

Elektrikli Araçlarda Otonom Filo Yönetim Sistemi İçin Federe Öğrenme Mimarisi
ile Prognostik Sistemi

Metin Yılmaz

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Ağustos 2025

Federated Learning Based Prognostic System for Autonomous Fleet Management
of Electrical Vehicles

Metin Yilmaz

DOCTORAL DISSERTATION

Department of Computer Engineering

August 2025

Elektrikli Araçlarda Otonom Filo Yönetim Sistemi İçin Federe Öğrenme Mimarisi
ile Prognostik Sistemi

Metin Yılmaz

Eskişehir Osmangazi Üniversitesi

Fen Bilimleri Enstitüsü

Lisansüstü Eğitim ve Öğretim Yönetmeliği Uyarınca

Bilgisayar Mühendisliği Anabilim Dalı

Robotik Bilim Dalında

DOKTORA TEZİ

olarak hazırlanmıştır.

Danışman: Prof. Dr. Ahmet Yazıcı

Bu tez, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'nun (TUBİTAK) 22AG040
nolu projesi tarafından desteklenmiştir.

YÖK 100/2000 Doktora Bursiyeri İleri Robotik Sistemler ve Mekatronik Alt Alanı

Ağustos 2025

ONAY

Bilgisayar Mühendisliği Anabilim Dalı Doktora öğrencisi Metin Yılmaz'ın DOKTORA tezi olarak hazırladığı “**Elektrikli Araçlarda Otonom Filo Yönetim Sistemi İçin Federe Öğrenme Mimarisi ile Prognostik Sistemi**” başlıklı bu çalışma, jürimizce lisansüstü yönetmeliğin ilgili maddeleri uyarınca değerlendirilerek oybirliği ile kabul edilmiştir.

Danışman : Prof. Dr. Ahmet Yazıcı

İkinci Danışman : -

Doktora Tez Savunma Jürisi:

Üye: Prof. Dr. Ahmet Yazıcı

Üye: Prof. Dr. İnci Sarıçiçek

Üye: Doç. Dr. Eyüp Çınar

Üye: Doç. Dr. Durmuş Özdemir

Üye: Dr. Öğr. Üyesi Altan Onat

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun tarih ve sayılı kararıyla onaylanmıştır.

Prof. Dr.

Enstitü Müdürü

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Prof. Dr. Ahmet Yazıcı danışmanlığında hazırlamış olduğum “**Elektrikli Araçlarda Otonom Filo Yönetim Sistemi İçin Federe Öğrenme Mimarisi ile Prognostik Sistemi**” başlıklı Yüksek Lisans /Doktora tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallarına uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim. 29/08/2025

Metin Yılmaz

İmza

ÖZET

Elektrikli araç (EV) filolarının verimli ve uzun ömürlü bir şekilde kullanımı için Şarj Durumu (SoC) ve Sağlık Durumu (SoH) gibi temel göstergelerin doğru ve güvenilir biçimde tahmin edilmesini gerektirir. Bu çalışmada, Batarya Yönetim Sistemleri (BMS) ve Prognostik Sağlık Yönetimi (PHM) alanında EV filo yönetimi karar destek süreçlerine katkı sunmak amacıyla, yapay zekâ (AI) tabanlı tahmin modellerini içeren bir yaklaşım sunulmaktadır.

Bu doğrultuda önce tek bir EV’de SoC tahmini için geliştirilen Transformer tabanlı bir model önerilmiştir. Daha sonra, veri mahremiyeti, iletişim maliyetleri ve heterojenlik gibi bazı sınırlılıkları göz önünde bulundurularak, tahmin sürecinin dağıtık ortamlarda da gerçekleştirilmesine olanak tanıyan Federe Öğrenme (FL) mimarisi kullanılmıştır. EV filoları için önerilen FL tabanlı yaklaşımda hem SoC hem de SoH tahmini gerçekleştirilmiştir. Bu kapsamda özgün olarak geliştirilen Federe Uyarlanabilir İstemci Momentumu (FedACM) yöntemi, istemciler arası veri heterojenliğini ve dağılım dengesizliklerini azaltmak amacıyla özelleştirilmiş bir momentum güncelleme mekanizması ile desteklenmiştir. FL temelli SoH tahmini çalışmasında ise, sabit bir rota üzerinde toplanan sürüş verileri ile sürücü davranışları hız temelli özniteliklerle analiz edilerek Dinamik Zaman Bükülmesi (DTW) algoritmasıyla benzerlik ölçülmüş ve her istemciye ağırlık değeri atanmıştır. SoH değeri, birim SoC değişimine karşılık gelen mesafe üzerinden referansla hesaplanmış ve FL yaklaşımıyla global tahmin elde edilmiştir. Önerilen yöntemler NASA, BMW i3, Stanford ve Musoshi L5 gibi çeşitli farklı alanlardaki veri kümeleri üzerinde yapılan deneysel çalışmalarda başarı ile test edilmiştir. Ayrıca verinin bir sunucuda toplanması senaryosunda merkezi yaklaşımların başarımı ise LSTM, Bi-LSTM ve SVR gibi klasik yöntemlerle karşılaştırmalı olarak değerlendirilmiştir.

Elde edilen bulgular, FL tabanlı modellerin yalnızca yüksek doğrulukla tahmin sunmakla kalmadığını, aynı zamanda veri gizliliği, ölçeklenebilirlik ve kişiselleştirilmiş yönetim açısından da önemli avantajlar sunduğunu ortaya koymaktadır. Bu yaklaşım batarya kullanımının kritik olduğu tüm robotik ve mekatronik sistem filoları için ölçeklenebilir.

Anahtar Kelimeler: Elektrikli Araçlar, Filo Yönetimi, Batarya Şarj Durumu, Batarya Sağlık Durumu, Federe Öğrenme

SUMMARY

For the efficient and long-lasting operation of electric vehicle (EV) fleets, it is essential to accurately and reliably predict key indicators such as State of Charge (SoC) and State of Health (SoH). In this study, an artificial intelligence (AI)-based predictive framework is proposed to contribute to decision support processes in EV fleet management, particularly within the domains of Battery Management Systems (BMS) and Prognostic Health Management (PHM).

Accordingly, a Transformer-based model was first developed for SoC estimation in a single EV. Subsequently, considering limitations such as data privacy, communication cost, and heterogeneity, a Federated Learning (FL) architecture was employed to enable the prediction process to be carried out in distributed environments as well. Within the proposed FL-based approach for EV fleets, both SoC and SoH estimation were performed. In this context, a novel Federated Adaptive Client Momentum (FedACM) method was introduced, which incorporates a customized momentum update mechanism to mitigate inter-client data heterogeneity and distribution imbalances. In the FL-based SoH estimation task, driving data collected on a fixed route were analyzed using speed-based features to capture driver behavior. Similarities were measured with the Dynamic Time Warping (DTW) algorithm, and weight values were assigned to each client. The SoH value was then calculated with reference to the distance corresponding to a unit SoC change, and a global prediction was obtained through the FL approach. The proposed methods were successfully validated through experimental studies on diverse datasets, including NASA, BMW i3, Stanford, and Musoshi L5. In addition, under a centralized data collection scenario, the performance of centralized approaches was comparatively evaluated against classical methods such as LSTM, Bi-LSTM, and SVR.

The findings reveal that FL-based models not only provide highly accurate predictions but also offer significant advantages in terms of data privacy, scalability, and personalized management. This approach is scalable to all robotic and mechatronic system fleets where battery usage is critical.

Keywords: Electric Vehicle, Fleet Management, Battery State of Charge, Battery State of Health, Federated Learning

TEŞEKKÜR

Doktora eğitimim, proje çalışmalarım ve tez sürecim boyunca bilgi ve deneyimleriyle bana her zaman yol gösteren, akademik disipliniyle örnek aldığım değerli hocalarım Prof. Dr. Ahmet Yazıcı ve Doç. Dr. Eyüp Çınar'a en içten teşekkürlerimi ve saygılarımı sunarım.

Proje döneminde, Eskişehir Osmangazi Üniversitesi Akıllı Fabrika ve Robotik Laboratuvarı'nda birlikte çalışma fırsatı bulduğum kıymetli hocalarım Prof. Dr. İnci Sarıçiçek, Prof. Dr. Kemal Özkan ve Doç. Dr. Uğur Yayan'a; ayrıca çalışma arkadaşlarım Sayın Mahmut Kasap ve Hande Cavşi Zaim'e destekleri için teşekkür ederim.

Tez çalışmam süresince sabırları, inançları ve koşulsuz destekleriyle daima yanımda olan aileme; teknik konularda katkı sunan ve bu süreçte beni her defasında motive eden hocalarıma, iş arkadaşlarıma ve okuldan dostlarıma teşekkür ederim.

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'nun (TÜBİTAK) 22AG040 numaralı projesi kapsamında desteklenmiştir. Sağladığı katkılar için TÜBİTAK'a teşekkür ederim. Tez konusu, Yükseköğretim Kurulu'nun 100/2000 Doktora Burs Programı kapsamında "İleri Robotik Sistemler ve Mekatronik" tematik alanı altında yürütülmüştür. Bu kapsamda, Yükseköğretim Kurulu'na da teşekkürlerimi sunarım.

Bu tezi, her zaman yanımda olan anneme, babama, ağabeyime, ablama ve yeğenlerime, en büyük destekçim olan eşime ve dünyaya gelmesini sabırsızlıkla beklediğimiz çocuğumuza ithaf ediyorum.

Metin Yılmaz

İÇİNDEKİLER

Sayfa

ÖZET	vi
SUMMARY	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	xiii
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	4
2.1. Batarya Sağlık Yönetimi	4
2.2. Makine Öğrenmesi ve Derin Öğrenme Yöntemleri	8
2.3. Federe Öğrenme Yöntemi	15
2.3.1. Federe öğrenme yaklaşımının temel işleyişi	16
2.3.2. Federe öğrenmede kullanılan toplama kuralları	17
2.3.3. Federe öğrenme uygulama mimarileri	20
2.3.4. Elektrikli araçlarda federe öğrenme uygulamaları	23
3. MATERYAL VE YÖNTEM	28
3.1. Materyal	29
3.2. Veri setleri	31
3.3. Önerilen Merkezi Öğrenme Temelli Şarj Durumu Tahmini Yöntemleri	33
3.3.1. Derin öğrenme modelleri	34
3.3.2. Makine öğrenimi yöntemi	35
3.4. Önerilen Dağıtık Federe Öğrenme Mimarisi ile Şarj Durumu Tahmini	35
3.4.1. FedACM	37
3.4.2. Diğer toplama kuralları ile karşılaştırma	41
3.5. Önerilen Federe Öğrenme Mimarisi ile Sağlık Durumu Tahmini	42
4. BULGULAR VE TARTIŞMA	47
4.1. Merkezi Öğrenme Temelli Yaklaşımlarda Elde Edilen Sonuçlar	47
4.2. Federe Öğrenme ile Elde Edilen Sonuçlar	53
4.3. Yöntemlerin Karşılaştırılması ve Analizi	58

İÇİNDEKİLER

	<u>Sayfa</u>
4.4. Federe Öğrenme ile Batarya Sağlığı Sonuçları	61
5.SONUÇ VE ÖNERİLER	65
KAYNAKLAR DİZİNİ	67



ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
2.1. LiFePO ₄ bazlı bataryaların OCV eğrileri	5
2.2. En önemli SoC tahmin yöntemleri.....	6
2.3. Farklı SOC seviyelerinde SOH ile $1/V'$ arasındaki korelasyon.....	8
2.4. Transformer model mimarisi.....	11
2.5. FL-IoT için ağ mimarisi ve iletişim süreci.....	15
2.6. Flower çekirdek çerçeve mimarisi.....	22
2.7. DTW sinyali.....	27
3.1. Önerilen FL SoC tahmin mimarisi.....	30
3.2. Musoshi firmasının 3 tekerlekli pop-up mini aracı.....	31
3.3. Tur 1 ve tur 2 boyunca Musoshi aracının güzergahı ve SoC verileri.....	32
3.4. Önerilen Federe Öğrenme algoritmasının çalışma adımları.....	39
3.5. SoH tahmini için sürüş profili karşılaştırmaları.....	43
3.6. Önerilen Federe Öğrenme SoH tahmin çalışma adımları.....	44
4.1. Transformer SoC tahmini (a) Musoshi (b) NASA (c) Stanford (d) BMW i3.....	48
4.2. LSTM SoC tahmini (a) Musoshi (b) NASA (c) Stanford (d) BMW i3.....	49
4.3. Bi-LSTM SoC tahmini (a) Musoshi (b) NASA (c) Stanford (d) BMW i3.....	50
4.4. Musoshi kayıp fonksiyonları (a) Transformer, (b) LSTM ve (c) Bi-LSTM.....	52
4.5. Musoshi SoC tahmini (a) Transformer, (b) LSTM ve (c) Bi-LSTM.....	53
4.6. Musoshi kayıp fonksiyonu.....	54
4.7. Musoshi tur sayıları performans karşılaştırılması.....	55
4.8. Musoshi tüm toplama kuralları için SoC tahmini.....	56
4.9. BMW i3 tüm toplama kuralları için SoC tahmini.....	56
4.10. Stanford tüm toplama kuralları için SoC tahmini.....	57
4.11. NASA tüm toplama kuralları için SoC tahmini.....	57
4.12. Performans karşılaştırması.....	58
4.13. Musoshi aracı ESOGU kampüsü rotası.....	62

ÇİZELGELER DİZİNİ

<u>Cizelge</u>	<u>Sayfa</u>
2.1. FL mimari karşılaştırmaları.....	20
3.1. Musoshi Batarya veri seti.....	32
3.2. Transformer modeli hiper parametreler ve kontrol parametreleri	34
3.3. LSTM ve Bi-LSTM modeli hiper parametreler ve kontrol parametreleri	34
3.4. SVR modeli hiper parametreler ve kontrol parametreleri	35
3.5. FL Deneylerinde kullanılan kontrol parametreleri.....	36
4.1. Merkezi ML ve DL yaklaşımları için kontrol parametreleri	47
4.2. Performans metrikleri karşılaştırması.....	51
4.3. FL kontrol parametre değerleri.....	54
4.4. Toplama kurallarının performans metrikleri.....	59
4.5. İstemci sayısı performans karşılaştırmaları.....	60
4.6. Hesaplama maliyetleri.....	60
4.7. Merkezi ve FL performans metrikleri.....	61
4.8. Farklı modeller için FL performans karşılaştırması.....	61
4.9. Kış testleri sağlık hesaplama sonuçları.....	63
4.10. Yaz testleri sağlık hesaplama sonuçları.....	64

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

σ

$\check{C}_t$

Açıklama

Sigmoid Fonksiyonu

Aday Hafıza Hücresi

Kısaltmalar

AdNN

ANN

AI

BMS

Bi-LSTM

CRM

CSA_FedVeh

DL

DN

DTW

DCCM

EV

EVCSL

FedACM

FedAvg

FedAvg-DWA

FedGM

FedSAC

FFN

FL

FLTN

G2V

GNN

GTA

Açıklama

Uyarlanabilir Sinir Ağı (Adaptive Neural Networks)

Yapay Sinir Ağları (Artificial Neural Networks)

Yapay Zekâ (Artificial Intelligence)

Batarya Yönetim Sistemi (Battery Management System)

Çift Yönlü LSTM (Bidirectional LSTM)

İstemci Rotasyon Yönetimi (Client Rotation Management)

Araç Ağları için İstemci Seçimine Duyarlı Federatif Öğrenme (Client Selection-Aware Federated Learning for Vehicular Networks)

Derin Öğrenme (Deep Learning)

Dağıtım Şebekesi (Distribution Network)

Dinamik Zaman Bükülmesi (Dynamic Time Warping)

Dinamik İstemci Sınırlama Mekanizması (Dynamic Client Capping Mechanism)

Elektrikli Araç (Electric Vehicle)

Elektrikli Araç Şarj İstasyonu Yüğü (Electric Vehicle Charging Station Load)

Federe Uyarlanabilir İstemci Momentumu (Federated Adaptive Client Momentum)

Federe Ortalama (Federated Averaging)

Mesafe Tabanlı Ağırlıklı Toplama ile FedAvg (FedAvg with Distance-based Weighted Aggregation)

Federe Genel Momentum (Federated General Momentum)

Sınırlı İş Birliği Adaleti için Dinamik Alt Model Tahsisli

Federe Öğrenme Çerçevesi (Federated learning framework with dynamic Submodel Allocation for bounded Collaborative fairness)

İleri Beslemeli Sinir Ağı (Feed Forward Neural Network)

Federe Öğrenme (Federated Learning)

Federe Öğrenme Transformer Ağı (Federated Learning Transformer Network)

Şebekeden Araca (Grid to Vehicle)

Çizge Sinir Ağı (Graph Neural Network)

Grafik Tabanlı Anomali (Graph Structures With Transformer Multivariate Time Series Anomaly Detection)

SİMGELER VE KISALTMALAR DİZİNİ

Kisaltmalar

GRU
GTN
IoV
LFP / LiFePO4
Li-ion
LSTM
MAE
ML
MT-RVAE
Non-IID
OCV
PHM
RNN
RUL
RMSE
SoC
SoH
SVR
SVM
STW-DBSCAN
TN
V2AFedEGAT
V2G

Açıklama

Geçitli Yinelemeli Birim (Gated Recurrent Unit)
Geçitli Transformer Ağı (Gated Transformer Networks)
Araçların İnterneti (Internet of Vehicle)
Lityum Demir Fosfat
Lityum İyon
Uzun-Kısa Vadeli Bellek (Long Short-Term Memory)
Ortalama Mutlak Hata (Mean Absolute Error)
Makine Öğrenmesi (Machine Learning)
Çok Değişkenli Zaman Serisi Varyasyonel Oto Enkoder (Multivariate Time Series Variational Autoencoder)
Bağımsız ve Özdeş Olmayan (Non-Independent and Identically Distributed)
Açık Devre Voltajı (Open Circuit Voltage)
Prognostik ve Sağlık Yönetimi (Prognostics and Health Management)
Yinelemeli Sinir Ağı (Recurrent Neural Network)
Kalan Kullanım Ömrü (Remaining Useful Life)
Ortalama Karekök Hatası (Root-Mean-Square Error)
Şarj Durumu (State of Charge)
Sağlık Durumu (State of Health)
Destek Vektör Regresyonu (Support Vector Regression)
Destek Vektör Makineleri (Support Vector Machines)
Uzay-Zaman Ağırlıklı Yoğunluk Tabanlı Gürültülü Uygulama Kümeleme (Spatio-Temporal-Weighted Density-Based Spatial Clustering of Applications with Noise)
Taşıma Ağı (Transfer Network)
Dikey Uyarlanabilir Dikkat Tabanlı Bir Federe Tahmin Yöntemi (Vertical Adaptive Attention-based Federated Prediction Method)
Araçtan Şebekeye (Vehicle to Grid)

1. GİRİŞ VE AMAÇ

Elektrikli araç (EV) filolarının artan kullanımı ile beraber bu araçlarda enerji verimliliği, güvenliği ve sürdürülebilirliği açısından batarya durumunun daha doğru ve güvenilir şekilde izlenmesini önemli hâle getirmiştir. Batarya, elektrikli araçların menzil, performans ve kullanım ömrü gibi kritik özelliklerini doğrudan etkileyen temel bileşendir. Ancak bataryaların zamanla yaşlanması ve çevresel etkileşimlere bağlı olarak farklı hızlarda performans düşmesi, Şarj Durumu (SoC) ve Sağlık Durumu (SoH) gibi göstergelerin doğru tahminini önemli hâle getirmiştir (Deng vd., 2020). Bu tür göstergelerin doğru tahmini, sadece batarya sağlığının izlenmesi için değil, aynı zamanda filo yönetimi, sürüş stratejisi ve bakım planlaması gibi karar destek süreçleri için de kritik öneme sahiptir. Batarya sistemlerinde yaşlanmadan dolayı meydana gelen kapasite düşüşleri, sıcaklık dengesizlikleri ve hücre bozulmaları, aracın performansının yanı sıra, kullanıcı güvenliğini de riske atabilmektedir. Bu nedenle, batarya sistemlerinin durumu hem sürekli olarak izlenmeli hem de geleceğe dönük sağlık tahminleri yapılabilmelidir. Bu amaçla geliştirilen Prognostik ve Sağlık Yönetimi (PHM) sistemleri, bataryaların kalan kullanım ömrünü (RUL) tahmin ederek hem güvenliği hem de verimliliği artırmayı hedeflemektedir (Dong vd., 2021).

Lityum iyon (Li-ion) ve lityum demir fosfat (LiFePO₄ veya LFP) bataryalar, yüksek enerji yoğunluğu ve uzun şarj-deşarj ömrü sayesinde elektrikli araçlarda yaygın olarak kullanılmaktadır (Marongiu vd., 2016). Ancak bu bataryalar da diğer batarya türleri gibi zamanla performans kaybına uğrayabilir ve arızalanabilir. Bu nedenle akıllı bir batarya prognostik sistemi, bataryanın hem güvenli çalışmasını sağlar hem de SoC ve SoH değerlerini sürekli izleyerek performans iyileştirmesi sunduğu için voltaj dengelemesi, aşırı şarj vedeşarja karşı koruma gibi işlevlerle kullanım ömrünü iyileştirir (Hannan vd., 2017). Bataryanın sürekli şarj vedeşarj edilmesi, bataryanın tuttuğu yük kapasitesinin zamanla azalmasına neden olur. Bu sebeple, SoC ve SoH tahminlerinin doğruluğu, batarya ömrünün uzamasını, bakım maliyetlerinin azalmasını ve genel sistem güvenliği sağlaması açısından büyük önem taşır. Bu tahminlerin doğruluğu, batarya sağlığının yansısı, sürücünün güvenliğini ve enerji yönetim sisteminin başarısına katkı sağlar (Yayan vd., 2021).

