

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**ELEKTRİKLİ ARAÇLARDA KULLANILMAK ÜZERE LİTYUM DEMİR
FOSFAT BATARYALARIN MODELLENMESİ VE ŞARJ DURUM TAHMİNİ**

YÜKSEK LİSANS TEZİ

Halil AYDIN

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Programı

OCAK 2026

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**ELEKTRİKLİ ARAÇLARDA KULLANILMAK ÜZERE LİTYUM DEMİR
FOSFAT BATARYALARIN MODELLENMESİ VE ŞARJ DURUM TAHMİNİ**

YÜKSEK LİSANS TEZİ

**Halil AYDIN
(518221023)**

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Fikret ÇALIŞKAN

OCAK 2026

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**MODELING AND STATE OF CHARGE ESTIMATION OF LITHIUM IRON
PHOSPHATE BATTERIES FOR USE IN ELECTRIC VEHICLES**

M.Sc. THESIS

**Halil AYDIN
(518221023)**

Department of Mechatronics Engineering

Mechatronics Engineering Programme

Thesis Advisor: Prof. Dr. Fikret ÇALIŞKAN

JANUARY 2026

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 518221023 numaralı Yüksek Lisans Öğrencisi Halil AYDIN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “ELEKTRİKLİ ARAÇLARDA KULLANILMAK ÜZERE LİTYUM DEMİR FOSFAT BATARYALARIN MODELLENMESİ VE ŞARJ DURUM TAHMİNİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Fikret ÇALIŞKAN**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Murat YILMAZ**
İstanbul Teknik Üniversitesi

Doç. Dr. Vahit Barış TAVAKOL
Kadir Has Üniversitesi

Teslim Tarihi : **02 Ocak 2026**
Savunma Tarihi : **20 Ocak 2026**





Canım Aileme,



ÖNSÖZ

Yüksek lisans eğitimim boyunca bana ışık tutan, engin bilgi birikimi ve tecrübelerini cömertçe paylaşarak hem bilimsel hem de insani yönden bana rehberlik eden çok değerli danışmanım Prof. Dr. Fikret ÇALIŞKAN'a en içten teşekkürlerimi sunarım.

Bugünlere gelmemde en büyük paya sahip olan canım aileme sonsuz sevgi ve teşekkürlerimi sunarım.

Ocak 2026

Halil AYDIN
(Mühendis)



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SEMBOLLER	xv
ÇİZELGE LİSTESİ.....	xvii
ŞEKİL LİSTESİ.....	xix
ÖZET.....	xxi
SUMMARY	xxiii
1. GİRİŞ.....	1
1.1 Tezin Amacı	3
1.2 Literatür Araştırması	4
2. BATARYA TEKNOLOJİLERİ	9
2.1 Batarya Türleri	9
2.1.1 Kurşun asit bataryalar (Lead acid)	10
2.1.2 Nikel kadmiyum bataryalar (Ni – Cd)	10
2.1.3 Nikel metal hidrat bataryalar (Ni – MH)	11
2.1.4 Lityum iyon bataryalar (Li-ion)	12
2.2 Lityum İyon Bataryaların Çalışma Prensibi.....	16
2.2.1 Lityum kobalt oksit (LiCoO_2 – LCO)	17
2.2.2 Lityum mangan oksit (LiMn_2O_4 – LMO).....	17
2.2.3 Lityum nikel mangan kobalt oksit (LiNiMnCoO_2 – NMC)	18
2.2.4 Lityum nikel kobalt alüminyum oksit (LiNiCoAlO_2 – NCA)	18
2.2.5 Lityum titanat oksit (Li_2TiO_3 – LTO)	18
2.2.6 Lityum demir fosfat (LiFePO_4 – LFP)	19
2.3 Batarya Teknolojisinin Geleceği.....	20
3. ŞARJ DURUMU TAHMİN YÖNTEMLERİ.....	23
3.1 Batarya Yönetim Sistemleri (BYS).....	23
3.2 Şarj Durumunun Tanımı.....	24
3.2.1 Doğrudan BŞD ölçüm yöntemleri.....	25
3.2.2 Dolaylı ölçüm yöntemleri	28
3.3 Çalışmada Kullanılan Şarj Durum Tahmin Yöntemleri.....	30
3.3.1 Genişletilmiş kalman filtresi (GKF)	30
3.3.2 Uzun kısa süreli bellek yöntemi (LSTM)	32
4. BATARYA HÜCRE MODELLEMESİ.....	35
4.1 Elektrokimyasal Devre Modeli	35
4.2 Veri Odaklı Modeller	36
4.3 Elektriksel Eşdeğer Devre Modelleri	37
4.3.1 Rint modeli.....	37
4.3.2 Thevenin modeli	38
4.3.3 Çift polarizasyon modeli (DP)	39

4.4 Batarya Model Parametrelerinin Bulunması	42
4.4.1 ADG-BŞD karakterizasyonu	43
4.4.2 Hibrid güç darbe karakterizasyon testi (HPPC)	44
4.4.3 Unutma faktörü yinelemeli en küçük kareler metodu (FFRLS)	45
5. ŞARJ DURUM TAHMİNİ SİMÜLASYON SONUÇLARI	53
5.1 Genişletilmiş Kalman Filtresi ile Şarj Durum Tahmini	53
5.2 LSTM Algoritması ile Şarj Durum Tahmininin İyileştirilmesi	58
6. SONUÇ VE ÖNERİLER	63
KAYNAKLAR	65
ÖZGEÇMİŞ	71



KISALTMALAR

ADG	: Açık Devre Gerilimi
AR-GE	: Araştırma-Geliştirme
BŞD	: Batarya Şarj Durumu
BYS	: Batarya Yönetim Sistemi
DL	: Deep Learning
DP	: Dual Polarizasyon
DST	: Dynamic Stress Test
EA	: Elektrikli Araçlar
ECM	: Equivalent Circuit Model
FFRLS	: Forgetting Factor Recursive Least Squares Method
FL	: Fuzzy Logic
FUDS	: Federal Urban Driving Schedule
GKF	: Genişletilmiş Kalman Filtresi
HEV	: Hybrid Electric Vehicle
HPPC	: Hybrid Power Pulse Characterization
LCO	: Lityum Kobalt Oksit
LFP	: Lityum Demir Fosfat
Li-ion	: Lityum İyon
LMO	: Lityum Manganez Oksit
LSTM	: Long Short Term Memory
LTO	: Lityum Titanat Oksit
NMA	: Nikel Manganez Kobalt Alüminyum Oksit
NMC	: Nikel Manganez Kobalt Oksit
Ni-Cd	: Nikel Kadmiyum
Ni-MH	: Nikel Metal Hibrit
NN	: Neural Networks
P2D	: Pseudo-2D
RLS	: Recursive Least Squares Method
RMSE	: Root Mean Square Error
RNN	: Recurrent Neural Network

SOC : State Of Charge
SVM : Support Vector Machine
UPS : Uninterruptible Power Supply
US06 : Highway Driving Schedule



SEMBOLLER

$SOC(t)$	: t zamanında bataryanın doluluk oranı
$SOC(t_0)$	: Başlangıç anında bataryanın doluluk oranı
η	: Coulomb verimi
I	: Birim matris
x_k	: Durum vektörü
z_k	: Ölçüm vektörü
u_k	: Giriş vektörü
w_k, v_k	: Süreç ve ölçüm gürültüleri
f, g	: Sırasıyla süreç ve ölçüm fonksiyonları
F_k	: Süreç fonksiyonundan türetilen Jacobian matrisi
H_k	: Ölçüm fonksiyonundan türetilen Jacobian matrisi
Q_k	: Süreç kovaryans matrisi
R_k	: Ölçüm kovaryans matrisi
K_k	: Kalman kazancı
P_k	: Kalman hata kovaryans matrisi
f_t	: LSTM – Unutma kapısı
σ	: Sigmoid
i_t	: LSTM – Giriş kapısı
o_t	: LSTM – Çıkış kapısı
R_1, R_2	: Eşdeğer devre modelindeki direnç değerleri
C_1, C_2	: Eşdeğer devre modelindeki kapasitans değerleri
$U_T(t)$	: t anında terminal gerilimi
$U_{ocv}(t)$	: t anında açık devre gerilimi
$I_L(t)$	: t anında devreden geçen yük akımı
τ_1, τ_2	: Zaman sabitleri
k	: Ayrık zaman indeksi
$\hat{\theta}(k)$	: FFRLS durum vektörü
$K(k)$	: FFRLS uyarlamalı kazanç vektörü
λ	: Unutma faktörü

P(k)	: FFRLS hata kovaryans matrisi
$\Phi(k)$	: Regresyon vektörü
A_k	: Durum geiş matrisi
B_k	: Giriş kontrol matrisi
C_k	: Ölçüm çıkış matrisi
D_k	: Doğrudan geiş matrisi
SOC_{EKF}	: GKF'nin SOC tahmin çıktısı
V_{Residual}	: Terminal gerilim rezidualı
T	: Sıcaklık
U	: Gerilim
X_{Train}	: LSTM'in eğitim vektörü



ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : Batarya türlerinin karşılaştırılması.	15
Çizelge 3.1 : Batarya modelleme yöntemlerinin karşılaştırılması.	29
Çizelge 4.1 : Çalışmada kullanılan batarya özellikleri.	43
Çizelge 4.2 : Her sıcaklıkta belirli ADG değerlerine karşılık gelen BŞD değerleri..	44
Çizelge 4.3 : Belirli BŞD değerlerinde 25°C için kestirilen model parametreleri.....	52
Çizelge 4.4 : Belirli BŞD değerlerinde 5°C için kestirilen model parametreleri.....	52
Çizelge 6.1 : US06 25°C Testleri İçin Tahmin Yöntemlerinin Karşılaştırılması	64



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Farklı Batarya Türlerinin Enerji Yoğunluğu Karşılaştırması.....	9
Şekil 2.2 : 12 V – 5 Ah Kurşun Asit Batarya	10
Şekil 2.3 : Nikel Kadmiyum Batarya.....	11
Şekil 2.4 : Toyota Highlander aracında kullanılan Ni-MH batarya	12
Şekil 2.5 : Isıl sürüklenme gerçekleşmiş bir cep telefonu bataryası.....	13
Şekil 2.6 : Geliştirilen Li-ion Bataryalarının Şematik Gösterimi.....	14
Şekil 2.7 : Li-ion batarya geometrisi	15
Şekil 2.8 : Lityum-iyon bataryaların çalışma prensibi: (a) Deşarj; (b) Şarj	16
Şekil 2.9 : Li-ion bataryaların birbirleriyle karşılaştırılması	19
Şekil 3.1 : Batarya şarj durumu tahmin yöntemleri	25
Şekil 3.2 : NMC tipi batarya için ADG-BŞD eğrisi örneği.....	27
Şekil 3.3 : LFP tipi batarya için ADG-BŞD eğrisi örneği.	27
Şekil 3.4 : Genişletilmiş kalman filtresi (GKF) algoritması.....	30
Şekil 3.5 : LSTM hücresi.....	33
Şekil 4.1 : Pseudo-2D modeli	36
Şekil 4.2 : Kara kutu model oluşturma süreci.....	36
Şekil 4.3 : Rint modeli.....	38
Şekil 4.4 : Thevenin modeli.....	38
Şekil 4.5 : Çift Polarizasyon (DP) modeli	39
Şekil 4.6 : ADG – BŞD eğrisi.....	44
Şekil 4.7 : 25°C için HPPC test profili	45
Şekil 4.8 : FFRLS algoritma akış diyagramı	46
Şekil 4.9 : 25°C için DST akım profili	49
Şekil 4.10 : 25°C’de HPPC-DST-RLS algoritmasının terminal gerilim kestirimi	51
Şekil 5.1 : US06 akım profili 25°C.....	54
Şekil 5.2 : US06 gerilim profili 25°C	54
Şekil 5.3 : 25°C - Batarya şarj durumu tahmin sonuçları.	55
Şekil 5.4 : 25°C - Batarya şarj durumu hata yüzdesi	56
Şekil 5.5 : 25°C - Terminal Gerilimlerin Karşılaştırılması.....	56
Şekil 5.6 : 5°C - Batarya şarj durumu tahmin sonuçları	57
Şekil 5.7 : FUDS 25°C - Batarya şarj durumu tahmin sonuçları.....	57
Şekil 5.8 : 25°C - US06 sürüş verisinin LSTM ile şarj durum tahmini	59
Şekil 5.9 : US06 için Residual GKF-LSTM şarj durum tahmini karşılaştırması	60
Şekil 5.10 : Eğitim süreci	60
Şekil 5.11 : FUDS için Residual GKF-LSTM şarj durum tahmini karşılaştırması ...	61



ELEKTRİKLİ ARAÇLARDA KULLANILMAK ÜZERE LİTYUM DEMİR FOSFAT BATARYALARIN MODELLENMESİ ve ŞARJ DURUM TAHMİNİ

ÖZET

Elektrikli araçlar, geçmişte sınırlı menzil ve yetersiz batarya teknolojileri nedeniyle yaygınlaşmamış olsa da, günümüzde artan enerji ihtiyacı ve çevresel kaygılar doğrultusunda ulaşım sektöründe yeniden ön plana çıkmıştır. Batarya teknolojilerindeki gelişmeler, elektrikli araçların menzil, güvenlik ve verimlilik açısından kabul görmesini sağlamıştır. Bu bağlamda lityum-iyon bataryalar, yüksek enerji yoğunluğu ve uzun çevrim ömrü gibi avantajları sayesinde elektrikli araçlarda en yaygın kullanılan enerji depolama elemanları haline gelmiştir. Elektrikli araç uygulamalarında, seri ve paralel bağlanan batarya hücrelerinden oluşan batarya paketlerinin güvenli ve verimli çalışması Batarya Yönetim Sistemleri (BYS) tarafından sağlanmaktadır.

BYS'nin en kritik görevlerinden biri bataryanın şarj durumu (BŞD) bilgisinin doğru şekilde belirlenmesidir. BŞD, bataryada mevcut kullanılabilir enerji miktarını ifade eder ve araç menzilin tahmini ile bataryanın aşırı şarj ve aşırı deşarjdan korunması açısından hayati öneme sahiptir. Ancak BŞD doğrudan ölçülebilen bir büyüklük değildir ve bataryanın içindeki karmaşık elektrokimyasal süreçler ile sıcaklık gibi değişkenlerden etkilenmektedir. Bu nedenle BŞD, gerilim, akım ve sıcaklık gibi ölçülebilen büyüklükler kullanılarak geliştirilen kestirim algoritmaları ile dolaylı olarak tahmin edilmektedir.

Bu tez çalışmasında, batarya şarj durumu kestirimi problemi ele alınmış ve lityum-iyon bataryalar arasından lityum demir fosfat (LFP) batarya kimyası seçilmiştir. LFP bataryaların açık devre gerilimi (ADG) ile BŞD arasındaki ilişkinin geniş bir şarj aralığında oldukça düz bir karakteristik sergilemesi, BŞD kestirimini zorlaştırmakta ve bu bataryaları kestirim algoritmalarının performansını değerlendirmek için zorlu bir test platformu haline getirmektedir.

Çalışmada bataryanın dinamik davranışını temsil etmek amacıyla çift polarizasyon (DP) eşdeğer devre modeli kullanılmıştır. Model parametrelerinin çalışma koşullarına bağlı olarak değişmesi nedeniyle, parametre kestirimi çevrim içi olarak gerçekleştirilmiştir. Bu amaçla Unutma Faktörü Yinelemeli En Küçük Kareler (FFRLS) algoritması kullanılmıştır. FFRLS algoritmasının sağlıklı çalışabilmesi için öncelikle Hibrit Güç Darbe Karakterizasyonu (HPPC) testi uygulanmış ve elde edilen parametreler algoritma için kararlı başlangıç değerleri olarak kullanılmıştır. Gerçek sürüş koşullarını temsil edebilmek amacıyla, FFRLS algoritması Dinamik Stres Testi (DST) verileri üzerinde çevrim içi olarak çalıştırılmış ve batarya parametrelerinin şarj durumu ve sıcaklığa bağlı değişimi izlenmiştir.

Bataryanın açık devre gerilimi ile BŞD arasındaki ilişki, düşük akımlı testler yardımıyla elde edilmiş ve polinom yaklaştırma yöntemiyle modellenmiştir. Elde edilen batarya modeli ve ADG-BŞD ilişkisi kullanılarak ayrı zamanlı durum uzay modeli oluşturulmuş ve Genişletilmiş Kalman Filtresi (GKF) tabanlı bir BŞD kestirim

algoritması geliştirilmiştir. GKF, BŞD ve iç polarizasyon gerilimlerini çevrim içi olarak tahmin etmekte ve terminal gerilim ölçümleri ile kestirimlerini güncellemektedir. US06 (Highway Driving Schedule) sürüş çevrimi altında gerçekleştirilen testler, GKF'nin orta BŞD aralığında başarılı sonuçlar verdiğini, ancak düşük BŞD ve deşarj sonu bölgelerinde hata artışı yaşandığını göstermiştir.

Bu sınırlamaları gidermek amacıyla, çalışmanın son aşamasında GKF çıktıları veri güdümlü bir yöntemle desteklenmiştir. GKF tabanlı BŞD kestirimi ve terminal gerilim artık hatası, Uzun Kısa Süreli Bellek (LSTM) ağı kullanılarak düzeltilmiştir. Geliştirilen hibrit GKF–LSTM yapısı, GKF'nin modelleme ve lineerleştirme kaynaklı hatalarını öğrenerek BŞD kestirim doğruluğunu artırmıştır. Elde edilen sonuçlar, önerilen hibrit yaklaşımın yalnızca GKF kullanan yöntemle kıyasla daha yüksek doğruluk sağladığını ortaya koymuştur.

Sonuç olarak bu tez çalışması, batarya modelleme, çevrim içi parametre kestirimi ve şarj durumu kestirimi problemlerini bütüncül bir yaklaşımla ele almış; FFRLS, GKF ve LSTM tabanlı yöntemleri birleştirerek gerçek sürüş koşullarına yönelik uygulamalar için geliştirilmeye açık bir temel sunmaktadır.

MODELING AND STATE OF CHARGE ESTIMATION OF LITHIUM IRON PHOSPHATE BATTERIES FOR USE IN ELECTRIC VEHICLES

SUMMARY

Electric vehicles, which are among the most prominent topics of today, are not in fact a recent technology. Electric vehicles were widely used over a century ago; however, due to their limited driving range, underdeveloped battery technology, safety concerns, and high costs, they were unable to compete with conventional internal combustion engine vehicles. Nevertheless, the depletion of fossil fuel reserves, increasing energy demand, global warming, and air pollution have driven the transportation sector toward sustainable and environmentally friendly alternatives. With the advancement of battery technologies, interest in electric vehicles has increased significantly, leading to their growing acceptance in the transportation sector.

The selection of batteries, which serve as the primary power source for electric vehicles, is of critical importance in terms of system performance, cost, lifespan, and safety. Over the past century, various battery technologies have been developed, each exhibiting distinct advantages and limitations. Among these technologies, lithium-ion batteries have emerged as the most widely adopted option in electric vehicle applications due to their superior performance characteristics. Lithium-ion batteries offer advantages such as high energy density, low self-discharge rate, lightweight structure, and long cycle life, effectively meeting the range and efficiency requirements of electric vehicles.

In applications such as electric vehicles, which require relatively high voltage and power levels, lithium-ion battery cells are connected in series and/or parallel configurations to form battery packs. The systems responsible for ensuring the safe, efficient, and balanced operation of these battery packs are referred to as Battery Management Systems (BMS). One of the most critical functions of a BMS is to provide accurate and reliable information regarding the battery state of charge (SOC). This enables precise driving range estimation and protects the battery from safety-critical operating conditions such as overcharging and over-discharging. However, accurately estimating the SOC is challenging due to the complex electrochemical reactions occurring within the battery.

The state of charge represents the amount of usable energy available in the battery and quantitatively indicates the level of charge. However, SOC is not a directly measurable physical quantity and is influenced by complex electrochemical processes within the battery. Furthermore, variations in load current, ambient temperature, and operating conditions cause the SOC to change dynamically. Therefore, SOC estimation is performed indirectly using estimation methods based on measurable variables such as voltage, current, and temperature.

This study focuses on the problem of battery state of charge estimation. First, lithium-ion batteries were examined, and lithium iron phosphate (LFP) batteries were selected for this work. The relatively flat characteristic of the open-circuit voltage (OCV)–SOC relationship over a wide SOC range in LFP batteries makes SOC estimation particularly challenging. This characteristic renders LFP batteries a demanding and representative test platform for evaluating the performance of SOC estimation algorithms. For these reasons, LFP battery chemistry was chosen to demonstrate the effectiveness of the proposed methods within the scope of this thesis.

