde farklılaştığını göstermektedir.

Sürücü davranışlarındaki değişimlerin istatistiksel açıdan anlamlılığını test etmek amacıyla bir dizi test gerçekleştirilmiştir. Testlerde farklı deneysel koşullar altında elde edilen tekrarlı ölçümlerin varlığı nedeniyle ilk olarak tekrarlı ölçümler varyans analizi (tekrarlı ölçümler ANOVA) tercih edilmiştir. Analizler iki temel grupta gerçekleştirilmiştir: ilki, farklı tünel kesimlerindeki (T4, T3, T2 ve Zigana Tüneli) ortalama hızların karşılaştırılması şeklinde, ikincisi ise her bir senaryo için giriş, merkez ve çıkış hızları arasındaki değişimlerin karşılaştırılması şeklindedir. Tekrarlı ölçümler varyans analizinin uygulanabilmesi için gerekli olan normallik varsayımı, Shapiro-Wilk

testi ile kontrol edilmiştir. Bu test özellikle küçük ve orta büyüklükteki örneklemlerde (N<2000) güçlü sonuçlar vermesi nedeniyle tercih edilmiştir. Shapiro-Wilk testi sonuçları Tablo 15'te verilmektedir.

Tablo 15. Farklı tünel kesimlerindeki ortalama hızların Saphiro-Wilk normallik testi sonuçları

Değişken (km/sa)	Test İstatistiği	p-değeri	Normal Dağılım
Ortalama Hız	0.95457	0.00026	Yok
T4 Tüneli Ortalama Hız	0.98188	0.08015	Var
T3 Tüneli Ortalama Hız	0.97412	0.01371	Yok
T2 Tüneli Ortalama Hız	0.96300	0.00131	Yok
Zigana Tüneli Ortalama Hız	0.94609	0.00001	Yok
T4-T3 Arası Ortalama Hız	0.97334	0.01154	Yok
T3-T2 Arası Ortalama Hız	0.96902	0.00452	Yok
T2-T1 Arası Ortalama Hız	0.90700	0.00000	Yok

Tablo 15 incelendiğinde yalnızca T4 Tüneli ortalama hız değişkeninin p değeri 0.05'ten büyük olup (p=0.08015), normal dağılım varsayımını karşıladığı görülmektedir. Diğer tüm değişkenler için p değerleri 0.05'ten küçük olduğundan bu değişkenlerin normal dağılım varsayımını karşılamadığı sonucuna ulaşılmıştır. Verilerin büyük bir kısmının normal dağılım göstermemesi ve tekrarlı ölçümlerin varlığı göz önüne alındığında gruplar arası farklılıkların incelenmesinde parametrik olmayan Friedman testi kullanılması uygun görülmüştür. Friedman testi, normal dağılım varsayımı gerektirmeyen ve tekrarlı ölçümlerin karşılaştırılmasında etkili olan bir non-parametrik testtir.

İkinci grupta ise her bir senaryo için giriş, merkez ve çıkış hızları arasındaki değişimler incelenmiştir. Bu ölçüm grubuna ait tanımlayıcı istatistik sonuçları Tablo 16'da verilmiştir.

Tablo 16. Her bir senaryo için giriş, merkez, çıkış hızlarının tanımlayıcı istatistik sonuçları

Senaryo No	Değişken Adı	N	Ortalama	Standart Sapma	Minimum	Maksimum
1	Giriş Hızı	130	47.19	11.71	22.75	71.65
	Merkez Hızı	130	65.92	20.72	25.39	94.60
	Çıkış Hızı	130	63.31	17.51	26.10	103.25
2	Giriş Hızı	130	73.38	17.52	33.35	110.00
	Merkez Hızı	130	69.10	15.65	34.85	99.20
	Çıkış Hızı	130	79.23	25.40	35.22	141.90

Tablo 16. (Devamı)

3	Giriş Hızı	130	92.12	24.96	34.56	145.54
	Merkez Hızı	130	70.70	21.92	16.74	117.26
	Çıkış Hızı	130	78.56	23.85	34.65	141.72
4	Giriş Hızı	130	90.64	25.69	48.18	146.77
	Merkez Hızı	130	68.54	19.60	31.10	109.85
	Çıkış Hızı	130	72.65	16.97	28.14	110.00
5	Giriş Hızı	130	81.05	21.49	26.05	127.48
	Merkez Hızı	130	84.53	21.72	48.93	132.44
	Çıkış Hızı	130	87.12	22.84	43.73	135.62
6	Giriş Hızı	130	86.96	22.97	44.02	135.03
	Merkez Hızı	130	77.94	20.20	42.25	122.22
	Çıkış Hızı	130	78.30	17.64	39.65	116.86
7	Giriş Hızı	130	84.61	24.14	29.52	142.99
	Merkez Hızı	130	82.89	25.69	29.57	142.16
	Çıkış Hızı	130	85.09	25.48	35.18	145.01
8	Giriş Hızı	130	93.65	25.18	51.11	147.00
	Merkez Hızı	130	87.69	25.96	35.86	146.66
	Çıkış Hızı	130	89.39	24.99	38.21	139.32
9	Giriş Hızı	130	95.00	25.46	43.67	149.18
	Merkez Hızı	130	84.36	23.92	42.93	134.80
	Çıkış Hızı	130	91.76	25.48	27.79	150.29
10	Giriş Hızı	130	99.36	27.53	47.22	150.91
	Merkez Hızı	130	102.18	30.55	9.56	151.48
	Çıkış Hızı	130	105.14	30.48	31.98	152.55
11	Giriş Hızı	130	98.43	22.67	55.03	134.34
	Merkez Hızı	130	79.10	15.14	50.36	99.96
	Çıkış Hızı	130	90.36	23.05	30.08	124.63
12	Giriş Hızı	130	88.69	25.36	27.18	129.66
	Merkez Hızı	130	80.10	22.39	34.24	124.85
	Çıkış Hızı	130	108.42	31.85	41.52	152.94

En düşük giriş hızı Senaryo 1'de (47.19 km/sa), en yüksek giriş hızı ise Senaryo 10'da (99.36 km/sa) ölçülmüştür. Bu değerler arasındaki yaklaşık 52 km/sa'lik fark, farklı senaryolardaki sürüş koşullarının belirgin şekilde değişkenlik gösterdiğini ortaya koymaktadır. Yapılan analizler sonucunda sürücülerin merkezi noktalara (tehlikeli/problemli bölgenin olduğu nokta) yaklaşırken genel eğilimlerinin hız azaltma yönünde olduğu sonucuna ulaşılmıştır. Merkez hızları açısından yapılan değerlendirmede en düşük merkez hızının Senaryo 1'de (65.92 km/sa), en yüksek merkez hızının ise Senaryo 10'da (102.18 km/sa) olduğu belirlenmiştir. Ayrıca her bir senaryodaki merkez-çıkış hız farklarının değişkenlik göstermesi, sürücülerin senaryolara özgü farklı davranış

eğilimleri sergilediklerine işaret etmektedir. Standart sapma değerleri incelendiğinde özellikle Senaryo 10'da merkez hızının (30.55 km/sa) ve çıkış hızının (30.48 km/sa) en yüksek değişkenliğe sahip olduğu görülmektedir. Bu durum, sürücülerin yüksek hızlarda daha farklı davranış biçimleri sergilediğine işaret etmektedir. Genel olarak, standart sapma değerlerinin yüksek olması, hız değişkenlerinin geniş bir aralıkta dağılım gösterdiğini ve sürücüler arasında hız seçiminde belirgin farklılıklar olduğunu ortaya koymaktadır. Sürücülerin senaryo bazlı davranışlarına ilişkin analizler, bazı senaryolarda hız azaltma eğiliminde olduklarını, diğer senaryolarda ise hız artırma yönünde bir tutum sergilediklerini göstermektedir. Bu değişkenlik sürücülerin karakteristik özelliklerini belirlemede önemli bir parametre olarak değerlendirilmektedir. Verilerin normallik varsayımını kontrol etmek amacıyla Shapiro-Wilk testi uygulanmış ve sonuçları Tablo 17'de sunulmuştur.

Tablo 17. Her bir senaryo için giriş, merkez, çıkış hızlarının Saphiro-Wilk normallik testi sonuçları

S. No	Değişken Adı (km/sa)	Test İstatistiği	p-değeri	Normal Dağılıma Uygun mu?
1	Giriş Hızı	0.96278	0.00125	Hayır
	Merkez Hızı	0.91983	0.00000	Hayır
	Çıkış Hızı	0.97403	0.01344	Hayır
2	Giriş Hızı	0.97208	0.00874	Hayır
	Merkez Hızı	0.98039	0.05693	Evet
	Çıkış Hızı	0.96206	0.00108	Hayır
3	Giriş Hızı	0.98075	0.06182	Evet
	Merkez Hızı	0.98028	0.05544	Evet
	Çıkış Hızı	0.97919	0.04313	Hayır
4	Giriş Hızı	0.96438	0.00173	Hayır
	Merkez Hızı	0.96686	0.00287	Hayır
	Çıkış Hızı	0.99388	0.85083	Evet
5	Giriş Hızı	0.96356	0.00146	Hayır
	Merkez Hızı	0.96541	0.00213	Hayır
	Çıkış Hızı	0.97650	0.02340	Hayır
6	Giriş Hızı	0.96938	0.00489	Hayır
	Merkez Hızı	0.96644	0.00263	Hayır
	Çıkış Hızı	0.98016	0.05392	Evet
7	Giriş Hızı	0.97944	0.04574	Hayır
	Merkez Hızı	0.95439	0.00025	Hayır
	Çıkış Hızı	0.95043	0.00012	Hayır

Tablo 17. (Devamı)

8	Giriş Hızı	0.94756	0.00000	Hayır
	Merkez Hızı	0.96192	0.00105	Hayır
	Çıkış Hızı	0.96355	0.00146	Hayır
9	Giriş Hızı	0.97950	0.04637	Hayır
	Merkez Hızı	0.96405	0.00161	Hayır
	Çıkış Hızı	0.98668	0.23858	Evet
10	Giriş Hızı	0.94788	0.00000	Hayır
	Merkez Hızı	0.95546	0.00031	Hayır
	Çıkış Hızı	0.94535	0.00000	Hayır
11	Giriş Hızı	0.94857	0.00000	Hayır
	Merkez Hızı	0.92022	0.00000	Hayır
	Çıkış Hızı	0.90171	0.00000	Hayır
12	Giriş Hızı	0.95344	0.00021	Hayır
	Merkez Hızı	0.96355	0.00146	Hayır
	Çıkış Hızı	0.93186	0.00000	Hayır

Verilerin tümü üzerinde gerçekleştirilen Shapiro-Wilk normallik testi sonuçlarında p değerlerinin kritik eşik olan 0.05'in altında kalması ($p < 0.05$), veri setinin normal dağılım varsayımını karşılamadığını göstermektedir. Yalnızca birkaç örnekte (örneğin Senaryo 3'te Giriş Hızı ve Senaryo 4'te Çıkış Hızı) $p>0.05$ olduğu, yani normal dağılıma uygunluk gösterdiği tespit edilmiştir. Verilerin normal dağılım göstermemesi ve tekrarlı ölçüm karakteristiği nedeniyle, giriş-merkez-çıkış hızlarının karşılaştırılmasında parametrik olmayan ve bağımlı grupların karşılaştırılmasında etkin bir yöntem olan Friedman testi tercih edilmiştir. Sonuç olarak sürücülerin farklı senaryolarda sergiledikleri hız artırma veya azaltma davranışları, bu davranışların karakteristikleri ve on iki farklı senaryo üzerinden elde edilen verilerin çeşitliliği, sürücü sınıflandırma modeli için önemli bir veri seti oluşturmaktadır. Hız değişimlerinin karakteristiği (ani veya kademeli olması), güvenlik açısından kritik önem taşımaktadır ve sonraki bölümlerde detaylı olarak ele alınacaktır.

Senaryo bazlı hız değişimlerinin istatistiksel olarak anlamlı olup olmadığını belirlemek amacıyla her bir senaryo için Friedman testi uygulanmıştır. Bu test ile sürücülerin giriş, merkez ve çıkış noktalarındaki ortalama hız değerlerinin anlamlı bir farklılık gösterip göstermediği test edilmektedir (Tablo 18).

Tablo 18. Senaryo bazlı ortalama hız değişimlerinin Friedman test sonuçları

Senaryo No	Friedman Test İstatistiği	Serbestlik Derecesi	p-değeri	Anlamlı mı?
1	129.66	2	0.00000	Evet
2	28.12	2	0.00001	Evet
3	98.51	2	0.00000	Evet
4	67.26	2	0.00000	Evet
5	15.52	2	0.00043	Evet
6	21.80	2	0.00000	Evet
7	10.77	2	0.00459	Evet
8	11.37	2	0.00340	Evet
9	58.48	2	0.00000	Evet
10	16.17	2	0.00031	Evet
11	117.06	2	0.00000	Evet
12	85.03	2	0.00000	Evet

Tablo 18'deki Friedman testi sonuçları incelendiğinde tüm senaryolarda istatistiksel olarak anlamlı farklılıklar tespit edilmiştir ($p<0.05$). En yüksek test istatistiği Senaryo 1'de ($\chi^2=129.66$) gözlemlenmiş ve bu senaryoda giriş, merkez ve çıkış hızları arasında belirgin bir farklılaşma olduğu sonucuna varılmıştır. Benzer şekilde Senaryo 11 ($\chi^2=117.06$) ve Senaryo 3'te de ($\chi^2=98.51$) yüksek test istatistikleri elde edilmiştir. En düşük test istatistiği ise Senaryo 7'de ($\chi^2=10.77$) gözlemlenmiş olup bu senaryoda da hız değerlerindeki farklılığın istatistiksel olarak anlamlı olduğu belirlenmiştir.

Sürücülerin giriş, merkez ve çıkış noktalarındaki hız davranışları arasındaki benzerlikleri ve tutarlılıkları belirlemek amacıyla korelasyon analizi gerçekleştirilmiştir. Verilerin normal dağılım varsayımını karşılamaması nedeniyle Spearman sıra korelasyon katsayısı kullanılmıştır. Analiz sonuçlarında istatistiksel olarak anlamlı ve 'Güçlü' ($r \geq 0.70$) ile 'Orta' ($0.40 \leq r < 0.70$) düzeydeki korelasyon katsayıları Tablo 19'da sunulmuştur.

Tablo 19. Spearman korelasyon testi sonuçları

Hız Bölgesi	Senaryo No	Senaryo No	Korelasyon Değeri	İlişki
Çıkış	11	12	0.618	Orta
	3	7	0.519	Orta
	3	12	0.461	Orta
	7	11	0.404	Orta
	7	12	0.426	Orta
Giriş	11	12	0.909	Güçlü
	3	4	0.706	Güçlü
	3	7	0.613	Orta
	4	7	0.619	Orta
	2	3	0.578	Orta
	2	4	0.530	Orta
	2	7	0.490	Orta
	2	11	0.462	Orta
	3	11	0.410	Orta
	4	11	0.470	Orta
	4	12	0.424	Orta
	7	11	0.553	Orta
	7	12	0.529	Orta
Merkez	7	12	0.607	Orta
	11	12	0.613	Orta
	3	7	0.516	Orta
	3	11	0.434	Orta
	3	12	0.416	Orta

Tablo 19'da verilen Spearman korelasyon analizi sonuçları, farklı senaryolar arasındaki hız ilişkilerini ortaya koymaktadır. Analiz sonuçları hız bölgelerine göre değerlendirildiğinde;

Giriş Bölgesinde, Senaryo 11 ve 12 arasında 'Güçlü' bir pozitif korelasyon (r=0.909) elde edilmiştir. Bu durum sürücülerin bu iki senaryodaki giriş hızı davranışlarının oldukça benzer olduğunu göstermektedir. Ayrıca, Senaryo 3 ile 4 arasında da 'Güçlü' bir pozitif korelasyon (r=0.706) bulunmuştur ve bu da sürücülerin bu senaryolardaki giriş hızlarının benzerlik gösterdiğine işaret etmektedir. Diğer senaryolar arasında 'Orta' düzeyde pozitif korelasyonlar (r=0.410 ile r=0.619 arasında) gözlemlenmiştir. Örneğin, Senaryo 3-7 (r=0.613) ve Senaryo 4-7 (r=0.619) arasındaki orta düzeyli korelasyonlar, sürücülerin bu senaryolardaki giriş hızı davranışlarının benzerlik gösterdiğini ortaya koymaktadır.

Çıkış Bölgesinde, en yüksek korelasyon Senaryo 11 ve 12 arasında olup (r=0.618), bu 'Orta' düzeyde bir pozitif ilişkiyi ifade etmektedir. Diğer senaryolar arasında da 'Orta'

düzeyde pozitif korelasyonlar tespit edilmiştir. Örneğin, Senaryo 3 ile 7 arasında (r=0.519) ve Senaryo 7 ile 12 arasında (r=0.426) 'Orta' düzeyde ilişkiler bulunmaktadır. Bu sonuçlar sürücülerin çıkış hızı davranışlarının belirli senaryolarda benzerlik gösterdiğini ancak bu benzerliğin giriş bölgesine kıyasla daha az olduğunu göstermektedir.

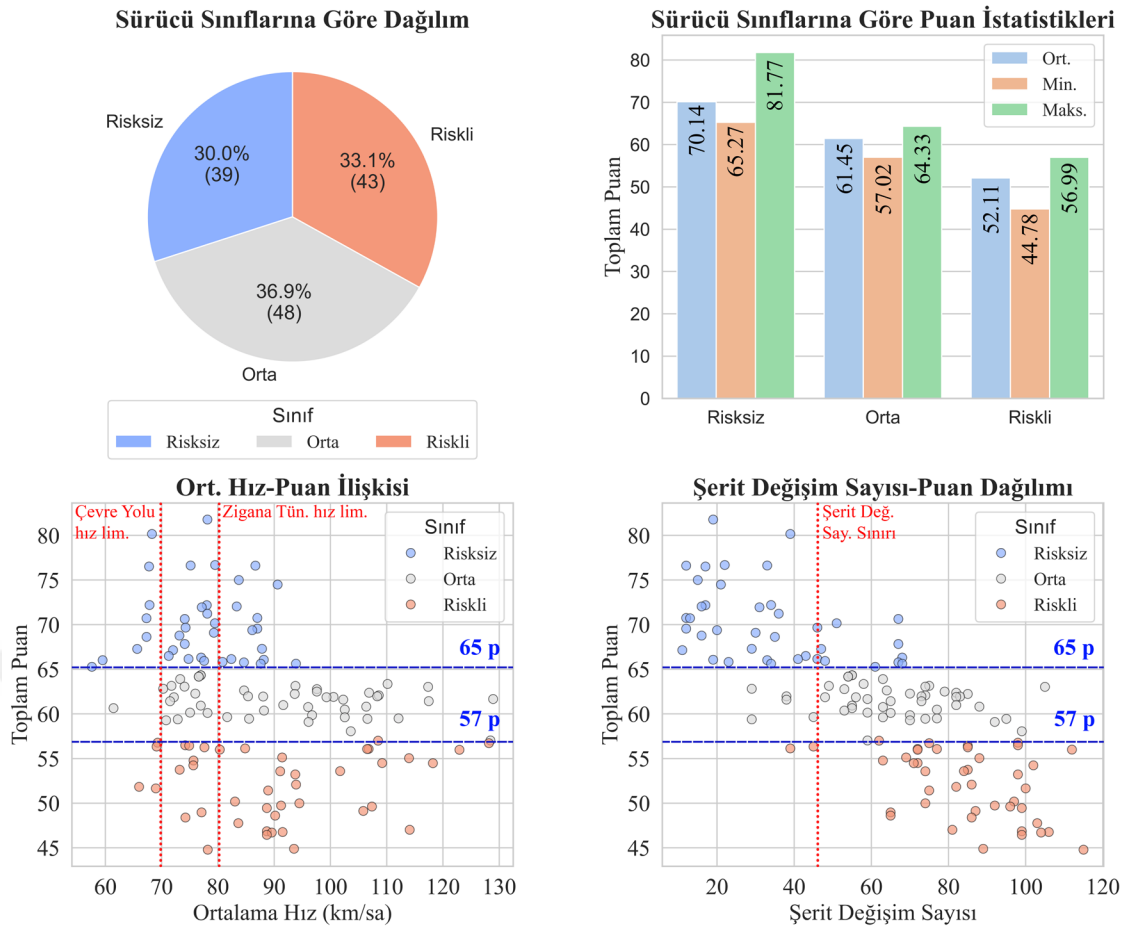
Merkez Bölgesinde, tüm korelasyonlar 'Orta' düzeyde pozitif ilişki göstermektedir. Senaryo 11 ile 12 (r=0.613) ve Senaryo 7 ile 12 (r=0.607) arasındaki korelasyonlar sürücülerin bu senaryolardaki merkez hızı davranışlarının benzer olduğunu ortaya koymaktadır. Bununla birlikte, merkez bölgesindeki korelasyonların genel olarak giriş ve çıkış bölgelerine göre daha düşük düzeyde olması sürücülerin bu bölgede daha fazla davranış çeşitliliği sergilediğine işaret etmektedir.

Özetle; korelasyon analizi sonuçları sürücülerin belirli senaryolarda benzer hız davranışları sergilediğini göstermektedir. Giriş bölgesinde Senaryo 11 ve 12 arasındaki 'Güçlü' pozitif ilişki, sürücülerin bu senaryolardaki giriş hızlarının oldukça tutarlı olduğunu vurgulamaktadır. Diğer bölgelerdeki korelasyonların genellikle 'Orta' düzeyde olması bu bölgelerdeki hız davranışlarının daha fazla değişkenlik gösterdiğini ve senaryolara göre farklılıklar olabileceğini düşündürmektedir.

Bu sonuçlar, sürücülerin hız davranışlarının senaryolara ve yol kesimlerine göre değişebileceğini ve belirli koşullarda benzer eğilimler gösterebileceklerini ortaya koymaktadır. Özellikle giriş bölgesindeki güçlü ilişkiler sürücülerin belirli başlangıç koşullarına benzer tepkiler verdiğini ancak sürüşün ilerleyen kısımlarında bu davranışların daha fazla çeşitlilik ortaya koyduğunu göstermektedir.

4.3. Etiketleme Sistemine Dayalı Sınıflandırma Sonuçları

Sürücülerin risk gruplarına göre dağılımları, risk gruplarının puan istatistikleri ve sürüş performansını belirleyen temel parametreler olan ortalama hız ve şerit değiştirme sayısının toplam puan ile ilişkisi incelenmiştir (Şekil 57). Geliştirilen puanlama sistemine göre sürücülerden 43'ü riskli, 48'i orta düzeyde riskli ve 39'u risksiz olarak etiketlenmiştir. Bu sayede sürücülerin risk gruplarına dağılımında makul bir denge sağlanmıştır.



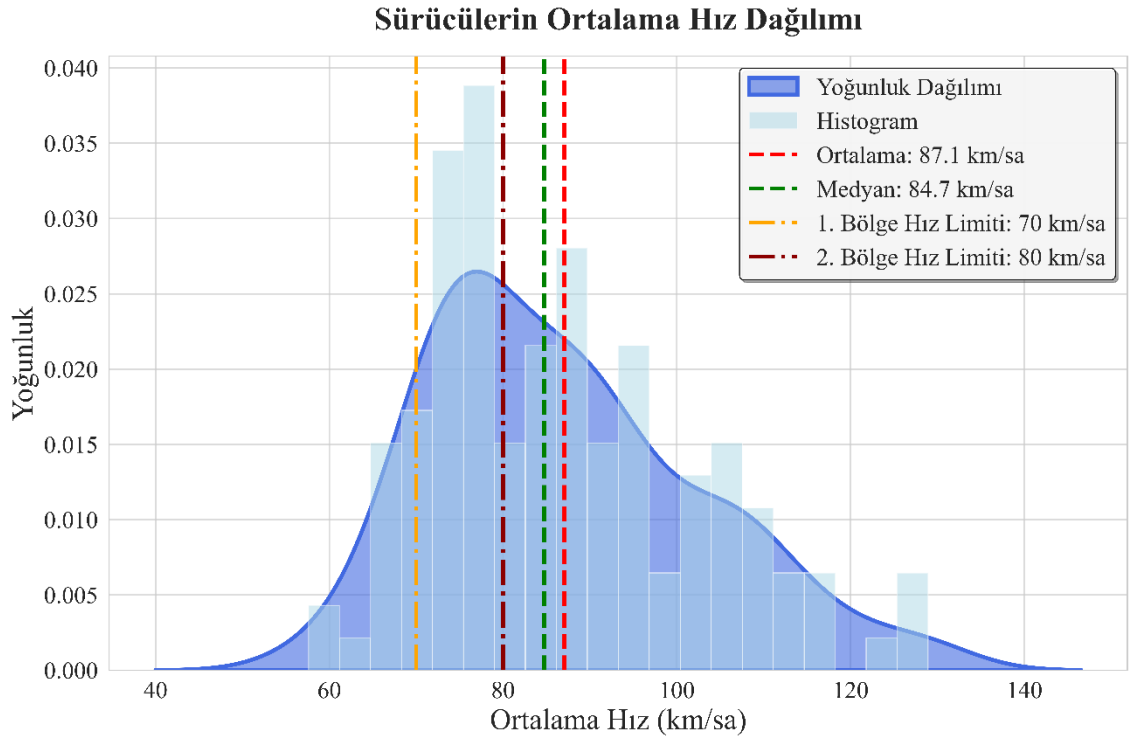
Şekil 57. Puanlama sistemine dayalı sonuçlar

Deney sonuçlarına göre sürücülerin %36,9'u (48 kişi) orta seviyede riskli, %33.1'i (43 kişi) riskli ve %30'u (39 kişi) risksiz kategoride yer almaktadır. Bu dağılım sürücülerin çoğunluğunun (%66.9) kabul edilebilir risk seviyelerinde olduğunu göstermektedir. Risk gruplarına ait puan istatistikleri incelendiğinde risksiz gruptaki sürücülerin ortalama 70.14 puan aldığı ve bu grubun puanlarının 65.27 ile 81.77 arasında değiştiği görülmektedir. Orta risk grubundaki sürücüler ortalama 61.45 puan almış olup puanları 57.02 ile 64.33 arasında dağılmaktadır. Riskli gruptaki sürücüler ise ortalama 52.11 puan ile en düşük performansı göstermiş ve puanları 44.78 ile 56.99 arasında değişmiştir. Ortalama hız ile puan arasındaki ilişkiyi gösteren dağılım grafiğinde, 75 km/sa'lik ortalama hızın kritik bir eşik değeri oluşturduğu tespit edilmiştir. Bu hız değerinin altında kalan sürücülerin büyük bir bölümünün 65 puan üzerinde performans gösterdiği belirlenmiştir. Buna karşılık 75 km/sa hızın üzerinde seyreden sürücülerin çoğunlukla 57 puanın altında kaldığı gözlemlenmiştir. Bu bulgu, yüksek hızın risk faktörü olarak önemli bir gösterge olduğunu ortaya koymaktadır.

Şerit değiştirme sayısı ile toplam puan arasındaki dağılım incelendiğinde 45'in altında şerit değişimi yapan bazı sürücülerin düşük puan aldığı görülmüştür. Bu durum, puanlama sisteminin sadece şerit değiştirme sayısına değil diğer sürüş parametrelerine de bağlı olduğunu göstermektedir. Bu sürücülerin hız limiti aşımı, ani frenleme veya keskin manevralar gibi diğer risk faktörleri nedeniyle düşük puan almış olabileceği düşünülmektedir. Benzer şekilde, 45'in üzerinde şerit değişimi yapmasına rağmen yüksek puan alan sürücüler de bulunmaktadır ki bu da bazı sürücülerin diğer sürüş parametrelerinde daha dikkatli olduklarını göstermektedir.

4.4. Simülatör Verilerinin İrdelenmesi

Sürücülerin ortalama hız dağılımları istatistiksel yöntemlerle (dağılım ve yoğunluk) analiz edilmiş ve belirlenen hız limitleriyle karşılaştırılmıştır. Dağılımın karakteristiğini belirlemek amacıyla merkezi eğilim ölçüleri, çarpıklık ve basıklık katsayıları hesaplanmış; sonuçlar histogram ve yoğunluk dağılımı kullanılarak Şekil 58'de sunulmuştur.

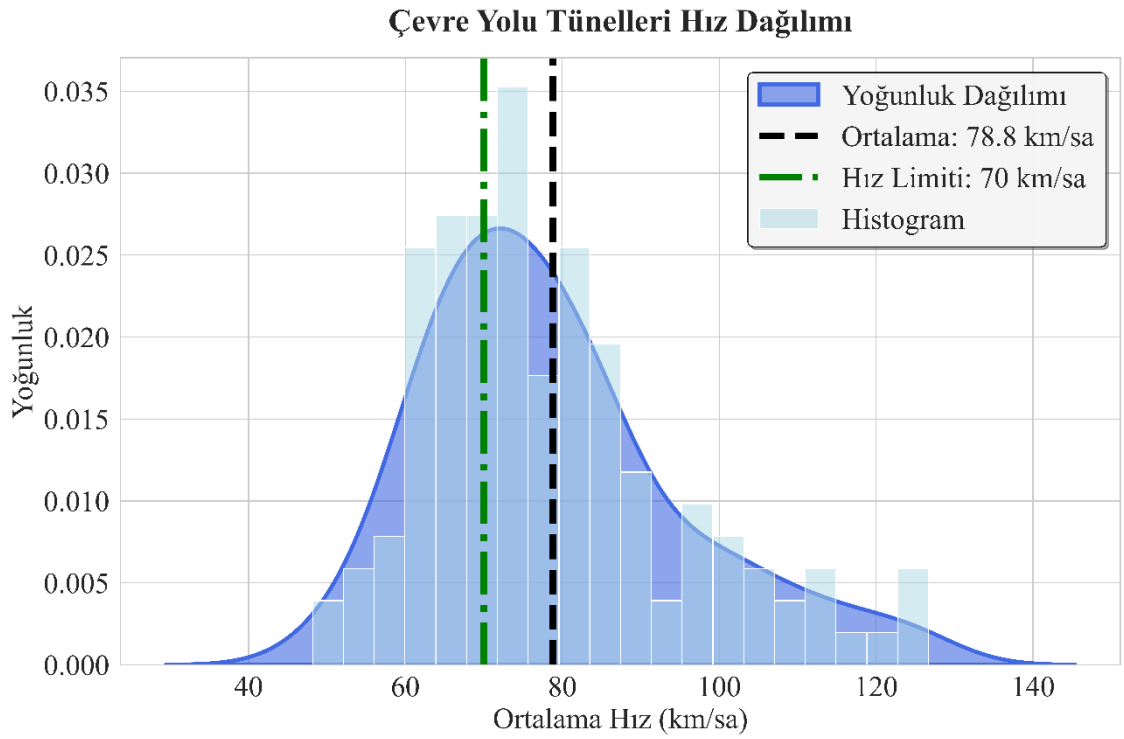


Şekil 58. Sürücülerin ortalama hız dağılımı

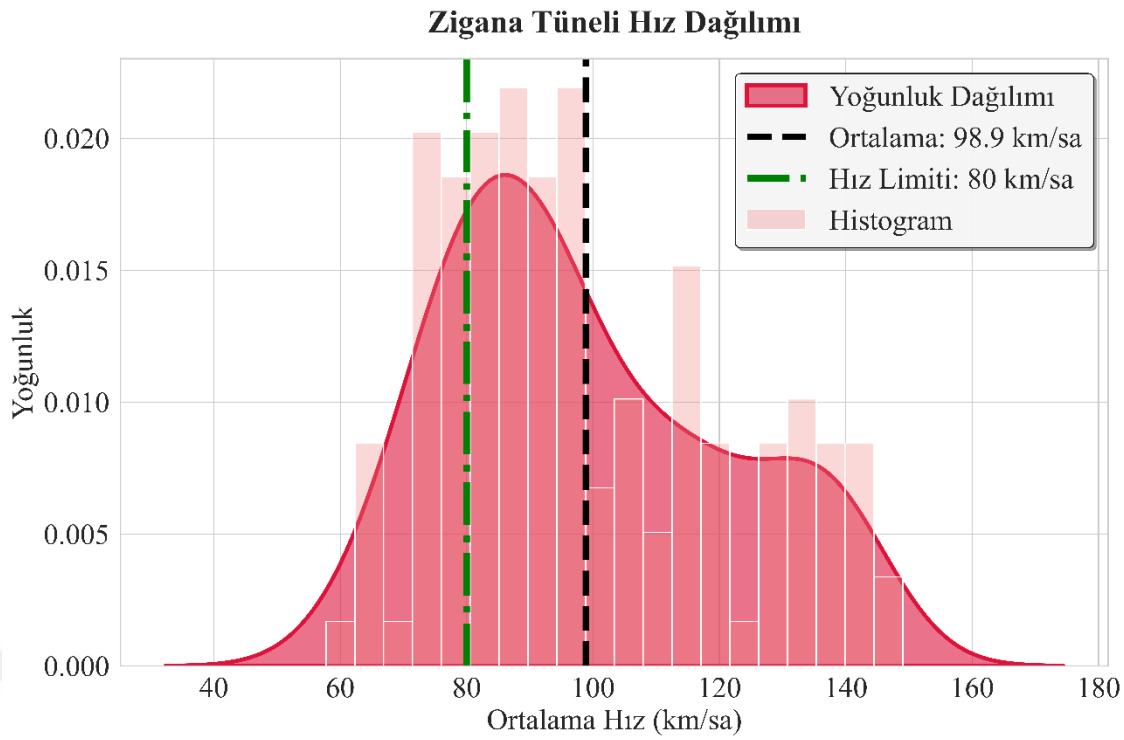
Analiz sonuçları, hız ölçümlerinin 57.61 km/sa ile 128.91 km/sa arasında geniş bir aralıkta değiştiğini göstermektedir. Dağılımın merkezi eğilim ölçüleri incelendiğinde ortalama hızın 87.07 km/sa, medyan hızın ise 84.7 km/sa olduğu tespit edilmiştir. Ortalamanın medyandan yüksek olması ve çarpıklık katsayısının 0.67 olarak

hesaplanması, dağılımın sağa çarpık olduğunu ortaya koymaktadır. Bu durum bazı sürücülerin belirgin şekilde yüksek hızlarda seyretme eğiliminde olduğuna işaret etmektedir. Hız değerlerindeki değişkenlik, standart sapmanın 15.5 km/sa olarak hesaplanmasıyla desteklenmekte ve hız ölçümlerinde önemli düzeyde bir yayılım olduğunu ortaya koymaktadır. Basıklık katsayısının -0.09 olması dağılımın normal dağılıma yakın ancak nispeten daha düz bir yapıda olduğunu belirtmektedir. Sürücü hızları grafikte işaretlenen birinci bölge (70 km/sa) ve ikinci bölge (80 km/sa) hız limitleri ile karşılaştırıldığında sürücülerin büyük çoğunluğunun bu limitlerin üzerinde sürüş yaptıkları görülmektedir. Bu bulgular sürücülerin bir kısmının hız limitlerine uyum konusunda trafik güvenliğini tehlikeye atacak şekilde eğilim gösterdiğini ve sürüş davranışlarında önemli farklılıklar bulunduğunu ortaya koymaktadır.

Çevre Yolu Tünelleri ve Yeni Zigana Tüneli'nde gerçekleştirilen hız ölçümlerine ilişkin istatistiksel analizler her iki tünelde de belirlenen hız limitlerinin genel olarak aşıldığını göstermektedir (Şekil 59, 60 ve Tablo 20). Çevre yolu tünellerinde 70 km/sa olan hız limiti aşılmış ve ortalama hız 78.8 km/sa olarak elde edilmiştir. Zigana Tüneli'nde ise 80 km/sa hız limiti belirgin şekilde aşılmış ve ortalama hız 98.9 km/sa olarak hesaplanmıştır.



