

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**ELEKTRİKLİ ARAÇLARIN KULLANICI TERCİHLERİNE GÖRE
SINIFLANDIRILMASI: HİBRİT BİR YAKLAŞIM**

YÜKSEK LİSANS TEZİ

Mehmet DEMİR

Endüstri Mühendisliği Anabilim Dalı

Mühendislik Yönetimi Programı

TEMMUZ 2025

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**ELEKTRİKLİ ARAÇLARIN KULLANICI TERCİHLERİNE GÖRE
SINIFLANDIRILMASI: HİBRİT BİR YAKLAŞIM**

YÜKSEK LİSANS TEZİ

Mehmet DEMİR

(507211233)

Endüstri Mühendisliği Anabilim Dalı

Mühendislik Yönetimi Programı

Tez Danışmanı: Doç. Dr. Umut ASAN

TEMMUZ 2025

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**CLASSIFICATION OF ELECTRIC VEHICLES BASED ON USER
PREFERENCE: A HYBRID APPROACH**



M.Sc. THESIS

Mehmet DEMİR

(507211233)

Department of Industrial Engineering

Engineering Management Programme

Thesis Advisor: Assoc. Prof. Dr. Umut ASAN

JULY 2025

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 507211233 numaralı Yüksek Lisans öğrencisi Mehmet DEMİR, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “ELEKTRİKLİ ARAÇLARIN KULLANICI TERCİHLERİNE GÖRE SINIFLANDIRILMASI: HİBRİT BİR YAKLAŞIM” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Umut ASAN**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Ayberk SOYER**
İstanbul Teknik Üniversitesi
Prof. Dr. S. Emre ALPTEKİN
Galatasaray Üniversitesi

Teslim Tarihi : **02 Haziran 2025**

Savunma Tarihi : **03 Temmuz 2025**





Kıymetli aileme,



ÖNSÖZ

Bu çalışmanın her aşamasında sabırla bana rehberlik eden, katkılarıyla çalışmama değer katan, tanımaktan onur duyduğum değerli danışmanım ve hocam Doç. Dr. Umut Asan’a şükranlarımı sunarım. Kendisine sadece akademik katkılarından dolayı değil, aynı zamanda destekleyici yaklaşımı için de minnettarım.

Bu süreçte bana sürekli destek olan, sabrı ve sevgisiyle bana güç veren sevgili eşim Fatma’ya, ufaklıklar Atlas ve Duru’ya ve canım kardeşim Onur’a sonsuz teşekkürlerimi sunarım. Onların sevgisi ve anlayışı olmadan bu süreci tamamlamak çok daha zor olurdu.

Temmuz 2025

Mehmet DEMİR

Endüstri Mühendisi



İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ.....	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SEMBOLLER	xv
ÇİZELGE LİSTESİ.....	xvii
ŞEKİL LİSTESİ.....	xix
ÖZET.....	xxi
SUMMARY	xxv
1. GİRİŞ	1
2. LİTERATÜR ARAŞTIRMASI	7
2.1 Çok Kriterli Karar Verme (ÇKKV) Yaklaşımları.....	8
2.1.1 Sınıflandırma tabanlı ÇKKV yöntemleri	9
2.1.2 TOPSIS-Sort	14
2.2 Elektrikli Araçlara İlişkin Karar Verme Uygulamaları.....	16
2.3 Makina Öğrenmesi ile Sınıflandırma	19
2.4 ÇKKV ve Makine Öğrenmesinin Birlikte Kullanımı	21
3. METODOLOJİ	25
3.1 Veri Seti ve Özellikleri.....	27
3.1.1 Kullanılan değişkenler	28
3.1.2 Veri ön işleme	28
3.2 Kümeleme ile Sınıf Sayısının Belirlenmesi	30
3.2.1 Kümeleme yöntemleri.....	31
3.2.2 Optimum küme sayısının belirlenmesi	33
3.3 TOPSIS-Sort-B ile Etiketleme	34
3.4 Sınıflandırma Algoritmaları ile Modelleme.....	36
3.4.1 Eğitim-Test verisi ayrımı	37
3.4.2 Kullanılan sınıflandırma yöntemleri	37
3.4.3 Model performans metriği	43
4. ANALİZ VE BULGULAR.....	45
4.1 Veri Toplama ve Hazırlık Süreci	45
4.2 Sınıf Sayısının Belirlenmesi: Kümeleme Analizi	49
4.2.1 Kümeleme yöntemleri ve değerlendirme kriterleri	49
4.2.2 Sınıf sayısının belirlenmesi	52
4.3 ÇKKV Yöntemi ile Sınıflandırma	55
4.3.1 TOPSIS-Sort-B yönteminin uygulanması.....	55
4.3.2 Sınıf dağılımı ve TOPSIS-Sort-B sonuçlarının özeti.....	57
4.4 Makine Öğrenmesi ile Sınıf Tahmini.....	58
4.4.1 Kullanılan algoritmalar ve modelleme süreci	58
4.4.2 Performans değerlendirme ve sonuçlar	60
4.5 ÇKKV ve Makina Öğrenmesi Sonuçlarının Karşılaştırması	62
5. TARTIŞMA VE SONUÇ.....	66

5.1 Çıkarımlar ve Teorik Katkılar	68
5.2 Kısıtlar ve Sonraki Çalışmalara Öneriler	69
KAYNAKÇA	71
EKLER.....	81
ÖZGEÇMİŞ.....	99



KISALTMALAR

ABD	: Amerika Birleşik Devletleri
AHP	: Analitik Hiyerarşi Süreci
AIC	: Akaike Bilgi Kriteri
BEV	: Bataryalı Elektrikli Araç
BIC	: Bayezyen Bilgi Kriteri
ÇKKV	: Çok Kriterli Karar Verme
DIC	: Sapma Bilgi Kriteri
DSA	: Derin Sinir Ağları
DVM	: Destek Vektör Makineleri
EA	: Elektrikli Araç
IT	: Bilgi Teknolojileri
KEYK	: K-En Yakın Komşu
KOBİ	: Küçük ve Orta Büyüklükteki İşletmeler
KUDH	: Kısa-Uzun Dönem Hafıza
LR	: Lojistik Regresyon
MÖ	: Makina Öğrenmesi
RO	: Rassal Orman
UEA	: Uluslararası Enerji Ajansı
VEF	: Varyans Enflasyon Faktörü
YSA	: Yapay Sinir Ağları



SEMBOLLER

$\mathbf{a}^+$: İdeal değer
 $\mathbf{a}^-$: Anti-ideal değer





ÇİZELGE LİSTESİ

Sayfa

Çizelge 4.1: Öznitelikler ve açıklamaları.	47
Çizelge 4.2: K-ortalamalar algoritmasında küme sayısına göre silhouette skoru.	50
Çizelge 4.3: Hiyerarşik kümelemeye göre kümelerin metrik öznitelikler bakımından ortalama değerleri.	54
Çizelge 4.4: Kriterlere ilişkin özellikler.	56
Çizelge 4.5: Performans metrikleri.	60
Çizelge A.1: Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.....	84



ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 3.1: Önerilen Metodolojinin Adımları.....	27
Şekil 4.1: Tek bağlantı metodu ve Mahalanobis uzaklığı ile oluşturulan dendrogram.	50
Şekil 4.2: Ortalama bağlantı metodu ve Mahalanobis uzaklığı ile oluşturulan dendrogram.	51
Şekil 4.3: Tam bağlantı metodu ve Mahalanobis uzaklığı ile oluşturulan dendrogram.	51
Şekil 4.4: Ward metodu ve Öklid uzaklığı ile oluşturulan dendrogram.	52
Şekil 4.5: Yapay sinir ağı modelinin karışıklık matrisi.	61
Şekil 4.6: Naive Bayes modelinin karışıklık matrisi.	62



ELEKTRİKLİ ARAÇLARIN KULLANICI TERCİHLERİNE GÖRE SINIFLANDIRILMASI: HİBRİT BİR YAKLAŞIM

ÖZET

Son yıllarda artan çevresel kaygılar, enerji verimliliği arayışları ve fosil yakıt bağımlılığının azaltılmasına yönelik politikalar, elektrikli araçlara olan ilgiyi küresel ölçekte ciddi biçimde artırmıştır. Bu teknolojik dönüşüm, yalnızca otomotiv sektörünün mühendislik boyutlarını değil, aynı zamanda tüketici davranışlarını, pazarlama stratejilerini ve karar destek sistemlerini de doğrudan etkilemektedir. Elektrikli araç pazarının hızlı genişlemesiyle birlikte kullanıcılar için ürün çeşitliliği önemli ölçüde artarken, üreticiler ve pazarlamacılar açısından da hangi araçların hangi kullanıcı segmentlerine hitap ettiğini belirlemek daha karmaşık hale gelmiştir. Özellikle, pazar araştırmacıları ve sektör analistleri, bu çok boyutlu karar verme ortamında geleneksel analiz yöntemlerinin yetersiz kaldığını ve daha sofistike yaklaşımlara ihtiyaç duyulduğunu belirtmektedir. Bu bağlamda, çok sayıda teknik özelliğe sahip araçların anlamlı şekilde tercih edilebilirlik düzeylerine göre sıralı sınıflandırılması önemli bir problem alanı olarak ortaya çıkmaktadır.

Bu tez çalışmasında, bu ihtiyaca yanıt verebilecek hibrit bir yöntemsel çerçeve geliştirilmiştir. Çok kriterli karar verme yöntemlerinden biri olan TOPSIS-Sort-B algoritması kullanılarak, piyasadaki 439 elektrikli aracın çeşitli performans, boyut, konfor ve fiyat vb. kriterlerine göre tercih edilebilirlik düzeyleri analiz edilmiştir. TOPSIS-Sort-B algoritmasının seçilmesindeki temel gerekçe, bu yöntemin geleneksel TOPSIS yaklaşımından farklı olarak alternatifleri önceden belirlenmiş sıralı sınıflara atayabilme kapasitesine sahip olması ve böylelikle sıralama yerine kategorilendirme yapmasıdır. Bu özellik, elektrikli araç pazarında segmentasyon çalışmaları için kritik önem taşımaktadır çünkü tüketiciler ve üreticiler için mutlak performans karşılaştırması yerine sınıf esaslı tercih seviyeleri daha anlamlı sonuçlar vermektedir.

Çalışmada kullanılan veri seti, elektrikli araçlar konusunda en geniş kamuya açık veri kaynağı olan EVdatabase platformundan veri kazıma yöntemiyle elde edilmiştir. Veri toplama sürecinde Python programlama dili ve web scraping kütüphaneleri kullanılmış, araçların teknik özelliklerini (menzil, maksimum hız, batarya kapasitesi, şarj süresi, bagaj hacmi, fiyat, hızlanma performansı, enerji tüketimi vb.) kapsayacak şekilde kapsamlı biçimde veri çekilmiştir. Toplanan veri seti, halihazırda piyasaya sürülmüş olan elektrikli araç modellerini içermekte olup, çeşitli araç segmentlerinden (sedan, SUV, hatchback, lüks araçlar) dengeli bir dağılım sağlanmıştır. Ancak verinin doğası gereği belirli düzeyde güncellik sınırlaması olduğu ve sürekli güncellenen piyasa koşullarının tam olarak yansıtılamayabileceği de kabul edilmiştir.

Sıralı sınıflandırma algoritmasının kaç sınıf üzerinden çalıştırılacağına hesaplanması bağlamında veriye öncelikle bölünmeli ve hiyerarşik kümeleme analizleri uygulanmıştır ve bu analizlerin sonucunda üç kümenin (sınıfın) veriyi en ideal şekilde yansıtacağı ortaya konmuştur. TOPSIS-Sort-B yöntemi ile elde edilen üçlü tercih sınıfları (yüksek, orta ve düşük tercih edilebilirlik), daha sonra çeşitli makine öğrenimi

sınıflandırma algoritmalarına etiketli veri olarak sunulmuş ve bu sınıfların farklı modeller tarafından ne ölçüde doğru tahmin edilebildiği karşılaştırılmıştır. Bu hibrit yaklaşımın arkasındaki temel mantık, ÇKKV yöntemlerinin uzman bilgisini ve çok kriterli değerlendirme kapasitesini makine öğrenmesi modellerinin örüntü tanıma ve genelleme kabiliyetleriyle birleştirmektir. Böylece hem karar destek sistemlerinin daha kararlı hale getirilmesi hem de ÇKKV yöntemlerinden elde edilen sınıfların öngörülebilirliği ve geçerliliği test edilmiştir.

Çalışma, sınıflandırma problemlerine ÇKKV yaklaşımını temel olarak entegre eden bu hibrit yöntemle, literatürde sınırlı olarak ele alınan bir yöntemle katkı sağlamaktadır. Özellikle, geleneksel olarak birbirinden bağımsız uygulanan bu iki yaklaşımın entegrasyonu, hem metodolojik hem de pratik açıdan önemli avantajlar sunmaktadır. Ayrıca, bu yaklaşım sayesinde, yeni elektrikli araç verileri üzerinden otomatik tercih sınıfı tahmini yapılabilmesi mümkün hale gelmiştir. Tüketicilerin karar süreçlerini kolaylaştırmak ve üreticilere stratejik öngörüler sunmak açısından, geliştirilen sistemin hem akademik hem de pratik değeri bulunmaktadır.

Veri ön işleme sürecinde, eksik ya da anlamlılığı düşük sütunlar sistematik olarak elenmiş; sürekli ve kategorik değişkenler uygun biçimde dönüştürülmüştür. Bu aşamada özellikle eksik veri problemlerinin çözümü için çeşitli yerine koyma teknikleri uygulanmış ve veri tutarlılığını sağlamak amacıyla ileri düzey kontroller yapılmıştır. Ardından, öz niteliklerin (kriterlerin) ağırlıklandırılması amacıyla Analitik Hiyerarşi Süreci (AHP) uygulanmıştır. Bu süreçte, elektrikli araçlar alanında uzman kişilerden alınan değerlendirmeler çerçevesinde, kriterlerin göreceli önemleri hesaplanmış ve bu ağırlıklar TOPSIS-Sort-B algoritmasına entegre edilmiştir. Uzmanların seçiminde, elektrikli araç teknolojileri konusunda akademik ya da sektörel uzmanlığa sahip bulunmaları kriterleri gözetilmiştir.

Ayrıca, sınıfların sınırlarının belirlenebilmesi amacıyla, tercih edilebilirlik skorları için üst ve alt eşik değerleri yine uzman görüşü ile belirlenmiştir. Bu eşik değerlerin belirlenmesinde veri setinin dağılım özellikleri dikkate alınmış ve her segmentin (sınıfın) anlamlı sayıda araç içermesi sağlanmıştır. Tercih edilebilirlik bağlamındaki sınıflandırma sonucunda elde edilen dağılım, dengeli bir yapı (130 düşük, 164 orta ve 145 yüksek tercih edilebilirlik) göstermiş ve üç sınıfın da yeterli temsil gücüne sahip olduğu görülmüştür.

Sıralı sınıflandırma algoritması ile elde edilen bu tercih edilebilirlik etiketleri, ikinci aşamada denetimli makine öğrenmesi modellerinin eğitilmesi için kullanılmıştır. Bu kapsamda karar ağaçları, lojistik regresyon, Naive Bayes, destek vektör makineleri, k-en yakın komşu ve yapay sinir ağları gibi farklı yaklaşımları temsil eden modeller uygulanmıştır. Veri seti eğitim (%80) ve test (%20) olarak katmanlı örnekleme yöntemiyle bölünmüş, böylelikle her sınıfın hem eğitim hem de test setinde dengeli şekilde temsil edilmesi sağlanmıştır. Modellerin performansları doğruluk, duyarlılık, kesinlik, F1-skoru gibi metriklerle kapsamlı biçimde değerlendirilmiştir.

Elde edilen bulgular, özellikle yapay sinir ağı modelinin %96,6 ile sınıflandırma doğruluğu açısından en başarılı performansı sergilediğini göstermiştir. Bunu %95,5 ile lojistik regresyon, %93,2 ile destek vektör makineleri ve karar ağacı modelleri takip etmiştir. Karışıklık matrisleri, modellerin özellikle yüksek ve düşük tercih edilebilirlik sınıflarını ayırt etmede oldukça başarılı olduğunu, orta sınıfta ise diğer iki tercih edilebilirlik düzeyine göre kısmen problem yaşayabildiklerini ortaya koymuştur. Ayrıca genel anlamda, test verisindeki araçların büyük bir bölümü tüm modeller

tarafından tutarlı şekilde doğru tahmin edilmiş, bu durum TOPSIS-Sort-B ile oluşturulan etiketlerin makine öğrenmesi açısından yüksek tutarlılığa sahip olduğunu kanıtlamıştır.

Bu tez, hem elektrikli araçlara ilişkin veri odaklı sınıflandırma yaklaşımlarına literatürde yeni bir katkı sunmakta hem de TOPSIS-Sort-B algoritmasının makine öğrenmesi modelleriyle entegrasyonunu sağlayarak hibrit bir analiz çerçevesi ortaya koymaktadır. Çalışmanın yöntemsel katkısı, geleneksel ÇKKV yöntemlerinin modern makine öğrenmesi teknikleriyle nasıl birleştirilebileceğini göstermesi ve bu entegrasyonun her iki yaklaşımın avantajlarını bir araya getirmesidir. Özellikle, ÇKKV yöntemlerinin uzman bilgisini yapılandırma kapasitesi ile makine öğrenmesi algoritmalarının büyük veri setlerini işleme ve örüntü tanıma yeteneklerinin bir araya getirilmesi, karar destek sistemleri literatürüne önemli bir katkı sunmaktadır.

Çalışmanın bulguları, üretici ve pazarlamacıların stratejik planlamalarına yön verebilecek nitelikte olup, özellikle tüketici tercihleri, ürün konumlandırması ve rekabet analizi açısından değerli bilgiler sunmaktadır. Ayrıca kullanıcı deneyimi açısından, geliştirilen sistem kişiselleştirilmiş öneri sistemlerine, akıllı ürün filtreleme araçlarına, fiyatlandırma stratejilerine ve otomatik değerlendirme platformlarına temel oluşturabilecek şekilde pratik faydalar da sunmaktadır.

Gelecek çalışmalar için bu hibrit yaklaşımın diğer sektörlere (beyaz eşya, elektronik, gayrimenkul vb.) uyarlanması, daha büyük ve çeşitli veri setleriyle test edilmesi, gerçek zamanlı veri akışlarıyla entegrasyonu ve kullanıcı geri bildirimlerinin sisteme dahil edilmesi önerilmektedir. Ayrıca, daha büyük veri setleri için derin öğrenme yöntemlerinin de hibrit modele entegre edilerek performans artışının sağlanabileceği düşünülmektedir.



CLASSIFICATION OF ELECTRIC VEHICLES BASED ON USER PREFERENCE: A HYBRID APPROACH

SUMMARY

In recent years, increasing environmental concerns, energy efficiency pursuits, and policies aimed at reducing fossil fuel dependency have significantly heightened global interest in electric vehicles. This technological transformation has directly affected not only the engineering aspects of the automotive sector but also consumer behaviours, marketing strategies, and decision support systems. While the rapid expansion of the electric vehicle market has significantly increased product diversity for users, determining which vehicles appeal to which user segments has become more complex for manufacturers and marketers. In particular, market researchers and industry analysts indicate that traditional analysis methods are insufficient in this multi-dimensional decision-making environment and that more sophisticated approaches are needed. In this context, the meaningful classification of vehicles with numerous technical features and their segmentation according to preference levels emerges as an important problem area.

In this thesis, a hybrid methodological framework has been developed to address this need. Using the TOPSIS-Sort-B algorithm, one of the multi-criteria sorting methods, the preference levels of 439 electric vehicles in the market were analysed according to various criteria such as performance, size, comfort, and price criteria. The fundamental rationale for selecting the TOPSIS-Sort-B algorithm is that this method, unlike the traditional TOPSIS approach, has the capacity to assign alternatives to predetermined classes, thus performing sorting rather than ranking. This feature is of critical importance for segmentation studies in the electric vehicle market because preference classes provide more meaningful results than absolute performance comparisons for consumers and manufacturers.

The dataset used in the study was obtained through web scraping from the EVdatabase platform, which is the most comprehensive publicly available data source on electric vehicles. Python programming language and web scraping libraries were used in the data collection process, and data was comprehensively extracted to cover the technical specifications of vehicles (range, maximum speed, battery capacity, charging time, trunk volume, price, acceleration performance, energy consumption, etc.). The collected dataset includes electric vehicle models that have already been launched in the market, with a balanced distribution from various vehicle segments (sedan, SUV, hatchback, luxury vehicles). However, it is acknowledged that due to the nature of the data, there are certain limitations in terms of currency and that continuously updated market conditions may not be fully reflected.

In the context of calculating how many classes the sorting algorithm would operate on, partitioning and hierarchical clustering methods were first applied to the data, and as a result of these analyses, it was established that three clusters (classes) would reflect the data most ideally. The triple preference classes (high, medium, and low preference) obtained through the TOPSIS-Sort-B method were then presented as labelled data to

various machine learning classification algorithms, and the extent to which these classes could be accurately predicted by different models was compared. The fundamental logic behind this hybrid approach is to combine the expert knowledge and multi-criteria evaluation capacity of MCDM methods with the pattern recognition and generalization capabilities of machine learning models. Thus, both strengthening decision support systems and testing the predictability and validity of classes obtained from MCDM methods were achieved.

This study presents a hybrid method that integrates the MCDM approach into classification problems—an area that has received limited attention in the literature. In particular, the integration of these two approaches, which are traditionally applied independently, offers significant advantages both methodologically and practically. Moreover, through this approach, it has become possible to make automatic preference class predictions on new electric vehicle data. The developed system has both academic and practical value in terms of facilitating consumers' decision-making processes and providing strategic insights to manufacturers.

In the data pre-processing phase, missing or low-significance columns were systematically eliminated, and continuous and categorical variables were appropriately transformed. At this stage, various imputation techniques were applied to solve missing data problems, and advanced controls were performed. Subsequently, the Analytic Hierarchy Process (AHP) was applied to weight the features (criteria). In this process, the relative importance of criteria was calculated based on evaluations obtained from experts in the field of electric vehicles, and these weights were integrated into the TOPSIS-Sort-B algorithm. The selection of experts was based on their academic or industrial experience in electric vehicle technologies.

Additionally, to determine the boundaries of classes, upper and lower threshold values for preference scores were determined with the opinions of the same experts. In determining these threshold values, the distribution characteristics of the dataset were taken into account, and it was ensured that each segment contained a meaningful number of vehicles. The distribution obtained as a result of sorting in the context of preference showed a balanced structure (130 low, 164 medium, and 145 high preference), and it was observed that all three classes had sufficient representational power.

These preference labels obtained through the sorting algorithm were used for training supervised machine learning models in the second phase. In this context, models representing different approaches such as decision trees, logistic regression, Naive Bayes, support vector machines, k-nearest neighbours, and artificial neural networks were applied. The dataset was divided into training (80%) and test (20%) using stratified sampling method, thus ensuring balanced representation of each class in both training and test sets. The performance of models was comprehensively evaluated with metrics such as accuracy, sensitivity, precision, and F1-score.

The findings obtained showed that the artificial neural network model exhibited the most successful performance in terms of classification accuracy with 96.6%. This was followed by logistic regression with 95.5%, support vector machines and decision tree models with 93.2%. Confusion matrices revealed that the models were quite successful in distinguishing high and low preference classes, while they could experience some problems in the medium class compared to the other two preference levels. Moreover, a large portion of the vehicles in the test data were consistently and correctly predicted

by all models, proving that the labels created with TOPSIS-Sort-B have high consistency in terms of machine learning.

This thesis contributes to data-driven classification approaches related to electric vehicles in the literature and presents a hybrid analysis framework by enabling the integration of the TOPSIS-Sort-B algorithm with machine learning models. The methodological contribution of the study is to show how traditional MCDM methods can be combined with modern machine learning techniques and that this integration brings together the advantages of both approaches. In particular, bringing together the capacity of MCDM methods to structure expert knowledge with the ability of machine learning algorithms to process large datasets and recognize patterns provides an important contribution to the decision support systems literature.

The findings of the study are of a nature that can guide the strategic planning of manufacturers and marketers, providing valuable information particularly in terms of consumer preferences, product positioning, and competitive analysis. Additionally, from a user experience perspective, the developed system offers practical benefits that can form the basis for personalized recommendation systems, intelligent product filtering tools, pricing strategies, and automatic evaluation platforms.

For future studies, it is recommended to adapt this hybrid approach to other sectors (white goods, electronics, real estate, etc.), test it with larger and more diverse datasets, integrate it with real-time data streams, and include user feedback in the system. Additionally, it is considered that performance improvement can be achieved by integrating deep learning methods into the hybrid model for larger datasets.



1. GİRİŞ

Günümüzde ulaşım sektörünün çevreye olan olumsuz etkileri giderek daha fazla gündeme gelmektedir. Fosil yakıtla çalışan içten yanmalı motorlu araçlar, dünya genelinde sera gazı emisyonlarının yaklaşık %15'ini oluşturmakta ve bu da araç sektörünü karbon ayak izinin en büyük nedenlerinden biri haline getirmektedir (Ritchie, 2024). Bu bağlamda elektrikli araçlar hem karbon emisyonlarının azaltılması hem de sürdürülebilir ulaşımın sağlanması açısından kritik bir rol oynamaktadır. Nitekim, bu bağlamda elektrikli araçlar, fosil yakıtlı araçlara kıyasla düşük karbon emisyonu, daha düşük işletme maliyeti ve enerji verimliliği gibi avantajları nedeniyle ulaşım sektöründe giderek daha fazla tercih edilmektedir (Hawkins vd., 2013). Özellikle şehir içi hava kirliliğinin azaltılması ve gürültü kirliliğinin önlenmesi açısından elektrikli araçlar, kentsel yaşam kalitesini artıran önemli bir faktör olarak görülmektedir (Hardman vd., 2018). Elektrikli araçlar sayesinde karbon ayak izinin daha da azaltılması mümkün olmaktadır. Ayrıca, günümüzde benimsenme oranları hızla tırmanan elektrikli araçlara yönelik yapılan çalışmalar çerçevesinde menzil, batarya verimliliği ve performans açısından da önemli ilerlemeler kaydedilmektedir (Ecer, 2021; Sonar ve Kulkarni, 2021; Higuera-Castillo vd., 2021).

Elektrikli araçların tarihi aslında sanıldığından çok daha eskilere dayanmaktadır. 19. yüzyılın sonlarında, içten yanmalı motorlu araçlardan da önce elektrikli araçlar oldukça popüler olduğu bilinmektedir. Örneğin; Chen (2007) 1900'lü yılların başında Amerika'da satılan otomobillerin yaklaşık üçte biri elektrikli araçlardan oluştuğunu ifade etmiştir. Ancak petrolün ucuzlaması ve içten yanmalı motor teknolojisinin hızla gelişmesiyle birlikte elektrikli araçlar uzunca bir süre piyasadan silinmiş, ancak çevresel sorunların büyümesi ve teknolojik gelişmeler sayesinde 21. yüzyılın başlarından itibaren tekrardan gündeme gelmiştir. 1970'lerin petrol krizleri sırasında kısa bir canlanma yaşansa da, gerçek anlamda tekrardan elektrikli araçlara yönelim ancak batarya teknolojilerindeki önemli atılımlarla mümkün olabilmektedir. Tarihsel süreçte elektrikli araçların gelişimi, enerji depolama kapasitesi ve maliyetler gibi

teknik kısıtlamalara bağılı olarak  ekillenmi , bug n geline nokta da ise bu engellerin kayda deęer kısmı a ılmı tır (Guarnieri, 2012).

2000’li yıllarda lityum-iyon batarya teknolojisindeki ilerlemeler, Tesla gibi firmaların  nc l ę , devlet te vikleri, karbon emisyonu azaltma hedefleri ve t keticilerin  evre duyarlılıęının artmasıyla birlikte elektrikli ara lar istikrarlı bi imde pazarda yer bulmaya ba lamı tır. Batarya maliyetlerinin d     ve  arj altyapısının yaygınla masıyla birlikte t keticilerin menzil kaygısı azalmı , dolayısıyla elektrikli ara  satı ları 2010’lu yıllardan itibaren  stel bir b y me g stermi tir. G n m zde pek  ok  retici ( rneęin, Tesla, Toyota, Renault, Volkswagen, BYD, MG vb.) elektrikli veya hibrit modeller geli tirerek pazarda rekabet etmektedir. Bu rekabet sadece  evresel bir gereklilik deęil, aynı zamanda ekonomik ve teknolojik geli melerin de bir sonucu olarak  ekillenmektedir.

Elektrikli ara ların benimsenmesi son yıllarda ivme kazanmı tır. Uluslararası Enerji Ajansı’nın 2024 raporuna g re, 2023 yılında d nya genelinde satılan her be  ara tan biri elektrikli ara tır ve bu oran Norve ’te %90’ı,  in’de ise %40’ı a mı tır. K resel  l ekte trafikteki elektrikli ara  sayısı ise 2022’de 26 milyon iken, 2024 itibarıyla 40 milyonun  zerine  ıkmı tır. Bu artı , yalnızca  evresel kaygılarla deęil, aynı zamanda h k metlerin saęladığı s bvansiyonlar, altyapı yatırımları ve deęi en t keticiler davranı ları ile de doęrudan ili kilidir (Ritchie, 2024; Morgan, 2025). Ek olarak, otomotiv devlerinin fosil yakıtlı ara   retimini belirli tarihlerden sonra sonlandıracaklarını a ıklamaları ve pek  ok  lkenin 2030 - 2040 yılları arasında yeni i ten yanmalı motorlu ara  satı larını yasaklama planları, sekt r n elektrikli ara lara doęru hızla evrildięinin en  nemli g stergeleridir (Ziemann vd., 2018; Xu vd., 2020).

Elektrikli ara ların gelecekteki yaygınlığına ili kin  ng r ler de dikkat  ekicidir. Statista’nın 2024  ng r lerine g re, k resel elektrikli ara  pazarının 2030 yılına kadar yıllık %17’lik bir bile ik b y me oranı ile geni lemesi beklenmektedir (Statista, 2024). Dięer yandan MarketWatch verileri, ABD’deki elektrikli ara  penetrasyonunun 2025 yılı itibarıyla toplam ara  stoęunun %15’ine ula acağını  ng rmektedir (Morgan, 2025). BloombergNEF’in (2023) raporunda ise 2040 yılına kadar d nya genelindeki t m yeni ara  satı larının %60’ından fazlasının elektrikli olacağı ifade edilmektedir. Bu projeksiyonlar, ula ım sekt r n n elektrifikasyonunun yalnızca ge ici bir eęilim olmadıęını, otomotiv sekt r ndeki kalıcı bir d n   m n ba langıcı olduęunu g stermektedir.

Bununla birlikte, elektrikli araçların yaygınlaşmasında kullanıcı tercihlerinden teknolojik engellere, şarj altyapısından enerji yönetimi stratejilerine kadar birçok parametre rol oynamaktadır. Elektrikli araçların pazardaki yaygınlaşmasında teknik özellikler kadar kullanıcıların bu araçları nasıl değerlendirdiği ve tercih ettiği de büyük önem taşımaktadır. Tüketicilerin bir elektrikli aracı satın alma kararında rol oynayan birçok faktör bulunmaktadır. Bunlar arasında menzile, şarj süresi, fiyat, marka itibarı, bakım maliyetleri ve teknolojik donanım gibi kriterler yer alır (Rezvani vd., 2015). Ek olarak, elektrikli araçların kullanıcılar tarafından benimsenmesinde sadece teknolojik yeterlilikler değil, aynı zamanda sosyal etmenler de önemli rol oynamaktadır. Tüketici kararları yalnızca teknik özelliklerle sınırlı kalmamakta, çevresel kaygılar ve yenilikçilik düzeyi de karar sürecini etkilemektedir (Rezvani vd., 2015; Castillo vd., 2021). Dahası, ekonomik teşviklerin ve çevreci tutumların benimsenmede önemli ancak sınırlı etkileri olduğu; asıl belirleyici unsurun yakıt tasarrufu, araç boyutlarına bağlı olarak ortaya çıkan konfor vb. faktörler ve teknolojik yeterliliğe duyulan güven olduğu saptanmıştır. Bu nedenle elektrikli araç tercihinde kullanıcı deneyimi ve araç içi dijital donanımlar da ön plana çıkmaktadır (Lieven vd., 2011; Li vd., 2020; Castillo vd., 2021).

Elektrikli araçların değerlendirilmesinde olduğu gibi, çok sayıda kriterin birlikte değerlendirildiği karar süreçlerinde, çok kriterli karar verme (ÇKKV) yöntemleri oldukça yaygın olarak kullanılmaktadır. ÇKKV yöntemleri, karar vericilerin farklı kriterler arasındaki dengeyi değerlendirerek optimal veya sıralı seçimler yapmasına olanak sağlar (Corrente vd., 2021). ÇKKV yöntemleri genellikle seçim, sıralama ve sınıflandırma gibi karar problemlerinde kullanılır. Seçim problemleri, alternatiflerin en iyiden en kötüye doğru sıralanmasını hedeflerken, sınıflandırma problemleri ise alternatiflerin önceden tanımlı sıralı sınıflara atanmasını amaçlar (Doupouos ve Zopounidis, 2006).

Elektrikli araçların kullanıcı açısından tercih edilebilirliği genellikle çok boyutlu bir kavramdır. Sadece araç performansı değil, aynı zamanda enerji altyapısı, çevresel kaygılar ve hatta hükümet teşvikleri gibi dışsal faktörler de kullanıcı tercihlerini şekillendirebilir (Egbue ve Long, 2012). Bu nedenle, bu tür çok boyutlu karar ortamlarında klasik analiz yöntemlerinin ötesine geçilerek daha karmaşık ve veri odaklı yöntemlerin kullanılması gerekliliği ortaya çıkmaktadır. İşte bu noktada, ÇKKV yaklaşımlarının sunduğu sistematik çerçeve ile makine öğrenmesi

yöntemlerinin tahmin gücü bir araya getirilerek yeni nesil karar destek sistemleri geliştirilebilir.