Various SOC estimation methods have been investigated in the literature. Numerous approaches have been proposed, including Coulomb counting, open-circuit voltage (OCV)-based methods, Kalman filter-based techniques, and artificial intelligence-based algorithms. Although Coulomb counting is computationally simple and efficient, it suffers from cumulative errors over long-term operation due to sensor offsets and uncertainties in the initial SOC. OCV-based methods are limited in real driving conditions, as they require the battery to be in a resting state. Model-based methods, particularly the Extended Kalman Filter (EKF), are widely used for online SOC estimation due to their structured model-based framework. However, since EKF relies on local linearization of nonlinear systems, its performance degrades in operating regions where the battery exhibits strong nonlinear behavior.

To overcome these limitations, this thesis proposes a hybrid SOC estimation approach that combines physics-based modeling, online parameter estimation, and data-driven learning techniques. The primary motivation of this study is to integrate the generalization and interpretability advantages of physical models with the capability of data-driven methods to learn complex nonlinear relationships.

In the first stage of the study, a second-order equivalent circuit model with dual RC networks was employed to represent the dynamic behavior of lithium-ion batteries. This model is widely adopted in automotive applications due to its ability to capture ohmic resistance and polarization effects occurring at different time scales. Since accurate parameter identification directly affects SOC estimation performance, the parameter estimation problem was investigated in detail.

Online estimation of battery model parameters was performed using the Forgetting Factor Recursive Least Squares (FFRLS) algorithm. To ensure sufficient excitation of the system for reliable parameter estimation, the Hybrid Pulse Power Characterization (HPPC) test was initially conducted. The HPPC test provides high observability of the battery's ohmic resistance and RC network parameters due to its current pulse and rest period structure. The parameters obtained from the HPPC tests served as physically meaningful and stable initial values for the FFRLS algorithm.

However, HPPC tests are conducted under controlled and idealized conditions and therefore provide limited representation of real driving scenarios. For this reason, Dynamic Stress Test (DST) profiles were employed in this study. Using the initial parameters obtained from HPPC tests, the FFRLS algorithm was executed online with DST data, enabling the observation of parameter variations with respect to SOC and temperature. This approach improved parameter estimation performance by ensuring both rapid convergence and numerical stability.

Low-current OCV–SOC tests were conducted to determine the relationship between open-circuit voltage and SOC. The obtained OCV–SOC data points were modeled using polynomial approximation in the MATLAB environment. Considering the wide voltage plateau of LFP batteries, moderate-to-high polynomial degrees were selected to balance modeling accuracy and numerical stability.

Based on the identified battery model and OCV–SOC relationship, a discrete-time state-space model was formulated for SOC estimation, and an Extended Kalman Filter-based estimation structure was developed. The EKF estimates SOC and internal polarization voltages online and updates its predictions using terminal voltage measurements. To evaluate the performance of the developed battery model and SOC estimation algorithms, the US06 (Highway Driving Schedule) driving cycle was selected. The US06 cycle realistically represents dynamic operating conditions with aggressive acceleration, high current demands, and irregular load variations. Test results under the US06 cycle indicated that the EKF provides high accuracy in the mid-SOC range but experiences increased estimation errors at low SOC and end-of-discharge regions due to nonlinearities. This behavior highlights the structural limitations of EKF, particularly in regions where the OCV–SOC curve of LFP batteries becomes steep.

To address these limitations, a hybrid data-driven approach was developed in the final stage of the study by combining EKF outputs with measurement data. In this framework, the EKF-based SOC estimates and terminal voltage residuals were corrected using a Long Short-Term Memory (LSTM) neural network. In the proposed residual EKF–LSTM structure, measured voltage, current, temperature, EKF-estimated SOC, and EKF voltage residuals were used as inputs to the LSTM network. The LSTM model aims to learn and compensate for the modeling and linearization errors of the EKF, thereby correcting the residual SOC estimation errors online.

The results demonstrate that the proposed hybrid EKF–LSTM approach significantly improves SOC estimation accuracy compared to the EKF-only method. This improvement indicates that combining data-driven techniques with physics-based models enables more effective capture of the nonlinear and temperature-dependent behavior of batteries. In conclusion, this thesis presents a comprehensive framework for battery modeling, online parameter estimation, and SOC estimation, offering a practical and high-accuracy hybrid solution for advanced battery management systems operating under real driving conditions.



1. GİRİŞ

Küresel ölçekte artan enerji talebi fosil yakıt rezervlerinin azalması ve çevresel etkiler, ulaşım sektöründe sürdürülebilir ve çevre dostu çözümlere olan ihtiyacı her geçen gün artırmaktadır. Bu doğrultuda elektrikli araçlar (EA), düşük karbon emisyonları ve yüksek enerji verimlilikleri sayesinde içten yanmalı motorlu araçlara güçlü bir alternatif olarak öne çıkmaktadır. Günümüzde elektrikli araç gelişiminin önündeki başlıca teknolojik engel, yüksek güç kapasitesini düşük üretim maliyetiyle birleştiren batarya sistemlerinin elde edilmesidir. Elektrikli araç bataryaları, yüksek güç ve enerji yoğunluklarını, hızlı şarj-deşarj yetenekleri ve uzun çevrim ömrü ile birleştirmelidir. Bu bağlamda, batarya teknolojisindeki farklı araştırma ve geliştirme çabaları sonucunda çeşitli batarya kimyaları elde edilmiştir. Elektrikli araçlarda en yaygın kullanılan enerji depolama elemanları lityum-iyon tabanlı bataryalardır. Yüksek özgül enerji, uzun çevrim ömrü ve düşük kendi kendinedeşarj oranı gibi avantajları sayesinde lityum-iyon bataryalar, farklı batarya kimyaları arasında önemli bir yer edinmiştir [1]. Elektrikli araçların performansı, güvenliği ve menzil kabiliyeti ise büyük ölçüde kullanılan batarya teknolojisine ve bu bataryaların etkin bir şekilde yönetilmesine bağlıdır [2].

Bataryaların güvenli, verimli ve uzun ömürlü bir şekilde çalışmasını sağlamak amacıyla Batarya Yönetim Sistemleri (BYS) kullanılmaktadır. BYS; batarya gerilimi, akımı ve sıcaklığı gibi ölçülebilir parametreleri izleyerek bataryanın çalışma durumunu değerlendiren ve kontrol eden bir sistemdir. BYS'nin temel görevleri arasında aşırı şarj vedeşarjın önlenmesi, hücre dengeleme işlemleri ve batarya durum değişkenlerinin kestirimi yer almaktadır. Bu durum değişkenleri arasında bataryanın şarj durumu, bataryada mevcut olan kullanılabilir enerjinin bir göstergesi olması nedeniyle en kritik parametrelerden biri olarak kabul edilmektedir [3].

Bataryanın şarj durumu, anlık mevcut kapasitesinin tam depolama kapasitesine oranını nicel olarak ifade eder ve belirli bir zamandaki kalan enerji seviyesinin bir göstergesi olarak hizmet eder [4]. Bataryanındeşarj oranı, ortam sıcaklığı ve bataryanın kullanım süresi gibi birçok parametreden dolayı bataryanın şarj durumunu tahmin etmek bir

hayli zordur. Bataryanın sahip olduđu elektro-kimyasal yapıdan dolayı batarya doğrusal olmayan bir karakteristik gösterdiği için anlık olarak gözlemlemek de zordur. Doğru BŞD kestirimi, elektrikli araçların sürüş menzilini ve performansını doğrudan etkilediği için hayati önem taşır. Ancak BŞD doğrudan ölçülemez ve akım, voltaj ve sıcaklık gibi ölçülebilir değişkenler kullanılarak dolaylı yoldan kestirilmelidir [5].

Lityum-iyon batarya ailesi içerisinde yer alan Lityum Demir Fosfat (LiFePO_4 – LFP) bataryalar ise yüksek termal kararlılıkları, uzun çevrim ömürleri ve güvenlik avantajları nedeniyle özellikle elektrikli araçlar ve enerji depolama sistemlerinde tercih edilmektedir [6]. LFP bataryaların açık devre gerilimi ile şarj durumu arasındaki ilişkinin geniş bir şarj aralığında oldukça düz bir karakteristik sergilemesi, özellikle model hataları ve sensör gürültüsü mevcut olduğunda güvenilir durum kestirimi için önemli zorluklar oluşturur [7], [8]. Bu bağlamda BŞD kestirimi için her biri kendine özgü güçlü ve zayıf yönleri sahip çok sayıda yöntem geliştirilmiştir. Bu yöntemler üç ana kategoride sınıflandırılabilir: doğrudan ölçümler, veri odaklı yaklaşımlar ve model tabanlı yaklaşımlar. Basit ve anlaşılır olan doğrudan yöntemler arasında Coulomb sayımı ve açık devre voltajı yöntemi bulunur. Coulomb sayımı, akımın zaman üzerinden integralini alarak şarj durumunu belirler. Hesaplama açısından basit olsa da, akım ölçüm sapmalarına ve kapasite düşüşüne karşı hassastır; bu da batarya yaşlandıkça önemli birikimli kestirim hatalarına yol açabilir [9]. Açık devre gerilimi (ADG) yöntemi, batarya terminal voltajını ölçerek BŞD tahmini yapar. Hücre gerilimi ve BŞD arasındaki doğrusal olmayan ilişki, sıcaklık dalgalanmaları ve histerezis etkileriyle birlikte, kestirimin doğruluğunu önemli ölçüde etkileyebilir. Bunların yanı sıra, Genişletilmiş Kalman Filtresi (GKF) ve Parçacık Filtresi (PF) gibi pratikte en yaygın kullanılan model tabanlı teknikler, güçlü bir sağlamlık ve net fiziksel yorumlanabilirlik sağlasa da, kestirim doğrulukları büyük ölçüde batarya modellerinin doğruluyla sınırlıdır. Batarya modelleri ise genellikle iki kategoriye ayrılır: eşdeğer devre modelleri (ECM) ve elektrokimyasal modeller. ECM'ler batarya davranışını temsil etmek için elektriksel bileşenler kullanır ve yapısal olarak basittir ancak fiziksel içgöründen yoksundur ve sıcaklık değişimlerine karşı hassastır, bu da genellikle kapsamlı deneysel parametre belirleme çalışmaları gerektirir. Buna karşılık, elektrokimyasal modeller iç reaksiyon dinamiklerini yakalayarak daha yüksek doğruluk sunar, ancak karmaşıklıkları ve hesaplama maliyetleri pratik uygulamaları sınırlar [10]. Yapay zeka uygulamalarının gelişmesiyle birlikte, BŞD kestirimi için

veri odaklı yöntemler öne çıkmaktadır. Sinir Ağları (NN), Uzun Kısa Süreli Bellek (LSTM), Bulanık Mantık (FL), Destek Vektör Makineleri (SVM) ve Derin Öğrenme (DL) gibi bu yöntemler yüksek doğruluk elde edebilir ancak genellikle zayıf genelleme, aşırı öğrenme ve sınırlı yorumlanabilirlik sorunları yaşarlar, bu da onları pratik kullanım için karmaşık hale getirir. Yüksek hassasiyetli kestirim, büyük miktarda örnek veri eğitime bağlıdır ve algoritma çok sayıda hesaplama gerektirir [11]. Bu zorlukların üstesinden gelebilmek için literatürde ve endüstriyel uygulamalarda, bataryanın şarj durumunun daha hassas tahmin edilebilmesi amacıyla kimi zaman model tabanlı ve veri odaklı yöntemlerin hibrit kullanımı geliştirilip uygulanmıştır.

1.1 Tezin Amacı

Bu çalışmada öncelikle literatürde yer alan batarya şarj durum tahmin metotları araştırılmıştır. Literatürde öne çıkan çalışmalarda LFP bataryaların belli bir şarj aralığı boyunca neredeyse düz karakteristiğinden dolayı şarj durum tahminlerinin zorluğu göze çarpmıştır. Bu nedenle LFP bataryalar için literatürde yer alan bazı yöntemler uygulanmış, batarya modellemesi ve şarj durum tahmini yapılmıştır.

Bu bağlamda tez çalışması, LFP bataryalar için uygulanabilir, güvenilir ve hibrit bir BŞD kestirim yaklaşımı geliştirmeyi hedeflemektedir. Bu amaç doğrultusunda, tez kapsamında öncelikle LFP bataryaların dinamik davranışlarını temsil edebilecek ikinci dereceden eşdeğer devre modeli oluşturulmuştur. Batarya model parametreleri, farklı sıcaklık koşullarında gerçekleştirilen Hibrit Darbe Güç Karakterizasyon (HPPC) testi ile Dinamik Stres Test (DST) verileri kullanılarak, Unutma Faktörlü Yinelemeli En Küçük Kareler (FFRLS) yöntemi ile çevrimiçi olarak tanımlanmıştır. Bu sayede batarya parametrelerinin sıcaklığa ve şarj durumuna bağlı değişimlerinin modele yansıtılması amaçlanmıştır. Elde edilen model kullanılarak, Genişletilmiş Kalman Filtresi (GKF) tabanlı bir şarj durumu kestirim algoritması geliştirilmiş ve dinamik sürüş koşullarını temsil eden test profilleri altında değerlendirilmiştir. GKF yöntemi ile elde edilen şarj durum kestirim sonuçlarının, model belirsizlikleri ve ölçüm gürültüsü nedeniyle belirli hata bileşenleri içerdiğini göz önünde bulundurarak, bu hataların daha da azaltılması hedeflenmiştir.

Bu kapsamda tezin bir diğer temel amacı, model tabanlı BŞD kestiriminin veri tabanlı yöntemlerle desteklenmesidir. GKF algoritması tarafından elde edilen şarj durum

kestirimleri ve gerilim kestirim hataları, Uzun Kısa Süreli Bellek (LSTM) ağına giriş olarak verilmiş ve artık öğrenme (Residual Learning) yaklaşımı ile kestirim hatalarının öğrenilmesi amaçlanmıştır. Böylece, model tabanlı ve veri tabanlı yaklaşımları birlikte kullanarak, LFP bataryalar için daha yüksek doğrulukta bir BŞD kestirim yapısının geliştirilmesi hedeflenmiştir.

1.2 Literatür Araştırması

Xing ve arkadaşları [12], lityum-iyon bataryalarda ortam sıcaklığının açık devre gerilimi ile şarj durumu arasındaki ilişki üzerindeki etkisini incelemiş ve bu etkinin BŞD kestirim doğruluğu açısından kritik olduğunu ortaya koymuştur. Çalışmada, sıcaklığa bağlı ADG-BŞD referans tablosu ile desteklenen basit bir iç direnç (R_{int}) batarya modeli geliştirilmiş ve BŞD kestirimi için Kokusuz Kalman Filtresi (UKF) kullanılmıştır. Önerilen yöntem, CALCE veri seti kullanılarak DST ve FUDS sürüş profilleri altında, 0 °C ile 50 °C arasındaki farklı sıcaklık koşullarında test edilmiştir. Deneysel sonuçlar, sıcaklık etkisini dikkate alan yaklaşımın klasik ADG tabanlı yöntemlere kıyasla belirgin biçimde daha düşük kestirim hatası ürettiğini göstermiştir. Özellikle FUDS profili altında, 10 °C ve 40 °C sıcaklık koşullarında BŞD kestirimi için elde edilen RMSE değerlerinin %4.7'nin altında kaldığı raporlanmıştır. Buna karşılık, sıcaklık etkisinin ihmal edildiği durumlarda bazı BŞD aralıklarında hata oranlarının %15'in üzerine çıktığı belirtilmiştir. Çalışma, sıcaklık bağımlı modellerin LFP benzeri batarya kimyalarında BŞD kestirim doğruluğunu anlamlı ölçüde artırabileceğini göstermektedir [12].

Yang ve arkadaşları [13], LFP bataryalar için BŞD kestirim doğruluğunu artırmak amacıyla ikinci dereceden Thevenin eşdeğer devre modelini temel alan bir Genişletilmiş Kalman Filtresi (GKF) yaklaşımı önermiştir. Çalışmada, LFP bataryalarda şarj ve deşarj süreçlerinin farklı dinamikler sergilemesi nedeniyle akım yönüne bağlı model parametreleri tanımlanmıştır. Deneysel sonuçlar, bu yaklaşımın sabit parametrelili GKF yöntemlerine kıyasla daha yüksek doğruluk sağladığını göstermiştir. Nicel olarak, şarj ve deşarj için ayrı parametreler kullanan GKF yapısında ortalama BŞD hata değeri %1.90, maksimum hata ise %4.00 olarak raporlanmıştır. Çalışma, LFP bataryalar için 2RC eşdeğer devre modelinin, polarizasyon etkilerini daha iyi temsil etmesi sayesinde BŞD kestiriminde etkili bir çözüm sunduğunu ortaya koymaktadır [13].

Guo ve arkadaşları [14], lityum demir fosfat (LFP) bataryalarda açık devre gerilimi ADG–BŞD eğrisinin düz yapısından kaynaklanan zayıf gözlemlenebilirlik problemini aşmak amacıyla rezidüel bias telafisine dayalı çift Genişletilmiş Kalman Filtresi (RBC-DGKF) yapısını önermiştir. Çalışmada, bataryanın elektro-kimyasal davranışı kontrol odaklı tek parçacık modeli (CPG-SPMT) ile temsil edilmiş; bir GKF bataryanın iç elektro-kimyasal durumlarını kestirirken, ikinci GKF model–ölçüm uyumsuzluğundan kaynaklanan gerilim biasını bağımsız olarak tahmin ederek ölçüm denkleminde çevrimiçi düzeltme uygulamıştır. Önerilen yöntem, CALCE veri setine ait A123 LFP 18650 hücresi üzerinde US06 (0 °C), DST (25 °C) ve FUDS (50 °C) sürüş profilleri altında doğrulanmıştır. Nicel sonuçlar, klasik GKF ile karşılaştırıldığında BŞD kestirim doğruluğunda çok belirgin bir iyileşme sağlandığını göstermiştir. Ortalama olarak, BŞD RMSE değeri %3.75’ten %0.20’ye düşürülmüş, bu da yaklaşık %94.7’lik bir hata azalmasına karşılık gelmektedir. Sıcaklığa bağlı ayrı testlerde ise BŞD RMSE değerleri sırasıyla 0.38 % (US06, 0 °C), 0.08 % (DST, 25 °C) ve 0.14 % (FUDS, 50 °C) olarak raporlanmıştır. Ayrıca gerilim kestiriminde RMSE değeri 32.8 mV’den 0.8 mV’ye düşürülerek model–ölçüm uyumu önemli ölçüde artırılmıştır. Bu çalışma, özellikle orta BŞD aralığında belirgin olan model hatalarının rezidüel bias telafisi ile etkin biçimde bastırılabilirdiğini ve fizik-tabanlı modellerle birlikte kullanılan çift GKF yapısının, LFP bataryalar için yüksek doğruluklu ve sıcaklığa dayanıklı BŞD kestirimi sağladığını ortaya koymaktadır [14].

Shrivastava ve arkadaşları [15], lityum-iyon bataryalar için çevrimiçi model parametre tanımlama doğruluğunu artırmak amacıyla Modified Adaptive Forgetting Factor Recursive Least Squares (MAFF-RLS) algoritmasını önermiştir. Çalışmada, birinci dereceden RC eşdeğer devre modeli kullanılmış ve unutma faktörü terminal gerilim hatasına bağlı olarak adaptif şekilde güncellenmiştir. Önerilen yöntem, US06 ve Dynamic Stress Test (DST) profilleri altında değerlendirilmiş ve klasik RLS ile sabit unutma faktörlü FFRLS yöntemleriyle karşılaştırılmıştır. Nicel sonuçlar, MAFF-RLS algoritmasının gerilim kestirim hatasını belirgin biçimde azalttığını göstermiştir. US06 profili altında gerilim RMSE değeri 1.75 mV olarak raporlanmış; bu değer FFRLS için 2.12 mV, RLS için ise 8.64 mV seviyesindedir. Benzer şekilde, maksimum mutlak hata değeri 27.56 mV’ye düşürülmüştür. Çalışma, adaptif unutma faktörü kullanımının dinamik koşullar altında daha kararlı ve doğru parametre tanımlaması sağladığını ortaya koymaktadır [15].

