



**ELEKTRİKLİ ARAÇLAR İÇİN MENZİL TAHMİNİNE
DAYALI ŞARJ PLANLAMA MODELİ**

Hilal YILMAZ



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ELEKTRİKLİ ARAÇLAR İÇİN MENZİL TAHMİNİNE DAYALI ŞARJ
PLANLAMA MODELİ**

Hilal YILMAZ
0000-0001-8125-6814

Prof. Dr. Betül YAĞMAHAN
(Danışman)

DOKTORA TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2022
Her Hakkı Saklıdır

ÖZET

Doktora Tezi

ELEKTRİKLİ ARAÇLAR İÇİN MENZİL TAHMİNİNE DAYALI ŞARJ PLANLAMA MODELİ

Hilal YILMAZ

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Betül YAĞMAHAN

Menzil kaygısı sorunu (range anxiety) elektrikli araçlara (EA'lara) geçişi olumsuz yönde etkileyen en önemli faktörlerden biri olmaya devam etmektedir. Menzil kaygısını tetikleyen unsurlar arasında EA sürücülerinin kalan menzil göstergelerine yeterince güvenmemeleri gelmektedir. Bununla birlikte, EA sürücüsünün yolculuğun başında kalan menzil bilgisine göre rota üzerinde şarj için durması gereken yerleri bilmesinin de menzil kaygısını düşürme potansiyeli bulunmaktadır. Akıllı ulaşım teknolojileri sayesinde EA'ların sürücü bilgilendirme sistemleri gerçek-zamanlı verilere erişebilse de belirlenen rotanın koşulları dikkate alınarak menzil tahmini yapılmadığı sürece oluşturulan şarj planının menzil kaygısını azaltması beklenemez. Bu çalışmanın amacı, belirlenen bir rota için gerçek-zamanlı menzil tahminine dayalı şarj planı oluşturarak EA'nın minimum yolculuk süresi veya maliyeti için nerede ve ne kadar şarj olması gerektiğini belirlemektir. Menzil tahmini için, yolculuğa ait statik öznitelikler ve dinamik öznitelikleri girdi olarak alan derin sinirsel ağ (DSA) modeli kullanılmıştır. Şarj planlaması kapsamında, şarj istasyonlarında doğrusal olmayan şarj süresini, zaman dilimlerine bağlı değişen şarj fiyatlarını, uygunluklarını (dolu/boş bilgisi), araçtan şebekeye enerji satışı uygulamalarını (Vehicle to grid /V2G), birden fazla ve farklı güç seviyelerinde şarj ünitelerini dikkate alan karma tamsayılı doğrusal programlama modeli geliştirilmiştir. Ancak geliştirilen matematiksel programlama modelin çözüm elde etme süresi açısından yetersiz kalması nedeniyle çözüm yaklaşımı olarak genetik algoritma ve matematiksel programlama modelinin hibrit kullanımından oluşan mat-sezgisel bir yaklaşım önerilmiştir. 32 farklı büyüklükteki problem üzerinde yapılan test sonuçları, mat-sezgisel yaklaşımının hem minimum yolculuk süresi hem de minimum yolculuk maliyeti için genetik algoritma ve sezgisel yaklaşımlardan daha başarılı sonuçlar verdiğini göstermektedir.

Anahtar Kelimeler: Elektrikli araçlar, menzil tahmini, şarj planlaması, yapay zekâ, karma tamsayılı doğrusal programlama, mat-sezgisel, genetik algoritma

2022, vii + 98 sayfa.

ABSTRACT

PhD Thesis

CHARGING PLANNING MODEL FOR ELECTRIC VEHICLES BASED ON RANGE PREDICTION

Hilal YILMAZ

Bursa Uludag University
Graduate School of Natural and Applied Sciences
Department of Industrial Engineering

Supervisor: Prof. Dr. Betül YAĞMAHAN

Range anxiety continues to be one of the most important factors negatively affecting the transition to electric vehicles (EVs). Factors that trigger range anxiety include EV drivers not relying enough on remaining range indicators. However, it has the potential to reduce range anxiety if the EV driver knows where to stop for charging on the route according to the range information remaining at the beginning of the journey. Although driver information systems of EVs can access real-time data thanks to smart transportation technologies, it cannot be expected that the created charging plan will reduce range anxiety unless range prediction is made considering the conditions of the determined route. The aim of this study is to determine where and how much the EV should be charged for minimum travel time or cost by creating a charging plan based on real-time range prediction for a specified route. The deep neural network (DNN) model was trained by using the inputs of the static features and dynamic features of the journey in the range prediction model. In the charge planning model, the amount of energy consumed between the nodes on the route was obtained by the range prediction model. Within the scope of charging planning, a mixed integer programming model is developed that take into account non-linear charging times, charging prices that vary depending on time slots, vehicle to the grid (V2G) applications, of charging units, multiple charger points with different power levels and their availability (occupied/free). However, since the developed mathematical programming model was insufficient in terms of the solution time, a mat-heuristic approach consisting of hybrid use of genetic algorithm and mathematical programming model was proposed as a solution approach. Test results on 32 various problems indicate that the mat-heuristic approach outperforms the metaheuristic and heuristics for both minimum travel time and minimum travel cost.

Key words: Electric vehicles, range prediction, charge planning, artificial intelligence, mixed integer linear programming, mat-heuristic, genetic algorithm

2022, vii + 98 pages.

TEŞEKKÜR

Doktora sürecim boyunca beni yönlendiren, akademik anlamda kendimi geliştirmemi sağlayan, değerli hocam Prof. Dr. Betül Yağmahan'a katkıları ve üzerimdeki emeği için çok teşekkür ediyorum.

Görüş ve önerileri ile teze sağladıkları önemli katkılarından ötürü Prof. Dr. Erdal Emel ve Prof. Dr. Gürkan Öztürk'e çok teşekkür ediyorum.

Dersini aldığım bölümdeki tüm hocalarıma katkıları için teşekkür ederim. Aramızda olmasını çok istediğim Prof. Dr. Hüseyin Cenk Özmutlu Hoca'ma, öğretileri ve bilimsel desteği için teşekkür ediyorum, kendisini rahmetle anıyorum.

Beş yıl boyunca 100/2000 bursu kapsamında maddi desteğinden faydalandığım Yüksek Öğretim Kuruluna (YÖK) teşekkürü borç bilirim.

Bursa'yı ve doktora serüvenimi eğlenceli hale getiren, sevgili oda arkadaşlarım Büşra Bozkurt, Esra Polatdemir ve Nuray Kıvrak'a çok teşekkür ediyorum.

Bursa'ya geldiğimden beri maddi manevi hiçbir şekilde yardım ve desteğini esirgemeyen, sevgili Seher Fındıklı ve ailesine, teyzem Tülay Yıldız ve eniştem Ali Yıldız ve kuzenim Fatıma Yıldız'a çok teşekkür ediyorum.

Son olarak en büyük destekçilerim olan sevgili annem Selma Yılmaz, babam Ruşen Yılmaz, kardeşlerim Fikri Bilal ve Mehmet Bekir'e her şey için çok teşekkür ediyorum.

Hilal YILMAZ
30/11/2022

İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ	v
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
2. KURAMSAL TEMELLER VE KAYNAK ARAŞTIRMASI.....	6
2.1. EA’larda Sürüş Menzili Tahmini (EASMT).....	6
2.2. EA’larda Şarj Planlama (EAŞP)	11
2.3. Bütünleşik Problem: EA’larda Menzil Tahminine Dayalı Şarj Planlaması	15
2.4. Araştırma Boşlukları	17
3. MATERYAL ve YÖNTEM.....	20
3.1. Veri Seti	21
3.1.1. Veri ön işleme	24
3.1.2. Yolculukların segmentasyonu.....	26
3.1.3. Hız profillerinin kümelenmesi	27
3.2. EASMT için Çözüm Yaklaşımı	30
3.3. EAŞP için Çözüm Yaklaşımı	34
3.3.1. Problem varsayımları	35
3.3.2. Matematiksel programlama modeli	36
3.3.3. Sezgisel yaklaşımlar.....	43
3.3.4. Metasezgisel yaklaşım: genetik algoritma	43
3.3.5. Mat-sezgisel yaklaşım.....	48
4. BULGULAR	58
4.1. Veri Analizi Bulguları.....	58
4.2. EASMT Bulguları	61
4.2.1. Deney 1: Gözlem tipinin etkisi	62
4.2.2. Deney 2: Rota tipi küme etiketinin etkisi.....	64
4.2.3. Deney 3: Statik ve dinamik verilerinin birlikte kullanımın etkisi.....	67
4.2.4. Deney 4: Kullanılan model mimarisinin etkisi	68
4.3. EAŞP Bulguları	69
4.3.1. Matematiksel modelin çözüm sonuçları.....	71
4.3.2. Önerilen yaklaşımların karşılaştırmalı sonuçları	73
4.3.3. Başlangıç popülasyonu ve iyileştirme eşiğinin etkisi	77
5. TARTIŞMA ve SONUÇ	80
KAYNAKLAR	83
EKLER.....	93
EK 1. EA’larda Menzil Tahmini ve Şarj Planlaması-Literatür Tablosu.....	94
ÖZGEÇMİŞ	97

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
A_i^a	EA'nın i . şarj istasyonuna vardığı sırada yolculuk süresinin H zaman dilimini geçme sayısı
A_i^d	EA'nın i . şarj istasyonundan ayrıldığı sırada yolculuk süresinin H zaman dilimini geçme sayısı
B	EA'nın batarya kapasitesi (kWh)
B_{min}	Kabul edilebilir minimum SOC yüzdesi (%)
bp	Doğrusal olmayan şarj süresinin EA'nın enerjisine bağlı kırılma noktası (%)
c_{ifh}^g	i . şarj istasyonunun f . şarj ünitesinin h . zaman dilimindeki deşarj fiyatı (\$/dk)
c_{ifh}^v	i . şarj istasyonunun f . şarj ünitesinin h . zaman dilimindeki şarj fiyatı (\$/dk)
CH_i	i . şarj istasyonundaki şarj üniteleri
CS	Şarj istasyonları kümesi
δ_{ifh}^1	EA, i . şarj istasyonunun f . şarj ünitesinin h . zaman diliminde vardığında geçen zaman dilimi sayısı H 'ı geçmezse 1, aksi takdirde 0
δ_{ih}^2	EA, i . şarj istasyonuna h . zaman diliminde varırsa 1, aksi takdirde 0
δ_{ih}^3	EA, i . şarj istasyonundan h . zaman diliminde ayrılırsa 1, aksi takdirde 0
e_i	Başlangıç düğümünden i . düğüme varmak için gereken birikimli enerji miktarı (kWh)
f_i^s	S kümesindeki i . şarj istasyonunda uğranılacak şarj ünitesi
G_i^g	EA'nın i . şarj istasyonuna aktardığı enerji miktarı (kWh)
G_i^v	EA'nın i . şarj istasyonundan aldığı enerji miktarı (kWh)
H	Zaman dilimi sayısı
h_0	Yolculuğun başladığı zaman dilimi
I_i^a	EA'nın i . şarj istasyonuna vardığı zaman dilimi
$\hat{I}_i^a$	Kayan pencereler yöntemi ile elde edilen EA'nın i . şarj istasyonuna en erken vardığı zaman dilimi
I_i^d	EA'nın i . şarj istasyonundan ayrıldığı zaman dilimi
$\hat{I}_i^d$	Kayan pencereler yöntemi ile elde edilen EA'nın i . şarj istasyonundan en geç ayrıldığı zaman dilimi
I_f^s	i . şarj istasyonundaki f . şarj ünitesinin uygun olduğu zaman dilimleri
l	Yolculuğu tamamlamak için gereken enerji miktarı (kWh)
M	Zaman dilimi uzunluğu (dk)
m_i	i . şarj istasyonundaki şarj ünitesi sayısı
n	Şarj istasyonu sayısı
p_{if}	i . şarj istasyonunun f . şarj ünitesinin şarj gücü (kW)
r_0	Yolculuğun başında kalan enerji miktarı (kWh)
R_i^a	EA'nın i . şarj istasyonuna varış anındaki enerji miktarı (kWh)
$\hat{R}_i^a$	Kayan pencereler yöntemi ile elde edilen EA'nın i . şarj istasyonuna varış anındaki kalan enerji miktarı (kWh)

R_i^d	EA'nın i . şarj istasyonundan ayrıldığındaki enerji miktarı (kWh)
$\hat{R}_i^d$	Kayan pencereler yöntemi ile elde edilen EA'nın i . şarj istasyonundan ayrılırken kalan enerji miktarı (kWh)
S	Uğranılacak şarj istasyonları kümesi
S'	Uğranılacak şarj istasyonları kümesi dışındaki şarj istasyonları
s_i	Başlangıç düğümünden i . düğüme varmak için gereken yolculuk süresi (dk)
sp	Doğrusal olmayan şarj süresinin kırılma noktasından sonraki eğimi (%)
T	Yolculuğun hiç durmaksızın tamamlanma süresi (dk)
T_i^a	EA'nın i . şarj istasyonuna varış zamanı (dk)
$\hat{T}_i^a$	Kayan pencereler yöntemi ile elde edilen i . şarj istasyonuna varış zamanı (dk)
T_i^d	EA'nın i . şarj istasyonundan ayrılış zamanı (dk)
$\hat{T}_i^d$	Kayan pencereler yöntemi ile elde edilen i . şarj istasyonundan ayrılış zamanı (dk)
t_{ifh}^g	EA'nın i . şarj istasyonunun f . şarj ünitesinden h . zaman dilimindekideşarj süresi (dk)
t_{ifh}^v	EA'nın i . şarj istasyonunun f . şarj ünitesinden h . zaman dilimindeki şarj süresi (dk)
TS	Zaman dilimleri kümesi
w_{ifh}	i . şarj istasyonunun f . şarj ünitesinin h . zaman dilimindeki uygunluk durumu (boş:1/dolu:0)
x_i^g	EA, i . şarj istasyonundadeşarj edilirse 1, aksi takdirde 0
x_i^v	EA, i . şarj istasyonunda şarj edilirse 1, aksi takdirde 0
y_{ifh}^g	EA, i . şarj istasyonunun f . şarj ünitesinden h . zaman dilimindedeşarj edilirse 1, aksi takdirde 0
y_{ifh}^v	EA, i . şarj istasyonunun f . şarj ünitesinden h . zaman diliminde şarj edilirse 1, aksi takdirde 0
$\tau_{if}(x)$	EA'nın i . şarj istasyonundaki f . şarj ünitesinde enerji miktarını sıfırdan x seviyesine (kWh) çıkarmak için gereken toplam süre (dk)
φ_{ih}^a	EA, i . şarj istasyonuna h . zaman diliminde varıp şarj/deşarj işlemini aynı gün içerisinde tamamlarsa 1, aksi takdirde 0
φ_{ih}^d	EA, i . şarj istasyonundan h . zaman diliminde ayrılıp şarj/deşarj işlemini aynı gün içerisinde tamamlarsa 1, aksi takdirde 0
ϕ_{ih}^a	EA, i . şarj istasyonuna h . zaman diliminde varıp şarj/deşarj işlemini aynı gün içerisinde tamamlamazsa 1, aksi takdirde 0
ϕ_{ih}^d	EA, i . şarj istasyonundan h . zaman diliminde ayrılıp şarj/deşarj işlemini aynı gün içerisinde tamamlamazsa 1, aksi takdirde 0
ζ_i	EA, aynı gün içerisinde i . şarj istasyonda şarj/deşarj işlemini tamamlarsa 1, aksi takdirde 0
ξ_i	EA, aynı gün içerisinde i . şarj istasyonda şarj/deşarj işlemini tamamlamazsa 1, aksi takdirde 0

Kısaltmalar	Açıklama
AC	Alternatif Akım (Alternative Current)
AUS	Akıllı Ulaşım Sistemleri
ClaSP	Sınıflandırma Puan Profili (Classification Score Profile)
DC	Doğru Akım (Direct Current)
DFS	Derin Öncelikli Arama (Depth First Search)
DSA	Derin Sinirsel Ağlar
DZB	Dinamik Zaman Bükme (Dynamic Time Wrapping)
EA	Elektrikli Araç
EASMT	EA’larda Sürüş Menzili Tahmini
EAŞP	EA’larda Şarj Planlama
EPA	Çevreyi Koruma Ajansı (Environmental Protection Agency)
FFM	Fiziksel Formülasyon Modeli
GA	Genetik Algoritma
IoT	Nesnelerin İnterneti (Internet of Things)
Li-ion	Lityum-iyon
MSE	Ortalama Kare Hata (Mean Squarred Error)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MAT-GA	Mat-sezgisel (Genetik Algoritma Tabanlı Matematiksel Model)
RMSE	Kök Ortalama Kare Hata (Root Mean Squarred Error)
SMAT-GA	Sınırlandırılmış MAT-GA
SOC	Bataryanın Şarj Durumu (State of Charge)
SŞPM	Sınırlandırılmış Şarj Planlama Modeli
ROR	Rasgele Orman Regresyonu
V2G	Araçtan Şebekeye (Vehicle to Grid)
VTM	Veri Tabanlı Model

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. EA'ların kalan sürüş menziline etki eden faktörler (Varga vd., 2019)	3
Şekil 1.2. Tez çalışmasının genel akışı	5
Şekil 2.1. Aracı etkileyen gelen kuvvetlerin diyagramı	6
Şekil 3.1. EA'larda menzil tahminine dayalı şarj planlaması-metodoloji	20
Şekil 3.2. Veri analizi akış şeması	23
Şekil 3.3. ChargeCar veri setindeki bir yolculuğa ait statik ve dinamik veriler	24
Şekil 3.4. Şehir içi ve şehir dışı sürüşlerine ait hız profilleri (EPA, 2021)....	25
Şekil 3.5. Duraksama içeren bir yolculuğa ait harcanan enerji (Wh) grafiği	26
Şekil 3.6. Zaman serisi segmentasyonu problemi	27
Şekil 3.7. K-ortalamlar algoritması adımları.....	29
Şekil 3.8. DZB ile bükme yolunun elde edilmesi (Müller, 2015).....	30
Şekil 3.9. Sızıntı ReLU grafiksel gösterimi (Leaky ReLU Explained, 2022)	32
Şekil 3.10. Menzil tahmini için geliştirilen DSA-A ve DSA-B modelleri	33
Şekil 3.11. Şarj süresi prosesinin parçalı lineer fonksiyon yaklaşımı.....	34
Şekil 3.12. Kromozom yapısı.....	44
Şekil 3.13. Çaprazlama için ebeveyn seçimi.....	46
Şekil 3.14. Çaprazlama için kullanılan örnek problemin ulaşılabilirlik ağı.....	46
Şekil 3.15. Mutasyon için uygun genlerin belirlenmesi.....	46
Şekil 3.16. Örnek mutasyon işlemi	47
Şekil 3.17. Enerji seçimi algoritması	47
Şekil 3.18. Mat-sezgisel yaklaşımın akış diyagramı	49
Şekil 3.19. Mat-sezgisel için başlangıç popülasyonun oluşturulması.....	50
Şekil 3.20. Ulaşılabilirlik ağının oluşumunu göstermek için verilen örnek problem	51
Şekil 3.21. Örnek problemin ulaşılabilirlik kümeleri ve ulaşılabilirlik ağı	51
Şekil 3.22. Şarj ünitesi seçimi algoritması	52
Şekil 3.23. Uğranılacak şarj ünitelerine en erken varış ve en geç ayrılış zaman dilimlerinin gösterimi	54
Şekil 4.1. Yolculuk uzunluklarına göre oluşturulan kutu grafiği.....	58
Şekil 4.2. Uzun yolculukların bölünmeden öncesi ve sonrası istatistikler.....	59
Şekil 4.3. DZB yolculukların hız profillerinin şekle dayalı kümelenmesi.....	60
Şekil 4.4. Menzil tahmin modeli için deneysel çalışmalar.....	62
Şekil 4.5. ROR ve DSA-A ile enerji tüketimi tahmini sonuçları	64
Şekil 4.6. Rota tipi kümeleme sonuçlarından bazı örnekler	65
Şekil 4.7. Statik ve dinamik segment verilerini birleştirmek için oluşturulan model mimarileri	68
Şekil 4.8. EPIAŞ 4 Nisan 2022 Pazartesi gününe ait saatlik elektrik enerjisi fiyatları	71

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1. Matematiksel modelde kullanılan notasyonlar	36
Çizelge 4.1. Hız profillerinden elde edilen öznitelikler	60
Çizelge 4.2. Yolculuk bazında enerji tahmini yapan modeller	63
Çizelge 4.3. Gözlem tipinin tahmin sonuçları.....	63
Çizelge 4.4. Küme etiketleri matrisi	64
Çizelge 4.5. Kümelerin karışıklık matrisi	65
Çizelge 4.6. Yolculuk tabanlı modelde rota tipi etiketi kullanmanın etkisi.....	66
Çizelge 4.7. Segment tabanlı modelde özniteliğe ve şekle dayalı küme etiketi kullanmanın etkisi	66
Çizelge 4.8. Statik ve dinamik verinin birlikte kullanmanın segmentte harcanan enerji tahmini üzerindeki etkisi	67
Çizelge 4.9. Statik ve dinamik verinin birlikte kullanmanın yolculukta harcanan enerji tahmini üzerindeki etkisi	68
Çizelge 4.10. Segmentte harcanan enerji tahmini için DSA-C, DSA-D ve DSA-E'nin karşılaştırmalı sonuçları	69
Çizelge 4.11. Yolculukta harcanan enerji tahmini için DSA-C, DSA-D ve DSA-E'nin karşılaştırmalı sonuçları	69
Çizelge 4.12. Test problemlerin üretilmesinde kullanılan parametreler	69
Çizelge 4.13. Matematiksel modelin amaç fonksiyonu minimum yolculuk süresi iken elde edilen sonuçlar	72
Çizelge 4.14. Matematiksel modelin amaç fonksiyonu minimum yolculuk maliyeti iken elde edilen sonuçlar	72
Çizelge 4.15. GA ve MAT-GA parametreleri.....	73
Çizelge 4.16. Minimum yolculuk süresi için karşılaştırmalı sonuçlar.....	74
Çizelge 4.17. Minimum yolculuk maliyeti için karşılaştırmalı sonuçlar.....	75
Çizelge 4.18. Minimum yolculuk süresi için çözüm sürelerinin (sn) karşılaştırılması	76
Çizelge 4.19. Minimum yolculuk maliyeti için çözüm sürelerinin (sn) karşılaştırılması	77
Çizelge 4.20. Minimum yolculuk süresi için karşılaştırmalı sonuçlar.....	78
Çizelge 4.21. Minimum yolculuk maliyeti için karşılaştırmalı sonuçlar.....	78

1. GİRİŞ

Akıllı evler, akıllı şebeke, akıllı şehirler... Son yıllarda birçok alanda karşılaşılabileceğimiz “akıllı” sistemler, kullanıldıkları gerçek zamanlı verileri ile optimal geribildirimler sunabilmekte ve dinamik koşullar altında karar verme sürecinin kolaylaştırılması sağlamaktadır. Cihazların da internete erişebilmesine olanak sağlayan nesnelerin teknolojisi (Internet of Things-IoT) akıllı sistemlerin büyük veriyi kullanarak daha kapsamlı geribildirimler üretmesine olanak sağlar.

Birçok dinamik ve gerçek-zamanlı kararların verildiği ulaşım alanı, akıllı sistem uygulamalarının en sık kullanıldığı alanlardan biridir. Akıllı ulaşım sistemleri (AUS), bulut ve IoT gibi teknolojiler aracılığıyla aktarılan gerçek zamanlı veriler ile ulaşımın yönetimi ve iyileşmeyi sağlayan bir karar destek sistemidir. AUS, seyahatleri optimize etmeye (rota rehberliği), seyahat edilen gereksiz kilometreleri azaltmaya ve trafikte harcanan zamanı azaltmaya yardımcı olabilmektedir (Susan ve Finson, 2013).


Yeşil ulaşımın yapıtaşlarından biri olan elektrikli araçların (EA) yakındaki şarj istasyonlarının konumlarına, şarj gücüne, şarj fiyatlarına, doluluk-boşluk bilgilerine ulaşması AUS ile mümkün hale gelmiştir (Yi ve Shirk, 2018). Başlangıçta özellikle şehir içi ulaşımına uygun olarak tasarlanan EA’lar, gelişen batarya teknolojisi sayesinde uzun yolculuklar yapabilir duruma gelmişlerdir (Ullah, Liu, Yamamoto, Zahid ve Jamal, 2021). Dahası, EA’lar, sıfır emisyonu sahip olduklarından çevre dostu araçlar olarak değerlendirilmekte ve gelecekte içten yanmalı araçların yerini tamamen almaları öngörülmektedir (Un-Noor Padmanaban, Mihet-Popa, Mollah ve Hossain, 2017).

Birçok Avrupa ülkesi, 2030 yılına kadar her türlü geleneksel içten yanmalı aracı yasaklamaya hazırlanmaktadır. Ancak, EA’ların tamamen geleneksel araçların yerine geçebilmesi için sürücülerin menzil kaygısı yaşamadan istedikleri her yere EA ile gidebilecek kadar EA’lara güven duymaları gerekmektedir. Menzil kaygısı, varış noktasına veya herhangi bir yakıt istasyonuna ulaşmadan önce yakıtın bitme korkusudur ve günümüzde EA’lara geçişi olumsuz yönde etkileyen en önemli faktörlerden biri olmaya devam etmektedir. EA’ların sınırlı menzilleri, uzun şarj süreleri ve yetersiz

sayıdaki şarj istasyonları (özellikle EA'ların yeni kullanılmaya başlandığı yerlerde) gibi faktörler menzil kaygısını tetiklemektedir. Menzil kaygısı, potansiyel bir EA alıcısında, EA kullanmanın önemli riskler taşıdığına dair bir algı oluşturabilir (Tannahill, Muttaqi ve Sutanto, 2016). Menzil kaygısının azaltılmasında EA'nın kalan sürüş menzili ile gidebileceği mesafenin bilinmesinin önemli bir katkısı bulunmaktadır (Varga, Sagoian ve Mariasiu, 2019). Bu nedenle, EA sürücülerine doğru bir kalan menzil bilgisi sağlanması, menzil kaygılarının hafifletilmesi açısından önemlidir. Ayrıca Türkiye'de de EA'lara geçişin önündeki en büyük engel olarak, menzil kaygısı ve kamu farkındalığının düşüklüğü olduğu belirlenmiştir (Gönül, Duman ve Güler, 2021).

EA'larda kalan sürüş menzilinın doğru bir şekilde belirlenebilmesi için EA'nın kalan sürüş menziline etki eden faktörler dikkate alınmalıdır. Şekil 1.1'de kalan sürüş menziline doğrudan etki eden faktörler ve etki yüzdeleri gösterilmiştir. Gösterilen sonuçlara göre gerçek dünya koşulları altında batarya şarj durumu (SOC-State of Charge) faktörünün kalan sürüş menziline etkisi %54'e kadar çıkabilmektedir. Geriye kalan %46'yı sıcaklık, sürüş biçimi, yol ve trafik koşulları oluşturmaktadır (Varga vd., 2019). EA'ların navigasyon sistemlerindeki menzil tahmin modellerinin yalnızca EA'nın teknik parametrelerini kullanması, sürüş yapılan rotanın ve diğer dinamik faktörlerin dikkate alınmaması nedeniyle yapılan menzil tahminleri yanıltıcı sonuçlara yol açmaktadır (Sarrafan vd. 2018, Ullah, Liu, Yamamoto, Zahid vd., 2021). Menzil tahminindeki büyük dalgalanmalar, özellikle eğimli yollarda veya yüksek hızlarda sürüş gibi yoğun enerji gerektiren durumlarda ortaya çıkmaktadır (Tannahill vd., 2016).

EA'ların şarj sürelerinin uzun ve şarj istasyon sayılarının yetersiz olması nedeniyle yolculuk öncesi şarj planlanmasının yapılması, menzil kaygısı yaşanmadan bir yolculuk gerçekleştirmek için gereklidir. Şarj planlaması, EA'nın nerede, ne zaman ve ne kadar şarj edilmesi gerektiği kararlarını içeren bir yolculuk planıdır. Akıllı şebeke uygulamalarının yaygınlaşmasıyla şebekeye enerji satışı (Vehicle-to-grid/V2G) işlemlerin artacağı düşünülürse şarj planlama sistemlerinin deşarj seçeneğini dikkate alması önemli hale gelecektir. Şarj planlamasının yapılmadığı yolculuklarda menzil kaygısı sorununun ortaya çıkması kaçınılmazdır (Smuts, Scholtz ve Wesson, 2017).



Şekil 1.1. EA'ların kalan sürüş menziline etki eden faktörler (Varga vd., 2019)


EA'ların uzun yolculuklarda menzil kaygısı çekmeden sürüş gerçekleştirebilmeleri için hangi şarj istasyonunda ne kadar şarj olmaları gerektiği sürücü tarafından bilinmesi gerekmektedir. Şarj planlama problemi, verilen bir rotada EA'nın nerede ve ne kadar şarj olması gerektiği problemidir. EA'ların şarj sürelerinin doğrusal olmaması, akıllı şebeke uygulamaları ile birlikte şarj fiyatlarının zaman dilimlerine bağlı değişmesi ve V2G işlemlerinin gerçekleştirilmesi, şarj planlama problemini zorlaştıran faktörlerdir. Bir EA'nın şarj olma süresi, bir akaryakıt ikmali süresinden oldukça uzundur. 50 kW seviye üç hızlı şarj cihazıyla bile bir EA'yı %0'dan %80 kapasiteye şarj etmek otuz dakika ile bir saat sürebilmektedir (Yang, Sarma, Hyland ve Jayakrishnan, 2021). Yani bir EA, hızlı şarj seçeneğini kullanmasına rağmen benzin istasyonundaki bir araçtan önemli ölçüde daha uzun bir süre beklemesi gerekecektir. Ayrıca, EA sürücüsünün gittiği şarj istasyonunda bekleme kuyruğu olması durumunda, şarj olmaya başlamak için bile uzun bir süre beklemek zorunda kalabilir.

Bu tezin amacı, EA'nın yolculuk yapacağı rotanın gerçek-zamanlı verileri ile menzil tahmini sonuçlarını kullanarak toplam yolculuk süresini veya maliyetini minimize edecek şekilde hangi şarj istasyonunda ne zaman ve ne kadar şarj/deşarj edilmesi gerektiği kararlarını kullanıcıya sunan entegre bir karar destek sisteminin geliştirilmesidir. EA'ların menzil tahmininin seçilen rotanın koşulları baz alınarak yapılmasının tahmin performansı üzerinde etkili olacağı savunulmaktadır.

Tez çalışması kapsamında, EA'lar için sürüş menzil tahmini (EASMT) ve EA'larda şarj planlama (EAŞP) olmak üzere iki temel problem üzerinde durulmuştur. Menzil tahmininin veri bazlı yapay zekâ yöntemi ile yapılması, şarj planlama modelinde menzil tahmin modelinin sonuçlarının kullanılması, şarj planlama modeli için optimal çözümü garantileyen özgün bir matematiksel programlama modelinin geliştirilmesi ve toplam yolculuk maliyetini minimize etmek için V2G seçeneğini dikkate alarak optimal şarj planının oluşturulması tez konusunu özgün kılan özelliklerdir. EA rota optimizasyon çalışmalarında da olduğu gibi (Bourass, Cherkaoui ve Khoukhi, 2017a; Barabadi, Tashtarian ve Moghaddam, 2018; Yi ve Shirk, 2018) şarj istasyonlarındaki doluluk-boşluk bilgileri, şarj kapasitesi ve fiyatları gibi dinamik verilerin, AUS ile edinildiği varsayılacaktır. Bu strateji, şarj istasyonu ve EA'ların birbirleriyle iletişim kurmasına ve EA'ların karayolu ile ilgili bilgi almasına izin veren bir iletişim altyapısı olduğunu varsayar. Bu varsayımlar mevcut teknolojilerin kapasitesi dahilindedir (Razo ve Jacobsen, 2016).

