

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MAKİNE ÖĞRENME Sİ ALGORİTMALARI KULLANILARAK SÜRÜCÜ
DAVRANIŞLARININ YAKIT VERİMLİLİĞİ ÜZERİNDEKİ ETKİSİ VE
ELEKTRİKLİ ARAÇLARA EĞİLİMİN TESPİTİ**

YÜKSEK LİSANS TEZİ

İlayda Nur ŞİŞMAN

Bilişim Sistemleri Mühendisliği Anabilim Dalı

OCAK 2025

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MAKİNE ÖĞRENME Sİ ALGORİTMALARI KULLANILARAK SÜRÜCÜ
DAVRANIŞLARININ YAKIT VERİMLİLİĞİ ÜZERİNDEKİ ETKİSİ VE
ELEKTRİKLİ ARAÇLARA EĞİLİMİN TESPİTİ**

YÜKSEK LİSANS TEZİ

İlayda Nur ŞİŞMAN

Bilişim Sistemleri Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Burcu ÇARKLI YAVUZ

OCAK 2025

İlayda Nur ŞİŞMAN tarafından hazırlanan “Makine Öğrenmesi Algoritmaları Kullanılarak Sürücü Davranışlarının Yakıt Verimliliği Üzerindeki Etkisi ve Elektrikli Araçlara Eğilimin Tespiti” adlı tez çalışması 16.01.2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilişim Sistemleri Mühendisliği Anabilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Prof. Dr. Devrim AKGÜN Sakarya Üniversitesi	
Jüri Üyesi :	Doç. Dr. Süleyman UZUN Sakarya Uygulamalı Bilimler Üniversitesi	
Jüri Üyesi :	Dr. Öğr. Üyesi Burcu ÇARKLI YAVUZ Sakarya Üniversitesi	



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “Makine Öğrenmesi Algoritmaları Kullanılarak Sürücü Davranışlarının Yakıt Verimliliği Üzerindeki Etkisi ve Elektrikli Araçlara Eğilimin Tespiti” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, etik kurul onay belgesi aldığımı, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(16/01/2025).

İlayda Nur ŞİŞMAN





İnandığı yolda azimle ilerleyen ve başarmak için hiç durmadan çalışan kendime...



TEŞEKKÜR

Bu çalışmanın hazırlanmasında bana rehberlik eden, öğrenim hayatım boyunca her zorluğumda yanımda olup beni cesaretlendiren ve başarıma olan inancını hissettiren sayın Dr. Öğr. Üyesi Burcu Çarklı Yavuz’a,

Hayatımın en kıymetli destekçilerinden biri olan, endişelerimi ve mutluluğumu her zaman benimle paylaşan, sevgisiyle bana güç ve huzur veren sevgili Kani Çakan’a,

Her adımında desteğini ve güvenini asla esirgemeyen, bana verdiği sonsuz sevgi ve hatalarımda dahi duyduğu sınırsız inançla hep yanımda olan sevgili aileme,

Pozitif enerjileriyle beni yüreklendiren, varlıklarıyla hayatıma renk ve anlam katan değerli dostlarıma,

Ve bugünümü görseydi benimle gurur duyacağını bildiğim, sabır ve sükûneti öğütleyen sözlerini dinleyerek yola devam ettiğim biricik anneanneme,

Sonsuz teşekkür ve minnetlerimi sunuyorum.

İlayda Nur ŞİŞMAN



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SİMGELER	xv
TABLO LİSTESİ	xvi
ŞEKİL LİSTESİ	xviii
ÖZET	xx
SUMMARY	xxii
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	3
3. YÖNTEM	19
3.1. Anket Tasarımı	19
3.2. Veri Seti ve Katılımcılar	19
3.3. Veri Hazırlama ve Temizleme	20
3.4. Veri Analizi	20
3.4.1. Korelasyon analizi	21
3.4.2. Random forest	21
3.4.3. Lojistik regresyon	23
3.4.4. Destek vektör makineleri (SVM)	24
3.4.5. XGBoost	25
3.4.6. SMOTE	26
3.4.7. Çapraz doğrulama yöntemleri	27
3.4.8. Karışıklık matrisi (confusion matrix)	29
3.4.9. Sınıflandırma raporu (classification report)	30
4. BULGULAR	33
4.1. Elektrikli Araçlara İlgi ve Sürücü Profilleri	33
4.1.1. Yaş gruplarına göre elektrikli araçlara ilgi ilişkisi	33
4.1.2. Sürüş deneyimine göre elektrikli araçlara ilgi ilişkisi	33
4.1.3. Şarj erişilebilirliğine göre elektrikli araçlara ilgi ilişkisi	34
4.1.4. Elektrikli araç bilgi seviyesine göre elektrikli araçlara ilgi ilişkisi	35
4.1.5. Elektrikli araç maliyetine göre elektrikli araçlara ilgi ilişkisi	35
4.2. Sürücü Davranışları ve Yakıt Verimliliği	36
4.2.1. Ani hızlanma, sık fren yapma ve yakıt tüketimi farkındalığı ilişkisi	36
4.2.2. Telematik cihaz kullanımı ve yakıt tüketimi farkındalığı ilişkisi	37
4.3. Hedef Değişken (Future_EV_Interest) ile Korelasyon Analizi	37
4.4. Makine Öğrenimi Modelleri ile Sınıflandırma Performansı	38
4.4.1. Mevcut veriler ile model performansı	38
4.4.1.1. Random forest model performansı	38
4.4.1.2. SVM model performansı	39
4.4.1.3. Lojistik regresyon model performansı	39

4.4.2. Yeni özellikler ile geliştirilmiş model performansı.....	40
4.4.2.1. Random forest model performansı.....	40
4.4.2.2. Yeni özelliklerin model performansı üzerindeki önemi.....	40
4.4.2.3. Önemli özelliklere dayalı random forest model performansı.....	41
4.4.2.4. Eğitim-test oranının değiştirilmesi ve SMOTE uygulamasının etkisi	42
4.4.2.5. SVM model performansı.....	43
4.4.2.6. Lojistik regresyon model performansı	43
4.4.2.7. XGBoost model performansı	43
4.4.2.8. Eğitim ve test setleri arasındaki ortak kayıtlar	44
4.4.2.9. Regularization ile XGBoost model performansı	44
4.5. Çapraz Doğrulama Yöntemleri.....	44
4.5.1. Leave-one-out cross validation (LOOCV).....	44
4.5.2. K-fold cross validation (K-FCV)	45
4.6. Makine Öğrenimi Yaklaşımlarının Özet Performans Değerlendirmesi	45
5. TARTIŞMA	49
6. SONUÇ VE ÖNERİLER.....	51
KAYNAKLAR.....	53
ÖZGEÇMİŞ.....	57

KISALTMALAR

ANOVA	: Analysis of Variance
COPERT	: Computer Programme to Calculate Emissions from Road Transport
FN	: False Negative
FP	: False Positive
GHSOM	: Growing Hierarchical Self-Organizing Maps
GPS	: Global Positioning System
HEV	: Hybrid Electric Vehicle
IQR	: Interquartile Range
K-FCV	: K-Fold Cross Validation
LIME	: Local Interpretable Model-agnostic Explanations
LOOCV	: Leave-One-Out Cross Validation
LSTM	: Long Short-Term Memory
MAE	: Mean Absolute Error
MAF	: Mass Air Flow
MATLAB	: MATrix LABoratory
MLE	: Maximum Likelihood Estimation
MSE	: Mean Squared Error
NEDC	: New European Driving Cycle
OBD	: On-Board Diagnostics
PEMS	: Portable Emissions Measurement System
PRISMA	: Preferred Reporting Items for Systematic Reviews and Meta-Analyses
PSAT	: Powertrain System Analysis Toolkit
RFECV	: Recursive Feature Elimination with Cross-Validation
RBF	: Radial Basis Function
SHAP	: SHapley Additive exPlanations
SMOTE	: Synthetic Minority Oversampling Technique
SVM	: Support Vector Machines
SVR	: Support Vector Regression
THW	: Time Headway
TN	: True Negative

TP	: True Positive
TTC	: Time to Collision
UDRIVE	: European Naturalistic Driving Study
VDI	: Vehicle Dynamics Index
VSP	: Vehicle Specific Power
VSS	: Vehicle Speed Sensor
WLTP	: Worldwide Harmonized Light Vehicles Test Procedure
XGBoost	: Extreme Gradient Boosting



SİMGELER

Ω	: Karmaşıklık fonksiyonu
α	: L1 düzenleme katsayısı
λ	: L2 düzenleme katsayısı
γ	: Yaprak (leaf nodes) sayısına bağlı düzenleme parametresi
η	: Öğrenme oranı
δ	: Rastgele bir değer ($\sim U(0,1)$)
$\wedge$	: Mantıksal "ve" işlemi
Π	: Çarpım sembolü
Σ	: Toplam sembolü
β	: Katsayı veya parametre
e	: Doğal logaritmanın tabanı (Euler sabiti, ≈ 2.718)

TABLO LİSTESİ

Sayfa

Tablo 4.1. Mevcut veriler ile makine öğrenimi modellerinin performans	
değerlendirmesi.	45
Tablo 4.2. Yeni özellikler ile geliştirilmiş makine öğrenimi modellerinin performans	
değerlendirmesi.	46





ŞEKİL LİSTESİ

Sayfa

Şekil 4.1. Yaş gruplarına göre elektrikli araçlara ilgi.	32
Şekil 4.2. Sürüş deneyimine göre elektrikli araçlara ilgi.	33
Şekil 4.3. Şarj erişilebilirliğine göre elektrikli araçlara ilgi.	33
Şekil 4.4. Elektrikli araç bilgi seviyesine göre elektrikli araçlara ilgi.	34
Şekil 4.5. Elektrikli araç maliyetine göre elektrikli araçlara ilgi.	35
Şekil 4.6. Ani hızlanma, sık fren yapma ve yakıt tüketimi farkındalığı ilişkisi.....	35
Şekil 4.7. Telematik cihaz kullanımı ve yakıt tüketimi farkındalığı ilişkisi.....	36
Şekil 4.8. Yeni eklenen özelliklerin model üzerindeki önem skorlarının dağılımı....	40



MAKİNE ÖĞRENMESİ ALGORİTMALARI KULLANILARAK SÜRÜCÜ DAVRANIŞLARININ YAKIT VERİMLİLİĞİ ÜZERİNDEKİ ETKİSİ VE ELEKTRİKLİ ARAÇLARA EĞİLİMİN TESPİTİ

ÖZET

Bu çalışma, sürücü davranışlarının yakıt tüketimi ve enerji verimliliği üzerindeki etkilerini derinlemesine analiz ederek, elektrikli araçların benimsenmesini etkileyen faktörleri ortaya koymayı amaçlamaktadır. Fosil yakıt tüketiminin azaltılması ve çevresel sürdürülebilirliğin sağlanması yönündeki küresel hedefler, bu çalışmayı önemli kılmaktadır. Elektrikli araçların yaygınlaşması, bu hedeflere ulaşmak için kritik bir fırsat sunarken, sürücü davranışları, altyapı eksiklikleri ve maliyet gibi çeşitli faktörler bu sürecin önündeki başlıca engeller arasında yer almaktadır. Çalışmada, 304 katılımcıdan toplanan çevrimiçi anket verileri kullanılmış ve bu veriler, sürücülerin demografik profilleri, sürüş alışkanlıkları ve elektrikli araçlara yönelik tutumlarını kapsamaktadır. Analizlerde, makine öğrenimi tekniklerinden yararlanılarak, elektrikli araçlara yönelik ilginin belirleyicileri ve yakıt tüketimi farkındalığını etkileyen davranış kalıpları incelenmiştir.

Elde edilen bulgular, elektrikli araçlara olan ilginin bilgi seviyesi, maliyet algısı, şarj altyapısı ve bireysel sürüş alışkanlıkları gibi faktörlerden etkilendiğini göstermektedir. Yaş gruplarına göre yapılan analizde, 30-39 yaş grubunun elektrikli araçlara en yüksek ilgiyi gösterdiği, diğer yaş gruplarının ise daha dengeli bir dağılım sergilediği gözlemlenmiştir. Şarj altyapısının erişilebilirliği arttıkça elektrikli araçlara olan ilginin de düzenli bir şekilde yükseldiği, özellikle genç yaş gruplarında bilgi seviyesindeki artışın ilgiyi daha fazla etkilediği görülmüştür. Sürüş deneyimi açısından bakıldığında, deneyimi az olan sürücülerin elektrikli araçlara daha fazla ilgi gösterdiği, deneyim arttıkça bu ilginin daha spesifik tercihlere dönüştüğü tespit edilmiştir. Ayrıca, agresif sürüş alışkanlıklarının (ani hızlanma ve sık fren yapma gibi) yakıt tüketimi farkındalığını azalttığı, buna karşılık düzenli araç bakımı gibi bilinçli sürüş uygulamalarının yakıt verimliliğini artırdığı belirlenmiştir.

Makine öğrenimi modelleriyle yapılan analizlerde, Random Forest, XGBoost, Lojistik Regresyon ve SVM gibi farklı algoritmalar kullanılmıştır. Özellikle XGBoost modeli, %100 doğruluk oranıyla en iyi performansı göstermiştir. Çalışmada, sınıf dengesizliklerini gidermek için SMOTE yöntemi uygulanmış ve bu yöntem, az temsil edilen sınıflar için model performansını önemli ölçüde artırmıştır. Ayrıca, düzenleme parametreleri (L1 ve L2 regülarizasyon) kullanılarak XGBoost modelinin genelleme performansı iyileştirilmiş, çapraz doğrulama ile ortalama %99.05 doğruluk oranı elde edilmiştir.

Çalışmada, veri setine eklenen yeni özellikler de modelleme sürecine anlamlı katkılar sağlamıştır. Örneğin, “Potential_EV_Use” ve “EV_Interest_Score” gibi özellikler, elektrikli araçlara olan ilginin tahmininde kritik bir rol oynamıştır. Diğer yandan, araç tipi ve yakıt türü kombinasyonu, tahmini günlük yakıt tüketimi ve agresif sürüş skoru gibi yeni değişkenler, sürüş alışkanlıklarının daha detaylı analiz edilmesine olanak

tanımıştır. Bu özellikler sayesinde model performansı artırılmış ve elektrikli araçlara olan ilgiyi etkileyen faktörler daha kapsamlı bir şekilde ortaya konmuştur.

Sonuç olarak, bu çalışma, sürdürülebilir sürüş alışkanlıklarının geliştirilmesi ve elektrikli araçların yaygınlaştırılmasına yönelik stratejik öneriler sunmaktadır. Elde edilen bulgular, bilgi seviyesinin artırılması, altyapı eksikliklerinin giderilmesi ve maliyet algısının iyileştirilmesinin, elektrikli araçların benimsenmesini hızlandırmak için önemli adımlar olduğunu göstermektedir. Ayrıca, daha verimli ve çevre dostu sürüş tekniklerinin teşviki ile yakıt tüketiminin azaltılabileceği ve bu araçların benimsenmesine katkı sağlanabileceği sonucuna varılmıştır.



USING MACHINE LEARNING ALGORITHMS FOR THE IMPACT OF DRIVER BEHAVIORS ON FUEL EFFICIENCY AND THE DETERMINATION OF PROPENSITY TOWARDS ELECTRIC VEHICLES

SUMMARY

This study comprehensively analyzes the impact of driver behaviors on fuel consumption and energy efficiency, aiming to identify the factors influencing the adoption of electric vehicles. Reducing dependency on fossil fuels, lowering greenhouse gas emissions, and ensuring environmental sustainability are prioritized goals at both individual and societal levels. Electric vehicles emerge as a critical solution for reducing carbon emissions and promoting more efficient use of energy resources. However, several barriers hinder their widespread adoption. Key challenges include driver behaviors, cost perceptions, lack of awareness, and insufficient charging infrastructure.

In recent years, artificial intelligence and machine learning technologies have been extensively employed to analyze energy efficiency and driver behaviors. These technologies provide unique capabilities to uncover the complex relationships between driver behaviors and fuel consumption. Within this context, the study analyzed data from 304 participants aged 18 and above, all of whom hold valid driver's licenses and actively operate vehicles. The analysis focused on demographic characteristics, driving habits, and attitudes toward electric vehicles. The research centered on analyzing data obtained via an online survey using machine learning techniques. The survey was designed to capture participants' demographic information, daily driving habits, and approaches to eco-friendly driving techniques. The first section of the survey gathered demographic details such as age, gender, years of driving experience, income level, and current vehicle characteristics (e.g., fuel type and model year). The second section addressed driving habits and factors influencing fuel consumption. To measure attitudes toward electric vehicles, participants were asked about their knowledge levels, usage intentions, and cost perceptions. Additionally, they were requested to evaluate the accessibility of electric vehicle charging stations in their respective regions. The collected data were analyzed using statistical methods and machine learning algorithms to identify factors influencing interest in electric vehicles.

The findings reveal that interest in electric vehicles is affected by factors such as knowledge level, cost perception, charging infrastructure, and individual driving habits. Age-based analyses indicate that individuals aged 30–39 exhibit the highest interest in electric vehicles, which is attributed to their economic stability and environmental awareness. Younger age groups (18–29 years) were more influenced by increases in knowledge levels, with the impact of knowledge being more pronounced in this group compared to others. For older age groups (40 years and above), the influence of knowledge levels was more balanced, while sensitivity to cost perception and infrastructure emerged as more significant factors. These findings suggest that increasing knowledge levels can have a stronger impact, particularly on

younger individuals, and that targeted strategies should be adopted for different demographic groups.

Access to charging infrastructure was identified as one of the most critical determinants of interest in electric vehicles. The data indicate that each incremental improvement in charging accessibility positively influences interest in electric vehicles. However, when accessibility reaches its maximum level, interest stabilizes. This finding underscores the importance of enhancing charging infrastructure as a pivotal strategy for promoting the adoption of electric vehicles. Investments in charging infrastructure are expected to improve user experience and make electric vehicle usage more appealing. Additionally, expanding the infrastructure while ensuring affordability for the public could accelerate the adoption process.

Cost perception also emerged as a significant determinant of interest in electric vehicles. Particularly in scenarios where cost impacts were high, interest in electric vehicles increased sharply. Users' sensitivity to policies that influence cost perceptions highlights the critical role of pricing strategies in the adoption of these technologies. The relationship between cost perception and interest in electric vehicles varies across demographic groups, emphasizing the need for tailored policies. For instance, offering entry-level models at more affordable prices for younger individuals or providing broader options to cater to family needs in the middle age group could make the electric vehicle market more appealing to a wider consumer base. Pricing policies and incentives are considered effective tools for addressing barriers related to cost perception.

The study also examined the impact of driving habits on fuel consumption awareness. Aggressive driving behaviors, such as sudden acceleration and frequent braking, were found to negatively affect fuel consumption awareness by increasing fuel usage and reducing energy efficiency. This highlights the significant impact of driving habits on energy savings. More conscientious driving techniques increased fuel consumption awareness and demonstrated the potential for energy savings. Measures such as regular vehicle maintenance and route planning were found to enhance energy efficiency. However, the relationship between telematics device usage and fuel consumption awareness was weak, though these devices were noted to have potential for improving driving habits, warranting further analysis.

The study employed various classification models using machine learning techniques, including Random Forest, XGBoost, Logistic Regression, and SVM. Among these, the XGBoost model demonstrated the best performance with an accuracy rate of 100%. The model was supported by the SMOTE technique to address class imbalances, effectively improving prediction accuracy for underrepresented classes. Furthermore, the generalization performance of the XGBoost model was enhanced through regularization parameters (L1 and L2), achieving an average accuracy rate of 99.05% via cross-validation. The Logistic Regression model performed well on balanced datasets, delivering successful results, particularly for more frequent classes. While the SVM model exhibited strong generalization capability, it showed lower performance on imbalanced classes.

The inclusion of new features significantly improved the accuracy and scope of the analyses. Features such as vehicle type and fuel type combinations, estimated daily fuel consumption, fuel cost ratio, aggressive driving score, average driving duration, and electric vehicle interest score (EV_Interest_Score) contributed to the model's predictive accuracy. Notably, EV_Interest_Score and Potential_EV_Use were among

the most influential features in enhancing model performance. By incorporating these features, the Random Forest model was retrained, demonstrating strong performance, especially in predicting interest in electric vehicles. During model optimization, adjustments to training-test ratios and the application of various data augmentation methods were implemented. Models trained with higher training ratios exhibited increased overall accuracy, but the limited class diversity in smaller test sets posed challenges. Balanced datasets created using SMOTE provided more consistent and balanced performance, significantly improving predictions for underrepresented classes. Cross-validation results supported the generalization capabilities of these models.

