

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

**ELEKTRİKLİ ARAÇLARIN KULLANIMINA YÖNELİK YÜK
TAHMİNİ VE KARAR DESTEK SİSTEMİ**

YÜKSEK LİSANS TEZİ

Hatice Menekşe KÖSEMEN

Endüstri Mühendisliği Anabilim Dalı

TEMMUZ 2024

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

**ELEKTRİKLİ ARAÇLARIN KULLANIMINA YÖNELİK YÜK
TAHMİNİ VE KARAR DESTEK SİSTEMİ**

YÜKSEK LİSANS TEZİ

Hatice Menekşe KÖSEMEN

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Orhan TORKUL

TEMMUZ 2024

Hatice Menekşe KÖSEMEN tarafından hazırlanan “ELEKTRİKLİ ARAÇLARIN KULLANIMINA YÖNELİK YÜK TAHMİNİ VE KARAR DESTEK SİSTEMİ” adlı tez çalışması 25.07.2024 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı : **Prof. Dr. Orhan TORKUL** (Danışman)
Sakarya Üniversitesi

Jüri Üyesi : **Prof. Dr. Semra BORAN**
Sakarya Üniversitesi

Jüri Üyesi : **Prof. Dr. Metin VARAN**
Sakarya Uygulamalı Bilimler Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “ELEKTRİKLİ ARAÇLARIN KULLANIMINA YÖNELİK YÜK TAHMİNİ VE KARAR DESTEK SİSTEMİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(25/07/2024).

Hatice Menekşe KÖSEMEN





Bir babanın kızına öğüdü “ahlâk+matematik=başarı”dır.



TEŞEKKÜR

Teşekkürün az kalacağı beni saygı, sevgi ve ahlâk çerçevesinde yetiştirerek bugünlere getiren ve benden hiçbir zaman desteğini esirgemeyen, bu hayattaki en büyük şansım olan sevgili aile üyelerim; babacığım İlhami Selâmi KÖSEMEN, anneciğim Sema KÖSEMEN ve canım ablam Kardelen Hediye GÜRBÜZ'e en içten duygularla sevgilerimi sunuyorum.

Akademik hayatın bana kattığı ve muhakkak ki benim ve gelecek nesillerin bilimde muvaffak olabilmesi adına kendisinden öğreneceğimiz çok fazla konu olan, hilm ve rıfk nimetlerinden nasibi verilen, bu çalışmanın gerçekleştirilmesinde değerli bilgilerini benimle paylaşan, kıymetli zamanını ayırıp sabırla ve büyük bir ilgiyle bana fayda sağlayan danışman hocam çok kıymetli, saygıdeğer Prof. Dr. Orhan TORKUL'a şükranlarımı sunuyorum. Çalışmanın konu, kaynak ve yöntem açısından geliştirilmesinde bana yol gösteren ve bu süreçte benden desteğini esirgemeyen kıymetli, saygıdeğer Arş. Gör. Merve ŞİŞCİ'ye sonsuz teşekkürlerimi sunuyorum.

Çalışmanın yazılımsal süreçlerine çok ciddi katkısı olan, bu süreçte beni anlatmadan dâhi anlayan ve karşılıksız bir şekilde değerli zamanını ayırıp çalışmaya hız, bana değer katan çok kıymetli, saygıdeğer Mehmet Emin GÜLŞEN'e desteği için minnettarım. Yüksek lisans eğitimim boyunca keyifle çalışma arkadaşlığı yaptığım ve bu süreçte de bana karşılıksız desteğini sunan kıymetli arkadaşım saygıdeğer Berkay SEVİNDİK'e teşekkürü borç bilirim. Son olarak yüksek lisans eğitimimin en başından en sonuna kadar karşılıksız destekleri olan kıymetli dostlarım Cengizhan ÜNSAL, Melda BAHAR TERCAN, Gamze BÖCEK, Bilal TORKUL ve tüm sevdiklerime teker teker sevgimi ve teşekkürlerimi sunuyorum. İyi ki hayatımdasınız...

Hatice Menekşe KÖSEMEN



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SİMGELER	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxv
1. GİRİŞ	1
1.1. Tezin Kapsamı	3
1.2. Tezin Amacı	3
1.3. Tezin Organizasyonu	4
2. LİTERATÜR ARAŞTIRMASI	5
2.1. Türkiye’de Elektrik Enerjisi Sektörü ve Piyasasının İşleyişi	5
2.2. Türkiye’de Elektrik Enerjisi Piyasası Talep Tarafı Yönetimi ve Yük Tahmin Algoritmaları	7
3. KARAR DESTEK SİSTEMİ	17
3.1. Elektrikli Araç Şarj Yüğü (Güç) Talebinin Dağıtım Şebekelerindeki Etki Analizine Dair Kavramsal Çerçeve	17
3.1.1. Bağımsız Değişkenler	20
3.1.2. Bağımlı Değişkenler	21
3.1.3. Karıştırıcı Değişkenler	21
3.1.4. Yönlendirici Değişkenler	23
3.1.5. Aracı Değişkenler	24
3.1.6. Kontrol Değişkenleri	25
3.2. Kavramsal Karar Destek Sistemi	26
3.2.1. Gerçek Zamanlı İzleme ve Analiz	27
3.2.2. Yük Tahmin Modelleri	28
3.2.3. Talep Yanıt Stratejileri	28
3.2.4. Altyapı Planlama ve Optimizasyonu	29
3.2.5. Kullanıcı Davranışı İlgörüleri	30
3.2.6. Mevzuata Uygunluk ve Raporlama	30
3.2.7. İşbirliği Platformları	31
4. ELEKTRİKLİ ARAÇLARIN ŞARJ YÜĞÜ TAHMİNİ	35
4.1. Evrişimsel Sinir Ağları (CNN)	35
4.2. Uzun Kısa Süreli Bellek (LSTM)	36
4.3. Geçitli Tekrarlayan Birim (GRU)	38
4.4. Çift Yönlü Uzun Kısa Süreli Bellek (BiLSTM)	39
4.5. Çift Yönlü Geçitli Tekrarlayan Birim (BiGRU)	39
4.6. Hafif Gradyan Artırma Makinesi (LightGBM)	40

4.7. Yığılma Topluluk Öğrenme	40
5. METODOLOJİ VE UYGULAMA.....	41
5.1. Verilerin Elde Edilmesi	43
5.2. Verilerin Analiz Edilmesi.....	43
5.3. Veri Hazırlama ve Ön İşleme	47
5.4. Derin Öğrenme Modellerinin Geliştirilmesi	50
5.5. Modellerin Değerlendirilmesi	58
6. DENEYSEL SONUÇLAR.....	61
7. SONUÇ VE ÖNERİLER.....	79
KAYNAKLAR.....	85
ÖZGEÇMİŞ.....	103



KISALTMALAR

ABD	: Amerika Birleşik Devletleri
ACN-DATA	: Adaptive Charging Network (Uyarlanabilir Şarj Ağı)
ANN	: Artificial Neural Network (YSA(Yapay Sinir Ağı))
APS	: Announced Pledges Scenario (Duyurulan Taahhütler Senaryosu)
ARIMA	: Autoregressive Integrated Moving Average (Otoregresif Entegre Hareketli Ortalama)
BiLSTM	: Bidirectional Long Short Term Memory (Çift Yönlü Uzun Kısa Süreli Bellek)
BiGRU	: Bidirectional Gated Recurrent Unit (Çift Yönlü Geçitli Tekrarlayan Birim)
CNN	: Convolutional Neural Network (Evrişimsel Sinir Ağı)
CPO	: Charge Point Operator (Şarj Noktası Operatörü)
DEK	: Dağıtık Enerji Kaynakları (DER(Distributed Energy Resources))
DKDE	: Diffusion-Based Kernel Density Estimator (Difüzyon Tabanlı Çekirdek Yoğunluğu Tahmincisi)
DR	: Demand Response (Talep Yanıtı)
DS	: Dempster–Shafer (Kanıt Teorisi)
DYS	: Dağıtım Yönetim Sistemi (DMS(Distributed Management System))
EA	: Elektrikli Araç (EV(Electric Vehicle))
EDDS	: Enerjide Dijital Dönüşüm Sözlüğü
EE	: Energy Efficiency (Enerji Verimliliği)
EMSP	: Electric Mobility Service Provider (Elektrikli Mobilite Hizmeti Sağlayıcısı)
EPDK	: Enerji Piyasası Düzenleme Kurumu
EPIAŞ	: Enerji Piyasaları İşletme Anonim Şirketi
EPK	: Elektrik Piyasası Kanunu
EPTTY	: Elektrik Piyasası Talep Tahminleri Yönetmeliği
EVCSs	: Electric Vehicle Charging Stations (Elektrikli Araç Şarj İstasyonları)
EVSE	: Electric Vehicle Supply Equipment (Elektrikli Araç Tedarik Ekipmanı)

GRU	: Gated Recurrent Unit (Geçitli Tekrarlayan Birim)
KDS	: Karar Destek Sistemi (DSS(Decision Support System))
LightGBM	: Light Gradient Boosting Machine (Hafif Gradyan Artırma Makinesi)
LSTM	: Long Short Term Memory (Uzun Kısa Süreli Bellek)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MLP	: Multi-Layer Perceptrons (Çok Katmanlı Algılayıcı)
MSE	: Mean Square Error (Ortalama Karesel Hata)
MTL	: Multi-Task Learning (Çok Görevli Öğrenme)
NRMSE	: Normalized Root Mean Square Error (Normalleştirilmiş Karekök Ortalama Karesel Hata)
NZE	: Net Zero Emissions (Net Sıfır Emisyon)
OEM	: Original Equipment Manufacturer (Orijinal Ekipman Üreticisi)
OSB	: Organize Sanayi Bölgeleri
RF	: Random Forest (Rastgele Orman)
RMSE	: Root Mean Square Error (Karekök Ortalama Karesel Hata)
R²	: R-Squared (Determinasyon Katsayısı)
SEDAŞ	: Sakarya Elektrik Dağıtım Anonim Şirketi
SEPAŞ	: Sakarya Elektrik Parakende Satış Anonim Şirketi
SMAPE	: Symmetric Mean Absolute Percentage Error (Simetrik Ortalama Mutlak Yüzde Hatası)
SOC	: State of Charge (Şarj Durumu)
STEPS	: Stated Policies Scenario (Belirtilen Politikalar Senaryosu)
SVR	: Support Vector Regression (Destek Vektör Regresyonu)
TCO	: Total Cost of Ownership (Toplam Sahip Olma Maliyeti)
TEDAŞ	: Türkiye Elektrik Dağıtım Anonim Şirketi
TEİAŞ	: Türkiye Elektrik İletim Anonim Şirketi
ToD	: Time of Day (Günün Saati)
ToU	: Time of Use (Kullanım Zamanı)
V2B	: Vehicle to Build (Araçtan Binaya Enerji Aktarımı)
V2G	: Vehicle to Grid (Araçtan Şebekeye Enerji Aktarımı)
V2H	: Vehicle to Home (Araçtan Eve Enerji Aktarımı)
V2L	: Vehicle to Load (Araçtan Yüke Enerji Aktarımı)
YDÖTM	: Yığılmış Derin Öğrenme Topluluk Modeli (Stacked Deep Learning Ensemble Model)
XGBoost	: Extreme Gradient Boosting (Aşırı Gradyan Artırma)

SİMGELER

b_c	: LSTM blok mimarisinde hücre durumundaki sapma (bias)
b_f	: LSTM blok mimarisinde unut kapısındaki sapma (bias)
b_i	: LSTM blok mimarisinde giriş kapısındaki sapma (bias)
b_o	: LSTM blok mimarisinde çıkış kapısındaki sapma (bias)
c_t	: LSTM blok mimarisindeki t zamanındaki durum vektörü
c_{t-1}	: LSTM blok mimarisindeki t-1 zamanındaki durum vektörü
$\tilde{c}_t$	: LSTM blok mimarisindeki t zamanındaki geçici durum vektörü
f_t	: LSTM blok mimarisindeki unut kapısı vektörü
h_t	: LSTM ve GRU blok mimarilerinde t zamanındaki çıktı
$h_{(t-1)}$	: LSTM ve GRU blok mimarilerinde t-1 zamanındaki önceki gizli durum vektörü
i_t	: LSTM blok mimarisindeki giriş kapısı vektörü
kWh	: kilowatt hour (kilowatt saat (enerji birimi))
o_t	: LSTM blok mimarisindeki çıkış kapısı vektörü
r_t	: GRU blok mimarisindeki sıfırla kapısı vektörü
$\tanh$	: Hiperbolik tanjant aktivasyon fonksiyonu
z_t	: GRU blok mimarisindeki güncelle kapısı vektörü
W_{hc}	: h_{t-1} 'e bağlı hücre durumundaki b_c 'ye karşılık gelen ağırlık kümesi
W_{hf}	: h_{t-1} 'e bağlı unut kapısındaki b_f 'ye karşılık gelen ağırlık kümesi
W_{hi}	: h_{t-1} 'e bağlı giriş kapısındaki b_i 'ye karşılık gelen ağırlık kümesi
W_{ho}	: h_{t-1} 'e bağlı çıkış kapısındaki b_o 'ya karşılık gelen ağırlık kümesi
W_{xc}	: x_t 'ye bağlı hücre durumundaki b_c 'ye karşılık gelen ağırlık kümesi
W_{xf}	: x_t 'ye bağlı unut kapısındaki b_f 'ye karşılık gelen ağırlık kümesi
W_{xi}	: x_t 'ye bağlı giriş kapısındaki b_i 'ye karşılık gelen ağırlık kümesi
W_{xo}	: x_t 'ye bağlı çıkış kapısındaki b_o 'ya karşılık gelen ağırlık kümesi
x_i	: Normalize edilecek değer
x_t	: LSTM ve GRU blok mimarilerindeki giriş vektörü
x_{min}	: Nitelikteki minimum değer
x_{maks}	: Nitelikteki maksimum değer
$x_{yeni(t)}$	: Normalizasyon işleminden sonra elde edilen değer

- σ : Sigmoid aktivasyon fonksiyonu
- $\otimes$: LSTM ve GRU blok mimarilerindeki eleman bazında çarpma



TABLO LİSTESİ

Sayfa

Tablo 6.1. Geliştirilen modeller ve MAE, RMSE, NRMSE, R^2 performans ölçütü değerleri.....	62
---	----





ŞEKİL LİSTESİ

Sayfa

Şekil 3.1. Elektrikli araç şarj yükü talebinin dağıtım şebekelerindeki etki analizine dair kavramsal çerçeve.	19
Şekil 3.2. Elektrikli araç kullanıcıları ve kamu hizmeti sağlayıcıları bakış açısıyla Karar Destek Sistemi.....	34
Şekil 4.1. Yük tahmini için CNN ağ mimarisi.....	36
Şekil 4.2. LSTM blok mimarisi.	37
Şekil 4.3. GRU blok mimarisi.	39
Şekil 5.1. Önerilen çalışma metodolojisi.	42
Şekil 5.2. Şarj bağlantı zamanına göre şarj yükü talep dağılımı.....	45
Şekil 5.3. Şarj bağlantı bitiş zamanına göre şarj yükü talep dağılımı.....	45
Şekil 5.4. Şarj bağlantı zamanına göre günlük şarj yükü talep dağılımı.	46
Şekil 5.5. Şarj bağlantı bitiş zamanına göre günlük şarj yükü talep dağılımı.....	47
Şekil 5.6. Enerji tüketim miktarı niteliğinin kutu grafikleri (a) Aykırı verilerden temizlenmeden önce, (b) Aykırı verilerden temizlendikten sonra.	49
Şekil 5.7. Geliştirilen CNN modeli mimarisi.	53
Şekil 5.8. Geliştirilen LSTM modeli mimarisi.	54
Şekil 5.9. Geliştirilen GRU modeli mimarisi.....	55
Şekil 5.10. Geliştirilen BiLSTM modeli mimarisi.	56
Şekil 5.11. Geliştirilen BiGRU modeli mimarisi.....	57
Şekil 5.12. Önerilen Yığılmış Derin Öğrenme Topluluk Modeli'nin mimarisi.	58
Şekil 6.1. MAE, RMSE, NRMSE, R ² performans ölçütlerinin model bazlı dağılımı. ..	...
Şekil 6.2. Geliştirilen modellerin MAE, RMSE, NRMSE, R ² performans ölçütü hata değerlerinin dağılımı.	64
Şekil 6.3. EA şarj yükü talebinin gerçek ve CNN modelinin tahmin ettiği değerlerin karşılaştırılması.	66
Şekil 6.4. EA şarj yükü talebinin gerçek ve CNN modelinin tahmin ettiği değerlerin 100:200 zaman aralığı karşılaştırılması.	67
Şekil 6.5. EA şarj yükü talebinin gerçek ve LSTM modelinin tahmin ettiği değerlerin karşılaştırılması.	68
Şekil 6.6. EA şarj yükü talebinin gerçek ve LSTM modelinin tahmin ettiği değerlerin 100:200 zaman aralığı karşılaştırılması.	69
Şekil 6.7. EA şarj yükü talebinin gerçek ve GRU modelinin tahmin ettiği değerlerin karşılaştırılması.	70
Şekil 6.8. EA şarj yükü talebinin gerçek ve GRU modelinin tahmin ettiği değerlerin 100:200 zaman aralığı karşılaştırılması.	71
Şekil 6.9. EA şarj yükü talebinin gerçek ve BiLSTM modelinin tahmin ettiği değerlerin karşılaştırılması.	72
Şekil 6.10. EA şarj yükü talebinin gerçek ve BiLSTM modelinin tahmin ettiği değerlerin 100:200 zaman aralığı karşılaştırılması.	73

Şekil 6.11. EA şarj yükü talebinin gerçek ve BiGRU modelinin tahmin ettiği değerlerin karşılaştırılması.	74
Şekil 6.12. EA şarj yükü talebinin gerçek ve BiGRU modelinin tahmin ettiği değerlerin 100:200 zaman aralığı karşılaştırılması.....	75
Şekil 6.13. EA şarj yükü talebinin gerçek ve önerilen YDÖTM'nin tahmin ettiği değerlerin karşılaştırılması.	76
Şekil 6.14. EA şarj yükü talebinin gerçek ve önerilen YDÖTM'nin tahmin ettiği değerlerin 100:200 zaman aralığı karşılaştırılması.	77
Şekil 7.1. Model Denemeleri ve Sonuçları.	81
Şekil 7.2. (a) GRU modelinin kayıp grafiği, (b) GRU modelinin metrik grafiği.	83



ELEKTRİKLİ ARAÇLARIN KULLANIMINA YÖNELİK YÜK TAHMİNİ VE KARAR DESTEK SİSTEMİ

ÖZET

Dünya’da teknolojik yenilikler ile eşgüdümlü küresel ölçekteki üretim ve tüketim anlayışı çerçevesinde birçok sektörü etkileyen devinim süreci yaşanmaktadır. Toplumsal düzeni temelden etkileyen bu durum ve beraberinde artan çevre bilinci, enerji sektörünün de farklı dinamiklerle yapılandırılması ihtiyacını ortaya çıkarmıştır. Enerji sektörü ve piyasasının dinamik altyapılarında operasyonel ve yönetsel birçok süreç yürütülmektedir. Enerjinin arz-talep dengesini koruma hedefiyle yürütülen bu süreçlerde ise tüketiciler, dağıtım şirketleri ve diğer piyasa paydaşları doğrudan veya dolaylı olarak etkileşim içerisindeyler.

Günümüzde küresel enerji sektörünün değişimi ve gelişimi için oluşturulan stratejik hedeflere bağlı olarak hükümetlerin, tüketiciler (müşteriler/kullanıcılar) ve piyasa paydaşları doğrultusunda belirli taahhütleri bulunmaktadır. Bu taahhütler arasında, güç sistemlerinin şebeke altyapılarına dijital dönüşüm destekli akıllı şebeke çözümlerinin üretilmesi ve net sıfır CO₂ emisyon hedefine ulaşılması yer almaktadır. Elektrikli araçlar (EA), farklı ölçeklerdeki dağıtık üretim kaynakları ve enerji depolama sistemlerinin orta/alçak gerilim şebekelerine entegrasyonu ile akıllı gömülü sistemler tesis edilmesi bu hedeflere ulaşmada kritik önem arz etmektedir.

Akıllı şebeke altyapısı ile bilgi, haberleşme, izleme, kontrol ve yönetim sistemlerinde otomasyon ve dijitalleşme artırılarak, karar vericiler için doğru ve güvenilir yönlendirme mekanizmalarının oluşması sağlanacaktır. Enerji sektöründe faaliyet gösteren şirketlerin ihtiyaç analizlerine uygun stratejiler geliştirmesi amacıyla oluşturulan bu sistematik ve teknolojik altyapılar ile karar vericilere geniş ve farklı bakış açıları sunulabilir. Şebekelerin yönetimindeki tahminleme, planlama, kontrol ve izlenebilirliğin gerçek zamanlı işletimi ile yaşanabilecek krizler anlık olarak fırsata dönüştürülerek karar verme sistemlerinin desteği artırılabilir. Böylelikle ilgililerin karar verme sürecine yardımcı karar destek sistemleri ile analiz, değerlendirme, yönlendirme, etkileşim, dengeleme ve uzlaştırma ortamı sağlanarak zamandan ve kaynaklardan tasarruf elde edilebilir.

Bu tez çalışmasında enerji sektöründeki genel yaklaşıma göre enerjinin üretimi ve tüketiminden etkilenen unsurları EA şarj yükü tahmini bazında ele alan ve puant yükün dağıtım şebekesine etkisini en aza indirmek için uygulanacak stratejilerin ve buna bağlı belirlenen değişken faktörlerin kavramsal çerçevesi oluşturulmuştur. EA kullanımının dağıtım şebekesine etkisi neden-sonuç ilişkisi kapsamında ele alınan bu kavramsal çerçevede; bağımlı ve bağımsız değişkenler ile bunlara etki eden karıştırıcı, yönlendirici, aracı, kontrol olmak üzere altı farklı değişken kategorisi yer almaktadır. EA kullanıcılarının şarj istasyonlarını yoğun kullanımı durumunda hem kullanıcı hem de yerel dağıtık üretim kaynakları açısından bir çok unsur göz önüne alınmalı ve takibi yapılmalıdır. Çalışmanın devamında, oluşturulan kavramsal çerçevede belirlenen faktörler dikkate alınarak elektrikli araç kullanıcıları ve kamu hizmeti sağlayıcıları

bakış açısıyla organizasyonların operasyonel ve yönetsel karar alma sürecini etkileyen unsurların yer aldığı bir kavramsal Karar Destek Sistemi geliştirilmiştir.

Tüketicilerin yoğun elektrik tüketim taleplerinin karşılanabilmesi adına çeşitli yenilenebilir enerji kaynaklarından enerji dönüşümleri sağlanmaktadır. Elektrikli araç kullanımının artışı ile oluşan yeni enerji talebinin gelişimi; tüketici rolündeki elektrikli araç kullanıcılarının davranışları ve üretimi besleyen yenilenebilir enerji kaynaklarında bir takım değişim ve dönüşümler yaşanmasına neden olmaktadır. Bu nedenle elektrikli araçların yoğun kullanımı ile dağıtım şebekesi üzerinde oluşacak yeni talebin ve tüketim profilinin iyi anlaşılması önemlidir. Elektrik şebekesinde oluşacak yük talebinin artışı ve bu talebin en yoğun olduğu zaman dilimindeki aşırı yüklenme sorunu ile baş edebilmek için farklı çözüm stratejileri üretilmesi gerekmektedir. Elektrik enerjisi tüketimi ile oluşan günlük enerji talebinin yönetimi ve bir sonraki gün için yapılan saatlik talep miktarını belirleyen yük tahmin planları enerji sektörü için belirleyici ve yol gösterici unsurlardır. EA'ların enerji tüketim verilerinin elde edildiği dağıtık üretimin (ya da dağıtılmış enerjinin) bir bileşeni olan elektrikli araç şarj istasyonlarının yaygınlaşması ile enerji talep tahminlerinin bölgesel odaklılık yerine gelişmiş şebeke analizlerini de içerecek şekilde daha detaylı yapılması gerekmektedir. Enerji sektöründeki talep tarafı yönetimi ve yük yönetimine bağlı yük tahmin planlarını etkin bir şekilde yapabilmek için enerji talebinin tahmin doğruluğu ciddi önem arz etmektedir.

Çalışma konusu ve kapsamında; dağıtım şebekesi üzerinde oluşacak yeni enerji talebi ve dönemsel puant güç (veya puant yük) talebinin analizi ile kısa dönemli yük tahmini için uygulanacak yük tahmin algoritmaları ele alınmıştır. Çalışmada geçmiş verilerden faydalanılarak gelecekteki yeni talebi oluşturan EA enerji tüketimi veya EA şarj yükünün tahmini için; gerçeğe en yakın, tutarlı ve efektif sonuçlar elde edilmesi hedeflenmektedir.

Çalışmada kullanılan tahmin yöntemleri literatürde zaman serisi tahmini olarak ele alınmakta olup tahmin algoritmalarını geliştirme sürecinde ise derin öğrenme modellerinden faydalanılmıştır. Bu amaçla çalışmada elektrikli araçların kısa dönemli şarj yükü tahmin doğruluğunun artırılması için Yığılmış Derin Öğrenme Topluluk Modeli (YDÖTM) önerilmiştir. Önerilen modelde CNN, LSTM, GRU, BiLSTM ve BiGRU modelleri temel öğrenici olarak ele alınırken meta öğrenici olarak LightGBM algoritması kullanılmıştır. Önerilen modelin uygulaması için ABD'nin Kaliforniya eyaletindeki Pasadena kentinde yer alan bir araştırma üniversitesinin, Caltech kampüsü garajında bulunan, 54 adet halka açık şarj istasyonlarından toplanan, gerçek zamanlı şarj oturum olaylarından yararlanılmıştır. Bu gerçek zamanlı şarj oturum olaylarına ait veriler; EA şarj bağlantı zamanı, EA şarj bağlantı bitiş zamanı ve enerji tüketim niteliklerini içermekte olup ACN-DATA adlı açık veri platformundan elde edilmiştir.

Geliştirilen Yığılmış Derin Öğrenme Topluluk Modeli'nin etkinliği MAE, RMSE, NRMSE ve R^2 performans ölçütleri kullanılarak, derin öğrenmeye dayalı tekli modellerin performansları ile karşılaştırılıp değerlendirilmiştir. Değerlendirme sonucu önerilen modelin MAE, RMSE, NRMSE ve R^2 performans ölçüt değerleri sırasıyla 3.5894, 4.9935, 0.0551 ve 0.9444 olarak elde edilmiş olup karşılaştırılan tekli modellere kıyasla en iyi performansı verdiği görülmüştür.

Dağıtım şebekelerinin EA şarj alyapısındaki kapasite planlamalarında elektrikli araç talebini yönetebilmek ve şarj kontrolünü optimize edebilmek için talep belirsizliği, enerji belirsizliği, EA mobilitesi, ağ belirsizliği, fiyat belirsizliği gibi sorunlar ele

alınmalıdır. Bilgi ve haberleşme teknolojilerinin güç sistemine entegrasyonu ile bu belirsizlikleri yönetebilmek adına enerjinin öngörü bazlı dinamik süreçlerindeki faaliyetlerde yapay zeka uygulamaları ile optimallik, iyileştirme ve sürdürülebilirlik sağlanmalıdır.

Çalışmada özetle; EA şarj yükü talebinin dağıtım şebekelerindeki etki analizine dair bir kavramsal çerçeve, bir kavramsal Karar Destek Sistemi ve EA'ların şarj yükü tahmini için bir metodoloji oluşturulmuş olup dâhilinde derin öğrenme algoritmalarına dayalı yük tahmin modelleri geliştirilmiştir. Bu bağlamda bilgi ve haberleşme teknolojilerinden faydalanılarak elde edilen ve anlamlandırılan verilere dayalı akıllı şarj kontrol ve karar verme mekanizmalarının inşa edilmesi desteklenerek güç sisteminin esnekliğini artırmak amaçlanmaktadır. Bu çalışmanın diğer akıllı şebeke teknolojilerini geliştirme çalışmalarına da yol gösterici nitelikte olacağı düşünülmektedir.