Önerilen entegre karar destek sisteminin genel akışı Şekil 1.2'de gösterilmiştir. EA'ların kalan sürüş menzilin tahmin edilmesinde veri bazlı bir model olarak derin öğrenmeye dayalı menzil tahmini model mimarisi oluşturulmuştur. Modelin eğitimi için uygun yolculuk veri seti araştırılmıştır. Veri seti gerekli ön işlemlere (veri temizleme, dönüştürme vs.) tabi tutulmuştur. Aykırı uzunluğa sahip yolculuk verileri segmente edilmiştir. Yolculukların hız-zaman verileri üzerinde kümeleme işlemi uygulanarak yolculukların rota tipi etiketleri elde edilmiştir ve menzil tahmin modelinde bu etiketler statik girdi olarak kullanılmıştır. Menzil tahmin modeli, sürüş yapılacak rotanın yol segmentleri üzerinde uygulanır. Rota üzerindeki her bir yol segmenti için ortalama hız, yol eğimi, sürüş mesafesi gibi dinamik verilerin yanı sıra hava sıcaklığı, araç ağırlığı ve yol tipi gibi statik veriler kullanılarak önce harcanan enerji, ardından menzil tahmini yapılır. Rota üzerindeki her bir şarj istasyonuna direk sürüş için gereken enerji tüketim miktarı menzil tahmin modelinden elde edilir. EA'nın optimal şarj planının elde edilmesi için matematiksel programlama modeli geliştirilmiştir. Şarj planlama modeli, şarj istasyonun konum bilgilerini, şarj ünitesi sayılarını, güç bilgilerini, fiyat bilgilerini ve uygunluk (doluluk/boşluk) bilgilerini kullanır. Tahmin sonuçları, şarj planlama modelinde girdi parametresi olarak kullanılarak optimal şarj planı bulunur. Şarj planlama

için geliştirilen matematiksel modelinin çözüm verme hızı açısından yetersiz kalması durumunda genetik algoritmaya (GA) dayalı mat-sezgisel yöntem geliştirilmiştir.



Şekil 1.2. Tez çalışmasının genel akışı

Tez çalışmasının birinci bölümünde, tez konusuna dair giriş bilgileri, EASMT ve EAŞP problemleri açıklanmıştır. İkinci bölümde, EASMT ve EAŞP ile ilgili kuramsal temellere ve kaynak araştırmasına yer verilmiştir. Üçüncü bölüm, üç kısımdan oluşmaktadır. İlk kısım, menzül tahmin modelinin eğitimi sırasında kullanılacak EA yolculuklarına ait veri setinin tanıtımı ve ön işlemleri ile ilgili detaylı bilgilendirmeleri içermektedir. İkinci kısım, EASMT için önerilen çözüm yaklaşımı ve üçüncü kısımda ise, EAŞP için kullanılan yöntemler anlatılmaktadır. Dördüncü bölümde, EASMT ve EAŞP için yapılan deneysel çalışmalar ve bulgularına sırasıyla yer verilmiştir. Beşinci bölümde, tartışma ve sonuçlar paylaşılmıştır.


2. KURAMSAL TEMELLER VE KAYNAK ARAŞTIRMASI

Bu bölümde EA'nın sürüş menzili tahmini problemi ve şarj planlaması problemi ile ilgili temel bilgiler ve kaynak araştırması bilgilerine yer verilmiştir.

2.1.EA'larda Sürüş Menzili Tahmini (EASMT)

EASMT, EA'nın yolculuğun başındaki enerji seviyesi ile gerçek zamanlı koşullar altında nereye kadar gidebileceğinin tahmin edilmesi problemidir. EA'ların menzili, bataryada kalan enerji miktarı ile doğrudan ilişkilidir. EA'nın kalan enerjisi ile nereye kadar gidebileceğini belirlemek için EA'nın harcayabileceği enerji hesaplanmalıdır. Menzil tahmini ile ilgili yapılan çalışmalarda kullanılan yaklaşımlar iki kategoride incelenebilir: Fiziksel formülasyon modeli (FFM) ve veri tabanlı model (VTM) (Yavasoglu, Tetik ve Gokce, 2019). FFM'de, EA'ya etki eden fiziksel kuvvetler üzerinden önce güç, sonra da harcanan enerji (veya kalan enerji) hesaplanır (Rhode, Van Vaerenbergh ve Pfriem, 2020). VTM'de ise, yapay zekâ yöntemlerinin kullanıldığı tahmin modelleridir.

Belirli bir yol segmenti için harcanan enerjinin hesaplanmasında FFM'lerinin kullanıldığı çalışmaların sayısı oldukça fazladır. EA'ların yolculuk sırasında harcadığı enerjinin bulunmasında en çok kullanılan FFM'in temelinde araç dinamik modeli yatmaktadır. Şekil 2.1'de EA'ya etki eden kuvvetlerin diyagramı gösterilmiştir.



Şekil 2.1. Aracı etkileyen gelen kuvvetlerin diyagramı

EA'ya etki eden kuvvetler: yuvarlanma direnci, hava direnci, araç ağırlığı ve çekiş kuvvetidir. EA'nın birim zamanda, belirli bir mesafede veya sabit bir hızda harcayabileceği enerjiyi bulabilmek için öncelikle EA'ya etki eden net kuvvet denklem (2.1) ile hesaplanır (Yi ve Shirk, 2018):

$$F(v) = \frac{1}{2}\rho C_d A(v - w)^2 + C_r M g \cos(\alpha) + \tilde{M} a + M g \sin(\alpha) \quad (2.1)$$

Bu denklemde, v , araç hızını ve C_d , hava sürüklenme katsayısını gösterir. A , öngörülen ön alan; w , araç hızı yönünde rüzgâr hızı bileşeni; ρ , hava yoğunluğu; M , araç kütlesi; C_r , yuvarlanma direnci katsayısı; α , yol yüzeyinin açısı; $\tilde{M}$, ataletsel kütle faktörleri; g yer çekimi ivmesi ve a , araç ivmesidir.

FFM'leri ile yapılan enerji tüketimi tahminlerinde, enerji tüketimini etkileyen tüm faktörlerin dikkate alınabilmesi için her faktörün matematiksel olarak tanımlanması gerekmektedir (R. Zhang ve Yao, 2015, Sarrafan vd., 2018;). EA bataryalarının karmaşık ve son derece dinamik davranışları göz önünde bulundurulduğunda, tahmin modelinin geliştirilmesini zorlaştırmaktadır (Bolovinou, Bakas, Amditis, Mastrandrea ve Vinciotti, 2014). Örneğin rejeneratif frenlemenin oluşabileceği durumları hesaba katabilen bir FFM'de frenleme yapılabilecek segmentlerde üretilen gücün belirlenerek enerjiye dönüştürülmesi gerekmektedir. Daha sonra bataryaya olan enerji transferi belirlenmelidir. Aynı şekilde aracın klima ve radyo gibi elektriksel özelliklerinin kullanımı da dikkate alınırsa bu parametreler tanımlanmalı ve tüketilen toplam enerjiye eklenecek denklem oluşturulmalıdır (De Nunzio ve Thibault, 2017). Ancak VTM'lerde ise, her bir parametreyi tanımlamaya ihtiyaç duymadan istenen çıktıların elde edilmesi mümkündür.

VTM'ler, yapay zekâ yöntemlerinin kullanıldığı tahmine dayalı modellerdir. VTM'lerde her bir parametreyi tanımlamaya gerek kalmadan istenilen çıktıları elde etmek mümkündür. FFM'ler, doğru tahminleri desteklemek için yüksek çözünürlüklü gerçek zamanlı bilgilere ihtiyaç duyarken, literatürdeki VTM'ler, enerji maliyeti ve trafik koşulları arasındaki içsel fiziksel ilişkileri içermez (Yi ve Shirk, 2018).

Enerji tüketim tahmini için kullanılan veriler, farklı düzeylerde ve gözlem tipi için derlenebilir. Gözlem türü, tahmin probleminin düzeyini (makro/mikro), uygulanacak tahmin modelini ve kullanılacak girdileri belirlemede önemli bir faktördür. Enerji tüketimi için en çok kullanılan gözlem türleri, segment tabanlı, yolculuk tabanlı, zaman tabanlı ve hız tabanlı gözlemlerdir. Segment ve yolculuk tabanlı gözlemlerde, varış noktasındaki menzili tahmin etmek için rota ile ilgili bilgiler girdi olarak kullanılır. Yolculuk tabanlı gözlemler, yolculuğa ait istatistiksel bilgileri ve/veya statik öznitelikler istatistikleri kullanarak yolculuk sonundaki toplam enerjinin, menzilin veya yolculuk SOC değerinin tahmini için kullanılır (Zheng, He, Zhao ve Li, 2016; El-Bayeh vd., 2016; Foiadelli, Longo ve Miraftebzadeh, 2018; Fukushima vd., 2018; Amirkhani, Haghanifar ve Mosavi, 2019; Ullah, Liu, Yamamoto, Al Mamlook ve Jamal, 2021; Ullah, Liu, Yamamoto, Zahid, vd., 2021). Zaman tabanlı gözlemler, genelde anlık SOC veya enerji tahminleri için kullanılmaktadır ve esas olarak önceki gözlemleri göz önünde bulundurarak veya saniyeler içinde gözlemler yapılarak gerçek zamanlı SOC, enerji tüketimi/hızı veya kalan sürüş mesafesi tahmin edilir (Bolvinou vd., 2014; Fiori, Ahn ve Rakha, 2018; Xia vd., 2018; Sun, Zhang, Bi, Wang ve Moghaddam, 2019; Modi, Bhattacharya ve Basak, 2021). Hız tabanlı modellerde, belirli hız aralıklarındaki enerji tüketim değerleri dikkate alınarak model eğitimi gerçekleştirilir (C. H. Lee ve Wu, 2015; Yi ve Shirk, 2018; J. Bi, Wang, Sai ve Ding, 2019; Topić, Škugor ve Deur, 2019; Ding vd., 2020). Hız tabanlı gözlemlerin kullanıldığı çalışmalarda genelde tek girdi olarak hız kullanılmaktadır.

Bedogni vd. (2014), Nunzio ve Thibault (2017), Sarrafan, Sutanto vd. (2017), Sarrafan, Muttaqi vd. (2017), Thibault vd. (2018), ve Çeven vd., (2020) segment tabanlı gözlemler için enerji tüketimi tahminini FFM'ler ile gerçekleştirmişlerdir. Segment tabanlı gözlemler için VTM geliştiren ilk çalışmalardan biri olan Bolvinou vd. (2014) tarafından ele alınan çalışmada, geçmiş yolculukların ortalama hızı ve enerji tüketimine bağlı doğrusal regresyon ve destek vektörü regresyonu ile sürüş menzilini tahmin etmişlerdir. Cauwer vd. (2017), gelecekteki bir yolculuk için enerji tüketimini tahmin etmek için gerçek dünyadan toplanan sürüş verilerini coğrafi ve hava durumu verileriyle birleştiren çoklu bir doğrusal regresyon modeli sunmuşlardır. Cauwer vd. (2020) çalışmalarında aynı model ile daha sonra en kısa yol algoritmalarını kullanarak enerji tasarruflu rotaların

seçimi için enerji tüketimi ve menzil tahminini entegre eden bir model sunmuşlardır. Zaman, mesafe ve enerjinin minimizasyonu için rota optimizasyonu yapılmıştır. Pamula ve Pamula (2020), otobüs durakları arasındaki enerji tüketimini tahmin etmek için girdi olarak yola bağlı statik veriler ve hava durumu içeren bir derin sinirsel ağ (DSA) modeli kullanmışlardır. Moawad vd. (2021), yolculuk tabanlı ve segment tabanlı gözlemleri birleştiren bir enerji tüketimi tahmin metodolojisi sunmuşlardır.

Enerji tüketimini tahmin etmek için önemli bir faktör, rota tipidir. Araştırmacılar, tahmin doğruluğunu geliştirmek için tahmin modellerinde rota tipi bilgilerini kullanmışlardır (Cauwer vd., 2017; Fetene vd., 2017; Foiadelli vd., 2018; Cauwer vd., 2020; J. Guo vd., 2020). Birçok çevrimiçi harita hizmeti, ayrıntılı rota bilgisi sunmaktadır. Ancak ne yazık ki bazı veri setleri GPS koordinatlarını veya rota tipini içermez ve bu nedenle rota tipinin tahmin edilmesi gerekir. EASMT ile ilgili yapılan bazı çalışmalarda rota tipinin etkisini incelemek için rota tipini tahmin edilmesi üzerinde durmuşlardır. Örneğin, Park vd. (2009) hız profillerine dayalı olarak rota tipini ve tıkanıklık seviyesini tahmin etmek için makine öğrenimi modelleri kullanmışlardır. Yao vd. (2013), farklı rota tipleri için EA'nın enerji tüketim faktörü modelleri oluşturmuşlardır. Elde edilen sonuçlara göre, enerji tüketim faktörü rota tipine göre önemli ölçüde değişmektedir. Shankar ve Marco (2013), rota tiplerini ve trafik sıkışıklık düzeylerini sınıflandırmak için yapay sinir ağlarını kullanan bir çerçeve önermişlerdir. Daha sonra farklı rota tipleri için bir FFM ile enerji tüketimi tahmin edilmiştir. Sarrafan, Sutanto vd. (2017) ve Tannahill vd. (2016), trafik koşullarının etkisini menzil tahmin modeline girdi olarak eklemek için, yol segmentlerini her kilometredeki durak sayısına göre sınıflandırmışlardır. J. Wang vd., (2018), OpenStreetsMap üzerinden elde edilen rota bilgilerine dayalı çevrimiçi ve çevrimdışı enerji tüketimi tahmin algoritması geliştirmişlerdir. Yavaşoğlu vd. (2019), rota tiplerini belirlemek için karar ağacı yöntemini kullanmışlar ve bu sonuçlarını menzili tahmin modellerinde girdi olarak kullanmışlardır. Karar ağacı algoritması, Worldwide Harmonized Light Vehicles Test Cycles (WLTC) üzerinde eğitilmiştir. Zhao vd. (2020), araç hızına, motor akımına ve motor akımının değişim hızına göre rota türleri olarak kabul edilebilecek farklı sürüş modellerini tanımlamak için k-ortalamalar kümeleme yöntemini uygulamışlardır.

EASMT için kullanılan girdileri, statik ve dinamik olarak sınıflandırmak mümkündür. Örneğin, yolculuk boyunca aracın ağırlığı, hava durumu ve yol tipi gibi değişmeyen veya diğer dinamik değişkenlere nispeten daha az değişen veriler statik olarak değerlendirilebilir. Bazı çalışmalarda yolculuklara ait statik bilgiler kullanılarak her bir yolculuk için harcanabilecek enerji tahmin edilir (El-Bayeh vd., 2016; Foiadelli vd., 2018; Fukushima vd., 2018; Amirkhani vd., 2019; Ullah, Liu, Yamamoto, Zahid, vd., 2021). EA'nın hızı, ivmesi, yol segmentlerinin eğimi, mesafesi gibi girdiler ise dinamik girdilerdir. Dinamik veriler hem EA'ya hem de sürüş yapılan rotaya bağlı veriler olabilir.

Statik ve dinamik verilerin birlikte kullanılması farklı problemlerde yaygın olarak görülmektedir. Bu tür problemler en çok tıp ve sağlık alanında görülmektedir. Hastaların yaşı ve geçmiş hastalıkları gibi statik veriler, hastanın durumunu tahmin etmek veya sınıflandırmak için EKG gibi zaman serisi verileriyle birleştirilir (Esteban ve diğerleri, 2016; C. Guo, Lu ve Chen, 2020; Ruan ve diğerleri, 2019). Kristensen ve Burelli (2019), müşteri kaybı tahmini (churn prediction) problemi için zamana bağlı dinamik verilerle birlikte müşteriler hakkındaki statik bilgileri birleştirmişlerdir. Menzil tahmini problemi için Rahimi-Eichi ve Chow (2014), Sarrafan, Muttaqi vd. (2017) ve Yavaşoğlu vd. (2019), statik veriler ile dinamik verileri birbirlerinden ayırt edilmeksizin tahmin modelinde tek bir girdi olarak kullanan çalışmalardır.

Problem türünden bağımsız olarak tahmin/sınıflandırma hatasını azaltmak için statik ve dinamik verilerin farklı kombinasyon yöntemlerine odaklanan çalışmalar da bulunmaktadır. Miebs vd. (2020), yinelemeli sinir ağı (Recurrent Neural Network) modelinin öğrenme sürecini iyileştirmek için zaman serilerinin statik özniteliklerini dahil eden yöntemler sunmuşlardır. Miebs vd. (2020), statik öznitelikleri modelin farklı katmanlarına eklemenin etkisini incelemişlerdir. Çalışmanın sonuçları, zaman serilerinin statik özniteliklerini birleştirme şeklinin, analiz edilen verilerin statik ve dinamik bileşenleri arasındaki istatistiksel ilişkileri öğrenmek için etkili bir araç sağladığını göstermiştir. Ayrıca, statik özniteliklerin tahmin modelinin tahmin gücü yeteneklerini önemli ölçüde artırdığını ortaya koymuştur.

2.2. EA’larda Şarj Planlama (EAŞP)

Tez kapsamında ele alınan EAŞP problemi, bir EA’nın kalan sürüş menziline daha fazla mesafe gerektiren bir rota üzerinde şarj ünitelerindeki farklı şarj güçlerini, zaman dilimlerine bağlı değişen şarj fiyatlarını, doğrusal olmayan şarj sürelerini ve doluluk-boşluk bilgisini ve V2G uygulamalarını da dikkate alarak optimal şarj ve deşarj yerlerinin, şarj/deşarj miktarının ve zamanlarının bulunması problemidir.

EA’larda şarj standartları ülkelere göre değişmektedir. Şarj standartlarına bağlı olarak şarj istasyonlarının konnektör türleri ve EA’ların şarj soket tipleri farklılık gösterebilmektedir. Örneğin Amerika’da SAE ve IEEE standartları, Avrupa’da IEC, Japonya’da ChaDeMo, Çin de ise IEC ve Guabiao standardı kullanılmaktadır (Das, Rahman, Li ve Tan, 2020).

Şarj istasyonun sağladığı maksimum gücün (kW), EA’nın kabul edebildiği maksimum gücü aşması durumunda EA kabul edebileceği kadar güç temin edebilir. Dolayısıyla EA’nın şarj istasyonlarından alabileceği maksimum güç sınırını EA belirler. Şarj sırasında enerji transferinin hızı, şarj gücü ile ilişkilidir ki bu da iki faktöre bağlıdır: voltaj ve amper (Mies, Helmus ve Hoed, 2018; Schoenberg ve Dressler, 2019). Gerçekte, bir EA’nın şarj süresi, şarj hızına ve EA’nın şarj öncesi ve sonrası SOC seviyesine bağlıdır. EA bataryasının çıkış voltajının belirli bir maksimum değerinde şarj işlemi iki aşamaya ayrılır: İlk aşamada, pil seviyesi zamanla hızlı ve doğrusal olarak artar. İkinci aşamada, pil seviyesi zamanla yavaş ve içbükey olarak artar. Bu nedenle, şarjı bitmiş bir bataryanın tam şarjlı bir batarya ile değiştirilmediği sürece sabit bir şarj süresi olduğu söylenemez (Fu ve Dong, 2019). Şarj süresi, EA’nın SOC miktarına bağlı olarak doğrusal olmayan, konkav bir yapı sergilemektedir. Şarj süresi bazı çalışmalarda doğrusal fonksiyon olarak varsayılırken (Keskin ve Çatay, 2016; Rastani, Yüksel ve Çatay, 2019), bazı çalışmalarda şarj süresi parçalı doğrusal fonksiyon olarak modellenmiştir (Fu ve Dong, 2019; Keskin, Laporte ve Çatay, 2019). Ayrıca, EA’nın SOC değeri belirli bir değerin altında iken (%20 ve altı) EA’nın sergilediği davranış, genel pil modelinden farklı ve tutarsız olduğundan, modellerde EA için minimum şarj seviyesi dikkate alınmıştır (Keskin vd., 2019; Sun vd., 2019).

EAŞP problemlerinde, şarj politikası farklı varsayımlara dayanarak modellenmiştir. Şarj politikaları varsayımları iki gruba ayrılır: tam şarj ve kısmi şarj. Tam şarj politikası altında, bir EA şarj istasyonuna her ulaştığında istasyonda tam şarj (veya belirlenen maksimum bir şarj seviyesi) ile ayrılırken, kısmi şarj politikası altında şarj miktarı karar değişkeni olarak ele alınır (Fu ve Dong, 2019).

EAŞP ve rotalama ile ilgili çalışmalarda iki perspektiften bahsetmek mümkündür: EA ve şarj istasyonu (kontrol merkezi olarak da tabir edilebilir) perspektifi. EA için amaç, minimum sürede ve minimum maliyet ile rotanın tamamlanmasıdır. Bu bakış açısı bireyseldir. Kontrol merkezli perspektifte ise hem EA'lar hem de şarj istasyonları için en uygun şarj programı belirlenir (Liu vd, 2020; L.P. Qian, Zhou, Yu ve Wu, 2020; F. Xia, Chen, Chen ve Qin, 2019; C. Zhang, Fanaee ve Thoresen, 2021). Kontrol merkezli perspektifte EA, en müsait şarj istasyonuna yönlendirilmektedir (Bourass vd., 2017a; Moghaddam vd., 2018; Razo ve Jacobsen, 2016; Tannahill vd., 2016). Bu tarz çalışmalarda amaç, EA için optimal rotayı ve şarj planını elde ederken şarj istasyonundaki enerji talep yükünü dengelemektir. EA'ların yanı sıra şarj istasyonları için de bir çizelge oluşturulur. Ancak bu yaklaşımlar belirli bir konum/simülasyon ortamı/şehir içerisinde yapılan kısa yolculuklar için uygundur.

Literatürde EAŞP problemi genel olarak EA rotalama ile birlikte ele alındığı (Bac ve Erdem, 2021; Basso vd., 2019; X. Bi ve Tang, 2019, Keskin vd., 2019; Pelletier vd., 2019, Rastani ve Çatay, 2021; Rastani vd., 2019; Shao vd., 2017) görülmektedir. Bu çalışmaların genel özellikleri şarj planı ile birlikte optimal rotanın elde edildiği modeller içermesidir. Başlangıçta EA'ların %100 şarj edildiği varsayımı mevcuttur. Rotalama problemlerinde amaç genellikle en kısa sürede ve maliyette müşterilere uğrayıp yolcuğu tamamlamaktır. Araç rotalamada müşteri, müşterilere teslim zamanları gibi faktörler dikkate alınır. Ayrıca çoğu EA rotalama probleminde EA'ların yolculuk sırasında en fazla bir kez şarj edilebilir şeklinde kısıtlama bulunmaktadır. Ancak bireysel sürüşlerde, sürücünün yolculuk amacına da bağlı olarak böyle bir kısıtlamaya gerek duyulmayabilir. Dahası, V2G işlemlerinin de dikkat alındığı varsayıldığında sürücü maliyetini minimize etmek amacıyla yolculuk süresini uzatarak aracını deşarj etmek isteyebilir. Sonuç olarak EA rotalama problemi ile sunulan EAŞP problemi ile tam olarak örtüşmese de EAŞP, EA

rotalama probleminin bir alt problemi olduğu için ilgili literatür çalışmalarına burada yer verilmiştir.

Pelletier vd. (2018), belirli rotalar üzerinde sürüş yapan EA filoları için şarj maliyetini minimize eden optimal şarj planı bulmak için matematiksel programlama modeli geliştirmişlerdir. Modellerinde farklı şarj tipleri ve doğrusal olmayan şarj süreleri dikkate alınmıştır. EA'ların rota üzerindeki şarj sayısı için bir üst limit verilmiştir. Rastani vd. (2019), hava sıcaklığının EA'nın enerji tüketimine etkisini incelemek için sıcaklığı bağlı toplam enerji maliyetini minimize eden bir matematiksel programlama modeli geliştirmişlerdir. EA rotalama probleminin ele alındığı çalışmada, EA'lar ardışık iki müşteri arasında en fazla bir kez şarj edildiği varsayılmıştır.

Keskin vd. (2019), EA rotalama problemi için istasyonda bekleme sürelerinin de hesaba katıldığı, şarj sürelerinin parçalı fonksiyon olarak belirtildiği bir matematiksel programlama modeli geliştirmişlerdir. Amaç, toplam maliyeti minimize edecek rota ve şarj planının ele edilmesidir. EA'ların başlangıç noktasından tam şarj ile ayrıldığı varsayıldığı çalışmada kısmi şarj stratejisi benimsenmiştir.

Pelletier vd. (2019), EA rotalama problemi bağlamında enerji tüketimi belirsizliklerini dikkate almak için bir optimizasyon modeli önermişlerdir. Amaç, EA'nın rotası sırasında şarjının bitmeyeceğine dair güçlü garantiler sağlayabilecek minimum maliyetli teslimat yollarını belirlemektir. Problem, karma doğrusal programlama modeli olarak formüle edilmiştir. Enerji tüketimi modellerinde rejeneratif enerji ile enerjinin geri kazanımı dikkate alınmamıştır. Modelde yolculuk içerisinde şarj yapılmadığı varsayıldığı için şarj planı oluşumu söz konusu değildir. Bac ve Erdem (2021), farklı EA modellerinden oluşan bir filo için optimal rota ve şarj planı elde etmek için komşuluk aramaya dayalı sezgisel algoritma önermişlerdir. Ele aldıkları problemde EA'ların başlangıç noktasından %100 şarj ile ayrıldığı varsayılmaktadır.

EAŞP ile ilgili çalışmalardaki problemlerde tek seferli ve çok seferli şarj olarak iki kategori mevcuttur. Tek seferli şarj için optimal şarj planı öneren çalışmalar bulunmaktadır (Basso vd., 2019; Qian vd., 2020; Y. Wang vd., 2018; Zhang vd., 2021).

Bu çalışmalarda genelde şehir içi sürüşler veya belirli bir yol ağı için geliştirilen şarj planları bulunmaktadır. Şarj planı ile beraber rotanın da belirlendiği problemlerdir.

Y. Wang vd. (2018), optimal rotaların belirlenmesinde yolculuk süresini, enerji tüketimini ve şarj maliyetlerini minimize etmek için çok amaçlı bir optimizasyon modeli geliştirmişlerdir. Şarj istasyonlarında tek tip, sabit güç miktarı olan şarj ünitelerinin olduğu ve EA'ların verilen yol ağında en fazla bir kez şarj olabileceği varsayılmaktadır. Problemin çözümü için GA tasarlanmıştır. T. Qian vd. (2020), trafik koşullarının, şarj fiyatlarının ve şarj istasyonlarındaki bekleme süresinin rassal değişiminin göz önünde bulundurulduğu, toplam yolculuk süresini ve şarj maliyetini en aza indirmeyi amaçlayan derin pekiştirmeli öğrenme (Deep Reinforcement Learning) tabanlı EV şarj navigasyon modeli önermişlerdir. EA şarj navigasyon modeli Markov karar süreci olarak formüle edilmiştir. EA pil tüketiminin gidilen mesafe ile doğrusal değiştiği varsayılmıştır.

Çok seferli şarj problemleri, genelde şehirlerarası yolculuklar için geliştirilen şarj planlarıdır. Sweda vd. (2017), şarj istasyonlarındaki bekleme sürelerinin bilinmemesi durumunda optimal bir uyarlamalı yönlendirme ve yeniden şarj etme politikası elde etmek için toplam yolculuk maliyetini minimize edecek dinamik programlamaya dayalı algoritmalar önermişlerdir. Strehler vd. (2017), EA ve hibrit EA'lara yönelik birden fazla durak seçimi içeren bir araç rotalama problemi için en kısa yolun bulunmasını sağlayan genel bir model tanıtmışlardır. Y.W. Wang vd. (2018), şarj istasyonu yer seçimi için geliştirdikleri matematiksel modeli (Y.W. Wang ve Lin (2009)) şarj planlama problemi için uyarlamışlardır. Sunulan modelde amaç, turistik bir rota takip eden bir EA'nın ziyaret edilen turistik merkezlerinin ağırlık puanının toplamını en üst düzeye çıkarmaktır. Problem bir maksimizasyon problemi olduğu için yolculuk süresi için üst limit belirlenmiştir.

Yapılan çalışmalardan anlaşıldığı üzere, spesifik olarak rotanın belirli olduğu bir senaryo için EA'nın şarj yeri ve miktarı seçimi problemi üzerinde çalışma sınırlı sayıdadır. Y. Wang vd. (2021), belirlenen bir rota için seyahat süresini ve şarj maliyetini birlikte en aza indirmeyi ve mevcut rotalar boyunca yer alan her şarj istasyonunda en uygun şarjlı enerji miktarını dinamik programlama yöntemi ile belirlemişlerdir.

2.3. Bütünleşik Problem: EA'larda Menzil Tahminine Dayalı Şarj Planlaması

EASMT ve EAŞP'yi birlikte ele alan ilk çalışmalar, optimal şarj yeri seçiminden ziyade daha çok şarj öneri sistemleri geliştirmişlerdir. Şarj öneri sistemlerinde amaç, menzil tahmini sonucuna göre SOC değerinin belirlenen bir eşik değerinin altında olmamasını sağlayacak şekilde EA'yı en yakın istasyona yönlendirmektir (Sarrafan, Muttaqi vd., 2017, Tannahill vd. 2016). Tannahill vd. (2016), menzil kaygısını azaltmak için rota bilgileri, şarj istasyonu konumları, sürüş koşulları ve sürücü davranışına bağlı SOC değerini tahmin eden bir FFM geliştirerek, tahmin edilen SOC değerine göre sürücünün şarj etmesi gerektiği durumları uyarıcı bir sistemi geliştirmişlerdir. Chokkalingam vd. (2017), SOC tahmini ile rota üzerinde şarj istasyon önerisi veren bir metodoloji geliştirmişlerdir. Sarrafan, Muttaqi vd., (2017), rota bilgileri, hava koşulları ve batarya sağlık durumunu da dikkate alan formülasyonlar ile EA'nın kalan şarj ve menzili belirlemişlerdir. EA'nın tüm yolculuk süresi içinde kaç kere şarj ihtiyacının oluşabileceğini ve nerede şarj edilebileceğini belirleyen bir sezgisel algoritma geliştirmişlerdir. EA'nın tam (%100) şarj edildiği veya hedefe varması için gereken minimum şarj miktarı kadar şarj edildiği varsayılır. Kalan sürüş menzili hesaplanırken EA'nın yolculuk boyunca oluşturduğu sürüş profili baz alınmıştır.

Bahsi geçen çalışmalarda menzil tahminine dayalı şarj öneri sistemi geliştirilmiştir. Şarj öneri sistemi yerine menzil tahminine dayalı optimal şarj planının elde edildiği çalışmalar da bulunmaktadır. Bourass vd. (2017a), şarj istasyonlarındaki bekleme süresini minimize etmek için şarj ihtiyacı olan EA'ları en uygun şarj istasyonuna yönlendiren bir algoritma geliştirmişlerdir. AUS ile bilgi aktarımının sağlandığı sistemde EA'ların ulaşabileceği şarj istasyonlarının belirlenmesi için geliştirdikleri matematiksel model ile enerji tüketim tahmini yapılmıştır. Çalışmada EA'ların hedef şarj seviyelerinin olduğu varsayılmaktadır. Yazarlar, iki aşamalı bir şarj planlama modeli geliştirmişlerdir. İlk aşamada EA'nın harcayacağı enerjiyi minimize eden rota belirlenir. Enerji tüketimi için FFM tercih edilmiştir. Ardından toplam yolculuk süresini minimize edecek şekilde şarj planı oluşturulur. Yi ve Shirk (2018), EA'ların şarj maliyetini minimize etmek için yalnızca aracın hızına bağlı bir enerji tüketim modeli geliştirerek dinamik programlama

ile şarj planı oluşturmuşlardır. EA'nın rotasının evde başlayıp evde bittiği ve rota üzerindeki durakların arasındaki mesafenin EA menziline kısa olduğu varsayılmıştır.

Schoenberg ve Dressler (2019), EA'ların hızına bağlı enerji tüketimine göre minimum yolculuk süresini belirlemek için rota seçimini ve şarj planını optimize eden bir yaklaşım önermişlerdir. Rota seçimi için, Dijkstra ve A* algoritmaları kullanılmıştır. Rota seçimi aşamasında EA'nın bir sonraki şarj istasyonunda tam şarj olduğu varsayılmıştır. Şarj istasyonu seçimi için, EA'nın mevcut şarj istasyonunda sağlanan güç ile bir sonraki istasyondaki gücün karşılaştırılmasına göre seçim yapılır.