Şekil 59. Sürücülerin çevre yolu tünellerindeki hız dağılımı



Şekil 60. Sürücülerin Zigana Tünelindeki hız dağılımı

Hız dağılımlarının karakteristik özellikleri incelendiğinde çevre yolu tünellerinde pozitif çarpıklık (0.91) ve sınırlı bir aralıkta yoğunlaşma gözlemlenirken sürücülerin çoğunlukla 60-90 km/sa aralığındaki hızları tercih ettiği tespit edilmiştir. Öte yandan Zigana Tüneli'nde daha dengeli bir çarpıklık değeri (0.5) ve geniş bir hız aralığı dikkat çekmektedir. Bu tünelde sürücüler genellikle 90-110 km/sa aralığında sürüş yapmış ve negatif basıklık değeri (-0.78) hızların geniş bir aralığa yayıldığını doğrulamıştır.

Tablo 20. Çevre yolu tünelleri ve Zigana tüneli ortalama hızlarına ilişkin tanımlayıcı istatistikler

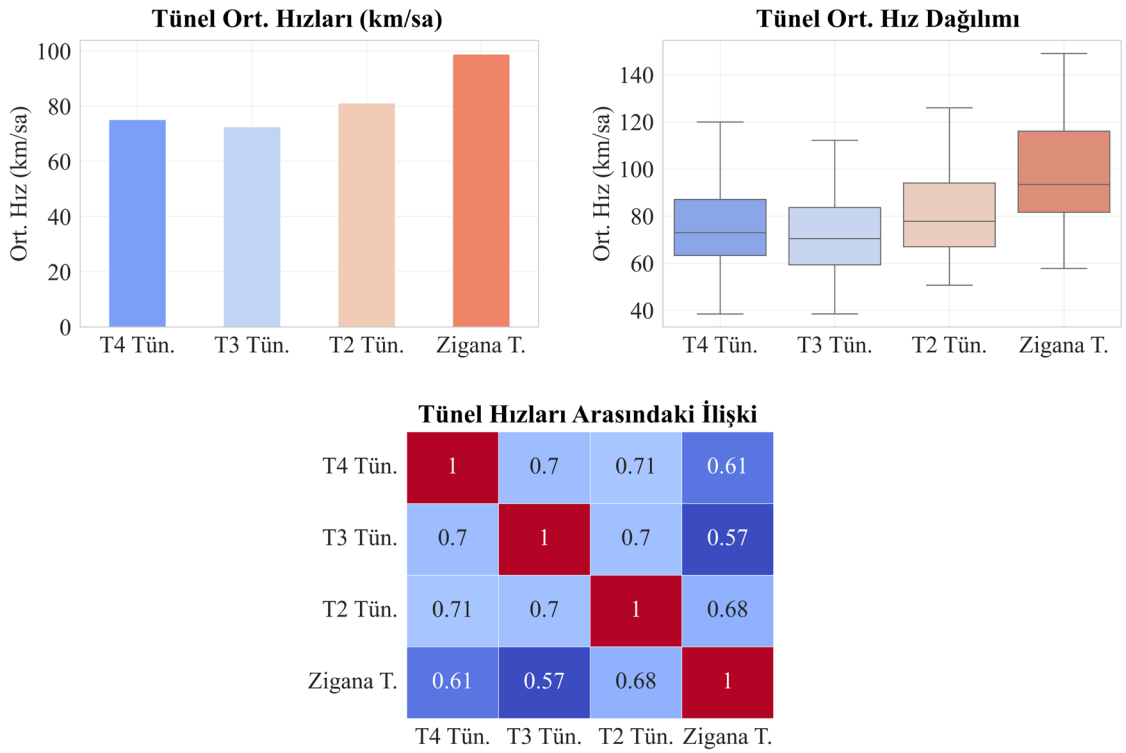
Bölge	N	Min.	Maks.	Ort.	Medyan	Std. Sapma	Çarpıklık	Basıklık
Çevre Yolu T.	130	48.20	126.70	78.80	74.70	18.80	0.91	0.54
Zigana Tüneli	130	57.80	149.00	98.90	93.40	22.40	0.50	-0.78

Standart sapma değerleri çevre yolu tünellerinde 18.8 km/sa, Zigana Tüneli'nde ise 22.4 km/sa olarak hesaplanmıştır. Bu değerler her iki tünelde de sürücülerin değişken hız davranışları sergilediğini ortaya koymaktadır. Zigana Tüneli'ndeki daha yüksek standart sapma, bu tünelde hız çeşitliliğinin daha belirgin olduğunu göstermektedir.

Elde edilen istatistiksel bulgular sürücülerin her iki tünelde de hız limitlerini sıklıkla aştığını ve hız davranışlarında heterojen bir yapı sergilediğini göstermektedir. Özellikle Zigana Tüneli'nde hız limitinin daha belirgin şekilde aşılması ve hız varyasyonunun daha yüksek olması, bu bölgede hız yönetimi ve denetimine yönelik hız aşımını engelleyici

çalışmaların yapılmasının faydalı olabileceğini düşündürmektedir. Çevre yolu tünellerinde ise hızlar daha dar bir aralıkta yoğunlaşmakla birlikte hız limitinin üzerinde seyir durumu devam etmektedir. Bu bulgular, tünellerdeki hız limitlerine uyumun genel olarak düşük olduğunu ve sürücülerin hız tercihleri arasında önemli farklılıklar bulunduğunu ortaya koymaktadır. Gelecek çalışmalarda bu hız davranışlarının altında yatan nedenlerin incelenmesi ve trafik güvenliğine etkilerinin değerlendirilmesi önem arz etmektedir.

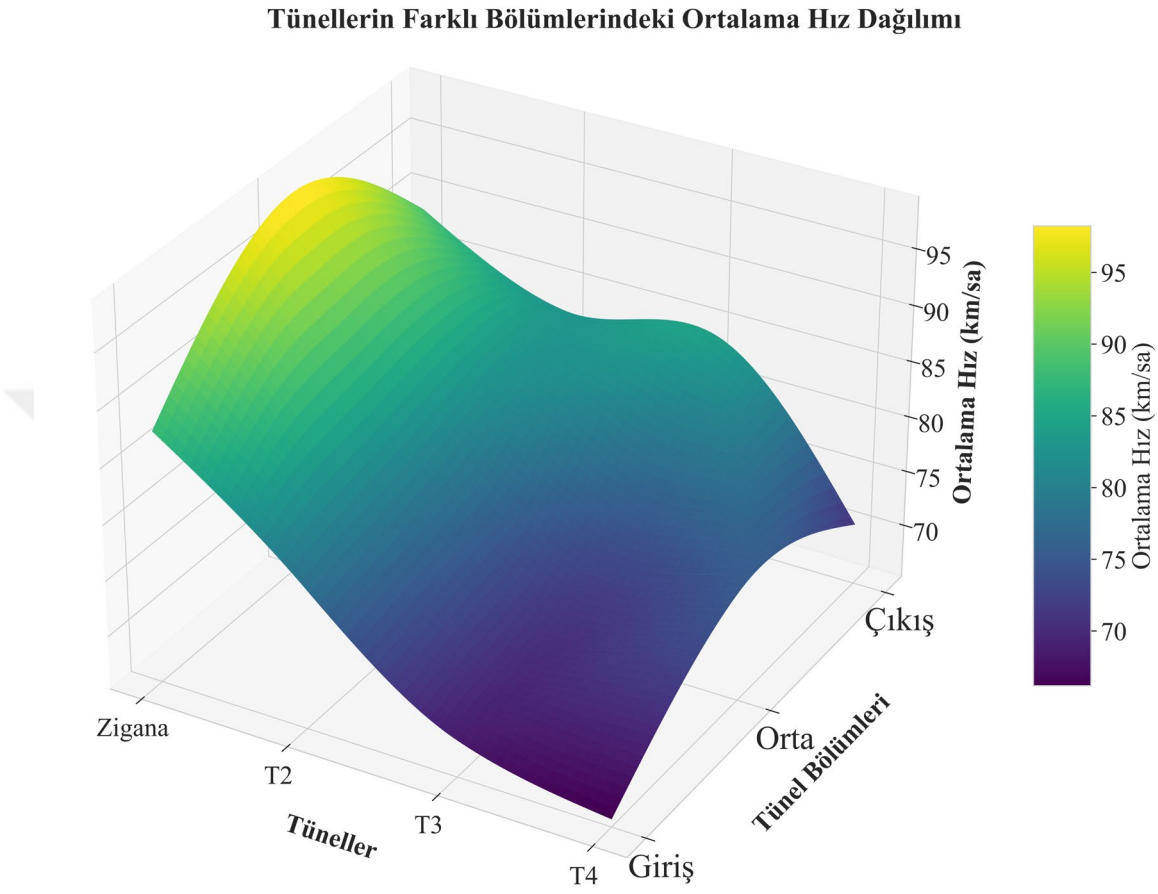
Veriler, tünel uzunluğu özelinde incelendiğinde, uzun tünel kategorisinde değerlendirilen Zigana Tüneli'nde (14476 metre) sürücülerin ortalama 98.90 km/sa hız ile sürüş yaptıkları tespit edilmiştir (Şekil 61). Diğer tünellerde gözlemlenen ortalama hızlar ise sırasıyla T4 Tüneli'nde (2255 metre) 75.16 km/sa, T3 Tüneli'nde (754 metre) 72.53 km/sa ve T2 Tüneli'nde (929 metre) 81.17 km/sa olarak kaydedilmiştir.



Şekil 61. Farklı uzunluktaki tünellerin ortalama hız dağılımları

Ayrıca, Şekil 62'de görüldüğü üzere Zigana Tüneli'nde sürücüler tünel giriş kesiminde daha düşük hızlarda seyrederken tünelin orta bölgesine doğru hızlarını kademeli olarak artırmakta ve çıkış bölümünde en yüksek hız değerlerine ulaşmaktadırlar. T2 Tüneli'nde de benzer bir eğilim gözlemlenmekte ancak hız artışı Zigana Tüneli'ne kıyasla daha kontrollü bir seviyede seyretmektedir. T3 ve T4 tünellerine ilişkin analizler hız değişiminin daha sabit bir karakteristik sergilediğini göstermektedir.

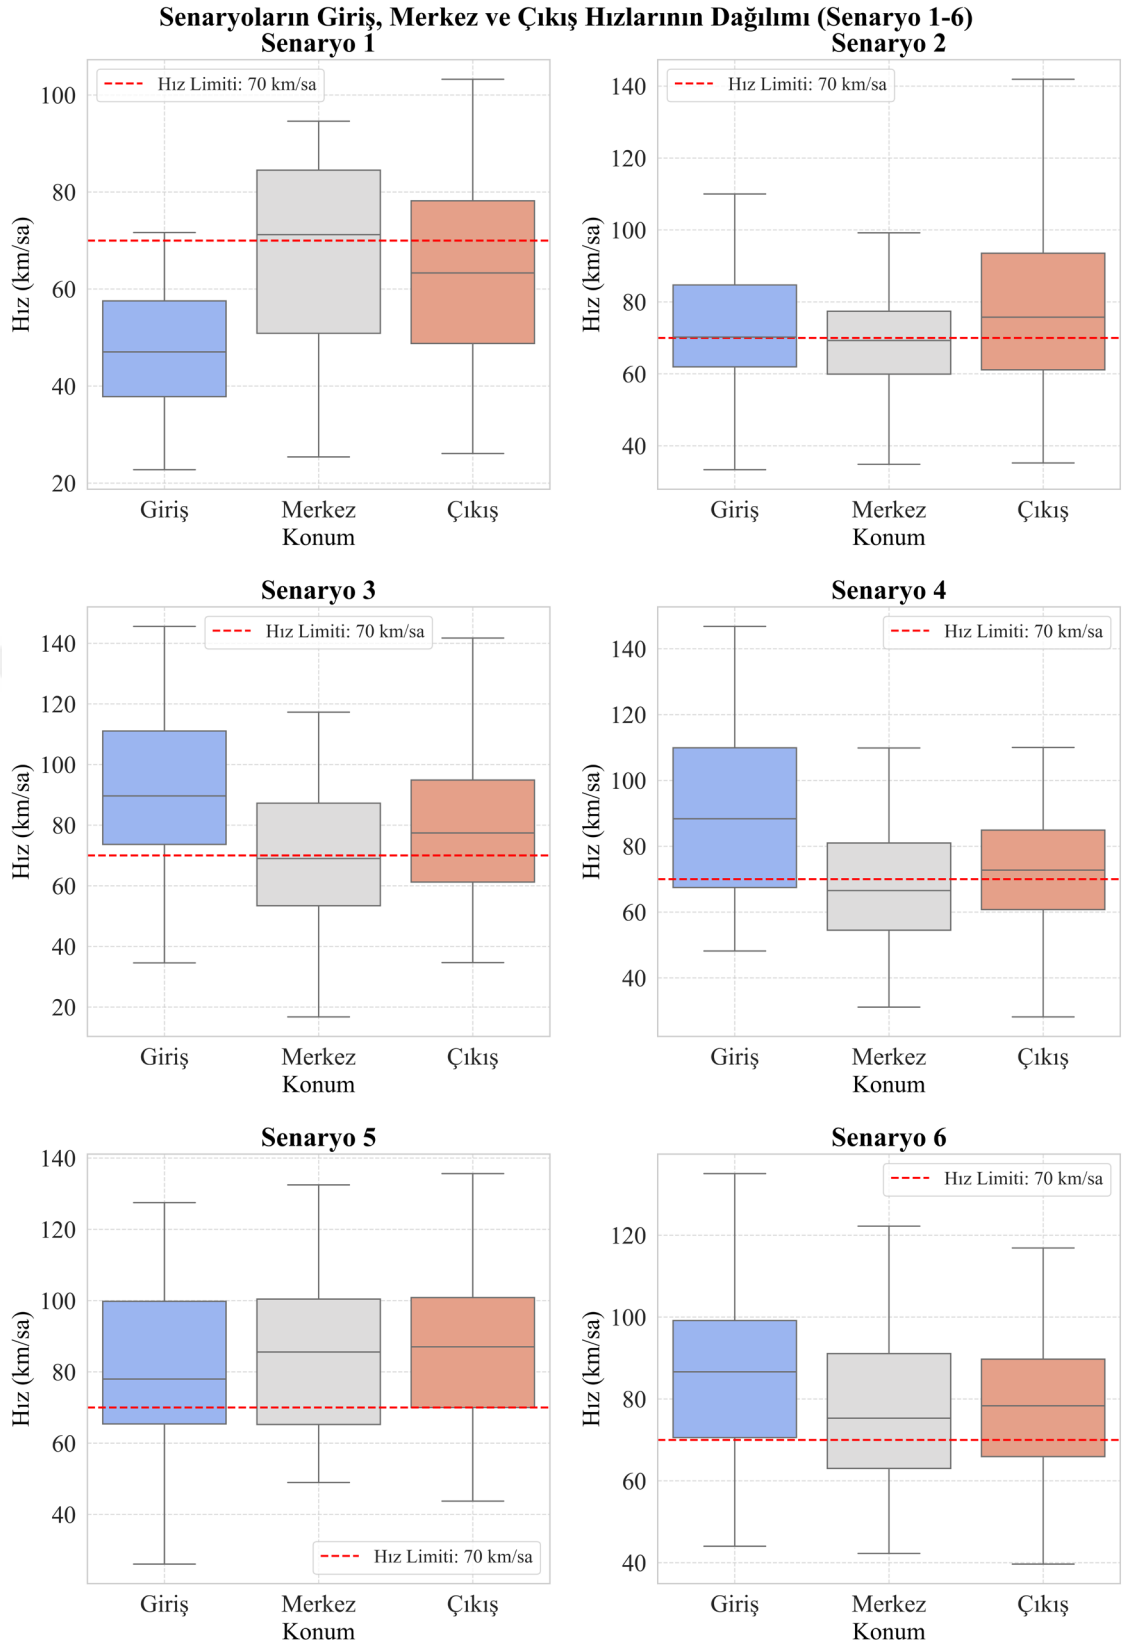
Bu tünellerde giriş, orta ve çıkış kesimleri arasında belirgin hız farklılıklarının gözlemlenmediği tespit edilmiştir. Bu durum tünellerdeki hız profilinin homojen bir dağılım gösterdiğini ve sürücü davranışlarında bölgesel farklılıkların sınırlı olduğunu işaret etmektedir.



Şekil 62. Tünellerin farklı kesimlerindeki ortalama hız dağılımı

Şekildeki renk gradyanı, hız değişiminin tünel boyunca gösterdiği değişimini vurgulamakta ve özellikle uzun tünellerde sürücülerin giriş bölümünden orta bölümüne doğru artan bir hız eğilimi gösterdiklerini ortaya koymaktadır. Bu bulgu tünel uzunluğu ve geometrisinin sürücü davranışları üzerindeki etkisinin sayısal bir göstergesi olarak değerlendirilmiştir.

Senaryolar için belirlenen ölçüm kesimlerinin giriş (merkeze kadar olan ortalama hız), merkez (tehlikeli veya problemli olayın gerçekleştiği an) ve çıkış (merkez noktasından ölçüm kesimi sonu) hızları incelendiğinde bazı senaryolarda belirgin hız değişimleri gözlemlenmiştir. Şekil 63 ve Şekil 64'te giriş, merkez ve çıkış hızlarının medyan değerleri karşılaştırılmıştır. Bu karşılaştırma senaryoların sürücüler üzerindeki etkisini anlamaya olanak sağlamaktadır.

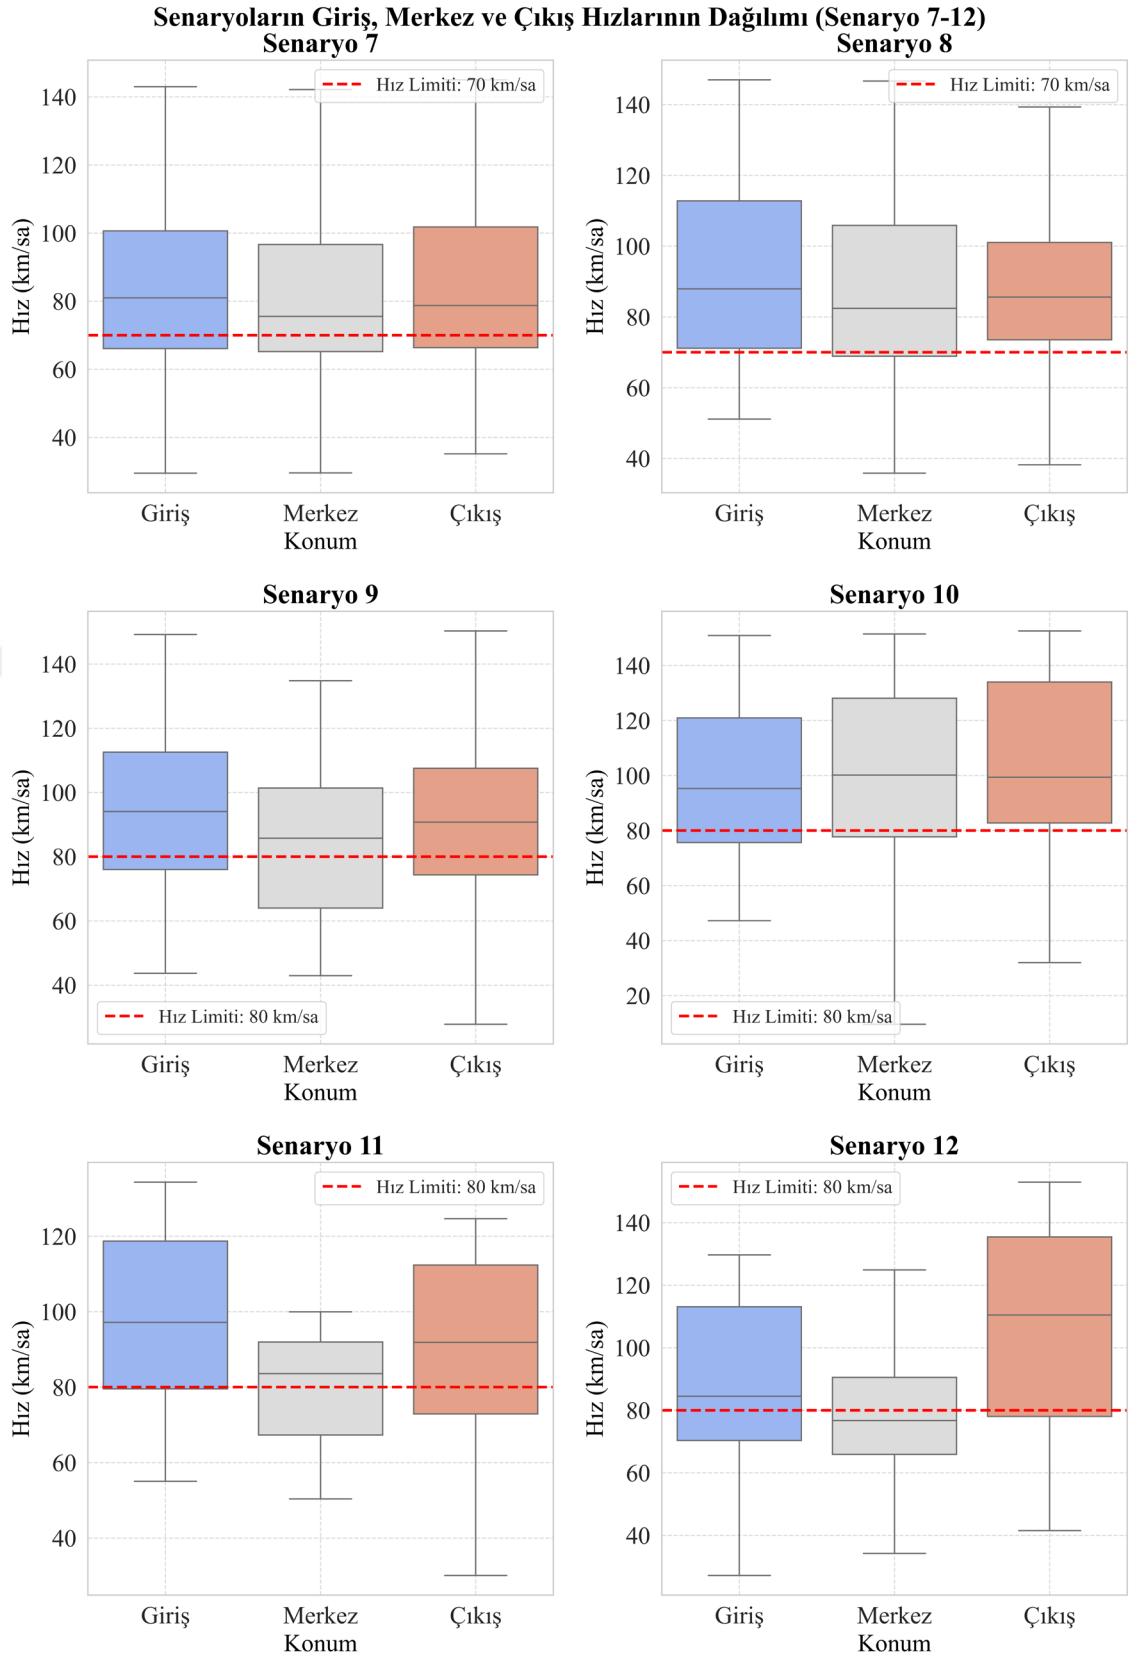


Şekil 63. Senaryoların (1-6) giriş-merkez-çıkış hızlarının dağılımı

Tünel girişini temsil eden Senaryo 1, 4, 6 ve 8'de, giriş hızlarının büyük çoğunluğunun hız limitinin altında olduğu tespit edilmiştir. Senaryo 1'de sürücüler tünel öncesi bölgede ortalama 45-50 km/sa hızla ilerlerken kritik nokta olan merkez bölgesinde

hızlarını artırarak 65 km/sa civarına çıkarmaktadır. Bu artış eğilimi merkez sonrası çıkış bölgesinde de devam etmektedir. Bu senaryoda hızlar genel olarak limit altında kalmasına rağmen sürücülerin merkez bölgesinden itibaren hız artırma eğiliminde bulunmuşlardır. Senaryo 4'te sürücüler giriş bölgesinde oldukça yüksek hızları (85-90 km/sa) tercih etmiş ancak merkez noktasında hızlarını 65 km/sa civarına düşürmüşlerdir. Çıkış bölgesinde ise tekrar hafif bir artış gözlemlenmektedir. Bu senaryo sürücülerin tehlikeli olabilecek bölgeyi (tünel girişi) fark ederek hızlarını düşürdüklerini göstermektedir. Senaryo 6'da giriş bölgesinde 85 km/sa civarında ölçülen hızlar, merkez noktasında 75 km/sa civarına düşmekte ve çıkış bölgesinde bu seviyeyi korumaktadır. Bu senaryoda hız düşüşü gözlemlense de hızlar limit üzerinde seyretmeye devam etmiştir. Senaryo 8'de ise giriş bölgesinde 85-90 km/sa olan hızlar, merkez noktasında ve çıkış bölgesinde kademeli olarak düşmektedir. Ancak bu senaryoda hızların dağılım aralığının geniş olması sürücüler arasında büyük hız farklılıkları olduğunu göstermektedir.

Bu dört senaryonun ortak sonucu; Senaryo 1 hariç diğerlerinde giriş bölgesinde hız limitinin üzerinde seyredilmesidir. Merkez noktasında genellikle bir hız düşüşü gözlemlense de çoğu durumda hızlar limit üzerinde kalmaya devam etmektedir. Özellikle giriş bölgesindeki yüksek hızlar ve merkez noktasındaki ani hız değişimleri, tünel güvenliği açısından risk oluşturabilecek faktörler olarak değerlendirilmektedir. Bu veriler, tünel yaklaşım bölgelerinde daha etkin hız kontrolü ve sürücü bilgilendirmesi ihtiyacını ortaya koymaktadır.



Şekil 64. Senaryoların (7-12) giriş-merkez-çıkış hızlarının dağılımı

Dijital uyarıcıların bulunduğu senaryo 11 ve 12 incelendiğinde; Senaryo 11'de (kırmızı tavan aydınlatması ve sağda duran araç senaryosu) sürücülerin giriş bölgesinde ortalama 95-100 km/sa gibi oldukça yüksek hızlarla seyrettikleri görülmektedir. Ancak

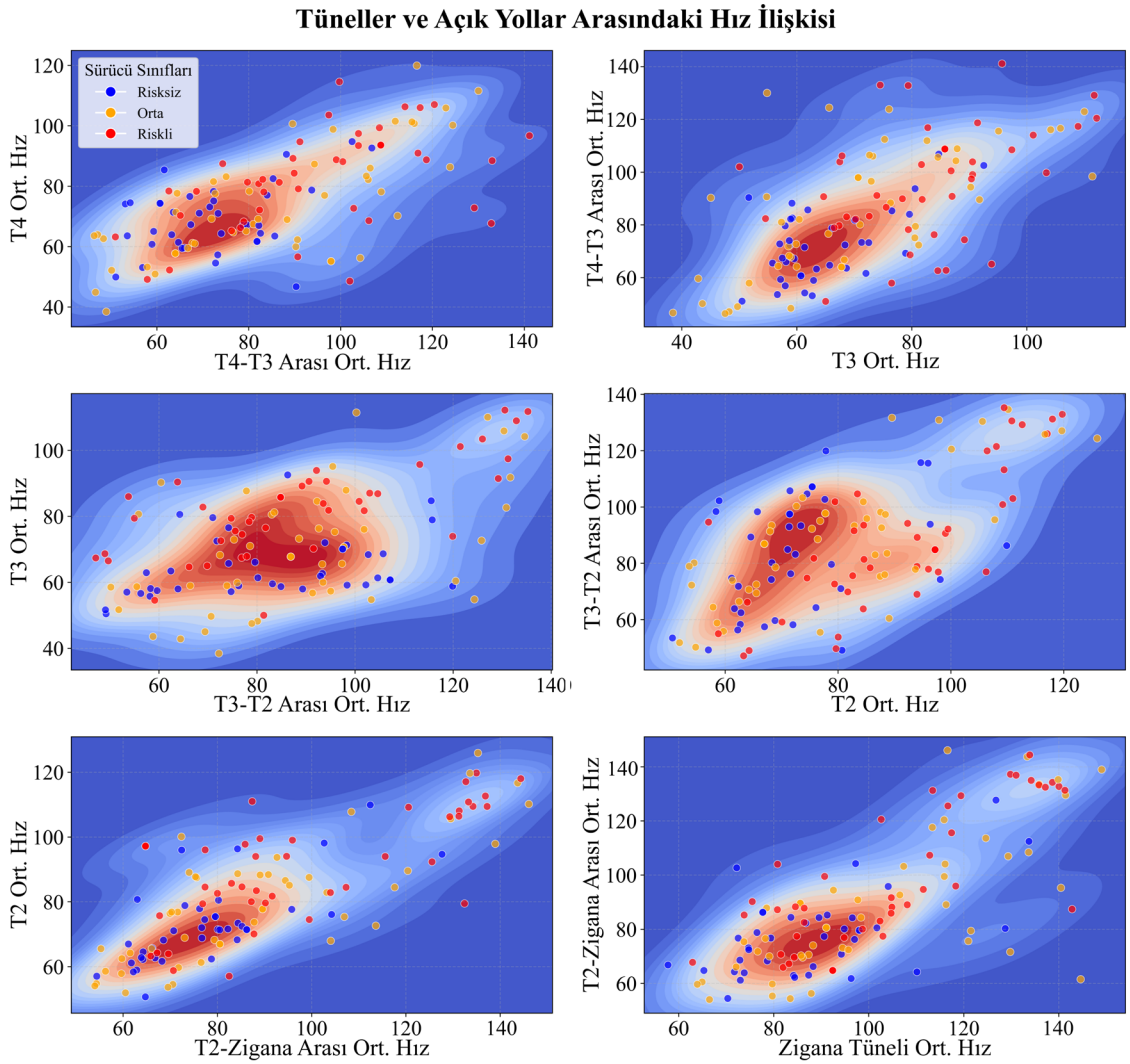
dijital uyarıcıların etkisiyle merkez bölgesinde hızlarını belirgin şekilde düşürerek 70-75 km/sa seviyelerine indirmektedirler. Çıkış bölgesinde ise hızlar tekrar artış göstererek 90-95 km/sa seviyelerine ulaşmaktadır. Bu durum, sürücülerin dijital uyarıları dikkate aldıklarını ancak tehlike bölgesini geçtikten sonra tekrar yüksek hızları tercih ettiklerini göstermektedir. Senaryo 12'de (yan duvarlarda led uyarıcı ve sonrasında şerit kapatma senaryosu) ise giriş bölgesinde 80-85 km/sa civarında seyreden hızlar, dijital uyarıcıların etkisiyle merkez bölgesinde 65-70 km/sa seviyelerine düşmektedir. Ancak çıkış bölgesinde hızlar önemli ölçüde artarak 100-115 km/sa gibi yüksek seviyelere ulaşmaktadır. Bu senaryoda sürücülerin merkez bölgesinde hız kontrolü sağladıkları ancak çıkış bölgesinde hız yapma eğilimine girdikleri görülmektedir.

Tünel çıkışı senaryolarında (3, 5 ve 7) sürücü davranışları ve hız değişimleri benzer özellikler göstermektedir. Bu senaryolarda giriş bölgesinde (tünel içi) yüksek hızlar görülmekte (90-100 km/sa), merkez bölgede hızlarda düşüş yaşanmakta (65-85 km/sa) ve çıkış bölgesinde ise hızlar tekrar artmaktadır (80-95 km/sa). Senaryo 3'te giriş hızları en yüksek seviyededir ve merkezdeki hız düşüşü en belirgindir. Senaryo 5'te hızlar tüm bölgelerde birbirine yakın seyretmekte ve 70 km/sa limitinin üzerinde kalmaktadır. Senaryo 7'de ise giriş ve çıkış hızları benzer seviyelerde olup, merkez bölgede kısmi bir düşüş gözlenmektedir Tünel çıkışını temsil eden Senaryo 3, 5 ve 7'de, sürücülerin hızlarını merkez bölgeye kıyasla çıkışta artırdıkları tespit edilmiştir. Bu durum, sürücülerin problemli bölge geçişinin ardından hızlarını artırma eğiliminde olduklarını göstermektedir. Friedman testi sonuçları da bu hız artışlarının istatistiksel olarak anlamlı olduğunu doğrulamaktadır. Sürücülerin senaryo 2, 6 ve 9'da ağır taşıtla karşılaştıklarında hızlarını belirgin bir şekilde azalttıkları görülmektedir. Merkez hızlarının bu senaryolarda limitin altına düşmesi, ağır taşıtın sürücü üzerindeki etkisinin tünelin farklı bölgelerinde de sürdüğünü göstermektedir. Özellikle Senaryo 6, tünel girişi ve tırla karşılaşmanın birleşik etkisiyle en düşük hızların gözlemlendiği senaryolardan biridir. Trafik hacmi azaltılmış bir bölgeyi temsil eden 10. senaryoda, sürücülerin hızlarının limitin üzerine çıkma eğiliminde olduğu gözlemlenmiştir. Düşük trafik hacmi koşulları sürücülerin daha fazla hızlanmalarına neden olmuş ve hız limitine uyum azalmıştır. Bu durum, düşük trafik hacminin olduğu durumlarda bazı sürücülerin trafik güvenliği açısından potansiyel bir risk faktörü oluşturabileceğini göstermektedir.

Senaryoların giriş, merkez ve çıkış bölgelerinde incelenen sürücülerin hız davranışları, önemli değişimler göstermektedir. Her senaryoda gözlemlenen farklı hız tercihleri ve değişken sürücü davranışları, her bir sürücünün kendine özgü bir sürüş karakteri olduğunu ortaya koymaktadır. Bazı sürücüler tünel girişinde yüksek hızları

tercih ederken, bazıları daha temkinli davranmakta; kimileri ise ağır taşıt varlığı veya dijital uyarıcılara daha duyarlı davranışlar sergilemektedir. Bu kadar fazla değişkenin ve farklı sürücü davranışının geleneksel yöntemlerle analiz edilmesinin oldukça karmaşık ve zor bir süreç olduğu düşünülmektedir. Özellikle 12 senaryonun tümünde görülen davranış örüntülerinin belirlenmesi ve sürücü profillerinin çıkarılması için makine öğrenmesi algoritmalarının kullanılmasının daha etkili sonuçlar sağlayacağı düşünülmektedir. Bu algoritmalar, her bir sürücünün hız tercihleri, risk algıları, ağır taşıt ve dijital uyarıcılara verdikleri tepkiler gibi faktörleri analiz ederek ayırt edici sürücü karakteristiklerini belirleyebilmektedir.

