

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİKLİ ARAÇLAR İÇİN BATARYA
YÖNETİM SİSTEMİ ALGORİTMASI
TASARIMI VE GELİŞTİRİLMESİ

Merve YENİOĞLU

YÜKSEK LİSANS TEZİ

Elektrik Mühendisliği Anabilim Dalı

Elektrik Makinaları ve Güç Elektronik Programı

Danışman

Dr. Öğr. Üyesi Engin AYÇİÇEK

Eş Danışman

Prof. Dr. Ozan ERDİNÇ

Ocak, 2025

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ELEKTRİKLİ ARAÇLAR İÇİN BATARYA YÖNETİM
SİSTEMİ ALGORİTMASI TASARIMI VE GELİŞTİRİLMESİ**

Merve YENİOĞLU tarafından hazırlanan tez çalışması 17.01.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Mühendisliği Anabilim Dalı, Elektrik Makinaları ve Güç Elektroniği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Dr. Öğr. Üyesi Engin AYÇİÇEK
Yıldız Teknik Üniversitesi
Danışman

Prof. Dr. Ozan ERDİNÇ
Yıldız Teknik Üniversitesi
Eş-Danışman

Jüri Üyeleri

Dr. Öğr. Üyesi Engin AYÇİÇEK, Danışman
Yıldız Teknik Üniversitesi

Doç. Dr. Ali Rıfat BOYNUEĞRİ, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Mustafa Alparslan ZEHİR, Üye
Marmara Üniversitesi

Danışmanım Dr. Öğr. Üyesi Engin AYÇİÇEK ve eş danışmanım Prof. Dr. Ozan ERDİNÇ sorumluluğunda tarafımda hazırlanan “Elektrikli Araçlar İçin Batarya Yönetim Sistemi Algoritması Tasarımı ve Geliştirilmesi” başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Merve YENİOĞLU

İmza

Cesaret verenlere ve ilham kaynađı olanlara,

TEŐEKKÜR

Yüksek lisans tezim kapsamındaki çalışmalarımın her aşamasında bilgi ve deneyimleriyle beni yönlendiren ve bu tezi hazırlayabilecek aşamaya gelmemde en büyük katkı sahibi olan sayın danışman hocam Dr. Öğr. Üyesi Engin AYÇİÇEK'e ve eş-danışman hocam Prof. Dr. Ozan ERDİNÇ'e teşekkürlerimi sunarım.

Çalışmamı zenginleştirmek adına katkıda bulunan ve değerli yardımlarını esirgemeyen Aligül Selim TÜRKOĞLU'na ve Başak Ersöz YILDIRIM'a, her zaman yanımda olduklarını hissettiren canım aileme, ne kadar uzak da olsak beni destekleyen ve bana yön veren canım abim Orhan DUMAN'a, çocukluğumdan beri yanımda olan, bana güvenen ve beni destekleyen canım kuzenlerim Nurcan'a, Burak'a, Ece'ye ve canım ablam Gamze'ye teşekkürlerimi sunarım.

Merve YENİOĞLU

İÇİNDEKİLER

SİMGE LİSTESİ	vii
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ	xi
ÖZET	xiii
ABSTRACT	xv
1 GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı	9
2 ELEKTRİKLİ ARAÇLAR	10
2.1 Elektrikli Araçların Tarihsel Gelişimi	10
2.2 Elektrikli Araç Bileşenleri	11
2.3 Elektrikli Araçların Sınıflandırılması	12
2.3.1 Bataryalı Elektrikli Araçlar	13
2.3.2 Hibrit Elektrikli Araçlar	14
2.3.3 Yakıt Hücreli Araçlar	15
2.4 Elektrikli Araçlarda Kullanılan Batarya Türleri	16
2.4.1 Nikel Metal Hidrit (NiMH) Bataryalar	16
2.4.2 Lityum-İyon Bataryalar	16
2.4.3 Lityum Polimer (Li-Po) Bataryalar	17
2.4.4 Kurşun-Asit Bataryalar	17
2.5 Elektrikli Araçlarda Batarya Yönetim Sistemi	17
2.6 BYS Fonksiyonları	18
3 YAPAY ZEKA TABANLI TAHMİN YÖNTEMLERİ	19
3.1 Yapay Zekanın Kalan Faydalı Ömür Tahmininde Konumu	19
3.2 Yapay Zeka Tabanlı Yöntemlerin Genel Adımları	19

3.3	Yaygın Yöntemler.....	20
3.3.1	Rastgele Orman Regresyon Yöntemi	21
3.3.2	İleri Seviye Gradyan Yükseltici Regresyon Yöntemi	22
3.3.3	K- En Yakın Komşu Regresyon Yöntemi	22
3.4	Kontrol Yöntemleri.....	23
3.4.1	Ortak Mutlak Hata	23
3.4.2	Determinasyon Katsayısı	23
3.4.3	Özellik Önem Derecesi	24
3.5	Tasarım Süreci	24
3.5.1.	Lityum-İyon Batarya Verilerinin Toplanması	25
3.5.2.	Lityum-İyon Batarya Verilerinin İşlenmesi	33
3.5.3.	Veri Setini Eğitim ve Test Verilerine Ayırma	34
4	SONUÇ	37
4.1	Rastgele Orman Regresyonu Yöntemi ile Tahmin Sonuçları.....	37
4.2	İleri Seviye Gradyan Yükseltici Regresyon Yöntemi ile Tahmin Sonuçları	43
4.3	K- En Yakın Komşu Regresyon Yöntemi ile Tahmin Sonuçları.....	51
4.4	Yapılan Tahminleme Sonuçlarının Değerlendirilmesi	55
4.5	Gelecek Çalışmalar	57
	KAYNAKÇA	58
	TEZDEN ÜRETİLMİŞ YAYINLAR	70

SİMGE LİSTESİ

A	Akım Birimi Amper
$(di/dt)_i$	Akımın Zamana Göre Değişimi
R^2	Determinasyon Katsayısı
Ω	Direnç Birimi Ohm
y_i	Gerçek Değer
\hat{y}	Gerçek Değerlerin Ortalaması
V	Gerilim Birimi Volt
$(dv/di)_i$	Gerilim Değişiminin Akım Değişimine Oranı
$(dv/dt)_i$	Geriliminin Zamana Göre Değişimi
Ahr	Kapasite Birimi Amper-saat
°C	Sıcaklık Birimi Santigrat Derece
\hat{y}_i	Tahmin Edilen Değer
n	Tahmin Edilen ve Gerçek Değerlerin Toplam Sayısı
s	Zaman Birimi Saniye

KISALTMA LİSTESİ

BEA	Bataryalı Elektrikli Araçlar
BYS	Batarya Yönetim Sistemi
CNN	Evrişimli Sinir Ağı
DC	Doğru Akım (Direct Current)
DNN	Deep Neural Network
EA	Elektrikli Araç
EIS	Elektrokimyasal Empedans Spektrometresi
HEA	Hibrit Elektrikli Araçlar
IC	Artan Kapasite (Incremental Capacity)
İSGYR	İleri Seviye Gradyan Yükseltici Regresyon
İYM	İçten Yanmalı Motor
KEYKR	K- En Yakın Komşu Regresyon
KFÖ	Kalan Faydalı Ömür
LSTM-RNN	Uzun Kısa Vadeli Bellek Yinelemeli Sinir Ağı
MAE	Ortalama Mutlak Hata
NASA	National Aeronautics and Space Administration
ROR	Rastgele orman regresyon
SOE	Enerji Durumu (State of Energy)
SOP	Güç Durumu (State of Power)

ŞEKİL LİSTESİ

Şekil 1.1	2013-2023 yılları arasında yayımlanan lityum iyon bataryanın kalan faydalı ömür tahmini hakkında IEEE veritabanında yayımlanan makaleler.....	1
Şekil 1.2	IEEE 2013-2023 arasında kalan faydalı kullanım ömrü üzerine incelenen parametrelerin makale sayısına göre dağılımları	8
Şekil 2.1	Elektrikli araç mimarisi	12
Şekil 2.2	Elektrikli araçların sınıflandırılması.....	12
Şekil 2.3	Batarya elektrikli araç yapısı	13
Şekil 2.4	Hibrit elektrikli araç yapısı	15
Şekil 2.5	Yakıt hücreli araç yapısı	16
Şekil 3.1	Yapay zeka tabanlı tahminler için izlenecek yol.....	20
Şekil 3.2	Kalan faydalı ömür tahmininde kullanılan yöntemlerin sınıflandırılması	20
Şekil 3.3	Rastgele orman regresyon yöntemi	21
Şekil 3.4	K-en yakın komşu regresyon yöntemi.....	23
Şekil 3.5	Tahmin algoritma şeması	24
Şekil 3.6	Şarj veri seti ölçülen gerilimin zamana göre değişimi	27
Şekil 3.7	Şarj veri seti ölçülen akımın zamana göre değişimi	27
Şekil 3.8	Şarj veri setinde ölçülen sıcaklığın zamana göre değişimi.....	28
Şekil 3.9	Şarj veri setinde şarj cihazı akımının zamana göre değişimi	28
Şekil 3.10	Şarj veri setinde şarj cihazı geriliminin zamana göre değişimi.....	29
Şekil 3.11	Deşarj veri setinde batarya terminal geriliminin zamana göre değişimi	30
Şekil 3.12	Deşarj veri setinde ölçülen akımın zamana göre değişimi	31
Şekil 3.13	Deşarj veri setinde ölçülen sıcaklığın zamana göre değişimi.....	31
Şekil 3.14	Deşarj veri setinde ölçülen yükte ölçülen akımın zamana göre değişimi	32
Şekil 3.15	Deşarj veri setinde ölçülen yük geriliminin zamana göre değişimi	32
Şekil 4.1	Mevcut veri setinde ROR ile KFÖ tahmini (%50 test verisi)	37

Şekil 4.2	Mevcut veri setine dv/dt ve di/dt eklenerek ROR ile KFÖ tahmini (%50 test verisi).....	39
Şekil 4.3	Mevcut veri setine direnç değeri, dv/dt , di/dt ve dv/di eklenerek ROR ile KFÖ tahmini (%50 test verisi).....	41
Şekil 4.4	Mevcut veri setine direnç değeri, dv/dt , di/dt ve dv/di eklenerek ROR ile KFÖ tahmini (%60 test verisi).....	41
Şekil 4.5	Mevcut veri setinde İSGYR ile KFÖ tahmini (%50 test verisi).....	44
Şekil 4.6	Mevcut veri setine dv/dt ve di/dt eklenerek İSGYR ile KFÖ tahmini (%50 test verisi).....	46
Şekil 4.7	Mevcut veri setine dv/dt ve di/dt eklenerek İSGYR ile KFÖ tahmini (%35 test verisi).....	46
Şekil 4.8	Mevcut veri setine direnç değeri, dv/dt , dv/di ve di/dt eklenerek İSGYR ile KFÖ tahmini (%50 test verisi).....	49
Şekil 4.9	Mevcut veri setine direnç değeri, dv/dt , dv/di ve di/dt eklenerek İSGYR ile KFÖ tahmini (%60 test verisi).....	49
Şekil 4.10	Mevcut veri setine dv/dt , di/dt eklenerek yapılan KEYKR tahminlemeleri (%50 test verisi).....	53
Şekil 4.11	Mevcut veri setine dv/dt , di/dt eklenerek yapılan KEYKR tahminlemeleri (%35 test verisi).....	54
Şekil 4.12	Mevcut veri setine direnç değeri, dv/dt , dv/di ve di/dt eklenerek KEYKR yöntemi ile tahminlemeleri (%50 test verisi).....	54

TABLO LİSTESİ

Tablo 1.1 IEEE veri tabanında 2013-2023 yılları arasında lityum iyon batarya kalan faydalı ömür tahmini üzerine yayınlanmış makalelerin dergilere göre dağılımı	2
Tablo 1.1 IEEE veri tabanında 2013-2023 yılları arasında lityum iyon batarya kalan faydalı ömür tahmini üzerine yayınlanmış makalelerin dergilere göre dağılımı (devamı)	3
Tablo 1.2 IEEE veri tabanında 2019-2023 yılları arasında lityum iyon batarya KFÖ tahmini üzerine yayınlanan makalelerde parametrelerin yıllara göre incelenme durumu	5
Tablo 1.2 IEEE veri tabanında 2019-2023 yılları arasında lityum iyon batarya KFÖ tahmini üzerine yayınlanan makalelerde parametrelerin yıllara göre incelenme durumu (devamı)	6
Tablo 1.2 IEEE veri tabanında 2019-2023 yılları arasında lityum iyon batarya KFÖ tahmini üzerine yayınlanan makalelerde parametrelerin yıllara göre incelenme durumu (devamı)	7
Tablo 3.1 Veri setine genel bakış	25
Tablo 3.2 Şarj veri setine genel bakış	26
Tablo 3.3 Deşarj veri setine genel bakış	30
Tablo 3.4 Parametrelerin veri setine işlenmesi	34
Tablo 3.5 Eğitim için kullanılacak hedef değişkeni RUL (KFÖ)	35
Tablo 3.6 Eğitim için kullanılacak özellikler	35
Tablo 3.7 Test için kullanılacak hedef değişkeni RUL(KFÖ)	36
Tablo 3.8 Test için kullanılacak özellikler	36
Tablo 4.1 Mevcut veri seti üzerinden ROR tahminleme metrikleri	38
Tablo 4.2 Mevcut veri seti üzerinden yapılan ROR tahminlemelerindeki özellik önem dereceleri	38
Tablo 4.3 Mevcut veri seti üzerine dv/dt ve di/dt parametreleri eklenerek yapılan ROR tahminleme metrikleri	39
Tablo 4.4 Mevcut veri seti üzerine dv/dt ve di/dt parametreleri eklenerek yapılan ROR tahminlemelerinde özellik önem dereceleri	40
Tablo 4.5 Mevcut veri setine direnç değeri, dv/dt , dv/di ve di/dt eklenerek ROR yöntemi ile tahminleme metrikleri	42

Tablo 4.6	Mevcut veri setine direnç değeri, dv/dt , dv/di ve di/dt eklenerek ROR yöntemi ile tahminlemede özellik önem sıralaması	42
Tablo 4.7	Mevcut veri setine direnç değeri, dv/dt , dv/di ve di/dt eklenerek ROR yöntemi ile tahminlemede özellik önem sıralaması	43
Tablo 4.8	Mevcut veri seti üzerinden İSGYR yöntemi ile tahminleme metrikleri	44
Tablo 4.9	Mevcut veri seti üzerinden İSGYR yöntemi ile tahminlemede özellik önem sıralaması.....	45
Tablo 4.10	Mevcut veri setine dv/dt ve di/dt eklenerek İSGYR ile KFÖ tahmini İSGYR yöntemi ile tahminleme metrikleri	45
Tablo 4.11	Mevcut veri setine dv/dt ve di/dt parametreleri eklenerek yapılan İSGYR yöntemi ile tahminlemede özellik önem sıralaması	47
Tablo 4.12	Mevcut veri setine dv/dt ve di/dt parametreleri eklenerek yapılan İSGYR yöntemi ile tahminlemede özellik önem sıralaması	48
Tablo 4.13	Mevcut veri setine direnç, dv/dt , di/dt ve dv/di değerleri eklenerek İSGYR yöntemi ile tahminleme metrikleri	50
Tablo 4.14	İSGYR ile tahminlemede özellik önem sıralaması	50
Tablo 4.15	İSGYR ile tahminlemede özellik önem sıralaması	51
Tablo 4.16	Mevcut veri seti üzerinden KEYKR yöntemi ile tahminleme metrikleri	52
Tablo 4.17	Mevcut veri setine dv/dt , di/dt parametreleri eklenerek KEYKR yöntemi yapılan tahminleme metrikleri	53
Tablo 4.18	Mevcut veri setine direnç değeri, dv/dt , dv/di ve di/dt eklenerek KEYKR yöntemi ile tahminleme metrikleri	55
Tablo 4.19	Test veri oranı %50 alınarak yapılan tahminleme çalışmaları.....	56

Elektrikli Araçlar İçin Batarya Yönetim Sistemi Algoritması Tasarımı Ve Geliştirilmesi

Merve YENİOĞLU

Elektrik Mühendisliği Anabilim Dalı
Elektrik Makinaları ve Güç Elektroniği Programı
Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Engin AYÇİÇEK

Eş-Danışman: Prof. Dr. Ozan ERDİNÇ

Bu yüksek lisans tezi çalışması, yüksek enerji yoğunluğu, hızlı şarj özellikleri ve uzun çevrim ömrü avantajları sebebiyle elektrikli araçlarda sıkça kullanılan lityum iyon bataryalarda kalan faydalı ömür (KFÖ) tahmini için makine öğrenmesi yaklaşımlarının uygulanmasını ve bu yaklaşımların geliştirilmesini amaçlamaktadır. Tez, lityum iyon bataryaların kalan faydalı ömrü tahmininde etkili dahili ve harici parametreleri, kalan faydalı ömür tahmininde sık kullanılan yöntemleri, literatürde yeterince ele alınmayan çalışmaları ve NASA lityum iyon batarya bozunum test verilerinin toplanması ve işlenmesini içerir. Bu veriler üzerinde rastgele orman regresyonu (ROR), ileri seviye gradyan yükseltici regresyon (İSGYR), K- en yakın komşu regresyon (KEYKR) gibi makine öğrenmesi yöntemleri kullanılarak kalan faydalı ömür tahminleme modeli oluşturulur. Oluşturulan model, deneysel veri setinden karmaşık ilişkileri öğrenerek kalan faydalı ömür değerini tahmin eder. Önerilen modelin performansı ve doğruluğu, ortak mutlak hata ve determinasyon katsayısı değerleri ile

değerlendirilir ve kontrolü yapılır. Yapılan tahminlemelerdeki sonuçlar ve bulgular, makine öğrenmesi tabanlı yaklaşımın lityum iyon batarya kalan faydalı ömür tahmininde etkinliğini göstermektedir. Lityum iyon batarya kalan faydalı ömür değerlerinin doğru tahminleri, kalan faydalı ömür tahmininde etkili harici ve dahili parametreler hakkında değerli bilgiler sağlayarak, batarya teknolojisi üzerine yapılan çalışmalara, bu konudaki karar vericilere ve düzenleyicilere olası riskleri önceden tahmin edip bilinçli kararlar vermelerinde yardımcı olmaktadır.

Anahtar Kelimeler: Lityum iyon batarya, kalan faydalı ömür tahminlemesi, makine öğrenmesi, elektrikli araç, yaklaşım.