Wei ve arkadaşları [16], lityum-iyon bataryalar için yüksek doğruluklu şarj durumu kestirimi amacıyla model tabanlı ve veri tabanlı yöntemleri birleştiren hibrit bir yaklaşım önermiştir. Çalışmada, bataryanın dinamik davranışı ikinci dereceden RC eşdeğer devre modeli ile temsil edilmiş ve model parametreleri, çevrimiçi olarak Unutma Faktörlü Yinelemeli En Küçük Kareler (FFRLS) yöntemi kullanılarak güncellenmiştir. Güncellenen parametreler ile Uyarlamalı Genişletilmiş Kalman Filtresi (AGKF) aracılığıyla ön BŞD kestirimi gerçekleştirilmiştir. Ardından, AGKF çıktıları ve kestirim hataları Uzun Kısa Süreli Bellek (LSTM) ağına giriş olarak verilerek residual learning yaklaşımı ile sistematik hataların düzeltilmesi hedeflenmiştir.

Deneysel sonuçlar, önerilen yöntemin yalnızca FFRLS-AGKF yapısına kıyasla daha düşük hata değerleri ürettiğini göstermiştir. Nicel olarak, RMSE değeri %1.47'den %0.83'e düşürülmüş ve MAE değeri %1.04 seviyesine indirilmiştir. Çalışma, çevrimiçi parametre tanımlama, adaptif filtreleme ve veri tabanlı hata telafisinin birlikte kullanılmasının BŞD kestirim doğruluğunu önemli ölçüde artırdığını ortaya koymaktadır [16].

Chung ve arkadaşları [17], lityum demir fosfat (LFP) bataryalarda ADG-BŞD eğrisinin düz karakteristiği ve ortam sıcaklığı değişimlerinin BŞD kestirim doğruluğu üzerindeki olumsuz etkilerini azaltmak amacıyla LSTM tabanlı, modelden bağımsız (model-free) bir BŞD kestirim yöntemi önermiştir.

Çalışmada, bataryanın akım, terminal gerilimi ve ortam sıcaklığı ölçümleri LSTM ağına girdi olarak verilmiş; BŞD, Coulomb sayımı ile elde edilen değerler referans kabul edilmiştir. Yöntem, A123 LFP (18650) hücresi üzerinde, DST profili altında ve 0–50 °C aralığındaki farklı sıcaklık koşullarında test edilmiştir. Deneysel sonuçlar, önerilen LSTM yaklaşımının tüm sıcaklık koşullarında yüksek doğruluk sağladığını göstermiştir. Genel değerlendirmede, BŞD kestirimi için RMSE değerleri %2.1'in, MAE değerleri ise %1.6'nın altında raporlanmıştır. En iyi performans, düşük ve oda sıcaklığı koşullarında elde edilmiş; 0–10 °C aralığında RMSE %1.06, MAE %0.88, 25 °C'de ise RMSE %1.06 ve MAE %0.93 olarak ölçülmüştür.

Karşılaştırmalı analizlerde, LSTM yöntemi klasik RNN ve SVM tabanlı yaklaşımlara kıyasla belirgin üstünlük göstermiş; örneğin RNN için RMSE %8.63, SVM için ise %10.26 seviyesinde raporlanmıştır. Buna karşılık, önerilen LSTM modeli aynı

koşullarda %0.93 RMSE ve %0.82 MAE değerlerine ulaşmıştır. Bu çalışma, LFP bataryalar için sıcaklığa duyarlı ve düz ADG-BŞD karakteristiğine sahip sistemlerde, fizik tabanlı model ve ADG-BŞD tablo gereksinimi olmadan, LSTM tabanlı veri odaklı yaklaşımların %1 seviyesinin altında BŞD kestirim hatası sağlayabildiğini göstermektedir.






2. BATARYA TEKNOLOJİLERİ

2.1 Batarya Türleri

Elektrikli araçlar, yaygın kanının aksine yeni bir teknoloji değildir. 1900'lerin başında elektrikli araçlar oldukça yaygındı ancak batarya teknolojisindeki yetersizlik, düşük kapasite ve yüksek üretim maliyetleri gibi teknik kısıtlamalardan ötürü fosil yakıtlarla çalışan içten yanmalı motorlu araçlar ulaşımında baskın hale gelmiştir. Günümüzde ise konvansiyonel araçların neden olduğu karbon emisyonları, fosil yakıt rezervlerinin azalması ve çevresel kaygılar, ulaşım sistemlerinde sürdürülebilir çözümlere olan ihtiyacı artırmıştır. Buna ek olarak, batarya teknolojilerindeki hızlı gelişmeler; daha yüksek enerji yoğunluğu, uzun çevrim ömrü ve düşen batarya maliyetleri sayesinde elektrikli araçların yeniden ön plana çıkmasını sağlamıştır. Bu gelişmeler, elektrikli araçları hem çevresel hem de ekonomik açıdan içten yanmalı motorlu araçlara güçlü bir alternatif haline getirmiştir.

Elektrikli araçların ekonomik ve verimli çalışabilmesi için çeşitli kimyalardan batarya türleri geliştirilmiştir. Günümüzde yaygın olarak kullanılan batarya türlerinin enerji yoğunlukları bakımından karşılaştırılması Şekil 2.1'de verilmiştir [18].



Şekil 2.1 : Farklı Batarya Türlerinin Enerji Yoğunluğu Karşılaştırması [18].

Son yarım asırda batarya teknolojilerinde katedilen gelişmeler çeşitli batarya türlerini kullanan elektrikli araçların pazarda yer almasına olanak sağlamıştır. Endüstriyel üretimde en fazla kullanılan batarya türleri Kurşun asit, Nikel kadmiyum, Nikel hitrat ve Lityum iyon bataryalardır.

2.1.1 Kurşun asit bataryalar (Lead acid)

Kurşun asit bataryalar, elektrikli araçlarda kullanılan en eski şarj edilebilen batarya tipi olup, ilk kez 1859 yılında Gaston Planté tarafından geliştirilmiştir. Kurşun asit bataryalar düşük maliyetli olmasına karşın düşük özgül enerji yoğunluğu (Wh/kg), yüksek ağırlık ve sınırlı çevrim ömrü gibi önemli dezavantajlara sahiptir [19]. Bunların yanı sıra, kurşunun zehirli olması ve çevreye verdiği zarardan ötürü kullanımı zamanla azalmıştır. Günümüzde genel olarak kesintisiz güç kaynaklarında (UPS), tekerlekli sandalyeler ve güvenlik aydınlatmalarında kullanılır. Şekil 2.2’ de 5 Ah kapasiteli UPS ve acil aydınlatma sistemlerinde kullanılan bir kurşun asit batarya model örneği verilmiştir.



Şekil 2.2 : 12 V – 5 Ah Kurşun Asit Batarya [19].

2.1.2 Nikel kadmiyum bataryalar (Ni – Cd)

İlk kez 1889 yılında Waldemar Jungner tarafından geliştirilen Nikel kadmiyum bataryalar, kurşun asit bataryaların dezavantajlı olduğu bazı uygulamalarda alternatif olarak değerlendirilmiştir [19]. Nikel kadmiyum bataryalar sahip oldukları kimya gereği, geniş çalışma sıcaklık aralığı, yüksek deşarj akımı ve yüksek çevrim ömrü sebebiyle en dayanıklı bataryalardan biridir [19]. Ancak yüksek maliyet, yüksek kendine kendine deşarj oranı ve kadmiyumun zehirli bir ağır metal olması sebebiyle

kullanım alanları kısıtlanmıştır. Bu nedenlerden dolayı yerlerini daha çevre dostu kimya yapısına sahip bataryalara bırakmışlardır. Şekil 2.3’ de bir Ni-Cd batarya örneği gösterilmiştir.



Şekil 2.3 : Nikel Kadmiyum Batarya [19].

2.1.3 Nikel metal hidrat bataryalar (Ni – MH)

Nikel kadmiyum bataryaların yüksek maliyetli olması ve kadmiyumun toksik özelliği nedeniyle nikel metal hidrat bataryalar elektrikli araçlarda kullanılmak üzere alternatif olarak öne çıkmıştır. Ni-MH bataryalar, kurşun asit ve Ni-Cd bataryalara kıyasla daha yüksek özgül enerji yoğunluğuna ve özgül güce sahiptir [20]. Ayrıca Ni-Cd bataryalarda gözlemlenen hafıza etkisinin görece zayıf olması nedeniyle de hibrit elektrikli araçlar (HEV) için tercih edilmesini sağlamıştır. 1990’lı yılların sonlarından itibaren özellikle Toyota Prius, Toyota Highlander, Lexus RX, Honda Insight, Honda Civic ve Ford Escape dahil olmak üzere birçok hibrit araçta kullanılmıştır [21]. Şekil 2.4’ de bir Toyota Highlander hibrit aracı için kullanılan Ni-MH batarya paketlemesi gösterilmektedir. Ni-Mh bataryaların kullanım ömüleri genellikle 300 ile 500 şarj-deşarj çevrimi arasında değişmektedir. Elektrikli araçlar için bu istenilen çevrim ömrü olmamakla birlikte batarya değişim maliyetlerini de beraberinde getirmektedir. Ni-Mh bataryalar şarj durumu %70’ in üzerine çıktığında batarya aşırı ısınır ve enerjinin bir kısmı ısı olarak kaybedilir. Böylelikle bataryanın sahip olduğu enerji yoğunluğu düşer [22]. Ayrıca yüksek nikel içeriğinden dolayı artan maliyetler, Ni-MH bataryaların lityum-iyon bataryalar karşısında rekabet gücünü sınırlamaktadır. Bu nedenle Ni-MH

bataryalar günümüzde daha çok hibrit araçlar, UPS ve telekomünikasyon gibi güvenilirliğin ön planda olduğu uygulamalarda kullanılmaktadır [3].



Şekil 2.4 : Toyota Highlander aracında kullanılan Ni-MH batarya [20].

2.1.4 Lityum iyon bataryalar (Li-ion)

Kurşun asit ve nikel bazlı bataryaların enerji yoğunluğu, çevrim ömrü, maliyetleri ve çevreye olan zararları gibi dezavantajlarından dolayı, yeni bir batarya teknoloji arayışı doğmuştur. Bu doğrultuda özellikle 1970’li yıllardaki petrol krizi sırasında Michael Stanley Whittingham’ın fosil yakıtlara alternatif enerji depolama yöntemleri geliştirmesiyle lityum temelli batarya teknolojisinin temelleri atılmıştır. Lityum yüksek enerji yoğunluğuna sahip en hafif metaldir. Bu elektrokimyasal yapısından dolayı bataryalar için oldukça elverişli bir elementtir. Whittingham, lityum iyonlarını barındırabilen titanyum disülfid katot ve metalik lityum anot kullanan bir batarya yapısı önermiştir; ancak metalik lityumun yüksek reaktivitesi güvenlik sorunlarına yol açmıştır [23]. Daha sonra John Bannister Goodenough, metal sülfatlar yerine metal oksit katotlar kullanarak daha yüksek hücre potansiyelleri elde etmiş ve özellikle kobalt oksit ile lityum metal bataryaların performansını önemli ölçüde artırmıştır.

1980’lerin ortalarında metalik lityum anot kullanılan bataryalarda gözlemlenen dendrit oluşumu, bu bataryaların güvenliğini ciddi şekilde tehdit etmiştir. Anot yüzeyinde oluşan dendrit yapılar zamanla büyüyerek anot ve katot arasındaki ayırıcıyı delip, hücre içi kısa devreye sebep olmakta ve hücre sıcaklığını arttırarak lityumun erime noktasına ulaşmasıyla birlikte ısıl sürüklenmeye (thermal runaway) yol açmaktadır


[24]. Bu durumda bataryalarda patlama ve alev oluşumu gözlemlenmiştir. Şekil 2.5’te ısıl sürüklenmeye uğramış bir cep telefonu gösterilmektedir.



Şekil 2.5 : Isıl sürüklenme gerçekleşmiş bir cep telefonu bataryası [23].

Özellikle taşınabilir elektronik cihazlarda yaşanan yangın vakaları nedeniyle metalik lityum bataryaların kullanımından büyük ölçüde vazgeçilmiştir. Bu güvenlik sorunlarını ortadan kaldırmak amacıyla, anotta metalik lityum içermeyen ve lityum atomlarının katot-anot arasında taşındığı batarya mimarisinde çalışmalar hız kazanmıştır. 1985 yılında ise Akira Yoshino, metalik lityum anot yerine lityum iyonlarını ara katmanlara alabilen karbon bazlı bir anot kullanarak ilk ticari ve güvenli lityum-iyon bataryayı geliştirmiştir [23]. Bu gelişmeler, günümüzde kullanılan lityum-iyon batarya teknolojisinin temelini oluşturmuştur. Ayrıca Şekil 2.6’te şematik çizimleri gösterilen bu çalışmalar neticesinde Whittingham, Goodenough ve Yoshino 2019 yılında Nobel Kimya ödülüne layık görülmüşlerdir.


Lityum-iyon bataryaların ticarileştirilmesinin ardından hızla yaygınlaşarak günümüzün baskın batarya teknolojisi haline gelmiştir. Lityum-iyon bataryalar, lityum metal bataryalara kıyasla daha düşük enerji yoğunluğuna sahip olmasına karşın sağladıkları yüksek güvenlik nedeniyle tercih edilmektedir. Lityum-iyon bataryalar, ilk ticarileştirildikleri dönemde yüksek maliyetli olmalarına rağmen, üretim ve bakım maliyetleri gün geçtikçe azalmaktadır. Diğer batarya türlerine göre yüksek enerji yoğunluğu, zehirli element içermemeleri ve düşük kendi kendine deşarj oranı sayesinde elektrikli ulaşım, tüketici elektroniği, enerji depolama sistemleri, endüstriyel, tıbbi ve askeri uygulamalar gibi hayatın hemen hemen her alanında vazgeçilmez olmuştur.



Şekil 2.6 : Geliştirilen Li-ion Bataryalarının Şematik Gösterimi [25].

Lityum-iyon bataryalarda en yaygın kullanılan hücre geometrileri silindirik, prizmatik ve poşet (pouch) tipleridir (Şekil 2.7). Silindirik ve prizmatik hücreler genellikle alüminyum veya paslanmaz çelikten oluşan sert muhafazalar içerisinde yer alırken, poşet hücreler çok katmanlı alüminyum kompozit folyo ile kaplanmaktadır. Silindirik hücrelerde elektrotlar ayırıcılarla birlikte sarılarak oluşturulurken, prizmatik

hücrelerde elektrotlar sarımlı ya da düz katmanlı şekilde düzenlenmektedir. Poşet hücrelerde ise elektrotlar yalnızca istiflenmiş yapıdadır. Hücre üretiminde kullanılan bu tasarım yaklaşımları, üretim teknolojilerine göre farklılık göstermekte olup, Asyalı üreticiler genellikle prizmatik sarım yöntemini tercih ederken, Avrupalı üreticiler tek tabaka istifleme yöntemini kullanmaktadır [26].



Şekil 2.7 : Li-ion batarya geometrisi [25].

Lityum iyon bataryaların hücre gerilimleri yaklaşık 4 V mertebesine kadar çıkabilmekte olup, kullanılan aktif malzemeler ve elektrolit türüne bağlı olarak enerji yoğunluğu artırılabilir. Bununla birlikte, aşırı şarj ve deşarj karşı hassas olmaları nedeniyle koruma devresi gereksinimi ve görece yüksek maliyetleri, lityum-iyon bataryaların başlıca dezavantajlarından bazılarıdır [24]. Çizelge 2.1’de lityum iyon bataryaların diğer bataryalara göre karşılaştırılması verilmiştir.


Çizelge 2.1 : Batarya türlerinin karşılaştırılması [24].

ÖZELLİKLER	Lead-Acid	Ni-Cd	Ni-MH	Li-ion
Maliyet	Düşük	Orta	Yüksek	Çok Yüksek
Enerji Yoğunluğu (Wh/kg)	30 – 50	50 – 80	40 – 100	100 – 275
Hücre Gerilimleri(V)	2	1.25	1.25	3.6
Şarj Akımı (A)	Düşük	Çok düşük	Orta	Yüksek
Çevrim Ömrü (Şarj/Deşarj)	200 – 500	1000	1000	Up to 3000
Kendine Deşarj (Aylık)	%5	%20	%30	<%5
Zehirlilik	Yüksek	Yüksek	Düşük	Düşük
Şarj Süresi	8 – 16 saat	1 – 2 saat	2 – 4 saat	1 – 2 saat

2.2 Lityum İyon Bataryaların Çalışma Prensibi

Lityum-iyon bataryalar, hücre yapısında kullanılan elektrot ve elektrolit malzemelerine bağlı olarak farklı kimyasal sınıflara ayrılmaktadır. Bu bataryalar yapısal olarak anot, katot, elektrolit ve ayırıcı bileşenlerinden meydana gelir. Negatif yüklü elektrot (anot) olarak çoğunlukla grafit esaslı karbon malzemeler tercih edilirken, pozitif yüklü elektrot (katot) lityum içeren metal oksit yapılarından oluşur. Elektrolit kısmı ise lityum iyonlarının hücre içerisinde hareket edebilmesini mümkün kılan lityum tuzları (LiPF_6 gibi) ve organik çözücü karışımlarını içerir. Ayırıcı tabaka ise, elektrotlar arasında fiziksel bir bariyer oluşturarak kısa devreyi önlerken, iyonların geçişine izin vererek elektrokimyasal sürecin devamlılığını sağlar.

Bataryanın enerji üretim mekanizması, şarj ve deşarj döngüleri sırasında gerçekleşen iyon taşınımına dayanır. Deşarj sırasında, anot yapısında depolanmış olan lityum atomları elektronlarını serbest bırakarak iyon haline geçer. Açığa çıkan elektronlar harici devre üzerinden akarken, lityum iyonları elektrolit ortamında katoda doğru ilerler ve bu sayede elektrik enerjisi elde edilir. Şarj aşamasında ise harici bir enerji kaynağı yardımıyla iyonlar tekrar anoda yönlendirilerek sistem başlangıç durumuna döndürülür [3]. Şekil 2.8’de bir lityum-iyon bataryanın çalışma prensibi gösterilmiştir.



Şekil 2.8 : Lityum-iyon bataryaların çalışma prensibi: (a) Deşarj; (b) Şarj [18].

Lityum-iyon bataryalarda kullanılan elektrot, elektrolit ve ayırıcı malzemeler, bataryanın hangi amaçla kullanılacağına göre seçilir. Bataryanın güvenli ve verimli çalışabilmesi için özellikle elektrolitin iyon iletim kabiliyeti ve tüm bileşenlerin geniş sıcaklık aralıklarına dayanıklı olması önemlidir. Doğru malzeme kombinasyonu, hem maliyeti düşürür hem de bataryanın kapasitesini artırır; bu nedenle farklı kimyalarda

çeşitli lityum-iyon bataryalar geliştirilmiştir. Kullanılan katot-anot malzemesine bağlı olarak lityum-iyon bataryalar lityum kobalt oksit (LCO), lityum mangan oksit (LMO), lityum nikel mangan kobalt oksit (NMC), lityum nikel kobalt alüminyum oksit (NMA), lityum titanat (LTO) ve lityum demir fosfat (LFP) bataryalar olarak sınıflandırılmaktadır [3].

2.2.1 Lityum kobalt oksit (LiCoO_2 – LCO)

İlk olarak 1991 yılında Sony tarafından geliştirilen lityum kobalt oksit bataryalar, yüksek enerji yoğunluğu, uzun çevrim ömrü ve üretim kolaylığı nedeniyle cep telefonları, dizüstü bilgisayarlar ve dijital kameralar gibi çoğu kişisel elektronik cihaz için tercih edilen pil olmuştur [27]. LCO'nin özgül enerji yoğunluğu, diğer pillere kıyasla çok daha iyi ve uzun bir kullanım süresine sahiptir. Bu bataryalarda katot elektrotunda kobalt oksit, anot elektrodunda ise grafit bulunur. LCO kimyası termal olarak kararsızdır ve bu nedenle çalışma sırasında potansiyel yangın tehlikesi oluşabilir. Ayrıca kobalt az bulunan bir element olduğu için oldukça maliyetlidir. Bu nedenle EA'larda pek yaygın kullanılmasa da örnek olarak Tesla Roadster aracında LCO batarya kullanılmaktadır.