Basso vd. (2019), Newton'un hareket yasasını baz alarak geliştirdikleri FFM ile yol segmentlerinde harcanan enerjiyi belirleyerek elde ettikleri çıktıları tamsayılı doğrusal programlama modellerine parametre olarak eklemişlerdir. Zaman pencereli EA'ların rotalama problemi için gerçekleştirilen çalışmada şarj istasyonlarına uğrayan EA'ların tam şarj edildiği varsayılmıştır. Bi ve Tang (2019), EA rotalama probleminin toplam yolculuk süresini minimize etmek için stokastik bir dinamik programlama model önermişlerdir. Trafikte bekleme sürelerinin zamana bağlı stokastik değiştiğinin varsayıldığı çalışmada EA'nın trafikteki hızına göre harcadığı enerji FFM ile hesaplanarak optimal şarj planını içeren strateji elde edilmiştir. Fu ve Dong (2019), EA'lar için şarj istasyonlarındaki bekleme sürelerini, doğrusal olmayan şarj süresini ve hıza bağlı değişen enerji tüketimini dikkate alan iki aşamalı bir şarj planlama ve rotalama modeli geliştirmişlerdir. Birden fazla şarja izin veren modelde EA'ların tam şarj ile istasyondan ayrıldıkları varsayılmıştır. C. Zhang vd. (2021), şehir içi tek seferlik şarj problemi için pekiştirmeli öğrenme yöntemi ile optimal EA-şarj istasyonu çizelgesi oluşturmuşlardır. EA'ların sürüş mesafesine göre harcadıkları enerjiyi tahmin etmek için doğrusal regresyon modeli kullanılmıştır. Hecht vd. (2021), Almanya'daki şarj istasyonlarının yeterliliğini değerlendirmek için yaptıkları çalışmada belirli bir rota üzerinde yolculuk maliyetini minimize etmek amacıyla iki aşamalı bir optimizasyon modeli geliştirilmişlerdir. İlk aşamada gidilecek şarj istasyonu belirlenirken, ikinci aşamada gidilecek istasyonlardaki şarj miktarı optimize edilmektedir. Modellerinde kısıt olarak yalnızca minimum şarj seviyesi ve varış sırasındaki hedef şarj seviyesinin altına inilmemesi sağlanmıştır. Optimizasyon modelinde harcanan enerjiye bağlı menzil

tahmini için polinomsal regresyon modeli kullanılmıştır. Rastani ve Çatay (2021), EA rotalama problemini taşıyan yükün ağırlığını dikkate alarak zaman pencereleri ile ele almışlardır. Çalışmalarında menzil tahmini için geniş adaptif komşuluk arama (Large Adaptive Neighbourhood Search) yönteminde optimal bir onarım prosedürünü bütünlükten ve performansını doğrulayan mat-sezgisel bir yaklaşım geliştirmişlerdir. Elde edilen sonuçlara göre kargo ağırlığının rota planlarında ve filo büyüklüğünde önemli değişiklikler yaratabileceğini ve ihmal edilmesinin hizmette ciddi aksamalara neden olabileceğini ve yükün artmasına neden olabileceğini göstermektedir.

2.4.Araştırma Boşlukları

Literatürde EASMT ve EAŞP problemlerini ile ilgili birçok çalışma olmasına rağmen bu iki problemi bir arada değerlendiren (menzil/enerji tüketim tahminine dayalı şarj planlama veya rotalama) sayılı çalışma bulunmaktadır (Basso vd. 2019). Ek 1’de EASMT ve EAŞP problemlerini bir arada ele alan çalışmaların listelendiği bir çizelge verilmiştir. EASMT ve EAŞP problemlerini birlikte ele alan çalışmalarda enerji tahmini için çoğunlukla FFM’lerinin tercih edildiği görülmektedir. Enerji/menzil tahminine ağırlık veren çalışmalar, optimal şarj yeri seçiminden ziyade şarj öneri sistemi olarak modellenmiştir (Sarrafan, Muttaqi, vd. 2017; Tannahill vd., 2016).

Şarj planlaması ile ilgili yapılan çalışmalardaki genel varsayım, EA’nın kat ettiği mesafe ile SOC değişiminin ve dolayısıyla harcanan enerjinin, doğrusal olarak değiştiğidir. (Keskin vd., 2019; Moghaddam vd., 2018; Pelletier vd., 2018). Ancak harcanan enerji yalnızca mesafeye bağlı olarak değişmemektedir. Yolculuğun gerçekleştirildiği rotanın eğim bilgisi, trafik, hava, ortalama hız gibi gerçek-zamanlı koşullar harcanan enerjiye ve dolayısıyla kalan sürüş menzili üzerinde etkili olacaktır. Bu nedenle optimal şarj planının elde edilmesinde menzil tahmininin rotaya bağlı olarak gerçek-zamanlı veriler dikkate alınarak yapılması doğruluk oranını artıracaktır.

Yapılan çalışmalar tek seferlik şarj odaklı tasarlandıklarından ve buna bağlı olarak test sürüşleri de kısa mesafelerden ibaret olduğundan dolayı uzun rotalar için şarj istasyonları ve menzil kaygısı açısından rotanın uygun olup olmadığı dikkate alınmamaktadır. Aynı

şekilde uzun rotalar için birden çok şarj işlemi gerçekleştirilebileceği için anlık şarj seviyesine göre şarj yeri öneren sistemler optimal bir şarj planı elde etme garantisi vermemektedir.

Varış noktasındaki menzili tahmin etmek için literatürde hem mesafe tabanlı hem de yolculuk tabanlı veriler kullanılmış olsa da daha iyi bir tahmin doğruluğu için her iki veri türünün birlikte kullanmanın etkisi araştırılmamıştır. Şarj planlama modelini menzil tahmini ile entegre eden çalışmalarda menzil tahminleri birbirine benzer FFM'lerden ibarettir. Menzil tahminini şarj planlaması ile birlikte dikkate alan çalışmalarda, belirlenen bir rota için zamana bağlı güncellenen parametreler bulunmamaktadır. Örneğin segmentlerde harcanan enerjinin yolculuk boyunca değişmediği varsayımı altında şarj planlaması yapılmaktadır. Ayrıca EA sürücülerini açısından maliyet azaltıcı bir etken olan V2G opsiyonları da şarj planlama modellerinde dikkate alınmamıştır.

Literatürdeki bu araştırma boşluklarını da dikkate alarak belirlenen bu tezin amacı, rota bilgilerine bağlı olarak harcanan enerji tahmini için veri bazlı yapay zekâ modeli ile kalan sürüş menzilini belirleyerek EA'nın belirli bir rota için toplam yolculuk süresini ve şarj maliyetini minimize edecek şekilde şarj/deşarj yerini ve miktarını veren optimal şarj planının oluşturulmasıdır. Önerilen metodoloji iki temel modülden oluşmaktadır: menzil tahmini ve şarj planlaması. EA'nın başlangıçtaki şarj durumu ile tamamlayamayacağı bir rota için nerede, ne zaman ve ne kadar şarj/deşarj edilmesi gerektiği yapılan menzil tahmin bilgilerine göre şekillenir. Şarj planlama modeline menzil tahmin modelini entegre ederek iç içe kullanılması ve menzil tahminin veri bazlı yapay zekâ yöntemi ile yapılması, şarj planlama modelinin doğrusal olmayan şarj, birden fazla şarj ünitesi varsayımını ve V2G seçeneğini aynı anda dikkate alması çalışmayı özgün kılan özelliklerdendir. Önerilen konu elektrikli otonom araçların uzun yolculuklarda şarj planlama sistemlerinin tasarımı için de bir altyapı oluşturabilir.

Bu çalışmanın ilk modülü olan EASMT bölümünde VTM ile kalan sürüş menzilinin tahmini üzerine odaklanılmıştır. Gözlem tipi, rota tipi ve statik-dinamik özelliklerin tahmin sonuçları üzerindeki etkilerini analiz etmek için deneyler yapılmıştır. Yapılan katkılar aşağıda özetlenmiştir:


- Yolculuk bazlı ve segment bazlı gözlemlere sahip enerji tüketimi tahmin modellerinin karşılaştırılması
- Rota türü bilinmeyen yolculukların özniteliğe ve şekle dayalı kümeleme yöntemi ile rota tiplerinin kümelenmesi ve tahmin performansına etkisinin incelenmesi
- Statik ve dinamik yolculuk verilerinin birlikte kullanımının tahmin performansına etkisinin incelenmesi

Çalışmanın ikinci modülü olan EAŞP bölümünde EA'ların sürüş yapmasına uygun uzun bir rota için özgün bir matematiksel programlama modeli ve mat-sezgisel çözüm yaklaşımı önerilmiştir. Tez çalışmasının EA'larda şarj planlama literatürüne katkıları aşağıdaki gibi listelenmiştir:

- Şarj istasyonlarında birden fazla şarj ünitesinin doğrusal olmayan şarj sürelerinin olduğu, zaman dilimlerine bağlı değişen şarj fiyatlarının ve V2G işlemlerinin gerçekleştirildiği bir şarj planlama problemi için özgün bir karmaşık tamsayılı doğrusal programlama modelinin geliştirilmesi
- Menzil tahminine dayalı şarj planlama problemi için genetik algoritmaya dayalı mat-sezgisel yaklaşım geliştirilmesi
- Geliştirilen mat-sezgisel yaklaşımının dört farklı sezgisel ve bir metasezgisel yaklaşımla karşılaştırılması

3. MATERYAL ve YÖNTEM

EA'lara yönelik kalan sürüş menzili tahminine dayalı şarj planlama modelinin genel akışı Şekil 3.1'de verilmiştir.



Şekil 3.1. EA'larda menzili tahminine dayalı şarj planlaması- metodoloji

Problemin çözümü için öncelikle EA'nın sürüş yapacağı rota belirlenir. Rota, yol segmentlerine bölünür. Her bir yol segmenti için eğim, hız limiti, ortalama hız, yol tipi gibi bilgiler elde edilir. Her segment için varış zamanına göre zamana bağlı parametrelerin bilgileri (hava durumu, trafik vs.) temin edilir. Bu bilgiler ile araç parametre bilgileri (araç kütlesi, anlık şarj durumu vs.) kullanılarak her bir yol segmenti için menzil tahmin modeli ile harcanan enerji tahmini yapılır ve kümülatif olarak toplanır. Rota üzerindeki her bir şarj istasyonuna direk sürüş için gereken enerji tüketim miktarı menzil tahmin modelinden elde edilir. Tahmin sonuçları, şarj planlama modelinde girdi parametresi olarak kullanılarak optimal şarj planı bulunur. Şarj planlama modeli şarj istasyonunun konum bilgilerini, şarj ünitesi sayılarını, güç bilgilerini ve fiyat bilgilerini kullanır. Şarj planlama modeli ile toplam yolculuk maliyetini veya süresini minimize eden optimal şarj planı elde edilir.

3.1. Veri Seti

Menzil tahmini modelinin eğitiminde kullanılmak üzere Carnegie Mellon Üniversitesi tarafından yürütülen ChargeCar projesine (CREATE Lab, 2009) ait gerçek GPS verileri kullanılmıştır. EA'ların verimliliğinin nasıl artırılabilirliğinin ve pil ömrünün nasıl uzatılabilirliğinin araştırıldığı projede Amerika ve Avrupa'dan farklı sürücü ve araçlara ait toplam 423 yolculuk verisi bulunmaktadır. Yapılan yolculukların başlangıç noktası, tarihi, hava sıcaklığı ve toplam harcanan enerji bilgileri mevcuttur. EA'ların sahip oldukları farklı motor ve batarya özellikleri, menzillerinin de farklı olmasına yol açmaktadır. Dolayısıyla farklı EA'lara ait yolculuk verilerinin menzil tahmin modeli eğitiminde kullanımının tahmin doğruluğunu azaltması ve önerilen şarj planlama sisteminin tek bir EA modelinin navigasyon sisteminde kullanımına uygun olması nedeniyle tahmin modeli eğitimi için belirli bir araca ait veriler kullanılmıştır.

Menzil tahmin modeli eğitimi için ChargeCar projesinde en fazla veriye sahip olan Toyota RAV4 EV araç modeli seçilmiştir. Seçilen EA'nın 10 farklı sürücüye ait toplam 55 adet yolculuk verisi bulunmaktadır. Bu yolculuklara ait bilgiler Çizelge 3.1'de verilmektedir.

Çizelge 3.1. Toyota RAV4 EV sürüşlerine ait bilgiler

Sürücü	Yolculuk sayısı (adet)	Yolculuk mesafesi (km)
İllah	18	478
Ron	7	265
Walter	6	441
Mike	4	101
Nikolay	6	340
Todd	4	194
Arnold	3	130
Marcos	3	198
Jorgen	3	54
Chris	1	33
Toplam	55	2234

Yolculuk verileri, yolculuğun başından itibaren araçtan belirli zaman aralıklarında alınan gözlemlerle oluşturulmuştur ve her gözlem için elde edilen öznitelikler Çizelge 3.2’de yer almaktadır. İtalik olan satırlar, orijinal veri setinde olmayıp, sonradan hesaplanıp eklenen öznitelikler belirtmektedir. Tahmin edilmek istenen öznitelik olan harcanan enerji öznitelik olarak veri setinde mevcut değildir. Yalnızca yolculuk için toplam harcanan enerji bilgileri verilmiştir. Her bir gözlem için harcanan enerjinin hesaplanması amacıyla iki gözlem arası geçen süre ile gücün çarpımı olarak harcanan enerji bulunmuştur.

Çizelge 3.2. EA’nın sürüş verisine ait dinamik veriler


Öznitelik	Açıklama (birim)
Zaman	Yolculuk sırasındaki zaman (saat: dakika: saniye)
<i>Süre</i>	<i>İki gözlem arası geçen zaman (s)</i>
Yükseklik	Aracın bulunduğu konumun yüksekliği (m)
<i>Yükseklik değişimi</i>	<i>İki gözlem arası yükseklik farkı (m)</i>
Eklenen mesafe	İki gözlem arası eklenen mesafe (m)
Hız	Aracın anlık hızı (m/s)
İvme	İki gözlem arası aracın ivmesi (m/s^2)
Güç	Aracın anlık gücü (kW)
<i>Enerji</i>	<i>İki gözlem arası aracın harcadığı enerji (Wh)</i>

Yolculuğa ait genel bilgileri içeren öznitelikler Çizelge 3.3’te verilmiştir.

Çizelge 3.3. Yolculuğa ait statik veriler

Öznitelik	Açıklama
Sürücü	Yolculuğu yapan sürücünün ismi
Sürüş tarihi	Yolculuk tarihi (gün.ay.yıl)
Ağırlık	Araç ve yük ağırlığı (kg)
Konum	Yolculuğun başlangıç konumu (şehir)
Süre	Yolculuk süresi (dk)
Harcanan enerji	Yolculukta harcanan toplam enerji (kWh)
Sıcaklık	Sıcaklık derecesi (°C)


Veri seti analizi için izlenen akış Şekil 3.2’de verilmiştir. Veri ön işleme kapsamında eksik veri, aykırı veri analizi, veri dönüşümü, veri normalizasyonu, öznitelik seçimi ve çıkarımı işlemleri gerçekleştirilmiştir.



Şekil 3.2. Veri analizi akış şeması

3.1.1. Veri önışleme

Veri setini menzil tahmin modelinde kullanılabilir hale getirirken dikkate alınması gereken ilk husus, verilerin önceden veya gerçek-zamanlı olarak temin edilebilirliğıdir. Yolculuklara ait veri seti, belirli saniyelerde aracın sensörlerinden elde edilen verileri içeren zaman serileridir. Ancak gerçek hayat uygulamasında bir rotanın ileriye dönük saniye bazında zaman-serileri verilerini temini mümkün olmayabilir. Bunun yerine yolculuklara ait zaman serileri yol segment verilerine dönüştürülebilir. Yol segmenti kullanmanın en önemli avantajı konuma dayalı olmasıdır. Böylece bulunan zamandan ileriye yönelik bir rota için menzil tahmini yapılırken rota segmentlere ayrılarak her bir segment için veri temin edilir ve menzil tahmin modelinde girdi olarak kullanılabilir. Zaman serilerini yol segmentlerine dönüştürmek için iki gözlem arasındaki fark alınır. ChargeCar veri setinde hız, yükseklik, gidilen mesafe gibi dinamik özniteliklerle birlikte hava sıcaklığı ve araç ağırlığı gibi statik öznitelikler de bulunmaktadır (Şekil 3.3).




Şekil 3.3. ChargeCar veri setindeki bir yolculuğa ait statik ve dinamik veriler

Tahmin modelinde kullanılacak verileri değerlendirirken ilk dikkate alınması gereken özellik verinin yolculuğun başında temin edilebilirliğıdir. Örneğin yol segmentlerine bölünmüş bir rotanın dinamik girdi parametrelerinden yol segment mesafesi, sürüş süresi, ortalama sürüş hızı ve yükseklik/eğim bilgilerin temin edilmesi mümkündür. Ancak EA'nın yol segmentlerinde sarf edeceği güç miktarının bilinmesi (herhangi bir tahmin

yöntemi ile tahmin edilmediği sürece) mümkün değildir. Bu nedenle “Güç” özneliği gerçek hayatta rota üzerinde uygulama yaparken önceden bilinebilecek bir öznitelik olmadığı için girdi parametresi olarak değerlendirilmemiştir.

Menzil tahmini probleminde kullanılacak olan veri seti, birçok önemli özneliği içeriyor olsa da yolculuğa bağlı bazı karakteristik özniteliklerin eklenmesi menzilin tahmin edilmesinde kritik değer taşıyabilir. Araştırmacılar, enerji veya menzil tahmin doğruluğunu artırmak için tahmin modellerinde rota tipi bilgilerini kullanmışlardır (De Cauwer vd. 2017, 2020, Fetene vd. 2017, Foadelli vd. 2018, J. Guo vd. 2020). ChargeCar veri setinde rota tipi bilgileri bulunmadığı için rota tipini tahmin etmek amacıyla kümeleme yöntemleri kullanılmıştır.


Bu çalışmada ChargeCar veri setindeki statik bilgidan yararlanarak daha fazla öznitelik çıkartmak amacıyla yolculuklara ait hız-zaman grafiklerini (hız profilini) kullanarak rota tipi elde edilebilir. Yolculukları genel itibariyle iki sınıfa ayırmak mümkündür (Fetene vd. 2017, Yavasoglu vd. 2019): şehir içi ve şehir dışında (otoyolda) yapılan yolculuklar. Şekil 3.4’te Amerika Çevre Koruma Ajansı EPA’nın emisyon standartları ve yakıt ekonomisi testleri için oluşturduğu farklı sürüş testlerine ait hız profilleri gösterilmiştir (EPA, 2021). Verilen grafiklerden görüldüğü üzere şehir içi ve şehir dışı/otoyolda gerçekleştirilen yolculukların hız profillerinin örüntüleri arasında belirgin farklılık söz konusudur. Yolculukların hız profilleri yapılabilecek bir kümeleme işlemi ile yolculukları tiplerinin etiketlenmesi mümkündür.



Şekil 3.4. Şehir içi ve şehir dışı sürüşlerine ait hız profilleri (EPA, 2021)


3.1.2. Yolculukların segmentasyonu

ChargeCar veri setindeki bazı yolculuklar birden fazla alt yolculuk içermektedir. Alt yolculuk içeren yolculuklar ve alt yolculuk sayısı verinin temin edildiği ChargeCar projesi veri setinde bulunmaktadır (CREATE Lab, 2009). Alt yolculukların yanı sıra uzun duraksamaların olduğu yolculuklarda iki gözlem arası geçen süre aykırı değerlere sahip olabilmektedir. Duraksama içeren yolculuklarda duruş zamanlarını enerji miktarı üzerinden tespit etmek de mümkündür. Harcanan enerji, geçen süre ile güç çarpımı sonucu elde edildiğinden uzun duraksama ve alt yolculuk içeren verilerin harcanan enerji-zaman grafiğinden yararlanarak duraksama sayısı elde edilebilir. Örneğin Şekil 3.5'te duraksama içeren yolculuğun harcanan enerji (Wh)-zaman (sn) grafiğine göre yolculukta dört kez duraksama yapılmıştır.



Şekil 3.5. Duraksama içeren bir yolculuğa ait harcanan enerji (Wh) grafiği

Uzun yolculukların daha kısa yolculuklara bölünmesi yolculuk tipi kümelenmesinde daha doğru sonuçlar elde edilmesinde etkili olacaktır. Bu amaçla yolculukları hız profillerindeki değişimin olduğu noktaları belirleyerek bu noktalarda yolculuklar bölünmesi gerekir. Hız profilleri esasında zaman serileri olduğundan zaman serilerinde değişimin olduğu noktaların bulunmasına literatürde değişim noktası seçimi (change point detection) problemi veya zaman serisi segmentasyonu (time-series segmentation) olarak geçmektedir. Şekil 3.6'da bu problem için bir örnek verilmiştir. Zaman serisinin değişim noktalarının belirlenmesi ile zaman serisi alt serileri oluşturulur.



Şekil 3.6. Zaman serisi segmentasyonu problemi

Uzun yolculukları hız profillerine göre bölmek için Schäfer vd. (2021) tarafından zaman serisi segmentasyonu problemi için önerilen ClaSP (Classification Score Profile) algoritmasını uygulanmıştır. ClaSP algoritması, benzer şekle sahip bölgeleri tanımlamak için bir zaman serisi sınıflandırıcısını uyarlayarak segmentasyona yaklaşır. CLaSP algoritmasının temel işlevi, bir zaman serisini hiyerarşik olarak ikili bir şekilde bölerek zaman serisi içerisindeki benzer şekle sahip bölgeleri tanımlamaktır. İkiye ayrılan her alt zaman serisinin sağ ve sol kısmını ayırmak üzere eğitilmiş bir ikili sınıflandırıcı kullanılır. Sınıflandırma performansının en yüksek olduğu nokta bulunarak değişim noktaları yinelemeli olarak belirlenir. CLaSP algoritmasının başlıca avantajları, diğer yöntemlere göre yüksek doğrulukta olması, tek parametre gerektirmesi (hareketli pencere uzunluğu) ve hızlı bir algoritma olmasıdır.

3.1.3. Hız profillerinin kümelenmesi

Genel olarak şehir içi, otoyollar, kırsal yollar, ana yollar vb. gibi birçok rota tipi vardır. Bu çalışmada, rota tipinin bilinmediği durumlarda izlenebilecek yöntemler üzerinde durulmuştur. Birçok araştırma, EA’larda harcanan enerjiyi tahmin etmek için rota tipinin önemine işaret etmektedir (Li vd. 2016, Wang vd. 2018, Yao vd. 2013, Zhang ve Yao 2015). ChargeCar veri seti yol tipini içermese de yol tipini tahmin etmek için yolculukların hız profilleri kullanılabilir. Hız profillerinden rota tipi, sürüş davranışı veya trafik durumu hakkında bilgi almak mümkündür (J. Wang vd. 2018, L. Zhao vd. 2020).

Veri setinden en iyi şekilde yararlanmak için hız profillerine kümeleme işlemi uygulayıp küme etiketini tahmin aşaması için statik bir girdi olarak menzil tahmin modelinde kullanılması mümkün hale getirilir. Hız profili, aracın zamana bağlı hızını temsil eden bir zaman serisi verisidir. Burada, her bir hız profilinin bir gözlem olarak ele alınması ile hız profillerinin kümelenmesi problemi söz konusudur. Bu problem, tüm zaman serisi kümeleme (whole time series clustering) olarak bilinir (Aghabozorgi, Seyed Shirkhorshidi ve Ying Wah, 2015). Bu problem için uygulanabilecek yöntemlerden biri, zaman serisine ait istatistiksel öznitelikler elde ederek zaman serisini iki boyuttan tek boyuta indirgemektir. Kümeleme için kullanılacak öznitelikler belirlendikten tüm zaman serisini kullanmak yerine öznitelikler üzerinden bir kümeleme tekniği uygulanır. Bu kümeleme tekniğine öznitelik tabanlı kümeleme denir (Räsänen ve Kolehmainen, 2009).

Zaman serilerini kümelemenin başka bir yolu da zaman serilerini şekillerine göre kümelemektir. Öklid mesafesi, Manhattan mesafesi, Chebyshev mesafesi vb. gibi zaman serisi verileri arasındaki benzerliği ölçmek için kullanılan ölçüler kümelemede yaygın olarak kullanılsa da benzer şekillere sahip zaman serilerini keşfetmek için kullanılması zordur. Şekle dayalı kümeleme için kullanılan en yaygın yöntem Dinamik Zaman Bükme (Dynamic Time Warping) (DZB) yöntemidir. DZB, iki zaman serisi arasındaki optimum hizalamayı, zaman serisini uzatarak veya büzleştirerek bulabilir ve benzer şekillere sahip örüntüleri keşfedebilir. DZB ile şekil tabanlı bir benzerlik ölçüsü hesaplanır ve minimum mesafeye sahip zaman serileri birlikte kümelenir (Wen, Zhou ve Yang, 2019). Çalışma kapsamında iki farklı kümeleme yöntemi kullanılmış ve menzil tahmin modeline etkisi karşılaştırılmıştır.

a) Özniteliğe dayalı kümeleme

Şehir içi ve şehir dışı sürüşlerine ait hız profillerini, belirli istatistiksel özniteliklerin çıkarımı ile kümeleyerek yapılan yolculukların rota tipi belirlenebilir. Hız profillerine ait istatistiksel öznitelikler, kümeleme algoritmasının girdisi olacaktır. Kümeleme algoritması olarak küme sayısının belirtilebilmesi nedeniyle k-ortalamalar algoritması (Macqueen, 1967) kullanılmıştır. K-ortalamalar algoritmasının adımları Şekil 3.7’de verilmiştir.

K-Ortalamlar Algoritması

Adım 1: Kümeleme işleminin gerçekleştirileceği veri setini temin et

Adım 2: Küme sayısını (k) belirle

Adım 3: Küme merkezlerini rasgele yerleştir

Adım 4: Yakınsama veya iterasyon kriteri sağlanana kadar 5. ve 6. adımı tekrarla


Adım 5: Her veri için veriyi Öklid uzaklığına göre en yakın ağırlık merkezinin kümesine ata

Adım 6: Her küme için yeni küme merkezini bul

Şekil 3.7. K-ortalamlar algoritması adımları**b) Şekle dayalı kümeleme**

Zaman serilerinde kümeleme yapmanın diğer bir yöntemi şekle dayalı kümelemedir. Bu tür kümeleme yöntemlerinde iki zaman serisi arasında DZB kullanılarak şekil tabanlı bir benzerlik ölçüsü hesaplanır ve minimum mesafeye sahip zaman serileri birlikte kümelenir. DZB ile iki zaman serisi arasındaki zamansal kaymalar ortadan kaldırılarak serilerin benzerliği tespit edilir. DZB ile elde edilen mesafe ölçüsü, şekil tabanlı kümeleme için uygun bir göstergedir. DZB, zaman serisinin bazı bölümlerini sıkıştırarak veya genişleterek iki zaman serisi arasında en uygun eşleşmeyi hesaplar. Bu nedenle, DZB, rota türlerinin şekillerine göre benzerliğini ölçmek için de uygulanabilir (Hu, Wu ve Schwanen, 2017).

Şekil 3.8’de DZB ile farklı uzunluklara sahip iki zaman serisi ($X = (x_1, x_2, \dots, x_n)$ ve $Y = (y_1, y_2, \dots, y_m)$) üzerinde uygulandığı gösterilmiştir. Şekilsel benzerliklerini karşılaştırmak için ve $(n \times m)$ boyutunda boş bir uzaklık matrisi (c) oluşturulur. Uzaklık matrisi oluşturulduktan sonra matrisin sağ üst köşesinden sol alt köşesinde “bükme yolu” elde edilir. Amaç, minimum mesafeli bükme yolunu elde etmektir. Bükme yolu $p = (p_1, p_2, \dots, p_k)$ farklı uzunluklarda oluşturulması mümkündür. Burada k , $\max(m, n)$ ve $(m + n + 1)$ arasında bir değer alır. Hesaplama karmaşıklığını azaltmak için bazı sınırlamalar yapılır. Matrisin ilk eleman c_{00} sıfır değerini alır. Matrisin geriye kalan diğer elemanları denklem (3.1)-(3.3) ile hesaplanarak özyinelemeli olarak doldurulur (Mishra, 2020).



Şekil 3.8. DZB ile bükme yolunun elde edilmesi (Müller, 2015)

$$c_{i0} = \infty, \forall i \in \{1, \dots, n\} \quad (3.1)$$

$$c_{0j} = \infty, \forall j \in \{1, \dots, m\} \quad (3.2)$$

$$c_{ij} = d(x_i, y_j) + \min(c_{i-1,j-1}, c_{i,j-1}, c_{i-1,j}) \quad (3.3)$$

$$DZB_{XY} = c_{nm} \quad (3.4)$$

Denklem (3.3)'te c_{ij} , komşu elemanların minimum uzunluğa sahip olanlarıyla oluşturulan ve mevcut hücrenin uzunluk değeri $d(x_i, y_j)$ ile bulunan birikimli uzaklık değeridir. X ve Y zaman serilerinin DZB ölçüsü (DZB_{XY}) küçük bir değere sahip ise serilerinin benzer oldukları çıkarımı yapılır, aksi takdirde X ve Y zaman serilerinin şekil itibari ile benzer olmadıkları sonucuna varılır (Diab vd., 2021; Tuncer ve Unlu, 2016).

3.2. EASMT için Çözüm Yaklaşımı

Bu tez kapsamında EASMT problemi için kullanılacak veri seti tablo formatında olup çıktı sayısal bir değerdir. Tahmin edilmek istenen öznitelik sayısal bir değere sahipse problem, regresyon problemi olarak değerlendirilir. Makine öğrenmesinde regresyon problemlerinin çözümünde regresyon modelleri kullanılmaktadır. Regresyon modelleri, sürekli değişkenlere dayalı gerçek değerleri tahmin etmek için kullanılır. Regresyon modelleri, tahmin hatasını minimize eden fonksiyonu bulmak için bağımsız ve bağımlı değişkenler arasında ilişkiler kurar. Regresyon problemlerinin çözümünde en çok kullanılan makine öğrenmesi yöntemleri regresyon modelleri, rastgele orman regresyonu, destek vektör regresyonları ve sinirsel ağlardır (Kumar ve Sharma, 2017).


Bir tür makine öğrenimi yöntemi olan derin öğrenme, bilgisayarla görme, doğal dil işleme, konuşma tanıma gibi birçok alanda yüksek performans göstermiştir. Derin öğrenme modellerinin temelini oluşturan derin sinir ağları (DSA), giriş ve çıkış katmanları arasında çok sayıda katman bulunan yapay bir sinir ağlarıdır (Schmidhuber, 2015). DSA, ilave işleme katmanları ekleyerek yüksek düzeyde soyut, doğrusal olmayan veri temsillerini öğrenebilmektedirler (Veres ve Moussa, 2020). DSA'nın temeli, canlıların sinir sisteminin modellenmesine dayanmaktadır. Canlıların sinir sistemindeki bir sinir ağının temel görevi, verileri depolayan ve yöneten ve bunları yapay sinapslarla bağlayan nöronlar veya düğümler geliştirmektir. Amaç, veriler arasında ilişki kurarak öğrenme ve hafızaya almayı sağlamaktır. DSA, giriş katmanı, gizli katman(lar) ve çıkış katmanından oluşur. Girdi katmanındaki düğüm sayısı, değerlendirilmekte olan öznelikleri temsil eden değişkenlerin sayısını ifade ederken, çıktı katmanındaki nöronların sayısı sınıfların sayısına eşittir. Nöronların sayısı ve gizli katmanların sayısı, probleme ve eğitim verilerinin sayısına bağlıdır. Her nöron, bir önceki katmandaki tüm düğümlerle, gizli ve çıkış katmanındaki ilişkili bir sayısal ağırlıkla ilişkilidir. İki nöron arasındaki ağırlık, aralarında oluşan sinyalin büyüklüğünü kontrol eder. DSA'nın gizli katmanındaki nöronlarda gerçekleştirilen matematiksel işlem denklem (3.5)'te yer almaktadır (Ullah, Liu, Yamamoto, al-Mamlook vd., 2021):

$$\eta_j^i = \sum_{k=1}^{\iota_{i-1}} \omega_k^i \chi_k^{\iota_{i-1}} + \beta_k^i, \quad \forall j = \{1 \dots \iota_i\} \quad (3.5)$$

Burada i , gizli katman numarasını ve j , katmandaki nöron numarasını belirtmektedir. ι_i , i . katmandaki nöron sayısını belirtir. i . katmandaki j . nöronunun çıktısı η_j^i olarak ifade edilmiştir. ω_k^i ve β_k^i sırasıyla, i . katmandaki k . nöronunun ağırlığını ve önyargı (bias) değerini belirtir. $\chi_k^{\iota_{i-1}}$ ise bir önceki katmanın k . nöronunun çıktı değerini temsil eder. η_j^i değeri aktivasyon fonksiyonunun girdisi olarak kullanılır. Aktivasyon fonksiyonunun çıktısı bir sonraki katmanın girdisi olarak kullanılır. Çıktı katmanında da denklem (3.5) ile bir sonuç elde edilir, ancak çıktı değeri üzerinde aktivasyon fonksiyonu kullanılmaz. DSA, çıktı değerleri ile istenilen değerler arasındaki ortalama hata değerlerini minimize eden optimal ω ve β değerlerinin bulunması problemini çözer. Bunun için geriye yayılım

algoritması kullanılır. Geri yayılım algoritması, hata fonksiyonunun gradyanını hesaplar. Geri yayılım, sinir ağının bir fonksiyonu olarak yazılabilir. Geri yayılım algoritmaları, zincir kuralından yararlanan bir gradyan iniş yaklaşımını izleyerek yapay sinir ağlarını verimli bir şekilde eğitmek için kullanılan bir dizi yöntemdir.


