



**T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



DOKTORA TEZİ

**ELEKTRİKLİ ARAÇ BATARYALARININ PROGNOSTİK VE SAĞLIK
DURUMUNUN TAHMİNİ İÇİN MAKİNE ÖĞRENMESİNE DAYALI AKILLI
BİR YÖNTEMİN GELİŞTİRİLMESİ**

Orçun KARADENİZ

**DANIŞMAN
Doç. Dr. Hasan TİRYAKİ**

Elektrik- Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği, Doktora Programı

Haziran, 2024



Anneme ithaf ediyorum...

BÜTÇE DESTEKLERİ

Tez Adını Giriniz

Bu tez çalışması, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'nun (TÜBİTAK) 216M252 numaralı “İçten Yanmalı Motorlu Taşıtlar İçin Yakıt Verimliliğini Arttırıcı ve Yenilikçi Teknolojilerin Geliştirilmesi” isimli TÜBİTAK 1003 projesi ile desteklenmiştir.

TEŞEKKÜR

Bu tezin hazırlanması sürecinde bana destek olan herkese en içten teşekkürlerimi sunarım.

Öncelikle, tez danışmanım Doç. Dr. Hasan TİRYAKİ 'ye, bilgi birikimi, değerli önerileri ve tez sürecim boyunca gösterdiği sabır ve anlayış için minnettarım. Bilimsel yolculuğumda bana rehberlik ettiği ve her zaman yanımda olduğu için kendisine derin saygı ve teşekkürlerimi sunuyorum.

Tez İzleme Komitemdeki değerli hocalarım Prof. Dr. Ozan ERDİNÇ ve Doç. Dr. Abdurrahim AKGÜNDOĞDU 'ya değerli yorumları, eleştirileri ve önerileri için teşekkür ederim. Onların katkıları, bu çalışmanın çok daha kapsamlı ve derinlemesine olmasını sağladı.

Hayatımın en önemli destekçisi olan eşim Cemre KARADENİZ 'e sonsuz sevgi ve sabrı için teşekkür ederim. Her zaman yanımda olduğun ve bana güç verdiğin için minnettarım.

Annem Safinaz KARADENİZ ve babam Erdoğan KARADENİZ 'e, bana sağladıkları sonsuz sevgi, destek ve güven için teşekkür ederim. Bana her zaman inandınız ve her koşulda yanımda oldunuz.

Çalışma arkadaşlarım Gökhan ERDOĞAN, Kadir ARAS ve Oğuz TORUNOĞLU 'na, tez sürecindeki yardımları ve moral desteği için teşekkür ederim. Sizlerle çalışmak büyük bir zevkti.

Son olarak, yöneticim Doç. Dr. Halil Sadi HAMUT' a, akademik ve iş kariyerimdeki rehberliği ve destekleri için teşekkür ederim. Bilgi ve deneyiminiz, bu tezin şekillenmesinde büyük rol oynadı.

Bu tez, sizlerin desteği olmadan tamamlanamazdı. Hepinize en derin şükranlarımı sunuyorum.

Haziran 2024

Orçun KARADENİZ

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI	ii
BEYAN	iii
BÜTÇE DESTEKLERİ	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ŞEKİL LİSTESİ	x
TABLO LİSTESİ	xii
SİMGE VE KISALTMA LİSTESİ	xiii
ÖZET	xvi
ABSTRACT	xviii
1. GİRİŞ	1
1.1. ÇALIŞMANIN AMACI	1
1.2. PROBLEM TANIMI	3
1.3. TEZİN KATKILARI	4
2. KAVRAMSAL ÇERÇEVE	5
2.1. PROGNOSTİK SAĞLIK YÖNETİMİ	5
2.1.1. PHM'nin Genel İdeolojisi	6
2.1.2. Prognostik Terimler ve Tanımlamalar	10
2.1.3. PHM Performans Metrikleri	15
2.1.4. Prognostik Tahminlerde Makine Öğrenme Modelleri Kullanmanın Zorlukları	18
2.1.5. Makine Öğrenmesine Dayalı Önerilen Prognostik Yaklaşım	23
2.2. LİTYUM BATARYALAR	24
2.2.1. Lityum Bataryaların Uygulama Alanları	25
2.2.2. Batarya Terminolojileri	28
2.3. LİTYUM BATARYALARDA YAŞLANMA MEKANİZMALARI	31
2.3.1. Pil Degradasyonunu Etkileyen İç (Hücresel) Faktörler	34
2.3.2. Pil Degradasyonunu Etkileyen Dış Faktörler	42
2.4. YAŞLANMA MODELLEMESİ	44