In conclusion, this study provides a detailed analysis of the critical factors influencing the adoption of electric vehicles and offers strategic recommendations to address these factors. Enhancing knowledge levels through educational programs, addressing infrastructure deficiencies through targeted investments, and adopting appropriate pricing policies were identified as essential strategies for increasing interest in electric vehicles. Additionally, promoting more conscious driving habits can reduce fuel consumption and enhance energy efficiency. Analyses conducted using machine learning techniques underscore the value of these methods in understanding complex relationships such as attitudes toward electric vehicles and fuel consumption awareness. These findings offer valuable insights to support sustainable transportation and energy policies.



1. GİRİŞ

Enerji kaynaklarının verimli kullanımı ve çevresel sürdürülebilirlik hem bireyler hem de toplumlar için öncelikli hedefler arasında yer almaktadır. Fosil yakıtlara olan bağımlılığın azalması ve sera gazı emisyonlarının düşürülmesi, sürdürülebilir bir geleceğe ulaşma yolunda kritik adımlardır. Bu bağlamda, elektrikli araçların yaygınlaşması ve benimsenmesi hem ekonomik hem de çevresel açıdan önemli katkılar sağlamaktadır. Ancak, bu yeni nesil araçların benimsenmesinde sürücü davranışları, altyapı yetersizlikleri ve maliyet gibi çeşitli engeller bulunmaktadır.

Son yıllarda yapay zekâ ve makine öğrenmesi teknolojileri, enerji verimliliği ve sürücü davranışlarının analizinde yaygın olarak kullanılmaktadır. Bu teknolojiler, sürücü davranışları ile yakıt tüketimi arasındaki karmaşık ilişkileri ortaya çıkarmak için benzersiz olanaklar sunmaktadır. Sürüş alışkanlıkları; hızlanma ve frenleme dinamikleri, düzenli araç bakımı ve telematik cihazların kullanımı gibi faktörlerle ilişkilidir [1], [2], [3]. Özellikle agresif sürüş alışkanlıklarının (ani hızlanma ve sık fren yapma gibi) motorun daha fazla yakıt tüketmesine neden olduğu bilinmektedir [4]. Ayrıca, düzenli araç bakımı ve uygun lastik basınçlarının kontrolü gibi önlemlerin de yakıt tüketimini önemli ölçüde azalttığı literatürde yaygın olarak vurgulanmaktadır [1], [5], [6]. Bu bağlamda, sürücü davranışlarını daha verimli ve çevre dostu hale getirmek hem bireysel hem de toplumsal düzeyde önemli bir katkı sağlayacaktır.

Bu çalışmanın temel amacı, sürücü davranışlarının yakıt tüketimi ve verimliliği üzerindeki etkilerini kapsamlı bir şekilde incelemektir. Özellikle elektrikli araçların, mevcut sürücü davranış modelleri ile uyumu ve bu araç türlerinin yakıt verimliliğine olan katkıları araştırılmaktadır. Artan enerji ihtiyacı ve çevresel sorunlar karşısında, sürücü davranışlarını iyileştirme potansiyeli, bu çalışmanın önemini daha da artırmaktadır.

Çalışma, sürücülerin yakıt tüketimi farkındalığını artırarak daha bilinçli sürüş alışkanlıkları edinmelerine rehberlik etmeyi amaçlamaktadır. Bu bağlamda, elektrikli araçlara olan ilgiyi belirleyen faktörlerin incelenmesi, bu araçların benimsenmesini hızlandıracak stratejiler geliştirilmesine katkı sağlayacaktır.

Çalışma, çevrimiçi bir anketle toplanan 304 katılımcı verisine dayanmaktadır. Anket soruları, sürücülerin demografik özelliklerini, günlük sürüş alışkanlıklarını ve elektrikli araçlara yönelik tutumlarını anlamaya yönelik olarak tasarlanmıştır. Katılımcılardan toplanan veriler, makine öğrenmesi teknikleri kullanılarak analiz edilmiş ve bu analizler yoluyla, elektrikli araçlara olan ilginin bilgi seviyesi, maliyet algısı ve altyapı erişimi gibi çeşitli faktörlerden etkilendiği davranış kalıpları ortaya çıkarılmıştır. Elde edilen bulgular, daha çevre dostu ve enerji verimli sürüş alışkanlıklarının teşviki için öneriler sunmaktadır.



2. LİTERATÜR TARAMASI

Bu bölümde, sürüş alışkanlıklarının yakıt ekonomisi üzerindeki etkilerini anlamak ve yeni teknolojilerin bu etkileri nasıl dönüştürebileceğini analiz eden mevcut literatür özetlenmiştir.

2010 yılında Lu ve ekibi [7], boyuna sürüş davranışlarını ölçülebilir parametrelerle karakterize eden bir çalışmada, sürücülerin sürüş stillerini, yeteneklerini ve özelliklerini dört ana kategori (agresif vs. ihtiyatlı, istikrarsız vs. istikrarlı, risk eğilimli vs. riskten kaçınan, yetersiz vs. yetenekli) üzerinden değerlendirmiştir. Araç içi veri toplama sistemleriyle toplanan veriler, K-means kümeleme algoritması kullanılarak analiz edilmiş ve sürücüler bu kategorilere ayrılmıştır. Çalışma, sürüş davranışlarını sabit takip, yaklaşma, hızlanma, frenleme, gaz pedalı kullanımı ve pedal geçişi olmak üzere altı fazda incelemiştir. Sonuçlar, agresif sürücülerin daha kısa zaman baş mesafesi (Time Headway, THW) ile araçları takip ettiğini ve daha riskli çarpışma önleme kararları aldığını göstermiştir. Zaman baş mesafesi, bir aracın belirli bir hızda seyahat ederken, önündeki araca ulaşması için geçen süreyi saniye cinsinden ölçmektedir. Benzer şekilde, istikrarsız sürücüler, istikrarlı sürücülere kıyasla daha değişken bir zaman baş mesafesi sergilemiştir. Yeteneği düşük sürücülerin ise daha sık ve daha yüksek hızda ani frenleme yaptığı tespit edilmiştir.

2011 yılında Raksit Thitipatanapong ve Thanad Luangnarutai [4] tarafından yapılan bir çalışmada, sürücü davranışlarının yakıt ekonomisi üzerindeki etkileri incelenmiştir. Tayland'da yapılan deneylerle, farklı sürüş davranışlarının yakıt tüketiminde %30'a varan farklar yarattığı gösterilmiştir. Araştırmada, araç içi teşhis sistemi (On-Board Diagnostics, OBD-II) kullanılarak sürüş verileri toplanmış ve bu veriler arasında araç hızı (Vehicle Speed Sensor, VSS) ve kütleli hava akışı (Mass Air Flow, MAF) gibi parametreler yer almıştır. sürücü davranışlarının değerlendirilmesi için Araç Dinamik İndeksi (Vehicle Dynamics Index, VDI) geliştirilmiş ve bu indeks hızlanma ile kat edilen mesafe arasındaki ilişkiyi analiz etmek için kullanılmıştır. Üç farklı sürüş tarzına sahip (agresif, ölçülü ve sakin) sürücüler, toplam 11 kilometrelik bir güzergâhta test edilmiştir. Analiz sonuçları, agresif sürücülerin daha yüksek VDI değerlerine

sahip olduğunu ve bu durumun yakıt ekonomisini olumsuz etkilediğini göstermiştir. Ayrıca, agresif sürüş davranışlarının, aşırı hızlanma ve ani manevralar nedeniyle yakıt tüketimini belirgin şekilde artırdığı tespit edilmiştir.

2013 yılında Jianqiang Wang, Keqiang Li ve Xiao-Yun Lu [8] tarafından yapılan bir çalışmada, insan faktörlerinin sürücü davranışları üzerindeki etkileri kapsamlı bir şekilde incelenmiş ve sürücü davranışlarını etkileyen faktörlerin yakıt tüketimi üzerindeki etkileri değerlendirilmiştir. Araştırmada, MATLAB tabanlı simülasyonlar ve gerçek dünya deneyleri kullanılarak sürüş senaryoları ve sürücü davranışları değerlendirilmiştir. Zaman baş mesafesi (Time Headway, THW), çarpışmaya kalan zaman (Time to Collision, TTC) ve hızlanma gibi ölçülebilir parametreler üzerinden hız, mesafe ve güvenlik açısından analizler yapılmıştır. Veriler, Kalman filtresi ile işlenerek doğruluğu artırılmış ve demografik faktörlerin (yaş, cinsiyet, deneyim) sürüş davranışları üzerindeki etkileri t-testi ve faktör analizi ile incelenmiştir. Sonuçlar, yaşlı sürücülerin daha temkinli ve düzenli bir sürüş tarzı sergilediğini, genç sürücülerin ise daha agresif ve riskli davranışlarda bulunduğunu göstermiştir. Aynı yıl, Karl W. Dunkle Werner [9] tarafından yapılan bir başka çalışmada, sürücü davranışlarının yakıt tüketimi üzerindeki etkileri incelenmiştir. Doğal sürüş verileri kullanılarak, GPS, hız sensörleri ve yakıt tüketimi ölçüm cihazlarıyla toplanan saniyelik veriler analiz edilmiştir. 108 sürücünün 17 milyondan fazla gözlemi değerlendirilmiş, hatalı veya eksik veriler temizlenerek Kalman filtresi ile doğruluk artırılmıştır. Yakıt tüketimi, motorun saniyelik tüketimi ve kat edilen mesafeye göre hesaplanmış; zaman baş mesafesi ve hızlanma gibi parametreler incelenmiştir. Çalışmada sabit etkiler modeli kullanılarak sürücü davranışlarının yakıt tüketimindeki farklılıkları analiz edilmiş ve en verimli sürüş tarzlarının toplam yakıt tüketiminde %17-26 oranında azalma sağlayabileceği belirlenmiştir.

2014 yılında Norbert E. Ligterink ve Arjan R.A. Eijk [10] tarafından yapılan bir çalışma, binek araçların gerçek dünya yakıt tüketimini analiz etmiştir. Çalışma, resmi tip onay değerleri ile gerçek dünya yakıt tüketimi arasındaki artan farkı vurgulamaktadır. Hollanda merkezli Travelcard şirketinin 2004-2014 yıllarına ait geniş veri seti kullanılarak, benzinli, dizel ve plug-in hibrit araçlar incelenmiştir. Plug-in hibrit araçlarda bu farkın %200'e kadar çıkabildiği tespit edilmiştir. Araştırmada, araçların model yılları, CO2 emisyon değerleri ve sürüş koşulları gibi faktörler analiz

edilmiştir. 2012 ve 2013 model araçlarda, tip onay değerleri ile gerçek dünya yakıt tüketimi arasındaki farkın belirgin şekilde arttığı görülmüştür.

2015 yılında Samantha L. Jamson ve ekibi [11] tarafından yapılan çalışmada, sürücülerin eko-sürüş becerilerini öğrenme yeteneği ve bu becerilerin yakıt verimliliği ve güvenli sürüş davranışı üzerindeki etkileri incelenmiştir. Çalışmada, görsel ve haptik geri bildirim sistemlerinin etkileri analiz edilmiştir. Görsel geri bildirim sistemi, renk kodlu bir ekran aracılığıyla gaz pedalının ideal pozisyonunu gösterirken, haptik geri bildirim sistemleri, gaz pedalına uygulanan kuvvet veya pedal sertliği ile sürücülere rehberlik etmiştir. Katılımcıların performansı, gaz pedalının ideal pozisyonda tutulmasıyla ölçülen pedal hatası ve dikkat dağılımı (yola odaklanma yüzdesi) gibi metriklerle değerlendirilmiş, veriler üzerinde tekrarlı ölçümler ANOVA analizi yapılmıştır. Sonuçlar, görsel geri bildirim sisteminin yakıt verimliliğini artırmada en etkili yöntem olduğunu, ancak dikkat dağılımına neden olduğunu göstermiştir. Haptik sistemler ise dikkat dağılımını azaltarak güvenli sürüş açısından daha avantajlı bulunmuştur. Aynı yıl, Samantha M. Pampel ve ekibi [2], sürücülerin eko-sürüş becerilerini nasıl öğrendiklerini ve bu becerilerin yakıt verimliliği ile güvenli sürüş davranışları üzerindeki etkilerini incelemiştir. Simülatör ortamında yapılan çalışmada, sürücülerin farklı sürüş talimatları altında sergiledikleri davranışlar gözlemlenmiştir. Deneyde, katılımcılara dört farklı sürüş talimatı verilmiştir: “Normal sür”, “Güvenli sür”, “Çevreci sür” ve bir kontrol koşulu olarak “Normal sür” tekrarı. Her bir sürüş sırasında yakıt tüketimi, hız, hızlanma, frenleme ve takip mesafesi gibi objektif davranışsal ölçümler kaydedilmiştir. Ayrıca, Yüksek Sesle Düşünme Protokolleri ile katılımcıların anlık düşünceleri toplanmış ve bu veriler NVivo yazılımı kullanılarak analiz edilmiştir. Deney sonuçları, iki yönlü ANOVA ve post-hoc testleri gibi istatistiksel yöntemlerle değerlendirilmiş, farklı sürüş talimatlarının yakıt tüketimi ve güvenlik üzerindeki etkileri analiz edilmiştir. Çevreci sürüş talimatlarının, şehir içi sürüşlerde %7.7, otoyol sürüşlerinde ise %2.8 oranında yakıt tasarrufu sağladığı belirlenmiştir. Ancak bu talimatların, belirli koşullarda güvenlik risklerini artırabileceği tespit edilmiştir. Benzer şekilde, Lai [12], eko-sürüş motivasyonu, bilgi düzeyi ve ödül sisteminin yakıt verimliliği üzerindeki etkilerini inceleyen bir çalışma gerçekleştirmiştir. Çalışmada, Tayvan’daki iki otobüs şirketi kullanılarak deneysel bir tasarım uygulanmış ve sürücü davranışlarındaki değişikliklerin yakıt tüketimi üzerindeki etkileri analiz edilmiştir. Deney grubunda, yakıt tasarrufu sağlayan

sürücülere litre başına para ödülü verilmiş, kontrol grubunda ise herhangi bir ödül sistemi uygulanmamıştır. Araştırmada, aylık ortalama yakıt tüketimi verileri toplanarak deney ve kontrol grupları arasında karşılaştırmalar yapılmıştır. Deney grubundaki değişiklikler, bağımsız t-testi ile analiz edilmiş ve yakıt tüketimindeki iyileşmelerin istatistiksel olarak anlamlı olduğu belirlenmiştir. Ayrıca, regresyon analizi kullanılarak, ödül sisteminin yakıt verimliliği üzerindeki etkileri ile motivasyon ve bilgi düzeyindeki değişiklikler arasındaki ilişkiler incelenmiştir. Sonuçlar, ödül sisteminin uygulandığı grupta yakıt tüketiminin ilk ayda %7.6 oranında, takip eden aylarda ise %10'un üzerinde iyileştiğini göstermiştir. Ancak, ödül sisteminin sürücülerin eko-sürüş bilgisi ve motivasyonu üzerinde anlamlı bir etkisi olmadığı belirlenmiştir. Deney grubunda, ortalama yakıt tüketimi 3.3 km/l'den 3.62 km/l'ye yükselmiş ve toplamda 645,706 litre yakıt tasarrufu sağlanmıştır. Bu iyileşme hem karbon emisyonlarını azaltmış hem de şirketin operasyonel maliyetlerini düşürmüştür. Araştırma, eko-sürüş teşviklerinin yakıt verimliliğini artırmada etkili bir araç olduğunu ortaya koymakla birlikte, standart yakıt tüketim hedeflerinin belirlenmesi sırasında sürüş koşulları gibi değişkenlerin dikkate alınması gerektiğini vurgulamaktadır. Holmén ve Sentoff [13], hibrit-elektrikli araçların (Hybrid Electric Vehicle, HEV) gerçek dünya sürüş koşullarında karbon dioksit (CO₂) emisyonları ve yakıt tüketimi üzerindeki faydalarını değerlendiren kapsamlı bir çalışma gerçekleştirmiştir. Çalışma, aynı modelin hibrit ve geleneksel araç versiyonlarını, Vermont'un değişken arazi yapısında, farklı mevsim koşullarında ve çeşitli yol türlerinde karşılaştırmıştır. Araştırmada, taşınabilir emisyon ölçüm sistemleri (Portable Emissions Measurement System, PEMS) ile araçların hız, hızlanma, motor çalışma durumu ve egzoz emisyonları gibi verileri toplanmıştır. Yol eğimi, hava sıcaklığı ve hız profili gibi faktörler dikkate alınarak Araç Özgül Gücü (Vehicle Specific Power, VSP) hesaplanmıştır. Toplanan veriler üzerinde ANOVA analizi gerçekleştirilmiş ve hibrit araç ile geleneksel araç performansları arasındaki farklar istatistiksel olarak değerlendirilmiştir. Ayrıca, farklı sürüş koşullarında (şehir içi, otoyol) CO₂ emisyonları ve yakıt tüketimi avantajlarının nasıl değiştiğini incelemek için logaritmik regresyon uygulanmıştır. Çeşitli VSP sınıflarındaki performans farklılıkları ve yol türlerine göre enerji verimliliği analiz edilmiştir. Sonuçlar, HEV'lerin özellikle şehir içi sürüşlerde CO₂ emisyonlarını geleneksel araçlara göre %55 oranında azalttığını ortaya koymuştur. Ancak otoyol sürüşlerinde, yüksek hızların içten yanmalı motorun enerji talebini artırması nedeniyle HEV'nin avantajlarının

azaldığı görülmüştür. Yol eğimi gibi faktörlerin de performans üzerinde önemli bir etkisi olduğu belirlenmiştir; dik yokuşlarda hibrit sistemlerin verimliliği düşmüştür. Genel olarak, HEV'lerin yakıt tüketimini şehir içi sürüşlerde %18, otoyolda ise %33 oranında daha iyi optimize ettiği bulunmuştur.