Batarya sistemlerinin SoH ve SoC tahminleri için kullanılan geleneksel Batarya Yönetim Sistemi (BMS) algoritmaları, bazı çevre ve iç etmenler sebebiyle ölçümde hata yapmakta bu nedenle de yetersiz kalabilmektedir. Bu parametreler arasında batarya hücrelerindeki kimyasal süreçler ve bataryanın yaşlanmasına bağlı olarak iç direnç değişikliği etkili olmaktadır. Bu tür problemler, sensör gürültüsüne ve ölçüm hatalarına neden olabilmekte ve tahminlerde yanlışlık yapabilmektedir (Yu vd., 2020). Bu zorlukların üstesinden gelebilmek için yapay zekâ (AI) ve makine öğrenmesi (ML) tabanlı yöntemler ön plana çıkmıştır. Özellikle zaman serisi verileriyle çalışmaya elverişli olan derin öğrenme yaklaşımları, batarya dinamiklerini modellemede etkili araçlar sunmaktadır. Transformer mimarisi, öz dikkat (self-attention) mekanizması sayesinde zamansal bağımlılıkları yakalamada yüksek başarı sağlamış ve SoC tahmini alanında geleneksel yöntemlerin ötesine geçmiştir. Model, ani şarj-deşarj değişimlerine duyarlılığı sayesinde batarya sistemlerindeki gerçek zamanlı değişimlere daha iyi uyum sağlamaktadır (Wen vd., 2023). Transformer modeli, Uzun-Kısa Vadeli Bellek (LSTM), Çift Yönlü LSTM (Bi-LSTM) ve Destek Vektör Regresyonu (SVR) gibi diğer yaklaşımlarla karşılaştırıldığında, doğruluk açısından üstün performans sergilemiş ve özellikle Musoshi L5 elektrikli aracı gibi gerçek dünya verileriyle yapılan testlerde daha yüksek başarı oranı elde etmiştir. Bu durum, SoH/SoC tahmininde Transformer mimarisinin uygulanabilirliğini ve katkısını gözler önüne sermektedir (Yılmaz vd., 2025a).

Merkezi öğrenme yaklaşımlarının üstün tahmin başarılarına karşın, veri iletimi için yüksek bant genişliği ihtiyacı ve veri mahremiyeti kaygıları gibi önemli problemler barındırmaktadır. Bu problemleri çözecek şekilde Federe Öğrenme (FL) yaklaşımları, son yıllarda birçok alanda başarıyla uygulanmıştır. FL, eğitimi istemcilerde gerçekleştirdiği için verinin yerel cihazda kalmasını sağlayarak sadece model ağırlıklarını merkezi sunucuya gönderir. Böylece veri iletişim yükü azaltılmış ve veri mahremiyeti sağlanmış olur (McMahan vd., 2017). Literatürde FL ile SoC tahmini üzerine yapılan öncü çalışmalar, verileri ön işleme ile homojenleştirerek çalışma yapmışlardır (Lai vd., 2024). En yaygın ağırlık güncelleme yöntemi olan Federe Ortalama (FedAvg) homojen verilerde yüksek başarımlar sağlasa da veri heterojen olduğu durumda yeterince iyi sonuçlar verememektedir. Bu nedenle, FL tabanlı sistemlerde daha etkili ve duruma özel optimizasyon stratejileri geliştirme ihtiyacı doğmuştur (Bian ve Zheng, 2023).

Bu tezde sunulan çalışma, FL mimarisi üzerinde, istemci bazlı momentum atamasını gerçekleştiren, yeni bir ağırlık toplama (aggregation) kuralı, Federe Uyarlanabilir İstemci Momentumu (FedACM) yaklaşımını önermektedir. Bu yöntemin amacı, her istemcinin momentum parametresini belirlenen kurallara göre atayarak, heterojen veri durumlarında daha doğru tahminler elde etmektir. Önerilen yöntem, literatürde yaygın olarak kullanılan toplama kuralları; FedAvg, Mesafe Tabanlı Ağırlıklı Toplama ile FedAvg (FedAvg-DWA), Federe Genel Momentum (FedGM) ve Average Drift yaklaşımları karşılaştırılmış ve NASA, BMW i3, Stanford ve Musoshi L5 gibi çeşitli veri kümeleri üzerinde yapılan deneysel çalışmalarda başarı ile test edilmiştir. Gerçek uygulamalarda oluşan farklı tip batarya verisi sebebiyle heterojen veri durumunda, daha düşük ortalama karekök hatası (RMSE), ortalama mutlak hata (MAE) değerleri ve daha yüksek R^2 skoru ile FL diğer yaklaşımlara karşı üstün olduğu gözlemlenmiştir. Bu sonuçlar, yöntemin farklı elektrikli araçlara sahip filolarda uygulanabilirliğini göstermektedir (Yılmaz vd., 2025b).

Ayrıca SoH tahmini için FL tabanlı bir yaklaşım sunulmuştur. Sabit bir rotadan toplanan sürüş verileriyle, sürücü davranışları hız tabanlı özniteliklerle analiz edilerek Dinamik Zaman Bükülmesi (DTW) algoritmasıyla benzerlik ölçülmüştür. Bu benzerlik ölçümüne dayanarak her istemciye bir ağırlık değeri atanmıştır; bu ağırlıklar, toplama kuralı üzerinde doğrudan etki ederek, daha benzer profillere sahip istemcilerin global modele daha fazla katkıda bulunmasını sağlayarak modelin daha hızlı ve doğru yakınsamasına olanak tanır. SoH değeri, birim SoC değişimine karşılık gelen mesafe üzerinden hesaplanmış ve FL yaklaşımıyla global tahmin elde edilmiştir.

Tezin yapısı şu şekildedir. Takip eden bölümde, önerilen çalışmalarla ilgili detaylı literatür taraması verilmektedir. Üçüncü bölümde, araştırmada kullanılan materyaller ve önerilen yöntemler ayrıntılı olarak açıklanmıştır. Dördüncü bölümde, elde edilen bulgular sunulmuş ve ilgili tartışmalar yapılmıştır. Beşinci bölümde ise çalışmadan elde edilen sonuçlar özetlenmiş ve gelecekte yapılabilecek çalışmalara yönelik önerilerde bulunulmuştur.

2. LİTERATÜR ARAŞTIRMASI

EV filolarının artan kullanımı, batarya performansı, enerji verimliliği ve donanım sağlığının doğru biçimde izlenmesi ihtiyacını da beraberinde getirmiştir. Özellikle batarya sistemleri, EV'lerin menzil, güvenlik ve ekonomik ömrü gibi kritik özelliklerini doğrudan etkileyen temel bileşenlerdir. Bu araçlardaki en önemli parçalardan biri olan batarya sistemleri, araç için enerji kaynağı olmasının yanında, araç performansı, menzil ve güvenlik açısından da kritik bir etmendir. Batarya sistemleri, şarj tahmini ve batarya sağlığının izlenmesi gibi görevleri yürüten algoritma ve yapay zekâ yaklaşımlara ihtiyaç duymaktadır. Bu sebeple, son yıllarda merkezi öğrenme içeren yöntemlerin zaman serisi veriler üzerindeki başarısı ile birlikte, veri gizliliği ve dağıtık öğrenme ihtiyacını karşılayan dağıtık sistem yaklaşımları da öne çıkmıştır.

2.1. Batarya Sağlık Yönetimi

Elektrikli araçlarda enerji sağlamak için, yüksek enerji yoğunluğu, düşük ağırlık ve bakım ihtiyacının az olması gibi nedenlerden ötürü Li-ion ve LFP türünde bataryalar tercih edilmektedir (Bala vd., 2012; Raszmann vd., 2017; Sun vd., 2020; Tingting vd., 2011). Bu bataryaların performanslı çalışmasını sağlamak için hem donanım hem de yazılım bileşenlerinden oluşan Batarya Yönetim Sistemi (BMS) geliştirilmiştir. Bu sistemler, sıcaklık kontrolü, şarj/deşarj yönetimi, hücre dengeleme ve arıza tespiti gibi görevleri yerine getirir (Daowd vd., 2014). Geleneksel BMS çözümleri çoğunlukla fiziksel modellere dayanırken, son yıllarda veriye dayalı yapay zekâ tabanlı çözümler öne çıkmaktadır (Allam vd., 2015). Bu yapay zekâ modelleri, tahminleme doğruluğunu artırmakta ve sistemlerin çevre koşullarına adapte olmasını sağlamaktadır (Rezvani vd., 2011).

BMS'nin temel görevlerinden biri, bataryaya ait voltaj, akım, sıcaklık gibi fiziksel parametrelerin düzenli olarak izlenmesidir (Rahimi-Eichi vd., 2013). Özellikle sıcaklık ve titreşim gibi çevresel etkenlerin, batarya performansı üzerinde doğrudan etkili olduğu, kapasite kaybı ve bozulmalara neden olabileceği gösterilmiştir (Tingting vd., 2011). Bu bozulmaları tahminleyerek bataryanın ne kadar etkili bir şekilde kullanılacağını RUL

hesaplanabilir (Rivera-Barrera vd., 2017; Wu vd., 2016). Bu hesaplama Denklem 2.1’de gösterilmiştir (Javed vd., 2017).


$$RUL = T_f - T_c \quad (2.1)$$

BMS için önemli parametrelerden biri elektrikli araç şarj göstergesi olan Şarj Durumu (SoC)’dir. Bu değer bataryanın doluluk oranını belirtir ve kullanılabilir kapasitenin yüzdesi olarak tanımlanır (Rivera-Barrera vd., 2017). SoC tahmini için genellikle akım-zaman değişimi göz önüne alınır, Denklem 2.2’deki gibi gösterilir (Rezvanizani vd., 2014).

$$SoC(t) = \frac{\int_{t_0}^t I_b(\tau) d\tau}{Q_0} \times 100\% \quad (2.2)$$


SoC aynı zamanda açık devre voltajı (OCV) temelli olarak da tahmin edilebilir; ancak OCV-SoC ilişkisi batarya türüne bağlı olarak değiştiğinden ve araç hareket halinde açık devre voltajı ölçmenin mümkün olmadığından sınırlı bir yöntemdir (Li, 2018; Tingting vd., 2011).

OCV, bataryanın boşta (yük altında olmayan) ölçülen voltajıdır ve SoC ile ilişkili olarak kullanılabilir (Şekil 2.1). Ancak bataryalarda gözlenen histerezis nedeniyle, OCV değerleri şarj ve deşarj sırasında farklılık gösterir. Bu da modellerde dikkat edilmesi gereken bir faktördür (Roscher ve Sauer, 2011).



Şekil 2.1. LiFePO4 bazlı bataryaların OCV eğrileri (Roscher ve Sauer, 2011)

Batarya sağlık yönetimi üzerine yapılan incelemeler, üreticiler, araç tasarımcıları ve kullanıcılar için karşılaşılan zorlukları ortaya koymaktadır (Javed vd., 2017; Qian vd., 2011). Özellikle batarya PHM tekniklerinin kapsamlı analizleri, bu alanda gelecekte yapılacak araştırmaların yönünü belirlemede önemlidir. SoC tahmininde kullanılan yapay zekâ tabanlı yöntemler, dolaylı ve doğrudan olarak sınıflandırılmaktadır. Şekil 2.2 bazı örneklerle SoC teknikleri sınıflandırmasının özetini göstermektedir (Chiang vd., 2011; Piller vd., 2001).



Şekil 2.2. Yapay zekâ SoC tahmin yöntemleri

BMS ile ilgili literatürde zaman serisi analiz yöntemlerinin yaygın olarak kullanıldığı görülmektedir. Sensörlerden elde edilen voltaj, akım ve sıcaklık gibi parametreler zamana bağlı olarak değiştiği için, bu verilerin modellenmesi, anomali tespiti ve tahmininde zaman serisi işleme yöntemlerinden yararlanılmaktadır (Dong vd., 2021).

BMS; yazılım algoritmaları, sensörler, kontrol birimleri ve iletişim donanımlarından oluşan, batarya takımının SoH, SoC ve RUL gibi bilgilerini izleyen ve yöneten bir sistemdir (Andwari vd., 2017; Guo vd., 2021). BMS, yalnızca güvenli ve verimli enerji yönetimini sağlamakla kalmaz, aynı zamanda bakım ve sistem yapılandırmasını destekleyen karar süreçlerinde de kullanılır (Javed vd., 2017). Modüler yapıda tasarlanan BMS’lerde her modül, kendi yönetim sistemi ile çalışırken, bu modüller merkezi bir sistem ile kontrol edilir (Li, 2018). BMS kendi içerisinde bu sistemleri yönetirken, BMS’ten alınan veriler ile akıllı sistem tasarımları gerçekleştirilerek bu kontrol ve yönetim sistemleri iyileştirilebilir.

SoC'nin %100 göstermesi durumunda her zaman aynı menzile aynı güç sağlanmayabilir. Burada aracın SoH değerinin de bilinmesi gerekir. Aracın kapasitesi için SoH değerinin bilinmesi gerekir. SoH, bir bataryanın mevcut maksimum kullanılabilir kapasitesinin, orijinal nominal kapasitesine göre yüzde olarak ifadesidir. Batarya yaşlandıkça SoH değeri düşer. Bataryanın kullanımda olup olmadığına bakılmaksızın, zamana, sıcaklığa ve depolama SoC'sine bağlı olarak meydana gelen kapasite kaybına takvimsel yaşlanma denir. Bataryanın aktif kullanımı, yani şarj ve deşarj sonucu oluşan kapasite kaybına ise Döngü Dejenerasyonu denir (Thingvad vd., 2021).

Bataryanın sağlık göstergesi olan SoH, bataryanın başlangıçtaki nominal kapasitesine göre mevcut kapasitesini ifade eder ve Denklem 2.3'teki şekilde hesaplanır (Wu vd., 2021).


$$SoH = \frac{C_t}{C_0} \times 100 \quad (2.3)$$

Burada C_t mevcut maksimum kullanılabilir kapasitedir ve C_0 bataryanın çalışmaya başladığı andaki kapasiteyi temsil eder. SoH belirleme genellikle kapasite ve iç direnç gibi ölçümlerle yapılır, ancak bu değerler doğrudan ölçülemeyen tahmini değerlerdir (Sarmah vd., 2019).

Huang vd., (2017) bir çalışmada, SoC ve SoH tahmininde kullanılabilecek regresyon modelleri geliştirilmiştir. SoC ile batarya voltajı (V) ve V' parametresi arasındaki korelasyon incelenmiş ve bu parametre deşarj süresinde bataryanın iç direncindeki değişim oranı ($\Delta V / \Delta t$) olarak tanımlanmıştır. Bu parametrenin yaşlanma etkisini yansıttığı gösterilmiştir. Bu nedenle, V' parametresi sadece SoC tahmini için değil, aynı zamanda batarya yaşlanmasına bağlı olarak SoH tahmini için de kullanılabilir hale gelmiştir. Bu bağlamda önerilen iki regresyon modeli Denklem 2.4'teki gibidir.

$$\begin{aligned} SoC(\%) &= a \cdot V + b \cdot (1/V') + c \\ SoH(\%) &= A \cdot (1/V') + B \end{aligned} \quad (2.4)$$

Şekil 2.3'te farklı SoC seviyelerinde SoH ile $1/V'$ arasındaki ilişkiyi göstermişlerdir. Tüm SoC seviyeleri (40%–90%) için SoH ile $1/V'$ arasında oldukça yüksek bir doğrusal korelasyon ($r > 0.99$) gözlemlenmiştir.



Şekil 2.3. Farklı SoC seviyelerinde SoH ile $1/V'$ arasındaki korelasyon (Huang vd., 2017)

Denklem 2.5'te formülü verilen RMSE, SoC tahmin modellerinin performansının testi için kullanılan başlıca performans göstergelerinden biridir. (Wu vd., 2021):

$$RMSE = \sqrt{\frac{1}{m} \sum_{j=1}^m (SOH_j - \hat{SOH}_j)^2} \quad (2.5)$$

Burada SOH_j ve $\hat{SOH}_j$, sırasıyla gerçek SoH ve tahmini SoH olup m örnek sayısıdır.

2.2. Makine Öğrenmesi ve Derin Öğrenme Yöntemleri

Batarya şarj tahmininde, makine öğrenmesi ve derin öğrenme gibi yaklaşımlar sıklıkla tercih edilmektedir. Bu yaklaşımlar, tüm verilerin tek bir sunucuda toplanıp işlemektedir. ML ve Derin Öğrenme (DL) teknikleri, batarya performans verilerinden öğrenerek daha doğru ve sağlam SoC tahminleri sunma potansiyeliyle öne çıkmaktadır.

Makine öğrenmesi tabanlı yaklaşımlar, batarya gerilimi, akım, sıcaklık ve döngü sayısı gibi çeşitli ölçülebilir parametreler ile gerçek SoC arasındaki karmaşık, doğrusal olmayan ilişkileri öğrenme yeteneğine sahiptir. Bu modeller, doğrudan bataryanın fiziksel veya elektrokimyasal modelini oluşturmaya gerek duymadan, büyük veri setleri üzerinden eğitilir. Örneğin, Yapay Sinir Ağları (ANN), Destek Vektör Makineleri (SVM), Rastgele Orman (Random Forest) gibi ML algoritmaları ve özellikle zaman serisi verileri için oldukça uygun olan LSTM gibi derin öğrenme modelleri, çeşitli çalışma koşulları altında bataryanın dinamik davranışlarını modelleyerek yüksek doğrulukta SoC tahmini yapabilirler (Kim ve Lee, 2024; Wu vd., 2025). Bu yöntemler, geleneksel yaklaşımların karşılaştığı model uyumsuzluğu ve parametre tanımlama zorluklarının üstesinden gelerek, bataryaların gerçek dünya koşullarındaki karmaşık davranışlarını daha iyi yansıtır.

SVR:

Bu tezde SoC tahmini için kullanılan makine öğrenim yöntemi olan Destek Vektör Regresyonu (SVR), regresyon problemlerini çözmek için kullanılmıştır (Awad ve Khanna, 2015). Literatürde SVR'nin SoC tahmininde yaygın olarak tercih edildiği görülmektedir (Kumar vd., 2024; Lombardi vd., 2024; Youssef vd., 2024). Yüksek boyutlu verilerle çalışırken karmaşık ilişkileri modellemek için uygundur. SVR, doğrudan bir regresyon doğrusu çizmek yerine, verilerin bir marjın (tolerans aralığı) içinde kalmasını hedefler. Bu marjın, doğrusal tahmin eğrisi ile veri noktaları arasındaki maksimum mesafeyi tanımlar. SVR, destek vektörlerini kullanır. Bu noktalar, regresyon çizgisine en yakın olanlardır ve marjın hesaplamasında kritiktir.


Transformer modeli:

Literatür irdelendiğinde son dönemde makine öğrenmesi yerine derin öğrenme yöntemlerinin sıklıkla kullanıldığı görülmektedir (Wu vd., 2025). Bu bağlamda, Transformer, LSTM ve Geçitli Yinelemeli Birim (GRU) gibi modeller öne çıkmaktadır (Yılmaz vd., 2025a). Bunun temel nedeni, SoC tahmininde batarya verilerinin zamansal bağımlılık ve karmaşık doğrusal olmayan ilişkiler içermesi, derin öğrenme modellerinin ise bu tür dinamikleri makine öğrenmesine kıyasla daha yüksek doğrulukla modelleyebilmesidir.

Transformer modeli, ilk olarak doğal dil işleme alanında kullanılmak üzere geliştirilmiş olsa da “çok başlı dikkat mekanizması” (multi-head attention) ve “pozisyonel kodlama” gibi özellikleri sayesinde zaman serisi verilerde de yüksek başarı sağlamıştır (Vaswani vd., 2023; Wen vd., 2023). Bu modeller, LSTM ve GRU gibi geleneksel sıralı modellere kıyasla paralel çalışabilmeleri ve uzun dönem veri ilişkileri daha iyi yakalayabilmeleri nedeniyle tercih edilmektedir. Ancak klasik Transformer mimarisinin hesaplama yükü ve bellek tüketimi oldukça fazladır. Bu nedenle literatürde çeşitli optimizasyon yöntemleri önerilmiştir. Katman bazlı optimizasyon (You vd., 2019), dağıtık eğitim stratejileri (Lepikhin vd., 2020), bilgi aktarımı (Qin vd., 2022), progresif eğitim (Li vd., 2022) ve küçük modellerin çıktılarının büyük modellere aktarılması gibi yaklaşımlar (Wang vd., 2023), Transformer mimarisinin pratik uygulamalardaki sınırlamalarını azaltmayı amaçlamaktadır.

Transformer mimarisinin daha etkili hale gelmesi için literatürde çok sayıda yapı önerilmiştir. Bunlar arasında Autoformer, zaman serisi bileşenlerini (trend ve mevsimsellik) ayırıştırarak model başarısını artırmayı hedeflerken (Wu vd., 2022), FEDformer farklı frekans bileşenlerine odaklanarak model performansını geliştirmeyi amaçlamaktadır (Zhou vd., 2022). Geçitli Transformer Ağı (GTN) ise zaman ve kanal tabanlı dikkat mekanizmalarını birlikte kullanarak sınıflandırma görevlerinde yüksek başarı sağlamıştır (Liu vd., 2021). Bu gelişmiş yapılar, elektrikli araç batarya verilerindeki karmaşık ve çok boyutlu ilişkileri öğrenmek için büyük potansiyel taşımaktadır. Batarya sistemlerinde, özellikle güvenli sürüş için kritik olan ani sıcaklık artışı ve beklenmeyen voltaj dalgalanmaları gibi anormalliklerin deşarj akımıyla ilişkisini öğrenmek, bu anomalilerin batarya arızasına dönüşüp dönüşmeyeceğini erken safhada öngörmeye yardımcı olur. Bu bağlamda Çok Değişkenli Zaman Serisi Varyasyonel Oto Enkoder (MT-RVAE) (Wang vd., 2022), TransAnomaly (Zhang vd., 2021) ve Grafik Tabanlı Anomali (GTA) modeli (Chen vd., 2022), çok boyutlu zaman serisi veriler üzerinde anomali tespiti için öne çıkan çalışmalardır. Han vd. (2025) çalışmasında, kısmi örnekleme noktaları kullanılarak eksik şarj eğrisinin tamamını tahmin etmek ve batarya dinamik parametrelerini çıkarmak için iyileştirilmiş Transformer yapısı önerilmiştir. Shi vd. (2025) makalesi, sadece şarj verileri kullanarak CVT (Constant Voltage Time) özelliğini çıkaran ve BiLSTM-Transformer modelini kullanarak lityum-iyon bataryaların sağlıklı durum tahminini gerçekleştiren bir yöntem sunmaktadır.

Bu tezde tahminde kullanılan yöntem, Şekil 2.4'te model mimarisi gösterilen Encoder ve Decoder katmanlarından oluşan Transformer modelidir (Wu vd., 2020). Encoder, giriş katmanı ile verileri dönüştürür. Girdi dizilerinin sıralı yapısını kodlamak için sinüzoidal ve kosinüs bazlı konumsal kodlama eklenir. Bu işlemin ardından her biri “çoklu başlı öz-dikkat” (multi-head self-attention) ve İleri Beslemeli Sinir Ağı (FFN) alt katmanlardan oluşan dört encoder katmanı devreye girer. Encoder, d_{model} boyutunda bir vektör üretir. Bu değer, Transformer modelinin çalıştığı vektör uzayının boyutunu ifade eder ve gizli katmanların ve gömme (embedding) katmanlarının boyutlarını belirleyen bir hiper parametredir.