Son yıllarda veri madenciliği ve makine öğrenmesi tekniklerinin ÇKKV yöntemleriyle birlikte kullanıldığı hibrit modellemelere yönelik ilgi artmıştır (Köksal vd., 2011). Özellikle karar ağacı, yapay sinir ağları (YSA), lojistik regresyon, naive Bayes ve destek vektör makineleri (DVM) gibi sınıflandırma algoritmaları; veri setlerinden öğrenerek, önceden belirlenmiş sınıflara (örneğin tercih seviyeleri veya segmentler) araçları atayabilmektedir (Kotsiantis vd., 2007). Böylelikle, hem karar vericiye öngörülse bir model sunulmakta hem de geçmiş veriler ışığında yeni yorumlamalar yapılabilmektedir.

Elektrikli araçların değerlendirilmesi ve kullanıcıya uygun alternatiflerin belirlenmesi gibi çok boyutlu karar problemlerinde hem Çok Kriterli Karar Verme (ÇKKV) yöntemleri hem de makine öğrenimi (ML) teknikleri kullanılabilmektedir. Ancak bu iki yaklaşımın da tek başına belirli sınırlılıkları bulunmaktadır. ÇKKV yöntemleri, karar verici tercihlerine dayalı olarak sistematik çözümler sunmakla birlikte, kriter ağırlıklarının belirlenmesi sürecinde öznellik içerebilir ve büyük veri setlerinde uygulaması zahmetli olabilir. Ayrıca, bu yöntemler genellikle geçmiş verilerden öğrenme yetisine sahip değildir. Öte yandan, makine öğrenmesi algoritmaları veriden öğrenme kapasitesine sahip olup büyük veri setlerinde güçlü tahmin performansı sergileyebilir; ancak yeterli sayıda etiketli veri olmadığında doğrulukları düşmekte ve karar verme sürecine dair açıklanabilirlikleri sınırlı kalmaktadır. Bu bağlamda, iki yöntemin birlikte kullanımı hem ÇKKV'nin yapısal avantajlarından hem de ML'nin tahmin gücünden faydalanarak daha güvenilir ve bütüncül bir karar destek süreci sunma potansiyeli taşımaktadır.

Bu tez çalışmasında, elektrikli araçlara ait teknik ve kullanıcıya yönelik içeriğe sahip olan verilerin analizi yapılarak, her bir aracın tercih edilebilirlik düzeyinin belirlenmesi amaçlanmıştır. Bu kapsamda öncelikle Çok Kriterli Karar Verme (ÇKKV) sınıflandırma yöntemlerinden biri olan TOPSIS-Sort-B uygulanarak araçlar üç farklı tercih sınıfına ayrılmıştır. Elde edilen bu sınıflar daha sonra makine öğrenimi sınıflandırma algoritmalarına veri etiketlemesi olarak sunulmuş ve farklı sınıflandırma yöntemlerinin doğrulukları karşılaştırılmıştır. Bu hibrit metodolojik yaklaşım sayesinde, elektrikli araç seçiminde kullanılabilecek güvenilir ve sistematik bir karar destek mekanizması ortaya konmaktadır. Çalışma, elektrikli araçların çeşitli teknik

özellikleri (batarya kapasitesi, menzil, şarj süresi vb.), fiyatı ve kullanıcı deneyimi parametrelerini (konfor vb.) bütüncül bir değerlendirme çerçevesinde ele almaktadır. Böylece iki temel soruya yanıt aranmaktadır:

1. ÇKKV yöntemiyle oluşturulan tercih sınıfları, makine öğrenimi modelleri tarafından hangi doğruluk seviyesinde öngörülebilmektedir?
2. Farklı makine öğrenimi algoritmaları arasında, ÇKKV temelli sınıflandırmaları yeniden üretme ve genelleme açısından en başarılı performansı hangi model göstermektedir?

Bu yaklaşım sayesinde hem karar destek sistemlerinin daha güçlü hale getirilmesi hem de ÇKKV yöntemlerinden elde edilen sınıfların geçerliliğinin test edilmesi mümkün olmuştur. Ayrıca, makine öğrenmesi modelleri yardımıyla bu sınıfların daha önce görülmemiş yeni araç verileri üzerinde öngörülebilirliği de sağlanmıştır. Tezin en önemli katkılarından biri, tüketicilerin karmaşık seçim süreçlerinde daha nesnel ve veri temelli kararlar alabilmelerine olanak tanınmasıdır. Elektrikli araç pazarında giderek artan model çeşitliliği, tüketicilerin optimal seçim yapabilmesini zorlaştırmakta, bu çalışma ise sistematik bir metodoloji sunarak bu zorluğu aşmaya yardımcı olmaktadır.

Araştırmanın özgünlüğü, ÇKKV'nin sıralı sınıflandırma yaklaşımını sınıflandırma problemlerine temel oluşturacak şekilde kullanması ve bu sınıfların makine öğrenimi algoritmaları ile tahmin edilmesini içeren çift yönlü bir analitik çerçeve sunmasından kaynaklanmaktadır. Bu durum literatürde oldukça sınırlı olarak ele alınan hibrit yöntem arayışlarına katkı sağlayacaktır (Zavadskas vd., 2014). Dahası, Uluslararası Enerji Ajansı'nın (UEA) 2023 yılı raporuna göre, dünya genelinde elektrikli araç satışları 2022 yılında 10 milyonu aşmış ve 2030 yılına kadar toplam araç satışlarının %60'ını oluşturacağı öngörülmektedir (UEA, 2023). Böylelikle yakın gelecekte bu denli yüksek benimsenme oranına sahip olacak bu araçlar için güçlü öngörüler oluşturulmuştur. Çalışma, elektrikli araç sektöründeki bu hızlı büyüme trendini göz önünde bulundurarak, hem akademik literatüre metodolojik bir katkı sunmakta hem de pratik uygulamada karar vericilere yol gösterici bir araç sağlamaktadır.

Tez çalışmasının akışı şu şekilde organize edilmiştir: İkinci bölümde, elektrikli araçlara ilişkin güncel literatür, kullanıcı tercihleri ve çok kriterli karar verme yaklaşımları pratikteki uygulamalarıyla beraber detaylı olarak ele alınmaktadır. Ayrıca literatürdeki makine öğrenmesi yöntemleriyle sınıflandırma bazlı çok kriterli karar

verme yöntemlerinin kombinlendiđi alıřmalar da sunulmuřtur. Üüncü bölümde ise KKV sınıflandırma ve makine öğrenmesi yöntemlerine ilişkin metodolojik altyapı sunulmakta ve araştırmanın yöntemleri anlatılmaktadır. Dördüncü bölümde veri setinin elde edilmesi, ön işleme süreçleri, öznitelik mühendisliđi ve model uygulamaları ayrıntılarıyla anlatılmakta ve sonuçlar verilmektedir. Son olarak beřinci bölümde bulgular özetlenmekte, teorik katkılar açıklanmakta, alıřma sınırlılıkları belirtilmekte ve geleceđe yönelik öneriler sunulmaktadır. Bu bölümde alıřmanın akademik literatüre ve endüstriyel uygulamalara katkıları ayrıntılı řekilde tartışılmakta, bulgulardan hareketle elektrikli araç pazarı dinamikleri ve tüketici davranışları bağlamında içgörüler sunulmaktadır.



2. LİTERATÜR ARAŞTIRMASI

Günümüzde karmaşık karar verme süreçlerinin analizinde, çok kriterli karar verme (ÇKKV) yöntemleri giderek daha yaygın bir biçimde kullanılmaktadır. Özellikle birçok alternatifi ve ölçütü barındıran problemler karşısında, karar vericilere sistematik ve nesnel destek sunma kapasitesi sayesinde bu yöntemler, akademik ve pratik alanda büyük ilgi görmektedir (Triantaphyllou ve Triantaphyllou, 2000). TOPSIS (Technique for Order Preference by Similarity to Ideal Solution) gibi sıralama temelli ÇKKV yaklaşımları, alternatiflerin ideal ve negatif-ideal çözüme göre uzaklıklarına dayalı değerlendirme yapımlarıyla öne çıkmaktadır. Son yıllarda bu yaklaşımların gelişmiş versiyonları olan TOPSIS-Sort-B gibi modeller de alternatiflerin sıralı sınıflara atanmasını mümkün kılarak çok daha stratejik karar süreçlerine olanak tanımaktadır (Zavadskas vd., 2014).

Öte yandan, makine öğrenmesi algoritmaları da sınıflandırma ve öngörü problemlerinde sağladığı yüksek doğruluk oranları sayesinde birçok disiplinde yaygın biçimde kullanılmaktadır. Özellikle denetimli öğrenme algoritmaları, etiketlenmiş verilerle çalışarak daha önce karşılaşılmamış yeni örneklerin başarılı biçimde tahmin edilmesini sağlamaktadır (Kotsiantis vd., 2007). Bu bağlamda, ÇKKV yöntemlerinden elde edilen sınıfların makine öğrenmesi algoritmalarına veri olarak sunulması, hem karar destek sistemlerinin öngörü kabiliyetini artırmakta hem de sınıfların doğrulanabilirliğini test etmeye olanak tanımaktadır.

Bu tez kapsamında önerilen hibrit yaklaşım, literatürde sınırlı sayıda çalışmada ele alınmış olan ÇKKV ve makine öğrenmesi entegrasyonuna katkı sağlamaktadır (Kumar, 2025). Bu tür metodolojik birleşimler, yalnızca teknik analiz açısından değil, aynı zamanda tüketici davranışlarının modellenmesi, pazar tahminleri ve sürdürülebilir teknoloji seçimi gibi çok boyutlu problemlerin çözümünde de etkili çözümler sunmaktadır.

2.1 Çok Kriterli Karar Verme (ÇKKV) Yaklaşımları

Modern karar verme süreçleri, çoğu zaman birden fazla alternatifi çok sayıda ve çoğu zaman çelişen kriterler temelinde değerlendirilmesini gerektirir. Bu tür durumlarda karar vericilerin sezgisel yaklaşımları yetersiz kalmakta, objektif ve yapılandırılmış yöntemlere olan ihtiyaç artmaktadır. Bu bağlamda, ÇKKV, özellikle karmaşık problemler karşısında rasyonel ve tutarlı kararlar almayı sağlayan güçlü analitik yaklaşımlar bütünü olarak tanımlanmaktadır (Belton ve Stewart, 2012). ÇKKV, karar vericilere hem nicel hem de nitel kriterler doğrultusunda alternatifleri karşılaştırma, önceliklendirme, sıralama veya sınıflandırma olanağı sunar (Toloi-Eshlaghy ve Homayonfar, 2011; Zavadskas vd., 2013; Mardani vd., 2015; Alvarez vd., 2021; Lopez vd., 2023; Taherdoost ve Madanchian, 2023; Kumar, 2025).

Son yıllarda bu yöntemlerin popülaritesi, hem karar süreçlerinin şeffaflığını artırması hem de nesnel temellere dayanan analizler sunması nedeniyle daha da artmıştır. Ayrıca gelişen bilgi teknolojileri sayesinde ÇKKV modelleri, büyük veri kümeleriyle entegre çalışabilmekte ve çok daha dinamik sistemler içerisinde uygulanabilir hâle gelmiştir (Zavadskas vd., 2014).

ÇKKV yöntemlerinin temel işleyişi, bir karar matrisinin oluşturulması ve bu matristeki her alternatifi her bir kritere göre değerlendirilmesi esasına dayanır. Öncelikle kriterlerin göreceli önemleri, yani ağırlıkları belirlenmekte ve alternatifler bu ağırlıklar doğrultusunda analiz edilmektedir. Değerlendirme sonucunda, alternatiflerin sıralanması, en uygun seçeneğin belirlenmesi veya belirli sınıflara atanması gibi çıktılar elde edilmektedir. Bu çerçevede, sıralama (ranking) ve sıralı sınıflandırma (sorting), ÇKKV en temel iki uygulama biçimidir. Sıralama işlemleri alternatifleri bir performans düzeyine göre en iyi–en kötü ekseninde yerleştirirken, sıralı sınıflandırma işlemleri ise bu alternatifleri önceden tanımlanmış tercihler düzeyine göre sınıflara ayırır.

Literatürde sıralama tabanlı yöntemlerin daha sık kullanıldığı gözlemlense de, son yıllarda ÇKKV'nin sınıflandırma temelli uzantılarına olan ilgi artmaktadır. Zira birçok uygulama alanında, karar vericiler yalnızca en iyi alternatifi değil, belirli bir kategoriye ait olanları (örneğin “yüksek tercih edilen”, “orta”, “düşük” gibi sınıflar) belirlemeye ihtiyaç duymaktadır. Bu doğrultuda geliştirilen sınıflandırma odaklı ÇKKV yöntemleri, karar destek sistemlerinin sınıflandırıcı yapılarla entegrasyonuna olanak

sağlamış ve bu yöntemlerin makine öğrenmesi gibi alanlarla kesişmesini kolaylaştırmıştır (Doumpos ve Zopounidis, 2006).

Sonuç olarak, ÇKKV yalnızca teknik bir çözüm aracı değil; aynı zamanda karar alma süreçlerini daha anlaşılır, sistematik ve izlenebilir hâle getiren stratejik bir metodoloji sunmaktadır. Bu bağlamda bir sonraki bölümde, ÇKKV'nin özellikle sınıflandırma odaklı yaklaşımlarına daha yakından bakılacaktır.

2.1.1 Sınıflandırma tabanlı ÇKKV yöntemleri

Çok Kriterli Karar Verme (ÇKKV) yöntemleri, özellikle sınıflandırma odaklı modeller, karar alternatiflerini önceden tanımlanmış sıralı sınıflara ayırmak için güçlü araçlardır. Bu yaklaşımlar; bireysel karar vericilerden kurumsal sistemlere kadar pek çok düzeyde, karmaşık karar problemlerinin çözümünde uygulanmaktadır. Sınıflandırma tabanlı ÇKKV tekniklerinin temel amacı, alternatifleri sadece sıralamak değil, aynı zamanda belirli karar sınıflarına uygun biçimde atamaktır. Bu bağlamda geliştirilen yöntemler, çeşitli alanlarda çözüm sağlamış ve literatürde ulaşımdan eğitime, tedarik zinciri yönetiminden sağlık hizmetlerine, finansal yönetimden risk yönetimine kadar geniş uygulama alanları bulmuştur. AHPSort, DEASort, ELECTRE Tri, UTADIS, FlowSort, VIKORSORT, ANP-Sort bu alanda en sık karşılaşılan yöntemlerdendir ve bu yöntemler kullanılarak yapılan çalışmalar hem model yapılarını hem de karar verme sürecindeki etkililiklerini ortaya koymaktadır (Alvarez vd., 2021; Lopez vd., 2023). Aşağıda, literatürde yer alan güncel sıralı sınıflandırma çalışmaları özetlenmiştir.

Dias ve Mousseau (2003), ulaşım sektörü bağlamında geliştirdikleri çalışmada, çok kriterli karar verme problemleri için Iris adlı yenilikçi bir sınıflandırma yöntemi önermiştir. ELECTRE Tri'ye dayanan bu yaklaşım, karar vericiden tüm parametreleri kesin biçimde belirtmesini beklemek yerine, sınıflama örnekleri ve bazı mantıksal kısıtlar üzerinden karar sürecini desteklemektedir. Yazarlar, bu yöntem ile tutarlı durumlarda karar vericinin verdiği örnekleri tamamen açıklayan çözümler üretmeyi; tutarsızlık durumlarında ise en az sapmayla alternatif öneriler sunmayı amaçlamışlardır. Bu yaklaşımın bir uygulaması da veri merkezi yeri seçiminde gerçekleştirilmiştir (Covas vd., 2013). Covas vd. (2013), teknik, sosyal, ekonomik ve çevresel boyutları içeren sürdürülebilirlik kriterleri doğrultusunda en uygun yerleşim bölgelerini, çok kriterli sınıflandırma problemi olarak ele almışlardır ve IRIS yazılımı

aracılığıyla ELECTRE Tri yöntemiyle analiz etmişlerdir. Kriter ağırlıklarına ilişkin belirsizliklerin de dikkate alındığı bu çalışmada, kararlar tek bir değere indirgenmeden grafiksel olarak sunulmuştur. Bu sayede IRIS'in farklı karar alanlarında belirsizlik altında da etkili ve esnek çözümler sunabildiği gösterilmiştir.

ELECTRE Tri yönteminin kullanıldığı bir başka çalışma ise insan kaynakları alanındaki iş birliği davranışlarını sürekli iş birliği düzeylerine çeviren ve bu düzeyleri önceden tanımlanmış kategorilere (düşük, orta, yüksek) sınıflayan bulanık çok kriterli bir karar yöntemi sunmaktadır (Silva vd., 2014). Bu yöntem, klasik ayrık oyun teorisini sürekli iş birliği düzeylerine dönüştürmek yerine, gerçek hayattaki iş birliği davranışlarını çok kriterli bir yapı içinde değerlendirerek sınıflamayı hedeflemektedir. Benzer şekilde ELECTRE Tri ile, Silva ve Sobral (2017) ise Brezilya'nın kurak bir bölgesinde süt tedarikçilerinin çok kriterli değerlendirmesini yaparak, sekiz tedarikçiyi üretim kapasitesi, ürün kalitesi, maliyet, ulaşım ve tesis uzaklığı gibi ölçütlere göre üç kategoriye ayırmıştır. Yazarlar bu yaklaşımlarıyla, karar vericilere çoklu ölçütleri aynı anda dikkate alarak daha bütüncül bir değerlendirme yapma olanağı sunmayı hedeflemiştir. Bu çalışmalara paralel olarak, Silva ve Costa (2014) da bilgi teknolojileri projelerinin değerlendirilmesine yönelik çok kriterli bir yaklaşım geliştirmiştir. Çalışmada, IT yatırımlarının sınıflandırılması ve önceliklendirilmesi için karar öncesi aşamada uygulanabilecek sistematik bir çerçeve sunulmuş; hem somut hem de soyut faydaların dikkate alındığı, sübjektifliğin azaltılmasını amaçlayan bir model önerilmiştir. Model, farklı IT projelerinin çeşitli özelliklerini göz önünde bulundurarak karar vericilere daha yapılandırılmış ve dengeli bir değerlendirme süreci sağlamayı amaçlamaktadır. Ayrıca, Madhooshiarzanagh ve Abi-Zeid (2021) tarafından gerçekleştirilen çalışmada, ELECTRE Tri ailesinin bir uzantısı olan ELECTRE Tri-nC yöntemi kullanılarak çevresel koşullara göre turistik bölgelerin dört kategoriye ayrılması hedeflenmiştir. Bu çalışmada, karar vericiden sınırlı bilgi alınarak tercihlerin dolaylı şekilde öğrenilmesini sağlayan bir ayrıştırma yaklaşımı oluşturulmuştur. Sonucunda 62.482 lokasyonun iklim temelli bir sınıflandırmaya tabi tutulduğu geniş ölçekli bir uygulama gerçekleştirilmiştir.

Ishizaka vd. (2012) özellikle çok sayıda alternatifin önceden tanımlanmış kategorilere yerleştirilmesi gereken durumlarda, karar vericilere sistematik ve esnek araçlar sunulmasının önemli bir husus olduğunu vurgulamıştır. Yazarlar, geleneksel AHP'nin sınıflandırma problemleri için uygun olmadığını belirterek bu eksikliği gidermek

amacıyla AHPSort yöntemini geliştirmiştir. Bu yöntem, tedarikçi seçiminde kullanılan bir vaka çalışmasında test edilerek, alternatiflerin "kabul" ve "ret" sınıflarına ayrılmasını sağlamış ve ardından nihai seçim klasik AHP ile yapılmıştır. Benzer şekilde, Miccoli ve Ishizaka (2017) çevresel bağlamda AHPSort II yöntemini geliştirerek, İtalya'nın Umbria bölgesindeki koyun çiftliklerinde kurt saldırısı risklerini sınıflandırmışlardır. Bu yöntemin özellikle büyük alternatif kümeleri için uygunluğu vurgulanmış ve geleneksel AHPSort'a göre çok daha az karşılaştırma gerektirdiği gösterilmiştir. Yazarlar, sınıflandırmanın hassasiyetini artırmak için kümeleme tekniklerini de entegre ederek yalnızca %0.54 oranında karşılaştırma ile güvenilir sonuçlar elde etmişlerdir. Öte yandan, Ishizaka vd. (2020), klasik AHPSort'un keskin sınırlarla sınıf ataması yapmasının, özellikle sınır durumlarındaki alternatiflerde yanıltıcı olabileceğini belirtmiş ve bu nedenle bulanık kümeler kuramını entegre ederek daha esnek bir sınıflama modeli önermiştir. Bu modelin, Londra ilçelerinin güvenlik düzeylerine göre sınıflandırılmasında kullanılması, yönteminin pratik geçerliliğini ortaya koymuştur. Dahası, Ishizaka ve Pereira (2020), gerçek dünyadaki ölçütlerin çoğu zaman birbiriyle bağımlı olduğu gerçeğinden hareketle ANPSort yöntemini tanıtmışlardır. Yükseköğretim alanındaki bir araştırmacı sınıflandırma vakasıyla sunulan bu yaklaşım, ölçütler arası bağımlılıkları dikkate alarak daha bütüncül ve yapısal bir karar süreci sağlamış; aynı zamanda çok sayıda alternatifin değerlendirildiği durumlarda karşılaştırma yükünü önemli ölçüde azaltmıştır.

FlowSort, PROMETHEE sıralama metodolojisine dayalı olarak geliştirilen yenilikçi bir sınıflandırma yaklaşımıdır. Nemery ve Lamboray (2008), bu yöntemi hem sınırlayıcı hem de merkezi profillerle tamamen sıralı kategorilere atama yapmak amacıyla önermiştir. Alternatiflerin, referans profillere göre gelen, giden ve net akış değerleri bağlamında göreceli konumları dikkate alınarak yapılan atamalara yönelik güçlü tercih koşulu tanımlanmış ve ELECTRE Tri ile karşılaştırmalı analizler gerçekleştirilmiştir. Bu temel üzerine inşa edilen bir diğer çalışmada, FlowSort yöntemine görselleştirme teknikleri entegre ederek yöntemin yorumlanabilirliğinin artırılması amaçlanmıştır (Nemery vd., 2012).

FlowSort'un sektörel uygulamalarda da etkili biçimde kullanıldığı örneklerden biri Sepulveda ve Derpich (2015) tarafından gerçekleştirilmiştir. Bu çalışmada, Şili'deki bir gazlı içecek üretim tesisinde tedarikçilerin sınıflandırılması amacıyla Electre ve

FlowSort yöntemleri karşılaştırılmış; özellikle bulanık çok kriterli yapıya sahip durumlarda FlowSort'un kural tabanlı sistemler kurmaya daha uygun olduğu belirtilmiştir. Sepulveda vd. (2010) ise yenilik kapasitesini değerlendirmek amacıyla merkezi profillerle çalışan bir FlowSort varyantı kullanarak KOBİ'lerin sınıflandırılmasını ve ardından kişiselleştirilmiş önerilerin geliştirilmesini mümkün kılmıştır. Benzer şekilde, tedarikçi sınıflandırması konusunda Sagura vd. (2020), taze meyve tedarik zincirinde sürdürülebilirlik odaklı kriterlerle geliştirdikleri iki aşamalı modelde MAUT ve PROMETHEE yöntemlerini harmanlayarak FlowSort benzeri bir sınıflandırma yapısını benimsemiştir. Bu model, stratejik kriterler doğrultusunda tedarikçilerin hem sıralanmasını hem de kategorilere ayrılmasını sağlamış ve karar destek sistemlerine temel teşkil edecek şekilde tasarlanmıştır. Öte yandan, Campos vd. (2015) ise FlowSort yöntemini bulanık mantıkla bütünleştirerek Fuzzy FlowSort yöntemini önermiştir. Bu çalışma, kesin olmayan verilerle başa çıkmak için geliştirilen yaklaşımın, hem klasik FlowSort hem de Fuzzy-PROMETHEE yöntemleriyle olan ilişkisinin analiz edilmesiyle, bulanık ortamda sınıflandırma problemlerine güçlü bir çözüm sunduğunu ortaya koymuştur.

Zopounidis ve Doumpos (2000), PREFDIS adlı çok kriterli karar destek sistemini tanıtarak, özellikle sınıflama problemlerinde karar vericilerin tercihlerini ayrıştırmaya dayalı yaklaşımlarla modelleyebilmelerine olanak tanımıştır. Sistem, UTADIS ve üç varyantı (I, II, III) ile alternatiflerin belirli kategorilere atanmasını sağlayan güçlü eklemeli fayda modelleri sunmakta ve karar vericinin tercihlerini modelleme konusunda esneklik sağlamaktadır. Aynı yazarlar daha sonraki çalışmalarında (Doumpos ve Zopounidis, 2004), UTADIS yöntemi üzerine gerçekleştirdikleri Monte Carlo simülasyonlarıyla, modelleme sürecinde kullanılan parametrelerin sınıflandırma performansı ve model istikrarı üzerindeki etkilerini detaylı biçimde analiz etmişlerdir. Bu analiz, tercih ayrıştırma tekniklerinin güvenilirliği açısından önemli bulgular sunmaktadır.

Öte yandan Ulucan ve Atıcı (2013), UTADIS yöntemine çoklu sınıflama kriterleri ekleyerek MCC-UTADIS yaklaşımını geliştirmiştir. Özellikle ülke risk değerlendirmesi örneğiyle, farklı kredi derecelendirme kuruluşlarının sınıflama kriterlerini eş zamanlı kullanarak yöntemin performansını test etmişlerdir. Sonuçlar, MCC-UTADIS özellikle sınıflama kriterlerinin çeşitliliği durumunda daha tutarlı sonuçlar verdiğini ortaya koymuştur. Köksalan vd. (2013) ise, sınıflara atanacak

alternatif sayısında kısıtların bulunduğu karar problemlerine odaklanarak, UTADIS yöntemini bu tür kısıtlamaları göz önünde bulunduracak şekilde yeniden formüle etmiştir. Geliştirilen model, ikili değişkenlerin sayısını azaltarak işlem yükünü hafifletmiş, ayrıca her alternatifin atanabileceği kategori aralığını daraltarak hesaplama verimliliğini artırmıştır. Ayrıca, Greco vd. (2011), UTADIS-GMS yöntemine dayanarak kararlı sınıflandırma anlayışını güçlendiren temsili değer fonksiyonu kavramını ortaya koymuşlardır. Bu fonksiyon, karar vericinin örnek atamalarıyla tutarlı olan tüm değer fonksiyonları arasında seçilmekte ve özellikle kararlı sınıflama bölgelerini vurgulamaktadır. Böylece karar destek sistemlerinde hem karar vericiye sonuçları daha şeffaf sunmakta hem de özerk sınıflama süreçleri için kullanılabilir.

Ishizaka vd. (2018), envanter yönetiminde benzer ürünlerin sınıflandırılması için geliştirdikleri DEASort yöntemini tanıtmaktadır. Geleneksel DEA modellerinin yalnızca sıralama yapması ve sınıfların yüzdeliklerle rassal tanımlanması gibi sınırlılıklarını aşmayı hedefleyen bu yöntem, karar vericilerin uzmanlığını da sürece entegre etmektedir. Karar vericiler öncelikle her sınıfa ait tipik örnekleri belirleyip AHP yöntemiyle kriter ağırlıklarını sunmuştur. Bu sayede, bu bilgiler modelde ağırlık kısıtı olarak yer almakta ve daha gerçekçi sınıflandırmalar elde edilmektedir. Yöntem, yedek parça stoklayan bir depo yönetim sürecinde uygulanarak somutlaştırılmıştır. Karasakal ve Aker (2017) ise Ar-Ge projelerinin değerlendirilmesi için veri zarflama analizi tabanlı çok kriterli sınıflandırma modelleri geliştirmiştir. Kriterlerin ağırlık aralıkları, aralıklı AHP yöntemiyle belirlenmiş ve modellerde güven bölgesi kısıtı olarak kullanılmıştır. İki eşik tahmin modeli ve beş atama modelinden oluşan yaklaşım, yalnızca sıralama değil aynı zamanda sınıflandırma da sağlamaktadır. UTADIS ile yapılan karşılaştırmalı analizde, önerilen modellerin daha kararlı sonuçlar verdiği görülmüştür.

Öte yandan Demir vd. (2018), çevresel performansa dayalı tedarikçi değerlendirme sürecine yenilikçi bir katkı sunarak, VIKOR tabanlı bir sınıflandırma yöntemi olan VIKORSORT'u geliştirmiştir. Yöntem, tedarikçileri çevresel kriterlere göre önceden tanımlı sıralı sınıflara ayırmakta ve her sınıfa uygun yeşil tedarikçi geliştirme programı önerilebilecek şekilde uzman sistemlerle bütünleştirilebilmektedir. Bu doğrultuda, sınıflandırma esnekliğini artırmak ve karar verme etkinliğini geliştirmek amacıyla, VIKORSORT yöntemine bulanık küme teorisini entegre eden yeni bir yaklaşım

geliştirilmiştir (Khan vd., 2025). Bu çalışmada, VIKORSORT yönteminde kullanılan keskin sınıf sınırlarının karar kalitesini olumsuz etkileyebileceği belirtilmiş ve bu sınırlılığın giderilmesi amacıyla bulanık küme teorisi yönteme entegre edilmiştir. Geliştirilen yaklaşımda, her alternatifin belirli sınıflara ait olma derecesi trapezoidal üyelik fonksiyonlarıyla ifade edilmektedir ve böylelikle sınıflar arasında daha yumuşak geçişler sağlanmaktadır. Ayrıca, alternatiflerin özellikleri daha nüanslı biçimde temsil edilebilmektedir. Tekstil sektöründeki yedek parça envanter yönetimine yönelik yapılan uygulamada, klasik ve bulanık modeller karşılaştırılmış; bulanık yaklaşımın hem maliyet hem de hizmet düzeyi açısından daha başarılı sonuçlar ürettiği gösterilmiştir.

2.1.2 TOPSIS-Sort

TOPSIS-Sort'un sıralı sınıflandırma modelleri arasında öne çıkmasının temel nedeni hem ideal hem de anti-ideal çözümlere göre yönelimi ve uzaklığı aynı anda dikkate alarak karar alternatiflerini sınıflandırmasıdır. Bu özellik, onu yalnızca sıralama değil, aynı zamanda sınıflandırma temelli karar problemlerinde de güçlü kılmaktadır (Behzadian vd., 2012). Ayrıca, TOPSIS'in farklı yöntemlerle birlikte kullanılması ya da karşılaştırılması, bu yöntemin hem bağımsız hem de hibrit yaklaşımlara uygun olduğunu ortaya koymaktadır. Bu çeşitlilik, özellikle gerçek hayat karar problemlerine yönelik geliştirilen sınıflandırma temelli modellerin, örneğin TOPSIS-Sort ve onun daha hassas versiyonu olan TOPSIS-Sort-B'nin, neden ortaya çıktığının ve hangi metodolojik boşluklara yanıt verdiğinin daha iyi anlaşılmasına olanak sağlamaktadır.

Faraji Sabokbar vd. (2016), klasik TOPSIS yöntemini esas alarak geliştirdikleri TOPSIS-Sort yaklaşımıyla çevresel sürdürülebilirliğe odaklanan sınıflandırma temelli bir karar modelini ortaya koymuşlardır. Bu modelde, sınıf tanımları için karakteristik profiller kullanılırken, tercihler üstünlük sağlamaya yönelik ilişkiler bağlamında modellenmiştir. Araştırmada, Tahran'ın 22 bölgesi çevresel kalite düzeylerine göre beş sınıfa ayrılmış; ancak dördüncü ve beşinci sınıflarda hiçbir bölge yer almamıştır. Bu durum, Tahran'daki çevresel durumun genel olarak düşük seviyede olduğunu ortaya koymuştur. Elde edilen sonuçların hem araştırmacıların hem de uzmanların değerlendirmeleriyle tutarlılık göstermesi, TOPSIS-Sort'un sıralı sınıflandırma problemlerinde ne denli geçerli ve güvenilir bir yöntem olduğunu göstermektedir. Yazarlar, bu modelin yalnızca TOPSIS'e özgü kalmayıp ELECTRE ve PROMETHEE

gibi diğer üstünlük esaslı (outranking) yöntemlere de entegre edilebileceğini vurgulamaktadır. Daha güncel bir çalışmada, de Lima Silva ve de Almeida Filho (2020) TOPSIS yönteminin sıralama bazlı sınıflandırmalarda karşılaştığı sıra değiştirme (rank reversal) problemini ele alarak TOPSIS-Sort-B ve TOPSIS-Sort-C adını verdikleri iki yeni versiyonu önermişlerdir. Bu yeni modellerden TOPSIS-Sort-B sınır profillerine dayalı sorunlara yönelik geliştirilmişken, TOPSIS-Sort-C karakteristik profillerin daha uygun olduğu durumlar için tasarlanmıştır. Her iki yöntem de ekonomik özgürlük düzeylerine göre 180 ülkenin beş önceden tanımlanmış sınıfa atanmasında kullanılmıştır. Sınıflandırma sonuçlarının, literatürdeki derecelendirmelerle ve ilgili uzman kuruluşun verileriyle tutarlılık göstermesi, önerilen yöntemlerin geçerliliğini ve pratikteki uygulanabilirliğini ortaya koymuştur.

de Lima Silva vd. (2020), TOPSIS-Sort yöntemine yönelik önemli bir iyileştirme sunarak PDTOPSIS-Sort adlı yeni bir yaklaşım geliştirmiştir. Bu yöntem, karar vericinin sınıf sınırları ve kriter ağırlıkları gibi birçok parametreyi doğrudan belirtmesini zorunlu kılan klasik TOPSIS-Sort'un aksine, yalnızca bütüncül karar örneklerine dayanarak çalışmaktadır. Yazarlar, doğrusal olmayan programlama aracılığıyla parametreleri çıkaran bu yöntemin, özellikle karar vericiler üzerindeki bilişsel yükü azaltmak açısından literatüre anlamlı bir katkı sunduğunu belirtmiştir. Finansal alanda yapılan uygulamada, Brezilya'da ihraç edilen 50 kurumsal tahvil analiz edilerek sınıflandırılmış; sonuçlar, yatırım bankacılığı uzmanının önceden tanımlı tercihleriyle yüksek düzeyde örtüşmüştür. Bu da yöntemin pratikte güvenilir biçimde çalıştığını ortaya koymaktadır. Aynı araştırma grubu tarafından sürdürülen bir başka çalışmada ise (de Lima Silva vd., 2023), bu kez PDTOPSIS-Sort-C adlı yeni bir yöntem önerilmiştir. Bu yöntem, karar örnekleri üzerinden öğrenilen tercihlerle karakteristik profillerin ve kriter ağırlıklarının matematiksel programlama aracılığıyla türetildiği bir süreci benimsemektedir. Böylece, daha önce önerilen TOPSIS-Sort-C yönteminde karar vericiden beklenen yüksek bilişsel çaba azaltılmıştır. Ayrıca, PDTOPSIS-Sort'un sınır profiline dayalı yapısını TOPSIS-Sort-B ile bütünleştirerek daha esnek bir sınıflama altyapısı sunulmuştur. Yöntem, dört yıl boyunca 180 ülkenin ekonomik özgürlük düzeyine göre sınıflandırıldığı bir uygulamada test edilmiş ve simüle edilmiş karar örnekleriyle anlamlı ve tutarlı sonuçlar üretmiştir.