2017 yılında yapılan çeşitli çalışmalar, eko-sürüş eğitiminin etkilerini ve sürüş davranış kalıplarının yakıt tüketimi üzerindeki etkilerini incelemiştir. Nocera ve ekibi [6] tarafından Çin'in Jiangsu eyaletinde yapılan saha deneyi, çevreci sürüş eğitiminin ağır yük araçlarında yakıt tüketiminde %5.5'lik bir azalma sağladığını göstermiştir. Çalışma, iki aşamalı bir deney tasarımı ile gerçekleştirilmiştir. Eğitim öncesi ve sonrası sürüş verileri toplanarak, yakıt tüketimi ve karbon emisyonları üzerindeki değişiklikler analiz edilmiştir. Veriler üzerinde ANOVA analizi uygulanmış ve çevreci sürüş eğitiminin etkisi istatistiksel olarak değerlendirilmiştir. Ayrıca, regresyon modelleri (lineer regresyon, çoklu regresyon, logaritmik regresyon) ile farklı sürüş koşullarının yakıt tüketimi üzerindeki etkileri incelenmiştir. Marta V. Faria ve ekibi [14], Lizbon'da yapılan bir çalışmada, sürüş bağlamının enerji tüketimi üzerindeki etkilerini ortaya koymuştur. Araçların hız, ivmelenme, motor durumu ve yakıt tüketimi verileri toplanmış, farklı yol türleri ve hava koşulları için analiz edilmiştir. Çalışmada, ANOVA ile yol türleri, hava koşulları ve yol eğimi gibi faktörlerin enerji tüketimine etkileri istatistiksel olarak değerlendirilmiştir. Ayrıca, çoklu doğrusal regresyon modelleri, hızlanma, frenleme gibi sürüş davranışlarının ve çevresel faktörlerin enerji tüketimine etkisini tahmin etmek için kullanılmıştır. Modeller, özellikle yağmur şiddeti ve yerel yolların enerji tüketimini önemli ölçüde artırdığını göstermiştir. Sonuçlar, yerel yollarda enerji tüketiminin ana arterlere göre %54 daha fazla olduğunu ve yağışlı havalarda enerji tüketiminde %16'lık bir artış olduğunu göstermiştir. Venkatesan Kanagaraj ve Martin Treiber [1], trafik için yakıt tüketimi ve emisyon modellerini incelemiş ve farklı trafik koşullarının yakıt tüketimi ve emisyonlar üzerindeki etkilerini analiz etmiştir. Çalışmada, makroskopik ve mikroskopik modelleme yöntemleri kullanılmış, trafik yoğunluğu, hız profilleri ve yol eğimi gibi faktörlerin yakıt tüketimi ve emisyonlarla olan ilişkisi incelenmiştir. Çok değişkenli doğrusal regresyon yöntemi kullanılarak hız, ivmelenme, durma süreleri ve yol eğimi gibi değişkenlerin yakıt tüketimi üzerindeki etkileri değerlendirilmiştir. Özellikle hız profilleri ve trafik akışı verileri, emisyon faktörleri ile ilişkilendirilmiştir. Ayrıca, ANOVA yöntemi ile farklı trafik durumları (serbest akış, sıkışık trafik, dur-kalk)

arasında yakıt tüketimi ve emisyon farklılıklarının istatistiksel anlamlılığı test edilmiştir. Trafik durumu ve yol türlerine göre yapılan kategorik analizlerde, sıkışık trafik koşullarının yakıt tüketimini ve emisyonları belirgin şekilde artırdığı, dur-kalk durumlarında ise bu etkinin en üst düzeye çıktığı bulunmuştur. Hız profilleriyle modal emisyon faktörleri arasında yapılan analizlerde, özellikle yüksek hız ve yoğun ivmelenme durumlarının emisyonları önemli ölçüde artırdığı belirlenmiştir. Heijne ve Ligterink [15] tarafından yapılan çalışmada, ağır hizmet araçlarının sürüş davranışı parametrelerinin emisyon faktörleri üzerindeki etkileri analiz edilmiştir. Hollanda'daki Euro VI araçlar üzerinde yapılan çalışmada, hız ve ivme gibi anlık parametreler "q-vektör" yöntemiyle analiz edilmiş ve veriler farklı yol türleri ve trafik koşullarına göre sınıflandırılmıştır. Emisyon faktörlerinin yol türleri, trafik sıkışıklığı seviyeleri ve araç kategorilerine göre farklılıklarını değerlendirmek için ANOVA kullanılmıştır. Bu analiz, farklı sürüş senaryolarında NOx ve CO2 emisyonlarındaki değişimlerin anlamlılığını test etmiştir. Ayrıca, çoklu doğrusal regresyon modelleri, hız, ivme ve diğer sürüş davranışı parametrelerinin emisyon faktörleri üzerindeki etkisini tahmin etmek için uygulanmıştır. Analizler, düşük hızlarda ve sıkışık trafik koşullarında NOx emisyonlarının arttığını, yüksek hızlarda ise kontrol sistemlerinin etkinliğinin yükseldiğini göstermiştir. Ayrıca, güç-ağırlık oranlarındaki artışın sürüş dinamiklerini ve emisyon tahminlerini etkilediği belirlenmiştir. Benzer şekilde, Heijne, Ligterink ve Stelwagen [16], Avrupa genelinde 150'den fazla sürücünün katılımıyla sürüş davranışlarının yakıt tüketimi üzerindeki etkilerini analiz etmek için geniş kapsamlı bir çalışma gerçekleştirmiştir. UDRIVE projesinden elde edilen 13.500 saatlik doğal sürüş verisi üzerinde yapılan analizlerde, frenleme enerjisi, vites değiştirme davranışı ve hız seçimi gibi üç temel sürüş davranışı yakıt tüketimini etkileyen kritik faktörler olarak belirlenmiştir. Özellikle frenleme sırasında kaybedilen enerji, düşük hızlarda toplam enerji tüketimine önemli ölçüde katkıda bulunmaktadır. Veriler, sürücülerin frenleme enerjisinde %120'ye varan farklar gösterdiğini ve bu farkın yakıt tüketimini %10'a kadar etkileyebileceğini ortaya koymuştur. İstatistiksel analizlerde ANOVA ve çoklu doğrusal regresyon modelleri kullanılmış, sürüş davranışlarının yakıt tüketimi üzerindeki etkileri detaylı bir şekilde incelenmiştir. Eko-skor adı verilen bir indeks geliştirilerek, frenleme, vites değiştirme ve hız dinamikleri gibi parametreler üzerinden yakıt tüketimi ile ilişkisi analiz edilmiştir. Çalışma, eko-skorlar temelinde yakıt tüketiminde %10 ila %25 arasında iyileştirme sağlanabileceğini ortaya koymuştur.

2018 yılında Benjamin Leard [17], tüketici dikkatsizliğinin araç yakıt maliyeti tasarrufu talebi üzerindeki etkilerini incelemiştir. Çalışma, tüketicilerin yakıt maliyeti tasarruflarını yeterince değerlendirmemesinin enerji verimliliği boşluğuna yol açtığını savunmaktadır. Çalışmada, tüketicilerin yakıt maliyeti tasarruflarına yönelik dikkat düzeyleri ve ödeme isteklilikleri, ayırık seçim deneyleri ve rastgele fayda modelleriyle analiz edilmiştir. Örneğin, dikkat düzeyine göre tüketicilerin yakıt tasarruflarına yönelik ödeme istekliliği, yakıt maliyeti tasarruflarının %45 ila %107'si arasında değişim göstermiştir. Tam dikkat gösteren katılımcılar, yakıt maliyeti tasarruflarının tam değerini ödemeye istekliken, dikkatsiz katılımcıların bu oranı %2'ye kadar düşmüştür. Yakıt tasarrufunun değerlendirilmesindeki dikkatsizliğin bireysel özelliklerle nasıl ilişkili olduğu incelenmiş ve tüketici tercihlerini etkileyen faktörler üzerinde regresyon analizleri gerçekleştirilmiştir. Araştırmanın sonuçları, tüketicilerin dikkat düzeylerinin enerji verimliliği politikalarının tasarımında önemli bir unsur olduğunu göstermiştir. Yang Wang ve Alessandra Boggio-Marzet [5] ise farklı yol türlerine göre eko-sürüş eğitiminin yakıt verimliliği ve emisyon azaltımı üzerindeki etkilerini değerlendirmiştir. Çalışmada, saha deneyi kapsamında iki araç (dizel ve benzinli) kullanılmış ve sürüş verileri gerçek trafik koşullarında toplanmıştır. Toplanan veri seti R programlama diliyle işlenerek, sürüş desenlerini ve yol türlerini değerlendirmeye yönelik 128 değişken içeren bir analiz yapılmıştır. Sürüş performansı, yakıt tüketimi ve trafik yoğunluğuna ilişkin çoklu regresyon analizleri gerçekleştirilmiş ve agresif hızlanma, ani yavaşlama, maksimum devir ve hız gibi sürüş parametreleri karşılaştırılmıştır. Eko-sürüş eğitimi sonrası, sürücülerin yakıt tüketiminde genel olarak %6,3 oranında azalma sağlanmıştır. Ayrıca, agresif hızlanma, ani yavaşlama, maksimum devir ve hız gibi sürüş parametrelerinde belirgin iyileşmeler gözlemlenmiştir. Bu değişimler, sürücülerin daha sakin bir sürüş tarzı benimsemelerine katkıda bulunmuştur. Sonuçlar, yol türüne bağlı olarak eko-sürüş uygulamalarının etkinliğinin değiştiğini ve özellikle arter yollar üzerinde yakıt tasarrufunun en yüksek düzeye ulaştığını göstermiştir.

2019 yılında Peng Ping ve ekibi [3], sürücü davranışının yakıt tüketimi üzerindeki etkisini makine öğrenimi kullanarak incelemiştir. İlk aşamada, sürüş davranışlarını yakıt tüketimi ile ilişkilendiren makro düzeyde analizler gerçekleştirilmiştir. Bu analizlerde, spektral kümeleme yöntemi kullanılarak sürücüler hız, hızlanma ve yakıt tüketimi özelliklerine göre üç farklı gruba ayrılmıştır. İkinci aşamada, kısa dönem

yakıt tüketimini tahmin etmek amacıyla LSTM (Long Short-Term Memory) tabanlı bir model geliştirilmiştir. Bu model, sürüş davranış verileri ile dinamik trafik koşullarını birleştirerek, gerçek zamanlı yakıt tüketimi tahminleri yapmıştır. Çalışmada ayrıca, yakıt tüketimi ile güçlü ilişkiye sahip özellikler Pearson korelasyon katsayısı kullanılarak belirlenmiş ve yalnızca bu özellikler analize dahil edilmiştir. Bu iki aşamalı yaklaşım, hem makro düzeyde davranış sınıflandırmasında hem de mikro düzeyde tahminlerde yüksek doğruluk sağlamış, spektral kümeleme yöntemiyle sürücüler %79.31 doğruluk oranıyla sınıflandırılmıştır. Lee ve Wu [18], elektrikli araçların sürüş davranışlarını modellemek ve güç tüketimini optimize etmek amacıyla, Genişleyen Hiyerarşik Öz-Öğrenen Haritalar (Growing Hierarchical Self-Organizing Maps, GHSOM) ve Destek Vektör Makineleri (Support Vector Machines, SVM) gibi makine öğrenimi yöntemlerini birleştirerek sürüş kalıplarını analiz etmiştir. Çalışma, 9 ay boyunca bir elektrikli araçtan ve 3 ay boyunca bir filo kapsamında toplanan verilerle dört ana sürüş modu (şehir içi, karışık, otoyol, servis) tanımlamıştır. Sınıflandırmalar %97,5 doğruluk oranıyla gerçekleştirilmiş ve şehir içi modunda ortalama menzil 40.1 ± 7.8 km, otoyol modunda ise 70.5 ± 7.7 km olarak belirlenmiştir. Sonuçlar, agresif sürüşün enerji tüketimini %30 artırabileceğini, sakin sürüşün ise yakıt verimliliğini %20 artırmada etkili olduğunu göstermektedir.

2020 yılında He Zhang ve ekibi [19], sosyo-demografik özellikler ve sürüş davranışlarının yakıt verimliliği üzerindeki etkilerini analiz etmiştir. Çalışmada yoğun bir otoyol kesitinden toplanan doğal sürüş verileri kullanılmış ve yakıt verimliliği FASTSim simülasyon modeliyle hesaplanmıştır. Araştırmada, sürücüler hız, hız varyansı ve hızlanma gibi sürüş parametrelerine göre hiyerarşik kümeleme yöntemiyle sınıflandırılmıştır. Sosyo-demografik veriler, mini anketler yoluyla toplanmış ve çoklu regresyon analizleriyle yakıt verimliliği üzerindeki etkileri değerlendirilmiştir. Zirve ve zirve dışı saatlerde sürüş davranışları ve yakıt verimliliği ayrı ayrı incelenmiştir. Zirve saatlerde, yüksek hızda sabit hız varyansıya seyreten sürücülerin en yüksek yakıt verimliliğine ulaşırken, düşük hızda ve yüksek hız varyansına sahip sürücülerin en düşük yakıt verimliliğine sahip olduğu bulunmuştur. Sosyo-demografik özellikler açısından, zirve saatlerde kadın sürücülerin yakıt verimliliği erkeklere göre %11.4 daha düşük çıkmış, zirve dışı saatlerde ise sık seyahat eden sürücülerin %7.8 daha fazla yakıt tükettiği görülmüştür. Aynı yıl Angela Sanguinetti ve ekibi [20], araç içi ekoyol sürüş geri bildiriminin yakıt ekonomisi üzerindeki ortalama etkisini inceleyen bir

meta-analiz sunmuştur. 17 çalışma ve 23 etki boyutundan elde edilen veriler, geri bildirimin yakıt ekonomisinde %6.6'lık bir iyileşme sağladığını göstermiştir. Meta-analizde, veri heterojenliğini dikkate almak için rastgele etkiler modeli kullanılmış ve sonuçların güvenilirliği istatistiksel olarak test edilmiştir. Moderatör analizleri ile geri bildirim tasarım özellikleri ve diğer çalışma parametrelerinin yakıt ekonomisi üzerindeki etkisi değerlendirilmiştir. Özellikle hem anlık hem de birikmiş bilgi sunan geri bildirimlerin, sadece bir tür bilgi sunan sistemlere kıyasla daha etkili olduğu bulunmuştur. Çalışma ayrıca, geri bildirim süresinin uzamasıyla etkinliğin azaldığını, ancak eğitim veya ödül gibi stratejilerle birleştirildiğinde etkisinin arttığını ortaya koymuştur. Gijlswijk ve ekibi [21], 2004-2020 yılları arasındaki yaklaşık 52 milyon yakıt dolum kaydı ve 1,8 milyon şarj olayı verisini kullanarak, yakıt türü ve araç kategorilerine göre emisyon faktörleri ile kilometre başına enerji tüketimi arasındaki ilişkiyi incelemiştir. Çalışmada, gerçek dünya yakıt tüketimi ve CO2 emisyonları, üreticilerin tip onay değerleriyle karşılaştırılmış ve dünya çapında hafif araçların yakıt tüketimi ve emisyonlarını daha gerçekçi koşullarda ölçmeyi amaçlayan WLTP ile daha basit ve laboratuvar odaklı bir test olan NEDC arasındaki geçiş sürecinin etkileri analiz edilmiştir. Elektrikli araçlarda enerji tüketimi şarj verileriyle eşleştirilmiş ve ortalama tüketimin WLTP değerlerinden %18 daha yüksek olduğu belirlenmiştir. Yüksek kilometreli araçlarda, kilometre arttıkça tüketimde hafif bir artış olduğu görülmüştür. Ayrıca, E10 benzine geçişin tüketim üzerindeki etkileri analiz edilmiştir ancak belirgin bir sonuç elde edilmemiştir. Çalışmada, istatistiksel analizler kapsamında veri setindeki tüketim farklılıklarını değerlendirmek için ortalama ve varyans analizleri kullanılmış, farklı araç gruplarının tüketim trendlerini karşılaştırmak için regresyon modelleri uygulanmıştır. Bu yöntemler, yakıt türü ve araç yaşının tüketim üzerindeki etkilerini anlamaya yardımcı olmuştur.

2021 yılında Panagiotis Fafoutellis, Eleni G. Mantouka ve Eleni I. Vlahogianni [22], eko-sürüşün yakıt verimliliği üzerindeki etkilerini ve bu alanda kullanılan teknolojiler ile veri odaklı yöntemleri incelemiştir. Çalışmada, hem fizik tabanlı modeller hem de veri odaklı yöntemler kullanılarak sürüş davranışlarının yakıt tüketimine etkisi analiz edilmiştir. Fizik tabanlı modellerde, aerodinamik direnç, hızlanma, araç ağırlığı gibi fiziksel parametreler dikkate alınmış ve yakıt tüketimi ile emisyon tahminleri yapılmıştır. Veriye dayalı analizlerde ise, doğrusal regresyon, karar ağaçları ve derin öğrenme yöntemleri kullanılmış, özellikle LSTM ağları sürücü davranışlarını

sınıflandırmak ve yakıt tüketimini tahmin etmek için uygulanmıştır. Mikro düzeydeki analizlerde, hız ve hızlanma gibi anlık değişkenlerin etkisi incelenirken, makro düzeydeki modellerde ortalama hız ve trafik yoğunluğu gibi genel parametreler değerlendirilmiştir. Araştırmada, eko-sürüş uygulamalarının yakıt tüketimini %15-25 oranında azaltabileceği, hız ve hızlanmanın bu azaltım üzerinde en büyük etkiye sahip olduğu ortaya koyulmuştur. Ayrıca, dış faktörler arasında trafik yoğunluğu ve yol eğiminin yakıt tüketimindeki farklılıkları anlamada önemli değişkenler olduğu vurgulanmıştır. Yuhan Huang ve ekibi [23] ise sürücülerin gerçek sürüş yakıt tüketimi ve emisyon performansı üzerindeki etkilerini incelemiştir. Araştırma, 15 yeni ve 15 deneyimli sürücünün aynı dizel aracı aynı güzergahta sürmesi ile gerçekleştirilmiştir. Çalışmada, gaz pedalının agresif kullanımının yakıt tüketimi ve emisyonlarla ilişkisi doğrusal regresyon analizi ile değerlendirilmiştir. Sonuçlar, yeni sürücülerin gaz pedalını daha agresif kullandığını ve daha yüksek araç ve motor hızlarına ulaştıklarını göstermiştir. Bu davranış, yeni sürücülerin yakıt tüketiminin deneyimli sürücülerinkinden %2 daha yüksek olmasına yol açmıştır.

2022 yılında Zhang ve ekibi [24], otonom araçların yakıt tüketimindeki tasarruf potansiyelini ve insan sürücülü araçlarla karşılaştırmalı olarak performanslarını analiz eden bir araştırma gerçekleştirmiştir. Çalışma, hız dalgalanmalarının yakıt tüketimi üzerindeki etkisini teorik ve deneysel olarak incelemiştir. Teorik analizde, hız dalgalanmalarının yakıt tüketimine olan etkisi VSP (Vehicle Specific Power) modeliyle değerlendirilmiş ve hız, hızlanma, direnç faktörleri gibi parametreler kullanılarak yakıt tüketimi tahmin edilmiştir. Simülasyon deneylerinde, gerçek sürüş hız verileri hareketli ortalama filtresiyle işlenmiş ve farklı dalgalanma senaryoları oluşturularak yakıt tüketimi karşılaştırılmıştır. Saha testleri kapsamında, otonom bir araç, sabit hızda (20 km/s ve 40 km/s) hem insan sürücülü hem de otonom modlarda test edilmiştir. Bu testler, otonom modda hız dalgalanmalarının daha az olduğunu ve yakıt tüketiminin insan sürücülü moda göre %5,6 ile %14,7 arasında daha düşük olduğunu göstermiştir. Ayrıca, insan sürücülü modda agresif hızlanma ve yavaşlama davranışlarının yakıt tüketimini %60'a kadar artırdığı gözlemlenmiştir. Çalışmada, hız dalgalanmalarının yakıt tüketimi üzerindeki etkisinin doğrusal bir artış gösterdiği ve otonom araçların elektronik kontrol sistemleri sayesinde hızlarını daha kararlı bir şekilde koruyarak bu dalgalanmaları minimize ettiği ortaya konulmuştur. Bu durumun,

otonom araçlarda yakıt tüketimini optimize eden en önemli faktörlerden biri olduğu vurgulanmıştır.