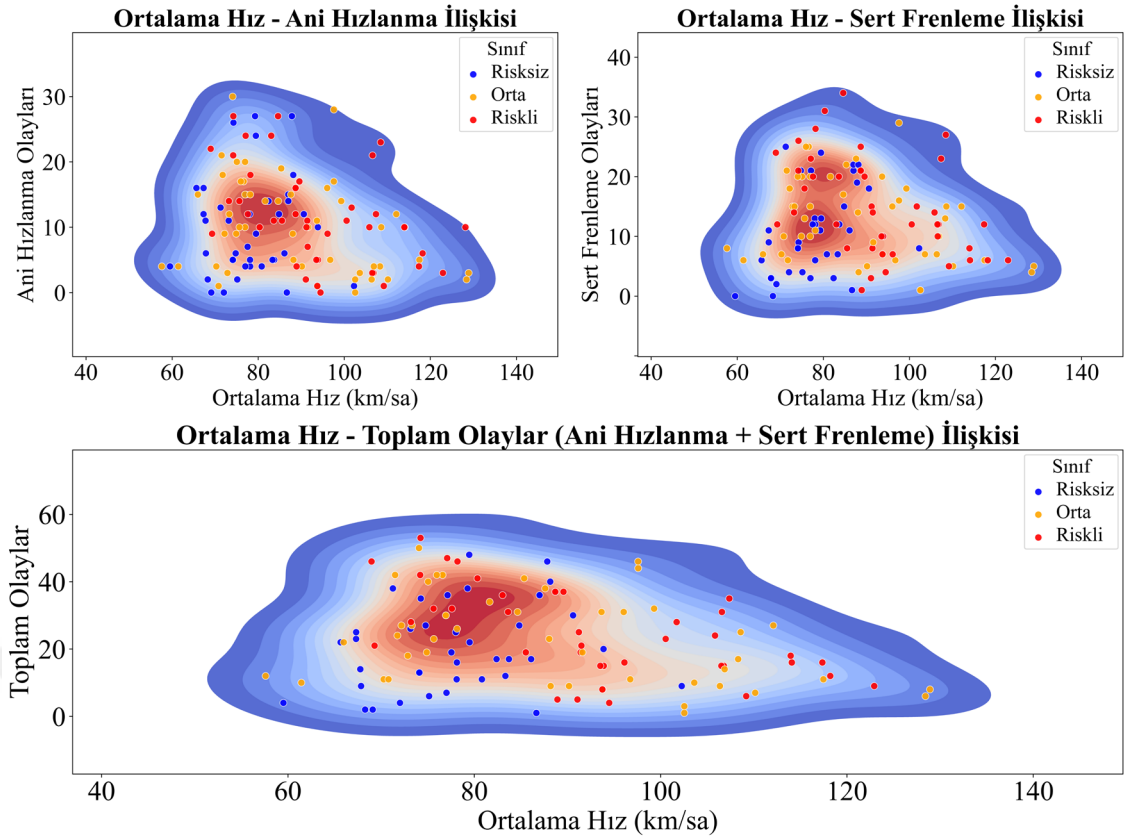
Tüneller ve açık yol kesimleri arasındaki geçişlerde sürücülerin hız eğilimleri incelendiğinde (Şekil 65), genel olarak sürücülerin tünellerde hızlarını daha sabit bir aralıkta tuttuğu ancak açık yollarda ise hızların daha geniş bir dağılım sergilediği gözlemlenmiştir.



Şekil 65. Tüneller ve açık yollardaki hızların ilişkisi

Şekil 65, puanlama sistemine göre ön sınıflandırması yapılmış sürücülerin davranışlarının karmaşık yapısını ortaya koymaktadır. Her bir grafikte görülen hız dağılımları ve ilişkileri, sürücü davranışlarının doğrusal olmayan, çok boyutlu ve karmaşık örüntüler içerdiğini göstermektedir. Örneğin, T4-T3 ve T4 hız ilişkisinde riskli ve risksiz sürücülerin belirgin şekilde örtüştüğü bölgeler bulunmaktadır. Bu durum, geleneksel sınıflandırma yöntemleriyle ayrımın zorluğunu gösterirken, makine öğrenmesi algoritmalarının bu karmaşık örüntüleri tanımada daha başarılı olabileceğine işaret etmektedir. Benzer şekilde, T3-T2 ve T2 hız ilişkisinde görülen çift modlu dağılım, sürücü davranışlarının basit eşik değerleriyle sınıflandırılamayacak kadar karmaşık olduğunu göstermektedir. Yeni Zigana Tüneli bölgesindeki hız ilişkileri ise diğer bölgelere göre daha geniş bir aralığa yayılmış ve daha karmaşık örüntüler sergilemektedir. Bu durum, sürücü davranışlarının bölgesel faktörlerden de etkilendiğini ve sınıflandırma modellerinin bu değişkenleri de dikkate alması gerektiğini vurgulamaktadır. Her grafikteki ısı haritası yoğunlukları ve nokta dağılımları, risk sınıflandırmasının çok boyutlu ve karmaşık bir yapıya sahip olduğunu göstermekte, bu da makine öğrenmesi yaklaşımlarının gerekliliğini desteklemektedir. Bu karmaşık yapı ve ilişkiler ağı, makine öğrenmesi ve gelişmiş sınıflandırma algoritmalarının kullanımını gerekli kılmakta ve uzman görüşüyle yapılan ön sınıflandırmanın makine öğrenmesi modelleri için önemli bir temel oluşturduğunu göstermektedir.

Sürücülerin ortalama hızları ile ani hızlanma ve sert frenleme davranışları arasındaki ilişkinin incelenmesi farklı risk gruplarındaki sürücülerin davranış profillerini ortaya koymaktadır (Şekil 66).

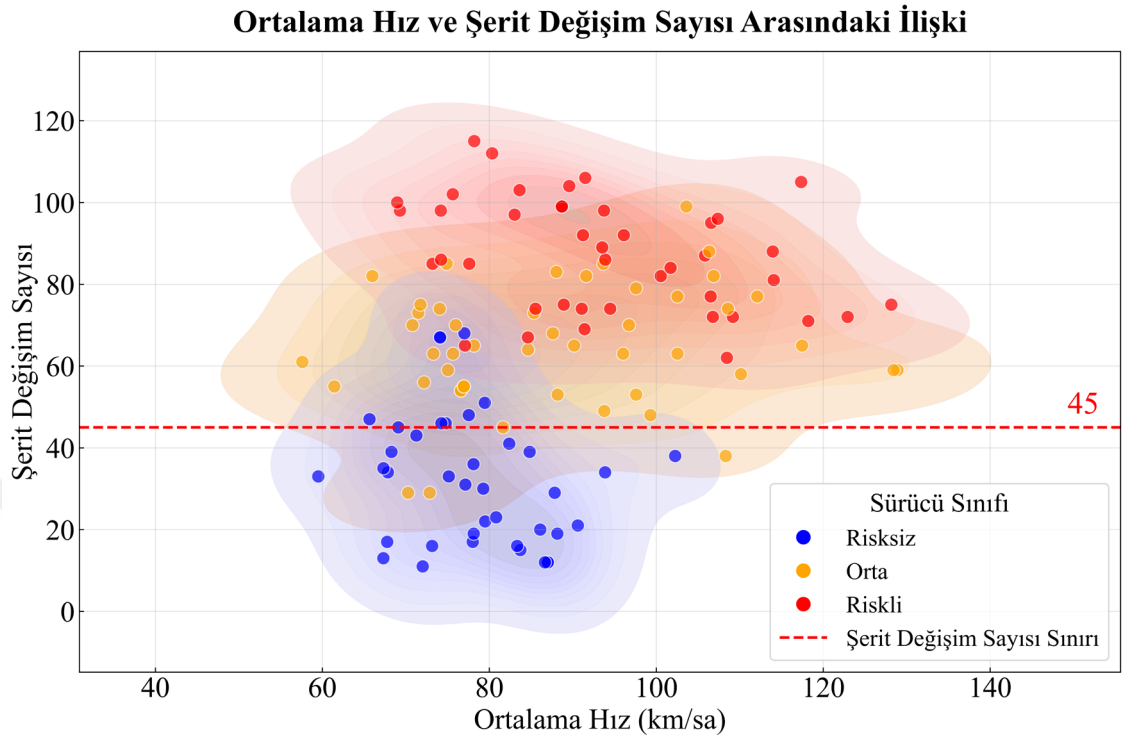


Şekil 66. Ortalama hız, ani hızlanma ve sert frenleme arasındaki ilişki

Ortalama hız ile ani hızlanma ve sert frenleme olayları arasındaki ilişkinin çeşitlilik göstermesi sürücü davranışlarının sınıflandırılmasında önemli bir öznitelik olarak değerlendirilmektedir. Şekil 66'da görüldüğü üzere her sürücü profili için ortalama hız, ani hızlanma ve sert frenleme değerleri geniş bir aralıkta dağılmakta ve belirgin bir ilişki göstermemektedir. Bu çeşitlilik, sürücü davranışlarının tek bir parametreye bağlı olmadığını, bu karmaşık örüntülerin sınıflandırma algoritmalarıyla çözülmesi gerektiğini ortaya koymaktadır. Örneğin, yüksek hızda seyreden bir sürücü düşük ani hızlanma değerlerine sahip olabilirken, düşük hızda seyreden başka bir sürücü yüksek ani hızlanma değerleri gösterebilmektedir. Bu durum, sürücülerin risk profillerinin belirlenmesinde hem hız hem de ivmelenme karakteristiklerinin bağımsız değişkenler olarak değerlendirilmesinin gerekliliğine işaret etmektedir. Sınıflandırma modelinin bu çeşitliliği kapsayacak şekilde tasarlanması, risk değerlendirmesinin doğruluk ve güvenilirlik düzeyini artıracağı düşünülmektedir.

Ortalama hız ve şerit değişim sayısı arasındaki ilişki incelendiğinde (Şekil 67) hızın artmasıyla birlikte şerit değiştirme eğiliminin de arttığı gözlemlenmektedir. Düşük hızlarda (60-80 km/sa) şerit değişim sayısı genellikle 20-50 aralığında seyrederken, orta

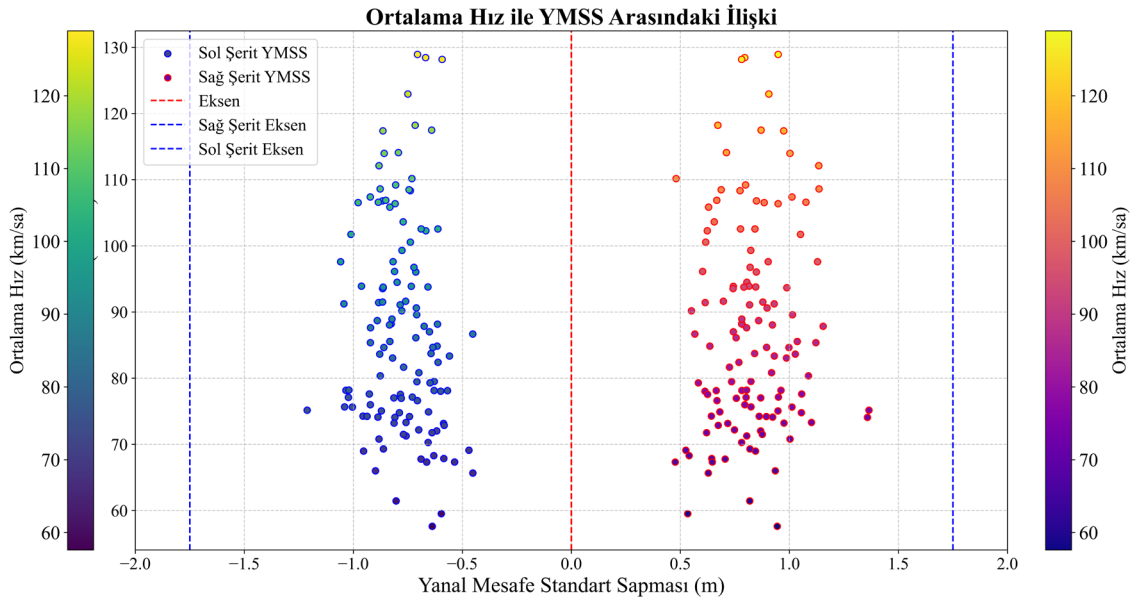
hızlarda (80-100 km/sa) bu sayı 40-80 aralığına yükselmektedir. Yüksek hızlarda (100-140 km/sa) ise şerit değişim sayısının 60-120 aralığına ulaştığı görülmektedir.



Şekil 67. Ortalama hız ve şerit değişim sayısı arasındaki ilişki

Şekilde belirtilen şerit değişim sayısı sınırı (45) model gereği (aynı şeritte, yavaş giden aracı sollama) zorunlu olmasa da tercih edilebilir şerit değişim sayısını ifade etmektedir.

Şerit değişim sayısının ortalama hıza bağlı dağılımı ve yoğunluk haritasındaki belirgin ayrışma, bu parametrenin sınıflandırma modeli için güçlü bir ayrıt edici öznitelik olacağını göstermektedir. Özellikle belirlenen eşik değerin üzerinde ve altında kalan bölgelerdeki net ayrışma, sınıflandırma algoritmasının karar verme sürecinde bu parametrenin etkin rol oynayacağına işaret etmektedir. Trafik güvenliğini doğrudan etkileyen bir diğer önemli parametre, sürücülerin bulunduğu şeritte yanal sapmalar yapmadan araç kullanmalarıdır; bu durum, araçların şerit ekseni boyunca kararlı bir şekilde ilerlemesiyle ilişkilidir. Bu bağlamda, sürücülerin hem sağ şeritte hem de sol şeritte ilerlerken eksene olan mesafeleri (araç merkezi baz alınarak) ayrı ayrı ölçülerek kaydedilmiştir. Her bir sürücünün şerit eksenine olan yanal mesafelerinin standart sapmaları (YMSS) hesaplanarak bu standart sapmanın ortalama hız ile ilişkisi incelenmiştir (Şekil 68).

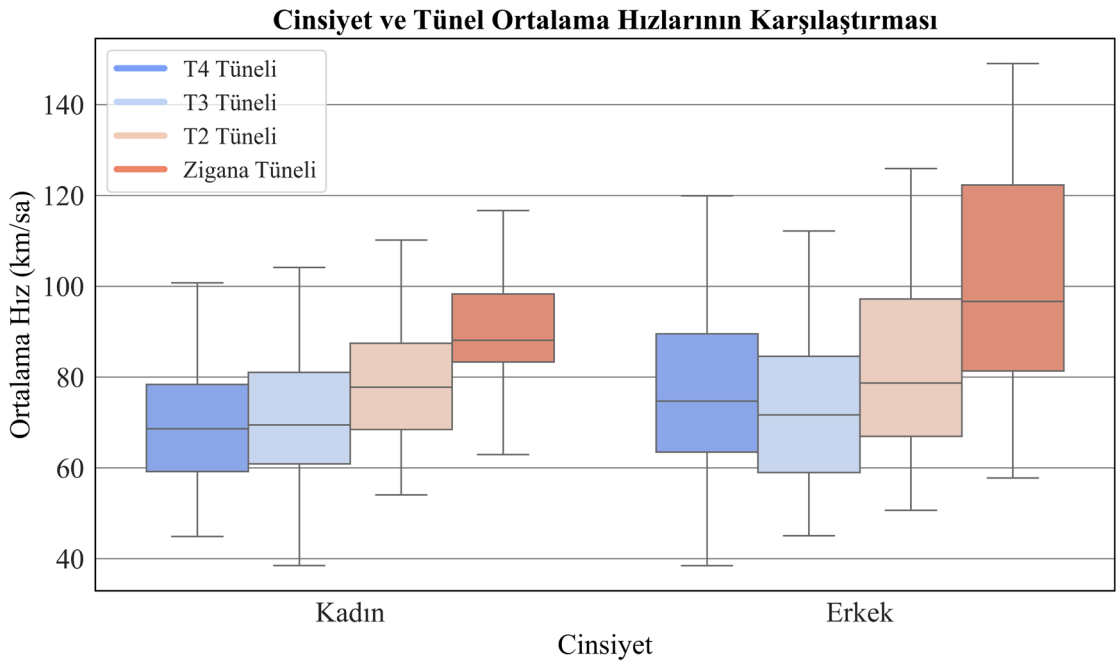


Şekil 68. Ortalama hız ile YMSS arasındaki ilişki

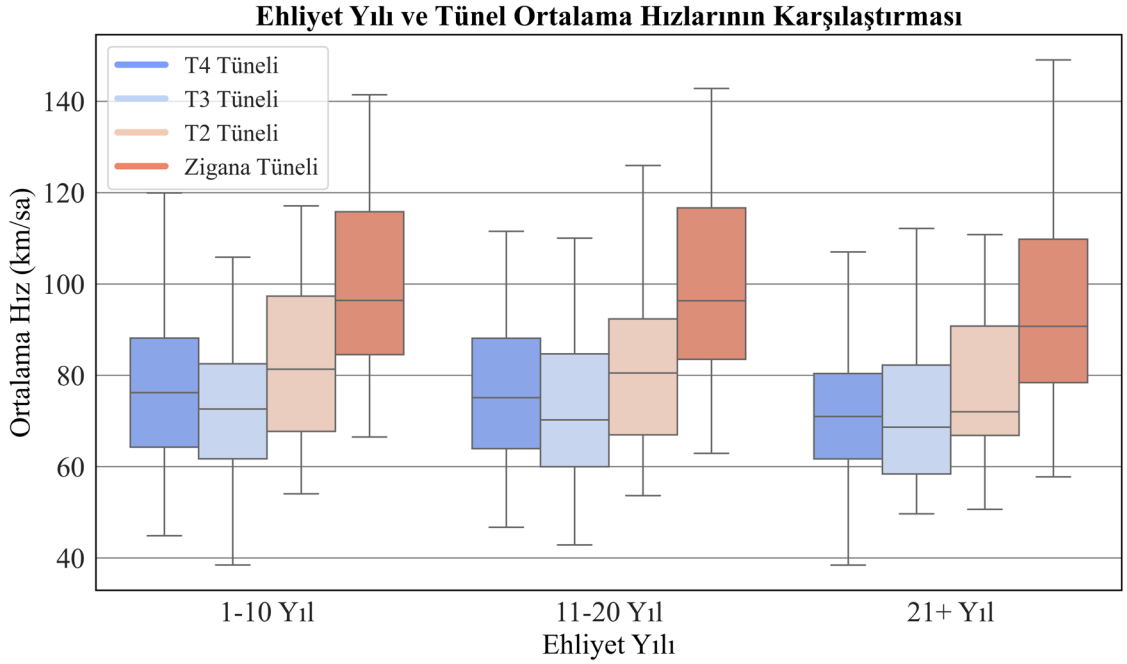
Şekil 68 incelendiğinde sağ ve sol şeritte 100 km/sa hızın altındaki sürüşlerde YMSS değerlerinin daha geniş bir dağılım gösterdiği, bu hızın üzerine çıkıldığında ise daha dengeli bir sürüş düzeninin ortaya çıktığı anlaşılmaktadır. Özellikle sol şeritte yüksek hızlarda ilerleyen araçların daha güvenli (sadece YMSS değerlendirildiğinde) bir sürüş disiplini ortaya koyduğu görülmektedir. Bununla birlikte sağ şeritte yüksek hızda hareket eden araçların YMSS değerlerinin sol şeritte ilerleyen araçlara kıyasla daha değişken olduğu gözlemlenmiştir. Sol şeritte hız artışına bağlı olarak sürüş tutarlılığının arttığı değerlendirildiğinde bu durumun beklenen bir eğilim olduğu ancak arzu edilen bir sürüş tarzı olmadığı (yüksek hızdan dolayı) bilinmektedir. Bu bağlamda yalnızca ortalama hız ile YMSS arasındaki ilişkiye dayanarak genel bir sonuca ulaşmanın analitik açıdan zor olduğu aşikârdır. Ayrıca sürücülerin şerit eksenine yakın konumda sürüş yapma eğiliminde oldukları belirlenmiş ve bunun da yan şeritteki araçlara daha yakın bir şekilde ilerlemelerine neden olduğu anlaşılmaktadır. Bu eğilimin özellikle ağır taşıtlarla karşılaşıldığında ciddi güvenlik sorunlarına yol açabileceği düşünülmektedir. Sonuç olarak sol şeritte yüksek hızlarda ilerleyen sürücülerin daha tutarlı bir sürüş davranışı ortaya koyduğu ancak sağ ve sol şeritler içinde yanal mesafe ve hız ilişkisinin farklılık gösterdiği ve bu ilişkinin doğrudan bir bağıntı ile açıklanamayacağı düşünülmektedir. Bu karmaşık ilişki yapısının ileri düzey analizlerle (yapay zekâ teknikleri gibi) incelenmesi, daha güvenilir ve genellenebilir sonuçlara ulaşılmasını sağlayacaktır.

Katılımcıların cinsiyet, ehliyet yılı, kaza geçmişi ve simülatörde modellenen güzergâhta daha önce araç kullanma tecrübesine sahip olup olmadıkları gibi değişkenlerin

ortalama hız ile olan ilişkisi incelenmiştir. Demografik değişkenler ile ortalama hız arasındaki ilişkiler Şekil 69 ve Şekil 70'te verilmektedir.



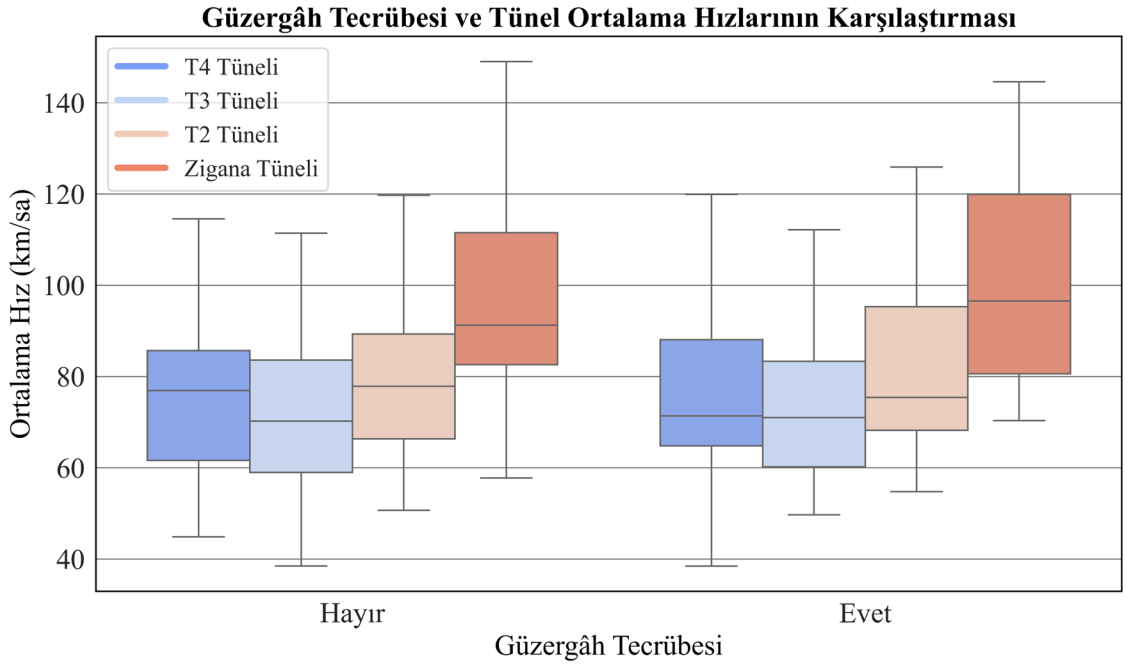
Şekil 69. Sürücülerin cinsiyet ile tünel ortalama hızları arasındaki ilişki



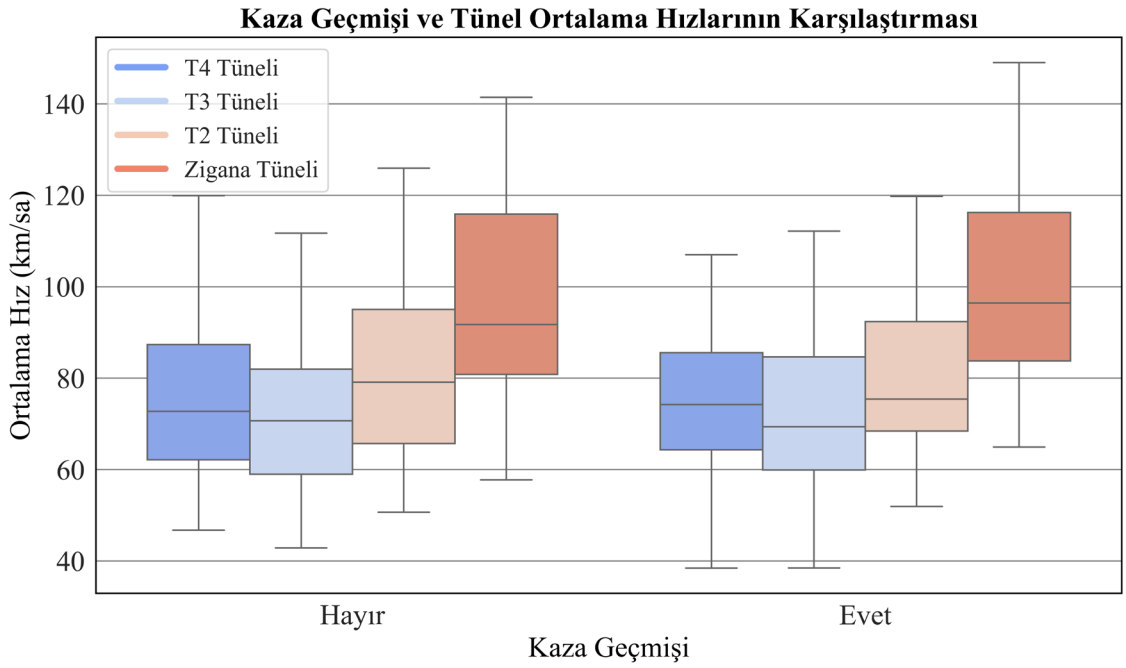
Şekil 70. Sürücülerin ehliyet yılı ile tünel ortalama hızları arasındaki ilişki

Şekil 69 ve 70'e göre sürücülerin demografik özellikleri ve sürüş deneyimlerinin tünel içi hız davranışlarını önemli ölçüde etkilediğini göstermektedir. Kadın ve erkek sürücüler arasında belirgin farklar olduğu ve ayrıca ehliyet yılı gibi deneyim düzeyinin de hız davranışları üzerinde etkisinin olduğu anlaşılmaktadır. Kadın sürücüler, tünel

geometrisinden ve diğer faktörlerden bağımsız olarak genellikle daha düşük hızları tercih ederek daha temkinli bir sürüş sergilemişlerdir. Ehliyet deneyimi arttıkça tünel geçişlerindeki ortalama hızların da arttığı görülmektedir. 1-10 yıl deneyime sahip sürücülerde tüm tünellerde daha düşük ve dengeli hızlar gözlemlenirken, 21+ yıl deneyime sahip sürücülerde özellikle T2 ve Zigana Tüneli'nde belirgin bir hız artışı ve daha geniş bir hız dağılımı görülmektedir. T4 ve T3 tünellerinde ehliyet deneyimine bağlı hız farklılıkları nispeten az iken T2 ve Zigana Tüneli'nde deneyimli sürücülerin daha yüksek hızları tercih ettiği açıkça görülmektedir. Her iki şekilde de T4 ve T3 tünellerinde hız davranışlarının daha kontrollü ve düşük seviyelerde olması, buna karşın T2 ve Zigana Tüneli'nde hem hızların hem de hız değişkenliğinin artması, tünel karakteristiklerinin sürücü davranışları üzerindeki etkisini göstermektedir. Şekil 71 ve 72'de, kaza geçmişi ve güzergâh tecrübesinin sürücülerin tünel içindeki hız davranışları üzerinde etkili olabildiğini göstermektedir.



Şekil 71. Sürücülerin güzergâh tecrübesi ile ortalama hızları arasındaki ilişki



Şekil 72. Sürücülerin kaza geçmişi ile ortalama hızları arasındaki ilişki

T4 ve T3 tünellerinde kaza geçmişi olan ve olmayan sürücüler arasında belirgin bir hız farkı gözlemlenmezken (ortalama 60-80 km/sa), T2 ve özellikle Zigana Tüneli'nde kaza geçmişi olan sürücülerin daha yüksek hızlarda seyrettiği görülmektedir. Zigana Tüneli'nde kaza geçmişi olan sürücülerin ortalama hızları 90-115 km/sa aralığında seyrederken, kaza geçmişi olmayan sürücülerde bu aralık 70-95 km/sa civarındadır. Güzergâh tecrübesi olan sürücülerin tüm tünellerde daha yüksek hızlarda seyretme eğiliminde olduğu görülmektedir. Bu fark özellikle T2 ve Zigana Tüneli'nde daha belirgindir. Tecrübeli sürücülerin Zigana Tüneli'ndeki ortalama hızları 80-120 km/sa aralığında değişirken tecrübesiz sürücülerde bu aralık 70-90 km/sa civarında olmuştur.

4.5. Denetimli Öğrenme Yöntemiyle Sınıflandırma

4.5.1. Öznitelik Seçimi

Simülatörden elde edilen 73 metriğin (hız, şerit disiplini, yanal sapmalar, hızlanma-değişim oranları ve şerit değişim sayıları gibi sürüş parametrelerine ilişkin çeşitli ölçümler), sınıflandırma problemlerinde doğrudan kullanımı, veri fazlalığı ve anlamlılık problemleri oluşturabileceğinden, öznitelik mühendisliği aşamaları uygulanmıştır. Birinci aşamada; ilk olarak sınıflandırma problemi için anlamlı olmayan 'toplam sürüş süresi' ve 'toplam yolculuk mesafesi' gibi öznitelikler sabit uzunlukta güzergâh olmasından dolayı veri setinden çıkarılmıştır. Ardından, 'ani hızlanma' ve 'sert frenleme' metrikleri birleştirilerek (ani hızlanma sayısı ile sert frenleme sayısın toplanması

şeklinde) sürücülerin hızlanma ve frenleme davranışlarını bütüncül bir şekilde temsil eden 'ani ivmelenme sayısı' özniteliği türetilmiştir. Ek olarak, her bir senaryo için 'senaryo merkezine kadar olan ortalama hızın merkez hızına oranı' hesaplanmış (bu oranın 1.00'dan büyük olması durumunda hızın azalması, küçük olması durumunda ise hızın artması, ancak her bir sürücünün artış ve azalış miktarları bilgisinin kaybedilmemesi için) ve bu oranların 12 senaryodaki ortalamaları alınmıştır. Böylece, sürücülerin genel hız değişim davranışlarını ifade eden 'senaryolar hız değişim oranı' özniteliği oluşturulmuştur. Bir diğer işlem olarak, sürücülerin 10 farklı senaryoda şerit değişimi yapıp yapmadığını belirleyen ikili değişkenler (0-1) üzerinden bir ortalama hesaplanmıştır. Örneğin, bir sürücü 10 senaryonun 5'inde şerit değiştirmişse, bu oran 0.5 olarak belirlenmiştir. Bu hesaplama, sürücülerin şerit değiştirme eğilimlerini yansıtan 'senaryo şerit değişim oranı' özniteliğinin elde edilmesini sağlamıştır.

Sonuç olarak, veri seti optimize edilerek daha az, ancak daha anlamlı öznitelikler kullanılarak model performansı üzerinde olumsuz bir etkiye karşı (aşırı uyum gibi) önlem alınmış ve güvenilir bir analiz sağlanmıştır. Nihai özniteliklere ilişkin tanımlayıcı istatistik bilgileri Tablo 21'de sunulmuştur.

Tablo 21. Özniteliklere ilişkin tanımlayıcı istatistikler

Öznitelik Adı	**N**	**Ort.**	**Standart Sapma**	**Min.**	**Maks.**
Ortalama Hız (km/sa)	130	87.07	15.54	57.61	128.91
Ani İvmelenme Sayısı	130	23.58	13.61	1	61
Ort. İvme (m/s^2)	130	0.12	0.04	0.03	0.21
Geçerli Hız Limitine Uyma Oranı	130	0.44	0.25	0.02	1
Şerit Değişim Sayısı	130	62.37	26.57	11	115
Ortalama Yanal Mesafe (m)	130	1.44	0.18	1.01	1.87
Senaryolar Hız değişim Oranı	130	1.13	0.1	0.94	1.53
Senaryolar Şerit Değişim Oranı	130	0.60	0.25	0.10	1

Ortalama hız değeri 87.07 km/sa olup hız değerleri 57.61 ile 128.91 km/sa arasında değişmektedir. Standart sapma 15.54 olarak hesaplanmıştır ve bu da hız davranışlarının sürücüler arasında farklılık gösterdiğini ifade etmektedir. Ani ivmelenme sayısı için ortalama 23.58 olarak belirlenmiştir ve bu öznitelik 1 ile 61 arasında bir dağılım göstermektedir. Ortalama ivme değeri ise minimum 0.03 ve maksimum 0.21 arasında değişim göstermiştir. Geçerli hız limitine uyma oranı 0.44 olarak elde edilmiş ve sürücülerin hız limitlerine genel olarak düşük bir uyum gösterdiğini ortaya koymuştur. Şerit değişim sayısı ortalama 62.37 olarak elde edilmiş, standart sapma 26.57 ile şerit değiştirme davranışlarında önemli farklılıklar olduğu gözlemlenmiştir. Ortalama yanal

mesafe 1.44 metre olarak hesaplanmıştır ve bu öznitelik 1.01 ile 1.87 (şeridin eksene olan yanal mesafesi 1.75 m) metre arasında bir aralıkta değişmektedir. Senaryolar hız değişim oranı 1.13 ile sürücülerin hız davranışlarının genel olarak birbirine yakın olduğunu, 0.94 ile 1.53 arasında değişen bir dağılım sergilediğini göstermektedir. Senaryolar şerit değişim oranı ise ortalama 0.60 olarak belirlenmiş olup 0.10 ile 1 arasında bir değişim göstermektedir. Bu oran bazı sürücülerin daha sık şerit değişimi yaparken diğerlerinin daha az şerit değişimi yaptığını ortaya koymaktadır. Veri setinde yer alan bu parametrelerin, hem sürücülerin ayırt edilebilmesini sağlayacak kadar açıklayıcı hem de farklı sürüş davranışlarını temsil edecek kadar çeşitli olduğu düşünülmektedir. Özellikle geniş standart sapma değerleri ve minimum ile maksimum sayılar arasındaki farklılıklar, bireysel davranış farklılıklarını vurgulayarak sınıflandırma işlemleri için gerekli olan ayrıştırıcı gücü sağlamaktadır.

Öznitelik mühendisliğinin ikinci aşamasında ise öznitelikler arasında korelasyon ve VIF (Varyans Şişirme Faktörü) analizi yapılmış ve modelin performansını ve güvenilirliğini artırmak amaçlanmıştır. Korelasyon analizi, öznitelikler arasında yüksek korelasyon olup olmadığını hakkında bilgi vermektedir ve bu tür ilişkiler modelin tahmin gücünü olumsuz etkileyebilmektedir. VIF analizi ise çoklu doğrusallık problemini nicel olarak değerlendirmeye imkân sağlamaktadır ve yüksek VIF değerleri, öznitelikler arasında güçlü doğrusal bağlılığın varlığını göstermektedir. Bu analizler, gereksiz veya problemli öznitelikleri tespit ederek veri setini optimize etmekte ve modelin genelleme yeteneğini artırmaktadır. Yüksek korelasyon değerleri ve çoklu doğrusallık problemlerinin varlığı durumunda ise boyut indirgeme yöntemleri (PCA, Kernel PCA, LDA, KDA vb.) tercih edilmektedir. Bu bağlamda özniteliklere ilişkin korelasyon değerleri Tablo 22'de, VIF analizi sonuçları ise Tablo 23'te sunulmuştur.