Menzil tahmini için derin öğrenme yöntemlerinden DSA modeli kullanılmıştır. Veri setinde hem statik hem de dinamik veriler bulunduğundan iki menzil tahmin modeli geliştirilmiştir. Yalnızca dinamik verilerin girdi olarak kullanıldığı tahmin modeli DSA-A ve statik ve dinamik verinin birlikte model eğitimi için kullanıldığı DSA-B modeli geliştirilmiştir. Her katmandaki katman sayısı ve nöronlar, en düşük doğrulama kaybı izlenerek ampirik olarak belirlenmiştir. DSA modelleri, nöron sayılarına sahip üç katmana sahiptir. Yığın boyutu 64 olarak ayarlanmıştır. Nöron ağırlıklarının optimizasyonu için Adam optimizasyon işlevi kullanılmıştır. Çıktı değişkeni olan harcanan enerji miktarı, pozitif ve negatif değerler aldığından kullanılacak aktivasyon fonksiyonunun da aynı aralığı kapsamaması gerekmektedir. Sızıntı (leaky) ReLU, çıktı olarak negatif değerler de üretebilmesi nedeniyle aktivasyon fonksiyonu olarak kullanılmıştır. Sızıntı ReLU fonksiyonu Şekil 3.9’da verilmiştir. Fonksiyonunun eğim parametresi (α) 0,2 olarak alınmıştır. Kayıp fonksiyonu olarak, ortalama kare hatası (Mean Square Error -MSE) seçilmiştir.



Şekil 3.9. Sızıntı ReLU grafiksel gösterimi (Leaky ReLU Explained, 2022)

DSA-A ve DSA-B tahmin modellerinin yapısı Şekil 3.10’da gösterilmiştir. Dinamik ve statik veri setleri oluşturulduktan sonra eğitim-doğrulama (validation) ve test aşamaları

için her iki veri seti üç gruba ayrılmıştır. Verilerin aldıkları değerlerin birbirlerinden farklı aralıklarda olması nedeniyle ölçeklendirme yapılması model eğitimi sırasında ağırlık değerlerinin kararlı bir şekilde güncellenebilmesi için gerekli bir önışlemdir. Yolculuk veri setindeki özniteliklerin maksimum ve minimum noktaları net olmadığı için Z-standart ölçeği kullanılmıştır. DSA modellerinin çıktısı segmentte harcanan enerji (Wh) tahminidir. Segmentlere bölünmüş bir rota üzerinde bir EA'nın kalan enerji seviyesi baz alınarak nereye kadar gidebileceğini tahmin etmek için rotanın segmentlerinin enerjisi DSA modelleri ile elde edilir ve EA'nın kalan enerji seviyesinin üstüne çıkana kadar segmentlerde harcanan enerji kümülatif olarak toplanır. Elde edilen segment mesafesi, EA'nın tahmini kalan menziline gösterir.




Şekil 3.10. Menzil tahmini için geliştirilen DSA-A ve DSA-B modelleri

3.3. EAŞP için Çözüm Yaklaşımı

EAŞP probleminde amaç, minimum yolculuk süresi veya yolculuk maliyeti için EA'nın nerede, ne zaman ve ne kadar şarj/deşarj olması gerektiğinin bulunmasıdır. Sürüş yapılacak rota belirlendikten sonra menzil tahmini yapılır. Rota, menzili aşan bir uzunluğa sahip ise rota üzerindeki şarj istasyonları belirlenir. Şarj istasyonlarının konumları, sıraları, doluluk-boşluk bilgileri ve fiyat bilgileri AUS aracılığıyla elde edilir. EA'nın rotası üzerindeki her bir şarj istasyonuna varabilmesi için harcaması gereken enerji miktarı menzil tahmini modeli ile elde edilir. Bu bilgi, şarj planlama modelinde bir girdi parametresi olarak kullanılır.

EAŞP için geliştirilen karma tamsayı doğrusal programlama modeli V2G (şebekeden-araca enerji satış) uygulamalarını, zaman dilimlerine bağlı değişen şarj/deşarj fiyatlarını, doğrusal olmayan şarj/deşarj sürelerini ve şarj ünitelerinin sürüşün başladığı zaman diliminde kullanılabilirliğini dikkate alır. Şarj süresi, şarj ünitesinin gücüne ve EA'nın şarj düzeyi miktarına bağlıdır. Genel olarak lityum-iyon pillerinin (Li-ion) şarj süresi, Şekil 3.11'de verildiği gibi parçalı doğrusal bir fonksiyona yakınsayan doğrusal olmayan bir yapı sergiler (Fu ve Dong, 2019; Keskin vd, 2019; Schoenberg ve Dressler, 2019).



Şekil 3.11. Şarj süresi prosesinin parçalı lineer fonksiyon yaklaşımı

Fu ve Dong'un (2019) çalışmasından yararlanarak parçalı doğrusal şarj süresi, Denklem (3.6)'da verildiği gibi hesaplanır. Burada x , EA'nın kalan enerji miktarı (kWh) olsun.

$\tau_{if}(x)$, i . şarj istasyonundaki f . şarj ünitesinde EA'nın enerji miktarının sıfırdan x 'e (kWh) çıkması için gereken toplam süre (dakika) olsun. EA'nın şarj sırasındaki enerji miktarı kapasitesinin (B) belirli bir kırılım yüzdesine ($\%bp$) ulaşana kadar şarj süresi $60 \cdot \frac{x}{p_{if}}$ değerine eşit olur. Burada p_{if} , kW cinsinden şarj gücüdür. Belirli bir seviyeden sonra ($B \cdot bp$) şarj gücü düşer, dolayısıyla şarj süresi artmaya başlar. sp , parçalı fonksiyonun kırılma noktasından sonraki eğimi olsun ($sp < 1$). EA'nın enerji miktarı, batarya kapasitesinin $\%bp$ seviyesinin üzerinde olduğunda dakika cinsinden şarj süresi $\tau_{if}(x)$ gibi hesaplanır.

$$\tau_{if}(x) = \begin{cases} 60 \cdot \frac{x}{p_{if}}, & x < B \cdot bp \\ 60 \cdot \frac{B \cdot bp}{p_{if}} + 60 \cdot \frac{x - B \cdot bp}{sp \cdot p_{if}}, & x \geq B \cdot bp \end{cases} \quad (3.6)$$

3.3.1. Problem varsayımları

EA'nın belirlenen bir rota üzerinde optimal şarj planının elde edilmesi için geliştirilen matematiksel programlama modelinin varsayımları aşağıda belirtilmiştir:

- Rota üzerinde seyahati tamamlamak için yeterli sayıda şarj istasyonu bulunmaktadır.
- Ardışık şarj istasyonlarına ulaşmak için gereken enerji EA'nın kapasitesinden azdır.
- Tüm şarj istasyonları V2G özelliğine sahip istasyonlardır.
- EA, bir şarj istasyonunda yalnızca bir şarj ünitesinde şarj edilebilir.
- EA, uğradığı istasyonda ya şarj veya deşarj olmak için uğrar. Bir istasyonda hem şarj hem de deşarj olamaz ve aynı şarj ünitesinden şarj/deşarj olabilir.
- Yolculuk boyunca SOC değerinin $\%20$ 'nin altına düşmesine izin verilmemektedir.
- Şarj süresi parçalı lineer fonksiyon olarak modellenmiştir.
 - EA'nın istasyona uğradığı zaman diliminde uygunluk durumu müsait olan (boş olan) şarj ünitelerinde şarj/deşarj olmaya başlayabilir.
- Tüm şarj ünitelerinin, zaman ufkunun uzunluğunu aşan yolculuk süreleri için uygun (boş) olduğu varsayılır.
- Şarj istasyonlarındaki şarj ünitelerinin uygunluk durumu (boş-dolu) ve fiyatı zaman dilimlerine bağlı değişmektedir.

3.3.2. Matematiksel programlama modeli

Şarj planlama modeli için kullanılan matematiksel notasyon Çizelge 3.1’de verilmiştir:

Çizelge 3.1. Matematiksel modelde kullanılan notasyonlar

Kümeler	
CS	Şarj istasyonları kümesi $i = \{1, \dots, n\}$
TS	Zaman dilimleri kümesi $h = \{1, \dots, H\}$
CH_i	i . şarj istasyonunun şarj üniteleri kümesi; $f = \{1, \dots, m_i\}$
Parametreler	
n	Şarj istasyonu sayısı
H	Zaman dilimi sayısı
M	Zaman dilimi uzunluğu (dk)
B	EA’nın batarya kapasitesi (kWh)
B_{min}	Kabul edilebilir minimum SOC yüzdesi (%)
bp	Doğrusal olmayan şarj süresinin EA’nın enerjisine bağlı kırılma noktası (%)
sp	Doğrusal olmayan şarj süresinin kırılma noktasından sonraki eğimi (%)
l	Yolculuğu tamamlamak için gereken enerji miktarı (kWh)
T	Yolculuğun hiç durmaksızın tamamlanma süresi (dk)
r_0	Yolculuğun başında kalan enerji miktarı (kWh)
h_0	Yolculuğun başladığı zaman dilimi, $h_0 \in TS$
m_i	i . şarj istasyonundaki şarj ünitesi sayısı
e_i	Başlangıç düğümünden i . düğüme varmak için gereken birikimli enerji miktarı (kWh)
s_i	Başlangıç düğümünden i . düğüme varmak için gereken yolculuk süresi (dk)
p_{if}	i . şarj istasyonunun f . şarj ünitesinin şarj gücü (kW/h)
w_{ifh}	i . şarj istasyonunun f . şarj ünitesinin h . zaman dilimindeki uygunluk durumu (boş:1/dolu:0)
c_{ifh}^v	i . şarj istasyonunun f . şarj ünitesinin h . zaman dilimindeki şarj fiyatı (\$/dk)
c_{ifh}^g	i . şarj istasyonunun f . şarj ünitesinin h . zaman dilimindeki deşarj fiyatı (\$/dk)
İkili Değişkenler	
x_i^v	EA, i . şarj istasyonunda şarj edilirse 1, aksi takdirde 0
x_i^g	EA, i şarj istasyonunda deşarj edilirse 1, aksi takdirde 0
y_{ifh}^v	EA, i şarj istasyonunun f şarj ünitesine h zaman diliminde şarj edilirse 1, aksi takdirde 0
y_{ifh}^g	EA, i şarj istasyonunun f şarj ünitesine h zaman diliminde deşarj edilirse 1, aksi takdirde 0
Tamsayı Değişkenler	
A_i^a	EA, i . istasyonuna vardığında yolculuk süresinin H zaman dilimini geçme sayısı
A_i^d	EA, i istasyonundan ayrıldığında yolculuk süresinin H zaman dilimini geçme sayısı
I_i^a	EA, i şarj istasyonuna vardığı zaman dilimi
I_i^d	EA, i şarj istasyonundan ayrıldığı zaman dilimi
Süreklili Değişkenler	
R_i^a	EA’nın i . şarj istasyonuna varış anındaki enerji miktarı (kWh)
R_i^d	EA’nın i şarj istasyonundan ayrıldığındaki enerji miktarı (kWh)
T_i^a	EA’nın i şarj istasyonuna varış zamanı (dk)
T_i^d	EA’nın i şarj istasyonundan ayrılış zamanı (dk)
G_i^v	EA’nın i şarj istasyonunun f şarj ünitesinden h zaman diliminde aldığı enerji miktarı (kWh)
G_i^g	EA’nın i şarj istasyonunun f şarj ünitesine h zaman diliminde aktardığı enerji miktarı (kWh)
t_{ifh}^v	EA’nın i şarj istasyonunun f şarj ünitesinden h zaman dilimindeki şarj süresi (dk)
t_{ifh}^g	EA’nın i şarj istasyonunun f şarj ünitesinden h zaman dilimindeki deşarj süresi (dk)

Çizelge 3.1. Matematiksel modelde kullanılan notasyonlar (devam)

Fonksiyon	
$\tau_{if}(x)$	EA'nın i . şarj istasyonunun f . şarj ünitesinde enerji miktarını sıfırdan x seviyesine (kWh) çıkarmak için gereken toplam süre (dk)
Ara İkili Değişkenler	
δ_{ifh}^1	EA, i . şarj istasyonunun f . şarj ünitesinin h zaman diliminde vardığında geçen zaman dilimi sayısı H 'ı geçmezse 1, aksi takdirde 0
δ_{ih}^2	EA, i şarj istasyonuna h zaman diliminde varırsa 1, aksi takdirde 0
δ_{ih}^3	EA, i şarj istasyonundan h zaman diliminde ayrılırsa 1, aksi takdirde 0
φ_{ih}^a	EA, i şarj istasyona h zaman diliminde varıp şarj/deşarj işlemini aynı gün içerisinde tamamlarsa 1, aksi takdirde 0
φ_{ih}^d	EA, i şarj istasyondan h zaman diliminde ayrılıp şarj/deşarj işlemini aynı gün içerisinde tamamlarsa 1, aksi takdirde 0
ζ_i	EA, aynı gün içerisinde i . şarj istasyonda şarj/deşarj işlemini tamamlarsa 1, aksi takdirde 0
ϕ_{ih}^a	EA, i şarj istasyona h zaman diliminde varıp şarj/deşarj işlemini aynı gün içerisinde tamamlamazsa 1, aksi takdirde 0
ϕ_{ih}^d	EA, i şarj istasyondan h zaman diliminde ayrılıp ve şarj/deşarj işlemini aynı gün içerisinde tamamlamazsa 1, aksi takdirde 0
ξ_i	EA, aynı gün içerisinde i şarj istasyonda şarj/deşarj işlemini tamamlamazsa 1, aksi takdirde 0

Şarj planlama için iki farklı amaç fonksiyonu kullanılmıştır. Denklem (3.7)'deki amaç fonksiyonu EA'nın toplam yolculuk süresinin minimize edilmesini sağlarken denklem (3.8), toplam yolculuk maliyetini minimize etmektedir:

$$\text{Min} \quad T_n^a - M * h_0 \quad (3.7)$$

$$\text{Min} \quad \sum_i^n \sum_f^{m_i} \sum_h^H (c_{ifh}^v * t_{ifh}^v - c_{ifh}^g * t_{ifh}^g) \quad (3.8)$$

Kısıtlar:

$$G_i^v \leq B * (1 - B_{min}) * x_i^v \quad \forall i \in CS \quad (3.9)$$

$$G_i^g \leq B * (1 - B_{min}) * x_i^g \quad \forall i \in CS \quad (3.10)$$

$$x_i^v + x_i^g \leq 1 \quad \forall i \in CS \quad (3.11)$$

$$\sum_f^{m_i} y_{ifh}^v \leq x_i^v \quad \forall i \in CS, \forall h \in TS \quad (3.12)$$

$$\sum_f^{m_i} y_{ifh}^g \leq x_i^g \quad \forall i \in CS, \forall h \in TS \quad (3.13)$$

$$y_{ifh}^v + y_{ifh}^g - w_{ifh} \leq 1 - \delta_{ifh}^1 \quad \forall i \in CS, \forall f \in CH_i, \forall h \in TS \quad (3.14)$$

$$H - (H * A_i^a + I_i^a - h_0) \leq H * \delta_{ifh}^1 \quad \forall i \in CS, \forall f \in CH_i, \forall h \in TS \quad (3.15)$$

$$r_0 - e_1 = R_1^a \quad (3.16)$$

$$R_{i-1}^d - e_i + e_{i-1} = R_i^a \quad \forall i \in CS/1 \quad (3.17)$$

$$R_n^d - l + e_n = R_{n+1}^a \quad (3.18)$$

$$R_i^d - G_i^v \leq R_i^a + B * (1 - x_i^v) \quad \forall i \in CS \quad (3.19)$$

$$R_i^d - G_i^v \geq R_i^a - B * (1 - x_i^v) \quad \forall i \in CS \quad (3.20)$$

$$R_i^a - G_i^g \leq R_i^d + B * (1 - x_i^g) \quad \forall i \in CS \quad (3.21)$$

$$R_i^a - G_i^g \geq R_i^d - B * (1 - x_i^g) \quad \forall i \in CS \quad (3.22)$$

$$R_i^a \leq R_i^d + B * (x_i^v + x_i^g) \quad \forall i \in CS \quad (3.23)$$

$$R_i^a \geq R_i^d - B * (x_i^v + x_i^g) \quad \forall i \in CS \quad (3.24)$$

$$\tau_{if}(R_i^d) - \tau_{if}(R_i^a) \leq \sum_h^H t_{ifh}^v + \frac{60*B}{(p_{if}*sp)} (1 - \sum_h^H y_{ifh}^v) \quad \forall i \in CS, \forall f \in CH_i \quad (3.25)$$

$$\tau_{if}(R_i^d) - \tau_{if}(R_i^a) \geq \sum_h^H t_{ifh}^v - \frac{60*B}{(p_{if}*sp)} (1 - \sum_h^H y_{ifh}^v) \quad \forall i \in CS, \forall f \in CH_i \quad (3.26)$$

$$\tau_{if}(R_i^a) - \tau_{if}(R_i^d) \leq \sum_h^H t_{ifh}^g + \frac{60*B}{(p_{if}*sp)} (1 - \sum_h^H y_{ifh}^g) \quad \forall i \in CS, \forall f \in CH_i \quad (3.27)$$

$$\tau_{if}(R_i^a) - \tau_{if}(R_i^d) \geq \sum_h^H t_{ifh}^g - \frac{60*B}{(p_{if}*sp)} (1 - \sum_h^H y_{ifh}^g) \quad \forall i \in CS, \forall f \in CH_i \quad (3.28)$$

$$\sum_h^H \sum_f^{m_i} y_{ifh}^v \leq H * x_i^v \quad \forall i \in CS \quad (3.29)$$

$$\sum_h^H \sum_f^{m_i} y_{ifh}^g \leq H * x_i^g \quad \forall i \in CS \quad (3.30)$$

$$\sum_h^H \sum_f^{m_i} y_{ifh}^v \geq x_i^v \quad \forall i \in CS \quad (3.31)$$

$$\sum_h^H \sum_f^{m_i} y_{ifh}^g \geq x_i^g \quad \forall i \in CS \quad (3.32)$$

$$y_{ifh}^v \leq t_{ifh}^v \quad \forall i \in CS, \forall f \in CH_i, \forall h \in TS \quad (3.33)$$

$$y_{ifh}^g \leq t_{ifh}^g \quad \forall i \in CS, \forall f \in CH_i, \forall h \in TS \quad (3.34)$$

$$t_{ifh}^v \leq M * y_{ifh}^v \quad \forall i \in CS, \forall f \in CH_i, \forall h \in TS \quad (3.35)$$

$$t_{ifh}^g \leq M * y_{ifh}^g \quad \forall i \in CS, \forall f \in CH_i, \forall h \in TS \quad (3.36)$$

$$60 * h_0 + s_1 = T_1^a \quad (3.37)$$

$$T_{i-1}^d + s_i - s_{i-1} = T_i^a \quad \forall i \in CS/1 \quad (3.38)$$

$$T_n^d - T + s_n = T_{n+1}^a \quad (3.39)$$

$$\frac{T_i^a}{60} < H * A_i^a + I_i^a \quad \forall i \in CS \quad (3.40)$$

$$\frac{T_i^a}{60} + 0.99 \geq H * A_i^a + I_i^a \quad \forall i \in CS \quad (3.41)$$

$$\frac{T_i^d}{60} < H * A_i^d + I_i^d \quad \forall i \in CS \quad (3.42)$$

$$\frac{T_i^d}{60} + 0.99 \geq H * A_i^d + I_i^d \quad \forall i \in CS \quad (3.43)$$

$$T_i^a + \sum_f^{m_i} \sum_h^H (t_{ifh}^v + t_{ifh}^g) = T_i^d \quad \forall i \in CS \quad (3.44)$$

$$\sum_f^{m_i} (t_{ifh}^v + t_{ifh}^g) - M * (I_i^a + H * A_i^a) + T_i^a \leq M \delta_{ih}^2 \quad \forall i \in CS, \forall h \in TS \quad (3.45)$$

$$I_i^a - h \leq H * \delta_{ih}^2 \quad \forall i \in CS, \forall h \in TS \quad (3.46)$$

$$I_i^a - h \geq -H * \delta_{ih}^2 \quad \forall i \in CS, \forall h \in TS \quad (3.47)$$

$$\sum_f^{m_i} (t_{ifh}^v + t_{ifh}^g) - T_i^d + M * (I_i^d + H * A_i^d - 1) \leq M \delta_{ih}^3 \quad \forall i \in CS, \forall h \in TS \quad (3.48)$$

$$I_i^d - h \leq H * \delta_{ih}^3 \quad \forall i \in CS, \forall h \in TS \quad (3.49)$$

$$h - I_i^d \geq -H * \delta_{ih}^3 \quad \forall i \in CS, \forall h \in TS \quad (3.50)$$

$$I_i^a - h * (1 - (A_i^d - A_i^a)) \leq H * \varphi_{ih}^a \quad \forall i \in CS, \forall h \in TS \quad (3.51)$$

$$h * (1 - (A_i^d - A_i^a)) - I_i^a \leq H * \varphi_{ih}^a \quad \forall i \in CS, \forall h \in TS \quad (3.52)$$

$$\sum_{k=1}^{h-1} \sum_f^{m_i} (y_{ifk}^v + y_{ifk}^g) \leq H * \varphi_{ih}^a \quad \forall i \in CS, \forall h \in TS \quad (3.53)$$

$$I_i^d - h * (1 - (A_i^d - A_i^a)) \leq H * \varphi_{ih}^d \quad \forall i \in CS, \forall h \in TS \quad (3.54)$$

$$h * (1 - (A_i^d - A_i^a)) - I_i^d \leq H * \varphi_{ih}^d \quad \forall i \in CS, \forall h \in TS \quad (3.55)$$

$$\sum_{k=h+1}^H \sum_f^{m_i} (y_{ifk}^v + y_{ifk}^g) \leq \varphi_{ih}^d \quad \forall i \in CS, \forall h \in TS \quad (3.56)$$

$$x_i^v + x_i^g - (1 - (A_i^d - A_i^a)) \leq H * \zeta_i \quad \forall i \in CS \quad (3.57)$$

$$(1 - (A_i^d - A_i^a)) - (x_i^v + x_i^g) \leq H * \zeta_i \quad \forall i \in CS \quad (3.58)$$

$$\sum_h^H \sum_f^{m_i} (y_{ifh}^v + y_{ifh}^g) - (I_i^d - I_i^a + 1) \leq \zeta_i \quad \forall i \in CS \quad (3.59)$$

$$I_i^a - h * (A_i^d - A_i^a) \leq H * \phi_{ih}^a \quad \forall i \in CS, \forall h \in TS \quad (3.60)$$

$$h * (A_i^d - A_i^a) - I_i^a \leq H * \phi_{ih}^a \quad \forall i \in CS, \forall h \in TS \quad (3.61)$$

$$\sum_{k=h}^H \sum_f^{m_i} (y_{ifk}^v + y_{ifk}^g) \leq (H - h + 1) * \phi_{ih}^a \quad \forall i \in CS, \forall h \in TS \quad (3.62)$$

$$I_i^d - h * (A_i^d - A_i^a) \leq H * \phi_{ih}^d \quad \forall i \in CS, \forall h \in TS \quad (3.63)$$

$$h * (A_i^d - A_i^a) - I_i^d \leq H * \phi_{ih}^d \quad \forall i \in CS, \forall h \in TS \quad (3.64)$$

$$\sum_{k=1}^h \sum_f^{m_i} (y_{ifk}^v + y_{ifk}^g) \leq h * \phi_{ih}^d \quad \forall i \in CS, \forall h \in TS \quad (3.65)$$

$$x_i^v + x_i^g - (A_i^d - A_i^a) \leq H * \xi_i \quad \forall i \in CS \quad (3.66)$$

$$(A_i^d - A_i^a) - (x_i^v + x_i^g) \leq H * \xi_i \quad \forall i \in CS \quad (3.67)$$

$$\sum_h^H \sum_f^{m_i} (y_{ifh}^v + y_{ifh}^g) - (H + I_i^d - I_i^a + 1) \leq \xi_i \quad \forall i \in CS \quad (3.68)$$

$$\sum_h^H (y_{ifh}^v + y_{ifh}^g) - \sum_h^H \sum_f^{m_i} (y_{ifh}^v + y_{ifh}^g) \leq H * (1 - \sum_h^H (y_{ifh}^v + y_{ifh}^g)) \quad \forall i \in CS, \forall f \in CH_i \quad (3.69)$$

$$B_{min} \leq R_i^a, R_i^d \leq B \quad \forall i \in CS \quad (3.70)$$

$$1 \leq I_i^a, I_i^d \leq H \quad \forall i \in CS \quad (3.71)$$

$$t_{ifh}^v, t_{ifh}^g, G_i^v, G_i^g, R_i^a, R_i^d, T_i^a, T_i^d \geq 0 \quad \forall i \in CS, \forall f \in CH_i, \forall h \in TS \quad (3.72)$$

$$x_i^v, x_i^g, y_{ifh}^v, y_{ifh}^g, \delta_{ifh}^1, \delta_{ifh}^2, \delta_{ifh}^3, \varphi_{ih}^a, \varphi_{ih}^d, \phi_{ih}^a, \phi_{ih}^d, \zeta_i, \xi_i \in \{0,1\} \quad \forall i \in CS, \forall f \in CH_i, h \in TS \quad (3.73)$$

$$A_i^a, A, I_i^a, I_i^d \in Z^+ \quad \forall i \in CS \quad (3.74)$$

Kısıt (3.9) ve (3.10), bir şarj istasyonundan alınan veya istasyona aktarılan toplam enerji miktarının, EA'nın kapasitesini aşmamasını sağlamaktadır. Kısıt (3.11), EA'nın uğradığı şarj istasyonunda şarj veya deşarj işlemlerinden yalnızca birinin gerçekleştirilmesine izin vermektedir. Kısıt (3.12) ve (3.13), EA'nın bir istasyonda bir zaman diliminde en fazla bir şarj ünitesinde şarj/deşarj olmasını sağlar. Kısıt (3.14) ve (3.15), EA'nın sürüşe başladığından itibaren geçen zaman dilimi sayısı ($H * A_i^a + I_i^a - h_0$), H zaman dilimi geçinceye kadar dolu olan şarj ünitelerini seçmesini engellemektedir. Diğer bir ifadeyle eğer EA, şarj istasyonuna vardığında geçen süre, bir zaman periyodunu aşmadığı sürece EA'nın dolu şarj ünitelerinden dolu olanlarında şarj/deşarj olmaması sağlanır. Ancak zaman periyodundan daha uzun süre geçtiyse şarj ünitesinin rezerve olup olmadığına göre bir kısıtlama yapılmaz. Şarj ünitelerinin uygunluğunu yalnızca ilk H zaman dilimleri için kısıtlamanın nedeni, bu bilginin sadece ilk bir zaman periyodu için belirli olduğu varsayıldığından kaynaklanmaktadır. Dolayısıyla daha uzun süreli yolculuklar için modelin geçmiş zaman periyoduna ait parametreleri kullanması önlenmektedir. Kısıt (3.16)-(3.18), yolculuk boyunca EA'nın enerji korunumunu sağlamaktadır. Kısıt (3.16), başlangıç düğümü ve ilk şarj istasyonu arasındaki enerji dengesini; kısıt (3.17), ardışık şarj istasyonları arasındaki enerji dengesini ve kısıt (3.18), son şarj istasyonu ile varış düğümü arasındaki enerji dengesini ifade etmektedir. Kısıt (3.19) ve (3.20), şarj istasyonlarında şarj işlemi sırasında enerji dengesini takip etmektedir. Kısıt (3.21) ve (3.22), EA'nın deşarj ettiği enerji miktarının, EA'nın istasyona varıştaki enerji miktarı ile istasyondan ayrıldığı sıradaki enerji miktarı farkına eşit olmasını sağlamaktadır. Kısıt (3.23) ve (3.24), EA'nın şarj istasyonunda şarj veya deşarj olmaması durumunda istasyona varırken ve istasyondan ayrıldığı sıradaki enerji miktarının değişmemesini sağlamaktadır.

Kısıt (3.25)-(3.28), doğrusal olmayan şarj/deşarj sürelerini modellemektedir. Denklem (3.6)'da verilen parçalı lineer şarj süresi fonksiyonu $\tau_{if}(x)$, EA'nın i . şarj istasyondan ayrılış anındaki enerji miktarı için f . şarj ünitesinden harcanması gereken şarj süresi ile istasyona varış zamanındaki enerji miktarı için gereken şarj süresi arasındaki farkı alarak şarj süresini hesaplamak için kullanılır. Deşarj süresini hesaplamak için de varıştaki enerji miktarı için gereken şarj süresinden istasyondan ayrılırken kalan enerji miktarı için gereken şarj süresi arasındaki fark alınır. Kısıt (3.29) ve (3.30), bir istasyonda şarj/deşarj işlemi için durulmadığı müddetçe y_{ifh}^v ve y_{ifh}^g değişkenlerinin sıfır değeri almasını sağlamaktadır. Ancak bir istasyonda şarj/deşarj işlemi için durulacaksa kısıt (3.31) ve (3.32)'ye göre en az bir şarj ünitesinin zaman dilimi şarj/deşarj işlemi için seçilmiş olmalıdır. Kısıt (3.33) ve (3.34), EA'nın bir şarj ünitesine atanması durumunda şarj ünitesindeki şarj/deşarj süresinin sıfırdan büyük olmasını garantilemektedir. Kısıt (3.35) ve (3.36) ise şarj/deşarj süresinin, zaman diliminde kalan süreyi aşmamasını sağlamaktadır.

Kısıt (3.37)-(3.39), EA'nın yolculuk içerisindeki zaman dengesini sağlayan kısıtlardır. Kısıt (3.37), EA'nın i . şarj istasyonunda şarj/deşarj edilmesi durumunda, istasyona vardığı zaman diliminde şarj/deşarj etmeye başlaması gerektiğini garanti etmektedir. Kısıt (3.38), ardışık şarj istasyonları arasında geçen zamanı dengelemektedir. Kısıt (3.39), son şarj istasyonu ile varış düğümü arasındaki zaman dengesini sağlamaktadır. Kısıt (3.40) ve (3.41), EA'nın şarj istasyonuna vardığı zaman diliminin bulunmasını garanti etmektedir. Kısıt (3.42) ve (3.43), EA'nın şarj istasyonundan ayrıldığı zaman diliminin bulunmasını sağlamaktadır. Kısıt (3.44), EA'nın şarj/deşarj işlemi sırasında zaman dengesini sağlamaktadır. Kısıt (3.45)-(3.47), EA'nın istasyona vardığı zaman diliminde harcayacağı şarj/deşarj süresinin, o zaman diliminde kalan mevcut süreyi aşmamasını engellemektedir. Kısıt (3.48)-(3.50), EA'nın, i . şarj istasyonundan h . zaman diliminde ayrılması durumunda ($I_i^d = h$), h . zaman dilimindeki şarj/deşarj süresinin istasyondan ayrılış zamanı ile h . zaman diliminin başlangıç zamanı arasındaki farktan daha az olmasını engellemektedir.