2023 yılında yapılan çeşitli çalışmalar, sürüş davranışlarının yakıt tüketimi ve sürüş performansı üzerindeki etkilerini kapsamlı bir şekilde incelemiştir. Zhizhuo Su, Roger Woodman, Joseph Smyth ve Mark Elliott [25] tarafından yürütülen çalışma, agresif sürüş davranışlarının sürücü performansı üzerindeki etkilerini inceleyen sistematik bir literatür taraması ve meta-analiz sunmuştur. Çalışma, PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) yönergelerine uygun olarak 2412 çalışma arasından belirlenen kriterlere uygun olanları seçerek 31 farklı araştırmadan 34 deneyin verilerini değerlendirmiştir. Meta-analiz, rastgele etkiler modeli kullanılarak gerçekleştirilmiş ve heterojenlik testi için I^2 istatistiği uygulanmıştır. Agresif sürüşün hız, şerit kontrolü ve sürüş hataları gibi performans ölçütleri üzerindeki etkileri, DerSimonian ve Laird yöntemleri ile analiz edilmiştir. Ayrıca, her bir çalışmanın sonuçlara etkisini değerlendirmek için hassasiyet analizi yapılmıştır. Yayın yanlılığı analizi, funnel plot yöntemiyle gerçekleştirilmiş ve bu durumun sonuçlar üzerindeki etkisi incelenmiştir. Çalışmada, deneylerin bir kısmında agresif sürüşü indüklemek için trafik sıkışıklığı veya kurgusal stres senaryoları kullanılırken, diğerlerinde katılımcılardan kendi agresif deneyimlerini hayal etmeleri istenmiştir. Bu yöntemlerin etkinliği narratif sentezle değerlendirilmiş ve agresif sürüş davranışlarının ölçüm yöntemlerine etkisi analiz edilmiştir. Sonuçlar, agresif sürüşün ortalama hızda 5,32 km/h artışa ve sürüş hatalarının 2,51 kat artmasına neden olduğunu göstermiştir. Ayrıca, bu davranışın trafik güvenliği, enerji tüketimi ve hava kirliliği üzerindeki olumsuz etkileri vurgulanmış ve agresif sürüşün diğer sürücüler üzerindeki tetikleyici etkilerine dikkat çekilmiştir. Dengfeng Zhao ve ekibi [26], yakıt tüketimini veriye dayalı yöntemlerle tahmin etmenin yollarını incelemiş ve makine öğrenimi modelleri ile yapay sinir ağlarının bu tahminlerdeki etkinliğini vurgulamıştır. Çalışmada, büyük veri setleri üzerinde doğrusal olmayan ilişkileri analiz edebilmek için SVM, Random Forest ve XGBoost gibi makine öğrenimi algoritmaları kullanılmıştır. Bu yöntemlerin doğruluğunu artırmak için, veri ön işleme sürecinde temel bileşen analizi ve Pearson korelasyon katsayısı gibi boyut azaltma teknikleri uygulanmış ve yalnızca en alakalı değişkenler modele dahil edilmiştir. Sinir ağları kapsamında, yapay sinir ağları ve LSTM modelleri üzerinde çalışılmış, özellikle LSTM'nin zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenme yeteneği sayesinde daha tutarlı ve hassas tahminler

sağladığı bulunmuştur. Hibrit modellerin de ele alındığı çalışmada, birden fazla algoritmanın kombinasyonu kullanılarak tahmin doğruluğu artırılmıştır. Örneğin, Random Forest ve XGBoost algoritmalarının birleşimiyle hem genelleme kapasitesi hem de model kararlılığı geliştirilmiştir. Performans değerlendirmesinde, hata oranlarının karşılaştırılması yapılmış ve derin öğrenme tabanlı modellerin, geleneksel makine öğrenimi yöntemlerine kıyasla daha düşük hata oranları ürettiği tespit edilmiştir. Çalışma, veriye dayalı yöntemlerin yakıt tüketimi tahmininde fiziksel modellere kıyasla daha esnek ve etkili olduğunu göstermiş ve bu alanda hibrit modellerin kullanımıyla daha da başarılı sonuçlar elde edilebileceğini vurgulamıştır. Mariusz Graba ve ekibi [27], benzinli bir binek otomobilin hızlanma sürecinde enerji verimliliğini ve dinamiklerini incelemiş, hızlanma yoğunluğunun yakıt tüketimini önemli ölçüde artırdığını tespit etmiştir. 45 km/h ile 120 km/h hız aralığında sabit vites oranında gerçekleştirilen testlerde, hızlanma yoğunluğu arttıkça yakıt tüketiminin doğrusal bir şekilde yükseldiği belirlenmiştir. Gaz pedalının %45'in üzerinde açıldığı durumlarda yakıt tüketiminde önemli artışlar kaydedilmiş, hızlanma yoğunluğu 0.8 m/s² üzerinde olduğunda enerji tüketiminin optimal değerlerin dışına çıktığı gözlemlenmiştir. Çalışma, hızlanma sırasında kütle ve enerji tüketimi ilişkisini değerlendiren "dinamik indeks" ölçütünü önererek, enerji verimliliğini optimize etmeye yönelik stratejiler geliştirilmesine katkı sağlamıştır. Boya Zhou ve ekibi [28], benzinli araçların yakıt tüketimi ve CO₂ emisyonlarının laboratuvar ve gerçek dünya yol testleri altındaki değişkenliğini analiz ederek, gerçek dünya sürüş koşullarının yakıt ekonomisi üzerinde önemli bir etkisi olduğunu ortaya koymuştur. Kullanılan analiz yöntemleri arasında şasi dinamometresi testleri, yol testleri ve farklı yol yük katsayılarının etkilerini değerlendiren matematiksel modelleme yer almıştır. Yol testlerinde, araç hızına bağlı yakıt tüketimi analiz edilmiş ve düşük hızlarda (25 km/s altı) tüketimde %63'e varan artışlar olduğu tespit edilmiştir. Hızın 25 km/s üzerine çıkmasıyla bu etkilerin azaldığı görülmüştür. Araştırmada, laboratuvar testlerinin gerçek dünya koşullarını yeterince yansıtamayabileceği ve bu nedenle düzenlemelerde yol testlerinin dikkate alınması gerektiği önerilmiştir. Peng ve ekibi [29], HEV'lerin yakıt tüketimini gerçek dünya sürüş koşullarında değerlendirmek için hız tabanlı VSP dağılımlarını kullanarak bir yöntem geliştirmiştir. Veriler, araçtan OBD sistemleri ve GPS cihazlarıyla toplanmış, hız, hızlanma, eğim ve motor çalışma durumları analiz edilmiştir. Yakıt tüketimi, hız aralıklarına göre farklı VSP kategorilerinde sınıflandırılarak Gaussian karışım modelleriyle tahmin edilmiştir. Çalışma, geleneksel

araçlar için kullanılan yakıt tüketim modellerinin, hibrit araçlarda düşük hızlarda (30 km/s altı) tüketimi fazla tahmin ederken, yüksek hızlarda (50 km/s üzeri) tüketimi düşük tahmin ettiğini ortaya koymaktadır. Bu fark, hibrit araçların hız aralığına göre değişen güç aktarım stratejilerinden kaynaklanmıştır. Sonuçlar, hız tabanlı VSP dağılımlarını kullanan yöntemin, hibrit araçların yakıt tüketimini %2.2'lik bir hata oranıyla doğru tahmin ettiğini ortaya koymuştur. Kumar ve Jain [30], araç içi teşhis sistemi verilerini kullanarak sürüş davranışlarının analizi ve sınıflandırılmasına yönelik bir model geliştirmiştir. Araştırma, sürücünün yakıt tüketimi, direksiyon kararlılığı, hız kararlılığı ve frenleme alışkanlıkları gibi parametrelerini analiz ederek sürüş davranışlarını on sınıfa ayırmayı hedeflemiştir. Çalışma kapsamında, araç içi sensörlerden toplanan veriler OBD-II protokolü ile toplanmış ve bu veriler arasında motor devri, araç hızı, frenleme durumu, uzunlamasına ivme ve direksiyon açısı gibi 50'den fazla parametre yer almıştır. Veriler, zaman serisi formatında düzenlenerek analiz edilmiştir. Sınıflandırma işlemi için makine öğrenimi algoritmaları kullanılmıştır. Random Forest algoritması, karar ağaçlarını birleştirerek sınıflandırma doğruluğunu artırmış ve %100 doğruluk oranıyla en başarılı yöntem olarak belirlenmiştir. SVM, veri setindeki sınıfları ayırmak için doğrusal bir hiperdüzlem oluşturarak etkili sonuçlar sağlamıştır. AdaBoost algoritması, yanlış sınıflandırılmış örnekler üzerinde ağırlıkları artırarak modeli geliştirmiş ve yüksek doğruluk oranlarına ulaşmıştır. Her algoritma, veri seti %70 eğitim ve %30 test oranında bölünerek doğrulanmıştır. Sınıflandırma sonuçları, hız kararlılığı, frenleme alışkanlıkları ve yakıt tüketimi gibi parametrelerin sürüş davranışlarının karakterizasyonunda önemli olduğunu göstermiştir. Çalışma, bu analizlerin trafik güvenliği, sürüş eğitimi ve sigorta politikaları gibi alanlarda uygulanabilirliğini vurgulamış ve sürüş davranışlarının iyileştirilmesine yönelik veri tabanlı yaklaşımların etkili bir çözüm sunabileceğini ortaya koymuştur. Zhang ve ekibi [31], yük taşımacılığında sürücü davranışlarının araç yakıt tüketimi ve CO₂e emisyonları üzerindeki etkilerini inceleyen bir araştırma gerçekleştirmiştir. Bu çalışmada, 4000'in üzerinde taşımacılık kaydından oluşan gerçek dünya verileri analiz edilerek çeşitli sürücü davranışlarının etkileri incelenmiştir. Veriler, telematik sistemler aracılığıyla toplanmış ve hızlanma, frenleme, motor devri ve hız limitine uyum gibi davranışlar detaylı şekilde değerlendirilmiştir. COPERT modeli (Computer Programme to Calculate Emissions from Road Transport) kullanılarak araç hızına, yol koşullarına ve motor türüne bağlı olarak yakıt tüketimi ve emisyon tahminleri yapılmıştır. Çalışmada ayrıca, çoklu

doğrusal regresyon modeli uygulanarak sürücü davranışlarının yakıt tüketimi üzerindeki etkileri istatistiksel olarak analiz edilmiştir. Gerçek yakıt tüketimi verileri ile COPERT modeli sonuçları karşılaştırılarak, sürüş davranışlarının yakıt tüketimi üzerindeki rolü izole edilmiştir. Araştırma, sert hızlanma ve keskin dönüşlerin yakıt tüketimi üzerinde en önemli etkiye sahip faktörler olduğunu ortaya koymuştur. Örneğin, sert hızlanmalar toplam seyahat mesafesinin yalnızca %6'sını oluşturmalarına rağmen, toplam yakıt tüketiminin %20'sine katkıda bulunmaktadır. Ayrıca, hız sınırlarına uyumsuzluğun özellikle 20 mph ve 30 mph gibi düşük hız sınırlarında yakıt tüketimini önemli ölçüde artırdığı belirlenmiştir. Bu bulgular, sürüş davranışlarının optimize edilmesinin yakıt tasarrufu ve emisyon azaltımı için kritik olduğunu göstermektedir.

2024 yılına ait çalışmalar da bu doğrultuda sürdürülmüş, enerji verimli sürüş davranışlarını ve bu alanda uygulanan yapay zekâ yöntemlerini kapsamlı bir şekilde incelemiştir. Zhipeng Ma, Bo Nørregaard Jørgensen ve Zheng Ma'nın çalışması [32], yapay zekâ tabanlı enerji verimli sürüş sistemlerinin geliştirilmesine yönelik önemli bir araştırma sunmuştur. Çalışmada, enerji verimli sürüş davranışlarını modellemek ve analiz etmek için hem denetimli hem de denimsiz makine öğrenimi algoritmaları kullanılmıştır. Enerji tüketimi tahmininde lineer regresyon, yapay sinir ağları ve Gaussian süreç regresyonu gibi algoritmalar uygulanmış ve hız, ivmelenme, yavaşlama gibi parametrelerin enerji tüketimi üzerindeki etkisi analiz edilmiştir. Pekiştirmeli öğrenme modelleri, karmaşık trafik senaryolarında enerji tasarruflu sürüş davranışlarını optimize etmek için geliştirilmiş ve bu modeller, enerji tüketimini %46 oranında azaltmayı başarmıştır. Çalışmada, veri toplama süreçleri için OBD-II cihazları ve CANbus sistemleri gibi araç içi veri kaynakları kullanılmıştır. Ayrıca, SHAP ve LIME algoritmaları ile özellik seçimi gerçekleştirilmiş ve yakıt tüketimini etkileyen en önemli değişkenler belirlenmiştir. Sonuçlar, enerji verimli sürüş davranışlarının optimize edilmesinde hız, ivmelenme, yavaşlama ve trafik durumu gibi faktörlerin kritik öneme sahip olduğunu göstermiştir. Rafael Canal ve ekibi [33] ise makine öğrenimi algoritmalarını kullanarak araçların elektronik kontrol ünitesinden alınan gerçek zamanlı verilerle yakıt tüketimi tahmini ve sürüş profili sınıflandırması yapmışlardır. Çalışmada, makine öğrenimi algoritmalarından K-Means, Lojistik Regresyon ve XGBoost kullanılarak sürüş profilleri ekonomik veya ekonomik olmayan olarak sınıflandırılmıştır. Ayrıca, yakıt tüketimini tahmin etmek için Ridge

Regresyonu, Destek Vektör Regresyonu (Support Vector Regression, SVR) ve XGBoost modelleri geliştirilmiş ve karşılaştırılmıştır. Özellik seçimi sürecinde, yakıt tüketimi ile güçlü bir korelasyona sahip 46 değişken seçilmiştir. Bu süreçte SelectPercentile, SelectKBest, SequentialFeatureSelector, SelectFromModel ve RFECV gibi algoritmalar kullanılmıştır. Çalışmada, sınıflandırma modelleriyle %100'e kadar doğruluk, kesinlik ve geri çağırma oranları elde edilmiş; regresyon modelleriyle ise Ortalama Kare Hata (MSE) 0.28 (l/h²), Ortalama Mutlak Hata (MAE) 0.23 (l/h) ve Determinasyon Katsayısı (R²) 0.99 değerleri yakalanmıştır. Bu yöntemler, sürüş sırasında gerçek zamanlı analiz sağlayarak sürücülerin anlık geri bildirim almasına ve yakıt tüketimini optimize etmelerine olanak tanımaktadır. Sami Shaffiee Haghsheenas ve ekibi [34], yapay zekâ destekli sürücü davranış analizinin yakıt tüketimini optimize etmedeki potansiyelini araştırmıştır. Çalışmada, hızlanma, frenleme ve rölanti süreleri gibi değişkenlerin yakıt tüketimi üzerindeki etkileri, makine öğrenimi algoritmalarıyla detaylı bir şekilde analiz edilmiştir. Yakıt tüketimini tahmin etmek ve sürüş davranışlarını modellemek için SVR, geri yayılım sinir ağları ve Random Forest gibi algoritmalar kullanılmıştır. Random Forest algoritması, doğruluk ve işlem verimliliği açısından diğer algoritmalarından üstün performans göstermiştir. Araçlardan OBD-II cihazlarıyla toplanan gerçek dünya verileri ve mobil uygulamalardan elde edilen sürüş verileri birleştirilmiştir. Bu veriler, hız, ivmelenme, frenleme oranları ve rölanti süreleri gibi faktörleri içerirken, veri işleme aşamasında SHAP ve LIME gibi özellik seçimi yöntemleri kullanılarak yakıt tüketimi üzerindeki etkili değişkenler belirlenmiştir. Ayrıca, sürüş davranışlarını kategorize etmek için spektral kümeleme yöntemi uygulanmış ve agresif hızlanma ile ani frenlemenin yakıt tüketiminde %20'ye varan artışlara neden olduğu tespit edilmiştir. Carlos Alberto Romero ve ekibi [35] ise, otomobil yakıt tüketimini azaltmak için geliştirilen stratejileri ve bu stratejilerin uygulanmasında karşılaşılan zorlukları kapsamlı bir şekilde ele almıştır. Çalışmada, yakıt tüketimini azaltmaya yönelik stratejiler; araç tasarımı, güç aktarım mekanizmaları, operasyonel faktörler ve trafik yönetimi olmak üzere dört temel kategoride incelenmiştir. Araç tasarımıyla ilgili olarak, motor verimliliğini artırma ve sürtünme kayıplarını azaltma üzerine odaklanılmış, bu amaçla matematiksel modelleme ve ileri simülasyon araçları kullanılmıştır. Güç aktarım mekanizmalarının değerlendirilmesinde, MATLAB/Simulink ortamında geliştirilen PSAT gibi araçlarla simülasyonlar gerçekleştirilmiş ve hafif malzemelerin kullanımının yakıt tüketimini %12'ye kadar düşürebileceği belirlenmiştir.

Operasyonel faktörlerin etkilerini değerlendirmek için dinamik programlama yöntemleri kullanılmış ve hızlanma, frenleme, rölanti süreleri gibi parametrelerin yakıt tüketimine etkisi analiz edilmiştir. Bu analizlerde, dur-kalk hareketlerinin azaltılması ve trafik akışının iyileştirilmesiyle yakıt tüketiminde %30'a kadar tasarruf sağlanabileceği tespit edilmiştir. Ayrıca, yakıt yaşam döngüsü analizleri ile yakıt üretimi ve kullanım süreçlerinin çevresel etkileri incelenmiş, düşük karbonlu yakıtların enerji verimliliğini artırmada önemli bir rol oynayabileceği vurgulanmıştır.

Özetlenen literatür, sürücü davranışlarının yakıt tüketimi ve enerji verimliliği üzerinde doğrudan etkili olduğunu ortaya koymaktadır. Araştırmalar, agresif sürüş davranışlarının yakıt tüketimini artırdığı, eko-sürüş tekniklerinin ise enerji verimliliğini önemli ölçüde iyileştirebildiğini göstermektedir. Bununla birlikte, teknolojik ilerlemeler, özellikle yapay zekâ ve makine öğrenimi uygulamaları, sürüş davranışlarının gerçek zamanlı analizini ve yakıt tüketimi tahminini mümkün kılarak bu alanda yeni fırsatlar sunmaktadır. Bu bulgular sürdürülebilir ulaşım ve enerji yönetimi hedeflerine ulaşmak için entegre bir yaklaşımın gerekliliğini ortaya koymaktadır. Gelecekteki araştırmalar, sürüş davranışlarını etkileyen faktörlerin daha derinlemesine anlaşılmasına ve eko-sürüş uygulamalarının genişletilmesine odaklanabilir. Bu bağlamda, teknolojik yeniliklerin yanı sıra toplumsal farkındalık ve eğitim programlarının da önemi büyüktür.

3. YÖNTEM

3.1. Anket Tasarımı

Anket soruları kapsamında katılımcıların demografik bilgileri, araç kullanımıyla ilgili davranışları ve çevre dostu sürüş tekniklerine yönelik yaklaşımları incelenmiştir.

Anketin ilk kısmında katılımcıların yaş, cinsiyet, ehliyet süresi, gelir durumu gibi demografik bilgileri ve mevcut araç özellikleri (örneğin, yakıt türü ve model yılı) toplanmıştır. İkinci kısımda, sürüş alışkanlıkları ve yakıt tüketimini etkileyen faktörler ile ilgili sorular yer almıştır. Katılımcılardan hız sınırlarına uyma, ani frenleme, hızlanma gibi davranışların sıklığını değerlendirmeleri istenmiştir. Ayrıca, yakıt ekonomisini artırmak için alınan önlemler (örneğin, eko mod kullanımı, rota planlaması) ve telematik sistemlerinin kullanımı sorgulanmıştır.

Elektrikli araçlara yönelik tutumları ölçmek amacıyla, katılımcılara bu araçlarla ilgili bilgi düzeyleri, kullanım niyetleri ve maliyet algılarıyla ilgili sorular yöneltilmiştir. Bunun yanı sıra, yaşadıkları bölgede bulunan elektrikli araç şarj istasyonlarının erişilebilirliğini değerlendirmeleri istenmiştir. Ankette, beşli Likert ölçeği kullanılarak katılımcıların çeşitli ifadelerle katılım düzeyleri ölçülmüş, bazı sorular ise çoktan seçmeli ya da açık uçlu yanıt formatında düzenlenmiştir.

Anket formu, katılımcıların soruları kolayca anlamasını sağlamak ve veri toplama sürecini optimize etmek için sade ve anlaşılır bir şekilde tasarlanmıştır. Çalışma kapsamında toplanan veriler, analiz süreçlerinde kapsamlı bir şekilde değerlendirilmiştir.

3.2. Veri Seti ve Katılımcılar

Bu çalışmada kullanılan veri seti, 24 Ocak 2024 ile 26 Kasım 2024 tarihleri arasında gerçekleştirilen çevrimiçi bir anket aracılığıyla toplanmıştır. Anket soruları, bu alandaki akademik literatür ve uzman görüşleri dikkate alınarak oluşturulmuş; sürüş alışkanlıkları, araç kullanımı, yakıt ekonomisi önlemleri ve elektrikli araçlara yönelik tutum gibi konuları kapsamıştır. Ankete 304 kişi katılmış ve katılımcılardan 18 yaş ve üzeri, geçerli bir sürücü ehliyetine sahip ve aktif araç kullanan kişiler olması şartı

aranmıştır. Veri toplama sürecinde etik kurallar titizlikle uygulanmış, katılımcılara çalışmanın amacı detaylı bir şekilde açıklanmış ve bilgilendirilmiş onayları alınmıştır. Toplanan veri seti, Python 3.12.7 sürümü kullanılarak analiz edilmiştir. Tüm bu işlemler Jupyter Notebook platformunda gerçekleştirilmiştir.