Zhang ve Li (2023), çok uzmanlı karar ortamlarında ortaya çıkan sıralama problemleri için, fikir birliğine dayalı iki farklı TOPSIS-Sort-B algoritması geliştirmiştir. Tek bir

uzmanın sınırlı bilgi ve deneyimiyle karar vermenin yeterli olmadığı durumlarda, grup temelli çok kriterli sıralama problemleri öne çıkmaktadır. Bu bağlamda, yazarlar her bir uzmanın belirlediği sınır profillerini dikkate alarak fikir birliğine dayalı profillerin elde edilmesini sağlayan en küçük düzeltme temelli bir optimizasyon modeli önermiştir. Bu model aracılığıyla hem bireysel hem de toplu karar matrisleri oluşturulmuş ve sıralama sonuçları elde edilmiştir. Ayrıca, uzmanların değerlendirmelerini yeniden gözden geçirmesine olanak tanıyan farklı geri bildirim stratejileri tasarlanmış ve önerilen algoritmalar, yeşil bina derecelendirme örneğiyle birlikte çeşitli simülasyon senaryolarında test edilmiştir. Diğer yandan Hajek vd. (2024), kredi notu tahminine yönelik belirsizliklerle başa çıkabilen, veri odaklı bir ÇKKV sınıflandırma yaklaşımı geliştirmiştir. Yöntem, kriterler arası etkileşimleri modellemek için bulanık bilişsel haritalardan yararlanmakta ve bulanık TOPSIS-Sort-C ile bulanık en-önemli ve en-önemsiz yöntemlerini birleştirmektedir. Kredi riskine etki eden kriterlerin seçimi için korelasyon tabanlı özellik seçimi ve bulanık c-means algoritmaları kullanılmıştır. ABD’de faaliyet gösteren 1138 şirket üzerinde gerçekleştirilen ampirik analiz, modelin hem finansal hem de finansal olmayan göstergeleri başarıyla işleyebildiğini ve mevcut modellere kıyasla yüksek bir tahmin doğruluğuna sahip olduğunu ortaya koymuştur. Bu çalışma, özellikle belirsizliklerin yoğun olduğu kredi derecelendirme gibi finansal uygulamalarda, ÇKKV tabanlı sınıflandırma modellerinin güçlü bir alternatif sunabileceğini göstermektedir.

2.2 Elektrikli Araçlara İlişkin Karar Verme Uygulamaları

Elektrikli araçlara yönelik karar verme süreçlerini inceleyen çeşitli çalışmalar literatürde yer almaktadır. Ancak bu çalışmaların büyük çoğunluğu, çok kriterli karar verme yöntemlerini sıralama veya seçim problemlerinde kullanmış; doğrudan sınıflandırma veya kategorik sıralama temelli yaklaşımlara yer vermemiştir. Buna rağmen, ÇKKV tekniklerinin uygulandığı bu çalışmalar, mevcut araştırmaya yöntemsel açıdan önemli bir zemin sunmaktadır.

Elektrikli araçlarla ilgili teknolojik gelişmeler yalnızca mühendislik alanında değil, karar destek sistemleri kapsamında da önemli uygulamalara yol açmaktadır. Aghabali vd. (2020), geleneksel 400-V bataryaların şarj akımı taşıma kapasitesi nedeniyle ultra hızlı şarjın sınırlı kaldığını belirtmiş ve 800-V mimariye sahip bataryalı elektrikli araçların (BEV) bu sorunu çözebilecek potansiyele sahip olduğunu ortaya koymuştur.

Bu sayede yazarlar elektrikli araçların benimsenmesi ve tercihi noktasındaki en önemli problemlerden birisi olan batarya problemine parmak basmışlardır. Benzer biçimde, İnci vd. (2021), yakıt hücreli elektrikli araçlar üzerine odaklanarak bu teknolojilerin sessiz çalışma, yüksek verimlilik ve modüler yapı gibi avantajlarına dikkat çekmiş; bu araçların konfigürasyonları, güç dönüştürücüleri, kontrol sistemleri ve pazarlama perspektifinden incelenmesini sağlamıştır. Özellikle, dönüştürücü sistemler ve kontrol mekanizmalarına yönelik teknik zorluklar detaylandırılmış ve pazardaki gelişim beklentileri kapsamlı bir şekilde analiz edilmiştir. Çalışma, mühendislik ve yönetimsel karar alma süreçlerini bütünsel bir çerçevede ele alan nadir örneklerdendir.

Öte yandan, Higuera-Castillo vd. (2021) daha çok kullanıcı davranışına odaklanarak, İspanya'daki 404 potansiyel tüketiciyle gerçekleştirdikleri çalışmada menzil, teşvikler ve güvenilirlik gibi değişkenlerin elektrikli araç satın alma niyetinin güçlü göstergeleri olduğunu saptamışlardır. Bu bulgular hem kamu kurumları hem de özel sektör için stratejik kararların alınmasında yol gösterici niteliktedir. Ayrıca uzman panelleri ile yapılan karşılaştırmalar, belirli değişkenlerin sınırlı sayıdaki güçlü göstergelerle satın alma niyetini anlamada yeterli olabileceğini desteklemiştir.

Elektrikli araçların yaygınlaştırılması sürecinde karar verme mekanizmalarının etkinliği hem tüketici tercihlerini hem de kamu politikalarını doğrudan etkilemektedir. Bu kapsamda Sonar ve Kulkarni (2021), çok kriterli karar verme bağlamında AHP-MABAC bütünleşik yöntemini kullanarak, farklı elektrikli araç alternatifleri arasından en uygun olanın seçimine yönelik bir model geliştirmiştir. AHP kriter ağırlıklarını belirlerken, MABAC yöntemi bu ağırlıklarla alternatiflerin sıralanmasını sağlamıştır. Çalışma hem metodolojik açıdan yenilik sunmakta hem de pratikte kullanıcı tercihlerini dikkate alan sağlam bir değerlendirme çerçevesi önermektedir. Öte yandan, Li vd. (2020) ise Çin'de gerçekleştirdikleri tercih deneyimi temelli bir saha araştırmasıyla, tüketicilerin elektrikli araç tercihlerini şekillendiren hem ürün özelliklerine hem de politika teşviklerine odaklanmıştır. Araştırmada, menzil ve maliyet gibi bilinen kriterlere ek olarak, batarya garantisi gibi daha az incelenmiş unsurların da önemli rol oynadığı ortaya konmuştur. Ayrıca, geleneksel sübvansiyonların yerini alabilecek kişisel karbon ticareti ve sürüş kredisi gibi piyasa temelli teşviklerin, özellikle genç kullanıcılar üzerinde olumlu etkiler yaratabileceği vurgulanmıştır. Bu bulgular, teşvik politikalarının yeniden tasarımı açısından

önemlidir. Ziemba (2020) ise, Polonya'daki kamu kurumları için sürdürülebilirlik temelli bir elektrikli araç seçim süreci geliştirmiştir. PROSA-C yöntemiyle teknik, ekonomik ve çevresel kriterleri dikkate alarak alternatifleri değerlendiren çalışmada, Monte Carlo simülasyonu da belirsizliklerin modellenmesi için kullanılmıştır. Bu sayede karar vericilere hem sağlam hem de sürdürülebilir çözümler sunulmuştur.

Ecer (2021), elektrikli araçların çevresel sürdürülebilirlik açısından taşıdığı önemi vurgulayarak, bataryalı elektrikli araç alternatiflerinin teknik özelliklerine göre müşteri bakış açısıyla değerlendirilmesi gerektiğini savunur. Çalışmasında, hızlanma, menzil, batarya kapasitesi ve fiyat gibi birçok kriter doğrultusunda on farklı BEV'i SECA, MARCOS, MAIRCA, COCOSO, ARAS ve COPRAS gibi çok kriterli karar verme teknikleriyle sıralamış, ardından elde edilen sonuçları Borda count ve Copeland yöntemleriyle birleştirerek nihai bir tercih sıralaması sunmuştur. Bu yaklaşım, özellikle fiyat, izin verilen yük miktarı ve enerji tüketiminin karar vericiler için öncelikli kriterler olduğunu göstermiştir. Tesla Model S'in en uygun seçenek olarak öne çıkması, bu tekniklerin karar sürecine nasıl sistematik katkı sağladığını da gözler önüne sermiştir. Pamucar vd. (2021) de alternatif yakıtlı araçların çevresel etkilerini değerlendirerek daha sürdürülebilir ulaşım sistemlerine katkı sunmayı amaçlamışlardır. ABD'nin New Jersey eyaletinde gerçekleştirilen çalışmada, belirsizliğin yoğun olduğu karar ortamlarını modellemek amacıyla bulanık FUCOM ve neutrosophic MARCOS yöntemlerini bir arada kullanmışlardır. Bu entegre yöntemle yapılan analiz sonucunda, satın alma maliyeti, enerji maliyeti ve toplumsal faydanın en belirleyici kriterler olduğu tespit edilmiştir. Elektrikli araçlar, bu değerlendirme çerçevesinde en çevreci alternatif olarak öne çıkarken, geliştirilen metodolojinin klasik yöntemlere kıyasla daha üstün sonuçlar sunduğu da karşılaştırmalı analizle ortaya konmuştur. Her iki çalışma da teknik, ekonomik ve sosyal faktörleri bütüncül biçimde ele alan ÇKKV tabanlı değerlendirmelerin, ulaşımda daha bilinçli ve sürdürülebilir tercihlere kapı aralayabileceğini göstermektedir.

Bütün bu çalışmalar değerlendirildiğinde, elektrikli araçlara yönelik karar verme süreçlerinde ÇKKV yöntemlerinin sıklıkla kullanıldığı; ancak bu uygulamaların büyük ölçüde sıralama veya seçim problemleriyle sınırlı kaldığı görülmektedir. ÇKKV ile ML tekniklerinin entegre biçimde kullanıldığı, yani ÇKKV yöntemleriyle oluşturulan karar sınıflarının ML algoritmalarıyla tahmin edildiği çalışmalara

literatürde rastlanmamaktadır. Dolayısıyla bu tez çalışması, hem ÇKKV temelli sınıflandırma yaklaşımını hem de bu sınıfların makine öğrenmesiyle tahmin edilmesini bir araya getirerek alanyazındaki önemli bir boşluğu doldurmayı hedeflemektedir.

2.3 Makina Öğrenmesi ile Sınıflandırma

Makine öğrenmesi, günümüzde birçok sektörde karar destek sistemlerinin temelini oluşturmakta ve karmaşık veri kümeleri üzerinde yüksek doğrulukla tahminler yapılmasına olanak tanımaktadır. Özellikle sınıflandırma algoritmaları, veri analizi süreçlerinin vazgeçilmez bir parçası hâline gelmiştir. Bu bölümde, başta otomotiv -ve özellikle elektrikli araçlar- olmak üzere çeşitli uygulama alanlarında naive bayes, lojistik regresyon, yapay sinir ağları (YSA), destek vektör makineleri (DVM), karar ağaçları ve k-en yakın komşu gibi yaygın sınıflandırma algoritmalarının kullanıldığı öne çıkan çalışmalara yer verilmiştir.

Makine öğrenmesi tekniklerinin otomobil endüstrisine yönelik üretim süreçlerinde kalite kontrol ve süreç optimizasyonunu iyileştirme potansiyeli son yıllarda dikkat çekici biçimde artmıştır (Wuest vd., 2016). Bu bağlamda, özellikle yüksek boyutlu ve çok değişkenli verileri işleyebilme yetenekleri ile gizli ilişkileri keşfedebilme kabiliyetleri, makina öğrenmesi algoritmalarını ön plana çıkarmaktadır (Köksal vd., 2011). Otomobil üretim alanında süreç optimizasyonu (Kwak ve Kim, 2012), arıza tespiti (Kim vd., 2012) ve kestirimci bakım (Susto vd., 2014) gibi pek çok problem için MÖ tabanlı yaklaşımlar başarıyla kullanılmıştır. Lojistik regresyon gibi doğrusal yöntemler temel ilişkileri ortaya çıkarmada etkili olsa da, daha karmaşık ikinci veya üçüncü dereceden etkileşimleri saptamada yetersiz kalabilmektedir (Hebert, 2016). Bu nedenle, karar ağaçları gibi doğrusal olmayan yöntemler daha güçlü alternatifler olarak öne çıkar.

Yapay sinir ağları, destek vektör makineleri, karar ağaçları, naive bayes ve k-en yakın komşu gibi makine öğrenimi teknikleri, elektrikli araçlar özelinde yapılan çok sayıda çalışmada yaygın biçimde kullanılmıştır. Örneğin Zahid vd. (2018), batarya sağlığı ve şarj durumu tahmininde YSA modellerini kullanarak yüksek doğruluk oranları ulaşırken; Sheng ve Xiao (2015) aynı problem için DVM kullanarak oldukça yüksek doğruluk seviyelerine ulaşmıştır. Benzer şekilde Yavasoglu vd. (2019), aracın menzil tahmini için 60 nöronlu gizli katmana sahip bir YSA ile karar ağacı modelini birlikte kullanarak, araçların kullandığı ancak tipi bilinmeyen yolları tahmin etmiştir. YSA

ayrıca, sürüş tarzı sınıflandırmasında da Wang vd. (2018) tarafından test edilmiş ve oldukça umut verici sonuçlar elde edilmiştir. Öte yandan, Goebel ve Plötz (2019), hibrit araçların elektrikli sürüş oranını tahmin etmek amacıyla YSA, DVM, regresyon ağacı ve rassal orman modellerini karşılaştırmış; en yüksek tahmin doğruluğunun ANN ve SVM ile elde edildiğini belirtmiştir.

Liu vd. (2019) ve Yi vd. (2019) gibi çalışmalar, sırasıyla trafik akışı tahmini ve sürüş davranışı tanıma gibi ulaşım odaklı uygulamalarda karar ağaçlarının ve DVM'nin performansını incelemişlerdir. Ayrıca, Hernandez vd. (2016), araçlara yönelik tercih verilerini kullanarak ulaşım tercihlerine etki eden algısal faktörleri açıklamak için karar ağacı modellerini tercih etmiştir. Bu yöntemler, kullanıcı davranışlarını açıklamada şeffaflık sağladığı için özellikle tercih edilmektedir. Zhao vd. (2020) ise SP verilerini temel alan bir çalışmada logit modelleri ile çeşitli makine öğrenimi algoritmalarını karşılaştırmış; YSA, DVM, karar ağacı ve doğrusal ayrıştırıcı analiz gibi yöntemlerin performansını detaylı biçimde incelemiştir. Bu çalışma, araçlara yönelik tercih verisi kullanarak sınıflandırma yapan nadir örneklerden biri olarak öne çıkmaktadır.

Ayrıca, Kotsiantis (2007) ve Singh vd. (2016), bu algoritmaların güçlü ve zayıf yönlerini karşılaştırmalı olarak ele almıştır. Bu incelemelerde DVM yüksek doğruluğu ve ilgisiz özelliklere toleransı ile öne çıkarken, YSA aşırı öğrenmeye yatkınlığına rağmen genel olarak dengeli bir performans sergilemektedir. Naive Bayes ve doğrusal ayrıştırıcı analiz gibi daha basit yöntemler ise hız ve sadelik avantajlarına sahip olmakla birlikte, karmaşık veri ilişkilerini modellemede sınırlı kalmaktadır. Tüm bu bulgular, elektrikli araçların benimsenmesi gibi sosyal ve teknik yönleri bir arada içeren karar süreçlerinde çeşitli algoritmaların birlikte değerlendirilmesini gerekli kılmaktadır (Bas vd., 2021).

Bas vd. (2021) yaptıkları çalışmada, elektrikli araçların benimsenmesinin, yakıt tasarrufu sağlama konusunda en büyük etkiye sahip yaklaşımlardan biri olarak gördüklerini ifade etmişlerdir. Ancak yazarlara göre, elektrikli araçların benimsenmesini öngören mevcut çalışmalar birbirinden oldukça farklı sonuçlar sunmakta, bu da stratejik kararlar için belirsizlik yaratmaktadır. Bu çalışma, potansiyel elektrikli araç alıcılarını sınıflandırmak için DVM, YSA, derin sinir ağları ve çeşitli ağaç tabanlı modelleri karşılaştırarak denetimli makine öğrenimi yöntemleriyle analiz yapmaktadır. Bulgular, tüm modellerin benzer başarı düzeyleri gösterdiğini ve çoklu

değişken kullanımının doğruluğu artırdığını ortaya koymaktadır. Şarj altyapısının dikkate alındığı bir başka çalışmada ise yük tahmini ve enerji yönetimi gibi çeşitli sorunların ortaya çıktığı vurgulanmıştır. Yazarlar çalışmalarında, elektrikli araç şarj yönetimi için Kısa-Uzun Dönem Hafıza (KUDH), Derin Sinir Ağlar (DSA), K-En Yakın Komşu (KEYK), Rassal Orman (RO), DVM ve karar ağaçları gibi makine öğrenimi yöntemleri karşılaştırılmış, KUDH'nin yük eğrisini dengeleyerek voltaj kararlılığı ve enerji kaybı açısından en iyi performansı gösterdiği bulunmuştur (Mazhar vd., 2023).

2.4 ÇKKV ve Makine Öğrenmesinin Birlikte Kullanımı

Bu bölümde, ÇKKV yöntemleri ile makine öğrenmesi tekniklerinin birlikte kullanımına yönelik literatür incelenmekte ve bu iki yaklaşımın entegrasyonuna dair güncel eğilimler değerlendirilmektedir. Liao vd. (2023), günümüzün veri odaklı bilgi çağında çok kriterli karar verme yöntemlerinin pratik uygulamalara aktarılmasında karşılaşılan zorluklara odaklanmıştır. Özellikle büyük veri hacmi ve zayıf veri korelasyonları gibi problemler, klasik ÇKKV tekniklerinin sınırlarını ortaya koymaktadır. Bu bağlamda, araştırmacılar makine öğrenmesi teknolojilerinin ÇKKV süreçlerine nasıl entegre edilebileceğini kapsamlı şekilde ele almıştır. Yapılan bibliyometrik analiz aracılığıyla, hem makine öğrenmesi hem de ÇKKV alanlarındaki araştırma eğilimleri, öne çıkan konular ve gelişim potansiyeli değerlendirilmiştir. Yazarlar, kriter çıkarımı, kriterler arası etkileşim analizi, parametre belirleme ve entegre çözüm üretimi gibi temel başlıklarda makine öğrenmesinin katkılarını derinlemesine incelemiştir. Ayrıca iş yönetimi, sanayi mühendisliği, enerji yönetimi, sürdürülebilir kalkınma ve afet yönetimi gibi çeşitli uygulama alanlarında bu teknolojilerin nasıl kullanıldığı örneklenmiştir. Liao vd. (2023), bu bulgular doğrultusunda makine öğrenmesinin ÇKKV süreçlerinde sadece destekleyici değil, aynı zamanda karar analizinin merkezine yerleşebilecek bir rol üstlenebileceğini ileri sürmektedir.

Makine öğrenmesi ve çok kriterli karar verme yöntemlerinin entegrasyonu, son yıllarda farklı sektörlerde sınıflandırma problemlerine yönelik etkili çözümler geliştirmek amacıyla yoğun şekilde incelenmektedir. Kartal vd. (2016), basit ağırlıklandırma, analitik hiyerarşi süreci ve VIKOR yöntemleriyle yapılan ABC analizlerini, destek vektör makineleri, yapay sinir ağları ve Bayes temelli

algoritmalarla birleřtirerek, ok ltl envanter sınıflandırması iin btncl bir metodoloji geliřtirmiřtir. Byk lekli bir otomotiv firmasında yapılan uygulama alıřmasında, zellikle DVM algoritmasının sınıflandırma doėruluėunda stnlk saėladıėı ve tm algoritmaların dengesiz daėılım gsteren envanter verisinde bařarılı sonular verdiėi grlmřtir. Bu alıřma, KKV ve makine ėrenmesini entegre eden nc uygulamalardan biri olarak ne ıkmaktadır.

Benzer biimde Albayrak nal ve Erkayman (2023), retim sektrnde stok kontrolne ynelik olarak AHP destekli bir ABC sınıflandırma srecini, karar aėacı, Naive Bayes, rassal orman ve SVM gibi makine ėrenimi algoritmalarıyla birleřtirerek envanter ynetimi iin etkili bir sistem nermiřtir. Elde edilen sonular, zellikle rassal orman algoritmasının stok sınıflandırmasında daha yksek performans sunduėunu gstermektedir. Roy vd. (2023) ise, envanter ynetiminde yeni rnlerin sınıflandırılması gibi zaman alıcı iřlemlerin daha hızlı yapılabilmesi adına, mevcut stokları TOPSIS yntemiyle sınıflandırdıktan sonra, yeni rnleri tahmin etmek iin k-en yakın komřu ve DVM algoritmalarını kullanmıřtır. Yapılan karřılařtırmalı deneylerde, k-en yakın komřu algoritması hem eėitim hem test verilerinde daha yksek doėruluk sergileyerek, yeni rn sınıflandırmalarında daha isabetli tahminler sunduėunu gstermiřtir.

alıřma alanı envanter ynetiminin tesine geerek, insan kaynakları gibi farklı baėlıamlara da uzanmaktadır. Chowdhury vd. (2023), alıřan devir oranlarını analiz etmek amacıyla, AHP yntemiyle belirlenen kriter aėırlıkları doėrultusunda TOPSIS ile alıřanları iřten ayrılma eėilimlerine gre sıralamıř; ardından yedi farklı makine ėrenmesi algoritmasını karřılařtırarak, personel sirklasyonunun tahmininde en yksek doėruluėa sahip olan algoritmanın rassal orman olduėunu rapor etmiřtir. Bu yaklařım, yalnızca alıřan sınıflandırmasında deėil, aynı zamanda karar verme srecinde hangi kriterlerin daha belirleyici olduėunu da gstermektedir. Bunlara ek olarak, Khodabakhshi vd. (2024), zellikle ila tařımacılıėı gibi hassas bir lojistik alanında, gnderim modunun (kara, hava, deniz) belirlenmesine ynelik bir model geliřtirmiřtir. SAW, MARCOS, TOPSIS, MULTIMOORA ve VIKOR gibi eřitli KKV yntemleriyle belirlenen kriter skorları, ardından XGBoost, rassal orman ve lojistik regresyon gibi algoritmalarla entegre edilerek tahminleme yapılmıřtır. Yapılan deėerlendirmelerde en yksek doėruluk XGBoost algoritmasında elde edilmiřtir. Bu arařtırma, tařımacılık alanında doėru mod seiminin karmařıklıėını dikkate alarak,

hem karar verme hem tahminleme bileşenlerini bütüncül şekilde ele alan başarılı bir hibrit yaklaşım sunmaktadır.

Bu çalışmalar, farklı sektörlerdeki (otomotiv, üretim, insan kaynakları, lojistik) sınıflandırma problemlerine odaklanarak, makine öğrenmesi ile ÇKKV yöntemlerinin birlikte nasıl verimli şekilde kullanılabileceğini göstermekte ve bu iki yaklaşımın entegrasyonunun karar destek sistemlerine olan katkısını açıkça ortaya koymaktadır. Bununla birlikte, literatürde çok kriterli karar verme yöntemleri ile makine öğrenmesi algoritmalarının birlikte kullanıldığı çalışmalar bulunsa da, bu entegrasyon genellikle genel sınıflandırma problemleriyle sınırlı kalmaktadır. Özellikle sıralı sınıflandırmaya dayalı ÇKKV yaklaşımlarının, makine öğrenmesine dayanan sınıflandırma algoritmalarıyla bütünleştiği örnekler oldukça sınırlıdır. Bu durum, alanda hem yöntemsel hem de uygulama düzeyinde önemli bir araştırma boşluğu olduğunu ortaya koymaktadır.



3. METODOLOJİ

Bu bölümde, çalışmanın temelini oluşturan yöntemsel çerçeve detaylı biçimde sunulmaktadır. Bu çalışmada, elektrikli araçlara yönelik olarak veri temelli karar verme süreçlerini desteklemek amacıyla çok kriterli karar verme yöntemleri ve denetimli makine öğrenmesi algoritmaları bir arada kullanılmıştır. İlk aşamada, çalışmanın uygulama alanına ilişkin veriler Python tabanlı veri kazıma teknikleri ile toplanmış; bu ham veriler, analiz sürecine uygun hale getirilmek üzere ön işleme adımlarına tabi tutulmuştur. Veri setinin yapısal özellikleri belirlendikten sonra, gözlemlerin sınıflandırılmasında kullanılacak kategori sayısını belirlemek amacıyla kümeleme analizi gerçekleştirilmiştir. Bu noktada, k-ortalamlar ve hiyerarşik kümeleme gibi yöntemler değerlendirilmiş ve optimum küme sayısı, iç tutarlılığı en yüksek olacak şekilde seçilmiştir. Elde edilen küme yapısı, TOPSIS-Sort-B algoritması kullanılarak karar alternatiflerinin tercih edilebilirlik düzeylerine göre sınıflandırılmasını sağlamıştır. Son aşamada, bu etiketler temel alınarak çeşitli sınıflandırma algoritmaları ile tahminleme modelleri oluşturulmuş ve bu modellerin performansı doğruluk, kesinlik, duyarlılık ve F1 skoru gibi metrikler aracılığıyla değerlendirilmiştir. Bu bütüncül yaklaşım hem nicel hem de nitel özelliklere sahip verilerin çok boyutlu analizine olanak tanımaktadır.

Bu çalışma, modern veri bilimi ve karar destek sistemlerinin kesişiminde yer alan sofistike bir metodoloji ile gerçekleştirilmiştir. Çok kriterli karar verme yöntemleri ile makine öğrenmesi tekniklerini entegre eden bu nicel yaklaşım, karmaşık veri kümelerinin derinlemesine analizine olanak sağlamaktadır. Temel araştırma motivasyonu, çok sayıda özneliğe sahip gözlemleri anlamlı ve yorumlanabilir sıralı sınıflara ayırmak ve bu sınıfların gelecekteki gözlemler için tahmin modellerini oluşturmaktır.


Çalışmanın metodolojik altyapısı, birbirini mantıksal olarak takip eden sistematik adımlarla örülmüştür. Veri toplama süreci, 2025 yılında güncel elektrikli araç verilerinin kapsamlı bir web kazıma işlemi ile EVDatabase (EVDatabase, 2025) platformundan elde edilmesiyle başlamıştır. Bu veri toplama yaklaşımı, anlık ve

güncel bilgilerin analizine imkân sağlarken, aynı zamanda geniş ölçekli bir veri setinin oluşturulmasına katkıda bulunmuştur. Toplanan veriler üzerinde ilk analitik adım olarak kümeleme analizi uygulanmış, bu sayede ham veriler içerisindeki örtük örüntüler ve istatistiksel benzerlikler ortaya çıkarılmaya çalışılmıştır. Ardından kümeleme analizi ile bu verilerden kaç farklı grup olduğu kestirilmeye çalışılmıştır. Bu gruplar, yalnızca istatistiksel benzerlik üzerinden değil, aynı zamanda karar verme bağlamında “tercih edilebilirlik düzeyleri”ne göre de yeniden anlamlandırılmıştır.

Kümeleme sonrası aşamada, her bir gözlem bir tercih sınıfına atanmış ve bu işlemde TOPSIS-Sort-B yöntemi kullanılmıştır. Böylece gözlemler, çok kriterli değerlendirme sonucu elde edilen puanlara göre yüksek, orta veya düşük tercih edilebilirlik düzeylerine göre etiketlenmiştir. Bu etiketler, çalışmanın sınıflandırma evresine veri hazırlığı niteliği taşımaktadır.

Çalışmanın sınıflandırma evresinde, farklı makine öğrenmesi algoritmaları stratejik olarak kullanılmıştır. Yapay sinir ağları, karar ağaçları, lojistik regresyon, destek vektör makineleri, k-en yakın komşu ve Naive Bayes gibi denetimli öğrenme teknikleri, önceki aşamada oluşturulan kategorilerin tahmin performansını optimize etmek amacıyla devreye sokulmuştur. Bu yaklaşım, yalnızca mevcut veri setinin analizini değil, aynı zamanda gelecekteki benzer veri kümelerinin de yorumlanabilirliğini artırmayı hedeflemektedir. Şekil 3.1’de çalışmanın metodolojik alt yapısı özetlenmiştir.

Metodolojinin bilimsel ve pratik açıdan önemi, büyük ölçekli veri kümelerinin çok boyutlu analizine sağladığı sistematik yaklaşımdan gelmektedir. Çalışma, karar destek sistemlerinin geliştirilmesine metodolojik bir katkı sunmanın yanı sıra, elektrikli araç ekosistemi gibi hızla değişen teknolojik alanlarda veri temelli içgörüler elde edilmesine de olanak tanımaktadır. Araştırmanın en dikkat çekici yönlerinden biri, farklı disiplinlerden analitik tekniklerin (veri madenciliği, çok kriterli karar verme, makine öğrenmesi) entegre bir şekilde kullanılmasıdır. Bu disiplinlerarası yaklaşım, salt istatistiksel analizin ötesine geçerek, verilerdeki anlamsal örüntülerin keşfedilmesini ve yorumlanmasını sağladığı gibi, yeni gözlemlerin tahminine de imkân tanımaktadır.



Şekil 3.1: Önerilen Metodolojinin Adımları

3.1 Veri Seti ve Özellikleri

Bu çalışmada kullanılan veri seti, ev-database.org adresinden (EVDATABASE, 2025) web kazıma yöntemiyle elde edilmiştir. Söz konusu veri tabanı, dünya genelinde piyasaya sunulan 400'ün üzerindeki elektrikli araca ilişkin kapsamlı bilgiler sunmaktadır. Araçlara dair veriler arasında satış fiyatı, batarya kapasitesi, menzil, hızlanma süresi, maksimum hız, kargo hacmi ve araç segmenti gibi hem teknik hem de ticari özellikler yer almaktadır. Bu sayede, elektrikli araç pazarına dair çok boyutlu bir analiz yapılabilmesi mümkün hale gelmektedir. Elde edilen bu veri, çalışmanın temel analiz aşamalarına girdi olarak kullanılmıştır.

3.1.1 Kullanılan değişkenler

İlgili veri seti oluşturulurken, ev-database.org adresinde (EVDATABASE, 2025) listelenen tüm araçlar detaylı bir biçimde incelenmiş ve analiz açısından en tutarlı ve yaygın şekilde bulunan değişkenler seçilmiştir. Örneğin bazı araçlara ait sayfalarda güvenlik puanı ya da sürücü destek sistemlerine dair bilgiler yer alırken, bu tür veriler çok sınırlı sayıda modele özgü olduğu için analiz dışında bırakılmıştır. Aynı şekilde, yalnızca bazı ticari araçlarda bulunan çekici gibi spesifik teknik donanımlara dair bilgiler de evrensel olarak karşılaştırılabilir bir nitelik taşımadığından elenmiştir. Bu filtreleme sürecinde temel ilke, mümkün olduğunca her araçta bulunan ve anlamlı bir karşılaştırma yapılmasını mümkün kılacak ortak öz niteliklerin toplanması olmuştur.

Bu seçici yaklaşımla birlikte, araçlara ilişkin toplam 100 adet değişken elde edilmiştir. Bu değişkenlerin önemli bir kısmı sayısal olup; örneğin aracın menzili (km), maksimum hızı (km/s), 0–100 km/s hızlanma süresi (saniye), dönüş çapı (metre), satış fiyatı (Euro, USD ve Sterlin), koltuk sayısı, boyutlar (uzunluk, genişlik, yükseklik), batarya kapasitesi, enerji tüketimi (kWh/100km), bu tüketimin eşdeğer benzin karşılığı (litre/100km), batarya garantisinin süresi (yıl) ve garanti kapsamında verilen toplam menzil (km) gibi değişkenleri kapsamaktadır. Buna ek olarak, bazı özellikler kategorik yapıdadır: aracın aktarma tipi (önden çekişli, arkadan itişli, dört çeker), ısı pompası desteği olup olmadığı, oto şarj desteği (plug & charge) mevcudiyeti ve aracın özel bir elektrikli araç platformunda tasarlanıp tasarlanmadığı gibi bilgiler bu gruba girmektedir. Kategorik veriler başlangıçta ilgili web sitesinde gözüktüğü şekilde elde edilmiştir. Bu çeşitlilik sayesinde, hem teknik hem de yapısal boyutta çok boyutlu analizler yapılabilmesi mümkün hale gelmiştir.