ABSTRACT

Battery Management System Algorithm Design And Implementation For Electric Vehicles

Merve YENİOĞLU

Department of Electrical Engineering
Master of Science Thesis

Supervisor: Assist. Prof. Engin AYÇİÇEK

Co-supervisor: Prof. Dr. Ozan ERDİNÇ

This master's thesis study aims to implement and develop machine learning approaches for the estimation of remaining useful life (RUL) in lithium-ion batteries, which are frequently used in electric vehicles due to their energy density, fast charging properties and long cycle life advantages. The thesis includes effective internal and external parameters in the estimation of remaining useful life of lithium-ion batteries, frequently used methods in the estimation of remaining useful life, studies that are not sufficiently addressed in the literature and the collection and processing of NASA lithium-ion battery degradation test data. A remaining useful life estimation model is created on these data using machine learning methods such as random forest regression (ROR), extreme gradient boosting regression (EGBR), K-nearest neighbor regression (KNNR). The created model estimates the remaining useful life value by learning complex relationships from the NASA experimental dataset. The performance and accuracy of the proposed model are evaluated and checked with mean absolute error and coefficient of determination values. The results and findings in the estimations show the effectiveness of the machine learning based approaches in the estimation of remaining useful life of lithium-ion batteries. Accurate estimations of lithium-ion battery RUL values provide valuable


information about the external and internal parameters that affect the remaining useful life estimate, helping battery technology researchers, decision makers and regulators to anticipate potential risks and make informed decisions.

Keywords: Lithium-ion battery, remaining useful life estimation, machine learning, electric vehicle, approach.

1.1 Literatür Özeti

Elektrikli araçlar ile ilgili çalışmaların başlangıcı 1800'lü yıllara kadar uzanmaktadır. O günden bugüne kadar da önem kazanan bir teknoloji olmaya devam etmektedir. Günümüzde de oldukça popüler olan elektrikli araçlar konusunda çok sayıda akademik çalışma yapılmıştır.

IEEE veritabanında 2013-2023 yılları arasında kalan faydalı ömür tahmini üzerine yayınlanmış 122 dergi makalesi yer almaktadır. Bu yayınların yıllara göre dağılımı şekilde sunulmuştur.



Şekil 1.1 2013-2023 yılları arasında yayımlanan lityum iyon bataryanın kalan faydalı ömür tahmini hakkında IEEE veritabanında yayımlanan makaleler

Tablo 1.1 IEEE veri tabanında 2013-2023 yılları arasında lityum iyon batarya kalan faydalı ömür tahmini üzerine yayınlanmış makalelerin dergilere göre dağılımı

Yayınlanan IEEE Dergileri	KFÖ Tahmini Üzerine Makale Sayısı
IEEE Transactions on Industrial Electronics	16
IEEE Transactions on Instrumentation and Measurement	22
IEEE Transactions on Reliability	4
IEEE Transactions on Systems, Man, and Cybernetics: Systems	2
IEEE Access	31
IEEE Transactions on Automation Science and Engineering	1
IEEE Transactions on Industrial Informatics	8
IEEE Transactions on Vehicular Technology	12
IEEE Transactions on Control Systems Technology	1
IEEE Transactions on Power Electronics	6
IEEE Transactions on Industry Applications	3
IEEE Systems Journal	1
IEEE Transactions on Circuits and Systems II: Express Briefs	1
IEEE Transactions on Energy Conversion	2

Tablo 1.1 IEEE veri tabanında 2013-2023 yılları arasında lityum iyon batarya kalan faydalı ömür tahmini üzerine yayınlanmış makalelerin dergilere göre dağılımı (devamı)

Yayınlanan IEEE Dergileri	KFÖ Tahmini Üzerine Makale Sayısı
IEEE Transactions on Fuzzy Systems	1
IEEE Transactions on Transportation Electrification	7
IEEE Journal of Emerging and Selected Topics in Power Electronics	2
IEEE/ASME Transactions on Mechatronics	1
IEEE/CAA Journal of Automatica Sinica	1

Tablo 1.1'e göre, literatürde kalan faydalı ömür tahmini üzerine birçok makale farklı dergilerde yer almış olup, bu kalan faydalı ömür tahmini çalışmalarına en çok yer veren dergiler sırasıyla 31 makale ile IEEE Access ve 22 makale ile IEEE Transactions on Instrumentation and Measurement olmuştur.

Literatür incelendiğinde, kalan faydalı ömür tahmini üzerine farklı yöntem ve parametrelerle çok sayıda çalışma olduğu görülmektedir.

Pil kapasitesi verileri, ölçüm hataları, ortam faktörleri ve diğer bilinmeyen nedenlerden kaynaklanan çeşitli gürültülerle kirlenebilir. Verilerdeki gürültü etkisinin azaltılmasının, tahmin doğruluğu ve kararlılığı açısından önemi literatürde vurgulanmıştır [5], [6], [7].

Veri setinin eksik veya yetersiz olması durumunda tahmin belirsizliği üzerine çalışmalar yapılmıştır. 2018 yılında veri odaklı Uzun Kısa Vadeli Bellek Yinelemeli Sinir Ağı (LSTM-RNN) yöntemi kullanılarak çevrimdışı eğitim verileri olmadan da batarya kalan faydalı ömrünü etkili bir şekilde tahmin edilebileceği belirtilmiştir[8]. Iván Sanz-Gorrachategui vd., geçmiş bilgilerin mevcut olmadığı durumlarda, basit şarj ve deşarj testleri yaparak ve gerilim dalgalarını analiz ederek,

kalan faydalı ömür döngü sayısının yüksek doğrulukla belirlenebileceğini öne sürmüştür[9]. Hancheng Dong, empedans ve kapasite verilerini kullanan kalan faydalı ömür tahmin yöntemlerini birleştirmiş ve mevcut verilerin az olduğu durumlarda bile daha doğru kalan faydalı ömür tahminleri sağlamıştır [10].

2023 yılında yapılan bir diğer çalışmada etiket verileri eksik ekipmanlar için Bayesian derin öğrenme çerçevesi ile, ilgili ekipmanın herhangi bir zamandaki arıza olasılığının da belirlenebileceği ve kalan faydalı ömür tahmin belirsizliği arasındaki ilişkiyi kurabileceği ve sonraki bakım kararlarını desteklemek için teknik destek sağlayabileceği belirtilmiştir [11].

2013-2023 yılları arasında kalan faydalı ömür tahmini çalışmalarında farklı yöntemlerle birçok parametrenin tahmin doğruluğuna etkisi incelenmiştir.

Datong Liu vd., kalan faydalı ömür tahmini için olasılıksal çerçeve sunarak kalan faydalı ömür için hem kapasite tabanlı hem de TIEDVD (Eşit Deşarj Voltajı Farkının Zaman Aralığı) tabanlı olacak şekilde etkili bir korelasyon modeli geliştirmiştir [12].

Arijit Guha vd., çalışmasında batarya yaşlanmasının pil parametreleri ve EIS karakteristikleri üzerindeki etkisini ortaya koymuştur [13].

Jingwen Wei vd., yaptığı çalışmada destek vektör regresyonu ve parçacık filtresi yöntemi ile empedans ve kapasite yaşlanma parametreleri ile batarya şarj durumunun doğrusal bir ilişkisi olduğu çıkarımını yapmıştır [14].

Rui Xiong vd. farklı sıcaklık ve C hızlarında test edilen 8 hücre verisi kullanarak kısmi şarj gerilimi eğrisi ile kapasite arasındaki ilişkiyi tanımlayan bir model oluşturmuştur [15].

IEEE 2013-2023 yılları arasında kalan faydalı ömür tahmini üzerine yayınlanan makalelerde incelenen parametrelerin yıllara göre dağılımı aşağıdaki tabloda gösterilmiştir. Bu tabloya göre 2013'ten beri batarya akım, gerilim, kapasite ve zamana dayalı tahminlerin yanısıra 2019'dan sonra dQ/dV diferansiyel kapasite, C oranı, farklı eğitim/test veri oranları ve 2023 yılında deşarj derinliği değerleri incelenerek batarya kalan Faydalı Ömür tahminleri yapılmaya başlanmıştır.

IEEE 2019-2023 yılları arasında kalan faydalı ömür tahmini üzerine yayınlanan makalelerde incelenen parametrelerin yıllara göre dağılımı aşağıdaki tabloda

gösterilmiştir. Bu tabloya göre 2019'dan beri batarya akım, gerilim, kapasite ve zamana dayalı tahminlerin yanısıra 2019'dan sonra dQ/dV diferansiyel kapasite, C oranı, farklı eğitim/test veri oranları ve 2023 yılında deşarj derinliği değerleri incelenerek batarya kalan faydalı ömür tahminleri yapılmaya başlanmıştır.

Tablo 1.2 IEEE veri tabanında 2019-2023 yılları arasında lityum iyon batarya KFÖ tahmini üzerine yayınlanan makalelerde parametrelerin yıllara göre incelenme durumu

İncelenen Parametreler	2019	2020	2021	2022	2023
Akım: Kesme Akımı, Rastgele Akım, Dinamik Akım, Minimum Şarj Akımı, Şarj Akımı, Deşarj Akımı, Ortalama Şarj Akımı, Ortalama Deşarj Akımı.	✓	✓	✓	✓	✓
Gerilim: Açık Devre Gerilimi, Şarj Gerilimi, Deşarj Gerilimi, Akü Terminal Gerilimi, Şarj/Deşarj Kesme Gerilimi.	✓	✓	✓	✓	✓
Kapasite Durumu: SOC, Maksimum Kapasite, %80 Nominal Kapasite.	✓	✓	✓	✓	✗
Direnç: Elektrolit Direnci, Şarj Aktarım Direnci, Katı Elektrolit Fazlar Arası Direnci, İç Direncin Artması, Ohmik Direnç, Warburg Direnci, Polarizasyon Direnci.	✓	✓	✓	✓	✓
Pil Fiziksel Durumu: Eski veya Yeni Pil, Hücre Kimyası, Kalibrasyon Durumu, titreşim	✓	✓	✗	✓	✓
C Oranı, Hızlı şarj durumu	✓	✗	✗	✓	✓

Tablo 1.2 IEEE veri tabanında 2019-2023 yılları arasında lityum iyon batarya KFÖ tahmini üzerine yayınlanan makalelerde parametrelerin yıllara göre incelenme durumu (devamı)

İncelenen Parametreler	2019	2020	2021	2022	2023
Döngü/Süre/Zaman: Boşaltma Süresi/Şarj Süresi, Başlangıç Noktası, Farklı Tahmin Süresi, Kesme Süresi, Örnekleme Noktası, Deşarj Süresi, Çalışma Adımı Süresi, İlk Vuruş Zamanı, Örnekleme Zamanı, Şarj-Deşarj Döngülerinin Sayı Artışı, TIEDVD((Eşit Deşarj Voltajı Farkının Zaman Aralığı), Eşit Voltaj Düşüşü Deşarj Zaman Aralığı), DECVD, Son Şarj Döngüsü Verisinden Maksimum Sıcaklık Değerine Ulaşma Süresi.	✓	✓	✓	✓	✓
Kapasite: Zaman İçindeki Deşarj Kapasitesi, Farklı Döngülerdeki Deşarj Artımlı Kapasitesi, DIC Eğrileri, DIC Zirvesinin Mutlak Değeri, Şarj Kapasitesi, Deşarj Kapasitesi, Zaman İçindeki Şarj Kapasitesi, Maksimum Deşarj Kapasitesi Arasındaki Fark, Tek Adımlı Kümülatif Şarj/Deşarj Kapasitesi.	✓	✓	✓	✓	✓
Sağlık Durumu	✓	✓	✓	✓	✓
Arıza Eşiği	✓	✓	✓	✓	✓
Sağlık Göstergesi (HI)	✓	✗	✓	✓	✗
Örnek Entropisi (SampEn)	✓	✗	✗	✗	✗
Farklı Eğitim / Test Veri Oranı	✓	✓	✗	✓	✓
Empedans: Elektrokimyasal Empedans Spektroskopisi (EIS), Dahili Empedans, Pil Şarj Empedansı.	✓	✓	✓	✓	✗

Tablo 1.2 IEEE veri tabanında 2019-2023 yılları arasında lityum iyon batarya KFÖ tahmini üzerine yayınlanan makalelerde parametrelerin yıllara göre incelenme durumu (devamı)

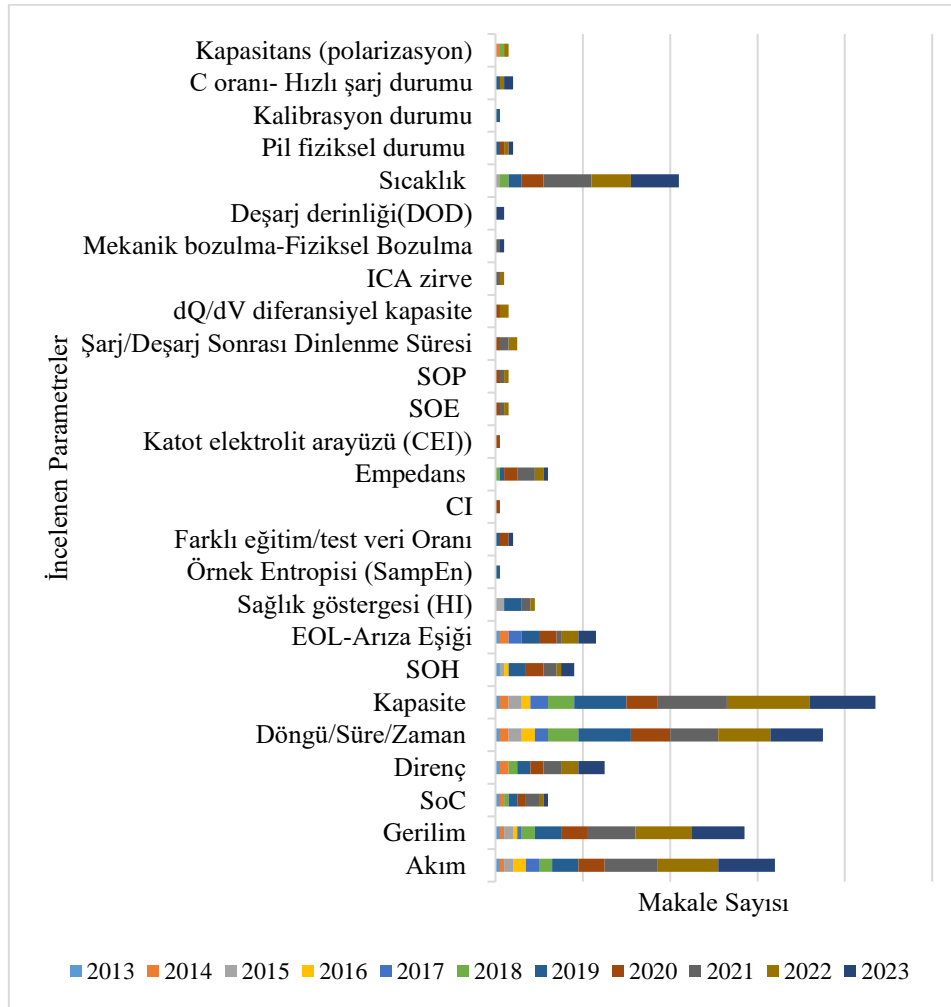
İncelenen Parametreler	2019	2020	2021	2022	2023
Katot Elektrolit Arayüzü (CEI)	✗	✓	✗	✗	✗
Enerji Durumu: Pilin Sağladığı Maksimum Enerji, Enerji.	✗	✓	✓	✓	✗
Güç Durumu: Güç	✗	✓	✓	✓	✗
Şarj/Deşarj Sonrası Dinlenme Süresi	✗	✓	✓	✓	✗
dQ/dV Diferansiyel Kapasite, dV/dQ Diferansiyel Gerilim	✗	✓	✗	✓	✗
ICA Zirve	✗	✗	✓	✓	✓
Mekanik Bozulma, Fiziksel Bozulma	✗	✗	✓	✗	✗
Deşarj Derinliği (DOD)	✗	✗	✗	✗	✓
Sıcaklık: Ortalama Sıcaklık, Ortam Sıcaklığı, Çalışma Sıcaklığı, Minimum Sıcaklık, Maksimum Sıcaklık, Maksimum Değere Ulaşmak İçin Deşarj Sıcaklığı, Farklı Sıcaklık, Sıcaklık Durumu.	✓	✓	✓	✓	✓

Yitao Wu vd. [21] tarafından yapılan çalışmada lityum iyon bataryalar için dQ/dV eğrisi ve IC eğrisi analizinden sağlık özellikleri çıkarılarak sağlık durumu tahmin yöntemi önerilmiş ve tek bir batarya için model eğitiminde %60 döngü veri oranının tahmin hatasına etkisi incelenirken, Sajad Saraygord Afshari vd. ticari pillerin diferansiyel kapasite (dQ/dV) ve diferansiyel gerilim (dV/dQ) eğrilerinin

sadece ilk yüz döngü verilerinden çıkarılan özelliklere dayalı pillerin erken kalan faydalı ömür erken tahminine odaklanmıştır[25].

Rui Xiong vd. çalışmasında, düşük hesaplama yükü ile batarya kapasitesini tahmin etmek ve çevrimdışı eğitim verilerinden bağımsız olarak batarya kalan faydalı ömrünü tahmin etmek için yöntem geliştirmiştir [15].

Aşağıdaki grafikler kalan faydalı ömür tahminini etkileyen parametrelerin yıllara göre kaç makalede incelendiğini göstermektedir.



Şekil 1.2 IEEE 2013-2023 arasında kalan faydalı kullanım ömrü üzerine incelenen parametrelerin makale sayısına göre dağılımları

Yukarıdaki grafiklere göre kalan faydalı ömür tahmininde etkisi olan birçok farklı lityum iyon batarya parametresi bulunmaktadır ve makalelerde değinilme oranları yıllara göre değişiklik göstermektedir. Gerilim ve kapasite parametrelerine her sene değinilmiş olup, bu parametreler incelendiği makale sayısına göre yıla bağlı olarak

artış göstermiştir. 2013-2023 yılları arasında IEEE veritabanlı batarya kalan faydalı ömür tahmini üzerine yayınlanan dergi makalelerinde örnek entropisi, katot elektrolit yüzeyi, enerji durumu, güç durumu, ICA zirvesi ve kalibrasyon gibi parametreler en az incelenen parametrelerdendir ve sayı olarak sadece bir makalede incelenmiştir.

Son yıllarda incelenme sayısında artış gösteren parametreler, 2019 yılından itibaren IEEE dergi makalelerinde yer bulan dQ/dV diferansiyel kapasite değeri ve C oranı, 2021 yılından sonra incelenen deşarj derinliğidir.

1.2 Tezin Amacı

Bu yüksek lisans tezi, NASA lityum iyon batarya bozunum veri setlerini kullanarak lityum iyon batarya kalan faydalı ömür tahmininde makine öğrenmesi yaklaşımının uygulanmasını ve geliştirilmesini amaçlamaktadır. Kalan faydalı ömür değerlerinin doğru tahminleri ile batarya teknolojisi üzerine yapılan çalışmalara ve bu konuda karar vericilerin bilinçli kararlar almasına ve gelecekteki çalışmalara yönelik bir perspektif sunulmaktadır. Çalışma, yapay zeka tabanlı kalan faydalı ömür tahmininde kullanılacak dahili ve harici parametreler ve yöntemler konusunda pratik sonuçlar sağlamaktadır. Kalan faydalı ömür tahmini sonuçlarının performansı, makine öğrenmesi tekniklerinin kontrol yöntemleri ile değerlendirilmiştir ve araştırma sonuçları yapay zeka tabanlı kalan faydalı ömür tahmininde ilerlemeler için yeni imkanlar sunmaktadır.