EA'nın şarj/deşarj olduğu şarj ünitelerini ve zaman dilimlerini modellerken, EA'nın istasyona varış ve istasyondan ayrılış zaman dilimlerinin aynı zaman periyodu (gün)

içerisinde gerçekleşip gerçekleşmediği dikkate alınmalıdır. Eğer EA, şarj/deşarj işlemini aynı günde tamamlıyorsa ($A_i^d = A_i^a$), varış zaman dilimi I_i^a , ayrılış zaman diliminden (I_i^d) sayıca küçük olur. EA, şarj/deşarj işleminin başladığı zaman diliminden bittiği zaman dilimine kadar geçen süre boyunca şarj/deşarj olmalıdır. Modelin (3.51)-(3.59) arasındaki kısıtları, aynı gün içerisinde şarj/deşarj işleminin tamamlanması durumunu kapsamaktadır. Kısıt (3.51)-(3.53), EA'nın aynı gün içerisinde şarj/deşarj işlemi tamamlaması ve istasyona h zaman diliminde varması durumunda, h . zaman dilimi öncesinde şarj/deşarj işleminin yapılmasını engellemektedir. Kısıt (3.54)-(3.56), EA'nın aynı gün içerisinde şarj/deşarj işlemi tamamlaması ve istasyondan h . zaman diliminden ayrılması durumunda, h . zaman dilimi sonrasında EA istasyonda şarj/deşarj olmasını engellemektedir. Kısıt (3.57)-(3.59), EA'nın aynı gün içerisinde şarj/deşarj olması durumunda toplam şarj/deşarj için harcadığı zaman dilimi sayısını ($I_i^d - I_i^a + 1$) değerine eşitlemektedir.

Şarj/deşarj işleminin aynı gün içerisinde tamamlanmaması durumunda ($A_i^d \neq A_i^a$) varış zaman dilimi I_i^a , ayrılış zaman diliminden (I_i^d) büyük olur. Bu durumda EA'nın istasyona varış zaman diliminden öncesi, istasyondan ayrılış zaman dilimine kadar istasyonun toplam tüm şarj üniteleri için y_{ifh}^v ve y_{ifh}^g değişkenlerinin değeri sıfır olmalıdır ($\sum_{h=I_i^a+1}^{I_i^d-1} (y_{ifh}^v + y_{ifh}^g)$). Kısıt (3.60)-(3.63), EA'nın aynı gün içerisinde şarj işlemi tamamlamaması ve istasyona h zaman diliminde varması durumunda, h . zaman diliminden zaman periyodunun sonuna kadar EA istasyonda şarj/deşarj olmasını sağlar. Kısıt (3.64)-(3.67), EA'nın aynı gün içerisinde şarj işlemi tamamlamaması ve istasyondan h . zaman diliminde ayrılması durumunda, zaman periyodunun başından h . zaman dilimine kadar EA istasyonda şarj/deşarj olmasını sağlar. Kısıt (3.68)-(3.69), EA'nın yine aynı gün içerisinde şarj işlemi tamamlamaması durumunda, EA'nın şarj/deşarj için toplam harcadığı zaman dilimi sayısının $H + I_i^d - I_i^a + 1$ değerine eşit olmasını sağlar. Kısıt (3.70)-(3.74), değişken sınırlarını göstermektedir.

3.3.3. Sezgisel yaklaşımlar

Şarj planlama için literatürde önerilen sezgisel stratejiler şu şekildedir (Barabadi vd. 2018, Schoenberg ve Dressler 2019, Y. Wang vd. 2021):

- **Her istasyonda tam dolum (Strateji-1, S1):** EA'nın rota üzerindeki tüm istasyonlarda durmasını ve %100 şarj olmasını gerektiren bir şarj stratejisidir. Şarj planlama ile ilgili çalışmalarda önerilen stratejilerle en çok karşılaştırılan stratejidir.
- **Eşik değerin altına düşemeyecek şekilde tam dolum (Strateji-2, S2):** Bu stratejiye göre EA, sıradaki istasyonda dolum yapmayıp bir sonraki istasyona vardığında enerji seviyesi, belirlenen minimum eşik değerinin (EA'da kalan enerji miktarı) altına düşecekse sıradaki ilk istasyonda tam dolum yapmalıdır.
- **Ulaşılabilen en uzak istasyona varabilecek kadar dolum (Strateji-3, S3):** EA'nın kalan menziline göre gidebileceği en uzak istasyonu seçtiği stratejidir. Bu stratejiye göre dolum miktarı tam olması gerekmez, yalnızca EA'nın ulaşabileceği en uzak istasyona varabilecek kadar şarj olması yeterlidir.
- **Sıradaki istasyona varabilecek kadar dolum (Strateji-4, S4):** Bu stratejiye göre EA yol üzerindeki tüm istasyonlara uğrar ve bir sonraki istasyona gidebilmek için gereken enerji miktarı kadar dolum yapar.

3.3.4. Metasezgisel yaklaşım: genetik algoritma

Metasezgisel algoritmalar, özellikle karmaşık optimizasyon problemlerini çözmek için kullanılan hesaplamalı zeka paradigmalarıdır (Abdel-Basset, Abdel-Fatah ve Sangaiiah, 2018). Metasezgisel yaklaşımlarını tek çözüm ve popülasyon tabanlı olarak iki kategoriye ayırmak mümkündür. GA, Holland (1975) tarafından önerilen popülasyon tabanlı bir metasezgisel yöntemdir. GA, problem çözme yetenekleri ve sağlamlığı açısından yaygın araştırma ilgisini çeken ve endüstriyel etkisi fark edilen erken optimizasyon yöntemleri arasında yer almaktadır (Ezugwu vd., 2021).

GA'nın temel çalışma prensibi doğal seçilime dayanmaktadır. Güçlü bireylerin hayatta kalmaya devam ederken zayıf bireyler zaman içerisinde elenerek en iyi bireyler seçilir. GA'da çözümleri kromozomlar temsil etmektedir. Kromozom yapısı belirlendikten sonra

başlangıç popülasyonu oluşturulur. Başlangıç popülasyonu rasgele oluşturulan kromozomları içeren bir çözüm havuzu olarak düşünülebilir. Başlangıç popülasyonundaki kromozomların değerlendirilmesi için uygunluk fonksiyonu tanımlanır ve kromozomların uygunluk değerleri elde edilir. Ardından kromozomlar arasında seçim işlemi gerçekleştirilir. Seçim işlemi uygunluk değerine göre yapılmaktadır. En yaygın kullanılan teknikler rulet tekerleği ve turnuva seçim tekniğidir. Seçilen kromozomlar bir sonraki popülasyonun oluşturulmasında kullanılır.

Bir sonraki popülasyonun oluşturulmasında, çaprazlama ve mutasyon gibi genetik operatörler etkin rol oynar. GA'nın her nesil daha iyi çözümler elde edebilmesindeki en önemli işlem genetik operatörlerdir. Çaprazlama, seçilen iki kromozomun kombinasyonu ile yeni kromozomların oluşturulma işlemidir. Burada çaprazlama için seçilen kromozomlar ebeveyn, üretilen yeni kromozomlar ise çocuk olarak nitelendirilir. Mutasyon, seçilen bir kromozomdaki bir parçanın değişimi işlemidir. Genetik operatörler ile elde edilen yeni kromozomlar uygunluk fonksiyonu ile değerlendirilir. Uygunluk değerleri iyi olmayan kromozomlar yeni kromozomların yerini alır. Algoritma durdurma kriteri sağlanana kadar devam ettirilir.

Kromozom Yapısı: EAŞP probleminde kullanılacak örnek bir kromozom yapısı Şekil 3.12'de verilmiştir. Kromozom, hiyerarşik bir yapıya sahip olup ilk katman uğranılacak şarj istasyonlarını, ikinci katman seçilen şarj ünitelerini ve son katman şarj ünitelerinden alınacak/verilecek enerji miktarını temsil etmektedir. Kromozomun uzunluğu, rota üzerindeki şarj istasyonu sayısına (n) eşittir.

	1	2	0	4	0	0	7	8	Şarj istasyonu
	2	1	0	1	0	0	3	1	Şarj ünitesi
	10	18	0	25	0	0	20	-8	Enerji miktarı


Şekil 3.12. Kromozom yapısı

Uygunluk Fonksiyonu: Minimum yolculuk süresi ve minimum yolculuk maliyeti olarak iki farklı amaç için uygunluk fonksiyonu oluşturulmuştur. Denklem (3.7) ve Denklem (3.8)'de verilen amaç fonksiyonlarını hesaplayabilmek için kromozomda verilen bilgiler kullanılarak zaman değişkenleri (y_{ifh} , u_{ifh} , t_{ifh}^v , t_{ifh}^g , T_i^a , T_i^d) bulunur. Ardından kromozomların amaç fonksiyonuna göre uygunluk değeri belirlenir.


Seçim: Kromozomların uygunluk değerine göre popülasyondaki en iyi kromozomlardan ilk %50'lik dilime girenler arasından rasgele seçim yapılır. Seçilen kromozomlar genetik işlemlere tabi tutulur. Burada amaç genetik işlemlere tabi tutulacak kromozomların en iyi kromozomlar arasından seçilmesini sağlayarak daha iyi bir popülasyon oluşturmaktır.

Genetik Operatörler: GA'da çaprazlama ve mutasyon olmak üzere iki türlü genetik operatör bulunmaktadır. Çaprazlama ile elde edilecek yeni kromozomların uygun olmayan çözümler oluşturmasını engellemek için çaprazlama işlemine tâbi tutulacak ebeveyn kromozomları seçerken dikkat edilmesi gereken ilk şart, ebeveyn kromozomlar arasında ilk ve son şarj istasyonu hariç en az bir ortak şarj istasyonu olması gerektiğidir. Çaprazlama işlemi bu ortak nokta üzerinden yapılmalıdır. Aksi takdirde mümkün olmayan bir rota oluşabilir.

Şekil 3.13'te bu duruma örnek bir çaprazlama işlemi gösterilmiştir. Çaprazlama işleminin gerçekleştirilebilmesi için kromozomların uğradıkları şarj istasyonları dikkate alındığından Şekil 3.13'te kromozomların yalnızca ilk katmanı gösterilmiştir. $Ebeveyn_1$ ve $Ebeveyn_2$ ile oluşturulan çocuk çözüme göre, EA sırasıyla 1-4-5 şarj istasyonlarına uğramalıdır. Ancak Şekil 3.14'te gösterilen örnek bir problemin ulaşılabilirlik ağı incelendiğinde bu rotanın mümkün olmadığı görülmektedir. $Ebeveyn_1$ ve $Ebeveyn_2$ ile uygun bir çözüm oluşturabilmek için çaprazlama yapılacak noktada en az bir ortak istasyon olmalıdır. Şekil 3.13 (a) örneğinde çaprazlama işlemi 2. ve 3. istasyonlar arasında yapılmıştır. Ancak çaprazlama yapılan yerin sağ ve sol tarafında (2 ve 3 numaralı istasyonlardan) gidilen ortak bir istasyon yoktur. Bu durum, $Ebeveyn_1$ ve $Ebeveyn_2$ ile çaprazlanması ile mümkün olmayan bir çözüm üretmesine neden olmuştur. Ancak Şekil 3.13 (b) örneğindeki gibi çaprazlama yapılacak noktada ortak bir istasyon olduğunda elde edilen çözümlerde uygun olmayan bir durum ile ortaya çıkmamaktadır.



Şekil 3.13. Çaprazlama için ebeveyn seçimi




Şekil 3.14. Çaprazlama için kullanılan örnek problemin ulaşılabilirlik ağı

Mutasyon işlemi için çözümde uğranılacak şarj istasyonlarından birden fazla şarj ünitesine sahip olan istasyonlar belirlenir. Belirlenen istasyonlar arasından rasgele bir tanesi seçilir. Seçilen istasyonun çözümdeki şarj ünitesi yerine rasgele bir şarj ünitesi belirlenir. Şekil 3.15'te beş istasyonlu bir rota için istasyonlardaki şarj ünitesi sayısı gösterilmiştir. Verilere göre üçüncü istasyonda bir şarj ünitesi olduğundan üçüncü istasyonun şarj ünitesi değeri mutasyon işlemine tabi tutulamaz.

Şarj istasyonu (i)	1	2	3	4	5
Şarj ünitesi sayısı (m_i)	2	3	1	2	3
$m_i \geq 1$?	✓	✓	✗	✓	✓

Şekil 3.15. Mutasyon için uygun genlerin belirlenmesi

Mutasyon işlemi için örnek Şekil 3.16’da verilmiştir. Kromozoma göre EA, 1-3-4-5 istasyonlarının sırasıyla 2, 1, 1 ve 3 numaralı şarj ünitelerine gitmektedir. Kromozomun mutasyona uğraması durumunda gidilen istasyonlar arasından 1, 4 ve 5 numaralı istasyonların şarj ünitelerinden biri değiştirilir.



Şekil 3.16. Örnek mutasyon işlemi

Genetik operatörlere maruz kalan kromozomlar için enerji miktarı katmanını yeniden oluşturulmalıdır. Aksi takdirde problem kısıtlarını sağlamayan çözümler ortaya çıkabilir. Bu durumu önlemek için uğrılacak şarj istasyonları ve şarj ünitelerine göre Şekil 3.17’de verilen enerji seçimi algoritması ile enerji değerleri belirlenir.

Enerji Seçimi Algoritması

1. $R^a \leftarrow$ Şarj istasyonuna varış anındaki kalan enerji seviyesi
2. $R^d \leftarrow$ Şarj istasyonundan ayrılış anındaki kalan enerji seviyesi
3. $G \leftarrow$ Şarj istasyonundan alınan veya verilen enerji miktarı
4. Uğrılacak istasyon listesi (S) içindeki her bir istasyon (i) için:
5. **Eğer** istasyon, uğrılacak istasyonlar arasında ilk istasyon ise:
6. $R^a[i] \leftarrow r_0 - e_i$
7. **Aksi takdirde:**
8. $R^d[i] \leftarrow R^d[i-1] - (e_i - e_{i-1})$
9. **Eğer** istasyon, uğrılacak istasyonlar arasında son istasyon değil ise:
10. $R^d[i] \leftarrow \text{rasgele}(B * B_{min} + (e_{i+1} - e_i), B)$
11. $G[i] \leftarrow R^d[i] - R^a[i]$
12. $R^d[i] = R^a[i]$ **iken:**
13. $R^d[i] \leftarrow \text{rasgele}(B * B_{min} + (e_{i+1} - e_i), B)$
14. $G[i] \leftarrow R^d[i] - R^a[i]$
15. **Eğer** istasyon, uğrılacak istasyonlar arasında son istasyon ise:
16. $R^d[i] \leftarrow \text{rasgele}(B * B_{min} + l - e_i), B)$
17. $G[i] \leftarrow R^d[i] - R^a[i]$
18. $R^d[i] = R^a[i]$ **iken:**
19. $R^d[i] \leftarrow \text{rasgele}(B * B_{min} + (e_{i+1} - e_i), B)$
20. $G[i] \leftarrow R^d[i] - R^a[i]$


Şekil 3.17. Enerji seçimi algoritması

3.3.5. Mat-sezgisel yaklaşım

Bu çalışmada ele alınan problem için, GA ve matematiksel programlama modeline dayanan bir mat-sezgisel yaklaşım önerilmiştir. Sezgisel algoritmaların hızlı sonuç elde etme özelliği ile popülasyon-tabanlı metasezgisellerin geniş çözüm arama özelliklerinin birleştirilmesiyle elde edilen nihai çözüm matematiksel model üzerinden optimize edilir. Bu yaklaşımın amacı, daha iyi bir başlangıç çözümü ile başlayarak optimal çözüme yakınsamayı hızlandırmak ve GA ile elde edilen çözümün iyileştirmeye çalışmaktır. Mat-sezgisel yaklaşımın akış diyagramı Şekil 3.18’de verilmiştir.


Mat-sezgisel yaklaşımda kullanılan matematiksel programlama, Bölüm 3.3.2’de verilen modeldeki kısıtlara ek olarak yeni kısıtlar dahil edilmiştir. Bunun nedeni, GA ile elde edilen çözümdeki bazı değişkenler (uğranılacak istasyonlar ve şarj üniteleri gibi) matematiksel modelde sabit değer olarak alınırken istasyona varış ve ayrılış anındaki zaman enerji miktarı gibi değişkenler sabitlenen değerlere göre sınırlandırılarak çözüm elde edilmesi gerektiğindendir. Mat-sezgisel içerisinde kullanılan bu matematiksel modele sınırlandırılmış şarj planlama modeli (SŞPM) ismi verilmiştir. SŞPM ile ilgili detaylar bölümün devamında verilmiştir.

Önerilen mat-sezgisel yaklaşım dört modülden oluşmaktadır: Başlangıç popülasyon modülü, GA modülü, iyileştirme prosedürü modülü ve nihai çözüm modülü. Mat-sezgisel yaklaşım ilk olarak başlangıç popülasyon modülünden başlamaktadır. Başlangıç popülasyonunda istenilen sayıda çözüm olması halinde GA modülüne geçilir. Durdurma kriteri sağlanana kadar GA çalıştırılır. İterasyon süresince elde edilen çözümlerin en iyi uygunluk değeri eğer belirlenen iyileştirme eşik değeri sayısı boyunca değişmezse iyileştirme prosedürü modülüne geçilir. İyileştirme prosedüründe popülasyon içerisinde seçilen bir GA çözümü SŞPM ile daha iyi hale getirilmesi durumunda GA çözümünün güncellenmesi işlemi gerçekleştirilir. Durdurma kriteri sağlandıktan sonra nihai çözüm modülüne geçilir. GA ile bulunan en iyi çözümün SŞPM ile daha iyi hale getirilmesi sağlanır. Eğer verilen sürede daha iyi bir çözüm elde edilebilirse nihai çözüm olarak iyileştirilmiş çözüm seçilir.




Şekil 3.18. Mat-sezgisel yaklaşımın akış diyagramı

A. Başlangıç popülasyonu: Başlangıç popülasyonu oluşturulurken sezgisel yaklaşımlardan elde edilen çözümler, SŞPM çözümleri ve ihtiyaç duyulması halinde (SŞPM'in verilen sürede uygun çözüm bulamaması ve/veya popülasyon istenilen sayıya ulaşmaması durumunda) rasgele uygun çözümler oluşturulur. Şekil 3.19'da mat-sezgiselin başlangıç popülasyonunun oluşturulma adımları detaylı bir şekilde gösterilmiştir.




Şekil 3.19. Mat-sezgisel için başlangıç popülasyonun oluşturulması

Öncelikle sürüş yapılacak rotanın ulaşılabilirlik ağı oluşturulması gerekir. Verilen bir rota üzerindeki şarj istasyonlarına ulaşmak için gereken enerji miktarının menzil tahmin modelinden elde edildiği varsayımı altında EA'nın rotanın başındaki menzili ile gidebileceği istasyonlar belirlenir. Ardından her bir istasyondan tam menzil ile gidebileceği düğümler (istasyon ve/veya varış noktası) belirlenerek rotanın ulaşılabilirlik ağı oluşturulur. Şekil 3.20'de A noktasından başlayıp B noktasında biten örnek bir rota için oluşturulmuş bir ulaşılabilirlik ağı gösterilmiştir. EA'nın enerji kapasitesinin (B) 80 kWh ve başlangıç enerji miktarının (r_0) 40 kWh olduğu örnekte beş istasyon yer almaktadır. İstasyonlara durmaksızın yapılacak sürüşler için menzil tahmin modeli ile gereken enerji miktarı (e_i) belirtildiği gibi olduğu varsayılın.



Şekil 3.20. Ulaşılabilirlik ağına örnek bir rota

Örnek problemin ulaşılabilirlik kümeleri ve buna göre oluşturulmuş ulaşılabilirlik ağı Şekil 3.21'de verilmiştir. Başlangıç noktası dışında diğer düğümlerin ulaşılabilirlik kümeleri oluşturulurken EA'nın batarya kapasitesi (B) dikkate alınır. Şarj planlama kapsamında ulaşılabilirlik ağı oluşturulurken, EA'nın istasyona vardığında kalan enerji seviyesinin batarya kapasitesinin %20'sinin altına düşmemesi dikkate alınmıştır.



Şekil 3.21. Örnek problemin ulaşılabilirlik kümeleri ve ulaşılabilirlik ağı

A.1. Sezgisel yaklaşımlar ile çözüm elde edilmesi: Sezgisel yaklaşımlarda önerilen algoritmalar ile uğrılacak şarj istasyonları ve enerji miktarları belirlenmektedir. Ancak istasyonlardaki şarj süresini belirlemek için her bir şarj istasyonunda seçilen şarj ünitesinin bilinmesi gerekmektedir. Şarj ünitesi seçimi için Şekil 3.22’de verilen Şarj Ünitesi Seçimi Algoritması kullanılmıştır.

Şarj Ünitesi Seçimi Algoritması	
1.	$F \leftarrow$ Şarj istasyonlarında uğrılacak şarj üniteleri listesi
2.	Uğrılacak istasyon listesi (S) içindeki her bir istasyon (i) için:
3.	Maksimum güç (p_{max}) $\leftarrow 0$
4.	Minimum fiyat (c_{max}) $\leftarrow$ Büyük bir sayı
5.	İstasyondaki her bir şarj ünitesi (f) için:
6.	Eğer istasyon, uğrılacak istasyonlar arasında ilk istasyon ise:
7.	Eğer EA, istasyona vardığı zaman diliminde (h) şarj ünitesi boş ise:
8.	Eğer amaç fonksiyonu “minimum yolculuk süresi” ise:
9.	Eğer şarj ünitesinin gücü (p_{if}) $\geq p_{max}$ ise:
10.	$p_{max} \leftarrow p_{if}$
11.	$F[i] \leftarrow f$
12.	Yoksa eğer amaç fonksiyonu “minimum yolculuk maliyeti” ise:
13.	Eğer şarj ünitesinin fiyatı (c_{ifh}^v) $\leq c_{min}$ ise:
14.	$c_{min} \leftarrow c_{ifh}^v$
15.	$F[i] \leftarrow f$
16.	Eğer istasyon, uğrılacak istasyonlar arasında ilk istasyon değil ise:
17.	Eğer açgözlü seçim yapılmayacak ise:
18.	Rasgele şarj ünitesi seçimi yap
19.	$F[i] \leftarrow f$
20.	Aksi takdirde:
21.	Eğer amaç fonksiyonu “minimum yolculuk süresi” ise:
22.	Eğer şarj ünitesinin gücü (p_{if}) $\geq p_{max}$ ise:
23.	$p_{max} \leftarrow p_{if}$
24.	$F[i] \leftarrow f$
25.	Yoksa eğer amaç fonksiyonu “minimum yolculuk maliyeti” ise:
26.	Her bir zaman dilimi (h) için:
27.	Eğer şarj ünitesinin fiyatı (c_{ifh}^v) $\leq c_{min}$ ise:
28.	$c_{min} \leftarrow c_{ifh}^v$
29.	$F[i] \leftarrow f$


Şekil 3.22. Şarj Ünitesi Seçimi Algoritması

Sezgisel yaklaşımlar ile elde edilen yolculuk süresi ve yolculuk maliyetini olabildiğince minimize etmek için açgözlü bir şarj ünitesi seçimi gerçekleştirilir. Örneğin, eğer amaç fonksiyonu yolculuk süresinin minimize edilmesi ise, güç değeri (kW) en yüksek şarj ünitelerinden seçim yapılır. Amaç fonksiyonu yolculuk maliyeti ise, tüm zaman dilimleri içerisinde şarj fiyatı en düşük olan şarj ünitesi seçilir. Şarj fiyatının zaman dilimine bağlı değişkenlik göstermesi ve istasyonlardaki şarj süresinin önceden bilinmemesi nedeniyle tüm zaman dilimleri içerisinde en düşük fiyata sahip şarj ünitesi seçilmiştir. Sadece ilk uğranılacak istasyon için varış zamanı belli olduğu için, varış zaman diliminde en düşük şarj fiyatı olan şarj ünitesi seçilir. Sezgisel yaklaşımlar için şarj ünitesi seçimi yapıldıktan sonra oluşturulan çözümler GA kromozomu formatında tutulur ve başlangıç popülasyonuna eklenir.

A.2. SŞPM ile çözüm elde edilmesi: SŞPM ile çözüm elde edebilmek için uğranılacak şarj istasyonları ve şarj üniteleri bilgisinin önceden belirlenmiş olması gerekmektedir. Ulaşılabilirlik ağı ile belirli sayıda şarj istasyon listesi üretilir. İstasyon listelerini elde etmek için derinlik öncelikli arama (Depth First Search-DFS) yöntemi kullanılmıştır. DFS yönteminde başlangıç düğümünden varış düğümüne varana kadar her bir düğümünden gidilebilecek bir düğüm belirlenir ve bu şekilde arama ağacının derinlerine inilir. Şarj istasyon listeleri oluşturulduktan sonra SŞPM ile çözümlerin elde edildiği döngü çalıştırılır. Bu döngü, başlangıç popülasyon sayısı ile kullanılacak sezgisel yaklaşım sayısının farkı kadar çalıştırılır. Döngünün her iterasyonunda şarj istasyon listesinden rasgele bir seçim yapılarak uğranılacak şarj istasyonları belirlenir. Şekil 3.22’de verilen şarj ünitesi seçimi algoritması ile amaç fonksiyonuna göre gidilecek şarj üniteleri (ilk istasyon hariç) rasgele olarak belirlenir. Seçilen rotalardaki şarj istasyonları için uygun (boş olan) şarj üniteleri arasından seçim yapılır.

A.2.1. Kayan pencereler yöntemi ile istasyonlara uğrama zamanlarının belirlenmesi: Uğranılacak şarj istasyonları ve şarj üniteleri seçildikten sonra kayan pencereler yöntemi zamana bağlı değişkenlerin (istasyona varış ve istasyondan ayrılış süresi, istasyona varış ve ayrılış zaman dilimleri gibi) sınır değerleri bulunur. EA’nın şarj ünitelerinde olabileceği zaman dilimleri bilgisine göre SŞPM’deki zaman dilimleri sınırlandırılabilir. Burada amaç, kullanılacak değişken sayısını azaltarak optimal

çözümün bulunmasını kolaylaştırmaktır. Şekil 3.23'te örnek bir uygunluk matrisi verilmiştir. Matristeki yeşil hücreler, EA'nın seçili şarj ünitesi ve zaman diliminde orada bulunma olasılığının olduğunu belirtmektedir. Kırmızı hücre ise, seçili şarj ünitesinin dolu olduğu zaman dilimleridir. Bir şarj ünitesinde geçirilen minimum zamanın belirlenmesinde EA'nın uğrayacağı şarj istasyonları baz alınarak bir sonraki istasyona varması için gereken enerji miktarı ve şarj süresi hesaplanır. Şarj ünitesinde geçirilecek maksimum süre hesaplanırken ise EA'nın tam dolum için gereken enerji miktarına göre şarj süresi hesaplanır. Varış düğümüne ulaşana kadar uğranılacak tüm şarj ünitelerinin uygun zaman dilimleri bu şekilde elde edilir.



Şekil 3.23. Uğranılacak şarj ünitelerine en erken varış ve en geç ayrılış zaman dilimlerinin gösterimi

A.2.2. SŞPM (Sınırlandırılmış Şarj Planlama Modeli): SŞPM için gerekli bilgiler (uğranılacak şarj istasyonları, şarj üniteleri, minimum ve maksimum enerji miktarları, şarj süreleri ve varış ve ayrılış zamanları) temin edildikten sonra bu bilgiler SŞPM'e aktarılır. SŞPM'de yer alan yeni kısıt ve sınırlar Denklem (3.75)-(3.91)'de verilmiştir. Burada S , uğranılacak şarj istasyonlarını içeren bir kümeyi ve S' , S dışında kalan şarj istasyonlarını ifade etmektedir.

$$x_i^v + x_i^g = 1 \quad \forall i \in S \quad (3.75)$$

$$x_i^v = 0 \quad \forall i \in S' \quad (3.76)$$

$$x_i^g = 0 \quad \forall i \in S' \quad (3.77)$$

$$G_i^v = 0 \quad \forall i \in S' \quad (3.78)$$

$$G_i^g = 0 \quad \forall i \in S' \quad (3.79)$$

$$\Sigma_h^H(y_{ifh}^v + y_{ifh}^g) \geq 1 \quad \forall i \in S, \forall f = f_i^s \quad (3.80)$$

$$\Sigma_h^H(y_{ifh}^v + y_{ifh}^g) \leq 0 \quad \forall i \in S, \forall f \neq f_i^s \quad (3.81)$$

$$y_{ifh}^v = 0 \quad \forall i \in S, \forall h \notin I_f^i, \forall f = f_i^s \quad (3.82)$$

$$u_{ifh}^v = 0 \quad \forall i \in S, \forall h \notin I_f^i, \forall f = f_i^s \quad (3.83)$$

$$tv_{ifh}^v = 0 \quad \forall i \in S, \forall h \notin I_f^i, \forall f = f_i^s \quad (3.84)$$

$$tg_{ifh}^v = 0 \quad \forall i \in S, \forall h \notin I_f^i, \forall f = f_i^s \quad (3.85)$$

$$\hat{I}_i^a \leq I_i^a \quad \forall i \in S \quad (3.86)$$

$$\hat{I}_i^d \geq I_i^d \quad \forall i \in S \quad (3.87)$$

$$\hat{R}_i^a \leq R_i^a \quad \forall i \in S \quad (3.88)$$

$$\hat{R}_i^d \leq R_i^d \quad \forall i \in S \quad (3.89)$$

$$\hat{T}_i^a \leq T_i^a \quad \forall i \in S \quad (3.90)$$

$$\hat{T}_i^d \geq T_i^d \quad \forall i \in S \quad (3.91)$$

Kısıt (3.75), EA'nın bu istasyonlarda şarj veya deşarj olmasını sağlamaktadır. Kısıt (3.76) ve (3.77), EA'nın uğranılacak şarj istasyonları içerisinde yer almayan şarj istasyonlarında şarj/deşarj olmasını engellemektedir. Kısıt (3.78) ve (3.79) ise, uğranılmayacak istasyonlardaki alınan/verilen enerji miktarını sifıra eşitler. Burada f_i^s , S kümesinde yer alan i . şarj istasyonunda uğranılacak şarj ünitesini temsil etmektedir. Kısıt (3.80), bu şarj ünitelerine uğranılmasını zorunlu kılmaktadır. Kısıt (3.81), EA'nın uğranılacak şarj üniteleri dışında kalan şarj ünitelerine uğramasını engellemektedir. I_f^i , i . şarj istasyonundaki f . şarj ünitesinin uygun olduğu zaman dilimleri kümesi olsun. Kısıt (3.82) ve (3.83), I_f^i dışında kalan zaman dilimlerinde EA'nın şarj/deşarj olmasını engellemektedir. Kısıt (3.84) ve (3.85), I_f^i dışında kalan zaman dilimlerinde EA'nın şarj/deşarj süresinin sıfır olmasını sağlar. $\hat{I}_i^a$ ve $\hat{I}_i^d$, uğranılacak şarj istasyonları (S) için kayan pencereler yöntemi ile elde edilen en erken varış ve en geç ayrılış zaman dilimlerini belirtir. Kısıt (3.86) ve (3.87), uğranılacak istasyonlardaki varış ve ayrılış zaman dilimlerini $\hat{I}_i^a$ ve $\hat{I}_i^d$ değerlerine göre sınırlamaktadır. Ancak zaman dilimleri periyodik oldukları için sınırlandırılmış modelin bu kısıtlar altında mümkün olmayan bir çözüm verme olasılığı vardır. Mümkün olmayan bir çözüm çıkması durumunda kısıt (3.86) ve

(3.87) SŞPM'e dahil edilmez. $\hat{R}_i^a$ ve $\hat{R}_i^d$, uğranılacak şarj istasyonları için varış ve ayrılış zamanındaki kalan enerji miktarını belirtmektedir. Kısıt (3.88), istasyona varış anındaki enerji miktarının alt sınır değerinin $\hat{R}_i^a$ ve kısıt (3.89) ise istasyondan ayrılış anındaki enerji miktarının $\hat{R}_i^d$ olmasını sağlamaktadır. $\hat{T}_i^a$ ve $\hat{T}_i^d$ uğranılacak şarj istasyonları için varış ve ayrılış zamanını belirtmektedir. Kısıt (3.90) ve (3.91), istasyonlara uğrama zamanlarını $\hat{T}_i^a$ ve $\hat{T}_i^d$ arasında sınırlamaktadır.