3.1.2 Veri ön işleme

Veri ön işleme, makine öğrenmesi uygulamalarında modelleme sürecinin temel adımlarından biridir. Gerçek dünya verileri çoğunlukla eksik, tutarsız ya da gürültülü yapıda olduğundan, doğrudan analize uygun değildir. Bu nedenle, verinin temizlenmesi, dönüştürülmesi ve analiz için elverişli hale getirilmesi gerekmektedir. Ön işleme süreci; eksik değerlerin yönetimi, aykırı gözlemlerin belirlenmesi, normalizasyon veya standardizasyon gibi dönüşümler, kategorik değişkenlerin kodlanması ve gerektiğinde boyut indirgeme gibi adımları içerir. Tüm bu işlemler, veri setinin kalitesini artırarak hem algoritmaların doğruluğunu yükseltmekte hem de

modelin daha hızlı ve stabil çalışmasına olanak tanımaktadır. Bu bağlamda, özellikle öz niteliklerin dikkatle seçilmesi ve homojenleştirilmesi, sınıflandırma ya da regresyon gibi görevlerde model performansını doğrudan etkileyen kritik bir adımdır (Garcia vd., 2015; Endel ve Piringer, 2015; Alasadi ve Bahaya, 2017; Hameed ve Naumann, 2020).

Makine öğrenmesi ve ÇKKV modellerinde çok sayıda değişkenin kullanılması, bazı bağımsız değişkenler arasında yüksek düzeyde korelasyon bulunmasına yol açabilir. Bu durum, çoklu doğrusallık olarak tanımlanmakta olup, modelin tahmin performansını olumsuz etkileyebilir çünkü değişkenlerin hedef değişken üzerindeki bireysel etkileri ayırt edilemez hale gelir. Çoklu doğrusallık genellikle varyans enflasyon faktörü (VEF) ile tespit edilir ve VEF değerinin 5'in üzerinde olması bu sorunun varlığına işaret eder. Bu durumda, yüksek korelasyon gösteren değişkenlerden birinin modelden çıkarılması, modelin doğruluğu ve kararlılığı açısından önerilen bir yöntemdir. Özellikle yüksek boyutlu veri setlerinde, bu tür değişkenlerin ayıklanması modelin yorumlanabilirliğini de artırır (Peeri et al., 2020).

Öte yandan, makine öğrenmesi algoritmalarında kategorik değişkenlerin modellenmesi için bu değişkenlerin uygun bir şekilde sayısal formatlara dönüştürülmesi gerekmektedir. Bu dönüşüm işlemi, kategorik kodlama olarak adlandırılır ve yaygın olarak kullanılan yöntemlerden biri de tekil kodlamadır (one-hot encoding). Tekil kodlama, her kategori için ayrı bir ikili (binary) sütun oluşturarak, kategorik verilerin algoritmalar tarafından işlenebilir hale getirilmesini sağlar. Bu yöntem, özellikle kategoriler arasında doğal bir sıralama olmadığında tercih edilmekte ve modelin öğrenme sürecine anlamlı katkı sunmaktadır. Ancak tekil kodlama, çok fazla kategorisi olan değişkenlerde veri setinin boyutunu önemli ölçüde artırdığından, dikkatli kullanılmalıdır. Yine de, bu yöntem sınıflar arası ilişkiyi bozmadığı ve doğrusal modellerle uyumlu olduğu için çalışmalarda sıklıkla tercih edilmektedir (Seeger, 2018; Cerda vd., 2018).

Makine öğrenmesi uygulamalarında özellikle sayısal verilerle çalışılırken standardizasyon ve normalizasyon işlemleri, modelin doğruluğu ve kararlılığı açısından kritik öneme sahiptir. Bu işlemler, farklı ölçeklerdeki değişkenlerin aynı düzleme taşınmasını sağlayarak modelin herhangi bir değişkene orantısız şekilde ağırlık vermesinin önüne geçer. Standardizasyon, verilerin ortalamasının sıfır, standart sapmasının ise bir olacak şekilde yeniden ölçeklendirilmesidir ve genellikle dağılımın

normal kabul edildiği durumlarda tercih edilir. Buna karşın normalizasyon, verileri genellikle $[0, 1]$ aralığına sıkıştırarak özellikle mesafeye dayalı algoritmalarda (örneğin k-en yakın komşu ve k-ortalamlar) daha sağlıklı sonuçlar alınmasını sağlar. Özellikle boyutları ve birimleri farklı olan değişkenlerin birlikte kullanıldığı modellerde bu dönüşümler yapılmadığında, büyük ölçekli değişkenler küçük ölçekli olanları baskılayabilir ve model performansını olumsuz yönde etkileyebilir. Bu nedenle ön işleme sürecinde sayısal değişkenlerin uygun yöntemlerle dönüştürülmesi, öğrenme algoritmalarının daha doğru ve dengeli çalışması açısından elzemdir (Ali vd., 2014; Gal ve Rubinfeld, 2019).

Gerçek dünya verileri çoğu zaman eksik veya tamamlanmamış olabilir. Bu durum, analizlerin doğruluğunu ve makine öğrenmesi modellerinin performansını olumsuz etkileyebileceğinden, eksik verilerin yönetimi veri ön işleme sürecinin en önemli adımlarından biri olarak kabul edilmektedir. Eksik değerlerin yerine koyulması, eksik gözlemleri veri setinden tamamen çıkarmak yerine, uygun istatistiksel ya da öğrenmeye dayalı yöntemlerle doldurmayı amaçlar. Bu işlem, hem veri kaybını azaltır hem de analizdeki yanlılığı minimize eder. Literatürde en sık kullanılan yöntemler arasında ortalama, medyan veya mod gibi tek değişkene dayalı yerleştirmeler yer alırken; daha gelişmiş teknikler arasında k-en yakın komşu imputasyonu, regresyona dayalı tahminleme ve çoklu imputasyon yöntemleri bulunmaktadır. Eksik veri oranının düşük olduğu durumlarda basit istatistiksel yöntemler yeterli olabilse de, eksiklik sistematik bir yapıya sahipse daha sofistike yöntemlerin kullanılması önerilmektedir. Bu bağlamda, eksik verilerin etkili biçimde ele alınması, hem modelin genel doğruluğu hem de çıktının güvenilirliği açısından kritik bir ön koşuldur (Lin ve Tsai, 2020; Emmanuel vd., 2021; Adhikari vd., 2022).

3.2 Kümeleme ile Sınıf Sayısının Belirlenmesi

Veri setinde kaç farklı sınıf ya da grup bulunduğunu önceden bilmediğimiz durumlarda, kümeleme yöntemleri sınıf sayısını belirlemek için etkili bir araç sunar. Bu süreçte amaç, benzer özelliklere sahip gözlemleri gruplayarak yapısal örüntüleri ortaya çıkarmaktır. Elde edilen kümeler, daha sonra yapılacak sınıflandırma veya etiketleme işlemleri için temel bir referans oluşturabilir. Bu bölümde, sınıf sayısının belirlenmesi amacıyla uygulanan kümeleme yaklaşımlarına yer verilecektir.

3.2.1 Kümeleme yöntemleri

Veri biliminin temel analiz araçlarından biri olan kümeleme algoritmaları, karmaşık veri kümelerindeki gizli örüntülerin ve grupların keşfedilmesine olanak sağlayan önemli bir metodolojik yaklaşımdır (Estivill-Castro, 2000). Bu algoritmaların temelinde, heterojen veri setlerini anlamlı ve homojen alt gruplara ayırma amacı yatar. Kümeleme sürecinin özgünlüğü, "küme" kavramının net bir tanımının olmamasından kaynaklanmakta ve bu durum araştırmacılara farklı yaklaşımlar geliştirme imkânı sunmaktadır (Rokach ve Maimon, 2005).

Kümeleme algoritmaları, veri bilimi literatüründe çeşitli sınıflandırma yaklaşımlarıyla karşımıza çıkmaktadır. Fraley ve Raftery (1998), bu algoritmaları temel olarak hiyerarşik ve bölünmeli yöntemler olarak ikiye ayırırken, Han (2009) daha kapsamlı bir sınıflandırma yaparak algoritmaları bölünmeli algoritmalar, yoğunluk esaslı yaklaşımlar, olasılıksal model tabanlı kümeleme ve ızgara esaslı yöntemler gibi alt kategorilere ayırmıştır.

Hiyerarşik kümeleme algoritmaları, veri nesnelerini iç içe geçmiş bir yapıda gruplandıran iki temel stratejiye sahiptir. Birleştirici (agglomerative) yaklaşımda, her bir veri noktası başlangıçta kendi kümesini oluşturur ve ardından benzerlik düzeylerine göre daha büyük kümeler oluşturulur. Bölücü (divisive) yaklaşımda ise tüm veriler tek bir kümede başlar ve ardından giderek daha küçük alt kümelere ayrılır (Jain vd., 1999). Kümeleme sürecinin görsel temsili olan dendrogram, bu algoritmaların en önemli çıktılarından biridir. Dendrogram, veri nesnelerinin birbirleriyle olan ilişkilerini ve benzerlik düzeylerini hiyerarşik bir şema üzerinde gösterir. Araştırmacılar, dendrogramdan istenen benzerlik seviyesinde kesit alarak farklı kümeleme yapıları elde edebilmektedir (Rokach ve Maimon, 2005; Madhulatha, 2012).

Hiyerarşik kümeleme sürecinde kümeler arası mesafelerin hesaplanmasında kullanılan bağlantı (linkage) yöntemleri belirleyicidir. Örneğin, tek bağlantı (single linkage) yöntemi, iki küme arasındaki en yakın nokta çiftinin mesafesini esas alır:

$$D_{\text{single}}(A, B) = \min_{x \in A, y \in B} d(x, y) \quad (3.1)$$

Buna karşılık, tam bağlantı (complete linkage) en uzak nokta çiftine odaklanır:

$$D_{\text{complete}}(A, B) = \max_{x \in A, y \in B} d(x, y) \quad (3.2)$$

Ortalama bağlantı (average linkage) yönteminde ise tüm nokta çiftleri arasındaki ortalama mesafe hesaplanır:

$$D_{\text{average}}(A, B) = \frac{1}{|A||B|} \sum_{x \in A} \sum_{y \in B} d(x, y) \quad (3.3)$$

Daha gelişmiş bir yöntem olan Ward yöntemi, kümelerin birleşmesiyle oluşan toplam iç varyans artışını minimize etmeye çalışır. Bu yöntemde mesafe şu şekilde hesaplanır:

$$D_{\text{Ward}}(A, B) = \frac{|A||B|}{|A|+|B|} \cdot |\mu_A - \mu_B|^2 \quad (3.4)$$

Burada μ_A ve μ_B , sırasıyla küme A ve B'nin merkezleridir. Hiyerarşik kümeleme algoritmalarının en önemli avantajı farklı küme yapılarını keşfetmeye olanak tanıyan esnekliğidir. Ancak büyük veri setlerinde yüksek hesaplama maliyeti ve geri izleme yeteneğinin sınırlılığı gibi dezavantajları da bulunmaktadır (Rokach ve Maimon, 2005).

Bölümleme algoritmaları, veri biliminde kümeleme analizinin bir diğer önemli alt dalını oluşturmaktadır. Bu algoritmaların temel yaklaşımı, başlangıç konumlandırmasından hareketle veri örneklerini farklı kümeler arasında yeniden konumlandırmaktır (Selim ve Ismail, 1984). Küme sayısının önceden kullanıcı tarafından belirlenmesi gereken bu yöntemler, kümeleme analizinde yaygın olarak kullanılan yaklaşımlardan biridir.

K-ortalamlar algoritması, bölümleme algoritmalarının en popüler ve yaygın kullanılan örneğidir. Algoritma, veri kümesini önceden belirlenen kkk sayıda kümeye ayırarak, her bir kümenin merkezini hesaplar ve veri noktalarını bu merkezlere olan uzaklıklarına göre gruplandırır (Dhillon ve Modha, 2001). Her iterasyonda, önce tüm gözlemler en yakın küme merkezine atanır:

$$c_i = \arg \min_j |x_i - \mu_j|^2 \quad (3.5)$$

Burada x_i , i. gözlemi, μ_j ise j. kümenin merkezini temsil etmektedir. Atama işleminden sonra, her küme için merkez noktası (centroid) yeniden hesaplanır:

$$\mu_j = \frac{1}{|C_j|} \sum_{x_i \in C_j} x_i \quad (3.6)$$

Bu iki adım, belirli bir durdurma kriteri sağlanana kadar iteratif olarak tekrarlanır. Genellikle algoritma, küme merkezleri artık değişmediğinde sonlandırılır:

$$\text{dur } \mu_j^{(t+1)} = \mu_j^{(t)} \quad \forall j \in \{1, \dots, k\} \quad (3.7)$$

K-ortalamlar algoritmasının temel hedefi, kümeler içindeki veri noktalarının küme merkezlerine olan toplam kare uzaklığını minimize etmektir. Bu optimizasyon hedefi şu şekilde ifade edilir:

$$\arg \min_C \sum_{j=1}^k \sum_{x_i \in C_j} |x_i - \mu_j|^2 \quad (3.8)$$

Yani amaç, küme içi homojenliği maksimize etmektir. K-ortalamlar algoritmasının hesaplama karmaşıklığının doğrusal olması, büyük veri setlerinde bile etkin ve hızlı biçimde çalışmasını sağlamaktadır (Rokach ve Maimon, 2005; Saputra vd., 2020).

Bununla birlikte, algoritmanın bazı önemli sınırlamaları bulunmaktadır. Başlangıç küme merkezlerinin seçimi sonuçları ciddi şekilde etkileyebilmekte, gürültülü veriler ve aykırı değerler algoritmanın performansını düşürebilmektedir. Ayrıca, algoritma yalnızca sayısal verilerle çalışabilmekte ve küme sayısının önceden bilinmesini gerektirmektedir (Rokach ve Maimon, 2005).

3.2.2 Optimum küme sayısının belirlenmesi

Kümeleme algoritmalarının en kritik aşamalarından biri, analiz edilecek veri setinin optimal küme sayısının belirlenmesidir. Birçok kümeleme algoritması, çalıştırılmadan önce küme sayısının önceden tanımlanmasını gerektirir. Bu zorluk, araştırmacılar için önemli bir analitik problem oluşturmaktadır.

Kümeleme algoritmalarında iç değerlendirme ölçütleri, küme kalitesini belirlemede kritik bir rol oynar. Bu yaklaşımlar, küme içi yakınlık ve kümeler arası farklılık olmak üzere iki temel parametreyi inceler. Küme içi yakınlık, aynı kümede yer alan veri noktalarının birbirine benzerliğini; kümeler arası ayrım ise farklı kümeler arasındaki mesafeyi ölçer (Saputra vd., 2020).

Küme sayısını belirlemeye yönelik temel yaklaşımlardan biri dirsek yöntemi olarak bilinir. Bu yöntemde, küme sayısına karşılık gelen varyans açıklama yüzdesi grafiğe dökülür. Grafikteki kırılma noktası (dirsek), optimal küme sayısını işaret eder. İlk kümeler çok bilgi eklerken, belirli bir noktadan sonra ek kümelerin marjinal katkısı belirgin şekilde azalır ve bu katkının azalma hızının azaldığı nokta, optimal küme sayısı olarak değerlendirilir. Alternatif olarak, bilgi kriterleri de küme sayısının belirlenmesinde kullanılır. Akaike Bilgi Kriteri (AIC), Bayezyen Bilgi Kriteri (BIC) ve Sapma Bilgi Kriteri (DIC) gibi istatistiksel yöntemler, kümeleme modellerinin

karmaşıklığını ve uyumunu değerlendirerek optimal küme sayısını tahmin etmeye çalışır (Madhulatha, 2012; Humaira ve Rasyidah, 2020).

Siluet Yöntemi (Silhouette Method) ise hem küme içi yakınlığı hem de kümeler arası ayrımı birlikte dikkate alır. Siluet katsayısı, her bir veri noktasının kendi kümesi içindeki ortalama mesafesi ile en yakın farklı kümeye olan ortalama mesafesi arasındaki ilişkiyi ölçer. iii indeksli bir veri noktası için siluet katsayısı aşağıdaki şekilde hesaplanır:

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (3.9)$$

Burada:

$a(i)$, i noktası ile aynı kümedeki diğer noktalar arasındaki ortalama mesafeyi, $b(i)$ ise i noktasının en yakın farklı kümedeki noktalarla olan ortalama mesafesini göstermektedir.

Siluet katsayısı -1 ile +1 arasında bir değer alır. Bu değerın yüksek olması, veri noktasının bulunduğu kümeye iyi oturduğunu ve diğer kümelerden uzak olduğunu gösterir. Grafik üzerinde küme sayısına karşılık siluet katsayıları çizilerek en yüksek değere sahip olan küme sayısı optimal küme sayısı olarak seçilir (Saputra vd., 2020).

Hiyerarşik kümeleme algoritmalarında ise dendrogramdaki eşik değerleri ve kümelerin yaşam süreleri dikkate alınır. Genel bir kural olarak, maksimum yaşam süresine sahip dendrogramdan kesit alınarak küme sayısı belirlenir (Madhulatha, 2012).

3.3 TOPSIS-Sort-B ile Etiketleme

TOPSIS-Sort-B, çok kriterli karar verme yaklaşımlarından biri olan klasik TOPSIS yönteminin, sıralı sınıflandırma problemlerine uyarlanmış yeniden yapılandırılmış bir versiyonudur. Bu yöntem, her alternatifin ideal ve anti-ideal çözümlere olan göreceli yakınlık değerini esas alarak, alternatifleri önceden tanımlanmış sınıflardan birine atamayı mümkün kılar. Böylece karar verici yalnızca alternatifler arasında göreceli üstünlük belirlemekle kalmaz, aynı zamanda her bir alternatifi belirli sıralı sınıflar (örneğin; yüksek, orta ve düşük gibi) altında gruplandırabilir (Lopez vd., 2023; Zhang ve Li, 2023).

Yöntemin uygulanabilmesi için öncelikle alternatifleri temsil eden çok kriterli karar matrisinin oluşturulması gereklidir. Bu matris, her alternatfin her kritere ilişkin nicel değerlendirmelerini içerir:

$$X = [x_{ij}] \quad (i = 1, \dots, m; j = 1, \dots, n) \quad (3.10)$$

Farklı ölçeklerdeki kriter değerlerini karşılaştırılabilir hale getirmek için normalizasyon işlemi uygulanır. Normalizasyon genellikle min-maks yöntemi ya da vektörel norm esaslı yöntemlerle gerçekleştirilir. Min-maks normalizasyon formülleri şu şekildedir:

Fayda kriterleri için:

$$r_{ij} = \frac{x_{ij} - \min(x_j)}{\max(x_j) - \min(x_j)} \quad (3.11)$$

Maliyet kriterleri için:

$$r_{ij} = \frac{\max(x_j) - x_{ij}}{\max(x_j) - \min(x_j)} \quad (3.12)$$

Ardından, her bir kriterin fayda (maksimizasyon) ya da maliyet (minimizasyon) türünde olup olmadığına göre ideal ve anti-ideal çözümler belirlenir. Fayda kriterleri için ideal değer maksimum, maliyet kriterleri için ise minimum değerdir; anti-ideal değerler bu durumun tersidir:

İdeal çözüm (a^+):

$$a^+ = \{ \max(v_{ij}) \mid j \in J_{\text{fayda}}; \min(v_{ij}) \mid j \in J_{\text{maliyet}} \} \quad (3.13)$$

Anti-ideal çözüm (a^-):

$$a^- = \{ \min(v_{ij}) \mid j \in J_{\text{fayda}}; \max(v_{ij}) \mid j \in J_{\text{maliyet}} \} \quad (3.14)$$

Alternatiflerin ideal ve anti-ideal çözümlere olan uzaklıkları hesaplandıktan sonra, her bir alternatfin görelî yakınlık skoru elde edilir:

İdeal uzaklık:

$$D_i^+ = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^+)^2} \quad (3.15)$$

Anti-ideal uzaklık:

$$D_i^- = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^-)^2} \quad (3.16)$$

Görelî yakınlık skoru:

$$C_i = \frac{D_i^-}{D_i^+ + D_i^-} \quad (3.17)$$

Bu skor, alternatifin ideal çözüme ne kadar yakın olduğunu ifade eder ve genellikle 0 ile 1 arasında bir değeri alır. Klasik TOPSIS yönteminde bu değerler sıralama amacıyla kullanılırken, TOPSIS-Sort-B yaklaşımında bu değerler sınıflandırma amacıyla yorumlanır.

Alternatiflerin sınıflandırılabilmesi için görelî yakınlık değerlerinin belirli sınıf aralıkları ile eşleştirilmesi gerekir. Bu noktada sınıf eşiklerinin nasıl belirleneceği önemli bir metodolojik karardır. Öznel sınıflandırmalar yerine veriye dayalı bir yaklaşım tercih edildiğinde, yakınlık değerlerinin dağılımına göre istatistiksel eşikler kullanılabilir. Örneğin, birinci ve üçüncü çeyrek değerler (Q1 ve Q3) sınıf sınırları olarak belirlendiğinde, alternatifler aşağıdaki gibi kategorilere ayrılabilir:

$$C_i < Q_1 \quad (3.18)$$

$$Q_1 \leq C_i < Q_3 \quad (3.19)$$

$$C_i \geq Q_3 \quad (3.20)$$

Bu tür çeyrek temelli eşikleme, verinin yapısına duyarlı ve nesnel bir sınıflandırma sağlar (Lopez vd., 2023; Zhang ve Li, 2023; Zhang vd., 2024).

TOPSIS-Sort-B, özellikle çok sayıda alternatifin değerlendirildiği durumlarda karar vericinin bilişsel yükünü azaltan, daha özet ve yorumlanabilir bir çıktı üretme olanağı sunar. Sıralama temelli yöntemlerin sunduğu detaylı ayrımlar yerine, belirli etiketlere dayalı gruplamalar sağlayarak, karar süreçlerini daha sistematik hale getirir. Bu yönüyle, karar verme sürecinde hem nicel hem de nitel değerlendirme imkânı sunan esnek bir metodolojik araç olarak değerlendirilmektedir.

3.4 Sınıflandırma Algoritmaları ile Modelleme

Bu bölümde, veri kümesinde yer alan alternatiflerin önceden tanımlanmış kategorilere atanabilmesi amacıyla kullanılan sınıflandırma algoritmalarına odaklanılmıştır. Çok

kriterli karar verme sürecinde sayısal çıktıların anlamlı etiketlerle ifade edilmesi, yorumlanabilirlik açısından önemli bir avantaj sağlamaktadır. Bu doğrultuda, TOPSIS-Sort-B gibi yöntemlerle elde edilen etiketler, denetimli makine öğrenmesi modelleri için zemin oluşturmaktadır. Aşağıda, bu dönüşümün yöntemsel altyapısı ve sınıflandırma algoritmaları ile kurulan modellerin genel çerçevesi sunulmaktadır.

3.4.1 Eğitim-Test verisi ayrımı

Sınıflandırma modellerinin güvenilirliğini değerlendirmek amacıyla, veri kümesi genellikle eğitim ve test olmak üzere iki ayrı alt kümeye ayrılır. Bu ayrım, modelin yalnızca öğrenilen verilere değil, daha önce hiç görmediği örneklerle karşı da genel performansını ortaya koymayı amaçlar. En yaygın yaklaşım olan rastgele bölme, veri kümesinden belirli bir oranda örneklemin test setine, geri kalanının ise eğitim setine atanmasını içerir. Uygulamada sıklıkla %80 eğitim ve %20 test oranı tercih edilmekle birlikte, %70-%30, %60-%40 ya da %50-50 gibi oranlar da kullanılmaktadır. Hatta, çok büyük veri setleri için olabildiğince büyük (yani %99 ve üzeri oranda) eğitim verisinin kullanılması önerilmektedir. Bu oranların seçimi genellikle deneyime ya da problem bağlamına dayanır; literatürde oranların optimal değerine dair net bir görüş birliği bulunmamaktadır (Joseph, 2022).

3.4.2 Kullanılan sınıflandırma yöntemleri

Sınıflandırma, denetimli öğrenme kapsamında yer alan temel bir yaklaşımdır ve gözlemlerin önceden tanımlanmış kategorilere (etiketlere) atanmasını amaçlar. Bu yöntemler, verideki özniteliklere dayalı olarak gözlemlerin hangi sınıfa ait olduğunu tahmin etmeye çalışır. Gerekli olan model, genellikle etiketli veri seti üzerinden öğrenilerek eğitilir ve daha sonra etiketlenmemiş yeni veriler üzerinde tahmin işlemi gerçekleştirilir. Bu doğrultuda kullanılan sınıflandırma algoritmaları, problemin doğasına, veri yapısına ve hedeflenen doğruluk düzeyine bağlı olarak çeşitlilik gösterebilir (Alnuaimi ve Albaldawi, 2024).

Bu çalışmada kullanılan yöntemlerden biri olan Naive Bayes algoritması, Bayes Teoremi'ne dayalı olasılıksal bir sınıflandırma tekniğidir. Algoritmanın temelinde, her sınıf için koşullu olasılıkların hesaplanması ve bir gözlemin en yüksek olasılıkla ait olduğu sınıfın belirlenmesi yatar. Naive Bayes'in "naive" olarak adlandırılmasının nedeni, tüm özniteliklerin birbirinden bağımsız olduğu varsayımdır. Gerçekte bu varsayım çoğu zaman sağlanmasa da, algoritma özellikle metin sınıflandırma, spam

filtreleme ve duygu analizi gibi pek çok uygulamada yüksek performans göstermektedir. Modelin temel formülü Bayes teoremiyle ifade edilir:

$$P(C_k | x) = \frac{P(C_k) \prod_{i=1}^n P(x_i | C_k)}{P(x)} \quad (3.21)$$

Burada C_k sınıflardan birini, $x=(x_1, x_2, \dots, x_n)$ ise gözlem vektörünü temsil eder. Naive Bayes, hem sürekli hem de kategorik verilerle çalışabilme, hızlı modelleme süreci ve düşük hesaplama maliyeti gibi önemli avantajlara sahiptir. Ancak, öznelilikler arasında yüksek korelasyon bulunması durumunda performansının azalabileceği, ayrıca sıfır koşullu olasılık problemlerinde Laplace düzeltmesi gibi yöntemlerin kullanılması gerektiği vurgulanmaktadır. Tüm bu özellikleriyle Naive Bayes, özellikle yüksek boyutlu ve gürültülü veri setlerinde sade ama etkili bir sınıflandırma yaklaşımı olarak tercih edilmektedir (Jadhav ve Channe, 2016; Ray, 2019; Alnuaimi ve Albaldawi, 2024).

Karar ağacı algoritmaları, sınıflandırma problemlerine yönelik en erken ve etkili gözetimli öğrenme yöntemlerinden biridir. İstatistik, veri madenciliği ve makine öğrenmesi gibi alanlarda yaygın olarak kullanılan karar ağaçları, verileri sınıflandırmak için görsel olarak anlaşılır, dallanmış bir yapı sunar ve böylelikle yorumlanabilirlik açısından avantajlı modellerdir. Her bir iç düğüm, belirli bir özelliğe dayalı karar fonksiyonunu değerlendirerek hangi alt düğüme gidileceğini belirlerken; yaprak düğümler, veri noktalarının ait olduğu sınıfları temsil eder. Kök düğüm, veri setindeki en iyi ayırt edici özelliği ifade eder ve veri, bu kökten başlayarak yukarıdan aşağıya doğru bir rota izleyerek sınıflandırılır. Ağaçlar, gereksiz dallanmaları önlemek ve aşırı öğrenmeyi azaltmak için budanabilir. Karar ağacı algoritmaları hem kategorik hem de sayısal verilerle çalışabilir; gürültülü verilere karşı dayanıklı olup eksik verilerle de başa çıkabilir. Modelde bölme noktaları, bilgi kazancı ölçütü gibi kriterlere göre seçilir. Bilgi kazancı, entropi farkı olarak hesaplanır:

$$IG(D, A) = Entropi(D) - \sum_{v \in Values(A)} \frac{|D_v|}{|D|} Entropi(D_v) \quad (3.22)$$

Burada entropi, veri setindeki belirsizliği ölçer ve şu şekilde tanımlanır:

$$Entropi(D) = - \sum_{i=1}^c p_i \ln p_i \quad (3.23)$$

Bu denklemler sayesinde, karar ağacı algoritmaları veri setindeki en uygun bölünme noktalarını belirleyerek sınıflandırma performansını artırır. Ancak aşırı dallanma ve karmaşıklık modelin genellenebilirliğini olumsuz etkileyebilir. Karar ağaçları finansal

fiyatlandırma, sađlık tehditlerinin tanımlanması ve desen tanıma gibi birçok alanda etkin biçimde kullanılmaktadır (Jadhav ve Channe, 2016; Ray, 2019; Kalcheva vd., 2020; Alnuaimi ve Albaldawi, 2024).

Lojistik regresyon, sınıflandırma problemlerini çözmek için yaygın olarak kullanılan, doğrusal regresyonun genelleştirilmiş bir versiyonudur ve özellikle gözetimli öğrenme yöntemlerinde tercih edilir. Sürekli çıktı üretmek yerine, bir olayın gerçekleşip gerçekleşmediğini belirten ikili sonuçlar üretir. Lojistik regresyon modeli, bir gözlemin belirli bir sınıfa ait olma olasılığını tahmin etmek için sigmoid (lojistik) fonksiyonu kullanır:

$$P(y = 1 | x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p)}} \quad (3.24)$$

Burada, $x = (x_1, x_2, \dots, x_p)$ bağımsız değişkenler vektörü, β_0 sabit terim ve $\beta_1, \beta_2, \dots, \beta_p$ regresyon katsayılarıdır. Sigmoid fonksiyonun çıktısı 0 ile 1 arasında bir olasılık değeri verir ve bu değeri belirlenen eşik (genellikle 0.5) kullanılarak sınıf etiketine dönüştürülür.

Model, logit dönüşümü kullanarak doğrusal regresyon modeline dönüştürülür:

$$\log\left(\frac{P(y = 1|x)}{1 - P(y = 1|x)}\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p \quad (3.25)$$

Burada, sol taraftaki ifade log-odds ya da logit fonksiyonu olarak adlandırılır.

Lojistik regresyon hem kategorik hem de sayısal verilerle çalışabilir ve özellikle hedef değişken ile açıklayıcı değişkenler arasındaki ilişkiyi modellemek için uygundur. Basit uygulanabilirliği, düşük hesaplama maliyeti, yorumlanabilirliği ve kolay güncellenebilir yapısı önemli avantajlarındandır. Ancak, yalnızca doğrusal sınırlarla ayrılabilen verilerde etkili olması, eksik veri veya değişkenler arası bağımlılık gibi durumlarda performansının düşmesi önemli sınırlamalarındandır. Lojistik regresyon; hastalık riski tahmini, hava durumu öngörüsü, oy verme davranışı ve mühendislikte arıza olasılığı hesaplamalarında yaygın şekilde uygulanmaktadır. Ayrıca, ikili, çoklu (multinomial) ve sıralı lojistik regresyon olmak üzere üç farklı türü vardır (Ray, 2019; Alnuaimi ve Albaldawi, 2024).

K-En Yakın Komşu (KEYK) algoritması, yeni bir veri noktasını sınıflandırmak için mevcut veri noktalarına olan benzerliğini -genellikle Öklid uzaklığı gibi metriklerle- hesaplayan, gözetimli öğrenmede yaygın olarak kullanılan basit ve etkili bir

yöntemdir. KEYK algoritmasında, test verisi xxx için eğitim veri setindeki tüm noktalarla olan uzaklıklar hesaplanır ve bu uzaklıklara göre en yakın kkk komşu seçilir. Bu komşuların sınıf etiketlerine göre çoğunluk oylaması yapılarak yeni veri noktasının hangi sınıfa ait olduğu belirlenir.

KEYK algoritmasında yaygın olarak kullanılan Öklid mesafesi şu şekilde hesaplanır:

$$d(x, x_i) = \sqrt{\sum_{j=1}^n (x_j - x_{ij})^2} \quad (3.26)$$

Burada x sınıflandırılmak istenen veri noktası, x_i ise eğitim veri setindeki veri noktalarından biridir. n ise öznitelik sayısını ifade eder.

Sınıf ataması şu şekilde yapılır:

$$\hat{y} = \arg \max_c \sum_{i \in N_k(x)} 1(y_i = c) \quad (3.27)$$

Burada $N_k(x)$, x'in en yakın k komşularının indeks kümesini, y_i bu komşuların sınıf etiketini, 1 ise gösterge fonksiyonunu ifade eder. En çok tekrar eden sınıf, sınıflandırma sonucu olarak atanır.

KEYK algoritması, parametrik olmayan bir yaklaşım olması sayesinde herhangi bir dağılım varsayımı yapmadan çalışabilir ve hem sınıflandırma hem de regresyon problemlerinde kullanılabilir. Gürültüye karşı dayanıklı yapısı ve sadeliği en büyük avantajlarından. Ancak, özellikle yüksek boyutlu veri kümelerinde en uygun kkk değerinin seçimi kritik önemdedir. KEYK algoritması; örüntü tanıma, el yazısı tanıma, görüntü ve video sınıflandırma, öneri sistemleri, kredi skorlama ve tıbbi teşhis gibi pek çok alanda başarıyla uygulanmaktadır. Buna karşılık, tahmin sırasında tüm veri setiyle kıyaslama yapması nedeniyle hesaplama maliyeti yüksek olabilir ve belleğe yoğun şekilde ihtiyaç duyar (Ray, 2019; Ram, 2022; Alnuaimi ve Albaldawi, 2024).

Destek Vektör Makineleri (DVM), istatistiksel öğrenme teorisine dayanan güçlü bir gözetimli makine öğrenme yöntemidir. DVM, sınıflandırma, öğrenme ve tahmin problemlerinde yaygın olarak kullanılır ve modern sınıflandırma problemlerinde oldukça etkili bir tekniktir. Bu yöntem, veri noktalarını sınıflandırmak için bağımlı ve bağımsız değişkenler arasındaki ilişkiyi açıklayan ve iki sınıf arasındaki en geniş marjini sağlayan bir hiperdüzlem belirler. Amaç, verisetini iki sınıfa ayıran bir karar sınırı (hiperdüzlem) bulmak ve bu düzlemle sınıflar arasındaki mesafeyi (marjin) maksimize etmektir.