2 ELEKTRİKLİ ARAÇLAR

2.1 Elektrikli Araçların Tarihsel Gelişimi

1835 yılında Hollanda'da, Profesör Stratingh tarafından geliştirilen ilk elektrikli araç modeliyle başlanarak, 1838'de Robert Davidson'un ürettiği ve 6.4 km/h hıza ulaşabilen elektrikli lokomotif kadar, elektrikli araçlar tarihinde önemli adımlar atılmıştır. 1859'dan sonra kurşun-asit tabanlı bataryalarının geliştirilmesiyle birlikte, elektrikli araçlar için daha verimli bir güç kaynağı sağlanmıştır [127]. Daha sonrasında geliştirilen şarj edilebilen bataryalar, elektrikli araçların gelişiminde önemli bir nokta olmuştur. İlerleyen yıllarda, hibrit araçların ortaya çıkışıyla beraber, özellikle ABD'de, elektrikli araçlar içten yanmalı motorlu araçlardan daha fazla tercih edilmiştir [126].

1882'de Siemens, Berlin'de dünyanın ilk elektrikli trolleybüsü olan iki adet 2.2kW'lık motora sahip, 550V DC ile beslenen Elektromote'u üretmiştir ve bu trolleybüsün ortalama hızı ise 12 km/saattir [127].

1920-1960 yılları arasında düşen petrol fiyatları, içten yanmalı motorlu araçlarda yapılan geliştirmeler, marş motorunun icadı ve araç maliyetlerinin düşmesi gibi faktörler, elektrikli araçların popülerliğinin giderek azalmasına neden olmuştur. Elektrikli araçlar şehir içinde kısa mesafelerde konforlu ve güvenli bir sürüş deneyimi sunarken, uzun mesafelerde ve zorlu yol koşullarında içten yanmalı motorlu araçlara kıyasla daha az etkili oldukları için bu dönemde elektrikli araçlara olan talep azalmıştır [126].

1980'lerde, hükümetler tarafından elektrikli araçların çevre dostu olmaları nedeniyle bu araçlara yönelik ilgiyi artırmaya ve resmi kaynaklardan ekonomik destek sağlanmaya başlanmıştır. 1990'lardan sonra, yeni gelişen batarya

teknolojileriyle birlikte birçok otomobil firması, Ford-Think City, Nissan-Altra EV ve Peugeot 106-Electric gibi elektrikli araç modellerini geliştirmeye başlamıştır [128].

Elektrikli araçların popülerliğini artıran bir diğer önemli bir faktör, Tesla Motors'un tek şarjla 330 km'den fazla yol alabilen lüks bir elektrikli araç üreteceğini ilan etmesi olmuştur. 2008'de Tesla Motors, Tesla Roadster'ı ilk kez müşterilere sunarak, diğer otomobil üreticilerini de elektrikli araçlar konusunda teşvik etmiştir. Batarya fiyatlarının düşmesi ve yeni batarya teknolojisi otomobil üreticilerinin daha uzun menzilli daha ucuz modeller üretmesini sağlayarak yakın gelecekte, hareketliliğin büyümesi ve sürücüsüz araçların ortaya çıkışı, elektrikli araçların elektrikli araç pazarına giriş sürecini daha da hızlandırmaktadır [132].

2.2 Elektrikli Araç Bileşenleri

Elektrikli araçlarda gücün sağlanmasından, sağlıklı bir şekilde aktarılmasına olanak sağlayan ana bileşenler bulunmaktadır [146].

Batarya: Araçtaki diğer bileşenlere güç ve elektrik sağlar.


DC – DC Dönüştürücü: Çekiş bataryası paketinden gelen yüksek gerilim doğru akım gücünü aracın diğer bileşenlerini çalıştırmak ve yardımcı bataryayı yeniden şarj etmek için gerekli düşük gerilim doğru akım gücüne dönüştürür.

Şarj Portu: Çekiş bataryası paketini şarj etmek için aracın harici bir güç kaynağına bağlanmasına izin veren porttur.

Elektrikli Çekiş Motoru: Çekiş bataryasından gelen gücü kullanan bu motor, aracın tekerlerini tahrik etmekte kullanılır.

Soğutma Sistemi: Bu sistem motorun, elektrik motorunun ve güç elektroniği diğer bileşenlerinin uygun çalışma sıcaklığı aralığını korumak için kullanılır.

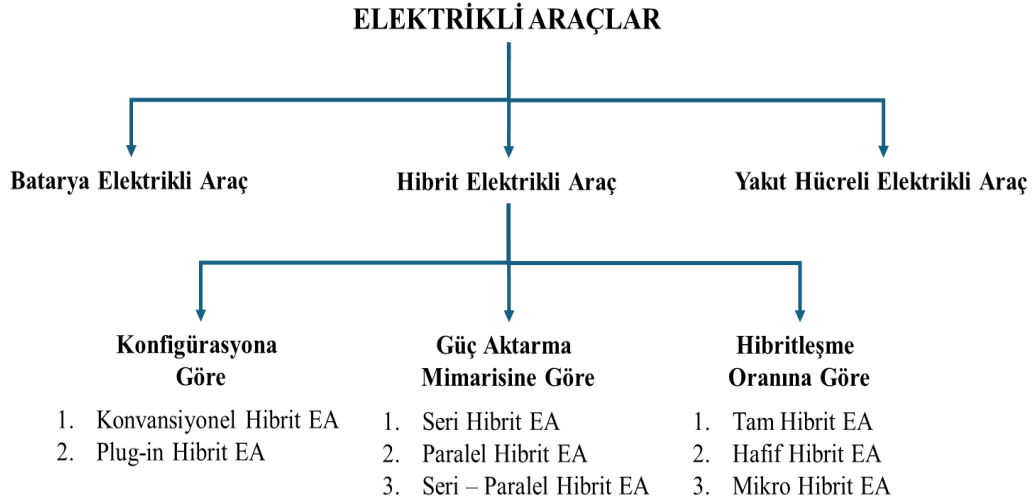
Çekiş Batarya Takımı: Elektrik çekiş motoru tarafından kullanılacak olan elektrikli depolar.



Şekil 2.1 Elektrikli araç mimarisi [146]


2.3 Elektrikli Araçların Sınıflandırılması

Elektrikli araçlar, güç kaynağı tipine göre batarya elektrikli, hibrit elektrikli ve yakıt hücreli araçlar olmak üç sınıfa ayrılmaktadır. Bu sınıfların alt kırımları da Şekil 2.2’de gösterilmiştir [127].



Şekil 2.2 Elektrikli araçların sınıflandırılması

2.3.1 Bataryalı Elektrikli Araçlar



Şekil 2.3 Batarya elektrikli araç yapısı [142]

Bataryalı elektrikli araçlar, UNECE Transport Division'a göre içten yanmalı motor yerine elektrik motoruna sahip olan araçlar, tam elektrikli araçlardır. BEA'lar, elektrik motoruna enerji sağlamak için yüksek kapasiteli bir batarya grubuna sahiptir. Bataryalı elektrikli araçlar batarya paketi, şarj soketi, motor sürücüsü, elektrik motoru, dönüştürücü ve hareket aktarım sisteminden oluşan basit bir mimariye sahiptir [140]. Araç üzerindeki bataryalar üzerinde önceden depo edilmiş olan yük, elektrik motoruna aktarılır ve elektrik motoru aracılığı ile üretilen hareket aktarma sistemi vasıtası ile tekerleklere iletilir ve hareket gerçekleşir. Bataryayı şarj etmek için aracın bir şarj istasyonuna veya duvar prizine bağlanması gerekir. Şarj modülü araç üzerinde veya şarj istasyonunda bulunabilir. Araç üzerinde yer alan sistemlerin boyutu, kapasitesi ve teknolojik özellikleri bu süreyi belirlediğinden bu durum şarj süresine etki eder. Bataryalı elektrikli araçlar elektrikle çalıştığı için bataryalı elektrikli araçlarda bir egzoz sistemi bulunmaz. Benzin pompası, yakıt hattı ve yakıt deposu gibi geleneksel içten yanmalı motor bileşenleri bataryalı elektrikli araçlarda bulunmamaktadır. Egzoz gazı emisyonu olmadığı için

karbondioksit, diğ er nitrojen bazlı zararlı gazlar veya sera gazları salınımı yapmadıklarından çevre dostudur. Ş ekil 2.3'te tam elektrikli aracın araç yapısı verilmiştir.

2.3.2 Hibrit Elektrikli Araçlar

Hibrit elektrikli araçlar (HEA), birden fazla ve farklı yapıda güç kaynağ ının kullanılmasıyla oluşturulur ve batarya-yakıt pili, batarya-kapasitörü veya batarya-batarya gibi farklı hibrit EA versiyonları bulunmaktadır. Birçok HEA'da ise enerji kaynağı olarak iç ten yanmalı motor (İYM), Stirling motoru, gaz türbini veya elektrokimyasal batarya gibi çeş itli sistemler kullanılmaktadır [127]. Hem benzin kullanımını sonucunda üretilen enerji hem de batarya üzerinde depo edilmiş olan enerji motorlar vasıtası ile hareket organlarına aktarılır.

2.3.2.1 Konfigürasyona Göre Hibrit Elektrikli Araçlar


HEA'lar konfigürasyonuna göre Ş ekil 2.2'de gösterildiğı gibi Konvansiyonel Hibrit ve Plug-in hibrit olmak üzere ikiye ayrılmaktadır. Konvansiyonel hibrit elektrikli araçlar, iç ten yanmalı motoru çalıştırmak için ve aracın hızlanmasına yardımcı olmak için düşük akım üreten elektrikli motora sahiptir. Bu araçlarda elektrik motoruna güç aktarımını sağlayan bataryalar genellikle 48V değerine sahiptir ve bu bataryalar hareket esnasında iç ten yanmalı motor yardımıyla doldurulurken plug-in hibrit elektrikli araçlar akaryakıt motorunun yanı sıra kablo bağlantısıyla doldurulabilmektedir. Bu sebeple Plug-in hibrit elektrikli araçlar, kablolu hibrit araç olarak da bilinmektedir ve bu araçlarda bataryanın kapasitesi oldukça yüksektir [141]. Ş ekil 2.4'te hibrit elektrikli aracın yapısı verilmiştir.

2.3.2.2 Güç Aktarma Mimarisine Göre Hibrit Elektrikli Araçlar

Hibrit elektrikli araçlar, güç aktarma mimarisine göre 3'e ayrılmaktadır. Paralel hibrit araçlar konvansiyonel motor ve elektrikli motorun birlikte çalıştığı araçlar, seri hibrit elektrikli araçlar, tekerlekteki hareketin doğ rudan elektrik motorundan sağ landığı araçlardır. Paralel hibrit elektrikli araçlarda tahrik için asıl güç kaynağı elektrik motoruyken, paralel hibrit elektrikli araçlarda asıl güç kaynağı akaryakıt motorudur [141]. Her iki hibrit elektrikli aracın kombinasyonundan seri – paralel hibrit elektrikli araç mimarisi oluş maktadır. Bu araçlarda elektrik motoru, ihtiyaca göre motor veya jeneratör olarak çalıştırılabilir.

2.3.2.3 Hibritleşme Oranına Göre Hibrit Elektrikli Araçlar


HEA'lar hibritleşme oranına göre hafif hibrit, tam hibrit ve mikrohibritle olarak üçe ayrılır. Tam hibrit elektrikli araçlar yalnızca elektrik motoru enerjisiyle çalışırken yarı hibritli araçlarda ana güç kaynağı, tam hibrit elektrikli araçların aksine geleneksel yakıtlı motordur. Yarı hibrit elektrikli araçlar, yakıt tüketimini azaltmak konusunda oldukça yararlıdır [143]. Rölantideyken start/stop ve enerji yönetimi fonksiyonlarına sahip olan araçlara mikrohibritle elektrikli araçlar adı verilir. Start/stop fonksiyonu, araç hareketsiz durumdayken, sürücünün müdahalesi olmadan içten yanmalı motoru kapatan fonksiyondur [142].



Şekil 2.4 Hibrit elektrikli araç yapısı [142]

2.3.3 Yakıt Hücreli Araçlar

Yakıt pilli elektrikli araçlar, tüm elektrikli araçlardaki uzun batarya şarj süresi ve kısa menzil sorunlarına karşı geliştirilen bir araç türüdür. İçerdiği sistem sayesinde ihtiyaç duyduğu enerjiyi anında üretebilmektedir [127]. Yakıt pilli elektrikli araçların menzili, konvansiyonel araçlara benzer şekilde yakıt tankındaki yakıt miktarına bağlıdır. Bu araçlar, yakıt depolama sistemi, yakıt pili kontrol ünitesi, güç işlemci ünitesi kontrolü ve tahrik sistemlerini de içinde barındırmaktadır. Şekil 2.5'te yakıt hücreli elektrikli aracın mimarisi verilmiştir.



Şekil 2.5 Yakıt hücreli araç yapısı [142]

2.4 Elektrikli Araçlarda Kullanılan Batarya Türleri

Günümüzde kullanım alanına göre çok fazla sayıda batarya çeşidi bulunmaktadır. Ancak kullanıcıların ve EA üreticilerinin en büyük sorunu batarya ömrü ve maliyetidir. Bataryalar kullanılan pil kimyasına göre sınıflandırılırlar.

2.4.1 Nikel Metal Hidrit (NiMH) Bataryalar

Şarj edilebilir bir pil türüdür ve nikel ve metal hidrit bileşiği içeren bir kimyasal bileşeninden ismini almaktadır. Önceki EA modellerinde yaygın olarak kullanılan nikel-metal hibrit bataryalar, daha düşük enerji yoğunlukları ve daha kısa döngü ömürleri nedeniyle lityum-iyon bataryaların performansından geride kalmaktadır. Bilgisayar ve tıbbi ekipmanlarda da sıkça kullanılan bu elektrikli araç batarya tipi, düşük özgül enerji ve özgül güç kapasitesine sahiptir. Yüksek enerji yoğunluğu, hafıza etkisinin az olması, geniş sıcaklık aralığında çalışabilmeleri gibi avantajlarının yanı sıra kendi kendine deşarj olma, düşük güç yoğunluğu ve performans düşüşü gibi dezavantajları bulunmaktadır [144].

2.4.2 Lityum-İyon Bataryalar

Elektrikli araçlarda kullanılan bataryalar arasında en yaygın tür olan lityum-iyon bataryalar, yüksek enerji yoğunluğu, hızlı şarj özellikleri ve uzun çevrim ömrüne sahiptir. Elektrikli araçlarda lityum iyon pil ayrıca hafif ve kompakt bir yapıya sahip

olduğu için sıkça kullanılmaktadır. Boyut ve ağırlığı sayesinde çok daha fazla enerji depolayan lityum iyon pil teknolojisi, araçlarda uzun menzil ve artırılmış verimlilik sağlamaktadır [133]. Lityum iyon bataryalar için hafıza etkisi olmadığından, bu bataryaları şarj etmek için tam olarak boşalmalarını beklemeye ihtiyaç duyulmamaktadır.

2.4.3 Lityum Polimer (Li-Po) Bataryalar

Lityum polimer bataryalar, lityum iyon bataryalara benzer özelliklere sahiptir. Ancak daha düşük yoğunluğa sahip olmalarına rağmen daha esnek şekillerde üretilirler. Bu esneklikten dolayı otonom robotlar için farklı şekil ve boyutlarda batarya tasarlanmasını sağlar. Ayrıca, lityum polimer bataryalar daha az şişme ve patlama riskine sahiptir.

2.4.4 Kurşun-Asit Bataryalar

En eski şarj edilebilir pillerden biri olan kurşun-asit bataryalar, düşük maliyetleri ve yüksek deşarj oranları sebebiyle hem içten yanmalı hem de elektrik motorlu birçok araçta tercih edilmektedir. Maliyeti düşük olmasının sebebi batarya yapımında kullanılan malzemelerin düşük maliyete sahip olmasıdır [145]. Bu batarya türü, lityum pillerle oranla çok daha ağır ve kısa ömürlüdür [126], [133]. Avantajlarının yanı sıra, sıcaklık karakteristiklerinin kötü olması ve sülfürik asidin yüksek oranda korozyon etkisinin olması sebebiyle, araç içerisindeki yolcular için potansiyel tehlike kaynağı olabilir [145].

2.5 Elektrikli Araçlarda Batarya Yönetim Sistemi

Uluslararası Enerji Ajansı'nın yaptığı çalışmalara göre, mevcut enerji tüketim hızı ve politikalar devam ederse artan enerji talebi daha da yükselecektir. Bu durum, daha fazla insana enerji arzı sağlanması gerekliliğini gündeme getirmektedir [1]. Enerji talebindeki artış, enerji depolama sistemleri ve batarya teknolojilerinin geliştirilmesi gibi yeni ihtiyaçları ortaya çıkarmaktadır. Yüksek enerji yoğunluğu, uzun çevrim ömrü, düşük kendi kendine deşarj oranı, hafiflik ve hafıza etkisi olmaması gibi özellikleri sayesinde elektrikli araçlarda yaygın olarak kullanılan lityum-iyon bataryalar, çalışma limitleri dışında kullanıldıklarında yangın, toksik gaz salınımı ve elektrik çarpması gibi riskler taşır. Bu nedenle, hücrelerin uygun akım, gerilim ve sıcaklık limitlerinde çalışmasını sağlamak amacıyla batarya

yönetim sistemlerinin kullanımı zorunludur [2]. Batarya Yönetim Sistemi (BYS), bataryanın izlenmesi ve optimizasyonunu sağlayacak, gerilim ve akım gibi bilgileri toplayarak bataryanın sağlık durumu ve kalan kullanım ömrünü önceden tahmin edebilecek özelliklere sahip olmalıdır [3]. Batarya yönetim sisteminin odaklandığı önemli konulardan biri de bataryanın sağlık durumu ve kalan faydalı ömrünün tahmin edilmesidir. Kalan faydalı ömür, elektrikli komponentin yeniden kullanıma sunulmak üzere etkili bir şekilde çalışmaya devam edebileceği tahmini zaman süresini ifade eder ve yaşam döngüsü veri analizi, deneysel gözlemler yoluyla tahmin edilir [136]. Bu tahminler, uzun menzilli araçların üretimine katkı sağlamaktadır [4].

2.6 BYS Fonksiyonları

Batarya yönetim sistemleri, elektrikli araçlar, yenilenebilir enerji sistemleri, enerji depolama sistemleri gibi birçok alanda kullanılan ve bataryaların kontrol ve denetimini sağlayan kontrol mekanizmalarıdır. Batarya yönetim sisteminin fonksiyonları aşağıdaki gibi sıralanabilir [137].