Tablo 22. Öznitelikler arası korelasyon değerleri

Değişken 1	Değişken 2	r	İlişki Gücü
Ortalama Hız (km/sa)	Senaryo Şerit Değişim Oranı	0.347	Zayıf
	Şerit Değişim Sayısı	0.315	Zayıf
	Senaryolar Hız Değişim Oranı	0.229	Zayıf
	Ort. İvme (m/s²)	0.013	Zayıf
	Ani İvmelenme Sayısı	-0.158	Zayıf
	Ortalama Yanal Mesafe (m)	-0.161	Zayıf
	Geçerli Hız Limitine Uyma Oranı	-0.909	Güçlü
Ani İvmelenme Sayısı	Senaryo Şerit Değişim Oranı	0.104	Zayıf
	Şerit Değişim Sayısı	0.164	Zayıf
	Geçerli Hız Limitine Uyma Oranı	0.217	Zayıf
	Senaryolar Hız Değişim Oranı	0.240	Zayıf
	Ortalama Yanal Mesafe (m)	0.291	Zayıf
	Ort. İvme (m/s²)	0.693	Güçlü
Ort. İvme (m/s²)	Geçerli Hız Limitine Uyma Oranı	-0.047	Zayıf
	Ortalama Yanal Mesafe (m)	0.193	Zayıf
	Senaryolar Hız Değişim Oranı	0.218	Zayıf
	Senaryo Şerit Değişim Oranı	0.272	Zayıf
	Şerit Değişim Sayısı	0.318	Zayıf
Geçerli Hız Limitine Uyma Oranı	Senaryo Şerit Değişim Oranı	-0.356	Zayıf
	Şerit Değişim Sayısı	-0.326	Zayıf
	Senaryolar Hız Değişim Oranı	-0.127	Zayıf
	Ortalama Yanal Mesafe (m)	0.178	Zayıf
Şerit Değişim Sayısı	Ortalama Yanal Mesafe (m)	-0.282	Zayıf
	Senaryolar Hız Değişim Oranı	0.317	Zayıf
	Senaryo Şerit Değişim Oranı	0.843	Güçlü
Ortalama Yanal Mesafe (m)	Senaryo Şerit Değişim Oranı	-0.353	Zayıf
	Senaryolar Hız Değişim Oranı	-0.202	Zayıf
Senaryolar Hız Değişim Oranı	Senaryo Şerit Değişim Oranı	0.205	Zayıf

Ortalama hız ile geçerli hız limitine uyma oranı arasındaki -0.909'luk güçlü negatif korelasyon, bu iki özniteliğin birbirine benzer bilgi taşıdığını göstermektedir. Ancak boyut indirgeme gibi yaklaşımlar sürecinde bu özniteliklerin sınıflandırma modeline nasıl bir katkı sağladığı analiz edilmeden doğrudan eleme yapılmamalıdır. Benzer şekilde, şerit değişim sayısı ile senaryolar şerit değişim oranı arasındaki 0.843'lük pozitif ilişki, bu özniteliklerin birlikte kullanıldığında çoklu doğrusallık yaratabileceğini düşündürmektedir. Zayıf korelasyonlara sahip özniteliklerin bağımsız olarak kullanılabilme potansiyeli olsa da nihai karar, boyut indirgeme yöntemlerinden elde edilecek bulgulara dayalı olarak verilmelidir. Zayıf ilişkilerin fazla olması, bu özniteliklerin doğrudan makine öğrenmesi algoritmalarına girdi olarak verilebileceği

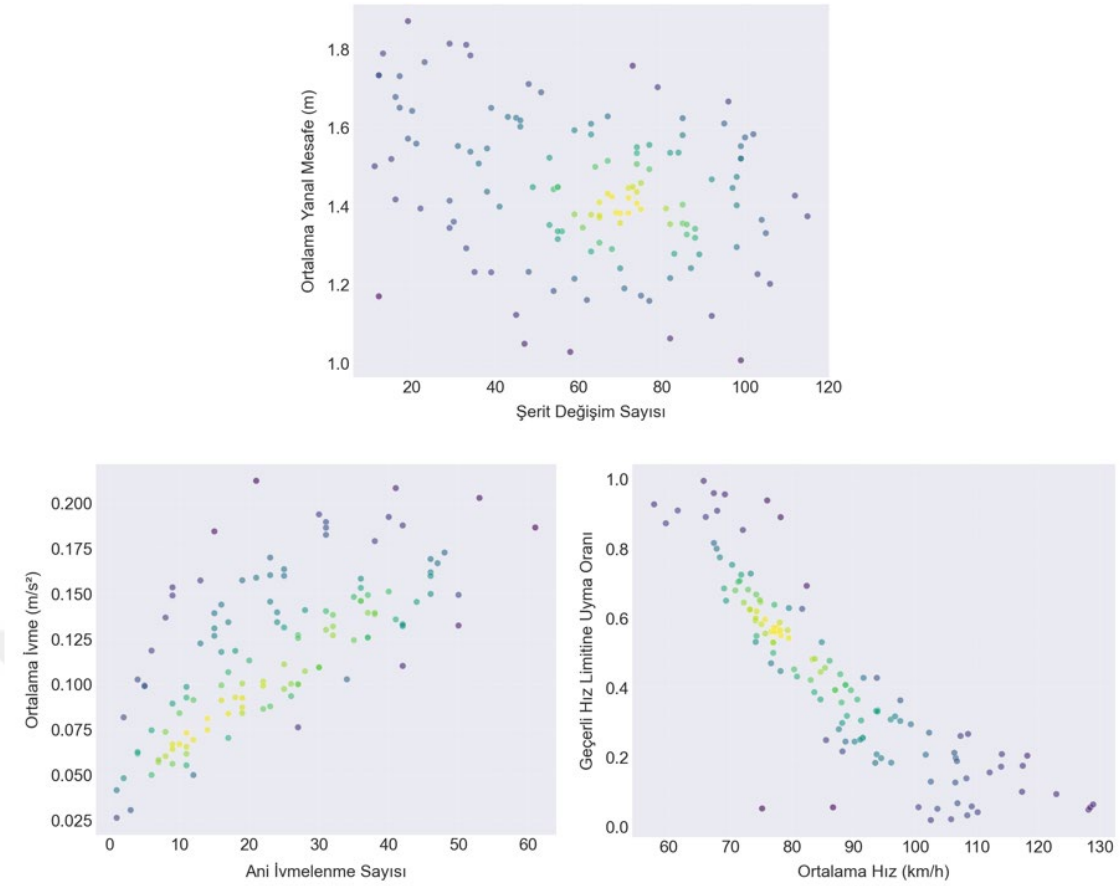
anlamına gelmemektir. Çünkü küçük veri seti (N=130) için öznitelik sayısının fazla olması hem model performansını düşürmekte hem de aşırı uyum gibi problemlerin ortaya çıkmasına neden olmaktadır. Burada amaç, veri kaybını minimize ederek modelin doğruluğunu ve açıklayıcı gücünü artırmaktır.

Tablo 23. VIF analizi sonuçları

Öznitelik Adı	**VIF değeri**	**Yorum**
Ortalama Hız (km/sa)	101.34	Yüksek düzeyde çoklu doğrusallık
Ani ivmelenme sayısı	8.14	Orta düzeyde çoklu doğrusallık
Ort. İvme (m/s²)	21.14	Yüksek düzeyde çoklu doğrusallık
Geçerli Hız Limitine Uyma Oranı	12.18	Yüksek düzeyde çoklu doğrusallık
Şerit Değişim Sayısı	28.95	Yüksek düzeyde çoklu doğrusallık
Ortalama Yanal Mesafe (m)	68.97	Yüksek düzeyde çoklu doğrusallık
Senaryolar Hız Değişim Oranı	130.84	Yüksek düzeyde çoklu doğrusallık
Senaryo Şerit Değişim Oranı	30.38	Yüksek düzeyde çoklu doğrusallık

VIF analizi, öznitelikler arasında çoklu doğrusallık problemi olduğunu göstermektedir (eşik değer genellikle 5 veya 10 olarak kabul edilmektedir). Ortalama hız (101.34) ve senaryolar hız değişim oranı (130.84) gibi öznitelikler, yüksek VIF değerleriyle modelde diğer değişkenlerle güçlü doğrusal bağlılık göstermektedir. Şerit değişim sayısı (28.95) ve senaryo şerit değişim oranı (30.38) da benzer şekilde yüksek VIF değerlerine sahiptir ve birbirlerini büyük ölçüde temsil edebileceklerini göstermektedir. Ortalama yanal mesafe (68.97) ve ortalama ivme (21.14) de yüksek doğrusal ilişkiyi işaret etmektedir. Ani ivmelenme sayısı (8.14) ise orta düzeyde bir VIF değerine sahiptir. Bu yüksek değerler, boyut indirgeme sırasında özniteliklerin dikkatlice ele alınması gerektiğini göstermekte, tamamen eleme yerine boyut indirgeme gibi yöntemlerle bu bağlılıkların etkisinin azaltılması önerilmektedir.

Dağılım grafikleri incelendiğinde (Şekil 73) veri setindeki doğrusal olmayan ilişkiler belirgin bir şekilde ortaya çıkmaktadır. Örnek grafiklerde birçok değişken çifti arasında geniş bir aralığa yayılma ve karmaşık desenler olduğu görülmektedir.



Şekil 73. Öznitelikler arası dağılımlar

Ani ivmelenme sayısı ve ortalama ivme arasında orta düzeyde bir ilişki mevcut olmasına rağmen (Tablo 22) dağılım grafiği bu ilişkinin tamamen doğrusal olmadığını ve aynı zamanda doğrusal olmayan etkiler barındırabileceğini ortaya koymaktadır. Benzer şekilde, şerit değişim sayısı ve ortalama yanal mesafe arasında doğrusallık bağlamında anlamlı bir desen gözlenmemekle birlikte, bu ilişki zayıf bir bağıntı ya da doğrusal olmayan bir yapı içermektedir. Dağılım grafiklerinin analizinde doğrusala yakın bir ilişki gösteren tek örnek, ortalama hız ile geçerli hız limitine uyma oranı arasındaki güçlü negatif ilişkidir. Bu değişken çiftinde, noktalardaki eğilim, nispeten doğrusal bir yapıyı işaret etmektedir. Veri setindeki değişkenlerin normalliği Shapiro-Wilk testi ile değerlendirilmiştir. Shapiro-Wilk testi sonuçlarına göre, veri setindeki değişkenlerin birçoğunun normal dağılım göstermediği tespit edilmiştir (Tablo 24).

Tablo 24. Özniteliklerin Saphiro-Wilk normallik testi sonuçları

Değişken	**Test istatistiği**	**p-değeri**	**Normal Dağılım**
Ortalama Hız (km/sa)	0.95457	0.00026	Yok
Ani ivmelenme sayısı	0.96982	0.00537	Yok
Ort. İvme (m/s²)	0.98797	0.31524	Var

Tablo 24. (Devamı)

Geçerli Hız Limitine Uyma Oranı	0.97044	0.00612	Yok
Şerit Değişim Sayısı	0.96931	0.00481	Yok
Ortalama Şerit Sapması (m)	0.99349	0.81560	Var
Senaryolar Hız Değişim Oranı	0.90619	0.00000	Yok
Senaryo Şerit Değişim Oranı	0.93753	0.00000	Yok

Özellikle ortalama hız, ani ivmelenme sayısı, geçerli hız limitine uyma oranı, şerit değişim sayısı, senaryolar hız değişim oranı ve senaryo şerit değişim oranı değişkenleri, p-değerleri 0.05'ten küçük olduğu için normal dağılım göstermemektedir. Buna karşılık, ortalama yanal mesafe ve ortalama ivme değişkenleri p-değerlerinin 0.05'ten büyük olması nedeniyle normal dağılım göstermektedir. Bu durum, veri setinde hem normal dağılıma uyan hem de uymayan değişkenlerin bir arada bulunduğunu göstermektedir. Korelasyon (Tablo 22), çoklu doğrusallık analizleri (Tablo 23), dağılım grafikleri (Şekil 73) ve normallik testi (Tablo 24) incelendiğinde, modelin kararlılığı ve performansı için öncelikle boyut indirgeme yapılması gerektiği anlaşılmaktadır. Ayrıca, boyut indirgeme işlemi öncesinde bilgi kaybını en aza indirebilmek için veri standardizasyonu yapılması gerekmektedir.

4.5.2. Veri Standardizasyonu

Veri standardizasyonu veri setindeki değişkenlerin farklı birimlerde veya ölçeklerde ifade edilmesi analiz süreçlerinde karşılaştırılabilirliği zorlaştırmakta ve bazı değişkenlerin model üzerinde daha baskın etkiler yaratmasına yol açabilmektedir. Bu nedenle veri standardizasyonu, özellikle ölçek duyarlılığına sahip çok değişkenli analiz yöntemleri ve makine öğrenmesi algoritmaları için önemli ve gerekli bir adımdır. Bu bağlamda standardizasyon ile tüm değişkenler, ortalaması 0 ve standart sapması 1 olacak şekilde aynı ölçeğe dönüştürülmüştür (Tablo 25). Bu sayede analizlerde her bir değişkenin eşit ağırlıkta değerlendirilmesi sağlanmakta ve yüksek değişken varyansına bağlı olarak algoritma performansını olumsuz etkileyebilecek sapmaların önüne geçilmeye çalışılmıştır. *Veri Ön İşleme ve Aykırı Değer Analizi* başlığı altında veri setindeki aykırı değer oluşturan sürücü verilerinin çıkarıldığı, veri setindeki bazı değişkenlerin normal dağılım göstermediği belirtilmişti. Bu aşamada standardizasyon için tercih edilen yöntem olan Z-skoru standardizasyonu, verilerin dağılımını değil, farklı ölçeklerdeki değişkenleri aynı seviyeye getirmeyi hedeflediğinden bu veri seti için uygun bir yöntem olarak kullanılmıştır.

Tablo 25. Standardizasyon öncesi ve sonrası tanımlayıcı istatistikler

Öznitelik Adı	Standardizasyon Öncesi				Standardizasyon Sonrası			
	Ort.	S. S.	Min.	Maks.	Ort.	S.S.	Min.	Maks.
Ortalama Hız (km/sa)	87.07	15.54	57.61	128.91	0	1	-1.90	2.69
Ani ivmelenme sayısı	23.58	13.61	1.00	61.00	0	1	-1.66	2.75
Ort. İvme (m/s^2)	0.12	0.04	0.03	0.21	0	1	-2.25	2.25
Geçerli Hız Limitine Uyma Oranı	0.44	0.25	0.02	1.00	0	1	-1.68	2.24
Şerit Değişim Sayısı	62.37	26.57	11.00	115.00	0	1	-1.93	1.98
Ortalama Şerit Sapması (m)	1.44	0.18	1.01	1.87	0	1	-2.39	2.39
Senaryo Şerit Değişim oranı	0.60	0.25	0.10	1.00	0	1	-2.00	1.60

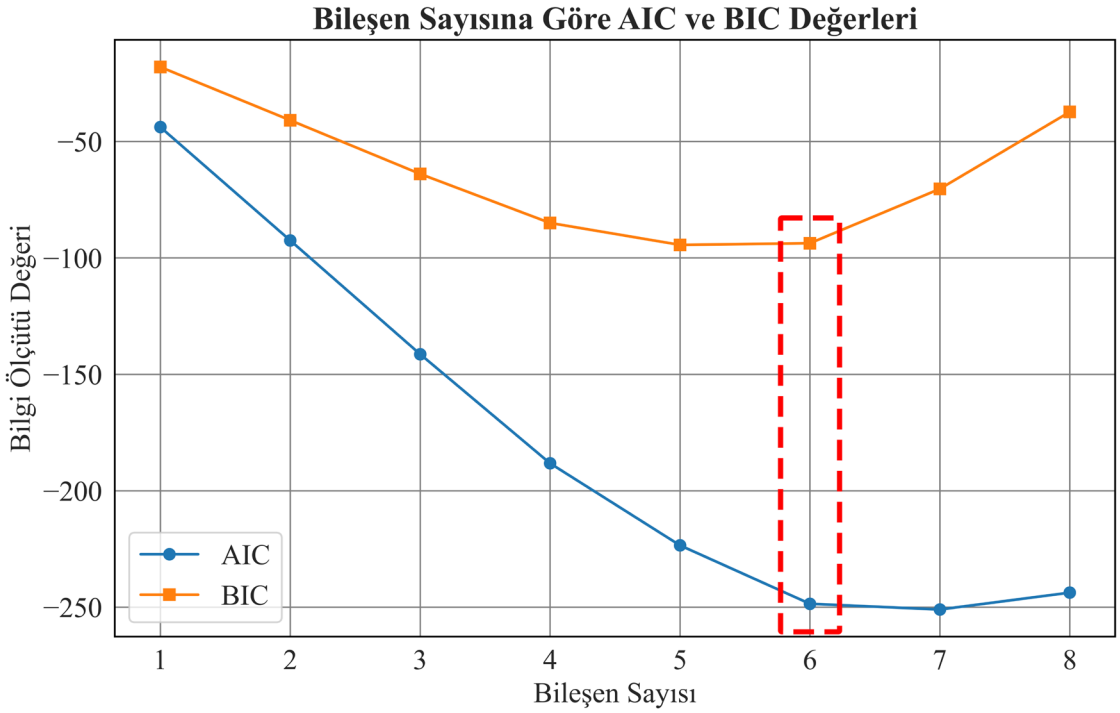
Tablo incelendiğinde, standardizasyon işleminin doğru ve etkili bir şekilde uygulandığı görülmektedir. Standardizasyon öncesinde farklı birim ve dağılımlara sahip olan değişkenlerin, dönüşüm sonrasında ortalamasının 0 ve standart sapmasının 1 olacak şekilde ölçeklendirildiği görülmektedir. Örneğin, 'Ortalama Hız' değişkeni dönüşüm öncesinde 57.61 ile 128.91 arasında bir aralığa sahipken, standardizasyon sonrasında -1.90 ile 2.69 arasında ifade edilmektedir. Benzer şekilde, 'Ani İvmelenme Sayısı' ve 'Şerit Değişim Sayısı' gibi değişkenlerin de benzer bir ölçekleme ile daha tutarlı bir hale getirildiği gözlemlenmektedir. Minimum ve maksimum değerlerdeki farklılıklar, z-skoru dönüşümünün doğal bir sonucu olarak ortaya çıkmakta ve değişkenler arası karşılaştırılabilirliği sağlamaktadır. Veri setinin normal dağılıma uymadığı bilinse de z-skoru dönüşümünün değişkenlerin ölçek farklarını ortadan kaldırması ve boyut indirgeme yöntemlerinin uygulanmasına olanak tanıması önemli bir avantaj sağlamaktadır. Standart sapmaların tüm değişkenler için 1'e eşitlenmiş olması, değişkenlerin eşit ağırlıkta işlenmesine olanak tanımakta ve boyut indirgeme sürecine uygun bir yapı oluşturmaktadır.

4.5.3. Boyut İndirgeme

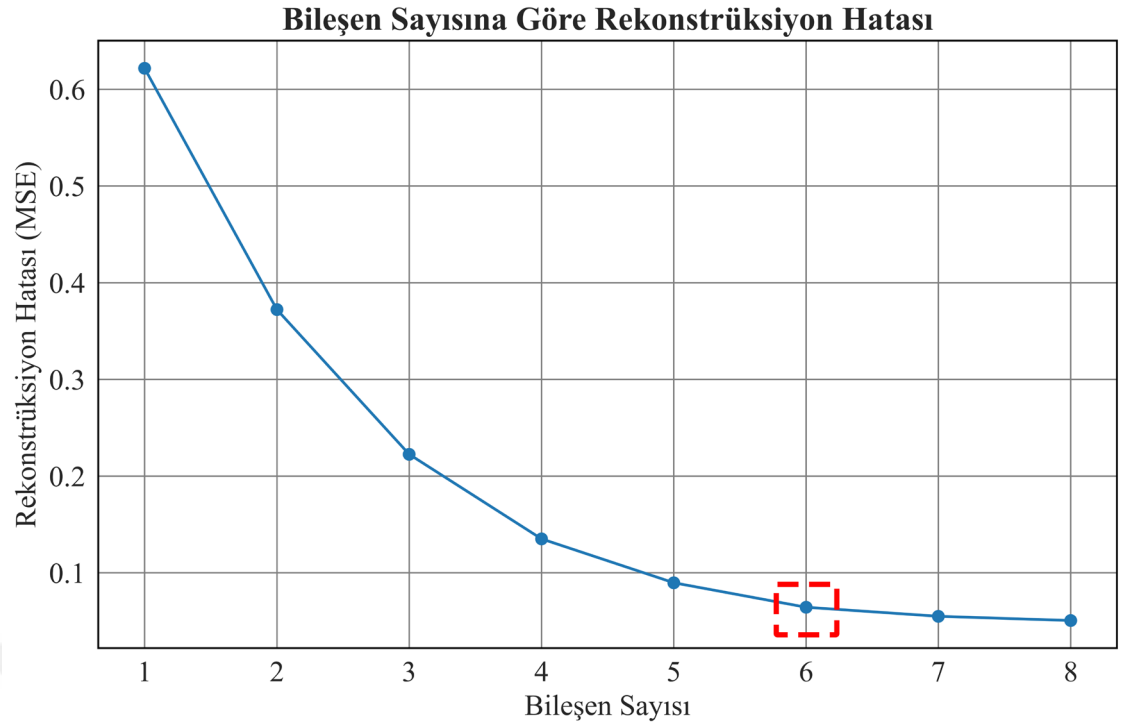
Veri setindeki doğrusal olmayan ilişkiler, korelasyonlar ve normal dağılıma uymama durumları, PCA ve LDA gibi doğrusal boyut indirgeme yöntemlerinin etkinliğini sınırlamaktadır. Bu nedenle doğrusal olmayan veri yapılarını daha iyi yakalayabilen Kernel PCA gibi gelişmiş boyut indirgeme tekniklerinin kullanılması modelin genelleme kapasitesini artırmak ve daha anlamlı sonuçlar elde etmek için uygun bir çözüm olarak değerlendirilmiştir. Her ne kadar veri seti uzman görüşüyle etiketlenmiş olsa da etiket bilgisini kullanan Kernel Diskriminant Analiz (KDA) yerine kernel PCA'nın tercih edilmesinin temel nedeni, bu aşamada sınıflandırma optimizasyonundan ziyade verinin doğal yapısının korunmasının öncelikli olmasıdır. KDA, sınıflar arası

ayrımı optimize etmeye odaklandığından, bu süreçte veri setindeki bazı yapısal özelliklerin veya doğrusal olmayan ilişkilerin yeterince temsil edilememesi riskini taşımaktadır. Kernel PCA ise öznitelikler arasındaki karmaşık ilişkileri kernel fonksiyonları yardımıyla yakalayarak sürücülerin hız profilleri, ani hızlanma-yavaşlama davranışları ve diğer sürüş karakteristikleri arasındaki doğrusal olmayan ilişkileri daha etkin şekilde modelleyebilmektedir.

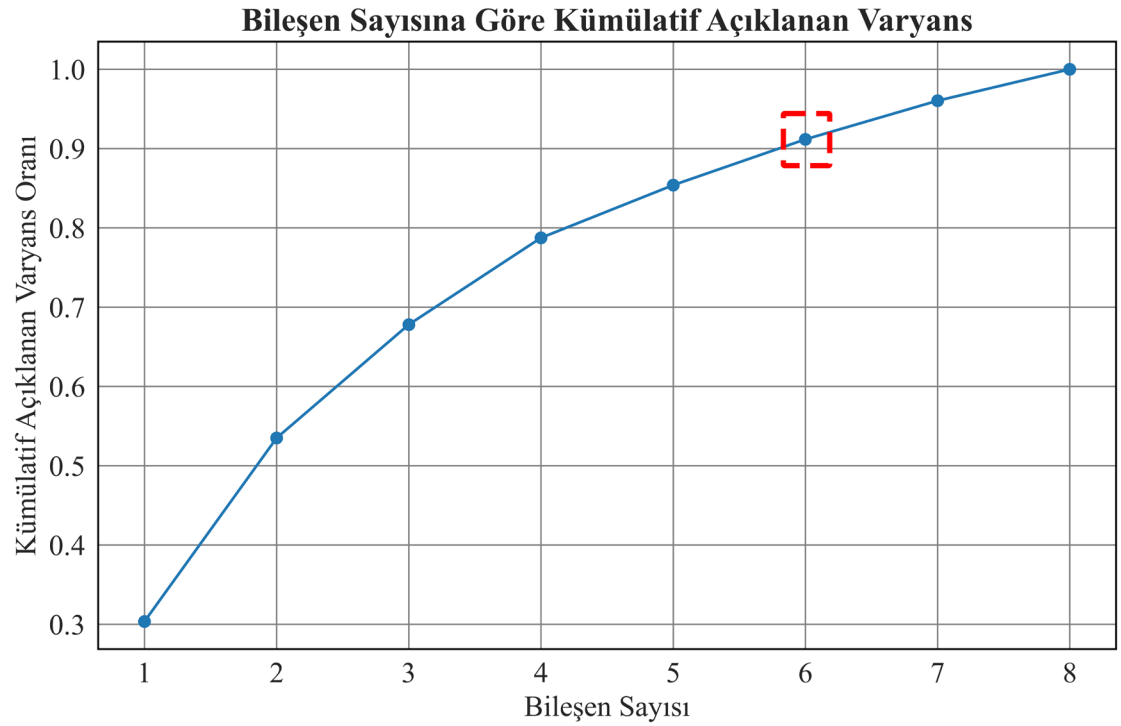
Kernel PCA'nın etiketlerden bağımsız çalışması, verinin yapısal özelliklerinin objektif bir şekilde değerlendirilmesini sağlamakta ve uzman görüşlerinden kaynaklanabilecek potansiyel yanlılıkların boyut indirgeme aşamasına yansımasını engellemektedir. İlk aşamada optimum bileşen sayısına karar verebilmek adına AIC (Akaike Bilgi Kriteri) ve BIC (Bayesyen Bilgi Kriteri) değerleri, bileşen sayısına göre kümülatif açıklanan varyans oranı, çekirdek matrisinin özdeğerleri ve bileşen sayısına göre yeniden yapılandırma (rekonstrüksiyon) hatası analizleri yapılarak sonuçlar Şekil 74, 75, 76 ve 77'de ve Tablo 26'da verilmiştir.



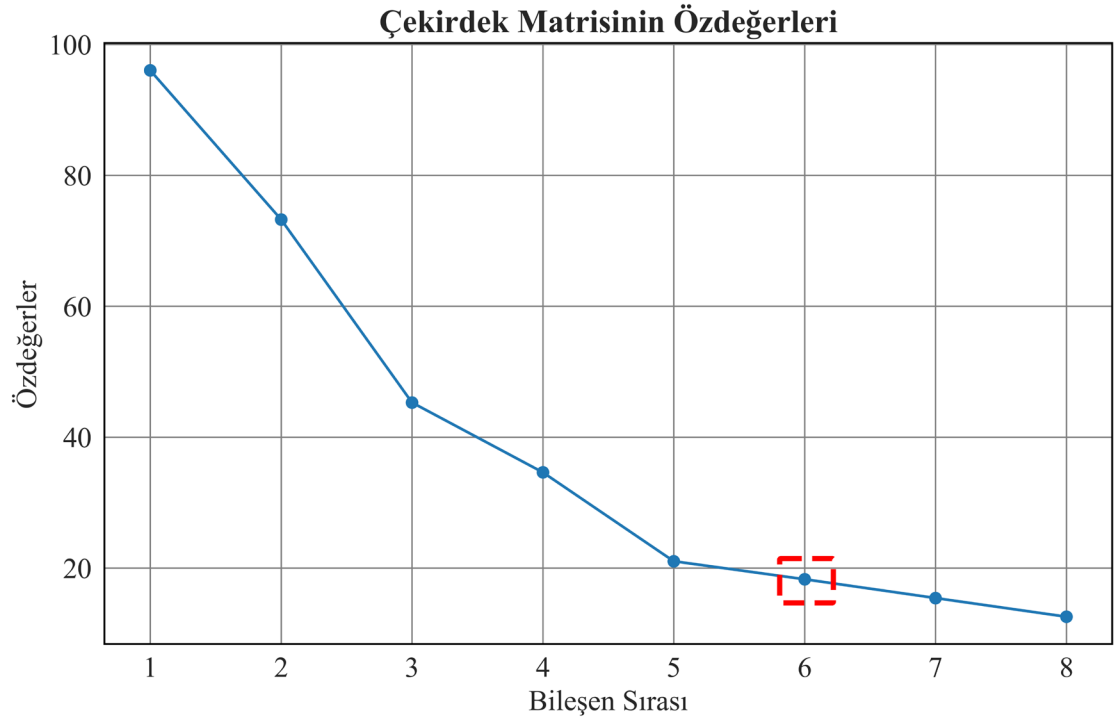
Şekil 74. Bileşen sayısına göre AIC ve BIC değerleri



Şekil 75. Bileşen sayısına göre rekonstrüksiyon hatası



Şekil 76. Bileşen sayısına göre kümülatif açıklanan varyans



Şekil 77. Çekirdek matrisinin özdeğerleri

Tablo 26. Optimum bileşen sayısının belirlenmesi için hesaplanan metrikler

Bileşen Sayısı	Kümülatif Açıklanan Varyans Oranı	Rekonstrüksiyon Hatası (MSE)	AIC	BIC	Özdeğerler
1	0.303	0.622	-43.80	-17.99	96.05
2	0.535	0.372	-92.49	-40.87	73.25
3	0.678	0.223	-141.34	-63.91	45.29
4	0.787	0.135	-188.21	-84.98	34.62
5	0.854	0.090	-223.44	-94.40	21.03
6	0.912	0.064	-248.55	-93.70	18.28
7	0.960	0.055	-251.01	-70.35	15.41
8	1.000	0.051	-243.75	-37.29	12.55

AIC ve BIC değerleri incelendiğinde, AIC'nin 7 bileşende en düşük seviyesine (-251.01) ulaştığı görülmektedir. Ancak BIC değeri 5 bileşende minimum seviyesine (-94.4) ulaşmış ve 6. bileşenden sonra artmaya başlamıştır. Bu durum, AIC açısından 7 bileşenin tercih edilebilir olduğunu gösterse de BIC'nin model karmaşıklığını göz önünde bulundurması nedeniyle 5 bileşenin daha dengeli bir seçim olduğunu işaret etmektedir. Bu farklılık özellikle modelin genellenebilirliğini sağlamak için karmaşıklığın sınırlandırılmasının gerekliliğini ortaya koymaktadır. Kümülatif açıklanan varyans oranı grafiği 6 bileşenle toplam varyansın %91.2'sinin açıklandığını göstermektedir. Daha fazla bileşen eklendiğinde, 7 bileşen ile bu oran %96'ya, 8 bileşen ile %100'e ulaşmıştır. Ancak 6 bileşen, veri setindeki varyansın büyük bir kısmını temsil etmekte ve eklenen

bileşenlerin katkı yüzdesi giderek azalmaktadır. Tablo verilerine göre 6. bileşen varyansa %5.8'lik bir katkı sağlarken, 7. bileşen bu katkıyı yalnızca %4.8 oranında artırmıştır. Bu, 6 bileşenin toplam varyansı açıklamak için yeterli olduğunu göstermektedir.

Çekirdek matrisinin özdeğerleri, incelendiğinde 6. bileşenin özdeğeri 18.28 seviyesinde iken, 7. ve 8. bileşenlerin özdeğerleri sırasıyla 15.41 ve 12.55 seviyelerine düşmüştür. Özdeğerlerdeki bu düşüş, 6 bileşenden sonraki bileşenlerin toplam varyansa katkısının oldukça sınırlı olduğunu ortaya koymaktadır. Rekonstrüksiyon hatası (MSE) açısından, 6 bileşenle hata 0.064 seviyesine düşmüş ve daha fazla bileşen eklenmesi bu hatayı yalnızca kısıtlı ölçüde azaltmıştır. 7 bileşenle hata 0.055 seviyesine, 8 bileşenle ise 0.051 seviyesine inmiştir. Ancak bu iyileştirme oldukça sınırlıdır ve kabul edilebilir hata seviyesi zaten 6 bileşenle sağlanmıştır. AIC, BIC, rekonstrüksiyon hatası, kümülatif varyans oranı ve çekirdek matrisinden elde edilen bulgular karşılaştırılmış; 6 bileşen, hem veri setinin büyük bir kısmını temsil etmesi hem de bilgi kaybını minimize ederek modelin genellenebilirliğini artırması nedeniyle tercih edilmiştir. Bu seçim, aşırı karmaşıklıktan kaçınarak modelin hem açıklayıcılığını hem de uygulanabilirliğini destekleyen bir denge sağlamaktadır.

Elde edilen yeni bileşenlerin orijinal veri setindeki özniteliklerle ilişkilendirilmesi, boyut indirgeme problemlerinde kritik bir öneme sahiptir. Özellikle Kernel PCA gibi doğrusal olmayan boyut indirgeme yöntemlerinde bu ilişkiyi anlamak, yöntemin karmaşıklığı nedeniyle oldukça güç olabilmektedir. Ancak, yeni bileşenlerin eski özniteliklerle bağlantısını değerlendirmek için en yaygın kullanılan yaklaşımlardan biri, bu iki grup arasında korelasyon analizi yapmaktır. Bu çalışmada, yeni bileşenler ile orijinal öznitelikler arasındaki ilişkileri belirlemek amacıyla Spearman korelasyon katsayısı hesaplanmış ve bu ilişkiler Tablo 27'de sunulmuştur.

Tablo 27. Elde edilen bileşenlerin eski özniteliklerle ilişkisi

Öznitelik Adı	**Bileşenler**					
	1	**2**	**3**	**4**	**5**	**6**
Ortalama Hız (km/sa)	-0.73	0.31	0.55	0.03	-0.05	0.00
Ani ivmelenme sayısı	-0.01	-0.87	0.14	-0.24	0.31	-0.12
Ort. İvme (m/s²)	-0.21	-0.81	0.20	-0.31	0.04	0.24
Geçerli Hız Limitine Uyma Oranı	0.72	-0.33	-0.53	0.06	0.08	-0.14
Şerit Değişim Sayısı	-0.80	-0.29	-0.27	-0.21	-0.25	-0.07
Ortalama Yanal Mesafe (m)	0.45	-0.30	0.56	-0.11	-0.37	-0.31
Senaryolar Hız Değişim Oranı	-0.41	-0.33	-0.02	0.65	0.19	-0.10
Senaryo Şerit Değişim Oranı	-0.81	-0.20	-0.28	-0.34	-0.28	-0.09

Yeni bileşenlere anlamlı isimler verilmesi, boyut indirgeme yöntemlerinin yorumlanabilirliğini artırmak ve elde edilen sonuçları daha anlaşılır hale getirmek için önemli bir adımdır. Her bir bileşenin en yüksek korelasyon gösterdiği öznitelik ya da öznitelik grubu dikkate alınarak bileşenin temsil ettiği temel özellik belirlenmiş ve buna uygun bir isimlendirme yapılmıştır. Bu süreç, boyut indirgeme sonucu elde edilen bileşenlerin daha somut ve sonuçların daha etkili bir şekilde yorumlanmasına katkı sağlamaktadır. Bu bağlamda bileşenlerin temel özellikleri ve temsil ettikleri öznitelikler Tablo 27'den faydalanılarak şu şekilde yorumlanmış ve yeniden adlandırılmıştır;

Bileşen 1, 'Ortalama Hız' (-0.73), 'Geçerli Hız Limitine Uyma Oranı' (0.72) ve 'Şerit Değişim Sayısı' (-0.80) değişkenleriyle yüksek korelasyon göstermektedir. Bu değişkenler sürücülerin hız ve şerit disiplini konusundaki davranışlarını temsil etmektedir. Bu nedenle Bileşen 1, 'Hız ve Şerit Disiplini İndeksi' (HSI) olarak adlandırılmıştır.

Bileşen 2, 'Ani İvmelenme Sayısı' (-0.87) ve 'Ortalama İvme' (-0.81) değişkenleriyle güçlü negatif korelasyon göstermektedir. Bu ilişki bileşenin sürücülerin ivmelenme davranışlarındaki değişkenliği ve ani ivmelenme eğilimlerini temsil ettiğini göstermektedir. Bu doğrultuda Bileşen 2'ye 'İvmelenme İndeksi' (IMI) adı verilmiştir.

Bileşen 3, 'Ortalama Yanal Mesafe' (0.56), 'Ortalama Hız' (0.55) ve 'Geçerli Hız Limitine Uyma Oranı' (-0.53) değişkenleriyle orta-yüksek düzeyde korelasyon göstermektedir. Bu bileşen sürücülerin hız kurallarına uyma disiplinini ve şerit kullanımı ile olan ilişkisini temsil etmektedir. Bu nedenle Bileşen 3, 'Hız Disiplini İndeksi' (HDI) olarak adlandırılmıştır.

Bileşen 4, 'Senaryolar Hız Değişim Oranı' değişkeni ile yüksek korelasyon göstermektedir (0.65). Bu ilişki bileşenin sürücülerin farklı senaryolardaki hız değişimlerini temsil ettiğini göstermektedir. Bu bağlamda, Bileşen 4, 'Senaryo Hız İndeksi' (SHI) olarak adlandırılmıştır.