2.2.2 Lityum mangan oksit (LiMn_2O_4 – LMO)

Lityum mangan oksit bataryalar ilk olarak 1995'ten itibaren ticari olarak kullanılmaya başlanmışlardır. LMO, katot malzemesi olarak spinel yapılı mangan oksit kullanmaları sayesinde yüksek güç yoğunluğu ve iyi termal kararlılık sunmaktadır. Manganın kobalt ve nikel gibi metallere kıyasla daha bol bulunması ve düşük maliyetli olması, LMO bataryaları ekonomik açıdan avantajlı hale getirmektedir. Bu bataryalar, hızlı şarj ve deşarja olanak sağlayan kimyaları nedeniyle özellikle yüksek güç gerektiren elektrikli araç uygulamalarında tercih edilmiştir. LMO batarya kimyası LCO' ya göre daha iyi termal kararlılık sağlasa da kapasitesi %33 daha düşük ve kısa ömürlüdür [28]. Bu sebeplerle LMO bataryalar, günümüzde çoğunlukla nikel mangan kobalt (NMC) gibi diğer lityum-iyon kimyalarıyla hibrit yapılar içerisinde kullanılmaktadır. LMO – NMC hibrit batarya yapısının kullanıldığı araçlardan bazıları Nissan Leaf, Chevy Volt ve BMW i3 dür [29].

2.2.3 Lityum nikel mangan kobalt oksit (LiNiMnCoO_2 – NMC)

Lityum nikel mangan kobalt oksit bataryalar, nikel, mangan ve kobaltın dengeli oranlarda birleştirildiği katot yapısı sayesinde enerji yoğunluğu, güç kapasitesi ve çevrim ömrü arasında dengeli bir performans sunmaktadır. Nikel içeriği enerji yoğunluğunu artırırken, mangan yapısal kararlılığı ve güvenliği desteklemekte, kobalt ise iletkenliği iyileştirmektedir.

Böylece LCO ve LMO'nun güçlü yönleri bir araya getirilerek daha iyi termal kararlılık ve yüksek enerji yoğunluğu gösteren NMC bataryalar tercih sebebi olmuştur. Ayrıca direkt LCO kullanmak yerine, kobalt miktarı azaltılarak kullanılan hibrit yapı sayesinde de üretim maliyeti düşürülmüştür. Bu özellikleri sayesinde NMC bataryalar, günümüzde birçok seri üretim elektrikli araçta kullanılmaktadır [29].

2.2.4 Lityum nikel kobalt alüminyum oksit (LiNiCoAlO_2 – NCA)

Lityum nikel kobalt alüminyum oksit bataryalar, LCO ile çok benzer kristal yapıya sahiptir. NMC ile benzer şekilde yüksek enerji yoğunluğu ve uzun çevrim ömrüne sahiptir [30]. NCA bataryalar, NMC ve LMO bataryalar kadar güvenli değildir ve ısı sürüklenme riski taşırlar. Ayrıca üretimleri de oldukça maliyetlidir. Buna rağmen NCA batarya teknolojisi Tesla'nın Model 3 ve Model S araçlarında kullanılmıştır.

2.2.5 Lityum titanat oksit (Li_2TiO_3 – LTO)


Lityum titanat oksit bataryalar, anot malzemesi olarak grafit yerine lityum titanat kullanmalarıyla diğer lityum-iyon bataryalardan ayrılmaktadır. Titanat kristalleri grafitte kıyasla 20 kat daha fazla anot yüzey alanı sağlar. Bu yapı sayesinde LTO bataryalar çok uzun çevrim ömrü, yüksek şarj-deşarj hızları ve üstün termal kararlılık sunmaktadır. Ayrıca lityum metal birikimi ve dendrit oluşumu riski son derece düşük olduğundan güvenlik açısından avantajlıdır.

Tüm bu üstün özelliklere rağmen, LTO bataryaların düşük enerji yoğunluğu ve yüksek maliyeti, bu batarya kimyasının uzun menzil gerektiren elektrikli araç uygulamalarında kullanımını sınırlandırmaktadır. Bu nedenle LTO bataryalar, daha çok hızlı şarj gerektiren ve güvenliğin ön planda olduğu mobil tıbbi cihazlar gibi özel uygulamalarda tercih edilmektedir [31].

2.2.6 Lityum demir fosfat (LiFePO₄ – LFP)

Lityum demir fosfat bataryalar 1996 yılında Teksas Üniversitesi'nde bulunmuştur. LFP bataryalar, düşük iç direnç, iyi elektrokimyasal performans, yüksek deşarj akım kabiliyeti, termal kararlılığı, çevre dostu olması, düşük maliyet ve uzun çevrim ömrü gibi avantajlara sahiptir [32]. Katotta fosfat kullanımı sayesinde elektrot malzemesi aşırı şarj-deşarj koşullarında daha kararlı davranmakta ve bu da bataryanın termal kararlılığını arttırmaktadır. LFP bataryalar, geniş bir sıcaklık aralığında (yaklaşık -30 °C ile 60 °C) güvenilir şekilde çalışabilmektedir. Isıl kaçak riski neredeyse yok seviyesindedir. Yüksek güvenlik seviyesi, iyi güç-ağırlık oranı ve uzun ömürlü yapısı sayesinde LFP bataryalar; elektrikli karavanlar, sabit enerji depolama sistemleri ve güvenliğin ön planda olduğu elektrikli araç uygulamalarında yaygın olarak tercih edilmektedir. Özellikle günümüzde popüleritesi giderek artmaktadır. Tesla Model Y, BYD Seal, BYD Atto 3, MG4 EV, Renault Megane e-Tech, Volvo EX30, Ford Mustang Mach-E gibi birçok EA'da LFP batarya teknolojisi kullanılmaktadır.

Lityum-iyon bataryalar çeşitli yönlerinden ele alınmış olup birbirleriyle olan karşılaştırması Şekil 2.9' da verilmiştir. LFP batarya kimyasının açık devre gerilimi ile şarj durumu arasındaki ilişkinin geniş bir BŞD aralığında oldukça düz bir karakteristik sergilemesi, BŞD kestirimini zorlaştırmakta ve bu da ilgi çekici bir mühendislik problemi haline gelmektedir. Bu nedenle bu çalışmada kullanılan batarya türü LFP tipi bir lityum-iyon bataryadır.



Şekil 2.9 : Li-ion bataryaların birbirleriyle karşılaştırılması [29].

2.3 Batarya Teknolojisinin Geleceđi

Batarya teknolojilerinde gncel ve gelecek odaklı alıřma projeksiyonları, temel olarak enerji yođunluđunun artırılması, řarj srelerinin kısaltılması ve gvenlik seviyelerinin en st noktaya tařınması hedefleri etrafında řekillenmektedir. Gnmzn baskın batarya teknolojisi olarak lityum iyon bataryalar, gittike nem arz eden bu talepler karřısında istenilen performansı sađlamakta zorlanmaktadırlar. Bu durum, arařtırmacıları hem mevcut teknolojilerin geliřtirilmesine hem de yeni nesil batarya kimyalarının ortaya ıkarılmasına ynlendirmiřtir [33].

Bu dođrultuda, katı hal bataryalar (solid-state batteries), sıvı elektrolitlerin yerine katı elektrolitlerin kullanılması sayesinde daha yksek gvenlik ve daha geniř elektrokimyasal kararlılık penceresi sunan yeniliki bir yaklařım olarak ne ıkmaktadır. Katı elektrolitlerin kullanımı, yanıcı organik sıvıların ortadan kaldırılmasıyla yangın ve patlama riskini azaltırken, aynı zamanda lityum metal anotların kullanılabilmesine imkan tanımaktadır [34]. Literatrde, katı hal elektrolitler sayesinde geliřtirilen yeni batarya kimyalarının daha uzun evrim mr ve daha yksek enerji yođunluđu potansiyeli tařıdıđı vurgulanmaktadır. Ancak iyonik iletkenlik, elektrot-elektrolit ara yz ve mekanik dayanım gibi konular halen temel arařtırma bařlıkları arasında yer almaktadır [34].

te yandan, lityum kaynaklarının sınırlı olması ve maliyet artıřı, sodyum-iyon bataryalara olan ilgiyi artırmıřtır. Sodyumun yer kabuđuunda bol bulunması ve dřk maliyeti, bu bataryaları zellikle byk lekli enerji depolama uygulamaları iin cazip kılmaktadır [35]. Sodyum-iyon bataryaların enerji yođunlukları lityum iyon sistemlere kıyasla daha dřk olmakla birlikte, yapılan modelleme alıřmaları uygun anot ve katot malzemelerinin geliřtirilmesiyle rekabeti deđerlere ulařılabileceđini gstermektedir [35]. Ayrıca, lityum-iyon bataryalarda enerji yođunluđunu artırmaya ynelik evrimsel bir yaklařım olarak silikon anotlu lityum iyon bataryalar da dikkat ekmektedir. Silikon, grafitte kıyasla ok daha yksek teorik kapasite sunmasına rađmen, hacim genleřmesi ve evrim kararlılıđı gibi sorunlar nedeniyle arařtırma ve geliřtirme ařamasında yođun biimde ele alınmaktadır [36].

Uzun vadede ise lityum-slfr ve lityum-hava bataryaları, teorik olarak ok yksek enerji yođunluklarıyla dikkat ekmektedir. Her ne kadar bu teknolojiler henz laboratuvar ve prototip ařamasında olsa da, zellikle havacılık ve uzun menzilli

elektrikli araç uygulamaları için büyük potansiyele sahiptir. Bununla birlikte, batarya geri dönüşüm teknolojileri ve çevresel etkilerin azaltılmasına yönelik çalışmalar da güncel ve gelecekteki batarya teknolojilerinin ayrılmaz bir parçası olarak önem kazanmaktadır [33].





3. ŞARJ DURUMU TAHMİN YÖNTEMLERİ

3.1 Batarya Yönetim Sistemleri (BYS)

Yüksek özgül enerji, uzun çevrim ömrü ve düşük kendi kendine deşarj oranı gibi özellikleri sayesinde lityum-iyon bataryalar, elektrikli araçlar için en uygun enerji depolama çözümlerinden biri olarak öne çıkmaktadır. Lityum-iyon bataryalar çeşitli batarya paketi konfigürasyonlarında kullanılarak EA'larda verimli bir sürüş elde edilmeye çalışılmıştır. Geliştirilen batarya paketlerinin şarj-deşarj süreçlerini kontrol eden ve denetleyen elektronik sistemlere batarya yönetim sistemleri (BYS) denir. BYS akım, gerilim ve sıcaklık gibi temel parametreleri sürekli olarak ölçerek, bataryanın güvenli sınırlar içinde çalışmasını sağlar ve bu sınırlar aşıldığında sistemi korumak için müdahale eder [37]. Günümüzde BYS'ler birçok uygulama alanında yaygın olarak kullanılmaktadır. BYS, hücrelerin nasıl izlendiğine ve kontrol edildiğine bağlı olarak farklı topolojilere sınıflandırılabilir. En yaygın BYS topolojileri arasında merkezi, dağıtılmış ve modüler mimariler bulunur. Her biri ölçeklenebilirlik, kablolama karmaşıklığı ve hata toleransı açısından farklı avantajlar ve dezavantajlar sunar. BYS topolojisinin seçimi, uygulama gereksinimlerine, pil paketi boyutuna ve sistem güvenilirliği gibi hususlara bağlıdır [38].

Batarya yönetim sistemlerinin temel fonksiyonları algılama ve ölçüm, koruma, arayüz, performans yönetimi ve teşhisdir. Algılama ve ölçüm işlevleri, voltaj, akım, sıcaklık ve empedans gibi önemli batarya parametrelerinin izlenmesini içerir. Koruma işlevleri, aşırı şarj, aşırı deşarj, aşırı akım, kısa devre ve sıcaklık aşımı gibi anormal koşullara karşı bataryayı koruyarak güvenli çalışmayı sağlar. Arayüz katmanı, menzil tahmini, harici sistemlerle iletişim, veri kaydı ve raporlama gibi işlevler sağlar. Performans yönetimi ise, şarj durumu tahmini, güç sınırı hesaplama, hücre dengeleme ve genel batarya çalışma yönetimi gibi operasyonel kontrol görevlerine odaklanır. Son olarak, teşhis işlevleri arıza tespiti, pil sağlık durumu tahmini ve kalan kullanım ömrü tahmini ile ilgilenir [38].


3.2 Şarj Durumunun Tanımı

Şarj edilebilir bataryaların EA’larda kullanılmasıyla birlikte, bataryada ne kadar enerji kaldığını, ne zaman şarj edilmesi veya hatta ne zaman değiştirilmesi gerektiğini bilmek önemli bir parametre haline gelmiştir. Batarya yönetim sistemlerinin en kritik parametrelerinden biri olan BŞD, bataryanın anlık enerji seviyesini belirleyen en temel göstergedir. Konvansiyonel araçlarda kullanılan yakıt göstergesini, elektrik araçlardaki BŞD ile benzeştirebiliriz. Teknik olarak BŞD, bataryanın kalan anlık kapasitesinin maksimum (nominal) kapasitesine oranıdır [39]. Yüzde (%) cinsinden belirtilen bu değer, BŞD %100 iken bataryanın tamamen şarjlı, BŞD %0 iken tamamen boş durumunu temsil eder. Batarya şarj durumu aşağıdaki denklemle ifade edilir (3.1).

$$SOC(t) = SOC(t_0) + \frac{1}{C_b} \int_{t_0}^t \eta \cdot I(t) \cdot dt \quad (3.1)$$

Denklemde yer alan BŞD(t) ifadesi t zamanındaki bataryanın doluluk oranını, BŞD(t_0) başlangıç anındaki bataryanın doluluk oranını, $I(t)$ ise zamanın fonksiyonu olarak batarya akımını, C_b bataryanın nominal kapasitesini ve η ise coulomb verimini temsil eder [39]. Akımın yönü batarya şarj edilirken pozitif; deşarj edilirken negatiftir. Bu çalışmada coulomb verimi 1 olarak alınmıştır. BŞD hesabının doğruluğu denklemden de (4.1) anlaşılacağı üzere başlangıç batarya şarj durumuna ve şarj-deşarj akımının ölçümüne bağlıdır. Bataryanın elektrokimyasal yapısı nedeniyle gerilimi dinamik bir davranış sergiler ve batarya akımı ölçümü sırasında gürültü kaynaklı gerçekleşecek hatalar nedeniyle şarj durumunu tahmin etmek zordur. Bu sebeplerden dolayı BŞD doğrudan ölçümlenemez ve kestirim yöntemlerine ihtiyaç duymaktadır.

EA’larda çok sayıda batarya hücresinin kullanılması ve BYS’ nin sınırlı hesaplama kapasitesi, gerçek zamanlı ve çevrimiçi BŞD tahminini zorlaştırmaktadır. Bu nedenle BŞD kestirim algoritmalarının yalnızca yüksek doğruluk sunması değil, aynı zamanda ölçüm hatalarına, model belirsizliklerine ve değişen çalışma koşullarına karşı sağlam, hesaplama açısından verimli ve gerçek zamanlı uygulanabilir olması gerekmektedir. Literatürde şarj durum tahmini genel olarak iki ana başlıkta incelenmiş olup bunlar; Doğrudan Ölçme Yöntemleri ve Dolaylı Ölçme Yöntemleridir [40]. Şekil 3.1’ de şarj durumu kestirim yöntemleri verilmiştir.



Şekil 3.1 : Batarya şarj durumu tahmin yöntemleri [40].

3.2.1 Doğrudan BŞD ölçüm yöntemleri

Doğrudan şarj durumu ölçüm yöntemleri, bataryanın fiziksel özellikleri ve karakteristiklerini kullanarak BŞD'yi kestirmeyi amaçlar. Bu yaklaşımda, batarya şarj durumu voltaj, akım ve sıcaklık gibi ölçülebilir faktörler doğrudan kullanılarak tahmin edilir [40]. Bu yöntemleri Şekil 3.1' de gösterilen üç ana başlıkta inceleyebiliriz. Bunlar, Coulomb Sayma (Ampere-hour integration), Açık Devre Gerilimi (ADG) ve Elektrokimyasal Empedans Spektroskopisidir (EIS).

3.2.1.1 Coulomb sayma yöntemi

Coulomb sayma yöntemi, bataryaya giren ve bataryadan çıkan akımın zamanla integrali alınarak bataryada kalan yük miktarının hesaplanmasına dayanır. Temel prensip, bataryadan çekilen veya bataryaya verilen elektrik yükünün (coulomb) başlangıçtaki şarj durumundan çıkarılması ya da eklenmesiyle BŞD'nin güncellenmesidir. Matematiksel olarak ifadesi denklem 3.1'de verilmiştir. Bu yöntemde, şarj sırasında biriken akım BŞD'yi artırırken, deşarj sırasında çekilen akım BŞD'yi azaltır ve hesaplama için başlangıç BŞD değerinin bilinmesi gereklidir [41].


Düşük maliyeti ve uygulanmasının kolay olması nedeniyle batarya yönetim sistemlerinde yaygın olarak tercih edilmektedir. Bununla birlikte, akım ölçümündeki küçük hatalar zamanla birikerek önemli tahmin sapmalarına yol açabilmekte ve batarya yaşlanması gibi etkiler dikkate alınmamaktadır [42]. Bu nedenle tek başına kullanımlarda BŞD ile ilgili doğru sonuçları vermekte yeterli değildir ancak yaklaşık referans değer (ground-truth) olarak değerlendirilir.

3.2.1.2 Açık devre gerilimi yöntemi (ADG)


Açık devre gerilimi (ADG) yöntemi, bataryanın şarj durumu kestiriminin, bataryanın yükten tamamen ayrıldığı durumdaki terminal gerilimi ile BŞD arasındaki ilişkiye dayanarak yapılmasını esas alır. Bu yaklaşımda, bataryanın elektrokimyasal dengeye ulaşması beklenir ve ölçülen ADG değeri, önceden elde edilmiş ADG-BŞD karakteristik eğrisi kullanılarak BŞD' ye dönüştürülür [43]. Denklem 3.2'de $f(ADG)$, ADG' nin bir fonksiyonu olarak BŞD (BŞD)' yi ifade etmektedir. ADG yöntemi, yapısal olarak basit olması ve ek hesaplama yükü gerektirmemesi nedeniyle referans veya kalibrasyon amaçlı BŞD belirlemede yaygın olarak kullanılmaktadır. Bununla birlikte, dengeye ulaşmak için uzun bekleme sürelerine ihtiyaç duyulması, sıcaklık ve yaşlanma ile histerezis etkilerine karşı hassas olması, yöntemin gerçek zamanlı uygulamalarda kullanımını sınırlandırmaktadır [44].

$$SOC = f(OCV) \quad (3.2)$$

Açık devre gerilimi ile şarj durumu arasındaki ilişki her batarya için aynı değildir. Örneğin, bir kurşun-asit batarya doğrusal bir ADG-BŞD ilişkisine sahipken, bir lityum-iyon bataryada bu ilişki doğrusal değildir. Özellikle LFP gibi düz ADG-BŞD eğrisine sahip batarya kimyalarında, küçük gerilim değişimleri BŞD kestiriminde büyük belirsizliklere yol açabilmektedir [42]. Ayrıca akım, gerilim ve sıcaklık üzerinden doğrudan bir ölçümleme yapıldığı için sensör gürültülerinden de etkilenir. Bu nedenlerden dolayı dolaylı ölçüm yöntemlerine yardımcı bir yöntem olarak kullanılır. Şekil 3.2' de NMC tipi bir batarya için ADG-BŞD eğrisi ve Şekil 3.3' te LFP tipi bir batarya için ADG-BŞD ilişkisi gösterilmiştir. Bu çalışmada da bu zorlu karakteristik yapısından ötürü LFP tipi bir batarya üzerinde çalışılmıştır.



Şekil 3.2 : NMC tipi batarya için ADG-BŞD eğrisi örneği.



Şekil 3.3 : LFP tipi batarya için ADG-BŞD eğrisi örneği.

3.2.2 Dolaylı ölçüm yöntemleri

Batarya Yönetim Sistemlerinde (BYS), hücrelerin elektrokimyasal durumu doğrudan fiziksel sensörlerle ölçülememiğinden, akım, gerilim ve sıcaklık gibi gözlemlenebilir değişkenler üzerinden Dolaylı Ölçüm Yöntemleri kullanılır. Bu yöntemler, Coulomb sayma ve ADG gibi doğrudan ölçüm yöntemlerine karşı daha güvenilir şarj durum tahminleri vermektedir.

Temel yaklaşımlardan biri olan Model Tabanlı Yöntemlerde, bataryaların elektriksel davranışını yansıtan ve bataryanın devre eşdeğerlerini oluşturan bileşenler aracılığıyla matematiksel modeller kullanılmaktadır. Bu kapsamda eşdeğer devre modeli (ECM) ve elektrokimyasal modeller yaygın olarak kullanılmaktadır. Model tabanlı tahminlerin doğruluğu, model parametrelerinin gerçek batarya dinamiğini ne kadar iyi temsil ettiğine bağlıdır. Yani batarya modeli ne kadar iyi tanımlanmışsa, bu modeli kullanarak yapılan BŞD kestirimi de bir o kadar başarılı olacaktır.