3.3. Veri Hazırlama ve Temizleme

Veri temizleme ve hazırlama süreci, analizin doğruluğunu artırmak ve verilerin kullanılabilirliğini sağlamak amacıyla özenle gerçekleştirilmiştir.

Başlangıç olarak analiz için gerekli olmayan sütunlar veri setinden çıkarılmış ve sütun isimleri daha okunabilir ve tutarlı hale getirilmiştir. Ardından, kategorik değişkenler sayısal formata dönüştürülmüştür. İkili kategorik değişkenler, "Evet" ve "Hayır" yanıtlarını sırasıyla 1 ve 0 olarak kodlamak için haritalanmıştır. Sıralı kategorik değişkenler ise önceden belirlenmiş sıralama yapısına uygun olarak sayısal değerlere dönüştürülmüştür. Geriye kalan kategorik değişkenler, one-hot encoding kullanılarak işlenmiştir. Numerik değişkenlerde aykırı değerler, kutu grafikleri ve IQR (Interquartile Range) yöntemiyle kontrol edilmiştir. Aykırı değerlerin veri setindeki oranı analiz edilmiş ve gerektiğinde bu değerler değerlendirmeye alınmıştır. Eksik veri kontrolü yapılmış ve eksik veriler, ilgili sütunlar için en sık görülen değerlerle doldurulmuştur. Tüm sayısal veriler, StandardScaler kullanılarak standartlaştırılmış ve analiz için ölçeklendirilmiştir. Bu, özellikle makine öğrenimi modellerinin verimli bir şekilde çalışması için önemli bir adımdır. Veri hazırlama sürecinin sonunda, veriler temizlenmiş, dönüştürülmüş ve analiz için hazır hale getirilmiştir.

3.4. Veri Analizi

Veri analizi sürecinde, elektrikli araçlara yönelik ilgiyi ve bu ilginin belirleyicilerini anlamak amacıyla kapsamlı istatistiksel ve makine öğrenimi yöntemleri uygulanmıştır. Hedef değişken (Future_EV_Interest), ankette Likert ölçeği ile oluşturulmuş ve 1'den 5'e kadar ilginin artmasını ifade eden bir formatta tasarlanmıştır. "1" ifadesi kesinlikle katılmıyorum anlamına gelirken, "2" katılmıyorum, "3" kararsızım, "4" katılıyorum ve "5" kesinlikle katılıyorum şeklinde ilgi düzeylerini ifade etmektedir. Bu değerler, bireylerin elektrikli araçlara olan ilgisini ölçmek için kullanılmış ve analiz sürecinde temel değişken olarak değerlendirilmiştir. Tanımlayıcı istatistikler ile veri setinin temel yapısı incelenmiş, korelasyon analizleri ile değişkenler arasındaki ilişkiler

belirlenmiş ve yeni özellikler türetilerek modelleme süreci güçlendirilmiştir. Ayrıca, hedef değişken tahmini için çeşitli makine öğrenimi algoritmaları (Random Forest, Lojistik Regresyon, SVM ve XGBoost) kullanılmış ve çapraz doğrulama yöntemleriyle modellerin genelleme performansları değerlendirilmiştir. Veri dengesizliklerini gidermek için SMOTE yöntemi uygulanmış ve tüm süreç boyunca veri kalitesini artırmak amacıyla eksik ve anormal değerler dikkatlice işlenmiştir. Bu yöntemler, elektrikli araçlara yönelik ilgiyi etkileyen temel faktörleri anlamaya ve model tahmin performansını artırmaya yönelik sistematik bir yaklaşım sunmuştur.

3.4.1. Korelasyon analizi

Korelasyon analizi, değişkenler arasındaki doğrusal ilişkiyi incelemek için kullanılan bir yöntemdir. Bu yöntem, bir değişkendeki artış veya azalışın diğer bir değişken üzerindeki etkisini anlamaya yönelik temel bir araçtır. Analiz sonucunda, değişkenler arasındaki ilişki pozitif, negatif veya yok olarak sınıflandırılabilir.

Pearson korelasyon katsayısı iki sürekli değişken arasındaki doğrusal ilişkiyi ölçmek için kullanılır ve -1 ile 1 arasında bir değer alır. Pozitif bir değer, bir değişkenin artışıyla diğerinin de arttığını; negatif bir değer ise bir değişkenin artışıyla diğerinin azaldığını ifade eder. Matematiksel olarak Denklem 3.1'deki gibi tanımlanır:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (3.1)$$

Burada X_i ve Y_i , sırasıyla X ve Y değişkenlerinin i 'nci gözlemlerini; $\bar{X}$ ve $\bar{Y}$, X ve Y değişkenlerinin ortalamalarını; n ise toplam gözlem sayısını ifade eder.

3.4.2. Random forest

Random forest, sınıflandırma ve regresyon problemlerinde kullanılan etkili bir ensemble yöntemidir. Bu algoritma, birden fazla karar ağacını eğiterek ve sonuçlarını birleştirerek daha yüksek doğruluk ve genelleme yeteneği sunar. Her bir karar ağacı, veriyi dallara ayırarak sınıflandırma veya tahmin yapar. Bölme işlemi, özelliklerin belirli eşik değerlerine göre yapılır ve bu süreç, ağaç yapısının kökten yapraklara kadar dallanmasına yol açar.

Karar ağacındaki bölme noktalarını belirlemek için entropi veya Gini indeksi gibi ölçütler kullanılır. Entropi, veri setindeki düzensizliği ölçer ve Denklem 3.2'deki gibi hesaplanır:

$$H(S) = - \sum_{i=1}^k p_i \log_2(p_i) \quad (3.2)$$

Burada S , veri kümesini; k , sınıf sayısını; ve p_i , i -inci sınıfa ait örneklerin oranını temsil eder. Gini indeksi ise veri setindeki saf olmayan durumun ölçüsüdür ve Denklem 3.3'teki gibi ifade edilir:

$$G(S) = 1 - \sum_{i=1}^k p_i^2 \quad (3.3)$$

Random forest algoritması, bootstrap örnekleme ve rastgele özellik seçimi yöntemlerini bir araya getirerek çalışır. İlk olarak, eğitim verisinden tekrarlarla örnekleme yapılarak farklı veri alt kümeleri oluşturulur. Ardından, her bir düğümde tüm özellikler yerine rastgele seçilen bir alt küme üzerinden en iyi bölme noktası belirlenir. Son aşamada, her ağacın tahmini alınarak sonuçlar birleştirilir. Sınıflandırma problemlerinde nihai tahmin çoğunluk oylaması ile yapılır ve Denklem 3.4'teki gibi ifade edilir:

$$\hat{y} = \text{Mode}\{h_1(x), h_2(x), \dots, h_B(x)\} \quad (3.4)$$

Regresyon problemlerinde ise her ağacın tahmini alınarak ortalama hesaplanır ve Denklem 3.5'teki gibi ifade edilir:

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B h_b(x) \quad (3.5)$$

Random forest, aşırı uyum (overfitting) riskini azaltır ve genelleme yeteneğini artırır. Özellikle, rastgele alt örnekleme ve özellik seçimi sayesinde model, veri setine aşırı bağlı kalmaz. Bununla birlikte, büyük veri kümelerinde hesaplama maliyetinin yüksek olması gibi bir dezavantajı vardır. Ancak genellikle bu yöntem, çeşitli veri analizi problemlerinde güvenilir bir seçenek olarak tercih edilir.

3.4.3. Lojistik regresyon

Lojistik regresyon, istatistiksel modelleme ve makine öğrenimi alanında, özellikle sınıflandırma problemlerinde yaygın olarak kullanılan bir yöntemdir. Bu yöntem, bağımlı değişkenin belirli bir sınıfa ait olma olasılığını tahmin etmeyi amaçlar. Model, doğrusal regresyonun bir uzantısı olarak düşünülebilir ancak temel farkı, çıktı değerinin sürekli bir sayı yerine bir olasılık olmasıdır. Lojistik regresyon, bağımlı değişkenin ikili (binary) olduğu durumlarda sıkça kullanılır ve tahminler, sigmoid fonksiyonu ile ifade edilir.

Sigmoid fonksiyonu, olasılık tahminlerini 0 ile 1 arasında bir aralığa sıkıştırır. Fonksiyonun matematiksel ifadesi Denklem 3.6'daki gibidir:

$$P(y = 1|X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_n X_n)}} \quad (3.6)$$

Burada $P(y = 1|X)$, X bağımsız değişkenleri kullanılarak y 'nin 1 olması olasılığını ifade eder. β_0 , sabit terimi; $\beta_1, \beta_2, \dots, \beta_n$, modelin katsayılarını temsil eder. Model, olasılık tahminlerini verirken logit fonksiyonu ile çalışır. Lojit fonksiyonu, sigmoid fonksiyonunun tersidir ve Denklem 3.7'deki gibi ifade edilir:

$$\text{logit}(P) = \log\left(\frac{P}{1-P}\right) = \beta_0 + \beta_1 X_1 + \dots + \beta_n X_n \quad (3.7)$$

Lojistik regresyon, parametrelerin optimizasyonu için maksimum olabilirlik tahminini (Maximum Likelihood Estimation, MLE) kullanır. MLE, modelin gözlemlenen verilere en uygun hale gelmesini sağlamak için parametreleri optimize eder. Maksimum olabilirlik fonksiyonu Denklem 3.8'deki gibi ifade edilir:

$$L(\beta) = \prod_{i=1}^n P(y_i|X_i) \quad (3.8)$$

Burada $P(y_i|X_i)$, i -inci gözlem için tahmin edilen olasılığı ifade eder. Logaritma alınarak bu fonksiyonun negatifine geçilir ve optimizasyon işlemi Denklem 3.9'daki gibi gerçekleştirilir:

$$L(\beta) = - \sum_{i=1}^n \left(y_i \log(P(y_i|X_i)) + (1 - y_i) \log(1 - P(y_i|X_i)) \right) \quad (3.9)$$

Bu model, özellikle sınıflandırma problemlerinde etkili ve anlaşılır bir yöntem sunar. Lojistik regresyon, parametrik bir model olduğu için verilere doğrudan bir varsayımda bulunur ve bu varsayımlar doğrultusunda etkili bir şekilde çalışır. Bununla birlikte, doğrusal olmayan sınıflandırma problemlerinde performansı düşebilir, bu durumda kernel tabanlı veya daha karmaşık modeller tercih edilebilir.

3.4.4. Destek vektör makineleri (SVM)

Destek Vektör Makineleri (Support Vector Machines, SVM), sınıflandırma ve regresyon problemlerinde kullanılan güçlü bir makine öğrenimi yöntemidir. SVM'nin temel amacı, veri noktalarını farklı sınıflara ayıran en iyi hiper düzlemi bulmaktır. Bu hiper düzlem, sınıflar arasındaki maksimum marjini sağlar ve modelin genelleme performansını artırır. İki sınıf arasındaki ayrım, destek vektörleri olarak adlandırılan kritik veri noktalarına dayanır. Destek vektörleri, hiper düzlemi tanımlayan ve marjini belirleyen veri noktalarıdır.

Lineer bir SVM modeli için hiper düzlem, Denklem 3.10'daki gibi ifade edilir:

$$w \cdot x + b = 0 \quad (3.10)$$

Burada w , hiper düzlemin normal vektörünü; x , veri noktasını; b , hiper düzlemin ofsetini temsil eder. Modelin amacı, sınıflar arasındaki marjini maksimize etmektir. Marjin, hiper düzleme en yakın veri noktaları arasındaki mesafedir ve Denklem 3.11'deki gibi hesaplanır:

$$Marjin = \frac{2}{\|w\|} \quad (3.11)$$

Sınıflandırma problemi, bu marjini maksimize ederken veri noktalarının doğru sınıflandırılmasını sağlayan bir optimizasyon problemi olarak ifade edilir. Hedef fonksiyon, w ve b parametrelerini minimize ederken, tüm veri noktalarının hiper düzlemden doğru tarafta bulunmasını sağlar ve bu durum Denklem 3.12'deki gibi ifade edilir:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \text{ şartıyla } y_i(w \cdot x_i + b) \geq 1, i = 1, 2, \dots, n \quad (3.12)$$

Eğer veri doğrusal olarak ayrılabilir değilse, SVM non-lineer sınıflandırma için kernel fonksiyonları kullanır. Kernel fonksiyonları, veriyi daha yüksek boyutlu bir uzaya dönüştürerek ayrılabilir hale getirir. Yaygın kullanılan kernel fonksiyonlarından biri olan RBF (Radial Basis Function) kernel Denklem 3.13'teki gibi ifade edilir:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (3.13)$$

Burada x_i ve x_j , iki veri noktası; γ , kernel parametresidir. Kernel fonksiyonları, SVM'nin doğrusal olmayan karar sınırlarını öğrenmesini sağlar.

SVM, büyük veri kümelerinde ve yüksek boyutlu verilerle çalışırken etkili bir performans sergiler. Ancak, veri setinin dengesiz olduğu durumlarda dikkatli uygulanması gerekir. Ayrıca, kernel seçimi ve hiperparametre ayarlamaları, modelin başarısını önemli ölçüde etkileyebilir.

3.4.5. XGBoost

XGBoost (Extreme Gradient Boosting), gradient boosting algoritmasının optimize edilmiş bir versiyonudur ve sınıflandırma ile regresyon problemlerinde etkili bir şekilde kullanılan güçlü bir makine öğrenimi yöntemidir. Bu yöntem, ardışık ağaçlar oluşturarak hataları azaltmayı ve modelin genelleme performansını artırmayı hedefler. Gradient boosting mantığında, her yeni ağaç önceki modelin hata paylarını düzeltmek üzere eğitilir. XGBoost ise bu sürece hız ve doğruluk kazandırmak için çeşitli optimizasyonlar içerir.

XGBoost, hedef fonksiyonu optimize ederek çalışır. Hedef fonksiyonu iki bileşenden oluşur: kayıp fonksiyonu ve düzenleme terimi. Kayıp fonksiyonu, tahmin edilen değerler ile gerçek değerler arasındaki farkı ölçerken düzenleme terimi, modelin karmaşıklığını kontrol ederek aşırı uyumu önler. Hedef fonksiyon Denklem 3.14'teki gibi ifade edilir:

$$L(t) = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{k=1}^T \Omega(f_k) \quad (3.14)$$

Burada $l(y_i, \hat{y}_i^{(t)})$, i -inci veri noktası için kayıp fonksiyonunu; $\Omega(f_k)$, k -inci ağacın karmaşıklığını ifade eder. Düzenleme terimi $\Omega(f_k)$, Denklem 3.15'teki gibi tanımlanır:

$$\Omega(f_k) = \gamma T + \alpha \sum_{j=1}^T |w_j| + \frac{1}{2} \lambda \cdot \sum_{j=1}^T w_j^2 \quad (3.15)$$

Burada γ , ağaç yapısındaki yaprak sayısına (T) bağlı düzenleme parametresini; α , yaprak ağırlıklarının (w_j) mutlak değerlerini azaltan ve seyrek modeller oluşturan L1 düzenleme katsayısını; λ ise yaprak ağırlıklarının (w_j) karelerini sınırlandırarak aşırı uyumu önleyen ve ağırlıkları dengeleyen L2 düzenleme katsayısını temsil eder. XGBoost, bu düzenleme terimlerini birleştirerek esneklik sağlar ve modelin karmaşıklığını kontrol altına alır. Ayrıca, bir Taylor serisi yaklaşımı ile hedef fonksiyonun ikinci dereceden türevine dayalı optimizasyon gerçekleştirir.

Her iterasyonda, bir önceki tahminlere dayalı artık hatalar hesaplanır ve bu hatalar, bir sonraki ağacın öğrenme sürecine dahil edilir. i -inci veri noktası için artık hata (r_i) Denklem 3.16'daki gibi hesaplanır:

$$r_i = y_i - \hat{y}_i^{(t-1)} \quad (3.16)$$

Modelin yeni tahmini, önceki tahmine bu hataların düzeltilmesi ile elde edilir ve Denklem 3.17'deki gibi ifade edilir:

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + \eta \cdot f_t(x_i) \quad (3.17)$$

Burada η , öğrenme oranını; $f_t(x_i)$, t -inci ağacın tahminini temsil eder. XGBoost, bu sürece ek olarak eksik veri işleme, paralel hesaplama ve ön budama gibi optimizasyon teknikleri ile diğer boosting yöntemlerine göre daha hızlı ve verimli çalışır.

XGBoost'un avantajı, karmaşık veri setlerinde yüksek performans sağlaması ve düzenleme terimi sayesinde aşırı uyum riskini azaltmasıdır. Bununla birlikte, hiperparametre ayarlaması dikkatli bir şekilde yapılmazsa modelin performansı olumsuz etkilenebilir.

3.4.6. SMOTE

SMOTE (Synthetic Minority Oversampling Technique), sınıflandırma problemlerinde dengesiz veri setlerini dengelemek amacıyla kullanılan bir yöntemdir. Dengesiz veri setlerinde, azınlık sınıfının sayıca az olması, modelin çoğunluk sınıfına aşırı uyum göstermesine neden olabilir. SMOTE, azınlık sınıfına ait örneklerin sayısını artırarak

bu sorunu gidermeyi hedefler. Bu yöntem, yeni örnekler oluştururken mevcut veri noktaları arasında doğrusal enterpolasyon yapar.

SMOTE algoritması, her bir azınlık sınıfı örneği için k -en yakın komşularını bulur ve bu komşular ile rastgele doğrusal kombinasyonlar yaparak yeni sentetik örnekler üretir. Matematiksel olarak, bir azınlık sınıfı örneği x_i ve onun komşularından biri $x_{neighbor}$ arasında yeni bir örnek Denklem 3.18'deki gibi oluşturulur:

$$x_{new} = x_i + \delta \cdot (x_{neighbor} - x_i) \quad (3.18)$$

Burada $\delta \sim U(0,1)$, rastgele bir değer olup 0 ile 1 arasında bir aralıktan seçilir. Bu işlem, azınlık sınıfının özelliklerini koruyarak yeni örnekler üretir ve veri setindeki dengesizliği giderir.

SMOTE algoritmasının önemli bir avantajı, sınıf dengesizliği nedeniyle oluşan model hatalarını azaltmasıdır. Bununla birlikte, SMOTE uygulanırken dikkat edilmesi gereken bazı noktalar vardır. Örneğin, aşırı sentetik örnekleme, azınlık sınıfının dağılımını bozabilir veya yeni örnekler arasında aşırı örtüşmeye (overlapping) neden olabilir. Bu gibi durumlarda, SMOTE yöntemi uygun ayarlamalarla veya diğer veri işleme yöntemleriyle birleştirilerek uygulanmalıdır.

SMOTE, genellikle makine öğrenimi modelleriyle birlikte kullanılır ve sınıflandırma problemlerinde model performansını artırmaya yardımcı olur. Bu yöntem, azınlık sınıfına ait önemli örnekleri çoğaltarak daha dengeli ve genelleme yeteneği yüksek modeller oluşturulmasını sağlar.

3.4.7. Çapraz doğrulama yöntemleri

Çapraz doğrulama, makine öğrenimi modellerinin genelleme performansını değerlendirmek için kullanılan bir yöntemdir. Modelin, veri setindeki farklı bölümler üzerinde test edilerek öğrenme kapasitesinin ölçülmesini sağlar. Bu süreçte, veri seti genellikle eğitim ve test olarak ikiye ayrılır; ancak çapraz doğrulama, bu bölme işlemini daha sistematik bir şekilde gerçekleştirir ve modelin performansını daha güvenilir bir şekilde değerlendirmek için tüm veri setinin kullanıldığından emin olur.

Leave-One-Out Cross Validation (LOOCV), çapraz doğrulamanın en temel türlerinden biridir. Bu yöntemde, veri setindeki her bir gözlem sırayla test veri seti olarak seçilirken geri kalan gözlemler modelin eğitimi için kullanılır. LOOCV'nin

matematiksel olarak ifade edilmesi gerekirse, n gözlemden oluşan bir veri seti için her bir i -inci gözlem test veri seti olarak seçildiğinde modelin tahmini Denklem 3.19'daki gibi yapılır:

$$\hat{y}_i = f(x_i; D_{\setminus i}) \quad (3.19)$$

Burada $D_{\setminus i}$, i -inci gözlem dışında kalan veri setini ifade eder. LOOCV, modelin her bir gözlem üzerinde ne kadar iyi tahmin yaptığını değerlendiren ortalama hata metriği ile sonuç verir ve bu, Denklem 3.20'deki gibi ifade edilir:

$$\text{LOOCV Hatası} = \frac{1}{n} \sum_{i=1}^n L(y_i, \hat{y}_i) \quad (3.20)$$

Burada $L(y_i, \hat{y}_i)$, gerçek değer ile tahmin arasındaki hata fonksiyonudur.