SŞPM için çözüm havuzu oluşturulur ve çözüm havuzundan rasgele bir çözüm seçilir. Bu işlem için CPLEX çözücüsünün Docplex Python kütüphanesinin “populate_solution_pool()” modülü kullanılmıştır (CPLEX Optimization Studio, 2021). Çözüm havuzu, dal-sınır algoritmasının bir uzantısını kullanarak karma tamsayılı programlama modeli için birden çok çözüm oluşturulmasına olanak tanır. Bu özellik alternatif çözümleri çeşitli şekillerde keşfetmek ve değerlendirmek için kullanılır. Çözüm havuzu ile elde edilen çözüm uygun ve geçerli bir çözüm ise popülasyona eklenir. Bu işlem döngü tamamlanana kadar devam ettirilir.

B. GA: Başlangıç popülasyonu oluşturulduktan sonra çözümlerin uygunluk değerleri hesaplanır. En iyi çözüm ve uygunluk değeri belirlenir. Durdurma kriteri ve iyileştirme sayacı eşik değeri ayarlanır. Ardından GA çalıştırılır. Her iterasyon sonucunda iyileştirme sayaç değeri güncellenir. Eğer iterasyon sonunda elde edilen uygunluk değeri bir önceki iterasyondaki uygunluk değeri ile aynı ise iyileştirme sayaç değeri bir artırılır, güncellenirse de sayaç değeri sıfırlanır. Sayaç değeri iyileştirme eşik değerine ulaşırsa iyileştirme prosedürüne geçilir. GA ile elde edilen uygunluk değerleri belirlenen iyileştirme sayaç değeri boyunca değişmemesi durumunda iyileştirme prosedürüne geçilir. GA, durdurma kriteri sağlanana kadar devam ettirilir. GA tamamlandıktan sonra nihai çözüm aşamasına geçilir.

C. İyileştirme Prosedürü: İyileştirme prosedüründe en iyi ilk %50'lik diliminde yer alan çözümler arasından bir çözüm, rulet tekerleği yöntemi ile seçilir. Seçilen çözüm için SŞPM çalıştırılır. Daha önce iyileştirme prosedürüne tabi tutulan bir çözüm için tekrar aynı işlemin uygulamaması için tabu listesi oluşturulur. Bu şekilde her seferinde farklı çözümlerin iyileştirme prosedürüne tabi tutulması sağlanır. GA çözümünden uğranılacak

şarj istasyonları ve şarj üniteleri bilgisi alınır, kayan pencereler yöntemi ile sınır değerler belirlenir ve SŞPM ile çözüm aranır. Verilen sürede daha iyi bir çözüm elde edilmesi durumunda GA çözümü güncellenir ve tekrar GA modülüne devam edilir. Durdurma kriteri sağlanınca nihai çözüm modülüne geçilir. Bu modül iyileştirme prosedürü modülünde olduğu gibi SŞPM ile verilen sürede daha iyi bir çözüm elde edebilmeyi sağlar. Elde edilen çözüm daha iyi ise yeni çözüm, eski çözüm ile değiştirilir. Aynı çözümler seçilmesinin engellemek için tabu listesi kullanılır. Böylece her seferinde farklı çözümlerin iyileştirilmesi sağlanır.

D. Nihai Çözüm: GA sonucunda elde edilen en iyi çözüm seçilir. Bu çözüme göre uğranılacak istasyonlar ve şarj üniteleri sabitlenir, zamana bağlı değişkenlerin sınır değerleri kayan pencereler yöntemi ile elde edilerek SŞPM'e aktarılır. SŞPM ile daha iyi bir sonuç elde edilmesi durumunda yeni şarj planı olarak sürücüye sunulur.


4. BULGULAR

Bu bölümde veri analizi, menzil tahmin ve şarj planlaması için önerilen yaklaşımlarla elde edilen bulgular paylaşılmıştır.

4.1. Veri Analizi Bulguları

ChargeCar veri setinde uzun duraksama ve alt yolculuklar içeren yolculuklar tespit edilmiştir. Uzun duraksama ve alt yolculuk içermeyen sadece 15 yolculuk vardır. Geriye kalan 40 yolculuk verisinde duraksamalar bulunmaktadır. Alt yolculuk ve uzun duraksama içeren yolculuk verilerindeki duruş zamanları belirlenerek veri setinden çıkarılmıştır ve duruş sonrası her yolculuk yeni bir yolculuk verisi olarak kaydedilmiştir. Bu işlem sonrası toplam yeni yolculuk sayısı 55'ten 152'ye çıkmıştır.


EA'ların menzil tahmininde yolculuğun statik öznitelikleri ile yolculuk segmentlerine ait dinamik öznitelikler kullanılmıştır. Veri setindeki yolculukların rota tipi segment bazında bilinmediği için yolculuğa ait statik bir öznitelik olarak değerlendirilmiştir. ChargeCar veri setindeki yolculukların sürüş mesafesi %77'si 25 km'nin altındadır ve yolculukların ortalama sürüş süresi 30 dk'dır. Genel olarak şehir içi sürüşlerine ait veriler bulunmaktadır. Dolayısıyla sürüşlerde rota tipinin yolculuğa ait statik bir öznitelik olarak kullanılması mümkündür. Ancak ortalamanın çok üzerinde olan aykırı yolculuklar da veri setinde bulunmaktadır. Yolculuk verilerindeki veri sayısı uzunluğu bakımından aykırı veri olarak değerlendirilen veriler Şekil 4.1'de gösterilmiştir.



Şekil 4.1. Yolculuk uzunluklarına göre oluşturulan kutu grafiği

Aykırı uzunluğa sahip yolculuklarda farklı rota tipleri bulunabilir. Bu kapsamda yolculukların hız-zaman verileri üzerinden değişim noktaları tespit edilerek, yolculuklar segmente edilebilir. Belirlenen uzun yolculuklar için zaman serisi segmentasyonunda kullanılan ClaSP algoritmasını uygulanarak rota tipinin değiştiği zaman noktaları belirlenmiştir. Değişim noktaları belirlendikten sonra, yolculuklar bu noktalardan bölünerek yeni alt yolculuklar oluşturulur. ClaSP algortması uzunluk bakımından diğerlerinden aykırı olan 14 yolculuk veri seti üzerinde uygulanmıştır. ClaSP algoritmasının tek parametresi olan pencere boyutu, yolculuk uzunluğuna göre parçalı bir fonksiyon olarak seçilmiştir.

ClaSP uygulandıktan sonra toplam sefer sayısı 62'ye yükselmiştir ve bu da 214 sefer ile sonuçlanmıştır. Ortalama süre 35,3 dakikadan 25,1 dakikaya, ortalama yolculuk mesafesi 14,7 km'den 10,5 km'ye düşmüştür (Şekil 4.2). Uzun yolculuklar alt yolculuklara ayrıldıktan sonra tüm yolculukların tiplerini kümelemek için öznitelige dayalı ve şekle dayalı olmak üzere iki farklı kümeleme yöntemi kullanılmış ve menzil tahmin modeli üzerindeki etkileri karşılaştırılmıştır.




Şekil 4.2. Uzun yolculukların bölünmeden öncesi ve sonrası istatistikler

Yolculuk hız profillerini kümelemek için zaman serisi özniteliklerinin elde edilmesinde kullanılan Christ vd. (2018) tarafından geliştirilen tsfresh kütüphanesi kullanılmıştır. Elde edilen öznitelikler Çizelge 4.1'de verilmiştir. K-ortalamlar algoritması $k = 2$ alınarak çalıştırılmıştır.

Çizelge 4.1. Hız profillerinden elde edilen öznitelikler

Öznitelik	Açıklama
“Absolute sum of changes”	Zaman serisindeki ardışık değişikliklerin mutlak değerinin üzerindeki toplamı verir.
“cid_ce”	Zaman serisi karmaşıklığı ölçen parametre (Daha karmaşık bir zaman serisinin daha fazla zirvesi, vadileri vb.).
“Number crossing”	Zaman serisinin belirli bir değerin üzerine çıktığı/altına düştüğü sayıyı verir. Uygulamada 20 ve 90 değerler için öznitelik oluşturulmuştur.
“Number peaks”	Zaman serisinde en az n komşuluktaki tepe sayısını hesaplar. Tepe noktası, sağ ve soldaki n komşusundan daha büyük olmalıdır. $n=10$ alınmıştır.
“Value count”	Zaman serisindeki değer (value) tekrarlarını sayar. Duraksamaları saymak amacıyla value=0 olarak alınmıştır.

Şekle dayalı kümeleme yönteminde yolculuklar, EPA’nın şehir içi ve şehir dışı hız profil verilerine benzerliklerine göre etiketlenmiştir. Her yolculuk ile EPA hız profilleri arasındaki benzerlik, DZB algoritması kullanılarak hesaplanmıştır. Şekil 4.3, şekle dayalı kümeleme yöntemi ile kümelenen bazı yolculukları göstermektedir. Yolculuk ile şehir dışı yolculuk ($DZB_{şehir\ dışı}$) arasındaki DZB mesafeleri ve yolculuk ile şehir içi yolculuk $DZB_{şehir\ içi}$ arasındaki DZB mesafesi hesaplandıktan sonra yolculuk, minimum DZB mesafesini veren aynı yol tipiyle etiketlenmiştir. Şehir içi yolculuk olarak etiketlenen sefer sayısı 126, karayolu güzergahı 88’dir.



Şekil 4.3. DZB yolculuklarının hız profillerinin şekle dayalı kümelmesi

4.2. EASMT Bulguları

EASMT için geliştirilen modelin tahmin sonuçlarını değerlendirmek amacıyla iki tür test seti oluşturulmuştur. Birinci test setinde ($test_y$) rasgele seçilen yolculukların (214 yolculuk) %80'i eğitim ve %20'si test için ayrılmıştır. İkinci test setinde ($test_s$) yolculuklara ait toplam 33625 segment verisi başlangıçta karıştırılarak %80'i eğitim ve %20'si test için rasgele seçilmiştir. $test_y$ için metrikler yolculuk bazında harcanan gerçek enerji ile tahmin edilen enerji tüketimine göre hesaplanırken, segment tabanlı modellerin performansını değerlendirmek için $test_s$ veri seti kullanılarak segment bazında harcanan gerçek enerji ile tahmini enerji üzerinden hesaplama yapılmıştır. Segment tabanlı model ile yolculuklardaki toplam enerji tüketimi tahmin etmek için, $test_y$ test kümesindeki her yolculuk segmentinin enerji tüketimini tahminleri toplanır. Çalışmada dört metrik kullanılmıştır: MSE, ortalama mutlak hata (MAE), kök ortalama kare hatası (RMSE) ve r kare (r^2). Metriklerin matematiksel formülleri aşağıda verilmiştir. Burada, N gözlem sayısını, y_i gözlemin gerçek değerini, $\hat{y}_i$ tahmin edilen değerini ve $\bar{y}_i$ ise gözlem değerlerinin ortalamasını ifade etmektedir. Tahmin modellenmesinde Keras ve Scikit-Learn kütüphaneleri kullanılmıştır. Tüm testler Python 3.8 programlama dilinde kodlanmıştır.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4.1)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (4.2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (4.3)$$

$$r^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (4.4)$$


EASMT modeli için dört deney gerçekleştirilmiştir (Şekil 4.4):

Deney 1: Gözlem tipinin (yolculuk verisi/segment verisi) etkisini araştırmaktadır.

Deney 2: Rota tipi küme etiketlerinin dahil edilmesinin etkisine odaklanmaktadır. Bu etkiyi test etmek için rota tipi etiketleri olan ve olmayan modeller ile elde edilen sonuçların metrikleri analiz edilmiştir.

Deney 3: Girdilerin segment bazlı gözlemler üzerindeki etkisini test etmek için DSA-A ve DSA-B modelleri arasında bir karşılaştırma yapılmıştır.

Deney 4: Statik verilerinin farklı katmanlarda eklemenin etkisini incelemek için farklı DSA model mimarileri geliştirilmiş ve tahmin performansları araştırılmıştır.



Şekil 4.4. Menzil tahmin modeli için deneysel çalışmalar

4.2.1. Deney 1: Gözlem tipinin etkisi

Yolculuk tabanlı ve segment tabanlı gözlem tipinin test veri setindeki tahmin performansı üzerindeki etkisi karşılaştırılmıştır. Öncelikle yolculuk tabanlı gözlemler de enerji tahmini yapabilmek için tahmin modeli olarak Rastgele Orman Regresyon (ROR), XGBoost ve tek gizli katmanlı bir DSA modeli eğitilmiştir. Burada yolculuk veri sayısının az olması nedeniyle (214 yolculuk) çok parametre optimizasyonu gerektirmeyecek makine öğrenmesi modelleri arasından seçim yapılmıştır. Model girdisi olarak yolculukların mesafesi, süresi, toplam araç ağırlığı, hava sıcaklığı, ortalama hızı

maksimum hız ve net yükseklik değişimi kullanılmıştır. Çizelge 4.2’de tahmin sonuçları paylaşılmıştır. Hata metrikleri en düşük olan yöntemin Rastgele Orman Regresyon (ROR) modeli olduğu görülmektedir.

Çizelge 4.2. Yolculuk bazında enerji tahmini yapan modeller


Modeller	MSE	MAE	RMSE	r^2
ROR	0,387	0,425	0,622	0,920
XGBoost	0,575	0,460	0,758	0,901
DSA	2,514	0,740	1,586	0,703

Enerji tahmini için gözlem tipi olarak segment veya yolculuk gözlemlerinden hangisinin daha iyi sonuç verdiğini bulmak için $test_y$ kullanılarak modellerin performansı test edilmiştir. Çizelge 4.3, segment gözlemlerini girdi olarak alan DSA-A ve yolculuk gözlemlerini girdi olarak alan ROR modeli sonuçlarını içerir. Segmentler üzerindeki enerji tüketimlerinin tahmin edilmesi, yolculuk tabanlı gözlemler kullanılarak yapılan tahmin sonuçlarına kıyasla daha az tahmin hatası verdiği görülmektedir.

Çizelge 4.3. Gözlem tipinin tahmin sonuçları

Eğitim-test veri seti	Model	MSE	MAE	RMSE	r^2
$test_y$	DSA-A	0,004	0,043	0,066	0,940
	ROR	0,387	0,425	0,622	0,920

Şekil 4.5’te $test_y$ veri setindeki yolculuklular için DSA-A ve ROR ile tahmin edilen enerji tüketimleri gösterilmiştir. Test setindeki yolculuklar farklı uzunluklara sahiptir. Gözlem türü için her yolculuk için tahmin sonuçlarını görmek Şekil 4.5’e göre, enerji tüketimi tahmin sonuçları kısa yolculuklar için daha doğrudur. Tahmin hatası, yolculuğun mesafesi ile orantılı olarak arttığı görülmektedir. Tahmin hatasının özellikle yolculuk tabanlı gözlemler için geçerli olduğu görülmektedir.



Şekil 4.5. ROR ve DSA-A ile enerji tüketimi tahmini sonuçları

4.2.2. Deney 2: Rota tipi küme etiketinin etkisi

Düşük veya yüksek hızda sürüş yapmak, “dur-kalk” yaparak yolculuğu tamamlamak veya durmaksızın bir sürüşü önceden oluşturmak, rota tipi ile ilişkili bir durumdur. Yolculukları rota tiplerine göre ayırmak için iki tür zaman serisi kümeleme tekniği uygulanmıştır. Hem özniteliğe dayalı hem de şekle dayalı kümeleme için yapılan etiketleme işlemi sonuçlarına ait bilgiler Çizelge 4.4’te verilmiştir. Sonuçlara göre, farklı kümelerde etiketlenmiş 95 yolculuk bulunmaktadır. Yolculukların çoğu her iki kümeleme yöntemi için şehir içi yolculuk olarak seçilmiştir.

Çizelge 4.4. Küme etiketleri matrisi


		Özniteliğe dayalı kümeleme		Toplam
		Şehir içi	Şehir dışı	
Şekle dayalı kümeleme	Şehir içi	83	45	128
	Şehir dışı	50	36	86
Toplam		133	81	214

Kümeleme tekniklerindeki farkı daha iyi anlamak için, ortalama yolculuk mesafesi (km), süre ve hız Çizelge 4.5’te verildiği gibi karşılaştırılır. Kümeleme sonuçlarını görsel olarak analiz etmek için Şekil 4.6, karışıklık matrisinde her kategori için seçilen yolculukları göstermektedir.

Çizelge 4.5. Kümelerin ortalama mesafe, süre ve hız bilgileri

Rota tipi	Küme Etiketi	Ortalama mesafe (km)	Ortalama süre (dk)	Ortalama hız (km/sa)
Şehir içi	Özniteliğe dayalı	4,51	12,99	22,82
	Şekle dayalı	5,91	21,46	14,05
Şehir dışı	Özniteliğe dayalı	20,05	33,25	40,82
	Şekle dayalı	17,06	19,48	37,38

Özniteliğe dayalı kümeleme yöntemi, yolculukları yoğunlukla uzunluklarına göre gruplandırırken, şekle dayalı kümeleme yolculukları hızın kararlılığına göre kümelemiştir. Özniteliğe dayalı kümeleme sonuçlarında kümeleme işleminin genel olarak hız profillerinin minimum ve maksimum değerlerine göre gerçekleştirildiği görülmektedir. Çizelge 4.5'te de belirtildiği üzere, şehir içi kümelenmenin ortalama mesafesi, süresi ve hızı karayolu kümesinden daha azdır. Bununla birlikte, şekil tabanlı kümeleme ile kentsel kümelenmede ortalama süre (21,46 dk), karayolu kümelenmesinden (19,48 dk) daha fazladır. Şekil 4.6'da verilen şekle dayalı kümeleme sonuçlarında, ardışık durakları içeren yolculuklar, şekle dayalı kümeleme sonuçlarında birlikte kümelenme eğiliminde olmuştur.



Şekil 4.6. Rota tipi kümeleme sonuçlarından bazı örnekler

Her iki kümeleme tekniği için rota tipi etiketlerinin etkisi, rota tipi etiketinin kullanılmadığı durumla karşılaştırılmıştır. Çizelge 4.6, rota tipi etiketlerini kullanmanın ROR modelini kullanan yolculuk tabanlı gözlemler için tahmin sonuçları üzerindeki etkisini göstermektedir. Girdi olarak rota tipi etiketi kullanılmadığında tahmin doğruluğu en düşük seviyede kalmaktadır. Şekle dayalı kümeleme etiketlerinden elde edilen rota tipi etiketleri, özniteliğe dayalı kümelemekten elde edilen etiketlere göre daha iyi sonuçlar vermiştir. Çizelge 4.6’da verilen her metrikte, şekle dayalı kümeleme etiketleri, özniteliğe dayalı kümelemeye göre tahmin hatasını daha fazla azaltmaktadır.

Çizelge 4.6. Yolculuk tabanlı modelde rota tipi etiketi kullanmanın etkisi

Test veri seti	Model	Rota tipi etiketi	MSE	MAE	RMSE	r^2
$test_y$	ROR	Yok	0,387	0,425	0,622	0,920
		Özniteliğe dayalı	0,368	0,417	0,606	0,924
		Şekle dayalı	0,352	0,407	0,593	0,925

Rota tipi etiketinin segment tabanlı gözlemlerin enerji tahmini üzerindeki etkisini incelemek için DSA-B modeli, $test_s$ veri seti ile eğitilip test edilmiştir. Çizelge 4.7’de statik ve dinamik segment verisini girdi olarak alan DSA-B modeli ile özniteliğe dayalı ve şekle dayalı kümeleme ile elde edilen rota tipi etiketlerinin segment bazında tahmin sonucuna etkisi gösterilmiştir.

Çizelge 4.7. Segment tabanlı modelde özniteliğe ve şekle dayalı küme etiketi kullanmanın etkisi

Test veri seti	Model	Rota tipi etiketi	MSE	MAE	RMSE	r^2
$test_s$	DSA-B	Özniteliğe dayalı	0,262	0,256	0,512	0,9911
		Şekle dayalı	0,207	0,216	0,455	0,9928

Genel olarak, rota tipi etiketinin yolculuk verilerine dahil edilmesinin olumlu etkisi gözlemlenebilir. Şekle dayalı kümelemekten elde edilen etiketler, özniteliğe dayalı kümelemekten elde edilen etiketlerden daha iyi performans göstermiştir. Sonuçlara göre enerji tahmini için hız profillerinin şekle bağlı ayırt edilmesinin, yolculukların genelleştirici istatistiklerinin kullanılmasından daha bilgilendirici olduğu sonucuna varılmaktadır. Kümeleme için öznitelik sayısının artırılmasının tahminleri iyileştirdiği ve hatta şekle

dayalı kümeleme tekniğinden daha iyi performans gösterdiği görülmüştür. Bu durumda, metodolojiye daha fazla veri önışleme adımları eklenmesi gerekecektir. En iyi sonucu en az veri önışlem adımı ile gerçekleştirmek veri bazlı modellerde önem arz eden bir konudur.

4.2.3. Deney 3: Statik ve dinamik verilerinin birlikte kullanımının etkisi

Yolculuğa ait statik öznitelikler ile yolculuk segmentlerinin dinamik verilerinin DSA modelinde birlikte girdi olarak kullanılmasının etkisi analiz edilmiştir. DSA-A modeli yalnızca dinamik verilerle, DSA-B modeli ise statik ve dinamik verilerle eğitilmiştir. Çizelge 4.8, segmentlere ilişkin tahmin sonuçlarını vermektedir. Sonuçlar, dinamik veriler ile birlikte statik verilerin kullanılmasının her bir metrik için tahmin doğruluğunu arttırdığını göstermektedir.

Çizelge 4.8. Statik ve dinamik verinin birlikte kullanmanın segmentte harcanan enerji tahmini üzerindeki etkisi

Test veri seti	Model	MSE	MAE	RMSE	r^2
$test_s$	DSA-A	0,2724	0,2496	0,5219	0,9904
	DSA-B	0,2075	0,2156	0,4555	0,9928


Statik ve dinamik verinin birlikte kullanmanın yolculukta harcanan enerji tahmini üzerindeki etkisi Çizelge 4.9’da verilmiştir. Sonuçlara göre DSA-A, DSA-B modeline göre daha düşük iyi performans göstermiştir. Ancak her yolculuk için kümülatif enerji tüketimini tahmin ederken (Çizelge 4.8) DSA-B, DSA-A’dan daha iyi sonuçlar elde etmiştir. Bu sonucun temel nedenlerinden biri negatif ve pozitif enerji tüketimi tahminlerinin kümülatif olarak birleştirilmesinden kaynaklanıyor olmasıdır. Önceki segmentlerde yapılan tahmin hataları, hata devam ettikçe kapatılır. Elbette bu, kümülatif hatanın her zaman azalacağı anlamına gelmez; tersi de mümkündür. Bununla birlikte, segmentler için tahmin hatası en aza indirilirse, kümülatif enerji tüketimi gerçekten azalacaktır.

Çizelge 4.9. Statik ve dinamik verinin birlikte kullanmanın yolculukta harcanan enerji tahmini üzerindeki etkisi

Test veri seti	Model	MSE	MAE	RMSE	r^2
$test_y$	DSA-A	0,0044	0,0425	0,0661	0,9989
	DSA-B	0,0045	0,0485	0,0672	0,9989

4.2.4. Deney 4: Kullanılan model mimarisinin etkisi

Bölüm 2.1’de de belirtildiği gibi, DSA modellerinde zaman serisi verilerinin statik özniteliklerinin kullanım şekli, tahmin sonuçlarının performansını etkileyebilmektedir. Bu nedenle DSA-A ve DSA-B dışında, statik özniteliklerinin modelde iki kez kullanıldığı üç farklı model mimarisi oluşturulmuştur. Şekil 4.7, geliştirilen yeni model mimarilerini göstermektedir. DSA-C, statik ve dinamik girdileri birinci katmandan önce birleştirir ve birinci katmanın çıktısını tekrar statik girdilerle birleştirir. DSA-D, statik girdileri ikinci katmanın dinamik girdileri ve çıktısı ile birleştirir ve DSA-E’de statik girdiler, birinci ve ikinci katmanın çıktısı ile iki kez birleştirilir. Statik ve dinamik girişler, DSA-B’de kullanılanlarla aynıdır. Modellerde kullanılan rota tipi etiketleri, şekle dayalı kümeleme ile belirlenmiştir.



Şekil 4.7. Statik ve dinamik segment verilerini birleştirmek için oluşturulan model mimarileri

Segment ve yolculuk gözlemlerindeki enerji tahmin sonuçları sırasıyla Çizelge 4.10 ve 4.11’de verilmiştir. Her iki gözlem türü için de DSA-D’nin en iyi sonuçları, DSA-C’nin ise en kötü sonuçları verdiği görülmektedir. Segmentler için tahminler, açmalardaki hatalardan daha yüksek bir hata değerine sahiptir. Ayrıca, segmentler için tahmin

sonuçları, açmalar için verilen hatalardan çok daha benzerdir. Başka bir deyişle, DSA-D, yolculuklardaki yüzdeler açısından daha iyi performans gösterir. Her metrik ve testi seti için sonuçların kararlılığı ve tutarlılığı, statik ve dinamik verileri birleştirmek için model mimarisinin tahmin sonuçlarını etkilediğini göstermektedir.

Çizelge 4.10. Segmentte harcanan enerji tahmini için DSA-C, DSA-D ve DSA-E'nin karşılaştırmalı sonuçları

Test veri seti	Model	MSE	MAE	RMSE	r^2
$test_s$	DSA-C	0,2370	0,2290	0,4870	0,9919
	DSA-D	0,2070	0,2134	0,4547	0,9928
	DSA-E	0,2222	0,2246	0,4713	0,9923

Çizelge 4.11. Yolculukta harcanan enerji tahmini için DSA-C, DSA-D ve DSA-E'nin karşılaştırmalı sonuçları

Test veri seti	Model	MSE	MAE	RMSE	r^2
$test_y$	DSA-C	0,0073	0,0571	0,0852	0,9982
	DSA-D	0,0018	0,0321	0,0428	0,9995
	DSA-E	0,0036	0,0411	0,0602	0,9991

4.3. EAŞP Bulguları

Şarj planlama modelinin çözüm süresini farklı büyüklüklerdeki problemlerde test etmek için rassal problemler üretilmiştir. Problemler üretilirken Çizelge 4.12'deki veriler dikkate alınmıştır. Her test probleminde belirli sayıda şarj istasyonu bulunmaktadır.

Çizelge 4.12. Test problemlerin üretilmesinde kullanılan parametreler

Parametre	Değer
Enerji Kapasitesi (B)	35 kWh
Minimum enerji seviyesi (B_{min})	%20
Başlangıç enerji miktarı (r_0)	14 kWh
Sürüşün başladığı zaman dilimi (h_0)	7
Zaman dilimi sayısı H ve uzunluğu (M)	24, 60 dk
Şarj süresinin (kırılma noktası) (bp)	%80
Şarj süresinin kırılma noktası sonrası güç değerindeki azalma oranı (sp)	%50


Şarj istasyon sayısı 5'ten 50'ye kadar beşer beşer arttırılıp, her istasyondaki şarj ünitesi sayısı $m_i \in [1,3]$, $m_i \in [2,5]$ ve $m_i \in [3,10]$ aralıkları için rasgele seçilmiştir. Başlangıç düğümünden her bir istasyona durmaksızın yapılan yolculuklarda gereken enerji tüketimi en az 2 kWh, en çok $B(1 - B_{min})$ kWh olacak şekilde belirlenmiştir. Böylece EA'nın menzil kaygısı çekmeden sürüş gerçekleştirebilmesi sağlanır. Aynı şekilde başlangıç düğümünden her bir istasyona durmaksızın yapılan yolculuklarda dakika cinsinden sürüş süresi s_i , enerji tüketim parametresiyle orantılı olarak hesaplanmıştır (Denklem (4.5)):

$$s_i = s_{i-1} + (e_i - e_{i-1}) * uniform(2,5) \quad (4.5)$$

Şarj ünitelerinin güç miktarlarının belirlenmesinde Türkiye'nin şarj istasyon firmalarından EŞarj'ın 2022 yılı AC ve DC güç miktarları baz alınmıştır (EŞarj, 2022). AC şarj üniteleri, $p_{AC} \in \{7 \text{ kW}, 11 \text{ kW}, 22 \text{ kW}\}$ güç miktarı değerlerinden rasgele olarak seçilmiştir. DC şarj üniteleri ise, $p_{DC} \in \{24 \text{ kW}, 50 \text{ kW}\}$ olarak kullanılabilir. Problemler uzun yolculukları kapsayan bir model için üretildiğinden yolculukların şehirlerarası sürüşler olduğu varsayımı ile oluşturulmuştur. Şehirlerarası yollardaki şarj istasyonlarında en az bir DC şarj ünitesi olduğu varsayımına göre şarj ünitelerinin güç miktarları seçilmiştir. Eğer şarj istasyonun bir şarj ünitesi varsa, güç miktarı p_{DC} içerisinden seçilir. Birden fazla şarj ünitesi olan şarj istasyonların için ise, içlerinden en az bir şarj ünitesinin DC şarj olması kaydıyla gerisi p_{AC} ve p_{DC} içerisinden rasgele seçilmiştir.

$$\$/dk = (\$/MWh) * (1/60) * (1/1000) * M/k * kW \quad (4.6)$$

Şarj istasyonlarındaki şarj ünitelerinin zaman dilimlerine bağlı değişen fiyatları oluştururken Enerji Piyasaları İşletme Anonim Şirketinin (EPIAŞ) şeffaflık platformunun 4 Nisan 2022 Pazartesi gününe ait saatlik elektrik enerjisi fiyatları verisi kullanılmıştır (EPIAŞ, 2022). Enerji fiyatlarına ait grafik, Şekil 4.8'de gösterilmiştir. Denklem (4.6) ile saatlik elektrik enerjisi fiyatlarının birimi ($\$/MWh$) şarj planlama modelindeki birime ($\$/dk$) dönüştürülmüştür.



Şekil 4.8. EPIAŞ 4 Nisan 2022 Pazartesi gününe ait saatlik elektrik enerjisi fiyatları

Denklem (4.6)'ya göre şarj ünitelerinin saatlik fiyatları, şarj ünitelerinin şarj gücüne bağlı hesaplanır. Şarj gücü yüksekse dakikalık şarj fiyatı da yüksek olacaktır. Oluşturulan test problemlerinde bir şarj ünitesinin zaman dilimine bağlı şarj ve deşarj fiyatları eşit olduğu varsayılmıştır. Şarj istasyonlarındaki şarj ünitelerinin uygunluk parametrelerini belirlerken, mümkün olmayan çözüm ortaya çıkarmamak için tek bir şarj ünitesi olan istasyonların her bir zaman dilimi için uygun olduğu ($w_{ifh} = 1$) varsayılmıştır. Birden fazla şarj ünitesi varsa, uygunluk değerleri %10 olasılıkla dolu olacak şekilde rasgele atanmıştır.

Toplamda 32 farklı büyüklükte test problemi oluşturulmuştur. Testler önce şarj planlama için geliştirilen matematiksel programlama modeli üzerinde test edilmiştir. Ardından önerilen diğer yaklaşımlar (sezgisel, metasezgisel ve mat-sezgisel) için test edilip amaç fonksiyonu ve çözüm süresi açısından karşılaştırmalar yapılmıştır.