Doğrusal olarak ayrılabilir durumlar için temel optimizasyon problemi şu şekilde tanımlanır:

$$\min_{\mathbf{w}, b} \quad \frac{1}{2} |\mathbf{w}|^2 \quad \text{şartıyla:} \quad y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1, \quad i = 1, \dots, n \quad (3.28)$$

Burada:

$\mathbf{w}$: hiperdüzlemin normal vektörü

b : sapma terimi (bias)

$y_i \in \{-1, 1\}$: sınıf etiketleri,

$\mathbf{x}_i$: gözlem verileri

Elde edilen karar sınırına en yakın veri noktalarına destek vektörleri adı verilir. Bu noktalar karar yüzeyinin belirlenmesinde doğrudan rol oynar. Sınıflandırma kararı, aşağıdaki karar fonksiyonu kullanılarak verilir:

$$f(\mathbf{x}) = \text{sign}(\mathbf{w}^T \mathbf{x} + b) \quad (3.29)$$

Eğer veriler doğrusal olarak ayrılamıyorsa, DVM çekirdek fonksiyonları (kernel trick) kullanarak veriyi daha yüksek boyutlu bir uzaya dönüştürür ve bu uzayda doğrusal ayırım yapar. Yaygın çekirdek fonksiyonları arasında polinom çekirdeği, radyal tabanlı fonksiyon (RBF) ve sigmoid çekirdeği bulunur.

DVM başlangıçta ikili sınıflandırma için geliştirilmiş olsa da, çok sınıflı problemler için “birine karşı hepsi” (OvR) ve “birine karşı biri” (OvO) gibi stratejilerle yaygın şekilde uygulanmaktadır. Avantajları arasında yüksek boyutlu verilerle iyi çalışması, aşırı öğrenmeye karşı dayanıklı olması ve bellek verimliliği yer alırken; büyük veri kümelerinde eğitim süresinin uzun olması, uygun çekirdek fonksiyonunun seçiminin zorluğu ve gürültülü verilerde performans düşüklüğü gibi dezavantajları da bulunmaktadır. DVM; metin sınıflandırma, yüz tanıma, el yazısı tanıma, dolandırıcılık tespiti ve hastalık teşhisi gibi pek çok alanda başarıyla kullanılmaktadır (Soofi ve Awan, 2017; Ray, 2019; Fadel ve Behadili, 2022; Alnuaimi ve Albaldawi, 2024).

Yapay Sinir Ağları (YSA), insan beyninin bilgi işleme biçiminden esinlenerek geliştirilen, çok katmanlı ve paralel çalışan öğrenme algoritmalarıdır. Bu algoritmalar, biyolojik nöronların çalışma mantığını taklit ederek, örüntü tanıma, karar verme ve tahminleme gibi görevlerde kullanılır. Tipik bir YSA; giriş katmanı, bir veya daha

fazla gizli katman ve çıkış katmanından oluşur. Giriş katmanı veriyi alır, gizli katmanlar bu veriyi dönüştürerek örüntüleri öğrenir, çıkış katmanı ise öğrenilen örüntüye göre karar üretir.

YSA'nın temel birimi olan yapay nöron, giriş değerlerini ağırlıklarla çarpar, toplar ve aktivasyon fonksiyonu ile bir çıktı üretir. Basit bir yapay nöronun matematiksel ifadesi şöyledir:

$$z = \sum_{i=1}^n w_i x_i + b \quad (3.30)$$

$$y = \phi(z) \quad (3.31)$$

Burada:

x_i : giriş değerleri,

w_i : her girişe ait ağırlıklar,

b : bias (sapma) terimi,

$\phi(z)$: aktivasyon fonksiyonu (örneğin sigmoid, ReLU, tanh).

Eğitim sürecinde modelin çıktısı ile gerçek değer arasındaki fark bir kayıp fonksiyonu ile ölçülür. Örneğin, sınıflandırma problemlerinde genellikle çapraz entropi kullanılır:

$$\mathcal{L} = - \sum_{i=1}^n y_i \log(\hat{y}_i) \quad (3.32)$$

Ağırlıklar, geri yayılım (backpropagation) ve gradyan inişi (gradient descent) yöntemleriyle güncellenerek hata minimize edilmeye çalışılır.

YSA modelleri, yüksek boyutlu ve gürültülü verilerde bile öğrenme kapasitesine sahiptir. Bu nedenle hem sınıflandırma hem de regresyon problemlerinde başarıyla kullanılmaktadır. Bununla birlikte, YSA modelleri genellikle “kara kutu” niteliği taşıdığından, karar mekanizmasını yorumlamak zor olabilir. Ayrıca, büyük veri setleri üzerinde çalışırken eğitim süreleri uzun olabilir. Tüm bu avantaj ve sınırlılıklarına rağmen YSA’lar; el yazısı tanıma, yüz ifadelerinden duygu çıkarımı, siyah-beyaz görüntüleri renklendirme, tıbbi teşhis, doğal dil işleme ve bilgisayarla görme gibi pek çok alanda yaygın olarak kullanılmaktadır (Preeti ve Dhankar, 2017; Pineda-Jaramillo, 2019; Alnuaimi ve Albaldawi, 2024).

3.4.3 Model performans metriği

Makine öğrenmesi algoritmalarının başarısı, yalnızca modelin eğitilmesiyle değil, aynı zamanda bu modelin çeşitli performans metrikleriyle sistematik olarak değerlendirilmesiyle anlaşılabilir. Modelin performansını doğru şekilde değerlendirebilmek hem geliştirilen modelin etkinliğini belirlemek hem de farklı algoritmalar arasında objektif karşılaştırmalar yapabilmek açısından kritik öneme sahiptir. Bu nedenle, hangi metriğin kullanılacağı problemin tanımına ve uygulama alanına göre özenle seçilmelidir (Grandini vd., 2020).

Sınıflandırma problemlerinde yaygın olarak kullanılan başlıca metrikler aşağıda tanımlanmıştır (Hossin ve Sulaiman, 2015; Grandini vd., 2020):

- **Karışıklık Matrisi (Confusion Matrix):** Gerçek sınıf etiketleri ile modelin tahmin ettiği sınıfların karşılaştırılmasıyla oluşturulan bir matristir. Doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) olmak üzere dört temel bileşenden oluşur. Bu matris üzerinden diğer metrikler türetilir ve modelin tahmin performansı bütüncül şekilde analiz edilebilir.
- **Doğruluk (Accuracy):** Modelin tüm veri seti üzerindeki doğru tahmin sayısının, toplam tahmin sayısına oranıdır. Her ne kadar yaygın olarak kullanılsa da dengesiz sınıf dağılımı olan veri kümelerinde yanıltıcı olabilir.
- **Hassasiyet (Precision):** Pozitif olarak tahmin edilen örneklerin ne kadarının gerçekten pozitif olduğunu gösterir. $TP / (TP + FP)$ formülüyle hesaplanır. Yanlış pozitiflerin önemli olduğu uygulamalarda kritik rol oynar.
- **Duyarlılık (Recall) / Geri Çağırma:** Gerçek pozitif örneklerin ne kadarının doğru şekilde pozitif olarak tahmin edildiğini gösterir. $TP / (TP + FN)$ formülüyle hesaplanır. Yanlış negatiflerin minimize edilmesi gereken durumlarda tercih edilir.
- **F1 Skoru (F1-Score):** Hassasiyet ve duyarlılık metriklerinin harmonik ortalamasıdır. Bu iki metriğin dengelenmesi gereken durumlarda kullanılır. Özellikle dengesiz sınıfların bulunduğu veri kümelerinde daha anlamlı sonuçlar sunar.

Çok sınıflı sınıflandırma problemlerinde F1 skoru farklı şekillerde hesaplanabilir:

- Makro F1: Tüm sınıfların F1 skorlarının aritmetik ortalamasını alır ve sınıf dengesinden bağımsızdır.
- Ağırlıklı (Weighted) F1: Her bir sınıfın F1 skorunu, o sınıfa ait örnek sayısı ile ağırlıklandırarak genel bir skor üretir.
- Mikro F1: Tüm sınıflar için TP, FP ve FN değerlerini topladıktan sonra bu toplamalar üzerinden tek bir F1 skoru hesaplar. Bu yöntem sınıf dengesizliklerinde daha güvenilir olabilir.

Bu metriklerin birlikte kullanılması, modelin yalnızca genel doğruluğunu değil, aynı zamanda hangi sınıflarda hangi tür hatalar yaptığını da görmeyi sağlar. Böylece modelin gerçek dünya uygulamaları için uygunluğu daha kapsamlı şekilde değerlendirilebilir.

4. ANALİZ VE BULGULAR

Bu bölümde, elektrikli araçların sınıflandırılmasına yönelik gerçekleştirilen analiz süreci ve elde edilen bulgular sistematik bir yaklaşımla sunulmaktadır. Çalışma metodolojisi dört temel aşamada ilerlemektedir.

İlk aşamada, araştırmanın veri tabanını oluşturan elektrikli araç özelliklerinin toplanma, ve hazırlanma süreçleri detaylandırılmıştır. İkinci aşamada, optimal sınıf sayısının belirlenmesine yönelik kümeleme analizleri gerçekleştirilmiş ve bulgular görselleştirmelerle desteklenmiştir. Bu sınıf yapısı, sonraki aşamalarda uygulanacak TOPSIS-Sort-B yönteminin temelini oluşturmaktadır.

Üçüncü aşamada, çok kriterli karar verme yöntemlerinden TOPSIS-Sort-B kullanılarak her bir elektrikli aracın ilgili performans sınıfına atanma süreci ve sonuçları sunulmuştur. Son aşamada ise, TOPSIS-Sort-B ile elde edilen sınıflandırma sonuçlarının, çeşitli makine öğrenmesi algoritmaları ile ne ölçüde tahmin edilebileceği araştırılmıştır. Tüm analizler Python 3.9 programlama dili ile gerçekleştirilmiştir.

Bölümün sonunda, bu iki farklı yaklaşımın -ÇKKV ve makine öğrenmesi- sonuçları karşılaştırmalı olarak değerlendirilmiş, benzerlik ve farklılıklar analiz edilerek her iki metodolojinin avantaj ve sınırlılıkları tartışılmıştır. Bu karşılaştırmalı analiz, elektrikli araç sınıflandırmasında alternatif yaklaşımların etkinliğine ışık tutmaktadır.

4.1 Veri Toplama ve Hazırlık Süreci

Bu çalışmada, elektrikli araçlara ilişkin veri seti, <https://ev-database.org> adresinden (EVDatabase, 2025) web kazıma yöntemiyle elde edilmiştir. Verinin toplanma sürecinde Python programlama dili ve Selenium kütüphanesi kullanılmıştır. Dinamik içerikler HTML yapısı üzerinden okunarak sistematik bir şekilde çekilmiştir. Web kazıma işlemleri, ilgili web sitesinin yapısına özel olarak geliştirilen bir tarayıcı otomasyonu aracılığıyla gerçekleştirilmiştir.

Veri çekimi sırasında bazı teknik işlemler de uygulanmıştır. Özellikle menzil, tahmini tüketim, araç tüketimi, karbondioksit salımı, tahmini yakıt eşdeğeri ve araç yakıt

eşdeğeri gibi bazı performans değişkenleri, ilgili internet sitesinde en düşük (TEL – Tip I Emisyon Alt Limit) ve en yüksek (TEH – Tip I Emisyon Üst Limit) değerler şeklinde sunulmaktadır. Bu tür özellikler için her iki sınır değer aritmetik ortalaması alınarak tek bir temsil değeri oluşturulmuş ve bu sayede veri seti daha tutarlı ve anlamlı hale getirilmiştir.

Toplanan veri, elektrikli araçlara ait oldukça geniş bir özellik kümesini içermektedir. Bunlar arasında fiyat bilgisi, gerçek menzil tahmini, uzun yol uygunluğu, batarya kapasitesi, şarj süresi, performans ölçütleri, çift yönlü şarj (araçtan şebekeye / araçtan binaya), enerji tüketimi, tahmini gerçek enerji tüketimi, boyut ve ağırlık bilgileri ile koltuk sayısı, dönüş çapı, ısı pompası, tavan rayı gibi çeşitli donanım bilgileri yer almaktadır. Araç modeliyle birlikte toplamda 100 farklı özelliğin bulunduğu veri seti, veri çekiminin yapıldığı tarih itibarıyla 439 farklı elektrikli araca dair tüm temel teknik ve fiziksel bilgileri içerecek şekilde oluşturulmuştur.

Veri çekimi sonrasında ilk olarak, sayısal niteliklerin analizlerde doğrudan kullanılabilmesi amacıyla birimlerinden arındırılması işlemi gerçekleştirilmiştir. Örneğin, batarya kapasitesi 76.6 kWh şeklinde ifade edilen bir araçta yalnızca sayısal değer olan 76.6 dikkate alınmış; benzer biçimde, “0’dan 100 km/sa hıza ulaşma süresi” gibi performans ölçütlerinde yer alan “6.1 saniye” ifadesinden yalnızca 6.1 değeri çekilmiştir. Bu işlem, tüm sayısal öznitelikler için tutarlı biçimde uygulanmıştır.

Araçlara ait fiyat bilgileri, veri kaynağında Birleşik Krallık, Hollanda ve Almanya için ayrı ayrı sunulmuştur. Ancak bazı araçlarda belli ülkelere ait fiyatlar mevcut değildir. Bu durumun nedeni, kimi zaman eksik veri olması, kimi zamansa ilgili aracın henüz o ülkede satışa sunulmamış olması olabilir. Çalışmada, fiyatların tek ve karşılaştırılabilir bir gösterimle kullanılabilmesi adına, tüm para birimleri Amerikan Doları’na çevrilmiştir. Bu dönüşüm için analiz döneminde geçerli olan döviz kurları esas alınmış; Birleşik Krallık Poundu, 1.3285 oranıyla USD’ye çevrilirken, Euro için 1.1197 dönüşüm oranı kullanılmıştır. Her bir ülkenin fiyatı bu şekilde USD’ye dönüştürüldükten sonra, araç başına ortalama fiyat değeri hesaplanarak tek bir fiyat niteliği oluşturulmuştur.

Veri setine türetilmiş bazı öznitelikler de dahil edilmiştir. Bu bağlamda, aracın uzunluk, genişlik ve yükseklik değerleri kullanılarak araç hacmi hesaplanmış; benzer şekilde, ön ve arka bagaj hacimleri toplanarak toplam bagaj hacmi özniteliği elde

edilmiştir. Bu şekilde, mevcut öz niteliklerin daha anlamlı ve analizde daha açıklayıcı biçimlere dönüştürülmesi amaçlanmıştır.

Veri setinde toplamda 100 öz nitelik yer almakla birlikte, bazı nitelikler birbiriyle yüksek oranda ilişkili ya da mükerrer bilgi içerebilmektedir. Bu nedenle, elektrikli araçlar konusunda uzman kişilerle – 3 kişi - gerçekleştirilen çok aşamalı istişareler sonucunda, analizlerde kullanılacak en açıklayıcı ve anlamlı öz nitelikler belirlenmiş; kalanlar elenmiştir. Nihai olarak kullanılan öz nitelikler, Çizelge 4.1’de listelenmiş olup, her birinin orijinal (İngilizce) adları ile Türkçe açıklamaları da çizelgeye dahil edilmiştir. Bu işlem, çok boyutluluğun yol açabileceği karmaşayı yani boyutluluğun laneti sorununu azaltmak amacıyla yapılmıştır.

Çizelge 4.1: Öz nitelikler ve açıklamaları.

Öz nitelik	Açıklama
Acceleration	İvmelenme
Top Speed	Maksimum sürat
Range	Menzil
Battery Architecture	Batarya mimarisi
Battery Warranty Period	Batarya garanti periyodu (Yıl)
Battery Warranty Mileage	Batarya garanti mesafesi (Km)
Charge Speed	Şarj hızı
Fast Charge Speed	Hızlı şarj hızı
Fuel Equivalent	Yakıt emsali (Benzin)
Car Weight	Araç ağırlığı
No Seats	Koltuk sayısı
Turning Circle	Kendi eksenini etrafında dönüş mesafesi (M)
Average USD	USD cinsinden ortalama fiyatı
Car Volume	Araç hacmi
Total Cargo Volume	Aracın toplam bagaj hacmi
Drive Type	Önden çekişli, arkadan itişli veya 4x4 değerlerini alan kategorik değişken
Autocharge support	Şarj işleminin otomatik olarak gerçekleşip gerçekleşmediğine dair ikili değişken
Preconditioning	Bataryaya ilişkin ön koşullandırma olup olmadığına dair ikili değişken
V2L Support	Araçtan araca batarya aktarımının olup olmadığına dair ikili değişken
Tow Hitch	Araçta çekme kancası olup olmadığına ilişkin ikili değişken
Dedicated Platform	Elektrikli araca özgü platformun olup olmadığına dair ikili değişken
Heat Pump	Isı pompasının olup olmadığına dair ikili değişken

Veri setinde bazı kategorik öznitelikler için eksik veri gözlemlenmiştir. Bu tür özniteliklerde genellikle “evet” ya da “hayır” şeklinde ikili cevaplar bulunmaktadır. Örneğin, ısı pompası ya da elektrikli araçlara özel platform kullanımı gibi öznitelikler, var/yok şeklinde değerlendirilmiştir. Eksik veya “bilgi yok” şeklindeki değerler, uzman görüşleri doğrultusunda “yok” (hayır) olarak kodlanmıştır. Bu şekilde, kategorik değişkenlerin eksikliği sistematik olarak giderilmiştir.

Sayısal özniteliklerdeki eksik değerler ise, doğrudan ortalama ile doldurulmamıştır. Bunun yerine, her aracın ait olduğu segment dikkate alınarak işlem yapılmıştır. Veride halihazırda bulunan araç segmenti bilgileri örneğin F (lüks), D (geniş), C (orta) gibi sınıflandırmalarla ayrılmıştır. Eksik değer bulundugu araç hangi segmentte yer alıyorsa, o segmente ait araçların ortalama değeri kullanılarak ilgili boşluk doldurulmuştur. Bu yöntem, eksik verinin daha gerçekçi ve bağlama uygun biçimde tamamlanmasını sağlamıştır.

Veri hazırlık sürecinin önemli aşamalarından biri de kategorik özniteliklerin sayısallaştırılmasıdır. Bu amaçla, çoklu doğrusal ilişki (multicollinearity) sorununu minimize etmek adına ikili kodlama (one-hot encoding) yöntemi uygulanmıştır. İkili değer alan değişkenler tek bir sütunda 0 ve 1 değerleriyle temsil edilmiş, böylelikle hem makine öğrenmesi algoritmaları açısından uygunluk sağlanmış hem de veri yapısı sadeleştirilmiştir.

Sayısal özniteliklerin ölçeklendirilmesi de analiz sürecinin kritik bir adımıdır. Özellikle Öklid ya da Mahalanobis mesafesi gibi uzaklık hesaplamalarının temel alındığı algoritmalarda, ölçekleme yapılmaması durumunda büyük değer aralıklarına sahip öznitelikler diğerlerine göre daha fazla ağırlık taşır. Örneğin, 0-10000 arasında değişen bir öznitelik, 0-10 aralığında değişen başka bir niteliği gölgede bırakabilir. Bu nedenle, tüm özniteliklerin aynı ölçeğe getirilmesi amaçlanmıştır. Ölçekleme için farklı yöntemler mevcuttur: standart sapma ve ortalama ile yapılan z-skoru normalizasyonu, çeyreklik değerler dikkate alınarak yapılan gürbüz (robust) ölçekleme veya min-maks normalizasyonu gibi. Çalışmada hem sayısal hem de kategorik özniteliklerin 0 ile 1 aralığında olması hedeflendiğinden, sayısal değişkenlerde min-maks normalizasyonu tercih edilmiştir. Böylece tüm değişkenler aynı ölçekle ifade edilerek analiz sürecine dahil edilmiştir (Trebuna vd., 2014).

Bu kapsamlı veri toplama ve hazırlık süreci, çalışmanın analiz aşamalarında güvenilir, tutarlı ve karşılaştırılabilir sonuçlar elde edilebilmesi için kritik bir temel

oluşturmuştur. Elde edilen temiz ve zenginleştirilmiş veri seti, elektrikli araçların çok boyutlu yapısını detaylı biçimde yansıtmakta ve sonraki analizlerin hem doğruluğunu hem de açıklayıcılığını artırmaktadır.

4.2 Sınıf Sayısının Belirlenmesi: Kümeleme Analizi

Bu bölümde, çalışmanın temel amaçlarından biri olan elektrikli araçların benzerliklerine göre gruplandırılması süreci ele alınmaktadır. Bu doğrultuda, sınıf (küme) sayısının belirlenmesi kritik bir adımdır. Kümeleme analizi, gözetimsiz öğrenme yöntemlerinden biri olarak, veri içindeki doğal yapıları ortaya çıkarmayı hedefler. Aşağıdaki alt başlıkta, analizde kullanılacak ideal küme sayısının belirlenmesine yönelik yöntemler ve bu süreçte izlenen adımlar ayrıntılı biçimde açıklanmaktadır.

4.2.1 Kümeleme yöntemleri ve değerlendirme kriterleri


Bu çalışmada, veri setinde yer alan elektrikli araçların benzer özelliklerine göre gruplandırılabilmesi amacıyla iki temel kümeleme yöntemi kullanılmıştır: K-ortalamlar algoritması ve hiyerarşik kümeleme. Her iki yöntem de farklı avantajlar sunmaları nedeniyle birlikte değerlendirilmiştir.

K-ortalamlar algoritması, yüksek boyutlu verilerde hızlı ve etkili bir kümeleme yapılmasına olanak tanıyan, sıkça başvurulmuş bir yöntemdir. Bu yöntem, gözlemleri önceden belirlenen k sayıda kümeye atar ve her bir gözlemin kendi küme merkezine olan uzaklığını minimize etmeye çalışır. Bu çalışmada k-ortalamlar algoritması hem Öklid uzaklığı hem de Mahalanobis uzaklığı ile uygulanmıştır. Mahalanobis uzaklığı, gözlemler arasındaki ilişkiyi yalnızca mutlak farklar üzerinden değil, aynı zamanda değişkenler arası kovaryans yapısını da dikkate alarak ölçmektedir. Bu yönüyle, özellikle değişkenler arası korelasyonların önemli olduğu durumlarda daha sağlıklı sonuçlar sunmaktadır (McLachlan, 1999). Her iki uzaklık metriğiyle, k değerleri 2 ile 10 arasında değiştirilerek çeşitli kümeleme senaryoları denenmiş ve her durumda Silhouette skoru hesaplanmıştır. Mahalanobis uzaklık ölçütü kullanılarak elde edilen sonuçlar Çizelge 4.2'de sunulmaktadır. Silhouette skoru, her gözlemin ait olduğu küme ile diğer kümelerle olan benzerliğini karşılaştıran bir ölçüttür ve kümeleme kalitesini değerlendirmede sıklıkla kullanılmaktadır (Shahapure ve Nicholas, 2020).

Çizelge 4.2: K-ortalamlar algoritmasında küme sayısına göre silhouette skoru.


Küme sayısı (k)	Silhouette Skoru
2	0.0650
3	0.0551
4	0.0596
5	0.0593
6	0.0613
7	0.0665
8	0.0712
9	0.0697
10	0.0735

K-ortalamlar yöntemine ek olarak, verinin içsel yapısını daha bütüncül bir şekilde analiz edebilmek amacıyla hiyerarşik kümeleme analizi de gerçekleştirilmiştir. Bu analizde, çeşitli bağlantı metotları ile farklı uzaklık metrikleri bir arada denenmiştir. Spesifik olarak, Ward, ortalama bağlantı (average linkage), tam bağlantı (complete linkage) ve tek bağlantı (single linkage) yöntemleri hem Öklid hem de Mahalanobis uzaklıklarıyla birlikte değerlendirilmiştir (Jarman, 2020). Hiyerarşik kümeleme sonucunda elde edilen dendrogramlar, veri içerisindeki kümelenme yapısının görsel olarak incelenmesine olanak tanımaktadır. Şekil 4.1'de, tek bağlantı metodu ve Öklid uzaklığı ile elde edilen dendrogram yer almakta, Şekil 4.2'de ortalama bağlantı metodu ve Mahalanobis uzaklığı kullanılarak oluşturulan dendrogram, Şekil 4.3'te tam bağlantı metodu ve Mahalanobis uzaklığı bağlamında oluşturulan dendrogram ve son olarak Şekil 4.4'te ise Ward metodu ve Öklid uzaklığı ile oluşturulmuş dendrogram sunulmaktadır.




Şekil 4.1: Tek bağlantı metodu ve Mahalanobis uzaklığı ile oluşturulan dendrogram.

Dendrogram (Metot: Ortalama bağlantı, Metrik: Mahalanobis)




Şekil 4.2: Ortalama bağlantı metodu ve Mahalanobis uzaklığı ile oluşturulan dendrogram.

Dendrogram (Metot: Tam bağlantı, Metrik: Mahalanobis)



Şekil 4.3: Tam bağlantı metodu ve Mahalanobis uzaklığı ile oluşturulan dendrogram.

Dendrogram (Metot: Ward, Metrik: Mahalanobis)



Şekil 4.4: Ward metodu ve Öklid uzaklığı ile oluşturulan dendrogram.

Mahalanobis uzaklığının bu bağlamda tercih edilme nedeni, klasik uzaklık ölçütlerinden farklı olarak değişkenler arası korelasyonları da dikkate almasıdır. Ortalama bağlantı yöntemi her bir küme çifti arasındaki tüm olası çiftli mesafelerin ortalamasını alarak daha dengeli bir birleşim mantığı sunar. Bu özellikleri nedeniyle, ortalama bağlantı ve Mahalanobis uzaklığının birlikte kullanımı hem istatistiksel hem de yapısal olarak tutarlı bir kümeleme profili ortaya koymaktadır. Öte yandan, Ward metodu ile Mahalanobis uzaklığı birlikte kullanılamamaktadır. Bunun nedeni, Ward yönteminin, kümeler arası varyansın toplamını minimize etmeye çalışırken yalnızca Öklid uzaklığına göre tanımlı olmasıdır. Mahalanobis uzaklığı, varyans-kovaryans yapısını hesaba kattığı için bu matematiksel öncül ile uyumlu değildir; bu nedenle birlikte kullanımları istatistiksel olarak anlamlı sonuçlar üretmez (McLachlan, 1999).

4.2.2 Sınıf sayısının belirlenmesi

Çizelge 4.2'de görüleceği üzere, k-ortalamlar algoritmasıyla yapılan analiz sonucunda en yüksek Silhouette skoru, küme sayısının 10 olduğu durumda elde edilmiştir. Ancak bu durum, her ne kadar nicel açıdan yüksek bir skor sunsa da, yorumlanabilirlik ve uygulama bağlamında anlamlı bir küme yapısı sunmamaktadır. Nitekim kümelerin aşırı parçalanması, gerçek hayat uygulamalarında karşılık

bulamayan yapay ayrımlara neden olabilmektedir. Bu nedenle sadece silhouette skoruna dayanarak nihai küme sayısının belirlenmesi uygun görülmemiştir.

Bu noktada, çalışmada kullanılan hiyerarşik kümeleme yöntemlerinden elde edilen dendrogramlar, daha niteliksel bir değerlendirme imkânı sunmuştur. Özellikle farklı uzaklık metrikleri ve bağlantı yöntemleriyle elde edilen dört farklı dendrogram incelendiğinde, veri setinde doğal olarak oluşan yapının üç kümelik bir ayrım önerdiği gözlemlenmiştir. Bu dendrogramlar, sadece küme sayısı hakkında değil, aynı zamanda kümeler arası yapısal benzerlikler ve ayrışmalar hakkında da sezgisel bir fikir vermektedir.

Sonuç olarak, hem nicel analiz sonuçları (silhouette skorları), hem de nitel değerlendirme çıktıları (dendrogram yapıları) birlikte ele alınarak, veri setinin üç kümeye ayrılmasının daha anlamlı ve uygulanabilir olduğu kanaatine varılmıştır. Bu bağlamda Şekil 4.1–4.4 arasında sunulan dendrogram yapıları, bu değerlendirmeye dayanak teşkil etmektedir.

Kümelerin sadece sayısal olarak değil, aynı zamanda içeriksel olarak da anlamlı ve yorumlanabilir olup olmadığını değerlendirmek amacıyla çizelge 4.3'te, her bir kümeye ait gözlemlerin metrik olan öznitelik bazında ortalama değerler gösterilmiştir. Bu çizelge, kümelerde yer alan araçların teknik ve donanımsal profillerine ilişkin genel bir görünüm sunmakta; kümeler arası farklılıkların daha net bir şekilde anlaşılmasına olanak tanımaktadır. Çizelgede satırlarda kümeler, sütunlarda ise öznitelikler yer almakta; hücrelerde ise ilgili özniteliklerin küme içerisindeki ortalama değerleri gösterilmektedir. Bu sayede her bir kümenin belirli özellikler bakımından öne çıkan yönleri analiz edilebilmekte ve kümelerin sadece istatistiksel değil, anlamlı yapısal ayrımlara dayandığı görülmektedir.

Çizelge 4.3: Hiyerarşik kümelemeye göre kümelerin metrik öznitelikler bakımından ortalama değerleri.

Küme	İvme	Maksimum	Menzil	Batarya	Batarya	Batarya	Şarj	Hızlı	Yakıt	Ağırlık	Koltuk	Dönüş	Fiyat	Hacim (mm ³)	Toplam
	Sürat			Mimarisi	Garanti	Garanti	Hızı	Şarj	Eşleniği	(Kg)	Sayısı	Ekseni	(USD)		Kargo
					Periyodu	Periyodu	Hızı	Hızı				(Metre)			Hacmi
					(Yıl)	(Mil)									(Litre)
Yüksek Tercih Edilebilirlik	5.77	193.86	433.73	413.73	8.26	177655	53.066	615.69	2.12	2276	5.13	11.44	86289	14459748152	511.81
Orta Tercih Edilebilirlik	9.75	153.59	291.96	403.87	8.01	175917	47.52	367.27	2.14	1817	5.56	11.07	49055	13611870622	520.82
Düşük Tercih Edilebilirlik	5.23	212	445.50	691.52	7.95	175037	56.79	874.32	2.12	2243	5.11	11.71	94637	14332383869	499.48

4.3 ÇKKV Yöntemi ile Sınıflandırma

Kümeleme analizinden elde edilen yapının ötesine geçerek alternatiflerin çok sayıda kritere göre daha sistematik biçimde değerlendirilmesi amacıyla çok kriterli karar verme yaklaşımı kullanılmıştır. Bu çerçevede, her bir alternatif belirlenen kriterler doğrultusunda puanlanarak anlamlı bir öncelik sırasına yerleştirilmiştir. Böylece yalnızca yapısal benzerliklere değil, karar verme sürecine dâhil edilen ağırlıklı değerlendirme ölçütlerine dayalı bir sınıflandırma yapılması sağlanmıştır.

4.3.1 TOPSIS-Sort-B yönteminin uygulanması

Bu çalışmada, elektrikli araç alternatiflerinin çok kriterli bir yaklaşımla tercih edilebilirlik düzeylerine göre sıralanması amacıyla TOPSIS-Sort-B algoritması kullanılmıştır. Bu yöntemin uygulanabilmesi için öncelikle metrik olan her bir özneliğe (kriter) ilişkin birtakım temel tanımlamaların yapılması gerekmektedir. Bunlar sırasıyla; her öznelik için ideal değer (a^+) ve anti-ideal değer (a^-) sınırlarının belirlenmesi, kriterlerin türlerinin (yarar/zarar; yani yüksek değer iyidir veya düşük değer iyidir) tanımlanması ve ağırlıklandırma sürecidir. Bu kapsamda, elektrikli araçlar alanında uzman iki kişi ile çalışılmıştır.

Öncelikle bu uzmanlardan, Analitik Hiyerarşi Süreci (AHP) yöntemi aracılığıyla her bir kriterin önem düzeyini karşılaştırmalı olarak değerlendirmeleri istenmiştir. AHP, karar vericilerin çok sayıda kriteri ikili karşılaştırmalar yoluyla tutarlı bir biçimde kıyaslamalarını sağlayan güçlü bir karar verme yöntemidir. Uzmanların verdiği yanıtlar doğrultusunda (tutarlılık değerleri 0.0871 ve 0.0389) kriter ağırlıkları hesaplanmış ve özneliklerin göreceli önemi elde edilmiştir. Bunun yanında, her bir kriterin "yarar" (yüksek değer tercih edilir) veya "zarar" (düşük değer tercih edilir) tipi de uzman görüşleri doğrultusunda belirlenmiştir.

Aynı uzmanlar, güncel piyasa verilerine dayalı bir araştırma yaparak her öznelik için a^+ (ideal değer) ve a^- (anti-ideal değer) sınırlarını tanımlamıştır. Özneliklerin ismi orijinal halinde tutularak tüm bu özneliklere (kriterlere) ilişkin ağırlık, kriter tipi, ideal ve anti-ideal değerler, Çizelge 4.3'te sistematik biçimde sunulmuştur.

Çizelge 4.4: Kriterlere ilişkin özellikler.