LOAD FORECASTING AND DECISION SUPPORT SYSTEM FOR ELECTRIC VEHICLES USE

SUMMARY

There is a dynamic process affecting many sectors in the world within the framework of global production and consumption understanding coordinated with technological innovations. This situation, which fundamentally affects the social order and the increasing environmental awareness, has revealed the need for the energy sector to be structured with different dynamisms. Many operational and administrative processes are carried out in the dynamic infrastructures of the energy sector and market. In these processes carried out with the aim of maintaining the supply-demand balance of energy, consumers, distribution companies and other market stakeholders interact directly or indirectly.

Today, depending on the strategic goals established for the change and development of the global energy sector, governments have certain commitments towards consumers (customers/users) and market stakeholders. These commitments include the production of digital transformation-supported smart grid solutions for the grid infrastructures of power systems and the achievement of net zero CO₂ emission targets. The integration of electric vehicles (EV), distributed generation resources of different scales and energy storage systems into medium/low voltage networks and the establishment of smart embedded systems are of critical importance in achieving these goals.

With the smart grid infrastructure, automation and digitalization in information, communication, monitoring, control and management systems will be increased, and accurate and reliable guidance mechanisms will be created for decision makers. With these systematic and technological infrastructures created for companies operating in the energy sector to develop strategies suitable for their needs analysis, decision makers can be provided with broad and different perspectives. With the real-time operation of forecasting, planning, control and traceability in the management of networks, crises that may be experienced can be instantly turned into opportunities and the support of decision-making systems can be increased. Thus, time and resources can be saved by providing an analysis, evaluation, guidance, interaction, balancing and reconciliation environment with decision support systems that assist the decision-making process of the relevant parties.

In this thesis study, the conceptual framework of the strategies to be applied to minimize the impact of peak load on the distribution network and the variable factors determined accordingly, which are considered based on the general approach in the energy sector, is created. In this conceptual framework, where the impact of EV usage on the distribution network is addressed within the scope of the cause-effect relationship; there are six different variable categories as dependent and independent variables and the confounding, moderating, mediating and control variables that affect them. In the case of intensive use of charging stations by EV users, many elements

should be considered and monitored in terms of both the user and local distributed generation resources. In the continuation of the study, a conceptual Decision Support System was developed, which includes the elements affecting the operational and managerial decision-making process of organizations from the perspective of electric vehicle users and public service providers, considering the factors determined in the conceptual framework.

In order to meet the intense electricity consumption demands of consumers, energy conversions are provided from various renewable energy sources. The development of new energy demand created by the increase in the use of electric vehicles; causes some changes and transformations in the behaviors of electric vehicle users in the consumer role and in the renewable energy sources that feed the production. Therefore, it is important to understand the new demand and consumption profile that will occur on the distribution network with the intense use of electric vehicles. Different solution strategies need to be produced in order to cope with the increase in the load demand that will occur on the electricity network and the overload problem during the peak time period of this demand. The management of daily energy demand created by electrical energy consumption and the load forecast plans that determine the hourly demand amount for the next day are the determining and guiding elements for the energy sector. With the spread of electric vehicle charging stations, which are a component of distributed production (or distributed energy) where the energy consumption data of EVs are obtained, energy demand forecasts need to be made in more detail, including advanced network analyses instead of regional focus. The accuracy of energy demand forecast is of great importance in order to be able to effectively make load forecast plans related to demand side management and load management in the energy sector.

The subject and scope of the study; analysis of new energy demand and periodic peak power (or peak load) demand on the distribution network and load forecasting algorithms to be applied for short-term load forecasting are discussed. In the study, it is aimed to obtain the most realistic, consistent and effective results for the forecasting of EV energy consumption or EV charging load that constitutes the future new demand by utilizing past data.

The forecasting methods used in the study are considered as time series forecasting in the literature, and deep learning models were used in the development process of forecasting algorithms. For this purpose, the Stacked Deep Learning Ensemble Model (SDLEM) was proposed in the study to increase the short-term charging load forecasting accuracy of electric vehicles. In the proposed model, CNN, LSTM, GRU, BiLSTM and BiGRU models were considered as base learners, while LightGBM algorithm was used as meta learner. For the implementation of the proposed model, real-time charging session events collected from 54 public charging stations located in the Caltech campus garage of a research university located in Pasadena, California, USA were used. The data belonging to these real-time charging session events; EV charging connection time, EV charging disconnection time and energy consumption attributes were obtained from the open data platform called ACN-DATA.

The effectiveness of the developed Stacked Deep Learning Ensemble Model was evaluated by comparing it with the performances of deep learning based single models using MAE, RMSE, NRMSE and R^2 performance metrics. As a result of the evaluation, the MAE, RMSE, NRMSE and R^2 performance metric values of the proposed model were obtained as 3.5894, 4.9935, 0.0551 and 0.9444, respectively,

and it was seen that it gave the best performance compared to the compared single models.

In order to manage the demand for electric vehicles and optimize charging control in the capacity planning of the EV charging infrastructure of distribution networks, problems such as demand uncertainty, energy uncertainty, EV mobility, network uncertainty, and price uncertainty should be addressed. In order to manage these uncertainties with the integration of information and communication technologies into the power system, optimality, improvement, and sustainability should be ensured with artificial intelligence applications in the activities of the predictive dynamic processes of energy.

In summary, the study; a conceptual framework for the impact analysis of EV charging load demand on distribution networks, a conceptual Decision Support System and a methodology for EV charging load forecasting have been created, and load forecasting models based on deep learning algorithms have been developed. In this context, it is aimed to increase the flexibility of the power system by supporting the construction of smart charging control and decision-making mechanisms based on data obtained and interpreted by utilizing information and communication technologies. It is thought that this study will also guide other smart grid technology development studies.



1. GİRİŞ

Son dönemlerde teknoloji ve dijitalleşme alanında yaşanan yeniliklere bağlı olarak dünya genelinde nüfus, ekonomik yapılar, piyasa koşulları gibi dinamik tabanlı birçok gelişmenin paralelinde tüm sektörlerde devrim niteliğinde dönüşümler yaşanmaktadır. Üretim ve tüketim davranışlarının da bu doğrultuda değişmesi ile beraber enerjinin de üretimi takip eden bir talep yerine tüketimini takip eden üretim öngörülerini belirlemek, değişken tüketim anlayışına göre çeşitli tahminlerde bulunmak ve ulusal/uluslararası gelişmeleri takip etmek ciddi önem taşımaktadır¹. Toplumsal yaşam düzenindeki eşgüdüm ile artış gösteren çevre bilinci de gelecekteki enerji sisteminin temelden değişmesi ihtiyacını ortaya çıkarmaktadır. Dünyadaki bu devrim ve dönüşüme ülkelerin hızlı adapte olabilmesi ve değişen üretim-tüketim ilişkilerinin kontrolünü sağlamak gerekmektedir. Ülkelerde enerjinin güvenilirliğini, karşılanabilirliğini ve sürdürülebilirliğini artırmak amacıyla International Energy Agency² (IEA) tarafından küresel ölçekte çeşitli senaryolar oluşturulmakta ve belirli politikalar savunulmaktadır. 2050 yılına kadar küresel elektrik talebinin büyümesi, STEPS, APS ve NZE³ senaryosunda küresel toplamın yaklaşık dörtte üçünü oluşturan yükselen piyasalar ve gelişmekte olan ekonomiler tarafından yönlendirileceği düşünülmektedir. Ülkelerin oluşturulan bu senaryolar çerçevesinde enerji stratejilerini belirlemesi istenmektedir. IEA'nın 2023 yılında yayınladığı "World Energy Outlook" raporunda (International Energy Agency [IEA], 2023, s. 124) küresel elektrik talebinin tüm sektörlerde ve tüm senaryolarda artmakta olduğu, elektrikli araçlar ve hidrojen

¹ EPDK, 2024; IEA, 2024; Enerdata, 2024; Statista, 2024; EIA, 2024; Filipinler DOE, 2024.

² IEA, 31 üye ülke, 11 birlik ülkesi ve diğer ülkelerde; petrol, gaz ve kömür arz ve talebi, yenilenebilir enerji teknolojileri, elektrik piyasaları, enerji verimliliği, enerjiye erişim, talep tarafı yönetimi ve çok daha fazlasını içeren enerji konularının tüm yelpazesini incelemektedir.

³ NZE veya NZE2050 Senaryosu, küresel enerji sektörünü 2050 yılına kadar net sıfır CO₂ emisyonuna ulaştırmak için önümüzdeki on yılda neye ihtiyaç duyulacağına dair ayrıntılı IEA modellemesini içeren yol gösterici normatif bir senaryodur (International Energy Agency [IEA], 2020).

üretiminin de elektrik talebindeki artışa katkıda bulunduğu belirtilmiştir⁴. Karayolu taşımacılığı sektörünün elektrifikasyonundaki artış ile birlikte elektrikli araç satışlarının yükselmesi ve 2030’da yollarda daha fazla görülmesi beklenmektedir (International Energy Agency [IEA], 2024).

Elektrikli araçlar, farklı ölçeklerdeki dağıtık üretim kaynakları ve enerji depolama sistemleri akıllı şebeke temel kategorilerden biri olan “Akıllı Gömülü Sistemler”in teknik bileşenlerindendir. Akıllı Gömülü Sistemler altında incelenen bu akıllı şebeke bileşenleri ise orta gerilim veya alçak gerilim şebekelerine gömülü bir şekilde tesis edilir ve düşük karbon hedeflerine ulaşmak için kritik önem arzeder. EA’ların yollarda daha fazla olması ile birlikte yük eğrisi artmakta ve şarj istasyonlarına güç sağlamak için daha fazla elektriğe ihtiyaç duyulmaktadır (Morais ve ark., 2014). Bu nedenle anlık elektrik ihtiyaç dinamizmine uygun altyapıların planlanması gerekmektedir. Çünkü EA’ların şarj için güç sistemlerine bağlanmasının genel sistem üzerindeki etkileri büyüktür (Qian ve ark., 2010).

Şarj yükünün doğru ve güvenilir şekilde tahmin edilmesi, gerekli planlamaların yapılması için yol gösterici olabilecektir. Tahmin doğruluğu ve güvenilirliği konusunda yapay zeka tekniklerinin bu alanda da başarılı olduğu değerlendirilmektedir (Xin ve ark., 2024). Özellikle makinelerin algoritmalar aracılığıyla mevcut verilerden öğrenerek çıkarımlar yapmalarını sağlayan makine öğrenmesi tekniklerinin üretim ve hizmet başta olmak üzere birçok alanda kullanımı gitgide artmıştır (Mohammed ve ark., 2016). Güncel bir alan olarak görülen enerji tüketiminin tahmini için farklı sektörlerde birçok araştırma yapılmıştır. Bu kapsamda zaman serileri de dâhil olmak üzere farklı veriler ve makine öğrenmesi algoritmaları kullanılmıştır (Javanmard ve Ghaderi, 2023). Ancak günümüz teknolojilerindeki gelişmeler ve artan veri hacimleri karşısında geleneksel makine öğrenmesi teknikleri her zaman beklenen çözümlere ulaşmayı sağlayamayabilmektedir. Gerçek zamanlı karmaşık ve büyük miktardaki verilerin işlenmesi söz konusu olduğunda en çok tercih edilen yöntemlerden birisi derin öğrenmedir (Mohsen ve ark., 2018). Derin öğrenme, girdi verilerini kullanıp çıktı üretmeyi sağlamak için çeşitli güçlü algoritmaları

⁴ IEA’nın 2023 yılında yayınladığı “World Energy Outlook” raporunda Şekil 3.14 (Figure3.14)’te sektöre, bölgeye ve senaryoya göre elektrik talebi grafikleştirilerek ifade edilmiştir (International Energy Agency [IEA], 2023, s. 124).

kullanmaktadır. Bu sayede büyük hacimli eğitim verilerindeki karmaşık ve doğrusal olmayan özelliklerin çıkartılmasını sağlamaktadır (Diro ve Chilamkurti, 2018).

EA saatlik enerji tüketim miktarını yüksek doğrulukta tahmin etmeyi amaçlayan bu çalışmada, yenilikçi bir model geliştirilerek en iyi performansı verebilecek tahmin modelinin belirlenmesi hedeflenmektedir. Bu amaçla derin öğrenme algoritmalarının temel öğrenici ve makine öğrenmesi algoritmasının meta öğrenici olarak kullanıldığı bir Yığılmış Derin Öğrenme Topluluk Modeli tasarlanmıştır. Modelin performansı, modelin mimarisinde kullanılan tekli derin öğrenme modelleri ile kıyaslanmıştır.

1.1. Tezin Kapsamı

Elektrikli araç (EA) kullanımının artışı ve gelişimiyle beraber kullanıcılara şarj hizmeti sağlayan şarj altyapısının ihtiyacına yönelik, yol gösterici nitelikteki öngörü çalışmaları doğrultusunda stratejik planlar yapılmaktadır. Bu planlar çerçevesinde; elektrikli araç kullanıcılarının şarj hizmetine ilişkin enerji piyasasını olumlu yönde etkileyecek teşvikler uygulanmalı ve şarj ağını besleyen dağıtım şebekelerinde ihtiyaç duyulan kapasitenin sağlanması için belirlenen politikalar dâhilinde gerekli tedbirler alınmalıdır. Dağıtık üretim kaynağı olan elektrikli araç şarj istasyonlarının (EVCS veya EVSE) şebekeye entegrasyonu ile birlikte dağıtım şebekelerindeki kapasitenin yönetimi için akıllı şarj stratejileri oluşturulmalıdır. Bu nedenle elektrikli araçların yoğun kullanımı ile gelecekte oluşacak yeni elektrik enerjisi talebinin ve tüketim profilinin iyi anlaşılması gerekmektedir.

1.2. Tezin Amacı

EA'lara şarj hizmeti sağlamak amacıyla oluşturulan şarj altyapısındaki; işletilen şarj ağının genişlemesi ve dâhilinde şarj istasyonlarının yaygınlaşması ile enerji talep tahminlerinin bölgesel odaklılık yerine gelişmiş şebeke analizlerini de içerecek şekilde daha detaylı yapılması gerekmektedir. Bu çalışma ile elektrikli araç şarj yükü (güç) talebinin dağıtım şebekesine etkisi analiz edilerek öngörülü karar problemlerini tanımlamak ve çözmek için oluşturulan kavramsal Karar Destek Sistemi ile farklı iş modellerinin desteklenmesi amaçlanmaktadır. Çalışma, EA'lara elektrik enerjisi aktarımı sağlayan şarj istasyonlarının geçmiş şarj olaylarına ait verilerden yararlanarak gelecekte talep edilmesi beklenen elektrikli araç şarj yükünü tahmin etmeyi

hedeflemektedir. Bu doğrultuda yük yönetimi ile dağıtım şebekelerinde ihtiyaç duyulan kapasitenin sağlanması için gerekli tedbirleri alabilmek ve şebeke performansını iyileştirmek için yük tahmin algoritmaları geliştirilecektir.

1.3. Tezin Organizasyonu

Çalışmanın organizasyonu şu şekildedir. Bölüm 2’de ilk olarak Türkiye’de elektrik enerjisi sektörü ve piyasasının işleyişi ile ilgili kurum ve kuruluşların görev, yetki ve sorumluluklarından bahsedilmiştir. Yine bu bölümde Türkiye’deki elektrik enerjisi piyasası referans alınarak talep tarafı yönetimi ve yük tahmin algoritmalarının pratikte ne gibi hususlarda ele alındığından bahsedilmiştir. Devamında elektrikli araçlar için şarj yükü tahmini üzerine literatürde bulunan çalışmalar incelenmektedir. Bölüm 3’te elektrikli araçların kullanımı ile gelecekte oluşacak yeni elektrik enerjisi talebinin dağıtım şebekesine etkisinin analiz edilmesi ve ilgililerin bu husustaki karar verme sürecini temel alan geniş çaplı bir kavramsal çerçeve oluşturulmuştur. Bu kavramsal çerçevede karar alma sürecini etkileyen unsurların analiz edilmesi ile belirlenen faktörler dikkate alınarak, elektrikli araç kullanıcıları ve kamu hizmeti sağlayıcıları bakış açısıyla bir kavramsal Karar Destek Sistemi geliştirilmiştir. Bölüm 4’te çalışma kapsamında kullanılan yöntemlere yer verilmiştir. Bölüm 5’te EA şarj yükü tahmini için önerilen metodoloji ve bu metodolojinin gerçek zamanlı elde edilmiş veriler üzerinde uygulanması sunulmuştur. Bölüm 6’da karşılaştırmalı deneysel sonuçlar incelenmiştir. Bölüm 7’de ise çalışma sonuçlarına ve önerilere yer verilmiştir.

2. LİTERATÜR ARAŞTIRMASI

2.1. Türkiye’de Elektrik Enerjisi Sektörü ve Piyasasının İşleyişi

Türkiye Cumhuriyeti’nin de üye ülke olarak yer aldığı IEA, güç sistemi açısından EA-şebeke entegrasyon süreçlerindeki yetkilileri ilgili faaliyetleri bağlamında operasyonel ve planlama paydaşları olarak ele almaktadır. Operasyonel paydaşlar doğrudan şarj operasyonlarına katılan; EA kullanıcıları (araç sürücüleri ve filo yöneticileri), EA üreticisi veya araç orijinal ekipman üreticisi (OEM), şarj noktası operatörü (CPO) veya pil değiştirme istasyonu operatörü, elektrikli mobilite hizmeti sağlayıcısı (EMSP), ağ/sistem operatörleri, toplayıcılar (agregatörler), elektrik tedarikçileri ve perakendecileridir. Planlama paydaşları ise EA-şebeke entegrasyonunun gerçekleşmesi için gerekliliklerin planlanması ve sağlanmasıyla ilgilenen; ulusal ve yerel yetkililer, enerji düzenleyicileri, batarya (pil) üreticileri, EA tedarik ekipmanı (EVSE veya EVCS) üreticileri, şehir ve ulaşım planlamacıları, inşaat sektörü (gayrimenkul ve yapı), araştırma enstitüleri ve düşünce kuruluşlarıdır. (International Energy Agency [IEA], 2022, ss. 13-16)

Türkiye Cumhuriyeti’nde, Enerji ve Tabii Kaynaklar Bakanlığı’na ait eski 4628 Elektrik Piyasası Kanunu⁵ ve güncel 6446 sayılı Elektrik Piyasası Kanunu gereklilikleri kapsamında elektrik enerjisi politikaları yürütülmektedir (EPDK, 2024).

Türkiye’deki enerji sektöründe doğal gaz, elektrik, petrol ve LPG piyasaları ile enerji dönüşüm faaliyetleri Enerji Piyasası Düzenleme Kurumu (EPDK) tarafından denetlenmekte ve yürütülmektedir. Yenilenebilir enerji kaynaklarının, elektrik üretim tesislerinde elektrik enerjisine dönüştürülmesi sonrasında EPDK’ya bağlı kamu hizmeti sağlayıcı kurumlarından EÜAŞ (Elektrik Üretim Anonim Şirketi) elektrik üretimi, EPIAŞ (Enerji Piyasaları İşletme Anonim Şirketi) elektrik piyasası

⁵ 4628 Elektrik Piyasası Kanunu 30/03/2013 tarihli ve 28603 sayılı Resmi Gazetede yayımlanan 6446 sayılı Elektrik Piyasası Kanununun 30’uncu maddesiyle “Enerji Piyasası Düzenleme Kurumunun Teşkilat ve Görevleri Hakkında Kanun” olarak değiştirilmiştir.

iřletmecilięi, TEDAř (Türkiye Elektrik Daęıtım Anonim řirketi) elektrik daęıtımı, TEİAř (Türkiye Elektrik İletim Anonim řirketi) elektrik iletimi görevlerinden sorumludur. Türkiye’de kamu hizmeti saęlayıcıları ve daęıtım řirketleri, lisansında belirlenmiř daęıtım bölgesinden sorumlu tutularak; elektrik daęıtım tesisleri, iletim tesisleri ve řebekelerini iřletmektedir. Örneęin, Sakarya bölgesi için Sakarya Elektrik Daęıtım Anonim řirketi (SEDAř) ve Sakarya Elektrik Parakende Satıř Anonim řirketi (SEPAř) tarafından elektrik üretim, iletim ve daęıtım süreçleri yürütölmektedir.

Organize toptan elektrik piyasaları, 6446 sayılı EPK’da řu biçimde tanımlanmıřtır:

Organize toptan elektrik piyasaları: Elektrik enerjisi, kapasitesi veya perakende alıř satıřının gerekleřtirildięi ve piyasa iřletim lisansına sahip merkezî bir aracı tüzel kiřilik tarafından organize edilip iřletilen gün öncesi piyasası, gün içi piyasası ve ileri tarihli fiziksel teslimat gerektiren dięer elektrik piyasaları ile sermaye piyasası aracı nitelięindeki standardize edilmiř elektrik sözleşmelerinin ve dayanaęı elektrik enerjisi ve/veya kapasitesi olan türev ürünlerin iřlem gördüęü ve Borsa İstanbul Anonim řirketi tarafından iřletilen piyasaları ve Türkiye Elektrik İletim Anonim řirketi tarafından organize edilip iřletilen dengeleme gü piyasası ve yan hizmetler piyasası gibi elektrik piyasalarını,...ifade eder. (EPK, 2013, s. 3)

Buradan elektrik piyasasının iřleyiři özetle anlařılmaktadır.

EPDK’nın 2021 yılında kurulan Enerji Dönüřüm Dairesi Başkanlıęı’na baęlı Dijital Dönüřüm Grup Başkanlıęı tarafından akademik alıřmalara yol gösterici nitelikte; dijitalleřme ve enerji sektöründeki gelişim ile birlikte oluřan temel kavramların anlařılması, bu alanda Türke terim kullanımının yaygınlařtırılması ve dil birlięinin saęlanması hedefiyle “Enerjide Dijital Dönüřüm Sözlüęü (EDDS)” hazırlanmıř ve Haziran 2023’te yayınlanmıřtır (EDDS, 2023).

TSKB’nin 2018 yılı itibariyle her yıl yayınladıęı "Enerji Görünümü" raporunun 2020 ve 2021 yılı yayınlarında Türkiye enerji sektörü için tematik konu bařlıkları belirlenmiřtir. Bu tematik konu bařlıkları arasında 2020 yılı raporunda hibrit teknolojileri, batarya depolama sistemleri, elektrikli araçlar yer almakta olup; 2021 yılı raporunda talep tarafı yönetimi, elektrikli araçlar ve depolama teknolojileri, emisyonlar ve iklim adımları yer almaktadır. 2020 ve 2021 yıllarında tematik olarak deęerlendirilen bu bařlıklar için 2022 yılında; elektrikli araçlar ve elektrikli araç řarj sistemleri hakkında standartların belirlenmesi, 6446 sayılı EPK’da řarj altyapısının oluřturulmasına dair mevzuat deęiřikliklerinin yapılması, sıfır emisyonlu araçlara vergi avantajlarının saęlanması gibi önemli adımların atılarak belirgin gelişmelerin

yaşandığı, yasal düzenlemelerin uygulamaya konulduğu belirtilmiştir (Türkiye Sınai Kalkınma Bankası A.Ş. [TSKB], 2022, s. 1, s. 26).

6446 sayılı EPK'da elektrikli araçlar ve şarj istasyon üniteleri ile ilgili işleyiş, birlikte çalışabilirlik kavramı altında “Birlikte çalışabilirlik: Şarj ağına bağlı veya bağımsız olarak çalışan şarj istasyonlarının, elektrik iletim veya dağıtım şebekeleri ile bunları destekleyen yazılım sistemlerinin etkileşimli, uyumlu ve etkili bir şekilde birlikte çalışmasını” ek maddesi⁶ ile anlatılmaktadır (EPK, 2013, s. 4). Ek olarak EPDK tarafından EA kullanıcıları için “Serbest Erişim Platformu- Şarj@TR” destek uygulaması hazırlanmıştır. Bu uygulama platformu ile elektrikli araçlara şarj hizmeti verilen mevcut halka açık tüm şarj istasyonlarının verileri gerçek zamanlı olarak görüntülenebilmektedir (EPDK, 2021).

TSKB'nin 2023 yılında yayınladığı "Enerji Görünümü" raporunda “Türkiye'de Belirli Sektörlerde Enerji Verimliliğindeki Gelişmeler” başlığı altında ulaştırma sektörü ve elektrikli araçların dağıtım şebekesi üzerindeki etkisini ele alan şu bilgilere yer verilmiştir:

Ulaştırma sektörü ülkemizde nihai enerji tüketimi açısından en büyük üçüncü paya sahiptir. Ayrıca son 20 yılda yıllık ortalama %4,5 büyüme oranı ile enerji talebinin en hızlı arttığı sektördür.Elektrikli ve hibrit araçların yaygınlaşmasına yönelik Özel Tüketim Vergisi (ÖTV) ve Motorlu Taşıtlar Vergisi (MTV) indirimleri uygulanmıştır. Elektrikli araçların Türkiye dağıtım şebekesine olan etkilerinin anlaşılabilmesi için dört farklı dağıtım şebekesi incelenmiş ve 2030 yılı itibarıyla toplam binek araç stoku içerisinde %10 oranında elektrikli aracı entegre etmek için yeterli kapasitenin olduğu analiz edilmiştir. (Türkiye Sınai Kalkınma Bankası A.Ş. [TSKB], 2023, s. 32)

2.2. Türkiye’de Elektrik Enerjisi Piyasası Talep Tarafı Yönetimi ve Yük Tahmin Algoritmaları

Elektrik enerji talebine etki eden tüketici sayısı, tüketici türü, tüketici profil grubu, tüketim miktarları talep tarafı yönetiminde dikkate alınan unsurlardır. Enerji tüketimi doğrultusunda dağıtım şirketleri gibi belirli kamu hizmeti sağlayıcıları tarafından oluşturulan talep tahminleri ise yük (güç) talebine bağlı yük tahmin planı ve puant güç talebi hesaplamaları ile desteklenmektedir.

⁶ EPK'nun uu) (Ek:21/12/2021-7346/30 md.) nolu ek maddesi 21/12/2021 yılında yürürlüğe girmiştir.

Türkiye’de elektrik enerjisi talep tahminleri Elektrik Piyasası Talep Tahminleri Yönetmeliği kapsamındaki usul ve esaslara uygun olarak TEİAŞ, Organize Sanayi Bölgeleri (OSB), dağıtım ve görevli tedarik şirketleri (dağıtım şirketleri) tarafından belirlenen talep tahmini yöntemine uygun olarak yapılması, değerlendirilmesi, güncellenmesi ve onaylanması süreçleri izlenerek oluşturulmaktadır (EPDK, 2016).

Türkiye’de elektrik piyasası EPİAŞ, TEİAŞ ve Borsa İstanbul Anonim Şirketi aracılığıyla işletilmektedir. Kanun kapsamında belirlenen piyasaların işleticisi olan Borsa İstanbul Anonim Şirketi, EPİAŞ’a bağlı olarak sermaye piyasası aracı niteliğindeki standardize edilmiş elektrik sözleşmelerinin ve dayanağı elektrik enerjisi ve/veya kapasitesi olan türev ürünlerin elektrik piyasası faaliyetlerine ilişkin iş ve işlemlerinden sorumludur (EPK, 2013, s. 18).

Dağıtım ve görevli tedarik şirketleri tarafından Elektrik Piyasası Talep Tahminleri Yönetmeliği’ne uygun olarak belli bir zaman aralığı için farklı senaryolar çerçevesinde geleceğe dönük elektrik enerjisi miktarı, puant güç talebi ve abone sayısı için talep tahmini süreci gerçekleştirilmektedir (EPDK, 2016, s. 1).

Yük tahmin algoritmalarının belirlenmesi süreci, ilgili yönetmelik⁷ maddesinde “Talep Tahmin Yöntemin Belirlenmesi ve Veri Seti” başlığı altında şu şekilde tanımlanmıştır.