4.3.1. Matematiksel modelin çözüm sonuçları

Şarj planlama problemi için geliştirilen matematiksel programlama modeli, oluşturulan küçük ve orta büyüklükteki problemler üzerinde test edilmiştir. Matematiksel model 8 GB ram bilgisayarda Python 3.8'de kodlanmıştır ve IBM ILOG CPLEX 20.0 versiyonunun Python kütüphanesi olan DOcplex kullanılarak dal-sınır algoritması ile çözülmüştür. Çözüm süresi 3600 dakika ile sınırlandırılmıştır. Her bir test problemdeki şarj istasyon sayısı (n), istasyonlardaki şarj ünitesi sayısı aralığı (m_i), toplam şarj ünitesi sayısı, tüm yolculuğu tamamlamak için gereken enerji miktarı (l) verilmiştir. Minimum yolculuk süresi için elde edilen sonuçlar Çizelge 4.13'de ve minimum yolculuk maliyetinin çözüm sonuçları Çizelge 4.14'te verilmiştir.

Çizelge 4.13. Matematiksel modelin amaç fonksiyonu minimum yolculuk süresi iken elde edilen sonuçlar

n	m_i	$\sum m_i$	l (kWh)	Tamsayı değişken	Kısıt	Yolculuk süresi (dk)	Çözüm süresi (sn)
5	[1-3]	9	57	1530	3733	427,7	17
5	[2-5]	18	47	1683	4123	185,4	837
5	[3-10]	25	58	2397	5943	289,1	3600
10	[1-3]	18	144	2753	6681	562,4	3600
10	[2-5]	33	121	3264	7983	737,7	3600
10	[3-10]	58	117	5049	12533	590,8	3600
15	[1-3]	29	196	3716	8969	846,5	3600
15	[2-5]	56	206	4845	11843	994,6	3600
15	[3-10]	100	178	13025	27232	-	3600

Her iki amaç fonksiyonu için sadece ilk iki test probleminin optimal çözümü elde edilmiştir. Şarj istasyon sayısı 5'ten 10'a çıkartıldığında 3600 sn içerisinde optimal çözüm elde edilememektedir. Ayrıca şarj istasyonlarındaki ünite sayısındaki artış, çözüm süresine olumsuz etkilemiştir. Sonuç olarak şarj planlama için geliştirilen matematiksel modelin küçük ve orta boyutlu problemlerde minimum süre ve maliyet için verilen sınırlı sürede optimal çözümü bulmakta yetersiz kaldığı görülmektedir.

Çizelge 4.14. Matematiksel modelin amaç fonksiyonu minimum yolculuk maliyeti iken elde edilen sonuçlar

n	m_i	$\sum m_i$	l (kWh)	Tamsayı değişken	Kısıt	Yolculuk Maliyeti (\$)	Çözüm süresi (sn)
5	[1-3]	9	57	1373	3044	9,9	55
5	[2-5]	18	47	2471	5276	3,0	3058
5	[3-10]	25	58	3325	7012	4,9	3600
10	[1-3]	18	144	2746	6086	10,1	3600
10	[2-5]	33	121	4576	9806	16,2	3600
10	[3-10]	58	117	7626	16006	-	3600
15	[1-3]	29	196	4363	9624	19,7	3600
15	[2-5]	56	206	7657	16320	-	3600
15	[3-10]	100	178	13025	27232	-	-

4.3.2. Önerilen yaklaşımların karşılaştırmalı sonuçları

Şarj planlama problemi için önerilen dört sezgisel yaklaşım (S1: Her istasyonda tam dolum, S2: Eşik değerin altına düşmeyecek şekilde tam dolum, S3: Ulaşılabilen en uzak istasyona varabilecek kadar dolum ve S4: Sıradaki istasyona varabilecek kadar dolum), metasezgisel yaklaşım (GA) ve mat-sezgisel yaklaşım (MAT-GA) kullanılarak test problemleri için çözümler elde edilmiş ve sonuçlar karşılaştırılmıştır. GA ve MAT-GA yöntemlerinin ortak parametreleri Çizelge 4.15'te verilmiştir. Buna ek olarak MAT-GA'nın iyileştirme sayacı eşiği 10 iterasyon olarak ayarlanmıştır (10 iterasyon boyunca iyileştirme olmaması durumunda sınırlandırılmış şarj planlama modeli ile iyileştirme yapılması adımı). Kayan pencereler yöntemi ile şarj ünitesinden ayrılış zaman dilimini belirlerken, en erken ve en geç ayrılış zaman diliminin ortalaması alınmıştır. Sınırlandırılmış şarj planlama modelinin çözüm süresi 20 sn olarak belirlenmiştir.

Çizelge 4.15. GA ve MAT-GA parametreleri

Parametre İsmi	Parametre değeri
İstasyon listesindeki rota sayısı	50
Popülasyon büyüklüğü	10
Çaprazlama oranı	0,7
Mutasyon oranı	0,1
Maksimum iterasyon sayısı	100

Çizelge 4.16 ve 4.17, sırasıyla minimum yolculuk süresi ve minimum yolculuk maliyeti için altı yaklaşım ile elde edilen amaç fonksiyon değerlerini içermektedir. Kalın gösterilen sayılar en iyi sonucu göstermektedir. S1, her iki amaç fonksiyonu için en kötü sonuçları içeren yöntem olduğu görülmektedir. Sezgisel yaklaşımlar arasından en iyi sonuç S4 ile elde edilmiştir. Minimum yolculuk süresi için sadece iki problemde (n : 25, m_i : [2-5] ve n : 30, m_i : [2-5]) S3, S4'ten daha iyi sonuç vermiştir. S4, toplam on altı test probleminde MATGA ile aynı en iyi minimum yolculuk süresini elde etmiştir. Ancak minimum yolculuk maliyeti için bir test problemi hariç (S1, n : 30, m_i : [3-10]) hiçbir sezgisel yaklaşım en iyi çözümü bulamamıştır. Bunun nedeni, sezgisel yaklaşımlar ile bulunan çözümlerde V2G işlemleri yer almamaktadır. Ancak GA ve MAT-GA yöntemlerinde V2G ile maliyet düşüşü mümkündür.

Çizelge 4.16. Minimum yolculuk süresi için karşılaştırmalı sonuçlar

n	m_i	$\sum m_i$	S1	S2	S3	S4	GA	MATGA
5	[2-5]	18	238,2	219	185,4	185,4	185,4	185,4
5	[3-10]	25	357,5	310,7	297,5	289,1	289,1	289,1
10	[1-3]	18	786,0	633,3	657,9	596,2	571,5	566,0
10	[2-5]	33	911,6	877,2	758,2	740,7	749,8	738,9
10	[3-10]	58	743,8	640,0	604,0	593,4	608,9	591,3
15	[1-3]	29	1103,2	989,2	919,7	889,1	888,9	879,0
15	[2-5]	56	1194,6	1153,1	1032,4	1019,5	1011,4	994,7
15	[3-10]	100	881,3	820,1	748,1	738,5	758,9	738,5
20	[1-3]	44	1783,6	1526,4	1524,0	1444,7	1530,4	1410,9
20	[2-5]	71	1432,5	1365,7	1235,7	1220,3	1239,2	1220,3
20	[3-10]	124	1424,7	1391,4	1285,1	1244,6	1245,0	1230,3
25	[1-3]	54	2186,1	2032,2	1856,3	1851,6	1836,8	1842,7
25	[2-5]	85	2086,8	1910,7	1781,1	1786,8	1788,3	1762,0
25	[3-10]	165	1737,6	1678,8	1528,8	1513,2	1551,6	1513,2
30	[1-3]	60	2366,8	2216,6	2042,1	2022,7	2050,5	2013,5
30	[2-5]	104	2408,1	2249,4	2024,7	2050,8	2044,2	2016,6
30	[3-10]	181	2217,2	2086,9	1977,7	1906,1	2008,2	1906,1
35	[1-3]	78	3119,8	2935,1	2727,0	2607,2	2747,8	2607,2
35	[2-5]	119	2857,3	2686,1	2472,3	2445,4	2464,0	2445,4
35	[3-10]	212	2513,2	2378,4	2230,3	2161,6	2202,9	2161,6
40	[1-3]	82	3283,0	3082,7	2827,1	2782,9	2897,0	2782,9
40	[2-5]	146	3209,5	3007,7	2777,2	2747,6	2817,2	2744,7
40	[3-10]	256	3098,8	2998,3	2683,9	2664,2	2764,1	2664,2
45	[1-3]	97	3333,7	3113,7	2786,0	2725,9	2816,2	2725,9
45	[2-5]	159	3744,7	3672,6	3393,0	3296,7	3466,9	3296,7
45	[3-10]	303	2938,7	2757,5	2579,9	2530,7	2634,4	2530,7
50	[1-3]	97	4133,0	3726,2	3482,6	3395,5	3531,4	3395,5
50	[2-5]	179	3524,2	3355,0	3103,4	3063,7	3166,7	3063,7
50	[3-10]	329	3901,0	3745,1	3448,8	3365,4	3475,8	3365,4
Ortalama			2190,2	2053,8	1895,5	1857,9	1908,4	1851,1

Her iki amaç fonksiyonu için ortalama en iyi çözüm MAT-GA ile elde edilmiştir. Minimum yolculuk süresi için GA'nın MAT-GA'dan daha iyi olduğu bir test problemi (n : 25, m_i : [1,3]) bulunmaktadır ve %0,3 daha iyi çözüm elde edebilmiştir. Amaç fonksiyonu yolculuk maliyeti olduğunda ise GA iki test probleminde (n : 5, m_i : [3,10] ve n : 15, m_i : [2,5]) MAT-GA'dan %4 ve %1 daha iyi çözüm vermiştir. MAT-GA yolculuk süresi için tüm test problemlerinde maksimum %8,5 ve ortalama %3 daha iyi sonuç elde edebilmişken yolculuk maliyet için maksimum %26 ve ortalama %6 daha iyi çözüm elde etmiştir.

MAT-GA'nın amaç fonksiyonu minimum yolculuk maliyeti olduğunda diğer yöntemlerle arasındaki fark, amaç fonksiyonu minimum yolculuk süresi olduğu duruma göre daha fazladır. Amaç fonksiyonu minimum yolculuk süresi olduğunda elde edilen optimal şarj planında EA istasyonlara sadece şarj işlem için uğramaktadır. Amaç fonksiyonu minimum maliyet olduğunda deşarj işlemleri ortaya çıkmaktadır.

Çizelge 4.17. Minimum yolculuk maliyeti için karşılaştırmalı sonuçlar

n	m_i	$\sum m_i$	S1	S2	S3	S4	GA	MATGA
5	[2-5]	18	10,33	8,31	5,43	6,25	4,33	3,44
5	[3-10]	25	13,40	10,84	9,24	7,05	5,15	5,34
10	[1-3]	18	26,13	16,85	13,62	12,59	11,84	10,61
10	[2-5]	33	27,80	23,97	21,0	20,66	18,82	16,78
10	[3-10]	58	26,34	19,48	17,16	15,67	14,34	13,87
15	[1-3]	29	36,08	27,32	25,31	22,04	21,39	21,12
15	[2-5]	56	42,13	39,58	28,86	28,53	25,89	26,03
15	[3-10]	100	30,52	24,96	19,34	17,98	16,59	15,44
20	[1-3]	44	57,68	46,91	37,51	35,09	34,88	33,44
20	[2-5]	71	53,67	46,53	34,69	32,50	31,69	29,31
20	[3-10]	124	44,95	39,42	27,46	28,12	25,00	24,14
25	[1-3]	54	61,72	54,91	41,13	38,45	39,55	35,99
25	[2-5]	85	68,47	59,69	44,22	39,77	39,85	37,78
25	[3-10]	165	67,63	61,09	44,68	43,99	42,28	42,17
30	[1-3]	60	76,96	66,77	52,37	48,80	47,67	46,78
30	[2-5]	104	79,70	72,60	49,83	50,40	47,71	46,05
30	[3-10]	181	78,77	67,64	50,94	45,61	48,02	45,61
35	[1-3]	78	93,67	79,33	63,32	57,79	57,99	54,16
35	[2-5]	119	93,17	81,74	64,74	60,02	60,19	57,45
35	[3-10]	212	82,90	65,55	58,44	50,76	52,18	48,28
40	[1-3]	82	99,97	87,67	68,30	63,80	66,89	63,12
40	[2-5]	146	110,01	89,93	67,21	63,08	67,12	61,54
40	[3-10]	256	105,36	89,12	69,59	67,23	67,46	66,10
45	[1-3]	97	101,84	82,15	64,40	62,09	62,93	57,23
45	[2-5]	159	125,54	110,75	84,91	81,87	84,72	79,05
45	[3-10]	303	110,07	91,00	71,88	65,76	64,58	62,48
50	[1-3]	97	128,12	110,81	87,27	80,82	84,16	78,94
50	[2-5]	179	118,77	110,06	86,73	82,43	77,56	76,01
50	[3-10]	329	130,79	112,96	91,73	84,07	87,86	82,54
Ortalama			72,50	62,00	48,32	45,28	45,13	42,79

Çizelge 4.18 ve Çizelge 4.19, sırasıyla amaç fonksiyonu minimum yolculuk süresi ve maliyeti için çözüm yaklaşımlarının sn bazında çözüm sürelerini göstermektedir.

Çizelge 4.18. Minimum yolculuk süresi için çözüm sürelerinin (sn) karşılaştırılması

n	m_i	$\sum m_i$	S1	S2	S3	S4	GA	MATGA
5	[2-5]	18	0,000	0,000	0,000	0,000	47,78	91,53
5	[3-10]	25	0,000	0,000	0,000	0,000	68,55	107,25
10	[1-3]	18	0,000	0,000	0,000	0,000	50,27	79,17
10	[2-5]	33	0,000	0,000	0,001	0,000	62,18	87,73
10	[3-10]	58	0,000	0,000	0,000	0,000	116,01	413,78
15	[1-3]	29	0,000	0,000	0,000	0,001	55,29	87,21
15	[2-5]	56	0,000	0,000	0,001	0,000	93,76	214,76
15	[3-10]	100	0,000	0,001	0,000	0,000	165,94	273,56
20	[1-3]	44	0,001	0,000	0,001	0,001	69,43	174,55
20	[2-5]	71	0,000	0,000	0,000	0,001	114,12	196,02
20	[3-10]	124	0,000	0,001	0,000	0,000	210,20	391,92
25	[1-3]	54	0,001	0,000	0,000	0,000	87,08	155,76
25	[2-5]	85	0,000	0,000	0,000	0,001	158,06	526,05
25	[3-10]	165	0,000	0,001	0,000	0,000	264,28	428,89
30	[1-3]	60	0,001	0,000	0,001	0,000	109,16	261,14
30	[2-5]	104	0,000	0,000	0,000	0,001	192,10	350,72
30	[3-10]	181	0,000	0,000	0,001	0,001	388,29	509,59
35	[1-3]	78	0,000	0,000	0,000	0,001	110,67	221,14
35	[2-5]	119	0,000	0,001	0,001	0,000	268,18	397,66
35	[3-10]	212	0,000	0,001	0,001	0,000	456,23	554,22
40	[1-3]	82	0,001	0,000	0,001	0,000	179,28	282,57
40	[2-5]	146	0,000	0,000	0,001	0,001	269,10	443,38
40	[3-10]	256	0,000	0,001	0,000	0,001	491,62	663,42
45	[1-3]	97	0,002	0,000	0,001	0,001	155,45	302,74
45	[2-5]	159	0,002	0,000	0,003	0,001	296,50	420,76
45	[3-10]	303	0,001	0,000	0,001	0,001	552,25	813,21
50	[1-3]	97	0,001	0,000	0,002	0,000	191,61	373,77
50	[2-5]	179	0,001	0,000	0,001	0,001	369,75	481,73
50	[3-10]	329	0,001	0,001	0,002	0,001	544,15	716,97
Ortalama			0,000	0,000	0,000	0,000	218,09	345,56

Her iki amaç fonksiyonu için sezgisel yaklaşımlar ile anında çözüm elde edilebilmesi mümkün iken GA ve MAT-GA ile çözüm elde etme süresinin problem boyutuna göre değişkenlik gösterdiği görülmektedir. Yine her iki amaç fonksiyonu için GA, çözüm süresi açısından MAT-GA'dan ortalama olarak daha hızlı sonuç elde etmektedir. Minimum yolculuk süresi için GA ortalama %36,8 ve minimum yolculuk maliyeti için ise %39,4 daha kısa sürede çözüm elde etmiştir.

Çizelge 4.19. Minimum yolculuk maliyeti için çözüm sürelerinin (sn) karşılaştırılması

n	m_i	$\sum m_i$	S1	S2	S3	S4	GA	MATGA
5	[2-5]	18	0,001	0,000	0,000	0,000	37,88	83,75
5	[3-10]	25	0,001	0,000	0,000	0,000	64,35	85,21
10	[1-3]	18	0,001	0,001	0,000	0,000	46,41	79,17
10	[2-5]	33	0,001	0,000	0,001	0,002	63,51	138,04
10	[3-10]	58	0,000	0,000	0,000	0,000	126,2	461,42
15	[1-3]	29	0,001	0,000	0,000	0,000	53,77	246,35
15	[2-5]	56	0,000	0,001	0,001	0,000	97,59	214,76
15	[3-10]	100	0,001	0,001	0,000	0,000	176,73	488,53
20	[1-3]	44	0,001	0,001	0,001	0,001	73,32	324,62
20	[2-5]	71	0,000	0,001	0,000	0,000	117,06	355,28
20	[3-10]	124	0,001	0,001	0,000	0,001	222,81	460,57
25	[1-3]	54	0,001	0,000	0,000	0,001	98,81	327,23
25	[2-5]	85	0,001	0,000	0,000	0,001	171,72	425,1
25	[3-10]	165	0,001	0,001	0,000	0,002	290,43	557,9
30	[1-3]	60	0,001	0,000	0,001	0,001	110,68	377,15
30	[2-5]	104	0,002	0,001	0,000	0,001	205,14	572,89
30	[3-10]	181	0,002	0,001	0,001	0,001	362,27	683,72
35	[1-3]	78	0,001	0,001	0,000	0,000	103,2	359,37
35	[2-5]	119	0,001	0,001	0,001	0,001	209,82	480,36
35	[3-10]	212	0,002	0,002	0,001	0,002	401,72	681,38
40	[1-3]	82	0,001	0,000	0,001	0,001	176,04	404,65
40	[2-5]	146	0,002	0,001	0,001	0,001	234,56	483,5
40	[3-10]	256	0,002	0,002	0,000	0,002	479,74	755,83
45	[1-3]	97	0,003	0,000	0,001	0,002	273,86	406,97
45	[2-5]	159	0,002	0,001	0,003	0,001	480,13	547,67
45	[3-10]	303	0,004	0,002	0,001	0,003	1346,65	893,77
50	[1-3]	97	0,001	0,001	0,002	0,001	444,11	464,78
50	[2-5]	179	0,002	0,001	0,001	0,002	930,09	597,20
50	[3-10]	329	0,003	0,001	0,002	0,003	583,12	1211,12
Ortalama			0,001	0,001	0,001	0,001	275,23	454,08

4.3.3. Başlangıç popülasyonu ve iyileştirme eşiğinin etkisi

MAT-GA'nın başlangıç popülasyonunda sezgisel yaklaşımlarla elde edilen çözümler ile ve sınırlandırılmış matematiksel model ile oluşturulan çözümler yer almaktadır. Eğer sınırlandırılmış matematiksel model, verilen sürede çözüm elde edemezse popülasyona rasgele oluşturulan çözümler eklenir. MAT-GA, belirlenen bir iterasyon sayısı boyunca (iyileştirme eşiği) amaç fonksiyon değerinde iyileşme olmaması durumunda sınırlandırılmış matematiksel model ile daha iyi bir çözüm araştırılır.

MAT-GA'nın diğer yaklaşımlardan güçlü olduğu yanları gösterebilmek adına başlangıç popülasyonun rasgele oluşturulduğu ve iyileştirme eşiğinin olmadığı bir sadeleştirilmiş MAT-GA versiyonu (SMAT-GA) ile karşılaştırma yapılmıştır. GA'dan farkı ise, iterasyonun sonunda elde edilen çözümün sınırlandırılmış matematiksel model ile çözülmesidir. Çizelge 4.20 ve 4.21'de sırasıyla amaç fonksiyonu minimum yolculuk süresi ve maliyeti olduğunda SMAT-GA ile MAT-GA'nın karşılaştırmalı sonuçları yer almaktadır.

Çizelge 4.20. Minimum yolculuk süresi için karşılaştırmalı sonuçlar

Test		SMAT-GA		MAT-GA	
n	m_i	Yolculuk süresi(dk)	Çözüm süresi (sn)	Yolculuk süresi (dk)	Çözüm süresi (sn)
5	[2-5]	185,4	47,78	185,4	91,53
5	[3-10]	297,5	68,55	289,1	107,25
10	[1-3]	562,4	50,43	566,0	79,17
10	[2-5]	741,3	62,79	738,8	87,73
10	[3-10]	602,8	116,17	591,3	413,78
15	[1-3]	875,9	56,46	879,0	87,21
15	[2-5]	1004,2	94,32	994,7	214,76
15	[3-10]	746,9	166,50	738,5	273,56
20	[1-3]	1503,4	71,43	1411,0	174,55
20	[2-5]	1225,8	115,92	1220,3	196,02
20	[3-10]	1230,3	211,96	1230,3	391,92
25	[1-3]	1807,0	88,55	1842,7	155,76
25	[2-5]	1763,2	160,72	1762,0	526,05
25	[3-10]	1531,2	265,98	1513,2	428,89
30	[1-3]	2008,6	115,04	2013,5	261,14
30	[2-5]	2001,2	195,88	2016,6	350,72
30	[3-10]	1978,7	393,31	1906,1	509,59
35	[1-3]	2684,5	121,23	2607,2	221,14
35	[2-5]	2437,4	271,98	2445,4	397,66
35	[3-10]	2183,3	460,57	2161,6	554,22
40	[1-3]	2842,4	193,69	2782,9	282,57
40	[2-5]	2773,2	280,48	2744,7	443,38
40	[3-10]	2698,4	502,82	2664,2	663,42
45	[1-3]	2765,6	164,78	2725,9	302,74
45	[2-5]	3405,3	313,12	3296,7	420,76
45	[3-10]	2576,9	561,09	2530,7	813,21
50	[1-3]	3489,1	229,20	3395,5	373,77
50	[2-5]	3089,6	385,27	3063,7	481,73
50	[3-10]	3418,5	558,62	3365,4	716,97
Ortalama		1876,9	218,09	1851,1	345,56

Çizelge 4.21. Minimum yolculuk maliyeti için karşılaştırmalı sonuçlar

Test		SMAT-GA		MAT-GA	
n	m_i	Yolculuk maliyeti (\$)	Çözüm süresi (sn)	Yolculuk maliyeti (\$)	Çözüm süresi (sn)
5	[2-5]	4,27	37,96	3,44	83,75
5	[3-10]	4,97	64,65	5,34	85,21
10	[1-3]	11,77	46,71	10,61	79,17
10	[2-5]	17,92	69,89	16,78	138,04
10	[3-10]	13,55	146,23	13,87	461,42
15	[1-3]	19,10	73,79	21,12	246,35
15	[2-5]	25,01	97,98	26,03	214,76
15	[3-10]	15,98	196,75	15,44	488,53
20	[1-3]	33,27	81,80	33,44	324,62
20	[2-5]	31,69	117,06	29,31	355,28
20	[3-10]	25,00	222,81	24,14	460,57
25	[1-3]	38,84	118,83	35,99	327,23
25	[2-5]	39,85	171,72	37,78	425,10
25	[3-10]	40,28	330,48	42,17	557,90
30	[1-3]	47,44	130,73	46,78	377,15
30	[2-5]	47,71	205,14	46,05	572,89
30	[3-10]	48,02	362,27	45,61	683,72
35	[1-3]	57,99	103,20	54,16	359,37
35	[2-5]	60,19	209,82	57,45	480,36
35	[3-10]	52,18	401,72	48,28	681,38
40	[1-3]	66,89	176,04	63,12	404,65
40	[2-5]	67,12	234,56	61,54	483,50
40	[3-10]	67,46	479,74	66,10	755,83
45	[1-3]	62,93	273,86	57,23	406,97
45	[2-5]	84,72	480,13	79,05	547,67
45	[3-10]	64,58	1346,65	62,48	893,77
50	[1-3]	84,16	444,11	78,94	464,78
50	[2-5]	77,56	930,09	76,01	597,20
50	[3-10]	87,86	583,12	82,54	1211,12
Ortalama		44,77	280,62	42,79	454,08

Çizelge 4.20 ve 4.21’de verilen sonuçlar incelendiğinde MAT-GA’nın ortalama olarak ile SMAT-GA’dan daha iyi çözüm elde ettiği görülmektedir. MAT-GA, minimum yolculuk süresi için en iyi %7, minimum yolculuk maliyet için ise %24 (n : 20, m_i : [1,3]) daha iyi sonuç bulmuştur. Şarj istasyon sayısının 25’in üzerine çıktığı test problemlerinde SMAT-GA’nın daha iyi bir sonuç elde edememektedir. MAT-GA’nın iyileştirme adımının çözüm süresi açısından negatif etkisi olduğu görülmektedir.

5. TARTIŞMA ve SONUÇ

Bu çalışma, şarj istasyonlarındaki şarj ünitelerinin fiyatlarının zaman dilimlerine bağlı değiştiği, uygunluk bilgilerinin bilindiği ve V2G uygulamalarının gerçekleştirilebildiği bir senaryoda, rotaya bağlı menzil tahminine dayalı olarak, EA'nın belirli bir yolculuğu minimum süre veya maliyetle tamamlaması için en uygun şarj planının elde edilmesi problemini ele almaktadır. EASMT ve EAŞP problemleri için ayrı ayrı çözüm yaklaşımları sunulmuştur.

EASMT için elde edilen sonuçlar, gözlem tipinin, özellikle uzun mesafeli yolculuklar için enerji tüketimi tahmininde önemli bir rol oynadığını açıklığa kavuşturmuştur. Kısa mesafeli yolculuklar için yolculuk tabanlı gözlemler ile yapılan tahminler, segment tabanlı gözlemlerle yapılan tahminlerle benzer doğruluğa sahiptir. Buradan çıkarılabilecek bir sonuç, girdi verilerinin boyutunu azaltmak için kısa mesafeli yolculuklar için yolculuk tabanlı gözlem kullanan bir VTM kullanılabilir ve daha uzun yolculuklar için, segment kullanan bir VTM ile enerji tüketimi tahmin edilebilir.

Rota tipinin önemini analiz etmek için, her yolculuğun hız profillerini kümelemek için kümeleme teknikleri uygulanmıştır ve küme etiketlerini tahmin için girdi olarak kullanılmıştır. Özniteliğe ve şekle dayalı kümeleme olmak üzere iki kümeleme tekniği uygulanmıştır. Şekle dayalı kümelemeden elde edilen etiketler, özniteliğe dayalı kümelemeden elde edilen etiketlerden biraz daha iyi performans göstermiştir. Sonuçlar, sürüş çevrimlerinin şeklinin ayırt edici faktörünün, rota tipi açısından öznitelik çıkarımından daha bilgilendirici olduğunu göstermektedir. Kümeleme için öznitelik sayısını artırmanın tahminleri iyileştireceği, üstelik bu durumda şekle dayalı kümeleme tekniğinden daha iyi performans gösterebilme ihtimali düşünülebilir. Ancak, daha fazla öznitelik eklemek, ön işlem sayısını artıracaktır. Ayrıca, daha şekle dayalı kümeleme ile daha az işlem ile daha iyi tahmin sonucu elde edilebildiği görülmektedir. Nitekim az veri ön işleme ile en iyi sonuçları elde etmek, veri-bazlı modeller için önem arz eden bir konudur.

Menzil tahmininde, yolculukların statik verileri ile yolculuk segmentlerine ait dinamik verileri birleştirmenin tahmin modelinin performansını etkilemektedir. Gerçekleştirilen deneysel çalışmaların sonuçlarına göre iki veri türünün birlikte kullanılması, rastgele karıştırılan segmentler için hata ölçümlerini azaltmıştır. Son deney, statik ve dinamik verileri farklı katmanlarda birleştiren DSA model mimarisinin tahmin modelinin performansı üzerinde herhangi bir etkisinin olup olmadığı sorunu ele aldı. Sonuçlar, en iyi model mimarisinin, statik verilerin dinamik verilerle giriş katmanında ve ikinci gizli katmanın çıkışında birleştirildiği DSA-C olduğunu göstermektedir. Tahmin doğruluğunu iyileştirme veya kötüleştirme potansiyeline sahip olduklarından, DSA model mimarisinin ve statik ve dinamik verilerin kombinasyonunun kritik olabileceği sonucuna varılmıştır. Bu çalışmada elde edilen sonuçlar aynı zamanda Miebs vd. (2020)'nin çalışmalarında elde edilen sonuçlarla örtüşmektedir.

Menzil tahmini için elde edilen sonuçlara göre rotaya bağlı menzil tahminin yapılması tahmin modelinin performansını artırmaktadır. Bu sonucu destekleyen diğer bir bulgu, yolculukların hız profillerinin kümelenmesi ile rota tipi etiketlerinin elde edildiği deney sonuçlarıdır. Yolculuk verilerinin rota tipinin bilinmediği halde, rota tipini tahmin edilmesini sağlayan kümeleme yöntemlerinin sonuçları ile yolculuklarda harcanan enerji değerinin ortalama hata değerinin azalması sağlanmıştır.

EAŞP için metasezgisel bir algoritma olan GA ile karma tamsayılı bir doğrusal programlama modelinin entegre bir şekilde kullanıldığı mat-sezgisel bir yaklaşım önerilmiştir. Mat-sezgisel yaklaşım, minimum yolculuk süresi ve maliyeti açısından dört sezgisel ve GA metasezgiseli ile karşılaştırılmıştır. Sezgisel yaklaşımlar, hızlı çözüm elde etmek adına iyi bir yaklaşım olarak değerlendirilebilir. Minimum yolculuk süresi ve maliyeti için en iyi sezgisel yaklaşım S4: Sıradaki istasyona varabilecek kadar dolum stratejisidir. Ancak minimum yolculuk süresi için bazı problemlerde S3'ün (Ulaşılabilen en uzak istasyona varabilecek kadar dolum stratejisinin), S4'ten daha iyi sonuç verdiği gözlemlenmiştir. Menzil kaygısı yüksek sürücülerin tercih edebileceği bir strateji olan S1 (Rota üzerindeki tüm istasyonlarda dolum stratejisi), hem yolculuk süresi hem de maliyet açısından tercih edilebilecek en kötü strateji olduğu sonucuna varılmıştır.

GA metasezgiseli ve mat-sezgisel yaklaşımın çözüm süreleri sezgisel yaklaşımlardan çok daha uzun sürmektedir. Ancak hem minimum yolculuk süresi ve maliyet için elde edilen optimal değerler açısından incelendiğinde mat-sezgiselin diğer yaklaşımlardan ortalama olarak belirgin bir şekilde daha iyi çözüm elde ettiği gösterilmiştir. Gelecek çalışmalarda, menzil tahminine dayalı şarj planlama için yolculuk boyunca EA sürücüsünü asiste edecek şekilde dinamik bir yaklaşım üzerinde durulacaktır. Şarj planlama modelinin çözüm verme süresinin azaltılması yönelik çalışmalar yapılacaktır. Mat-sezgiselin iyileştirme oranına göre erken durdurma özelliğinin eklenmesi, paralel mat-sezgisel gibi konular incelenecektir. Önerilen çalışmanın otonom EA'ların uzun yolculuklarda şarj planlama sistemlerinin tasarımı için bir altyapı oluşturması beklenmektedir.