K-Fold Cross Validation (K-FCV), LOOCV'ye kıyasla daha yaygın olarak kullanılan bir çapraz doğrulama türüdür. Bu yöntemde, veri seti k eşit alt kümeye bölünür. Her bir alt küme sırayla test veri seti olarak seçilirken geri kalan $k - 1$ alt küme modelin eğitimi için kullanılır. Bu işlem k kez tekrarlanır ve modelin ortalama performansı Denklem 3.21'deki gibi hesaplanır:

$$\text{K - Fold Hatası} = \frac{1}{k} \sum_{i=1}^k L(y_i, \hat{y}_i) \quad (3.21)$$

K-Fold çapraz doğrulamanın önemli bir avantajı, modelin genelleme yeteneğini daha az varyansla değerlendirmesidir. Ancak, k değerinin seçimi performansı etkileyebilir. Genellikle $k = 10$ yaygın bir seçimdir, çünkü bu değer model performansını dengelemek için yeterli veri sağlar.

Çapraz doğrulama, modelin doğruluk, kesinlik, geri çağırma gibi metriklerle değerlendirilmesine olanak tanır ve aşırı uyum riskini azaltmaya yardımcı olur. Bununla birlikte, büyük veri setlerinde çapraz doğrulama uygulamanın yüksek hesaplama maliyetine yol açabileceği unutulmamalıdır. Doğru uygulandığında, çapraz doğrulama yöntemleri model seçimi ve hiperparametre optimizasyonunda güvenilir bir değerlendirme süreci sağlar.

3.4.8. Karışıklık matrisi (confusion matrix)

Karışıklık matrisi, sınıflandırma problemlerinde modelin performansını değerlendirmek için kullanılan bir araçtır. Bu matris, modelin doğru ve yanlış tahminlerini dört temel bileşene ayırarak sonuçları görselleştirir. Bu bileşenler, gerçek ve tahmin edilen sınıflar arasındaki ilişkiyi ortaya koyar ve şu şekilde tanımlanır: Doğru Pozitif (True Positive, TP), Yanlış Pozitif (False Positive, FP), Doğru Negatif (True Negative, TN) ve Yanlış Negatif (False Negative, FN).

Karışıklık matrisi, Denklem 3.22'deki gibi bir yapı ile ifade edilir:

$$\begin{bmatrix} TP & FP \\ FN & TN \end{bmatrix} \quad (3.22)$$

Burada TP, modelin pozitif sınıfı doğru şekilde tahmin ettiği örneklerin sayısını; FP, negatif sınıfı yanlış bir şekilde pozitif olarak sınıflandırdığı örneklerin sayısını; TN, negatif sınıfı doğru şekilde tahmin ettiği örneklerin sayısını; FN, pozitif sınıfı yanlış bir şekilde negatif olarak sınıflandırdığı örneklerin sayısını temsil eder.

Doğru Pozitif (TP): Pozitif sınıfa ait olan bir örneğin model tarafından doğru bir şekilde pozitif olarak tahmin edilmesi durumudur. Matematiksel olarak Denklem 3.23'teki gibi ifade edilir:

$$TP = \sum_{i=1}^n 1(y_i = 1 \wedge \hat{y}_i = 1) \quad (3.23)$$

Yanlış Pozitif (FP): Negatif sınıfa ait olan bir örneğin model tarafından yanlış bir şekilde pozitif olarak tahmin edilmesi durumudur. Matematiksel olarak Denklem 3.24'teki gibi ifade edilir:

$$FP = \sum_{i=1}^n 1(y_i = 0 \wedge \hat{y}_i = 1) \quad (3.24)$$

Doğru Negatif (TN): Negatif sınıfa ait olan bir örneğin model tarafından doğru bir şekilde negatif olarak tahmin edilmesi durumudur. Matematiksel olarak Denklem 3.25'teki gibi ifade edilir:

$$TN = \sum_{i=1}^n 1(y_i = 0 \wedge \hat{y}_i = 0) \quad (3.25)$$

Yanlış Negatif (FN): Pozitif sınıfa ait olan bir örneğin model tarafından yanlış bir şekilde negatif olarak tahmin edilmesi durumudur. Matematiksel olarak Denklem 3.26'daki gibi ifade edilir:

$$FN = \sum_{i=1}^n 1(y_i = 1 \wedge \hat{y}_i = 0) \quad (3.26)$$

Bu tanımlamalar, gerçek sınıf y_i ile modelin tahmini $\hat{y}_i$ arasındaki ilişkiye dayanır. TP, FP, TN ve FN değerleri, modelin performansını anlamak ve farklı metrikler türetmek için temel oluşturur. Bu bileşenlerin doğru bir şekilde anlaşılması, sınıflandırma problemlerinde model analizi ve iyileştirme süreçlerinde kritik öneme sahiptir.

3.4.9. Sınıflandırma raporu (classification report)

Sınıflandırma raporu, sınıflandırma problemlerinde modelin performansını değerlendiren kapsamlı bir analiz aracıdır. Bu rapor, modelin her sınıf için kesinlik (precision), geri çağırma (recall), F1-Skoru (F1-score) ve destek (support) metriklerini içerir. Bu metrikler, sınıflandırma modelinin her bir sınıfa ne kadar iyi uyum sağladığını ve genel performansını anlamak için kritik öneme sahiptir.

Kesinlik, modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu ölçer ve Denklem 3.27'deki gibi hesaplanır:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3.27)$$

Geri çağırma, pozitif sınıfa ait tüm gerçek örneklerin ne kadarının doğru tahmin edildiğini gösterir ve Denklem 3.28'deki gibi hesaplanır:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3.28)$$

F1-Skoru, kesinlik ve geri çağırma arasındaki dengeyi ifade eden bir ölçüttür ve bu iki metriğin harmonik ortalaması olarak tanımlanır ve Denklem 3.29'daki gibi hesaplanır:

$$F1 - Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (3.29)$$

Destek, her bir sınıfa ait toplam gerçek örnek sayısını belirtir ve modelin performansının bu örnekler üzerindeki etkisini anlamak için kullanılır. Destek metriği bir sınıfın dağılımını ortaya koyarak dengesiz veri setlerinde performans değerlendirmesinin daha iyi yapılmasını sağlar.

Doğruluk (accuracy), tüm sınıflar üzerindeki genel performansı ölçer. Modelin doğru sınıflandırdığı örneklerin toplam örneklere oranını ifade eder ve Denklem 3.30'daki gibi hesaplanır:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.30)$$

Accuracy metriği, modelin genel başarısını özetlemek için kullanışlıdır; ancak sınıf dengesizliği durumlarında yanıltıcı olabilir. Örneğin, çoğunluk sınıfının yüksek oranda olduğu bir veri setinde, model çoğunluk sınıfını doğru tahmin ederek yüksek doğruluk değerleri gösterebilir. Bu nedenle, doğruluk metriği genellikle diğer metriklerle birlikte değerlendirilmelidir.

Raporun sağladığı bilgiler, modelin hangi sınıflar üzerinde iyi performans gösterdiğini ve hangi sınıflarda iyileştirmelere ihtiyaç duyulduğunu anlamak için kullanılır. Ayrıca, bu metrikler hiperparametre optimizasyonu ve model seçimi süreçlerinde yönlendirici bir rol oynar. Sınıflandırma raporu ile modelin genel başarısını değerlendirirken, aynı zamanda sınıflara özel ayrıntılı analizler de yapılabilir.




4. BULGULAR

Bu bölümde, elektrikli araçlara yönelik ilgi ve sürücü profillerine ilişkin yapılan analizlerden elde edilen bulgular detaylı bir şekilde sunulmaktadır.

4.1. Elektrikli Araçlara İlgi ve Sürücü Profilleri

4.1.1. Yaş gruplarına göre elektrikli araçlara ilgi ilişkisi

Analiz sonuçlarına göre, yaş grupları arasında ortalama elektrikli araç ilgisi (Future_EV_Interest) değerleri şu şekilde hesaplanmıştır: birinci yaş grubunda (18-29 yaş grubu) 3.44, ikinci yaş grubunda (30-39 yaş grubu) 3.62 ve üçüncü yaş grubunda (40 yaş ve üzeri grup) 3.46. Bu bulgular, ikinci yaş grubunun (30-39 yaş arası) elektrikli araçlara daha fazla ilgi gösterdiğini, diğer yaş gruplarının ise benzer seviyelerde olduğunu göstermektedir. Şekil 4.1’de bu farklar görselleştirilmiş olup, ikinci yaş grubunun ilgisinin görsel olarak da öne çıktığı görülmektedir.




Şekil 4.1. Yaş gruplarına göre elektrikli araçlara ilgi.

4.1.2. Sürüş deneyimine göre elektrikli araçlara ilgi ilişkisi

Sürüş deneyimi az olan bireylerde (0-5 yıl), elektrikli araçlara olan ilgi genel olarak yüksek bir seviyededir. Bununla birlikte, sürüş deneyimi arttıkça ilgi düzeyinin daha geniş bir dağılım sergilediği ve bazı gruplarda daha düşük seviyelerde kaldığı gözlemlenmiştir. 20 yıl ve üzeri sürüş deneyimine sahip bireylerde, ilginin daha istikrarlı ancak genelde orta seviyelerde olduğu dikkat çekmiştir. Şekil 4.2’de bu


dağılım görselleştirilmiştir ve daha az deneyime sahip sürücülerin yeni teknolojilere daha açık olabileceği, deneyim arttıkça bireylerin daha spesifik tercihlere yöneldiği ifade edilmektedir.



Şekil 4.2. Sürüş deneyimine göre elektrikli araçlara ilgi.

4.1.3. Şarj erişilebilirliğine göre elektrikli araçlara ilgi ilişkisi


Analiz sonuçlarına göre, şarj erişilebilirlik seviyesi arttıkça elektrikli araçlara olan ilginin de düzenli bir şekilde yükseldiği gözlemlenmiştir. Şarj altyapısının yetersiz olduğu durumlarda, ilgi düşük seviyelerde kalırken, şarj erişimindeki her birim artış, ilgi seviyesini pozitif yönde etkilemiştir. Ancak, erişilebilirlik seviyesi 4. ve 5. seviyelerde maksimuma ulaştığında, ilginin daha dengeli bir seyir izlediği görülmüştür. Şekil 4.3'te bu eğilim net bir şekilde gösterilmektedir. Bu durum, şarj erişimindeki iyileştirmelerin elektrikli araçların benimsenmesini teşvik etmek için kritik bir faktör olduğunu ortaya koymaktadır.



Şekil 4.3. Şarj erişilebilirliğine göre elektrikli araçlara ilgi.

4.1.4. Elektrikli araç bilgi seviyesine göre elektrikli araçlara ilgi ilişkisi


Elektrikli araçlara ilişkin bilgi seviyesi arttıkça, bu araçlara olan ilgi de genellikle artış göstermektedir. Ancak, farklı yaş grupları arasında bilgi seviyesi ile ilgi arasındaki ilişkinin yoğunluğu farklılık göstermektedir. Özellikle genç yaş gruplarında (18-29), bilgi seviyesindeki artışın ilgi üzerinde daha belirgin bir etkisi olduğu görülmektedir. Orta yaş grubu (30-39) ve ileri yaş grubunda (40+) ise bilgi seviyesine bağlı ilgi değişiklikleri daha dengeli bir seyir izlemektedir. Şekil 4.4'te bu bulgular görselleştirilmiş olup, bilgi seviyesinin elektrikli araçlara olan ilgiyi artırmada önemli bir etken olduğu, ancak yaş gruplarının bu etkiyi farklı şekilde deneyimlediği ifade edilmektedir.



Şekil 4.4. Elektrikli araç bilgi seviyesine göre elektrikli araçlara ilgi.

4.1.5. Elektrikli araç maliyetine göre elektrikli araçlara ilgi ilişkisi

Elektrikli araçların maliyetinin önemli bir etken olarak değerlendirildiği durumlarda, bu araçlara yönelik ilgi de artış göstermektedir. Özellikle maliyet etkisi seviyesi 3 ve üzerindeyken, ilginin keskin bir şekilde yükseldiği görülmüştür. Bu, kullanıcıların maliyet konusunda bilinçlendikçe elektrikli araçları daha cazip bulduklarını göstermektedir. Ancak maliyet etkisinin daha düşük olduğu seviyelerde, elektrikli araçlara olan ilginin nispeten düşük seviyelerde seyrettiği gözlemlenmiştir. Şekil 4.5, maliyet etkisi ile elektrikli araçlara ilgi arasındaki bu ilişkiyi detaylı olarak göstermektedir. Bulgular, elektrikli araçların yaygınlaşması için maliyet engelinin önemli bir faktör olduğunu ve uygun fiyatlandırma politikalarının bu ilgiyi artırabileceğini vurgulamaktadır.




Şekil 4.5. Elektrikli araç maliyetine göre elektrikli araçlara ilgi.

4.2. Sürücü Davranışları ve Yakıt Verimliliği

4.2.1. Ani hızlanma, sık fren yapma ve yakıt tüketimi farkındalığı ilişkisi


Ani hızlanma seviyesinin arttığı durumlarda, yakıt tüketimi farkındalığının genellikle daha düşük olduğu tespit edilmiştir. Bununla birlikte, sık fren yapma davranışı da bu ilişkiyi etkileyen önemli bir faktör olarak öne çıkmaktadır. Sık fren yapma seviyesinin düşük olduğu gruplarda, yakıt tüketimi farkındalığı daha yüksek seyretmektedir. Bu durum, Şekil 4.6’da gösterildiği üzere, sürüş alışkanlıklarının yakıt verimliliği üzerindeki etkilerini daha iyi anlamak için önemli bir içgörü sunmaktadır. Sonuçlar, daha bilinçli sürüş tekniklerinin yakıt tüketiminde farkındalığı artırabileceğini ve dolayısıyla verimliliği iyileştirebileceğini göstermektedir.



Şekil 4.6. Ani hızlanma, sık fren yapma ve yakıt tüketimi farkındalığı ilişkisi.

4.2.2. Telematik cihaz kullanımı ve yakıt tüketimi farkındalığı ilişkisi

Telematik cihaz kullanan sürücüler ile kullanmayanlar arasında yakıt tüketimi farkındalığı açısından çok küçük bir fark gözlemlenmiştir. Telematik cihaz kullanmayanların farkındalık seviyesi ortalama 3.60 iken, cihaz kullananların farkındalık seviyesi 3.57 olarak kaydedilmiştir. Bu eğilim, Şekil 4.7’de açıkça gösterilmektedir. Bu sonuç, telematik cihaz kullanımının yakıt tüketimi farkındalığı üzerinde belirgin bir etkisi olmadığını göstermektedir. Ancak, telematik cihazların sürüş alışkanlıklarını iyileştirme potansiyeline sahip olduğu göz önüne alındığında, bu durum daha kapsamlı analizlerle desteklenebilir.



Şekil 4.7. Telematik cihaz kullanımı ve yakıt tüketimi farkındalığı ilişkisi.

4.3. Hedef Değişken (Future_EV_Interest) ile Korelasyon Analizi

Elektrikli araçlara olan ilgi (Future_EV_Interest) hedef değişkeniyle en güçlü 20 pozitif korelasyona sahip değişkenler incelendiğinde, en yüksek korelasyon değeri elektrikli araç maliyet etkisi (EV_Cost_Impact) ile 0.47 olarak tespit edilmiştir. Bunu bilgi seviyesi (EV_Knowledge) 0.33 ve halihazırda elektrikli araç kullanımını ifade eden (Currently_Uses_EV) 0.25 değerleri takip etmektedir. Ayrıca elektrikli yakıt türü (Fuel_Type_Elektrik) 0.24, şarj istasyonu erişilebilirliği (EV_Charging_Accessibility) 0.23, ve araç model yılı (Vehicle_Model_Year) 0.19 pozitif korelasyon gösteren diğer önemli faktörlerdir. Yakıt tüketimi farkındalığı (Fuel_Consumption_Knowledge) 0.12 ile daha düşük, ancak anlamlı bir pozitif ilişkiye sahiptir. Ek olarak, telematik cihaz kullanımı (Telematics_Usage) 0.09, alışveriş ve günlük işler için araç kullanım amacı 0.08 ve işe gidip gelme amacı 0.07 pozitif korelasyon göstermiştir.

En güçlü 20 negatif korelasyona bakıldığında, "boş zaman etkinlikleri" kullanım amacı -0.15 ve "sağlık ve doktor randevuları" kullanım amacı -0.14 korelasyon değerleriyle dikkat çekmektedir. Yakıt tasarrufu davranışları arasında ani hızlanma ve yavaşlamadan kaçınma, hız sınırlarına uyum ve rota planlaması gibi değişkenler de -0.11 ile -0.13 aralığında negatif korelasyon göstermiştir. Ayrıca, sık fren yapma davranışı (Frequent_Hard_Braking) -0.08 ve hız sınırı ihlalleri (Speed_Limit_Violations) -0.09 negatif ilişki gösteren diğer faktörler arasındadır. Telematik cihaz etkileri "kullanmıyorum/karışık buluyorum" yanıtıyla -0.09 korelasyona sahiptir. Diğer yakıt tasarrufu önlemlerinin kombinasyonları, negatif korelasyonların bir kısmını oluşturmuştur.

Bu analizler, elektrikli araçlara olan ilginin bilgi seviyesi, maliyet etkisi ve altyapı gibi olumlu etkilere daha duyarlı olduğunu, ancak bireysel sürüş alışkanlıkları ve kullanım amaçlarının bu ilgiyi farklı yönlerde etkileyebileceğini göstermektedir.

4.4. Makine Öğrenimi Modelleri ile Sınıflandırma Performansı

Bu bölümde, elektrikli araçlara yönelik ilginin sınıflandırılmasında makine öğrenimi modellerinin performans analizleri sunulmaktadır. İki ana başlık altında gerçekleştirilen bu analizler, mevcut veriler ve geliştirilmiş özellikler ile modellerin performansını karşılaştırmaktadır.

4.4.1. Mevcut veriler ile model performansı

4.4.1.1. Random forest model performansı

Hedef değişken olan Future_EV_Interest ile en güçlü pozitif ve negatif korelasyona sahip değişkenler kullanılarak üç farklı yöntemle random forest modeli eğitilmiştir: varsayılan ağırlıklandırma, dengeli sınıf ağırlıkları ve SMOTE yöntemi.

Varsayılan model ile elde edilen sonuçlarda, modelin genel doğruluk oranı %91.30 olarak hesaplanmıştır. F1-skorları, 1 ve 2 seviyelerindeki sınıflar için sırasıyla 0.80 ve 0.60 ile daha düşük seviyelerde kalmıştır. Ancak, 4 ve 5 seviyelerindeki sınıflar için F1-skorları 1.0 ile mükemmel bir performans göstermiştir. Bu durum, modelin yüksek frekanslı sınıfları daha iyi tahmin ettiğini ancak az temsil edilen sınıflarda performansın düştüğünü göstermektedir.

Dengeli ağırlıklandırma yöntemi kullanıldığında, genel doğruluk oranı %89.13 olarak hesaplanmıştır. F1-skorları, sınıf 2 için 0.44 ile düşük bir performans sergilerken, diğer

sınıflar için oldukça yüksektir. Örneğin, sınıf 4 için F1-skoru 0.97 ve sınıf 5 için 0.95 olarak hesaplanmıştır. Bu yöntem, dengesiz sınıfları ele alırken bazı sınıfların performansını artırmış ancak sınıf 2 gibi daha az temsil edilen sınıflarda hala yetersiz kalmıştır.