Bileşen 5, 'Ortalama Yanal Mesafe' (-0.37) ve 'Ortalama Hız' (-0.05) ile en yüksek korelasyona sahip olsa da herhangi bir değişkene baskın şekilde bağlılık göstermemektedir. Bu durum bileşenin genel bir durumu yansıttığını ortaya koymaktadır. Bu nedenle Bileşen 5, 'Genel İndeks 1' (GI1) olarak adlandırılmıştır

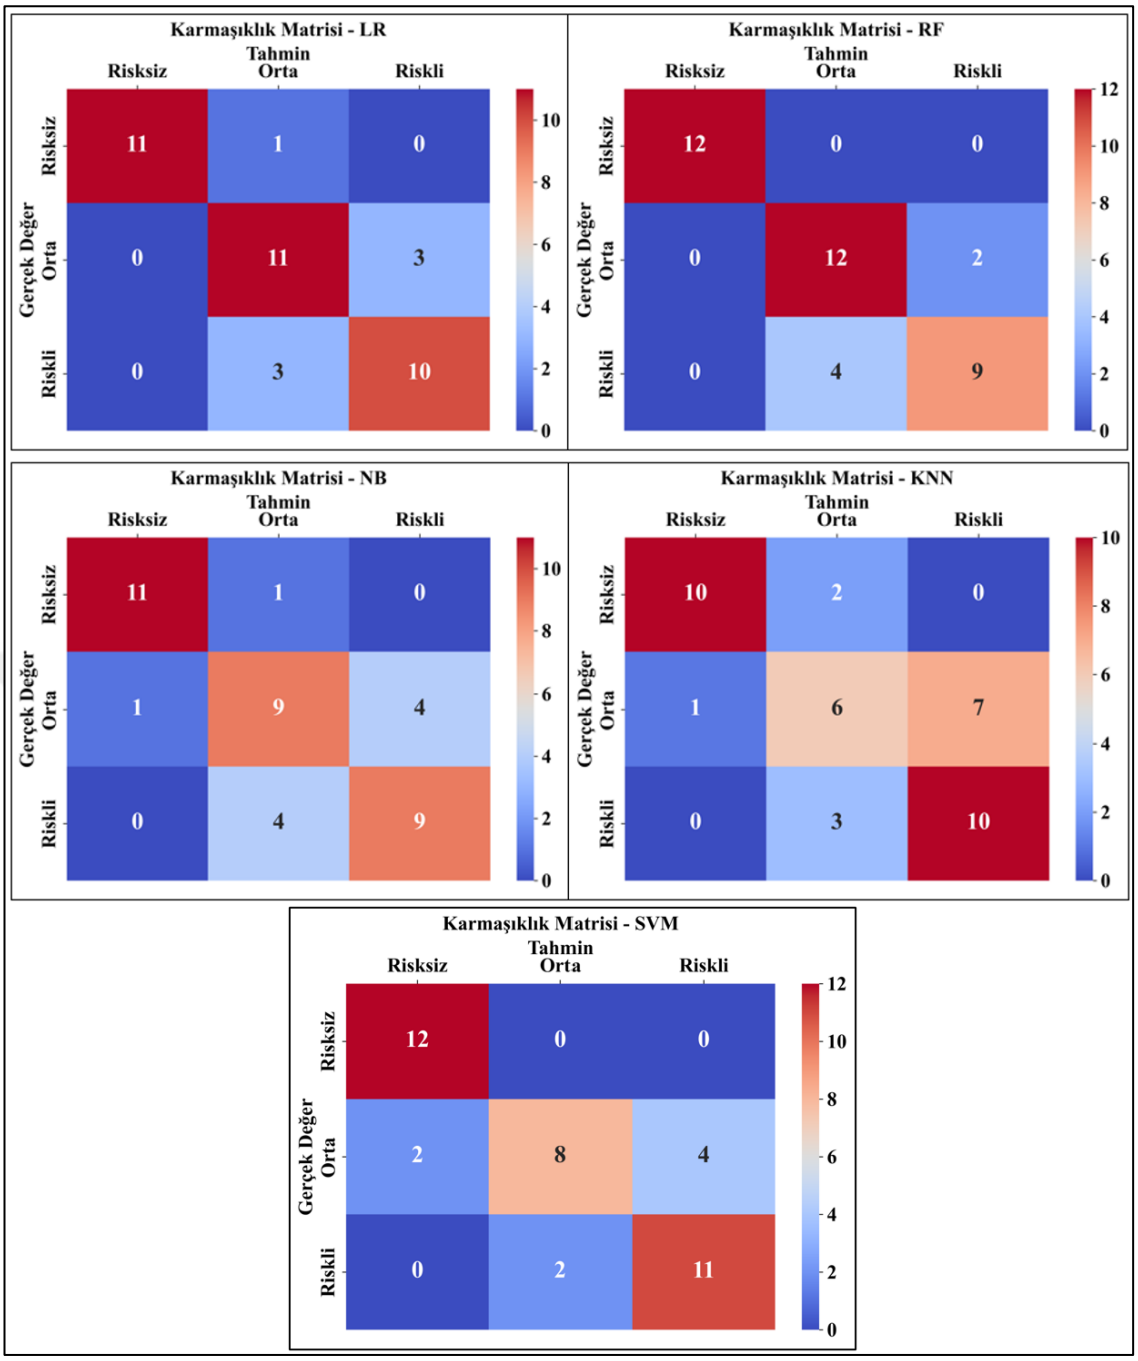
Bileşen 6, özniteliklerle dengeli bir korelasyon yapısı sergileyen, belirli bir değişkene baskın bir şekilde bağlılık göstermeyen bir bileşen olarak gözlemlenmiştir. Bu nedenle Bileşen 6, 'Genel İndeks 2' olarak adlandırılmıştır. Yeni bileşenlere ilişkin bilgiler daha anlaşılır olması açısından Tablo 28'de verilmiştir.

Tablo 28. Oluşturulan yeni bileşenlerin tanımlanması ve isimlendirilmesi

Bileşen Adı	İlişkili Olduğu Öznitelik	Yeni Bileşen Adı	Kısaltma
Bileşen 1	Ortalama Hız	Hız ve Şerit Disiplini İndeksi	**HSI**
	Geçerli Hız Limitine Uyma Oranı		
	Şerit Değişim Sayısı		
Bileşen 2	Ani İvmelenme Sayısı	İvmelenme İndeksi	**IMI**
	Ortalama İvme		
Bileşen 3	Ortalama Yanal Mesafe	Hız Disiplini İndeksi	**HDI**
	Ortalama Hız		
	Geçerli Hız Limitine Uyma Oranı		
Bileşen 4	Senaryolar Hız Değişim Oranı	Senaryo Hız İndeksi	**SHI**
Bileşen 5	Güçlü Korelasyon yok	Genel İndeks 1	**GI1**
Bileşen 6	Güçlü Korelasyon yok	Genel İndeks 2	**GI2**

4.5.4. Sınıflandırma Performanslarının Değerlendirilmesi

Veri setinde toplamda 130 sürücü yer almakta olup, 'Risksiz' sınıfında 39 sürücü, 'Orta' sınıfında 48 sürücü ve 'Riskli' sınıfında 43 sürücü bulunmaktadır. Toplam 130 sürücünün % 70'i (91 sürücü) eğitim verisi, %30' u ise test verisi olarak ayrılmış ve veri setinde yer alan yeni bileşenler kullanılarak farklı algoritmalarla (LR, RF, NB, KNN, SVM) ile sınıflandırma gerçekleştirilmiş ve her bir modelin temel hiperparametreleri ile sağladıkları performans karşılaştırılmıştır. Elde edilen karmaşıklık matrisleri (confusion matrix), modellerin gerçek ve tahmin edilen sınıflar arasındaki eşleşmeleri sayısal olarak ortaya koymaktadır. Bu matrisler, doğru sınıflandırmaların yanı sıra yanlış pozitif (false positive) ve yanlış negatif (false negative) tahminleri içeren performans ölçütlerinin değerlendirilmesine olanak tanımaktadır. Modellerin karmaşıklık matrisleri Şekil 78'de sunulmuştur.



Şekil 78. Modellerin temel hiperparametrelerle elde edilen karmaşıklık matrisleri

Karmaşıklık matrislerinden yola çıkarak modellerin doğruluk, duyarlılık, F1 skoru gibi performans metrikleri hesaplanabilmektedir. Bu bağlamda hesaplanan performans metrikleri Tablo 29'da verilmiştir.

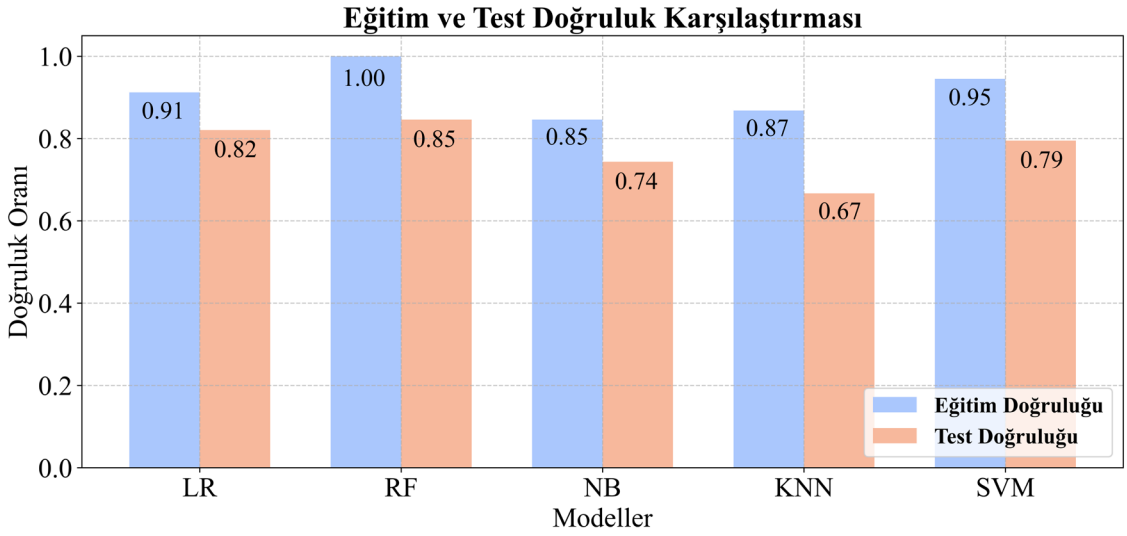
Tablo 29. Modellerin temel hiperparametrelerle elde edilen performans metrikleri

Model	Sınıf	Kesinlik	Duyarlılık	F1 Score	Örnek Sayısı	Eğitim Doğruluğu	Test Doğruluğu
LR	Risksiz	1.00	0.92	0.96	12	0.9121	0.8205
	Orta	0.73	0.79	0.76	14		
	Riskli	0.77	0.77	0.77	13		
	Doğruluk			0.82	39		
	Makro Ort.	0.83	0.82	0.83	39		
	Ağırlıklı Ort.	0.83	0.82	0.83	39		
RF	Risksiz	1.00	1.00	1.00	12	1.0000	0.8462
	Orta	0.75	0.86	0.80	14		
	Riskli	0.82	0.69	0.75	13		
	Doğruluk			0.85	39		
	Makro Ort.	0.86	0.85	0.85	39		
	Ağırlıklı Ort.	0.85	0.85	0.85	39		
NB	Risksiz	0.92	0.92	0.92	12	0.8462	0.7436
	Orta	0.64	0.64	0.64	14		
	Riskli	0.69	0.69	0.69	13		
	Doğruluk			0.74	39		
	Makro Ort.	0.75	0.75	0.75	39		
	Ağırlıklı Ort.	0.74	0.74	0.74	39		
KNN	Risksiz	0.91	0.83	0.87	12	0.8681	0.6667
	Orta	0.55	0.43	0.48	14		
	Riskli	0.59	0.77	0.67	13		
	Doğruluk			0.67	39		
	Makro Ort.	0.68	0.68	0.68	39		
	Ağırlıklı Ort.	0.67	0.67	0.66	39		
SVM	Risksiz	0.86	1.00	0.92	12	0.9451	0.7949
	Orta	0.80	0.57	0.67	14		
	Riskli	0.73	0.85	0.79	13		
	Doğruluk			0.79	39		
	Makro Ort.	0.80	0.81	0.80	39		
	Ağırlıklı Ort.	0.80	0.80	0.79	39		

Tablo 29'da sunulan analiz sonuçlarına göre, temel hiperparametrelerle oluşturulan sınıflandırma modellerinin 'Risksiz', 'Orta' ve 'Riskli' sınıflar üzerindeki performansı değerlendirilmiştir. Bu değerlendirme sonucunda, farklı algoritmaların sınıflar arasında doğruluk, kesinlik, duyarlılık ve F1 skorlarında belirli sınırlamalar gösterdiği tespit edilmiştir. LR modeliyle Risksiz sınıfta %100 kesinlik ve %92 duyarlılık elde edilerek yüksek bir performans elde edilmiştir. Ancak Orta ve Riskli sınıflarda kesinlik sırasıyla %73 ve %77'ye düşmüş, F1 skorları ise %76 ve %77 seviyelerinde kalmıştır. Test doğruluğunun (%82,05), eğitim doğruluğuna (%91,21) kıyasla düşüş göstermesi, modelin genelleme kapasitesinde eksikliklere ve aşırı uyuma işaret etmektedir.

RF modeli Risksiz sınıfta %100 kesinlik ve duyarlılık ile güçlü bir performans sergilemiştir. Ancak, Orta sınıfta duyarlılık %86'ya, Riskli sınıfta ise %69'a gerilemiştir. Test doğruluğu %84,62 olarak ölçülmüş ve bu oran, eğitim doğruluğu olan %100'ün gerisinde kalmıştır. Bu durum, modelin aşırı öğrenme eğiliminde olduğunu göstermektedir. NB modeli Risksiz sınıfta %92 kesinlik ve duyarlılık ile makul bir performans göstermiştir. Ancak, Orta sınıfta hem kesinlik hem de duyarlılık %64 seviyesinde kalmış, Riskli sınıfta ise duyarlılık %69 olarak hesaplanmıştır. Test doğruluğu %74,36 ile eğitim doğruluğu olan %84,62'nin gerisinde kalmış ve modelin genelleme yeteneğindeki sınırlamaları ortaya koymuştur. KNN modeli Risksiz sınıfta %91 kesinlik ve %83 duyarlılık ile sınırlı bir başarı elde etmiştir. Ancak, Orta sınıfta duyarlılık %43'e, F1 skoru ise %48'e kadar gerilemiş ve Riskli sınıfta duyarlılık %77 olarak kalmıştır. Test doğruluğu %66,67 olarak hesaplanmış ve bu oran, eğitim doğruluğu olan %86,81'e kıyasla belirgin bir düşüş göstermiştir. SVM modeli Risksiz sınıfta %86 kesinlik ve %100 duyarlılık ile diğer modellerle benzer bir performans sergilemiştir. Ancak, Orta sınıfta duyarlılık %57'ye gerilemiş, Riskli sınıfta ise duyarlılık %85 olarak ölçülmüştür. Test doğruluğu %79,49 olarak ölçülmüş ve eğitim doğruluğu olan %94,51 ile karşılaştırıldığında belirgin bir fark oluşmuştur. Bu durum, modelin aşırı öğrenme eğiliminde olduğunu ve test veri setindeki genelleme kapasitesinin sınırlı kaldığını göstermektedir.

Özet olarak; LR ve RF modellerinin risksiz sınıfta üstün bir performans sergilemesine rağmen bu başarıyı Orta ve Riskli sınıflarda sürdüremediği görülmüştür. NB ve KNN modellerinin özellikle Orta sınıfta yetersiz kaldığı, SVM modelinin ise Risksiz ve Orta sınıflarda kabul edilebilir sonuçlar vermesine karşın Riskli sınıfta beklenen performansı sağlayamadığı tespit edilmiştir. Eğitim ve test doğruluğu arasındaki belirgin farklar (Şekil 79) özellikle RF ve SVM modellerinde aşırı öğrenme eğilimini işaret etmektedir.



Şekil 79. Modellerin eğitim-test doğruluğu karşılaştırması

Hiperparametre optimizasyonu yapılmadan elde edilen bu sonuçlar modellerin sınıflar arası dengesiz performansını ve test veri setlerindeki sınırlı genelleme başarısını ortaya koymaktadır. Bu bağlamda modeller için hiperparametre optimizasyonu yapmadan sınıflandırma modeli oluşturmak, doğru bir yaklaşım olmayacaktır.

4.5.5. Hiperparametre Optimizasyonu

Modellerin performansını artırmak ve sınıflandırma başarısını maksimize etmek amacıyla hiperparametre optimizasyonu gerçekleştirilmiştir. Bu süreçte, GridSearchCV fonksiyonu kullanılarak önceden tanımlanan hiperparametre aralıkları sistematik olarak taranmış ve çapraz doğrulama yöntemiyle en uygun parametreler seçilmiştir. Böylece, modellerin genellenebilirliğini ve doğruluğunu artırmaya yönelik en iyi hiperparametre kombinasyonları elde edilmiştir. Optimizasyon sonrası en iyi hiperparametreler Tablo 30'da sunulmuştur.

Tablo 30. Modeller için en iyi hiperparametreler

Model	Hiperparametreler
LR	solver='saga', C=1, penalty='l2', max_iter=3000, class_weight='balanced'
RF	n_estimators=200, max_depth=5, min_samples_split=4, min_samples_leaf=2, max_features='sqrt', class_weight='balanced'
KNN	n_neighbors=5, weights='uniform', metric='euclidean', algorithm='auto'
SVM	C=100, kernel='poly', gamma=0.01, degree=2, coef0=0.5, class_weight='balanced'
NB	var_smoothing=1e-8

Tablo 30, optimizasyon süreci sonunda elde edilen en iyi parametreleri göstermektedir. Optimizasyon sonuçları şu şekilde özetlenebilir;

• LR: En iyi performans, düzenlileştirme parametresi C=1, sınıf ağırlığı ‘balanced’, maksimum iterasyon sayısı 3000, L2 düzenlileştirme ve ‘saga’ çözücüsü ile elde edilmiştir.

• RF: Kapsamlı bir parametre araması sonucunda, 200 ağaç sayısı, maksimum derinlik 5, minimum örneklem bölme sayısı 4, minimum yaprak düğüm örneklem sayısı 2, ‘sqrt’ maksimum özellik seçimi ve dengeli sınıf ağırlıkları en optimal sonucu vermiştir.

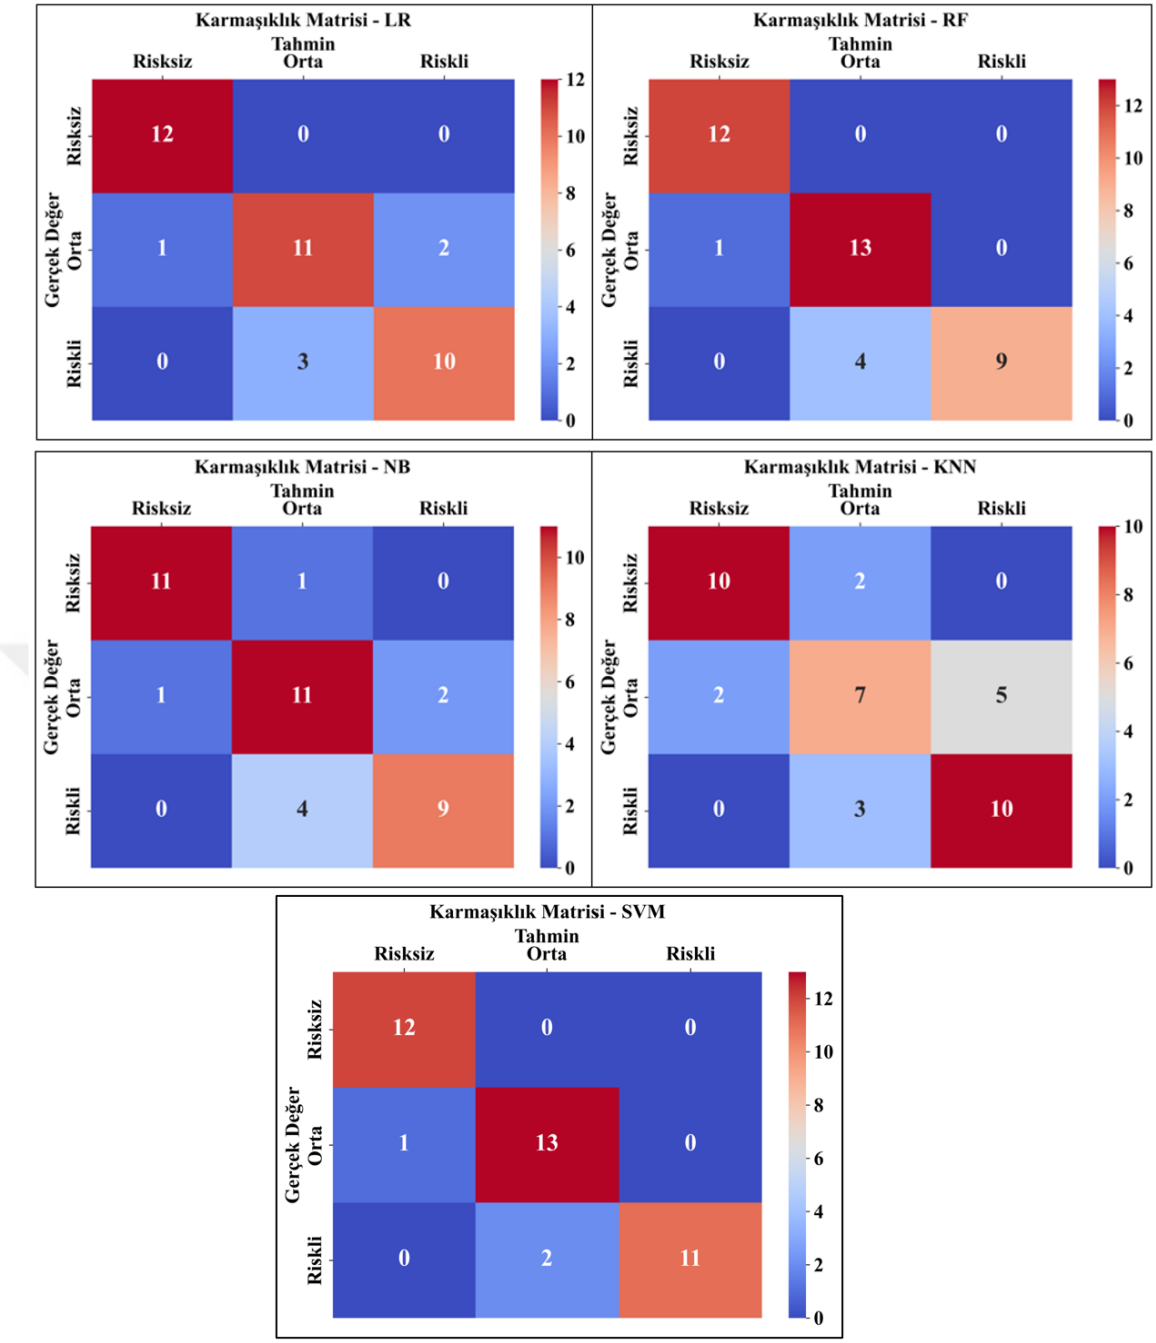
• KNN: Optimizasyon sürecinde, 5 komşu sayısı, ‘uniform’ ağırlıklandırma, ‘euclidean’ mesafe metriği ve ‘auto’ algoritması en iyi sonucu sağlamıştır.

• SVM: En iyi performans; C=100 düzenlileştirme parametresi, sınıf ağırlığı ‘balanced’, 0.5 serbest terim katsayısı, 2. dereceden polinom kernel, γ=0.01 değeri ve ‘poly’ kernel fonksiyonu ile elde edilmiştir.

• NB: Varyans düzeltme parametresi olarak belirlenmiş ve bu düzenlemelerle model %79 doğruluk oranı sağlamıştır.

4.5.6. Hiperparametre Optimizasyonu Sonrası Performans Değerlendirmesi

Hiperparametre optimizasyonu sonucunda en yüksek doğruluk oranına %92.31 ile SVM modeli ulaşmış, bunu sırasıyla %87 ile RF ve %85 ile LR modelleri takip etmiştir. NB ve KNN modelleri ise sırasıyla %79 ve %69 doğruluk oranlarıyla diğer modellere göre daha düşük performans göstermiştir. Modellerin performans değerlendirmesi için karmaşıklık matrisleri Şekil 80’de sunulmuş ve bu matrislere dayalı performans değerlendirmeleri yapılmıştır.



Şekil 80. Optimizasyon sonrası karmaşıklık matrisleri

Optimizasyon sonrasında, karmaşıklık matrislerine dayalı olarak modellerin sınıflandırma performanslarında belirgin iyileşmeler gözlemlenmiştir. Örneğin, SVM modeli, 'Risksiz' sınıfta 12 sürücünün tamamını doğru sınıflandırarak hatalı sınıflandırma yapmamıştır. 'Riskli' sınıfta ise 11 sürücüyü doğru sınıflandırmış ve 2 yanlış tahminde bulunmuştur. Benzer şekilde, RF modeli, 'Orta' sınıfta 13 sürücüyü doğru tahmin ederek bu sınıfta yüksek bir performans sergilemiştir. Buna karşılık, KNN ve NB modelleri özellikle 'Orta' sınıfta yüksek hata oranlarıyla dikkat çekmiştir. KNN modeli, 'Orta' sınıfta 7 sürücüyü yanlış sınıflandırırken, NB modeli bu sınıfta 11 doğru

tahmin gerçekleştirmiştir. Optimizasyon sonrası oluşan performans metrikleri Tablo 31'de sunulmuştur.

Tablo 31. Modellerin optimizasyon sonrası performans metrikleri

Model	Sınıf	Kesinlik	Duyarlılık	F1-Skoru	Örnek Sayısı	AUC	Eğ. Doğ.	Test Doğ.
LR	Risksiz	0.92	1.00	0.96	12	0.99	0.9121	0.8462
	Orta	0.79	0.79	0.79	14	0.89		
	Riskli	0.83	0.77	0.80	13	0.98		
	Doğruluk			0.85	39			
	Makro Ort.	0.85	0.85	0.85	39			
	Ağırlıklı Ort.	0.84	0.85	0.85	39			
RF	Risksiz	0.92	1.00	0.96	12	1.00	0.967	0.8718
	Orta	0.77	0.93	0.84	14	0.92		
	Riskli	1.00	0.69	0.82	13	0.95		
	Doğruluk			0.87	39			
	Makro Ort.	0.90	0.87	0.87	39			
	Ağırlıklı Ort.	0.89	0.87	0.87	39			
NB	Risksiz	0.92	0.92	0.92	12	0.99	0.8462	0.7949
	Orta	0.69	0.79	0.74	14	0.90		
	Riskli	0.82	0.69	0.75	13	0.96		
	Doğruluk			0.79	39			
	Makro Ort.	0.81	0.80	0.80	39			
	Ağırlıklı Ort.	0.80	0.80	0.80	39			
KNN	Risksiz	0.83	0.83	0.83	12	0.96	0.8681	0.6923
	Orta	0.58	0.50	0.54	14	0.76		
	Riskli	0.67	0.77	0.72	13	0.88		
	Doğruluk			0.69	39			
	Makro Ort.	0.69	0.70	0.70	39			
	Ağırlıklı Ort.	0.69	0.69	0.69	39			
SVM	Risksiz	0.92	1.00	0.96	12	1.00	0.9451	0.9231
	Orta	0.87	0.93	0.90	14	0.96		
	Riskli	1.00	0.85	0.92	13	0.99		
	Doğruluk			0.92	39			
	Makro Ort.	0.93	0.93	0.93	39			
	Ağırlıklı Ort.	0.93	0.92	0.93	39			

Tablo 31'de modellerin optimizasyon sonrası performansları doğruluk metriği üzerinden değerlendirildiğinde şu sonuçlar elde edilmiştir:

LR modelinin, eğitim doğruluğu %91,21 ve test doğruluğu %84,62 olarak hesaplanmıştır. Eğitim ve test doğruluğu arasında belirgin bir fark bulunması, modelin genelleme kapasitesinde eksikliklere işaret etmektedir. Ancak, Risksiz sınıfta %96 gibi yüksek bir F1 skoru, modelin bu sınıf üzerinde tutarlı bir performans sergilediğini

göstermektedir. Buna rağmen, Orta ve Riskli sınıflarda performans farklarının devam ettiği görülmektedir.

RF modelinin, eğitim doğruluğu %96,70 ve test doğruluğu %87,18 olarak hesaplanmıştır. Eğitim doğruluğunun test doğruluğundan yüksek olması, modelin aşırı uyum eğiliminde olabileceğini göstermektedir. Yine de test doğruluğunun diğer modellere kıyasla daha yüksek bir seviyede olması, modelin genelleme başarısının görece iyi olduğunu ortaya koymaktadır.

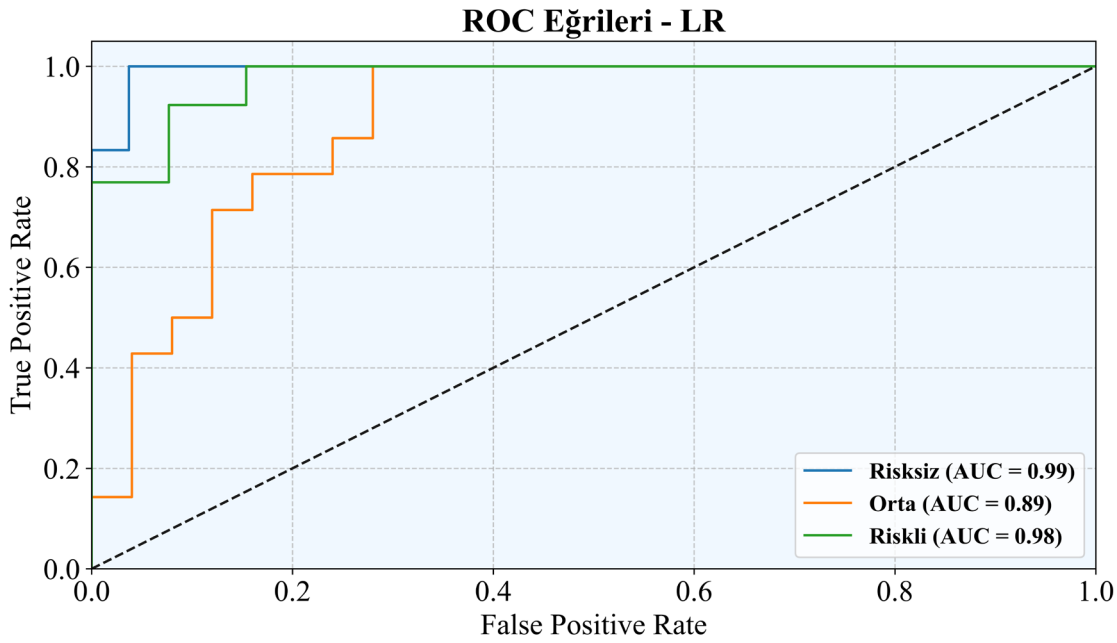
NB modeli, eğitim doğruluğu %84,62 ve test doğruluğu %79,49 olarak ölçülmüştür. Eğitim ve test doğruluğu arasındaki fark diğer modellere göre daha düşük olmakla birlikte, test doğruluğunun %79,49 seviyesinde kalması, modelin genel performansının sınırlı olduğunu göstermektedir. Risksiz sınıfta yüksek doğruluk sergileyen modelin, Orta ve Riskli sınıflarda daha düşük performans sergilediği görülmektedir.

KNN modeli, eğitim doğruluğu %86,81 ve test doğruluğu %69,23 olarak hesaplanmıştır. Test doğruluğunun düşük seviyede kalması, modelin genelleme kapasitesinin zayıf olduğunu açıkça ortaya koymaktadır. Bu durum, modelin özellikle Orta sınıfta düşük performans sergilemesiyle de tutarlıdır.

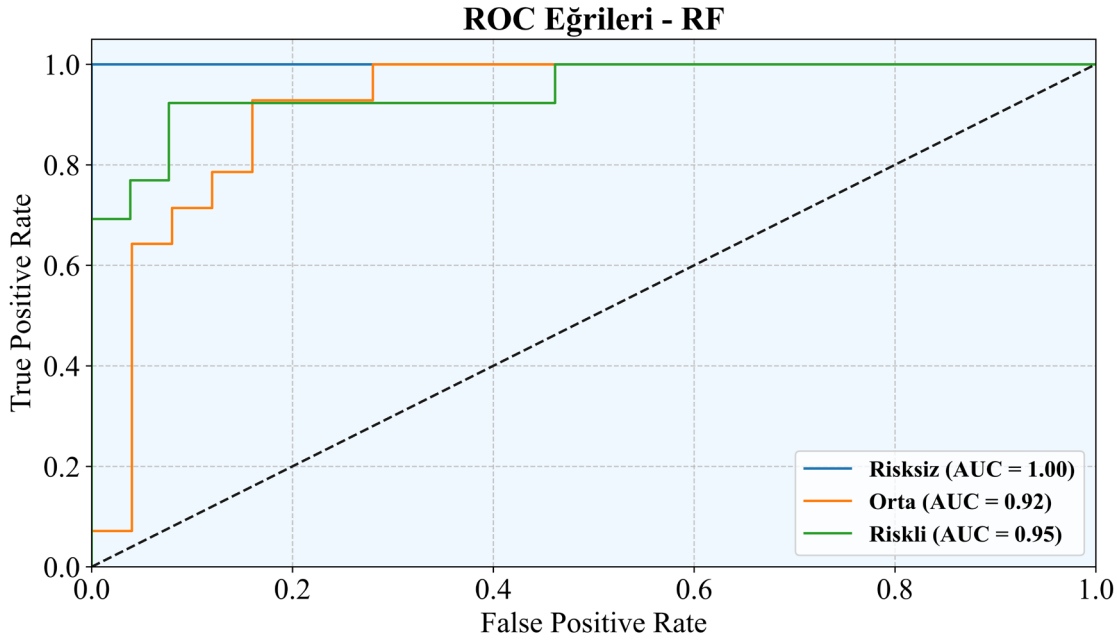
SVM modeli, eğitim doğruluğu %94,51 ve test doğruluğu %92,31 ile diğer modeller arasında en yüksek test doğruluğuna sahip olmuştur. Eğitim ve test doğrulukları arasındaki farkın az olması, modelin genelleme kapasitesinin güçlü olduğunu göstermektedir.

Genel olarak, SVM modeli doğruluk açısından en başarılı model olarak öne çıkarken, RF modeli de yüksek test doğruluğu ile güçlü bir alternatif sunmaktadır. NB ve KNN modelleri test doğruluğu açısından düşük performans göstermiş ve genelleme kapasitesinde sınırlamalar sergilemiştir. LR modeli ise Risksiz sınıfta yüksek doğruluk sağlasa da Orta ve Riskli sınıflardaki performans düşüşleri, modelin dengesiz bir başarıya sahip olduğunu göstermektedir.