Şekil 2.4. Transformer model mimarisi

Decoder, giriş katmanı ile başlar ve Encoder'dan gelen veriyi kullanır. Giriş verisini yine d_{model} boyutunda bir vektöre dönüştürür. Her decoder katmanı “çoklu başlı öz-dikkat mekanizmaları” ve ileri beslemeli katmanlar içerir. Ayrıca Decoder, Encoder çıktısına yönelik öz-dikkat uygular. Çıkış katmanı, tahminleri hedef zaman serileriyle hizalar. Tahminler, önceki veri noktalarına ve konumsal kaydırmalarla birlikte öz-dikkat mekanizmalarına dayanır.

Her encoder katmanı; self-attention, toplama ve normalizasyon (add & normalize) ve ileri beslemeli katmanlardan oluşur. Girdiye konumsal kodlama uygulanır. Decoder

katmanları, giriş ve çıkış dizileri arasındaki etkileşimi kolaylaştırmak için ek olarak encoder-decoder dikkat mekanizması içerir. Bu mimari, sıralı verilerin verimli işlenmesini ve bağlamsal anlamlandırılmasını mümkün kılar.

Transformer modeli, sıralı bilgiyi öğrenmek için yinleme (recurrence) ve evrimsel (convolution) işlemlerini ortadan kaldırır; bunun yerine konumsal kodlama kullanır. Konumsal kodlamalar embedding'lerle aynı boyuttadır (d_{model}) ve bu sayede toplanabilir. Konumsal kodlama Denklem 2.6 ve Denklem 2.7'deki sinüs ve kosinüs fonksiyonlarıyla hesaplanır (Vaswani vd., 2023).

$$PE_{(pos,2i)} = \sin\left(\frac{pos}{10.000^{2i/d_{model}}}\right) \quad (2.6)$$

$$PE_{(pos,2i+1)} = \cos\left(\frac{pos}{10.000^{2i/d_{model}}}\right) \quad (2.7)$$

Burada pos pozisyonu, i boyutu ve d_{model} modelin boyutunu ifade eder. Her boyut, geometrik olarak artan dalga boylarına sahip bir sinüzoidal fonksiyon ile temsil edilir (2π 'den $10.000 \cdot 2\pi$ 'ye kadar).

Transformer'daki FFN, iki doğrusal dönüşüm ve arada ReLU aktivasyon fonksiyonu içerir (bkz. Denklem 2.8). Bu yapı, modelin ifade gücünü artıran etkili bir bileşendir (Vaswani vd., 2023).

$$FFN(H_0) = ReLU(H_0 W_1 + b_1) W_2 + b_2 \quad (2.8)$$

Burada H_0 önceki katmandan gelen çıktıdır, $W_1 \in \mathbb{R}^{d_f \times d_{model}}$, $W_2 \in \mathbb{R}^{d_{model} \times d_f}$, $b_1 \in \mathbb{R}^{d_f}$, and $b_2 \in \mathbb{R}^{d_{model}}$ ağırlık ve bias vektörlerini ifade eder.

Kalıntı bağlantılar, bir katmanın çıktısını bir sonraki katmanın girişine bağlar. Bu bağlantıların ardından uygulanan katman normalizasyonu, modelin eğitim sürecini stabilize eder ve yakınsama başarisini artırır (Denklem 2.9-2.10) (Vaswani vd., 2023).

$$H_0 = \text{LayerNorm}(\text{SelfAttention}(X) + X) \quad (2.9)$$

$$H = \text{LayerNorm}(\text{FFN}(H_0) + H_0) \quad (2.10)$$

Burada SelfAttention, öz-dikkat modülünü; LayerNorm, normalizasyon işlemini; X ise giriş verisini temsil eder.

Transformer'ın temel yeniliği, “çoklu başlı öz-dikkat” katmanları içinde gömülü olan öz-dikkat mekanizmasıdır. Bu mekanizma, modelin tahmin sırasında girişteki farklı öğelerin görelî önemini değerlendirmesini sağlar. Geleneksel sabit pencere boyutlarına bağlı kalmadan, tüm girdiler arasındaki ilişkileri aynı anda göz önünde bulundurur.

Transformer, ölçekli iç çarpım dikkatini hesaplamak için Sorgu-Anahtar-Değer (Query (Q)-Key (K)-Value (V)) çerçevesini kullanır (Denklem 2.11) (Vaswani vd., 2023).

$$\text{Attention}(Q, K, V) = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right) V \quad (2.11)$$

Paralel olarak çalışan çıktıları birleştirilerek, “çoklu başlı dikkat mekanizmasının” çıktısı oluşturulur (Denklem 2.12) (Vaswani vd., 2023).

$$\begin{aligned} \text{MultiHead}(Q, K, V) &= \text{Concat}(h_1, \dots, h_n)W^0 \\ h_i &= \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \end{aligned} \quad (2.12)$$

Burada W_i^Q, W_i^K, W_i^V parametre metrikleridir. Transformer'lar, son dönemde SoC tahmini alanında literatürde yoğun olarak araştırılan ve umut vadeden bir derin öğrenme mimarisidir. Mevcut çalışmalar genellikle laboratuvar ortamlarında elde edilen kontrollü veri setleri veya açık kaynaklı veri setleri kullanılarak gerçekleştirilmiştir. Bu tez çalışması ise, Transformer tabanlı SoC tahminini gerçek dünya uygulamalarında kullanan öncü bir yaklaşım sunmaktadır.

LSTM:

SoC tahmininde karşılaştırma için kullanılan, Yinelemeli Sinir Ağı (RNN) türünde bir yöntem olan LSTM'dir. LSTM hücresi; unutma (forget), giriş (input) ve çıkış (output) kapılarından oluşur. LSTM'nin iç yapısı Denklem 2.13'te gösterilmiştir (Yayan vd., 2021).

$$\begin{aligned}
 F_t &= \sigma(W_{hf} H_{t-1} + W_{xf} X_t + b_f) \\
 I_t &= \sigma(W_{hi} H_{t-1} + W_{xi} X_t + b_i) \\
 \check{C}_t &= \tanh(W_{hc} H_{t-1} + W_{xc} X_t + b_c) \\
 C_t &= F_t * C_{t-1} + I_t * \check{C}_t \\
 O_t &= \sigma(W_{ho} H_{t-1} + W_{xo} X_t + b_o) \\
 H_t &= O_t * \tanh(C_t)
 \end{aligned} \tag{2.13}$$

Burada F_t unutma kapısı, I_t giriş kapısı, $\check{C}_t$ aday hafıza hücresi, C_t hafıza hücresi, O_t çıkış kapısı, H_t gizli durum, X_t girdi ve H_{t-1} bir önceki zaman adımının gizli durumu olarak tanımlanır. W ile başlayanlar ağırlık matrisleri, b ile başlayanlar bias terimleridir. σ sigmoid fonksiyonu, $\tanh$ ise hiperbolik tanjant fonksiyonudur.

Bi-LSTM:

SoC tahmininde kullanılan bir diğer yöntem de Çift Yönlü LSTM (Bi-LSTM)'tir. Çift yönlü LSTM biriminden oluşan bu yöntem, sıralı veriler üzerinde ileri (forward) ve geri (backward) işlem yapar. Bi-LSTM'nin yapısı Denklem 2.14'teki gibidir (Yayan vd., 2021).


$$y_t = \sigma(h_{b,t}, h_{f,t}) \tag{2.14}$$

Burada $h_{b,t}$ geri yöndeki gizli durum, $h_{f,t}$ ise ileri yöndeki gizli durumdur.

Literatürdeki makine öğrenmesi ve derin öğrenme yaklaşımlarına bakıldığında, SoC veya SoH tahmini için ilgili tüm verilerin merkezi sunucuya toplanması ihtiyacı EV filoları için uygulanabilir olmayabilir. Diğer taraftan filodaki farklı EV'lerde farklı alt algoritmaların çalışması, yeni araçların kullanacağı modeller konusunda karmaşa oluşturacaktır. Bu bağlamda tüm EV filo üyeleri için ortak SoC ve SoH hesaplaması değerli olmaktadır.

2.3. Federe Öğrenme Yöntemi

Dağıtık SoC ve SoH tahmin yöntemi için kullanılan FL, verilerin EV'lerde yerel olarak tutulduğu, yalnızca model parametrelerinin merkezi sunucuya gönderildiği bir öğrenme yöntemidir. Bu yapı, özellikle veri mahremiyeti ve bant genişliğinin önemli olduğu uygulamalarda tercih edilmektedir (Bian ve Zheng, 2023; Lazzarini vd., 2023; Rani vd., 2024). FL literatürde mobil cihazlar başta olmak üzere, Nesnelerin İnterneti (IoT) sistemleri temelli sistemlerde etkin şekilde kullanılmaktadır. Şekil 2.5'te IoT cihazlarında FL kullanıma ilişkin genel mimari gösterilmektedir (Nguyen vd., 2021).



Şekil 2.5. FL-IoT için ağ mimarisi ve iletişim süreci (Nguyen vd., 2021)

IoT ağlarında FL kavramı, iki ana bileşenden oluşur: veriye sahip istemciler (örneğin, IoT cihazları) ve bir merkezi sunucu veya erişim noktasında konumlanan bir toplama sunucusu. Katılımcılar kümesi akıllı telefon, dizüstü bilgisayar, uç cihazlar veya tablet gibi IoT cihazlarını kullanarak ortak bir FL algoritması uygular. Örneğin, bir IoT tabanlı araç ağında, araçlar yol durumu verilerini toplayarak trafik sıkışıklığını azaltmaya yönelik ortak bir yönlendirme haritası oluşturmak için FL sürecine katılabilirler (Nguyen vd., 2021).

2.3.1. Federe öğrenme yaklaşımının temel işleyişi

FL çalışma süreci genel olarak şu temel adımlardan oluşur:

Adım 1. Sistem Başlatma ve Cihaz Seçimi: Toplayıcı sunucu, örneğin insan aktivitesi tanıma gibi bir IoT görevini belirler ve öğrenme oranı, iletişim tur sayısı gibi parametreleri ayarlar. Katılacak cihazlar, kanal koşulları ve güncelleme önemine göre seçilir.

Adım 2. Dağıtık Yerel Eğitim ve Güncellemeler: Sunucu, başlangıç global modeli w_G^0 oluşturur ve bunu istemcilere göndererek eğitim sürecini başlatır. Her bir istemci k , kendi verisi üzerinde yerel bir model w_k eğitir ve bu modeli bir kayıp fonksiyonunu minimize ederek günceller. Bu yaklaşım Denklem 2.15’de gösterilmiştir (Nguyen vd., 2021).

$$w_k^* = \arg \min \mathcal{F}_{loss}(w_k), k \in \mathcal{K}. \quad (2.15)$$

$\{x_i, y_i\}_{i=1}^K$ giriş çıkış çiftleri için, doğrusal regresyon FL modeli kayıp fonksiyonu Denklem 2.16’teki şekilde tanımlanabilir (Nguyen vd., 2021).

$$\mathcal{F}(w_k) = \frac{1}{2} (x_i^T w_k - y_i)^2 \quad (2.16)$$

Adım 3. Model Toplama ve Dağıtma: İstemciler modellerini sunucuya ilettikten sonra $|D_k|$ boyutundaki veri kümesi için, sunucu bu yerel modelleri toplayarak Denklem 2.17’deki gibi yeni bir global model oluşturur (Nguyen vd., 2021).

$$w_G = \frac{1}{\sum_{k \in \mathcal{K}} |D_k|} \sum_{k=1}^K |D_k| w_k \quad (2.17)$$

Bu işlem, tüm istemcilerin aynı modeli paylaşmasını sağlayan Denklem 2.18'deki optimizasyon problemiyle ifade edilir (Nguyen vd., 2021).

$$\begin{aligned} (P1): \min_{w_k \in \mathcal{K}} \frac{1}{K} \sum_{k=1}^K \mathcal{F}(w_k) \\ (C1): w_1 = w_2 = \dots = w_K = w_G \end{aligned} \quad (2.18)$$

Burada PI , her bir istemcinin (kullanıcının) yerel modeline karşılık gelen kayıp fonksiyonlarının ortalamasını minimize etmeyi hedefleyen bir optimizasyon problemidir. K , toplam istemci sayısıdır. $F(w_k)$, k -inci istemcinin modeline ait yerel kayıp fonksiyonu, tüm istemcilerdeki modellerin ortalama kaybını en aza indirmeyi amaçlar. CI (constraint), tüm istemcilerin model parametrelerinin aynı olmasını, yani tek bir global model (w_G) paylaşmalarını şart koşar. Sunucu yeni global modeli tekrar tüm istemcilere gönderir. Bu süreç, global kayıp fonksiyonu yakınsayana kadar veya istenen doğruluk seviyesine ulaşılan dek tekrarlanır.

2.3.2. Federe öğrenmede kullanılan toplama kuralları

FL'de farklı istemcilerden gelen ağırlık katsayılarının birleştirilip ortak model çıkartılmasında toplama kuralları kullanılmakta olup istemcilere gelen modelin karakteristiğine bağlı uygun toplama kuralı seçimi ve tanımlaması sistem öğrenme performansını etkilemektedir.

FL toplama kulları arasında en yoğun kullanılan yöntem olan FedAvg (McMahan vd., 2017), tüm katılımcıların eşit katkı sağladığı varsayımıyla, model parametrelerini basit bir ağırlıklı ortalama mekanizmasıyla günceller (Denklem 2.19).

$$f(w) = \sum_{k=1}^K \frac{n_k}{n} \mathcal{F}_k(w), \quad \mathcal{F}_k(w) = \frac{1}{n_k} \sum_{i \in \mathcal{P}_k} f_i(w) \quad (2.19)$$

Burada, model parametreleri w ile gösterilmektedir. K , toplam istemci sayısını, n , tüm istemcilerdeki toplam örnek sayısını ve n_k , k -inci istemcinin elindeki örnek sayısını ifade eder. Veriler, K adet istemciye dağılmış durumdadır ve P_k , k -inci istemcide bulunan veri noktalarının indis kümesini temsil eder. Denklem 2.20, FedAvg yönteminde kullanılan ağırlıklı ortalamayı ifade eder ve her bir istemcinin güncellemesinin eşit katkı sağladığı varsayımına dayanır. Buna karşılık, Denklem 2.21, yerel gradyanlara (eğrilere) dayalı model güncellemesini tanımlar.

$$w_t^k \leftarrow \sum_{k=1}^K \left(\frac{n_k}{n} w_t^k \right) \quad (2.20)$$

$$w_{t+1}^k \leftarrow w_t^k - \nabla w_t^k \quad (2.21)$$

FL'nin klasik yöntemi olan FedAvg, tüm istemcilerin ağırlıklarının ortalamasını alarak global modeli günceller. Ancak veri heterojenliği, istemciler arası donanım farkı ve bağlantı kararsızlıkları gibi nedenlerle bu yaklaşım her zaman başarılı sonuç vermez (Lai vd., 2024). Bu nedenle literatürde FedProx (Li vd., 2020), FedExp (Jhunhunwala vd., 2023), FedGP (Jiang vd., 2023) gibi alternatif toplama kuralları geliştirilmiştir.

Karşılaştırma amaçlı bu tezde kullanılan toplama kurallarından birisi olan FedAvg-DWA (Bian ve Zheng, 2023) yöntemi, sınıf dengesizliğinin toplama kurallarına etkisini ele alır. Sınıflar arasındaki belirgin farklar, tahmin sırasında çoğunluk sınıfının ağırlık etkisi daha büyük olmasına neden olur. Bu sorunu aşmak için FedAvg-DWA, ağırlıklar arası mesafeye dayalı bir toplama stratejisi kullanır (Denklem 2.22) ve bu sayede örnekler arasındaki dengesizliği azaltmayı amaçlar.

$$w_{t+l} = \sum_{k \in St} \left(\frac{D[k]}{\sum_{k \in St} D[k]} \right)_{W[k]} \quad (2.22)$$

Burada, K istemci sayısını belirtir ve k istemci indeksidir. $D[i]$, i -inci istemcinin yerel modeli ile küresel model arasındaki mesafeyi gösterir. $W[i]$, i -inci örneğe karşılık gelen ağırlığı belirtir.

Homojen verilerde üstün performans sağlasa da FedAvg'nin bazı durumlarda yetersiz kalmaktadır. İstemci kaymaları (client drift) karşısında oldukça hassastır çünkü yalnızca mevcut toplama kuralını dikkate alır ve geçmiş yönelimleri göz ardı eder. Bu nedenle, büyük ölçekli görsel veya dil modeli eğitimlerinde ideal değildir. Bu gibi senaryolarda Stokastik gradyan inişi (SGD) yerine momentum veya adaptif optimize ediciler tercih edilir. Örneğin, FL sistemlerinde sunucu momentumu stratejilerinin rolünü sistematik bir şekilde anlamak amacıyla, FedGM (Sun vd., 2024) geliştirilmiştir. FedGM, klasik FedAvg algoritmasında yer alan sunucu tarafındaki güncelleme adımı Denklem 2.23'te verilmiştir.

$$\begin{aligned} d_{t+1} &= (1 - \beta)\Delta_t + \beta d_t, h_{t+1} = (1 - \nu)\Delta_t + \nu d_{t+1} \\ x_{t+1} &= x_t - \eta h_{t+1} \end{aligned} \quad (2.23)$$

FedGM, klasik FedAvg'ın basit ağırlıklı ortalama mantığını genişleterek, momentum tabanlı bir yaklaşım getirmektedir. Bu sayede model güncellemeleri sadece anlık gradyanlara (yani istemcilerden gelen mevcut model değişikliklerine) değil, önceki tur bilgilerine de dayandırılıyor. Denklemde Δ_t turdaki model değişimi, dt Zamanla biriken momentum (önceki turların etkisi), ht Nihai momentum etkisi (hem mevcut hem de geçmiş değişimleri dengeler), β ve ν Momentum ağırlıkları (esneklik katsayıları) ve η : Öğrenme oranıdır.

Average Drift (Wang vd., 2022), veri heterojenliğinin etkilerini daha iyi yakalamak için, başlangıçta optimal bir noktadan itibaren birden fazla yerel adım sonrası modeldeki ortalama değişimi hesaplar. Bu yaklaşım, istemci modellerinin optimal noktaya yakın bölgelerde çok az değişim gösterdiği varsayımına dayanır. Gradyan farklılıklarını (gradient dissimilarity) kullanmanın bir problemi, istemciler (clients) arasındaki olası korelasyonları göz ardı etmesidir. Bu nedenle yöntem veri heterojenliğinin etkilerini doğrudan beklenen değerin normu üzerinden ölçmeyi önermiştir. Özellikle, optimal nokta ağırlıktaki gradyan yanlılığını kullanarak optimaldeki ortalama sapmayı tanımlar ve bunu veri heterojenliğini ölçmek için kullanmıştır. Denklem 2.24'de Average Drift optimum gösterilmiştir.

$$\rho \triangleq \|\mathcal{G}(w^*) - \nabla F(w^*)\| = \|\mathcal{G}(w^*)\| \quad (2.24)$$

Burada, $\mathcal{G}(w)$ ifadesi, tüm istemcilerin beklenen pseudo-gradyanını temsil eder.

2.3.3. Federe öğrenme uygulama mimarileri

FL istemciler ve sunucu üzerinde entegre uygulaması için farklı çerçeve yazılımları kullanılabilir. Çizelge 2.1’de literatürde kullanılan farklı çerçeve FL yazılım mimarileri karşılaştırmaları verilmektedir. Burada Flower, Tensorflow Federated (TFF) , Syft, FedScale ve LEAF (A Benchmark for Federated Settings) karşılaştırarak, bu özelliklerin daha ayrıntılı açıklamasını içeren bir genel bakış sunmaktadır (Beutel vd., 2022).

Çizelge 2.1. FL mimari karşılaştırmaları

Değerlendirme Boyutları	TFF	Syft	FedScale	LEAF	Flower
Tek düğüm simülasyonu	+	+	+	+	+
Çoklu düğüm yürütme	*		+(***)		+
Ölçeklenebilirlik	*		**		+
Heterojen istemciler		+(***)	**		+
ML çatısı		****	****		+
İletişim bağımsız					+
Dil bağımsız					+
Temel çizgiler			+	+	*

- * Planlandı
- ** Yalnızca simülasyon
- *** Yalnızca Python tabanlı
- **** Yalnızca PyTorch veya TF/Keras

Çizelge 2.1’de irdelenen değerlendirme boyutları ilgili değerlendirmeler aşağıda açıklanmaktadır.

- Tek düğüm simülasyonu, FL sistemlerini tek bir makinede simüle etmek için kullanılır ve tüm çerçeveler tarafından desteklenir. Çoklu düğüm yürütme, farklı makineler arasındaki ağ iletişimini gerektirir ve şu anda Syft ve Flower tarafından desteklenmektedir.

- Ölçeklenebilirlik, büyük gruplara genelleme yapmak için önemlidir. Tek makine simülasyonu genellikle büyük sayıda farklı özelliklere sahip istemciler içeren iş yüklerini sınırlar. Flower, milyonlarca istemciyi destekleyen iş yüklerini kolayca ölçeklendirebilen sanal istemci motoru içerir.
- Heterojen istemciler, farklı dillerde çalışan ve farklı platformlarda bulunan istemcilerin aynı iş yükünde çalıştırılmasını gerektirir. Flower, bu tür heterojen istemci havuzlarını dil ve iletişimden bağımsız bir şekilde destekler.
- ML çerçevelerine bağımlı olmayan araçlar, araştırmacıların farklı ML çerçevelerini kullanmalarına olanak tanır. Flower, birden fazla ML çerçevesini destekler, bu da kullanıcıların tercih ettikleri çerçeveyi kullanmalarına izin verir.
- Dil bağımsızlık, farklı dillerde istemci uygulamalarını tanımlar. Flower, dil bağımsız bir arabirim sunar, bu da mobil ve gömülü platformlarda yapılan araştırmalar için önemlidir.
- Temel çizgiler, FL algoritmalarını mevcut yöntemlerle karşılaştırmak için kullanılır ve araştırma ilerlemesini hızlandırır. Flower, popüler ML ölçütleri bağlamında çeşitli FL yöntemlerini uygular ve farklı veri kümeleri ile temel çizgiler sunar.