MADDE 5 - (1) Dağıtım şirketleri dağıtım bölgelerine ilişkin, görevli tedarik şirketler ise enerji tedarik etmeyi planladığı son kaynak, perakende satış ve serbest tüketicilerin tüketimine ilişkin talep tahminlerini bilimsel yöntemlerle, bölgelerine özgü şartları dikkate alarak, resmi ekonomik hedefleri göz önünde bulundurarak ve gerek duyulması halinde ilgili kamu ya da özel sektör kurum ve kuruluşlarının görüşlerini de alarak yapar veya yaptırır. (EPDK, 2016, s. 2)

Talep tahmininde, tahmin modelinin oluşturulmasında gözetilecek ilkeler⁸ yine ilgili yönetmeliğin içeriğinde yer almaktadır. Puant talep (en yoğun elektrik tüketim talebi) ve abone sayısına ilişkin tahminler ekonometrik bir modele dayalı olması; elektrik talep davranışı ile tutarlı, bilimsel ve ekonomik olarak anlamlı açıklayıcı değişkenlerin kullanılması ve belirlilik katsayılarının açıklama gücü açısından yüksek olması durumunda seçilip kullanılabilir (EPDK, 2016, s. 2).

⁷ Elektrik Piyasası Talep Tahminleri Yönetmeliği: Bu yönetmelik Enerji Piyasası Düzenleme Kurumu tarafından oluşturulmuş olup 07 Mayıs 2016 tarihli ve 29705 sayılı Resmî Gazete’de yayımlanmıştır.

⁸ Elektrik Piyasası Talep Tahminleri Yönetmeliği MADDE 8 (s. 2); “Talep tahmininde gözetilecek ilkeler”

2.2.1. Elektrikli Araç Şarj Yüğü Tahmini

Elektrikli araç kullanımının artması çevresel sürdürülebilirliğe önemli katkı sağlamakta olup araçların sunduğu enerji güvenliği ve maliyet tasarrufu sayesinde hükümetler de bu alanda çalışmakta ve eylem planları geliştirmektedir (Yi ve ark., 2022).

EA'ya olan talebin artması ile bu alan araştırma konusu olarak oldukça popüler hale gelerek birçok farklı açıdan ele alınmıştır. EA şarj istasyonlarındaki enerji tüketim miktarlarını tahmin etmeye yönelik bir model geliştirilmesi amacıyla gerçekleştirilen bu çalışmada tahmin modelleri geliştirmeye yönelik araştırmalar incelenmiştir.

Bae ve Kwasinski (2011) tarafından yapılan çalışmada şarj istasyonu için elektrik araç şarj talep miktarını tahmin etmeye yönelik bir matematiksel model önerilmiştir. Sayısal bir örnek üzerinde test edndan yapılan çalışmada şarj istasyonu için elektrik araç şarj talep miktarını tahmin etmilen modelin mekansal ve zamansal olarak şarj talebini tespit edebildiği belirtilmiştir. Yazarlar tarafından bu modelin şarj istasyonu dağıtım sistemini bilgisayar ortamında planlamak ve analiz etmek için yardımcı olabileceği düşünülmektedir. Verinin işlenmesi ile anlamlı bir sonuç elde edebilmek için sürecin başında doğru parametlerin seçilmesi ve modellerin temelinde seçilen parametlerin etkinliğinin ölçülmesi tahmin çıktıların daha sağlıklı sonuçlar vermesini sağlayacaktır. Xydas ve ark. (2016) tarafından gerçekleştirilen ve İngiltere'nin Nottinghamshire, Leicestershire ve West Midlands elektrikli araç şarj verilerinden yararlanan çalışmada EA şarj talebini, şarj olaylarının her bir özelliğini ölçmek için faktörler kullanarak kümeleme, korelasyon ve regresyon modülleri ile analiz eden bir çerçeve önerilmiştir. Bu modüller, tipik günlük profilin şeklini, hava koşullarına göre öngörülebilirliği ve sırasıyla EA'ların şarj talep etme eğilimini araştırmak için kullanılmıştır. EA şarj talebini karakterize etmek amacıyla coğrafi bir bölgedeki enerji talebi üzerindeki potansiyel etkisini yansıtan üç faktörü tek bir 'risk seviyesi' endeksinde toplayan bulanık mantık karar modeli geliştirilmiştir.

Chung ve ark. (2019), EA şarj programını optimize etmek için EA şarj davranışlarını inceleyerek toplu (hibrit) makine öğrenme tabanlı bir algoritma geliştirmişlerdir. 252 kullanıcıdan alınan gerçek EA şarj verilerini kullanarak EA şarj davranışını, özellikle de şarj oturumları sırasında kalış süresini ve enerji tüketimini tahmin etmeyi amaçlamışlardır. Bu amaçla, Destek Vektör Regresyonu (SVR), Rastgele Orman (RF)

Regresyonu ve Difüzyon Tabanlı Çekirdek Yoğunluğu Tahmincisi (DKDE) algoritmalarından faydalanmışlardır. Çalışma şebekeye fayda sağlaması amacıyla EA şarj planlanını (çizelgesini) optimize etmeye de odaklanmıştır. En iyi ve uygun tahmin algoritmasını seçmek için entropi/seyreklilik oranı (R) göstergesi tanımlanmıştır. R düşük olduğunda SVR ve RF regresyonu, sırasıyla kalış süresi ve enerji tüketimi tahminleri için daha iyi doğruluk gösterirken, R yüksek olduğunda DKDE her iki tahmin için de daha iyi performans göstermiştir. Tahmin algoritmalarının performanslarını değerlendirmek için Simetrik Ortalama Mutlak Yüzde Hatası (SMAPE) hesaplanmıştır. Genel tahmin performansını iyileştirmek, kalış süresi tahmin hatasını %11 ve enerji tüketimi tahmin hatasını %22 azaltmak için tekli makine öğrenmesi algoritmalarından SVR, RF ve DKDE kombinasyonundan oluşan EPA topluluk tahmin algoritması önermişlerdir. Geliştirilen EPA tahminleri, şarj maliyetlerini azaltırken yük değişimini de en aza indirmek için optimum EA şarj planlama (çizelgeleme) algoritmasına uygulanmıştır. Çalışma sonucunda EPA modelinin tahminiyle birlikte şarj planlamasının, koordinesiz şarja kıyasla puant gücü %27, güç değişimini %10 ve maliyeti %4 azaltabildiğini gözlemlemişlerdir.

Zhu ve ark. (2019), elektrikli araçların şarj yükü tahmini için derin öğrenme yaklaşımlarını karşılaştıran bir çalışma gerçekleştirmiştir. Araştırmada, dakika düzeyinde gerçek veriler kullanılarak çeşitli popüler ve yeni derin öğrenme yöntemleri incelenmiştir. Elektrikli araçların düzensiz şarj davranışlarına karşı geleneksel yük tahmin yöntemlerinin yetersiz kaldığına işaret etmiştir. Derin öğrenme yöntemleri, büyük veri setlerinden öğrenme kabiliyetleri sayesinde bu zorlu tahmin görevlerini başarılı bir şekilde yerine getirmektedir. Çalışmada, LSTM modeli'nin geleneksel Yapay Sinir Ağı (ANN) modeline göre tahmin hatasını %30'dan fazla azaltarak en iyi performansı gösterdiği gözlemlenmiştir. Bu doğrultuda derin öğrenme yöntemlerinin elektrikli araç şarj yükü tahmininde yüksek doğruluk sağladığı ifade edilmiştir.

Orzechowski (2021), EA şarj altyapısının verimli yönetimi ve planlanması için halka açık elektrikli araç şarj istasyonlarındaki talebi tahmin etmek için sağlam ve doğru bir model geliştirmeye odaklanmıştır. Çalışma, kamu hizmeti sağlayıcıları tarafından toplanan günlük istasyon enerji kullanımından oluşan veri kümesinin geçmiş şarj verileri ile hava koşulları parametreleri kullanılarak halka açık elektrikli araç şarj istasyonlarındaki talebi tahmin etmiştir. Yapay sinir ağları (YSA) ve otoregresif entegre hareketli ortalama (ARIMA) modelleri kullanılarak model geliştirme ve

normalleştirme tekniklerini içeren bir metodoloji sunulmuştur. Veri kümesi oluşturma, özellik çıkarma ve etiketleme, hava koşulları ve diğer veri kaynaklarını kullanarak genişletme, farklı zaman ufku parametrelerinin ve çıktı katmanları yapılarının etkisini araştırmıştır. Tahmin doğruluğunu artırmak için çok görevli öğrenmenin (MTL) potansiyelini de ele almıştır. Hem tüketicileri hem de kamu hizmetlerini desteklemek için bir şarj ağındaki çeşitli istasyonların bireysel ve tüm ağın orta ve uzun vadeli enerji talebini tahmin etmek için çeşitli makine öğrenimini ve diğer yöntemleri değerlendirmiştir. Çalışmanın sonucunda YSA modelinde diğer yöntemlere kıyasla SMAPE'de bireysel istasyonlar için %21,3 ve ağ için %5,9 olmak üzere önemli bir iyileşme sağlanmıştır.

Van Krieking ve ark. (2021), çalışmalarında elektrikli araç şarj talebinin bir gün öncesinden tahmin edilmesi için derin sinir ağlarının kullanımını araştırmışlardır. Yazarlar, mevcut tahmin modellerini geliştirerek yeni özellikler eklemiş ve değişken öğrenme oranı fonksiyonu kullanmışlardır. Bir hastane şarj alanındaki gerçek EA şarj verilerinin kullanıldığı çalışmada, küçük bir EA filosunun (örneğin, hastane gibi yarı kamusal bir şarj alanı) bir gün öncesinden, 15 dakikalık zaman dilimlerinde tahmin edilmesine odaklanılmıştır. Bu kapsamda, EA şarj talebi tahmininin hatasını azaltmak için çeşitli veri ön işleme ve model değerlendirme yöntemleri uygulayarak zaman serisi analizleri yerine, LSTM ağlarını kullanmıştır. Çalışma sonucunda performans ölçütlerinden ortalama mutlak hata (MAE) %28,8, kök ortalama kare hata (RMSE) ise %19,22 oranında azaltılarak önemli iyileşmeler gözlemlenmiştir. Bu çalışma özellikle, küçük ve daha öngörülemez EA filoları için kısa vadeli yüksek çözünürlüklü tahminler yapılabilmesi, şebeke operatörleri ve yerel enerji sistemlerinin daha etkili bir şekilde yönetilmesine katkı sağlayarak enerji yönetim sistemleri için etkili tahmin modelleri sunmayı hedeflemiştir.

Soares ve Franco (2021), enerji sektöründeki şirketlere kısa vadeli (1 saatten 1 haftaya kadar) elektrik yükü tahmini için karar destek aracı olarak hizmet verebilmesi amacıyla; uzun vadeli zamansal korelasyonları çıkarmak için ilk olarak zaman serisiyle beslenen BiGRU katmanı ve sonrasında bu zaman özelliklerinin uzamsal eğilimleri yakalayabilmesi için CNN katmanından oluşan BiGRU-CNN hibrit modeli önermiştir. Çok Katmanlı Algılayıcı (MLP), Tekrarlayan Sinir Ağları (RNN), GRU, LSTM, GRU-CNN ve CNN-BiGRU modelleri ile BiGRU-CNN tahmin modeli sonuçları MAPE, MAE ve RMSE performans ölçütleri ile analiz edilerek

karşılaştırıldığında, BiGRU-CNN modelinin kısa vadeli yük tahmin doğruluğu açısından klasik ve diğer hibrit sinir ağı modellerinden daha verimli ve iyi performans gösterdiği belirtilmiştir. Yazarlar gelecek çalışmalarda BiGRU-CNN modelinin sinir ağlarının hiperparametreleri ve onları besleyen zaman serilerinin değiştirilmesinin faydalı olabileceğini önermiştir.

Karar vericiler, şebeke üzerinde olumsuz bir etki oluşturmada tüketici ihtiyaçlarını karşılayabilmek için, elektrikli araç şarj talebinin stokastik yapısını (başlangıç zamanı, kalış süresi ve ilk şarj kapasitesi gibi) dikkate alan gelişmiş yük tahminleme yaklaşımlarını kullanabilirler. Vahidmohammadi (2021), EA şarj yüklerinin kısa süreli tahmini için RNN tabanlı veriye dayalı çok değişkenli DeepAR derin öğrenme modeli önermiştir. Önerilen çok değişkenli DeepAR tahmin modelinde konut ve işyeri kullanımı için iki özel veri kümesi üzerinden; şarj başlangıç zamanı, şarj süresi, kWh cinsinden enerji tüketim miktarı veya şarj yükü, iki konum için ortalama elektrik kullanım fiyatı, hafta içi ve hafta sonu olmak üzere haftanın günlerinden oluşan 5 boyutlu girdi verileri kullanılmıştır. Çalışmada kısa vadeli tahmin penceresi olarak; bir, üç, yedi ve on beş gün öncesi için çok adımlı günlük ufuklarda yük tahmini gerçekleştirilmiştir. Önerilen çok değişkenli DeepAR modelinin, birkaç popüler derin öğrenme modeli ile MASE ve SMAPE performans ölçütlerine bakılarak tahmin performansı karşılaştırılmış olup sırasıyla 0,049 ve 0,019 değerleriyle daha iyi performans gösterdiği değerlendirilmiştir. Çalışma, EA şarj yükü tahmin ağlarında daha iyi gerçek zamanlı tahminler için hiperparametrelerin optimize edilmesinin önemini vurgulamıştır. Kumar ve ark. (2022), gelecekteki şarj yükünü tahmin etmenin EA şarj planlarını yönetmek için yol göstereceğini belirtip bu amaçla bir çalışma gerçekleştirmişlerdir. California Teknoloji Enstitüsü'ndeki şarj ağından elde edilen gerçek zamanlı verilerin kullanıldığı modelleri geliştirmek için Yapay Sinir Ağı ve LSTM kullanılmıştır ve çalışmada şarj ihtiyaçlarını saatlik, günlük ve haftalık olarak tahmin etmek hedeflenmiştir. Sonuç olarak LSTM modelinin daha başarılı tahmin performansı gösterdiği belirtilmiştir. Şen (2022), Elektrikli araçların şarj istasyonlarından talep etmiş olduğu enerji miktarını tahmin etmeye yönelik bir çalışma gerçekleştirmiş olup, tahmin modeli için 7 farklı (MLR, PR, DT, RF, KNN, SVR, XGBoost olmak üzere) gözetimli makine öğrenmesi algoritması kullanmıştır. Modelin test edilmesi için Birleşik Krallık'ın Dundee kentinde bulunan şarj istasyonlarına ait verilerden farklı değişken kombinasyonu ile 4 ayrı veri seti oluşturulmuştur. Veri

setinin girdi değişkenleri; şarj noktası kimliği, şarj olayının numarası, elektrikli araç kullanıcı kimliği, şarj başlama tarihi, şarj başlama zamanı, şarj bitiş tarihi, şarj bitiş zamanı iken tahmin edilen değer, kWh cinsinden EA'ların şarj istasyonlarından talep etmiş oldukları enerji miktarlarıdır. Birinci ve dördüncü veri setinde R^2 performans ölçüt değeri 1'e en yakın ve RMSE değeri 0'a en yakın değerde olduğu için Rastgele Orman (RF) algoritması en iyi enerji talebi tahmin sonuçlarına sahip olup, ikinci ve üçüncü veri setinde ise enerji talebini en iyi Aşırı Gradyan Artırma (XGBoost) algoritması tahmin etmiştir. Karabiyik ve Karabiyik (2023) önceki çalışmalarda vurgulanmış olan önemi destekler nitelikte EA yük tahmininde hiperparametre optimizasyonu kullanmıştır. Sistematik olarak optimize edilmiş hiperparametrelerle oluşturulmuş farklı LSTM ağları yapılandırmaları, önceki saatleri yineleme ve yeni giriş özellikleri baz alınarak optimize edilmiştir. Sonuç olarak kısa süreli (saatlik) elektrikli araç şarj yükü için Uzun Kısa Süreli Bellek (LSTM) tahmin modelleri Normalleştirilmiş Karekök Ortalama Karesel Hata (NRMSE) ile değerlendirilerek en yüksek doğruluğa sahip; eğitim veri kümesi için 0,074 ve test veri kümesi için 0,077 olan optimal bir LSTM modeli elde edilmiştir. Vishnu ve ark. (2023), gerçek zamanlı uyarlanabilir şarj ağı verileri kullanılarak EA yük tahmini için üç tahmin modeli geliştirmiş ve performansları karşılaştırmıştır. Sonuç olarak Destek Vektör Regresyonu ve LSTM ile geliştirilen modellerin başarılı performans gösterdiği belirtilmiştir. Bunlar arasında LSTM, 4 kW Ortalama Mutlak Hata (MAE) ve 5,9 kW Karekök Ortalama Karesel Hata (RMSE) performans ölçüt değerleri ile en iyi performansı göstermiştir. Khan ve ark. (2023) tarafından yapılan çalışmada EA entegrasyonunun şebekeye olan kötü yönde etkilerini azaltma amacıyla yük tahmini gerçekleştirilmiştir. Farklı mekansal seviyelerden 15 dakikalık çözünürlük verilerinin kullanıldığı çalışmada Rastgele Orman ve Yapay Sinir Ağı algoritmalarının tahmin performansı üzerindeki etkileri karşılaştırılmıştır. Elde edilen sonuçlar tek şarj yığınlarına kıyasla toplu tahminlerin daha iyi performans gösterdiğini doğrulamıştır. Benzer amaçlar taşıyan bir diğer çalışma Koohfar ve ark. (2023) tarafından gerçekleştirilmiş olup EA'ya yönelik şarj talebinin belirlenmesi için geliştirilen tahmin modellerinde altı farklı derin öğrenme algoritması karşılaştırılmıştır. Bunlar RNN, LSTM, Bi-LSTM, GRU, CNN ve transformatörlerdir. Sonuç olarak transformatör yönteminin şarj talebi tahmini konusundaki performansının en iyi olduğu belirtilmiştir. Hava koşulları, EA sürücülerinin davranışlarını ve sürüş modellerini önemli ölçüde

etkilemektedir. Değişim gösteren bu davranış ve sürüş modelleri ile farklı dinamiklerde şarj modelleri oluşmaktadır.

Aduama ve ark. (2023) tarafından elektrikli araç şarj istasyonu yük tahmin doğruluğunu artırmak amacıyla çok özellikli veri birleştirmeye dayalı bir tahmin tekniği önerilmiştir. Çalışmada, UCI'nin geçmiş hava koşulları (rüzgar hızı, sıcaklık ve nem) gözlemleri ve şarj yüküne ilişkin çok özellikli girdi verileri kullanılarak LSTM derin öğrenme modeli ile üç farklı başlangıç tahmini yapılmıştır. LSTM modeli tarafından oluşturulan başlangıç yük tahminlerini birleştirmek ve sonuçları optimize etmek için Kanıt Teorisi (Dempster–Shafer (DS)) uygulanmıştır. Çalışmada MAE performans ölçütü ile gerçekleştirilen değerlendirmeler sonucunda önerilen modelin %3,29 değeri ile LSTM'in başlangıç tahmin sonuçlarından daha düşük değer vererek tahmin doğruluğunun artırıldığı gözlemlenmiştir.

Liang ve ark. (2023), çalışmalarında iyi performans gösteren makine öğrenimi ve sinir ağı modellerinin güçlü yönlerini birleştirmişlerdir. Çalışmada, enerji tüketimi tahmininde orijinal zaman serisinden tahmini özellikleri çıkarmak için Prophet ayrıştırmasına dayalı özellik seçimiyle GRU-MMattention-LightGBM'nin hibrit bir model mimarisi önerilmiştir. LightGBM ve GRU-MMattention arasındaki son tahmin ağırlıklarını öğrenmek için bir MLP kullanılmıştır. Yazarlar, ACF ve PACF diyagramlarını kullanarak zaman penceresi uzunluğunun hiperparametrelerini seçmek için bir yöntem önermiştir. GRU-MMattention-LightGBM modelinin MAPE'si %1,69 elde edilmiş ve bağıl hatanın GRU yapısınınkinden %8,66 ve LightGBM tahmininden %2,02 daha az olduğu değerlendirilmiştir. Böylece önerilen hibrit mimarinin tek bir yöntemle karşılaştırıldığında tahmin doğruluğu ve kararlılığını önemli ölçüde iyileştirdiği gözlemlenmiştir.

Literatür incelendiğinde, genel olarak elektrikli araçlarda enerji tüketim miktarının tahminine yönelik geliştirilen modellerin makine öğrenmesi ve derin öğrenmeye dayalı tekli veya hibrit modellere dayalı geliştirildiği görülmektedir. İncelenen literatür kapsamında, topluluk modeli geliştiren çalışmalardan Bae ve Kwasinski (2011) çalışmasında ise sadece makine öğrenmesi algoritmaları kombinasyonu kullanılmıştır. Bu çalışmada ise literatüründen farklı olarak, elektrikli araçların kısa dönemli enerji tüketim miktarının tahmin doğruluğunun artırılması için ilk aşamada; farklı türdeki tekli derin öğrenme algoritmalarının birleştirilmesi ile temel öğrenmenin gerçekleştirilmesi, ikinci aşamada ise meta öğrenici olarak gradyan artırma

algoritmalarının bir türü olan makine öğrenme algoritması ile oluşan hibrit Yığılmış Derin Öğrenme Topluluk Modeli önerilmiştir.





3. KARAR DESTEK SİSTEMİ

3.1. Elektrikli Araç Şarj Yüğü (Güç) Talebinin Dağıtım Şebekelerindeki Etki Analizine Dair Kavramsal Çerçeve

Enerji piyasası, sürekli değışen doğası gereğı esnek bir yönetim anlayışı gerektirmektedir. Sektördeki süreç ve operasyonların yönetim yapısının bu dinamizme uyum sağlayabilmesi için karar alma süreci en kritik ve etkin safhadır. Bu nedenle alınacak kararların doğru ve bir o kadar da hızlı gerçekleşmesi ciddi önem arz etmektedir.

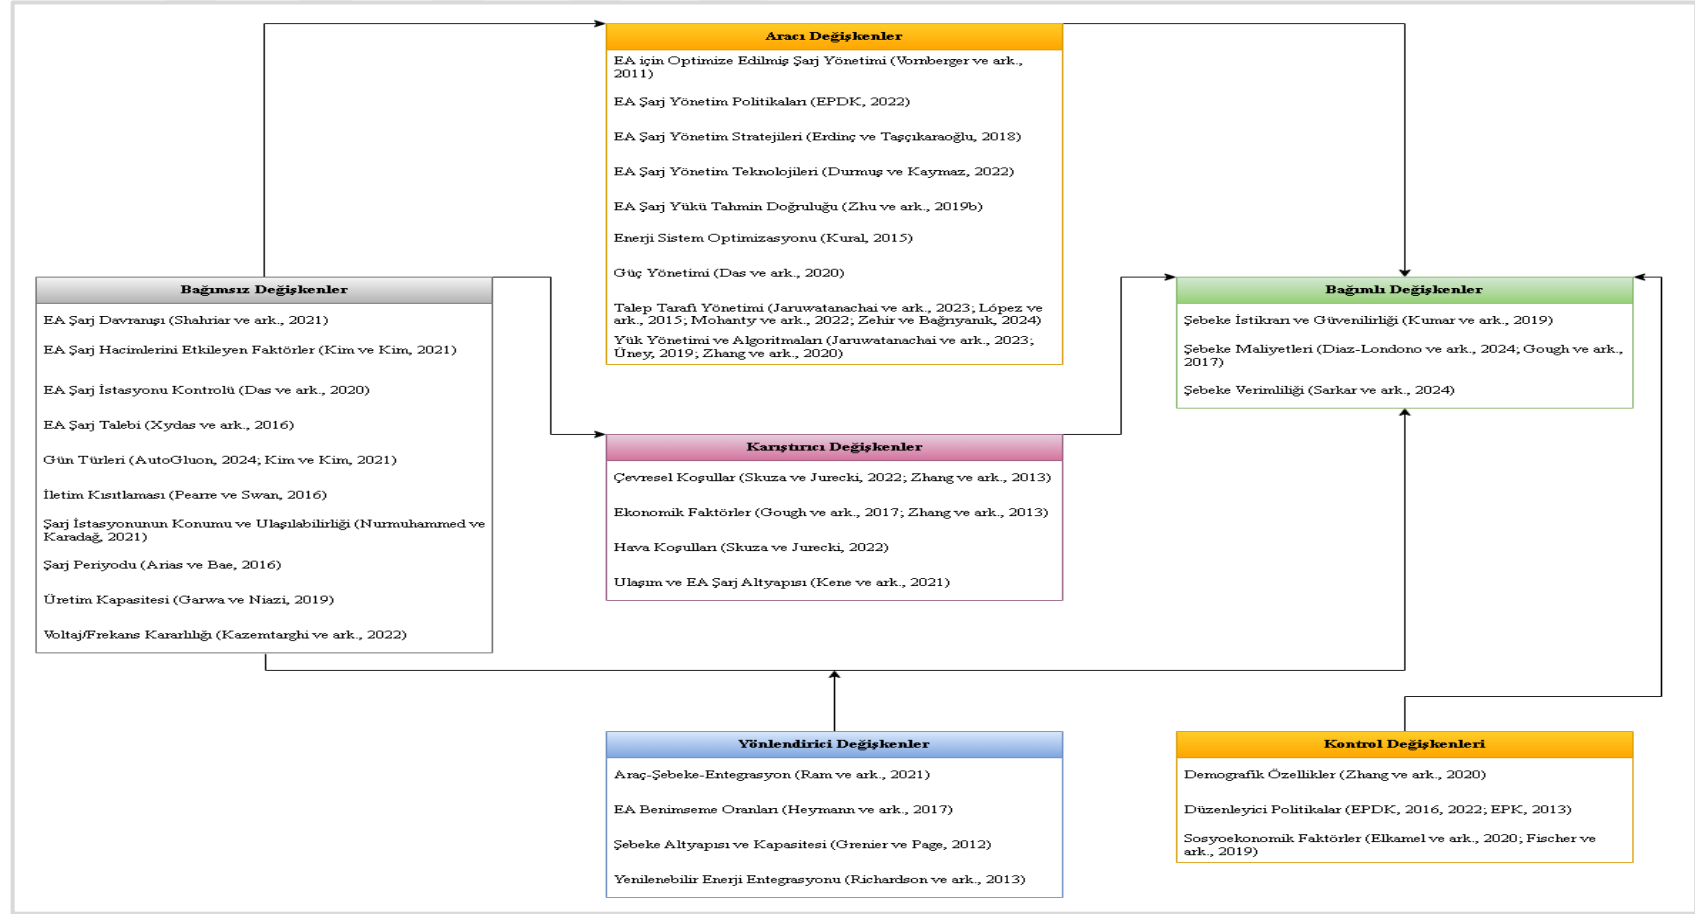
Enerjide dijital dönüşüm ile elektrik enerji akışının gerçek zamanlı izlenmesi, ölçümü ve kontrolü sağlanacaktır. Li ve Jenn (2024)'ye göre EA-şebeke entegrasyonunun birincil darboğazı EA'ların dağıtım şebekeleri üzerindeki etkisidir. Karar vericilerin bu etkiyi değerlendirmesine yardımcı teknoloji destekli bir karar destek sistemi geliştirilmesi büyük önem taşımaktadır. Karar verme süreci, hem EA kullanıcıları hem de kamu hizmeti sağlayıcılarının farklı bakış açıları dikkate alınarak gerçekleştirilmelidir. Bu çalışmada, enerjiyi talep eden ve kullanan bireyler EA kullanıcıları olarak anılırken, enerji arzını dönüştürmekten sorumlu kurum ve yetkililer ise kamu hizmeti sağlayıcıları olarak adlandırılmaktadır.

Akıllı şebeke sistemi, elektrik enerjisinin üretimden son kullanıcıya kadar izlenmesi, akıllı ölçümlerin yapılması ve yönetilmesine olanak sağlayarak araçtan şebekeye veya şebekeden araca bağlantı aktarımlarında sistematik ve teknolojik bir zemin hazırlar (Colak ve ark., 2020). Enerji sektöründe V2G, V2B, V2H, V2L gibi gelişen ve geliştirilmeye devam eden teknoloji altyapıları doğrultusunda farklı iş modellerinin hayata geçirilmesi planlanmaktadır. Araçtan şebekeye veya araçtan konuta enerji aktarımının söz konusu olduğu bu iş modelleriyle, ilerleyen dönemlerde enerjiyi talep edenin kamu hizmeti sağlayıcıları, arz sahiplerinin de EA kullanıcıları olacağı öngörülmektedir.