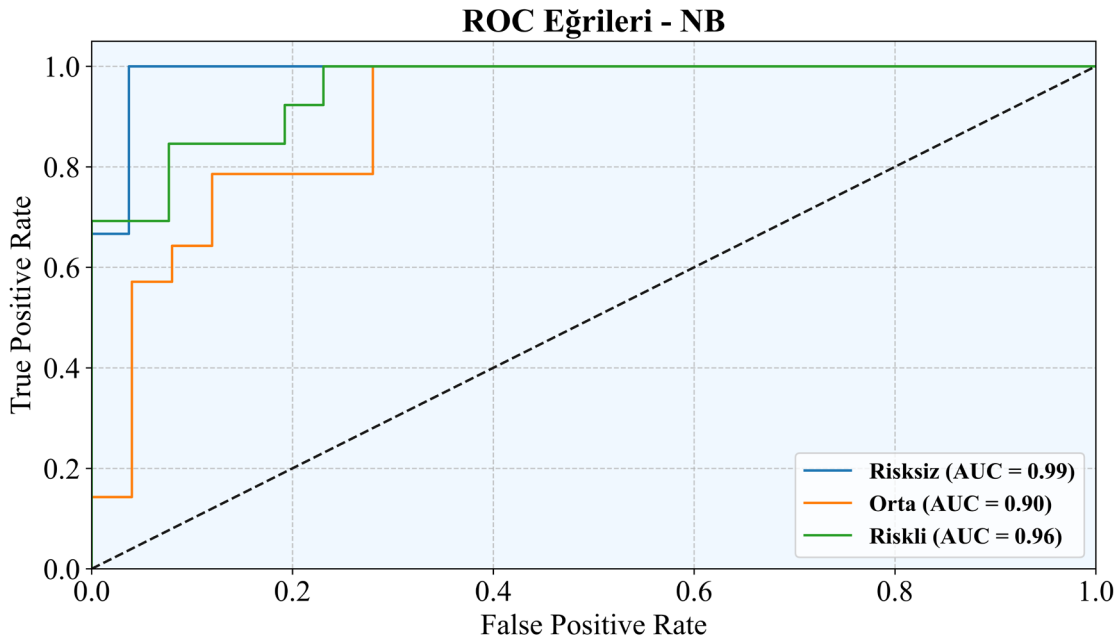
ROC (Receiver Operating Characteristic) eğrileri, modellerin sınıf ayrım yeteneklerini değerlendirmek için önemli bir araç sunmakta olup doğru pozitif oran (True Positive Rate) ile yanlış pozitif oran (False Positive Rate) arasındaki ilişkiyi göstermektedir. Bu eğriler ve bunların altında kalan alan (AUC - Area Under the Curve) değerleri, modellerin performansını karşılaştırmak amacıyla Şekil 81, 82, 83, 84 ve 85'te sunulmuştur.



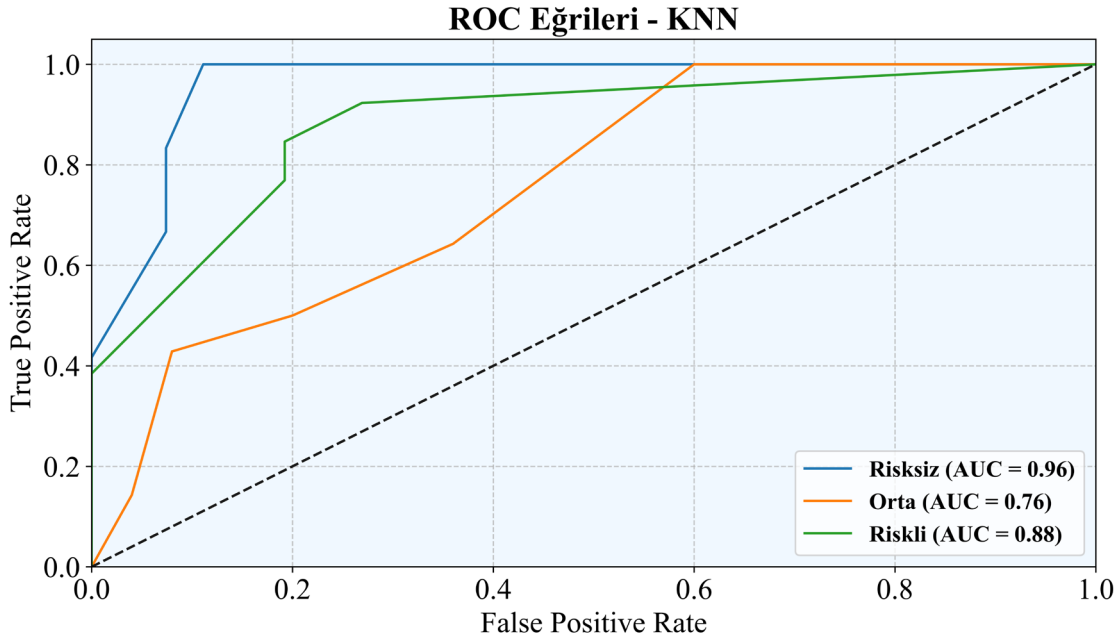
Şekil 81. LR modeli ROC eğrisi



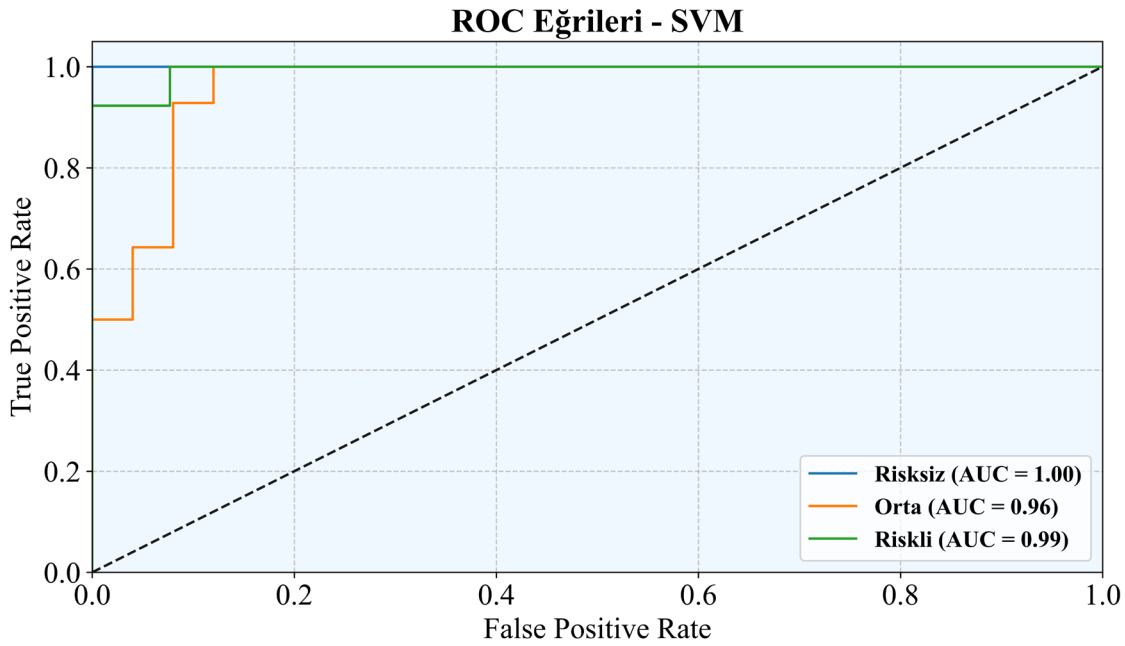
Şekil 82. RF modeli ROC eğrisi



Şekil 83. NB modeli ROC eğrisi



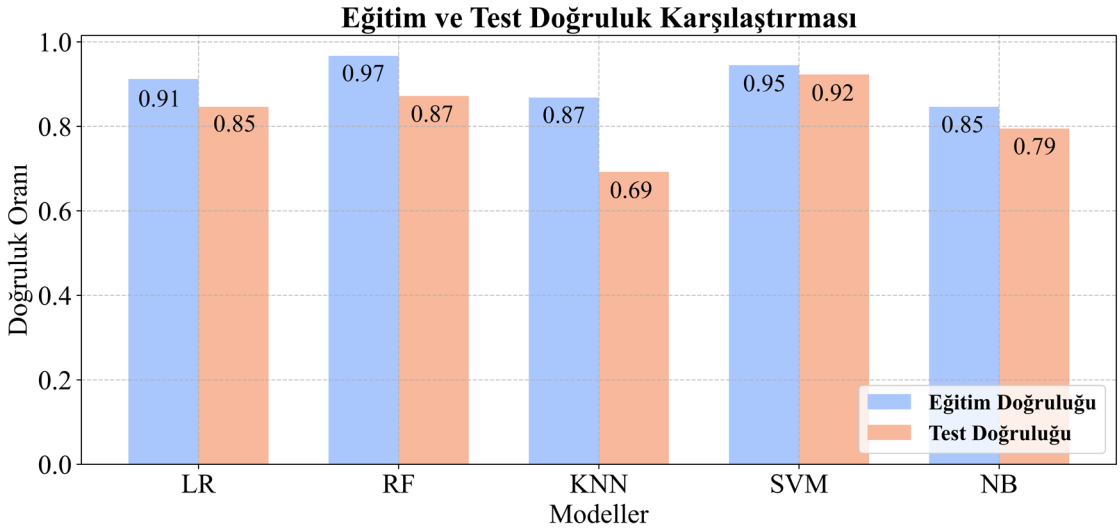
Şekil 84. KNN modeli ROC eğrisi



Şekil 85. SVM modeli ROC eğrisi

SVM modelinin AUC değerleri, 'Risksiz', 'Orta' ve 'Riskli' sınıflarında sırasıyla 1.00, 0.96 ve 0.99 olarak hesaplanmıştır. Bu değerler, SVM modelinin sınıf ayrımında oldukça başarılı bir performans sergilediğini göstermektedir. Benzer şekilde, RF modeli de 'Risksiz', 'Orta' ve 'Riskli' sınıflarında sırasıyla 1.00, 0.92 ve 0.95 AUC değerleri ile yüksek bir performans ortaya koymuştur. Buna karşılık, KNN modeli özellikle 'Orta' sınıfta düşük bir AUC değeri (0.76) ile sınırlı bir performans göstermiştir. Bu durum, KNN modelinin bu sınıfta sınıf ayrımı konusunda yetersiz kaldığını açıkça ortaya koymaktadır.

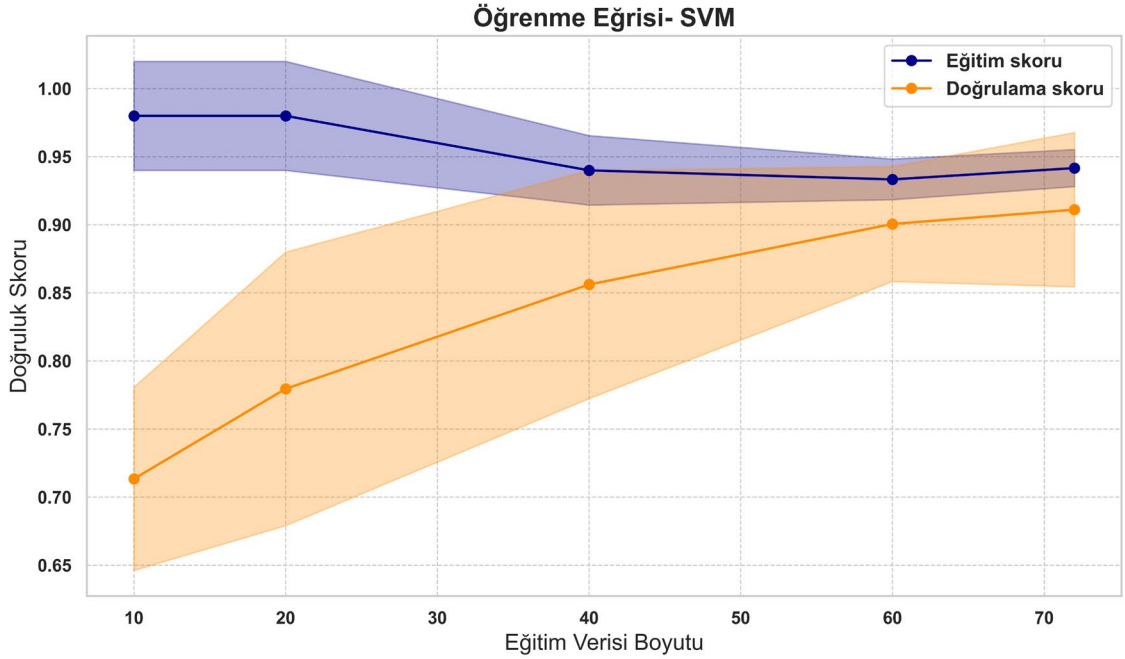
Şekil 86' da verilen eğitim ve test doğruluk oranlarının karşılaştırılması, modellerin genelleme performansını değerlendirmek açısından önemli bir ölçüt sunmaktadır.



Şekil 86. Modellerin eğitim-test doğruluğu karşılaştırması

SVM modeli, 0.95 eğitim doğruluğu ve 0.92 test doğruluğu ile aralarındaki 0.02'lik fark sayesinde genelleme başarısını açıkça ortaya koymuştur. RF modeli ise eğitim doğruluğunda 1.00 gibi yüksek bir değer elde etmiş olmasına rağmen test doğruluğunun 0.87'ye düşmesi, modelin aşırı uyuma eğilimli olduğunu göstermektedir. KNN modelinde ise eğitim doğruluğu ile test doğruluğu arasındaki 0.18'lik fark, bu modelin genelleme performansının zayıf olduğunu ve aşırı uyuma daha yatkın bir yapıya sahip olduğunu ortaya koymaktadır.

Öğrenme eğrisi, modelin farklı eğitim veri boyutlarında nasıl performans gösterdiğini değerlendirmek amacıyla 5 katlı çapraz doğrulama (cross-validation) yöntemiyle oluşturulmuştur (Şekil 87).



Şekil 87. Modellerin öğrenme eğrileri

Şekilde, SVM modeli için eğitim ve doğrulama doğruluk skorlarının eğitim veri boyutuna bağlı değişimi gösterilmektedir. Eğitim skorları başlangıçta yaklaşık %100 seviyesindedir, bu durum modelin küçük veri kümelerinde aşırı uyum sağladığını ortaya koymaktadır. Ancak eğitim veri boyutu arttıkça bu skor %95 düzeyine ulaşmış ve daha dengeli bir performans sergilemeye başlamıştır. Bu durum, modelin artan veri ile aşırı uyumdan uzaklaşarak genelleme yeteneğini geliştirdiğini göstermektedir. Doğrulama skorları ise başlangıçta düşük seviyelerde (%70 civarında) olup, veri boyutunun artmasıyla düzenli bir artış göstermektedir ve eğitim skorlarına yaklaşmaktadır. Bu durum, artan veri miktarının modelin genelleme performansını iyileştirdiğine işaret etmektedir. Eğitim ve doğrulama skorları arasındaki fark, küçük veri kümelerinde oldukça belirginken, veri boyutunun artmasıyla azalmış ve her iki skor %95 seviyesinde dengelenmiştir. Gölgeli alanlar, doğrulama skorlarında özellikle küçük veri boyutlarında görülen yüksek varyansı işaret etmekte ve bu varyansın veri boyutunun artmasıyla azaldığı anlaşılmaktadır.

Beş farklı modelin (LR, RF, NB, KNN, SVM) optimizasyon öncesi ve sonrası performans metrikleri karşılaştırılmıştır. Her bir model için sınıf bazında duyarlılık, kesinlik ve F1 skoru ile genel doğruluk, makro ortalama ve ağırlıklı ortalama değerleri Tablo 32'de sunulmuştur.

Tablo 32. Hiperparametre optimizasyonunun modeller üzerindeki etkisi

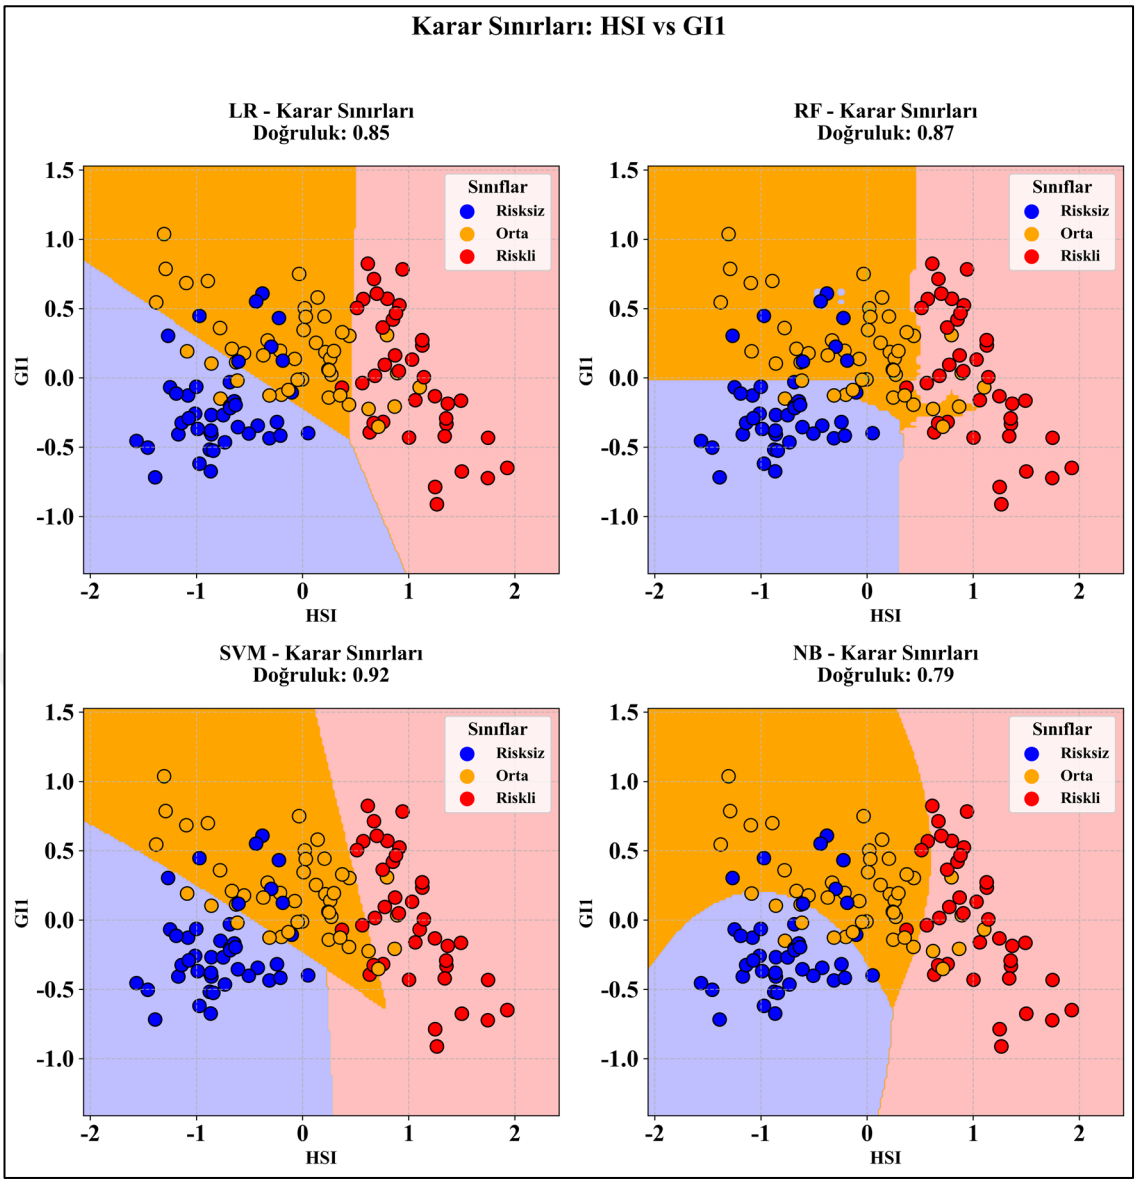
Model	Optimizasyon Öncesi				Optimizasyon Sonrası			
	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Sınıf	Kesinlik	Duyarlılık	F1 Skoru
LR	Risksiz	1.00	0.92	0.96	Risksiz	0.92	1.00	0.96
	Orta	0.73	0.79	0.76	Orta	0.79	0.79	0.79
	Riskli	0.77	0.77	0.77	Riskli	0.83	0.77	0.80
	Doğruluk		0.82		Doğruluk		0.85	
	Makro Ort.	0.83	0.82	0.83	Makro Ort.	0.85	0.85	0.85
	Ağırlıklı Ort.	0.83	0.82	0.83	Ağırlıklı Ort.	0.84	0.85	0.85
RF	Risksiz	1.00	1.00	1.00	Risksiz	0.92	1.00	0.96
	Orta	0.75	0.86	0.80	Orta	0.77	0.93	0.84
	Riskli	0.82	0.69	0.75	Riskli	1.00	0.69	0.82
	Doğruluk		0.85		Doğruluk		0.87	
	Makro Ort.	0.86	0.85	0.85	Makro Ort.	0.90	0.87	0.87
	Ağırlıklı Ort.	0.85	0.85	0.85	Ağırlıklı Ort.	0.89	0.87	0.87
NB	Risksiz	0.92	0.92	0.92	Risksiz	0.92	0.92	0.92
	Orta	0.64	0.64	0.64	Orta	0.69	0.79	0.74
	Riskli	0.69	0.69	0.69	Riskli	0.82	0.69	0.75
	Doğruluk		0.74		Doğruluk		0.79	
	Makro Ort.	0.75	0.75	0.75	Makro Ort.	0.81	0.80	0.80
	Ağırlıklı Ort.	0.74	0.74	0.74	Ağırlıklı Ort.	0.80	0.80	0.80
KNN	Risksiz	0.91	0.83	0.87	Risksiz	0.83	0.83	0.83
	Orta	0.55	0.43	0.48	Orta	0.58	0.50	0.54
	Riskli	0.59	0.77	0.67	Riskli	0.67	0.77	0.72
	Doğruluk		0.67		Doğruluk		0.69	
	Makro Ort.	0.68	0.68	0.68	Makro Ort.	0.69	0.70	0.70
	Ağırlıklı Ort.	0.67	0.67	0.66	Ağırlıklı Ort.	0.69	0.69	0.69
SVM	Risksiz	0.86	1.00	0.92	Risksiz	0.92	1.00	0.96
	Orta	0.80	0.57	0.67	Orta	0.87	0.93	0.90
	Riskli	0.73	0.85	0.79	Riskli	1.00	0.85	0.92
	Doğruluk		0.79		Doğruluk		0.92	
	Makro Ort.	0.80	0.81	0.80	Makro Ort.	0.93	0.93	0.93
	Ağırlıklı Ort.	0.80	0.80	0.79	Ağırlıklı Ort.	0.93	0.92	0.93

Tablo incelendiğinde, hiperparametre optimizasyonunun modellerin performansı üzerinde genel bir iyileştirme sağladığı görülmektedir. Doğruluk değerlerinde en belirgin artış, SVM modelinde (%79'dan %92'ye) gözlemlenmiştir. RF modelinin doğruluk değeri %85'ten %87'ye, NB modelinin doğruluk değeri ise %74'ten %79'a artış göstermiştir. LR modelinde de %82'den %85'e bir iyileşme gerçekleşmiştir. Ancak KNN modelinde doğruluk değerinde yalnızca sınırlı bir artış gözlenmiştir (%67'den %69'a). Bu durum, hiperparametre optimizasyonunun modelin performansını artırma kapasitesinin model türüne göre farklılık gösterebileceğini ifade etmektedir. Sınıf bazındaki metriklerde de belirgin değişimler tespit edilmiştir. Özellikle SVM modelinde

tüm sınıflar için duyarlılık, kesinlik ve F1 skorlarında anlamlı artışlar sağlanmıştır. RF modelinde, özellikle orta risk grubunda duyarlılık %86'dan %93'e yükselmiş ve modelin bu sınıfı ayırt etme yeteneği artmıştır. Diğer yandan, KNN modeli sınıflandırma performansında özellikle 'riskli' sınıfında bir iyileşme kaydetmiştir (duyarlılık %73'ten %100'e). Ancak 'orta' sınıfında duyarlılıkta düşüş yaşanmıştır. Makro ve ağırlıklı ortalama metrikler açısından değerlendirildiğinde, optimizasyon sonrası değerlerin genellikle arttığı görülmüştür. Özellikle SVM modeli, optimizasyon sonrası her iki ortalamada %80'den %93'e yükselerek en yüksek artışı sağlamıştır. NB ve LR modellerinde de bu ortalamalarda iyileşmeler kaydedilmiştir. Sonuç olarak, hiperparametre optimizasyonu, modellerin performansını artırmada etkili bir strateji olmuştur. Bununla birlikte, bu iyileştirme her model ve sınıf için aynı düzeyde gerçekleşmemiştir. Özellikle SVM modeli, optimizasyon sonrası en yüksek performans artışını sergilerken, KNN modelinde sınırlı bir gelişim sağlanmıştır.

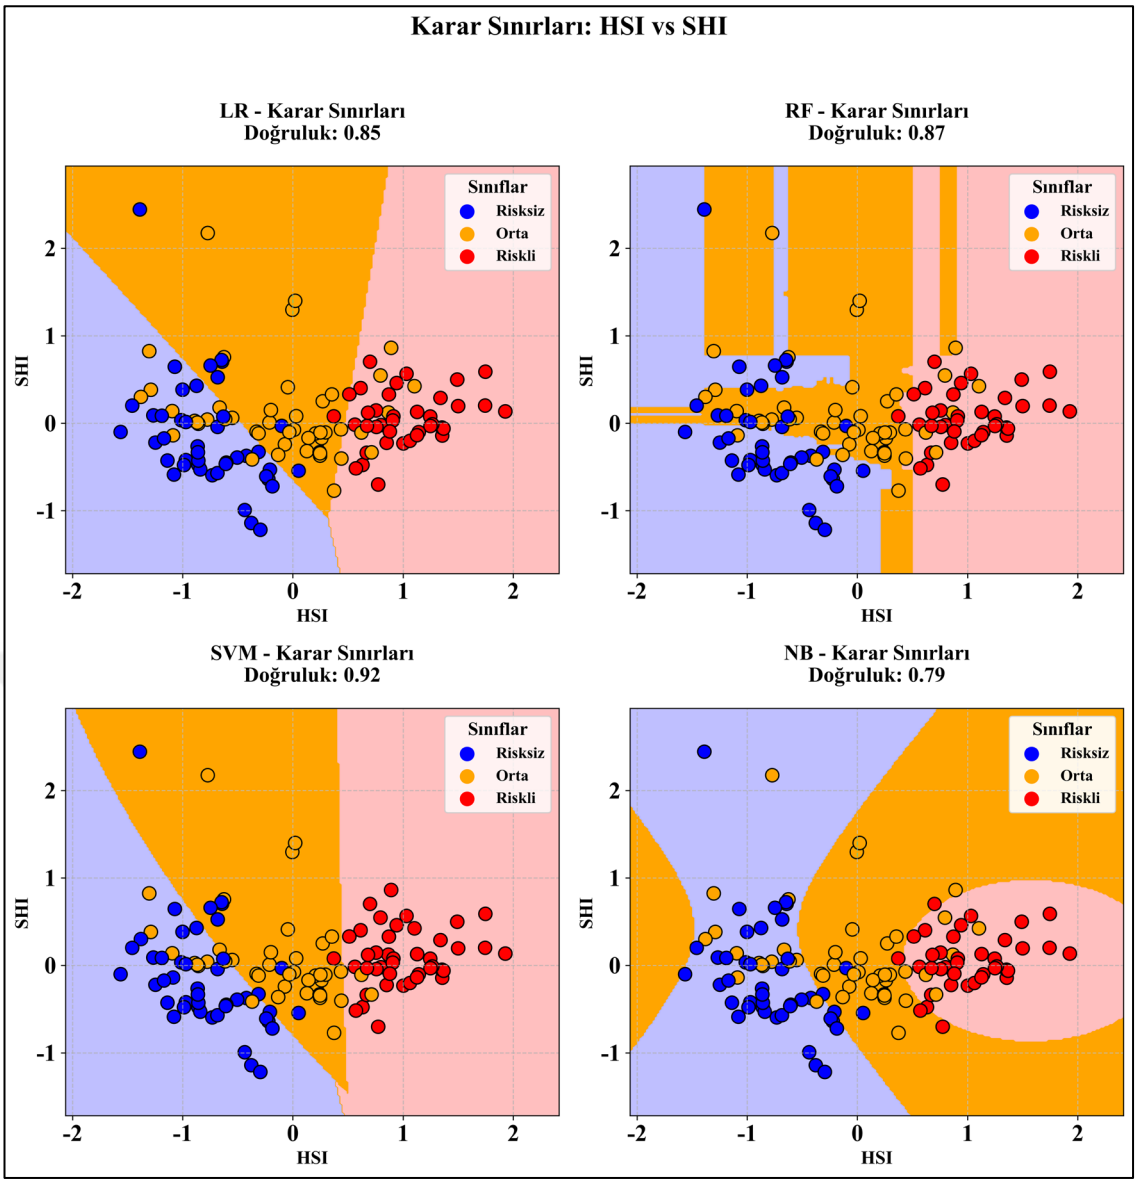
4.5.7. Karar Sınırları ve Tahmin Güvenilirliği

Model performanslarını değerlendirmek ve sınıflandırma modellerinin açıklanabilirliğini artırmak amacıyla modellerin karar sınırlarının görselleştirilmesi yaygın olarak kullanılan bir yöntemdir. Sınıflandırma modellerine ait karar sınırları, farklı bileşenler özelinde analiz edilmiştir. Tüm bileşenlerin görselleştirilmesi, fazla sayıda görsel oluşmasına neden olabileceği için Hız ve Şerit Disiplini İndeksi, Senaryolar Hız İndeksi ve Genel İndeks 1 tercih edilmiştir. Bu analizlere ait karar sınırları Şekil 88 ve 89'da sunulmuştur. Söz konusu şekiller, modellerin sınıflandırma süreçlerindeki ayrım yeteneklerini daha iyi anlamak ve değerlendirmek için önemli bir yöntemdir.



Şekil 88. HSI ve GI1 karar sınırları

Şekil 88, HSI (Hız ve Şerit Disiplini İndeksi) ile GI1 (Genel İndeks 1) arasındaki kombinasyona dayalı olarak sınıflandırma modellerinin oluşturduğu karar sınırlarını göstermektedir. Örneğin, SVM modeli, sınıflar arasında en net ayrımı yapmış ve doğruluk oranı 0.92 olarak hesaplanmıştır. Buna karşılık, NB modeli, daha yayılmış ve belirsiz karar sınırları sergilemiş ve doğruluk oranı 0.79 seviyesinde kalmıştır. RF modeli doğruluk skoru olarak SVM modelini takip etmektedir ancak karar sınırlarındaki belirsizlikler nedeniyle LR modelinin gerisinde kalmaktadır.



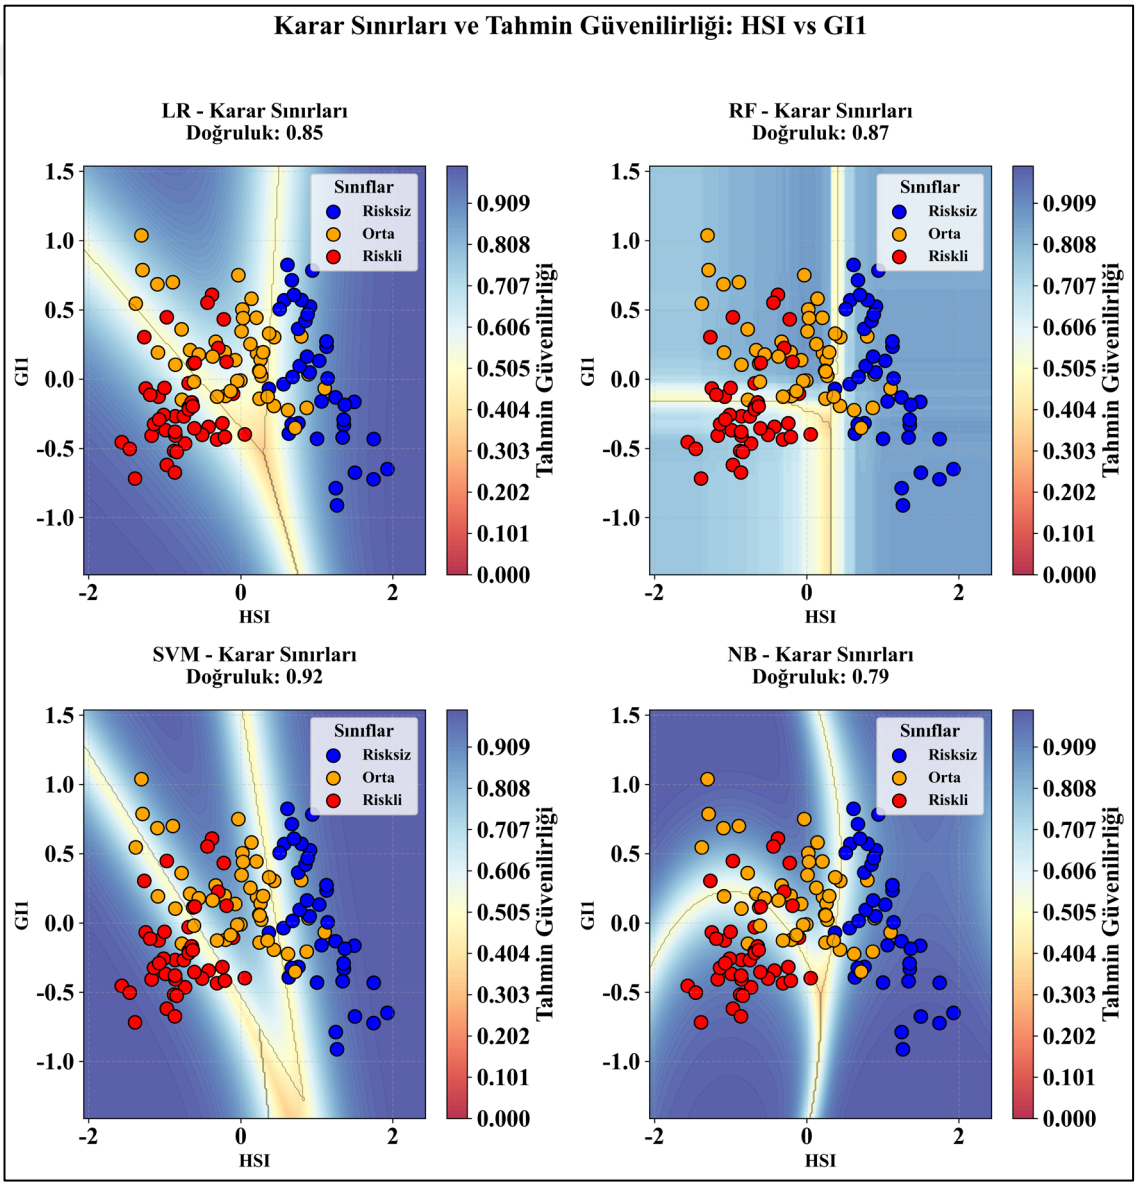
Şekil 89. HSI ve SHI karar sınırları

Şekil 89, (HSI ve SHI kombinasyonu), sınıflandırıcıların HSI ve SHI (Senaryo Hız İndeksi) arasında oluşturduğu karar sınırlarını göstermektedir. SVM modeli burada da en iyi performansı göstermiş ve sınıflar arasındaki ayrımı başarıyla sağlamıştır. RF modeli ise doğruluk açısından SVM'yi takip etmektedir ancak bu bileşenler özelinde değerlendirildiğinde karar sınırlarındaki belirsizlikler göze çarpmaktadır. Şekil 90, sınıflandırıcıların yalnızca doğruluk açısından değil, aynı zamanda karar sınırlarının doğasına ilişkin önemli ipuçları sunduğunu göstermektedir.