Tüm değerlendirme boyutları incelendiğinde FL uygulaması için Flower (Beutel vd., 2022), çerçeve mimarisi öne çıkmaktadır. Bu çerçeve hem simülasyon hem de gerçek dünya cihazları için uygun olup, yatay ve dikey genişleyebilme esnekliği sağlar. Flower'ın kullanım durumları, büyük gruplarda denemeleri ölçeklendirmeyi, heterojen cihazlar üzerinde denemeleri, simülasyondan gerçek cihazlara geçişi ve farklı ML çerçevelerini bir arada kullanmayı içerir.

Flower, bu kullanım durumlarını ele almak için tasarlanmıştır ve beş temel tasarım hedefini benimsemektedir. Bunlar ölçeklenebilir, farklı cihazlara uyumlu, iletişim çeşitliliğini ve gizliliği desteklemeli ayrıca esnek olmalıdır.

Flower'ın çerçeve mimarisi hem global hem de yerel hesaplamaları destekler. Sunucu tarafında, strateji soyutlaması, global mantığı ifade eder. İstemci tarafında, istemci soyutlaması yerel düzeyde model eğitimi ve değerlendirmesi ile ilgilenir. Flower, farklı ML çerçevelerini birleştirmek için yüksek düzeyde çözümler sunar ve heterojen istemcileri destekler. Ayrıca, bağlantı işleme, istemci yaşam döngüsü, zaman aşımı ve hata işleme gibi karmaşıklıkları ele alır. Şekil 2.6'da çekirdek çatı mimarisi görüldüğü üzere Flower, hem

istemci kesintilerine karşı yüksek dayanıklılık sergiler ve diğer geleneksel çok yönlü güvenli toplama protokollerine kıyasla daha düşük iş yüküne sahiptir.

2.3.4. Elektrikli araçlarda federe öğrenme uygulamaları

Literatür irdelendiğinde, elektrikli araçlar için geliştirilen SoC/SoH tahminleme yaklaşımlarının ağırlıklı olarak derin öğrenme modelleri kullanılmaktadır. Bu alanda Transformer mimarisi, karmaşık zaman bağımlılıklarını öğrenebilmesi sayesinde öne çıkmaktadır. EV filoları için FL veri mahremiyetini koruyarak dağıtık öğrenme süreçlerini mümkün kılmaktadır. Bu iki teknolojinin yerine göre kullanımı, geleceğin elektrikli araç filo yönetiminde daha akıllı, güvenli ve özelleştirilebilir enerji yönetim sistemlerinin yolunu açmaktadır.

Elektrikli araçlar hareketli cihazlar olmaları ve çok sayıda sensörden veri toplamaları nedeniyle FL için uygun bir uygulama alanıdır. FL ile araçlar, SoC, sıcaklık, akım gibi verileri paylaşmadan, yalnızca model ağırlıklarını merkezi sisteme ileterek global modellerin eğitilmesini mümkün kılar (Bian ve Zheng, 2023). Böylece veri mahremiyeti sağlanırken, ağ üzerindeki veri yükü de azaltılmış olur.

Elektrikli araç filolarında enerji verimliliğini artırmak, bakım maliyetlerini azaltmak ve güvenliği sağlamak için FL tabanlı uygulamalar geliştirilmektedir. Örneğin, Fed-BEV modeli, farklı üreticilere ait bataryaların enerji tüketim modellerini FL ortamında ortaklaşa öğrenmek için geliştirilmiştir (Liu, 2021). AGV’lerde enerji tahmini yapmak için kullanılan FL tabanlı yaklaşımlar ise merkezi modellere kıyasla daha iyi sonuçlar vermiştir (Shubyn vd., 2023).

Elektrikli araçların dağıtım şebekelerine entegrasyonunu optimize etmek amacıyla çok ajanlı pekiştirmeli öğrenmeye dayalı Sınırlı İş Birliği Adaleti için Dinamik Alt Model Tahsisli Federe Öğrenme Çerçevesi (FedSAC) adlı bir federe öğrenme algoritması geliştirilmiştir (Qian vd., 2024). Bu yenilikçi yaklaşım, şebeke kararlılığını sağlamanın yanı sıra sürücülerin gizliliğini de korumuştur. Algoritma, araçtan şebekeye (V2G) ve şebekeden araca (G2V) geçişleri yöneterek güç akışını gerçek zamanlı olarak optimize etmiş, böylece hem V2G kazançlarını hem de şebeke yükünü dengelemiştir.

Araçların İnterneti (IoV) sistemlerinde araçlar arası heterojenliği ve iletişim maliyetlerini azaltmak için küme tabanlı yarı-asen kron bir federe öğrenme çerçevesi olan Araç Ağları için İstemci Seçimine Duyarlı Federatif Öğrenme (CSA_FedVeh) önerilmiştir (Cao vd., 2024). Bu çerçeve, araçların konumsal ve model ağırlığı benzerliklerine dayanarak kümelenmesini sağlayan Uzay-Zaman Ağırlıklı Yoğunluk Tabanlı Gürültülü Uygulama Kümeleme (STW-DBSCAN) algoritmasını kullanmıştır. Bu sayede, veri dağılımındaki bağımsız ve özdeş olmayan (Non-IID) sorunların etkisi azaltılmış, hesaplama kaynakları daha verimli kullanılmış ve iletişim yükü önemli ölçüde düşürülmüştür. Ayrıca IoV kaynak heterojenliği sorununu ele almak ve federe öğrenme modellerinin yakınsama hızını artırmak için bir model bölme işbirlikçi eğitim mekanizması önerilmiştir (Wu vd., 2024). Bu mekanizma, kaynak kısıtlı araçlar için eğitim görevlerini bölerek karmaşık hesaplama yüklerini yakındaki hizmet araçlarına aktarmış, böylece yüksek mobilite koşullarında dahi eğitim verimliliğini ve yakınsama süresini iyileştirmiştir.

Bir başka çalışmada otonom sürüşe yönelik algılama modellerinin merkezi sunucular olmaksızın eğitilmesini sağlayan bir federe öğrenme yaklaşımı sunulmuştur (Liu vd., 2024). Çalışma, farklı sahne dağılımlarına sahip araçlardan gelen verilerin dengelenmesi yoluyla model eğitiminde sahne heterojenliğinin olumsuz etkilerini hafifletmiş ve çoklu görev algılama modelleri için daha sağlam bir öğrenme süreci sağlamıştır.

Park ve Joe (2024) çalışmalarında elektrikli araçların enerji tüketimini tahmin etmek amacıyla blockchain tabanlı kara kutu verilerini kullanan bir federe öğrenme mimarisi tasarlamıştır. Bu entegre yaklaşım, verilerin gizliliğini güvenli bir şekilde korurken, akıllı şebeke yönetimi için EV enerji tüketimi tahmin doğruluğunu artırarak şebeke yükünün dengelenmesine ve enerji arzının optimizasyonuna katkıda bulunmuştur. Farklı bir çalışmada elektrikli araç şarj altyapısında şarj yükü tahmini için blockchain ve federe öğrenme teknolojilerini birleştiren güvenli bir model olan Block-FeDL'yi geliştirmiştir (Danish vd., 2025). Bu model, BiLSTM kullanarak bireysel EV şarj davranışlarını dikkate almış ve merkezi sunucu yerine blockchain üzerinde model toplama yaparak yüksek doğruluk ve güvenilirlik sunmuştur.

Han ve Li (2025) dağıtım ağı (DN) güvenli ve istikrarlı çalışması için önemli olan elektrikli araç şarj istasyonu yükünün (EVCSL) doğru tahmin edilmesini sağlamak amacıyla

dikey uyarlanabilir dikkat tabanlı bir federe tahmin yöntemi (V2AFedEGAT) önermiştir. Bu yöntem, DN ve taşıma ağı (TN) özelliklerini birleştirerek uzamsal-zamansal hibrit dikkat modülü ile veri dağılımındaki sapmaları gidermiş ve yüksek tahmin performansı ile hızlı yanıt süresi sunmuştur.

Marlin vd. (2025 a) elektrikli araçların bir sonraki şarj konumunu tahmin etmek için Federe öğrenme transformer tabanlı sinir ağı (FLTN) modelini geliştirmiştir. Bu model, gizliliği koruyarak %92'ye varan doğrulukla tahminler yapabilmiş ve merkezi bir modelin veri gizliliği olmadan ulaştığı doğruluk seviyesine yakın sonuçlar elde etmiştir. Marlin vd. (2025 b) elektrikli araçların şarj ihtiyaçlarının uzamsal-zamansal tahmini için hiyerarşik bir federe öğrenme mimarisi olan H-FLTN'i önermiştir. Üç katmanlı bu mimari (EV'ler, topluluk DERMS ve Enerji Sağlayıcı Veri Merkezi), Secure Aggregation, Additive Secret Sharing ve P2P Paylaşımı gibi mekanizmalarla gizliliği sağlarken, Dinamik İstemci Sınırlama Mekanizması (DCCM) ve İstemci Rotasyon Yönetimi (CRM) ile eğitim verimliliğini ve ölçeklenebilirliği artırmıştır.

Hallak ve Kem (2025) elektrikli araç şarj istasyonu doluluk tahmini için adaptif bir federe öğrenme çerçevesi önermiştir. Bu çerçeve, kavram kayması (concept drift) ve istemciler arasındaki veri heterojenliği gibi gerçek dünya zorluklarını ele alırken, istasyonları benzer kayma modellerine göre kümelemiş ve artımlı öğrenme ile kişiselleştirilmiş modeller kullanarak tahmin doğruluğunu artırmıştır.

Rahal vd. (2025) elektrikli araç şarj ekipmanlarının siber güvenliğini güçlendirmek amacıyla çok modlu veri kaynaklarından (ağ trafiği ve çekirdek olayları) yararlanan yeni bir izinsiz giriş tespit çerçevesi sunmuştur. Bu çerçeve, federe öğrenme aracılığıyla şarj ekipmanlarının istasyonları arasında işbirlikçi istihbarat sağlayarak veri gizliliğini korumuş ve yüksek tespit ve hassasiyet oranları elde etmiştir.

Li vd. (2024) federe çizge öğrenmesini kullanarak elektrikli araç şarj istasyonlarındaki talebi hem kişiselleştirme hem de siber saldırılara karşı dayanıklılık boyutlarıyla modellemiştir. Önerilen Çizge Sinir Ağı (GNN) tabanlı model, farklı istasyonlar arasındaki coğrafi korelasyonu yakalarken, kötü niyetli istemcilerden gelen tehditleri azaltmak için kredi tabanlı özel bir fonksiyon tasarlamıştır.

FL ile SoH üzerine yapılan çalışmalarda merkezi ve merkezi olmayan öğrenme yaklaşımları karşılaştırılmıştır (Alharbi vd., 2025). Çalışmada Alharbi vd. (2025) merkezi yaklaşım için 1D CNN, CNN+LSTM ve CNN+GRU modelleri kullanılmış; NASA batarya veri setindeki şarj-deşarj döngülerinden elde edilen eğriler ile SoH tahmini yapılmıştır. FL yaklaşımında ise 1D CNN modeli beş istemci üzerinde FedAVG yöntemiyle eğitilmiş, böylece veriler paylaşılmadan yerel eğitim sağlanmıştır. Sonuçlar, zamanla şarj oldukça SoH değerlerinin düştüğünü ve bunun batarya yaşlanma etkisini açıkça gösterdiğini ortaya koymuştur. Bataryalarda yaşlanma, batarya kapasitesinde bir azalmaya ve EV uygulamaları için iç dirençte bir artışa neden olur (Soyoye vd., 2025). Enerji döngüsü arttıkça batarya kapasitesi düşmektedir. Thingvad vd. (2021) çalışmasında yapılan deneyde, her gün aynı mesafeyi gitmek için zamanla daha fazla şarj edilmesi gerektiği ölçülmüştür. Yani zamanla aynı şarjla gidilen mesafe azalır. Dolayısıyla zamanla SoC başına gidilen mesafe de azalır. Buna göre aynı ortam koşullarında, aynı sıcaklık aynı sürüş profili aynı rota ve çevre koşullarını olduğunda batarya yaşlanmasıyla gidilen mesafenin düşmesi beklenir.

EV araç filolarında farklı araçlardaki uygun sürücü profilleri karşılaştırmaları SoH hesaplamada kullanılmaktadır. Bu profillerin benzerliklerinin tespitinde DTW kullanılabilir. DTW, zaman serileri analizinde sıkça kullanılan ve doğrusal olmayan hizalama (alignment) yeteneği sayesinde, farklı uzunluktaki ya da zamansal olarak kaymış seriler arasında benzerlik ölçümünde yüksek doğruluk sağlayan bir yöntemdir (Kasap vd., 2023). Özellikle elektrikli araç sürüş verileri gibi düzensiz zaman serileri içeren durumlarda, klasik Öklid mesafe ölçütlerinin yetersiz kaldığı durumlarda DTW daha etkili bir karşılaştırma sunmaktadır.


DTW'nin temel amacı, iki zaman serisi olan X ve Y arasındaki toplam mesafeyi minimize edecek şekilde bu serileri hizalamaktır. Bu hizalama işlemi sonucunda elde edilen benzerlik metriği, Denklem 2.25'te tanımlanmaktadır:

$$s(X, Y) = \min_p \sqrt{\sum_{\theta=1}^L c(x_{p_{\theta,0}} y_{p_{\theta,1}})^2} \quad (2.25)$$

Burada her p, θ çifti, x ve y serilerindeki karşılık gelen öğelerin pozisyonlarını belirtir. Bükülme yolu (warping path) üç temel koşulu sağlamalıdır. $p = (p_1, p_2, \dots, p_L)$

Sınır koşulu (boundary condition): Warping path ilk ve son öğeleri kapsamalıdır. $p1,0 \leq p2,0 \leq \dots \leq pL,0$ Monotonluk koşulu (monotonicity condition): İleri doğru hareket sağlanmalıdır. $p\theta + 1 - p\theta \in \{(1,0), (0,1), (1,1)\}$ for $1 \leq \theta \leq L - 1$ Adım koşulu (step size condition): Her adım yalnızca (1,0), (0,1) veya (1,1) yönünde ilerleyebilir.

DTW algoritması uygulanmadan önce, zaman serilerinin genlik farklılıklarından kaynaklanacak hizalama hatalarını önlemek amacıyla veriler normalize edilmelidir. Bu sayede ölçülen mesafeler mutlak büyüklüklerden bağımsız hale getirilir. Şekil 2.7, iki keyfi zaman serisinin hizalanmasına ilişkin bir örneği göstermektedir.



Şekil 2.7. DTW sinyali

DTW'nin bu çalışmada kullanılmasının temel gerekçesi, farklı sürücüler tarafından gerçekleştirilen sürüşlerin zamanlamasının ve hız dağılımlarının farklılık göstermesi, ancak genel seyir davranışlarının benzerlik gösterebilmesidir. Örneğin iki farklı sürüş aynı güzergâhta ve benzer ortalama hızda gerçekleşmiş ancak anlık hız değişimleri zaman ekseninde kaymış olabilir. Bu gibi durumlarda klasik uzaklık, büyük farklar gösterirken, DTW daha gerçekçi bir benzerlik ölçümü sunmaktadır.

3. MATERYAL VE YÖNTEM

Batarya sistemleri, elektrikli araçların menzili, performans ve genel kullanım ömrü gibi kritik özelliklerini doğrudan etkileyen temel bileşenlerden biridir. Günümüzde yaygın olarak kullanılan Li-ion ve LFP bataryalar yüksek enerji yoğunlukları ile öne çıkmakla birlikte, güvenlik, dayanıklılık ve maliyet açısından çeşitli sınırlamalara sahiptir. Bataryaların zamanla yaşlanması ve çevresel koşullara bağlı olarak performanslarında meydana gelen farklı hızlardaki azalmalar, SoC ve SoH gibi temel göstergelerin doğru ve güvenilir biçimde tahmin edilmesini gerekli kılmaktadır. Bu bağlamda, batarya sistemlerinin güvenli ve verimli şekilde yönetilebilmesi için sürekli izleme sağlayan akıllı sistemlerin entegrasyonu büyük önem taşımaktadır.

Geleneksel olarak kullanılan merkezi öğrenme tabanlı yaklaşımlar, yüksek tahmin doğrulukları sunmakla birlikte, veri iletimi için yüksek bant genişliği ihtiyacı ve kişisel veri mahremiyeti gibi önemli sorunlara yol açmaktadır. Bu tür sınırlamaların aşılması amacıyla son yıllarda FL yaklaşımları birçok alanda başarıyla uygulanmaya başlanmıştır. FL, model eğitiminin istemcilerin yerel cihazlarında gerçekleştirilmesini sağlar; bu sayede ham veriler paylaşılmaksızın yalnızca model ağırlıkları merkezi sunucuya iletilir. Böylece veri iletişim yükü azaltılırken, veri gizliliği korunur ve dağıtık sistemler üzerinden yüksek doğrulukta tahmin yapabilen etkin bir prognostik yapı kurulmuş olur.

Bu tez kapsamında hem merkezi hem de FL temelli dağıtık öğrenme yöntemleri önerilmiş ve performans değerlendirme amacıyla da çeşitli test senaryoları geliştirilmiştir. İlk olarak, Musoshi L5 elektrikli aracına ait BMS verileri merkezi bir sunucuda toplanarak, bu veriler üzerinden merkezi bir öğrenme modeli ile SoC tahmini gerçekleştirilmiştir. Ardından, verilerin paylaşımına gerek duyulmadan, araç üzerindeki uç (edge) cihazlarda yerel verilerle model eğitimi yapılmış ve ağırlıklar sunucudaki genel modele entegre edilerek FL tabanlı SoC tahmini gerçekleştirilmiştir.


Bu bölümde, elektrikli araçlar için geliştirilen merkezi ve dağıtık (federe) şarj durumu ve sağlık durumu tahmin yöntemlerine ilişkin ayrıntılar sunulmaktadır.

3.1. Materyal

Merkezi öğrenme tabanlı yaklaşımda LSTM, Bi-LSTM, SVR ve Transformer mimarileri değerlendirilmiştir. Federe öğrenme kapsamında ise Flower çerçevesi üzerinde FedAvg, FedAvg-DWA, FedGM, Average Drift ve önerilen FedACM gibi farklı model toplama kuralları; LSTM, GRU ve Transformer tabanlı yerel modeller ile birlikte uygulanmıştır. Flower çerçevesi, farklı istemcilerde paralel olarak yürütülen yerel eğitimlerden elde edilen model ağırlıklarını merkezi sunucuya ileterek global modeli güncellemekte; ardından güncellenmiş model ağırlıklarını istemcilere geri göndererek tüm sistemin senkronizasyonunu sağlamaktadır.

Musoshi firmasına ait üç tekerlekli L5 Pop-Up mini elektrikli araçtan elde edilen bu veri seti, gerçek sürüş koşullarında toplanmıştır. 1100 kg ağırlığındaki araç, her biri yaklaşık 49 dakika süren iki tur tamamlamıştır. İlk tur %100, ikinci tur ise %80 şarjla başlamıştır. Araç, farklı eğimlere sahip bir parkurda test edilmiştir ve bu, enerji tüketimini ve batarya deşarj dinamiklerini doğrudan etkilemiştir.

Araç üzerinde kullanılan uç cihazlar NVIDIA Orin platformudur. Bu cihazlar, sahip oldukları yüksek işlem kapasitesi ve paralel hesaplama yetenekleri sayesinde, yerel model eğitimlerinde önemli ölçüde performans artışı sağlamıştır. Özellikle federe öğrenme senaryolarında, verilerin merkezi sunucuya gönderilmeden uç birimlerde işlenmesi gerektiğinden, Orin'in sunduğu yüksek işlem gücü, düşük gecikme süresi ve enerji verimliliği, eğitim süreçlerini hızlandırmış ve model doğruluğunu olumlu yönde etkilemiştir. Önerilen FL tabanlı mimari Şekil 3.1'de sunulmuştur.



Şekil 3.1. Önerilen Federe Öğrenme mimarisi

Bu çalışmada aynı zamanda batarya sağlık durumu tahmini de gerçekleştirilmiştir. Literatürde, elektrikli araçlarda zamanla aynı şarjla kat edilebilen mesafenin azaldığı bilinmektedir (Thingvad vd., 2021). Bu durumdan yola çıkarak, zaman içinde birim SoC başına kat edilen mesafenin de azaldığı gözlemlenmiştir. Dolayısıyla, aynı ortam sıcaklığı, sürüş profili, rota ve çevresel koşullar altında bataryanın yaşlanmasıyla birlikte menzilde bir düşüş beklenmektedir. Bu yaklaşımla, aynı rota üzerinde farklı zamanlarda gerçekleştirilen sürüşler karşılaştırılarak SoH değeri tahmin edilmiştir.

3.2. Veri setleri


Bu çalışmada, merkezi ve dağıtık SoC tahmini yaklaşımlarında kullanılan yapay zekâ algoritmalarının bireysel performanslarını değerlendirmek amacıyla dört farklı veri seti kullanılmıştır. Bu veri setleri; Musoshi L5 aracından elde edilen batarya verileri ile NASA (*Li-ion Battery Aging Datasets* | *NASA Open Data Portal*, t.y.), Stanford (Catenaro ve Onori, 2021) ve BMW i3 (Steinstraeter, 2020) batarya veri setlerinden oluşmaktadır. Tüm veri setlerinde yer alan akım, voltaj, sıcaklık ve hız gibi sensör verileri, istemcilerde SoC tahmini için giriş özellikleri olarak kullanılmıştır.

Musoshi EV Veri Seti, Musoshi Şirketi tarafından üretilen ve toplam ağırlığı 1100 kg olan üç tekerlekli bir L5 Pop-Up mini araçtan toplanmıştır (Şekil 3.2). Araç, belirlenen pistte her biri yaklaşık 49 dakika süren iki tur tamamlamıştır. İlk tur tam şarjla başlarken, ikinci tur %80 şarjla başlamıştır.



Şekil 3.2. Musoshi firmasının 3 tekerlekli pop-up mini aracı

Test boyunca yol haritası ve SoC değişimi Şekil 3.3'te gösterilmiştir. Test boyunca araç, yokuş yukarı ve yokuş aşağı bölümler de dahil olmak üzere çeşitli yükseklik değişiklikleriyle karşılaşmış ve bu da enerji tüketimini ve akü deşarj özelliklerini etkilemiştir. Bu eğimli bölümler grafiklerde sarı renkle vurgulanmıştır.