Şekil 3.1' de elektrikli araç şarj yüğü talebinin dağıtım şebekesine etkisini analiz etmek için geniş çaplı bir kavramsal çerçeve oluşturulmuştur. Buradan yola çıkılarak KDS'ye zemin hazırlayacak neden-sonuç ilişki diyagramları oluşturulabilir. Kavramsal

çerçeve yapısını bağımlı (dependent), bağımsız (independent), karıştırıcı (confounding), yönlendirici (moderating), aracı (mediating), kontrol (control) eden olmak üzere altı farklı değişken (faktör veya etken olarak da adlandırılır) kategorisi oluşturmaktadır. EA-şebeke entegrasyonunun güç sistemindeki etki analizine dair oluşturulan bu kavramsal çerçevede; bağımlı ve bağımsız değişken arasındaki neden-sonuç ilişkisini dolaylı veya doğrudan etkileyen diğer değişken faktörler ele alınmıştır.





Şekil 3.1. Elektrikli araç şarj yükü talebinin dağıtım şebekelerindeki etki analizine dair kavramsal çerçeve.

3.1.1. Bağımsız değişkenler

EA'ların elektrik şebekelerini (power grids) nasıl etkilediğini, neden-sonuç ilişkisi bağlamında değerlendirmeye almak için nedenlerin etkisini ifade eden ve kavramsal çerçevede belirlenmesi gereken iki temel değişkenden biridir. Bağımsız değişkenler (independent variables) olarak belirlenen niteliksel faktörler, tahmin edici veya açıklayıcı özellikteki nedenselliği ifade etmektedir. EA'ların dağıtım şebekelerine etki analizi için belirlenen bağımsız değişkenler, 10 farklı faktör olarak ele alınmış olup hem birbirleri arasında hem de diğer faktörler ile ilişkilendirilebilmektedir. Bunlar;

1. EA Şarj Davranışı (EV Charging Behavior) (Shahriar ve ark., 2021)
2. EA Şarj Hacimlerini (EV Charging Volumes) Etkileyen Faktörler (Kim ve Kim, 2021)
 - araç sınıfı
 - aracın durumu (the condition of a vehicle)
 - batarya şarj durumu (the battery's state of charge (SOC))
 - varış noktasına olan mesafe (the distance to the destination)
3. EA Şarj İstasyonu Kontrolü (EV charging station control) (Das ve ark., 2020)
 - şarj istasyonunun AC/DC özelliği (Tunçer ve Çetin, 2024)
 - şarj istasyonunun kullanılabilirliği
 - şarj istasyonundaki depolama sisteminin şarj durumu
 - doluluk oranı
4. EA Şarj Talebi (Xydas ve ark., 2016)
5. Gün Türleri (AutoGluon, 2024; Kim ve Kim, 2021)
 - haftanın günleri
 - haftaiçi
 - haftasonu
 - tatiller
 - ay
 - yıl
6. İletim Kısıtlaması (transmission constraint) (Pearre ve Swan, 2016)
7. Şarj İstasyonunun Konumu ve Ulaşılabilirliği (Nurmuhammed ve Karadağ, 2021)
8. Şarj Periyodu (Arias ve Bae, 2016) (veya Günün Saati (ToD))

- gündüz
- akşam
- gece
- çalışma saatleri

9. Üretim Kapasitesi (generation capacity) (Garwa ve Niazi, 2019)

10. Voltaj/Frekans Kararlılığı (voltage/frequency stability) (Kazemtarghi ve ark., 2022)

3.1.2. Bağımlı değişkenler

EA'ların elektrik şebekelerini nasıl etkilediğinin neden-sonuç ilişkisi bağlamında bağımlı değişkenler (dependent variables), sonuçların etkisinin gözlemleneceği değişkenlerdir. Bu değişken başlığı altında toplanan niteliksel faktörler tepki veya sonuç özellikteki etkisel değişkenleri ifade etmektedir. EA'ların dağıtım şebekesine etkisinin analizi için belirlenen bağımlı değişkenler aşağıdaki gibi 3 farklı faktör olarak ele alınmış olup hem birbirleri arasında hem de diğer faktörler ile ilişkilendirilebilmektedir.

1. Şebeke İstikrarı (kararlılığı veya stabilitesi) ve Güvenilirliği (Kumar ve ark., 2019)
 - elektrik kesintileri
 - voltaj düşüklüğü veya frekans/voltaj dalgalanmaları
2. Şebeke Maliyetleri (Diaz-Londono ve ark., 2024; Gough ve ark., 2017)
 - altyapı maliyetleri
 - operasyonel ve işletme maliyetleri
3. Şebeke Verimliliği (Sarkar ve ark., 2024)
 - elektrik üretim süreci
 - elektrik iletim süreci
 - elektrik dağıtım süreci

3.1.3. Karıştırıcı değişkenler

Karıştırıcı değişkenler (confounding variables), analizin hem varsayılan nedeni hem de varsayılan etkisiyle ilişkilidir. Bağımsız değişkenin gerçek etkisini karıştırıcı değişkenin etkisinden ayırmak zor olabilir. Olası karıştırıcı değişkenleri belirlemek ve

etkisinin nasıl azaltılacağını planlamak önemlidir. Kavramsal çerçevede karıştırıcı değişkenleri kontrol etmek için yönlendirici (moderatör) değişkenler dâhil edilmiştir.

EA'ların dağıtım şebekesine etkisinin analizi için belirlenen karıştırıcı değişkenler aşağıdaki gibi 4 farklı faktör olarak ele alınmış olup hem birbirleri arasında hem de diğer faktörler ile ilişkilendirilebilmektedir.

1. Çevresel Koşullar (Skuza ve Jurecki, 2022; Zhang ve ark., 2013)
 - iç çevresel koşullar
 - dış çevresel koşullar
 - CO₂ emisyonu
2. Ekonomik Faktörler (Gough ve ark., 2017; Zhang ve ark., 2013)
 - elektrikli araç fiyatları
 - elektrik tarifeleri (elektrik fiyatlandırması veya elektrik fiyatı)
 - basit oran
 - kademeli oran
 - şarj hizmeti fiyatı veya elektrik kullanım zamanı fiyatı (ToU electricity price)
 - talep oranları
 - diğer fiyatlandırma oranları
 - yakıt maliyeti
 - pil bozulma maliyeti
 - devam eden araç bakımları
 - elektrikli araç elektrik satış fiyatı (V2G, V2G teknolojilerinde)
 - döviz
 - teşvikler
3. Hava Koşulları (Skuza ve Jurecki, 2022)
 - sıcaklık
 - yağış
 - nem
 - rüzgar
4. Ulaşım (Taşımacılık) ve EA Şarj Altyapısı (Kene ve ark., 2021)

Güç sistemi planlamasını iyileştirmek için kentsel ulaşım hizmetlerinin planlanması ve yönetimiyle koordineli çalışmalar gerçekleştirilmelidir.

EA şarj talebiyle şarj istasyonlarının kullanım sıklığı tespit edilebilir. Mevcut ve planlanan ulaşım ağı ile dağıtım ve iletim ağlarının ortak haritalandırılması, kentsel hizmet alanlarındaki şarj istasyonlarının yerseçimi ve EA şarj noktası operatörleri (CPOs) tarafından bu istasyonların kurulumu gibi altyapı yatırımları ve operasyonel stratejilerin belirlenmesinde karar mekanizmalarının oluşturulması gerekmektedir. Doğru talep tahminleri, şarj istasyonlarının yerleşimini ve kullanımını optimize etmeye yardımcı olarak şarj ağlarının ekonomik uygulanabilirliğini artırabilir. Bu nedenle şarj istasyonlarının gelecekteki kullanım sıklığının belirlenmesine ve elektrikli araç şarj altyapısının şebekeye etkin bir şekilde entegre edilmesine EA şarj yükü tahminlerinin etkisi ve katkısı olacaktır. Bu yönetim işleyişi EA kullanıcılarının davranış analizleri doğrultusunda kamu hizmeti sağlayıcılarının politika yapıları ile koordineli olarak çalışması esasına dayanmaktadır.

3.1.4. Yönlendirici değişkenler

Yönlendirici değişkenler veya moderatörler (moderating variables) başlığı altında toplanan faktörler, bağımsız değişkenin bağımlı değişken üzerindeki etkisini yani neden-sonuç ilişkisinin "etki" bileşenini değiştiren faktörleri içerir. Bir yönlendirici değişken, bağımlı değişkeni etkilemesine rağmen bağımsız değişkenden etkilenmez (Swaen ve George, 2024). Yönlendirici değişkenin seviyelerine bağlı olarak bağımsız ve bağımlı değişkenler arasındaki ilişkide değişiklikler meydana gelebilir. (Pedada, 2023; Salomão, 2023).

Çalışmada, EA'ların dağıtım şebekesine etkisini değiştirecek yönlendirici değişkenler aşağıdaki gibi 4 farklı faktör olarak ele alınmış olup hem birbirleri arasında hem de diğer faktörler ile ilişkilendirilebilmektedir.

1. Araç-Şebeke-Entegrasyon (Vehicle-Grid-Integration (VGI)) (Ram ve ark., 2021)
2. EA Benimseme Oranları (King ve Datta, 2018; Heymann ve ark., 2017)
 - toplam sahip olma maliyeti (total cost of ownership (TCO))
3. Şebeke Altyapısı ve Kapasitesi (Grenier ve Page, 2012)
 - şebekenin mevcut üretim kapasitesi
 - şebekenin mevcut iletim kapasitesi
 - şebekenin mevcut dağıtım kapasitesi
4. Yenilenebilir Enerji Entegrasyonu (Richardson ve ark., 2013)

- güneş enerjisi
- rüzgar enerjisi
- hidroelektrik enerji
- hidrojen enerjisi
- dalga enerjisi
- jeotermal enerji
- biyokütle enerjisi

3.1.5. Aracı değişkenler

Aracı değişkenler (mediating variables) başlığı altında toplanan faktörler bağımsız ve bağımlı değişkenlerdeki faktörleri birbirine bağlayarak aralarındaki ilişkinin daha iyi açıklanmasını sağlar. Aracı değişken, bağımsız değişkenden etkilenir. Sırasıyla, bağımlı değişkeni de etkiler. Bu nedenle, iki değişkeni birbirine bağlar ve aralarındaki ilişkiyi açıklamaya yardımcı olur (Swaen ve George, 2024). EA'ların dağıtım şebekesine etkisinin analizi için belirlenen aracı değişkenler aşağıdaki gibi 9 farklı faktör olarak ele alınmış olup hem birbirleri arasında hem de diğer faktörler ile ilişkilendirilebilmektedir.

1. EA için Optimize Edilmiş Şarj Yönetimi (Optimized Charging Management for Electric Vehicles) (Vornberger ve ark., 2011)
2. EA Şarj Yönetim Politikaları (EPDK, 2022)
3. EA Şarj Yönetim Stratejileri (Erdinç ve Taşçıkaraoğlu, 2018)
4. EA Şarj Yönetim Teknolojileri (Durmuş ve Kaymaz, 2020)
5. EA Şarj Yüğü Tahmin Doğruluğu (Zhu ve ark., 2019b)
6. Enerji Sistem Optimizasyonu (Kural, 2015)

EDDS'de de belirtildiği gibi "Enerji Sistemi Optimizasyonu (Energy System Optimization): Enerjide arz talep dengesi ile piyasada istikrarı sağlamayı amaçlayan optimizasyon ve tahmin modelleri kapsamında karar verme tabanlı, matematiksel, sezgisel ve bulanık modellerden oluşan en iyileme süreçleridir." (EDDS, 2023 s. 49).

7. Güç Yönetimi (Das ve ark., 2020)
 - planlı şarj/deşarj kullanımı
 - puant (pik) saatlerdedeşarjın planlanmasıyla puant yük talebini karşılama

- güç kaybı (power loss)
 - güç tedarikini sürdürme
8. Talep Tarafı Yönetimi (Jaruwatanachai ve ark., 2023; López ve ark., 2015; Mohanty ve ark., 2022; Zehir ve Bağrıyanık, 2024)
- enerji verimliliği (EE)
 - dönen rezerv
 - talep yanıtı (DR)
 - teşvik tabanlı talep yanıtı (incentive-based DR)
 - fiyat bazlı talep yanıtı (price-based DR)
 - yük kaydırma (load shifting)
 - yük dengeleme (load leveling)
 - tıkanıklık yönetimi (congestion management)
 - kullanım süresi (Time of Use (ToU))

EA kullanıcıları daha yüksek talep ücretlerinden kaçınmak için araçlarını düşük saatlerde şarj etmeye teşvik eden bir talep yanıt stratejisi olarak kullanım saati (ToU) tarifesi
 - Günün saati (Time of Day (ToD))

Elektrik şebekesinin aşırı yüklenmesini azaltmak için yoğun saatlerde EA şarjının daha pahalı olmasını sağlayacak şekilde tasarlanan tarifeler
9. Yük Yönetimi ve Algoritmaları (Jaruwatanachai ve ark., 2023; Üney, 2019; Zhang ve ark., 2020)
- yük profillerini oluşturma
 - yük profillerini modelleme

3.1.6. Kontrol değişkenleri

Kontrol değişkenleri (control variables), bağımlı değişkeni etkilemeyecek şekilde kontrol edilen veya sabit tutulan (kabul gören değişken sabitini) değişkenleri ifade etmektedir (Pedada, 2023). Kontrol değişkenleri başlığı altında toplanan faktörler, ölçülmesine gerek duyulmasa da KDS’de dikkate alınmalı ve hesaba katılmalıdır. EA’ların dağıtım şebekesine etkisinin analizi için belirlenen kontrol değişkenleri aşağıdaki gibi 3 farklı faktör olarak ele alınmış olup hem birbirleri arasında hem de diğer faktörler ile ilişkilendirilebilmektedir.

1. Demografik Özellikler (Zhang ve ark., 2020)

- nüfus
 - EA kullanıcılarının demografik özellikleri
 - cinsiyet
 - yaş
 - eğitim seviyesi
 - gelir düzeyi
2. Düzenleyici Politikalar (EPDK 2016, 2022; EPK, 2013)
- kanunlar ve yönetmelikler
3. Sosyoekonomik Faktörler (Elkamel ve ark., 2020; Fischer ve ark., 2019)

3.2. Kavramsal Karar Destek Sistemi

Enerji sektöründe sürece özgü farklı algoritmalar ile tanımlanmış interaktif bilgisayar tabanlı KDS'ler mevcuttur. Organizasyonel süreçlerin iç ve dış etkenler doğrultusunda varolan operasyonel ve yönetsel problemlerine ek oluşabilecek potansiyel problemlerin de öngörülmesi bu sistemlerin geliştirilmesinde önem arz etmektedir. Akıllı şebeke altyapısını destekleyen Dağıtım Yönetim Sistemleri (Distributed Management Systems) gibi diğer enerji otomasyon sistemlerinin KDS'lere entegre edilmesi sistemlerin performansını yükseltme, operasyonları optimize etme ve karar verme sürecine yardımcı olmaktadır. Çalışmadaki kavramsal çerçevenin içeriğini oluşturan değişken faktörleri ve onların altında ele alınan özellik ya da niteliklerin de bu sistemleri besleyeceği düşünülmektedir. Bu nedenle mevcut ve potansiyel problemlerin; türlerinin belirlenmesi, etkilerinin tespiti ve analizlerinin hassasiyetle yapılması ve ihtiyaç doğrultusunda sürece özgü yapılandırılmasında, kavramsal bir çerçevenin oluşturulması başlangıç ve en önemli adımdır.

Çalışmada elektrikli araç kullanıcıları⁹; elektrikli araç sahipleri ve sürücülerini temsil etmekte olup kamu hizmeti sağlayıcıları; dağıtım şirketleri, şebeke operatörleri ve diğer piyasa paydaşları ile ilişkilendirilerek temsil edilmiştir. Şarj istasyonlarını yoğun kullanımlarında hem kullanıcı hem de yerel dağıtık üretim kaynakları açısından bir çok unsur göz önüne alınmalı ve takibi yapılmalıdır. Bu nedenle oluşturulan kavramsal çerçevede belirlenen etkenler dikkate alınarak elektrikli araç kullanıcıları ve kamu

⁹ IEA, araç sürücülerini ve filo yöneticilerini EA kullanıcıları altında ele almaktadır. Bu çalışma, şahsi araç sahipleri ve sürücülerini kapsamaktadır.

hizmeti sağlayıcıları bakış açısıyla organizasyonların operasyonel ve yönetsel karar alma sürecini etkileyen unsurların yer aldığı bir kavramsal Karar Destek Sistemi geliştirilmiştir.

KDS, akıllı şebeke sistemleriyle iletişim kuracak şekilde tasarlanarak, gerçek zamanlı şebeke koşullarına ve kullanıcı talebine göre dinamik yük yönetimi sağlanabilir. Çalışmada akıllı şebeke teknolojileri ve enerji yönetim sistemlerinin entegrasyonu ile oluşturan KDS'lerin modüler ve fonksiyonel unsurları kavramsal olarak ele alınmıştır. Bunlar;

1. Gerçek Zamanlı İzleme ve Analiz (Real-Time Monitoring and Analytics)
2. Yük Tahmin Modelleri (Load Forecasting Models)
3. Talep Yanıt Stratejileri (Demand Response Strategies)
4. Altyapı Planlama ve Optimizasyonu (Infrastructure Planning and Optimization)
5. Kullanıcı Davranışı İçgörüler (User Behavior Insights)
6. Mevzuata Uygunluk ve Raporlama (Regulatory Compliance and Reporting)
7. İşbirliği Platformları (Collaboration Platforms)

Modül yapısını oluşturacak bu unsurların KDS sistemlerine entegre edilmesi ile karar vericiler, elektrikli araçların dağıtım şebekesi üzerindeki etkisini etkin bir şekilde yönetebilir, şebeke istikrarı ve güvenilirliği garanti altına alabilir ve aynı zamanda EA şarj altyapısına yönelik artan talebi karşılayabilir.

3.2.1. Gerçek zamanlı izleme ve analiz

BT ve büyük veri analitiği altyapılarının KDS'ye entegrasyonu ile veri tabanlarında biriken verilerin şebeke operasyonel verimliliğini artıracak şekilde yönetilmesi sağlanmalıdır (TAŞ, 2023). Elektrik enerji akışının gerçek zamanlı analizini sağlamak için gelişmiş şebeke izleme, kontrol ve yönetim sistemleri entegre edilmelidir. Bu teknolojiler ile talep yanıt stratejilerini daha da kolaylaştırabilir ve şebekenin genel verimliliği artırılabilir (Alaerjan ve ark., 2024; Liu ve ark., 2022). Paydaşlar bu kararları alarak, değişen talep tahminlerine yanıt olarak elektrik şebekesinin istikrarını, verimliliğini ve güvenilirliğini sağlarken, puant yük talebiyle ilgili zorlukları da etkili bir şekilde ele alabilirler.

Veri Entegrasyonu: EA şarj istasyonları, şebeke sensörleri, hava durumu tahminleri ve diğer karıştırıcı değişkenler dâhil olmak üzere çeşitli kaynaklardan gelen gerçek

zamanlı veriler KDS'ye entegre edilerek enerjinin kapsamlı bir görünümü ve izlenebilirliği sağlanabilir.

Tahmine Dayalı Analiz: Şarj istasyonlarından veya diğer entegre dağıtık üretim kaynaklarından toplanan geçmiş şarj verileri analiz edilerek gelecekteki yük taleplerini tahmin eden yapay zeka ve makine öğrenimi destekli gelişmiş yük tahmin algoritmaları kullanılabilir. Böylece karar vericilerin tahmini puant yük dönemlerini belirlemesi ve buna bağlı şarj stratejileri geliştirilmesine yardımcı olunabilir.

KDS'yi besleyen bu veri analitiği alt yapıları ile kullanıcı davranışları analiz edilerek talep tahmin modelleri iyileştirebilir. Böylece karar vericiler belirlenen yük yönetimi stratejileri ile bilinçli seçimler yapabilir. Ayrıca dağıtım şebekelerinin kapasitesi etkin bir şekilde yönetilerek gelecekteki ek yatırımların altyapı maliyetlerinin azaltılması sağlanabilir.

3.2.2. Yük tahmin modelleri

Elektrikli araçların şarj yükü talebinin etki ettiği kullanıcı şarj davranış eğilimi, puant yük durumu, mekansal ve zamansal dağılım ile yük tahmini yapılabilir. Kapasite yönetimi açısından elektrikli araç şarj yüklerinin mekansal ve zamansal dinamiklerini yakalayabilen yük tahmin algoritmaları için derin öğrenme mimarileri gibi gelişmiş tahmin modelleri kullanılabilir (Mohammad ve ark., 2023). EA şarj yüklerinin mekansal ve zamansal dağılımını dikkate alan olasılıksal modeller geliştirilebilir (Koç ve ark., 2021; Kong ve ark., 2022; Li ve Jenn, 2024; Ray ve ark., 2023). EA şarj yüklerine etki eden karıştırıcı değişkenlerin tahmin modellerine entegrasyonu ile bütünsel yaklaşım sağlanarak tahmin doğruluğu artırılabilir (Aduama ve ark., 2023; Orzechowski, 2021; Vahidmohammadi, 2021; Xydas ve ark., 2016; Zhou ve ark., 2023). Farklı penetrasyon oranları ve kullanıcı davranış koşulları altında şarj profilleri senaryoları modellenerek şarj olaylarının simülasyonu oluşturulup tahmin doğruluğu artırılabilir (Almutairi ve ark., 2023; Li ve Jenn, 2024).

3.2.3. Talep yanıt stratejileri

Kamu hizmeti sağlayıcılarının oluşturduğu talep yanıt stratejileri ile tüketicinin enerjiye erişimi kolaylaştırılabilir. Bu stratejilere bağlı olarak EA şarj yönetiminin planlanması ve optimize edilmesi ile EA'ların ne zaman ve nerede şarj edileceğine ilişkin karar verme süreci desteklenebilir. Böylece EA kullanıcılarının yoğun enerji tüketim talebiyle oluşabilecek trafik sıkışıklığı ve şarj bekleme süresinin azaltılması,

kamu hizmeti sağlayıcılarının kısa ve orta vadeli güç ihtiyaçlarını belirlenmesi sağlanabilir.

Şarj istasyon altyapısı ve uygulamalarında akıllı şarj, ödeme ve teknik standartların birleşiminin doğru şekilde yapılması; EA şarjı ve ilgili tarifeler, EA kullanıcıları, vergi mükellefleri ve toplumun tamamı için beklenen faydaların gerçekleştirilmesine yardımcı olabilir (King ve Datta, 2018).

Dinamik Fiyatlandırma Modelleri: Elektrikli araç benimsenmesinde en önemli faktör toplam sahip olma maliyeti (TCO) dir. EA'ların daha fazla benimsenmesi ile düşük maliyetli yakıt olan elektriğe kolay erişimi sağlayacak tarifeleri belirleyen EA şarjı finansal analiz (EV Charging financial analysis) sistemleri kullanılabilir.

EA'ların yoğun yük talebinin olduğu periyotlarda elektrik şebekesine aşırı yüklenmenin önüne geçilmesi adına fiyatlandırma stratejileri geliştirilebilir. Böylelikle EA kullanıcıları, genel enerji tüketiminin yoğun olmadığı saatlerde şarj etmeye teşvik edilerek puant talep seviyesi düzleştirilebilir ve şebeke istikrarı artırılabilir.

Yük Yönetim Algoritmaları: EA şarj talebinin yoğun dönemlerinde şebekeye aşırı yüklemeyi engellemek ve gerçek zamanlı şebeke koşullarına göre şarj planlamalarını optimize etmek için gelişmiş yük yönetim algoritmaları oluşturulmalıdır.

Kapasite planlaması ve yönetimi açısından EA'ların şarj programlarını optimize edebilen yük yönetim algoritmalarının geliştirilmesi ile beraber farklı iş modellerinin uygulamalı karşılaştırmaları yapılabilir. Böylece gelişmiş ve optimize edilmiş şarj yönetimi ile şebeke istikrarının korunması sağlanabilir.

3.2.4. Altyapı planlama ve optimizasyonu

Kapasite Yönetim Araçları: Mevcut altyapı kapasitelerini değerlendirmek ve artan EA şarj yüklerini karşılamak için gerekli yükseltmeleri veya genişletmeleri planlamak amacıyla KDS'ye dağıtım yönetimi sistemleri (DYS) entegre edilebilir.

Elektrikli araçların optimum şarj altyapısının planlanması adına güçlü ve stratejik kararlar verilmesi gereklidir. Şarj istasyonlarının optimal konumlandırılması adına alınacak kararlar doğrultusunda; şebeke altyapısı ve operasyonel maliyetlerin azaltılması, konum kullanılabilirliğinin sağlanması ve minimum şarj bekleme süresi hedeflenir (Matkovic ve ark., 2024). KDS ile gelişmiş şarj altyapısının EA

kullanıcılarına mümkün olan en iyi hizmeti sağlayacak şekilde tasarlanması desteklenebilir ve aynı zamanda şebekenin kapasite kısıtlamaları dikkate alınarak tüketicilere net faydalar sağlanabilir.

Dağıtık Enerji Kaynaklarının (DEK) Entegrasyonu: Puant talebi yönetmede ve şebeke verimliliğini artırmada enerji depolamanın elektrik şebekesindeki rolü kritiktir. Elektrik sistemine entegre EA şarj altyapısını beslemek ve enerji depolamanın rolünü yükseltmek amacıyla DEK'ler ile mikro şebekeler oluşturulabilir. Örneğin, güneş enerjisi santralleriyle en sık birleştirilen depolama teknolojileri; PV santralleriyle elektrokimyasal depolama (piller) ve CSP santralleriyle termal depolama sıvılarıdır (EERE). Bütünleşik bir mikro şebeke yönetim sistemi ile arz-talep dengesi sağlanabilir, şebeke istikrarı ve güvenilirliği artırılabilir.

3.2.5. Kullanıcı davranışı içgörülleri

Davranış Analitiği: EA şarj yükü tahmini ile gelecek dönem enerji tüketimi davranış (energy consumption behavior next period) eğilimi analiz edilebilir. Akıllı şarj teknolojilerini tanıtmak gibi EA kullanıcılarını verimli şarj davranışına teşvik eden iletişim stratejileri geliştirilerek kullanıcı şarj davranış modelleri belirlenebilir. Buna bağlı olarak, EA kullanıcılarının tüketici profillerini belirleyen EA şarj davranışı ve kalıplarının, şarj olaylarının başlangıç saatleri ve şarj süreleri dâhil olmak üzere ayrıntılı bir davranış analizi gerçekleştirilebilir (Almutairi ve ark., 2023; Zhou ve ark., 2023). Kullanıcı davranış verilerini analiz ederek şarj programlarını optimize etmek ve şebeke üzerindeki en yoğun yük etkilerini azaltmak için akıllı şarj stratejileri geliştirilebilir (Dai ve ark., 2023).

Geri Bildirim Mekanizmaları: Potansiyel trafik sıkışıklığından kaçınma, batarya şarj durumu ve menzile bağlı olarak optimum şarj konumuna yönelme, şarj tarifelerine bağlılık, şarj istasyonundaki şarj bekleme süresini azaltma gibi kullanıcı davranışı içgörülleri ve eğilimi doğrultusunda farklı şarj davranış modelleri oluşmaktadır. EA kullanıcılarının şarj alışkanlıkları hakkında geri bildirim sağlayan sistemler uygulanarak, araçlarını ne zaman ve nerede şarj edeceklerine dair bilinçli karar almalarına yardımcı olunabilir.

3.2.6. Mevzuata uygunluk ve raporlama

Uyumluluk İzleme: Güç sistemindeki tüm operasyonların enerji tüketimi, emisyonlar ve şebeke güvenilirliği ile ilgili düzenleyici gerekliliklere uygun olması sağlanmalıdır.

Raporlama Araçları: KDS’lerde enerji tüketim profillerine ve kalıplarına ilişkin öngörüler sağlayan ve paydaşların uyumluluk ölçümlerine dayalı bilinçli kararlar almasına yardımcı olan raporlama altyapısı geliştirilmelidir.