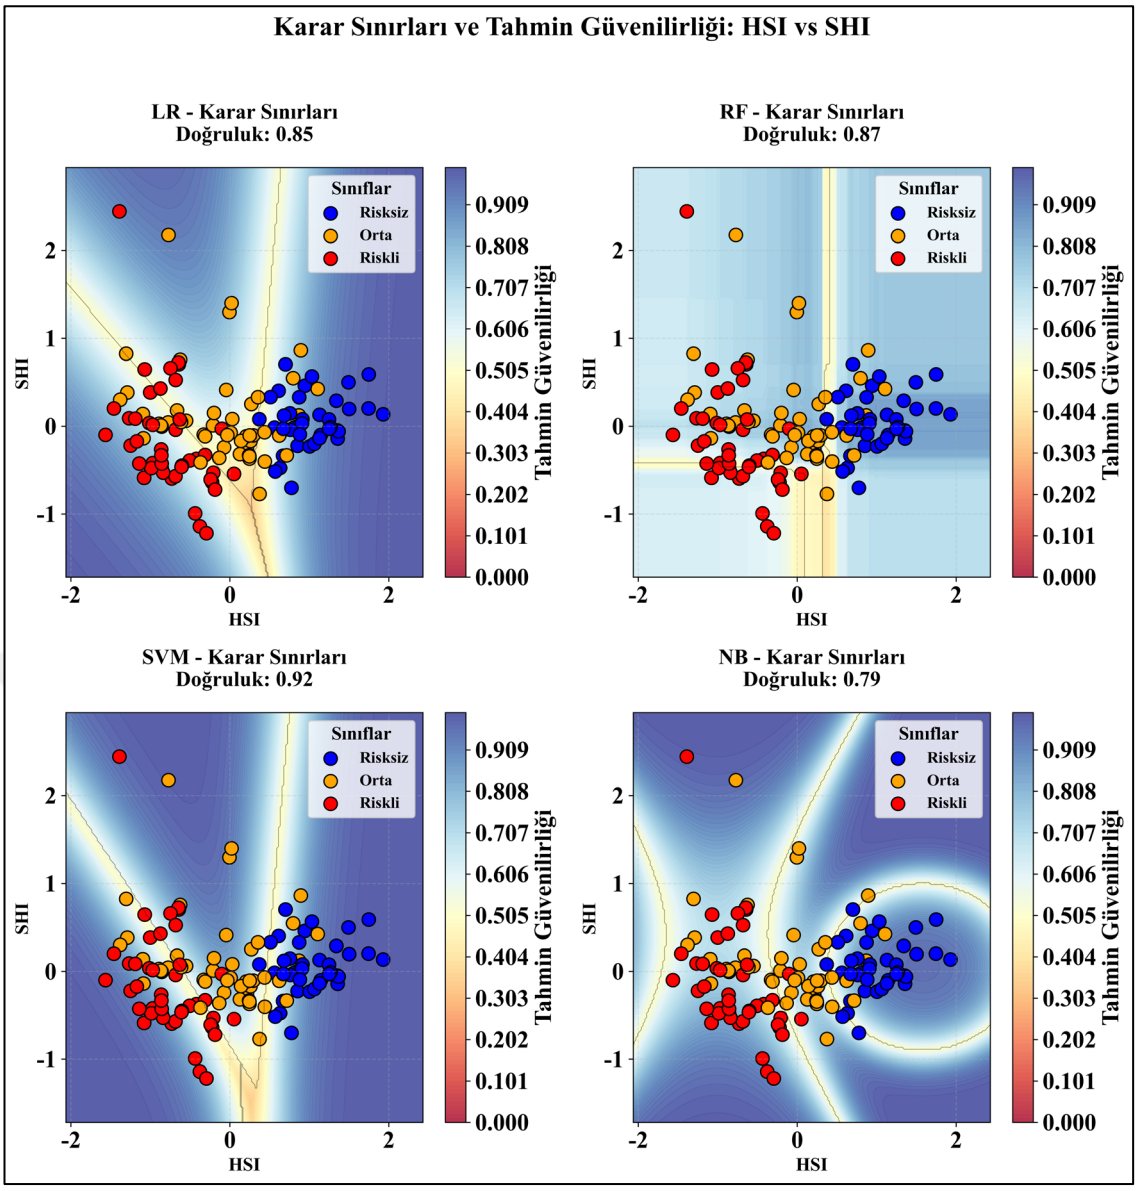
Sonuç olarak, SVM modelinin doğrusal olmayan ayrımlarda diğer modellere göre üstün performans sergilediği açıkça görülmektedir. Bununla birlikte, LR modeli, doğruluk skoru bakımından RF modelinin gerisinde kalmasına rağmen, SVM modeline kıyasla daha düzgün ve düzenli karar sınırları oluşturmuştur. Ancak SVM modeli hem

karar sınırlarının doğası hem de genel performans açısından diğer modellere kıyasla üstün bir performans sergilemiştir.

Karar sınırları ve tahmin güvenilirliği görselleri, sınıflandırma modellerinin performansını değerlendirmek için kullanılan bir diğer önemli kriterdir. Bu bağlamda, karar sınırları ve modellerin tahmin güvenilirlikleri Şekil 90 ve 91'de sunulmuştur. Şekiller, dört farklı sınıflandırma modelinin (LR, RF, SVM ve NB) karar sınırlarını ve tahmin güvenilirliklerini HSI ve SHI öznitelikleri üzerinden karşılaştırmalı olarak sunmaktadır. Her modelde kullanılan renk gradyanı, tahmin güvenilirlik seviyelerini 0.000 ile 0.909 arasında bir skala ile temsil etmektedir. Koyu mavi alanlar yüksek güvenilirliği, açık sarı alanlar ise düşük güvenilirlik seviyelerini göstermektedir.



Şekil 90. HSI ve GI1 karar sınırları ve tahmin güvenilirliği



Şekil 91. HSI ve SHI karar sınırları ve tahmin güvenilirliği

SVM modeli, 0.92 doğruluk oranı ile en iyi performansı sergileyerek geniş koyu mavi alanlar ve ince sarı bantlarla yüksek güvenilirlik sunmuştur. RF modeli, 0.87 doğruluk oranıyla ikinci sırada yer almakta ve daha yumuşak geçişli güvenilirlik bölgeleri göstermektedir. LR modeli, 0.85 doğruluk oranı ile doğrusal karar sınırları etrafında düzenli bir güvenilirlik geçişi sergilerken, NB modeli 0.79 doğruluk oranıyla en düzensiz ve dalgalı güvenilirlik dağılımına sahiptir. Veri noktalarının dağılımı, risksiz (mavi), orta (turuncu) ve riskli (kırmızı) sınıfların belirgin şekilde kümelendiğini göstermektedir. SVM modelinin bu kümeleri ayırmadaki başarısı hem doğruluk oranına hem de güvenilirlik dağılımına yansımıştır. Karar sınırlarına yaklaşıldıkça güvenilirliğin azalması, modellerin geçiş bölgelerinde temkinli tahminler yaptığını göstermektedir.

Şekiller, modellerin yalnızca performansını değil, aynı zamanda tahmin güvenilirliklerini de etkili bir şekilde değerlendirme imkânı sunmaktadır.

Optimizasyon sonrası yapılan tüm değerlendirmeler şu şekilde özetlenebilmektedir;

• SVM modeli, değerlendirme kriterlerinin tamamında üstün performans sergilemiş ve %92.31 doğruluk oranıyla en iyi sonuçları elde etmiştir.

• RF modeli, doğruluk performansı açısından SVM modelini takip etmiş ancak karar sınırları değerlendirmesinde hem SVM modelinin hem de LR modelinin gerisinde kalmıştır.

• LR modeli, doğruluk oranı bakımından RF modelinin gerisinde kalmasına rağmen daha keskin karar sınırları oluşturarak RF modelini bu açıdan geride bırakmış ancak genel performansta SVM modelinin altında kalmıştır.

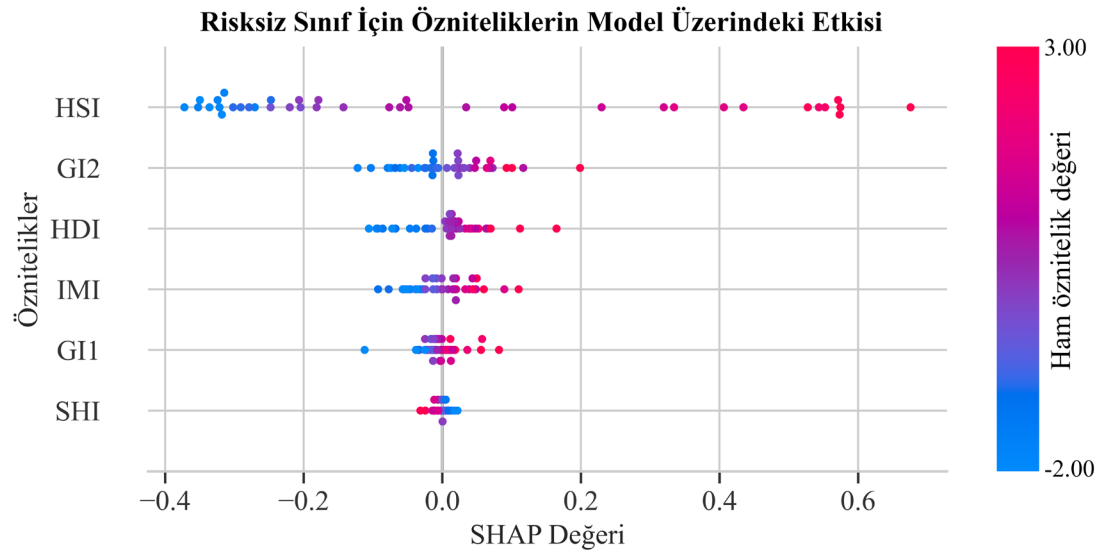
• NB modeli, nispeten düşük doğruluk oranına rağmen karar sınırları açısından görece iyi bir performans sergilemiş ancak diğer modellerin çoğunun gerisinde yer almıştır.

• KNN modeli, optimizasyon sürecinde aşırı uyum problemini çözemezken, genel olarak modeller arasında en düşük performansı göstermiştir.

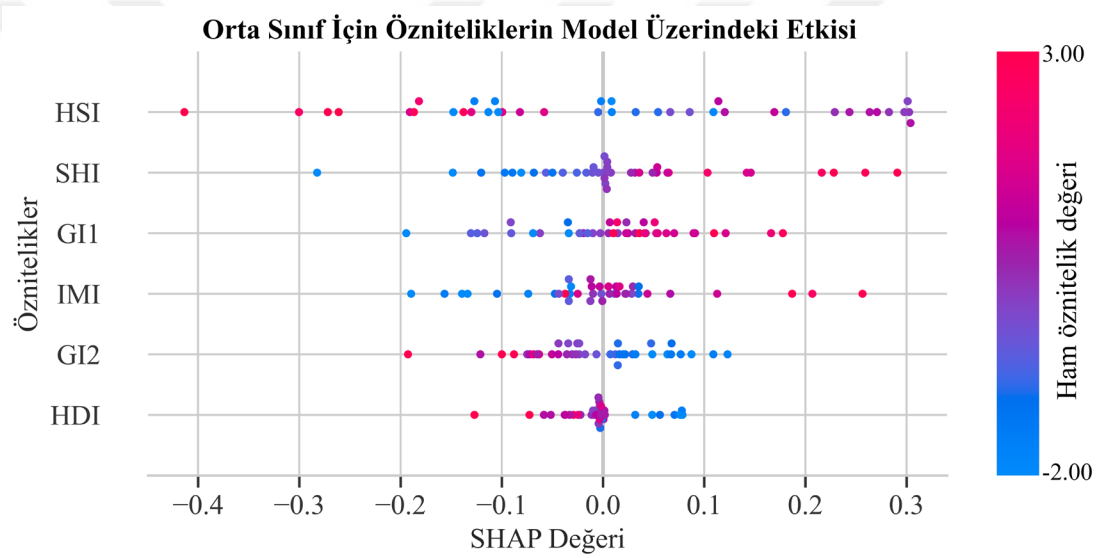
Sonuç olarak, SVM modeli, %92 doğruluk oranı ile tüm modeller arasında en iyi performansı sergilemiş ve en başarılı model olarak öne çıkmıştır. Bu doğrultuda, SVM modelinin açıklanabilirliğini artırmak amacıyla SHAP analizleri gerçekleştirilmiştir.

4.5.8. Özniteliklerin Model Üzerindeki Etkisinin İrdelenmesi

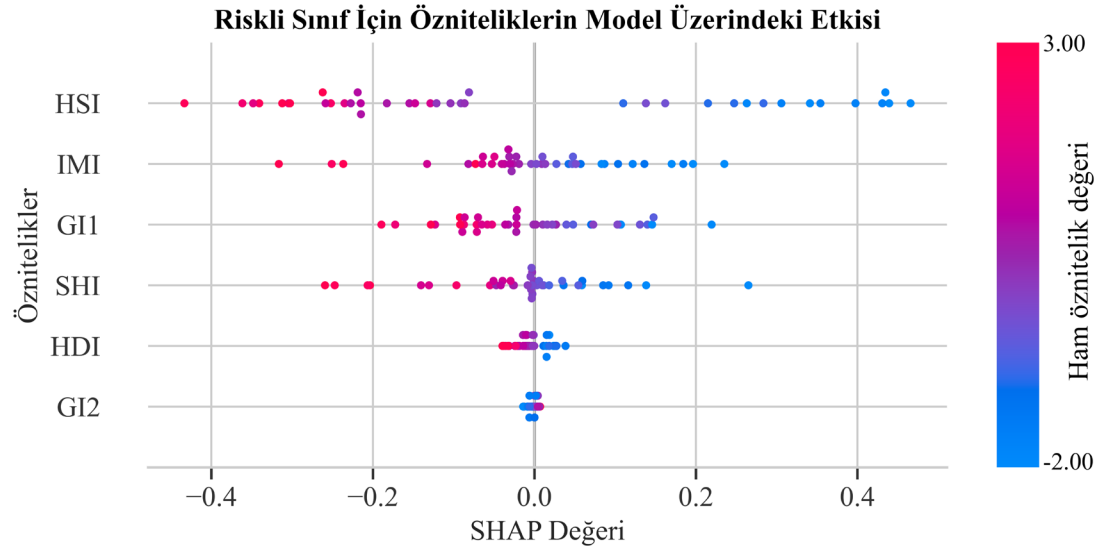
Bu aşamada, en yüksek doğruluk oranına sahip olan SVM modeli için SHAP analizi gerçekleştirilmiştir. SHAP analizi, modelin tahminlerinde hangi özniteliklerin ne ölçüde etkili olduğunu ve bu özniteliklerin model çıktısını nasıl şekillendirdiğini açıklamaya yardımcı olan matematiksel temelli bir yorumlanabilirlik yöntemi olarak kullanılmıştır. Analiz, tüm veri seti üzerinde özniteliklerin genel önem derecelerini ortaya koymanın yanı sıra, her bir örnek için özniteliklerin bireysel katkılarını da detaylı bir şekilde göstermektedir. Bu bağlamda, yalnızca SVM modeli için her bir sınıfa özel öznitelik açıklamaları Şekil 92, 93 ve 94'te, tüm sınıflara ilişkin özet ise Şekil 95'te sunulmuştur.



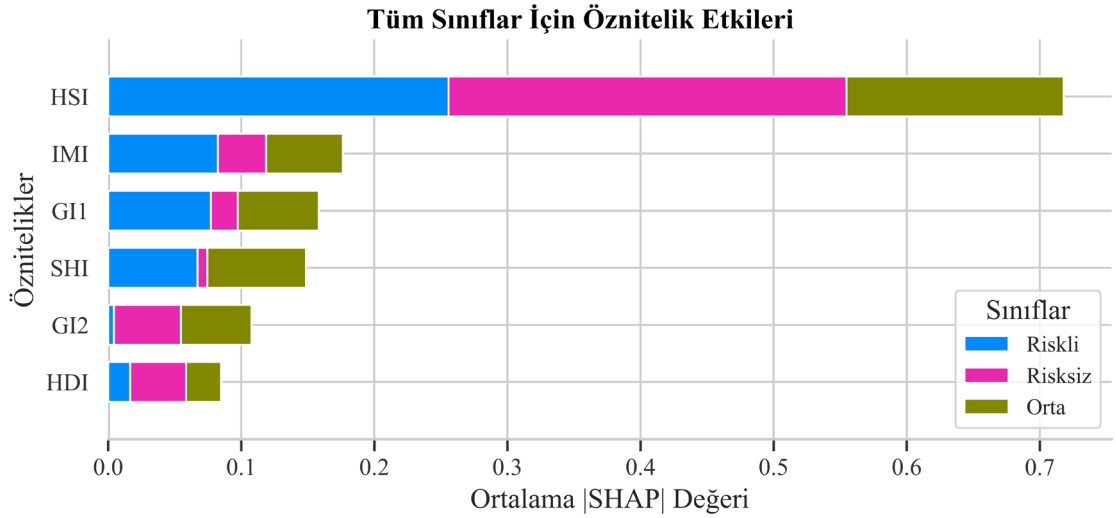
Şekil 92. Özniteliklerin risksiz sınıfı ayırmadaki etkisi



Şekil 93. Özniteliklerin orta riskli sınıfı ayırmadaki etkisi



Şekil 94. Özniteliklerin riskli sınıfı ayırmadaki etkisi



Şekil 95. Tüm sınıflar için SHAP özet grafiği

SVM modeli için gerçekleştirilen SHAP analizi, modelin tahminlerinde özniteliklerin etkisini ve sınıflandırma kararlarını nasıl şekillendirdiğini açıklamayı amaçlamaktadır. Bu analiz, farklı sınıflar için özniteliklerin SHAP değerlerini ve genel etki düzeylerini görselleştirerek modelin karar mekanizmasını daha şeffaf hale getirmektedir. Orta sınıf analizinde, HSI (Hız ve Şerit Disiplini İndeksi) en baskın öznitelik olarak öne çıkmış, diğer özniteliklerin SHAP değerleri sıfır civarında yoğunlaşarak sınıflandırma kararlarına daha az etkili olduğu görülmüştür. Pozitif ve negatif SHAP değerlerinin dengeli dağılımı, modelin sınıfları ayırmadaki hassasiyetini göstermektedir. Riskli sınıf için, HSI ve IMI (İvmelenme İndeksi) belirgin öznitelikler olarak ön plana çıkmıştır. HSI pozitif bir etki sağlarken, IMI'nin daha geniş bir etki alanına sahip olduğu tespit edilmiştir. Bu durum, hız ve ivmelenmenin riskli davranışları tespit etmede kritik bir rol oynadığını ortaya koymaktadır.

Sonuç olarak, Hız ve Şerit Disiplini İndeksi'nin tüm sınıflarda en baskın öznitelik olduğu görülürken İvmelenme indeksi ve Genel İndeks 1 gibi özniteliklerin daha düşük ancak anlamlı katkılar sağladığı belirlenmiştir.

5. SONUÇLAR ve ÖNERİLER

Karayolu tünellerinde sürücü davranışlarının simülatör ortamında analiz edilmesi ve yapay zekâ teknikleriyle sınıflandırılmasını hedefleyen bu çalışmanın, tünel inşaatlarının hızla arttığı Türkiye gibi ülkelerde tünel içi sürüş dinamiklerine yönelik sınırlı sayıdaki araştırmalara önemli katkılar sağlayacağı öngörülmektedir. Çalışma, sürüş güvenliğini artırmaya yönelik veri odaklı yaklaşımlar geliştirerek tünel içi trafik yönetimi süreçlerini optimize etmeyi amaçlamaktadır. Bu kapsamda sunulan yöntemler, karayolu tünellerinde trafik güvenliğinin artırılmasına yönelik yenilikçi çözümler sunmaktadır. Araştırma kapsamında, Erzincan Binali Yıldırım Üniversitesi'nde kurulan Otonom Sürüş Teknikleri ve Sürücü Davranışları Tespit Laboratuvarında 12 senaryo (gerçek koşullarda meydana gelebilecek tehlikeli durumlar) simüle edilerek test edilmiştir. Toplanan veriler doğrultusunda tünellerdeki farklı trafik koşullarının sürücü davranışları üzerindeki etkileri analiz edilmiş ve makine öğrenmesi yöntemleriyle sürücüler sınıflandırılmıştır. Çalışmaya katılan 134 sürücünün sürüş öncesi anket sonuçları incelendiğinde; katılımcıların %72.39'u erkek, %27.61'i kadın sürücülerden oluşmuştur. Yaş dağılımında 31-45 yaş aralığı %50 ile en büyük grubu oluştururken, katılımcıların yaş ortalaması 37.87 (SS=10.60) olarak belirlenmiştir. Sürücülerin ehliyet deneyimleri incelendiğinde, ortalama 15.95 (SS=9.67) yıllık bir tecrübe gözlemlenmiş ve katılımcıların %34.33'ünün geçmişte en az bir trafik kazasına karıştığı tespit edilmiştir. Sürüş sonrası simülatör performans ölçeği anketi incelendiğinde, katılımcıların %73.88'i düşük tedirginlik düzeyi bildirirken, %79.85'i mevcut tünellerin güvenliğini orta ve üzeri düzey olarak değerlendirmiştir. Dijital uyarıcıların etkinliği konusunda olumlu bir algı (%61.94) tespit edilmiştir. Katılımcıların büyük çoğunluğu simülatör deneyimini gerçekçi bulmuş ve senaryolara uygun tepkiler verdiğini belirtmiştir.

Etiketleme yöntemi (sürücü puanlama sistemi) yaklaşımıyla katılımcılar üç risk grubuna ayrılmıştır. Sürücülerin %30'u (39 kişi) risksiz, %36.9'u (48 kişi) orta seviyede riskli, %33.1'i (43 kişi) riskli kategoride sınıflandırılmıştır. Risk gruplarının puan dağılımları incelendiğinde, risksiz gruptaki sürücüler 65.27-81.77 aralığında (ortalama 70.14), orta risk grubu 57.02-64.33 aralığında (ortalama 61.45) ve riskli grup 44.78-56.99 aralığında (ortalama 52.11) puan almıştır. Sürüş parametreleri değerlendirildiğinde, 75 km/sa değerinin kritik bir hız eşiği oluşturduğu tespit edilmiştir. Bu hızın altında seyreden sürücülerin çoğunlukla 65 puan üzerinde performans gösterdiği, üzerinde seyreden sürücülerin ise genellikle 57 puanın altında kaldığı gözlenmiştir.

Şerit değiştirme davranışı tek başına belirleyici olmamakla birlikte, diğer sürüş parametreleriyle birlikte değerlendirildiğinde anlamlı bir risk göstergesi oluşturmuştur.

Veri setindeki doğrusal olmayan ilişkiler nedeniyle Kernel PCA yöntemi kullanılarak boyut indirgeme gerçekleştirilmiştir. Optimum bileşen sayısının belirlenmesinde AIC, BIC değerleri, kümülatif açıklanan varyans oranı, çekirdek matrisinin özdeğerleri ve rekonstrüksiyon hatası metrikleri değerlendirilmiştir. Analizler sonucunda 6 bileşenin seçilmesine karar verilmiş olup, bu bileşenlerle toplam varyansın %91.2'si açıklanmıştır. Yeni bileşenler ile orijinal öznitelikler arasındaki ilişkiler incelendiğinde, Bileşen 1 (HSI) ortalama hız (-0.73), hız limitine uyma (0.72) ve şerit değişim sayısı (-0.80) ile yüksek korelasyon göstermiştir. Bileşen 2 (IMI) ani ivmelenme sayısı (-0.87) ve ortalama ivme (-0.81) ile güçlü ilişki sergilemiştir. Bileşen 3 (HDI) ortalama yanal mesafe (0.56), ortalama hız (0.55) ve hız limitine uyma (-0.53) parametreleriyle orta düzeyde korelasyon göstermiştir. Bileşen 4 (SHI) senaryo hız değişim oranı (0.65) ile belirgin ilişki sergilemiştir. Bileşen 5 ve 6 ise özniteliklerle güçlü korelasyonlar göstermemiş ve genel indeksler olarak değerlendirilmiştir.

Modellerin sınıflandırma başarısını maksimize etmek amacıyla GridSearchCV kullanılarak hiperparametre optimizasyonu gerçekleştirilmiştir. Bu süreç sonunda, en yüksek performansı %92.31 doğruluk oranı ile SVM modeli göstermiştir. RF modeli %87 doğruluk oranıyla ikinci en iyi performansı sergilerken, bunu %85 ile LR modeli takip etmiştir. KNN modelinde 5 komşu sayısı ve Öklid mesafe metriği kullanılarak %69 doğruluk elde edilmiş, NB ise %79'luk bir başarı göstermiştir.

Sınıflandırma modellerinin performansını değerlendirmek için karar sınırları ve tahmin güvenilirliği analizleri gerçekleştirilmiştir. Hız ve Şerit Disiplini İndeksi (HSI), Senaryo Hız İndeksi (SHI) ve Genel İndeks 1 (GI1) kombinasyonları üzerinden yapılan değerlendirmeler sonucunda, SVM modeli karar sınırlarında net ayrımlar oluşturmuş ve yüksek güvenilirlik seviyeleri (0.909) sergilemiştir.

Çalışmada kullanılan yapay zekâ teknikleri, tünel içi sürücü davranışlarının objektif ve sistematik bir şekilde değerlendirilmesine olanak sağlamıştır. Boyut indirgeme teknikleri ile veri setinin karmaşıklığı azaltılırken, hiperparametre optimizasyonu sayesinde model performansı maksimize edilmiştir. Çalışmada geliştirilen yapay zekâ modeli, otonom araçlar ve akıllı uyarı sistemlerine entegre edilebilir bir yapı sunmaktadır. %92'lik doğruluk oranıyla sürücüleri sınıflandırabilen sistem, tünel girişlerinde ve içinde risk seviyesine göre özelleştirilmiş uyarılar üretebilecek potansiyele sahip olduğu düşünülmektedir. Özellikle Hız ve Şerit Disiplini İndeksi (HSI) ile Senaryo Hız İndeksi (SHI) parametrelerinin yüksek ayırt edici gücü, gerçek zamanlı risk değerlendirmesi

yapılmasına olanak tanımaktadır. Bu sistemin, tünel yönetimi ile araç arası iletişimin sağlanabildiği durumlarda sürücü güvenliğini artırma potansiyeline sahip olduğu ve gelecekteki akıllı ulaşım sistemlerine entegre edilebilecek nitelikte olduğu düşünülmektedir.

Çalışmada kullanılan denetimli öğrenme yöntemlerinin başarılı sonuçları, gelecekte pekiştirmeli öğrenme yaklaşımlarının kullanılmasına zemin hazırlayabilecektir. Pekiştirmeli öğrenme, sürücü davranışlarının dinamik yapısını daha iyi modelleyebilme ve gerçek zamanlı öğrenme potansiyeline sahip olduğundan bu yöntemlerle, çalışmanın daha da geliştirilebileceği öngörülmektedir. Özellikle tünel içi değişen koşullara (trafik yoğunluğu, taşıt kompozisyonu, hava şartları, görüş mesafesi) göre sürücü davranışlarının sürekli öğrenilmesi ve uyarı sistemlerinin dinamik olarak güncellenmesi mümkün olabilecektir. Pekiştirmeli öğrenme algoritmaları, mevcut çalışmada elde edilen %92.31'lik sınıflandırma başarısını interaktif öğrenme süreciyle daha da iyileştirebilecektir. Ayrıca, sürücülerin risk faktörlerini gerçek zamanlı olarak değerlendirip, kişiselleştirilmiş güvenlik önerileri sunabilecek akıllı sistemlerin geliştirilmesine olanak tanıyabilecek potansiyele sahiptir.

Gelecek araştırmalarda, tünel güvenliğini daha kapsamlı analiz etmek amacıyla farklı hava ve yol koşullarında sürücü davranışlarının modellendiği daha geniş kapsamlı veri setleri kullanılmalıdır. Sürücü davranışlarının çevresel faktörlerle ilişkisini anlamak için mevsimsel değişimleri de içeren uzun süreli çalışmalar planlanmalıdır. Bu bağlamda, simülatör deneylerinin gerçek tünel verileriyle karşılaştırmalı analizi yapılmalı ve oluşturulan modellerin gerçek koşullardaki performansı detaylı bir şekilde değerlendirilmelidir. Gelecek çalışmalarda, farklı hava ve yol koşullarını kapsayan daha geniş veri setleriyle çalışılması ve modelin otonom araçlar ile tünel yönetim sistemlerine entegrasyonuyla yapay zekâ tabanlı dinamik karayolu tüneli yönetim sistemlerinin geliştirilmesi planlanmaktadır.

KAYNAKÇA

Abdelouahed, S. M., Abla, R., Asmae, E., ve Abdellah, A. (2024). Harnessing feature engineering to Improve Machine Learning: A review of different data processing techniques. *2024 International Conference on Intelligent Systems and Computer Vision (ISCV)*, 1–6.

Abdelrahman, A. E., Hassanein, H. S., ve Abu-Ali, N. (2022). Robust data-driven framework for driver behavior profiling using supervised machine learning. *IEEE Transactions on Intelligent Transportation Systems*, *23*(4), 3336–3350.

Abe, N. (2018). *2018 IEEE International Conference on Big Data: Proceedings: DEC 10 - DEC 13, 2018, Seattle, WA, USA*. IEEE.

Adar, U. G., ve Altan, Z. (2024). AUTOMIND: Otomobil Ne Kadar "oto"? insan-Otonom Araç Etkileşimi üzerine bir inceleme. *Uludağ University Journal of The Faculty of Engineering*, 623–638.

Aiolli, F., Bunte, K., Hérault, R., ve Kanevski, M. (2016). Special issue: Advances in artificial neural networks, machine learning and computational intelligenceselected papers from the 23rd European Symposium on Artificial Neural Networks (ESANN 2015). *Neurocomputing*, *192*, 1–2.

Akgol, K., Gunay, B., ve Aydin, M. M. (2022). Geometric optimisation of chicanes using driving simulator trajectory data. *Proceedings of the Institution of Civil Engineers - Transport*, *175*(4), 238–248.

Anaissi, A., Kennedy, P. J., ve Goyal, M. (2010). A framework for high dimensional data reduction in the microarray domain. *2010 IEEE Fifth International Conference on Bio-Inspired Computing: Theories and Applications (BIC-TA)*, 903–907.

Aschepkov, V. (2024). Methods for outlier detection in Metrological Studies. *Measuring Equipment and Metrology*, *85*(3), 25–29.

Aydınoğlu, A. Ç., Şişman, S., Şaşmaz, M. A., ve Akın, S. N. (2024). Sürdürülebilir Ulaşım planlamasında CBS tabanlı Otopark Uygunluk Analizi. *Afyon Kocatepe University Journal of Sciences and Engineering*, *24*(3), 628–640.

Azad, A. K., Atkison, T., ve Shah, A. F. (2024). A review on machine learning in Intelligent Transportation Systems Applications. *The Open Transportation Journal*, *18*(1).

Bakar, S., M. A., Mazumder, Md. M., Alam, R., ve Khan, M. (2021). Performance comparison between dimension reduction and feature selection approaches for Data

Classification. *2021 5th International Conference on Computing Methodologies and Communication (ICCMC)*, 893–898.

Bala, B., ve Behal, S. (2024). A brief survey of data preprocessing in machine learning and Deep Learning Techniques. *2024 8th International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*, 1755–1762.

Barakat, Anas, Fatkhullin, Ilyas, ve He, Niao. (2023). *Reinforcement learning with general utilities: Simpler variance reduction and large state-action space*.

Bayliss, B. (1998). *Regulation in the road freight transport sector*.

Benatti, A., ve da F. Costa, L. (2024). On the transient and equilibrium features of growing fractal complex networks. *Chaos, Solitons veamp; Fractals*, *183*, 114904.

Beram, R., ve El-Kotory, A. (2024). Simulation-based assessment of classification methods: Statistical models vs. Machine Learning Algorithms. *The Egyptian Statistical Journal*, *68*(1), 91–124.

Bouajjani, A., Boutglay, W.-A., ve Habermehl, P. (2022). Data-driven numerical invariant synthesis with automatic generation of attributes. *Lecture Notes in Computer Science*, 282–303.

Bouhsissin, S., Sael, N., ve Benabbou, F. (2023). Driver behavior classification: A systematic literature review. *IEEE Access*, *11*, 14128–14153.

Bröcker, J. (2008). Some remarks on the reliability of categorical probability forecasts. *Monthly Weather Review*, *136*(11), 4488–4502.

Caliendo, C., De Guglielmo, M. L., ve Guida, M. (2013). A crash-prediction model for Road Tunnels. *Accident Analysis veamp; Prevention*, *55*, 107–115.

Ceci, R., Patten, C., ve Mårdh, S. (2013). An evaluation of the Interior Design of the Stockholm Bypass Tunnel – a driving simulator study. *Lecture Notes in Computer Science*, 3–11.

Cherrington, M., Thabtah, F., Lu, J., ve Xu, Q. (2019). Feature selection: Filter methods performance challenges. *2019 International Conference on Computer and Information Sciences (ICCIS)*, 1–4.

Chicco, D., Oneto, L., ve Tavazzi, E. (2022). Eleven quick tips for data cleaning and feature engineering. *PLOS Computational Biology*, *18*(12).

Clarke, B. R. (2008). Linear models: The theory and application of analysis of variance. *Wiley Series in Probability and Statistics*.

Cleophas, T. J., ve Zwinderman, A. H. (2013). Support Vector Machines. *Machine Learning in Medicine*, 155–161.

Danišovič, P., Rázga, M., ve Šedivý, Š. (2015). Road tunnel operation and Simulation. *Procedia Engineering*, *111*, 134–141.

Debbarma, T., Pal, T., ve Debbarma, N. (2024). Prediction of dangerous driving behaviour based on vehicle motion. *Procedia Computer Science*, *235*, 1125–1134.

Dimitrov, D. (2024). Digitization and intelligent management systems in transport: An overview of problems and solutions. *Environment Technologies Resources. Proceedings of the International Scientific and Practical Conference*, *2*, 89–96.

Du, W., Dash, A., Li, J., Wei, H., ve Wang, G. (2023). Safety in traffic management systems: A comprehensive survey. *Designs*, *7*(4), 100.

Elliott, I., ve Gosselin, R. A. (2016). Motor vehicle accidents: The scourge of the developing world. *Orthopaedic Trauma in the Austere Environment*, 79–86.

Erdem, Y. (1994). Highway tunnels in Turkey: Opportunities for international transport links. *Tunnelling and Underground Space Technology*, *9*(4), 455–459. https://doi.org/10.1016/0886-7798(94)90104-x

Erdoğan, H. T. (2016). Ulaşım Hizmetlerinin Ekonomik Kalkınma üzerine Etkisi. *İstanbul Gelişim Üniversitesi Sosyal Bilimler Dergisi*, *3*(1), 187. https://doi.org/10.17336/igusbd.05060

Escobar-Naranjo, J., Caiza, G., Ayala, P., Jordan, E., Garcia, C. A., ve Garcia, M. V. (2023). Autonomous Navigation of robots: Optimization with DQN. *Applied Sciences*, *13*(12), 7202. https://doi.org/10.3390/app13127202

Esmaeili, A., Ghorrati, Z., ve Matson, E. T. (2023). Agent-based collaborative random search for hyperparameter tuning and global function optimization. *Systems*, *11*(5), 228. https://doi.org/10.3390/systems11050228

Gaudreault, J.-G., Branco, P., ve Gama, J. (2021). An analysis of performance metrics for Imbalanced Classification. *Lecture Notes in Computer Science*, 67–77. https://doi.org/10.1007/978-3-030-88942-5_6

Gorzelańczyk, P., ve Tylicki, H. (2024). Optimization of methods for forecasting the number of road accidents. *Archives of Advanced Engineering Science*, *2*(4), 206–214. https://doi.org/10.47852/bonviewaaes42022114

Groth, D., Hartmann, S., Klie, S., ve Selbig, J. (2012). Principal Components Analysis. *Methods in Molecular Biology*, 527–547. https://doi.org/10.1007/978-1-62703-059-5_22

Hadjiiski, L., Geladi, P., ve Hopke, P. (1999). A comparison of modeling nonlinear systems with artificial neural networks and partial least squares. *Chemometrics and*

Intelligent Laboratory Systems, *49*(1), 91–103. https://doi.org/10.1016/s0169-7439(99)00030-1

Hou, C.-D., ve Su, R.-H. (2024). An outlier detection approach to recognize the sources of a process failure within a multivariate Poisson process. *Mathematics*, *12*(18), 2813. https://doi.org/10.3390/math12182813

Huang, Y., ve Li, L. (2011). Naive Bayes classification algorithm based on small sample set. *2011 IEEE International Conference on Cloud Computing and Intelligence Systems*, 34–39. https://doi.org/10.1109/ccis.2011.6045027

Hubin, A., Storvik, G., ve Frommlet, F. (2021). Flexible bayesian nonlinear model configuration. *Journal of Artificial Intelligence Research*, *72*, 901–942. https://doi.org/10.1613/jair.1.13047

Hynes, D. (2013). *Artificial Intelligence in simulations*. McMaster University.