Verileri İzleme: Batarya paketlerinin anlık durumları gözlemlenir. Batarya gerilim durumu, sıcaklık bilgisi, şarj durumu, deşarj yoğunluğu, akım gibi değerler batarya yönetim sistemi tarafından izlenir.

Hesaplama: Hesaplama kısmında batarya yönetim sistemi, maksimum şarj akımı, maksimum deşarj akımı, hücrelerde ve bataryalarda görülen gerilim değeri ve şarj-deşarj döngü sayısı gibi hesaplamalar yapmaktadır.

Koruma: Koruma fonksiyonunda batarya yönetim sistemi, optimum değerler aşıldığında duruma müdahale etmek için bir takım önlemler alarak sistemin korunmasını sağlar. Yüksek sıcaklık, yüksek basınç, aşırı akım vb. gibi durumlarda koruma sağlar.

Optimizasyon: Batarya yönetim sistemi, bataryaların kapasitesini üst seviyeye çıkarmayı ve verimliliğini artırmak için dengeleme sağlar. Herhangi bir hücrede aşırı gerilim durumunda müdahale eder ve sistemi optimize eder.

3

YAPAY ZEKA TABANLI TAHMİN YÖNTEMLERİ

3.1 Yapay Zekanın Kalan Faydalı Ömür Tahmininde Konumu

Yapay zeka tabanlı yaklaşımlar, altta yatan mekanizma hakkında bilgi gerektirmemesi, esneklik ve güçlü eşleştirme yeteneklerinden dolayı kalan faydalı ömür tahmininde sıkça kullanılırlar. Bu yapay zeka tabanlı yöntemlerde, bataryanın değişken bozulma modeline uyması açısından mevcut gözlem ve ölçümlere yapay zeka teknikleri uygulanarak sistemin bozulma modeli oluşturulur ve parametreler ile birlikte arıza eşiği genelleştirilerek kalan faydalı ömür belirlenir [32].

3.2 Yapay Zeka Tabanlı Yöntemlerin Genel Adımları

Yapay zeka tabanlı tahminleme yöntemleri uygulanırken dikkate alınması gereken birkaç önemli adım bulunmaktadır. Model seçiminden önce, tahmin doğruluğu ve güvenilirliği açısından yeterli sayıda ve yüksek kaliteli veriye sahip olmak ve model seçiminin modelin üstünlükleri ve sınırlamalarını göz önünde bulundurularak yapılması önemlidir. Verilerin eğitim seti ve test setine ayrılarak eğitim setini modele uydurulur ve test seti modelin performansını değerlendirmek için kullanılır.

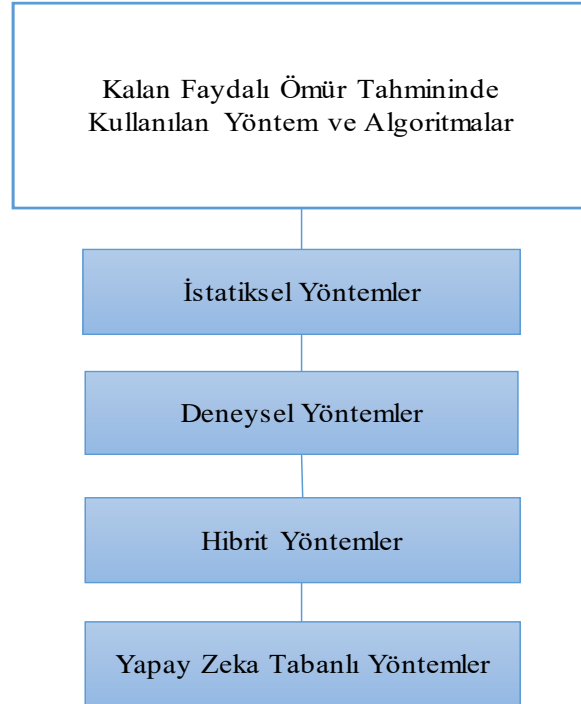
Yapay zeka modelinin performansının düzenli olarak değerlendirilmesi ve gerçek ölçümlerle karşılaştırılması doğruluk, hassasiyet gibi temel performans göstergelerini izlemek modelin hala doğru ve uygun olduğundan emin olunması açısından önemlidir. Modelin doğru çalışmaya devam etmesi için düzenli olarak kontrol edilmesi eğer gerekiyorsa güncellenmesi ve bakım yapılması önemlidir.



Şekil 3.1 Yapay zeka tabanlı tahminler için izlenecek yol

3.3 Yaygın Yöntemler

Kalan faydalı ömür tahminlerinde kullanılacak veriye göre ve tahmin amacına göre farklı yöntemler kullanılmaktadır. Kalan faydalı ömür tahmini yapılırken kullanılan yöntemlerin sınıflandırılması Şekil 3.2’de sunulmuştur. İstatistiksel yöntemler, daha önce toplanmış veriler üzerinden kalan faydalı ömür yapmak için kullanılırken yapay zeka tabanlı yöntemlerde ise mevcut gözlemlere yapay zeka teknikleri uygulanarak sistem bozulma modeli oluşturulur ve bu modele göre kalan faydalı ömür tahmini yapılır. Hibrit yöntemler, farklı modellerin üstünlüklerini birleştirerek kalan faydalı ömür konusunda yüksek tahmin doğruluğu üretmek için kullanılmaktadır. Deneysel yöntemlerde ise pilin işlevini etkileyen belirli kimyasal ve fiziksel parametrelere dayanarak model oluşturulur [32].



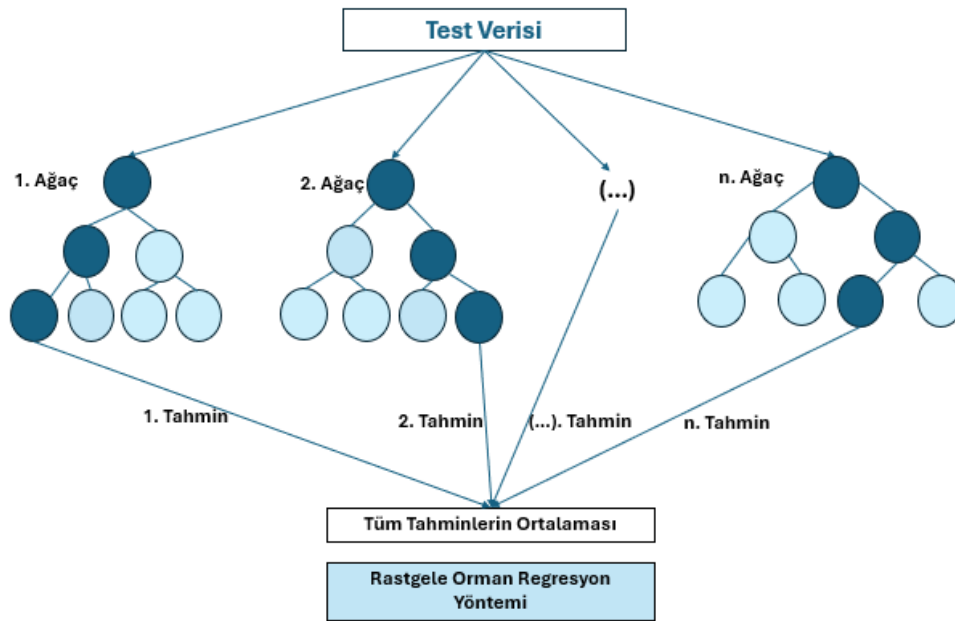
Şekil 3.2 Kalan faydalı ömür tahmininde kullanılan yöntemlerin sınıflandırılması

3.3.1 Rastgele Orman Regresyon Yöntemi

Rastgele orman regresyon (ROR) yöntemi, veri biliminde sınıflandırma ve regresyon problemlerinde sıkça kullanılan gözetimli bir yapay zeka tabanlı algoritmadır. Farklı örneklemeler üzerinde karar ağacı oluşturarak sınıflandırma kısmında çoğunluk oyunu yaparken, regresyon durumunda ise ortalamayı alarak hesaplama almaktadır. ROR yöntemi, hem sürekli değişkenleri (regresyon problemlerinde), hem de kategorik değişkenleri (sınıflandırma problemlerinde) etkili bir şekilde işleyebilmesi özelliğinden dolayı yüksek performans göstermektedir [135].

Makine öğreniminde ROR algoritmasının çalışma prensibini anlamadan önce, ensemble öğrenme tekniğine bakmamız gerekmektedir. Ensemble, birçok modelin bir araya getirilerek kullanılması demektir. Böylece tek bir model yerine bir model koleksiyonu kullanılarak tahminler yapılır [138]. Ensembled model iki tür yöntem kullanır:

- Eğitim verilerinden değişik eğitim alt kümeleri oluşturarak, çoğunluk oylamasına dayanır. Örneğin, ROR.
- Zayıf öğrencileri güçlü öğrencilere dönüştürerek ardışık modeller oluşturur ve nihai modelin en yüksek doğruluğa sahip olmasını sağlar [138].



Şekil 3.3 Rastgele orman regresyon yöntemi

3.3.2 İleri Seviye Gradyan Yükseltici Regresyon Yöntemi


İleri seviye gradyan yükseltici regresyon yöntemi, karar ağaçlarını kullanarak ve model genellemesini geliştirmek için düzenleme teknikleriyle regresyon, sınıflandırma ve sıralama dahil olmak üzere çok çeşitli görevler için başvurulan algoritmadır. Genellikle karar ağaçları olan birden fazla bireysel modelin tahminlerini yinelemeli bir şekilde birleştirerek tahmini bir model oluşturur. Algoritma, zayıf öğrenenleri topluluğa sırayla ekleyerek çalışır ve her yeni öğrenen mevcut olanların yaptığı hataları düzeltmeye odaklanır. Eğitim sırasında önceden tanımlanmış bir kayıp fonksiyonunu en aza indirmek için bir gradyan iniş optimizasyon tekniği kullanır [134].

3.3.3 K- En Yakın Komşu Regresyon Yöntemi

Kolayca uygulanmasının yanısıra, büyük veri setleri veya yüksek boyutlu özellik alanlarında hesaplama maliyeti oldukça yüksek olabilir [129].

K-En Yakın Komşu, veriye dayalı bir öğrenme algoritması olduğu için modelin eğitim aşamasında bir işlem yapmaz. Sadece tahmin yapmak istediğimiz nokta için en yakın komşuları kullanarak tahmin değerini hesaplar. K-En Yakın Komşu Regresyonunun çalışma mantığı aşağıdaki adımlarla gerçekleştirilmektedir.

- İlk olarak, regresyon yapmak için kullanılacak veri seti belirlenir ve K değeri seçilir.
- Veri noktaları, uzaydaki konumlarına göre gruplandırılır.
- Tahmin yapmak istenen noktanın K en yakın komşusu belirlenir.
- Belirlenen K en yakın komşu değişken değerlerine göre tahmin yapılır ve bu değerler, ağırlıklı bir ortalama veya medyan değer olarak hesaplanabilir.



Şekil 3.4 K-en yakın komşu regresyon yöntemi

3.4 Kontrol Yöntemleri

Tahmin doğruluklarının değerlendirilmesi, tahmin edilen ve gerçek değer arasındaki farkı inceleyen kayıp fonksiyonlarla açıklanmaktadır. Kayıp fonksiyonu değeri daha küçük olması, tahmin edilen değer ile gerçek değer arasında farkın az olduğu ve modelin daha iyi performans gösterdiği anlamına gelmektedir [130].

3.4.1 Ortak Mutlak Hata

Ortak Mutlak Hata (Mean Absolute Error-MAE) metriği tahmin edilen değerler ve gerçek değerler arasındaki farkın mutlak değerlerinin ortalamasını ifade eder. Bu hata metriği, tahmin doğruluğunu değerlendirmek ve hata boyutunu anlamak için kullanılır [131].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.1)$$

3.4.2 Determinasyon Katsayısı

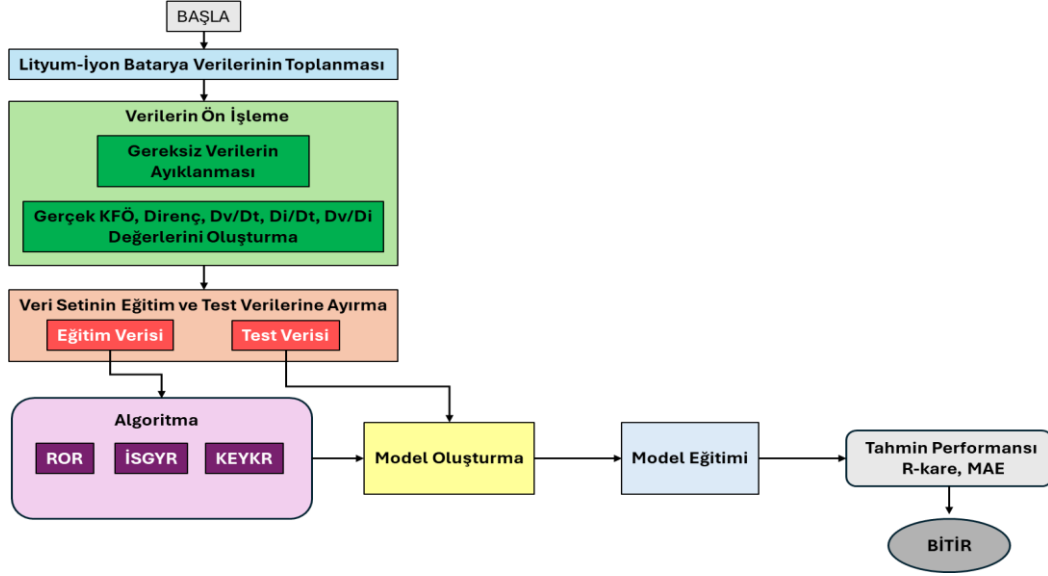
Determinasyon katsayısı bir regresyon modelinin veriye ne kadar iyi uyarlandığını gösteren bir ölçüttür [131].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.2)$$

3.4.3 Özellik Önem Derecesi

Özellik önem derecesi bir makine öğrenmesi modelinin hangi giriş değişkenlerinin (özelliklerin) tahmin yaparken ne kadar etkili olduğunu gösteren bir metriktir. Modellemelerde özellik önem derecesi incelenmiştir.

3.5 Tasarım Süreci



Şekil 3.5 Tahmin algoritma şeması

Tahminleme sürecinde kullanılacak olan algoritma şeması Şekil 3.5'te gösterilmektedir. Bu şemaya göre, lityum iyon batarya verileri toplandıktan sonra gereksiz verilerin ayıklanması ve gerçek kalan faydalı ömür değerleri veri seti içerisine eklenir. Daha sonrasında bu veriler eğitim ve test verisi olacak şekilde ikiye ayrıldıktan sonra yapay zeka tabanlı makine öğrenmesi teknikleri ile tahminleme modeli oluşturulur. Model tahmin performansı ortalama mutlak hata ve determinasyon katsayısı değerleri ile değerlendirilir. Bu adımlar ilerleyen bölümlerde sırasıyla açıklanmıştır.

3.5.1. Lityum-İyon Batarya Verilerinin Toplanması

Lityum-iyon batarya bozunum veri setleri NASA'nın açık veri setlerinden elde edilmiştir. Tekrarlanan şarj ve deşarj döngüleri bataryanın yaşlanmasına neden olurken empedans ölçüleri, yaşlanma ilerledikçe bataryanın parametreleri hakkında bilgi sağlar.

Tablo 3.1 Veri setine genel bakış

Type	Ambient Tempera ture	...	Filename	Capacity	Re	Rct
Discharge	4	...	00001.csv	1.6743047		
Impedance	24	...	00002.csv		0.0560578	0.2009701658
Charge	4	...	00003.csv			
Impedance	24	...	00004.csv		0.0531918	0.164733999
Discharge	4	...	00005.csv	1.5243662		
...

Deneyler, bataryalar belirli bir kullanım ömrü sonu kriterine, nominal kapasitede %30 azalma (2Ahr'den 1,4Ahr'ye). ulaştığında durdurulmuştur.

3.5.1.1. Batarya Şarj Profili

Veri seti içerisindeki tüm batarya testlerinin şarj profili aynıdır. Şarj işlemi batarya gerilimi 4.2V'a ulaşana kadar 1.5A sabit akım(CC) modunda gerçekleştirilmiş ve daha sonra şarj akımı 20mA'e düşene kadar sabit voltaj(CV) modunda devam ettirilmiştir.


Şarj veri setindeki parametreler aşağıdaki gibi tanımlanır.

- Voltage_measured: Batarya terminal gerilimi (V)
- Current_measured: Batarya çıkış akımı (A)
- Temperature_measured: Batarya sıcaklığı (°C)
- Current_charge: Şarj cihazında ölçülen akım (A)
- Voltage_charge: Şarj cihazında ölçülen gerilim (V)
- Time: Döngü için zaman vektörü (sn)


Tablo 3.2 Şarj veri setine genel bakış

Ind	Voltage measured	Current measured	Temp measured	Current Charge	Voltage Charge	Battery_id	cycle
0	3.486189	0.001417	5.990142	-0.0006	0.002	B0047	1
1	3.746592	1.489057	5.992528	1.4995	4.618	B0047	1
2	3.775438	1.490426	5.991340	1.4995	4.669	B0047	1
...
6512875	4.214086	0.035222	6.428595	0.0348	4.250	B0055	2815


Bataryanın şarj profilindeki batarya terminal gerilimi Şekil 3.6'da, batarya çıkış akımı Şekil 3.7'de, batarya sıcaklığı Şekil 3.8'de, şarj cihazı akımı Şekil 3.9'da, ve şarj cihazı akımı Şekil 3.10'da gösterilmektedir.




Şekil 3.6 Şarj veri seti ölçülen gerilimin zamana göre değişimi




Şekil 3.7 Şarj veri seti ölçülen akımın zamana göre değişimi



Şekil 3.8 Şarj veri setinde ölçülen sıcaklığın zamana göre değişimi



Şekil 3.9 Şarj veri setinde şarj cihazı akımının zamana göre değişimi



Şekil 3.10 Şarj veri setinde şarj cihazı geriliminin zamana göre değişimi

3.5.1.2. Batarya Deşarj Profili

Veri seti içerisindeki deşarj profilleri bataryaya göre deęişkenlik göstermektedir. Batarya gerilimi 2.7 V, 2.5 V, 2.2 V deęerlerine düşene kadar 1-4A sabit akım(CC) seviyesinde deşarj gerçekleştirilmiştir.


Deşarj veri setindeki parametreler aşağıdaki gibi tanımlanır.