3.2.7. İşbirliği platformları

Paydaş Katılımı: Enerji yönetimiyle ilgili şeffaflığı ve kolektif karar almayı teşvik eden ortak platformlar oluşturularak piyasa paydaşları, enerji düzenleyiciler, müşteriler/kullanıcılar ve diğer kamu hizmeti sağlayıcıları arasındaki iş birliği kolaylaştırılabilir.

Serbest Erişim Platformu: KDS’ye EA kullanıcıları için serbest erişim platformunun entegre edilmesi, karar vericilerin artan enerji tüketimini etkili bir şekilde yönetme yeteneğini artırabilir. Bu sistemlerin gerçek zamanlı verilerinden, topluluk içgörülerinden ve gelişmiş analizlerinden yararlanarak EA-şebeke entegrasyonu bağlamında stratejik planlama ve operasyonel verimlilik desteklenebilir.

KDS’ye entegre bu sistemler ile şarj istasyonlarının kullanılabilirliği ve durumu hakkında gerçek zamanlı bilgi sağlanabilir. Bu bilgi paylaşımı, EA kullanıcılarının yakınlardaki şarj seçeneklerini bulmasına, menzil kaygısının azaltılmasına ve şarj davranışlarının optimize edilmesine yardımcı olabilir.

Sezgisel ve kullanımı kolay kullanıcı dostu arayüzler oluşturularak, kullanıcı etkileşimleri artırılabilir. Örneğin, kullanıcıların şarj istasyonlarını çeşitli kriterlere göre filtrelemesine olanak tanıyan ve böylelikle EA kullanıcıları için karar alma sürecini iyileştiren uygulamalar tasarlanabilir.

Kullanıcı yorumları ve deneyimleri gibi topluluk geri bildirimlerini içeren platformlar, kullanıcılara sunulan bilgilerin kalitesini artıracaktır. Kullanıcıların şarj istasyonlarıyla ilgili deneyimlerini ve güncellemelerin paylaşıldığı topluluk odaklı görüşler, diğer kullanıcılar üzerinde olumlu veya olumsuz bir etki yaratacaktır. Bu yönlendirmeler doğrultusunda EA kullanıcılarının karar süreci etkilenecektir.

Tek bir uygulama veya kart aracılığıyla birden fazla şarj ağına erişim sunan çoklu operatör erişimi ile kullanıcı deneyimleri basitleştirilebilir. Bu entegrasyon, kamu hizmeti sağlayıcılarının da farklı ağlardaki kullanım modellerini anlamalarına ve altyapıyı buna göre optimize etmelerine yardımcı olabilir.

Platform içindeki kolaylaştırılmış ödeme seçenekleri, kullanıcılar için daha kolay işlemlere olanak tanıyacaktır. Bu durum EA kullanıcılarını, kolay ödeme çözümleri olan şarj istasyonlarını daha sık kullanılmasına teşvik edebilir.

Elektrikli araç filolarına sahip işletmeler için filo yönetimi özellikleri sağlayan platformlar oluşturulması, operasyonel ihtiyaçlara ve şebeke koşullarına göre şarj programlarının optimize edilmesine yardımcı olabilir.

Akıllı şebekeler, akıllı sayaçları ve diğer akıllı cihazları, üreticileri, tüketicileri ve şebeke işletmecilerini bir altyapı ağına entegre ederek çift yönlü iletişim sağlayan, enerjiyi kaynaktan tüketim noktasına kadar verimli ve sürdürülebilir bir şekilde aktaran akıllı enerji ağ yapılarıdır. Şebekelerde IoT ve diğer otomasyon sistemleri ile gerçek zamanlı izleme, kontrol ve yönetimi sağlanabilen akıllı şarj altyapıları oluşturulmalıdır.

Şarj yönetimi¹⁰, daha fazla yenilenebilir enerjiye yer açmak, yerel ve sistem düzeyinde güç sistemini rahatlatmak ve emisyonları önlemek için sistem esnekliğini artırmak amacıyla kullanılabildiğinden, güç sektörü için önemli bir fırsattır (IEA, 2023). Şarj istasyonlarının kontrolü ve optimize edilmiş şarj yönetimi doğrultusunda EA-şebeke entegrasyonunda dijitalleşmenin artırılması, izlenebilirliğin sağlanması adına akıllı şebeke altyapısına geçişi hızlandıran stratejik kararlar verilmeli ve buna uygun iş modelleri oluşturulmalıdır.

Şebeke kapasitesinin artışının sağlayan gerekli altyapıların oluşturulmasında yatırım maliyetlerinin geri dönüş hesaplamalarının da yapılması gerekmektedir. Böylelikle ilerleyen dönemlerde güç sistemine yapılacak entegrasyonlarda şebeke altyapı maliyetlerinin azaltılması sağlanmalıdır. Kısa dönemli stratejik kararların uygulanmasında, kamu hizmeti sağlayıcılarından elektrik dağıtım şirketleri ile enerji düzenleyici (energy regulators) kurumların hem şebeke hem de mevzuat altyapısını planlamaları büyük önem arz etmektedir.

Çalışmada geliştirilen kavramsal Karar Destek Sistemi Şekil 3.2.'de gösterilmiştir. Geliştirilen KDS, hem EA kullanıcılarının ihtiyaçlarını hem de şebekenin

¹⁰ Şarj yönetimi için geliştirilen “EV Charging and Grid Integration Tool” isimli elektrikli araç şarj aracının kullanımına ilişkin teknik not ve kılavuza erişim adresi:
https://iea.blob.core.windows.net/assets/466c3c59-f020-45a1-8ba4-8d6016488959/EVChargingandGridIntegrationTool_TechnicalNote.pdf

kısıtlamalarını göz önünde bulundurarak anlık ve doğru yönlendirmeler ile her iki taraf için de faydaları dengeleyen ve bilinçli karar almaya yönelik yapılandırılmış bir yaklaşım sunmaktadır. Buradan farklı iş modellerinin oluşturulması hedeflenebilir. Elektrikli araçların şarj yükü talebine dayalı KDS ile şebeke üzerindeki etkinin gerekli şarj altyapısının şebekeye entegrasyonu için faydalı yatırımlar yapılabilmesi ve ilgili kamu hizmeti sağlayıcıları tarafından farklı çözüm stratejileri üretilmesinde çerçevenin genişletilmesi sağlanabilir.



4. ELEKTRİKLİ ARAÇLARIN ŞARJ YÜKÜ TAHMİNİ


EA şarj talebinin stokastik yapısı ve öngörülemezliği, tahmin zorluklarının çözümlenmesi ile güvenilir tahmin yöntemlerine ihtiyaç duyulmasına neden olmaktadır. Yapay zeka ve makine öğrenimi gibi gelişmiş teknikler, geçmiş verileri ve kullanıcı şarj yükü profillerini analiz ederek bu tahminlerin doğruluğunu artırmak için uygulanmaktadır.

Bu çalışmada EA'ların şarj yükü tahmini için derin öğrenmenin avantajlarını içeren bir yığılmış model önerisi sunulmuştur. Zaman serisi verilerinden oluşan tahmin modellerinde karmaşık yapının öğreniminde, genelleme yeteneğine ve dâhili hafızaya sahip LSTM, BiLSTM, GRU ve BiGRU derin öğrenme modelleri kullanılmıştır. Bu model kapsamında derin öğrenme modellerinden CNN, LSTM, GRU, BiLSTM ve BiGRU modelleri, makine öğrenme algoritmalarından LightGBM algoritması ve yığılmış genelleme topluluk yöntemi kullanılmıştır.

4.1. Evrişimsel Sinir Ağları (CNN)

Evrişimsel Sinir Ağları (Convolutional Neural Network(CNN)), sinyal ve görüntü işleme, bilgisayarlı görme, elektrik yükü tahmini vb. gibi birçok uygulamada yaygın olarak kullanılan yapay sinir ağı tabanlı bir derin öğrenme algoritmasıdır. Model mimarisinde evrişim, havuzlama ve tam bağlı katmanlar gibi birden fazla yapı taşını kullanarak geri yayılım yoluyla uyarlanabilir ve otomatik olarak öğrenir (Butt ve ark., 2022). İleri beslemeli bir yapıda olan bu sinir ağı modeli geleneksel ağ yapısında olduğu gibi giriş, gizli ve çıktı katmanlarından oluşmaktadır. Evrişim katmanı girdi verilerinden özellik haritalarının çıkarılmasını sağlamaktadır. Bu katman verileri kendisinden önce gelen girdi, evrişim veya havuzlama katmanından almaktadır. Geleneksel bir sinir ağına göre daha fazla gizli katman içermesinden dolayı yeteneği yüksektir (Chen ve He, 2018; Li ve ark., 2021). 2D CNN'nin iki boyutlu görüntülerden özellik çıkarmak için kullanılması gibi, zaman serisi verilerinden desenler çıkarmak için tek boyutlu evrişimli sinir ağlarını (1D CNN) kullanmak mümkündür (P

Sasidharan ve ark., 2023). Şarj yükü tahmini için CNN mimari yapısı Şekil 4.1’ de gösterilmiştir (Butt ve ark., 2022).




Şekil 4.1.Yük tahmini için CNN ağ mimarisi.

4.2. Uzun Kısa Süreli Bellek (LSTM)

Uzun Kısa Süreli Bellek (Long Short Term Memory (LSTM)), geçmişten çıkarım yaparak tahminlerde bulunan en başarılı RNN mimarilerinden biridir. Ancak RNN’ nin uzun süreli belleği belleği depolayamama gibi bir dezavantajı bulunmaktadır. LSTM sinir ağı, geri yayılım tabanlı gradyan iniş öğrenimi gerçekleştirir ve dik gradyan oluşumu ve en aza indirilmiş eğitim süresi ve daha yüksek tahmin doğruluğu ile kaybolan gradyan ve patlayan gradyan oluşumunun üstesinden gelir (Shanmuganathan ve ark., 2022). LSTM’ nin uzun süreli verileri tahmin etme konusunda oldukça başarılı olduğu bilinmektedir (Chen ve ark., 2015). En popüler derin öğrenme modelleri arasında olan bu sinir ağı uzun süreli verileri tahmin edebilme yeteneği sayesinde çözümü zor olan zaman serisi tahmin problemlerinde de kullanılabilmektedir. Önemli olan nokta hiper parametrelerin dikkatli şekilde seçilip belirlenmesidir. Mimarisinin oluşturulması ile ilgili önceden belirlenmiş kesin bir yönerge bulunmamaktadır (Yadav ve ark., 2020).

Şekil 4.2’ de görüldüğü gibi LSTM blok mimarisi, bir giriş kapısı (input gate), bir unutma kapısı (forget gate), bir güncelleme kapısı (update gate) ve bir çıkış kapısından (output gate) oluşmaktadır. LSTM blok mimarisini oluşturan denklemler (4.1), (4.2), (4.3), (4.4), (4.5), (4.6)’da gösterilmiştir.



Şekil 4.2. LSTM blok mimarisi.

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i), \quad (4.1)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f), \quad (4.2)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o), \quad (4.3)$$

$$\tilde{c}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c), \quad (4.4)$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes \tilde{c}_t, \quad (4.5)$$

$$h_t = o_t \otimes \tanh(c_t), \quad (4.6)$$

Denklem 4.1’de giriş kapısının (input gate) fonksiyonel yapısını ifade ediyor olup, x_t giriş vektörü (mevcut bilgi) ile onun h_{t-1} önceki gizli durum vektörünü (önceki hücreden gelen bilgiyi) $t - 1$ ’de birleştirir ve sigmoid işlemi sonucuna göre güncelleme yapıp yapılmayacağı kararına varılarak hücre durum (cell state) güncellemesi yapar. 0 olan bilgi önemsiz ve 1 olan bilgi önemli olarak kabul edilir. Ayrıca ağı düzenleme (regulate) işlemi için veriyi -1 ve 1 aralığına sıkıştıran tanh aktivasyon fonksiyonu da kullanılır. Daha sonrasında sigmoid ve tanh fonksiyonu çıktıları çarpılır ve hangi bilginin güncelleneceği kararına varılır.

Denklem 4.2’de unutma kapısı, saklanacak uzun vadeli bilgileri filtreler ve hangi bilgilerin unutulacağı veya tutulacağı kararını verir. Önceki hücreden gelen bilgi olan önceki gizli durum (h_{t-1}) ve mevcut hücrenin girişi olan mevcut bilgi (x_t) sigmoid

aktivasyon fonksiyonuna sokulur ve sonucuna göre karar verilir. 0 olan bilgiler unutulur ve 1 olan bilgiler hücre durum (cell state) ile taşınmaya devam eder.

Denklem 4.3'te çıkış kapısı, hücre durumu için hangi bilginin ıktılanacağını yani bir sonraki hücrenin girişini (h_t) belirlemek için bir sigmoid aktivasyon fonksiyonu kullanır. Çıkış kapısı tahmin yapmak için de kullanılır.

Kısaca öncelikle önceki bilgi ve mevcut giriş bilgisi sigmoid fonksiyondan geçirilir, daha sonra hücre durumu üzerinde var olan bilgi tanh fonksiyonundan geçirilir ve son olarak iki sonucu arparak hangi bilgilerin bir sonraki hücre için giriş (h_t) olacağına karar verilir.

Mevcut hücre için kapı işlemleri tamamlandığında bir sonraki hücreye gidecek olan c_t hücre durumu ve hücrenin giriş bilgisi olarak tanımlanan h_t gizli durum bilgilerine karar verilmiş olunur. Denklem 4.4, $t - 1$ 'deki x_t mevcut girişı ve h_{t-1} önceki gizli duruma (hidden state) dayalı olarak $\tilde{c}_t$ geçici hücre durumunu hesaplar.

Denklem 4.5, c_t t zamanında hücre durumu, c_{t-1} önceki durumu ve $\tilde{c}_t$ geçici hücre durumu (zamansal durumu) tarafından güncellenir. Denklem 4.6'da ise çıkış kapısı, t zamanındaki h_t hücrenin nihai çıkışını o_t ve c_t 'ye baėlı olarak kontrol eder (Ma ve Faye, 2022).


4.3. Geçitli Tekrarlayan Birim (GRU)

Derin öğrenme modeli olan Geçitli Tekrarlayan Birim (Gated Recurrent Unit(GRU)), yapısal olarak LSTM modeli ile neredeyse aynıdır. İki model sadece bellek hücre yapısı tasarımı açısından farklılaşmaktadır. GRU daha az parametreye sahip olduğundan belleğin hücre yapısı daha basit ve küçük tasarıma sahiptir. LSTM'den farklı olarak neyin unutulacağı yani sıfırlama ile durumun hangi kısmının üzerine yazılacağı yani güncelleme süreci tek bir kapıda birleştirilir ve hücrenin tüm durumu çıktı olarak verilir (P Sasidharan ve ark., 2023). GRU modelinin en önemli üstünlükleri eğitim süresinin kısa olması ve az veri ile bile başarılı performans elde edilebilmesidir (Sunny ve ark., 2020).

GRU blok mimarisi Şekil 4.3'te gösterilmiştir. GRU blok mimarisinde, z_t güncelleme kapısı (update gate) ve r_t sıfırlama kapısıdır (reset gate). Güncelleme kapısı, h_{t-1} önceki zaman adımında gizli durum bilgisinin ne kadarının korunacağını düzenler

geçerli zaman adımı t 'ye iletilir. Güncelleme kapısı ne kadar çok etkinleştirilirse, önceki zaman adımındaki gizli durum bilgisi o kadar çok yansıtılır.

Sıfırlama kapısı, önceki zaman adımındaki gizli durum bilgisinin geçerli zaman adımı t 'ye iletilmeden önce ne kadarının atılacağını kontrol eder. Sıfırlama kapısı ne kadar küçükse, önceki zaman adımındaki bilgi o kadar çok göz ardı edilir (Jin ve ark., 2022).



Şekil 4.3. GRU blok mimarisi.

4.4. Çift Yönlü Uzun Kısa Süreli Bellek (BiLSTM)

Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short Term Memory (BiLSTM)) ağ yapısı, LSTM ağ yapısından farklı olarak çift yönlüdür yani zaman serisini işlerken hem ileri hem de geri yönde çalışabilmek için iki gizli katman kullanmaktadır. Bu iki katmanda aynı çıktı katmanına bağlanmaktadır. Bu sayede tahmin performansı LSTM'den başarılıdır (Yang ve Wang, 2022).

4.5. Çift Yönlü Geçitli Tekrarlayan Birim (BiGRU)

GRU sadece önceki anın bilgisine dayanarak bir sonraki anın çıktısını tahmin edebilirken, Çift Yönlü Geçitli Tekrarlayan Birim (Bidirectional Gated Recurrent Unit (BiGRU)) bunun yanında andaki bilgileri arkadan öne alarak anın içeriğini tahmin etmektedir. BiLSTM ile genel yapısı aynı olmakla birlikte bellek yapıları farklılık göstermektedir (Xu ve ark., 2022).

4.6. Hafif Gradyan Artırma Makinesi (LightGBM)


Hafif Gradyan Artırma Makinesi (Light Gradient Boosting Machine (LightGBM)), gradyan artırma algoritmalarının bir türü olan makine öğrenme algoritmasıdır. Ağaç tabanlı bu algoritma kayıp fonksiyonun negatif eğimini kullanmaktadır bu sayede yeni karar ağacına uyum sağlamaktadır (Tian ve ark., 2022). Eğitim hızının yüksek olması, bellek kullanımının az olması, büyük veriyi işleme yeteneğinin bulunması ve doğrulukların yüksek olması bu algoritmanın en önemli üstünlükleri arasında, sayılabilir (Yang ve ark., 2021).

4.7. Yığılma Topluluk Öğrenme

Yığılma Topluluk Öğrenme (Stacking Ensemble Learning) yöntemi farklı türdeki tekli algoritmaların birleştirilmesi için kullanılmaktadır. Temel öğrenme ve meta öğrenme olarak iki aşamalı gerçekleşen birleştirme prosedüründe; temel seviyede eğitim veri setinin ilk hali kullanılırken, bunun çıktısı meta öğrenen algoritma tarafından girdi olarak kullanılmaktadır. İki aşamalı tahminleme sayesinde hataların düzeltilmesi sağlanmaktadır (Onan, 2018; Zhou, 2012).

5. METODOLOJİ VE UYGULAMA

Elektrikli araç şarj istasyonlarına yönelik enerji tüketim tahmini olarak da adlandırılan şarj yükü tahmini için çalışmada önerilen metodoloji Şekil 5.1’de sunulmaktadır. Metodoloji verilerin elde edilmesi, verilerin analiz edilmesi, veri hazırlama ve ön işleme, derin öğrenmeye dayalı tahmin modellerinin geliştirilmesi ve modellerin değerlendirilmesi olmak üzere beş temel aşamadan oluşmaktadır. Verilerin analizi, gözlem değerlendirme amaçlı gerçekleştirilmiştir. Bu nedenle metodolojinin diğer aşamalarından ayrı tutularak akış şemasında bu aşamaya yer verilmemiştir.



Şekil 5.1. Önerilen çalışma metodolojisi.

5.1. Verilerin Elde Edilmesi

Çalışmada kullanılan veri seti uyarlanabilir şarj ağlarını işleten PowerFlex Systems destekli veri paylaşım platformu olan ACN-DATA sitesinden elde edilmiştir (Zachary vd., 2019). Veri setindeki girdiler, elektrikli araçların belirli alanlarda konumlandırılmış şarj istasyonlarındaki şarj olaylarından elde edilmiştir. Her bir girdi tek bir şarj oturumu hakkında bilgileri içerir ve gerçek zamanlı olarak kayıt altına alınmaktadır. Şarj istasyonlarının bulunduğu Caltech, JPL, Office 1 olmak üzere üç farklı yerden veri elde edilmektedir. Bu çalışmada Caltech olarak tanımlanan araştırma üniversitesinde yer alan kampüs garajındaki 54 şarj istasyonundan toplanan veriler kullanılmıştır.

Veri setindeki elektrikli araç şarj olayları 01.08.2018 ile 30.09.2018 tarih aralığı seçilerek oluşturulmuştur. Bu şekilde oluşturulan verisetinde 4749 şarj oturum girdisi bulunmaktadır. Ayrıca bu veri seti her bir oturum için 13 farklı niteliği kapsamaktadır. Bu nitelikler sırasıyla oturum kimliği, istasyon kümesi kimliği, şarj bağlantı zamanı, şarj bağlantı bitiş zamanı, şarj bitiş zamanı, enerji tüketim miktarı, oturum kimliği, konum kimliği, park alanı kimliği, istasyon kimliği, saat dilimi, kullanıcı kimliği ve kullanıcı girişleri şeklindedir. Çalışmada bu niteliklerden şarj bağlantı zamanı, şarj bağlantı bitiş zamanı ve kWh cinsinden değerler içeren şarj yükü/enerji tüketim miktarı nitelikleri kullanılmıştır.

5.2. Verilerin Analiz Edilmesi

EA kullanıcılarının şarj yükü profilini (yani tüketici profiline eşdeğer olarak; EA şarj talebi ve davranış profilini) nicelleştiren ve görselleştiren şarj yükü talep dağılım grafiklerinden faydalanılarak, çalışmadaki Karar Destek Sistemi'nde belirlenen bağımsız değişkenlerden;

1. EA Şarj Talebi
2. EA Şarj Davranışı
3. Gün Türleri
4. Şarj Periyodu

faktörleri hakkında faydalı analizler yapılabilir. Gün türü ve şarj periyoduna bağlı olarak talebin hangi zaman diliminde (yıl, ay, hafta, gün vb.) yoğunlaştığı


gözlemlenebilir. Bu gözlemler ile belirlenen faktörlere ait niceliksel sonuçlarla, beklenen EA kullanımı artışına dayalı değerlendirme ve karar verme süreçlerinde kamu hizmeti sağlayıcılardan planlamacılar ve politika sağlayıcılar desteklenebilir.

Çalışmada şarj oturum olaylarının gerçekleştiği şarj periyotlarına göre veri analizleri yapılmıştır. EA kullanıcılarının şarj yükü profilini anlamak üzere EA şarj talebi ve EA şarj davranışı profillerinden yola çıkılarak şarj yükü talep dağılımları (güç talep eğrileri) ele alınmıştır. EA'ların geçmiş şarj oturum olaylarına ait zaman serisi verilerinden şarj bağlantı zamanı ve şarj bağlantı bitiş zamanı referans alınarak enerji tüketim (şarj yükü) niteliğine bağlı iki farklı türde şarj yükü talep dağılım grafikleri oluşturulmuş ve incelenmiştir. Oluşturulan bu dağılımlarda geçmiş şarj oturum verilerindeki aykırı değerler henüz temizlenmemiştir.


Çalışmadaki EA'lara ait geçmiş şarj oturum olayları günlük şarj periyodunda gerçekleşmiş olup her günün 24 saatine ait EA şarj yükü verileri bulunmaktadır. Şekil 5.2, Şekil 5.3, Şekil 5.4 ve Şekil 5.5'te gösterilen EA şarj yükü talep dağılım grafiklerinden (EA güç talep eğrilerinden) yola çıkılarak puant yük talebin olduğu zaman periyotları (aralıkları) için kullanıcı şarj davranış eğilimi (yani tüketici profili) saat bazında analiz edilmiştir. Şekil 5.2'de şarj bağlantı zamanına göre şarj yükü talep dağılımı verilmiştir. Şekil 5.4' te şarj bağlantı zamanına göre günlük şarj yükü talep dağılımı gösterilmiştir. Şekil 5.3'te ise şarj bağlantı bitiş zamanına göre şarj yükü talep dağılımı verilmiş olup Şekil 5.5'te de şarj bağlantı bitiş zamanına göre günlük şarj yükü talep dağılımı gösterilmiştir.

Şarj bağlantı zamanı ve şarj bağlantı bitiş zamanı referans alınarak oluşturulan şarj yükü talep dağılımlarından Şekil 5.2 ve Şekil 5.3'teki grafikler incelendiğinde belirli günlerde ve saatlerde enerji talebinin yoğun olduğu görülmüştür. Bu yoğun talep ile oluşan puant yük şebeke üzerinde olumsuz bir etkiye neden olacaktır. Güç yönetimindeki karar verme sürecinde bu puant yük talebini karşılamak için kamu hizmeti sağlayıcıları tarafından puant (pik) saatlerde deşarjın planlanarak ivedi kararlar verilmesi böylece şarj yönetiminin optimize edilmesi gerekmektedir. Bu durumda KDS'de yer alan talep tarafı yönetimi, güç yönetimi, şebeke verimliliği, şebeke istikrarı ve güvenilirliği, EA için optimize edilmiş şarj yönetimi, EA şarj yönetim stratejilerine ait yöntemler dikkate alınmalıdır. Puant gücün oluşturacağı olumsuz etkilere karşı kamu hizmeti sağlayıcıları tarafından belirlenecek yöntemler ile uygun çözümler üretilerek ilgili sorunların önüne geçilebilir. Buradan da anlık durum

analizleri yapılarak optimize edilen süreçler kontrol altına alınabilir. Benzer şekilde EA kullanıcılarının da şarj davranışlarının optimum şarj istasyon konumunu seçme eğiliminde olması için şarj istasyonunun; kullanılabilirliği, durumu, doluluk oranı, konumu ve ulaşılabilirliği karar alma sürecinde etkili olacaktır.




Şekil 5.2. Şarj bağlantı zamanına göre şarj yükü talep dağılımı.



Şekil 5.3. Şarj bağlantı bitiş zamanına göre şarj yükü talep dağılımı.


Günlük şarj periyodunun şarj bağlantı zamanına göre şarj yükü talep dağılımı Şekil 5.4' te incelendiğinde, EA kullanıcılarının şarj oturumlarını günün diğer saatlerine oranla öğleden sonra saat 15:00 zaman diliminde daha yoğun olarak gerçekleştirdiği gözlemlenmiştir. Ek olarak bir sonraki yoğun talebi içeren zaman diliminin 16:00 ve 14:00 civarında olmasına bakılır ise kullanıcıların, EA güç taleplerini büyük bir

olasılıkla haftaiçi mesai saatleri içerisinde iş yerindeyken gerçekleştirmiş olduğu varsayımı yapılabilir.



Şekil 5.4. Şarj bağlantı zamanına göre günlük şarj yükü talep dağılımı.

Şekil 5.5' teki şarj bağlantı bitiş zamanına göre günün saatlerinde şarj yükü talep dağılımı incelendiğinde EA kullanıcılarının şarj oturumlarını günün diğer saatlerine oranla gece saat 00:00 zaman diliminde daha yoğun olarak gerçekleştirdiği gözlemlenmiştir. Ek olarak bir sonraki yoğun talebi içeren zaman diliminin 01:00 ve 23:00 civarında olmasına bakılır ise kullanıcıların, EA güç taleplerini büyük bir olasılıkla evlerinde bulundukları zaman içerisinde gerçekleştirmiş olduğu varsayımı yapılabilir.



Şekil 5.5. Şarj bağlantı bitiş zamanına göre günlük şarj yükü talep dağılımı.

Yük tahmin algoritmalarının oluşturulmasında veri analizi, veri hazırlama ve ön işleme adımları gibi teknik hesaplamalar büyük önem arz etmektedir. Bu analizde şarj istasyonlarından toplanan şarj oturum verilerinin aykırı veriler içeriyor olması çalışmayı başka bir iyileştirme adımına yönlendirmiştir. EA şarj yükü tahmin doğruluğunu artırmak için veri analizi adımından sonra veri hazırlama ve ön işleme adımları ele alınmıştır. Sonrasında yük tahmin algoritmalarının belirlenmesi ve tahmin performanslarının analizi gerçekleştirilmiştir.

5.3. Veri Hazırlama ve Ön İşleme

Verilerin kalitesinin artırılması ve derin öğrenme modellerine uygun olacak şekilde yapılandırılması için veri hazırlama ve ön işleme aşamasında sırasıyla nitelik oluşturma, zaman aralığı işleme, aykırı verilerin temizlenmesi, kayan pencere yaklaşımının uygulanması, normalizasyon ve veri setinin ayrılması olmak üzere altı adım uygulanmıştır.

5.3.1. Nitelik Oluşturma

Nitelik mühendisliği olarak da adlandırılan nitelik oluşturma, modelin performansının iyileştirilmesi amacıyla yüksek kalitedeki niteliklerden yeni niteliklerin geliştirilmesi sürecidir (Lazzeri, 2020). Bu adımda, zaman aralığı işleme sürecine temel olması amacıyla veri setinde bulunan niteliklere ek olarak şarj süresi niteliği oluşturulmuştur.