Eşdeğer batarya modelleri, Adaptif Filtreleme Tabanlı Yöntemler (örneğin Kalman Filtresi ve varyasyonları) ile birleştirildiğinde çok daha iyi kestirim sonuçları sağlarlar. Bu yöntemlerde hem doğrudan hem de model tabanlı yaklaşımlar entegre edilerek system içindeki değişimlere otonom olarak uyum sağlanır. Bu algoritmalar akım, sıcaklık ve gerilim gibi batarya verilerini kullanarak sürekli olarak mevcut çıktıları değişen girişlere göre günceller. Aynı zamanda sistemdeki gürültüyü filtreler ve ölçüm verisiyle model tahminini sürekli karşılaştırarak optimum BŞD değerine yakınsar [45].

Batarya modellemek görüldüğünden çok daha zordur. Oluşturulan modeldeki bilinmezlikler, doğrusal olmayan davranışların tanımının zorluğu ve hatalar BŞD tahminini büyük ölçüde etkiler. Fiziksel modellemenin zor olduğu durumlarda ise Adaptif Yapay Zeka Tabanlı Yöntemler devreye girer. Yapay Sinir Ağları (YSA), Derin Öğrenme, Bulanık Mnatık (FL), Uzun Kısa Süreli Bellek Yöntemi (LSTM) ve Destek Vektör Makineleri (SVMs) gibi çeşitli yapay zeka teknikleri kullanılarak BŞD tahmini yapılır. Bu yöntemlerde bataryanın yüksek dereceden doğrusal olmayan (nonlinear) davranışlarını geniş veri setleri üzerinden öğrenir. Yapay zeka tabanlı yaklaşımlar, karmaşık kimyasal süreçleri matematiksel denklemlere dökmeden modelleme esnekliği sunar. Son olarak, Gelişmiş Algoritmalar, bu tekniklerin hibrit kombinasyonlarını kullanarak hem modelleme belirsizliklerini hem de sıcaklık değişimlerinin yarattığı sapmaları minimize etmeyi hedefler [46].

BŞD kestiriminde kullanılan dolaylı ölçüm metotlarının birbirleriyle karşılaştırılması Çizelge 3.1’de verilmiştir. Bu çalışmada kullanılan BŞD tahmin yöntemleri Genişletilmiş Kalman Filtresi (GKF) ve Uzun Kısa Süreli Bellek (LSTM) yöntemidir.


Çizelge 3.1: Batarya modelleme yöntemlerinin karşılaştırılması.

YÖNTEM	TEKNİKLER	AVANTAJLAR	DEZAVANTAJLAR
Model Tabanlı	ECM (Eşdeğer Devre Modeli), EChM (Elektrokimyasal Model)	Daha yüksek doğruluk, kompleks batarya davranışını modelleme	Karmaşık modeller, hesaplama gücü ve veri gereksinimi
Uyarlamalı Filtre Tabanlı	GKF (Genişletilmiş Kalman Filtresi), H_{∞} (H Sonsuzluk)	Gerçek zamanlı tahmin, gürültü ve hatalara direnç	Doğru batarya modeli gerektirir, bazı durumlarda karmaşık
Uyarlamalı Yapay Zeka Tabanlı	GA (Genetik Algoritma), YSA (Yapay Sinir Ağları), DL (Derin Öğrenme), FL (Bulanık Mantık), LSTM (Uzun Kısa Süreli Bellek)	Karmaşık ilişkileri öğrenme, yüksek doğruluk potansiyeli	Eğitim verileri gerektiriyor, model seçimi ve ayarlama zorlukları
Gelişmiş Algoritmalar	DNN (Derin Sinir Ağları), TCN (Zamansal Evrişim Ağı), NN-KF (Sinir Ağları-Kalman Filtresi)	Daha yüksek doğruluk, farklı yöntemlerin avantajlarını birleştirir	Karmaşık yapı, uygulama zorlukları

3.3 Çalışmada Kullanılan Şarj Durum Tahmin Yöntemleri

3.3.1 Genişletilmiş kalman filtresi (GKF)

Literatürde ve uygulamalarda en çok kullanılan yöntemlerin başında Genişletilmiş Kalman Filtresi (GKF) gelmektedir. GKF geleneksel Kalman Filtresinin (KF) değiştirilmiş bir biçimi olup doğrusal olmayan sistemlere uyarlanır. Standart KF, doğrusal sistem modelleriyle sınırlıdır, oysa birçok pratik mühendislik sistemi doğrusal olmayan davranış sergiler. LFP gibi lityum-iyon batarya sistemleri de elektrokimyasal süreçler, sıcaklık etkileri ve yaşlanma gibi faktörlerden dolayı doğrusal olmayan davranışlar gösterdiklerinden dolayı GKF kullanımı gereklidir. GKF algoritması, doğrusal olmayan batarya modeline dayalı olarak sistemin iç durumlarını tahmin ederken, ölçüm verilerini istatistiksel olarak birleştirerek ölçüm gürültülerinin etkisini azaltmayı hedefler [39]. GKF algoritması, tahmin (predict) ve düzeltme (correct) olmak üzere iki temel adımdan oluşur. GKF algoritmasının tasarım konsepti Şekil 3.4' teki gibidir.



Şekil 3.4 : Genişletilmiş kalman filtresi (GKF) algoritması.

GKF algoritmasını kullanmak için öncelikle doğrusal olmayan sistemin durum uzay gösterimini elde etmek gerekir. GKF’de kullanılmak üzere doğrusal olmayan durum uzay geçiş (f) ve ölçüm (g) fonksiyonlarının matematiksel ifadesi denklem 3.3 ve 3.4’de gösterilmiştir [47].

$$x_k = f(x_{k-1}, u_{k-1}) + W_k \quad (3.3)$$

$$z_k = g(x_k, u_k) + V_k \quad (3.4)$$

Denklem 3.3’ te x_k durum vektörünü; u_k kontrol girdisini; W_k süreç (process) gürültüsünü ifade etmektedir. Denklem 3.4’ te ise z_k ölçüm fonksiyonunu ve V_k ölçüm (measurement) gürültüsünü ifade etmektedir. W_k ve V_k gürültüleri genellikle sırasıyla Q ve R kovaryanslarıyla ifade edilmektedir. Her iki gürültü de birbirinden bağımsız, ortamları sıfır olan Gauss gürültüleridir [47].

Doğrusal olmayan durum geçiş ve ölçüm fonksiyonları için algoritmada kullanılmak üzere öncelikle doğrusallaştırma işlemi yapılmaktadır. Doğrusallaştırma işlemi durum değişkenlerine göre kısmi türevler alınarak ve birinci mertebeden Taylor serisi açılımını kullanarak gerçekleştirilir. Denklem 3.5’ te gösterilen F_k Jacobian matrisi, $f(.)$ fonksiyonunun x_k ’ ye göre kısmi türevi alınarak elde edilirken; Denklem 3.6’ da gösterilen H_k Jacobian matrisi ise $g(.)$ fonksiyonunun x_k ’ ye göre kısmi türevi alınarak elde edilir [47].

$$F_k = \left. \frac{\partial f(x_k, u_k)}{\partial x_k} \right|_{x_k = \hat{x}_k} \quad (3.5)$$

$$H_k = \left. \frac{\partial g(x_k, u_k)}{\partial x_k} \right|_{x_k = \hat{x}_k} \quad (3.6)$$

Algoritmanın tahmin aşamasında sistemin bir sonraki zaman adımındaki durumu (3.4) ve hata kovaryansı (3.5) mevcut bilgilerle tahmin edilir.

$$\hat{x}_{k|k-1} = f(\hat{x}_{k-1|k-1}, u_{k-1}) \quad (3.4)$$

$$P_{k|k-1} = F_k P_{k-1|k-1} F_k^T + Q_k \quad (3.5)$$

Denklem 3.4’ te $\hat{x}_{k|k-1}$ sistemin bir sonraki zaman adımında hangi durumda olabileceğini belirten durum tahminini, $P_{k|k-1}$ ise hata kovaryansını temsil etmektedir. Hata kovaryansı sistemin belirsizliğini temsil eder. Düzeltme adımında ise ölçüm verileri kullanılarak durum tahmininin güncellenerek iyileştirilmesi hedeflenmektedir.

Bu aşamada algoritma oluşturulan sistem modeline mi yoksa ölçüm verilerine mi daha çok güvenmesi gerektiği konusunda karar vermeye çalışır. Böylelikle Kalman kazancı hesaplanır (3.6).

$$K_k = P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R_k)^{-1} \quad (3.6)$$

Ardından GKF algoritması sistem durum vektörünü ve hata kovaryansını, ölçüm vektörü ve Kalman kazancı kullanılarak devamlı olarak günceller (3.7) – (3.8). Denklem 3.8’ de I birim matristir.

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k (z_k - h(\hat{x}_{k|k-1})) \quad (3.7)$$


$$P_k = (I - K_k H_k) P_{k|k-1} \quad (3.8)$$

3.3.2 Uzun kısa süreli bellek yöntemi (LSTM)

Model tabanlı uyarlamalı adaptif çalışmalar BŞD tahmininde iyi sonuçlar verse de batarya modelindeki hatalar, histerezis etkisi ve yakalanamayan diğer doğrusal olmayan dinamik davranışlar nedeniyle uyarlanabilir yapay zeka tabanlı algoritmalar BŞD tahmininde kullanılmaktadır. BŞD tahmininin bir zaman serisi tahmini problem olduğunu söyleyebiliriz. Bu bağlamda, zaman serisi verilerindeki uzun dönemli bağımlılıkları öğrenme yeteneğine sahip, tekrarlayan sinir ağlarının (RNN) gelişmiş yöntemlerinden biri olan uzun kısa süreli bellek yöntemi (LSTM) bu çalışmada BŞD tahmininin geliştirilmesi için kullanılmıştır.

LSTM’ in BŞD tahmini gibi zamana dayalı çalışmalarda bu kadar popüler olmasının nedeni uzun zaman serilerinde standart RNN’lerde karşılaşılan gradyan sönümlemesi (gradient vanishing) probleminin üstesinden gelmesidir [17]. Ayrıca standart tekrarlayan sinir ağlarından (RNN) farklı olarak LSTM ağları, özel hücre yapıları sayesinde hata sinyalinin kararlı biçimde iletilmesini sağlayarak, uzun zaman aralıklarında bilgi kaybı olmadan öğrenme yapılmasına olanak tanır [48].

Bir LSTM hücre birimi mimarisi, unutma kapısı (forgetting gate), giriş kapısı (input gate) ve çıkış kapısından (output gate) oluşur. LSTM hücre yapısı Şekil 3.5’ te gösterilmiştir. Bu yapı içerisinde unutma kapısı, sigmoid aktivasyon fonksiyonu aracılığıyla önceki hücre durumundan hangi bilgilerin korunacağına veya silineceğine karar verir [49].



Şekil 3.5 : LSTM hücresi [50].

Denklem 3.9’ da f_t t anında unutma kapısı çıktısını temsil eder ve 0 ile 1 aralığında değer alır. Değer sıfıra yaklaştıkça bilginin silinmesini, 1’e yaklaştıkça da bilginin korunması gerektiği anlamını ifade eder. Sigmoid σ aktivasyon fonksiyonunu temsil eder ve $[0, 1]$ aralığında değer alır. Unutma kapısı için öğrenilebilir ağırlık ve bias terimleri ise sırasıyla W_f ve b_f ile gösterilir. Giriş vektörü x_t ile ve önceki giriş durumu h_{t-1} ile gösterilmiştir.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.9)$$

Giriş kapısı ise yeni bilgilerin hücre belleğine hangi ölçüde ekleneceğini belirler. Bu süreç iki aşamalı olarak gerçekleştirilir: öncelikle sigmoid fonksiyonu kullanılarak eklenecek bilginin ağırlığı belirlenir, ardından tanh aktivasyon fonksiyonu yardımıyla hücre belleğine aktarılacak aday değerler oluşturulur. Unutma ve giriş kapılarının çıktıların birleşimiyle hücre belleği güncellenir [49]. Denklem 3.10’ da görüldüğü gibi giriş kapısı çıktısı i_t hesaplanır.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.10)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.11)$$

Denklem 3.11’de de görüldüğü gibi çıkış kapısı o_t hücre belleğindeki bilginin ne kadarının ağ çıktısına yansıtılacağını belirleyerek LSTM biriminin çıktısını üretir [49].



4. BATARYA HÜCRE MODELLEMESİ


Bataryaların elektrokimyasal yapılarından dolayı sergilemiş oldukları karmaşık iç dinamik davranışları anlamlandırmak kolay değildir. Bataryaların fiziksel özelliklerine göre modellemeler yapılarak bu davranışları yansıtan benzetimler oluşturulmaktadır. Bu benzetimler elektrokimyasal modeller, elektriksel eşdeğer devre modelleri, ve veri odaklı modeller olmak üzere üç ana başlıkta incelenebilir. Elektrokimyasal modeller, batarya hücresi içerisinde gerçekleşen fiziksel ve kimyasal olaylara odaklanarak davranışları yansıtmaya çalışır. Eşdeğer devre modelleri ise soyut matematiksel modellerdir. Veri odaklı modeller ise çeşitli yapay zeka modelleriyle elde edilen deneysel parametreler sayesinde batarya davranışını taklit eden modellerdir.

4.1 Elektrokimyasal Devre Modeli

Elektrokimyasal modeller, lityum-iyon bataryaların iç yapısında gerçekleşen iyon taşınımı, difüzyon süreçleri ve elektrot–elektrolit arayüzündeki reaksiyonları fizik temelli olarak tanımlar. Elektrot ve elektrolit içerisindeki bu süreçler genellikle zamana bağlı kısmi diferansiyel denklemlerle ifade edilir. Ancak bu denklemler analitik olarak çözülemedikleri için çeşitli sayısal yöntemlerle adi diferansiyel denklemlere indirgenmeleri gerekir. Her ne kadar elektrokimyasal modeller bataryanın fiziksel davranışını iyi yansıtsa da, bu durum, hesaplama açısından oldukça karmaşık ve maliyetlidir [50]. Ayrıca çok fazla değişken parametre hesaplama zorluğu bulunduğu ve simülasyon süresinin uzun olmasından dolayı BYS’lerin tercih edeceği modeller değildir.

Literatürde lityum-iyon bataryaların davranışlarını temsil etmek amacıyla en yaygın olarak Pseudo-2D (P2D) modeli kullanılır (Şekil 4.1). Pseudo-2D modeli, gözenekli elektrot ve konsantre çözelti teorisine dayanarak elektrotlar ve ayırıcı bölge içindeki fiziksel ve kimyasal süreçleri ayrıntılı biçimde açıklar. Yüksek doğruluğu sayesinde


P2D modeli, hem batarya mekanizmasının analizi hem de batarya yönetim sistemlerinde referans model olarak yaygın biçimde kullanılmaktadır [51].



Şekil 4.1 : Pseudo-2D modeli [51].

4.2 Veri Odaklı Modeller

Batarya sisteminin iç dinamikleri hakkında herhangi bir bilgiye sahip olmadan sadece deneysel verilere odaklı geliştirildikleri için kara kutu modelleri de denir. Veri odaklı modeller genellikle bulanık mantık ve makine öğrenmesi metotları kullanılarak geliştirilir. Eğitim verileri şekil 4.2’ de görüldüğü gibi akım, sıcaklık, gerilim ve BŞD gibi bataryanın çalışmalarını kapsayan ölçümlerin geçmiş verileriyle doğrudan ilgilidir. Batarya davranışını sağlam ve güvenilir şekilde yansıtan bir kara kutu modelinin geliştirilmesi için çok fazla deney yapılması ve yeterli bir veritabanı oluşturulması gerekmektedir.



Şekil 4.2 : Kara kutu model oluşturma süreci.

4.3 Elektriksel Eşdeğer Devre Modelleri


Elektriksel eşdeğer devre modelleri, bataryaların elektriksel davranışını simüle etmek için ideal gerilim kaynağı, direnç ve kapasitör gibi devre elemanlarıyla oluşturulan matematiksel modellerdir. Elektrokimyasal modellere kıyasla oldukça basit olmasına rağmen batarya modelinin doğruluğu başarılıdır. Bu modeller için gerekli olan hesaplama gücü ve simülasyon süresi diğer modellere kıyasla düşüktür. Elektriksel eşdeğer devre modellerinin temelinde bataryanın şarj durumu ile doğrudan ilişkili bir gerilim kaynağı bulunur. Gerilim kaynağı bataryanın iç direnci üzerinden akan akımın neden olduğu gerilim düşüşleriyle birlikte bataryanın açık devre voltajını temsil eder. Bu yapı eşdeğer devre modellerinin en basit hali olan ve bir iç dirençle ifade edilen Rint modeli temsil eder. Ancak Rint model karmaşık yük profilleri ve değişken lityum-iyon batarya elektrokimyasal süreçlerini yansıtmada yetersiz kalmaktadır. Bu nedenle bu modellerin doğruluğunu arttırmak için bir ya da daha fazla direnç-kapasitör (RC) devresi eklenir. Devreye eklenen RC kısımları bataryanın elektrokimyasal olaylarını ve polarizasyon etkisini temsil etmek için kullanılır. Eklenen her bir RC devresi modelin doğruluğunu arttırdığı ölçüde karmaşıklığını da arttırmaktadır. Bu nedenle uygulamada kullanılacak batarya eşdeğer modeli seçilirken, modelin karmaşıklığı ve model doğruluğu arasında bir denge kurularak karar verilmesi gerekmektedir. Çeşitli elektriksel eşdeğer devre modelleri geliştirilmiştir. Bunlardan en yaygın olarak kullanılanları Rint model, Thevenin model ve Çift Polarizasyon (DP) modelidir. Bu çalışmada LFP bataryanın model dinamiklerini iyi yansıttığı ve model karmaşıklığının optimum seviyesinde olması nedeniyle Çift Polarizasyon (DP) modeli tercih edilmiştir.

4.3.1 Rint modeli

Rint modeli aynı zamanda sıfırıncı dereceden eşdeğer devre modeli olarak da adlandırılır. Şekil 4.3' te de görüldüğü gibi Rint modeli en basit eşdeğer devre modelidir. Model batarya iç direncini temsil eden R_0 ve açık devre gerilimini temsilen U_{OCV} hem şarj durumunun hem de sıcaklığın bir fonksiyonudur.

$$U_T(t) = U_{OCV}(t) - I_L(t) \cdot R_0 \quad (4.1)$$


Devreden geçen yük akımı $I_L(t)$ ise şarj sırasında negatif, deşarj sırasında pozitifdir. Terminal gerilim U_T ise ohm yasasına göre hesaplanır (4.1).



Şekil 4.3 : Rint modeli.

4.3.2 Thevenin modeli

Thevenin modeli, birinci dereceden eşdeğer devre modeli olarak da adlandırılır. Thevenin modeli, anlık (ohmik) ve gecikmeli (kapasitif) gerilim değişimlerini temsil eder. Şekil 4.4’ te de görüldüğü gibi Rint modelindeki iç direncine paralel bir RC elemanı seri bağlanarak oluşturulur [52].



Şekil 4.4 : Thevenin modeli.


Eklenen RC bağlantısıyla birlikte bataryanın elektriksel davranışı daha doğru simüle edilir. Rint modelinde göz ardı edilen polarizasyon etkileri ve şarj-deşarj döngüsünde oluşan geçici tepkilerin de dikkate alınır. Eklenen RC devresi akım çekildiğinde oluşan gecikmeli gerilim düşüşlerini modeller. Şekil 4.4' te görüldüğü gibi U_1 RC devresinin iki ucu arasında oluşan gerilimi temsil eder. Denklem 4.2' de U_1 geriliminin yük akımı, polarizasyon dirençleri ve kapasitansları bakımından matematiksel ifadesi yer almaktadır. Terminal gerilim, iç direncin yanı sıra RC devresi de dikkate alınarak hesaplanır (4.3).

$$\frac{d}{dt}U_1(t) = -\frac{1}{R_1C_1}U_1(t) + \frac{1}{C_1}I_L(t) \quad (4.2)$$

$$U_T(t) = U_{OCV}(t) - I_L(t) \cdot R_0 - U_1(t) \quad (4.3)$$

4.3.3 Çift polarizasyon modeli (DP)

Çift Polarizasyon modeli ikinci dereceden Thevenin eşdeğer devre modeli olarak da bilinir. Thevenin modeline bir RC kolu eklenerek elde edilir. Bataryanın geçici davranışını ve polarizasyon davranışlarını daha iyi yansıtır ancak parametre sayısı arttığı için Thevenin modeline göre daha karmaşıktır. Şekil 4.5' te DP devre modeli gösterilmiştir.