- Voltage_measured: Batarya terminal gerilimi (V)
- Current_measured: Batarya çıkış akımı (A)
- Temperature_measured: Batarya sıcaklığı (°C)
- Current_load: Yükte ölçülen akım (A)
- Voltage_load: Yükte ölçülen gerilim (V)
- Time: Döngü için zaman vektörü (sn)
- Capacity: 2,7V'a kadar deşarj için akü kapasitesi (Ahr)


Tablo 3.3 Deşarj veri setine genel bakış

Ind	Voltage measured	Current measured	Temp measured	Current Load	Voltage Load	Battery_id	cycle
0	4.246711	0.000252	6.212696	0.0002	0.000	B0047	1
1	4.246764	-0.001411	6.234019	0.0002	4.262	B0047	1
2	4.039277	-0.995093	6.250255	1.0000	3.465	B0047	1
...
770069	3.734484	-0.000687	12.690525	0.0006	0.000	B0055	2794


Bataryanın deşarj profilindeki batarya terminal gerilimi Şekil 3.11’de, batarya çıkış akımı Şekil 3.12’de, batarya sıcaklığı Şekil 3.13’te, yükte ölçülen akım Şekil 3.14’te, ve yükte ölçülen gerilim Şekil 3.15’te gösterilmektedir.




Şekil 3.11 Deşarj veri setinde batarya terminal geriliminin zamana göre deęişimi




Şekil 3.12 Deşarj veri setinde ölçülen akımın zamana göre değişimi



Şekil 3.13 Deşarj veri setinde ölçülen sıcaklığın zamana göre değişimi



Şekil 3.14 Deşarj veri setinde ölçülen yükte ölçülen akımın zamana göre deęişimi



Şekil 3.15 Deşarj veri setinde ölçülen yük geriliminin zamana göre deęişimi

3.5.1.3. Batarya Empedans Ölçümü

Bataryaların empedans ölçümü, 0.1Hz'den 5kHz'e kadar bir elektrokimyasal empedans spektroskopisi (EIS) frekans taraması yoluyla gerçekleştirilmiştir. Bataryalar belirli bir kullanım ömrü değerine ulaştığında deneyler durdurulmuştur.

Empedans veri setindeki parametreler aşağıdaki gibi tanımlanır.

- Sense_current: Algılama dalındaki akım (A)
- Battery_current: Akü dalındaki akım (A)
- Current_ratio: Yukarıdaki akımların oranı
- Battery_impedance: Ham verilerden hesaplanan akü empedansı (Ω)
- Rectified_impedance: Kalibre edilmiş ve düzeltilmiş akü empedansı (Ω)
- Re: Tahmini elektrolit direnci (Ω)
- Rct: Tahmini şarj transfer direnci (Ω)

3.5.2. Lityum-İyon Batarya Verilerinin İşlenmesi

Lityum iyon şarj veri setinde kullanılmayacak olan batarya kimliği gibi sütunlar veri setinden çıkarılarak, direnç, gerilimin zamana göre değişimi, akımın zamana göre değişimi ve bu değişimlerin birbirine oranı parametreleri veri setine eklenir.

Eklenen parametreler aşağıdaki gibi tanımlanır.

- Resistance : Direnç değeri, mevcut veri seti üzerindeki batarya terminal geriliminin batarya terminal akımına oranı olarak tanımlanır. Denklem 3.3'teki formül ile hesaplanır.

$$\text{Direnç } (\Omega) = \frac{\text{Batarya Terminal Gerilimi (V)}}{\text{Batarya Terminal Akımı (I)}} \quad (3.3)$$

- dv/dt parametresi: Batarya terminal geriliminin zamana göre değişimi olarak tanımlanmaktadır. Denklem 3.4'teki formül ile hesaplanır.

$$\left(\frac{dv}{dt}\right)_i = \frac{V_{i+1}-V_i}{T_{i+1}-T_i} \quad (3.4)$$

- di/dt parametresi: batarya terminal akımının zamana göre değişimi olarak tanımlanmaktadır.

$$\left(\frac{di}{dt}\right)_i = \frac{I_{i+1}-I_i}{T_{i+1}-T_i} \quad (3.5)$$

- dv/di parametresi: dv/dt ve di/dt parametrelerinin birbirine oranıdır.

$$\left(\frac{dv}{di}\right)_i = \frac{\left(\frac{dv}{dt}\right)_i}{\left(\frac{di}{dt}\right)_i} \quad (3.6)$$

Tablo 3.4 Parametrelerin veri setine işlenmesi

Ind	RUL	...	Resistance	dv/dt	di/dt	dv/di
0
1	10800.719	...	2.516084	0.004558	0.000216	21.073628
2	10794.391	...	2.533127	0.003074	0.000174	17.619660
...
6512875	0.000	...	119.644558	0.000000	0.000000	NaN

3.5.3. Veri Setini Eğitim ve Test Verilerine Ayırma

Mevcut şarj veri setinin %50'si test kümesi, %50'si eğitim kümesi ayrılarak eğitim kümesindeki hedef değişken RUL(KFÖ) sütununu içerirken, eğitim kümesindeki özellik değişkenleri içerir.

- `train_X`: Eğitim için kullanılacak özellikleri belirtir.
- `train_y`: Eğitim için kullanılacak hedef değişkeni (KFÖ) belirtir.
- `test_X`: Test için kullanılacak özellikleri belirtir.
- `test_y`: Test için kullanılacak hedef değişkeni (KFÖ) belirtir.

Tablo 3.5 Eğitim için kullanılacak hedef deęişkeni RUL (KFÖ)

Ind	RUL
30396	4336.546
1484677	6650.781
3933510	8240.125
...	...
6413414	8190.563

Tablo 3.6 Eğitim için kullanılacak özellikler

Ind	Current Measured	...	Resistance	dv/dt	di/dt	dv/di
30396	0.072035	...	58.496717	-0.000004	-0.000001	2.754328
1484677	0.446859	...	9.396935	0.000018	-0.000248	-0.073735
3933510	1.512445	...	2.747047	0.000225	0.000716	0.313649
...

Tablo 3.7 Test için kullanılacak hedef değışkeni RUL(KFÖ)

Ind	RUL
2393138	8821.860
2833048	2170.766
2605205	3744.922
...	...
152004	1117.219

Tablo 3.8 Test için kullanılacak özellikler

Ind	Current Measured	...	Resistance	dv/dt	di/dt	dv/di
30396	0.072035	...	58.496717	-0.000004	-0.000001	2.754328
1484677	0.446859	...	9.396935	0.000018	-0.000248	-0.073735
3933510	1.512445	...	2.747047	0.000225	0.000716	0.313649
...

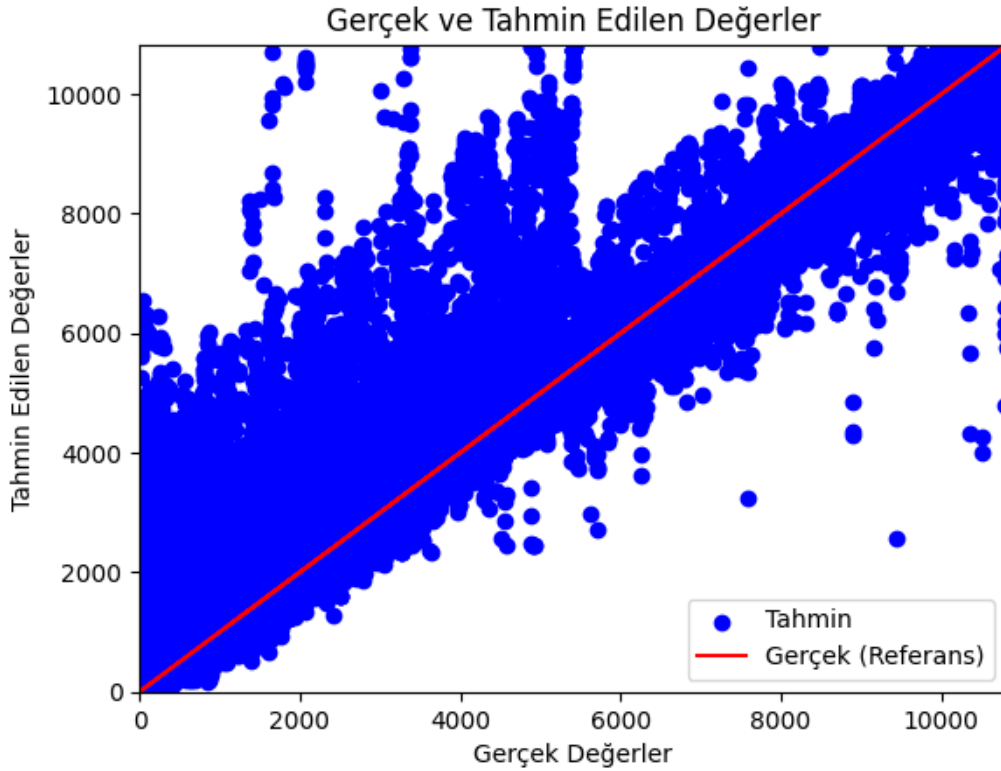
Eđitim verisi ve test verisi kullanılacak özellikler ve kullanılacak hedef değışkeni üzerinden model oluşturmak için kullanılır. Daha sonra modelin doğruluđu metriklerle birlikte değerlendirilir.

4

SONUÇ

4.1 Rastgele Orman Regresyonu Yöntemi ile Tahmin Sonuçları

Veri seti eğitim ve test veri setlerine ayrıldıktan sonra rastgele orman regresyonu yöntemi ile tahminleme yapılır. Rastgele orman regresyonu ile yapılan tahminlemelerde, Şekil 4.1, Şekil 4.2, Şekil 4.3 ve Şekil 4.4'te tahmin edilen değerler ve gerçek değerler arasındaki bağlantı görselleştirilmiştir. Kırmızı eğri, gerçek kalan faydalı ömür değerini gösterirken mavi değerler rastgele orman regresyonu ile yapılan tahmin değerlerini göstermektedir.



Şekil 4.1 Mevcut veri setinde ROR ile KFÖ tahmini (%50 test verisi)

Şekil 4.1’de mevcut veri seti üzerinden yapılan tahminlemenin sonuçlar görülmektedir. Veri seti %50 test verisi olacak şekilde ayrıştırılmıştır. Ortalama mutlak hata değeri 22.5023 iken, determinasyon katsayısı değeri 0.99868’dir.

Tablo 4.1 Mevcut veri seti üzerinden ROR tahminleme metrikleri

Metrik (%50 Test verisi)	
MAE	22.5023
R^2	0.99868


Tablo 4.2 Mevcut veri seti üzerinden yapılan ROR tahminlemelerindeki özellik önem dereceleri

Özellik Önem Sıralaması	
(%50 Test verisi)	
Time	0.9503214158531171
Temperature_measured	0.020465822919568954
Cycle	0.020325252758386005
Voltage_Charge	0.0035819171111145074
Current_Charge	0.0032262622086964175
Current_Measured	0.002079329149116938

Tablo 4.2’de mevcut veri setinde %50 test verisi ile yapılan rastgele orman regresyon yöntemi tahminlemesinde etkili parametrelerin hassasiyet dereceleri hesaplanmıştır. Bu tabloya göre, zaman ve döngü değerlerinden farklı olarak tahmin değeri ile en yüksek ilişkisi bulunan parametrelerden biri batarya sıcaklığı olmuştur.

Mevcut veri setine dv/dt ve di/dt parametreleri eklenerek tahminlemeler yapıldığında tahminleme metrikleri Tablo 4.3’te verildiği gibi hesaplanmaktadır. Şekil 4.2’de mevcut veri setine dv/dt ve di/dt eklenerek ve test veri oranı %50

alınarak yapılan ROR ile tahminlemelerin dağılım grafiği verilmiştir. Eklenen özellikler ile birlikte MAE oranı artarak determinasyon katsayısı oranı düşmektedir. Buna bağlı olarak model doğruluk performansı düşmektedir.



Şekil 4.2 Mevcut veri setine dv/dt ve di/dt eklenerek ROR ile KFÖ tahmini (%50 test verisi)

Tablo 4.3 Mevcut veri seti üzerine dv/dt ve di/dt parametreleri eklenerek yapılan ROR tahminleme metrikleri

Metrik (%50 Test verisi)	
MAE	27.1661
R^2	0.99832


Tablo 4.4'te mevcut veri setine dv/dt ve di/dt parametreleri eklenerek ve test veri oranı %50 alınarak yapılan ROR tahminlemelerinde etkili parametrelerin hassasiyet dereceleri hesaplanmıştır. Eklenen parametrelerle birlikte özellik önem sıralamasında ciddi bir değişiklik olmamıştır. Zaman ve döngü değerlerinden farklı olarak tahmin değeri ile en yüksek ilişkisi bulunan parametrelerden biri batarya

sıcaklığı olmuştur. Ancak ilk tahminlemeye göre, yeni parametrelerin eklenmesiyle birlikte hassasiyet oranı biraz azaldığı tablolardan görülmektedir.


Tablo 4.4 Mevcut veri seti üzerine dv/dt ve di/dt parametreleri eklenerek yapılan ROR tahminlemelerinde özellik önem dereceleri

Özellik Önem Sıralaması	
(%50 Test verisi)	
Time	0.9502622333784975
Temperature_measured	0.02035865152817304
Cycle	0.019859436657879776
Voltage_Charge	0.003539211566201547
Current_Charge	0.0031559494758424196
Current_Measured	0.0020019403073676116
dv/dt	0.0004669969409793801
di/dt	0.0003555801450586694

Mevcut veri setine batarya terminal gerilim ve akımı değerlerinden direnç hesabı yapılarak direnç değerleri, gerilim ve akımın zamana göre değişim değerleri (dv/dt ve di/dt) ve bu değerlerin birbirine oranı dv/di değeri yeni özellik olarak eklenerek ve test verisi oranı %50 alınarak, rastgele orman regresyonu yöntemi ile tahminlemeler gerçekleştirildiğinde Şekil 4.3'teki grafik elde edilirken, test verisi oranı %60 olarak alındığında Şekil 4.4'teki grafik elde edilir ve Tablo 4.2'de bu tahminlemelerin metrik değerleri verilmiştir. Buna göre, ROR ile yapılan tahminlemede %60 test verisi kullanılması durumu MAE değerini artırarak, tahmin doğruluğunu azaltmıştır. Buna ek olarak, mevcut veri seti üzerinden yapılan tahminlemeye göre, yeni parametrelerin eklenerek ROR ile tahminleme yapılması tahmin doğruluğunu azaltmıştır. MAE değeri yaklaşık 22.5023'ten 30.56133235'e çıkarken, determinasyon katsayısı oranı 0.99868'den 0.9980 civarlarına düşmüştür. Yeni parametrelerin eklenmesi ROR ile tahminlemede efektif olmamıştır.



Şekil 4.3 Mevcut veri setine direnç değeri, dv/dt , di/dt ve dv/di eklenerek ROR ile KFÖ tahmini (%50 test verisi)



Şekil 4.4 Mevcut veri setine direnç değeri, dv/dt , di/dt ve dv/di eklenerek ROR ile KFÖ tahmini (%60 test verisi)

Tablo 4.5 Mevcut veri setine direnç değeri,dv/dt,dv/di ve di/dt eklenerek ROR yöntemi ile tahminleme metrikleri

Metrik	%50 Test verisi	%60 Test verisi
MAE	30.561332359311994	36.99829039869016
R^2	0.998000210242206	0.9975092570212319

ROR ile tahminlemede özelliklerin tahmin doğruluğunda önem sıralaması çıkarıldığında Tablo 4.6'daki bulgular elde edilir. Buna göre, zaman ve döngü parametrelerinden farklı olarak kalan faydalı ömür ile çıkarılan özelliklerden en fazla sıcaklık, şarj gerilimi ve direnç arasında yüksek bir korelasyon göstermektedir. Test veri oranı %50'den %60'a çıkarıldığında da önem sıralamasında değişiklik olmamıştır. Dv/dt, dv/di, di/dt parametreleri son sırada yer alarak tahmin doğruluğuna etkisi düşüktür.

Tablo 4.6 Mevcut veri setine direnç değeri,dv/dt,dv/di ve di/dt eklenerek ROR yöntemi ile tahminlemede özellik önem sıralaması


Özellik Önem Sıralaması	
(%50 Test verisi)	
Time	0.9497214668921087
Temperature_measured	0.020680066024623567
Voltage_charge	0.0030651449605850387
Resistance	0.002703659781178567
Current_Charge	0.002558553551406392
Current_Measured	0.0011448373397433538
Dv/Dt	0.0003740780363411151
Dv/Di	0.0003314876853529653
Di/Dt	0.00032818026856564435

Tablo 4.7 Mevcut veri setine direnç değeri, dv/dt , dv/di ve di/dt eklenerek ROR yöntemi ile tahminlemede özellik önem sıralaması

Özellik Önem Sıralaması	
(%60 Test verisi)	
Time	0.9497033610333974
Temperature_measured	0.02084132717897532
Cycle	0.01863950128223266
Voltage_charge	0.0030429840292608337
Resistance	0.0028271357779910637
Current_Charge	0.002558794756497517
Current_Measured	0.0011836346880244714
Dv/Dt	0.0004166610195521773
Dv/Di	0.0003959149102566031
Di/Dt	0.0003906853238120106

4.2 İleri Seviye Gradyan Yükseltici Regresyon Yöntemi ile Tahmin Sonuçları

Veri seti eğitim ve test verisi olacak şekilde ayrılarak ileri seviye gradyan yükseltici regresyon yöntemi (İSGYR) ile tahminleme yapıldığında Şekil 4.5, Şekil 4.6, Şekil 4.7, Şekil 4.8 ve Şekil 4.9, Şekil 4.10’da tahmin edilen değerler ve gerçek değerler arasındaki bağlantı görselleştirilmiştir.



Şekil 4.5 Mevcut veri setinde İSGYR ile KFÖ tahmini (%50 test verisi)

Mevcut veri seti üzerinden İSGYR yöntemi ile tahminleme yapıldığında Tablo 4.8'deki metrikler elde edilir. Test veri seti %50 olacak şekilde ayrıldığında ortalama mutlak hata değeri 136.5274 iken determinasyon katsayısı 0.985599 olarak hesaplanır. Model, ROR ile yapılan tahminlemeye göre daha düşük doğruluk performansı göstermiştir.

Tablo 4.8 Mevcut veri seti üzerinden İSGYR yöntemi ile tahminleme metrikleri

Metrik (%50 Test verisi)	
MAE	136.5274
R^2	0.985599

Mevcut veri seti üzerinden yapılan İSGYR ile tahminlemelerde özellik önem dereceleri çıkarıldığında Tablo 4.9'daki bulgular elde edilir. Buna göre test veri oranı %50 alınarak mevcut veri seti üzerinden yapılan tahminlemelerde, zaman ve

döngü sayısı özellikleri dışında, tahmin değeri batarya sıcaklığı ve şarj cihazı akımı arasında yüksek korelasyon bulunmaktadır.


Tablo 4.9 Mevcut veri seti üzerinden İSGYR yöntemi ile tahminlemede özellik önem sıralaması

Özellik Önem Sıralaması	
(%50 Test verisi)	
Time	0.9513269066810608
Temperature_measured	0.01940753683447838
Current_Charge	0.00932450033724308
cycle	0.006619833409786224
Current_Measured	0.004827664699405432


Mevcut veri setine dv/dt ve di/dt eklenerek yapılan tahminlemeler test oranı %50 olarak alındığında, MAE oranı artmıştır. %35 test verisi kullanılarak MAE oranının azaltılabileceği görülmektedir.