Bu niteliğin oluşturulması için şarj bağlantı bitiş zamanı ile şarj bağlantı zamanı arasındaki fark saniye cinsinden hesaplanmıştır. Veriler incelendiğinde, şarj bağlantı zamanı, şarj bağlantı bitiş zamanı, şarj süresi ve enerji tüketim miktarı niteliklerinde eksik değer bulunmadığı tespit edilmiştir.

5.3.2. Zaman Aralığı İşleme


Verilerin elde edilmesi adımıyla oluşturulan elektrikli araçlara ait enerji tüketim talepleri veri seti, farklı zaman aralıklarındaki (periyotlarındaki) oturum verilerinden oluşmaktadır. Ancak zaman serisi verilerinde gözlemler eşit aralıklı zaman adımlarından oluşturulmaktadır (Mills, 2019). Bu nedenle veri setindeki olaya dayalı şarj verilerinin zaman serisi tahmin modeline girdi olarak beslenmeden önce şarj yükü değerlerinin bir zaman serisi olacak şekilde düzenlenmesi için (Unterluggauer ve ark., 2021) enerji tüketim miktarı niteliği için zaman aralığı işleme adımı uygulanmıştır. Bu adımda, şarj bağlantı zamanına ek olarak şarj süresi niteliği referans alınmıştır ve bir saat aralıklı zaman adımlarından oluşan enerji tüketim miktarı zaman serisi veri seti oluşturulmuştur. İşlem uygulanırken enerji tüketim miktarı şarj bağlantı zamanından başlayarak şarj süresi boyunca dâhil olduğu zaman adımlarının tümüne şarj süresi ile orantılı olacak şekilde yansıtılmıştır.

5.3.3. Aykırı Verilerin Temizlenmesi

Aykırı değerler, nitelikte bulunan diğer değerlerden uzakta gözlemlenen değerlerdir (Zhang ve ark., 2019). Beklenen aralığın önemli ölçüde dışında olarak ortaya çıkan bu değerlerin veri analizi sürecinde olumsuz etkilerinin olabileceği bilinmektedir. Bu nedenle aykırı değerlerin ele alınması önemli bir gerekliliktir (Dastjerdy ve ark., 2023). Çalışmada enerji tüketim miktarındaki aykırı verilerin belirlenmesi amacıyla kutu grafiği analizi (Tukey, 1977) kullanılmıştır. Bu analizde aykırı değer tespiti, alt çeyrek, medyan, üst çeyrek ve üst çeyrek ile alt çeyreğin farkı ile hesaplanan çeyrekler arası aralık bilgileri ile gerçekleştirilir. Alt eşik alt çeyrekten çeyrekler arası değer 1.5 katının farkı ile hesaplanırken, üst eşik ise üst çeyreğe çeyrekler arası değer 1.5 katının eklenmesi ile hesaplanmaktadır (Zhang ve ark., 2023).

Zaman aralığı işleme adımıyla oluşturulan enerji tüketim miktarı zaman serisi niteliğinin kutu grafiği Şekil 5.6(a)'da verilmektedir. Grafikte görüldüğü gibi enerji tüketim miktarı niteliğinde kutu grafiğinin üst eşiklerinin üzerinde aykırı değerler

bulunmaktadır. Tespit edilen üst aykırı değerler bu adımda üst eşik değerlere eşitlenerek temizlenmiştir. Niteliğin aykırı değerlerden temizlendikten sonra oluşturulan kutu grafiği Şekil 5.6(b)'de sunulmaktadır.



Şekil 5.6. Enerji tüketim miktarı niteliğinin kutu grafikleri (a) Aykırı verilerden temizlenmeden önce, (b) Aykırı verilerden temizlendikten sonra.

5.3.4. Kayan Pencere Yaklaşımının Uygulanması

Zaman serisi verileri kayan pencere yaklaşımı kullanılarak denetimli öğrenme problemine dönüştürülebilir. Gecikme yöntemi olarak da adlandırılan bu yaklaşımda, bir sonraki zaman adımındaki değerin tahmini için önceki zaman adımlarındaki değerler kullanılır. Burada, önceki zaman adımlarının sayısı pencere genişliği olarak ifade edilir (Brownlee, 2018). Çalışmada, bir güne ait saatlik enerji tüketim miktarları girdi olarak kullanılıp bir sonraki saate ait enerji tüketim miktarı tahmin edileceği için pencere genişliği 24, adım sayısı ise 1 olarak belirlenmiştir. Kayan pencere yönteminin uygulanması ile 1464 örnek oluşturulmuştur.

5.3.5. Veri Setinin Ayrılması

Tahmin modeline girdi oluşturmak için işlenen veri seti rassal olarak eğitim, doğrulama ve test veri setlerine ayrılır ve eğitim veri seti ağı eğitmek için kullanılır. Doğrulama ve test verileri sırasıyla modeli belirli bir doğruluğa ulaşana kadar revize etmek ve geçerliliğini doğrulamak için kullanılır (Yoon, 2021). Çalışmada veri seti modelde kullanılmak üzere rassal olarak %70 eğitim seti, %10 doğrulama seti ve %20 test seti olacak şekilde ayrılmıştır.

5.3.6. Normalizasyon

Sinir ağırları tabanlı modellerde verilerin dağıldığı aralık modellerin eğitim sürecini ve ürettiği sonuçları önemli derecede etkileyebilmektedir (Zhu ve ark., 2019a). Bu etki doğrultusunda girdi niteliklerini modellere beslenmeden önce her veri noktasının aynı ölçekte olması sağlayan, büyük eğimleri önleyen ve böylece modelin daha efektif çalışmasına yardımcı olan veri ön işleme adımlarından ölçeklendirme ve normalleştirme yöntemi (Koohfar ve ark., 2023) uygulanır. Bu yöntem sınırlı girdi gerektiren algoritmalar için kullanışlı olup verilerin özgün dağılım şeklini koruyarak veri noktaları arasındaki ilişkileri muhafaza eder.

Çalışmada veri boyutu ve dağılımından kaynaklanan etkiyi azaltmak için tüm niteliklere MinMaxScaler ölçeklendirme ve normalleştirme yöntemi uygulanmıştır. Normalizasyon veri ön işleme adımı aykırı değerlere karşı hassas olup veri setinde tek bir aykırı değer olması durumunda tüm niteliklerin ölçeklenmesini önemli ölçüde etkileyebileceğinden aykırı verilerin temizlenmesi adımından sonra uygulandı.

Denklem 5.1’de formülasyonu verilen MinMaxScaler yöntemi, uygulandığı nitelik verisindeki değerleri $[0, 1]$ sabit aralığına ölçekleyerek dönüştürür. Burada, x_i normalize edilecek değer, x_{min} nitelikteki minimum değer, x_{maks} nitelikteki maksimum değer ve $x_{yeni(i)}$ ise normalize edildikten sonra elde edilen değerdir.

$$x_{yeni(i)} = \frac{x_i - x_{min}}{x_{maks} - x_{min}} \quad (5.1)$$

5.4. Derin Öğrenme Modellerinin Geliştirilmesi


Çalışmada şarj istasyonlarındaki geçmiş şarj oturum olaylarına ait ilgili nitelik verilerinin zamansal bağımlılıklarını yakalayan elektrikli araç şarj yükü tahmini için CNN, LSTM, GRU, BiLSTM ve BiGRU olmak üzere 5 farklı tekli model ve bu modellerin kullanımını içeren bir Yığılmış Derin Öğrenme Topluluk Modeli (YDÖTM) geliştirilmiştir. Model geliştirme sürecinde uygun hiperparametre seçimleri deneme yanılma yöntemiyle yapılmıştır. Dönem (epoch) sayısı seçimi denemelerindeki uzun çalışma süreleri için Google Colab’teki çalışma ortamının kullanıcıya sunduğu CPU çalışma zamanı türü yerine GPU T4 türü bağlantısı kullanılmış olup bu çalışma sürelerinin (en uzun yaklaşık 15 dk) azaltılması sağlanmıştır.

Çalışmanın model geliştirme sürecinde, başlangıçta 5000 dönem (epoch veya eğitim turu) sayısı seçilerek model denemeleri yapılmıştır. Bu dönem sayısı eğitim ve test verilerinde aşırı öğrenme (overfitting) durumuna neden olmuştur. Çalışmada gerçekleştirilen diğer deneme yanılma işlemleri sonrasında eğitim veri setinin modeli (ağı) eğitmesi için nihai dönem sayısı 200 olarak seçilmiştir. Yine çalışmada derin öğrenme algoritmalarında tahmin modeli ağının eğitim sürecinde aşırı uyumu daha da azaltmak için seyreltme oranı haricinde doğrulama setinin performansına dayalı erken durdurma (earlystopping) komutu kullanılmıştır. Buna bağlı olarak geliştirilen her model, eğitim test verilerinin uyumunu en iyileyen dönem sayısına ulaştığında eğitimini tamamlamıştır. Bu aşamadaki model performanslarının ön izlemesinde kayıp (loss) fonksiyon ve metrik grafikleri analiz edilmiştir.

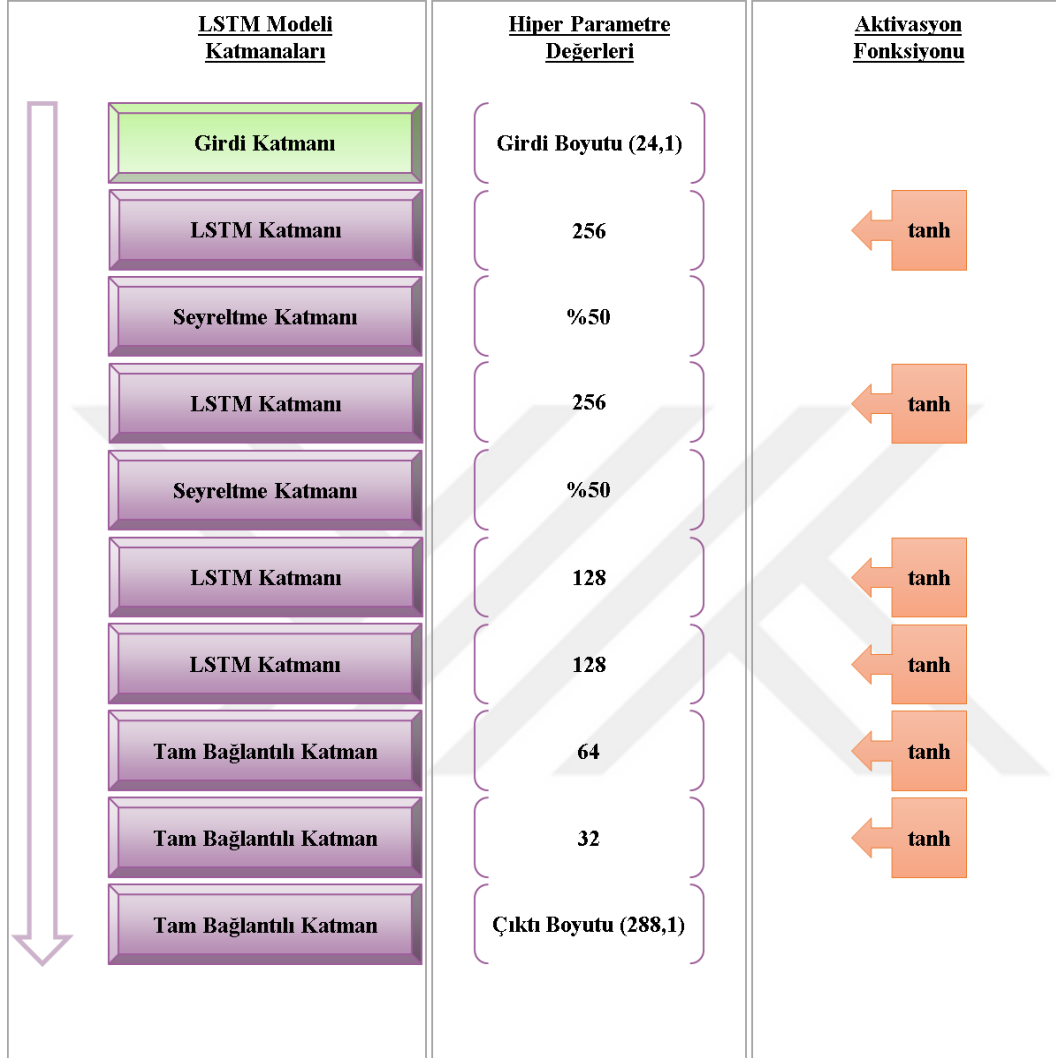
5.4.1. Tekli Modeller

Geliştirilen CNN modelinin mimarisi Şekil 5.7’de gösterilmektedir. Model 11 katmandan oluşmaktadır. Enerji tüketim miktarı örnekleri ilk olarak giriş şekli (24,1) olan girdi katmanına beslenir. Ardından, girdi verilerinden özellik haritalarının çıkarılması için çekirdek boyutu 1 olan 64 filtrelili ve tanh aktivasyon fonksiyonu kullanan 1 boyutlu evrişim katmanına gönderilirler. Evrişim katmanını havuz boyutu 1 olan 1 boyutlu maksimum havuzlama katmanı izlemektedir. Bu katman evrişim katmanında üretilen özellik haritalarının her biri üzerinde çalışarak örtüşmeyen bölgelerin maksimum değerini alarak alt örnekler. Böylece ağırlık hesaplama karmaşıklığını azaltmak için özellik haritalarının boyutu azaltılmış olur (Krichen, 2023). Modele havuzlama katmanından sonra aynı özelliklere sahip bir evrişim katmanı ve bir maksimum havuzlama katmanı daha eklenmiştir. Son havuzlama katmanından geçen veriler bu katmandan sonra gelen bir düzleştirme katmanında düzleştirilir. Ardından 64 nöronu ve tanh aktivasyon fonksiyonlu bir tam bağlantılı katman (fully connected layer) ilave edilmiştir. Modelin aşırı öğrenmesini önlemek için tam bağlantılı katmandan sonra 0.1 seyreltme oranına sahip bir seyreltme katmanı gelmektedir. Bu katmandan sonra model bir tam bağlantılı katman ve bir seyreltme katmanı ile devam etmektedir. Eklenen tam bağlantılı katman 32 nörona ve tanh aktivasyon fonksiyonuna, seyreltme katmanı ise 0.1 seyreltme oranına sahiptir. Son olarak modele tahmin sonucunun elde edilmesini sağlayacak 1 nöronlu bir tam bağlantılı katman eklenmiştir.


10 katmandan oluşan LSTM modelinin mimarisi Şekil 5.8’de verilmektedir. Modelde girdi katmanından sonra sırasıyla 256 nörona sahip bir LSTM katmanı, 0.5 seyreltme oranına sahip bir seyreltme katmanı, aynı özelliklere sahip bir LSTM ve bir seyreltme katmanı eklenmiştir. Seyreltme katmanından sonra 128 nörona sahip 2 LSTM katmanı, 64 nörona sahip bir tam bağlantılı katman ve 32 nörona sahip bir tam bağlantılı katman gelmektedir. Tüm LSTM ve tam bağlantılı katmanlar tanh aktivasyon fonksiyonu kullanmaktadır. LSTM katmanları girdi verilerinden özelliklerin çıkarılmasını sağlarken, tam bağlantılı katmanlar doğrusal olmayan bağımlılıkların öğrenilmesini sağlar. Son olarak, yük tahmini sonucunu sağlayacak bir tam bağlantılı katman bulunmaktadır. Sırasıyla Şekil 5.9, Şekil 5.10 ve Şekil 5.11’de sunulan GRU, BiLSTM ve BiGRU modelleri ise LSTM modeline benzer özelliklere sahip olacak şekilde yapılandırılmıştır. Modeller, LSTM modelinde bulunan LSTM katmanlarının GRU, BiLSTM ve BiGRU katmanları ile değiştirilmesi işlemi sonucu oluşturulmuştur.




Şekil 5.7. Geliştirilen CNN modeli mimarisi.




Şekil 5.8. Geliştirilen LSTM modeli mimarisi.



Şekil 5.9. Geliştirilen GRU modeli mimarisi.



Şekil 5.10. Geliştirilen BiLSTM modeli mimarisi.



Şekil 5.11. Geliştirilen BiGRU modeli mimarisi.


Modellerin ağ yapısındaki katmanlar ve hiperparametre ayarlaması ıktılanan tahmin performansını etkileyen önemli bir süreçtir. Aşırı öğrenme (overfitting) durumu ise tahmin doğruluğunu etkileyen bir sorun olarak ele alınmaktadır. Seyreltme katmanı ve ayarlanan oranı, eğitim sürecinde birimleri rastgele bırakarak derin öğrenme modellerinin aşırı uyum sorununu çözen popüler bir algoritmadır (Ko ve ark., 2017).

Modeller oluşturulduktan sonra eğitim aşamasına geçmeden önce Tensorflow kütüphanesine ait compile komutu ile modeller, kayıplar ve ölçümlerle (metriklerle) yapılandırılarak yani uyarlanabilir iyileştiricileri kullanarak uygun öğrenme oranlarıyla optimize edilmiştir.

Çalışmada daha sonra tahmin modeli ağının eğitim sürecinde aşırı uyumu daha da azaltmak için seyreltme oranı haricinde doğrulama setinin performansına dayalı erken durdurma (earlystopping) komutu kullanılmıştır.

5.4.2. Önerilen Yığılmış Derin Öğrenme Topluluk Modeli (YDÖTM)

Çalışmada şarj yükü tahmini için önerilen topluluk modeli yığılmış genelleme yöntemi ile geliştirilmiştir. Modelin mimarisi Şekil 5.12’de gösterilmektedir. Şekilde görüldüğü gibi, temel öğrenen olan Seviye 0’daki modeller eğitim ve doğrulama veri setlerini kullanan CNN, LSTM, GRU, BiLSTM ve BiGRU modelleridir. Bu modellerin mimarisi çalışmada geliştirilen tekli derin öğrenme modelleri ile aynı mimariye sahiptir. Meta öğrenen olarak adlandırılan Seviye 1’deki model ise bu çalışmada LightGBM modeli olarak belirlenmiştir. Bu model temel öğrenici modellerin tahminlerini ve test veri setini girdi olarak alır.



Şekil 5.12. Önerilen Yığılmış Derin Öğrenme Topluluk Modeli'nin mimarisi.

5.5. Modellerin Değerlendirilmesi

Şarj işlemi sürekli olmadığından, elektrikli şarj verileri kesiklidir. Enerji tüketiminin gerçekleşmediği durumlarda ilgili nitelik verileri sıfır değerleri içermektedir (Khan ve ark, 2023). Çalışmada geliştirilen zaman serisi veri setinde şarj noktalarının kullanılmadığı tüm zaman adımlarında 0 değerli şarj yükleri bulunmaktadır. Bu veri satırları için MAPE ölçüm metriğinin hesabında paydanın sıfır olmasından dolayı bu çalışmada MAPE performans ölçütü kullanılamamaktadır (Zhu ve ark., 2019b). Bu nedenle, regresyon modellerinin değerlendirilmesinde yaygın olarak kullanılan MAE, RMSE, NMRSE ve determinasyon katsayısı (R^2) değerlendirme ölçütleri kullanılmıştır. İyi bir regresyon modeli düşük değerli MAE, RMSE, NMRSE ölçütleri, yüksek değerli R^2 ölçütü göz önünde bulundurularak elde edilebilir (Liu ve ark., 2019).

MAE, RMSE, NRMSE ve R^2 ölçütlerinin formülasyonları sırasıyla Denklem 5.2-5.5'te verilmektedir (Sarkar ve ark., 2022; Gülmez, 2023; Obiora ve ark., 2021). Burada N test veri setindeki örnek sayısını, $x_{gercek(i)}$ i. örneğin gerçek enerji tüketim miktarı değerini, $x_{tahmin(i)}$ i. örneğin model tarafından tahmin edilen enerji tüketim miktarı değerini, x_{ort} gerçek enerji tüketim miktarı değerlerinin ortalamasını, $x_{gercek(maks)}$ ve $x_{gercek(min)}$ ise gerçek enerji tüketim miktarlarının sırasıyla maksimum ve minimum değerini göstermektedir.

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_{gercek(i)} - x_{tahmin(i)}| \quad (5.2)$$

$$RMSE = \frac{1}{N} \sum_{i=1}^N \sqrt{(x_{gercek(i)} - x_{tahmin(i)})^2} \quad (5.3)$$

$$NRMSE = \frac{RMSE}{x_{gercek(maks)} - x_{gercek(min)}} \quad (5.4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (x_{gercek(i)} - x_{tahmin(i)})^2}{\sum_{i=1}^N (x_{gercek(i)} - x_{ort})^2} \quad (5.5)$$

Uygulanan derin öğrenme modellerinin tahmin grafik çizimleri ve performans ölçüt hesaplamaları, normalizasyon adımıyla oluşturulan özgün ölçekli değerler referans alınarak gerçekleştirilmiştir.



6. DENEYSEL SONUÇLAR

Python programlama dili ile gerçekleştirilen model eğitim ve test süreçlerinde CNN, LSTM, BiLSTM, GRU, BiGRU modelleri için TensorFlow platformunda çalışan makine öğrenimi iş akışının her adımını (veri işlemeden hiper parametre ayarlamaya ve dağıtımına kadar) kapsayan Keras sinir ağı kütüphanesinden (Tensorflow, 2024) yararlanılmıştır.

Veri setinin ayrılması adımıyla oluşturulan eğitim veri seti (X) ve test veri seti (y) için ayrı ayrı scaler X ve scaler y fonksiyonları tanımlanmıştır. Bu işlem Python'da fit_transform ve transform komutları ile gerçekleştirilmiştir. Normalize edilen eğitim ve test verileri üzerinden modelin eğitilmesi ile elde edilen tahmin değerleri (0,1) sabit aralığında oluşturulmuştur. Veri niteliklerinin ve oluşturulan tahmin performansının analizinde gerçeklik ve doğruluk sağlamak amacıyla normalize edilen değerleri özgün ölçeklerine dönüştürmek için Python'da inverse_transform komutu kullanılmıştır. Böylece nitelik verilerine ait değerler (0,1) sabit değer aralığından çıkarılmıştır.


Yığılmış Derin Öğrenme Topluluk Modeli'nde LightGBM algoritması için 'LightGBM' Python kütüphanesinden (LightGBM, 2024) yararlanılmıştır. Tüm modellerde derin öğrenme algoritmaları için optimizasyon algoritması Adam, yığın büyüklüğü 32, eğitim turu (dönem veya epoch) sayısı 200, kayıp fonksiyonu MSE, metrik MAE, öğrenme oranı ise 0.001 olarak, YDÖTM'nde LightGBM algoritması için öğrenme oranı 0.1, iterasyon sayısı 100 ve yaprak sayısı 31 olarak belirlenmiştir.

Çalışmada geliştirilen CNN, LSTM, GRU, BiLSTM, BiGRU ve YDÖTM'nin test veri seti üzerindeki performans ölçütü sonuçları Tablo 6.1, Şekil 6.1 ve Şekil 6.2'de sunulmuştur. Deneysel sonuçlara göre, MAE, RMSE, NRMSE ve R² performans ölçütlerinde en düşük performans sırasıyla 8.4537, 10.7639, 0.1189, 0.7417 değerleri ile LSTM modeli göstermiştir. BiLSTM modeli LSTM modeline göre tüm performans ölçütlerinde daha iyi değerler elde etmesine rağmen, BiGRU modeli GRU modeline göre tüm performans ölçütlerinde daha kötü performans sağlamıştır. Tüm performans ölçütleri göz önünde bulundurulduğunda, en iyi tahmin performansı MAE, RMSE,


NRMSE ve R^2 ölçütleri için sırasıyla 3.5894, 4.9935, 0.0551, 0.9444 değerleri ile çalışmada önerilen YDÖTM ile elde edilmiştir.

Tablo 6.1. Geliştirilen modeller ve MAE, RMSE, NRMSE, R^2 performans ölçütü değerleri.

Modeller & Performans Ölçütleri	MAE	RMSE	NRMSE	R^2
CNN	6,3460	8,2169	0,0907	0,8495
LSTM	8,4537	10,7639	0,1189	0,7417
GRU	5,5210	7,2531	0,0801	0,8827
BiLSTM	6,7066	8,8194	0,0974	0,8266
BiGRU	5,9394	7,7141	0,0852	0,8673
YDÖTM	3,5894	4,9935	0,0551	0,9444




Şekil 6.1. MAE, RMSE, NRMSE, R² performans ölçütlerinin model bazlı dağılımı.




Şekil 6.2. Geliştirilen modellerin MAE, RMSE, NRMSE, R² performans ölçütü hata değerlerinin dağılımı.

Saatlik enerji tüketiminde, tekli modellerin (CNN, LSTM, GRU, BiLSTM ve BiGRU) test veri seti için tüm dönemlere ait EA şarj yükü talebinin gerçek ve tahmini talep grafiklerinin karşılaştırması Şekil 6.3, Şekil 6.5, Şekil 6.7, Şekil 6.9 ve Şekil 6.11 verilmiştir. Çalışmada tekli modellerin gerçek ve tahmin değerlerinin karşılaştırıldığı grafiklerin daha detaylı incelenebilmesi adına ek olarak 100:200 zaman aralığına odaklanılmıştır. Tekli modellerin oluşturulan yakınlaştırılmış karşılaştırma grafikleri de sırasıyla Şekil 6.4, Şekil 6.6, Şekil 6.8, Şekil 6.10 ve Şekil 6.12’de sunulmaktadır.


Saatlik enerji ihtiyacında önerilen YDÖTM’nin test veri seti için tüm dönemlere ait gerçek ve tahmin değerlerinin karşılaştırma grafiği Şekil 6.13’te, 100:200 zaman aralığına odaklanan yakınlaştırılmış karşılaştırma grafiği ise Şekil 6.14’te sunulmaktadır.




Şekil 6.3. EA şarj yükü talebinin gerçek ve CNN modelinin tahmin ettiği değerlerin karşılaştırılması.




Şekil 6.4. EA şarj yükü talebinin gerçek ve CNN modelinin tahmin ettiği değerlerin 100:200 zaman aralığı karşılaştırılması.




Şekil 6.5. EA şarj yükü talebinin gerçek ve LSTM modelinin tahmin ettiği değerlerin karşılaştırılması.




Şekil 6.6. EA şarj yükü talebinin gerçek ve LSTM modelinin tahmin ettiği değerlerin 100:200 zaman aralığı karşılaştırılması.




Şekil 6.7. EA şarj yükü talebinin gerçek ve GRU modelinin tahmin ettiği değerlerin karşılaştırılması.




Şekil 6.8. EA şarj yükü talebinin gerçek ve GRU modelinin tahmin ettiği değerlerin 100:200 zaman aralığı karşılaştırılması.




Şekil 6.9. EA şarj yükü talebinin gerçek ve BiLSTM modelinin tahmin ettiği değerlerin karşılaştırılması.




Şekil 6.10. EA şarj yükü talebinin gerçek ve BiLSTM modelinin tahmin ettiği değerlerin 100:200 zaman aralığı karşılaştırılması.




Şekil 6.11. EA şarj yükü talebinin gerçek ve BiGRU modelinin tahmin ettiği değerlerin karşılaştırılması.



Şekil 6.12. EA şarj yükü talebinin gerçek ve BiGRU modelinin tahmin ettiği değerlerin 100:200 zaman aralığı karşılaştırılması.



Şekil 6.13. EA şarj yükü talebinin gerçek ve önerilen YDÖTM'nin tahmin ettiği değerlerin karşılaştırılması.



Şekil 6.14. EA şarj yükü talebinin gerçek ve önerilen YDÖTM'nin tahmin ettiği değerlerin 100:200 zaman aralığı karşılaştırılması.