SMOTE yöntemi ile veri seti dengelendiğinde, modelin doğruluk oranı %97.26 olarak belirlenmiştir. Precision, recall ve F1-skorları tüm sınıflar için oldukça yüksektir ve sınıf 2'deki recall değeri 0.86 ile varsayılan model ve dengeli ağırlıklandırmaya göre önemli bir iyileşme göstermiştir. Özellikle F1-skorlarının 1.0'a yakın değerler alması, bu yöntemin sınıflar arasındaki dengesizliği başarıyla giderdiğini ve tüm sınıflar için tutarlı bir performans sergilediğini göstermektedir.

Bu sonuçlar, sınıf dengesizliğinin model performansı üzerinde önemli bir etkisi olduğunu ve SMOTE gibi dengeleme yöntemlerinin sınıflar arasındaki tahmin başarısını artırmada etkili bir araç olduğunu ortaya koymaktadır. SMOTE yöntemi, özellikle az temsil edilen sınıflar için model doğruluğunu artırarak daha dengeli bir performans sergilemiştir.

4.4.1.2. SVM model performansı

SVM modeli, genel doğruluk oranı %93.15 ile lojistik regresyon modeline benzer bir performans göstermiştir. Model, sınıf 1, 4 ve 5 için precision, recall ve F1-skoru değerlerinde yine 1.0 seviyesinde başarı sağlamıştır. Ancak, sınıf 2 için recall değeri 0.79 ve sınıf 3 için precision 0.81 ile performansın düştüğü gözlemlenmiştir. Bu sonuçlar, SVM'nin doğruluk ve kararlılık açısından güçlü olduğunu, ancak düşük temsil edilen sınıflarda daha fazla zorluk yaşadığını göstermektedir.

4.4.1.3. Lojistik regresyon model performansı

Lojistik regresyon modeli, genel doğruluk oranı %95.89 ile yüksek bir performans sergilemiştir. Model, özellikle sınıf 1, 4 ve 5 için precision, recall ve F1-skoru değerlerinde 1.0 ile mükemmel bir başarı elde etmiştir. Ancak, sınıf 2 için recall değeri 0.86, sınıf 3 için precision 0.87 ile diğer sınıflara kıyasla daha düşük performans göstermiştir. Bu sonuçlar, lojistik regresyon modelinin dengesiz sınıflarda belirli zorluklar yaşadığını göstermektedir.

4.4.2. Yeni özellikler ile geliştirilmiş model performansı

4.4.2.1. Random forest model performansı

Modelin tahmin doğruluğunu artırmak ve daha anlamlı öngörüler elde etmek amacıyla dokuz yeni özellik üretilmiştir. Bu özellikler arasında araç tipi ve yakıt türü kombinasyonu, tahmini günlük yakıt tüketimi, yakıt gideri oranı, agresif sürüş skoru, ortalama sürüş süresi, elektrikli araç ilgisi skoru, maliyet algısı, potansiyel elektrikli araç kullanımı ve şarj erişimi ile bilgi kombinasyonu yer almaktadır. Yeni özelliklerin veri setine eklenmesiyle random forest modeli yeniden eğitilmiş ve test edilmiştir.

Modelin genel doğruluk oranı %78.26 olarak hesaplanmıştır. Precision ve recall değerleri, sınıflar arasında önemli farklılıklar göstermiştir. Sınıf 4 için recall değeri 0.93, sınıf 5 için precision değeri 0.95 ile en yüksek seviyelerde gerçekleşmiştir. Buna karşılık, sınıf 1 ve sınıf 2 gibi daha az temsil edilen sınıflar için recall değerleri sırasıyla 0.36 ve 0.29 ile daha düşük performans göstermiştir. F1-skorları açısından sınıf 3, 4 ve 5 için sırasıyla 0.75, 0.89 ve 0.91 gibi yüksek değerler elde edilmiştir. Bu, modelin özellikle yüksek frekanslı sınıflarda daha iyi sonuçlar verdiğini göstermektedir.

Karışıklık matrisi incelendiğinde, sınıf 4 ve 5'in doğru tahmin oranlarının oldukça yüksek olduğu görülmüştür. Bununla birlikte, sınıf 1 ve 2'de yanlış tahminlerin yoğunlaştığı dikkat çekmektedir. Örneğin, sınıf 1 için toplamda 11 örnekten sadece 4'ü doğru tahmin edilmiştir. Bu durum, dengesiz veri dağılımının etkisini ve model performansını artırmak için sınıf dengeleme yöntemlerine ihtiyaç duyulabileceğini göstermektedir.

Sonuç olarak, yeni özelliklerin eklenmesi modelin performansını belirli ölçüde iyileştirmiş olsa da, dengesiz sınıflar için daha ileri yöntemlerin kullanılması gerekmektedir. Ayrıca, üretilen yeni özellikler, daha anlamlı öngörüler sunarak modelin genelleştirme yeteneğini artırmıştır.

4.4.2.2. Yeni özelliklerin model performansı üzerindeki önemi


Dokuz yeni özellik, modelin tahmin gücünü artırmak amacıyla veri setine eklenmiştir. Ancak, bu eklemelere rağmen beklenen başarıya ulaşılamamıştır. Bu nedenle, yeni özelliklerin modele olan katkısını analiz etmek için özellik önemleri incelenmiştir.

Şekil 4.8'de gösterildiği gibi, en önemli yeni özellik, Potential_EV_Use (Potansiyel Elektrikli Araç Kullanımı) değişkeni olup, toplam önem skoru içerisinde açık bir farkla öne çıkmıştır. Bu değişken, elektrikli araç ilgisini ve mevcut kullanım durumunu

birleştiren bir göstergedir. Bunu, EV_Interest_Score (Elektrikli Araç İlgisi Skoru) ve EV_Access_Knowledge_Score (Şarj Erişimi ve Bilgi Kombinasyonu) takip etmiştir. Bu iki özellik, elektrikli araçlara yönelik bireylerin genel tutum ve bilgi seviyelerinin modele katkısını yansıtmaktadır.

Daha düşük önem derecelerine sahip olan özellikler arasında Fuel_Cost_Income_Ratio (Yakıt Gideri Oranı) ve Estimated_Fuel_Consumption (Tahmini Yakıt Tüketimi) yer almıştır. Bu özellikler, model üzerinde nispeten daha az etkili olmuştur. Bununla birlikte, Aggressive_Driving_Score (Agresif Sürüş Skoru) ve Average_Driving_Time (Ortalama Sürüş Süresi) gibi sürüş alışkanlıklarını yansıtan değişkenler orta seviyede önem göstermiştir.

Bu analiz, modele eklenen özelliklerden bazılarının önemli katkılar sağladığını, ancak diğerlerinin sınırlı bir etkiye sahip olduğunu ortaya koymaktadır.



Şekil 4.8. Yeni eklenen özelliklerin model üzerindeki önem skorlarının dağılımı.

4.4.2.3. Önemli özelliklere dayalı random forest model performansı

Model performansını artırmak ve özelliklerin model üzerindeki etkisini daha iyi analiz etmek amacıyla iki farklı özellik setiyle random forest modelleri eğitilmiştir.

İlk modelde, yalnızca en önemli üç özellik olan Potential_EV_Use, EV_Interest_Score ve EV_Access_Knowledge_Score kullanılmıştır. Bu model, genel doğruluk oranında %96.74 seviyesine ulaşmış ve sınıflar arasındaki f1-skoru değerlerinde güçlü bir performans sergilemiştir. Özellikle, sınıf 3, 4 ve 5 için f1-skorları 1.0 ile mükemmel sonuçlar elde etmiştir. Sınıf 1 ve 2 için precision ve recall değerleri ise sırasıyla 0.90 ve 0.75 gibi yüksek seviyelerde gerçekleşmiştir. Ancak, bu iki sınıfta yanlış tahminler olduğu dikkat çekmiştir.

İkinci modelde, en önemli beş özellik olan Potential_EV_Use, EV_Interest_Score, EV_Access_Knowledge_Score, EV_Cost_Perception ve Aggressive_Driving_Score dahil edilmiştir. Bu model, genel doğruluk oranını %100 seviyesine çıkarmış ve tüm sınıflarda precision, recall ve f1-skoru değerlerini 1.0 olarak sağlamıştır. Bu sonuçlar, özellik setinin genişletilmesinin modele pozitif bir katkı sağladığını göstermektedir. Çapraz doğrulama sonuçları da bu modeli desteklemektedir; beş katlı çapraz doğrulama ile ortalama doğruluk oranı %98.68 olarak hesaplanmıştır.

Sonuç olarak, özelliklerin seçimi model performansı üzerinde büyük bir etkiye sahiptir. İlk model, yalnızca üç özellik kullanarak oldukça başarılı bir sonuç elde etmiş olsa da, özellik sayısının artırılması modelin doğruluk oranını ve genel performansını daha da iyileştirmiştir. En önemli özelliklerin stratejik bir şekilde seçilmesi ve modelleme sürecine dahil edilmesi, tahmin başarısını artırmada etkili bir yaklaşım sunmaktadır.

4.4.2.4. Eğitim-test oranının değiştirilmesi ve SMOTE uygulamasının etkisi

Model performansını optimize etmek için eğitim-test oranı artırılmış ve SMOTE yöntemi kullanılarak dengesiz veri seti yeniden örneklenmiştir. İki farklı yaklaşımın sonuçları analiz edilmiştir.

Eğitim oranının artırıldığı ilk yaklaşımda, test seti küçültülerek modelin eğitim verisi üzerindeki öğrenme kapasitesi artırılmıştır. Bu modelde doğruluk oranı %74.14 olarak gerçekleşmiş, ancak sınıflar arasında belirgin performans farklılıkları gözlemlenmiştir. Sınıf 3, recall açısından 1.0 sonucu sergilerken, sınıf 1 ve sınıf 2 gibi daha az temsil edilen sınıflar için performans görece düşük kalmıştır. Bu durum, küçük test setlerinin sınıf çeşitliliğini tam olarak yansıtamaması nedeniyle model genelleştirme yeteneğini sınırlayabileceğini göstermektedir. Çapraz doğrulama ile yapılan değerlendirmelerde ise ortalama doğruluk oranı %80.95 olarak hesaplanmıştır.

İkinci yaklaşımda, SMOTE kullanılarak dengesiz veri seti yeniden örneklenmiş ve tüm sınıflar için dengeli bir dağılım sağlanmıştır. Bu yöntemin kullanıldığı model, genel doğruluk oranını %93.15 seviyesine çıkarmış ve sınıflar arasında daha dengeli bir performans elde edilmiştir. Sınıf 1 ve 5 için precision ve recall değerleri 0.97, sınıf 2 ve 4 için ise 0.90 seviyesinde gerçekleşmiştir. Çapraz doğrulama sonuçları da SMOTE yöntemiyle elde edilen sonuçları desteklemekte olup, ortalama doğruluk oranı %93.4 olarak belirlenmiştir.

Sonuç olarak, SMOTE yöntemi, dengesiz veri setlerinde sınıf çeşitliliğini artırarak modelin genelleştirme yeteneğini geliştirmiştir. Eğitim-test oranının değiştirilmesi model performansını sınırlı ölçüde artırırken, SMOTE ile daha dengeli bir performans ve daha yüksek doğruluk oranı sağlanmıştır. Bu bulgular, dengesiz veri setleriyle çalışırken veri artırma tekniklerinin etkili bir araç olduğunu ortaya koymaktadır.

4.4.2.5. SVM model performansı

SVM modeli, dengeli olmayan veri seti üzerinde uygulanmış ve sınıf bazında değişen sonuçlar elde edilmiştir. Sınıf 3 ve 4 için oldukça yüksek doğruluk ve hatırlama oranları (1.0) elde edilmişken, sınıf 2 için precision ve recall değerleri sırasıyla 0.33 ve 0.29 ile görece düşük kalmıştır. Genel doğruluk oranı %90.22 olarak gerçekleşmiştir. Çapraz doğrulama sonuçlarında ortalama doğruluk oranı %91.96 olarak belirlenmiş, bu da modelin genelleştirme yeteneğinin iyi olduğunu göstermiştir. SVM modeli, dengesiz veri setlerinde bazı sınıflar için daha düşük performans sergilerken, genelleştirme yeteneği açısından güçlü bir aday olarak değerlendirilebilir.

4.4.2.6. Lojistik regresyon model performansı

Lojistik regresyon modeli ise SMOTE ile dengelenmiş bir veri seti üzerinde eğitilmiştir. Bu yöntemle tüm sınıflar için daha dengeli performanslar sağlanmış ve genel doğruluk oranı %96.58 seviyesine ulaşmıştır. Sınıf 1, 3 ve 5 için precision ve recall değerleri 1.0 olarak gerçekleşirken, sınıf 2 için 0.90 doğruluk elde edilmiştir. Lojistik regresyon modelinin çapraz doğrulama sonuçları da yüksek bir performansı yansıtmış, ortalama doğruluk oranı %93.61 olarak hesaplanmıştır. Bu sonuçlar, SMOTE gibi veri dengeleme tekniklerinin etkili olduğunu ve lojistik regresyon gibi daha basit modellerin bile dengeli bir veri seti üzerinde yüksek performans gösterebileceğini ortaya koymaktadır.

4.4.2.7. XGBoost model performansı

Sonuçlar, XGBoost modelinin oldukça başarılı bir sınıflandırıcı olduğunu ortaya koymuştur. Eğitim ve test setlerinin dikkatli bir şekilde yeniden ayrılması ve potansiyel veri sızıntılarının önlenmesiyle birlikte, model tüm sınıflarda %100 doğruluk elde etmiştir. XGBoost'un test seti performansında sınıf bazında precision, recall, ve f1-score değerleri 1.0 olarak gerçekleşmiştir. Bu sonuçlar, modelin her sınıfta yüksek bir genelleme yeteneğine sahip olduğunu göstermektedir.

Eğitim setinde yapılan tahminlerde de aynı şekilde %100 başarı sağlanmıştır. Bu durum, modelin eğitim setini tam anlamıyla öğrendiğini ancak aşırı öğrenme belirtisi göstermediğini ortaya koymaktadır, zira test setinde de benzer doğruluk değerleri elde edilmiştir. Ayrıca, çapraz doğrulama ile modelin genelleme yeteneği daha kapsamlı bir şekilde değerlendirilmiş ve ortalama doğruluk oranı %99.05 olarak hesaplanmıştır. Bu durum, XGBoost'un veri setindeki tüm desenleri etkili bir şekilde öğrenebildiğini ve genelleme yapabildiğini göstermektedir.

4.4.2.8. Eğitim ve test setleri arasındaki ortak kayıtlar

Eğitim ve test setleri ayrılırken herhangi bir veri sızıntısını önlemek amacıyla setler arasındaki ortak kayıtlar kontrol edilmiştir. Yapılan analizler sonucunda ilk ayrımda eğitim ve test setleri arasında 21 ortak kayıt tespit edilmiştir. Bunun üzerine, eğitim ve test setleri yeniden rastgele ayrılmış ve bu sefer sadece 3 ortak kayıt bulunmuştur. Bu durum, modelin eğitim ve test sırasında farklı veri kümeleri üzerinde eğitilip değerlendirildiğini garanti etmektedir.

4.4.2.9. Regularization ile XGBoost model performansı

L1 (Lasso) ve L2 (Ridge) düzenleme parametreleri eklenmiş XGBoost modeli, hem test setinde hem de çapraz doğrulamada mükemmel sonuçlar vermiştir. Düzenleme, hedef değişkenle yüksek korelasyona sahip özelliklerin etkisini azaltmak için kullanılmıştır. Bu düzenleme, özelliklerin önem sıralamasını dengeleyerek daha genelleştirilebilir bir model oluşturulmasını sağlamıştır. Test setinde accuracy, precision, recall ve f1-score değerlerinin tamamı 1.0 olarak gerçekleşmiştir. Ayrıca, çapraz doğrulamada ortalama doğruluk %99.05 olarak kaydedilmiştir.

4.5. Çapraz Doğrulama Yöntemleri

4.5.1. Leave-one-out cross validation (LOOCV)

Modelin güvenilirliğini artırmak ve aşırı öğrenme ihtimalini minimize etmek için LOOCV kullanılmıştır. Her bir veri noktası test seti olarak tek başına değerlendirilmiş ve model geri kalan verilerle eğitilmiştir. LOOCV sonuçlarına göre model, %99.06 doğruluk elde etmiştir. Bu yöntem, modelin her bir veri noktası üzerinde dengeli bir performans sergilediğini göstermektedir.

4.5.2. K-fold cross validation (K-FCV)

K-Fold apraz doęrulama, veriyi 10 eřit paraya blerek her birini dnřml olarak test seti olarak kullanmıřtır. K-FCV, dzenleme uygulanmıř XGBoost modelinin %99.05 ortalama doęruluk oranına ulařtıęını gstermiřtir. Standart sapma deęeri (%1.9) olduka dřktr, bu da modelin istikrarlı ve gvenilir performansını doęrulamaktadır.

4.6. Makine ęrenimi Yaklařımlarının zet Performans Deęerlendirmesi

Bu blmde, elektrikli aralara ynelik ilginin sınıflandırılmasında kullanılan makine ęrenimi modellerinin performans zetleri sunulmaktadır. Performans deęerlendirmesi, mevcut veri seti ve yeni zelliklerle zenginleřtirilmiř veri seti kullanılarak yapılan analizlere dayanmaktadır. İki ayrı tablo halinde gsterilen bu sonular, veri kalitesinin ve yeni zelliklerin model tahmin gc zerindeki etkilerini karřılařtırmalı olarak incelemeyi amalamaktadır.

Tablo 4.1. Mevcut veriler ile makine öğrenimi modellerinin performans değerlendirmesi.

Model	Yöntem	Özellikler	Accuracy	CV Accuracy
Random Forest	Standart Eğitim + 5 Katlı Çapraz Doğrulama	Hedef Değişken ile En Güçlü Pozitif ve Negatif Korelasyona Sahip Özellikler	% 91.30	% 91.97
Random Forest (Dengeli Ağırlıkları)	Dengeli Sınıf Ağırlıkları + Standart Eğitim + 5 Katlı Çapraz Doğrulama	Hedef Değişken ile En Güçlü Pozitif ve Negatif Korelasyona Sahip Özellikler	% 89.13	% 92.43
Random Forest (SMOTE)	SMOTE + Standart Eğitim + 5 Katlı Çapraz Doğrulama	Hedef Değişken ile En Güçlü Pozitif ve Negatif Korelasyona Sahip Özellikler	% 97.26	% 98.96
SVM	Standart Eğitim + 5 Katlı Çapraz Doğrulama	SMOTE ile Dengelenmiş Tüm Özellikler	% 93.15	% 97.52
Lojistik Regresyon	Standart Eğitim + 5 Katlı Çapraz Doğrulama	SMOTE ile Dengelenmiş Tüm Özellikler	% 95.89	% 97.11

Tablo 4.2. Yeni özellikler ile geliştirilmiş makine öğrenimi modellerinin performans değerlendirmesi.

Model	Yöntem	Özellikler	Accuracy	CV Accuracy
Random Forest (Gelişmiş Özellikler)	Standart Eğitim + 5 Katlı Çapraz Doğrulama	Gelişmiş Özellik Mühendisliği ile Üretilen ve One Hot Encoding ile Kodlanan Tüm Özellikler	% 78.26	% 81.16
Random Forest (Önemli Özellikler)	Standart Eğitim + 5 Katlı Çapraz Doğrulama	Önem Skorlarına Göre Seçilen En Önemli 3 Özellik	% 96.74	% 97.37
Random Forest (Önemli Özellikler)	Standart Eğitim + 5 Katlı Çapraz Doğrulama	Önem Skorlarına Göre Seçilen En Önemli 5 Özellik	% 100	% 98.68
Random Forest (Büyük Seti)	Eğitim Seti Boyutu Artırılarak Standart Eğitim + 5 Katlı Çapraz Doğrulama	Genişletilmiş Eğitim Seti ile Tüm Seçili Özellikler	% 74.14	% 80.95
Random Forest (SMOTE)	SMOTE Uygulaması ile Veri Dengelenmesi + Standart Eğitim + 5 Katlı Çapraz Doğrulama	SMOTE ile Dengelenmiş Tüm Özellikler	% 93.15	% 93.40
SVM	Standart Eğitim + RBF Kernel Kullanımı + 5 Katlı Çapraz Doğrulama	Standart Eğitim Setindeki Tüm Özellikler	% 90.22	% 91.96
Lojistik Regresyon	Standart Eğitim + Maksimum 2000 İterasyon + 5-Katlı Çapraz Doğrulama	SMOTE ile Dengelenmiş Tüm Özellikler	% 96.58	% 93.61
XGBoost	logloss Değerlendirme Metrik Kullanımı + Standart Eğitim + 5 Katlı Çapraz Doğrulama	SMOTE ile Dengelenmiş Tüm Özellikler	% 100	% 100
XGBoost	Rastgele Ayrılmış Veri ile Eğitim + 5 Katlı Çapraz Doğrulama	SMOTE ile Dengelenmiş ve Eğitim-Test Seti Kesişim Kontrolü Yapılmış Özellikler	% 100	% 99.05
XGBoost	L1 ve L2 Düzenleme ile Standart Eğitim + 5 Katlı Çapraz Doğrulama	SMOTE ile Dengelenmiş Tüm Özellikler	% 100	% 99.05



5. TARTIŞMA

Bu çalışmada, sürücü davranışları, elektrikli araçlara olan ilgi ve yakıt tüketimi farkındalığı gibi unsurlar üzerine kapsamlı analizler gerçekleştirilmiştir. Elde edilen bulgular, hem literatürdeki mevcut çalışmaları destekleyen hem de bu alanda yeni katkılar sağlayan önemli gözlemler ortaya koymuştur.