Tablo 4.10 Mevcut veri setine dv/dt ve di/dt eklenerek İSGYR ile KFÖ tahmini İSGYR yöntemi ile tahminleme metrikleri

Metrik	%50 Test verisi	%35 Test verisi
MAE	137.238875	136.724585236584
R^2	0.985609694574227	0.985714971738701



Şekil 4.6 Mevcut veri setine dv/dt ve di/dt eklenerek İSGYR ile KFÖ tahmini (%50 test verisi)



Şekil 4.7 Mevcut veri setine dv/dt ve di/dt eklenerek İSGYR ile KFÖ tahmini (%35 test verisi)

Mevcut veri setine dv/dt ve di/dt eklenerek test veri oranı %50 ve %35 alınarak yapılan tahminlemelerin dağılım grafikleri Şekil 4.6 ve Şekil 4.7’de gösterilmiştir. Tablo 4.11’e ve Tablo 4.12’ye göre zaman ve döngü parametrelerinden farklı olarak, en yüksek korelasyon gösteren parametreler batarya sıcaklığı, şarj cihazı akımı ve şarj cihazı gerilimi olarak hesaplanmıştır. Veri setine eklenen dv/dt ve di/dt parametrelerinin tahmin doğruluğuna etkisi düşüktür. Önem sıralamasında son sıralarda yer almıştır. Test veri oranının değiştirilmesi özellik önem sıralamasında değişikliğe sebep olmamıştır.


Tablo 4.11 Mevcut veri setine dv/dt ve di/dt parametreleri eklenerek yapılan İSGYR yöntemi ile tahminlemede özellik önem sıralaması

Özellik Önem Sıralaması	
(%50 Test verisi)	
Time	0.9500706195831299
Temperature_measured	0.017616553232073784
Current_charge	0.00869622454047203
Voltage_Charge	0.00849863514304161
cycle	0.006727140862494707
Current_Measured	0.005274950060993433
dv/dt	0.002214981010183692
di/dt	0.0009009622735902667


Tablo 4.12 Mevcut veri setine dv/dt ve di/dt parametreleri eklenerek yapılan İSGYR yöntemi ile tahminlemede özellik önem sıralaması

Özellik Önem Sıralaması	
(%35 Test verisi)	
Time	0.9484856724739075
Temperature_measured	0.018149359151721
Current_charge	0.008835683576762676
Voltage_Charge	0.008649876341223717
Current_measured	0.006544568110257387
cycle	0.006113966926932335
dv/dt	0.0020119608379900455
di/dt	00.0012089427327737212

Mevcut veri setine batarya terminal gerilim ve akım değerlerinden direnç hesabı yapılarak direnç değerleri, gerilim ve akımın zamana göre değişim değerleri (dv/dt ve di/dt) ve dv/di parametreleri yeni sütun olarak eklenerek ve test verisi oranı %50 alınarak İSGYR yöntemi ile tahminlemeler gerçekleştirildiğinde Şekil 4.8'deki grafik elde edilirken, test verisi oranı %60 olarak alındığında Şekil 4.9'daki grafik elde edilir ve Tablo 4.13'te bu tahminlemelerin metrik değerleri verilmiştir. Buna göre, İSGYR ile yapılan tahminlemede %60 test verisi kullanılması durumu MAE değerini artırarak, tahmin doğruluğunu azaltmıştır. Bu durumda daha çok eğitim verisi kullanılarak tahmin doğruluğu artırılabilir. Buna ek olarak, mevcut veri seti üzerinden yapılan tahminlemeye göre, yeni parametrelerin eklenerek İSGYR ile tahminleme yapılması tahmin doğruluğunu çok az da olsa arttırmıştır.



Şekil 4.8 Mevcut veri setine direnç değeri, dv/dt , dv/di ve di/dt eklenerek İSGYR ile KFÖ tahmini (%50 test verisi)



Şekil 4.9 Mevcut veri setine direnç değeri, dv/dt , dv/di ve di/dt eklenerek İSGYR ile KFÖ tahmini (%60 test verisi)

Tablo 4.13 Mevcut veri setine direnç, dv/dt , di/dt ve dv/di değerleri eklenerek İSGYR yöntemi ile tahminleme metrikleri

Metrik	%50 Test verisi	%60 Test verisi
MAE	136.23614886627868	141.167645382063
R^2	0.9856023361531803	0.9845397664471199

Tablo 4.14 İSGYR ile tahminlemede özellik önem sıralaması

Özellik Önem Sıralaması
(%50 Test verisi)

Time	0.9391707181930542
Temperature_Measured	0.018381129950284958
Resistance	0.00998710561543703
Current_Charge	0.009244280867278576
Voltage_Charge	0.008768214844167233
Current_Measured	0.005928952246904373
dv/dt	0.0013368292711675167
di/dt	0.00100444932468235
dv/di	0.0006712421891279519

İSGYR ile tahminlemede özelliklerin önem sıralaması çıkarıldığında Tablo 4.14'teki ve Tablo 4.15'teki bulgular elde edilir. Buna göre, kalan faydalı ömür ile

çıkarılan özelliklerden en fazla sıcaklık,direnç ve şarj akımı arasında yüksek bir korelasyon bulunmaktadır. Test veri oranı %50'den %60'a çıkarıldığında da önem sıralamasında ciddi değişiklik olmamıştır.

Tablo 4.15 İSGYR ile tahminlemede özellik önem sıralaması

Özellik Önem Sıralaması	
(Test veri oranı = %60)	
Time	0.9434475898742676
Temperature_Measured	0.01794058457016945
Resistance	0.009662510827183723
Voltage_Charge	0.009123144671320915
Current_charge	0.007422416936606169
cycle	0.006128744687885046
Current_Measured	0.0029990416951477528
dv/dt	0.0015098417643457651
di/dt	0.001051069237291813
dv/di	0.0007151455502025783

4.3 K- En Yakın Komşu Regresyon Yöntemi ile Tahmin Sonuçları

Mevcut veri seti üzerinden, test verisi oranı %50 alınarak K- en yakın komşu regresyon yöntemi ile tahminleme yapıldığında Tablo 4.16'daki metrikler elde edilir.

Tablo 4.16 Mevcut veri seti üzerinden KEYKR yöntemi ile tahminleme metrikleri

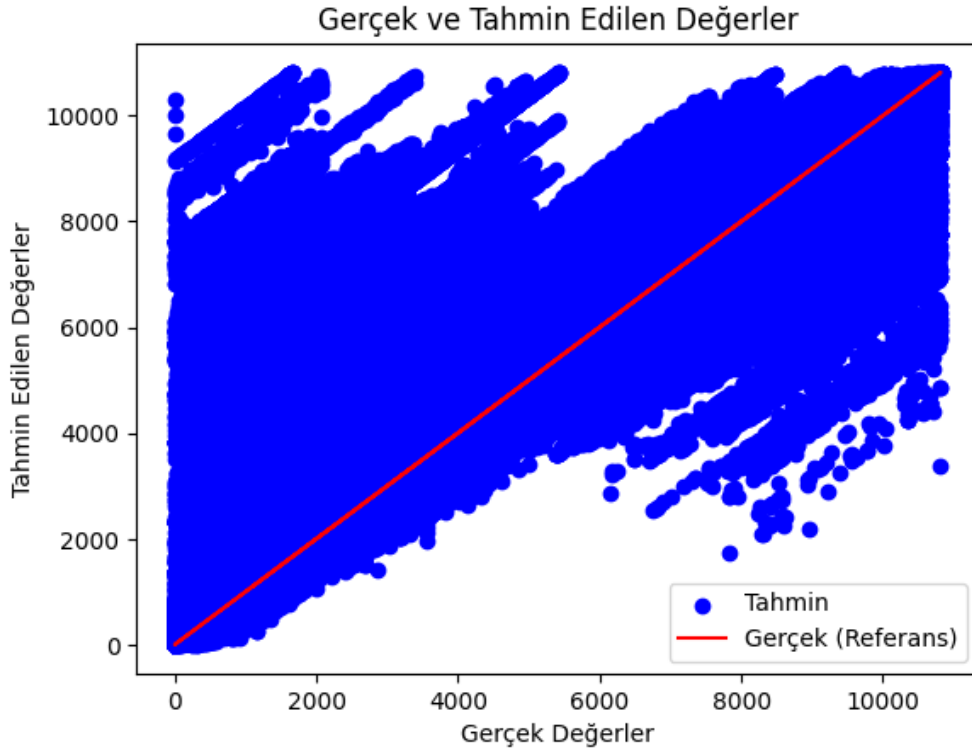
Metrik (%50 Test verisi)	
MAE	148.372576084871
R^2	0.975355756004064

Mevcut veri setine anlık gerilim ve akım değerlerinden direnç hesabı yapılarak direnç değerleri, gerilim ve akımın zamana göre değişim değerleri (dv/dt ve di/dt) ve dv/di parametreleri yeni sütun olarak eklenerek ve test verisi oranı %50 alınarak KEYKR yöntemi ile yapılan tahminlemelerde MAE 137.9738 iken determinasyon katsayısı 0.9796 olarak hesaplanmıştır. KEYKR ile tahminlemede, mevcut veri setine dv/dt ve di/dt parametrelerinin eklenmesi çok az da olsa MAE oranını azaltarak model performansını artırmıştır. Tablo 4.17’de bu tahminlemeye ait metrik değerleri verilmiştir. Tahminlemelerde test veri oranının etkisi incelendiğinde, %35 test verisinin kullanılması, %50 test verisinin kullanılması durumuna göre model performansını artırmaktadır.


KEYKR ile tahminlemede direnç değeri, dv/dt , dv/di ve di/dt eklenmesi, MAE’yi 148.37257’den 137.9738283’e düşürerek, tahmin doğruluğunda artış sağlamaktadır. KEYKR yönteminde özellik önem sıralaması yapılmamıştır. Tablo 4.18’de mevcut veri setine batarya terminal gerilim ve akım değerlerinden direnç hesabı yapılarak direnç değerleri, gerilim ve akımın zamana göre değişim değerleri (dv/dt ve di/dt) ve dv/di parametreleri yeni sütun olarak eklenerek yapılan tahminleme metrikleri verilmiştir.

Tablo 4.17 Mevcut veri setine dv/dt , di/dt parametreleri eklenerek KEYKR yöntemi yapılan tahminleme metrikleri


Metrik	%50 Test verisi	%35 Test verisi
MAE	148.37118832499405	146.73722260054473
R^2	0.975356400057311	0.9761015010994714



Şekil 4.10 Mevcut veri setine dv/dt , di/dt eklenerek yapılan KEYKR tahminlemeleri (%50 test verisi)



Şekil 4.11 Mevcut veri setine dv/dt , di/dt eklenerek yapılan KEYKR tahminlemeleri (%35 test verisi)



Şekil 4.12 Mevcut veri setine direnç değeri, dv/dt , dv/di ve di/dt eklenerek KEYKR yöntemi ile tahminlemeleri (%50 test verisi)

Tablo 4.18 Mevcut veri setine direnç değeri, dv/dt , dv/di ve di/dt eklenerek KEYKR yöntemi ile tahminleme metrikleri

Metrik (%50 test verisi)	
MAE	137.973828253447
R^2	0.979629629512918

4.4 Yapılan Tahminleme Sonuçlarının Değerlendirilmesi

Çalışmada, ROR yöntemi, İSGYR yöntemi ve KEYKR yöntemi kullanılarak batarya kalan faydalı ömür tahminlemeleri yapılmıştır.

Tablo 4.19’da test veri oranı %50 alınarak yapılan tüm tahminleme çalışmalarının özeti sunulmuştur.

Tablo 4.19’a göre %50 test verisi baz alınarak yapılan tahminleme çalışmalarında yapılan çalışmalara ek olarak, verisetine sadece direnç değeri eklenirken ölçülen gerilim ve ölçülen akım değerleri verisetinden çıkarılarak ilgili yöntemler ile tahminleme çalışmaları yapılmıştır. ROR ile yapılan tahminlemede MAE yaklaşık olarak %11, İSGYR olan tahminleme çalışmasında %15 artmıştır. MAE artışı, hata oranının arttığını ve model performansının düştüğünü gösterir. KEYKR ile yapılan tahminleme çalışmasında ise model performansı yaklaşık %3 oranında artmıştır.

Mevcut veri setine direnç, dv/dt , dv/di ve di/dt eklenerek yapılan tahmin çalışmalarında, ROR ile yapılan tahminlemede hata oranı yaklaşık olarak %36,36 artmıştır. Bu durum, model performansının önemli ölçüde kötüleştiğini göstermektedir. İSGYR ile yapılan tahminlemede ise hata oranı %0.2 oranında azalarak model performansında çok küçük bir iyileşme gözlemlenmiştir. KEYKR ile yapılan tahminleme çalışmasında ise, MAE yaklaşık %7 oranında azalarak, model performans doğruluğu arttığı gözlemlenmiştir.

Yapılan tahminleme çalışmalarında rastgele orman regresyonu ve ileri seviye gradyen yükseltici regresyon yönteminde çıkarılan özellik önem sıralamasında ilk

sıralarda sıcaklık ve direnç değeri yer almıştır. Bu sıralama test veri oranının değiştirilmesi durumunda da yer değiştirmemiştir. Buna göre, kalan faydalı ömür tahmininde sıcaklık ve direnç değerleri kullanılan yöntemlerde tahmin doğruluğunda yüksek korelasyon göstermektedir. Veri setine eklenen dv/dt , di/dt ve dv/di parametreleri özellik önem sıralamasında yapılan tahminlemelerde son sıralarda yer almıştır. Test veri oranının değiştirilmesi durumunda da son sırada olma durumunu korumuştur.

Bu tahminleme çalışmalarında daha iyi sonuçlara ulaşabilmek için yüksek korelasyon gösterilen parametreler kullanılarak, model performansı iyileştirilebilir.

Tablo 4.19 Test veri oranı %50 alınarak yapılan tahminleme çalışmaları

Yöntemler	ROR		İSGYR		KEYKR	
	MAE	R^2	MAE	R^2	MAE	R^2
Senaryolar (Test Verisi %50)						
Mevcut veri seti	22.5023	0.9987	136.5274	0.98559	148.372 6	0.97535 5
Dv/dt ve di/dt eklenerek tahmin	27.1661	0.9983	137.2389	0.9856	148.371 18	0.97535 6
Direnç Değeri Eklenerek Tahmin	25.0136	0.9985	157.1785	0.98266	143.462 3	0.97862 0
Direnç, dv/dt, dv/di ve di/dt eklenerek tahmin	30.5613	0.9980	136.236	0.9856	137.974	0.97962 9

4.5 Gelecek Çalışmalar

Literatürde, verilerdeki gürültü etkisinin azaltılmasının, sağlık durumu ve kalan faydalı ömür tahmin doğruluğu ve kararlılığı açısından önemi vurgulanmış ve veri seti eksik veya yetersiz olması durumunda batarya kalan faydalı ömür tahmin belirsizliği üzerine tahmin iyileştirme üzerine çalışmalar yapılmıştır. Bu çalışmada batarya kalan faydalı ömrünü etkileyen parametreler açıklanmış ve üç farklı yöntem ile tahminleme çalışmaları yapılmıştır. Ancak tahminleme çalışmasında tahmin süresi göz önüne alınmamıştır. Bu yüzden gelecek çalışmalar, bu alanlarda daha ileri düzey tahmin çalışmaları ve gerçek zamanlı yenilikçi çözümler geliştirmeyi hedeflemelidir. Yüksek doğruluğa sahip batarya kalan faydalı ömür tahminleri ile hem maliyet hem de performans açısından batarya yönetim sistemleri için önemli iyileştirmeler sağlanabilir. Çalışmada kullanılan yöntemlere ek olarak, farklı üstünlüklerini ortaya koyan hibrit yöntemlerin tahminleme çalışmalarında kullanılması tahmin doğruluğu açısından faydalı olabilir. Batarya teknolojisi üzerine karar vericilerin, iş sahiplerinin bu alanda önceden bilgi sahibi olması, gelecekte neler yapılacağını öğrenerek, olası riskleri önceden görebilmeye ve karlılık oranlarını artırmaya yönelik adım atmalarına yardımcı olabilir.