Şekil 4.5 : Çift Polarizasyon (DP) modeli.

Çift polarizasyon modeli, iki farklı zaman sabitine sahip RC kolları sayesinde bataryanın hem hızlı hem de yavaş dinamik gerilim tepkilerini daha gerçekçi şekilde temsil eder [52]. Bu nedenle literatürde model tabanlı BŞD tahmini çalışmalarında en sık kullanılan modeldir. Her bir RC kolu üzerine düşen gerilimlerin matematiksel ifadeleri denklem 4.4’ te gösterilmektedir. DP modelinin dinamik denklemleri Kirchhoff’un kuralları uygulanarak ifade edilir (4.5) - (4.6).

$$\frac{d}{dt}SOC(t) = -\frac{1}{C_b}I(t) + w_1(t) \quad (4.4)$$

$$\frac{d}{dt}U_1(t) = -\frac{1}{R_1C_1}U_1(t) + \frac{1}{C_1}I_L(t) + w_2(t) \quad (4.5)$$

$$\frac{d}{dt}U_2(t) = -\frac{1}{R_2C_2}U_2(t) + \frac{1}{C_2}I_L(t) + w_3(t)$$

$$U_T(t) = U_{OCV}(t) - I_L(t). R_0 - U_1(t) - U_2(t) + v(t) \quad (4.6)$$

Bu çalışmada DP model üzerinde çalışılmıştır. DP batarya model parametrelerini elde etmek için kullanılacak FFRLS algoritmasında ve ardından şarj durum tahmini için kullanılacak GKF algoritmasında, sistemin ayrık durum uzay denklemlerini kullanmak gereklidir. Denklem 4.4’ teki BŞD gösterimi denklem 3.1’ deki ifadenin türevi alınarak elde edilmiştir. Denklemlerde $w(t) = [w_1(t) \ w_2(t) \ w_3(t)]^T$ süreç gürültüsü, $v(t)$ ise ölçüm gürültüsüdür. Her ikisi de sıfır ortalamalı ve birbirinden bağımsız Gauss gürültüleridir.

Gerçek bir bataryada, model parametreleri sabit değillerdir. Parametreler BŞD ve sıcaklığa bağlıdır. Testler sabit ortam sıcaklıklarında kontrollü koşullar altında gerçekleştirildiğinden, model parametreleri yalnızca BŞD’ ye bağlı olarak dikkate alınmışlardır. Parametreler BŞD’ nin bir fonksiyonu olduğu için batarya modeli, doğrusal olmayan bir sistemdir. DP modeli için doğrusal olmayan sürekli zaman gösteriminin genel ifadesi 4.7 ve 4.8’ de ifade edilir

$$\dot{x}(t) = f(x(t), u(t)) + w(t) \quad (4.7)$$

$$y(t) = h(x(t), u(t)) + v(t) \quad (4.8)$$

Modelin durum vektörü $x(t)$, bataryanın şarj durumunu ve iki adet RC dalına ait gerilimleri içerecek şekilde tanımlanmıştır (4.9). Birinci RC dalına ait gerilim U_1 , hızlı dinamikleri ve aktivasyon polarizasyonunu, ikinci RC dalına ait gerilim U_2 ise daha

yavaş dinamikleri ve difüzyon polarizasyonunu temsil etmektedir. Sistem matrisi A , RC dallarına ait zaman sabitlerini (τ_1, τ_2) tanımlanmıştır (4.10). Bu ifadeler, RC gerilimlerinin zamanla sönümlenen bir yapıya sahip olduğunu göstermektedir.

$$x(t) = \begin{bmatrix} SOC(t) \\ U_1(t) \\ U_2(t) \end{bmatrix}; A = \begin{bmatrix} 0 & 0 & 0 \\ 0 & -\frac{1}{\tau_1} & 0 \\ 0 & 0 & -\frac{1}{\tau_2} \end{bmatrix}; B = \begin{bmatrix} -\frac{1}{C_b} \\ \frac{1}{C_1} \\ \frac{1}{C_2} \end{bmatrix} \quad (4.9)$$

$$R_0 = R_0(SOC); R_1 = R_1(SOC); R_2 = R_2(SOC) \quad (4.10)$$

$$\tau_1 = R_1 C_1; \tau_2 = R_2 C_2; u(t) = I(t) \quad (4.11)$$

$$y(t) = U_0(t) = U_{oc}(SOC(t)) - U_1(t) - U_2(t) - I(t)R_0 + v(t) \quad (4.12)$$

Modelin giriş matrisi, uygulanan akımın BŞD ve RC gerilimleri üzerindeki etkisini tanımlamaktadır. Burada batarya kapasitesi C_b , BŞD'nin zamana göre değişimini belirlerken; C_1 ve C_2 parametreleri RC dallarının dinamik tepkisini belirlemektedir (4.9). Model giriş değişkeni olarak batarya akımı $I(t)$ kullanılmıştır (4.11). Bataryanın ohmik direnci R_0 ile birlikte RC dallarına ait direnç ve kapasitans değerlerinin BŞD'ye bağlı olarak değiştiği kabul edilmiştir (4.10). Bu durum, batarya modelinin doğrusal olmayan bir yapıya sahip olduğunu göstermektedir. Ölçüm vektörü $y(t)$, terminal geriliminin açık devre geriliminden (ADG) polarizasyon gerilimleri ve ohmik gerilim düşüşlerinin çıkarılmasıyla elde edildiğini ifade etmektedir (4.12). ADG, BŞD'nin bir fonksiyonu olarak tanımlanırken, ölçüm denklemi içerisine eklenen gürültü terimi $v(t)$ sensör ve ölçüm belirsizliklerini temsil etmektedir.

Sürekli zamanlı durum uzay denklemleri, belirlenen örnekleme periyodu kullanılarak ayrık zamanlı forma dönüştürülmüştür. Ayrık zamanlı durum uzay genel denklemleri 4.13, 4.14 ve 4.15' te ifade edilmiştir. Sürekli zamanlı modelde tanımlanan RC dallarına ait zaman sabitleri, denklem 4.16' teki gibi ayrık zamanlı formda üstel katsayılar ile ifade edilmiştir. Bu işlem sonucunda elde edilen üstel katsayılar, RC gerilimlerinin her örnekleme adımında nasıl evrildiğini göstermekte; giriş katsayıları ise akımın RC dalları üzerindeki ayrık zamanlı etkisini ifade etmektedir (4.17). Ayrık zamanlı ölçüm denklemi ise batarya terminal gerilimini tanımlamaktadır (4.18). Sonuç olarak elde edilen ayrık durum uzay modeli, GKF ve FFRLS gibi çevrim içi kestirim algoritmalarının uygulanabilmesi için uygun bir matematiksel altyapı sunmaktadır.

$$x(k+1) = f_d(x(k), u(k)) + w(k) \quad (4.13)$$

$$y(k) = h_d(x(k), u(k)) + v(k) \quad (4.14)$$

$$\begin{bmatrix} SOC(k+1) \\ U_1(k+1) \\ U_2(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & a_1 & 0 \\ 0 & 0 & a_2 \end{bmatrix} \begin{bmatrix} SOC(k) \\ U_1(k) \\ U_2(k) \end{bmatrix} + \begin{bmatrix} -\frac{T_s}{C_b} \\ b_1 \\ b_2 \end{bmatrix} I(k) + w(k) \quad (4.15)$$

$$a_1 = e^{-\frac{T_s}{\tau_1}}; a_2 = e^{-\frac{T_s}{\tau_2}} \quad (4.16)$$

$$b_1 = R_1 \left(1 - e^{-\frac{T_s}{\tau_1}} \right); b_2 = R_2 \left(1 - e^{-\frac{T_s}{\tau_2}} \right) \quad (4.17)$$

$$y(k) = U_0(k) = U_{oc}(SOC(k)) - U_1(k) - U_2(k) - I(k)R_0 + v(k) \quad (4.18)$$

4.4 Batarya Model Parametrelerinin Bulunması

Bu çalışmada kullanılan deneysel ham veriler, Phillip Kollmeyer Research Group tarafından oluşturulan ve Mendeley Data platformunda paylaşılan açık erişimli lityum-iyon batarya veri setinden alınmıştır [53]. Veri seti; akım, gerilim, sıcaklık ve batarya şarj durumu gibi batarya modelleme ve durum tahmini çalışmalarında yaygın olarak kullanılan ölçümleri içermektedir. İlgili veri seti, batarya modelleme ve batarya şarj durum tahmini doğrulama çalışmalarında literatürde sıkça kullanılan güvenilir bir referans niteliğindedir. Testler için, LFP, NCA ve NMC gibi farklı kimyasallara sahip 18650 hücreler, Neware BTS 4000 pil test cihazı ile ESPEC SU-241 sıcaklık odası kullanılarak kontrollü sıcaklıklar altında test edilmiştir.

Çalışmada seçilen A123 tipi LFP batarya üç farklı sıcaklık altında (5°C, 25°C, ve 45°C) çeşitli test prosedürleri uygulanarak test edilmiştir. Deney sürüş protokolleri 1 saniyelik örnekleme periyotlarında çeşitli test senaryoları içermektedir. Test prosedürleri düşük akım ADG-BŞD testleri, Dinamik Stres Testi (DST), Federal Kentsel Sürüş Programı (FUDS), Otoyol Sürüş Programı (US06), Dünya Çapında Uyumlaştırılmış Hafif Araçlar Test Prosedürü (WLTP) ve Hibrit Güç Darbe Karakterizasyonu (HPPC) içermektedir. Test verileri excel formatında kaydedilip,

hücre gerilimi, akım, sıcaklık, güç, enerji ve kapasite gibi ölçümleri içermektedir. Çalışmada kullanılan LFP tipi bataryanın özellikleri Çizelge 4.1’ de verilmiştir.

Çizelge 4.1 : Çalışmada kullanılan batarya özellikleri.

Karakteristik	Nominal Gerilim (V)	Nominal Kapasite (Ah)	Üst Kesme Gerilimi (V)	Alt Kesme Gerilimi (V)
LiFePO ₄	3.3 V	2.6 Ah	3.6 V	2.0 V

4.4.1 ADG-BŞD karakterizasyonu

LFP bataryanın %20-%80 BŞD aralığında neredeyse düz olan ADG-BŞD ilişkisi zayıf gözlemlenebilirliğe neden olmakta ve şarj durumunu zorlaştırmaktadır. Öncelikle bataryanın farklı sıcaklıklardaki ADG-BŞD ilişkisi çıkarılmıştır. ADG-BŞD ilişkisi, bataryanın denge durumundaki termodinamik karakteristiğini temsil ettiğinden, polarizasyon etkilerinin minimum olduğu düşük akımlı ADG testleri kullanılarak elde edilmiştir [14].


Bu çalışmada, batarya düşük akımlı deşarj sırasında belirli BŞD adımlarında dinlenmeye bırakılmış, her BŞD seviyesinde akım kesilerek gerilim kararlı hale geldikten sonra ölçülen değer ADG olarak kabul edilmiştir. Elde edilen ADG-BŞD veri noktaları enterpolasyon yöntemiyle birleştirilerek ADG-BŞD eğrisi oluşturulmuştur. Eğrinin matematiksel temsili için MATLAB ortamında polinom yaklaştırma yöntemi kullanılmış, BŞD değişkeni sayısal kararlılığı artırmak amacıyla normalize edilmiştir. Polinom derecesi, model doğruluğu ve sayısal kararlılık dikkate alınarak hata analiziyle belirlenmiştir.

LFP bataryaların geniş plato bölgesi nedeniyle ADG-BŞD eğrisinin düşük dereceli polinomlarla yeterince temsil edilememesi sebebiyle, hata ve kararlılık dengesi gözetilerek 8. derece polinom tercih edilmiştir. Analizin ardından üç sıcaklık değeri için ADG-BŞD tablosu oluşturulmuştur. Çizelge 4.2’ de üç sıcaklık için aynı ADG gerilimlerine denk gelen BŞD değerleri gösterilmiştir.

Çizelge 4.2 : Her sıcaklıkta belirli ADG değerlerine karşılık gelen BŞD değerleri.

ADG-T-BŞD	ADG 3.33 V	ADG 3.31 V	ADG 3.30 V	ADG 3.28 V
5°C	0.89	0.71	0.59	0.34
25°C	0.85	0.66	0.56	0.33
45°C	0.84	0.63	0.55	0.32

Çizelge 4.2’ de görüldüğü gibi BŞD seviyesi düşmesine karşın ADG değerlerindeki değişim çok sınırlıdır. 25°C için oluşturulan ADG-BŞD eğrisi Şekil 4.6’ da verilmiştir.



Şekil 4.6 : ADG – BŞD eğrisi


Şekil 4.6’ da görüldüğü gibi mavi ile gösterilen şarj eğrisi, kırmızı ile gösterilen deşarj eğrisinden her zaman üsttedir. Literatürde bu histerezis (genelde ihmal edilen) etkisi olarak açıklanır. Bu çalışmada histerezis etkisi ihmal edilerek eğrilerin ortalaması alınarak simülasyonlara devam edilmiştir.

4.4.2 Hibrid güç darbe karakterizasyon testi (HPPC)

Hibrid güç darbe karakterizasyon (HPPC) testi, bataryanın dinamik davranışlarını ve güç karakteristiklerini belirlemek amacıyla yaygın olarak kullanılan standart bir test

yöntemidir. Bu testte batarya, farklı BŞD seviyelerinde belirli genlik ve sürelerle sahip şarj ve deşarj akım darbelerine maruz bırakılır. Her akım darbesi sonrasında bataryanın kısa süreli ve uzun süreli gerilim tepkileri gözlemlenir. Bu yapı sayesinde ohmik direnç, hızlı ve yavaş polarizasyon etkileri gibi batarya model parametreleri ayrıştırılabilir şekilde uyarılmış olur.

Çalışmadaki her bir HPPC döngüsü altı adımdan oluşur. İlk olarak, tam şarjlı durumdan başlayarak, batarya 10 saniye boyunca 1,5C ile boşaltılır. Bunu 180 saniyelik bir dinlenme süresi izler. Ardından, 1,5C ile 10 saniyelik bir şarj darbesi uygulanır ve ardından bataryanın tekrar 180 saniye dinlenmesine izin verilir. Ardından, batarya 720 saniye boyunca 0,5C ile boşaltılır. Son olarak, döngü 1 saatlik bir dinlenme süresi ile sona erer. Kısaca batarya hücrelerine bu akım darbeleri uygulanarak, tam şarjlı bir hücrenin şarj durumu tamamen boşalana kadar %10'luk adımlarla azaltılır. Şekil 4.7' de 25°C için HPPC test profili gösterilmiştir. HPPC test verisi, unutma faktörü yinelemeli en küçük kareler metodunda kullanılacaktır.




Şekil 4.7 : 25°C için HPPC test profili.

4.4.3 Unutma faktörü yinelemeli en küçük kareler metodu (FFRLS)

Batarya, şarj ve deşarj sırasında karmaşık iç reaksiyonlara maruz kaldığı için, model parametreleri çeşitli faktörlerden etkilenebilir. Parametre değişimlerinden

kaynaklanan BŞD tahmin hatalarını azaltmak ve modelin doğruluğunu korumak için, parametrelerin çevrimiçi olarak tanımlanması ve gerçek zamanlı olarak güncellenmesi gerekir [17]. Yinelemeli En Küçük Kareler (RLS) metodu, hesaplama maliyetini artırmadan yeni veriler geldikçe parametre tahminlerini verimli bir şekilde güncelleyerek standart en küçük kareler yöntemini geliştirir. Ancak, birçok güncellemeden sonra parametreler yeni verilere duyarsız hale gelebilir. Bunu önlemek ve yeni verilerin parametre tahminlerini etkilemeye devam etmesini sağlamak için bir unutma faktörü (λ) kullanılır [13]. Böylece unutma faktörü yinelemeli en küçük kareler yöntemi (FFRLS) adı altında standart RLS algoritmasının gelişmiş bir versiyonu tanımlanır. Bu çalışmada, batarya parametrelerini gerçek zamanlı olarak tanımlamak ve güncellemek için unutma faktörü yinelemeli en küçük kareler yöntemi (FFRLS) kullanılmaktadır. FFRLS algoritmasının akış diyagramı gösterilmiştir Şekil 4.8’ de gösterilmiştir.



Şekil 4.8 : FFRLS algoritma akış diyagramı [39].

Denklem 4.19’ da $\hat{\theta}(k) = [k_1, k_2, k_3, k_4, k_5]$ vektörü FFRLS algoritması ile kestirilen eşdeğer devre modeline ait parametreleri içerir. Zamanla değişen batarya karakteristiklerine uyum sağlayacak şekilde çevrim içi olarak bu parametre vektörü güncellenir.

$$\hat{\theta}(k) = \hat{\theta}(k-1) + K(k)[y(k) - \Phi^T(k)\hat{\theta}(k-1)] \quad (4.19)$$

Regresyon giriş vektörü $\Phi(k) = [U_{(k-1)}, U_{(k-2)}, i_{(k)}, i_{(k-1)}, i_{(k-2)}]^T$, akım ve RC kollarına ait geçmiş gerilim durumlarından oluşmaktadır. Denklemde $U_{(k)} = U_{OC} - U_0$ Ayırık zamanlı ölçüm vektörü $y(k)$, 4.18’ de ifade edilmiş olup k anında ölçülen sistemin çıkışını ifade eder. Bataryaya uygulanan uyarımı ve sistemin geçmiş davranışını temsil ederek, parametrelerin gözlemlenebilirliğini sağlar. Denklem 4.20’

de gösterilen uyarlamalı kazanç vektörü $K(k)$, FFRLS algoritmasının yeni ölçüm bilgisine ne kadar ağırlık vereceğini belirleyerek, parametrelerin yalnızca anlamlı uyarımlar altında güncellenmesini sağlar. Yani kısaca öğrenme hızı ile gürültü bastırma arasında denge kurar.

$$K(k) = \frac{P(k-1)\Phi(k)}{\lambda + \Phi^T(k)P(k-1)\Phi(k)} \quad (4.20)$$

Parametre hata kovaryans matrisi $P(k)$ ise parametre kestirimine ait belirsizliği temsil eden hata kovaryans matrisidir (4.21). Algoritmanın yeni ölçümlere ne kadar duyarlı olacağını belirleyerek uyarlamalı kazanç vektörünün hesaplanmasında kullanılır.

$$P(k) = \frac{1}{\lambda} [I - K(k)\Phi^T(k)]P(k-1) \quad (4.21)$$

DP modelinin ayrık zamanlı durum uzay modeli 4.3.3' teki denklemlerle ifade edilmişti. Modelde yer alan zaman sabitlerinin ve dirençlerin daha kompakt bir biçimde ifade edilebilmesi amacıyla, bazı ara değişkenler tanımlanmıştır. Bu kapsamda, RC dallarına ait zaman sabitlerinin çarpımı ve toplamı sırasıyla a ve b parametreleri ile gösterilmiş; toplam direnç etkisi c değişkeni ile ifade edilmiştir (4.22). Ayrıca ohmik direnç ile RC dallarının zaman sabitlerinin birlikte etkisini temsil eden d parametresi tanımlanmıştır. Bu ara değişkenler sayesinde model denklemleri sadeleştirilmiş ve ayrık zamanlı forma dönüştürülmesi kolaylaştırılmıştır.

$$\begin{aligned} a &\triangleq \tau_1\tau_2; \quad b \triangleq \tau_1 + \tau_2; \\ c &\triangleq R_0 + R_1 + R_2; \end{aligned} \quad (4.22)$$

$$d = R_0(\tau_1 + \tau_2) + R_1\tau_2 + R_2\tau_1$$

Denklem 4.18' de Elde edilen sürekli zamanlı ifade, örnekleme periyodu (1 s) dikkate alınarak ayrık zamanlı bir fark denklemine dönüştürülmüştür. Bu ayrık zamanlı denklemde, açık devre gerilimi ile terminal gerilimi arasındaki fark, geçmiş iki zaman adımına ait gerilim farkları ve akım girdisinin mevcut ve geçmiş değerlerinin doğrusal bir kombinasyonu şeklinde ifade edilmiştir (4.23).