Yaş grupları üzerine yapılan analizler, 30-39 yaş grubunun elektrikli araçlara en yüksek ilgiyi gösterdiğini ortaya çıkarmış ve bu durumun, orta yaş grubunun ekonomik stabilitesi ve çevre bilinciyle ilişkili olabileceği düşünülmüştür. Bu bulgular, Lee ve Wu [18] ile Wang ve ekibinin [11] çalışmalarında vurgulanan sosyo-demografik faktörlerin elektrikli araçlara olan ilgiyi etkileyebileceği sonucunu desteklemektedir. Ancak, bu çalışma daha spesifik veriler sunarak, bilgi seviyesinin ve şarj altyapısının bu ilgiyi daha yoğun bir şekilde şekillendirdiğini göstermiştir.

Sürüş deneyimi ve bilgi seviyesi arasındaki ilişkiler, yeni sürücülerin elektrikli araçlara daha yüksek bir ilgi gösterdiğini ancak deneyim arttıkça bu ilginin daha çeşitli faktörlerle modüle edildiğini ortaya koymuştur. Lu ve ekibinin [7] çalışmaları, sürüş deneyiminin sürücü davranışları üzerindeki etkilerini desteklerken, bizim çalışmamız, bu davranışların teknoloji benimsenmesi ile olan karmaşık etkileşimlerini detaylandırmıştır. Bu çerçevede şarj altyapısının erişim seviyesinin, bilgi seviyesine bağlı olarak çok daha belirleyici bir rol oynadığı gözlemlenmiştir.

Ani hızlanma ve sık fren yapma gibi sürüş alışkanlıklarının yakıt tüketimi farkındalığıyla olan ilişkisi, literatürde yaygın olarak kabul edilen bir bulguyu tekrarlamakla birlikte [31], bu çalışma daha bilinçli sürüş tekniklerinin yakıt verimliliği üzerindeki etkisini vurgulayan yeni öneriler sunmuştur. Telematik cihaz kullanımı ile yakıt tüketimi farkındalığı arasındaki farkın minimal seviyede olması, bu cihazların etkisinin sınırlı olabileceğini işaret etmektedir. Ancak, bu sonucun daha geniş kapsamda doğrulanması için daha çok veri ve detaylı analiz gereklidir.

Makine öğrenimi modellerinin kullanılması, elektrikli araçlara yönelik ilginin ve yakıt verimliliği davranışlarının öngörülmesinde yüksek bir başarı oranı sağlamıştır. Özellikle XGBoost modelinin %100 doğruluk oranıyla diğer modellerden daha iyi

performans gösterdiği, bu çalışmanın makine öğrenimi ile desteklenen çevre dostu stratejiler önerme kapasitesini artırmaktadır. Bununla birlikte, model performanslarının sınıflar arasındaki dengesizliklerden etkilenmiş olabileceği de dikkate alınmalıdır. SMOTE gibi veri dengeleme tekniklerinin uygulanması, bu sorunun önüne geçilmesinde etkili bir strateji olarak değerlendirilmiştir.

Sonuç olarak, bu çalışma, elektrikli araçlara yönelik ilgi ve yakıt verimliliği konularında önemli kavrayışlar sunmuş, sürücü davranışlarının çevresel süreçlere etkisini açığa çıkarmıştır. Ancak, çalışmanın sınırlılıklarından biri, örneklem boyutunun ve coğrafi yaygınlığının sınırlı olmasıdır. Bu nedenle, gelecekteki çalışmaların daha geniş ve çeşitli veri setleriyle desteklenmesi önerilmektedir. Ayrıca, altyapı yetersizlikleri ve ekonomik engeller gibi başlıca faktörlerin, sürücü davranışlarıyla olan etkileşimlerinin daha derinlemesine incelenmesi gerekmektedir. Bu bulgular, sürdürülebilir enerji ve ulaşım politikalarını şekillendirecek stratejilere katkı sağlama potansiyeline sahiptir.

6. SONUÇ VE ÖNERİLER

Çalışmada, yaş grupları ve sürüş deneyimi ile elektrikli araçlara olan ilgi arasındaki ilişkilere dikkat çekilmiştir. 30-39 yaş grubunun elektrikli araçlara diğer yaş gruplarına kıyasla daha fazla ilgi gösterdiği, genç ve ileri yaş gruplarının ise benzer seviyelerde ilgiye sahip olduğu tespit edilmiştir. Bununla birlikte, sürüş deneyimi arttıkça ilgi seviyesinin daha geniş bir dağılım sergilediği ve deneyimi az olan bireylerin elektrikli araçlara daha fazla ilgi duyduğu gözlemlenmiştir. Bu durum, genç sürücülerin ve yeni deneyim kazanmakta olan bireylerin yeni teknolojilere daha açık olduklarını göstermektedir. Elektrikli araçlara ilişkin bilgi seviyesi ve şarj erişilebilirliği gibi değişkenler de bu araçlara olan ilgiyi belirgin şekilde artıran faktörler arasında yer almıştır. Özellikle, bilgi seviyesindeki artışın genç yaş gruplarında daha etkili olduğu, şarj erişilebilirliğinin ise genel olarak tüm gruplar için pozitif bir etkisi olduğu tespit edilmiştir.

Sürüş davranışları ve yakıt verimliliği arasındaki ilişkilere odaklanıldığında, ani hızlanma ve sık fren yapma gibi alışkanlıkların yakıt tüketimi farkındalığını olumsuz etkilediği görülmüştür. Daha bilinçli sürüş tekniklerinin yakıt verimliliğini artırabileceği, bu bulgularla desteklenmiştir. Telematik cihaz kullanımı ve yakıt tüketimi farkındalığı arasındaki ilişki incelendiğinde ise, bu cihazların kullanımının farkındalık seviyesine belirgin bir etkisi olmadığı, ancak sürüş alışkanlıklarını iyileştirme potansiyeline sahip olduğu belirlenmiştir. Bu durum, telematik cihazların etkilerinin daha derinlemesine incelenmesi gerektiğini ortaya koymaktadır.

Makine öğrenimi modelleriyle yapılan analizler, özellikle XGBoost ve Random Forest modellerinin yüksek doğruluk oranları ile etkili sonuçlar sunduğunu göstermiştir. Yeni özelliklerin eklenmesi ve SMOTE gibi dengeleme yöntemlerinin kullanımı, model performansını iyileştirirken dengesiz veri setlerinde sınıf tahmin başarısını artırmıştır. Bununla birlikte, sınıf bazında doğruluk oranlarının değişkenlik göstermesi, daha dengeli veri setleri ve daha gelişmiş modelleme tekniklerine ihtiyaç olduğunu ortaya koymaktadır.

Sonu olarak, elektrikli aralara olan ilginin artırılması iin bilgi seviyesini ykseltecek eēitim programları ve maliyet engellerini ortadan kaldıracak teēvik politikalarının uygulanması gerekmektedir. Őarj altyapısının geliőtirilmesi, bu araların benimsenmesini teēvik edecek kritik bir adımdır. Yakıt verimliliēi aısından ise, srclere ynelik bilinlendirme programlarının, ani hızlanma ve sık fren yapma gibi alışkanlıkların azaltılmasında etkili olabileceēi grlmőtr. Makine ērenimi algoritmalarının daha geniő veri setleri zerinde kullanılması, bu tr analizlerin genelleőtirilebilirliēini artırabilir. Elektrikli araların yaygınlaőmasını ve srdrlebilir ulaőtımı desteklemek iin ok ynl ve yeniliki yaklaőtımların benimsenmesi gerektiēi aıktır.



KAYNAKLAR

- [1] Kanagaraj, V., & Treiber, M. (2017). Fuel Consumption and Emissions Models for Traffic. In *Traffic and Granular Flow '17* (pp. 403-420). Springer, Cham. https://doi.org/10.1007/978-3-030-03816-8_20
- [2] Pampel, S. M., Jamson, S. L., Hibberd, D. L., & Barnard, Y. (2015). How I reduce fuel consumption: An experimental study on mental models of eco-driving. *Transportation Research Part C: Emerging Technologies*, 58, 669-680. <https://doi.org/10.1016/j.trc.2015.02.005>
- [3] Ping, P., Qin, W., Xu, Y., Miyajima, C., & Takeda, K. (2019). Impact of Driver Behavior on Fuel Consumption: Classification, Evaluation, and Prediction Using Machine Learning. *IEEE Access*, 7, 78515-78530. <https://doi.org/10.1109/ACCESS.2019.2920489>.
- [4] Thitipatanapong, R., & Luangnarutai, T. (2011). Effects of a vehicle's driver behavior on the fuel economy. *The 7th International Conference on Automotive Engineering (ICAE-7)*, March 28 – April 1, 2011, Bangkok, Thailand. https://www.researchgate.net/publication/260172245_Effects_of_A_Vehicle's_Driver_Behavior_to_The_Fuel_Economy
- [5] Wang, Y., & Boggio-Marzet, A. (2018). Evaluation of Eco-Driving Training for Fuel Efficiency and Emissions Reduction According to Road Type. *Sustainability*, 10(11), 3891. <https://doi.org/10.3390/su10113891>
- [6] Ayyildiz, K., Cavallaro, F., Nocera, S., & Willenbrock, R. (2017). Reducing fuel consumption and carbon emissions through eco-drive training. *Transportation Research Part F*, 46, 96–110. <https://doi.org/10.1016/j.trf.2017.01.006>
- [7] Lu, M., Wang, J., Li, K., Yamamura, T., Kuge, N., & Nakagawa, T. (2010). Characterization of longitudinal driving behavior by measurable parameters. *Transportation Research Record: Journal of the Transportation Research Board*, 2185(1), 1-12. <https://doi.org/10.3141/2185-03>
- [8] Wang, J., Li, K., & Lu, X. (2013). Effect of human factors on driver behavior. In *Advances in Intelligent Vehicles* (pp. 111-154). Elsevier. <https://doi.org/10.1016/B978-0-12-397199-9.00005-7>
- [9] Werner, K. W. D. (2013). *Driver Behavior and Fuel Efficiency*. Undergraduate Honors Thesis, University of Michigan. <https://deepblue.lib.umich.edu/bitstream/handle/2027.42/98892/karldw.pdf>
- [10] Ligterink, N. E., & Eijk, A. R. A. (2014). Real-World Fuel Consumption of Passenger Cars. *7th International Conference on Automotive Engineering (ICAE-7)*. <https://doi.org/10.13140/2.1.1252.3527>
- [11] Jamson, S. L., Hibberd, D. L., & Jamson, A. H. (2015). Drivers' ability to learn eco-driving skills: Effects on fuel-efficient and safe driving behaviour. *Transportation Research Part C: Emerging Technologies*, 58, 657–668. <https://doi.org/10.1016/j.trc.2015.02.004>

- [12] Lai, W.-T. (2015). The effects of eco-driving motivation, knowledge and reward intervention on fuel efficiency. *Transportation Research Part D*, 34, 155–160. <https://doi.org/10.1016/j.trd.2014.10.003>
- [13] Holmén, B. A., & Sentoff, K. M. (2015). Hybrid-electric passenger car carbon dioxide and fuel consumption benefits based on real-world driving. *Environmental Science & Technology*, 49(17), 10199–10208. <https://doi.org/10.1021/acs.est.5b01203>
- [14] Faria, M. V., Baptista, P. C., & Farias, T. L. (2017). Identifying driving behavior patterns and their impacts on fuel use. *Transportation Research Procedia*, 27, 953-960. <https://doi.org/10.1016/j.trpro.2017.12.038>
- [15] Heijne, V. A. M., & Ligterink, N. E. (2018). *Driving behaviour parameters for emission factors of heavy-duty vehicles* (TNO 2017 R11678). TNO. <https://www.researchgate.net/publication/332253425>
- [16] Heijne, V. A. M., Ligterink, N. E., & Stelwagen, U. (2017). Effects of driving behaviour on fuel consumption [Conference paper]. *UDRIVE Project Deliverable 45.1*, TAP Lyon Conference.
- [17] Leard, B. (2018). Consumer inattention and the demand for vehicle fuel cost savings. *Journal of Choice Modelling*, 29, 1-16. <https://doi.org/10.1016/j.jocm.2018.08.002>
- [18] Lee, C.-H., & Wu, C.-H. (2019). Learning to recognize driving patterns for collectively characterizing electric vehicle driving behaviors. *International Journal of Automotive Technology*, 20(6), 1263–1276. <https://doi.org/10.1007/s12239-019-0118-4>
- [19] Zhang, H., Sun, J., & Tian, Y. (2020). The impact of socio-demographic characteristics and driving behaviors on fuel efficiency. *Transportation Research Part D: Transport and Environment*, 88, 102565. <https://doi.org/10.1016/j.trd.2020.102565>
- [20] Sanguinetti, A., Queen, E., Yee, C., & Akanesuvan, K. (2020). Average impact and important features of onboard eco-driving feedback: A meta-analysis. *Transportation Research Part F: Traffic Psychology and Behaviour*, 70, 1-14. <https://doi.org/10.1016/j.trf.2020.02.010>
- [21] Van Gijlswijk, R., Paalvast, M., Ligterink, N. E., & Smokers, R. (2020). *Real-world fuel consumption of passenger cars and light commercial vehicles* (TNO 2020 R11664). TNO. <https://doi.org/10.13140/RG.2.2.24856.42249>
- [22] Fafoutellis, P., Mantouka, E. G., & Vlahogianni, E. I. (2021). Eco-driving and its impacts on fuel efficiency: An overview of technologies and data-driven methods. *Sustainability*, 13(1), 226. <https://doi.org/10.3390/su13010226>
- [23] Huang, Y., Ng, E. C. Y., Zhou, J. L., Surawski, N. C., Lu, X., Du, B., Forehead, H., Perez, P., & Chan, E. F. C. (2021). Impact of drivers on real-driving fuel consumption and emissions performance. *Science of the Total Environment*, 798, 149297. <https://doi.org/10.1016/j.scitotenv.2021.149297>
- [24] Zhang, L., Zhang, T., Peng, K., Zhao, X., & Xu, Z. (2022). Can autonomous vehicles save fuel? Findings from field experiments. *Journal of Advanced Transportation*, 2022(Article ID 2631692), 1–12. <https://doi.org/10.1155/2022/2631692>

- [25] Su, Z., Woodman, R., Smyth, J., & Elliott, M. (2023). The relationship between aggressive driving and driver performance: A systematic review with meta-analysis. *Accident Analysis and Prevention*, 183, 106972. <https://doi.org/10.1016/j.aap.2023.106972>
- [26] Zhao, D., Li, H., Hou, J., Gong, P., Zhong, Y., He, W., & Fu, Z. (2023). A Review of the Data-Driven Prediction Method of Vehicle Fuel Consumption. *Energies*, 16(14), 5258. <https://doi.org/10.3390/en16145258>
- [27] Graba, M., Bieniek, A., Prażnowski, K., Hennek, K., Mamala, J., Burdzik, R., & Śmieja, M. (2023). Analysis of energy efficiency and dynamics during car acceleration. *Eksploatacja i Niezawodność – Maintenance and Reliability*, 25(1). <https://doi.org/10.17531/ein.2023.1.17>
- [28] Zhou, B., He, L., Zhang, S., Wang, R., Zhang, L., Li, M., Liu, Y., Zhang, S., Wu, Y., & Hao, J. (2023). Variability of fuel consumption and CO₂ emissions of a gasoline passenger car under multiple in-laboratory and on-road testing conditions. *Journal of Environmental Sciences*, 125, 266–276. <https://doi.org/10.1016/j.jes.2021.12.042>
- [29] Peng, F., Zhang, Y., Song, G., Huang, J., Zhai, Z., & Yu, L. (2023). Evaluation of real-world fuel consumption of hybrid-electric passenger car based on speed-specific vehicle power distributions. *Journal of Advanced Transportation*, 2023(9016510), 1–13. <https://doi.org/10.1155/2023/9016510>
- [30] Kumar, R., & Jain, A. (2023). Driving behavior analysis and classification by vehicle OBD data using machine learning. *The Journal of Supercomputing*, 79(18800–18819). <https://doi.org/10.1007/s11227-023-05364-3>
- [31] Zhang, Z., Demir, E., Mason, R., & Di Cairano-Gilfedder, C. (2023). Understanding freight drivers' behavior and the impact on vehicles' fuel consumption and CO₂e emissions. *Operational Research*, 23, 59. <https://doi.org/10.1007/s12351-023-00798-2>
- [32] Ma, Z., Jørgensen, B. N., & Ma, Z. (2024). A Scoping Review of Energy-Efficient Driving Behaviors and Applied State-of-the-Art AI Methods. *Energies*, 17(500), 1-19. <https://doi.org/10.3390/en17020500>
- [33] Canal, R., Riffel, F. K., & Gracioli, G. (2024). Machine Learning for Real-Time Fuel Consumption Prediction and Driving Profile Classification Based on ECU Data. *IEEE Access*, 12, 68586-68599. <https://doi.org/10.1109/ACCESS.2024.3400933>
- [34] Shaffiee Haghshenas, S., Astarita, V., Shaffiee Haghshenas, S., & Guido, G. (2024). Artificial Intelligence-Powered Driver Behavior Analysis for Fuel Consumption Optimization: A Pathway to Greener Roads. *10th International Conference on Control, Decision and Information Technologies (CoDIT)*, Valletta, Malta, 116-122. IEEE. <https://doi.org/10.1109/CoDIT62066.2024.10708512>
- [35] Romero, C. A., Correa, P., Ariza Echeverri, E. A., & Vergara, D. (2024). Strategies for Reducing Automobile Fuel Consumption. *Applied Sciences*, 14(2), 910. <https://doi.org/10.3390/app14020910>



ÖZGEÇMİŞ

Ad-Soyad : İlayda Nur ŞİŞMAN

ÖĞRENİM DURUMU:

- Lisans** : 2022, Sakarya Üniversitesi, Fen Edebiyat Fakültesi, Matematik Bölümü
- Yükseklisans** : 2025, Sakarya Üniversite, Fen Bilimleri Enstitüsü, Bilişim Sistemleri Mühendisliği EABD

MESLEKİ DENEYİM:

- 2024 Kasım - 2025 Ocak ayları arasında Sakarya Üniversitesi Fen Bilimleri Enstitüsü'nde öğrenci asistanı olarak görev yaptı.

TEZDEN TÜRETİLEN ESERLER:

- Şişman, İ. N., & Çarklı Yavuz, B. (2024, 26-28 Aralık). The Effect of Driver Behaviour on Fuel Consumption and Efficiency: A Survey Based Study. 5. *Uluslararası Hazar Bilimsel Araştırmalar ve İnovasyon Kongresi*, Türkistan, Kazakistan.

DİĞER ESERLER:

- Şişman, İ. N., & Çarklı Yavuz, B. (2023, 20-21 Mayıs). Veri Analitiği ve Değişen İş Dünyası: Analistlerin Rolü. 5. *Uluslararası Bilimsel Araştırmalar ve İnovasyon Kongresi (ISARC)*, Ankara, Türkiye.