KAYNAKÇA

- [1] GAZBİR, "2016 Yılı Doğal Gaz Dağıtım Sektörü Değerlendirme Raporu," 2017.
- [2] C. Hendricks, N. Williard, S. Mathew, M. Pecht, "A failure modes, mechanisms, and effects analysis (fmmea) of lithium-ion batteries," *Journal of Power Sources*, vol. 297, pp. 113–120, 2015
- [3] U. Şahin, "Otomotiv Sektörüne Yönelik Batarya Yönetim Sistemi Geliştirilmesi," Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, 2022.
- [4] Q. Xu, M. Wu, E. Khoo, Z. Chen, and X. Li, "A Hybrid Ensemble Deep Learning Approach for Early Prediction of Battery Remaining Useful Life", *IEEE/CAA Journal of Automatica Sinica*, vol. 1, pp. 177–187, 2023.
- [5] C. Zhang, Y. He, L. Yuan, and S. Xiang, "Capacity Prognostics of Lithium-Ion Batteries using EMD Denoising and Multiple Kernel RVM", *IEEE Access*, vol. 5, pp. 12061–12070, 2017.
- [6] X. Cui and T. Hu, "State of Health Diagnosis and Remaining Useful Life Prediction for Lithium-ion Battery Based on Data Model Fusion Method", *IEEE Access*, vol. 8, pp. 207298–207307, 2020.
- [7] Z. Jiao, H. Wang, J. Xing, Q. Yang, M. Yang, Y. Zhou, and J. Zhao, "A LightGBM Based Framework for Lithium-Ion Battery Remaining Useful Life Prediction Under Driving Conditions", *IEEE Transactions on Industrial Informatics*, vol. 11, pp. 11353–11362, 2023.
- [8] Y. Zhang, R. Xiong, H. He, M. G. Pecht, "Long Short-Term Memory Recurrent Neural Network for Remaining Useful Life Prediction of Lithium-Ion Batteries", *IEEE Transactions on Vehicular Technology*, vol. 7, pp. 5695-5705, 2018.
- [9] I. Sanz-Gorrachategui, P. Pastor-Flores, M. Pajovic, Y. Wang, P.V. Orlik, C. Bernal-Ruiz, A. Bono-Nuez, and J. S. Artal-Sevil, "Remaining Useful Life Estimation for LFP Cells in Second-Life Applications", *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp. 2505810, 2021.
- [10] H. Dong, "Prediction of the Remaining Useful Life of Lithium-Ion Batteries Based on Dempster-Shafer Theory and the Support Vector Regression-Particle Filter", *IEEE Access*, vol. 9, pp. 165490–165503, 2021.
- [11] H. Pei, X.S. Si, C. Hu, T. Li, C. He, and Z. Pang, "Bayesian Deep-Learning-Based Prognostic Model for Equipment Without Label Data Related to

- Lifetime", *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, no. 1, pp. 504–517, 2023.
- [12] D. Liu, W. Xie, H. Liao, Y. Peng, "An Integrated Probabilistic Approach to Lithium-Ion Battery Remaining Useful Life Estimation", *IEEE Transactions on Instrumentation and Measurement*, vol. 3, pp. 660-670, 2015.
- [13] A. Guha and A. Patra, "Online Estimation of the Electrochemical Impedance Spectrum and Remaining Useful Life of Lithium-Ion Batteries", *IEEE Transactions on Instrumentation and Measurement*, no. 8, pp. 1836–1849, 2018.
- [14] J. Wei, G. Dong, and Z. Chen, "Remaining Useful Life Prediction and State of Health Diagnosis for Lithium-Ion Batteries Using Particle Filter and Support Vector Regression", *IEEE Transactions on Industrial Electronics*, no. 7, pp. 5634–5643, 2018.
- [15] R. Xiong, Y. Zhang, J. Wang, H. He, S. Peng, and M. Pecht, "Lithium-Ion Battery Health Prognosis Based on a Real Battery Management System Used in Electric Vehicles", *IEEE Transactions on Vehicular Technology*, no. 5, pp. 4110–4121, 2019.
- [16] M. Cao, T. Zhang, B. Yu, and Y. Liu, "A Method for Interval Prediction of Satellite Battery State of Health Based on Sample Entropy", *IEEE Access*, vol. 7, pp. 141549–141561, 2019.
- [17] Q. Xue, S. Shen, G. Li, Y. Zhang, Z. Chen, and Y. Liu, "Remaining Useful Life Prediction for Lithium-Ion Batteries Based on Capacity Estimation and Box-Cox Transformation", *IEEE Transactions on Vehicular Technology*, no. 12, pp. 14765–14779, 2020.
- [18] S. B. Vilsen, S. K. Kær, and D. Stroe, "Log-Linear Model for Predicting the Lithium-ion Battery Age Based on Resistance Extraction from Dynamic Aging Profiles", *IEEE Transactions on Industry Applications*, no. 6, pp. 6937–6948, 2020.
- [19] C. Díaz, V. Quintero, A. Pérez, F. Jaramillo, C. Burgos-Mellado, H. Rozas, M. E. Orchard, D. Sáez, and R. Cárdenas, "Particle-Filtering-Based Prognostics for the State of Maximum Power Available in Lithium-Ion Batteries at Electromobility Applications", *IEEE Transactions on Vehicular Technology*, vol. 69, no. 7, pp. 7187-7200, July 2020.
- [20] B. Gou, Y. Xu, X. Feng, "State-of-Health Estimation and Remaining-Useful-Life Prediction for Lithium-Ion Battery Using a Hybrid Data-Driven Method", *IEEE Transactions on Vehicular Technology*, vol. 10, pp. 10854-10867, 2020.
- [21] Y. Wu, Q. Xue, J. Shen, Z. Lei, Z. Chen, Y. Liu, "State of Health Estimation for Lithium-Ion Batteries Based on Healthy Features and Long Short-Term Memory", *IEEE Access*, vol. 8, pp. 28533-28547, 2020.
- [22] Yun, Z., Qin, W., "Remaining Useful Life Estimation of Lithium-Ion Batteries Based on Optimal Time Series Health Indicator", *IEEE Access*, 8, 55447 – 55461, 2020.
- [23] S. Kim, H.J. Park, J.H. Choi, D. Kwon, "A Novel Prognostics Approach Using Shifting Kernel Particle Filter of Li-Ion Batteries Under State Changes", *IEEE Transactions on Industrial Electronics*, vol. 4, pp. 3485-3493, 2021.

- [24] G. Dong, Y. Xu, Z. Wei, "A Hierarchical Approach for Finite-Time $H-\infty$ State-of-Charge Observer and Probabilistic Lifetime Prediction of Lithium-Ion Batteries", *IEEE Transactions on Energy Conversion*, vol. 1, pp. 718-728, 2022.
- [25] S. S. Afshari, S. Cui, X. Xu, and X. Liang, "Remaining Useful Life Early Prediction of Batteries Based on the Differential Voltage and Differential Capacity Curves", *IEEE Transactions on Instrumentation and Measurement*, vol. 71, pp. 6500709, 2022.
- [26] J. Wang, Y. Xiang, "Fast Modeling of the Capacity Degradation of Lithium-Ion Batteries via a Conditional Temporal Convolutional Encoder–Decoder", *IEEE Transactions on Transportation Electrification*, vol. 2, pp. 1695-1709, 2022.
- [27] L. Li, Y. Mao, R. Li, L. Hua, J. Zhang, "Remaining useful life prediction for lithium-ion batteries with a hybrid model based on TCN-GRU-DNN and dual attention mechanism", *IEEE Transactions on Transportation Electrification*, vol. 9, pp. 4726-4740, 2023.
- [28] L. Timilsina, P.R. Badr, P.H. Hoang, G. Ozkan, B. Papari, C.S. Christopher S. Edrington, "Battery Degradation in Electric and Hybrid Electric Vehicles: A Survey Study", *IEEE Access*, vol. 11, pp. 42431-42462, 2023.
- [29] Y. Huang, Y. Tang, J. VanZwieten, "Prognostics With Variational Autoencoder by Generative Adversarial Learning", *IEEE Transactions on Industrial Electronics*, vol. 1, pp. 856-867, 2022.
- [30] M.O. Tarar, N.U. Hassan, I.H. Naqvi, M. Pecht, "Techno-Economic Framework for Electric Vehicle Battery Swapping Stations", *IEEE Transactions on Transportation Electrification*, vol. 3, pp. 4458-4473, 2023.
- [31] Y. Zhang, R. Xiong, H. He, M. G. Pecht, "Lithium-Ion Battery Remaining Useful Life Prediction With Box–Cox Transformation and Monte Carlo Simulation", *IEEE Transactions on Industrial Electronics*, vol. 2, pp. 1585-1597, 2019.
- [32] S.A. Hasib, S. Islam, R.K. Chakraborty, M.J. Ryan, D.K. Saha, Md. H. Ahamed, S.I. Moyeen, S.K. Das, Md F. Ali, Md R. Islam, Md R. Tasneem, F.R. Badal, "A Comprehensive Review of Available Battery Datasets, RUL Prediction Approaches, and Advanced Battery Management", *IEEE Access*, vol. 9, pp. 86166-86193, 2021.
- [33] Z. Chen, Q. Xue, Y. Wu, S. Shen, Y. Zhang, and J. Shen, "Capacity Prediction and Validation of Lithium-Ion Batteries Based on Long Short-Term Memory Recurrent Neural Network", *IEEE Access*, vol. 8, pp. 172783-172798, 2020.
- [34] Y. Wu, Q. Xue, J. Shen, Z. Lei, Z. Chen, Y. Liu, "State of Health Estimation for Lithium-Ion Batteries Based on Healthy Features and Long Short-Term Memory", *IEEE Access*, vol. 8, pp. 28533-28547, 2020.
- [35] M. Haris, M.N. Hasan, S. Qin, "Degradation Curve Prediction of Lithium-Ion Batteries Based on Knee Point Detection Algorithm and Convolutional Neural Network", *IEEE Transactions on Instrumentation and Measurement*, vol. 71, pp. 3514810, 2022.
- [36] T. Aggab, M. Avila, P. Vrignat, and F. Kratz, "Unifying Model-Based Prognosis With Learning-Based Time-Series Prediction Methods: Application to Li-Ion Battery", *IEEE Systems Journal*, vol. 4, pp. 5245–5254, 2021.

- [37] M. Ahwiadi and W. Wang, "An Enhanced Mutated Particle Filter Technique for System State Estimation and Battery Life Prediction", *IEEE Transactions on Instrumentation and Measurement*, vol. 68, no. 3, pp. 923-935, Mar. 2019.
- [38] M. Ahwiadi and W. Wang, "An Adaptive Evolving Fuzzy Technique for Prognosis of Dynamic Systems", *IEEE Transactions on Fuzzy Systems*, vol. 30, no. 3, pp. 841-849, Mar. 2022.
- [39] S. Bamati and H. Chaoui, "Lithium-Ion Batteries Long Horizon Health Prognostic Using Machine Learning", *IEEE Transactions on Energy Conversion*, vol. 37, no. 2, pp. 1176-1186, June 2022.
- [40] T. Berghout, M. Benbouzid, Y. Amirat, and G. Yao, "Lithium-ion Battery State of Health Prediction with a Robust Collaborative Augmented Hidden Layer Feedforward Neural Network Approach", *IEEE Transactions on Transportation Electrification*, vol. 9, no. 3, pp. 4492-4502, Sept. 2023.
- [41] M. Catelani, L. Ciani, R. Fantacci, G. Patrizi, and B. Picano, "Remaining Useful Life Estimation for Prognostics of Lithium-Ion Batteries Based on Recurrent Neural Network", *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp. 3524611, 2021.
- [42] Y. Che, Z. Deng, X. Lin, and L. Hu, "Predictive Battery Health Management With Transfer Learning and Online Model Correction", *IEEE Transactions on Vehicular Technology*, vol. 2, pp. 1269–1277, 2021.
- [43] A. A. Chehade and A. A. Hussein, "A Multioutput Convolved Gaussian Process for Capacity Forecasting of Li-Ion Battery Cells", *IEEE Transactions on Power Electronics*, vol. 1, pp. 896-909, 2022.
- [44] D. Chen, W. Hong, and X. Zhou, "Transformer Network for Remaining Useful Life Prediction of Lithium-Ion Batteries", *IEEE Access*, vol. 10, pp. 19621-19628, 2022.
- [45] Y. Chen, Y. He, Z. Li, L. Chen, and C. Zhang, "Remaining Useful Life Prediction and State of Health Diagnosis of Lithium-Ion Battery Based on Second-Order Central Difference Particle Filter", *IEEE Access*, vol. 8, pp. 37305-37313, 2020.
- [46] Z. Chen, L. Chen, W. Shen, and K. Xu, "Remaining Useful Life Prediction of Lithium-Ion Battery via a Sequence Decomposition and Deep Learning Integrated Approach", *IEEE Transactions on Vehicular Technology*, vol. 71, pp. 1466-1479, 2022.
- [47] E. Chiodo, P. De Falco, and L. P. Di Noia, "Probabilistic Modeling of Li-Ion Battery Remaining Useful Life", *IEEE Transactions on Industry Applications*, vol. 4, pp. 5214-5226, 2020.
- [48] E. Choi, Y. Huh, K. R. Lee, H. Son, and C. T. Rim, "Battery State-of-Health Prediction Based on a Fusion Method With Coupled Dictionary Learning", *IEEE Transactions on Energy Conversion*, vol. 35, no. 4, pp. 1953-1962, Dec. 2020.
- [49] D. A. Christensen, J. B. Siegel, Y. Ding, and Y. Ding, "Tracking Battery Degradation Using In Situ and Post-Test Micro-Scale X-ray Computed Tomography", *Journal of The Electrochemical Society*, 2023.

- [50] X. Cui and T. Hu, "State of Health Diagnosis and Remaining Useful Life Prediction for Lithium-ion Battery Based on Data Model Fusion Method", *IEEE Access*, vol. 8, pp. 207298–207307, 2020.
- [51] G. Dong, W. Han, Y. Wang, "Dynamic Bayesian Network-Based Lithium-Ion Battery Health Prognosis for Electric Vehicles", *IEEE Transactions on Industrial Electronics*, vol. 11, pp. 10949-10958, 2021.
- [52] G. Dong, F. Yang, Z. Wei, J. Wei, K.-L. Tsui, "Data-Driven Battery Health Prognosis Using Adaptive Brownian Motion Model", *IEEE Transactions on Industrial Informatics*, vol. 7, pp. 4736-4746. 2020.
- [53] Z. Du, L. Zuo, J. Li, Y. Liu, H.T. Shen, "Data-Driven Estimation of Remaining Useful Lifetime and State of Charge for Lithium-Ion Battery", *IEEE Transactions on Transportation Electrification*, vol. 1, pp. 356-367, 2022.
- [54] M. Elmahallawy, T. Elfouly, A. Alouani, A.M. Massoud, "A Comprehensive Review of Lithium-Ion Batteries Modeling, and State of Health and Remaining Useful Lifetime Prediction", *IEEE Access*, vol. 12, pp. 119040-119070, 2022.
- [55] A. Ezzouhri, Z. Charouh, M. Ghogho, Z. Guennoun, "A Data-Driven-Based Framework for Battery Remaining Useful Life Prediction", *IEEE Access*, vol. 11, pp. 76142-76155, 2023.
- [56] J. Fan, J. Fan, F. Liu, J. Qu, R. Li, "A Novel Machine Learning Method Based Approach for Li-Ion Battery Prognostic and Health Management", *IEEE Access*, vol. 7, pp. 160043-160061, 2019.
- [57] J. Hu, L. Weng, Z. Gao, B. Yang, "State of Health Estimation and Remaining Useful Life Prediction of Electric Vehicles Based on Real-World Driving and Charging Data", *IEEE Transactions on Vehicular Technology*, vol. 1, pp. 382-394, 2023.
- [58] G. Dong; Z. Chen, J. Wei, Q. Ling, "Battery Health Prognosis Using Brownian Motion Modeling and Particle Filtering", *IEEE Transactions on Industrial Electronics*, vol. 11, pp. 8646-8655, 2018.
- [59] B. Jiang, H. Dai, X. Wei, Z. Jiang, "Multi-Kernel Relevance Vector Machine With Parameter Optimization for Cycling Aging Prediction of Lithium-Ion Batteries", *IEEE Journal of Emerging and Selected Topics in Power Electronics*, vol. 1, pp. 175-186, 2023.
- [60] Y. Jiang, J. Zhang, L. Xia, Y. Liu, "State of Health Estimation for Lithium-Ion Battery Using Empirical Degradation and Error Compensation Models", *IEEE Access*, vol. 8, pp. 123858-123868, 2020.
- [61] R. Jiao, K. Peng, J. Dong, "Remaining Useful Life Prediction of Lithium-Ion Batteries Based on Conditional Variational Autoencoders-Particle Filter", *IEEE Transactions on Instrumentation and Measurement*, vol. 11, pp. 8831-8843, 2020.
- [62] Y. Jinsong, L. Shuang, T. Diyin, L. Hao, "Remaining Discharge Time Prognostics of Lithium-Ion Batteries Using Dirichlet Process Mixture Model and Particle Filtering Method", *IEEE Transactions on Instrumentation and Measurement*, vol. 9, pp. 2317-2328, 2017.

- [63] J.Z. Kong, D. Wang, T. Yan, J. Zhu, X. Zhang, "Accelerated Stress Factors Based Nonlinear Wiener Process Model for Lithium-Ion Battery Prognostics", *IEEE Transactions on Industrial Electronics*, vol. 11, pp. 11665-11674, 2022.
- [64] C. Li, N. Wang, W. Li, Y. Zhang, "Regrouping and Echelon Utilization of Retired Lithium-Ion Batteries Based on a Novel Support Vector Clustering Approach", *IEEE Transactions on Transportation Electrification*, vol. 3, pp. 3648-3658, 2022.
- [65] D.Z. Li, W. Wang, F. Ismail, "A Mutated Particle Filter Technique for System State Estimation and Battery Life Prediction", *IEEE Transactions on Instrumentation and Measurement*, vol. 8, pp. 2034-2043, 2014.
- [66] T. Li, H. Pei, Z. Pang, X. Si, J. Zheng, "A Sequential Bayesian Updated Wiener Process Model for Remaining Useful Life Prediction", *IEEE Access*, vol. 8, pp. 5471-5480, 2020.
- [67] Y.H. Lin, L.L. Tian, Z.Q. Ding, "Ensemble Remaining Useful Life Prediction for Lithium-Ion Batteries With the Fusion of Historical and Real-Time Degradation Data", *IEEE Transactions on Vehicular Technology*, vol. 5, pp. 5934-5947, 2023.
- [68] Y.H. Lin, L.X. Guan, L. Chang, E. Zio, "A Semisupervised Deep Hybrid Multitask Model for RUL Prediction", *IEEE Transactions on Instrumentation and Measurement*, vol. 72, pp. 3522911, 2023.
- [69] Y.H. Lin, G.H. Li, "A Bayesian Deep Learning Framework for RUL Prediction Incorporating Uncertainty Quantification and Calibration", *IEEE Transactions on Industrial Informatics*, vol. 10, pp. 7274-7284, 2022.
- [70] D. Liu, J. Zhou, H. Liao, Y. Peng, X. Peng, "A Health Indicator Extraction and Optimization Framework for Lithium-Ion Battery Degradation Modeling and Prognostics", *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, pp. 915-928, 2015.
- [71] J. Liu, Z. Chen, "Remaining Useful Life Prediction of Lithium-Ion Batteries Based on Health Indicator and Gaussian Process Regression Model", *IEEE Access*, vol. 7, pp. 39474-39484, 2019.
- [72] J. Liu and Z. Chen, "Remaining Useful Life Prediction of Lithium-Ion Batteries Based on Health Indicator and Gaussian Process Regression Model", *IEEE Access*, vol. 7, pp. 39474-39484, 2019.
- [73] K. Liu, Y. Shang, Q. Ouyang, and W. D. Widanage, "A Data-Driven Approach With Uncertainty Quantification for Predicting Future Capacities and Remaining Useful Life of Lithium-ion Battery", *IEEE Transactions on Industrial Electronics*, vol. 4, pp. 3170-3180, 2021.
- [74] Y. Liu, G. Zhao, and X. Peng, "Deep Learning Prognostics for Lithium-Ion Battery Based on Ensembled Long Short-Term Memory Networks", *IEEE Access*, vol. 7, pp. 155130-155142, 2019.
- [75] Z. Liu, G. Sun, S. Bu, J. Han, X. Tang, and M. Pecht, "Particle Learning Framework for Estimating the Remaining Useful Life of Lithium-Ion Batteries", *IEEE Transactions on Instrumentation and Measurement*, vol. 2, pp. 280-293, 2017.