$$\begin{aligned} U(k) &= U_{oc}(k) - U_0(k) = k_1[U_{oc}(k-1) - U_0(k-1)] \\ &\quad + k_2[U_{oc}(k-2) - U_0(k-2)] \\ &\quad + k_3I(k) + k_4I(k-1) + k_5I(k-2) \end{aligned} \quad (4.23)$$

Bu yapı, RLS ve FFRLS algoritmalarının gerektirdiği doğrusal regresyon formunu sağlamaktadır. Denklem 4.24' te yer alan k_i katsayıları, ayırıklaştırma işlemi sonucunda elde edilen ve model parametrelerini dolaylı olarak temsil eden katsayılardır. Bu katsayılar, örnekleme periyodu ve tanımlanan ara değişkenler kullanılarak açık biçimde ifade edilmiştir.


$$\begin{aligned} k_1 &= \frac{2a + bT}{T^2 + bT + a} & k_2 &= \frac{-a}{T^2 + bT + a} \\ k_3 &= -\frac{aR_0 + dT + cT^2}{T^2 + bT + a} \\ k_4 &= \frac{2aR_0 + dT}{T^2 + bT + a} & k_5 &= -\frac{aR_0}{T^2 + bT + a} \end{aligned} \quad (4.24)$$

Böylece FFRLS algoritması yardımıyla çevrim içi olarak kestirilen k_i parametrelerinden, eşdeğer devre modeline ait fiziksel parametreler geri hesaplanabilmektedir. Bu amaçla, öncelikle ohmik iç direnç R_0 , kestirilen katsayılar kullanılarak doğrudan elde edilmiştir. Ardından, RC dallarına ait dirençler R_1 ve R_2 , zaman sabitleri ve tanımlanan ara değişkenler yardımıyla hesaplanmıştır (4.25). Son olarak, her bir RC dalına ait kapasitans değerleri, ilgili zaman sabitlerinin dirençlere oranlanmasıyla belirlenmiştir (4.25).

$$\begin{aligned} R_0 &= \frac{k_5}{k_2} \quad ; \quad R_1 = \frac{\tau_1 c + \tau_2 R_0 - d}{\tau_1 - \tau_2} \\ R_2 &= \frac{\tau_2 c + \tau_1 R_0 - d}{\tau_2 - \tau_1} \\ C_1 &= \frac{\tau_1}{R_1} \quad ; \quad C_2 = \frac{\tau_2}{R_2} \end{aligned} \quad (4.25)$$

Bu yaklaşım sayesinde, RLS tabanlı algoritma ile doğrudan kestirilen parametreler ile bataryanın fiziksel eşdeğer devre model parametreleri arasında açık ve sistematik bir ilişki kurulmuştur. Böylece, çevrim içi parametre kestirimi sonucunda elde edilen değerler fiziksel olarak anlamlı batarya parametrelerine dönüştürülerek modelin gerçekçi ve yorumlanabilir olması sağlanmıştır. Batarya parametrelerini uyarlamalı olarak kestirebilmek için, unutma katsayısı λ geçmiş ölçüm verilerine verilen ağırlığı belirleyen bir katsayı olarak kullanılır. Unutma katsayısı genellikle 0.9 ile 1.0 aralığında seçilir ve algoritmanın yakınsama hızı ile kararlılığı üzerinde doğrudan etkilidir. λ değerinin 1.0'a yakın olması, algoritmanın daha kararlı çalışmasını

sağlarken, hızlı değişen parametrelerin takibinde gecikmelere neden olabilmektedir. Bu çalışmada $\lambda=0.98$ olarak alınmıştır. Bu seçim, algoritmanın BŞD ve sıcaklığa bağlı olarak değişen batarya model parametrelerini takip edebilmesine olanak tanırken, aynı zamanda ölçüm gürültüsüne karşı aşırı duyarlı olmasını da engellemektedir. FFRLS (Forgetting Factor Recursive Least Squares) algoritması, zamana bağlı olarak değişen batarya model parametrelerinin çevrim içi kestirilmesine olanak tanıyan bir yöntemdir. Algoritmanın kararlı ve doğru sonuçlar üretebilmesi için yeterince zengin ve uyarıcı bir giriş sinyaline ihtiyaç vardır. Bu açıdan HPPC testi, içerdiği kontrollü akım darbeleri ve dinlenme periyotları sayesinde batarya modelinin ohmik direnç ve RC ağ parametrelerini etkin biçimde uyarmakta ve FFRLS algoritması için güvenilir bir başlangıç veri seti sunmaktadır. Buna karşılık DST (Dynamic Stress Test), gerçek kullanım koşullarına daha yakın dinamik akım profilleri içermekte olup, batarya parametrelerinin zamanla ve çalışma koşullarına bağlı değişimini gözlemlemek açısından önemlidir (Şekil 4.9).



Şekil 4.9 : 25°C için DST akım profili.


Bu çalışmada, FFRLS algoritmasının başlangıç parametreleri HPPC testleri kullanılarak belirlenmiştir. Başlangıç parametrelerinin seçimi sırasında, algoritmanın %100–%90 şarj durumu aralığında gerçekleştirdiği terminal gerilim kestirimleri esas alınmış ve Şekil 4.10’da sunulan sonuçlar değerlendirilmiştir. Bu kapsamda, algoritma

tarafından kestirilen terminal gerilimler ile deneysel olarak ölçülen terminal gerilimler karşılaştırılmış; karesel ortalama hatası (KOH) en düşük olan aşama başlangıç parametreleri için referans nokta olarak belirlenmiştir.

Belirlenen bu referans şarj durumu aralığı, terminal gerilim hatasının en küçük olduğu ve dolayısıyla kestirilen parametrelerin batarya dinamiğini en doğru şekilde temsil ettiği bölge olarak değerlendirilebilir. HPPC ve DST testlerinin tam şarjlı batarya ile başlatılması da, başlangıç parametrelerinin bu şarj durumu aralığında belirlenmesini destekleyen önemli bir gerekçedir. Böylece test koşulları ile parametre belirleme süreci arasında tutarlılık sağlanmıştır. Her ne kadar daha düşük şarj durumlarında (örneğin %60 şarj durumu seviyesinde) daha küçük karesel ortalama hata değerleri elde edilebilse de, batarya parametrelerinin şarj durumuna bağlı olarak değişkenlik göstermesi nedeniyle referans şarj aralığı olarak %100–%90 bandı tercih edilmiştir. Aksi halde, %100 ile %60 şarj durumu aralığında belirlenen parametreler arasında anlamlı farklılıklar oluşacak ve bu durum, batarya modelinin tutarlılığını olumsuz yönde etkileyecekti.

Başlangıç parametrelerinin elde edilmesinin ardından DST verisi ile algoritma çalıştırılarak model parametrelerinin gerçek sürüş koşullarına uyum sağlaması amaçlanmıştır. Bu yaklaşım sayesinde, FFRLS algoritmasının yakınsama hızı artırılmış, kararlılığı iyileştirilmiş ve elde edilen parametrelerin fiziksel olarak anlamlı olması sağlanmıştır. Şekil 4.10’ da 25°C DST testinin farklı BŞD seviyeleri için deneysel terminal gerilimi ile FFRLS algoritması kullanılarak elde edilen model çıktıları karşılaştırılmıştır. Orta BŞD aralığında model çıktılarının deneysel verilerle yüksek uyum gösterdiği, ani akım değişimlerine karşı oluşan ohmik ve polarizasyon kaynaklı gerilim düşüşlerinin doğru şekilde temsil edildiği gözlemlenmiştir.

Düşük BŞD bölgelerinde gözlenen sınırlı sapmalar ise bataryanın doğrusal olmayan karakteristiği, ADG-BŞD eğrisinin bu bölgelerdeki yüksek eğimi ve difüzyon sınırlamaları ile ilişkilendirilmektedir. Genel olarak sonuçlar, FFRLS algoritmasının batarya model parametrelerini BŞD boyunca kararlı ve fiziksel olarak anlamlı bir biçimde kestirebildiğini göstermektedir.



Şekil 4.10 : 25°C’de HPPC-DST-RLS algoritmasının terminal gerilim kestirimi.

DST testi tüm sıcaklıklar için FFRLS algoritmasında kullanılmış ve model parametreleri elde edilmiştir. Çizelge 4.3 ve çizelge 4.4’ te FFRLS sonucu kestirilen batarya model parametreleri belirli BŞD değerleri için gösterilmiştir.

Çizelge 4.3 : Belirli BŞD değerlerinde 25°C için kestirilen model parametreleri.

BŞD	$R_0(\Omega)$	$R_1(\Omega)$	$C_1(F)$	$R_2(\Omega)$	$C_2(F)$
%30	0.01674	0.0136	949	0.0130	11560
%50	0.01674	0.0144	949	0.0132	13456
%70	0.01675	0.0101	969	0.0174	18174

Çizelge 4.4 : Belirli BŞD değerlerinde 5°C için kestirilen model parametreleri.

BŞD	$R_0(\Omega)$	$R_1(\Omega)$	$C_1(F)$	$R_2(\Omega)$	$C_2(F)$
%30	0.01903	0.0215	655	0.0456	9860
%50	0.01906	0.0209	676	0.0325	9950
%70	0.01913	0.0211	685	0.0308	9960

5. ŞARJ DURUM TAHMİNİ SİMÜLASYON SONUÇLARI

Önce bataryanın farklı sıcaklıklardaki ADG-BŞD ilişkisi kuruldu. Ardından HPPC ve DST verileri FFRLS algoritmasında kullanılarak çift polarizasyon modeli için parametreler her bir sıcaklık değeri için belirlenmiştir. Bu veriler GKF algoritması için bilinmesi gereken girdilerdir. Bu veriler ışığında batarya önce GKF ile bataryanın şarj durum tahminini yapılacaktır. Ardından uzun kısa süreli bellek yöntemi ile GKF’de elde edilen tahminin iyileştirilmesi amaçlanacaktır.

5.1 Genişletilmiş Kalman Filtresi ile Şarj Durum Tahmini

Genişletilmiş Kalman Filtresi’nin tanımı ve algoritma denklemleri bölüm 3.3.1’ de ifade edilmiştir. Batarya modeli doğrusal olmayan bir sistem olduğundan dolayı doğrusallaştırmaya ihtiyaç duyulmaktadır. (3.3) ve (3.4)’ teki nonlinear f ve g fonksiyonlarının durum vektörü x_k (5.1)’ e göre birinci dereceden kısmi türevleri alınarak A_k (5.2) ve C_k (5.3) matrisleri; u_k (5.3)’ a göre türevleri alınarak B_k (5.4) ve D_k (5.5) matrisleri elde edilir.

$$x_k = [SOC \ U_{1,k} \ U_{2,k}] \quad (5.1)$$


$$A_k = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 - \frac{\Delta t}{R_1 C_1} & 0 \\ 0 & 0 & 1 - \frac{\Delta t}{R_1 C_1} \end{bmatrix} \quad (5.2)$$

$$B_k = \begin{bmatrix} \frac{\Delta t}{C_n} \\ \frac{\Delta t}{C_1} \\ \frac{\Delta t}{C_2} \end{bmatrix} \quad (5.3)$$


$$C_k = \begin{bmatrix} \frac{\partial OCV}{\partial SOC} \\ -1 \\ -1 \end{bmatrix} \quad (5.4)$$

$$D_k = [-R_0] \quad (5.5)$$

GKF algoritması, şarj durum tahmin doğrulaması için Otoyol Sürüş Programı (US06) ölçümü ile test edilmiştir. US06 testi, yüksek ve hızlı değişen akım profiliyle en zorlayıcı sürüş testlerinden birisi olduğundan dolayı validasyon için seçilmiştir. Bir US06 döngüsünün süresi 596 saniyedir. Her US06 döngüsünde, batarya akımının ortalaması 0,532 A'dır. US06 testinin akım profili Şekil 5.1'de ve gerilim profili Şekil 5.2' de gösterilmiştir. Akım profilinde pozitif akım deşarjı temsil etmektedir.




Şekil 5.1 : US06 akım profili 25°C



Şekil 5.2 : US06 gerilim profili 25°C


GKF algoritmasının uygulanabilmesi için başlangıç şarj durumu, bataryanın tam dolu olduğu varsayımıyla %100 olarak alınmıştır. Başlangıçta iç polarizasyonun bulunmadığı kabul edilerek U_1 ve U_2 durum değişkenleri 0 V olarak başlatılmıştır. Örnekleme periyodu, veri güncelleme hızına uyumlu olacak şekilde 1 saniye olarak

seçilmiştir. Sıcaklık ve BŞD'ye bağlı batarya model parametreleri, deneysel ölçüm verilerinden elde edilen referans tabloları (lookup table) kullanılarak dinamik olarak interpolate edilmiştir. Sistem durumlarına ait başlangıç belirsizliğini temsil eden durum hata kovaryans matrisi P_k , BŞD durumu için 0.025, polarizasyon gerilimleri U_1 ve U_2 için ise 0.01 olarak başlatılmıştır. Süreç gürültüsü kovaryans matrisi Q_k ile ölçüm gürültüsü kovaryans matrisi R_k 'nin uygun şekilde seçilmesi, batarya modelinin doğruluğuna ve ölçüm sensörlerinin karakteristiklerine güçlü biçimde bağlı olduğundan doğrudan belirlenmesi zor bir problemdir. Bu çalışmada süreç gürültüsü kovaryans matrisi, sezgisel ayarlama yaklaşımı kullanılarak $Q_k = \text{diag}[1e^{-6} \ 1e^{-5} \ 1e^{-4}]$ şeklinde seçilmiştir. U_2 durum değişkenine daha büyük bir varyans atanması, yavaş polarizasyon dinamikleri ile ilişkili belirsizliğin daha yüksek olduğunu yansıtmakta ve filtrenin difüzyon modelleme hatalarını daha agresif biçimde telafi edebilmesine olanak tanımaktadır. Ölçüm gürültüsü kovaryans matrisi R_k , terminal gerilim ölçümlerindeki gürültü seviyesini temsil edecek şekilde 0.01 V olarak belirlenmiştir. Bu nispeten muhafazakar seçim, özellikle LFP bataryaların düz ADG karakteristiği göz önünde bulundurulduğunda, kestiricinin küçük gerilim dalgalanmalarına aşırı tepki vermesini engelleyerek düzgün ve kararlı bir yakınsama sağlamaktadır. 25°C için şarj durum tahmini karşılaştırması Şekil 5.3' te gösterilmektedir.




Şekil 5.3 : 25°C - Batarya şarj durumu tahmin sonuçları.

BŞD tahmin hatası oranı yüzde olarak Şekil 5.4’ te görülmektedir. GKF’ den kestirilen terminal gerilim ile deneysel verinin karşılaştırılması Şekil 5.5’ te gösterilmiştir.




Şekil 5.4 : 25°C - Batarya şarj durumu hata yüzdesi.




Şekil 5.5 : 25°C - Terminal Gerilimlerin Karşılaştırılması.

Algoritma US06 5°C için ve FUDS 25°C için de test edilmiştir. Şekil 5.6'da US06 5°C için şarj durum tahmini karşılaştırması gösterilirken; Şekil 5.7'de FUDS 25°C şarj durum tahmini karşılaştırması gösterilmektedir.



Şekil 5.6 : 5°C - Batarya şarj durumu tahmin sonuçları.



Şekil 5.7 : FUDS 25°C - Batarya şarj durumu tahmin sonuçları.

5.2 LSTM Algoritması ile Şarj Durum Tahmininin İyileştirilmesi

Bu çalışmada BŞD kestirim doğruluğunu artırmak amacıyla, model tabanlı bir kestirim yöntemi olan Genişletilmiş Kalman Filtresi (GKF) ile veri güdümlü bir yöntem olan Uzun Kısa Süreli Bellek (LSTM) ağı birleştirilmiştir. Önerilen yaklaşım, batarya davranışını tamamen veri üzerinden öğrenmeye çalışan saf sinir ağı modellerinden farklı olarak, fizik tabanlı modelin sağladığı kararlılığı korumayı ve yalnızca modelin açıklayamadığı hata bileşenlerini öğrenmeyi hedeflemektedir. Bu nedenle geliştirilen yapı literatürde uygulamaları olan artık öğrenme (residual learning) olarak tanımlanabilir. LSTM ağı, BŞD'yi sıfırdan öğrenmek amacıyla değil, GKF tarafından üretilen BŞD kestirimindeki bu artık (residual) hataları telafi etmek üzere tasarlanmıştır. LSTM'nin girdi vektörü, her zaman adımında ölçülen terminal gerilim, ölçülen akım, ölçülen sıcaklık, GKF tarafından kestirilen BŞD ve terminal gerilim residual'ından oluşmaktadır (5.6). Terminal gerilim residual'ı, ölçülen gerilim ile GKF tarafından tahmin edilen gerilim arasındaki fark olarak tanımlanmıştır. Bu residual sinyali, fizik tabanlı modelin açıklamakta zorlandığı difüzyon etkileri, histerezis, parametre sürüklenmesi ve doğrusal olmayan davranışlar hakkında dolaylı bilgi taşımaktadır. Böylece LSTM'ye yalnızca ham ölçümler değil, aynı zamanda modelin nerede ve ne ölçüde yanıldığını gösteren açık bir hata bilgisi de sunulmuştur.

LSTM mimarisi, zamana bağlı etkileri etkin biçimde öğrenebilmek amacıyla ardışık veri işleme yapısında tasarlanmıştır. İki katmanlı LSTM yapısı kullanılmış olup, ilk katman daha uzun zaman ölçekli ve yavaş değişen dinamikleri (örneğin difüzyon ve sıcaklık etkileri) öğrenmeye, ikinci katman ise daha hızlı değişen hata bileşenlerini temsil etmeye yöneliktir. LSTM katmanlarını takiben kullanılan tam bağlantılı katmanlar, öğrenilen zamansal özelliklerin BŞD düzeltme değerine dönüştürülmesini sağlamaktadır. Ağın her zaman adımı için çıktı üretmesi, çevrim içi uygulamalarla uyumlu bir yapı elde edilmesine olanak tanımaktadır.


Eğitim sürecinde, farklı dinamik özelliklere sahip FUDS, Low Current-OCV ve DST sürüş döngülerine ait veriler kullanılmıştır. Her bir sürüş döngüsü öncelikle Genişletilmiş Kalman Filtresi (GKF) algoritması ile işlenmiş; bu aşamada batarya şarj durumu tahmini ve terminal gerilim rezidüel sinyali elde edilmiştir. Elde edilen bu veriler, LSTM ağının eğitimi ve doğrulaması için kullanılmıştır. Bu yaklaşım, ağın

yalnızca tek bir sürüş profiline özgü davranışları ezberlemesini önlemekte ve genelleme kabiliyetini artırmaktadır.

Test aşamasında ise, eğitim ve doğrulama süreçlerinde hiç kullanılmamış olan US06 sürüş döngüsü tercih edilerek, önerilen hibrit yapının daha önce görülmemiş bir profil üzerindeki performansı değerlendirilmiştir. Tüm giriş verileri, yalnızca eğitim verilerinden elde edilen istatistikler kullanılarak normalize edilmiş ve böylece veri sızıntısının (data leakage) önüne geçilmiştir.


$$X_{Train} = [U; I; T; SOC_{EKF}; V_{Residual}] \quad (5.6)$$

Hibrit GKF-LSTM yaklaşımının performansı değerlendirilmeden önce, karşılaştırma amacıyla yalnızca deneysel ölçüm verilerini kullanan saf bir LSTM modeli oluşturulmuştur. Bu model, FUDS, Low Current-OCV ve DST sürüş döngülerine ait verilerle eğitilmiş ve daha önce hiç görmediği US06 sürüş döngüsü üzerinde test edilmiştir (Şekil 5.8).




Şekil 5.8 : 25°C - US06 sürüş verisinin LSTM ile şarj durum tahmini.

25°C için US06 test verisi, oluşturulan hybrid GKF-LSTM algoritmasında test edilmiştir (Şekil 5.9). Şekil 5.10' da eğitim süreci gösterilmiştir.




Şekil 5.9 : US06 için Residual GKF-LSTM şarj durum tahmini karşılaştırması.



Şekil 5.10 : Eğitim süreci.

Oluşturulan hibrit algoritmanın sağlamlığını sınamak için FUDS verisi ile de test yapıp sonuçlar karşılaştırılmıştır (Şekil 5.11). Eğitim ve doğrulama sürecine US06, Low Current-OCV ve DST testleri dahil edilmiştir.



Şekil 5.11 : FUDS için Residual GKF-LSTM şarj durum tahmini karşılaştırması.