Şekil 3.3. Tur 1 ve tur 2 boyunca Musoshi aracının güzergahı ve SoC verileri

Tur 1 ve Tur 2 için Musoshi araç rotaları, deneyler sırasında kat edilen yolları vurgulayarak haritada gösterilmiştir. Her tur için ilgili SoC profilleri, kat edilen mesafeye (kilometre cinsinden) göre çizilmiştir. Mavi çizgi Tur 1'in SoC profilini temsil ederken, turuncu çizgi Tur 2'ye karşılık gelmektedir. SoC grafiğindeki gölgeli bölgeler, potansiyel olarak yol koşulları, trafik veya sürüş alışkanlıklarındaki değişiklikler nedeniyle enerji tüketiminde önemli değişikliklerin gözlemlendiği rota bölümlerini göstermektedir.

Veri setinde toplam 194 özellik bulunmaktadır. Bu özellikler araçtaki BMS, inverter, batarya şarj ünitesi ve gösterge panelinden alınan akım, voltaj, sıcaklık gibi anlık ölçümleri içermektedir. Veri seti 2912 satırdan oluşur ve özellikle ilk turun ilk yarısındaki veriler eksiksiz ve anlamlı olduğu için analizlerde bu bölge kullanılmıştır. Çizelge 3.1'de toplanan veriler gösterilmiştir.

Çizelge 3.1. Musoshi Batarya veri seti

Sembol	Açıklama
V_CELLS	Toplam batarya voltajı (V)
T_Min	Batarya sıcaklık sensörü minimum sıcaklık değeri (°C)
T_Max	Batarya sıcaklık sensörü maksimum sıcaklık değeri (°C)
V_AVG	Batarya hücrelerinden okunan ortalama voltaj değeri (mV)
V_MAX	Batarya hücrelerinden okunan maksimum voltaj değeri (mV)
V_MIN	Batarya hücrelerinden okunan minimum voltaj değeri (mV)
SOC_TRIMMED	Kalibre edilmiş batarya şarj seviyesi (%)
SOC_INTERNAL	Bataryanın içsel şarj seviyesi (%)
I_HALL	Akım değeri (A)

Çalışmada test edilen, literatürde yaygın olarak kullanılan batarya veri seti olan NASA, Ames Prognostics Center of Excellence tarafından geliştirilen bu veri seti, Li-ion bataryaların yaşlanma süreçlerini modellemek için oluşturulmuştur (*Li-ion Battery Aging Datasets | NASA Open Data Portal*, t.y.). Farklı sıcaklıklarda yapılan şarj-deşarj testleri ve Electrochemical Impedance Spectroscopy tekniği ile batarya sağlığı izlenmiştir. 2.7V'un altındakideşarj eşik değerleri ile derindeşarj etkileri tetiklenmiş, kapasitede %30 düşüş gerçekleşene kadar testler sürdürülmüştür. Bu veri seti, SoC tahmini için voltaj, akım, sıcaklık vedeşarj profilleri gibi temel özellikleri içermektedir.

Bir diğer batarya veri seti olan Stanford, Arbin Instruments LBT21024 test sistemi ve termal ölçüm donanımlarıyla oluşturulmuştur (Catenaro ve Onori, 2021). Bataryalara özel akım profilleri uygulanmış ve yüzey sıcaklıkları T-type termokupl sensörlerle ölçülmüştür. Galvanostatikdeşarj işlemi ile bataryalar belli voltaj değerlerine kadardeşarj edilmiştir (örneğin, NMC/NCA için 2.5V, LFP için 2.0V). Ayrıca, sıcaklık odası yardımıyla ortam sıcaklığı da kontrol altında tutulmuştur. Bu veri seti, donanım ve yazılım bileşenlerinin detaylı açıklamalarıyla birlikte sunulmuştur ve akademik araştırmalarda yaygın olarak kullanılmaktadır.

Çalışmada kullanılan son batarya veri seti, BMW i3 (60 Ah) aracı ile 72 özgün sürüş gerçekleştirilerek toplanan veri setidir (Steinstraeter, 2020). Bu veri seti, batarya sistemi, güç aktarım organları ve ısıtma devresi gibi bileşenleri içeren detaylı bir araç modelinin doğrulanmasında kullanılmıştır. Gerçek sürüş koşulları altında SoC tahmini ve enerji yönetimi için değerli bir referans kaynağıdır.

3.3. Önerilen Merkezi Öğrenme Temelli Şarj Durumu Tahmini Yöntemleri

Bu bölümde, SoC tahmininde kullanılan yapay zekâ yöntemleri açıklanmakta olup, Transformer modeli ile geleneksel LSTM, Bi-LSTM ve SVR modellerine yer verilmiştir. Modellerin detayları Bölüm 2 – Literatür Taraması bölümünde verilmiştir.

3.3.1. Derin öğrenme modelleri

Transformer, sıralı verileri modellemedeki etkinliği sayesinde zaman serisi tahminleri için uygundur. Model, veri setine ve özel ihtiyaçlara göre yapılandırılmıştır. Yapılandırma sırasında katman sayısı, dikkat mekanizmaları ve embedding boyutları gibi mimari detaylar özelleştirilmiştir. Hiper parametre optimizasyonu, Transformer performansını artırmak için kritik bir adımdır. Bu tezde Transformer yapısı, veri setine uyum sağlayacak şekilde optimize edilmiştir. Çizelge 3.2 Transformer modeli için hiper parametreler ve kontrol parametreleri gösterilmektedir.

Çizelge 3.2. Transformer modeli hiper parametreler ve kontrol parametreleri

Parametre	Değer	Açıklama
Katman Sayısı	4	Encoder blok sayısı
Dikkat Başlığı (Heads)	8	Çoklu başlıklı dikkat mekanizması
Embedding Boyutu	128	Girdi vektör boyutu
Öğrenme Oranı (η)	0.001	Adam optimizier ile
Batch Size	64	Her iterasyonda kullanılan örnek sayısı
Epoch Sayısı	100	Eğitim tekrar sayısı

LSTM, zaman serilerinin sınıflandırılması ve tahmininde yaygın olarak kullanılır (Yayan vd., 2021). Bi-LSTM yönteminde ise eğitim sırasında veriyi hem geçmişten geleceğe hem de gelecekte geçmişe doğru işler. Bu sayede tek yönlü LSTM'ye göre daha hızlı öğrenir. Çizelge 3.3'te kullanılan LSTM ve Bi-LSTM modelleri için hiper parametreler ve kontrol parametreleri gösterilmektedir.

Çizelge 3.3. LSTM ve Bi-LSTM modeli hiper parametreler ve kontrol parametreleri

Parametre	LSTM	Bi-LSTM
Gizli Katman Boyutu	64	64
Katman Sayısı	2	2
Dropout Oranı	0.2	0.2
Öğrenme Oranı	0.001	0.001
Batch Size	64	64
Epoch Sayısı	100	100

Transformer LSTM, Bi-LSTM modellerinde girdi vektörü kullanılan özellikler olup zaman serisi, SoC ölçümleri, akım (A), gerilim (V), sıcaklık ($^{\circ}\text{C}$) ve hız (km/s)'dir. Her bir

zaman adımındaki sensör verileri normalize edilerek model beslenmiştir. Tüm sayısal veriler [0,1] aralığına normalize edilir. Zaman serileri, 60 saniyelik kayar pencere ile segmentlere ayrılır. Eğitim/test oranı da her bir batarya testi ya da turu için eğitim ve test olacak şekilde belirlenir.

3.3.2. Makine öğrenimi yöntemi

SVR Doğrusal ve doğrusal olmayan regresyon problemlerini çözebilir. Doğrusal olmayan durumlarda kernel fonksiyonları kullanarak veriyi yüksek boyutlu uzaylara dönüştürür. SVR'nin temel parametrelerinden biri “epsilon”dır. Bu parametre, marjın içindeki hata payını belirler. Modelin esnekliğini ya da katılığını epsilon değeri belirler. Çizelge 3.4'te SVR modeli hiper parametreler ve kontrol parametreleri gösterilmektedir.

Çizelge 3.4. SVR modeli hiper parametreler ve kontrol parametreleri

Parametre	Değer
Kernel	RBF
C	100
Gamma	0.1

SVR'nin genelleme kabiliyeti yüksek olduğundan aşırı öğrenmeyi (overfitting) azaltır ve gerçek dünya verileriyle uyumlu sonuçlar üretir.

3.4. Önerilen Dağıtık Federe Öğrenme Mimarisi ile Şarj Durumu Tahmini

Bu çalışmada, dağıtık tahmin yöntemi olarak, farklı istemcilerden elde edilen non-IID veriler kullanılarak elektrikli araçlarda SoC tahmini yapılmış ve çeşitli model toplama yöntemleri test edilmiştir. Literatürdeki mevcut yöntemlere ek olarak, her istemcinin veri özelliklerine göre farklı momentum değerleriyle katılmasına olanak tanıyan yeni bir toplama yöntemi olan FedACM önerilmiştir. Bu yöntem sayesinde SoC tahmin performansı iyileştirilmiştir.

FL sürecinde her istemci öncelikle yerel verisiyle modeli eğitir. Bu çalışmada hem yerel hem de küresel model olarak öncelikli olarak LSTM seçilmiştir. LSTM'nin ağırlık paylaşımındaki basitliği, hızlı eğitimi ve zaman serisi verilerindeki güçlü başarımı bu tercihi

desteklemiştir. Zaman serisi tahminlerinde sıklıkla kullanılan veri odaklı yöntemler arasında LSTM, GRU ve Transformer mimarileri öne çıkmaktadır (Yılmaz vd., 2025a). Karşılaştırma amaçlı bu yöntemler de kullanılmıştır. LSTM, uzun dönem bağımlılıkları modelleme kapasitesi sayesinde batarya şarj tahmini gibi görevlerde güçlü bir adaydır. Yerel modeller eğitildikten sonra, istemciler model parametrelerini sunucuya gönderir. Sunucu, gelen parametreleri toplar ve küresel modeli güncelleyerek tekrar istemcilere dağıtır. Bu süreç, tüm FL turları tamamlanana kadar tekrarlanır. Her tur sonunda modelin performansı değerlendirilir ve turlar bittiğinde tüm istemciler güncellenmiş küresel modeli paylaşır. Çizelge 3.5 FL Deneylerinde kullanılan kontrol parametreleri gösterilmektedir.

Çizelge 3.5. FL Deneylerinde kullanılan kontrol parametreleri

Parametre	Değer / Aralık	Açıklama
İstemci Sayısı (K)	2, 3, 4	Farklı senaryolar için test edilmiştir
Veri Dağılımı	Non-IID farklı batarya testleri ya da araç turları	Non-IID senaryolarda istemciler farklı veri dağılımlarına sahiptir
FL Turu (Round)	10	Her turda yerel eğitim + küresel toplama adımı
Katılım Oranı (C)	1.0 (tam katılım)	Her turda eğitime katılan istemci oranı
Yerel Epoch (E)	100	Her istemci tur başına 100 epoch eğitilir
Yerel Batch Size (B)	64	Yerel eğitimde kullanılan minibatch boyutu
Öğrenme Oranı (η)	0.001	Adam optimizer ile
Momentum (β)	0.5 – 0.9	FedACM’de istemciye özel uyarlanmıştır
Toplama Yöntemi	FedAvg, FedACM, FedAvg-DWA, FedGM, Average Drift	Performans karşılaştırması için
Model Mimarisi	LSTM, GRU, Transformer	Yerel ve küresel model olarak test edilmiştir
Kayıp Fonksiyonu	MSE	SoC tahmin hatasını ölçmek için
Değerlendirme Metrikleri	RMSE, MAE, R^2	Tahmin doğruluğu ölçümü

FL ön işleme ve veri hazırlama adımlarında önce tüm istemcilerde veriler [0,1] aralığına normalize edilmiştir. Non-IID senaryoda her istemcinin veri seti farklı sürüş/sıcaklık koşullarına göre ayrılmıştır. Farklı batarya testleri ya da farklı test sürüşleri eğitim ve test olarak ayrılmıştır.

3.4.1. FedACM

SoC tahmini özelinde yapılan çalışmalarda ise genellikle sabit momentumlu FedAvg yöntemi kullanılmıştır. Ancak son dönemde, istemci yoğunluğu ve veri yapısına göre adaptif momentum kullanan yaklaşımlar, daha doğru modellerin elde edilmesine olanak tanımaktadır. Önerilen FedACM yöntemi, klasik FedAvg'a göre daha yüksek doğruluk sunmaktadır. Bu model, batarya veri setlerinin heterojen doğasını dikkate alarak ağırlık güncellemelerini özelleştirmektedir.

FedACM yönteminin temel amacı, heterojen veri dağılımlarında istemcilerin katkısını daha etkin hale getirmektir. Örneğin, sisteme sonradan katılan ve daha yoğun veri sağlayan istemciler, toplama sürecine daha fazla katkıda bulunmalıdır. Bu doğrultuda momentum değeri her istemcinin veri özelliklerine göre hesaplanmıştır.

FedACM, temel olarak FedAvg algoritmasını temel alır. FedAvg'da, tüm istemcilerden gelen model güncellemeleri ağırlıklı ortalama ile birleştirilir. Bu durum, tüm istemcilerin eşit katkıda bulunduğu varsayımına dayanır. Oysa FedACM'de istemciye özgü uyarlanabilir momentum terimiyle her istemcinin katkısı verisine göre belirlenir. Bu fark, Denklem 3.1 ve 3.2'da FedAvgM momentum eklentili versiyonda gösterilmektedir:

$$w_{t+1}^k \leftarrow w_t^k - v_t^k \quad (3.1)$$

$$v_t^k \leftarrow \beta v_t^k + \nabla w_t^k \quad (3.2)$$

FedACM'de istemciye özel momentum değerlerini Denklem 3.3'deki gibi tanımlar:

$$\beta = \frac{1}{N} \sum_{i=1}^N x_i, \quad x \in (N, T, \rho, d) \quad (3.3)$$

Burada, N veri noktalarının toplamı, T veri toplama süresi, ρ veri yoğunluğu (birim zamanda toplanan veri miktarı) ve d özellik sayısıdır (örneğin akım, voltaj, hız gibi). Bu şekilde, daha fazla ve yoğun veri sağlayan istemciler daha büyük momentum değerleriyle

katkı sağlar. FedACM yönteminin sözde kodu Algoritma 1’de, akış diyagramı ise Şekil 3.4’te verilmiştir.


Algoritma 1: Federated Adaptive Client Momentum

*K: İstemci sayısı (istemciler k ile indekslenir). C : Hesaplama yapılacak istemci oranı. B : Yerel mini-yığın (minibatch) boyutu. E : Yerel epoch (devir) sayısı
 η : Öğrenme oranı (learning rate). β : Momentum katsayısı. N : Veri noktası sayısı
 ρ : Veri yoğunluğu. T : Toplam süre. d : Özellik (feature) sayısı*

Sunucu başlatma:

w_0 ağırlıklarını başlat
for her devir $t=1,2,\dots$ **do**:
 $m \leftarrow \max(C \cdot K, 1)$
 $S_t \leftarrow$ (rastgele seçilen m istemciden oluşan küme)
 for her istemci $k \in S_t$ **parallel olarak**:
 $w_{t+1}^k \leftarrow \text{IstemciGuncelle}(k, w_t)$
 $m_t \leftarrow \sum_{k \in S_t} n_k$
 $w_{t+1} \leftarrow \sum_{k \in S_t} \frac{n_k}{m_t} w_{t+1}^k$
 $w_{t+1}^k \leftarrow w_t^k - v_t^k$
 $v_t^k \leftarrow \beta v_t^k + \nabla w_t^k$
IstemciGuncelle(k, w): (*İstemci k üzerinde çalışır*)
 $\beta \leftarrow \frac{1}{N} \sum_{i=1}^N x_i, x \in (N, \rho, T, d)$
 $B \leftarrow$ (Veri kümesi Pk boyutu B olan mini-yığınlara bölünür)

 for her yerel devir i from 1 to E **do**:
 for her mini yığın $b \in B$ **do**:
 $w \leftarrow w - \eta \nabla \ell(w; b) + \beta$
 Güncellenmiş w ağırlıklarını sunucuya geri gönder



Şekil 3.4. Önerilen Federe Öğrenme algoritmasının çalışma adımları

Bu çalışmada, merkezi olmayan öğrenme ortamında kullanılan model, bir TensorFlow Keras mimarisi ile tanımlanmıştır. Modellemenin değerlendirme süreci, her federe turunda güncellenen ağırlıkların merkezi test verisi üzerinde doğrulanmasıyla gerçekleştirilir. Bu amaçla, sunucuda Denklem 3.4’te verilen değerlendirme fonksiyonu (*evaluate_fn*) kullanılmıştır.

$$Evaluate(w) = Loss(w, X_{test}, Y_{test}), \quad (3.4)$$

$$Accuracy(w) = Acc(w, X_{test}, Y_{test})$$

Burada, w modeli temsil eden ağırlık vektörüdür. X_{test} ve Y_{test} merkezi test veri seti. $Loss$, modelin kayıp fonksiyonu. Acc , modelin doğruluk (accuracy) metriği.

FedAvg Momentum Stratejisi: FL ortamında sunucu tarafında kullanılan strateji FedAvg Momentum algoritmasıdır. Bu strateji, klasik FedAvg algoritmasının bir uzantısıdır ve sunucu tarafında momentuma dayalı ağırlık güncellemeleri içerir. Her tur sonunda, sunucu yeni ağırlıkları Denklem 3.5’teki şekilde günceller.

$$v_t = \beta \cdot v_{t-1} + \frac{1}{K} \sum_{k=1}^K (w_k^t - w_t) \quad (3.5)$$

$$w_{t+1} = w_t + v_t$$

Burada, w_k^t k -inci istemciden gelen model ağırlıkları. w_t , mevcut sunucu ağırlıkları (tur t 'de). v_t , sunucu momentumu. β momentum katsayısı (istemci verileri göz önüne alınarak hesaplanmıştır). K , o turda katılım gösteren istemci sayısı.

Bu mekanizma, öğrenme sürecinde önceki ağırlık güncellemelerinin yönünü koruyarak daha dengeli ve kararlı bir yakınsama sağlamayı amaçlar.

Flower mimarisi kullanan bu FL iş akışı temel olarak dört aşamadan oluşmaktadır. İlk olarak, her istemci kendi yerel verisi üzerinde modeli eğitir ve böylece kullanıcı verisi gizliliği korunmuş olur. Ardından, istemciler elde ettikleri yerel model güncellemelerini merkezi sunucuya iletir. Bu noktada, sunucu her istemcinin veri özelliklerine özgü olarak tanımlanmış momentum değerlerini dikkate alarak model güncellemelerini toplar. Son aşamada, bu güncellemelerle global model güncellenir ve bu süreç, hedef doğruluk seviyesi elde edilene kadar yinelemeli olarak devam eder.

Önerilen FedACM yöntemi genel olarak heterojen veri dağılımları için özel olarak uyarlanmış istemci taraflı bir momentum mekanizması içerir. Heterojen veri ortamlarında daha yüksek tahmin başarımı sağlar. Veri kümesi boyutu, veri yoğunluğu ve özellik zenginliği gibi kritik faktörleri dikkate alarak daha doğru ve adil bir toplama sağlar. İstemcilerin veri yoğunluğu, özellik sayısı ve veri miktarına göre katkı oranı belirlenir. Sunucu taraflı momentum stratejileri ve sabit toplama kurallarına kıyasla, istemciye özel veri çeşitliliğini doğrudan ele alarak daha üstün performans sergiler. Mesafeye dayalı yöntemlere kıyasla daha düşük hesaplama maliyeti sunar ve yüksek tahmin verimliliğini korur.

Önerilen FedACM bazı kısıtlara sahiptir. Heterojenlik varsayımı nedeniyle homojen veri ortamlarında gereksiz hesaplama yükü oluşturabilir. Tüm istemciler aynı veri koşullarındaysa, FedAvg gibi basit yöntemler daha uygun olabilir. Ağırlık normalizasyonu ağırlık sapmalarını azaltmakta etkilidir ancak ek karmaşıklık yaratabilir.

3.4.2. Diğer toplama kuralları ile karşılaştırma

Bu tez çalışmasında, karşılaştırma amacıyla literatürde yaygın olarak kullanılan çeşitli toplama kuralları test edilmiştir. İlk olarak, FL çalışmalarında yaygın kullanılan yöntemlerden biri olan FedAvg referans noktası olarak kullanılmıştır. FedAvg, tüm katılımcıların eşit katkı sağladığı varsayımıyla, model parametrelerini basit bir ağırlıklı ortalama mekanizmasıyla günceller. Tüm istemcilerin eşit katkı yaptığı temel yöntemdir. Ancak veri heterojenliğini göz önüne almaz. Önerilen FedACM, her bir istemcinin veri özelliklerine göre uyarlanmış momentumdan faydalanarak, daha dengeli ve etkili bir agregasyon süreci sağlar; bu sayede farklı veri dağılımlarına sahip istemciler dikkate alınır ve FedAvg'nin eşit katkı varsayımının ötesine geçilir.

FedAvg-DWA yöntemi, sınıf dengesizliği sorununu aşmak için ağırlıklar arası mesafeye dayalı toplama kuralı yaparken, bu mesafe hesaplamaları fazladan hesaplama yükü getirir ve özellikle çok sayıda istemci veya büyük model boyutlarında ciddi maliyetlere yol açabilir. Ayrıca, veri heterojenliğinin bulunduğu durumlarda, mesafeye dayalı ağırlıklandırma bazı istemcilerin katkılarını azaltabilir veya model güncellemelerinin yanlış değerlendirilmesine neden olabilir. FedACM, FedAvg-DWA'daki mesafeye dayalı hesaplamaların getirdiği bu işlem yükünü ortadan kaldırır ve bu nedenle çok sayıda istemciye veya karmaşık modellere sahip senaryolarda daha verimli çalışır. Ayrıca, momentum tabanlı yaklaşımı sayesinde, istemci verilerindeki heterojenliği daha etkili şekilde yönetir ve mesafeye dayalı yöntemlerin neden olduğu potansiyel yanlış değerlendirmelerden kaçınır.