7. SONUÇ VE ÖNERİLER

Mevcut düzende; üretim-tüketim ilişkisi, tüketim davranış ve alışkanlıkları, teknolojik birikim seviyeleri ve teknolojik gelişme düzeylerinin devinim ve dönüşümü içerisinde küresel enerji sisteminin zaman içinde nasıl evrimleşebileceğine dair; ekonomik büyüme, demografik yapı, hükümet politikaları, fiyatlar ve yatırımlar doğrultusunda varsayımları içeren çeşitli enerji senaryoları oluşturulmaktadır. Bu senaryolarda dünya çapındaki enerji ile ilgili mevcut ve geliştirilmekte olan politikalar; sektör ve ülke bazında değerlendirilmekte olup, bu doğrultuda hükümetler tarafından taahhütler verilmektedir. Verilen bu taahhütler arasında çevreye yapılan karbon salınımının azaltılması adına ülkelerin hazırlıklarını tamamlaması yer almakta hatta küresel enerji sektörünün 2050 yılına kadar net sıfır CO₂ emisyonuna ulaşması hedeflenmektedir. Nihai enerji tüketimindeki payı yüksek olan ulaştırma sektörünün 2023 yılındaki enerji talebi, 2022 yılında görülen orana benzer şekilde yaklaşık %4 oranında artmıştır. Karayolu taşımacılığının karbondan arındırılmasının temel unsurları elektrikleştirme ve enerji verimliliğidir (IEA, 2024). Sürdürülebilir kalkınma hedeflerine ulaşmak ve enerji verimliliği artırmak amacıyla yürütülen muhtelif çalışmalardan biri ise ulaştırma sektöründeki elektrikli araçların (EA) gelişimidir.

Elektrikli araçların kullanımının sağladığı faydaların yanında şebeke entegrasyonundaki operasyonel, teknik ve yönetsel süreçlerde planlanması ve karar verilmesi gereken birçok konuyu beraberinde getirmektedir. EA üretimi ve kullanımının artması ile oluşan belirsizler nedeniyle şarj kontrol sisteminde sorunlar meydana gelmektedir. Talep belirsizliği, enerji belirsizliği, EA mobilitesi, ağ belirsizliği, fiyat belirsizliği şeklinde sınıflandırılan bu belirsiz yönle uyum sağlayacak kordine sistemler oluşturulmalıdır.

EA'lara elektrik enerjisi aktarımı sağlayan şarj istasyonlarının gerçek zamanlı şarj oturum olaylarından yararlanılarak gelecekte talep edilmesi beklenen elektrikli araç şarj yükü tahmininin yapılması ve enerji sektörünün bu doğrultuda eylem planı geliştirmesi de alınması gereken önemli bir karardır. Bu çalışmada;

- Enerji sektöründeki güç sistemi planlamasını iyileştirmek adına dağıtım şirketleri ve diğer kamu hizmeti sağlayıcılarının karar mekanizmalarının desteklenmesi,
- İlgili kamu hizmeti sağlayıcıları için şarj oturum olaylarına ait verileri kullanarak gelişmiş yük tahmin algoritmalarının oluşturulması,
- Elektrikli araçların kısa dönemli şarj yükü tahmin doğruluğunun artırılması,

amacıyla CNN, LSTM, GRU, BiLSTM ve BiGRU tekli derin öğrenme modelleri ve bu modellerin kullanımını içeren hibrit Yığılmış Derin Öğrenme Topluluk Modeli (YDÖTM) geliştirilmiştir.


Çalışmada EA'lara ait geçmiş şarj oturum verilerinin stokastik yapısı ve geliştirilen modellerin eğitim sürecindeki hiperparametre ayarlamasına bağlı rassallık durumu dikkate alınarak tüm modellerin algoritması 4'er kez çalıştırılmıştır. Böylelikle her model sonucunda farklı değerler elde edilmiş olup MAE, RMSE, NRMSE ve R^2 performans ölçütlerinin hepsinde önerilen YDÖTM'nin tekli modellere kıyasla en iyi sonuçları verdiği görülmüştür. Şekil 7.1' de geliştirilen modellerin 4 kez tekrarlanan çalıştırma denemelerinin sonuçları verilmiştir. Model bazlı performans ölçütleri göz önüne alındığında diğer denemelere kıyasla daha iyi sonuçlar verdiği için, çalışmada 1. model denemesine ait sonuçlar kullanılmış ve bu sonuçlar üzerinden analizler yapılmıştır.

1. Model Denemesi										
		data	slide hour	Model	epochs	patience	MAE	RMSE	NRMSE	R ²
	0	/caltech_ch_8_9_kwh_0.xlsx	24	CNN	200	20	6.346041421837608	8.216922341271163	0.09073612817875489	0.8494509519805689
	1	/caltech_ch_8_9_kwh_0.xlsx	24	LSTM	200	20	8.453747183208955	10.763850695514776	0.11886082110082559	0.7416580229172818
	2	/caltech_ch_8_9_kwh_0.xlsx	24	GRU	200	20	5.521047561128199	7.253120320108359	0.08009325483773189	0.88269692076808
	3	/caltech_ch_8_9_kwh_0.xlsx	24	BiLSTM	200	20	6.706596427110524	8.8193943385846	0.0973889811694387	0.8265648294398277
	4	/caltech_ch_8_9_kwh_0.xlsx	24	BiGRU	200	20	5.939407826977455	7.714120428296259	0.08518389135219188	0.8673117464806722
	5	/caltech_ch_8_9_kwh_0.xlsx	24	LightGBM	200	20	3.5893500868152484	4.993463388004437	0.05514078327772017	0.9444015498175265
2. Model Denemesi										
		data	slide hour	Model	epochs	patience	MAE	RMSE	NRMSE	R ²
	0	/caltech_ch_8_9_kwh_0.xlsx	24	CNN	200	20	6.04794605906822	7.903806612763833	0.08727851866309405	0.860706048107076
	1	/caltech_ch_8_9_kwh_0.xlsx	24	LSTM	200	20	8.065112867271663	10.501000112193896	0.11595826911974234	0.7541212622239596
	2	/caltech_ch_8_9_kwh_0.xlsx	24	GRU	200	20	6.03754099021583	7.94121244125215	0.08769157599860045	0.8593844734778165
	3	/caltech_ch_8_9_kwh_0.xlsx	24	BiLSTM	200	20	5.841313595437429	7.696495687505218	0.0849892685149404	0.8679173695213925
	4	/caltech_ch_8_9_kwh_0.xlsx	24	BiGRU	200	20	5.744159059407773	7.849896174927011	0.0866832076458333	0.8625997654454418
	5	/caltech_ch_8_9_kwh_0.xlsx	24	LightGBM	200	20	3.545693684090681	5.195721129871473	0.05737423317890956	0.9398062618093078
3. Model Denemesi										
		data	slide hour	Model	epochs	patience	MAE	RMSE	NRMSE	R ²
	0	/caltech_ch_8_9_kwh_0.xlsx	24	CNN	200	20	5.997237226729734	7.973608135019827	0.08804930845608999	0.8582348683812787
	1	/caltech_ch_8_9_kwh_0.xlsx	24	LSTM	200	20	9.014812629884963	11.878361647993827	0.13116791181444198	0.6853898454597935
	2	/caltech_ch_8_9_kwh_0.xlsx	24	GRU	200	20	5.875730132424916	7.58471081923517	0.0837548737239794	0.8717262760301044
	3	/caltech_ch_8_9_kwh_0.xlsx	24	BiLSTM	200	20	5.804479983777952	7.723728604323701	0.08528999052842617	0.8669810059724703
	4	/caltech_ch_8_9_kwh_0.xlsx	24	BiGRU	200	20	5.685210087320552	7.490757105609033	0.08271738111441283	0.874884510727443
	5	/caltech_ch_8_9_kwh_0.xlsx	24	LightGBM	200	20	3.695274025636202	5.207906459567452	0.05750879081390647	0.9395235904998499
4. Model Denemesi										
		data	slide hour	Model	epochs	patience	MAE	RMSE	NRMSE	R ²
	0	/caltech_ch_8_9_kwh_0.xlsx	24	CNN	200	20	6.247921479964291	8.155996231514921	0.0900633459526763	0.8516752306612085
	1	/caltech_ch_8_9_kwh_0.xlsx	24	LSTM	200	20	8.24969290975492	10.566993483581063	0.11668700705305081	0.751021109122532
	2	/caltech_ch_8_9_kwh_0.xlsx	24	GRU	200	20	6.082519988271034	8.293841527232892	0.09158551543434251	0.8466191590416853
	3	/caltech_ch_8_9_kwh_0.xlsx	24	BiLSTM	200	20	5.600591948913443	7.27721788258519	0.08035935440967393	0.8819161770715418
	4	/caltech_ch_8_9_kwh_0.xlsx	24	BiGRU	200	20	5.771445262617489	7.681769830315543	0.08482665686911856	0.8684223186048329
	5	/caltech_ch_8_9_kwh_0.xlsx	24	LightGBM	200	20	3.571926153979768	5.240897494612129	0.0578730973827453	0.9387549519347278

Şekil 7.1. Model Denemeleri ve Sonuçları.

Model denemeleri sonuçlarından anlaşılacağı üzere tekli modellerde sonuçlar değişkenlik gösterebilmektedir. Bu durum veri setinin rassal olarak eğitim, doğrulama ve test setlerine bölündüğü veri setinin ayrılması süreci ve model içi hiperparametre ayarlamasına (hyperparameter tuning) bağlı değişkenlik göstermektedir. Çalışmadaki model hazırlığında ayarlanan hiperparametrelerin model sonuç farklılıklarına neden olduğu bilinmektedir. Bu sonuçların; katmanlar (layers), aktivasyon fonksiyonu, seyreltme katmanı (dropout), optimizasyon algoritması (optimizer), öğrenme oranı (learning rate), kayıp fonksiyonu (loss function), dönem sayısı (number of epochs), parti boyutu (batch size) hiperparametrelerinin ayarı ve dâhilinde rassallık, veri setinin yapısı, değerlendirme için seçilen performans ölçütleri gibi bir çok değişkene bağlı olduğu gözlemlenmiştir.

Çalışmada derin öğrenme algoritmalarında tahmin modeli ağının eğitim sürecinde aşırı öğrenme (overfitting) durumunu azaltmak için dönem sayısı seçimi, seyreltme oranı, erken durdurma (earlystopping) komutu kullanılmıştır. Geliştirilen modeller, eğitim test verilerinin uyumunu en iyileyen dönem sayılarına ulaştığında eğitimi tamamlanmıştır. Bu aşamada model performansının ön izlemesi açısından kayıp (loss) fonksiyon ve metrik grafikleri analiz edilmiştir. Çalışmanın YDÖTM'den sonra geliştirilen tekli derin öğrenme modelleri arasından GRU modelinin en iyi performans ölçüt değerlerine sahip model olduğu görülmüştür. Şekil 7.2'de GRU modelinin kayıp ve metrik grafiği gösterilmiştir. Ek-A'da Tablo A.1'de GRU modelinin eğitim ve test veri setine ait kayıp fonksiyonu ve metrik değerleri ile eğitim sonuçları verilmiş olup eğitimin 73 dönem sayısında tamamlandığı görülmektedir. Böylece GRU modelinde eğitim ve test verilerinin uyumu en iyilenerek (optimize edilerek) başarılı tahmin sonuçları elde edilmiştir.



Şekil 7.2. (a) GRU modelinin kayıp grafiği, (b) GRU modelinin metrik grafiği.

Önerilmiş olan Yığılmış Derin Öğrenme Topluluk Modeli (YDÖTM) ile MAE, RMSE, NRMSE ve R^2 performans ölçüt değerleri sırasıyla 3.5894, 4.9935, 0.0551 ve 0.9444 olarak elde edilmiş olup karşılaştırılan modeller arasında en iyi performansı verdiği görülmüştür. Bu sonuçlar Onan (2018)'nın da belirttiği gibi iki aşamalı tahminlemenin gücünü ortaya koymaktadır. Önerilen model yapısının kullanımının birçok farklı alanda fayda sağlayacağı öngörülmektedir.

Literatürde yenilenebilir enerji desteği ile elektrikli araçların enerji depolamasında kullanılmasıyla enerjideki belirsizliğin yönetilebilir olduğundan söz edilmektedir. Çalışmada EA kullanıcıları enerjiyi talep eden, kamu hizmeti sağlayıcıları ise enerji arzı sağlayan taraf olarak ele alınmakta olup gelecek çalışmaların, gelişen V2G, V2B, V2H, V2L teknolojilerinin kullanıldığı iş modellerine de katkı sağlayacağı düşünülmektedir. Böylelikle elektrikli araçların kullanımının artması ile dağıtım şebekesi üzerindeki etkinin analizi çerçevesinde çalışmada elde edilen başarılı sonuçların gelecekte gerçekleştirilecek,

- EA'ların artan talebine bağlı yenilenebilir enerji teknolojilerinin kullanımının artırılması,
- Tüketicinin elektrik talebini karşılayabilmek adına dağıtım ve iletimin planlamasında yenilenebilir enerji ve depolama desteği ile EA'ların tampon görevinde kullanılması,

- K resel enerji sekt r n n 2050 yılına kadar net sıfır CO₂ emisyonu hedefine ulařabilmesi,
- EA kullanıcılarının davranıř      r leri ve enerji t ketimi davranıř e ilimlerine ba lı farklı řarj davranıř modellerinden yararlanarak fiyatlandırma stratejilerinin geliştirilmesi, teřviklerin uygulanması, enerji tasarrufu ve verimlili inin sa lanması,
- řarj istasyonlarının optimal konumlandırılması, planlaması ve kontrol  ile kullanıcıların motivasyonunu ve EA kullanımındaki benimseme oranlarını etkileyen mezil kaygısının en aza indirilmesi,
- řarj istasyonlarının optimize edilmiř řarj y netimi do rultusunda řebeke entegrasyonunda dijitalleřmenin artırılması,
- Akıllı řebeke altyapısına ge iři hızlandıran stratejik kararların verilmesi ve buna uygun iř modellerinin oluřturulması,

ile ilgili  alıřmalara katkı sa layaca ı     r lmektedir.  alıřmada enerji sistemlerinin geliřmiř talep tarafı y netimi ile oluřturulacak talep tahminleri i in enerji y netim sistemlerini besleyecek etkili, geliřmiř y k tahmin algoritmaları sunulmaktadır. B ylelikle puant talebin d ř r lerek kaynak verimlili inin artırılması sa lanacaktır.

KAYNAKLAR

- Aduama, P., Zhang, Z., & Al-Sumaiti, A. S. (2023). Multi-feature data fusion-based load forecasting of electric vehicle charging stations using a deep learning model. *Energies*, 16(3), 1309.
- Alaerjan, A., Jabeur, R., Ben Chikha, H., Karray, M., & Ksantini, M. (2024). Improvement of Smart Grid Stability Based on Artificial Intelligence with Fusion Methods. *Symmetry*, 16(4), 459.
- Almutairi, A., Albagami, N., Almesned, S., Alrumayh, O., & Malik, H. (2023). Electric vehicle load estimation at home and workplace in Saudi Arabia for grid planners and policy makers. *Sustainability*, 15(22), 15878.
- Arias, M. B., & Bae, S. (2016). Electric vehicle charging demand forecasting model based on big data technologies. *Applied energy*, 183, 327-339.
- AutoGluon. (2024). Forecasting Time Series - In Depth. <https://auto.gluon.ai/stable/tutorials/timeseries/forecasting-indepth.html> adresinden 29 Ağustos 2024 tarihinde alınmıştır.
- Bae, S., & Kwasinski, A. (2011). Spatial and temporal model of electric vehicle charging demand. *IEEE Transactions on Smart Grid*, 3(1), 394-403.
- Butt, F. M., Hussain, L., Jafri, S. H. M., Alshahrani, H. M., Al-Wesabi, F. N., Lone, K. J., ... & Duhayyim, M. A. (2022). Intelligence based accurate medium and long term load forecasting system. *Applied Artificial Intelligence*, 36(1), 2088452.
- Brownlee, J. (2018). *Deep learning for time series forecasting: predict the future with MLPs, CNNs and LSTMs in Python*. Machine Learning Mastery.
- Chen, K., Zhou, Y., & Dai, F. (2015, October). A LSTM-based method for stock returns prediction: A case study of China stock market. *In 2015 IEEE international conference on big data (big data)* (pp. 2823-2824). IEEE.
- Chen, S., & He, H. (2018, November). Stock prediction using convolutional neural network. *In IOP Conference series: materials science and engineering* (Vol. 435, p. 012026). IOP Publishing.
- Chung, Y. W., Khaki, B., Li, T., Chu, C., & Gadh, R. (2019). Ensemble machine learning-based algorithm for electric vehicle user behavior prediction. *Applied Energy*, 254, 113732.
- Colak, I., Bayindir, R., & Sagiroglu, S. (2020, June). The effects of the smart grid system on the national grids. *In 2020 8th International Conference on Smart Grid (icSmartGrid)* (pp. 122-126). IEEE.
- Dai, X., Li, H., Olanrewaju, I., Kotter, R., Putrus, G., Aslam, N., ... & Portvik, S. (2023). Data-Driven EV Charging Load Forecasting and Smart Charging. *Transportation Research Procedia*, 72, 2832-2839.

- Das, H. S., Rahman, M. M., Li, S., & Tan, C. W. (2020). Electric vehicles standards, charging infrastructure, and impact on grid integration: A technological review. *Renewable and Sustainable Energy Reviews*, 120, 109618.
- Dastjerdy, B., Saeidi, A., & Heidarzadeh, S. (2023). Review of applicable outlier detection methods to treat geomechanical data. *Geotechnics*, 3(2), 375-396.
- Diaz-Londono, C., Fambri, G., Maffezzoni, P., & Gruosso, G. (2024). Enhanced EV charging algorithm considering data-driven workplace chargers categorization with multiple vehicle types. *eTransportation*, 20, 100326.
- Diro, A. A., & Chilamkurti, N. (2018). Distributed attack detection scheme using deep learning approach for Internet of Things. *Future Generation Computer Systems*, 82, 761-768. <https://doi.org/10.1016/j.future.2017.08.043>
- Durmuş, F. S., & Kaymaz, H. (2020). Elektrikli Araç Şarj Yöntemleri. *Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi*, 3(2), 123-139.
- Energy Efficiency & Renewable Energy (EERE) (2024). U.S. Department of Energy, Office of Energy Efficiency & Renewable Energy, Solar Energy Technologies Office. Solar Integration: Solar Energy and Storage Basics. <https://www.energy.gov/eere/solar/solar-integration-solar-energy-and-storage-basics> adresinden 15 Ekim 2024 tarihinde alınmıştır.
- Elkamel, M., Schleider, L., Pasiliao, E. L., Diabat, A., & Zheng, Q. P. (2020). Long-term electricity demand prediction via socioeconomic factors—A machine learning approach with florida as a case study. *Energies*, 13(15), 3996.
- EPK. (Mart 2013). Türkiye Cumhuriyeti. 6446 sayılı ELEKTRİK PİYASASI KANUNU.
- EPDK. (Mayıs 2016). Enerji Piyasası Düzenleme Kurumu. ELEKTRİK PİYASASI TALEP TAHMİNLERİ YÖNETMELİĞİ.
- EPDK. (2021). Enerji Piyasası Düzenleme Kurumu. Serbest Erişim Platformu-Şarj@TR. <https://www.epdk.gov.tr/Detay/Icerik/1-3428/enerji-donusumuserbest-erisim-platformu--sarj@tr>
- EPDK. (Nisan 2022). Enerji Piyasası Düzenleme Kurumu. ŞARJ HİZMETİ YÖNETMELİĞİ.
- EDDS. (Haziran 2023). T.C. Enerji Piyasası Düzenleme Kurumu'nun Enerji Dönüşüm Dairesi Başkanlığı'na bağlı Dijital Dönüşüm Grup Başkanlığı. Enerjide Dijital Dönüşüm Sözlüğü (EDDS). <https://www.epdk.gov.tr/Detay/Icerik/1-3416/enerji-donusumuenerjide-dijital-donusum-sozlugu>
- EPDK. (2024). Enerji Piyasası Düzenleme Kurumu. Tarihçe. <https://www.epdk.gov.tr/Detay/Icerik/1-1051/kurumumuztarihce> adresinden 23 Ağustos 2024 tarihinde alınmıştır.
- Erdoğan, O., & Taşçıkaraoğlu, A. (2018). Pik güç azaltımı tabanlı talep cevabı stratejisi ve yük faktörü maksimizasyonu amaçlı bir elektrikli araç toplu park bölgesi enerji yönetim stratejisi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(5), 824-830.

- Fischer, D., Harbrecht, A., Surmann, A., & McKenna, R. (2019). Electric vehicles' impacts on residential electric local profiles–A stochastic modelling approach considering socio-economic, behavioural and spatial factors. *Applied energy*, 233, 644-658.
- Garwa, N., & Niazi, K. R. (2019, December). Impact of EV on integration with grid system–a review. In *2019 8th international conference on power systems (ICPS)* (pp. 1-6). IEEE.
- Gough, R., Dickerson, C., Rowley, P., & Walsh, C. (2017). Vehicle-to-grid feasibility: A techno-economic analysis of EV-based energy storage. *Applied energy*, 192, 12-23.
- Grenier, A., & Page, S. (2012). The impact of electrified transport on local grid infrastructure: A comparison between electric cars and light rail. *Energy policy*, 49, 355-364.
- Gülmez, B. (2023). Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm. *Expert Systems with Applications*, 227, 120346.
- Heymann, F., Miranda, V., Neyestani, N., & Soares, F. J. (2017, December). Mapping the impact of daytime and overnight electric vehicle charging on distribution grids. In *2017 IEEE Vehicle Power and Propulsion Conference (VPPC)* (pp. 1-6). IEEE.
- International Energy Agency (IEA). (2020). *World Energy Outlook 2020*. IEA Publications. <https://www.iea.org/reports/world-energy-outlook-2020> adresinden 04 Haziran 2024 tarihinde alınmıştır.
- International Energy Agency (IEA). (2022). *Grid integration of electric vehicles: A manual for policy makers*. Global Environment Facility. <https://www.iea.org/reports/grid-integration-of-electric-vehicles> adresinden 04 Haziran 2024 tarihinde alınmıştır.
- International Energy Agency (IEA). (2023). *EV Charging and Grid Integration Tool*. Global Environment Facility. <https://www.iea.org/data-and-statistics/data-tools/electric-vehicle-charging-and-grid-integration-tool> adresinden 21 Ekim 2024 tarihinde alınmıştır.
- International Energy Agency (IEA). (2023). *World Energy Outlook 2023*. IEA Publications. <https://www.iea.org/reports/world-energy-outlook-2023> adresinden 04 Haziran 2024 tarihinde alınmıştır.
- International Energy Agency (IEA). (2024). *World Energy Outlook 2024*. IEA Publications. <https://www.iea.org/reports/world-energy-outlook-2024> adresinden 19 Ekim 2024 tarihinde alınmıştır.
- Jaruwatanachai, P., Sukamongkol, Y., & Samanchuen, T. (2023). Predicting and managing EV charging demand on electrical grids: A simulation-based approach. *Energies*, 16(8), 3562.
- Javanmard, M. E., & Ghaderi, S. F. (2023). Energy demand forecasting in seven sectors by an optimization model based on machine learning algorithms. *Sustainable Cities and Society*, 95, 104623.

- Jin, H., Lee, S., Nengroo, S. H., & Har, D. (2022). Development of charging/discharging scheduling algorithm for economical and energy-efficient operation of multi-EV charging station. *Applied sciences*, 12(9), 4786.
- Karabiyik, E., & Karabiyik, A. S. (2023, November). Investigation of Long Short-Term Memory Networks in Short-Term Electric Vehicle Charging Load Modeling. In *2023 14th International Conference on Electrical and Electronics Engineering (ELECO)* (pp. 1-5). IEEE.
- Kazemtarghi, A., Dey, S., & Mallik, A. (2022). Optimal utilization of bidirectional EVs for grid frequency support in power systems. *IEEE Transactions on Power Delivery*, 38(2), 998-1010.
- Kene, R., Olwal, T., & van Wyk, B. J. (2021). Sustainable electric vehicle transportation. *Sustainability*, 13(22), 12379.
- Khan, W., Somers, W., Walker, S., de Bont, K., Van der Velden, J., & Zeiler, W. (2023). Comparison of electric vehicle load forecasting across different spatial levels with incorporated uncertainty estimation. *Energy*, 283, 129213.
- Kim, Y., & Kim, S. (2021). Forecasting charging demand of electric vehicles using time-series models. *Energies*, 14(5), 1487.
- King, C., & Datta, B. (2018). EV charging tariffs that work for EV owners, utilities and society. *The Electricity Journal*, 31(9), 24-27.
- Ko, B., Kim, H. G., Oh, K. J., & Choi, H. J. (2017, February). Controlled dropout: A different approach to using dropout on deep neural network. In *2017 IEEE International Conference on Big Data and Smart Computing (BigComp)* (pp. 358-362). IEEE.
- Koç, M., Tör, O. B., & Demirbaş, Ş. (2021). Analysis the Effects of Electric Vehicles on Distribution Networks with Simulations Based on Probabilistic Methods. *Gazi University Journal of Science Part C: Design and Technology*, 9(1), 95-107.
- Kong, W., Ye, H., Wei, N., Xing, D., & Chen, W. (2022). Dynamic pricing based EV load management in distribution network. *Energy Reports*, 8, 798-805.
- Koohfar, S., Woldemariam, W., & Kumar, A. (2023). Performance comparison of deep learning approaches in predicting EV charging demand. *Sustainability*, 15(5), 4258
- Krichen, M. (2023). Convolutional neural networks: A survey. *Computers*, 12(8), 151.
- Kumar, M., Vyas, S., & Datta, A. (2019, December). A review on integration of electric vehicles into a smart power grid and vehicle-to-grid impacts. In *2019 8th International Conference on Power Systems (ICPS)* (pp. 1-5). IEEE.
- Kumar, N., Kumar, D., & Dwivedi, P. (2021, December). Load forecasting for EV charging stations based on artificial neural network and long short term memory. In *International Conference on Advanced Network Technologies and Intelligent Computing* (pp. 473-485). Cham: Springer International Publishing.
- Kural, E. (2015). *Hibrid Elektrikli Araçlar İçin Enerji Yönetim Sistemleri* [Doktora tezi]. İstanbul Teknik Üniversitesi. <https://polen.itu.edu.tr/items/c9bc19b2-91f2-407b-9e6d-9ef964238314> adresinden 28 Ağustos 2024 tarihinde alınmıştır.