LSTM ağının hiperparametreleri, hesaplama maliyeti ve genelleme kabiliyeti göz önünde bulundurularak literatürde yaygın olarak kullanılan değerler ve ön deneyler doğrultusunda belirlenmiştir. LSTM katman sayısı ve gizli birim sayıları, batarya sistemlerinde gözlenen hem yavaş değişen dinamikleri (örneğin difüzyon ve sıcaklık etkileri) hem de daha hızlı hata bileşenlerini temsil edebilecek şekilde iki katmanlı bir yapı olarak seçilmiştir.

Öğrenme oranı, ağın kararlı bir şekilde yakınsamasını sağlamak amacıyla başlangıçta nispeten yüksek bir değerle başlatılmış ve eğitim ilerledikçe kademeli olarak azaltılmıştır. Eğitim sürecinde doğrulama verisi üzerindeki hata eğilimi izlenmiş; aşırı öğrenmenin önüne geçmek amacıyla erken durdurma mekanizması kullanılmıştır. Bu yaklaşım sayesinde hiperparametrelerin seçimi, yalnızca eğitim performansına değil, aynı zamanda genelleme yeteneğine dayalı olarak gerçekleştirilmiştir.

Eğitim ve doğrulama aşamasında, LSTM ağının artık öğrenme yaklaşımıyla GKF kaynaklı hata bileşenlerini istikrarlı biçimde öğrendiği görülmektedir. Validation hatasının eğitim hatasıyla paralel seyretmesi, modelin aşırı öğrenme göstermediğini ortaya koymaktadır. Test aşamasında ise, daha önce hiç görülmemiş US06 sürüş döngüsü üzerinde GKF-LSTM yapısının, saf GKF'ye kıyasla daha düşük hata ve daha az bias ile gerçek SOC'yi takip ettiği gözlenmiştir. SOC hata sinyalinin sıfır etrafında merkezlenmesi ve uzun vadeli sürüklenme göstermemesi, önerilen hibrit yaklaşımın genelleme kabiliyetini doğrulamaktadır.



6. SONUÇ VE ÖNERİLER

Bu çalışmada, lityum-demir-fosfat (LFP) tip bir batarya için şarj durum kestirimi problemini ele alan bütüncül ve hibrit bir yaklaşım geliştirilmiştir. Çalışmanın temel amacı, fizik tabanlı modelleme yöntemlerinin sağladığı kararlılığı korurken, veri güdümlü yöntemlerin sunduğu esneklikten faydalanarak BŞD kestirim doğruluğunu artırmaktır. Bu doğrultuda, öncelikle bataryanın kimyasına uygun olacak şekilde ADG-BŞD eğrisi ve referans tablosu oluşturulmuştur. Ardından eşdeğer devre modeli parametreleri HPPC test ve DST test verileri kullanılarak FFRLS yöntemiyle tanımlanmış, ardından bu parametreler GKF tabanlı BŞD ve terminal gerilim kestiriminde kullanılmıştır.

Elde edilen sonuçlar, FFRLS algoritmasının batarya parametrelerini BŞD ve sıcaklık boyunca fiziksel olarak anlamlı ve kararlı bir biçimde kestirebildiğini göstermektedir. Özellikle ohmik direnç ve polarizasyon parametrelerinin sıcaklıkla birlikte beklenen yönde değişim sergilemesi, parametre tanımlama aşamasının doğruluğunu teyit etmektedir. GKF ile gerçekleştirilen BŞD ve terminal gerilim kestirimi sonuçlarında, US06 gibi agresif sürüş döngüleri altında dahi terminal gerilim için 4.9 mV seviyesinde ideal bir karesel ortalama (RMSE) elde edilmiştir. Ayrıca algoritmanın tutarlılığı ve geliştirilen batarya modelinin doğruluğunu sınamak için farklı bir sıcaklıkta US06 sürüş senaryosu test edilip başarılı bir sonuç elde edilmiştir. Bu sonuç, önerilen fizik tabanlı modelin dinamik davranışları yüksek doğrulukla temsil edebildiğini ortaya koymaktadır.

Buna karşın, LFP bataryaların düz ADG-BŞD karakteristiği ve agresif sürüş profillerinin etkisiyle BŞD kestiriminde belirli hata seviyelerinin kaçınılmaz olduğu gözlemlenmiştir. Bu sınırlamayı aşmak amacıyla, çalışmanın ikinci aşamasında GKF çıktılarındaki artık hataları öğrenen LSTM tabanlı bir residual learning yapısı önerilmiştir. Residual GKF-LSTM olarak adlandırılan bu hibrit yapı, GKF tarafından üretilen BŞD ve terminal gerilim kestirimlerini, ölçüm verileri ve gerilim residual bilgisi ile birlikte kullanarak zamana bağlı ve sistematik hataları telafi etmektedir.

Farklı dinamiklere sahip ADG, DST ve FUDS verileri ile eğitilen LSTM ağı, US06 sürüş döngüsü üzerinde doğrulanmış. Ardından GKF-LSTM hibrit yapısı kullanılarak aynı eğitim süreci uygulanmıştır. Elde edilen sonuçlar, önerilen hibrit yaklaşımın hem genelleme kabiliyeti yüksek hem de fiziksel olarak güvenilir bir BŞD kestirim yöntemi sunduğunu göstermektedir (Çizelge 6.1).

Çizelge 6.1 : US06 25°C Testleri İçin Tahmin Yöntemlerinin Karşılaştırılması.

Tahmin yöntemi	RMSE (BŞD %)	MAE (BŞD %)	Maksimum hata
GKF	2.36	1.48	<%6
LSTM	3.19	2.22	<%10
GKF-LSTM	1.78	0.86	<%3

Çizelge 6.1’de sunulan nicel sonuçlar incelendiğinde, önerilen hibrit GKF-LSTM yaklaşımının BŞD kestirim doğruluğunu anlamlı ölçüde artırdığı görülmektedir. Yalnızca GKF kullanılması durumunda BŞD kestirimi yüzdesel ölçek için RMSE değeri %2.36 seviyesinde elde edilirken, veri güdümlü LSTM yöntemi tek başına uygulandığında bu değer %3.19’a yükselmiştir. Bu durum, LSTM’in dinamik örüntüleri öğrenme kabiliyetine rağmen, fiziksel kısıtlar olmaksızın özellikle agresif sürüş koşullarında kararlılık kaybı yaşayabildiğini göstermektedir.

Önerilen GKF-LSTM hibrit yapısı ise GKF’nin fizik tabanlı kararlılığını koruyarak, LSTM’in artık hataları öğrenme yeteneğinden faydalanmış ve RMSE değerini %1.78 seviyesine düşürmüştür. Bu sonuç, yalnızca GKF yaklaşımına kıyasla yaklaşık %24.6, yalnızca LSTM yaklaşımına kıyasla ise yaklaşık %44.2 oranında hata azalımı sağlandığını ortaya koymaktadır. Ayrıca maksimum BŞD hata değeri hibrit yapı için %3’ ün altında kalırken, bu sınır GKF için %6, LSTM için ise %10 seviyelerine kadar çıkabilmektedir.

Bu bulgular, önerilen hibrit yaklaşımın yalnızca ortalama hata değerlerini düşürmekle kalmadığını, aynı zamanda hata dağılımını daraltarak kestirim güvenilirliğini artırdığını göstermektedir. Özellikle LFP bataryaların düz ADG–BŞD karakteristiği ve US06 gibi agresif sürüş profilleri altında, maksimum hata seviyesinin kontrol altında tutulabilmesi, geliştirilen yöntemin batarya yönetim sistemleri açısından pratik uygulanabilirliğini ortaya koymaktadır.

KAYNAKLAR

- [1] **Dubarry, M., Svoboda, V., Hwu, R., & Liaw, B. Y.** (2007). Capacity loss in rechargeable lithium cells during cycle life testing. *Journal of Power Sources*, 165(2), 566–572.
<https://doi.org/10.1016/j.jpowsour.2006.11.097>
- [2] **Jaguemont, J., Boulon, L., & Dubé, Y.** (2016). A comprehensive review of lithium-ion batteries used in hybrid and electric vehicles. *Renewable and Sustainable Energy Reviews*, 64, 103–122.
<https://doi.org/10.1016/j.rser.2016.05.093>
- [3] **Hannan, M. A., Hoque, M. M., Mohamed, A., & Ayob, A.** (2017). Review of energy storage systems for electric vehicle applications. *Renewable and Sustainable Energy Reviews*, 69, 771–789.
<https://doi.org/10.1016/j.rser.2016.11.171>
- [4] **Wang, X., et al.** (2024). Lithium Battery SOC Estimation Based on Improved Iterated Extended Kalman Filter. *Applied Sciences*, 14(13), 5868.
- [5] **Zhou, H., Luo, J., & Yu, Z.** (2023). Co-estimation of SOC and SOH for Li-ion battery based on MIEKPF-EKPF fusion algorithm. *Energy Reports*, 10, 4420–4428.
- [6] **Scrosati, B., & Garche, J.** (2010). Lithium batteries: Status, prospects and future. *Journal of Power Sources*, 195(9), 2419–2430.
<https://doi.org/10.1016/j.jpowsour.2009.11.048>
- [7] **Che, Y., Xu, L., Teodorescu, R., Hu, X., & Onori, S.** (2025). Enhanced SOC estimation for LFP batteries: A synergistic approach using coulomb counting reset, machine learning, and relaxation. *ACS Energy Letters*, 10(2), 741–749.
- [8] **Yan, L., Peng, J., Li, H., Huang, Z., Sauer, D. U., & Li, W.** (2025). Slope-adaptive state-of-charge estimation for LFP batteries with temperature-aware hysteresis modeling. *eTransportation*, 19, 100473.
- [9] **Zubi, G., Dufo-López, R., Carvalho, M., & Pasaoglu, G.** (2018). The lithium-ion battery: State of the art and future perspectives. *Renewable and Sustainable Energy Reviews*, 89, 292–308.
- [10] **Yi, B., et al.** (2025). Bias-Compensated State of Charge and State of Health Joint Estimation for Lithium Iron Phosphate Batteries. *IEEE Transactions on Power Electronics*. <https://doi.org/10.1109/TPEL.2024.3492714>
- [11] **M. Charkhgard and M. Farrokhi**, “State-of-charge estimation for lithium-ion batteries using neural networks and GKF,” *IEEE Transactions on Industrial Electronics*, vol. 57, no. 12, pp. 4178–4187, 2010.

- [12] **Wei, Y., & Ling, L.** (2022). State-of-charge estimation for lithium-ion batteries based on temperature-based fractional-order model and dual fractional-order Kalman filter. *IEEE Access*, 10, 37131–37148.
- [13] **Yang, D., Qi, G., & Li, X.** (2013). State-of-charge estimation of LiFePO₄/C battery based on extended Kalman filter. *2013 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC)*, 1-5.
- [14] **Khanum, F., Louback, E., Duperly, F., Jenkins, C., Kollmeyer, P. J., & Emadi, A.** (2021). A Kalman Filter Based Battery State of Charge Estimation MATLAB Function. *2021 IEEE Transportation Electrification Conference & Expo (ITEC)*, 484-489.
- [15] **Shrivastava, P., Soon, T. K., Idris, M. Y. B., & Mekhilef, S.** (2021). Lithium-ion Battery Model Parameter Identification Using Modified Adaptive Forgetting Factor-Based Recursive Least Square Algorithm. *2021 IEEE 12th Energy Conversion Congress & Exposition - Asia (ECCE-Asia)*, 2169-2174.
- [16] **Wei, M., Yu, X., & Ding, J.** (2025). A Joint SOC Estimation Method Based on FFRLS-AGKF-LSTM. *Concurrency and Computation: Practice and Experience*, 37(25-26), e70359.
- [17] **Chung, D. W., Ko, J. H., & Yoon, K. Y.** (2022). State-of-charge estimation of lithium-ion batteries using LSTM deep learning method. *Journal of Electrical Engineering & Technology*, 17(3), 1931-1945.
- [18] **Sciatti, F., Tamburrano, P., Distaso, E., Amirante, R., Radogna, A. V., Morciano, A., & Grassi, G.** (2026). A comprehensive overview of lithium-ion batteries for electric vehicles: Materials, performance, safety, recycling, and emerging technologies. *Journal of Energy Storage*, 144, 119694.
- [19] **Suberu, M. Y., Mustafa, M. W., & Bashir, N.** (2014). Energy storage systems for renewable energy power sector integration and mitigation of intermittency. *Renewable and Sustainable Energy Reviews*, 35, 499-514.
- [20] **Cano, G., et al.** (2016). State-of-the-art of energy storage systems for energy-intensive applications. *Renewable and Sustainable Energy Reviews*, 55, 104–119. <https://doi.org/10.1016/j.rser.2015.10.073>
- [21] **Budde-Meiwes, H., Drillkens, J., Lunz, B., Muennix, J., Rothgang, S., Kowal, J., & Sauer, D. U.** (2013). A review of current automotive battery technology and future prospects. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 227(5), 761–776. <https://doi.org/10.1177/0954407013485567>
- [22] **Battery University.** (2019, September 27). *Are hybrid cars here to stay*. https://batteryuniversity.com/learn/archive/are_hybrid_cars_here_to_stay
- [23] **Goodenough, J. B., Whittingham, M. S., & Yoshino, A.** (2019). *Lithium-ion batteries*. The Royal Swedish Academy of Sciences.
- [24] **Tarascon, J.-M., & Armand, M.** (2001). Issues and challenges facing rechargeable lithium batteries. *Nature*, 414, 359–367.

- [25] **Monroe, D.** (2020). Building a better battery. *MRS Bulletin*, 45, 246–247. <https://doi.org/10.1557/mrs.2020.81>
- [26] **Tosun, E., Keyinci, S., Yakaryılmaz, A. C., Yıldızhan, Ş., & Özcanlı, M.** (2024). Evaluation of Lithium-ion Batteries in Electric Vehicles. *International Journal of Automotive Science And Technology*, 8(3), 332-340.
- [27] **Miao, Y., Hynan, P., Von Jouanne, A., & Yokochi, A.** (2019). Current Li-ion battery technologies in electric vehicles and opportunities for advancements. *Energies*, 12(6), 1074.
- [28] **Battery University.** (2019, May 5). *BU-205:Types of Li-Ion*. https://batteryuniversity.com/learn/article/types_of_lithium_ion
- [29] **Battery University.** (2019, September 27). *Is Li-ion the solution for the electric vehicle?*https://batteryuniversity.com/learn/archive/is_li_ion_the_solution_for_the_electric_vehicle
- [30] **Hannan, M. A., Hoque, M. M., Hussain, A., Yusof, Y., & Ker, P. J.** (2018). State-of-the-art and energy management systems of Li-ion batteries in EV applications: Issues and recommendations. *IEEE Access*, 6, 19362–19378.
- [31] **EE Times.** (2019, May 5). *All About Batteries, Part 12: Lithium Titanate (LTO)*. https://www.eetimes.com/author.asp?section_id=36&doc_id=1325358
- [32] **Sun, C., Rajasekhara, S., Goodenough, J. B., & Zhou, F.** (2011). Monodisperse porous LiFePO₄ microspheres for a high power Li-ion battery cathode. *Journal of the American Chemical Society*, 133, 2132–2135.
- [33] **Bruce, P. G., Freunberger, S. A., Hardwick, L. J., & Tarascon, J.-M.** (2012). Li–O₂ and Li–S batteries with high energy storage. *Nature Materials*, 11, 19–29. <https://doi.org/10.1038/nmat3191>
- [34] **Manthiram, A., Yu, X., & Wang, S.** (2017). Lithium battery chemistries enabled by solid-state electrolytes. *Nature Reviews Materials*, 2, Article 16103. <https://doi.org/10.1038/natrevmats.2016.103>
- [35] **Slater, M. D., Kim, D., Lee, E., & Johnson, C. S.** (2013). Sodium-ion batteries. *Advanced Functional Materials*, 23, 947–958. <https://doi.org/10.1002/adfm.201200691>
- [36] **Zuo, X., Zhu, J., Müller-Buschbaum, P., & Cheng, Y.-J.** (2017). Silicon based lithium-ion battery anodes: A chronicle perspective review. *Nano Energy*, 31, 113–143. <https://doi.org/10.1016/j.nanoen.2016.11>
- [37] **Barsukov, Y., & Qian, J.** (2013). *Battery power management for portable devices*. Artech House.
- [38] **TÜBİTAK Marmara Araştırma Merkezi Enerji Enstitüsü.** (2017, February). *Batarya Yönetim Sistemleri [PowerPoint Slides]*. <https://challenge.tubitak.gov.tr/assets/batarya-yonetim-sistemleri.pdf>
- [39] **Hu, X., Feng, F., Liu, K., Zhang, L., Xie, J., & Liu, B.** (2019). State estimation for advanced battery management: Key challenges and future trends. *Renewable and Sustainable Energy Reviews*, 114, 109334.

- [40] **Demirci, O., Taskin, S., Schaltz, E., & Demirci, B. A.** (2024). Review of battery state estimation methods for electric vehicles - Part I: SOC estimation. *Journal of Energy Storage*, 87, 111435. <https://doi.org/10.1016/j.est.2024.111435>
- [41] **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).
- [42] **Ng, K. S., Moo, C. S., Chen, Y. P., & Hsieh, Y. C.** (2009). Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries. *Applied Energy*, 86, 1506–1511. <https://doi.org/10.1016/j.apenergy.2008.11.021>
- [43] **Xing, Y., He, W., Pecht, M., & Tsui, K. L.** (2014). State of charge estimation of lithium-ion batteries using the open-circuit voltage at various ambient temperatures. *Applied Energy*, 113, 106–115. <https://doi.org/10.1016/j.apenergy.2013.07.008>
- [44] **Chen, X., Lei, H., Xiong, R., Shen, W., & Yang, R.** (2019). A novel approach to reconstruct open circuit voltage for state of charge estimation of lithium ion batteries in electric vehicles. *Applied Energy*, 255, 113758. <https://doi.org/10.1016/j.apenergy.2019.113758>
- [45] **Plett, G. L.** (2004). Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs. *Journal of Power Sources*, 134, 252–261.
- [46] **Hu, X., Li, S., & Peng, H.** (2012). A comparative study of equivalent circuit models for Li-ion batteries. *Journal of Power Sources*, 198, 359–367.
- [47] **Welch, G., & Bishop, G.** (1995). *An Introduction to the Kalman Filter* (Tech. Rep. TR 95-041). University of North Carolina at Chapel Hill.
- [48] **Pascanu, R., Mikolov, T., & Bengio, Y.** (2013). On the difficulty of training recurrent neural networks. *Proceedings of the 30th International Conference on Machine Learning (ICML)*, 28, 1310–1318.
- [49] **Wu, Y., Liu, X., Zhang, J., Liu, M., Wang, L., Du, X., & Yan, X.** (2025). Temperature-influenced SOC estimation of LiFePO₄ batteries in hybrid electric tractors based on SAO-LSTM model. *World Electric Vehicle Journal*, 16(5), 283.
- [50] **Chaturvedi, N. A., Klein, R., Christensen, J., Ahmed, J., & Kojic, A.** (2010). Modeling, estimation, and control challenges for lithium-ion batteries. *Proceedings of the 2010 American Control Conference*, 1997–2002.
- [51] **Zhang, Q., Wang, D., Yang, B., Cui, X., & Li, X.** (2020). Electrochemical model of lithium-ion battery for wide frequency range applications. *Electrochimica Acta*, 343, 136094.
- [52] **He, H., Xiong, R., & Fan, J.** (2011). Evaluation of lithium-ion battery equivalent circuit models for state of charge estimation by an experimental approach. *Energies*, 4(4), 582–598.

- [53] **Shrivastava, P., & Tey, K. S.** (2022). *Battery Test Data (LiFePO₄ 18650 Rechargeable Cell 3.3V 1100 mAh, Panasonic NCR18650B 3400mAh, Murata VTC6 18650 3000mAh 15A)* [Data set]. Mendeley Data, V1. <https://doi.org/10.17632/29kw38kzwj.1>



ÖZGEÇMİŞ

Ad-Soyad : Halil AYDIN

ÖĞRENİM DURUMU:

- **Lisans** : 2021, İstanbul Teknik Üniversitesi, Elektrik Elektronik Fakültesi, Kontrol ve Otomasyon Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- Kontrol Sistem Mühendisi, FEV Türkiye, 2021 – Halen

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

Bildiriler:

- **Aydın, H.** (2026, January). *Battery state of charge estimation based on extended kalman filter for electric vehicles*. ICAD2I'2025 International Conference on Advanced Technologies and Interdisciplinary Innovation, Fez, Morocco.