Bunun yanı sıra, FedGM yöntemi, FL'de sunucu tarafı momentum kullanımını sistematik biçimde ele alır ve momentum değerlerini öğrenme oranını dinamik olarak ayarlayarak günceller. Bu yöntem ağırlık güncellemeleri için öğrenme sürecini optimize eder. Ancak FedGM bu işlemi sunucu tarafında gerçekleştirdiğinden istemciler arasındaki farklılıkları göz ardı eder. FedACM'nin istemci odaklı momentum yaklaşımı ise, istemciler arası heterojenliği açıkça dikkate alarak bu eksikliği kapatır. Bu yaklaşım, özellikle batarya performansı tahmini gibi istemciye özel veri özelliklerinin model başarımını ciddi biçimde etkilediği uygulamalar için avantaj sağlar.

Son olarak, Average Drift yöntemi de batarya performansı tahmini gibi karmaşık ve değişken veri desenlerine sahip gerçek dünya uygulamalarında, optimal noktaya yakın bu düşük değişim, modelin gerçek veri değişkenliklerini yeterince yansıtmamasını engelleyebilir. İstemcinin optimal modele yakınlık düzeyine göre güncellemeyi değerlendirir. Gerçek dünyadaki değişken verilerde (ör. batarya) düşük sapma varsayımı geçersiz kalabilir. FedACM, veri odaklı momentum hesaplaması sayesinde bu tür karmaşık ve değişken desenlere karşı daha dayanıklıdır. Gerçek veri değişimlerine odaklanarak, Average Drift yönteminin kaçırabileceği ince desenleri yakalayabilir.


SoC, bir bataryanın mevcut kapasitesinin maksimum kapasitesine oranını gösteren bir ölçüdür. Bu ölçü bataryanın akımı, sıcaklığı ve voltajı gibi değerler üzerinden tahmin edilir (Li vd., 2021; Yayan vd., 2021; Yılmaz vd., 2024). Bu çalışmada zaman serisi verileri ile LSTM tabanlı bir model geliştirilmiştir. LSTM'nin uzun dönemli bağımlılıkları öğrenme kabiliyeti, batarya gibi yavaş değişen süreçlerin modellenmesinde avantaj sağlamaktadır. Modelin performansı çeşitli hata metrikleriyle değerlendirilmiş ve görselleştirilmiştir.

Çalışmada, FL uygulamaları için açık kaynaklı bir çerçeve olan Flower tercih edilmiştir (Beutel vd., 2022). Flower, sağlık, otomotiv ve mobil uygulamalarda yaygın şekilde kullanılmaktadır. Diğer platformlarla karşılaştırıldığında, Flower; çok düğümlü çalışmayı desteklemesi, istemci heterojenliği ile uyumlu yapısı, ML kütüphanelerine bağımlı olmadan çalışabilmesi ve yüksek iletişim esnekliği gibi avantajlara sahiptir. Flower'ın genişletilebilir yazılım mimarisi, bu çalışmanın ihtiyaçlarına uyarlanabilirliği kolaylaştırmış ve önerilen mimarinin temel bileşenlerini yapılandırmada önemli rol oynamıştır.


3.5. Önerilen Federe Öğrenme Mimarisi ile Sağlık Durumu Tahmini

Bu çalışmada, Musoshi elektrikli aracı için matematiksel temelli bir model kullanılarak hep aynı rota üzerinde gittiği durumda, önceki turlarına göre referans noktası belirlenerek, elektrikli araç bataryaları için SoH tahmini gerçekleştirilmiştir. Geliştirilen model, sürücü profillerinin analizine dayalı olarak her bir aracın katkı derecesini hesaplamakta ve FL aracılığıyla merkezi bir SoH tahmini sağlamaktadır.

Çalışma, kontrollü bir rota üzerinde elde edilen batarya verilerine dayanmaktadır. Bu rota boyunca yapılan sürüşlerin ilki "referans sürüş" olarak tanımlanmış ve SoH değeri bu sürüş için %100 kabul edilmiştir. Daha sonraki sürüşlerde elde edilen veriler, referans sürüşe göre değerlendirilmiştir. Her bir sürüş için araç hızı zaman serisi olarak toplanmış; bu verilerden ortalama hız, hızın standart sapması ve referans sürüş profiline göre *DTW* ile mesafe hesaplanmıştır. Şekil 3.5'te SoH sürüş profili karşılaştırma kurgulanan senaryosu görülmektedir. Şekil 3.6'te ise SoH tahmin akış diyagramı verilmektedir.



Şekil 3.5. SoH tahmini için sürüş profili karşılaştırmaları



Şekil 3.6. Önerilen Federe Öğrenme SoH tahmin çalışma adımları

Batarya performansının bozulması, zaman içinde birim SoC başına kat edilen mesafenin analiz edilmesiyle modellenebilir. Batarya eskidikçe, her SoC başına elde edilebilen mesafe azalır ve bu da sağlık tahmini için bir temel oluşturur. Her bir sürüşün SoH değeri, mesafeye dayalı olarak, araçların %1'lik SoC düşüşüyle kat ettikleri mesafenin, referans sürüşteki aynı SoC kaybı ile kat edilen mesafeye oranı üzerinden elde edilmiştir. Bu yöntem, batarya verimliliğini doğrudan gözlemlemeye imkân tanıyan basit fakat etkili bir ölçüm yaklaşımı sunmaktadır. Bu varsayımlar eşliğinde Denklem 3.6'teki gibi bir formül oluşturulabilir.

$$SoH_{local} = \left(\frac{d_{local, 1\% SoC}}{d_{ref, 1\% SoC}} \right) \times 100 \quad (3.6)$$

Burada d_{local} , 1% SoC %1'lik SoC kaybı sırasında ilgili sürüşte katedilen mesafeyi, d_{ref} , 1% SoC ise aynı kayıp için referans sürüşte katedilen mesafeyi ifade eder. Böylece referans noktaya göre SoH değerlendirmesi yapılır.

Elektrikli araç batarya yaşlanmasında sürücü profili önemli bir belirleyicidir. Sürücünün araç kullanım tarzı; örneğin ani hızlanmalar, sık sık sert frenleme, yüksek hızda sürüş veya yoğun dur-kalk trafiğe maruz kalma, bataryanın yüklenme profiline doğrudan etki eder (Guo vd., 2021). Ortam ve sürüş koşullarının aynı olmadığı koşullarda her bir istemcinin (araç biriminin), bu hesaplamalara göre elde ettiği yerel SoH değeri ve sürüş profil benzerlik ölçütleri (DTW, hız ortalaması, standart sapma), sistemde bir güven katsayısı üretmek amacıyla birleştirilmiştir. Bu katsayı, ilgili istemcinin genel modele ne kadar katkı sağlayacağına karar vermek için kullanılır (Denklem 3.7).

$$W_i = avg(DTW + AvgSpeedRate + DevSpeedRate) \quad (3.7)$$

Burada W_i istemci ağırlığı, $AvgSpeedRate$ ortalama hız, $DevSpeedRate$ hızın standart sapmasıdır. Bu bağlamda düşük DTW ve düşük hız değişkenliği, daha güvenilir ve referansa turuna daha uygun bir sürüş profili anlamına gelmekte ve dolayısıyla ağırlığı artırmaktadır.

Son aşamada, bu istemcilerden gelen yerel SoH tahminleri ve ağırlık katsayıları, Flower federe öğrenme çerçevesi kullanılarak sunucuda birleştirilmiştir. Merkezi sunucu, istemcilerden gelen SoH değerlerini ağırlıklı ortalama yöntemiyle birleştirerek global bir SoH tahmini üretmiştir (Denklem 3.8).

$$SoH_{global} = \frac{\sum_{i=1}^N w_i SoH_i}{\sum_{i=1}^N w_i} \quad (3.8)$$

Bu yapı, herhangi bir veri aktarımı yapılmadan, sürüş profili temelli matematiksel hesaplamaların araç tarafında yerel olarak gerçekleştirilmesine olanak tanımakta ve veri gizliliğini koruyarak merkezi bir SoH çıkarımı sağlamaktadır. Hesaplama için optimum

koşullar kontrol edildiği için ortam sıcaklığı referans noktasından minimum ve maksimum değerleri ortalaması kadar farklı olan turlar hesaba katılmamıştır.



4. BULGULAR VE TARTIŞMA

Bu bölümde SoC ve SoH tahmini üzerine gerçekleştirilen merkezi ve dağıtık öğrenme tabanlı çalışmaların bulguları sunulmakta ve tartışılmaktadır. Gerçek dünya verileri ile literatürde yaygın olarak kullanılan veri setleri kullanılarak yapılan deneysel çalışmaların sonuçları grafikler ve tablolar aracılığıyla görsel olarak ifade edilmiştir. Ayrıca, kullanılan yöntemlerin performansları karşılaştırmalı olarak değerlendirilmiş ve elde edilen sonuçlar doğrultusunda yöntemlerin güçlü ve zayıf yönleri tartışılmıştır.


4.1. Merkezi Öğrenme Temelli Yaklaşımlarda Elde Edilen Sonuçlar

Bu bölümde merkezi ML ve DL modelleri kullanılarak yapılan SoC tahmini deneylerinin sonuçları sunulmaktadır. Transformer, LSTM, Bi-LSTM ve SVR modellerinin çıktıları Musoshi, NASA, Stanford ve BMW i3 veri setleri üzerinde hem grafiksel hem de sayısal olarak karşılaştırılmıştır. Her bir modelin performans sonuçları eğilimleri, güçlü ve zayıf yönleri değerlendirilmiştir. Modellerin eğitiminde Çizelge 4.1’de gösterilen kontrol parametreleri kullanılmıştır.

Çizelge 4.1. Merkezi ML ve DL yaklaşımları için kontrol parametreleri

Parametre	Transformer	LSTM	Bi-LSTM	SVR
Girdi Özellikleri	Akım, Voltaj, Sıcaklık, Hız	Akım, Voltaj, Sıcaklık, Hız	Akım, Voltaj, Sıcaklık, Hız	Akım, Voltaj, Sıcaklık, Hız
Çıkış	SoC (%)	SoC (%)	SoC (%)	SoC (%)
Katman Sayısı	4 encoder, 4 decoder	2 LSTM	2 Bi-LSTM	—
Gizli Boyut	64	64	64	—
Dikkat Başlığı (head)	8	—	—	—
Epoch Sayısı	100	100	100	—
Batch Size	64	64	64	—
Öğrenme Oranı (η)	0.001	0.001	0.001	—
Optimizasyon Yöntemi	Adam	Adam	Adam	Linear Kernel (C=1.0)
Kayıp Fonksiyonu	MSE	MSE	MSE	MSE
Değerlendirme Metrikleri	RMSE, MAE, R^2	RMSE, MAE, R^2	RMSE, MAE, R^2	RMSE, MAE, R^2

İlk çalışmada test edilen Transformer modeli, öz-dikkat mekanizması sayesinde zaman serisi verilerinde bağlamsal ilişkileri etkin şekilde öğrenebilmektedir. Bu çalışmada kullanılan konfigürasyon ile batarya akımı, voltajı, sıcaklığı ve hız gibi çok boyutlu sensör verileri işlenmiş ve SoC tahmini yapılmıştır. Şekil 4.1’de Transformer modeli sonuçları gösterilmiştir.




Şekil 4.1. Transformer SoC tahmini (a) Musoshi (b) NASA (c) Stanford (d) BMW i3

Transformer modelinin dört veri setindeki tahmin performansı özellikle Musoshi veri setinde modelin gerçek SoC değerlerini yüksek doğrulukla izlediği ve ani değişimlere iyi tepki verdiği gözlemlenmiştir. Eğitim sürecinde gözlenen kayıp fonksiyonu eğrisi, modelin aşırı öğrenmeden kaçındığını ve genel geçerliği yüksek bir yapı oluşturduğunu göstermektedir.


LSTM modeli, zaman serilerindeki uzun dönemli bağımlılıkları modelleyebilme kabiliyetiyle bilinmektedir. Bu çalışmada giriş olarak ölçülen voltaj, akım, sıcaklık ve hız gibi temel özellikler kullanılmıştır. Modelin performansı, özellikle kısa vadeli değişimlerin

öğrenilmesinde başarılı olmakla birlikte, ani değişimlerde Transformer kadar hassas sonuçlar üretememiştir (Şekil 4.2).



Şekil 4.2. LSTM SoC tahmini (a) Musoshi (b) NASA (c) Stanford (d) BMW i3

Bi-LSTM modelinin tahmin çıktıları Şekil 4.3'te sunulmuştur. Model bazı veri setlerinde LSTM'ye kıyasla daha dengeli bir performans sergilemiş; özellikle NASA ve BMW i3 veri setlerinde daha düşük sapma üretmiştir. Transformer kadar güçlü olmasa da Bi-LSTM'in genel doğruluk seviyesi yüksektir.



Şekil 4.3. Bi-LSTM SoC tahmini (a) Musoshi (b) NASA (c) Stanford (d) BMW i3


SVR, derin öğrenme modellerine kıyasla daha geleneksel bir regresyon tekniğidir. Bu çalışmada SVR modeli, lineer çekirdek ile tüm veri setleri üzerinde eğitilmiş ve değerlendirilmiştir. Diğer modellere kıyasla yüksek RMSE ve MAE değerleri, SVR'nin bu problem için yeterince esnek olmadığını göstermektedir.

Tüm veri setlerinde modellerin SoC tahmin performansı metrikleri Çizelge 4.2'de özetlenmiştir. Transformer modeli genel olarak en düşük RMSE, MAE ve Max Error değerlerini üretmiş; SVR modeli ise en düşük R^2 skorlarını elde etmiştir.

Çizelge 4.2. Performans metrikleri karşılaştırması


Veri seti	Metrik	LSTM	Bi-LSTM	SVR	Transformer
NASA	RMSE	1.716	2.226	16.662	0.872
	MAE	1.674	2.147	16.296	0.799
	R^2 Score	0.998	0.998	0.361	0.994
	Max Error	7.245	6.958	8.245	6.697
Stanford	RMSE	2.024	1.921	5.417	1.921
	MAE	1.874	1.731	3.298	1.553
	R^2 Score	0.999	0.999	0.831	0.995
	Max Error	5.805	5.739	5.861	5.902
BMW i3	RMSE	0.703	0.584	3.777	0.289
	MAE	0.337	0.347	3.619	0.259
	R^2 Score	0.998	0.998	0.284	0.999
	Max Error	1.210	0.744	3.697	1.210
Musoshi - L5	RMSE	1.170	0.944	3.277	0.166
	MAE	1.006	0.756	3.050	0.132
	R^2 Score	0.962	0.974	0.344	0.997
	Max Error	2.614	2.325	3.558	2.135

Musoshi veri seti için dört modelin eğitim sürecindeki kayıp fonksiyonları Şekil 4.4’de bir arada sunulmuştur. Tüm modeller için 100 dönem (epoch) boyunca kayıp ve doğrulama kaybı eğrilerini göstermektedir. Bu eğriler, her modelin eğitim sırasındaki yakınsama davranışını ve genelleme yeteneklerini göstermektedir. Transformer modeli en düşük kayıp değerine sahiptir.



Şekil 4.4. Musoshi kayıp fonksiyonları (a) Transformer, (b) LSTM ve (c) Bi-LSTM

Gerçek ve tahmin SoC değerlerinin karşılaştırıldığı grafikler Şekil 4.5'te verilmiştir. LSTM ve Bi-LSTM modellerinin test sonuçları incelendiğinde doğrulama eğrilerinin dalgalı yapısı dikkat çekmektedir. Bu durum, zaman zaman aşırı uyum ya da yetersiz öğrenme gibi problemlerin yaşandığını göstermektedir.



Şekil 4.5. Musoshi SoC tahmini (a) Transformer, (b) LSTM ve (c) Bi-LSTM

4.2. Federe Öğrenme ile Elde Edilen Sonuçlar


Bu bölümde, LSTM tabanlı batarya SoC tahmini için Flower çerçevesi kullanılarak dört farklı veri kümesi ve çeşitli ağırlık birleştirme yöntemleriyle FL sistemi uygulanmıştır. Önerilen FedACM yöntemi ile birlikte, FedAvg, FedAvg-DWA, FedGM ve Average Drift yöntemler de karşılaştırmalı olarak değerlendirilmiştir. Kullanılan veri kümeleri NASA, Stanford, BMW i3 ve Musoshi L5 elektrikli araca ait gerçek dünya verileridir.

FL süreci, sunucunun başlangıç parametrelerini belirlemesi ve bir strateji seçmesiyle başlar. İlk turda, sunucu yeterli sayıda istemcinin bağlanmasını bekler. Sunucu başlatıldığında, Google uzak prosedür çağrısı (gRPC) sunucusu seçilen stratejiye ait global parametreleri kullanır. Her bir istemci, kendi yerel veri kümesi üzerinde belirli epoch sayısı kadar modeli eğitir. Eğitim tamamlandıktan sonra, istemciler güncellenmiş ağırlıkları sunucuya gönderir. Sunucu, gelen güncellemeleri belirlenen toplama kuralına göre birleştirerek global modeli günceller ve bu modeli tüm istemcilere gönderir. Bu işlem her turda tekrar eder. Eğitim tamamlandıktan sonra, global model bir test veri kümesi üzerinde değerlendirilerek performans ölçülür.

Yapılan yerel testlerde, kayıp fonksiyonu 100 epoch sonunda sabitlendiğinden dolayı (Şekil 4.6) eğitim için epoch değeri 100 olarak belirlenmiştir. Eğitim süreci boyunca RMSE, MAE ve R^2 gibi metrikler kullanılarak model performansı değerlendirilmiştir. FL deneyinde kullanılan parametre değerleri ise Çizelge 4.3'te gösterilmektedir.


Çizelge 4.3. FL kontrol parametre değerleri

Parametre	Değer / Açıklama
FL Çerçevesi	Flower (Python)
Toplama Yöntemleri	FedACM (önerilen), FedAvg, FedAvg-DWA, FedGM, Average Drift
İstemci Sayısı (K)	4 (NASA, Stanford, BMW i3, Musoshi)
Veri Dağılımı	Non-IID
Yerel Model Tipleri	LSTM (ana model), GRU, Transformer (karşılaştırma)
Girdi Özellikleri	Akım, Voltaj, Sıcaklık, Hız
Çıkış	SoC (%)
Yerel Epoch Sayısı	100 (tur başına)
Toplam FL Turu	20
Batch Size	64
Öğrenme Oranı (η)	0.001
Optimizasyon Yöntemi	Adam
Kayıp Fonksiyonu	MSE
Değerlendirme Metrikleri	RMSE, MAE, R^2
FedACM Özel Parametreleri	İstemciye özel momentum katsayıları (0.7–0.95 arası, veri istatistiklerine göre belirlenmiştir)




Şekil 4.6 Musoshi kayıp fonksiyonu

FL yöntemleri, Musoshi veri kümesi üzerinde tur 1’den başlayarak 10. tura kadar test edilmiştir. Tüm yöntemler için en iyi sonuçlar 10. turda elde edilmiştir. Farklı toplama kurallarının SoC tahmini üzerindeki etkileri değerlendirilmiş ve gerçek SoC ile tahmin edilen SoC değerleri karşılaştırılmıştır (Şekil 4.7).




Şekil 4.7 Musoshi tur sayıları performans karşılaştırılması

Özellikle önerilen FedACM yöntemi, gerçek SoC değerlerine en yakın tahminleri sağlayarak yüksek doğruluk göstermiştir. FedAvg, heterojen veri yapılarında zayıf performans göstermiştir. Tahminlerde büyük sapmalar görülmüştür. FedAvg-DWA, genellikle gerçek SoC değerlerinin altında kalmış, SoC’yi düşük tahmin etmiştir. FedGM, özellikle zaman serisinin ikinci yarısında sapmalar artmış, heterojen veri ile başa çıkmakta yetersiz kalmıştır. Average Drift, veri dağılımı sapmalarını azaltmayı hedeflese de genel doğruluğu düşüktür. FedACM, tüm veri kümelerinde (BMW i3, NASA, Stanford) en iyi tahmin sonuçlarını üretmiştir. Özellikle heterojen ve gerçek dünya verileri üzerinde yüksek başarımlıdır. Şekil 4.8’de Musoshi veri seti ile yapılan test gözükmemektedir.




Şekil 4.8 Musoshi tüm toplama kuralları için SoC tahmini

BMW i3 veri kümesinde FedACM yöntemi, SoC'deki düşüş trendini en doğru şekilde takip eden tahminleri üretmiştir (Şekil 4.9). Diğer yöntemler ciddi sapmalar göstermiştir.




Şekil 4.9 BMW i3 tüm toplama kuralları için SoC tahmini

Stanford veri kümesinde ise FedACM ve FedGM görece daha iyi sonuçlar verirken, Average Drift büyük sapmalar sergilemiştir (Şekil 4.10).



Şekil 4.10 Stanford tüm toplama kuralları için SoC tahmini

NASA veri kümesinde FedGM, FedACM'e daha yakın sonuçlar üretmiş olsa da FedACM doğruluğunu ve kararlılığını korumuştur (Şekil 4.11). Diğer yöntemler tahminlerde kararsız ve dengesiz sonuçlar üretmiştir.



Şekil 4.11 NASA tüm toplama kuralları için SoC tahmini


Sunulan dört şekil (Şekil 4.8, 4.9, 4.10 ve 4.11), farklı veri setleri (Musoshi, BMW i3, Stanford ve NASA) üzerinde Batarya Şarj Durumu (SoC) tahmini için çeşitli birleştirme algoritmalarının performansını görsel olarak karşılaştırmaktadır. Bu grafikler bir bütün olarak incelendiğinde, önerilen FedACM yönteminin diğer tüm algoritmalarla kıyasla tutarlı bir şekilde en üstün performansı sergilediği açıkça görülmektedir. FedACM, tüm veri kümelerinde gerçek SoC değerlerini en yakın şekilde takip ederek yüksek doğruluk ve kararlılık göstermiştir. Buna karşılık, özellikle heterojen veri yapılarında zayıf kalan FedAvg

ve genel doğruluğu düşük olan Average Drift gibi yöntemler, gerçek değerlerden belirgin sapmalar sergilemiştir. FedAvg-DWA genellikle SoC'yi olduğundan düşük tahmin etme eğilimindeyken, FedGM bazı senaryolarda (NASA ve Stanford) daha rekabetçi sonuçlar üretse de FedACM'nin genel başarısı ve tutarlılığına ulaşamamıştır. Sonuç olarak, bu görsel kanıtlar, FedACM'nin farklı ve zorlu veri koşulları altında bile SoC tahmini için en güvenilir ve sağlam yöntem olduğunu güçlü bir şekilde desteklemektedir.