- Lazzeri, F. (2020). *Machine learning for time series forecasting with Python*. John Wiley & Sons.
- Li, Y., & Jenn, A. (2024). Impact of electric vehicle charging demand on power distribution grid congestion. *Proceedings of the National Academy of Sciences*, 121(18), e2317599121.
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*, 33(12), 6999-7019.
- Liang, S., Deng, T., Huang, A., Liu, N., & Jiang, X. (2023). Energy consumption prediction using the GRU-MMattention-LightGBM model with features of Prophet decomposition. *PLoS One*, 18(1), e0277085.
- LightGBM. LightGBM Regressor.
<https://lightgbm.readthedocs.io/en/latest/pythonapi/lightgbm.LGBMRegressor.html> adresinden 06 Mayıs 2024 tarihinde alınmıştır.
- Liu, H., Li, Q., Yu, D., & Gu, Y. (2019). Air quality index and air pollutant concentration prediction based on machine learning algorithms. *Applied sciences*, 9(19), 4069.
- Liu, T., Song, Y., Zhu, L., & Hill, D. J. (2022). Stability and control of power grids. *Annual Review of Control, Robotics, and Autonomous Systems*, 5(1), 689-716.
- López, M. A., De La Torre, S., Martín, S., & Aguado, J. A. (2015). Demand-side management in smart grid operation considering electric vehicles load shifting and vehicle-to-grid support. *International Journal of Electrical Power & Energy Systems*, 64, 689-698.
- Ma, T. Y., & Faye, S. (2022). Multistep electric vehicle charging station occupancy prediction using hybrid LSTM neural networks. *Energy*, 244, 123217.
- Matkovic, D., Matijasevic, T., & Capuder, T. (2024). Charging station placement optimization based on the location significance prediction. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 46(1), 12218-12239.
- Mills, T. C. (2019). *Applied time series analysis: A practical guide to modeling and forecasting*. Academic press.
- Mohammad, F., Kang, D. K., Ahmed, M. A., & Kim, Y. C. (2023). Energy demand load forecasting for electric vehicle charging stations network based on convlstm and biconvlstm architectures. *IEEE Access*, 11, 67350-67369.
- Mohammed, M., Khan, M. B., Bashier, E. B. M., *Machine learning: Algorithms and applications*, 1. baskı. CRC Press, 5-11, 2016.
- Mohanty, S., Panda, S., Parida, S. M., Rout, P. K., Sahu, B. K., Bajaj, M., ... & Kamel, S. (2022). Demand side management of electric vehicles in smart grids: A survey on strategies, challenges, modeling, and optimization. *Energy Reports*, 8, 12466-12490.
- Mohsen, H., El-Dahshan, E. S. A., El-Horbaty, E. S. M., & Salem, A. B. M. (2018). Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, 3(1), 68-71.
<https://doi.org/10.1016/j.fcij.2017.12.001>

- Morais, H., Sousa, T., Vale, Z., & Faria, P. (2014). Evaluation of the electric vehicle impact in the power demand curve in a smart grid environment. *Energy Conversion and Management*, 82, 268-282.
- NITI Aayog. (2021). *Handbook for electric vehicle charging infrastructure implementation* (Version 1). Government of India. <https://www.niti.gov.in/sites/default/files/2021-08/HandbookforEVChargingInfrastructureImplementation081221.pdf>
- Nimalsiri, N. I., Mediawathe, C. P., Ratnam, E. L., Shaw, M., Smith, D. B., & Halgamuge, S. K. (2019). A survey of algorithms for distributed charging control of electric vehicles in smart grid. *IEEE Transactions on Intelligent Transportation Systems*, 21(11), 4497-4515.
- Nurmuhammed, M., & Karadağ, T. (2021). Elektrikli araç şarj istasyonlarının konumlandırılması ve enerji şebekesi üzerine etkisi konulu derleme çalışması. *Gazi University Journal of Science Part A: Engineering and Innovation*, 8(2), 218-233.
- Obiora, C. N., Hasan, A. N., Ali, A., & Alajarmeh, N. (2021). Forecasting hourly solar radiation using artificial intelligence techniques. *IEEE Canadian Journal of Electrical and Computer Engineering*, 44(4), 497-508.
- Onan, A. (2018). Particle swarm optimization based stacking method with an application to text classification. *Academic Platform-Journal of Engineering and Science*, 6(2), 134-141.
- Orzechowski, A. (2021). *Machine Learning for Public EV Charging Station Forecasting* [Yüksek lisans tezi]. McGill University (Canada).
- Orzechowski, A., Lugosch, L., Shu, H., Yang, R., Li, W., & Meyer, B. H. (2023). A data-driven framework for medium-term electric vehicle charging demand forecasting. *Energy and AI*, 14, 100267.
- Qian, K., Zhou, C., Allan, M., & Yuan, Y. (2010, October). Load model for prediction of electric vehicle charging demand. In *2010 International Conference on Power System Technology* (pp. 1-6). IEEE.).
- P Sasidharan, M., Kinattungal, S., & Simon, S. P. (2023). Comparative analysis of deep learning models for electric vehicle charging load forecasting. *Journal of The Institution of Engineers (India): Series B*, 104(1), 105-113.
- Pearre, N. S., & Swan, L. G. (2016). Electric vehicle charging to support renewable energy integration in a capacity constrained electricity grid. *Energy conversion and management*, 109, 130-139.
- Pedada S. (2023, February 25). *Research Variables: Not the Usual Math Stuff*. Mind the Graph. <https://mindthegraph.com/blog/research-variables/> adresinden 05 Eylül 2024 tarihinde alınmıştır.
- Ram, S. K., Devassy, S., Verma, B. K., Mishra, S., & Akbar, S. A. (2021, March). Review on renewable energy based ev charging system with grid support functionality. In *2021 7th International Conference on Advanced Computing and Communication Systems (ICACCS)* (Vol. 1, pp. 482-487). IEEE.

- Ray, S., Kasturi, K., Patnaik, S., & Nayak, M. R. (2023). Review of electric vehicles integration impacts in distribution networks: Placement, charging/discharging strategies, objectives and optimisation models. *Journal of Energy Storage*, 72, 108672.
- Richardson, D. B. (2013). Electric vehicles and the electric grid: A review of modeling approaches, Impacts, and renewable energy integration. *Renewable and Sustainable Energy Reviews*, 19, 247-254.
- Sarkar, N., Gupta, R., Keserwani, P. K., & Govil, M. C. (2022). Air Quality Index prediction using an effective hybrid deep learning model. *Environmental Pollution*, 315, 120404.
- Sarkar, R., Saha, P. K., Mondal, S., & Mondal, A. (2024). MAGE: Microgrids with Advanced Grid Efficiency through Battery-Aware EV management. *Sustainable Cities and Society*, 107, 105399.
- Salomão, A. (2023, August 6). *Araştırmalarda Kavramsal Çerçevenin Önemi*. Mind the Graph. <https://mindthegraph.com/blog/tr/arastirma-icinde-kavramsal-cerceve/adresinden> 05 Eylül 2024 tarihinde alınmıştır.
- Shahriar, S., Al-Ali, A. R., Osman, A. H., Dhou, S., & Nijim, M. (2021). Prediction of EV charging behavior using machine learning. *Ieee Access*, 9, 111576-111586.
- Shanmuganathan, J., Victoire, A. A., Balraj, G., & Victoire, A. (2022). Deep learning LSTM recurrent neural network model for prediction of electric vehicle charging demand. *Sustainability*, 14(16), 10207.
- Skuza, A., & Jurecki, R. S. (2022, July). Analysis of factors affecting the energy consumption of an EV vehicle-a literature study. In *IOP Conference Series: Materials Science and Engineering* (Vol. 1247, No. 1, p. 012001). IOP Publishing.
- Soares, L. D., & Franco, E. M. C. (2021). BiGRU-CNN neural network applied to short-term electric load forecasting. *Production*, 32, e20210087.
- Sultan, V., Bitar, H., Alzahrani, A., & Hiltona, B. (2017). A conceptual framework to integrate electric vehicles charging infrastructure into the electric grid. *International Journal of Smart Grid and Clean Energy*, 6(3), 207-218.
- Sunny, M. A. I., Maswood, M. M. S., & Alharbi, A. G. (2020, October). Deep learning-based stock price prediction using LSTM and bi-directional LSTM model. In *2020 2nd novel intelligent and leading emerging sciences conference (NILES)*(pp. 87-92). IEEE.
- Swaen, B. & George, T. (2024, March 18). *What Is a Conceptual Framework? | Tips & Examples*. Scribbr. Retrieved August 30, 2024, from <https://www.scribbr.com/methodology/conceptual-framework/>
- Şen, E. (2022). *Elektrikli araçların enerji talep tahmini* [Yüksek lisans tezi]. Erciyes Üniversitesi.
- TAŞ. (2023). *Türkiye Akıllı Şebekeler 2023 Vizyon ve Strateji Belirleme Projesi*. AF MERCADOS EMI. <https://www.elder.org.tr/Content/yayinlar/TAS%20TR.pdf> adresinden 23 Mayıs 2024 tarihinde alınmıştır.

- Tensorflow. (2024). Keras. <https://www.tensorflow.org/guide/keras?hl=tr> adresinden 29 Ağustos 2024 tarihinde alınmıştır.
- Tian, L., Feng, L., Yang, L., & Guo, Y. (2022). Stock price prediction based on LSTM and LightGBM hybrid model. *The Journal of Supercomputing*, 78(9), 11768-11793.
- TSKB. (2022). *Enerji Görünümü 2022* (5. yayın). Türkiye Sınai Kalkınma Bankası A.Ş. <https://www.tskb.com.tr/uploads/file/enerji-gorunumu-final.pdf>
- TSKB. (2023). *Enerji Görünümü 2023* (6. yayın). Türkiye Sınai Kalkınma Bankası A.Ş. <https://www.tskb.com.tr/uploads/file/enerji-gorunumu-2023.pdf>
- Tukey, J. W. (1977). *Exploratory data analysis* (Vol. 2, pp. 131-160). Reading, MA: Addison-wesley.
- Tunçer, B., & Çetin, E. *Elektrikli Araç Şarj İstasyonlarının Dağıtım Şebekesi Üzerindeki Etkilerinin Örnek Bir Saha Üzerinde İncelenmesi*. Pamukkale Üniversitesi. https://www.emo.org.tr/ekler/9a0d6cd8ad5fe25_ek.pdf adresinden 29 Ağustos 2024 tarihinde alınmıştır.
- Unterluggauer, T., Rauma, K., Järventausta, P., & Rehtanz, C. (2021). Short-term load forecasting at electric vehicle charging sites using a multivariate multi-step long short-term memory: A case study from Finland. *IET Electrical Systems in Transportation*, 11(4), 405-419.
- Üney, M. Ş. (2019). *Akıllı şebekelerde yük yönetimi ve yük tahmini*. Konya Teknik Üniversitesi. <https://gcris.ktun.edu.tr/handle/20.500.13091/1466> adresinden 29 Ağustos 2024 tarihinde alınmıştır.
- Vahidmohammadi, A. (2021). *A Comparative Study of Short-Term Electric Vehicle Load Forecasting Using Data-Driven Multivariate Probabilistic DeepAR Approach* [Yüksek lisans tezi]. The University of Regina (Canada).
- Van Kriekinge, G., De Cauwer, C., Sapountzoglou, N., Coosemans, T., & Messagie, M. (2021). Day-ahead forecast of electric vehicle charging demand with deep neural networks. *World Electric Vehicle Journal*, 12(4), 178.
- Vornberger, J., Tröschel, M., Nieße, A., & Appelrath, H. J. (2011, October). Optimized charging management for electric vehicles. *In Proceedings of the 1st International* (Vol. 100).
- Yadav, A., Jha, C. K., & Sharan, A. (2020). Optimizing LSTM for time series prediction in Indian stock market. *Procedia Computer Science*, 167, 2091-2100.
- Yang, Y., Wu, Y., Wang, P., & Jiali, X. (2021). Stock price prediction based on xgboost and lightgbm. *In E3s web of conferences* (Vol. 275, p. 01040). EDP Sciences.
- Yi, Z., Liu, X. C., Wei, R., Chen, X., & Dai, J. (2022). Electric vehicle charging demand forecasting using deep learning model. *Journal of Intelligent Transportation Systems*, 26(6), 690-703.
- Yoon, H. (2021). Finding unexpected test accuracy by cross validation in machine learning. *International Journal of Computer Science & Network Security*, 21(12spc), 549-555.

- Zachary J. Lee, Tongxin Li, and Steven H. Low. 2019. ACN-Data: Analysis and Applications of an Open EV Charging Dataset. In *Proceedings of Proceedings of the Tenth ACM International Conference on Future Energy Systems, Phoenix, AZ, USA, June 25–28, 2019 (e-Energy '19)*, 11 pages. <https://doi.org/10.1145/3307772.3328313>
- Zehir, M. A., & Bağrıyanık, M. *Akıllı Şebekelerde Gelişmiş Yerel Talep Yönetimi*. İstanbul Teknik Üniversitesi. https://www.emo.org.tr/ekler/26934d7dc340d61_ek.pdf adresinden 29 Ağustos 2024 tarihinde alınmıştır.
- Zhang, Q., Mclellan, B. C., Tezuka, T., & Ishihara, K. N. (2013). A methodology for economic and environmental analysis of electric vehicles with different operational conditions. *Energy*, 61, 118-127.
- Zhang, J., Yan, J., Liu, Y., Zhang, H., & Lv, G. (2020). Daily electric vehicle charging load profiles considering demographics of vehicle users. *Applied Energy*, 274, 115063.
- Zhang, M., Li, X., & Wang, L. (2019). An adaptive outlier detection and processing approach towards time series sensor data. *IEEE Access*, 7, 175192-175212.
- Zhang, S., Yao, R., Du, C., Essah, E., & Li, B. (2023). Analysis of outlier detection rules based on the ASHRAE global thermal comfort database. *Building and Environment*, 234, 110155.
- Zhou, X., Zhang, K., Jia, X., & Fan, J. (2023, March). Electric Vehicle Charging Load Demand Forecasting Model based on Spatial and Temporal Characteristics. In *Journal of Physics: Conference Series* (Vol. 2465, No. 1, p. 012005). IOP Publishing.
- Zhou, Z. H., *Ensemble methods: foundations and algorithms*. Chapman & Hall/CRC Data Mining and Knowledge Discovery Series, Taylor & Francis, 2012.
- Zhu, J., Yang, Z., Chang, Y., Guo, Y., Zhu, K., & Zhang, J. (2019a). A novel LSTM based deep learning approach for multi-time scale electric vehicles charging load prediction. In *2019 IEEE Innovative Smart Grid Technologies-Asia (ISGT Asia)* (pp. 3531-3536). IEEE.
- Zhu, J., Yang, Z., Guo, Y., Zhang, J., & Yang, H. (2019b). Short-term load forecasting for electric vehicle charging stations based on deep learning approaches. *Applied sciences*, 9(9), 1723.
- Zhu, J., Yang, Z., Mourshed, M., Guo, Y., Zhou, Y., Chang, Y., ... & Feng, S. (2019). Electric vehicle charging load forecasting: A comparative study of deep learning approaches. *Energies*, 12(14), 2692.
- Xin, F., Yang, X., Beibei, W., Ruilin, X., Fei, M., & Jianyong, Z. (2024). Research on electric vehicle charging load prediction method based on spectral clustering and deep learning network. *Frontiers in Energy Research*, 12, 1294453.
- Xu, H., Chai, L., Luo, Z., & Li, S. (2022). Stock movement prediction via gated recurrent unit network based on reinforcement learning with incorporated attention mechanisms. *Neurocomputing*, 467, 214-228.
- Xydas, E., Marmaras, C., Cipcigan, L. M., Jenkins, N., Carroll, S., & Barker, M. (2016). A data-driven approach for characterising the charging demand of electric vehicles: A UK case study. *Applied energy*, 162, 763-771.



EKLER

EK A. Tablolar



EK A

Tablo A.1. GRU modelinin eğitim ve test veri setine ait kayıp fonksiyonu ve metrik değerleri ile eğitim sonuçları.

Epoch 1/200
36/36 ————— 18s 316ms/step - loss: 0.0602 - mae: 0.1883 - val_loss: 0.0247 - val_mae: 0.1227
Epoch 2/200
36/36 ————— 11s 294ms/step - loss: 0.0244 - mae: 0.1216 - val_loss: 0.0125 - val_mae: 0.0898
Epoch 3/200
36/36 ————— 18s 229ms/step - loss: 0.0143 - mae: 0.0889 - val_loss: 0.0092 - val_mae: 0.0705
Epoch 4/200
36/36 ————— 12s 270ms/step - loss: 0.0116 - mae: 0.0832 - val_loss: 0.0099 - val_mae: 0.0776
Epoch 5/200
36/36 ————— 10s 290ms/step - loss: 0.0111 - mae: 0.0813 - val_loss: 0.0086 - val_mae: 0.0673
Epoch 6/200
36/36 ————— 19s 234ms/step - loss: 0.0100 - mae: 0.0746 - val_loss: 0.0083 - val_mae: 0.0675
Epoch 7/200
36/36 ————— 12s 280ms/step - loss: 0.0115 - mae: 0.0825 - val_loss: 0.0084 - val_mae: 0.0695
Epoch 8/200
36/36 ————— 11s 295ms/step - loss: 0.0103 - mae: 0.0765 - val_loss: 0.0084 - val_mae: 0.0679
Epoch 9/200
36/36 ————— 18s 232ms/step - loss: 0.0104 - mae: 0.0754 - val_loss: 0.0082 - val_mae: 0.0670
Epoch 10/200
36/36 ————— 12s 275ms/step - loss: 0.0089 - mae: 0.0699 - val_loss: 0.0084 - val_mae: 0.0695
Epoch 11/200
36/36 ————— 11s 291ms/step - loss: 0.0111 - mae: 0.0802 - val_loss: 0.0101 - val_mae: 0.0781
Epoch 12/200
36/36 ————— 18s 231ms/step - loss: 0.0115 - mae: 0.0818 - val_loss: 0.0115 - val_mae: 0.0846
Epoch 13/200
36/36 ————— 12s 264ms/step - loss: 0.0107 - mae: 0.0785 - val_loss: 0.0078 - val_mae: 0.0663
Epoch 14/200
36/36 ————— 10s 283ms/step - loss: 0.0090 - mae: 0.0702 - val_loss: 0.0095 - val_mae: 0.0713

Tablo A.1. (Devamı) GRU modelinin eğitim ve test veri setine ait kayıp fonksiyonu ve metrik değerleri ile eğitim sonuçları.

Epoch 15/200
36/36 ————— 10s 265ms/step
- loss: 0.0098 - mae: 0.0734 - val_loss: 0.0085 - val_mae: 0.0681
Epoch 16/200
36/36 ————— 10s 260ms/step
- loss: 0.0099 - mae: 0.0762 - val_loss: 0.0090 - val_mae: 0.0689
Epoch 17/200
36/36 ————— 11s 295ms/step
- loss: 0.0100 - mae: 0.0743 - val_loss: 0.0077 - val_mae: 0.0643
Epoch 18/200
36/36 ————— 19s 249ms/step
- loss: 0.0082 - mae: 0.0683 - val_loss: 0.0083 - val_mae: 0.0685
Epoch 19/200
36/36 ————— 10s 237ms/step
- loss: 0.0090 - mae: 0.0705 - val_loss: 0.0072 - val_mae: 0.0627
Epoch 20/200
36/36 ————— 13s 312ms/step
- loss: 0.0088 - mae: 0.0710 - val_loss: 0.0077 - val_mae: 0.0652
Epoch 21/200
36/36 ————— 11s 296ms/step
- loss: 0.0085 - mae: 0.0695 - val_loss: 0.0075 - val_mae: 0.0644
Epoch 22/200
36/36 ————— 19s 241ms/step
- loss: 0.0083 - mae: 0.0680 - val_loss: 0.0079 - val_mae: 0.0675
Epoch 23/200
36/36 ————— 12s 291ms/step
- loss: 0.0083 - mae: 0.0666 - val_loss: 0.0076 - val_mae: 0.0663
Epoch 24/200
36/36 ————— 20s 271ms/step
- loss: 0.0075 - mae: 0.0656 - val_loss: 0.0071 - val_mae: 0.0635
Epoch 25/200
36/36 ————— 9s 236ms/step
- loss: 0.0076 - mae: 0.0652 - val_loss: 0.0077 - val_mae: 0.0683
Epoch 26/200
36/36 ————— 12s 285ms/step
- loss: 0.0083 - mae: 0.0716 - val_loss: 0.0073 - val_mae: 0.0639
Epoch 27/200
36/36 ————— 11s 295ms/step
- loss: 0.0082 - mae: 0.0682 - val_loss: 0.0082 - val_mae: 0.0689
Epoch 28/200
36/36 ————— 21s 307ms/step
- loss: 0.0086 - mae: 0.0687 - val_loss: 0.0076 - val_mae: 0.0668

Tablo A.1. (Devamı) GRU modelinin eğitim ve test veri setine ait kayıp fonksiyonu ve metrik değerleri ile eğitim sonuçları.

Epoch 29/200
36/36 ————— 20s 297ms/step
- loss: 0.0076 - mae: 0.0664 - val_loss: 0.0076 - val_mae: 0.0668
Epoch 30/200
36/36 ————— 18s 235ms/step
- loss: 0.0081 - mae: 0.0685 - val_loss: 0.0072 - val_mae: 0.0627
Epoch 31/200
36/36 ————— 10s 287ms/step
- loss: 0.0078 - mae: 0.0651 - val_loss: 0.0070 - val_mae: 0.0633
Epoch 32/200
36/36 ————— 10s 290ms/step
- loss: 0.0077 - mae: 0.0656 - val_loss: 0.0077 - val_mae: 0.0661
Epoch 33/200
36/36 ————— 20s 280ms/step
- loss: 0.0077 - mae: 0.0649 - val_loss: 0.0080 - val_mae: 0.0657
Epoch 34/200
36/36 ————— 10s 286ms/step
- loss: 0.0080 - mae: 0.0655 - val_loss: 0.0068 - val_mae: 0.0616
Epoch 35/200
36/36 ————— 19s 231ms/step
- loss: 0.0073 - mae: 0.0646 - val_loss: 0.0071 - val_mae: 0.0630
Epoch 36/200
36/36 ————— 10s 291ms/step
- loss: 0.0083 - mae: 0.0666 - val_loss: 0.0068 - val_mae: 0.0612
Epoch 37/200
36/36 ————— 11s 297ms/step
- loss: 0.0079 - mae: 0.0656 - val_loss: 0.0065 - val_mae: 0.0598
Epoch 38/200
36/36 ————— 8s 233ms/step
- loss: 0.0071 - mae: 0.0617 - val_loss: 0.0070 - val_mae: 0.0629
Epoch 39/200
36/36 ————— 12s 272ms/step
- loss: 0.0074 - mae: 0.0646 - val_loss: 0.0066 - val_mae: 0.0619
Epoch 40/200
36/36 ————— 11s 291ms/step
- loss: 0.0082 - mae: 0.0668 - val_loss: 0.0065 - val_mae: 0.0605
Epoch 41/200
36/36 ————— 18s 232ms/step
- loss: 0.0075 - mae: 0.0628 - val_loss: 0.0070 - val_mae: 0.0628
Epoch 42/200
36/36 ————— 12s 274ms/step
- loss: 0.0072 - mae: 0.0630 - val_loss: 0.0072 - val_mae: 0.0648

Tablo A.1. (Devamı) GRU modelinin eğitim ve test veri setine ait kayıp fonksiyonu ve metrik değerleri ile eğitim sonuçları.

Epoch 43/200
36/36  10s 292ms/step - loss: 0.0077 - mae: 0.0662 - val_loss: 0.0084 - val_mae: 0.0711
Epoch 44/200
36/36  18s 231ms/step - loss: 0.0076 - mae: 0.0646 - val_loss: 0.0066 - val_mae: 0.0606
Epoch 45/200
36/36  12s 269ms/step - loss: 0.0078 - mae: 0.0644 - val_loss: 0.0065 - val_mae: 0.0609
Epoch 46/200
36/36  10s 281ms/step - loss: 0.0067 - mae: 0.0608 - val_loss: 0.0066 - val_mae: 0.0631
Epoch 47/200
36/36  9s 250ms/step - loss: 0.0080 - mae: 0.0645 - val_loss: 0.0066 - val_mae: 0.0612
Epoch 48/200
36/36  10s 231ms/step - loss: 0.0077 - mae: 0.0647 - val_loss: 0.0073 - val_mae: 0.0652
Epoch 49/200
36/36  10s 283ms/step - loss: 0.0075 - mae: 0.0644 - val_loss: 0.0067 - val_mae: 0.0628
Epoch 50/200
36/36  10s 293ms/step - loss: 0.0069 - mae: 0.0610 - val_loss: 0.0065 - val_mae: 0.0625
Epoch 51/200
36/36  8s 231ms/step - loss: 0.0074 - mae: 0.0647 - val_loss: 0.0074 - val_mae: 0.0647
Epoch 52/200
36/36  12s 268ms/step - loss: 0.0078 - mae: 0.0658 - val_loss: 0.0066 - val_mae: 0.0631
Epoch 53/200
36/36  11s 293ms/step - loss: 0.0072 - mae: 0.0626 - val_loss: 0.0061 - val_mae: 0.0592
Epoch 54/200
36/36  19s 241ms/step - loss: 0.0068 - mae: 0.0638 - val_loss: 0.0070 - val_mae: 0.0634
Epoch 55/200
36/36  11s 263ms/step - loss: 0.0078 - mae: 0.0664 - val_loss: 0.0081 - val_mae: 0.0669
Epoch 56/200
36/36  11s 296ms/step - loss: 0.0075 - mae: 0.0647 - val_loss: 0.0061 - val_mae: 0.0592
Epoch 57/200
36/36  18s 234ms/step - loss: 0.0069 - mae: 0.0623 - val_loss: 0.0067 - val_mae: 0.0600

Tablo A.1. (Devamı) GRU modelinin eğitim ve test veri setine ait kayıp fonksiyonu ve metrik değerleri ile eğitim sonuçları.

Epoch 58/200
36/36 ————— 10s 278ms/step
- loss: 0.0080 - mae: 0.0654 - val_loss: 0.0067 - val_mae: 0.0619
Epoch 59/200
36/36 ————— 10s 289ms/step
- loss: 0.0069 - mae: 0.0621 - val_loss: 0.0075 - val_mae: 0.0648
Epoch 60/200
36/36 ————— 19s 236ms/step
- loss: 0.0065 - mae: 0.0600 - val_loss: 0.0062 - val_mae: 0.0605
Epoch 61/200
36/36 ————— 12s 281ms/step
- loss: 0.0073 - mae: 0.0643 - val_loss: 0.0069 - val_mae: 0.0614
Epoch 62/200
36/36 ————— 11s 295ms/step
- loss: 0.0069 - mae: 0.0616 - val_loss: 0.0069 - val_mae: 0.0639
Epoch 63/200
36/36 ————— 18s 236ms/step
- loss: 0.0067 - mae: 0.0599 - val_loss: 0.0066 - val_mae: 0.0627
Epoch 64/200
36/36 ————— 12s 287ms/step
- loss: 0.0071 - mae: 0.0619 - val_loss: 0.0061 - val_mae: 0.0593
Epoch 65/200
36/36 ————— 20s 291ms/step
- loss: 0.0075 - mae: 0.0628 - val_loss: 0.0064 - val_mae: 0.0610
Epoch 66/200
36/36 ————— 21s 294ms/step
- loss: 0.0071 - mae: 0.0618 - val_loss: 0.0070 - val_mae: 0.0646
Epoch 67/200
36/36 ————— 20s 290ms/step
- loss: 0.0067 - mae: 0.0608 - val_loss: 0.0066 - val_mae: 0.0618
Epoch 68/200
36/36 ————— 8s 235ms/step
- loss: 0.0068 - mae: 0.0615 - val_loss: 0.0072 - val_mae: 0.0643
Epoch 69/200
36/36 ————— 12s 286ms/step
- loss: 0.0066 - mae: 0.0576 - val_loss: 0.0063 - val_mae: 0.0614
Epoch 70/200
36/36 ————— 21s 297ms/step
- loss: 0.0068 - mae: 0.0607 - val_loss: 0.0061 - val_mae: 0.0610
Epoch 71/200
36/36 ————— 8s 235ms/step
- loss: 0.0067 - mae: 0.0599 - val_loss: 0.0077 - val_mae: 0.0676

Tablo A.1. (Devamı) GRU modelinin eğitim ve test veri setine ait kayıp fonksiyonu ve metrik değerleri ile eğitim sonuçları.

Epoch 72/200	
36/36	12s 281ms/step
- loss: 0.0069 - mae: 0.0609 - val_loss: 0.0073 - val_mae: 0.0659	
Epoch 73/200	
36/36	11s 295ms/step
- loss: 0.0067 - mae: 0.0599 - val_loss: 0.0064 - val_mae: 0.0610	





ÖZGEÇMİŞ

Ad-Soyad : Hatice Menekşe KÖSEMEN

ÖĞRENİM DURUMU:

- Lisans** : 2016, SAKARYA ÜNİVERSİTESİ, Mühendislik Fakültesi, Endüstri Mühendisliği

MESLEKİ DENEYİM:

- 2023 yılında ECOPLAS OTOMOTİV SAN. TİC. A.Ş.'de Planlama Mühendisi olarak çalıştı.
- 2016-2019 yılları arasında TEM KABLO DONANIMLARI TİC. SAN. LTD. ŞTİ.'de Kalite Sistem Yöneticisi ve Kalite Kontrol Birim Yöneticisi olarak çalıştı.

TEZDEN TÜRETİLEN ESERLER:

- Kösemen, H.M., Torkul, O., Şişci M., Demircioğlu Diren D., Selvi İ.H. & Gülşen M.E. (2024). A Novel Model for Short-Term Charging Load Prediction of Electric Vehicles: Stacked Deep Learning Ensemble Model
- Kösemen, H.M., Torkul, O., Şişci M., Demircioğlu Diren D., Selvi İ.H. & Gülşen M.E. (2024). Short-Term Charging Load Prediction of Electric Vehicles Using Deep Learning Models. Google Colab bağlantı: <https://colab.research.google.com/drive/1LuLnPR65FsGYMZzkKHmwYwWcaJbGchjt?usp=sharing>