KAYNAKLAR

- Abdel-Basset, M., Abdel-Fatah, L. ve Sangaiah, A. K. (2018). Metaheuristic Algorithms: A Comprehensive Review. *Computational Intelligence for Multimedia Big Data on the Cloud with Engineering Applications*, 185–231. doi:10.1016/B978-0-12-813314-9.00010-4
- Aghabozorgi, S., Seyed Shirkhorshidi, A. ve Ying Wah, T. (2015). Time-series clustering – A decade review. *Information Systems*, 53, 16–38. doi:10.1016/J.IS.2015.04.007
- Amirkhani, A., Haghanifar, A. ve Mosavi, M. R. (2019). Electric Vehicles Driving Range and Energy Consumption Investigation: A Comparative Study of Machine Learning Techniques. *5th Iranian Conference on Signal Processing and Intelligent Systems, ICSPIS 2019*, (December), 18–19. doi:10.1109/ICSPIS48872.2019.9066042
- Bac, U. ve Erdem, M. (2021). Optimization of electric vehicle recharge schedule and routing problem with time windows and partial recharge: A comparative study for an urban logistics fleet. *Sustainable Cities and Society*, 70, 102883. doi:10.1016/j.scs.2021.102883
- Barabadi, B., Tashtarian, F. ve Moghaddam, M. H. Y. (2018). An Optimal Spatial and Temporal Charging Schedule for Electric Vehicles in Smart Grid. *2018 IEEE Global Communications Conference, GLOBECOM 2018 - Proceedings*, 1–6. doi:10.1109/GLOCOM.2018.8647463
- Basso, R., Kulcsár, B., Egardt, B., Lindroth, P. ve Sanchez-Diaz, I. (2019). Energy consumption estimation integrated into the Electric Vehicle Routing Problem. *Transportation Research Part D: Transport and Environment*, 69, 141–167. doi:10.1016/j.trd.2019.01.006
- Bedogni, L., Bononi, L., D’Elia, A., Di Felice, M., Di Nicola, M. ve Cinotti, T. S. (2014). Driving without anxiety: A route planner service with range prediction for the electric vehicles. *2014 International Conference on Connected Vehicles and Expo, ICCVE 2014 - Proceedings*, 199–206. doi:10.1109/ICCVE.2014.7297541
- Bi, J., Wang, Y., Sai, Q. ve Ding, C. (2019). Estimating remaining driving range of battery electric vehicles based on real-world data: A case study of Beijing, China. *Energy*, 169, 833–843. doi:10.1016/j.energy.2018.12.061
- Bi, X. ve Tang, W. K. S. (2019). Logistical Planning for Electric Vehicles under Time-Dependent Stochastic Traffic. *IEEE Transactions on Intelligent Transportation Systems*, 20(10), 3771–3781. doi:10.1109/TITS.2018.2883791
- Bolovinou, A., Bakas, I., Amditis, A., Mastrandrea, F. ve Vinciotti, W. (2014). Online prediction of an electric vehicle remaining range based on regression analysis. *2014 IEEE International Electric Vehicle Conference, IEVC 2014*. doi:10.1109/IEVC.2014.7056167

- Bourass, A., Cherkaoui, S. ve Khoukhi, L. (2017). Intelligent route guidance for electric vehicles in the smart grid. *2017 IEEE Global Communications Conference, GLOBECOM 2017 - Proceedings, 2018-Janua(Icd)*, 1–7. doi:10.1109/GLOCOM.2017.8254525
- Çeven, S., Albayrak, A. ve Bayır, R. (2020). Real-time range estimation in electric vehicles using fuzzy logic classifier. *Computers and Electrical Engineering*, 83. doi:10.1016/j.compeleceng.2020.106577
- Chokkalingam, B., Padmanaban, S., Siano, P., Krishnamoorthy, R. ve Selvaraj, R. (2017). Real-Time Forecasting of EV Charging Station Scheduling for Smart Energy Systems. *Energies*, 10(3), 377. doi:10.3390/en10030377
- Christ, M., Braun, N., Neuffer, J. ve Kempa-Liehr, A. W. (2018). Time Series FeatuRe Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package). *Neurocomputing*, 307, 72–77. doi:10.1016/J.NEUCOM.2018.03.067
- CPLEX Optimization Studio. (2021, 3 Mayıs). What is the solution pool. *IBM-ILOG*. 3 Kasım 2022 tarihinde <https://www.ibm.com/docs/en/icos/12.9.0?topic=solutions-what-is-solution-pool> adresinden erişildi.
- CREATE Lab. (2009). ChargeCar - Recharging your Daily Commute. *Carnegie Mellon University*. 7 Aralık 2021 tarihinde <http://www.chargecar.org/data> adresinden erişildi.
- Das, H. S., Rahman, M. M., Li, S. ve Tan, C. W. (2020). Electric vehicles standards, charging infrastructure, and impact on grid integration: A technological review. *Renewable and Sustainable Energy Reviews*, 120, 109618. doi:10.1016/j.rser.2019.109618
- De Cauwer, C., Verbeke, W., Coosemans, T., Faid, S. ve Van Mierlo, J. (2017). A data-driven method for energy consumption prediction and energy-efficient routing of electric vehicles in real-world conditions. *Energies*, 10(5), 608. doi:10.3390/en10050608
- De Cauwer, C., Verbeke, W., Van Mierlo, J. ve Coosemans, T. (2020). A Model for Range Estimation and Energy-Efficient Routing of Electric Vehicles in Real-World Conditions. *IEEE Transactions on Intelligent Transportation Systems*, 21(7), 2787–2800. doi:10.1109/TITS.2019.2918019
- De Nunzio, G. ve Thibault, L. (2017). Energy-optimal driving range prediction for electric vehicles. *IEEE Intelligent Vehicles Symposium, Proceedings, (Iv)*, 1608–1613. doi:10.1109/IVS.2017.7995939
- Diab, D. M., AsSadhan, B., Binsalleeh, H., Lambbotharan, S., Kyriakopoulos, K. G. ve Ghafir, I. (2021). Denial of service detection using dynamic time warping. *International Journal of Network Management*, 31(6). doi:10.1002/NEM.2159
- Ding, D., Li, J., Tu, P., Wang, H., Cao, T. ve Zhang, F. (2020). Electric vehicle charging warning and path planning method based on spark. *IEEE Access*, 8, 8543–8553. doi:10.1109/ACCESS.2020.2964307

El-Bayeh, C. Z., Mougharbel, I., Saad, M., Chandra, A., Lefebvre, S., Asber, D. ve Lenoir, L. (2016). A detailed review on the parameters to be considered for an accurate estimation on the Plug-in Electric Vehicle's final State of Charge. *2016 3rd International Conference on Renewable Energies for Developing Countries, REDEC 2016*, (i). doi:10.1109/REDEC.2016.7577540

EPA. (2021). Dynamometer Drive Schedules | US EPA. 24 Aralık 2021 tarihinde <https://www.epa.gov/vehicle-and-fuel-emissions-testing/dynamometer-drive-schedules> adresinden erişildi.

EPIAŞ. (2022, Nisan). Piyasa Takas Fiyatı - Gün Öncesi Piyasası - Piyasalar | EPIAŞ Şeffaflık Platformu. 2 Kasım 2022 tarihinde <https://seffaflik.epias.com.tr/transparency/piyasalar/gop/ptf.xhtml> adresinden erişildi.

Eşarj. (2022). Türkiye'nin en hızlı ve en büyük eşarj istasyon ağı. 18 Ekim 2022 tarihinde <https://esarj.com/uyelik> adresinden erişildi.

Esteban, C., Staack, O., Baier, S., Yang, Y. ve Tresp, V. (2016). Predicting Clinical Events by Combining Static and Dynamic Information Using Recurrent Neural Networks. *Proceedings - 2016 IEEE International Conference on Healthcare Informatics, ICHI 2016*, 93–101. doi:10.1109/ICHI.2016.16

Ezugwu, A. E., Shukla, A. K., Nath, R., Akinyelu, A. A., Agushaka, J. O., Chiroma, H. ve Muhuri, P. K. (2021). Metaheuristics: a comprehensive overview and classification along with bibliometric analysis. *Artificial Intelligence Review 2021* 54:6, 54(6), 4237–4316. doi:10.1007/S10462-020-09952-0

Fetene, G. M., Kaplan, S., Mabit, S. L., Jensen, A. F. ve Prato, C. G. (2017). Harnessing big data for estimating the energy consumption and driving range of electric vehicles. *Transportation Research Part D: Transport and Environment*, 54, 1–11. doi:10.1016/j.trd.2017.04.013

Fiori, C., Ahn, K. ve Rakha, H. A. (2018). Optimum routing of battery electric vehicles: Insights using empirical data and microsimulation. *Transportation Research Part D: Transport and Environment*, 64(June), 262–272. doi:10.1016/j.trd.2017.08.007

Foiadelli, F., Longo, M. ve Miraftabzadeh, S. (2018). Energy Consumption Prediction of Electric Vehicles Based on Big Data Approach. *Proceedings - 2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe, IEEEIC/I and CPS Europe 2018*, 1–6. doi:10.1109/IEEEIC.2018.8494573

Fu, F. ve Dong, H. (2019). Targeted optimal-path problem for electric vehicles with connected charging stations. *PLoS ONE*, 14(8), 1–23. doi:10.1371/journal.pone.0220361

Fukushima, A., Yano, T., Imahara, S., Aisu, H., Shimokawa, Y. ve Shibata, Y. (2018). Prediction of energy consumption for new electric vehicle models by machine learning. *IET Intelligent Transport Systems*, 12(9), 1174–1180. doi:10.1049/iet-its.2018.5169

Gönül, Ö., Duman, A. C. ve Güler, Ö. (2021, 1 Haziran). Electric vehicles and charging infrastructure in Turkey: An overview. *Renewable and Sustainable Energy Reviews*. Elsevier Ltd. doi:10.1016/j.rser.2021.110913

Guo, C., Lu, M. ve Chen, J. (2020). An evaluation of time series summary statistics as features for clinical prediction tasks. *BMC Medical Informatics and Decision Making*, 20(1), 1–20. doi:10.1186/s12911-020-1063-x

Guo, J., Jiang, Y., Yu, Y. ve Liu, W. (2020). A novel energy consumption prediction model with combination of road information and driving style of BEVs. *Sustainable Energy Technologies and Assessments*, 42, 100826. doi:10.1016/j.seta.2020.100826

Hecht, C., Victor, K., Zurmühlen, S. ve Sauer, D. U. (2021). Electric vehicle route planning using real-world charging infrastructure in Germany. *eTransportation*, 10, 100143. doi:10.1016/j.etrans.2021.100143

Holland, J. A. (1975). *Adaptation in natural and artificial systems: an introductory analysis with application to biology*. University of Michigan Pres. ABD. <https://cir.nii.ac.jp/crid/1572261550376545152> adresinden erişildi.

Hu, K., Wu, J. ve Schwanen, T. (2017). Differences in energy consumption in electric vehicles: An exploratory real-world study in Beijing. *Journal of Advanced Transportation*, 2017. doi:10.1155/2017/4695975

Keskin, M. ve Çatay, B. (2016). Partial recharge strategies for the electric vehicle routing problem with time windows. *Transportation Research Part C: Emerging Technologies*, 65, 111–127. doi:10.1016/j.trc.2016.01.013

Keskin, M., Laporte, G. ve Çatay, B. (2019). Electric Vehicle Routing Problem with Time-Dependent Waiting Times at Recharging Stations. *Computers and Operations Research*, 107, 77–94. doi:10.1016/j.cor.2019.02.014

Kristensen, J. T. ve Burelli, P. (2019). Combining sequential and aggregated data for churn prediction in casual freemium games. *IEEE Conference on Computational Intelligence and Games, CIG, 2019-Augus(August 2019)*. doi:10.1109/CIG.2019.8848106

Kumar, N. ve Sharma, D. (2017). A Review on Machine Learning Algorithms, Tasks and Applications. *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, 6(10), 2278–1323. <https://www.researchgate.net/publication/320609700> adresinden erişildi.

Leaky ReLU Explained. (2022). *Papers With Code*. 22 Kasım 2022 tarihinde <https://paperswithcode.com/method/leaky-relu> adresinden erişildi.

Lee, C.-H. ve Wu, C.-H. (2015). A Novel Big Data Modeling Method for Improving Driving Range Estimation of EVs. *IEEE Access*, 3, 1980–1993. doi:10.1109/ACCESS.2015.2492923

Li, W., Stanula, P., Egede, P., Kara, S. ve Herrmann, C. (2016). Determining the Main Factors Influencing the Energy Consumption of Electric Vehicles in the Usage Phase. *Procedia CIRP*, 48, 352–357. doi:10.1016/j.procir.2016.03.014

Liu, P., Wang, C., Hu, J., Fu, T., Cheng, N., Zhang, N. ve Shen, X. (2020). Joint Route Selection and Charging Discharging Scheduling of EVs in V2G Energy Network. *IEEE Transactions on Vehicular Technology*, 69(10), 10630–10641. doi:10.1109/TVT.2020.3018114

Macqueen, J. (1967). Some methods for classification and analysis of multivariate observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability* içinde (ss. 281–297). Oakland, CA, ABD.

Miebs, G., Mochol-Grzelak, M., Karaszewski, A. ve Bachorz, R. A. (2020). Efficient Strategies of Static Features Incorporation into the Recurrent Neural Network. *Neural Processing Letters*, 51(3), 2301–2316. doi:10.1007/s11063-020-10195-x

Mies, J. J., Helmus, J. R. ve Hoed, R. (2018). Estimating the Charging Profile of Individual Charge Sessions of Electric Vehicles in The Netherlands. *World Electric Vehicle Journal* 2018, Vol. 9, Page 17, 9(2), 17. doi:10.3390/WEVJ9020017

Mishra, A. (2020). Time Series Similarity Using Dynamic Time Warping -Explained. *Walmart Global Tech Blog*. 25 Ekim 2022 tarihinde <https://medium.com/walmartglobaltech/time-series-similarity-using-dynamic-time-warping-explained-9d09119e48ec> adresinden erişildi.

Moawad, A., Gurumurthy, K. M., Verbas, O., Li, Z., Islam, E., Freyermuth, V. ve Rousseau, A. (2021). A Deep Learning Approach for Macroscopic Energy Consumption Prediction with Microscopic Quality for Electric Vehicles. *arXiv preprint arXiv:2111.12861*. <http://arxiv.org/abs/2111.12861> adresinden erişildi.

Modi, S., Bhattacharya, J. ve Basak, P. (2021). Convolutional neural network–bagged decision tree: a hybrid approach to reduce electric vehicle’s driver’s range anxiety by estimating energy consumption in real-time. *Soft Computing*, 25(3), 2399–2416. doi:10.1007/s00500-020-05310-y

Moghaddam, Z., Ahmad, I., Habibi, D. ve Phung, Q. V. (2018). Smart Charging Strategy for Electric Vehicle Charging Stations. *IEEE Transactions on Transportation Electrification*, 4(1), 76–88. doi:10.1109/TTE.2017.2753403

Müller, M. (2015). Fundamentals of Music Processing. *Fundamentals of Music Processing*. doi:10.1007/978-3-319-21945-5

Pamuła, T. ve Pamuła, W. (2020). Estimation of the Energy Consumption of Battery Electric Buses for Public Transport Networks Using Real-World Data and Deep Learning. *Energies*, 13(9), 2340. doi:10.3390/en13092340

Park, J., Chen, Z., Kiliaris, L., Kuang, M. L., Masrur, M. A., Phillips, A. M. ve Murphey,

- Y. L. (2009). Intelligent vehicle power control based on machine learning of optimal control parameters and prediction of road type and traffic congestion. *IEEE Transactions on Vehicular Technology*, 58(9), 4741–4756. doi:10.1109/TVT.2009.2027710
- Pelletier, S., Jabali, O. ve Laporte, G. (2018). Charge scheduling for electric freight vehicles. *Transportation Research Part B: Methodological*, 115, 246–269. doi:10.1016/j.trb.2018.07.010
- Pelletier, S., Jabali, O. ve Laporte, G. (2019). The electric vehicle routing problem with energy consumption uncertainty. *Transportation Research Part B: Methodological*, 126, 225–255. doi:10.1016/j.trb.2019.06.006
- Qian, L. P., Zhou, X., Yu, N. ve Wu, Y. (2020). Electric Vehicles Charging Scheduling Optimization for Total Elapsed Time Minimization. *2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring)* içinde (C. 2020, ss. 1–5). IEEE. doi:10.1109/VTC2020-Spring48590.2020.9128915
- Qian, T., Shao, C., Wang, X. ve Shahidehpour, M. (2020). Deep Reinforcement Learning for EV Charging Navigation by Coordinating Smart Grid and Intelligent Transportation System. *IEEE Transactions on Smart Grid*, 11(2), 1714–1723. doi:10.1109/TSG.2019.2942593
- Rahimi-Eichi, H. ve Chow, M.-Y. (2014). Big-data framework for electric vehicle range estimation. *IECON 2014 - 40th Annual Conference of the IEEE Industrial Electronics Society* içinde (ss. 5628–5634). IEEE. doi:10.1109/IECON.2014.7049362
- Räsänen, T. ve Kolehmainen, M. (2009). Feature-based clustering for electricity use time series data. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 5495 LNCS, 401–412. doi:10.1007/978-3-642-04921-7_41
- Rastani, S. ve Çatay, B. (2021). A large neighborhood search-based matheuristic for the load-dependent electric vehicle routing problem with time windows. *Annals of Operations Research*. doi:10.1007/S10479-021-04320-9
- Rastani, S., Yüksel, T. ve Çatay, B. (2019). Effects of ambient temperature on the route planning of electric freight vehicles. *Transportation Research Part D: Transport and Environment*, 74, 124–141. doi:10.1016/j.trd.2019.07.025
- Razo, V. ve Jacobsen, H.-A. (2016a). Smart Charging Schedules for Highway Travel With Electric Vehicles. *IEEE Transactions on Transportation Electrification*, 2(2), 160–173. doi:10.1109/TTE.2016.2560524
- Razo, V. ve Jacobsen, H. A. (2016b). Smart Charging Schedules for Highway Travel with Electric Vehicles. *IEEE Transactions on Transportation Electrification*, 2(2), 160–173. doi:10.1109/TTE.2016.2560524
- Rhode, S., Van Vaerenbergh, S. ve Pfriem, M. (2020). Power prediction for electric

vehicles using online machine learning. *Engineering Applications of Artificial Intelligence*, 87(September 2019), 103278. doi:10.1016/j.engappai.2019.103278

Ruan, T., Lei, L., Zhou, Y., Zhai, J., Zhang, L., He, P. ve Gao, J. (2019). Representation learning for clinical time series prediction tasks in electronic health records. *BMC Medical Informatics and Decision Making*, 19(Suppl 8), 1–14. doi:10.1186/s12911-019-0985-7

Sarrafan, K., Muttaqi, K. M., Sutanto, D. ve Town, G. E. (2017). An Intelligent Driver Alerting System for Real-Time Range Indicator Embedded in Electric Vehicles. *IEEE Transactions on Industry Applications*, 53(3), 1751–1760. doi:10.1109/TIA.2017.2658538

Sarrafan, K., Muttaqi, K. M., Sutanto, D. ve Town, G. E. (2018). A real-time range indicator for EVs using web-based environmental data and sensorless estimation of regenerative braking power. *IEEE Transactions on Vehicular Technology*, 67(6), 4743–4756. doi:10.1109/TVT.2018.2829728

Sarrafan, K., Sutanto, D., Muttaqi, K. M. ve Town, G. (2017). Accurate range estimation for an electric vehicle including changing environmental conditions and traction system efficiency. *IET Electrical Systems in Transportation*, 7(2), 117–124. doi:10.1049/iet-est.2015.0052

Schäfer, P., Ermschaus, A. ve Leser, U. (2021). ClaSP - Time Series Segmentation. *International Conference on Information and Knowledge Management, Proceedings*, (October), 1578–1587. doi:10.1145/3459637.3482240

Schmidhuber, J. (2015, 1 Ocak). Deep Learning in neural networks: An overview. *Neural Networks*. Elsevier Ltd. doi:10.1016/j.neunet.2014.09.003

Schoenberg, S. ve Dressler, F. (2019). Planning Ahead for EV: Total Travel Time Optimization for Electric Vehicles. *2019 IEEE Intelligent Transportation Systems Conference, ITSC 2019*, 3068–3075. doi:10.1109/ITSC.2019.8917335

Shankar, R. ve Marco, J. (2013). Method for estimating the energy consumption of electric vehicles and plug-in hybrid electric vehicles under real-world driving conditions. *IET Intelligent Transport Systems*, 7(1), 138–150. doi:10.1049/IET-ITS.2012.0114

Shao, S., Guan, W., Ran, B., He, Z. ve Bi, J. (2017). Electric Vehicle Routing Problem with Charging Time and Variable Travel Time. *Mathematical Problems in Engineering*, 2017. doi:10.1155/2017/5098183

Smuts, M., Scholtz, B. ve Wesson, J. (2017). A critical review of factors influencing the remaining driving range of electric vehicles. *2017 1st International Conference on Next Generation Computing Applications, NextComp 2017*, 196–201. doi:10.1109/NEXTCOMP.2017.8016198

Strehler, M., Merting, S. ve Schwan, C. (2017). Energy-efficient shortest routes for

electric and hybrid vehicles. *Transportation Research Part B: Methodological*, 103, 111–135. doi:10.1016/j.trb.2017.03.007

Sun, S., Zhang, J., Bi, J., Wang, Y. ve Moghaddam, M. H. Y. (2019). A Machine Learning Method for Predicting Driving Range of Battery Electric Vehicles. *Journal of Advanced Transportation*, 2019. doi:10.1155/2019/4109148

Susan, S. ve Finson, R. (2013). Intelligent Transportation Systems Joint Program Office Mobility Research Archive. *Innovative Mobility Research*. 28 Kasım 2020 tarihinde <http://innovativemobility.org/?project=intelligent-transportation-systems> adresinden erişildi.

Sweda, T. M., Dolinskaya, I. S. ve Klabjan, D. (2017). Adaptive routing and recharging policies for electric vehicles. *Transportation Science*, 51(4), 1326–1348. doi:10.1287/trsc.2016.0724

Tannahill, V. R., Muttaqi, K. M. ve Sutanto, D. (2016). Driver alerting system using range estimation of electric vehicles in real time under dynamically varying environmental conditions. *IET Electrical Systems in Transportation*, 6(2), 107–116. doi:10.1049/iet-est.2014.0067

Thibault, L., De Nunzio, G. ve Sciarretta, A. (2018). A Unified Approach for Electric Vehicles Range Maximization via Eco-Routing, Eco-Driving, and Energy Consumption Prediction. *IEEE Transactions on Intelligent Vehicles*, 3(4), 463–475. doi:10.1109/TIV.2018.2873922

Topić, J., Škugor, B. ve Deur, J. (2019). Neural network-based modeling of electric vehicle energy demand and all electric range. *Energies*, 12(7). doi:10.3390/en12071396

Tuncer, E. ve Unlu, M. Z. (2016). Accelerometer based handwritten character recognition using Dynamic Time Warping method. *2016 24th Signal Processing and Communication Application Conference (SIU)* içinde (ss. 1805–1808). Zonguldak, Türkiye: IEEE. doi:10.1109/SIU.2016.7496112

Ullah, I., Liu, K., Yamamoto, T., Al Mamlook, R. E. ve Jamal, A. (2021). A comparative performance of machine learning algorithm to predict electric vehicles energy consumption: A path towards sustainability. *Energy & Environment*, 0(0). doi:10.1177/0958305X211044998

Ullah, I., Liu, K., Yamamoto, T., Zahid, M. ve Jamal, A. (2021). Electric vehicle energy consumption prediction using stacked generalization: an ensemble learning approach. *International Journal of Green Energy*, 00(00), 1–14. doi:10.1080/15435075.2021.1881902

Un-Noor, F., Padmanaban, S., Mihet-Popa, L., Mollah, M. N. ve Hossain, E. (2017). A comprehensive study of key electric vehicle (EV) components, technologies, challenges, impacts, and future direction of development. *Energies*, 10(8). doi:10.3390/EN10081217

- Varga, B. O., Sagoian, A. ve Mariasiu, F. (2019). Prediction of electric vehicle range: A comprehensive review of current issues and challenges. *Energies*, 12(5). doi:10.3390/en12050946
- Veres, M. ve Moussa, M. (2020). Deep Learning for Intelligent Transportation Systems: A Survey of Emerging Trends. *IEEE Transactions on Intelligent Transportation Systems*, 21(8), 3152–3168. doi:10.1109/TITS.2019.2929020
- Wang, J., Besselink, I. ve Nijmeijer, H. (2018). Battery electric vehicle energy consumption prediction for a trip based on route information. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 232(11), 1528–1542. doi:10.1177/0954407017729938
- Wang, Y., Bi, J., Guan, W., Lu, C. ve Xie, D. (2021). Optimal charging strategy for intercity travels of battery electric vehicles. *Transportation Research Part D: Transport and Environment*, 96, 102870. doi:10.1016/j.trd.2021.102870
- Wang, Y., Bi, J., Guan, W. ve Zhao, X. (2018). Optimising route choices for the travelling and charging of battery electric vehicles by considering multiple objectives. *Transportation Research Part D: Transport and Environment*, 64(3), 246–261. doi:10.1016/j.trd.2017.08.022
- Wang, Y. W. ve Lin, C. C. (2009). Locating road-vehicle refueling stations. *Transportation Research Part E: Logistics and Transportation Review*, 45(5), 821–829. doi:10.1016/j.tre.2009.03.002
- Wang, Y. W., Lin, C. C. ve Lee, T. J. (2018). Electric vehicle tour planning. *Transportation Research Part D: Transport and Environment*, 63, 121–136. doi:10.1016/j.trd.2018.04.016
- Wen, L., Zhou, K. ve Yang, S. (2019). A shape-based clustering method for pattern recognition of residential electricity consumption. *Journal of Cleaner Production*, 212, 475–488. doi:10.1016/J.JCLEPRO.2018.12.067
- Xia, B., Guo, S., Wang, W., Lai, Y., Wang, H., Wang, M. ve Zheng, W. (2018). A State of Charge Estimation Method Based on Adaptive Extended Kalman-Particle Filtering for Lithium-ion Batteries. *Energies*, 11(10). doi:10.3390/en11102755
- Xia, F., Chen, H., Chen, L. ve Qin, X. (2019). A Hierarchical Navigation Strategy of EV Fast Charging Based on Dynamic Scene. *IEEE Access*, 7, 29173–29184. doi:10.1109/ACCESS.2019.2899265
- Yang, D., Sarma, N. J. S., Hyland, M. F. ve Jayakrishnan, R. (2021). Dynamic modeling and real-time management of a system of EV fast-charging stations. *Transportation Research Part C: Emerging Technologies*, 128. doi:10.1016/J.TRC.2021.103186
- Yao, E., Yang, Z., Song, Y. ve Zuo, T. (2013). Comparison of electric vehicle's energy consumption factors for different road types. *Discrete Dynamics in Nature and Society*,

2013. doi:10.1155/2013/328757

Yavasoglu, H. A., Tetik, Y. E. ve Gokce, K. (2019). Implementation of machine learning based real time range estimation method without destination knowledge for BEVs. *Energy*, 172, 1179–1186. doi:10.1016/j.energy.2019.02.032

Yi, Z. ve Shirk, M. (2018). Data-driven optimal charging decision making for connected and automated electric vehicles: A personal usage scenario. *Transportation Research Part C: Emerging Technologies*, 86, 37–58. doi:10.1016/j.trc.2017.10.014

Zhang, Chi, Fanaee, H. ve Thoresen, M. (2021). Feature extraction from unequal length heterogeneous EHR time series via dynamic time warping and tensor decomposition. *Data Mining and Knowledge Discovery*. doi:10.1007/s10618-020-00724-6

Zhang, Cong, Liu, Y., Wu, F., Tang, B. ve Fan, W. (2021). Effective Charging Planning Based on Deep Reinforcement Learning for Electric Vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 22(1), 542–554. doi:10.1109/TITS.2020.3002271

Zhang, R. ve Yao, E. (2015). Electric vehicles' energy consumption estimation with real driving condition data. *Transportation Research Part D: Transport and Environment*, 41, 177–187. doi:10.1016/j.trd.2015.10.010

Zhao, L., Yao, W., Wang, Y. ve Hu, J. (2020). Machine Learning-Based Method for Remaining Range Prediction of Electric Vehicles. *IEEE Access*, 8, 212423–212441. doi:10.1109/ACCESS.2020.3039815

Zheng, B., He, P., Zhao, L. ve Li, H. (2016). A hybrid machine learning model for range estimation of electric vehicles. *2016 IEEE Global Communications Conference, GLOBECOM 2016 - Proceedings*. doi:10.1109/GLOCOM.2016.7841506

EKLER

EK 1 Literatür Tablosu



EK 1. EA’larda Menzil Tahmini ve Şarj Planlaması-Literatür Tablosu

Makale	Menzil Tahmin Modeli	Menzil Tahmin Çıktısı	Doğrusal Olmayan Şarj Süresi	Zamana Bağlı Değişen Fiyat	Birden Fazla Şarj Noktası	V2G	Amaç	Çıktı	Yöntem
(C. Zhang vd., 2021)	Doğrusal regresyon	Harcanan enerji			X		Min. şarj süresi	Şarj çizelgesi	Derin Q-Öğrenme Algoritması
(Rastani ve Çatay 2021)	FFM	Harcanan enerji					Min. enerji tüketimi	Şarj planı (şarj yeri, zamanı ve miktarı) -Rota seçimi	Mat-sezgisel
(Hecht vd., 2021)	Polinomsal regresyon	Harcanan enerji	X				Min. yolculuk süresi	Şarj planı (şarj yeri ve miktarı)	Matematiksel Programlama (iki aşamalı)
(Ding vd., 2020)	Doğrusal regresyon	Harcanan enerji					Min. yolculuk süresi	Şarj planı (şarj yeri ve miktarı)	Dijkstra Algoritması
(Basso vd., 2019)	Doğrusal regresyon	Harcanan enerji					Min. enerji tüketimi	-Şarj planı (şarj yeri, zamanı ve miktarı) -Rota seçimi	Matematiksel Programlama
(X. Bi ve Tang 2019)	Doğrusal olmayan regresyon	Menzil	X				Min. yolculuk süresi	-Şarj planı (şarj yeri, zamanı ve miktarı) -Rota seçimi	-Stokastik dinamik programlama -Sezgisel Algoritmalar

EK 1. EA’larda Menzil Tahmini ve Şarj Planlaması-Literatür Tablosu (Devamı)

Makale	Menzil Tahmin Modeli	Menzil Tahmin Çıktısı	Doğrusal Olmayan Şarj Süresi	Zamana Bağlı Değişen Fiyat	Birden Fazla Şarj Noktası	V2G	Amaç	Çıktı	Yöntem
(Fu ve Dong 2019)	FFM	Harcanan enerji	X		X		Min. yolculuk süresi	-Şarj planı (şarj yeri ve süresi) -Rota seçimi	Handler-Zang Algoritması + Dijkstra
(Schoenberg ve Dressler 2019)	FFM	Harcanan enerji	X				Min. yolculuk süresi	Şarj planı (şarj yeri ve miktarı) -Sürtüş hızı -Rota seçimi	Dijkstra + A* Algoritması
(Yi ve Shirik 2018)	FFM	Harcanan enerji					Min. enerji tüketimi	Şarj planı (şarj yeri ve miktarı)	Dinamik Programlama
(Chokkalingam vd., 2017)	FFM	SOC			X		Min. enerji tüketimi	Şarj yeri	Atama algoritması
(Bourass vd., 2017b)	FFM	Harcanan enerji			X		Min. bekleme süresi, enerji tüketimi	-Şarj planı (şarj yeri ve miktarı) -Rota seçimi	Matematiksel Programlama, k-En Kısa Yol
(Bourass vd., 2017a)	FFM	Harcanan enerji			X		Min. bekleme süresi, enerji tüketimi	-Şarj planı (şarj yeri ve miktarı) -Rota seçimi	Sezgisel Algoritma

EK 1. EA’larda Menzil Tahmini ve Şarj Planlaması-Literatür Tablosu (Devamı)

Makale	Menzil Tahmin Modeli	Menzil Tahmin Çıktısı	Doğrusal Olmayan Şarj Süresi	Zamana Bağlı Değişen Fiyat	Birden Fazla Şarj Noktası	V2G	Amaç	Çıktı	Yöntem
(Sarrafan, Muttiaqi vd., 2017)	FFM	Harcanan enerji					Min. şarj sayısı	-Şarj planı (şarj yeri ve miktarı)	Sezgisel Algoritma
(Tannahill vd., 2016)	FFM	SOC					Min. şarj sayısı	-Şarj planı (şarj yeri ve miktarı)	Sezgisel Algoritma
(Bedogni vd., 2014)	FFM	Harcanan enerji					Min. enerji tüketimi	Şarj yeri rota seçimi	Dijkstra Algoritması
Önerilen Çalışma	Derin Sinirsel Ağ	Harcanan enerji	X	X	X	X	Min. yolculuk süresi ve maliyeti	-Şarj planı (şarj yeri, zamanı ve miktarı)	Mat-sezgisel