4.3. Yöntemlerin Karşılaştırılması ve Analizi

Bölüm 4.2’de elde edilen sonuçlar, FedAvg yönteminin veri yoğunluğu ve dağılım farklılıklarını dikkate almadan ağırlık ortalaması alması nedeniyle heterojen veri setlerinde başarısız olduğunu göstermektedir. Özellikle BMW i3 gibi veri setlerinde bu fark bariz biçimde görülmüştür.

Genel olarak, FedACM yöntemi, farklı veri kümeleri arasında denge kurarak üstün sonuçlar üretmiştir. Adaptif yapısı sayesinde ağırlık güncellemelerinde esneklik sağlamış, heterojen ve dengesiz veri yapılarına karşı etkili olmuştur. Dört farklı veri kümesinde elde edilen RMSE değerleri, FedACM’in en düşük hata değerlerine sahip olduğunu göstermektedir (Şekil 4.12).



Şekil 4.12. Performans karşılaştırması

Çizelge 4.4, kullanılan FL yöntemlerinin RMSE, MAE ve R^2 performans metriklerini özetlemektedir.

Çizelge 4.4. Toplama kurallarının performans metrikleri

Yöntem	RMSE	MAE	R ²
FedAvg	1.9161	1.2929	0.8374
Average Drift	1.2365	1.2133	0.8581
FedAvg-DWA	0.8374	0.8944	0.957
FedGM	1.1392	1.0838	0.8985
FedACM	0.0601	0.0518	0.9997

FedACM, en düşük RMSE ve MAE değerleri ile en yüksek R² skoruna sahiptir. Bu durum, önerilen yöntemin yüksek tahmin doğruluğuna sahip olduğunu açıkça göstermektedir. FedAvg, en yüksek hata oranları ve en düşük R² değeri ile en zayıf performansı göstermiştir. Diğer yöntemler (FedAvg-DWA, FedGM) orta düzeyde performans sergilemiştir. Sonuç olarak, FedACM yöntemi batarya SoC tahmini gibi zaman serisi problemlerinde yüksek doğruluk sağlamış ve veri çeşitliliğine karşı dayanıklılığını ispatlamıştır.

FL kapsamında yapılan testlerde, istemci sayısının SoC tahmin doğruluğu üzerindeki etkisi detaylı şekilde incelenmiştir. İki istemcili (Musoshi, BMW i3), üç istemcili (Musoshi, BMW i3, NASA) ve dört istemcili (Musoshi, BMW i3, NASA, Stanford) senaryolar değerlendirilmiştir. Elde edilen sonuçlar, istemci sayısındaki artışın modelin hata metriklerini belirgin şekilde iyileştirdiğini; RMSE ve MAE değerlerinin düştüğünü, R² skorunun ise yükseldiğini göstermektedir. En az dört istemci ile sistem kararlı ve yüksek doğrulukta çalışmakta, istemci sayısı arttıkça genel olarak performans korunmakta veya küçük iyileşmeler görülmektedir. Dördüncü istemciden sonra eklenecek istemcilerin katkısı normal düzeyde kalmakta ve performans artışı doygunluk noktasına yaklaşmaktadır. Bu bulgular, FL yapılarında yeterli istemci sayısının sağlanmasının kararlı ve güvenilir tahminler için kritik olduğunu ortaya koymaktadır (Çizelge 4.5).

Çizelge 4.5. İstemci sayısı performans karşılaştırmaları

Yöntem	RMSE	MAE	R ²
2-istemci	3.1830	2.8463	0.8356
3-istemci	0.6370	0.6108	0.9934
4-istemci	0.0601	0.0518	0.9997

FL yöntemi ile merkezi veri toplama temelli SoC tahmin modelleri karşılaştırmalı olarak analiz edilmiştir. Dört farklı veri seti birleştirilerek merkezi eğitim yapılmış ve LSTM modeli kullanılarak sonuçlar elde edilmiştir. Hesaplamalar, NVIDIA GTX 1650 Ti GPU üzerinde gerçekleştirilmiş ve işlem süresi, CPU kullanımı, RAM ve GPU VRAM kullanımı gibi kaynak tüketim metrikleri kaydedilmiştir (Çizelge 4.6).

Çizelge 4.6 Hesaplama maliyetleri

Yöntem	Çalışma Zamanı (sn)	Ortalama CPU Kullanımı (%)	Ortalama RAM Kullanımı (GB)	Ortalama GPU VRAM Kullanımı (MB)
Merkezi	2932	27.2	7.07	86.19
FL	782.41	17.75	3.31	100.53

FL yöntemi, merkezi modele kıyasla daha kısa sürelerde çalışmakta, daha az CPU ve RAM kullanmakta, ancak istemcilerin kendi GPU kaynaklarını kullanması nedeniyle hafif derecede daha fazla VRAM tüketmektedir. Performans açısından ise, FL yöntemi RMSE, MAE ve R² metriklerinde merkezi modele kıyasla açık farkla daha başarılıdır (Çizelge 4.7). Bu fark, FL yönteminin her istemcide yerel olarak model eğitimi yapması ve ağırlıkların daha verimli şekilde güncellenmesi sayesinde oluşmaktadır. Sonuçlar, FL yaklaşımının sadece kaynak verimliliği açısından değil, aynı zamanda model doğruluğu ve güvenilirliği bakımından da daha üstün olduğunu ortaya koymaktadır.

Çizelge 4.7. Merkezi ve FL performans metrikleri

Yöntem	RMSE	MAE	R ²
Merkezi	1.162	0.8344	0.9780
FL	0.0601	0.0518	0.9997

FL altyapısı üzerinde FedACM stratejisiyle GRU, LSTM ve Transformer mimarileri karşılaştırmalı olarak değerlendirilmiştir (Çizelge 4.8).

Çizelge 4.8. Farklı modeller için FL performans karşılaştırması


Yöntem	RMSE	MAE	R ²
Transformer	0.4340	0.3689	0.9855
GRU	0.0330	0.0286	0.9998
LSTM	0.0601	0.0518	0.9997

Musoshi veri seti kullanılarak yapılan deneylerde GRU modeli, en düşük RMSE ve MAE değerleriyle en yüksek doğruluğu sağlamıştır. LSTM modeli de benzer şekilde başarılı sonuçlar üretmiş ve yüksek hesaplama verimliliği sunmuştur. Buna karşın, Transformer modeli yüksek doğruluk elde etse de hesaplama süresi ve kaynak tüketimi açısından daha maliyetli olmuştur. Bu durum, Transformer'ın daha karmaşık veri yapılarını modellemede avantajlı olmasına rağmen, görece daha hafif uygulamalarda GRU ve LSTM gibi mimarilerin daha uygun olduğunu göstermektedir. Sonuç olarak, FL içinde SoC tahmini için GRU ve LSTM modelleri, doğruluk ve verimlilik dengesini en iyi sağlayan mimariler olarak öne çıkmaktadır

4.4. Federe Öğrenme ile Batarya Sağlığı Sonuçları

Federe Öğrenme ile SoH tahmini için, Musoshi L5 elektrikli aracının sabit bir rotada sürülerek elde edilen batarya verileri temel alınmıştır (Şekil 4.13 (a)). Bu rotada eğim, trafik gibi çeşitli çevresel etkenlerin şarj tüketimine olan etkisini en aza indirmek amacıyla, düz bir yol kesiminden elde edilen veriler kullanılmış (Şekil 4.13 (b)) ve böylece daha kontrollü bir test ortamı sağlanmıştır. Bu bağlamda iki farklı deney senaryosu geliştirilmiştir.

İlk deneyde, 2024 yılının kış aylarında elde edilen sürüş verileri referans olarak kabul edilmiştir. Bu rotaya ait şarj değişim oranları belirlenmiş ve 2024–2025 yıllarında benzer sıcaklıklarda gerçekleştirilen diğer sürüşler, filo üyesi olarak tanımlanan sanal istemciler şeklinde modellenmiştir. Benzer şekilde, ikinci deney için 2024 yılı yaz aylarında gerçekleştirilen sürüş referans alınmış; sıcaklık açısından benzer koşullardaki diğer sürüş verileri ile karşılaştırmalı analiz yapılmıştır. Bu yapı sayesinde mevsimsel değişkenliğe karşı iki farklı kontrollü deney ortamı oluşturulmuştur.



Şekil 4.13. Musoshi aracı ESOGU kampüsü rotası

Yürütülen deneylerde, Bölüm 3.4’te detaylandırıldığı üzere, sürücü profillerine ait hız grafiklerinden öznitelikler (ortalama hız, standart sapma) çıkartılmış ve bu öznitelikler referans verilerine göre orantılanmıştır. Ayrıca, her bir sürüş profili için referans profile olan benzerlik, DTW yöntemiyle ölçülmüştür. Elde edilen öznitelik oranları ve DTW değerleri 0–1 aralığına normalize edilmiş ve her istemci için bu değerlerin ortalaması alınarak bir ağırlık katsayısı hesaplanmıştır.

SoH hesaplamasında ise, her istemcinin %1’lik bir SoC ile ne kadar yol katettiği belirlenmiş ve bu değer referans noktasında yapılan aynı hesaplama ile orantılanmıştır. Böylelikle her bir istemciye karşılık gelen bireysel SoH değerleri elde edilmiştir. Tüm bu istemciler Flower tabanlı federe öğrenme mimarisi altında simüle edilerek, SoH ve ağırlık değerleri modele dahil edilmiştir. Hesaplanan ağırlıklar, her istemcinin toplama kuralına ne

ölçüde katkı sağlayacağını belirlemiş ve böylece federe modelin global SoH çıktısına etkisi kontrol edilmiştir. Örneğin, referans sürücü profiline göre hız değişimi daha fazla olan istemciler daha düşük ağırlıkla modele katkı sağlamıştır. Kış aylarına ait ölçüm sonuçları Çizelge 4.9’de sunulmuştur.

Çizelge 4.9. Kış testleri sağlık hesaplama sonuçları

İstemci	Toplam Süre (sn)	Ortalama Hız (km/h)	Hız Standart Sapma	Ortalama Sıcaklık (°C)	SoC başına KM	DTW Skoru	SoH (%)
1	206	17.95	8.88	1.89	2.78	0.00	98.53
2	68	23.71	1.97	3.42	2.80	0.93	99.33
3	103	15.65	1.66	3.50	2.63	0.57	93.46
4	59	32.77	3.87	7.70	2.56	0.79	90.74
5	52	30.45	5.50	3.27	2.44	0.83	86.72
6	59	33.10	4.05	7.79	2.58	0.80	91.66
7	64	28.25	5.88	-4.84	1.48	0.91	52.41
8	84	23.32	3.29	1.63	2.37	0.88	83.93
9	99	16.29	1.65	3.99	2.36	0.64	83.64
10	129	15.20	1.54	2.36	2.27	0.50	80.55
11	52	31.15	6.17	4.63	2.25	0.80	79.83
12	121	16.17	1.36	2.96	2.17	0.59	77.14

Çizelge 4.7 incelendiğinde, özellikle istemci 13 ve 14'te ortam sıcaklığının diğerlerine göre daha düşük seyrettiği, buna bağlı olarak da SoH değerlerinin düştüğü gözlemlenmiştir. Ancak bu istemcilerin ağırlık katsayıları da düşük olduğundan, toplama kuralına etkileri sınırlı kalmıştır.

Tüm istemcilerin SoH ve ağırlık değerleri, toplama kuralına göre federe öğrenmeye dahil edildiğinde, global SoH değeri %84.64 olarak hesaplanmıştır. Referans sürüşüne göre SoH değerinin düştüğü gözlemlenmiştir. Kış koşullarındaki düşük sıcaklıklar dikkate alındığında, bu değer makul bir seviyededir.

Benzer şekilde yaz mevsiminde gerçekleştirilen testlerin sonuçları Çizelge 4.10’da sunulmuştur. Bu deneyde de yaz aylarına ait referans sürüş profili kullanılarak öznitelikler çıkarılmış, normalize edilmiş ve ağırlıklar hesaplanmıştır. Aynı şekilde her bir istemcinin %1 SoC ile katettiği mesafeye göre bireysel SoH değeri elde edilmiştir. Bu SoH ve ağırlık değerleri federe öğrenme toplama kuralına tabi tutularak global SoH hesaplanmıştır.

Çizelge 4.10. Yaz testleri sağlık hesaplama sonuçları

İstemci	Topla m Süre (sn)	Ortalama Hız (km/h)	Hız Standart Sapma	Ortalama Sıcaklık (°C)	SoC başına KM	DTW Skoru	SoH (%)
1	128	14.56	1.17	26.00	2.07	0.09	93.19
2	117	14.68	1.96	26.00	2.17	0.11	97.59
3	63	29.39	9.74	26.00	2.05	0.93	92.23
4	69	26.43	5.87	26.00	1.71	0.73	77.02
5	47	35.80	8.72	17.28	1.80	0.85	80.92
6	40	39.94	10.02	19.36	1.71	0.93	76.83
7	39	41.65	11.32	19.84	1.80	0.93	81.24
8	41	40.14	10.02	23.90	1.69	0.92	76.22
9	46	37.83	8.46	21.65	1.79	0.88	80.58
10	44	39.21	9.91	20.78	1.60	0.89	71.91
11	46	38.45	9.61	20.44	1.58	0.89	71.33
12	39	43.46	8.54	23.38	1.57	0.89	70.64

Bu testlerde, bazı istemcilerin sürüş profilleri sayesinde daha az şarj tükettiği ve dolayısıyla referansa göre daha yüksek SoH değerleri elde ettiği gözlemlenmiştir. Ancak bu istemcilerin hız profilleri referansa daha az benzerlik gösterdiğinden, ağırlıkları düşük kalmış ve global toplama kuralına etkileri sınırlı olmuştur.

Bu testler sonucunda toplama kuralına göre federe öğrenme modeliyle hesaplanan global SoH değeri %89.23 olmuştur. Yaz aylarında sıcaklık koşullarının daha stabil olması, şarj tüketimini daha dengeli hale getirerek bu yüksek SoH sonucunu desteklemiştir.

5.SONUÇ VE ÖNERİLER

Bu tez çalışmasında, elektrikli araçlarda batarya SoC tahmini için hem merkezi hem de FL öğrenme yaklaşımları değerlendirilmiş, farklı veri setleri üzerinde kapsamlı deneysel analizler gerçekleştirilmiştir.

Merkezi öğrenme temelli yaklaşımlarda Transformer tabanlı modelin öne çıktığı görülmüştür. Transformer modeli, özellikle zamansal bağımlılıkları ve doğrusal olmayan yapıları yüksek doğrulukla modelleyebilme yeteneği sayesinde, SoC tahmini görevinde düşük RMSE ve yüksek R^2 skorlarıyla üstün başarı göstermiştir. LSTM, Bi-LSTM gibi klasik RNN mimarileri belirli veri setlerinde rekabetçi sonuçlar sunarken, SVR gibi geleneksel regresyon yöntemleri daha düşük başarımlar sergilemiştir. Bu durum, model seçiminde veri setinin yapısal özellikleri ve uygulama gereksinimlerinin dikkate alınması gerektiğini bir kez daha ortaya koymaktadır. Merkezi öğrenme modelleme yöntemlerinin başarısı, batarya yönetim sistemlerinin daha akıllı, verimli ve güvenilir hale getirilmesi açısından önemli katkılar sağlamaktadır. Bununla birlikte, merkezi öğrenme yaklaşımları büyük veri iletimi sorunu ve bilgi mahremiyeti sağlamada sınırlı kalmaktadır.

Bu sınırlamaların aşılması amacıyla FL tabanlı bir yaklaşım olan FedACM toplama kuralı yöntemi geliştirilmiş ve test edilmiştir. FedACM, istemcilere özgü adaptif momentum toplama kuralı ile farklı veri dağılımlarına sahip katılımcıların güncellemelerini daha dengeli bir şekilde birleştirmeyi başarmıştır. Yapılan deneyler sonucunda, FedACM tüm veri setlerinde en yüksek doğrulukla sonuçlar üretmiş ve RMSE 0.0601, MAE 0.0518, R^2 0.9997 gibi oldukça başarılı metrikler elde etmiştir. Katılımcı sayısındaki artışla birlikte modelin başarımının yükselmesi, yöntemin ölçeklenebilirliğini ve heterojen veri ile başa çıkma becerisini göstermektedir. GRU ve Transformer mimarisi ile birlikte kullanıldığında, FL yaklaşımı merkezi modele göre daha düşük hata oranları ve daha kısa çalışma süresiyle dikkat çekmiştir.

FL yöntemlerinin sağladığı bir diğer önemli avantaj ise veri mahremiyetini korurken iletişim maliyetlerini azaltmasıdır. Batarya verilerinin merkezi sunuculara gönderilmesine

gerek kalmadan, yerel veriler üzerinde model güncellemeleri yapılabilmekte ve bu durum sistemin ağ gecikmelerine karşı daha dayanıklı ve hızlı olmasını sağlamaktadır. Bu bağlamda FL, elektrikli araçlar için daha güvenli, ölçeklenebilir ve enerji verimliliği yüksek bir SoC tahmin altyapısı sunmaktadır.

Ayrıca SoH tahmini yapılarak gerçek araçta karşılaştırmaya dayalı bir tahminleme ile FL yöntemi test edilerek batarya sağlık sistemi de kurgulanmıştır.

Gelecek çalışmalarda, FedACM yaklaşımının gerçek zamanlı sistemlerde uygulanabilirliği artırılacak ve gömülü sistemler gibi kaynak kısıtlı ortamlarda kullanılabilmesi için yöntemler değerlendirilecektir. Burada geliştirilen FL temelli yaklaşımlar batarya içeren ileri robotik ve mekatronik sistemler için de pratik olarak uygulanabilir. Bu alanlarda ihtiyaç olan düşük veri iletimi ve bilgi mahremiyeti gereksinimlerini sağlamaktadır.

Sonuç olarak, bu tezde geliştirilen merkezi ve FL tabanlı SoC tahmin yaklaşımları hem akademik literatüre hem de farklı alanlardaki pratik uygulamalara önemli katkılar sunmaktadır. Transformer mimarisinin sunduğu yüksek modelleme kapasitesi ve FedACM'nin veri gizliliğine duyarlı, ölçeklenebilir yapısı sayesinde, batarya içeren sistemlerde sağlık yönetimini daha etkili kılacak çözümler geliştirilmiştir. Bu çalışma, sürdürülebilir batarya yönetimi sistemlerinin oluşturulmasında önemli bir adım olarak değerlendirilebilir.

KAYNAKLAR DİZİNİ

- Alharbi, T., Umair, M., & Alharbi, A. (2025). Lithium-Ion Battery State of Health Degradation Prediction Using Deep Learning Approaches. *IEEE Access*, 13, 13464-13481. <https://doi.org/10.1109/ACCESS.2025.3530351>
- Allam, A., Onori, S., Marelli, S., & Taborelli, C. (2015). Battery Health Management System for Automotive Applications: A retroactivity-based aging propagation study. *2015 American Control Conference (ACC)*, 703-716. <https://doi.org/10.1109/ACC.2015.7170817>
- Andwari, A. M., Pesiridis, A., Rajoo, S., Martinez-Botas, R., & Esfahanian, V. (2017). A review of Battery Electric Vehicle technology and readiness levels. *Renewable and Sustainable Energy Reviews*, 78, 414-430. <https://doi.org/10.1016/j.rser.2017.03.138>
- Awad, M., & Khanna, R. (2015). Support Vector Regression. İçinde M. Awad & R. Khanna (Ed.), *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers* (ss. 67-80). Apress. https://doi.org/10.1007/978-1-4302-5990-9_4
- Bala, S., Tengnér, T., Rosenfeld, P., & Delince, F. (2012). The effect of low frequency current ripple on the performance of a Lithium Iron Phosphate (LFP) battery energy storage system. *2012 IEEE Energy Conversion Congress and Exposition (ECCE)*, 3485-3492. <https://doi.org/10.1109/ECCE.2012.6342318>
- Beutel, D. J., Topal, T., Mathur, A., Qiu, X., Fernandez-Marques, J., Gao, Y., Sani, L., Li, K. H., Parcollet, T., de Gusmão, P. P. B., & Lane, N. D. (2022). *Flower: A Friendly Federated Learning Research Framework* (arXiv:2007.14390). arXiv. <https://doi.org/10.48550/arXiv.2007.14390>
- Bian, K., & Zheng, H. (2023). FedAvg-DWA: A Novel Algorithm for Enhanced Fraud Detection in Federated Learning Environment. *2023 4th International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE)*, 13-17. <https://doi.org/10.1109/ICBAIE59714.2023.10281317>
- Cao, D., Xiong, J., Lei, N., Sherratt, R. S., & Wang, J. (2024). CSA_FedVeh: Cluster-Based Semi-asynchronous Federated Learning Framework for Internet of Vehicles. İçinde H. Gao, X. Wang, & N. Voros (Ed.), *Collaborative Computing: Networking, Applications and Worksharing* (ss. 79-99). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-54531-3_5

KAYNAKLAR DİZİNİ

- Catenaro, E., & Onori, S. (2021). *Experimental data of three lithium-ion batteries under galvanostatic discharge tests at different C-rates and operating temperatures. 2.* <https://doi.org/10.17632/kxsbr4x3j2.2>
- Chen, Z., Chen, D., Zhang, X., Yuan, Z., & Cheng, X. (2022). Learning Graph Structures With Transformer for Multivariate Time-Series Anomaly Detection in IoT. *IEEE Internet of Things Journal*, 9(12), 9179-9189. IEEE Internet of Things Journal. <https://doi.org/10.1109/JIOT.2021.3100509>
- Chiang, Y.-H., Sean, W.-Y., & Ke, J.-C. (2011). Online estimation of internal resistance and open-circuit voltage of lithium-ion batteries in electric vehicles. *Journal of Power Sources*, 196(8), 3921-3932. <https://doi.org/10.1016/j.jpowsour.2011.01.005>
- Danish, S. M., Hameed, A., Ranjha, A., Srivastava, G., & Zhang, K. (2025). Block-FeDL: Electric Vehicle Charging Load Forecasting Using Federated Learning and Blockchain. *IEEE Transactions on Vehicular Technology*, 74(2), 2048-2056. <https://doi.org/10.1109/TVT.2024.3406946>
- Daowd, M., Antoine, M., Omar, N., Lataire, P., Van Den Bossche, P., & Van Mierlo, J. (2014). Battery Management System—Balancing Modularization Based on a Single Switched Capacitor and Bi-Directional DC/DC Converter with the Auxiliary Battery. *Energies*, 7(5), Article 5. <https://doi.org/10.3390/en7052897>
- Deng, J., Bae, C., Denlinger, A., & Miller, T. (2020). Electric Vehicles Batteries: Requirements and Challenges. *Joule*, 4(3), 511-515. <https://doi.org/10.1016/j.joule.2020.01.013>
- Dong, G., Han, W., & Wang, Y. (2021). Dynamic Bayesian Network-Based Lithium-Ion Battery Health Prognosis for Electric Vehicles. *IEEE Transactions on Industrial Electronics*, 68(11), 10949-10958. IEEE Transactions on Industrial Electronics. <https://doi.org/10.1109/TIE.2020.3034855>
- Guo, J., Li, Y., Pedersen, K., & Stroe, D.-I. (2021). Lithium-Ion Battery Operation, Degradation, and Aging Mechanism in Electric Vehicles: An Overview. *Energies*, 14(17), Article 17. <https://doi.org/10.3390/en14175220>
- Guo, Y., Cai, X., Shen, S., Wang, G., & Zhang, J. (2021). Computational prediction and experimental evaluation of nitrate reduction to ammonia on rhodium. *Journal of Catalysis*, 402, 1-9. <https://doi.org/10.1016/j.jcat.2021.08.016>