Kriter	Tipi	Ağırlığı	İdeal Değeri	Anti-İdeal Değeri
acceleration	Zarar	0.049	20	2.1
top_speed	Fayda	0.071	120	350
range	Fayda	0.105	120	1000
battery_architecture	Fayda	0.032	400	800
battery_warranty_period	Fayda	0.073	7	15
battery_warranty_mileage	Fayda	0.058	120000	1000000
charge_speed	Fayda	0.055	18	120
fast_charge_speed	Fayda	0.078	170	1400
fuel_equivalent	Zarar	0.037	4	1
car_weight	Zarar	0.011	3300	100
no_seats	Fayda	0.026	2	9
turning_circle	Zarar	0.011	15	9
average_usd	Zarar	0.142	450000	17000
car_volume	Fayda	0.020	9000000000	21000000000
total_cargo_volume	Fayda	0.019	140	1500
drive_type_Front	Zarar	0.013		
drive_type_Rear	Zarar	0.013		
autocharge_support_Yes	Fayda	0.015		
preconditioning_Yes	Fayda	0.016		
v2l_support_Yes	Fayda	0.016		
tow_hitch_Yes	Fayda	0.007		
dedicated_platform_Yes	Fayda	0.060		
heat_pump_Yes	Fayda	0.071		

Tüm bu ön bilgiler doğrultusunda, TOPSIS-Sort-B algoritması Python programlama dili ile geliştirilmiştir. Verilerin normalize edilmesinde min–maks normalizasyon yöntemi tercih edilmiştir. Önceki kümeleme analizlerinden elde edilen sonuçlar, verinin üç ana segmente (yüksek, orta ve düşük tercih edilebilirlik düzeyi) ayrılmasının uygun bir yaklaşım olduğunu ortaya koymuştur. Bu bağlamda, TOPSIS-Sort-B algoritması da üçlü bir sınıflandırma yapacak şekilde uygulanmıştır.

Yöntemin sınıflandırma yapabilmesi için üst ve alt profil değerlerinin belirlenmesi gerekmektedir. Bu doğrultuda, yarar tipindeki her bir kriter için üst profil değeri olarak 3. çeyrek değer (Q3), alt profil değeri olarak ise 1. çeyrek değer (Q1) kullanılmıştır. Zarar tipine sahip kriterler için ise tam tersine üst profil değeri 1. çeyrek, alt profil değeri ise 3. çeyrek seçilmiştir. Uzmanların da tavsiyesi sonucunda böyle bir yaklaşımın hem istatistiksel anlamlılık taşıdığını hem de gerçekçi sınıflandırmalar yapılmasına olanak sunabileceği düşünülmüştür. Böylece sınıflandırma süreci hem alan uzmanlarının görüşleriyle hem de veri odaklı istatistiksel analizlerle desteklenerek daha sağlam bir temele oturtulmuştur.

4.3.2 Sınıf dağılımı ve TOPSIS-Sort-B sonuçlarının özeti

TOPSIS-Sort-B algoritması ile yapılan analiz sonucunda, toplam 439 elektrikli araç üç farklı tercih edilebilirlik düzeyine ayrılmıştır. Bu sınıflandırmaya göre; 130 araç düşük tercih edilebilirlik, 164 araç orta derecede tercih edilebilirlik ve 145 araç ise yüksek tercih edilebilirlik sınıfında yer almıştır. Bu dağılım, araçların çok sayıda öznitelige göre bütüncül bir değerlendirmeye tabi tutulduğunu ve sadece tek bir kriterle dayalı olarak sınıflandırılmadığını göstermektedir.

Sıralı sınıflandırmada belirleyici olan kriter ağırlıkları incelendiğinde, araç fiyatı başta olmak üzere, menzil, maksimum sürat, batarya garanti süresi ve ısı pompasının varlığı gibi özelliklerin yüksek etkiye sahip olduğu görülmektedir. Bu durum, genel eğilimde fiyat-performans dengesinin güçlü olduğu modellerin daha yüksek bir tercih edilebilirlik düzeyine yerleştirilmesini beraberinde getirmiştir.

Bununla birlikte, analiz sonuçları bazı istisnai örneklere de işaret etmektedir. Örneğin; Mercedes Benz Eqs 450Plus, Porsche Taycan Plus, Lotus Emeya R, Tesla Model X Plaid, Kia Ev9 99.8 KWh RWD ve Maserati Grancabrio Folgore gibi modeller, 100.000 USD üzerindeki yüksek fiyatlarına rağmen yüksek tercih edilebilirlik sınıfında yer almıştır. Bu durum, söz konusu araçların performans, teknoloji ve donanım özelliklerinin fiyatlarına oranla oldukça tatmin edici düzeyde olmasıyla açıklanabilir. Yani fiyat yüksek olsa dahi, diğer kriterlerde sağlanan üst düzey performans bu maliyeti rasyonel kılmakta ve genel değerlendirmede aracı üst tercih edilebilirlik segmentine taşımaktadır.

Öte yandan, Fiat 500E 3+1 24 KWh, Dongfeng Box 31.4 KWh, Dacia Spring Electric 45, Opel Frontera 44 KWh, MG4 Electric 51 KWh, Skoda Elroq 50 ve Lynkco 02 gibi bazı araçlar, düşük fiyatlı olmalarına rağmen düşük tercih edilebilirlik sınıfında kalmıştır. Bu araçların tamamı 40.000 USD altında fiyatlandırılmıştır. Ancak analiz sonucunda, fiyat avantajına rağmen diğer kriterlerde (örneğin menzil, sürat, batarya kapasitesi, boyutsal özellikleri gibi) sağlanan performansın yetersiz olduğu görülmektedir. Bu bağlamda, düşük maliyetin tek başına yeterli olmadığı, tüketicinin bütüncül beklentilerini karşılayamayan modellerin tercih edilebilirlik açısından alt sıralarda kaldığı söylenebilir.

Sonuç olarak, TOPSIS-Sort-B algoritmasıyla yapılan bu çok kriterli değerlendirme; fiyatın önemli bir kriter olduğunu, ancak tek başına belirleyici olmadığını, dolayısıyla

araçların toplam özellik profili üzerinden yapılan kapsamlı bir analizle daha tutarlı sonuçlar elde edilebileceğini ortaya koymuştur.

4.4 Makine Öğrenmesi ile Sınıf Tahmini

TOPSIS-Sort-B algoritması ile elde edilen tercih edilebilirlik sınıfları, çalışmanın bu bölümünde birer hedef değişken olarak kullanılmış ve çeşitli makine öğrenmesi algoritmaları aracılığıyla bu sınıfların tahmin edilebilirliği test edilmiştir. Bu süreçte amaç, elektrikli araçlara ait teknik ve yapısal özelliklerden yola çıkarak, bir modelin aracı doğru tercih sınıfına atayıp atayamayacağını belirlemektir. Böylelikle hem geliştirilen çok kriterli karar modelinin doğruluğu dolaylı olarak sınanmakta hem de karar vericilere gelecekteki ürün analizlerinde yardımcı olabilecek öngörücü bir modelleme yaklaşımı sunulmaktadır. Bu bağlamda sınıflandırma problemlerine özgü çeşitli denetimli öğrenme algoritmaları uygulanmış ve modellerin başarımı farklı performans ölçütleri ile karşılaştırılmıştır.

4.4.1 Kullanılan algoritmalar ve modelleme süreci

Modelleme süreci kapsamında ilk olarak veri kümesi eğitim ve test olmak üzere ikiye ayrılmıştır. Bu ayrım, literatürde en yaygın kullanılan oranlardan biri olan %80 eğitim ve %20 test bölüşümüne göre gerçekleştirilmiştir. Bu oran, modelin yeterli miktarda veriden öğrenmesini sağlarken, test verisi üzerinde de anlamlı bir değerlendirme yapılabilmesine olanak tanımaktadır. Ancak salt rastgele bir bölme yerine, sınıflar arası dengenin korunması amacıyla tabakalı (stratified) bölme yöntemi tercih edilmiştir. Böylece düşük, orta ve yüksek tercih edilebilirliğe sahip araçlar test kümesinde de veri setindeki oransal yapıyı koruyacak şekilde temsil edilmiş, bu sayede model değerlendirme sürecinde oluşabilecek sınıfsal yanlılıkların önüne geçilmiştir.

Modelleme süreci kapsamında, TOPSIS-Sort-B tabanlı etiket sütunu hedef değişken (label) olarak seçilmiş, açıklayıcı değişkenler olarak ise bu etiketlerin dışında kalan sayısal öznitelikler kullanılmıştır. Veri ön işleme sürecinde, algoritmaların girdilerden etkili biçimde öğrenebilmesini sağlamak amacıyla standartlaştırma (standardizasyon) işlemi uygulanmıştır. Özellikle Öklid uzaklığı temelli algoritmalarda (örneğin; K-En Yakın Komşu, Lojistik Regresyon, SVM, Yapay Sinir Ağları) değişkenlerin benzer ölçeklerde olması gerektiğinden, StandardScaler yöntemiyle tüm değişkenler sıfır

ortalamalı ve birim standart sapmalı hale getirilmiştir. Karar Ağaçları algoritması bu tür ön işleme duyarlı olmadığından, bu modelde ham değerler kullanılmıştır.

Modelleme aşamasında altı farklı denetimli öğrenme algoritması uygulanmıştır. Bu algoritmalarda kullanılan hiperparametreler şöyledir:

- Karar Ağaçları:
 - Ayırma ölçütü: gini
 - Maksimum derinlik: Otomatik belirlenir
 - Bir dalın ikiye ayrılması için gereken minimum örnek sayısı: 2
 - Bir yaprak düğümde bulunması gereken minimum örnek sayısı: 1
- Lojistik Regresyon:
 - Çok sınıflı durumlar için sınıflandırma stratejisi: 'multinomial'
 - Optimizasyon algoritması (çözücü): lbfgs
 - Düzenleme parametresi (C): 1.0
 - Maksimum iterasyon sayısı: 100
- Naive Bayes:
 - Varyans düzeltme katsayısı (sayısal kararlılık için): 1e-9
- K-En Yakın Komşu:
 - Komşu sayısı: 5
 - Ağırlıklandırma yöntemi: uniform (her komşu eşit ağırlıkta)
 - Mesafe metriği: minkowski
 - $p=2$ (Öklid uzaklığı)
- Destek Vektör Makineleri:
 - Çekirdek (kernel) fonksiyonu: rbf (radial basis function)
 - C parametresi (hata toleransı/düzenleme katsayısı): 1.0
 - Gamma (çekirdek fonksiyonu parametresi): scale (veriye göre otomatik hesaplanır)

- Yapay Sinir Ağları: Katmanlar üzerinden öğrenme sağlayan, doğrusal olmayan ilişkileri modelleyebilen esnek bir algoritmadır.
 - Gizli katman yapısı: (100,) (tek gizli katman, 100 nöron)
 - Aktivasyon fonksiyonu: relu
 - Optimizasyon algoritması (çözücü): adam
 - L2 düzenleme katsayısı (alpha): 0.0001
 - Maksimum iterasyon sayısı: 200

Tüm modeller Python programlama dili ile, ağırlıklı olarak scikit-learn kütüphanesi kullanılarak uygulanmıştır. Eğitim süreci tamamlandıktan sonra, test kümesi üzerinde tahminlemeler yapılmış ve model performansları değerlendirilmiştir.

4.4.2 Performans değerlendirme ve sonuçlar

Model karşılaştırmalarında yalnızca doğruluk oranı değil, aynı zamanda sınıf dengesini gözeten doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1-skoru gibi metrikler de hesaplanmıştır. Bu metrikler, sınıflar arasındaki dengesizliklerin etkisini minimize etmek amacıyla ağırlıklı ortalama yöntemiyle değerlendirilmiştir. Ayrıca her bir model için karışıklık matrisi (confusion matrix) oluşturulmuş ve bu matrisler görselleştirilerek sınıflandırma başarısının hangi sınıflarda yoğunlaştığı analiz edilmiştir. Tüm bu modellere ait metriklerin tamamı Çizelge 4.5'te özetlenmiştir. Ek olarak, her modelin test veri kümesine yaptığı tahminler ayrı sütunlar halinde test kümesine eklenmiştir. Bu sayede modellerin çıktıları sonraki analiz veya görselleştirme adımları için tekrar kullanılabilir hale getirilmiştir.


Çizelge 4.5: Performans metrikleri.

Model	Doğruluk	Kesinlik	Duyarlılık	F1-Skoru
Karar Ağacı	0.932	0.935	0.932	0.932
Lojistik Regresyon	0.955	0.959	0.955	0.955
Naive Bayes	0.852	0.853	0.852	0.851
K-En Yakın Komşu	0.898	0.898	0.898	0.898
DVM	0.932	0.933	0.932	0.931
YSA	0.966	0.966	0.966	0.966


Toplamda 439 elektrikli araç verisiyle çalışılmış olup, bu veri kümesi %80–%20 oranında eğitim ve test verileri olmak üzere ikiye ayrılmıştır. Bu kapsamda, 351 araçlık

eğitim verisi ile modeller eğitilmiş, 88 araçlık test verisi ile ise değerlendirme yapılmıştır. Verinin görece küçük olması bazı algoritmalar için sınırlayıcı olmuş olabileceği düşünülmektedir. Özellikle yapay sinir ağı gibi daha yüksek veri hacmiyle daha iyi performans sergileyebilen modellerin, buna rağmen diğer yöntemlerin tamamından daha yüksek performans göstermesi dikkat çekicidir. YSA modeli, yalnızca F1-skoru değil, aynı zamanda doğruluk, kesinlik ve duyarlılık metriklerinde de en yüksek değere ulaşmıştır. Bu sonuç, YSA modelinin bu veri setinde en güçlü sınıflandırma başarısına sahip olduğunu göstermektedir.

Öte yandan, Naive Bayes algoritması, tüm metrikler açısından en düşük performansı sergilemiş ve bu bağlamda en zayıf model olarak değerlendirilmiştir. Bu durum, Naive Bayes'in temel varsayımlarının (özelliklerin birbirinden bağımsız olması gibi) bu veri kümesi üzerinde yeterince sağlanamamasından kaynaklanıyor olabilir. Örnek olması açısından, en başarılı model olan YSA ve en zayıf kalan Naive Bayes algoritmalarına ait karışıklık matrisleri sırasıyla Şekil 4.5 ve Şekil 4.6'da sunulmuştur.



Şekil 4.5: Yapay sinir ağı modelinin karışıklık matrisi.



Şekil 4.6: Naive Bayes modelinin karışıklık matrisi.

Tüm modellerin %85'in üzerinde bir başarı sergilemiş olması, yalnızca kullanılan makine öğrenmesi algoritmalarının değil, aynı zamanda sıralı sınıflandırma sürecinde uygulanan etiketleme stratejisinin de etkili olduğunu göstermektedir. Özellikle TOPSIS-Sort-B yöntemiyle yapılan sınıf etiketlemesinin, gözlemler arasındaki yapısal örüntüleri anlamlı bir şekilde yansıttığı ve bu nedenle sınıflandırma algoritmalarına uygun bir öğrenme zemini sunduğu söylenebilir. Etiketleme süreci hatalı veya anlamsız olsaydı, bu durum doğrudan sınıflandırma performansına da yansıtacak ve genel başarı oranları daha düşük seviyelerde kalacaktı. Dolayısıyla, elde edilen yüksek performans değerleri, etiketleme yaklaşımının da doğruluğunu desteklemektedir.

Sonuç olarak, her bir modelin farklı özelliklerinden kaynaklanan avantaj ve dezavantajları göz önüne alındığında, YSA modelinin bu bağlamda en uygun yöntem olduğu söylenebilir. Ancak veri hacminin daha büyük olduğu durumlarda modeller arası performans farklarının daha belirgin ve güvenilir olacağı da unutulmamalıdır.

4.5 ÇKKV ve Makina Öğrenmesi Sonuçlarının Karşılaştırması

Bu bölümde, ÇKKV yöntemi olarak kullanılan TOPSIS-Sort-B algoritması ile denetimli makine öğrenmesi modellerinden elde edilen sınıflandırma sonuçları karşılaştırılmıştır. Amaç, makine öğrenmesi modellerinin ÇKKV temelli tercih edilebilirlik sınıflarını ne ölçüde doğru şekilde yeniden üretebildiğini değerlendirmektir. Bu bağlamda, her bir sınıflandırma modelinin hangi araçları doğru

ya da yanlış sınıflandırdığı detaylı olarak incelenmiş ve özellikle yüksek, orta ve düşük tercih edilebilirlik düzeylerinde gözlemlenen yanlış sınıflamalar analiz edilmiştir. Elde edilen bulgular, modellerin karar verme tutarlılığına dair derinlemesine bir perspektif sunmakta ve veri temelli otomatik sınıflandırma yaklaşımlarının ÇKKV tabanlı yöntemlerle olan uyumunu tartışmaya açmaktadır.

TOPSIS-Sort-B algoritması sonuçlarına göre yüksek tercih edilebilirlik düzeyinde sınıflandırılan araçlar arasında, bazı denetimli öğrenme modellerinin hatalı tahminlerde bulunduğu gözlemlenmiştir. Bu grupta yer alan Lucid Air Grand Touring, Nio Et7 Long Range, Tesla Model 3 Performance, BMW iX M60, Volkswagen ID.7 GTX, Zeekr 001 Performance AWD ve Volkswagen ID.7 Pro modelleri, en az bir makine öğrenmesi modeli tarafından yanlış sınıflandırılmıştır. Bu durum, modellerin yüksek tercih edilen araçların özelliklerini her zaman doğru şekilde öğrenemediğine işaret etmektedir.

Denetimli öğrenme modelleri bazında değerlendirildiğinde, yapay sinir ağları modeli yüksek tercih edilebilirlik sınıfındaki araçların tamamını doğru bir şekilde tahmin etmeyi başarmıştır. Karar ağacı modeli, Nio Et7 Long Range, Tesla Model 3 Performance ve Volkswagen ID.7 Pro araçlarını hatalı şekilde orta tercih edilebilirlik düzeyine yerleştirmiştir. Lojistik regresyon yalnızca Volkswagen ID.7 Pro modelini orta seviyede tahminleyerek hata yapmıştır. Diğer yandan, Naive Bayes ve DVM, hem Lucid Air Grand Touring hem de Volkswagen ID.7 Pro araçlarını yanlış tahminlemiştir. K-En Yakın Komşu modeli ise BMW iX M60, Volkswagen ID.7 GTX ve Zeekr 001 Performance AWD araçlarını hatalı şekilde sınıflandırmıştır.

Bu analizde özellikle Volkswagen ID.7 Pro modeli dikkat çekmektedir; çünkü altı modelden dördü bu aracı yanlış sınıflandırmıştır. Modelin maksimum sürat, batarya mimarisi, V2L desteği eksikliği, toplam bagaj hacmi ve koltuk sayısı gibi kriterlerde bazı üst düzey modellere kıyasla nispeten zayıf kalması, modellerin bu aracı orta tercih edilebilirlik düzeyine kaydırmasına sebep olmuş olabilir. Bu durum, makine öğrenmesi modellerinin bazı teknik ya da donanımsal farklılıklara karşı duyarlılığını göstermesi açısından anlamlıdır.

Orta tercih edilebilirlik düzeyinde sınıflandırılan araçlar incelendiğinde, BMW i7 eDrive50, BMW i5 M60 xDrive Sedan, Nio ET5 Standard Range, KGM Torres EVX, Kia EV6 Standard Range 2WD, BYD Dolphin 44.9 kWh Active, Opel Zafira-e Life L2 75 kWh, Toyota Proace Verso M 75 kWh ve Renault Kangoo Grand E-Tech

Electric modellerinin en az bir denetimli öğrenme modeli tarafından yanlış sınıflandırıldığı görülmektedir. Bu durum, orta sınıf araçların sınıflandırılmasının diğer gruplara kıyasla daha fazla model tarafından zorlandığını göstermektedir.

Bu gruptaki araçların tamamını doğru şekilde tahmin edebilen tek model lojistik regresyon olmuştur. Karar ağacı modeli, KGM Torres EVX ve Renault Kangoo Grand E-Tech Electric modellerini yanlış şekilde düşük tercih edilebilirlik düzeyine yerleştirmiştir. En fazla hata yapan model ise Naive Bayes olmuş; BMW i7 eDrive50, BMW i5 M60 xDrive Sedan, Nio ET5 Standard Range, KGM Torres EVX araçlarını yüksek, BYD Dolphin 44.9 kWh Active, Opel Zafira-e Life L2 75 kWh, Toyota Proace Verso M 75 kWh ve Renault Kangoo Grand E-Tech Electric araçlarını ise düşük tercih edilebilirlik seviyesine yerleştirerek oldukça fazla hata yapmıştır. K-En Yakın Komşu algoritması da benzer şekilde, KGM Torres EVX ve Kia EV6 Standard Range 2WD modellerini yüksek seviyede, BYD Dolphin 44.9 kWh Active ve Renault Kangoo Grand E-Tech Electric modellerini düşük seviyede tahminlemiştir. Destek vektör makineleri, BMW i7 eDrive50 modelini yüksek seviyede, KGM Torres EVX, BYD Dolphin 44.9 kWh Active ve Renault Kangoo Grand E-Tech Electric modellerini düşük seviyede tahminlemiştir. Son olarak, Yapay sinir ağı ise BMW i7 eDrive50'yi yüksek, Renault Kangoo Grand E-Tech Electric modelini ise düşük tercih edilebilirlikte sınıflandırarak hata yapmıştır.

Bu araçlar arasında Renault Kangoo Grand E-Tech Electric modeli özellikle dikkat çekmektedir; zira lojistik regresyon dışında tüm modeller bu aracı düşük tercih edilebilir sınıfa yerleştirmiştir. Aracın maksimum sürat değerinin düşük olması ve elektrikli araçlara özel bir platform yerine geleneksel içten yanmalı platform üzerinden geliştirilmiş olması, bu tür bir sınıflandırma eğilimini tetiklemiş olabilir. Bu durum, orta sınıftaki bazı araçların teknik özellikleri nedeniyle düşük sınıfa kaydırıldığını ve modellerin bu nüanslara karşı oldukça duyarlı olduğunu göstermektedir.

Düşük tercih edilebilirlik sınıfına TOPSIS-Sort-B yöntemine göre dahil edilen araçlar incelendiğinde, GWM Ora 07 GT, Lynkco 02, Lexus UX 300e ve Skoda Elroq 50 modellerinin en az bir denetimli öğrenme modeli tarafından hatalı şekilde farklı bir sınıfa atandığı görülmektedir. Bu durum, her ne kadar düşük tercih edilebilirlik seviyesi teknik açıdan daha ayırt edici gibi görünse de, bazı modellerin bu gruptaki araçları farklı sınıflara yönlendirme eğilimi gösterdiğini ortaya koymaktadır.

Bu gruptaki tüm araçları doğru tahmin eden tek yöntem destek vektör makineleri olmuştur. Diğer yandan karar ağacı yalnızca GWM Ora 07 GT aracını hatalı sınıflandırarak orta seviyeye taşımıştır. Lojistik regresyon, GWM Ora 07 GT, Lynkco 02 ve Lexus UX 300e modellerini orta tercih edilebilirlik düzeyine koyarak üç araçta hata yapmıştır. Naive Bayes, Lynkco 02 ve Škoda Elroq 50 modellerini orta seviyeye, Lexus UX 300e'yi ise yüksek seviyeye yerleştirmiştir. KNN algoritması da benzer şekilde Lexus UX 300e'yi yüksek seviyede, Skoda Elroq 50'yi ise orta seviyede tahminlemiştir. Yapay sinir ağı ise yalnızca Lexus UX 300e aracını orta tercih edilebilir olarak etiketlemiştir.

Bu araçlar arasında özellikle Lexus UX 300e modeli öne çıkmaktadır. Çünkü bu araç iki model tarafından düşük, iki model tarafından orta ve iki model tarafından da yüksek tercih edilebilirlikte olarak tahmin edilmiştir. Bu kadar geniş bir yelpazede tahminlenen nadir araçlardan biri olması, modelin sınıflandırma açısından ne denli sınırdaki bir profil çizdiğini göstermektedir. Aracın elektrikli araçlara özgü platforma sahip olmaması, ısı pompası, çekici özelliği ve V2L desteği gibi unsurların eksikliği, düşük tercih edilebilirliğe işaret eden unsurlar arasındayken; buna karşın batarya garanti süresi ve garanti mesafesinin uzun olması, ayrıca tatmin edici şarj hızı, bazı modellerin bu aracı yüksek tercih edilebilirlik sınıfına almasına neden olmuş olabilir. Bu durum, çok boyutlu özelliklerin sınıflandırma modelleri üzerindeki etkisini açıkça ortaya koymaktadır.

Tüm araçların sıralı sınıflandırmaya ilişkin etiket verileri ve test verisinde yer alan araçların makine öğrenmesi metotları çerçevesinde tahmin edilen sınıf değerleri ekte verilmiştir.

Tüm bu bulgular, TOPSIS-Sort-B gibi çok kriterli karar verme yöntemleri ile makine öğrenmesi tabanlı sınıflandırma modelleri arasında karar mekanizması bakımından temel farklar olabileceğini göstermektedir. ÇKKV yöntemleri, önceden belirlenmiş kriter ağırlıkları ve yapısal tercih kuralları çerçevesinde tutarlı sonuçlar üretirken; makine öğrenmesi modelleri verideki örüntülere dayanarak öğrenme yapar ve bu nedenle özellikle sınırdaki yer alan örneklerde farklı sınıflandırma eğilimleri sergileyebilir. Bu durum, her iki yaklaşımın birbirini tamamlayıcı şekilde değerlendirilmesi gerektiğini ortaya koymaktadır. Ayrıca, kullanılan veri setindeki gözlem sayısının görece sınırlı olması da, özellikle sınırdaki yer alan araçların tahmininde model hatalarının artmasına neden olmuş olabilir.

5. TARTIŞMA VE SONUÇ

Son yıllarda sürdürülebilirlik hedeflerinin küresel ölçekte öncelik kazanması, ulaşım sektörünü de ciddi biçimde dönüştürmeye başlamıştır. Bu dönüşümün en somut yansımalarından biri ise içten yanmalı motorlu araçlardan elektrikli araçlara geçiş sürecidir. Karbon emisyonlarını azaltma, enerji verimliliğini artırma ve uzun vadede ekonomik sürdürülebilirlik sağlama gibi nedenlerle, elektrikli araçların bireysel ve kamusal ulaşımında giderek daha fazla tercih edildiği gözlemlenmektedir. Bu gelişmelere paralel olarak, pazarda yer alan çok sayıda elektrikli araç alternatifi arasından seçim yapmak da giderek daha karmaşık bir hâl almıştır. Bu karmaşıklığın temelinde ise, her bir aracın farklı teknik, ekonomik ve donanımsal özelliklere sahip olması ve kullanıcıların bu kriterler doğrultusunda farklı tercih önceliklerine sahip olması yatmaktadır (Hawkins vd., 2013; Sonar ve Kulkarni, 2021; Higuera-Castillo vd., 2021). Bir kullanıcı için menzile kritik önemdeyken, diğeri için hızlanma performansı veya şarj altyapısıyla uyumluluk daha belirleyici olabilmektedir. Bunun yanı sıra, elektrikli araçların satış fiyatları, işletim maliyetleri, bakım-onarım gereksinimleri ve yeniden satış değerleri gibi ekonomik faktörler de karar verme süreçlerini doğrudan etkilemektedir. Bu çok boyutlu değerlendirme ihtiyacı, tüketicilerin optimal seçim yapabilmeleri için sistematik yaklaşımlara duyulan talebi artırmıştır.

Bu tez çalışması, söz konusu karmaşıklığı anlamlandırmak ve elektrikli araçların tercih edilebilirlik açısından nasıl sınıflandırılabilirliğini ortaya koymak amacıyla gerçekleştirilmiştir. Bu doğrultuda, çok kriterli karar verme yöntemlerinden biri olan TOPSIS-Sort-B algoritması kullanılarak araçlar üç ayrı tercih düzeyine göre sınıflandırılmıştır. TOPSIS-Sort-B'nin seçimindeki temel neden, sınıflandırma temelli karar problemlerine uygunluğu ve belirli eşik değerler aracılığıyla alternatiflerin kategorilere atanmasına olanak sağlamasıdır. Geleneksel TOPSIS yönteminden farklı olarak, TOPSIS-Sort-B alternatifleri önceden tanımlanmış sıralı sınıflara atar ve böylelikle karşılaştırmalı sıralama yerine değerlendirme yapılmasına imkan tanır. Ayrıca, sıralı sınıflandırma yöntemleri uzman görüşlerinden faydalanarak çok sayıda

alternatif için dahi kabul edilebilir bir çabayla sınıfların (etiketlerin) elde edilmesini mümkün kılmakta, bu sınıflar da tercih edilebilirlik açısından kendi aralarında sıralanarak makine öğrenmesine dayalı sınıflandırma algoritmalarına göre ek bilgi sunmaktadır.

Elde edilen sınıflandırma etiketleri, çalışmanın ikinci aşamasında birer denetimli öğrenme verisi olarak kullanılmış ve böylelikle çeşitli makine öğrenmesi algoritmaları ile sınıflandırma yapılması mümkün hâle gelmiştir. Bu yönüyle çalışma, bir yandan ÇKKV ve makine öğrenmesi yaklaşımlarını birleştiren hibrit bir yapı önermekte; diğer yandan da her iki yaklaşımın sınıflama çıktılarındaki örtüşme düzeyini irdelemektedir. Bu bağlamda, ÇKKV temelli sıralı sınıflandırma yöntemleri, makine öğrenmesi algoritmalarının ihtiyaç duyduğu etiketli veriyi sağlayarak etiketleme sürecinin daha etkin ve verimli yürütülmesine katkı sunmaktadır.

Makine öğrenmesi aşamasında veriler, eğitim ve test olmak üzere ikiye ayrılmış; etiketli eğitim verisiyle modeller eğitilmiş ve test verisi üzerinden doğruluk ile F1-skoru bazlı performans değerlendirmesi yapılmıştır. Bu bağlamda Yapay Sinir Ağı modeli, hem doğruluk oranı hem de F1-skoru açısından en yüksek başarıyı göstermiştir. Karar ağacı, destek vektör makinesi ve lojistik regresyon gibi diğer sınıflandırıcı modellerin de genel anlamda yüksek performans sergilediği ve test veri setindeki araçların büyük bir kısmının tüm modeller tarafından doğru şekilde tahminlendiği görülmüştür. Bu sonuç, TOPSIS-Sort-B algoritması ile oluşturulan etiketlerin makine öğrenmesi açısından tutarlı ve genellenebilir olduğunu göstermektedir. Ayrıca sorting tabanlı geleneksel ÇKKV yöntemlerinin, uygun bir etiketleme aracı olarak denetimli öğrenme modelleriyle başarılı biçimde bütünleşebileceğini ortaya koymaktadır. Öte yandan, makine öğrenmesi algoritmaları ile yeni gözlemlerin sınıflandırılması kolaylaşmakta; öngörülen sınıflar yalnızca teknik bir çıktı olmanın ötesine geçerek tercih edilebilirlik açısından da anlam taşımaktadır.

Normal şartlarda sıralı sınıflandırma için makine öğrenmesi kapsamında daha karmaşık model ve algoritmaların kullanılması gerekirken, bu hibrit yaklaşım hem etiketleme hem de öngörü süreçlerinin etkinliğini ve verimliliğini artırmakta; daha basit yöntemlerle de yüksek doğruluk oranları elde edilebileceğini göstermektedir.

Genel olarak bu çalışma, elektrikli araçların tercih edilebilirliğine ilişkin sınıflama sorununu hem karar verme kuramı hem de veri bilimi perspektifiyle ele almış; bu iki

yaklaşımın bir arada nasıl çalışabileceğine dair ampirik bir örnek sunmuştur. Bulgular, yalnızca akademik anlamda değil; aynı zamanda tüketici odaklı karar destek sistemlerinin geliştirilmesi, otomotiv endüstrisinin pazar segmentasyonu stratejileri ve politika yapıcılarının elektrikli araç teşvik programlarının tasarlanması açısından da potansiyel uygulama alanları taşımaktadır. Bu hibrit yaklaşım, gelecekte diğer sektörlerdeki karmaşık sınıflandırma problemlerine de uyarlanabilir ve böylelikle interdisipliner araştırma alanları için metodolojik katkı sağlayabilir.

5.1 Çıkarımlar ve Teorik Katkılar

Bu tez kapsamında elde edilen bulgular, hem akademik literatüre katkı sağlamakta, hem de sektörel anlamda üreticiler, pazarlamacılar ve nihai kullanıcılar açısından da çeşitli pratik çıkarımlar sunmaktadır. Öncelikle, elektrikli araç pazarının giderek genişlemesi ve teknik özelliklerin çeşitlenmesi, ürünlerin karşılaştırılmasını ve uygun hedef kitleye sunulmasını zorlaştırmaktadır. Farklı menzil, batarya kapasitesi, şarj süresi, azami hız, güvenlik donanımı gibi çok sayıda özelliğin aynı anda değerlendirilmesi gerektiğinde, hangi aracın hangi kullanıcı profiline uygun olduğu sorusu daha karmaşık bir hâl almaktadır. Bu noktada tezde önerilen yaklaşım, araçları çok kriterli karar verme mantığıyla anlamlı gruplara (yüksek, orta, düşük tercih edilebilirlik) ayırarak hem analiz kolaylığı sağlamakta hem de bu ayrımı makine öğrenmesi modelleriyle genişletilebilir hâle getirmektedir.

Üreticiler ve pazarlamacılar açısından, bu sınıflama sistemi belirli araç modellerinin hangi tercih sınıfında konumlandığını görmelerine imkân tanımaktadır. Örneğin, düşük tercih edilebilirlik sınıfına düşen araçların hangi kriterlerde zayıf kaldığı analiz edilerek ürün geliştirme stratejileri yeniden şekillendirilebilir. Aynı şekilde, tüketicilerin farklı ihtiyaç ve beklentilerine göre tasarlanmış filtreleme sistemleri, bu tür sınıflamalardan beslenerek daha kullanıcı dostu hâle getirilebilir. Böylelikle, ürün ile kullanıcı arasındaki eşleşme süreci daha rasyonel bir zemine oturtulabilir. Ek olarak, bu sınıflama sistemi üzerinden fiyatlandırma politikalarının da optimize edilmesi mümkündür. Özellikle benzer segmentte yer alan araçlar arasında rekabet avantajı sağlanması adına, fiyat-performans ilişkisi çok daha sağlıklı biçimde değerlendirilebilir.