Jan, T. (2023). Combining analytic models with Neural Networks. *Proceedings of the 3rd IEEE International Symposium on Signal Processing and Information Technology (IEEE Cat. No.03EX795)*, 605–608. https://doi.org/10.1109/isspit.2003.1341193

Jia, W., Sun, M., Lian, J., ve Hou, S. (2022). Feature dimensionality reduction: A Review. *Complex veamp; Intelligent Systems*, *8*(3), 2663–2693. https://doi.org/10.1007/s40747-021-00637-x

Kempfert, K. C., Wang, Y., Chen, C., ve Wong, S. W. K. (2020). A comparison study on nonlinear dimension reduction methods with kernel variations: Visualization, optimization and classification. *Intelligent Data Analysis*, *24*(2), 267–290. https://doi.org/10.3233/ida-194486

KGM., (2024). Tünel Envanter Bilgileri. https://www.kgm.gov.tr/SiteCollectionDocuments/KGMdocuments/Istatistikler/KopruveTunelBilgileri/tunelenvanterbilgileri.pdf

Khoshgoftaar, T. M., Fazelpour, A., Dittman, D. J., ve Napolitano, A. (2015). Alterations to the bootstrapping process within Random Forest: A case study on imbalanced bioinformatics data. *2015 IEEE International Conference on Information Reuse and Integration*, 342–348. https://doi.org/10.1109/iri.2015.59

Khujaev, O. K., Nurmetova, B. B., ve Urazmatov, T. K. (2023). Algorithms for selecting the most efficient method for solving classification problems. *2023 IEEE XVI International Scientific and Technical Conference Actual Problems of Electronic Instrument Engineering (APEIE)*, 1740–1743. https://doi.org/10.1109/apeie59731.2023.10347690

Kircher, K., ve Ahlstrom, C. (2012). The impact of tunnel design and lighting on the performance of attentive and visually distracted drivers. *Accident Analysis veamp; Prevention*, *47*, 153–161. https://doi.org/10.1016/j.aap.2012.01.019

Kirytopoulos, K., Kazaras, K., Papapavlou, P., Ntzeremes, P., ve Tatsiopoulos, I. (2017). Exploring driving habits and safety critical behavioural intentions among Road Tunnel Users: A questionnaire survey in Greece. *Tunnelling and Underground Space Technology*, *63*, 244–251. https://doi.org/10.1016/j.tust.2016.12.002

Koçhan, B. (2021). *Karayolu Tünel Güvenliği ve Meydana Gelen Kazalar* [Yüksek Lisans Tezi]. Fen Bilimleri Enstitüsü. Gümüşhane Üniversitesi.

Koçhan, B., Çoruh, E., ve Aydın, M. M. (2023). Sürücülerin Tünel işletim Ve Güvenliği Algısı üzerine Bir Araştırma. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, *6*(1), 493–516. https://doi.org/10.47495/okufbed.1064987

Kramer, O. (2013). K-Nearest Neighbors. *Intelligent Systems Reference Library*, 13–23. https://doi.org/10.1007/978-3-642-38652-7_2

Kummetha, V. C., Durrani, U., Mason, J., Concas, S., ve Kondyli, A. (2023). Driver classification using self-reported, psychophysiological, and performance metrics within a simulated environment. *Data Science for Transportation*, *5*(2). https://doi.org/10.1007/s42421-023-00069-8

Kärkkäinen, T. (2014). On cross-validation for MLP model evaluation. *Lecture Notes in Computer Science*, 291–300. https://doi.org/10.1007/978-3-662-44415-3_30

Larson, R. C., Metzger, M. D., ve Cahn, M. F. (2006). Responding to emergencies: Lessons learned and the need for analysis. *Interfaces*, *36*(6), 486–501. https://doi.org/10.1287/inte.1060.0250

Latha, N. M., Geetha, K., ve Damodharan, S. (2024). Overview of regression models and how to determine the best model for Data. *Journal of Scientific Research and Reports*, *30*(10), 250–266. https://doi.org/10.9734/jsrr/2024/v30i102452

Li, Z. (2024). Feature engineering and data visualization analysis in artificial intelligence in Big Data Era. *International Journal of Computer Science and Information Technology*, *3*(3), 390–395. https://doi.org/10.62051/ijcsit.v3n3.41

Lu, Z., Lin, F., ve Ying, H. (2007). Design of decision tree via kernelized hierarchical clustering for multiclass support vector machines. *Cybernetics and Systems*, *38*(2), 187–202. https://doi.org/10.1080/01969720601139058

López, J. C., Grindlay, A. L., Carpio, M., ve Peña-García, A. (2014). Strategies for the optimization of binomial energy saving landscape integration in road tunnels. *WIT*

Transactions on Ecology and the Environment, *1*, 511–520. https://doi.org/10.2495/eq140491

Ma, S., ve Li, T. (2009). On clustering techniques. *Encyclopedia of Data Warehousing and Mining, Second Edition*, 264–268. https://doi.org/10.4018/978-1-60566-010-3.ch043

Manigandan, Dr. S. (2024). Accident prevention system. *International Journal Of Scientific Research In Engineering and Management*, *08*(07), 1–16. https://doi.org/10.55041/ijsrem36861

Manseer, M., ve Riener, A. (2014). Evaluation of driver stress while Transiting Road Tunnels. *Adjunct Proceedings of the 6th International Conference on Automotive User Interfaces and Interactive Vehicular Applications*, 1–6. https://doi.org/10.1145/2667239.2667269

Mariani, M. M., Machado, I., Magrelli, V., ve Dwivedi, Y. K. (2023). Artificial Intelligence in Innovation Research: A systematic review, Conceptual Framework, and Future Research Directions. *Technovation*, *122*, 102623. https://doi.org/10.1016/j.technovation.2022.102623

Mehmood, F., Ahmad, S., ve Whangbo, T. K. (2023). An efficient optimization technique for training deep neural networks. *Mathematics*, *11*(6), 1360. https://doi.org/10.3390/math11061360

Miller, J. W., Goodman, R., ve Smyth, P. (1993). On loss functions which minimize to conditional expected values and posterior probabilities. *IEEE Transactions on Information Theory*, *39*(4), 1404–1408. https://doi.org/10.1109/18.243457

Mirzarazi, F., Danishvar, S., ve Mousavi, A. (2024). The safety risks of AI-driven solutions in Autonomous Road Vehicles. *World Electric Vehicle Journal*, *15*(10), 438. https://doi.org/10.3390/wevj15100438

Montgomery, R. M. (2024). *Techniques for Outlier Detection: A Comprehensive View*. https://doi.org/10.20944/preprints202410.1603.v1

Murata, M., Miyazaki, K., ve Koriyama, T. (2024). An attribute interpolation method in speech synthesis by model merging. *Interspeech 2024*, 3380–3384. https://doi.org/10.21437/interspeech.2024-208

Musicant, D. R., Christensen, J. M., ve Olson, J. F. (2007). Supervised learning by training on aggregate outputs. *Seventh IEEE International Conference on Data Mining (ICDM 2007)*, 252–261. https://doi.org/10.1109/icdm.2007.50

Namin, F. S., Ghafari, H., ve Dianati, A. (2014). New Model for Environmental Impact Assessment of Tunneling Projects. *Journal of Environmental Protection*, *05*(06), 530–550. https://doi.org/10.4236/jep.2014.56056

Nasteski, V. (2017). An overview of the supervised machine learning methods. *HORIZONS.B*, *4*, 51–62. https://doi.org/10.20544/horizons.b.04.1.17.p05

Nelles, O. (2001). Nonlinear dynamic system identification. *Nonlinear System Identification*, 547–577. https://doi.org/10.1007/978-3-662-04323-3_15

Niu, J., Liang, B., He, S., Xiao, J., ve Qin, C. (2022). Long Tunnel Lighting Environment Improvement Method based on multiple-parameter intelligent control: Considering dynamic changes in luminance difference. *Tunnelling and Underground Space Technology*, *128*, 104637. https://doi.org/10.1016/j.tust.2022.104637

Nurwinto, C., Kurniawan, T. B., Misinem, Sutabri, T., ve Kunang, Y. N. (2024). Enhancing classification algorithms with metaheuristic technique. *Journal of Data Science*, *2024*(1). https://doi.org/10.61453/jods.v2024no22

Onat, A., Kita, H., ve Nishikawa, Y. (1997). Reinforcement learning of dynamic behavior by using recurrent neural networks. *Artificial Life and Robotics*, *1*(3), 117–121. https://doi.org/10.1007/bf02471125

Pagan, M., Zarlis, M., ve Candra, A. (2023). Investigating the impact of data scaling on the K-nearest neighbor algorithm. *Computer Science and Information Technologies*, *4*(2), 135–142. https://doi.org/10.11591/csit.v4i2.p135-142

Paiva, A. R., Xu, J.-W., ve Príncipe, J. C. (2006). Kernel principal components are maximum entropy projections. *Lecture Notes in Computer Science*, 846–853. https://doi.org/10.1007/11679363_105

Patel, D., Saxena, A., ve Wang, J. (2024). A machine learning-based Wrapper method for feature selection. *International Journal of Data Warehousing and Mining*, *20*(1), 1–33. https://doi.org/10.4018/ijdwm.352041

Pelkmann, D., Tharwat, A., ve Schenck, W. (2020). How to label? combining experts' knowledge for German text classification. *2020 7th Swiss Conference on Data Science (SDS)*, 61–62. https://doi.org/10.1109/sds49233.2020.00023

Qin, P., Wang, M., Chen, Z., Yan, G., Yan, T., Han, C., Bao, Y., ve Wang, X. (2021). Characteristics of driver fatigue and fatigue-relieving effect of special light belt in extra-long highway tunnel: A real-road driving study. *Tunnelling and Underground Space Technology*, *114*, 103990. https://doi.org/10.1016/j.tust.2021.103990

Raheem, A., Ali Arsal, S., Basit, T., Areeba, S., Salar Abro, M., ve Kumar, A. (2024). Inguinal arteriovenous malformation. *Frontiers in Medical Case Reports*, *05*(01), 01–05. https://doi.org/10.47746/fmcr.2024.5103

Ramanathan, R. A., R, B., Bama Krishna, R. S., ve Selvan, M. P. (2023). A review of Intelligent Traffic Management Systems. *2023 7th International Conference on Trends in Electronics and Informatics (ICOEI)*, 1652–1657. https://doi.org/10.1109/icoei56765.2023.10126024

Rane, N. L., Mallick, S. K., Kaya, Ö., ve Rane, J. (2024). Applications of deep learning in healthcare, finance, agriculture, retail, energy, manufacturing, and Transportation: A Review. *Applied Machine Learning and Deep Learning: Architectures and Techniques*. https://doi.org/10.70593/978-81-981271-4-3_7

Raymaekers, J., Rousseeuw, P. J., ve Hubert, M. (2021). Class maps for Visualizing Classification Results. *Technometrics*, *64*(2), 151–165. https://doi.org/10.1080/00401706.2021.1927849

Rezvani, A. Z., Kemmsies, W., Parlikad, A. K., ve Jafari, M. A. (2015). Toward closing the loop between infrastructure investments and societal and economic impacts. *The Engineering Economist*, *60*(4), 263–290. https://doi.org/10.1080/0013791x.2015.1065358

Rudin-Brown, C. M., Young, K. L., Patten, C., Lenné, M. G., ve Ceci, R. (2013). Driver distraction in an unusual environment: Effects of text-messaging in Tunnels. *Accident Analysis veamp; Prevention*, *50*, 122–129. https://doi.org/10.1016/j.aap.2012.04.002

Schmitt, M. S., Koch-Janusz, M., Fruchart, M., Seara, D. S., Rust, M., ve Vitelli, V. (2024). *Information Theory for Data-Driven Model Reduction in Physics and Biology*. https://doi.org/10.1101/2024.04.19.590281

Shang, T., Lu, J., Luo, Y., Wang, S., He, Z., ve Wang, A. (2024). Understanding the traffic flow in different types of freeway tunnels based on car-following behaviors analysis. *Tunnelling and Underground Space Technology*, *143*, 105494. https://doi.org/10.1016/j.tust.2023.105494

Singh, N., ve Rajamani, D. (1996). Similarity coefficient-based clustering: Methods for Cell Formation. *Cellular Manufacturing Systems*, 70–96. https://doi.org/10.1007/978-1-4613-1187-4_4

Sperandei, S. (2014). Understanding logistic regression analysis. *Biochemia Medica*, 12–18. https://doi.org/10.11613/bm.2014.003

Steyerberg, E. W. (2008). Evaluation of performance. *Statistics for Biology and Health*, 255–280. https://doi.org/10.1007/978-0-387-77244-8_15

Su, E., Zhang, X., Wen, X., Liu, J., Ye, F., Han, X., ve Lei, P. (2023). Visual characteristics of drivers in different directions and lengths of gradual landscape zones in extra-long highway tunnels. *Tunnelling and Underground Space Technology*, *137*, 105136. https://doi.org/10.1016/j.tust.2023.105136

Takeishi, N. (2019). Shapley values of reconstruction errors of PCA for explaining anomaly detection. *2019 International Conference on Data Mining Workshops (ICDMW)*, 793–798. https://doi.org/10.1109/icdmw.2019.00117

Thorslund, B., Thellman, S., Nyberg, V., ve Selander, H. (2024). Simulator-based driving test prescreening as a complement to driver testing – toward safer and more risk-aware drivers. *Accident Analysis veamp; Prevention*, *194*, 107335. https://doi.org/10.1016/j.aap.2023.107335

Torrecilla, J. S., Matute, G., Calvo, C., Ceña, C., ve Rodríguez, F. (2012). P1.9.16 nonlinear algorithms to reduce the dimension of databases without loss of information. *Proceedings IMCS 2012*, 1206–1208. https://doi.org/10.5162/imcs2012/p1.9.16

Uddin, M. F., Lee, J., Rizvi, S., ve Hamada, S. (2018). Proposing enhanced feature engineering and a selection model for Machine Learning Processes. *Applied Sciences*, *8*(4), 646. https://doi.org/10.3390/app8040646

Ullah, I., Liu, K., Yamamoto, T., Zahid, M., ve Jamal, A. (2023). Modeling of machine learning with Shap Approach for Electric Vehicle Charging Station Choice Behavior Prediction. *Travel Behaviour and Society*, *31*, 78–92. https://doi.org/10.1016/j.tbs.2022.11.006

Ulusal Akıllı Ulaşım Sistemleri Strateji Belgesi ve 2020-2023 Eylem Planı. (2019). https://www.uab.gov.tr/uploads/pages/bakanlik-yayinlari/ulusal-akilli-ulas-im-sistemleri-strateji-belgesi-ve-2020-2023-eylem-plani.pdf

URL-1, https://en.wikipedia.org/wiki/Mont_Blanc_Tunnel_fire 5 Mart 2024.

URL-2, http://news.bbc.co.uk/onthisday/hi/dates/stories/october/24/newsid_2488000/2488557.stm. 7 Nisan 2024.

URL-3, https://en.wikipedia.org/wiki/Kaprun_disaster. 7 Nisan 2024.

URL-4, https://hgm.uab.gov.tr/akilli-ulasim-sistemleri-aus. 11 Temmuz 2024.

URL-5, https://www.perforce.com/blog/vcs/unreal-engine-5. 10 Ekim 2023.

URL-6, https://www.mevzuat.gov.tr/mevzuatmetin/1.5.2918.pdf. 11 Mayıs 2024.

URL-7, https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=8182&MevzuatTur=7&MevzuatTertip=5. 12 Mayıs 2024.

URL-8, https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=18408&MevzuatTur=7&MevzuatTertip=5. 12 Mayıs 2024.

URL-9, https://www.trafik.gov.tr/kurumlar/trafik.gov.tr/03-Mevzuat/2024-yili-Trafik-Idari-Para-Ceza-Rehberi.pdf. 15 Mayıs 2024.

URL-10, https://www.resmigazete.gov.tr/eskiler/2015/12/20151205-3-3.xls. 21 Mayıs 2024.

Vallejo, J. R., ve Bayro-Corrochano, E. (2008). Clifford Hopfield Neural Networks. *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*, 3609–3612. https://doi.org/10.1109/ijcnn.2008.4634314

VanderVeen, J. (2021). *Artificial Neural Network Hyperparameter Effectiveness Determination and Optimization Algorithm*. https://doi.org/10.32920/ryerson.14635770

Vivanco, R., ve Jin, D. (2008). Enhancing predictive models using principal component analysis and search based metric selection. *Proceedings of the Second ACM-IEEE International Symposium on Empirical Software Engineering and Measurement*, 273–275. https://doi.org/10.1145/1414004.1414049

Wang, S., Aggarwal, C., ve Liu, H. (2018). Random-Forest-inspired Neural Networks. *ACM Transactions on Intelligent Systems and Technology*, *9*(6), 1–25. https://doi.org/10.1145/3232230

Wang, W., Van Gelder, P. H., ve Vrijling, J. K. (2005). Some issues about the generalization of neural networks for time series prediction. *Lecture Notes in Computer Science*, 559–564. https://doi.org/10.1007/11550907_88

Wang, Y., Zhang, W., Wu, S., ve Guo, Y. (2007). Simulators for driving safety study – A literature review. *Lecture Notes in Computer Science*, 584–593. https://doi.org/10.1007/978-3-540-73335-5_63

Wibbeke, J., Teimourzadeh Baboli, P., ve Rohjans, S. (2022). Optimal Data Reduction of training data in machine learning-based modelling: A multidimensional bin packing approach. *Energies*, *15*(9), 3092. https://doi.org/10.3390/en15093092

Wolpert, D. H., ve Macready, W. G. (1997). No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation*, *1*(1), 67–82. https://doi.org/10.1109/4235.585893

Xi, W., Xu, C., Yang, W., Yu, P., Ma, X., ve Lu, J. (2014). Shap: Suppressing the detection of inconsistency hazards by Pattern Learning. *2014 21st Asia-Pacific Software Engineering Conference*, 391–398. https://doi.org/10.1109/apsec.2014.64

Yang, L., ve Chen, S. (2014). Linear discriminant analysis with worst between-class separation and average within-class compactness. *Frontiers of Computer Science*, *8*(5), 785–792. https://doi.org/10.1007/s11704-014-3337-x

Yao, Z., ve Wu, L. (1990). Interactive pattern recognition approach to lithological interpretation with a new clustering algorithm. *SEG Technical Program Expanded Abstracts 1990*, 325–327. https://doi.org/10.1190/1.1890186

Yeung, J. S., ve Wong, Y. D. (2014). The effect of road tunnel environment on car following behaviour. *Accident Analysis veamp; Prevention*, *70*, 100–109. https://doi.org/10.1016/j.aap.2014.03.014

Zhang, Y., Orgun, M., ve Lin, W. (2006). Unsupervised learning aided by hierarchical analysis in knowledge exploration. *Sixth International Conference on Intelligent Systems Design and Applications*, *1*, 661–665. https://doi.org/10.1109/isda.2006.276

Zhao, X., Liu, Q., Li, H., Qi, J., Dong, W., ve Ju, Y. (2022). Evaluation of the effect of decorated sidewall in tunnels based on driving behavior characteristics. *Tunnelling and Underground Space Technology*, *127*, 104591. https://doi.org/10.1016/j.tust.2022.104591

Zheng, C., Pan, L., ve Wu, P. (2023). Attribute augmented network embedding based on generative adversarial nets. *IEEE Transactions on Neural Networks and Learning Systems*, *34*(7), 3473–3487. https://doi.org/10.1109/tnnls.2021.3116419

Zheng, H., Du, Z., ve Wang, S. (2024). Dynamic driving risk in highway tunnel groups based on pupillary oscillations. *Accident Analysis veamp; Prevention*, *195*, 107414. https://doi.org/10.1016/j.aap.2023.107414

Zhou, X., Huang, C., ve Zhou, Y. (2022). Unsafe behavior analysis and risk measurement of traffic accidents in Mountainous Highway Tunnel. *Mathematical Problems in Engineering*, *2022*, 1–12. https://doi.org/10.1155/2022/3938051

Zhou, Z., Xie, X., Song, J., Shu, Z., ve Ma, L. (2024). GenSafe: A generalizable safety enhancer for safe reinforcement learning algorithms based on reduced order

Markov Decision Process Model. *IEEE Transactions on Neural Networks and Learning Systems*, 1–15. https://doi.org/10.1109/tnnls.2024.3496492

Zou, C. (2024). Revolutionizing Machine Learning: Harnessing Hardware Accelerators for enhanced AI efficiency. *Applied and Computational Engineering*, *47*(1), 141–146. https://doi.org/10.54254/2755-2721/47/20241256

EKLER

Ek 1. Sürüş öncesi anket formu

Bu anket Erzincan Binali Yıldırım Üniversitesi Mühendislik Fakültesinde kurulan *Sürüş Teknikleri ve Sürücü Davranışları Tespit Laboratuvarında* yapılacak olan '*Tünellerin Geometrik ve İşletim Özelliklerindeki Farklılıkların Sürücü Davranışları Üzerindeki Etkilerinin Simülatör Ortamında İrdelenmesi'* isimli çalışmaya veri sağlamak amacıyla hazırlanmıştır.

1. Yaşınız: (.....)
2. Cinsiyetiniz? (a) Erkek (b) Kadın
3. Eğitim durumunuz nedir? (a) İlköğretim b) Lise (c) Ön Lisans (d) Lisans (e) Yüksek Lisans (f) Doktora
4. Çalışıyor musunuz? (a) Evet (Mesleğiniz…….) (b) Hayır
5. Ehliyetiniz var mı? Cevabınız evet ise süresi nedir? (a) Evet (……. yıldır var) (b) Hayır
6. Araç kullanma becerinizi nasıl tanımlarsınız? (a) Kullanamıyorum (b) Başlangıç seviyesinde (c) Orta seviyede (d) Profesyonel seviyede
7. Kendinizi nasıl bir sürücü olarak tanımlarsınız? (a) Agresif (b) Orta (c)Sakin
8. Ne tip araç kullanıyorsunuz? (a) Ticari ağır (kamyon, otobüs vb.) (b) Ticari hafif (kamyonet, otomobil vb.) (c) Şahsi Ağır (d) Şahsi Hafif (e) Kullanmıyorum
9. Daha önce trafik kazası yaptınız mı? (a) Hayır (b) Evet aşırı hız (c) Evet takip mesafesini ayarlayamama sonucu arkadan çarpma (d) Evet bir engel sonucu ani fren yapma (e) Evet diğer …….
10. Daha önce hiç araç simülatörü kullandınız mı? (a) Evet sürekli (b) Evet birçok kez (c) Evet birkaç kez (d) Hayır hiç kullanmadım
11. Araç simülatörü hakkında önceden herhangi bir bilginiz var mıydı? (a) Evet (b) Hayır
12. Daha önce bu laboratuvardaki simülatör ile sürüş gerçekleştireceğiniz güzergâhta hiç araç kullandınız mı? (a)Evet (ortalama hızım……..km/sa) (b) Hayır
13. Sürücülerin tünellerde olması gerekenden daha hızlı gittiğini düşünüyor musunuz? (a) Evet (yaklaşık hızları……..km/sa) (b)Hayır
14. Tünel içerisinde sürüş yapmak sizi tedirgin eder mi?

(a) Hiç etmez (b) Biraz eder (c) Orta derecede eder (d) Tedirgin eder (e) Çok tedirgin eder

15. Mevcut karayolu tünelleri trafik güvenliği açısından yeterli midir?

(a) Hiç yeterli değil (b) Biraz (c) Orta derecede (d) Yeterli (e) Çok yeterli

16. Mevcut karayolu tünelleri, tünel içerisindeki tehlikeli/problemli bölgeyi sürücüye önceden bildirme açısından yeterli midir?

(a) Hiç yeterli değil (b) Biraz (c) Orta derecede (d) Yeterli (e) Çok yeterli

17. Mevcut karayolu tünellerinde tünel içi, girişi ve çıkışı aydınlatma açısından yeterli midir?

(a) Hiç yeterli değil (b) Biraz (c) Orta derecede (d) Yeterli (e) Çok yeterli

18. Açık yollara kıyasla tünellerde kaza riskinin daha fazla olduğunu düşünüyor musunuz?

(a) Hiç düşünmüyorum (b) Biraz (c) Orta derecede (d) Düşünüyorum (e) Çok düşünüyorum

19. Uzun tünellerde sürüş yapmak sıkıcı mıdır?

(a) Hiç sıkıcı değil (b) Biraz (c) Orta derecede (d) Sıkıcı (e) Çok sıkıcı

20. Uzun tünelden daha hızlı çıkmak için hızınızı arttırır mısınız?

(a) Hiç arttırmam (b) Biraz (c) Orta derecede (d) Arttırırım (e) Çok arttırırım

21. Tüneldeki ağır vasıtayı bir an önce geçmek (sollamak) için hızınızı arttırır mısınız?

(a) Hiç arttırmam (b) Biraz (c) Orta derecede (d) Arttırırım (e) Çok arttırırım

22. Tünel giriş ve çıkışlarında güvenlik amacıyla hızınızı azaltmayı tercih eder misiniz?

(a) Hiç azaltmam (b) Biraz (c) Orta derecede (d) Azaltırım (e) Çok azaltırım

23. Tünel içerisindeki dijital uyarıcılar dikkatinizi çeker mi?

(a) Hiç çekmez (b) Biraz (c) Orta derecede (d) Çeker (e) Çok çeker

24. Elektronik Denetleme Sistemi (EDS) hızınızı azaltmak için etkili bir sistem midir?

(a) Hiç değil (b) Biraz (c) Orta derecede (d) Etkili (e) Çok etkili

25. Tünel içerisinde kaza gerçekleşen bölgenin önceden (tünel girişinde veya tünel içerisinde) size bildirilmesi kendinizi güvende hissettirir mi?

(a) Hiç hissettirmez (b) Biraz (c) Orta derecede (d) Hissettirir (e) Çok hissettirir

26. Tehlikeli/problemli bölgelerin size önceden bildirileceğini bilmek tünelden geçerken sürüş stresinizi azaltır mı?

(a) Hiç azaltmaz (b) Biraz (c) Orta derecede (d) Azaltır (e) Çok azaltır

27. Bir ana yolda takip mesafesini düzenlemek için yol yüzeylerinde kullanılan ok işaretleri hakkında daha önceden bilginiz var mı?

(a)Evet (b)Hayır



Ek 2. Sürüş sonrası anket formu

	Kesinlikle Katılmıyorum	**Katılmıyorum**	**Biraz Katılmıyorum**	**Kararsızım**	**Biraz Katılıyorum**	**Katılıyorum**	**Kesinlikle Katılıyorum**
1.Sorunsuz bir sürüş testi gerçekleştirdim (Kullanırken herhangi bir sıkıntı yaşamadım).	1	2	3	4	5	6	7
2. Sürüş öncesi ya da sonrasında herhangi bir fiziksel rahatsızlık hissetmedim.	1	2	3	4	5	6	7
3. Araç simülatöründe kendimi gerçek bir araç kullanıyormuş gibi hissettim.	1	2	3	4	5	6	7
4. Test için hazırlanan 3D modellemeler oldukça gerçekçidir.	1	2	3	4	5	6	7
5. Hazırlanan sürüş senaryoları ile kendimi senaryonun içerisinde hissettim ve gerçek bir sürüşteki gibi davranmaya çalıştım.	1	2	3	4	5	6	7
6. Senaryo içerisindeki trafik akımı oldukça gerçekçidir.	1	2	3	4	5	6	7



7-10. sorular için bu görseli dikkate alınız

7. Tünel içerisindeki ağır araç yoğunluğu araç kullanım hızımı önemli derecede etkiledi.	1	2	3	4	5	6	7
	Kesinlikle Katılmıyorum	**Katılmıyorum**	**Biraz Katılmıyorum**	**Kararsızım**	**Biraz Katılıyorum**	**Katılıyorum**	**Kesinlikle Katılıyorum**
8. Tünel içerisinde ağır vasıta ile karşılaşmak hızımı azaltmama ve şerit disiplinimin artmasına sebep oldu.	1	2	3	4	5	6	7
9. Ağır vasıta ile yan yana hareket etmek stresli sürüş yapmama sebep oldu.	1	2	3	4	5	6	7
10. Ağır vasıtayı bir an önce geçmek için hızımı arttırdım.	1	2	3	4	5	6	7

11-13. sorular için bu görseli dikkate alınız



11. Aşırı aydınlıktan tamamen karanlık bir tünele girmek göz kamaşmasına neden oldu ve sürüş disiplinimi çok olumsuz etkiledi.	1	2	3	4	5	6	7
12. Bu senaryoda kaza yapma olasılığım oldukça fazlaydı	1	2	3	4	5	6	7
13. Bu senaryoda hızımı azalttım	1	2	3	4	5	6	7



14. soru için bu görseli dikkate alınız

	Kesinlikle Katılmıyorum	Katılmıyorum	Biraz Katılmıyorum	Kararsızım	Biraz Katılıyorum	Katılıyorum	Kesinlikle Katılıyorum
14. Tünel giriş, çıkış ve tüneller arasında ortalama hız koridoru uygulamasını faydalı buldum	1	2	3	4	5	6	7



15-16. sorular için bu görseli dikkate alınız

	Kesinlikle Katılmıyorum	Katılmıyorum	Biraz Katılmıyorum	Kararsızım	Biraz Katılıyorum	Katılıyorum	Kesinlikle Katılıyorum
15. Ortalama hız koridoru içerisinde bulunan radar aracı beklemediğim bir durumdu.	1	2	3	4	5	6	7
16. Ortalama hız koridoru içerisinde anlık hız ölçen radar	1	2	3	4	5	6	7

araçlarının olması doğru bir uygulamadır.							



17-19. sorular için bu görseli dikkate alınız

	Kesinlikle Katılmıyorum	**Katılmıyorum**	**Biraz Katılmıyorum**	**Kararsızım**	**Biraz Katılıyorum**	**Katılıyorum**	**Kesinlikle Katılıyorum**
17. Tünel içerisinde araç takip mesafesini gösteren okların olması trafik güvenliği açısından önemlidir.	1	2	3	4	5	6	7
18. Asfalt üzerindeki OK işaretleri araç takip mesafesini ayarlamama yardımcı oldu.	1	2	3	4	5	6	7
19. Tünel içerisindeki dijital hız uyarı levhaları ve değişken mesaj	1	2	3	4	5	6	7

sistemleri sürüş davranışım üzerinde etkilidir.							



20-22. sorular için bu görseli dikkate alınız

	Kesinlikle Katılmıyorum	**Katılmıyorum**	**Biraz Katılmıyorum**	**Kararsızım**	**Biraz Katılıyorum**	**Katılıyorum**	**Kesinlikle Katılıyorum**
20. Kırmızı tavan aydınlatması gördüğüm bölgede bir problem/tehlike olduğunu düşündüm.	1	2	3	4	5	6	7
21. Kırmızı tavan aydınlatması ile hızımı azalttım.	1	2	3	4	5	6	7
22. Kırmızıdan sonra gelen yeşil tavan aydınlatması problemin/tehlikenin geçtiğini anlamamı sağladı.	1	2	3	4	5	6	7



23-24. sorular için bu görseli dikkate alınız

	Kesinlikle Katılmıyorum	**Katılmıyorum**	**Biraz Katılmıyorum**	**Kararsızım**	**Biraz Katılıyorum**	**Katılıyorum**	**Kesinlikle Katılıyorum**
23. Tünel duvarındaki led uyarıcıları gördüğümde problemli/tehlikeli bölgeye yaklaştığımı düşündüm.	1	2	3	4	5	6	7
24. Tehlikeli bölge öncesi ışıklı uyarıcılar hızımı azaltmama neden oldu.	1	2	3	4	5	6	7

25. Tünel içerisindeki hangi uygulama tehlikeli/problemli bölgenin olduğunu bildirmede daha etkilidir?	Sadece Kırmızı Tavan Aydınlatmalı Uygulama ☐	Öncesinde Kenar, Sonrasında Kırmızı Tavan Aydınlatmalı Uygulama ☐

ETİK KURUL KARARI

T.C.
GÜMÜŞHANE ÜNİVERSİTESİ REKTÖRLÜĞÜ
BİLİMSEL ARAŞTIRMA VE YAYIN ETİĞİ KURULU

Sayı : E-95674917-108.99-253421
Konu : Etik Kurul Onay

Sayın Dr. Öğr. Üyesi Emine ÇORUH

"**TÜNELLERİN GEOMETRİK VE İŞLETİM ÖZELLİKLERİNDEKİ FARKLILIKLARIN SÜRÜCÜ DAVRANIŞLARI ÜZERİNDEKİ ETKİLERİNİ SİMÜLATÖR ORTAMINDA İRDELENMESİ**" konulu etik kurul başvurunuz; Gümüşhane Üniversitesi Bilimsel Araştırma ve Yayın Etiği Kurulu'nun **30/05/2024** tarih ve **2024/5** sayılı toplantısında görüşülmüş olup; projenin yürürlükteki mevzuata uygun olduğuna oy birliği ile karar verilmiştir.
Bilgilerinize rica ederim.

Prof. Dr. Günay ÇAKIR
Kurul Başkanı

Bu belge, güvenli elektronik imza ile imzalanmıştır.
Belge Doğrulama Kodu : 0T90-I1Z1-0KPP Belge Doğrulama Adresi : https://www.turkiye.gov.tr/gumushane-universitesi-ebys

Adres:
Telefon No : Fax No :
e-Posta : İnternet Adresi : http://www.gumushane.edu.tr/
Kep Adresi : gumushaneuniversitesi@hs01.kep.tr

Bilgi İçin :Özge GÖKAY
Memur
Dahili No:

ÖZGEÇMİŞ

Ömer Faruk ÖZTÜRK, lisans eğitimini 2014 yılında Gümüşhane Üniversitesi İnşaat Mühendisliği Bölümünde ve 2015 yılında aynı üniversitenin Çift Ana Dal programı kapsamında Harita Mühendisliği Bölümü'nde tamamladı.

Mesleki kariyerine 2014 yılında ulaştırma projelerinde saha mühendisi olarak başladı. 2016-2019 yılları arasında Gümüşhane Belediyesi Fen İşleri Müdürlüğü'nde İnşaat Mühendisi olarak görev yaptı. 2019 yılında Giresun Üniversitesi'nde öğretim görevlisi olarak göreve başladı ve halen bu görevine devam etmektedir.

Yüksek lisans eğitimini 2018 yılında Gümüşhane Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı'nda tamamladı.

İyi derecede İngilizce bilen ÖZTÜRK, evli ve iki çocuk babasıdır.

Yayınlar:

Ozturk, O. F., Mazlum, Y., Aydin, M. M., Coruh, E. ve Bayata, H. F. (2024). Performance comparison of various tunnel lighting scenarios on driver Lane-changing behaviours in a driving simulator. *Applied Sciences*, *14*(23), 11319.

Ozturk, O. F. ve Çoruh, E. (2019). Gümüşhane İli İçin Bisiklet Ulaşımı planlaması. *Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, *12*(3), 1283–1294.

Çoruh, E., Aydın, M. M., Dağlı, E., Öztürk, Ö. F. ve Yıldırım, M. S. (2020). Kapalı Otobüs Durağı uygulamalarının Kullanıcı Beklentileri ve Memnuniyeti Doğrultusunda incelenmesi: Gümüşhane ve Antalya örneği. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, *10*(4), 1027-1038.

Çoruh, E., Aydın, M. M., Dağlı, E., Öztürk, Ö. F. ve Mazlum, Y. (2022). İklim Değişikliği Baskıları ve Afetler Karşısında Türkiye'de Ulaşım. TMMOB Afet Sempozyumu, Ankara.