KAYNAKLAR DİZİNİ

- Hallak, K., & Kem, O. (2025). Adaptive federated learning framework for predicting EV charging stations occupancy. *International Journal of Transportation Science and Technology*. <https://doi.org/10.1016/j.ijst.2025.04.007>
- Han, Q., & Li, X. (2025). A Vertical Federated Learning Method for Electric Vehicle Charging Station Load Prediction in Coupled Transportation and Power Distribution Systems. *Processes*, 13(2), Article 2. <https://doi.org/10.3390/pr13020468>
- Han, Y., Yan, W., Yin, M., Wang, P., Li, C., Luo, J., Wang, C., & Zhang, X. (2025). *Complete Charging-Curve Prediction and Dynamic Parameter Estimation of Lithium Battery Based on Improved Transformer and Partial Sampling Points* (SSRN Scholarly Paper 5093189). Social Science Research Network. <https://doi.org/10.2139/ssrn.5093189>
- Hannan, M. A., Lipu, M. S. H., Hussain, A., & Mohamed, A. (2017). A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations. *Renewable and Sustainable Energy Reviews*, 78, 834-854. <https://doi.org/10.1016/j.rser.2017.05.001>
- Huang, S.-C., Tseng, K.-H., Liang, J.-W., Chang, C.-L., & Pecht, M. G. (2017). An Online SOC and SOH Estimation Model for Lithium-Ion Batteries. *Energies*, 10(4), Article 4. <https://doi.org/10.3390/en10040512>
- Javed, K., Gouriveau, R., & Zerhouni, N. (2017). State of the art and taxonomy of prognostics approaches, trends of prognostics applications and open issues towards maturity at different technology readiness levels. *Mechanical Systems and Signal Processing*, 94, 214-236. <https://doi.org/10.1016/j.ymssp.2017.01.050>
- Jhunjhunwala, D., Wang, S., & Joshi, G. (2023). *FedExp: Speeding Up Federated Averaging via Extrapolation* (arXiv:2301.09604). arXiv. <https://doi.org/10.48550/arXiv.2301.09604>
- Jiang, E., Zhang, Y. J., & Koyejo, S. (2023, Ekim 13). *Principled Federated Domain Adaptation: Gradient Projection and Auto-Weighting*. The Twelfth International Conference on Learning Representations. <https://openreview.net/forum?id=6J3ehSURMU>
- Kasap, M., Yılmaz, M., Çinar, E., & Yazıcı, A. (2023). Unsupervised dissimilarity-based fault detection method for autonomous mobile robots. *Autonomous Robots*, 47(8), 1503-1518. <https://doi.org/10.1007/s10514-023-10144-2>

KAYNAKLAR DİZİNİ

- Kim, S.-B., & Lee, S.-H. (2024). Application of Deep Learning Techniques for the State of Charge Prediction of Lithium-Ion Batteries. *Applied Sciences*, 14(17), Article 17. <https://doi.org/10.3390/app14178077>
- Kumar, S. S., Prabhakar, P., Bala, S. M., Sri, V. J., Kumar, K., & Vigneshwaran, B. (2024). Optimized Support Vector Regression model for accurate state of charge estimation of Li-Ion Phosphate batteries for Electric Vehicles. *2024 5th International Conference on Circuits, Control, Communication and Computing (I4C)*, 81-86. <https://doi.org/10.1109/I4C62240.2024.10748470>
- Lai, R., Wang, J., Tian, Y., & Tian, J. (2024). FedCBE: A federated-learning-based collaborative battery estimation system with non-IID data. *Applied Energy*, 368, 123534. <https://doi.org/10.1016/j.apenergy.2024.123534>
- Lazzarini, R., Tianfield, H., & Charissis, V. (2023). Federated Learning for IoT Intrusion Detection. *AI*, 4(3), Article 3. <https://doi.org/10.3390/ai4030028>
- Lepikhin, D., Lee, H., Xu, Y., Chen, D., Firat, O., Huang, Y., Krikun, M., Shazeer, N., & Chen, Z. (2020). *GShard: Scaling Giant Models with Conditional Computation and Automatic Sharding* (arXiv:2006.16668). arXiv. <https://doi.org/10.48550/arXiv.2006.16668>
- Li, C., Zhuang, B., Wang, G., Liang, X., Chang, X., & Yang, Y. (2022). *Automated Progressive Learning for Efficient Training of Vision Transformers* (arXiv:2203.14509). arXiv. <https://doi.org/10.48550/arXiv.2203.14509>
- Li, D., Zhang, Z., Liu, P., Wang, Z., & Zhang, L. (2021). Battery Fault Diagnosis for Electric Vehicles Based on Voltage Abnormality by Combining the Long Short-Term Memory Neural Network and the Equivalent Circuit Model. *IEEE Transactions on Power Electronics*, 36(2), 1303-1315. *IEEE Transactions on Power Electronics*. <https://doi.org/10.1109/TPEL.2020.3008194>
- Li, T., Sahu, A. K., Zaheer, M., Sanjabi, M., Talwalkar, A., & Smith, V. (2020). Federated Optimization in Heterogeneous Networks. *Proceedings of Machine Learning and Systems*, 2, 429-450.
- Li, Y., Xie, R., Li, C., Wang, Y., & Dong, Z. (2024). *Federated Graph Learning for EV Charging Demand Forecasting with Personalization Against Cyberattacks* (arXiv:2405.00742). arXiv. <https://doi.org/10.48550/arXiv.2405.00742>

KAYNAKLAR DİZİNİ

- Li, Z. (2018). Lithium-Ion Battery Management System for Electric Vehicles. *International Journal of Performability Engineering*, 14. <https://doi.org/10.23940/ijpe.18.12.p28.31843194>
- Li-ion Battery Aging Datasets* | NASA Open Data Portal. (t.y.). Geliş tarihi 27 Nisan 2023, gönderen <https://data.nasa.gov/dataset/Li-ion-Battery-Aging-Datasets/uj5r-zjdb>
- Liu, J., Yin, Z., Nie, L., & Zhao, X. (2024, Nisan 9). *Federated Learning Enable Training of Perception Model for Autonomous Driving*. WCX SAE World Congress Experience. <https://doi.org/10.4271/2024-01-2873>
- Liu, M. (2021). *Fed-BEV: A Federated Learning Framework for Modelling Energy Consumption of Battery Electric Vehicles* (arXiv:2108.04036). arXiv. <https://doi.org/10.48550/arXiv.2108.04036>
- Liu, M., Ren, S., Ma, S., Jiao, J., Chen, Y., Wang, Z., & Song, W. (2021). *Gated Transformer Networks for Multivariate Time Series Classification* (arXiv:2103.14438). arXiv. <https://doi.org/10.48550/arXiv.2103.14438>
- Lombardi, G., Stighezza, M., De Munari, I., & Bianchi, V. (2024). FPGA Implementation of Support Vector Regression for Battery SoC Estimation. *2024 IEEE International Workshop on Metrology for Automotive (MetroAutomotive)*, 100-105. <https://doi.org/10.1109/MetroAutomotive61329.2024.10615595>
- Marlin, R., Jurdak, R., & Abuadbba, A. (2025a). *H-FLTN: A Privacy-Preserving Hierarchical Framework for Electric Vehicle Spatio-Temporal Charge Prediction* (arXiv:2502.18697). arXiv. <https://doi.org/10.48550/arXiv.2502.18697>
- Marlin, R., Jurdak, R., Abuadbba, A., & Miller, D. (2025b). *Privacy Preserving Charge Location Prediction for Electric Vehicles* (arXiv:2502.00068). arXiv. <https://doi.org/10.48550/arXiv.2502.00068>
- Marongiu, A., Nußbaum, F. G. W., Waag, W., Garmendia, M., & Sauer, D. U. (2016). Comprehensive study of the influence of aging on the hysteresis behavior of a lithium iron phosphate cathode-based lithium ion battery – An experimental investigation of the hysteresis. *Applied Energy*, 171, 629-645. <https://doi.org/10.1016/j.apenergy.2016.02.086>
- McMahan, B., Moore, E., Ramage, D., Hampson, S., & Arcas, B. A. y. (2017). Communication-Efficient Learning of Deep Networks from Decentralized Data. *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics*, 1273-1282. <https://proceedings.mlr.press/v54/mcmahan17a.html>

KAYNAKLAR DİZİNİ

- Nguyen, D. C., Ding, M., Pathirana, P. N., Seneviratne, A., Li, J., & Vincent Poor, H. (2021). Federated Learning for Internet of Things: A Comprehensive Survey. *IEEE Communications Surveys & Tutorials*, 23(3), 1622-1658. IEEE Communications Surveys & Tutorials. <https://doi.org/10.1109/COMST.2021.3075439>
- Park, J.-H., & Joe, I.-W. (2024). Federated Learning-Based Prediction of Energy Consumption from Blockchain-Based Black Box Data for Electric Vehicles. *Applied Sciences*, 14(13), Article 13. <https://doi.org/10.3390/app14135494>
- Piller, S., Perrin, M., & Jossen, A. (2001). Methods for state-of-charge determination and their applications. *Journal of Power Sources*, 96(1), 113-120. [https://doi.org/10.1016/S0378-7753\(01\)00560-2](https://doi.org/10.1016/S0378-7753(01)00560-2)
- Qian, J., Jiang, Y., Liu, X., Wang, Q., Wang, T., Shi, Y., & Chen, W. (2024). Federated Reinforcement Learning for Electric Vehicles Charging Control on Distribution Networks. *IEEE Internet of Things Journal*, 11(3), 5511-5525. IEEE Internet of Things Journal. <https://doi.org/10.1109/JIOT.2023.3306826>
- Qian, K., Zhou, C., Allan, M., & Yuan, Y. (2011). Modeling of Load Demand Due to EV Battery Charging in Distribution Systems. *IEEE Transactions on Power Systems*, 26(2), 802-810. IEEE Transactions on Power Systems. <https://doi.org/10.1109/TPWRS.2010.2057456>
- Qin, Y., Lin, Y., Yi, J., Zhang, J., Han, X., Zhang, Z., Su, Y., Liu, Z., Li, P., Sun, M., & Zhou, J. (2022). *Knowledge Inheritance for Pre-trained Language Models* (arXiv:2105.13880). arXiv. <https://doi.org/10.48550/arXiv.2105.13880>
- Rahal, R., Korba, A. A., & Ghamri-Doudane, Y. (2025). *Fuse and Federate: Enhancing EV Charging Station Security with Multimodal Fusion and Federated Learning* (arXiv:2506.06730). arXiv. <https://doi.org/10.48550/arXiv.2506.06730>
- Rahimi-Eichi, H., Ojha, U., Baronti, F., & Chow, M.-Y. (2013). Battery Management System: An Overview of Its Application in the Smart Grid and Electric Vehicles. *IEEE Industrial Electronics Magazine*, 7(2), 4-16. <https://doi.org/10.1109/MIE.2013.2250351>
- Rani, P., Sharma, C., Ramesh, J. V. N., Verma, S., Sharma, R., Alkhayyat, A., & Kumar, S. (2024). Federated Learning-Based Misbehavior Detection for the 5G-Enabled Internet of Vehicles. *IEEE Transactions on Consumer Electronics*, 70(2), 4656-4664. IEEE Transactions on Consumer Electronics. <https://doi.org/10.1109/TCE.2023.3328020>

KAYNAKLAR DİZİNİ

- Raszmann, E., Baker, K., Shi, Y., & Christensen, D. (2017). Modeling stationary lithium-ion batteries for optimization and predictive control. *2017 IEEE Power and Energy Conference at Illinois (PECI)*, 1-7. <https://doi.org/10.1109/PECI.2017.7935755>
- Rezvani, M., AbuAli PhD, M., Lee, S., Lee, J., & Ni PhD, J. (2011). *A Comparative Analysis of Techniques for Electric Vehicle Battery Prognostics and Health Management (PHM)*. 2011-01-2247. <https://doi.org/10.4271/2011-01-2247>
- Rezvanizani, S. M., Liu, Z., Chen, Y., & Lee, J. (2014). Review and recent advances in battery health monitoring and prognostics technologies for electric vehicle (EV) safety and mobility. *Journal of Power Sources*, 256, 110-124. <https://doi.org/10.1016/j.jpowsour.2014.01.085>
- Rivera-Barrera, J. P., Muñoz-Galeano, N., & Sarmiento-Maldonado, H. O. (2017). SoC Estimation for Lithium-ion Batteries: Review and Future Challenges. *Electronics*, 6(4), Article 4. <https://doi.org/10.3390/electronics6040102>
- Roscher, M. A., & Sauer, D. U. (2011). Dynamic electric behavior and open-circuit-voltage modeling of LiFePO₄-based lithium ion secondary batteries. *Journal of Power Sources*, 196(1), 331-336. <https://doi.org/10.1016/j.jpowsour.2010.06.098>
- Sarmah, S. B., Kalita, P., Garg, A., Niu, X., Zhang, X.-W., Peng, X., & Bhattacharjee, D. (2019). A Review of State of Health Estimation of Energy Storage Systems: Challenges and Possible Solutions for Futuristic Applications of Li-Ion Battery Packs in Electric Vehicles. *Journal of Electrochemical Energy Conversion and Storage*, 16(4). <https://doi.org/10.1115/1.4042987>
- Shi, Y., Xie, H., Wang, X., Lu, X., Wang, J., Xu, X., Wang, D., & Chen, S. (2025). A State-of-Health Estimation Method of a Lithium-Ion Power Battery for Swapping Stations Based on a Transformer Framework. *Batteries*, 11(1), 22. <https://doi.org/10.3390/batteries11010022>
- Shubyn, B., Kostrzewa, D., Grzesik, P., Benecki, P., Maksymyuk, T., Sunderam, V., Syu, J.-H., Lin, J. C.-W., & Mrozek, D. (2023). Federated Learning for improved prediction of failures in Autonomous Guided Vehicles. *Journal of Computational Science*, 68, 101956. <https://doi.org/10.1016/j.jocs.2023.101956>
- Soyoye, B. D., Bhattacharya, I., Anthony Dhasan, M. V., & Banik, T. (2025). State of Charge and State of Health Estimation in Electric Vehicles: Challenges, Approaches and Future Directions. *Batteries*, 11(1), Article 1. <https://doi.org/10.3390/batteries11010032>

KAYNAKLAR DİZİNİ

- Steinstraeter, M. (2020). *Battery and Heating Data in Real Driving Cycles* [Dataset]. IEEE. <https://ieee-dataport.org/open-access/battery-and-heating-data-real-driving-cycles>
- Sun, J., Wu, X., Huang, H., & Zhang, A. (2024). On the Role of Server Momentum in Federated Learning. *Proceedings of the AAAI Conference on Artificial Intelligence*, 38(13), Article 13. <https://doi.org/10.1609/aaai.v38i13.29439>
- Sun, Z., Lv, W., Wang, Z., Zheng, X., Cao, H., & Yi, Z. (2020). Processes and Technologies for the Recycling and Recovery of Spent Lithium Ion Batteries. *İçinde Rechargeable Lithium-Ion Batteries*. CRC Press.
- Thingvad, A., Calearo, L., Andersen, P. B., & Marinelli, M. (2021). Empirical Capacity Measurements of Electric Vehicles Subject to Battery Degradation From V2G Services. *IEEE Transactions on Vehicular Technology*, 70(8), 7547-7557. <https://doi.org/10.1109/TVT.2021.3093161>
- Tingting, D., Jun, L., Fuquan, Z., Yi, Y., & Qiqian, J. (2011). Analysis on the influence of measurement error on state of charge estimation of LiFePO4 power Battery. *2011 International Conference on Materials for Renewable Energy & Environment*, 1, 644-649. <https://doi.org/10.1109/ICMREE.2011.5930893>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2023). *Attention Is All You Need* (arXiv:1706.03762). arXiv. <https://doi.org/10.48550/arXiv.1706.03762>
- Wang, J., Das, R., Joshi, G., Kale, S., Xu, Z., & Zhang, T. (2022). *On the Unreasonable Effectiveness of Federated Averaging with Heterogeneous Data* (arXiv:2206.04723). arXiv. <https://doi.org/10.48550/arXiv.2206.04723>
- Wang, P., Panda, R., Hennigen, L. T., Greengard, P., Karlinsky, L., Feris, R., Cox, D. D., Wang, Z., & Kim, Y. (2023). *Learning to Grow Pretrained Models for Efficient Transformer Training* (arXiv:2303.00980). arXiv. <https://doi.org/10.48550/arXiv.2303.00980>
- Wang, X., Pi, D., Zhang, X., Liu, H., & Guo, C. (2022). Variational transformer-based anomaly detection approach for multivariate time series. *Measurement*, 191, 110791. <https://doi.org/10.1016/j.measurement.2022.110791>
- Wen, Q., Zhou, T., Zhang, C., Chen, W., Ma, Z., Yan, J., & Sun, L. (2023). Transformers in time series: A survey. *Proceedings of the Thirty-Second International Joint*

KAYNAKLAR DİZİNİ

- Conference on Artificial Intelligence*, 6778-6786.
<https://doi.org/10.24963/ijcai.2023/759>
- Wu, C., Fan, H., Wang, K., & Zhang, P. (2024). Enhancing Federated Learning in Heterogeneous Internet of Vehicles: A Collaborative Training Approach. *Electronics*, 13(20), Article 20. <https://doi.org/10.3390/electronics13203999>
- Wu, H., Xu, J., Wang, J., & Long, M. (2022). *Autoformer: Decomposition Transformers with Auto-Correlation for Long-Term Series Forecasting* (arXiv:2106.13008). arXiv. <https://doi.org/10.48550/arXiv.2106.13008>
- Wu, J., Cui, X., Zhang, H., & Lin, M. (2021). Health Prognosis With Optimized Feature Selection for Lithium-Ion Battery in Electric Vehicle Applications. *IEEE Transactions on Power Electronics*, 36(11), 12646-12655. *IEEE Transactions on Power Electronics*. <https://doi.org/10.1109/TPEL.2021.3075558>
- Wu, J., Zhang, C., & Chen, Z. (2016). An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks. *Applied Energy*, 173, 134-140. <https://doi.org/10.1016/j.apenergy.2016.04.057>
- Wu, N., Green, B., Ben, X., & O'Banion, S. (2020). *Deep Transformer Models for Time Series Forecasting: The Influenza Prevalence Case* (arXiv:2001.08317). arXiv. <https://doi.org/10.48550/arXiv.2001.08317>
- Wu, Y., Bai, D., Zhang, K., Li, Y., & Yang, F. (2025). Advancements in the estimation of the state of charge of lithium-ion battery: A comprehensive review of traditional and deep learning approaches. *Journal of Materials Informatics*, 5(2), N/A-N/A. <https://doi.org/10.20517/jmi.2024.84>
- Yayan, U., Arslan, A. T., & Yucel, H. (2021). A Novel Method for SoH Prediction of Batteries Based on Stacked LSTM with Quick Charge Data. *Applied Artificial Intelligence*, 35(6), 421-439. <https://doi.org/10.1080/08839514.2021.1901033>
- Yılmaz, M., Çınar, E., & Yazıcı, A. (2024). Elektrikli Araçlarda Otonom Batarya Yönetim Sistemi Literatür İncelemesi. *EMO Bilimsel Dergi*, 14(2), Article 2.
- Yılmaz, M., Çınar, E., & Yazıcı, A. (2025a). A Transformer-Based Model for State of Charge Estimation of Electric Vehicle Batteries. *IEEE Access*, 13, 33035-33048. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2025.3542961>

KAYNAKLAR DİZİNİ

- Yılmaz, M., Çınar, E., & Yazıcı, A. (2025b). Federated Learning-Based State of Charge Estimation in Electric Vehicles Using Federated Adaptive Client Momentum. *IEEE Access*, 13, 72128-72141. <https://doi.org/10.1109/ACCESS.2025.3563188>
- You, Y., Li, J., Reddi, S., Hseu, J., Kumar, S., Bhojanapalli, S., Song, X., Demmel, J., Keutzer, K., & Hsieh, C.-J. (2019, Eylül 23). *Large Batch Optimization for Deep Learning: Training BERT in 76 minutes*. International Conference on Learning Representations. <https://openreview.net/forum?id=Syx4wnEtvH>
- Youssef, M. B., Jarraya, I., Zdiri, M. A., & Salem, F. B. (2024). Support vector regression-based state of charge estimation for batteries: Cloud vs non-cloud. *Indonesian Journal of Electrical Engineering and Computer Science*, 34(2), 697-710. <https://doi.org/10.11591/ijeecs.v34.i2.pp697-710>
- Yu, B., Qiu, H., Weng, L., Huo, K., Liu, S., & Liu, H. (2020). A Health Indicator for the Online Lifetime Estimation of an Electric Vehicle Power Li-Ion Battery. *World Electric Vehicle Journal*, 11(3), Article 3. <https://doi.org/10.3390/wevj11030059>
- Zhang, H., Xia, Y., Yan, T., & Liu, G. (2021). Unsupervised Anomaly Detection in Multivariate Time Series through Transformer-based Variational Autoencoder. *2021 33rd Chinese Control and Decision Conference (CCDC)*, 281-286. <https://doi.org/10.1109/CCDC52312.2021.9601669>
- Zhou, T., Ma, Z., Wen, Q., Wang, X., Sun, L., & Jin, R. (2022). FEDformer: Frequency Enhanced Decomposed Transformer for Long-term Series Forecasting. *Proceedings of the 39th International Conference on Machine Learning*, 27268-27286. <https://proceedings.mlr.press/v162/zhou22g.html>