Teorik bağlamda bu çalışma, elektrikli araçların çok sayıda teknik ve performans özelliği doğrultusunda sıralı sınıflandırma esaslı bir segmentasyona tabi tutulmasına

yönelik literatürdeki sınırlı örneklerden biri olma niteliğindedir. Özellikle TOPSIS-Sort-B algoritmasının bu bağlamda kullanılması, mevcut sınıflandırma temelli karar verme yöntemlerinin elektrikli araçlar pazarına uygulanabilirliğine dair önemli bir katkı sunmaktadır. Literatürde genellikle bireysel alternatiflerin sıralanması veya ikili karşılaştırmalar yapılırken, bu çalışmada belirli eşik değerler çerçevesinde gruplandırma yapılması, elektrikli araçlar segmentasyonu açısından özgün bir yaklaşım ortaya koymaktadır. Dahası, sıralı sınıflandırma yönteminin çıktılarının makine öğrenmesi ile ilişkilendirilmesi, ÇKKV yöntemlerinin denetimli öğrenme çerçevesinde nasıl yeniden işlevselleştirilebileceğine dair önemli bir metodolojik tartışma zemini sunmaktadır.

Bu yönüyle tez, yalnızca elektrikli araç pazarıyla sınırlı kalmamakta, aynı zamanda çok kriterli karar verme ile yapay zekâ temelli yaklaşımlar arasında köprü kuran hibrit bir metodolojinin uygulanabilirliğini göstermektedir. Bu metodoloji, farklı sektörlerdeki ürün segmentasyonu, müşteri sınıflaması veya öneri sistemleri gibi bağlamlara da uyarlanabilir olup, gelecekte çok yönlü akademik ve sektörel uygulamalara ilham verebilecek potansiyele sahiptir.

5.2 Kısıtlar ve Sonraki Çalışmalara Öneriler

Bu çalışma, elektrikli araçların tercih edilebilirlik açısından sınıflandırılmasına yönelik olarak kapsamlı ve sistematik bir yaklaşım sunmakla birlikte, bazı sınırlılıkları da beraberinde taşımaktadır. İlk olarak, analizde kullanılan veriler, hâlihazırda internetteki en kapsamlı elektrikli araç veritabanlarından biri olan EVDatabase platformundan temin edilmiştir (EVDatabase, 2025). Ancak elektrikli araç sektörünün oldukça hızlı geliştiği ve üretici firmaların sürekli olarak yeni modeller piyasaya sürdüğü göz önüne alındığında, kullanılan veri setinin tam anlamıyla güncel tüm araçları kapsadığını söylemek mümkün değildir. Üstelik bu veriler çalışmanın başlangıcında, yaklaşık dört ay önce derlenmiş olup, bu süreçte EVDatabase veritabanına yeni modellerin eklenmiş olabileceği ihtimali de dikkate alınmalıdır. Bu nedenle, analiz kapsamındaki 439 araç üzerinden elde edilen bulgular, veri kümesinin temsili gücüne bağlı olarak değerlendirilmelidir.

Bir diğer sınırlılık, tercih edilebilirlik segmentlerinin belirlenmesinde kullanılan TOPSIS-Sort-B algoritmasının belirli varsayımlar altında çalışıyor olmasıdır. Özellikle eşik değerlerin belirlenmesi istatistiksel olarak anlamlı olsa da, bu değerlerin

farklı yöntemlerle türetilmesi durumunda segmentasyon çıktıları değişebilir. Ayrıca, makine öğrenmesi modelleri için kullanılan train-test ayrımı, veri kümesinin homojenliği varsayımına dayanmaktadır. Gerçek dünyada ise kullanıcı tercihlerinin bölgesel, kültürel veya sosyoekonomik faktörlere göre değişiklik gösterebileceği göz önünde bulundurulmalıdır.

Bu çalışmada dikkate alınan özellikler daha çok teknik, donanımsal ve performans odaklıdır. Ancak gelecek çalışmalarda, fren mesafesi, çarpışma testlerinden elde edilen güvenlik puanları, yol tutuş, servis ağı genişliği, garanti kapsamı gibi başka özelliklerin de dahil edilmesi, tercih edilebilirlik analizlerini daha bütüncül bir perspektife taşıyabilir. Ayrıca, çalışmada ağırlıklı olarak sayısal nitelikler ele alınmış olsa da, kategorik verilerle daha esnek çalışabilecek yaklaşımların kullanılması, modellerin farklı veri türleri karşısındaki başarısını artırabilir.

Gelecek çalışmalarda, daha dinamik ve güncel veri kaynaklarının kullanılması, analizlerin doğruluğunu ve genellenebilirliğini artıracaktır. Ayrıca kullanıcı temelli verilerin (örneğin kullanıcı puanları, yorumlar, satış rakamları gibi) entegre edilmesi, tercih edilebilirlik sınıflandırmasının daha zengin bir bağlamda yapılmasına olanak tanıyabilir. Diğer yandan, bu çalışmada kullanılan hibrit yaklaşım farklı ÇKKV ve denetimli öğrenme yöntemleriyle karşılaştırmalı olarak yeniden denenebilir. Farklı segmentasyon teknikleriyle sonuçların ne ölçüde tutarlı olduğu incelenebilir. Son olarak, önerilen modelin gerçek dünyada bir öneri sistemine entegre edilmesi, hem akademik hem de endüstriyel anlamda önemli katkılar sağlayacaktır.

KAYNAKÇA

- Adhikari, D., Jiang, W., Zhan, J., He, Z., Rawat, D. B., Aickelin, U., & Khorshidi, H. A.** (2022). A comprehensive survey on imputation of missing data in internet of things. *ACM Computing Surveys*, 55(7), 1-38.
- Aghabali, I., Bauman, J., Kollmeyer, P. J., Wang, Y., Bilgin, B., & Emadi, A.** (2020). 800-V electric vehicle powertrains: Review and analysis of benefits, challenges, and future trends. *IEEE Transactions on Transportation Electrification*, 7(3), 927-948.
- Alasadi, S. A., & Bhaya, W. S.** (2017). Review of data preprocessing techniques in data mining. *Journal of Engineering and Applied Sciences*, 12(16), 4102-4107.
- Albayrak Ünal, Ö., & ErKayman, B.** (2023). Multi-criteria Inventory Classification with Machine Learning Algorithms in the Manufacturing Industry. In *International Conference on Optimization and Data Science in Industrial Engineering* (pp. 86-103). Cham: Springer Nature Switzerland.
- Ali, P. J. M., Faraj, R. H., Koya, E., Ali, P. J. M., & Faraj, R. H.** (2014). Data normalization and standardization: a technical report. *Mach Learn Tech Rep*, 1(1), 1-6.
- Alnuaimi, A. F., & Albaldawi, T. H.** (2024). An overview of machine learning classification techniques. In *BIO Web of Conferences* (Vol. 97, p. 00133). EDP Sciences.
- Alvarez, P. A., Ishizaka, A., & Martinez, L.** (2021). Multiple-criteria decision-making sorting methods: A survey. *Expert Systems with Applications*, 183, 115368.
- Bas, J., Cirillo, C., & Cherchi, E.** (2021). Classification of potential electric vehicle purchasers: A machine learning approach. *Technological Forecasting and Social Change*, 168, 120759.
- Behzadian, M., Otaghsara, S. K., Yazdani, M., & Ignatius, J.** (2012). A state-of-the-art survey of TOPSIS applications. *Expert Systems with applications*, 39(17), 13051-13069.
- Belton, V., & Stewart, T.** (2012). *Multiple criteria decision analysis: an integrated approach*. Springer Science & Business Media.
- BloombergNEF** (2023). *Electric Vehicle Outlook 2023*. <https://about.bnef.com/electric-vehicle-outlook/>
- Campos, A. C. S. M., Mareschal, B., & de Almeida, A. T.** (2015). Fuzzy FlowSort: An integration of the FlowSort method and Fuzzy Set Theory for decision making on the basis of inaccurate quantitative data. *Information sciences*, 293, 115-124.

- Cerda, P., Varoquaux, G., & Kegl, B.** (2018). Similarity encoding for learning with dirty categorical variables. *Machine Learning*, 107(8), 1477-1494.
- Chan, C. C.** (2007). The state of the art of electric, hybrid, and fuel cell vehicles. *Proceedings of the IEEE*, 95(4), 704-718.
- Chowdhury, S. J., Mahi, M. I., Saimon, S. A., Urme, A. N., & Nabil, R. H.** (2023). An Integrated Approach of MCDM Methods and Machine Learning Algorithms for Employees' Churn Prediction. In *2023 3rd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)* (pp. 68-73). IEEE.
- Corrente, S., Figueira, J. R., Greco, S., & Slowinski, R.** (2021). Multiple criteria decision support. *Handbook of Group Decision and Negotiation*, 893-920.
- Covas, M. T., Silva, C. A., & Dias, L. C.** (2013). Multicriteria decision analysis for sustainable data centers location. *International Transactions in Operational Research*, 20(3), 269-299.
- de Lima Silva, D. F., & de Almeida Filho, A. T.** (2020). Sorting with TOPSIS through boundary and characteristic profiles. *Computers & Industrial Engineering*, 141, 106328.
- de Lima Silva, D. F., Ferreira, L., & de Almeida Filho, A. T.** (2023). Preference disaggregation on TOPSIS for sorting applied to an economic freedom assessment. *Expert Systems With Applications*, 215, 119341.
- de Lima Silva, D. F., Ferreira, L., & de Almeida-Filho, A. T.** (2020). A new preference disaggregation TOPSIS approach applied to sort corporate bonds based on financial statements and expert's assessment. *Expert systems with applications*, 152, 113369.
- Demir, L., Akpınar, M. E., Araz, C., & Ilgin, M. A.** (2018). A green supplier evaluation system based on a new multi-criteria sorting method: VIKORSORT. *Expert Systems with Applications*, 114, 479-487.
- Dhillon, I. S., & Modha, D. S.** (2001). Concept decompositions for large sparse text data using clustering. *Machine learning*, 42, 143-175.
- Dias, L. C., & Mousseau, V.** (2003). IRIS: A DSS for multiple criteria sorting problems. *Journal of Multi-Criteria Decision Analysis*, 12(4-5), 285-298.
- Doumpos, M., & Zopounidis, C.** (2004). Developing sorting models using preference disaggregation analysis: An experimental investigation. *European Journal of Operational Research*, 154(3), 585-598.
- Doumpos, M., & Zopounidis, C.** (2006). *Multicriteria decision aid classification methods* (Vol. 73). Springer Science & Business Media.
- Ecer, F.** (2021). A consolidated MCDM framework for performance assessment of battery electric vehicles based on ranking strategies. *Renewable and Sustainable Energy Reviews*, 143, 110916.
- Egbue, O., & Long, S.** (2012). Barriers to widespread adoption of electric vehicles: An analysis of consumer attitudes and perceptions. *Energy policy*, 48, 717-729.

- Electric Vehicle Database.** (2025). EV Database: All electric vehicles in Europe, <https://ev-database.org/> (Eriřim: 04 Mayıs 2025).
- Emmanuel, T., Maupong, T., Mpoeleng, D., Semong, T., Mphago, B., & Tabona, O.** (2021). A survey on missing data in machine learning. *Journal of Big data*, 8, 1-37.
- Endel, F., & Piringer, H.** (2015). Data Wrangling: Making data useful again. *IFAC-PapersOnLine*, 48(1), 111-112.
- Estivill-Castro, V., & Yang, J.** (2000). Fast and robust general purpose clustering algorithms. In *Pacific Rim International Conference on Artificial Intelligence* (pp. 208-218). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Fadel, F. H., & Behadili, S. F.** (2022). A comparative study for supervised learning algorithms to analyze sentiment tweets. *Iraqi Journal of Science*, 2712-2724.
- Faraji Sabokbar, H., Hosseini, A., Banaitis, A., & Banaitiene, N.** (2016). A novel sorting method TOPSIS-SORT: an applicaiton for Tehran environmental quality evaluation.
- Fraley, C., & Raftery, A. E.** (1998). How many clusters? Which clustering method? Answers via model-based cluster analysis. *The computer journal*, 41(8), 578-588.
- Gal, M. S., & Rubinfeld, D. L.** (2019). Data standardization. *NYUL Rev.*, 94, 737.
- Garcia, S., Luengo, J., & Herrera, F.** (2015). *Data preprocessing in data mining* (Vol. 72, pp. 59-139). Cham, Switzerland: Springer International Publishing.
- Goebel, D., & Plötz, P.** (2019). Machine learning estimates of plug-in hybrid electric vehicle utility factors. *Transportation research part D: Transport and environment*, 72, 36-46.
- Grandini, M., Bagli, E., & Visani, G.** (2020). Metrics for multi-class classification: an overview. *arXiv preprint arXiv:2008.05756*.
- Greco, S., Kadzinski, M., & Slowinski, R.** (2011). Selection of a representative value function in robust multiple criteria sorting. *Computers & Operations Research*, 38(11), 1620-1637.
- Guarnieri, M.** (2012). Looking back to electric cars. In *2012 Third IEEE HISTory of ELection-technology CONFERENCE (HISTELCON)* (pp. 1-6). IEEE.
- Hajek, P., Sahut, J. M., & Olej, V.** (2024). Credit rating prediction using a fuzzy MCDM approach with criteria interactions and TOPSIS sorting. *Annals of Operations Research*, 1-29.
- Hameed, M., & Naumann, F.** (2020). Data preparation: A survey of commercial tools. *ACM SIGMOD Record*, 49(3), 18-29.
- Han, J.** (2009). Data mining. In *Encyclopedia of Database Systems* (pp. 595-598). Springer, Boston, MA.
- Hardman, S., Jenn, A., Tal, G., Axsen, J., Beard, G., Daina, N., ... & Witkamp, B.** (2018). A review of consumer preferences of and interactions with

- electric vehicle charging infrastructure. *Transportation Research Part D: Transport and Environment*, 62, 508-523.
- Hawkins, T. R., Singh, B., Majeau-Bettez, G., & Strømman, A. H.** (2013). Comparative environmental life cycle assessment of conventional and electric vehicles. *Journal of industrial ecology*, 17(1), 53-64.
- Hebert, J.** (2016). Predicting rare failure events using classification trees on large scale manufacturing data with complex interactions. In *2016 IEEE international conference on big data (big data)* (pp. 2024-2028). IEEE.
- Hernandez, S., Monzon, A., & De Ona, R.** (2016). Urban transport interchanges: A methodology for evaluating perceived quality. *Transportation Research Part A: Policy and Practice*, 84, 31-43.
- Higueras-Castillo, E., Guillén, A., Herrera, L. J., & Liébana-Cabanillas, F.** (2021). Adoption of electric vehicles: Which factors are really important. *International Journal of Sustainable Transportation*, 15(10), 799-813.
- Hossin, M., & Sulaiman, M. N.** (2015). A review on evaluation metrics for data classification evaluations. *International journal of data mining & knowledge management process*, 5(2), 1.
- Humaira, H., & Rasyidah, R.** (2020). Determining the appropriate cluster number using elbow method for k-means algorithm. In *Proceedings of the 2nd Workshop on Multidisciplinary and Applications (WMA)* (pp. 1-8).
- İnci, M., Büyük, M., Demir, M. H., & İlbey, G.** (2021). A review and research on fuel cell electric vehicles: Topologies, power electronic converters, energy management methods, technical challenges, marketing and future aspects. *Renewable and Sustainable Energy Reviews*, 137, 110648.
- International Energy Agency (IEA).** (2023). *Global EV Outlook 2023*. <https://www.iea.org/reports/global-ev-outlook-2023>
- Ishizaka, A., & Pereira, V.** (2020). Utilisation of ANPSort for sorting alternative with interdependent criteria illustrated through a researcher's classification problem in an academic context. *Soft Computing*, 24, 13639-13650.
- Ishizaka, A., Lolli, F., Balugani, E., Cavallieri, R., & Gamberini, R.** (2018). DEASort: Assigning items with data envelopment analysis in ABC classes. *International Journal of Production Economics*, 199, 7-15.
- Ishizaka, A., Pearman, C., & Nemery, P.** (2012). AHPSort: an AHP-based method for sorting problems. *International Journal of Production Research*, 50(17), 4767-4784.
- Ishizaka, A., Tasiou, M., & Martínez, L.** (2020). Analytic hierarchy process-fuzzy sorting: An analytic hierarchy process-based method for fuzzy classification in sorting problems. *Journal of the Operational Research Society*, 71(6), 928-947.
- Jadhav, S. D., & Channe, H. P.** (2016). Comparative study of K-NN, naive Bayes and decision tree classification techniques. *International Journal of Science and Research (IJSR)*, 5(1), 1842-1845.

- Jain, A. K., Murty, M. N., & Flynn, P. J.** (1999). Data clustering: a review. *ACM computing surveys (CSUR)*, 31(3), 264-323.
- Jarman, A. M.** (2020). Hierarchical cluster analysis: Comparison of single linkage, complete linkage, average linkage and centroid linkage method. *Georgia Southern University*, 29, 32.
- Joseph, V. R.** (2022). Optimal ratio for data splitting. *Statistical Analysis and Data Mining: The ASA Data Science Journal*, 15(4), 531-538.
- Kalcheva, N., Todorova, M., & Marinova, G.** (2020). Naive bayes classifier, decision tree and adaboost ensemble algorithm—advantages and disadvantages. In *Proceedings of the 6th ERAZ Conference Proceedings (part of ERAZ conference collection)*, Online (pp. 153-157).
- Karasakal, E., & Aker, P.** (2017). A multicriteria sorting approach based on data envelopment analysis for R&D project selection problem. *Omega*, 73, 79-92.
- Kartal, H., Oztekin, A., Gunasekaran, A., & Cebi, F.** (2016). An integrated decision analytic framework of machine learning with multi-criteria decision making for multi-attribute inventory classification. *Computers & Industrial Engineering*, 101, 599-613.
- Khan, J., Ishizaka, A., & Babai, M. Z.** (2025). Enhancing multi-criteria inventory classification: Resolving boundary issues with VIKOR-Fuzzy Sorting. *International Journal of Production Economics*, 281, 109526.
- Khodabakhshi, S., Habib, M. A. A., & Peng, W.** (2024). A decision-making system for medical transportation mode using machine learning methods. *Engineering Proceedings*, 76(1), 74.
- Kim, D., Kang, P., Cho, S., Lee, H. J., & Doh, S.** (2012). Machine learning-based novelty detection for faulty wafer detection in semiconductor manufacturing. *Expert Systems with Applications*, 39(4), 4075-4083.
- Köksal, G., Batmaz, I., & Testik, M. C.** (2011). A review of data mining applications for quality improvement in manufacturing industry. *Expert systems with Applications*, 38(10), 13448-13467.
- Köksalan, M., Mousseau, V., & Özpeynirci, S.** (2017). Multi-criteria sorting with category size restrictions. *International Journal of Information Technology & Decision Making*, 16(01), 5-23.
- Kotsiantis, S. B., Zaharakis, I., & Pintelas, P.** (2007). Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, 160(1), 3-24.
- Kumar, R.** (2025). A Comprehensive Review of MCDM Methods, Applications, and Emerging Trends. *Decision Making Advances*, 3(1), 185-199.
- Kwak, D. S., & Kim, K. J.** (2012). A data mining approach considering missing values for the optimization of semiconductor-manufacturing processes. *Expert Systems with Applications*, 39(3), 2590-2596.
- Li, L., Wang, Z., Chen, L., & Wang, Z.** (2020). Consumer preferences for battery electric vehicles: A choice experimental survey in China.

Transportation Research Part D: Transport and Environment, 78, 102185.

- Liao, H., He, Y., Wu, X., Wu, Z., & Bausys, R.** (2023). Reimagining multi-criterion decision making by data-driven methods based on machine learning: A literature review. *Information Fusion*, 100, 101970.
- Lieven, T., Mühlmeier, S., Henkel, S., & Waller, J. F.** (2011). Who will buy electric cars? An empirical study in Germany. *Transportation Research Part D: Transport and Environment*, 16(3), 236-243.
- Lin, W. C., & Tsai, C. F.** (2020). Missing value imputation: a review and analysis of the literature (2006–2017). *Artificial Intelligence Review*, 53, 1487-1509.
- Liu, Z., Liu, Y., Meng, Q., & Cheng, Q.** (2019). A tailored machine learning approach for urban transport network flow estimation. *Transportation Research Part C: Emerging Technologies*, 108, 130-150.
- Lopez, L. M., Ishizaka, A., Qin, J., & Alvarez-Carrillo, P. A.** (2023). *Multi-criteria decision-making sorting methods: applications to real-world problems*. Academic Press.
- Madhooshiarzanagh, P., & Abi-Zeid, I.** (2021). A disaggregation approach for indirect preference elicitation in Electre TRI-nC: Application and validation. *Journal of Multi-Criteria Decision Analysis*, 28(3-4), 144-159.
- Madhulatha, T. S.** (2012). An overview on clustering methods. *arXiv preprint arXiv:1205.1117*.
- Mardani, A., Jusoh, A., Nor, K., Khalifah, Z., Zakwan, N., & Valipour, A.** (2015). Multiple criteria decision-making techniques and their applications—a review of the literature from 2000 to 2014. *Economic research-Ekonomska istraživanja*, 28(1), 516-571.
- Mazhar, T., Asif, R. N., Malik, M. A., Nadeem, M. A., Haq, I., Iqbal, M., ... & Ashraf, S.** (2023). Electric vehicle charging system in the smart grid using different machine learning methods. *Sustainability*, 15(3), 2603.
- McLachlan, G. J.** (1999). Mahalanobis distance. *Resonance*, 4(6), 20-26.
- Miccoli, F., & Ishizaka, A.** (2017). Sorting municipalities in Umbria according to the risk of wolf attacks with AHPSort II. *Ecological Indicators*, 73, 741-755.
- Morgan, A.** (2025). The Latest EV Statistics and Trends, <https://www.marketwatch.com/insurance-services/auto-insurance/electric-vehicle-statistics/> (Erişim: 28 Nisan 2025).
- Nemery, P., & Lamboray, C.** (2008). FlowSort: a flow-based sorting method with limiting or central profiles. *Top*, 16(1), 90-113.
- Nemery, P., Ishizaka, A., Camargo, M., & Morel, L.** (2012). Enriching descriptive information in ranking and sorting problems with visualizations techniques. *Journal of Modelling in Management*, 7(2), 130-147.
- Pamucar, D., Ecer, F., & Deveci, M.** (2021). Assessment of alternative fuel vehicles for sustainable road transportation of United States using integrated

fuzzy FUCOM and neutrosophic fuzzy MARCOS methodology. *Science of the Total Environment*, 788, 147763.

- Peeri, N. C., Shrestha, N., Rahman, M. S., Zaki, R., Tan, Z., Bibi, S., ... & Haque, U.** (2020). The SARS, MERS and novel coronavirus (COVID-19) epidemics, the newest and biggest global health threats: what lessons have we learned. *International journal of epidemiology*, 49(3), 717-726.
- Pineda-Jaramillo, J. D.** (2019). A review of Machine Learning (ML) algorithms used for modeling travel mode choice. *Dyna*, 86(211), 32-41.
- Preeti, K. S., & Dhankar, A.** (2017). A review on machine learning techniques. *International Journal of Advanced Research in Computer Science*, 8(3), 778-882.
- Ram, A.** (2022). Short Review on Machine Learning and its Application. *Special Education*, 1(43).
- Ray, S.** (2019). A quick review of machine learning algorithms. In *2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon)* (pp. 35-39). IEEE.
- Rezvani, Z., Jansson, J., & Bodin, J.** (2015). Advances in consumer electric vehicle adoption research: A review and research agenda. *Transportation research part D: transport and environment*, 34, 122-136.
- Ritchie, H.** (2024). Tracking Global Data on Electric Vehicles, <https://ourworldindata.org/electric-car-sales> (Eriřim: 26 Nisan 2025).
- Rokach, L., & Maimon, O.** (2005). Clustering methods. *Data mining and knowledge discovery handbook*, 321-352.
- Roy, A., Islam, M., Karim, M., Ahmed, K. A., Khan, A. R., Uddin, M., & Xames, M. D.** (2023). Comparative analysis of KNN and SVM in multicriteria inventory classification using TOPSIS. *International Journal of Information Technology*, 15(7), 3613-3622.
- Saputra, D. M., Saputra, D., & Oswari, L. D.** (2020). Effect of distance metrics in determining k-value in k-means clustering using elbow and silhouette method. In *Sriwijaya international conference on information technology and its applications (SICONIAN 2019)* (pp. 341-346). Atlantis Press.
- Seeger, C.** (2018). An investigation of categorical variable encoding techniques in machine learning: binary versus one-hot and feature hashing.
- Segura, M., Maroto, C., Segura, B., & Casas-Rosal, J. C.** (2020). Improving food supply chain management by a sustainable approach to supplier evaluation. *Mathematics*, 8(11), 1952.
- Selim, S. Z., & Ismail, M. A.** (1984). K-means-type algorithms: A generalized convergence theorem and characterization of local optimality. *IEEE Transactions on pattern analysis and machine intelligence*, (1), 81-87.
- Sepulveda, J. M., & Derpich, I. S.** (2015). Multicriteria supplier classification for DSS: Comparative analysis of two methods. *International Journal of Computers Communications & Control*, 10(2), 238-247.

- Sepulveda, J., Gonzalez, J., Alfaro, M., & Camargo, M.** (2010). A metrics-based diagnosis tool for enhancing innovation capabilities in SMEs. *International Journal of Computers Communications & Control*, 5(5), 919-928.
- Shahapure, K. R., & Nicholas, C.** (2020). Cluster quality analysis using silhouette score. In *2020 IEEE 7th international conference on data science and advanced analytics (DSAA)* (pp. 747-748). IEEE.
- Sheng, H., & Xiao, J.** (2015). Electric vehicle state of charge estimation: Nonlinear correlation and fuzzy support vector machine. *Journal of Power sources*, 281, 131-137.
- Silva, A. M. R., & Sobral, M. F. F.** (2017). Multicriteria model to sort suppliers in a Brazilian dairy industry. *International Journal of Decision Support System Technology (IJDSST)*, 9(3), 42-53.
- Silva, L. C. E., & Costa, A. P. C. S.** (2014). IT project investments: an analysis based on a sort and rank problem. *International Journal of Information Technology & Decision Making*, 13(04), 699-719.
- Silva, M. M., Costa, A. P. C. S., & de Gusmão, A. P. H.** (2014). Continuous cooperation: a proposal using a fuzzy multicriteria sorting method. *International Journal of Production Economics*, 151, 67-75.
- Singh, A., Thakur, N., & Sharma, A.** (2016). A review of supervised machine learning algorithms. In *2016 3rd international conference on computing for sustainable global development (INDIACom)* (pp. 1310-1315). Ieee.
- Sonar, H. C., & Kulkarni, S. D.** (2021). An integrated AHP-MABAC approach for electric vehicle selection. *Research in Transportation Business & Management*, 41, 100665.
- Soofi, A. A., & Awan, A.** (2017). Classification techniques in machine learning: applications and issues. *Journal of Basic & Applied Sciences*, 13, 459-465.
- Statista** (2024). Electric Vehicles Worldwide – Statistics & Facts, <https://www.statista.com/topics/1010/electric-mobility/> (Erişim: 28 Nisan 2025).
- Susto, G. A., Schirru, A., Pampuri, S., McLoone, S., & Beghi, A.** (2014). Machine learning for predictive maintenance: A multiple classifier approach. *IEEE transactions on industrial informatics*, 11(3), 812-820.
- Taherdoost, H., & Madanchian, M.** (2023). Multi-criteria decision making (MCDM) methods and concepts. *Encyclopedia*, 3(1), 77-87.
- Toloie-Eshlaghy, A., & Homayonfar, M.** (2011). MCDM methodologies and applications: a literature review from 1999 to 2009. *Research Journal of International Studies*, 21(21), 86-137.
- Trebuna, P., Halcinova, J., Fil'o, M., & Markovic, J.** (2014). The importance of normalization and standardization in the process of clustering. In *2014 IEEE 12th International Symposium on Applied Machine Intelligence and Informatics (SAMI)* (pp. 381-385). IEEE.

- Triantaphyllou, E., & Triantaphyllou, E. (2000).** *Multi-criteria decision making methods* (pp. 5-21). Springer Us.
- Ulucan, A., & Atici, K. B. (2013).** A multiple criteria sorting methodology with multiple classification criteria and an application to country risk evaluation. *Technological and Economic Development of Economy*, 19(1), 93-124.
- Wang, Z., Wang, Y., Zeng, R., Srinivasan, R. S., & Ahrentzen, S. (2018).** Random Forest based hourly building energy prediction. *Energy and Buildings*, 171, 11-25.
- Wuest, T., Weimer, D., Irgens, C., & Thoben, K. D. (2016).** Machine learning in manufacturing: advantages, challenges, and applications. *Production & Manufacturing Research*, 4(1), 23-45.
- Xu, C., Dai, Q., Gaines, L., Hu, M., Tukker, A., & Steubing, B. (2020).** Future material demand for automotive lithium-based batteries. *Communications Materials*, 1(1), 99.
- Yavasoglu, H. A., Tetik, Y. E., & Gokce, K. (2019).** Implementation of machine learning based real time range estimation method without destination knowledge for BEVs. *Energy*, 172, 1179-1186.
- Yi, D., Su, J., Liu, C., Quddus, M., & Chen, W. H. (2019).** A machine learning based personalized system for driving state recognition. *Transportation Research Part C: Emerging Technologies*, 105, 241-261.
- Zahid, T., Xu, K., Li, W., Li, C., & Li, H. (2018).** State of charge estimation for electric vehicle power battery using advanced machine learning algorithm under diversified drive cycles. *Energy*, 162, 871-882.
- Zavadskas, E. K., Turskis, Z., & Kildienė, S. (2014).** State of art surveys of overviews on MCDM/MADM methods. *Technological and economic development of economy*, 20(1), 165-179.
- Zhang, S., Zhu, F., Deveci, M., & Liu, X. (2024).** Consensus-oriented linguistic multi-criteria group sorting method incorporating dynamic trust management. *Information Fusion*, 112, 102539.
- Zhang, Z., & Li, Z. (2023).** Consensus-based TOPSIS-Sort-B for multi-criteria sorting in the context of group decision-making. *Annals of Operations Research*, 325(2), 911-938.
- Zhao, X., Yan, X., Yu, A., & Van Hentenryck, P. (2020).** Prediction and behavioral analysis of travel mode choice: A comparison of machine learning and logit models. *Travel behaviour and society*, 20, 22-35.
- Ziemann, S., Müller, D. B., Schebek, L., & Weil, M. (2018).** Modeling the potential impact of lithium recycling from EV batteries on lithium demand: A dynamic MFA approach. *Resources, conservation and recycling*, 133, 76-85.
- Ziemba, P. (2020).** Multi-criteria stochastic selection of electric vehicles for the sustainable development of local government and state administration units in Poland. *Energies*, 13(23), 6299.

Zopounidis, C., & Doumpos, M. (2000). PREFDIS: a multicriteria decision support system for sorting decision problems. *Computers & Operations Research*, 27(7-8), 779-79



EKLER

EK A: Araçların etiket verileri.