- [76] G. Lyu, H. Zhang, and Q. Miao, "RUL Prediction of Lithium-Ion Battery in Early-Cycle Stage Based on Similar Sample Fusion Under Lebesgue Sampling Framework", *IEEE Transactions on Instrumentation and Measurement*, vol. 72, pp. 3511-3511, 2023.
- [77] Z. Lyu, R. Gao, and L. Chen, "Li-Ion Battery State of Health Estimation and Remaining Useful Life Prediction Through a Model-Data-Fusion Method", *IEEE Transactions on Power Electronics*, vol. 6, pp. 6228-6240, 2021.
- [78] Y. Ma, Y. Chen, X. Zhou, and H. Chen, "Remaining Useful Life Prediction of Lithium-Ion Battery Based on Gauss-Hermite Particle Filter", *IEEE Transactions on Control Systems Technology*, vol. 4, pp. 1788-1795, 2019.
- [79] A. E. Mejdoubi, H. Chaoui, H. Gualous, P. V.D. Bossche, N. Omar, and J.V. Mierlo, "Lithium-Ion Batteries Health Prognosis Considering Aging Conditions", *IEEE Transactions on Power Electronics*, vol. 7, pp. 6834-6844, 2019.
- [80] G. Niu, X. Wang, E. Liu, and B. Zhang, "Lebesgue Sampling Based Deep Belief Network for Lithium-Ion Battery Diagnosis and Prognosis", *IEEE Transactions on Industrial Electronics*, vol. 8, pp. 8481-8490, 2022.
- [81] B.E. Olivares, M.A.C. Munoz, M.E. Orchard, and J.F. Silva, "Particle-Filtering-Based Prognosis Framework for Energy Storage Devices With a Statistical Characterization of State-of-Health Regeneration Phenomena", *IEEE Transactions on Instrumentation and Measurement*, vol. 2, pp. 364-376, 2013.
- [82] M.E. Orchard, P.H. Koch, B. Zhang, and L. Thang, "Risk Measures for Particle-Filtering-Based State-of-Charge Prognosis in Lithium-Ion Batteries", *IEEE Transactions on Industrial Electronics*, vol. 11, pp. 5260-5269, 2013.
- [83] T. Ouyang, P. Xu, J. Chen, J. Lu, and N. Chen, "An Online Prediction of Capacity and Remaining Useful Life of Lithium-Ion Batteries Based on Simultaneous Input and State Estimation Algorithm", *IEEE Transactions on Power Electronics*, vol. 7, pp. 8102-8113, 2021.
- [84] D. Pan, H. Li, and S. Wang, "Transfer Learning-Based Hybrid Remaining Useful Life Prediction for Lithium-Ion Batteries", *IEEE Transactions On Instrumentation And Measurement*, vol.71, 3501810, 2022.
- [85] K. Park, Y. Choi, W.J. Choi, H. Ryu, and H. Kim, "LSTM-Based Battery Remaining Useful Life Prediction With Multi-Channel Charging Profiles", *IEEE Access*, vol. 8, pp. 20786-20798, 2020.
- [86] J. Peng, Z. Zhou, J. Wang, D. Wu, and Y. Guo, "Residual Remaining Useful Life Prediction Method for Lithium-Ion Batteries in Satellite With Incomplete Healthy Historical Data", *IEEE Access*, vol. 7, pp. 127788-127799, 2019.
- [87] K. Pugalenthi, H. Park, S. Hussain, N. Raghavan, "Hybrid Particle Filter Trained Neural Network for Prognosis of Lithium-Ion Batteries", *IEEE Access*, vol. 9, pp. 135132-135143, 2021.
- [88] J. Qu, F. Liu, Y. Ma, J. Fan, "A Neural-Network-Based Method for RUL Prediction and SOH Monitoring of Lithium-Ion Battery", *IEEE Access*, vol. 7, pp. 87178-87191, 2019.

- [89] L. Ren, J. Dong, X. Wang, Z. Meng, L. Zhao, M.J. Deen, "A Data-Driven Auto-CNN-LSTM Prediction Model for Lithium-Ion Battery Remaining Useful Life", *IEEE Transactions on Industrial Informatics*, vol. 5, pp. 3478-3487, 2021.
- [90] L. Ren, L. Zhao, S. Hong, S. Zhao, H. Wang, L. Zhang, "Remaining Useful Life Prediction for Lithium-Ion Battery: A Deep Learning Approach", *IEEE Access*, vol. 6, pp. 50587-50598, 2018.
- [91] S. Sankararaman, M. J. Daigle, K. Goebel, "Uncertainty Quantification in Remaining Useful Life Prediction Using First-Order Reliability Methods", *IEEE Transactions on Reliability*, vol. 2, pp. 603-619, 2014.
- [92] D. Shen, T. Xu, L. Wu, Y. Guan, "Research on Degradation Modeling and Life Prediction Method of Lithium-Ion Battery in Dynamic Environment", *IEEE Access*, vol. 7, pp. 130638-130649, 2019.
- [93] X.S. Si, "An Adaptive Prognostic Approach via Nonlinear Degradation Modeling: Application to Battery Data", *IEEE Transactions on Industrial Electronics*, vol. 8, pp. 5082-5096, 2015.
- [94] A. Sinha, D. Das, V. Udutalapally, S.P. Mohanty, "iThing: Designing Next-Generation Things With Battery Health Self-Monitoring Capabilities for Sustainable IIoT", *IEEE Transactions on Instrumentation and Measurement*, vol. 71, pp. 3528409, 2022.
- [95] P. Venugopal, S.S. Shankar, C.P. Jebakumar, R. Agarwal, H.H. Alhelou, S.S. Reka, M.E.H. Golshan, "Analysis of Optimal Machine Learning Approach for Battery Life Estimation of Li-Ion Cell", *IEEE Access*, vol. 9, pp. 159616-159626, 2021.
- [96] D. Wang, F. Yang, K.L. Tsui, Q. Zhou, S.J. Bae, "Remaining Useful Life Prediction of Lithium-Ion Batteries Based on Spherical Cubature Particle Filter", *IEEE Transactions on Instrumentation and Measurement*, vol. 6, pp. 1282-1291, 2016.
- [97] J. Wang, S. Zhang, C. Li, L. Wu, Y. Wang, "A Data-Driven Method With Mode Decomposition Mechanism for Remaining Useful Life Prediction of Lithium-Ion Batteries", *IEEE Transactions on Power Electronics*, vol. 11, pp. 13684-13695, 2022.
- [98] Y. Wang, C. Hei, H. Liu, S. Zhang, J. Wang, "Prognostics of Remaining Useful Life for Lithium-Ion Batteries Based on Hybrid Approach of Linear Pattern Extraction and Nonlinear Relationship Mining", *IEEE Transactions on Power Electronics*, vol. 1, pp. 1054-1063, 2023.
- [99] Y. Wang, Y. Ni, S. Lu, J. Wang, X. Zhang, "Remaining Useful Life Prediction of Lithium-Ion Batteries Using Support Vector Regression Optimized by Artificial Bee Colony", *IEEE Transactions on Vehicular Technology*, vol. 10, pp. 9543-9553, 2019.
- [100] B. Wen, M. Xiao, G. Wang, Z. Yang, J. Li, X. Chen, "A Fusion Prognostic Method for Remaining Useful Life Prediction Based on an Extended Belief Rule Base and Particle Filters", *IEEE Access*, vol. 9, pp. 73377-73391, 2021.
- [101] W. Wu, S. Lu, "Remaining Useful Life Prediction of Lithium-Ion Batteries Based on Data Preprocessing and Improved ELM", *IEEE Transactions on Instrumentation and Measurement*, vol. 72, pp. 2510814, 2023.

- [102] Y. Wu, W. Li, Y. Wang, K. Zhang, "Remaining Useful Life Prediction of Lithium-Ion Batteries Using Neural Network and Bat-Based Particle Filter", *IEEE Access*, vol. 7, pp. 54843-54854, 2019.
- [103] W. Xian, B. Long, M. Li, H. Wang, "Prognostics of Lithium-Ion Batteries Based on the Verhulst Model, Particle Swarm Optimization and Particle Filter", *IEEE Transactions on Instrumentation and Measurement*, vol. 1, pp. 2-17, 2014.
- [104] J. Xie, Y. Weng, H. D. Nguyen, "Health-Informed Lifespan-Oriented Circular Economic Operation of Li-Ion Batteries", *IEEE Transactions on Industrial Informatics*, vol. 3, pp. 2749-2760, 2023.
- [105] R. Xiong, Y. Zhang, H. He, X. Zhou, M. G. Pecht, "Double-Scale, Particle-Filtering, Energy State Prediction Algorithm for Lithium-Ion Batteries", *IEEE Transactions on Industrial Electronics*, vol. 2, pp. 1526-1538, 2018.
- [106] X. Xu, Z. Li, N. Chen, "A Hierarchical Model for Lithium-Ion Battery Degradation Prediction", *IEEE Transactions on Reliability*, vol. 1, pp. 310-325, 2016.
- [107] K. Xue, J. Yang, M. Yang, D. Wang, "An Improved Generic Hybrid Prognostic Method for RUL Prediction Based on PF-LSTM Learning", *IEEE Transactions on Instrumentation and Measurement*, vol. 72, pp. 3509121, 2023.
- [108] W. Yan, B. Zhang, W. Dou, D. Liu, Y. Peng, "Low-Cost Adaptive Lebesgue Sampling Particle Filtering Approach for Real Time Li-Ion Battery Diagnosis and Prognosis", *IEEE Transactions on Automation Science and Engineering*, vol. 4, pp. 1601-1611, 2017.
- [109] W. Yan, B. Zhang, X. Wang, W. Dou, J. Wang, "Lebesgue-Sampling-Based Diagnosis and Prognosis for Lithium-Ion Batteries," *IEEE Transactions on Industrial Electronics*, vol. 3, pp. 1804-1812, 2016.
- [110] W. Yan, B. Zhang, G. Zhao, S. Tang, G. Niu, X. Wang, "A Battery Management System With a Lebesgue-Sampling-Based Extended Kalman Filter", *IEEE Transactions on Industrial Electronics*, vol. 4, pp. 3227-3236, 2019.
- [111] W. Yan, B. Zhang, G. Zhao, J. Weddington, G. Niu, "Uncertainty Management in Lebesgue-Sampling-Based Diagnosis and Prognosis for Lithium-Ion Battery", *IEEE Transactions on Industrial Electronics*, vol. 10, pp. 8158-8166, 2017.
- [112] Z. Yang, Y. Wang, C. Kong, "Remaining Useful Life Prediction of Lithium-Ion Batteries Based on a Mixture of Ensemble Empirical Mode Decomposition and GWO-SVR Model", *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp. 2517011, 2021.
- [113] J. Yu, "State-of-Health Monitoring and Prediction of Lithium-Ion Battery Using Probabilistic Indication and State-Space Model", *IEEE Transactions on Instrumentation and Measurement*, vol. 11, pp. 2937-2949, 2015.
- [114] Q. Zhai and Z. Ye, "RUL Prediction of Deteriorating Products Using an Adaptive Wiener Process Model", *IEEE Transactions on Industrial Informatics*, vol. 6, pp. 2911-2921, 2017.
- [115] C. Zhang, Y. He, L. Yuan, and S. Xiang, "Capacity Prognostics of Lithium-Ion Batteries using EMD Denoising and Multiple Kernel RVM", *IEEE Access*, vol. 5, pp. 12061-12070, 2017.

- [116] C. Zhang, S. Zhao, and Y. He, "An Integrated Method of the Future Capacity and RUL Prediction for Lithium-Ion Battery Pack", *IEEE Transactions on Vehicular Technology*, vol. 3, pp. 2601-2613, 2022.
- [117] H. Zhang, D. Zhou, M. Chen, and J. Shang, "FBM-Based Remaining Useful Life Prediction for Degradation Processes With Long-Range Dependence and Multiple Modes", *IEEE Transactions on Reliability*, vol. 3, pp. 1021-1033, 2019.
- [118] J. Zhang et al., "Remaining Useful Life Prediction of Lithium-Ion Battery With Adaptive Noise Estimation and Capacity Regeneration Detection", *IEEE/ASME Transactions on Mechatronics*, vol. 2, pp. 632-643, 2023.
- [119] J. Zhang et al., "A Data-model Interactive Remaining Useful Life Prediction Approach of Lithium-ion Batteries Based on PF-BiGRU-TSAM", *IEEE Transactions on Industrial Informatics*, vol. 2, pp. 1144-1154, 2023.
- [120] L. Zhang, Z. Mu, and C. Sun, "Remaining Useful Life Prediction for Lithium-Ion Batteries Based on Exponential Model and Particle Filter", *IEEE Access*, vol. 6, pp. 17729-17740, 2018.
- [121] S. Zhang, Z. Liu, H. Su, "A Bayesian Mixture Neural Network for Remaining Useful Life Prediction of Lithium-Ion Batteries", *IEEE Transactions on Transportation Electrification*, vol. 4, pp. 4708-4721, 2022.
- [122] S. Zhang, Q. Zhai, X. Shi, X. Liu, "A Wiener Process Model With Dynamic Covariate for Degradation Modeling and Remaining Useful Life Prediction", *IEEE Transactions on Reliability*, vol. 1, pp. 214-223, 2023.
- [123] X. Zhang, Y. Qin, C. Yuen, L. Jayasinghe, X. Liu, "Time-Series Regeneration With Convolutional Recurrent Generative Adversarial Network for Remaining Useful Life Estimation", *IEEE Transactions on Industrial Informatics*, vol. 17, pp. 6820-6831, 2021.
- [124] Y. Zhang, Y. Yang, X. Xiu, H. Li, R. Liu, "A Remaining Useful Life Prediction Method in the Early Stage of Stochastic Degradation Process", *IEEE Transactions on Circuits and Systems II: Express Briefs*, vol. 6, pp. 2027-2031, 2021.
- [125] D. Zhou, A. Al-Durra, K. Zhang, A. Ravey, F. Gao, "A Robust Prognostic Indicator for Renewable Energy Technologies: A Novel Error Correction Grey Prediction Model", *IEEE Transactions on Industrial Electronics*, vol. 12, pp. 9312-9325, 2019.
- [126] Z. T. Cem, "Elektrikli Araçlarda Kullanılan Bataryaların Sağlık Ve Şarj Durumlarının Makine Öğrenmesi İle Tahmini" ,Yüksek Lisans Tezi, Düzce Üniversitesi, Lisansüstü Eğitim Bilimleri Enstitüsü, 2023.
- [127] A. Kerem, "Elektrikli Araç Teknolojisinin Gelişimi ve Gelecek Beklentileri", Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 2014.
- [128] N. Ünlü, Ş. Karahan, O. Tür, H. Uçarol, E. Özsu, A. Yazar, L. Turhan, F. Akgün, M. Tırıs, "Elektrikli Araçlar" , TÜBİTAK Marmara Araştırma Merkezi Enerji Sistemleri ve Çevre Araştırma Enstitüsü, 2003.
- [129] A. A. Awan, <https://www.datacamp.com/tutorial/k-nearest-neighbors-knn-classification-with-r-tutorial> adresinden alındı.

- [130] O. I. Abiodun et al., "Comprehensive review of artificial neural network applications to pattern recognition", IEEE Access, vol. 7, pp. 158 820–158 846, 2019.
- [131] P. Z. Lodetti, E. A. C. A. Neto, M. A. I. Martins, G. H. D. S. Costa, M. A. Ludwig, "Mae and rmse analysis of k-means predictive algorithm for photovoltaic generation," 2022 International Conference on Electrical, Computer and Energy Technologies (ICECET), 2022, pp. 1–6.,
- [132] M. Hamurcu, E. Çakır, T. Eren, "Kullanıcı Perspektifli Çok Kriterli Karar Verme ile Elektrikli Araçlarda Batarya Seçimi", Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, vol.13, pp. 733-749, 2021
- [133] Hedef Filo, "Bataryalar", [Çevrimiçi]. Mevcut: <https://ev.hedef filo.com/ev-nedir/bataryalar>. [Erişim: 2 Ocak 2025].
- [134] Analytics Vidhya, "An end-to-end guide to understand the math behind XGBoost", [Çevrimiçi]. Mevcut: <https://www.analyticsvidhya.com/blog/2018/09/an-end-to-end-guide-to-understand-the-math-behind-xgboost/>. [Erişim: 2 Ocak 2025].
- [135] Analytics Vidhya, "Understand Random Forest Algorithms With Examples", [Çevrimiçi]. Mevcut: <https://www.analyticsvidhya.com/blog/2021/06/understanding-random-forest/>. [Erişim: 2 Ocak 2025].
- [136] Islam, M. T., Huda, N., "Reverse Logistics And Closed-Loop Supply Chain Of Waste Electrical And Electronic Equipment (WEEE)/E-Waste: A Comprehensive Literature Review", Resources, Conservation And Recycling, Vol.137, Pp. 48-75, 2018.
- [137] İnçitaş, "Batarya yönetim sistemi (BMS)," [Çevrimiçi]. Mevcut: <https://www.incitas.com.tr/bilgi-merkezi/blog/batarya-yonetim-sistemi-bms>. [Erişim: 29 Aralık 2024].
- [138] A. Chakure, "Random Forest Regression in Python Explained", [Çevrimiçi]. Mevcut: <https://builtin.com/data-science/random-forest-python>. [Erişim: 2 Ocak 2025].
- [139] BMW, "Elektrikli otomobil türleri", [Çevrimiçi]. Mevcut: <https://www.bmw.com.tr/tr/bmw-i-ve-e-mobilite/elektrikli-otomobil-turleri.html>. [Erişim: 2 Ocak 2025].
- [140] M. E. Özcan, B. Oral, "Elektrikli araç mimarileri ve batarya teknolojilerinin değerlendirilmesi", Çanakkale Onsekiz Mart Üniversitesi.
- [141] Hedef Filo, "Elektrikli araç teknolojisi nedir? HEV, PHEV, BEV ne demektir?", [Çevrimiçi]. Mevcut: <https://ev.hedef filo.com/ev-gundem/blog/elektrikli-arac-teknolojisi-nedir-hev-phev-bev-ne-demektir>. [Erişim: 2 Ocak 2025].
- [142] X-Engineer, "Micro, Mild, Full Hybrid Electric Vehicle", [Çevrimiçi]. Mevcut: <https://x-engineer.org/micro-mild-full-hybrid-electric-vehicle/>. [Erişim: 2 Ocak 2025].
- [143] Lexus, "Yarı hibrit nedir, full hibritten farkı nedir?", [Çevrimiçi]. Mevcut: <https://www.lexus.com.tr/lexusu-kesfet/lexus-otomobilleri-hakkinda/hersey/yari-hibrit-nedir-full-hibritten-farki-nedir>. [Erişim: 2 Ocak 2025].

- [144] Otomasyon Avm, "NiMH (Nikel Metal Hidrit) pil nedir?", [Çevrimiçi]. Mevcut: <https://www.otomasyonavm.com/tr/nimh-nikel-metal-hidrit-pil-nedir>. [Erişim: 2 Ocak 2025].
- [145] Otomotiv Lab, "Kurşun-asit bataryalar", [Çevrimiçi]. Mevcut: <https://otomotivlab.net/kursun-asit-bataryalar>. [Erişim: 2 Ocak 2025].
- [146] Experix, "Tamamen elektrikli arabalar nasıl çalışır?", [Çevrimiçi]. Mevcut: <https://experix.com.tr/tamamen-elektrikli-arabalar-nasil-calisir/>. [Erişim: 2 Ocak 2025]

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirileri

1. M.Yeniođlu, E. Ayççek, O. Erdinç, "Lityum İyon Bataryalarda Kalan Faydalı Ömür Tahmini", ELECO , 2024.