EK A: Araçların etiket verileri.**Çizelge A.1:** Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive			
		Sort-B	Ağacı	Regresyon	Bayes	KEYK	DVM	YSA
0	Lucid Air Grand Touring	0	0	0	1	0	1	0
1	Mercedes Benz Eqs 500 4Matic	0	0	0	0	0	0	0
	Audi A6 Avant E Tron							
2	Performance	0	0	0	0	0	0	0
3	Porsche Taycan Turbo	0	0	0	0	0	0	0
	Mercedes Benz Eqs Suv 580							
4	4Matic	0	0	0	0	0	0	0
	Tesla Model 3 Long Range Dual							
5	Motor	0	0	0	0	0	0	0
6	Bmw I7 Edrive50	1	1	1	0	1	0	0
7	Mercedes Benz Eqs 350 4Matic	0	0	0	0	0	0	0
	Audi Q6 E Tron Sportback							
8	Performance	0	0	0	0	0	0	0
9	Nio Et7 Long Range	0	1	0	0	0	0	0
	Audi Q6 E Tron Sportback							
10	Quattro	0	0	0	0	0	0	0
11	Porsche Taycan	0	0	0	0	0	0	0
12	Audi Sq6 E Tron Sportback	0	0	0	0	0	0	0
13	Tesla Model 3 Performance	0	1	0	0	0	0	0
14	Bmw Ix M60	0	0	0	0	1	0	0
15	Volkswagen Id7 Gtx	0	0	0	0	1	0	0
16	Audi A6 Sportback E Tron	0	0	0	0	0	0	0
17	Zeekr 001 Performance Awd	0	0	0	0	1	0	0
18	Volkswagen Id7 Pro	0	1	1	1	0	1	0
19	Skoda Enyaq Coupe 85X	1	1	1	1	1	1	1
20	Mercedes Benz Eqs Suv 350Plus	0	0	0	0	0	0	0
21	Hyundai Ioniq 9 Performance	0	0	0	0	0	0	0
	Awd							
22	Porsche Taycan Sport Turismo	0	0	0	0	0	0	0
23	Cupra Born 170 Kw 77 Kwh	1	1	1	1	1	1	1
24	Xpeng P7 Wing Edition	0	0	0	0	0	0	0

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive	KEYK	DVM	YSA
		Sort-B	Ağacı	Regresyon	Bayes			
25	Volkswagen Id5 Pro	1	1	1	1	1	1	1
	Mercedes Benz Eqe Amg 53							
26	4Maticplus	0	0	0	0	0	0	0
27	Skoda Elroq 85	1	1	1	1	1	1	1
28	Mercedes Benz Eqe Suv 300	0	0	0	0	0	0	0
29	Hyundai Ioniq 5 84 Kwh Awd	0	0	0	0	0	0	0
30	Skoda Enyaq 85X	1	1	1	1	1	1	1
31	Volkswagen Id4 Pro 4Motion	1	1	1	1	1	1	1
	Mercedes Benz Eqe Suv 350							
32	4Matic	0	0	0	0	0	0	0
33	Bmw I4 Edrive35	1	1	1	1	1	1	1
34	Gwm Ora 07 Gt	2	1	1	2	2	2	2
	Mercedes Benz Eqe Suv Amg 43							
35	4Matic	0	0	0	0	0	0	0
36	Bmw I5 M60 Xdrive Sedan	1	1	1	0	1	1	1
37	Mercedes Benz Eqb 250Plus	1	1	1	1	1	1	1
38	Nio Et5 Standard Range	1	1	1	0	1	1	1
39	Volvo Ec40 Twin Motor	1	1	1	1	1	1	1
40	Audi Q4 E Tron 55 Quattro	1	1	1	1	1	1	1
41	Audi Q6 E Tron	0	0	0	0	0	0	0
	Nissan Ariya E 40rce 87Kwh							
42	320 Kw Nismo	1	1	1	1	1	1	1
	Volvo Ex40 Twin Motor							
43	Performance	1	1	1	1	1	1	1
	Renault Megane E Tech Ev60							
44	220Hp	1	1	1	1	1	1	1
45	Lynkco 02	2	2	1	1	2	2	2
46	Kgm Torres Evx	1	2	1	0	0	2	1
47	Opel Grandland 73 Kwh	1	1	1	1	1	1	1
	Peugeot E 5008 73 Kwh Dual							
48	Motor	1	1	1	1	1	1	1
49	Mg Mg4 Electric 64 Kwh	1	1	1	1	1	1	1
50	Smart 3 Premium	1	1	1	1	1	1	1

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive			
		Sort-B	Ağacı	Regresyon	Bayes	KEYK	DVM	YSA
51	Kia Ev6 Standard Range 2Wd	1	1	1	1	0	1	1
52	Lexus Rz 450E	2	2	2	2	2	2	2
53	Mercedes Benz Eqa 300 4Matic	1	1	1	1	1	1	1
54	Volvo Ex40 Single Motor	1	1	1	1	1	1	1
55	Hyundai Ioniq 5 63 Kwh Rwd	0	0	0	0	0	0	0
56	Mercedes Benz Eqb 350 4Matic	1	1	1	1	1	1	1
57	Omoda E5	2	2	2	2	2	2	2
58	Lexus Ux 300E	2	2	1	0	0	2	1
	Volvo Ex30 Twin Motor							
59	Performance	1	1	1	1	1	1	1
60	Skywell Be11 Standard Range	2	2	2	2	2	2	2
61	Smart 1 Brabus	1	1	1	1	1	1	1
	Mercedes Benz Evito Tourer							
62	Long 90 Kwh	2	2	2	2	2	2	2
63	Mg Mg4 Electric Xpower	1	1	1	1	1	1	1
64	Mercedes Benz Eqv 300 Long	2	2	2	2	2	2	2
65	Skoda Elroq 50	2	2	2	1	1	2	2
66	Fiat 600E	2	2	2	2	2	2	2
67	Peugeot E 2008 54 Kwh	2	2	2	2	2	2	2
68	Audi Q4 Sportback E Tron 35	1	1	1	1	1	1	1
69	Hyundai Inster Long Range	2	2	2	2	2	2	2
70	Mini Aceman Se	2	2	2	2	2	2	2
71	Abarth 600E Turismo	2	2	2	2	2	2	2
72	Mg Zs Ev Standard Range	2	2	2	2	2	2	2
	Mg Mg5 Electric Standard							
73	Range	2	2	2	2	2	2	2
74	Byd Dolphin 449 Kwh Active	1	1	1	2	2	2	1
75	Opel Zafira E Life L2 75 Kwh	1	1	1	2	1	1	1
76	Toyota Proace Verso M 75 Kwh	1	1	1	2	1	1	1
77	Dongfeng Box 423 Kwh	2	2	2	2	2	2	2
78	Citroen E C3 Aircross	2	2	2	2	2	2	2
79	Fiat 500E 3Plus1 42 Kwh	2	2	2	2	2	2	2
80	Nissan Leaf	2	2	2	2	2	2	2

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive	KEYK	DVM	YSA
		Sort-B	Ağacı	Regresyon	Bayes			
81	Renault Kangoo E Tech Electric	2	2	2	2	2	2	2
82	Mercedes Benz Eqt 200 Standard	2	2	2	2	2	2	2
83	Mercedes Benz Eqt 200 Long	2	2	2	2	2	2	2
	Renault Kangoo Grand E Tech							
84	Electric	1	2	1	2	2	2	2
85	Citroen E Spacetourer M 50 Kwh	2	2	2	2	2	2	2
86	Toyota Proace Verso M 50 Kwh	2	2	2	2	2	2	2
87	Fiat 500E 3Plus1 24 Kwh	2	2	2	2	2	2	2
88	Mercedes Benz Eqs 450Plus	0	-	-	-	-	-	-
89	Mercedes Benz Eqs 450 4Matic	0	-	-	-	-	-	-
90	Mercedes Benz Eqs 580 4Matic	0	-	-	-	-	-	-
	Audi A6 Sportback E Tron							
91	Performance	0	-	-	-	-	-	-
	Mercedes Benz Eqs Amg 53							
92	4Maticplus	0	-	-	-	-	-	-
	Audi A6 Sportback E Tron							
93	Quattro	0	-	-	-	-	-	-
94	Lucid Air Touring	1	-	-	-	-	-	-
95	Porsche Taycan Plus	0	-	-	-	-	-	-
96	Tesla Model S Dual Motor	0	-	-	-	-	-	-
97	Porsche Taycan 4S Plus	0	-	-	-	-	-	-
98	Lucid Air Pure Rwd	1	-	-	-	-	-	-
99	Porsche Taycan 4 Plus	0	-	-	-	-	-	-
100	Tesla Model S Plaid	0	-	-	-	-	-	-
101	Ds N8 Fwd Long Range	1	-	-	-	-	-	-
102	Mercedes Benz Eqs 350Plus	0	-	-	-	-	-	-
103	Audi S6 Sportback E Tron	0	-	-	-	-	-	-
104	Tesla Model 3 Long Range Rwd	0	-	-	-	-	-	-
105	Mercedes Benz Eqs Suv 450Plus	0	-	-	-	-	-	-
106	Audi E Tron Gt S	0	-	-	-	-	-	-
107	Ds N8 Awd Long Range	1	-	-	-	-	-	-
108	Audi A6 Avant E Tron Quattro	0	-	-	-	-	-	-
109	Porsche Taycan Gts	0	-	-	-	-	-	-

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive			
		Sort-B	Ağacı	Regresyon	Bayes	KEYK	DVM	YSA
110	Mercedes Benz Eqs Suv 450 4Matic	0	-	-	-	-	-	-
111	Mercedes Benz Eqs Suv 500 4Matic	0	-	-	-	-	-	-
112	Porsche Taycan Plus Sport Turismo	0	-	-	-	-	-	-
113	Volkswagen Id7 Pro S	0	-	-	-	-	-	-
114	Porsche Taycan Turbo S	0	-	-	-	-	-	-
115	Mercedes Benz Eqs 300	0	-	-	-	-	-	-
116	Audi E Tron Gt Rs	0	-	-	-	-	-	-
117	Audi E Tron Gt Rs Performance	0	-	-	-	-	-	-
118	Audi S6 Avant E Tron	0	-	-	-	-	-	-
119	Volkswagen Id7 Tourer Pro S	0	-	-	-	-	-	-
120	Lotus Emeya	0	-	-	-	-	-	-
121	Lotus Emeya S	0	-	-	-	-	-	-
122	Vinfast Vf 9 Extended Range	2	-	-	-	-	-	-
123	Bmw I4 Edrive40	1	-	-	-	-	-	-
124	Porsche Macan Electric	0	-	-	-	-	-	-
125	Porsche Taycan 4S Plus Sport Turismo	0	-	-	-	-	-	-
126	Porsche Taycan 4 Cross Turismo	0	-	-	-	-	-	-
127	Porsche Taycan 4S Cross Turismo	0	-	-	-	-	-	-
128	Bmw I7 Xdrive60	0	-	-	-	-	-	-
129	Porsche Taycan Turbo Sport Turismo	0	-	-	-	-	-	-
130	Porsche Taycan Turbo S Sport Turismo	0	-	-	-	-	-	-
131	Zeekr 001 Long Range Rwd	0	-	-	-	-	-	-
132	Mercedes Benz Eqs 500 4Matic	0	-	-	-	-	-	-
133	Bmw Ix Xdrive50	1	-	-	-	-	-	-
134	Porsche Taycan Gts Sport Turismo	0	-	-	-	-	-	-

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive	KEYK	DVM	YSA
		Sort-B	Ağacı	Regresyon	Bayes			
135	Polestar 3 Long Range Single Motor	0	-	-	-	-	-	-
136	Peugeot E 3008 97 Kwh Long Range	0	-	-	-	-	-	-
137	Nio Et5 Long Range	0	-	-	-	-	-	-
138	Xpeng P7 Rwd Long Range	0	-	-	-	-	-	-
139	Polestar 4 Long Range Single Motor	0	-	-	-	-	-	-
140	Porsche Taycan Turbo Cross Turismo	0	-	-	-	-	-	-
141	Hyundai Ioniq 6 Long Range 2Wd	0	-	-	-	-	-	-
142	Lotus Eletre	0	-	-	-	-	-	-
143	Hyundai Ioniq 9 Long Range Rwd	0	-	-	-	-	-	-
144	Mercedes Benz Eqs Suv Maybach 680	0	-	-	-	-	-	-
145	Bmw I7 M70 Xdrive	0	-	-	-	-	-	-
146	Porsche Taycan 4S	0	-	-	-	-	-	-
147	Bmw I4 Xdrive40	1	-	-	-	-	-	-
148	Audi Q6 E Tron Performance	0	-	-	-	-	-	-
149	Porsche Taycan 4	0	-	-	-	-	-	-
150	Porsche Macan 4 Electric	0	-	-	-	-	-	-
151	Polestar 4 Long Range Dual Motor	0	-	-	-	-	-	-
152	Porsche Taycan Turbo S Cross Turismo	0	-	-	-	-	-	-
153	Peugeot E 5008 97 Kwh Long Range	0	-	-	-	-	-	-
154	Nio Et5 Touring Long Range	0	-	-	-	-	-	-
155	Tesla Model X Dual Motor	0	-	-	-	-	-	-
156	Porsche Macan 4S Electric	0	-	-	-	-	-	-
157	Polestar 3 Long Range Dual Motor	0	-	-	-	-	-	-

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive			
		Sort-B	Ağacı	Regresyon	Bayes	KEYK	DVM	YSA
158	Voyah Free 106 Kwh	2	-	-	-	-	-	-
159	Lotus Eletre S	0	-	-	-	-	-	-
	Renault Scenic E Tech Ev87							
160	220Hp	0	-	-	-	-	-	-
161	Xpeng G9 Rwd Long Range	0	-	-	-	-	-	-
162	Audi Q6 E Tron Quattro	0	-	-	-	-	-	-
163	Volkswagen Id7 Tourer Gtx	0	-	-	-	-	-	-
164	Xpeng G6 Rwd Long Range	0	-	-	-	-	-	-
165	Zeekr 001 Privilege Awd	0	-	-	-	-	-	-
166	Byd Seal 825 Kwh Rwd Design	0	-	-	-	-	-	-
167	Ford Mustang Mach E Er Rwd	2	-	-	-	-	-	-
168	Skoda Enyaq Coupe 85	1	-	-	-	-	-	-
	Hyundai Ioniq 9 Long Range							
169	Awd	0	-	-	-	-	-	-
170	Porsche Taycan Turbo Gt	0	-	-	-	-	-	-
	Porsche Taycan Turbo Gt							
171	Weissach	0	-	-	-	-	-	-
172	Xpeng G6 Awd Performance	0	-	-	-	-	-	-
	Polestar 2 Long Range Single							
173	Motor	1	-	-	-	-	-	-
174	Audi A6 Avant E Tron	0	-	-	-	-	-	-
175	Byd Han	1	-	-	-	-	-	-
176	Porsche Macan Turbo Electric	0	-	-	-	-	-	-
177	Volkswagen Id7 Tourer Pro	0	-	-	-	-	-	-
178	Audi Sq6 E Tron	0	-	-	-	-	-	-
179	Bmw I5 Edrive40 Sedan	1	-	-	-	-	-	-
	Polestar 3 Long Range							
180	Performance	0	-	-	-	-	-	-
181	Xpeng G9 Awd Performance	0	-	-	-	-	-	-
182	Cupra Born Vz	1	-	-	-	-	-	-
183	Lotus Emeya R	0	-	-	-	-	-	-
184	Tesla Model X Plaid	0	-	-	-	-	-	-
185	Rolls Royce Spectre	0	-	-	-	-	-	-

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive	KEYK	DVM	YSA
		Sort-B	Ağacı	Regresyon	Bayes			
186	Volvo Ex90 Twin Motor	0	-	-	-	-	-	-
187	Hongqi E Hs9 120 Kwh	2	-	-	-	-	-	-
188	Xpeng P7 Awd Performance	0	-	-	-	-	-	-
189	Byd Tang Flagship	1	-	-	-	-	-	-
190	Volkswagen Id3 Gtx	1	-	-	-	-	-	-
	Volkswagen Id3 Gtx							
191	Performance	1	-	-	-	-	-	-
192	Volvo Ex90 Single Motor	0	-	-	-	-	-	-
193	Cadillac Lyriq 600 E4	0	-	-	-	-	-	-
194	Kia Ev6 Long Range 2Wd	0	-	-	-	-	-	-
195	Skoda Enyaq Coupe Rs	1	-	-	-	-	-	-
	Mercedes Benz Eqe Suv 500							
196	4Matic	0	-	-	-	-	-	-
197	Bmw I5 Xdrive40 Sedan	1	-	-	-	-	-	-
198	Bmw I5 Edrive40 Touring	1	-	-	-	-	-	-
199	Tesla Model Y Long Range Rwd	0	-	-	-	-	-	-
200	Kia Ev3 Long Range	2	-	-	-	-	-	-
	Polestar 2 Long Range Dual							
201	Motor	1	-	-	-	-	-	-
202	Lotus Eletre R	0	-	-	-	-	-	-
203	Nissan Ariya 87Kwh	1	-	-	-	-	-	-
204	Kia Ev9 998 Kwh Rwd	0	-	-	-	-	-	-
205	Bmw I4 M50	1	-	-	-	-	-	-
	Mercedes Benz Eqe Amg 43							
206	4Matic	0	-	-	-	-	-	-
207	Volkswagen Id3 Pro S	1	-	-	-	-	-	-
	Polestar 2 Long Range							
208	Performance	1	-	-	-	-	-	-
209	Hyundai Ioniq 5 84 Kwh Rwd	0	-	-	-	-	-	-
210	Ford Capri Extended Range Rwd	1	-	-	-	-	-	-
211	Kia Ev6 Long Range Awd	0	-	-	-	-	-	-
212	Skoda Enyaq 85	1	-	-	-	-	-	-
	Volvo Ex90 Twin Motor							
213	Performance	0	-	-	-	-	-	-

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive	KEYK	DVM	YSA
		Sort-B	Ağacı	Regresyon	Bayes			
	Tesla Model Y Long Range Dual							
214	Motor	0	-	-	-	-	-	-
215	Cupra Tavascan Endurance	1	-	-	-	-	-	-
216	Ford Capri Extended Range Awd	1	-	-	-	-	-	-
	Byd Seal 825 Kwh Awd							
217	Excellence	1	-	-	-	-	-	-
218	Volkswagen Id4 Pro	1	-	-	-	-	-	-
	Porsche Taycan 4S Sport							
219	Turismo	0	-	-	-	-	-	-
220	Genesis G80 Electrified Luxury	1	-	-	-	-	-	-
221	Nio El8 Long Range	0	-	-	-	-	-	-
	Hyundai Ioniq 6 Long Range							
222	Awd	0	-	-	-	-	-	-
223	Ford Mustang Mach E Er Awd	2	-	-	-	-	-	-
	Byd Sealion 7 913 Kwh Awd							
224	Excellence	0	-	-	-	-	-	-
225	Kia Ev9 998 Kwh Awd	0	-	-	-	-	-	-
226	Nio El6 Long Range	1	-	-	-	-	-	-
227	Audi Q4 Sportback E Tron 45	1	-	-	-	-	-	-
228	Skoda Enyaq Rs	1	-	-	-	-	-	-
	Ford Explorer Extended Range							
229	Rwd	1	-	-	-	-	-	-
	Ford Explorer Extended Range							
230	Awd	1	-	-	-	-	-	-
231	Mg Cyberster Trophy	2	-	-	-	-	-	-
232	Tesla Model Y Performance	0	-	-	-	-	-	-
233	Volkswagen Id5 Gtx	1	-	-	-	-	-	-
234	Nio El7 Long Range	0	-	-	-	-	-	-
235	Ds N8 Fwd	1	-	-	-	-	-	-
236	Byd Seal U 87 Kwh Design	1	-	-	-	-	-	-
237	Cupra Tavascan Vz	1	-	-	-	-	-	-
238	Mg Mg4 Electric 77 Kwh	1	-	-	-	-	-	-
239	Kia Ev9 998 Kwh Awd Gt Line	0	-	-	-	-	-	-
240	Ford Mustang Mach E Gt	2	-	-	-	-	-	-

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive	KEYK	DVM	YSA
		Sort-B	Ağacı	Regresyon	Bayes			
	Byd Sealion 7 825 Kwh Rwd							
241	Comfort	0	-	-	-	-	-	-
242	Maserati Granturismo Folgore	0	-	-	-	-	-	-
243	Volvo Ec40 Single Motor Er	1	-	-	-	-	-	-
244	Mercedes Benz Eqa 250Plus	1	-	-	-	-	-	-
245	Tesla Model 3	1	-	-	-	-	-	-
246	Audi Q4 E Tron 45	1	-	-	-	-	-	-
	Mercedes Benz Eqa Suv Amg 53							
247	4Maticplus	0	-	-	-	-	-	-
248	Volkswagen Id4 Gtx	1	-	-	-	-	-	-
249	Bmw I5 M60 Xdrive Touring	1	-	-	-	-	-	-
	Polestar 2 Standard Range Single							
250	Motor	1	-	-	-	-	-	-
251	Nio Et7 Standard Range	1	-	-	-	-	-	-
	Audi Q4 Sportback E Tron 55							
252	Quattro	1	-	-	-	-	-	-
253	Opel Grandland 82 Kwh	1	-	-	-	-	-	-
	Audi Q4 Sportback E Tron 45							
254	Quattro	1	-	-	-	-	-	-
255	Audi Q6 E Tron Sportback	0	-	-	-	-	-	-
256	Ford Mustang Mach E Rally	2	-	-	-	-	-	-
	Vinfast Vf 8 Eco Extended							
257	Range	2	-	-	-	-	-	-
	Nissan Ariya E 40rce 87Kwh							
258	225 Kw	1	-	-	-	-	-	-
	Byd Sealion 7 825 Kwh Awd							
259	Design	1	-	-	-	-	-	-
	Vinfast Vf 8 Plus Extended							
260	Range	2	-	-	-	-	-	-
261	Maserati Grecale Folgore	2	-	-	-	-	-	-
262	Volvo Ex40 Single Motor Er	1	-	-	-	-	-	-
	Volvo Ec40 Twin Motor							
263	Performance	1	-	-	-	-	-	-
264	Nio Et5 Touring Standard Range	1	-	-	-	-	-	-

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive			
		Sort-B	Ağacı	Regresyon	Bayes	KEYK	DVM	YSA
265	Mg Cyberster Gt	2	-	-	-	-	-	-
266	Xpeng G9 Rwd Standard Range	0	-	-	-	-	-	-
267	Bmw Ix2 Edrive20	1	-	-	-	-	-	-
268	Maserati Grancabrio Folgore	0	-	-	-	-	-	-
269	Mercedes Benz Eqa 250	1	-	-	-	-	-	-
270	Audi Q4 E Tron 45 Quattro	1	-	-	-	-	-	-
271	Kia Ev6 Gt	0	-	-	-	-	-	-
272	Hyundai Kona Electric 65 Kwh	1	-	-	-	-	-	-
273	Genesis Gv60 Premium	1	-	-	-	-	-	-
274	Elaris Beo 86 Kwh	2	-	-	-	-	-	-
275	Bmw Ix1 Edrive20	1	-	-	-	-	-	-
276	Skywell Be11 Long Range	2	-	-	-	-	-	-
277	Hyundai Ioniq 5 N	0	-	-	-	-	-	-
278	Volvo Ex40 Twin Motor	1	-	-	-	-	-	-
279	Kia Niro Ev	1	-	-	-	-	-	-
280	Ford Mustang Mach E Sr Rwd	2	-	-	-	-	-	-
281	Bmw Ix2 Xdrive30	1	-	-	-	-	-	-
282	Jaguar I Pace Ev400	1	-	-	-	-	-	-
	Renault Megane E Tech Ev60							
283	130Hp	1	-	-	-	-	-	-
284	Genesis Gv60 Sport	1	-	-	-	-	-	-
285	Bmw Ix1 Xdrive30	1	-	-	-	-	-	-
286	Mini Countryman E	1	-	-	-	-	-	-
287	Peugeot E 3008 73 Kwh	1	-	-	-	-	-	-
	Peugeot E 3008 73 Kwh Dual							
288	Motor	1	-	-	-	-	-	-
289	Peugeot E 408 58 Kwh	2	-	-	-	-	-	-
290	Mg Zs Ev Long Range	2	-	-	-	-	-	-
291	Peugeot E 5008 73 Kwh	1	-	-	-	-	-	-
292	Volkswagen Id Buzz Lwb Pro	1	-	-	-	-	-	-
293	Xpeng G6 Rwd Standard Range	0	-	-	-	-	-	-
294	Hongqi E Hs9 99 Kwh	2	-	-	-	-	-	-
295	Kia E Soul 64 Kwh	2	-	-	-	-	-	-

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive	KEYK	DVM	YSA
		Sort-B	Ağacı	Regresyon	Bayes			
296	Maxus Mifa 9	1	-	-	-	-	-	-
297	Genesis Gv60 Sport Plus	1	-	-	-	-	-	-
298	Nio El6 Standard Range	1	-	-	-	-	-	-
299	Nio El8 Standard Range	1	-	-	-	-	-	-
300	Mini Countryman Se All4	1	-	-	-	-	-	-
301	Lexus Rz 300E	2	-	-	-	-	-	-
302	Mg Marvel R	1	-	-	-	-	-	-
303	Byd Seal U 718 Kwh Comfort	1	-	-	-	-	-	-
304	Volvo Ec40 Single Motor	1	-	-	-	-	-	-
305	Volvo Ex30 Single Motor Er	1	-	-	-	-	-	-
306	Mercedes Benz G 580	1	-	-	-	-	-	-
307	Volkswagen Id3 Pro	1	-	-	-	-	-	-
308	Volkswagen Id Buzz Nwb Pro	1	-	-	-	-	-	-
309	Cupra Born 170 Kw 59 Kwh	1	-	-	-	-	-	-
310	Bmw Ix Xdrive40	1	-	-	-	-	-	-
311	Kia Ev9 761 Kwh Rwd	0	-	-	-	-	-	-
312	Volkswagen Id Buzz Lwb Gtx	1	-	-	-	-	-	-
313	Zeekr X Long Range Rwd	1	-	-	-	-	-	-
314	Smart 3 Proplus	1	-	-	-	-	-	-
315	Leapmotor C10	1	-	-	-	-	-	-
316	Nio El7 Standard Range	1	-	-	-	-	-	-
317	Toyota Bz4X Fwd	1	-	-	-	-	-	-
318	Byd Dolphin 604 Kwh	1	-	-	-	-	-	-
319	Tesla Model Y	1	-	-	-	-	-	-
320	Genesis Gv70 Electrified Sport	2	-	-	-	-	-	-
321	Mg Marvel R Performance	1	-	-	-	-	-	-
322	Mercedes Benz Eqa 350 4Matic	1	-	-	-	-	-	-
323	Gwm Ora 07 Pure	2	-	-	-	-	-	-
324	Gwm Ora 07 Pro	2	-	-	-	-	-	-
325	Ford Mustang Mach E Sr Awd	2	-	-	-	-	-	-
326	Aiways U6	2	-	-	-	-	-	-
327	Toyota Bz4X Awd	1	-	-	-	-	-	-
328	Zeekr X Privilege Awd	1	-	-	-	-	-	-
329	Mercedes Benz Eqb 300 4Matic	1	-	-	-	-	-	-

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive			
		Sort-B	Ağacı	Regresyon	Bayes	KEYK	DVM	YSA
330	Skoda Elroq 60	1	-	-	-	-	-	-
	Renault Scenic E Tech Ev60							
331	170Hp	1	-	-	-	-	-	-
332	Gwm Ora 03 63 Kwh	2	-	-	-	-	-	-
333	Nissan Leaf Eplus	2	-	-	-	-	-	-
334	Citroen E C4 X 54 Kwh	2	-	-	-	-	-	-
335	Smart 1 Premium	1	-	-	-	-	-	-
336	Nissan Ariya 63Kwh	1	-	-	-	-	-	-
337	Volkswagen Id Buzz Nwb Gtx	1	-	-	-	-	-	-
338	Smart 1 Proplus	1	-	-	-	-	-	-
339	Honda Eny1	2	-	-	-	-	-	-
340	Smart 1 Pureplus	1	-	-	-	-	-	-
	Hyundai Ioniq 6 Standard Range							
341	2Wd	0	-	-	-	-	-	-
342	Mg Mg5 Electric Long Range	2	-	-	-	-	-	-
343	Smart 3 Brabus	1	-	-	-	-	-	-
344	Citroen E C4 54 Kwh	2	-	-	-	-	-	-
345	Mini Cooper Se	2	-	-	-	-	-	-
346	Byd Atto 3	1	-	-	-	-	-	-
347	Gwm Ora 03 Gt	2	-	-	-	-	-	-
348	Smart 1 Pulse	1	-	-	-	-	-	-
349	Kia Ev3 Standard Range	2	-	-	-	-	-	-
350	Opel Astra Electric	2	-	-	-	-	-	-
351	Volkswagen Id5 Pure	1	-	-	-	-	-	-
352	Subaru Solterra Awd	1	-	-	-	-	-	-
353	Renault 5 E Tech 52Kwh 150Hp	1	-	-	-	-	-	-
	Alfa Romeo Junior Elettrica 54							
354	Kwh	2	-	-	-	-	-	-
355	Volkswagen Id3 Pure	1	-	-	-	-	-	-
356	Hongqi E Hs9 84 Kwh	2	-	-	-	-	-	-
357	Aiways U5	2	-	-	-	-	-	-
358	Opel Corsa Electric 51 Kwh	2	-	-	-	-	-	-
	Mercedes Benz Eqv 300 Extra							
359	Long	2	-	-	-	-	-	-

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive	KEYK	DVM	YSA
		Sort-B	Ağacı	Regresyon	Bayes			
	Opel Astra Sports Tourer							
360	Electric	2	-	-	-	-	-	-
361	Jeep Avenger Electric	2	-	-	-	-	-	-
362	Lancia Ypsilon	2	-	-	-	-	-	-
	Alfa Romeo Junior Elettrica 54							
363	Kwh Veloce	2	-	-	-	-	-	-
364	Peugeot E 208 51 Kwh	2	-	-	-	-	-	-
365	Ford Capri Standard Range Rwd	1	-	-	-	-	-	-
366	Skoda Enyaq 50	2	-	-	-	-	-	-
367	Alpine A290 Electric 180 Hp	1	-	-	-	-	-	-
368	Alpine A290 Electric 220 Hp	1	-	-	-	-	-	-
	Ford Explorer Standard Range							
369	Rwd	1	-	-	-	-	-	-
370	Mg Mg4 Electric 51 Kwh	2	-	-	-	-	-	-
371	Peugeot E 308	2	-	-	-	-	-	-
372	Peugeot E 308 Sw	2	-	-	-	-	-	-
373	Ds 3 E Tense	2	-	-	-	-	-	-
374	Hyundai Kona Electric 48 Kwh	2	-	-	-	-	-	-
375	Opel Corsa Electric 50 Kwh	2	-	-	-	-	-	-
376	Citroen E C4 X	2	-	-	-	-	-	-
377	Citroen E C4	2	-	-	-	-	-	-
378	Ssangyong Korando E Motion	2	-	-	-	-	-	-
379	Peugeot E 208 50 Kwh	2	-	-	-	-	-	-
380	Mini Cooper Jcw	2	-	-	-	-	-	-
381	Audi Q4 E Tron 35	1	-	-	-	-	-	-
382	Volkswagen Id4 Pure	1	-	-	-	-	-	-
383	Opel Mokka Electric	2	-	-	-	-	-	-
384	Abarth 600E Scorpionissima	2	-	-	-	-	-	-
385	Mini Aceman Jcw	2	-	-	-	-	-	-
386	Ford Puma Gen E	2	-	-	-	-	-	-
387	Volvo Ex30 Single Motor	2	-	-	-	-	-	-
388	Peugeot E 2008 50 Kwh	2	-	-	-	-	-	-
389	Smart 3 Pro	2	-	-	-	-	-	-

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive	KEYK	DVM	YSA
		Sort-B	Ağacı	Regresyon	Bayes			
	Renault Megane E Tech Ev40							
390	130Hp	1	-	-	-	-	-	-
391	Gwm Ora 03 48 Kwh	2	-	-	-	-	-	-
392	Byd Dolphin 449 Kwh Boost	1	-	-	-	-	-	-
393	Fiat Grande Panda	2	-	-	-	-	-	-
394	Citroen E Spacetourer M 75 Kwh	1	-	-	-	-	-	-
	Citroen E Spacetourer Xl 75							
395	Kwh	1	-	-	-	-	-	-
396	Peugeot E Traveller L2 75 Kwh	1	-	-	-	-	-	-
397	Peugeot E Traveller L3 75 Kwh	1	-	-	-	-	-	-
398	Opel Zafira E Life L3 75 Kwh	1	-	-	-	-	-	-
399	Toyota Proace Verso L 75 Kwh	1	-	-	-	-	-	-
400	Citroen E C3	2	-	-	-	-	-	-
401	Renault 5 E Tech 40Kwh 95Hp	1	-	-	-	-	-	-
402	Renault 5 E Tech 40Kwh 120Hp	1	-	-	-	-	-	-
403	Smart 1 Pure	2	-	-	-	-	-	-
404	Hyundai Inster Standard Range	2	-	-	-	-	-	-
405	Opel Frontera 44 Kwh	2	-	-	-	-	-	-
406	Mini Cooper E	2	-	-	-	-	-	-
407	Smart 1 Pro	2	-	-	-	-	-	-
408	Fiat 500E Hatchback 42 Kwh	2	-	-	-	-	-	-
409	Citroen E Berlingo M 50 Kwh	2	-	-	-	-	-	-
410	Opel Combo E Life 50 Kwh	2	-	-	-	-	-	-
411	Peugeot E Rifter M 50 Kwh	2	-	-	-	-	-	-
	Toyota Proace City Verso							
412	Electric L1 50 Kwh	2	-	-	-	-	-	-
413	Citroen E Berlingo Xl 50 Kwh	2	-	-	-	-	-	-
414	Opel Combo E Life Xl 50 Kwh	2	-	-	-	-	-	-
415	Peugeot E Rifter Xl 50 Kwh	2	-	-	-	-	-	-
	Toyota Proace City Verso							
416	Electric L2 50 Kwh	2	-	-	-	-	-	-
417	Mini Aceman E	2	-	-	-	-	-	-
418	Leapmotor T03	2	-	-	-	-	-	-
419	Fiat 500E Cabrio 42 Kwh	2	-	-	-	-	-	-

Çizelge A.1 (devam): Elektrikli araçların sıralı sınıflandırma etiketleri ve makine öğrenmesi metotlarının tahmin ettiği test verileri.

ID	Araç Modeli	TOPSIS-	Karar	Lojistik	Naive	KEYK	DVM	YSA
		Sort-B	Ağacı	Regresyon	Bayes			
420	Abarth 500E Hatchback	2	-	-	-	-	-	-
421	Abarth 500E Convertible	2	-	-	-	-	-	-
422	Nissan Townstar Ev Passenger	2	-	-	-	-	-	-
	Nissan Townstar Ev Passenger							
423	L2	2	-	-	-	-	-	-
	Mercedes Benz Evito Tourer							
424	Long 60 Kwh	2	-	-	-	-	-	-
425	Mercedes Benz Eqv 250 Long	2	-	-	-	-	-	-
	Mercedes Benz Evito Tourer							
426	Extra Long 60 Kwh	2	-	-	-	-	-	-
	Mercedes Benz Eqv 250 Extra							
427	Long	2	-	-	-	-	-	-
428	Dongfeng Box 314 Kwh	2	-	-	-	-	-	-
	Citroen E Spacetourer Xl 50							
429	Kwh	2	-	-	-	-	-	-
430	Peugeot E Traveller L2 50 Kwh	2	-	-	-	-	-	-
431	Peugeot E Traveller L3 50 Kwh	2	-	-	-	-	-	-
432	Opel Zafira E Life L2 50 Kwh	2	-	-	-	-	-	-
433	Opel Zafira E Life L3 50 Kwh	2	-	-	-	-	-	-
434	Mazda Mx 30	2	-	-	-	-	-	-
435	Dacia Spring Electric 45	2	-	-	-	-	-	-
436	Dacia Spring Electric 65	2	-	-	-	-	-	-
437	Fiat 500E Hatchback 24 Kwh	2	-	-	-	-	-	-
438	Fiat 500E Cabrio 24 Kwh	2	-	-	-	-	-	-



ÖZGEÇMİŞ

Ad Soyad : Mehmet Demir

ÖĞRENİM DURUMU

Lisans : 2012, Hava Harp Okulu, Endüstri Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2012-2024 : Hv.K.K., İkmal Subayı
- 2020-2021 : NATO RSM, Lojistik Subayı