2.4.1. Fizik Tabanlı Yaklaşımlar.....	45
2.4.2. Veriye Dayalı Teknikler.....	46
2.4.3. KNEE Noktası Tahmini	49
2.5. AÇIK KAYNAKLI VERİ SETLERİ VE ÖZELLİKLERİ	50
2.5.1. Nasa Ames Veri Seti	51
2.5.2. Calce Veri Seti	52
2.5.3. Oxford Veri Seti.....	53
2.5.4. Toyota Araştırma Enstitüsü Veri Seti	54
2.5.5. Raj-2020	56
2.5.6. Dechant-2017 ve Dechant-2020.....	56
2.5.7. Sauer-2021	57
2.6. GİRİŞ PARAMETRE ÖZELLİKLERİ.....	58
2.6.1. Literatürde kullanılan Giriş Özellikleri	58
2.6.2. Giriş Parametre Seçiminin Etkisi	59
2.7. TAHMİN PERFORMANSININ NİCELENDİRİLMESİ	61
2.8. MAKİNE ÖĞRENMESİ MODELLERİ	63
2.8.1. Destek Vektör Regresyonu (SVR) Genel Bakış	63
2.8.2. Uzun Kısa Süreli Bellek (LSTM) Ağı Genel Bakış.....	66
3. YÖNTEM	70
3.1. TEST ALTYAPISI VE VERİ TOPLAMA SİSTEMİ.....	70
3.2. VERİ SETİNİN ÖZELLİKLERİ.....	72
3.3. KEŞİFSEL VERİ ANALİZİ.....	74
3.4. VERİ ÖN İŞLEME VE ÖZELLİK MÜHENDİSLİĞİ.....	76
3.4.1. İstenmeyen sütunları kaldırma	76
3.4.2. Eksik değerleri işleme	76
3.4.3. Kapasite değerlerinin normalleştirilmesi	77
3.4.4. Pil döngüsünün tanımlanması	77
3.4.5. Yeni özellikler ekleme	78
3.4.6. Özellik seçimi ve Toplama.....	78
3.4.7. Standart Özellikleri ölçeklendirme.....	80
3.4.8. Özet	80
3.5. MAKİNE ÖĞRENMESİ UYGULAMALARI	81
3.5.1. Destek Vektör Regresyonu (SVR)	81
3.5.2. Uzun Kısa Süreli Bellek (LSTM).....	81

4. BULGULAR	84
4.1. DESTEK VEKTÖR REGRESYON MODELİ (SVR)	84
4.2. UZUN KISA SÜRELİ BELLEK MODELİ (LSTM).....	88
5. TARTIŞMA.....	92
5.1. BULGULARIN GENEL DEĞERLENDİRİLMESİ	92
5.2. SVR VE LSTM SONUÇLARININ KARŞILAŞTIRILMASI.....	92
5.2.1. Doğruluk Karşılaştırması	92
5.2.2. İşlem Süresi Karşılaştırması.....	93
5.2.3. MAPE ve Alternatif Metriklerin Kullanımı	93
5.3. MODELLERİN GÜÇLÜ VE ZAYIF YANLARI.....	93
6. SONUÇ VE ÖNERİLER	94
6.1. SONUÇ	94
6.2. ÖNERİLER.....	95
6.2.1. Veri Setinin Genişletilmesi ve Çeşitlendirilmesi	95
6.2.2. Hücre Bazlı Optimizasyon ve Kişiselleştirilmiş Modeller.....	95
6.2.3. Alternatif Metriklerin Kullanımı	95
6.2.4. Gerçek Zamanlı Optimizasyon.....	95
6.2.5. RUL Tahmini için Ek Değişkenlerin Dahil Edilmesi	96
6.2.6. Derin Öğrenme Modellerinin Geliştirilmesi	96
6.2.7. Enerji Yönetim Sistemleri ile Entegrasyon	96
6.2.8. Geri Dönüşüm ve Yeniden Kullanım Uygulamaları.....	96
KAYNAKLAR	98
ETİK KURUL İZİN YAZISI	139
KURUM İZNİ YAZILARI.....	140
ÖZGEÇMİŞ	141

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Bakım senaryolarında teşhis ve prognostik şemaların rolleri [51].	8
Şekil 2.2: Prognostik aşaması ve teşhisten geçişi [40].	9
Şekil 2.3: Bazı önemli prognostikler, zaman tanımları ve kavramlarının gösterimi [45].	12
Şekil 2.4: RUL tahminine karşılık gelen trend tahmini [56].	14
Şekil 2.5: RUL tahminlerinin temel gerçeklerden karşılaştırılması [56]. tP [70, 240]'a kadar, $tEOL = 240$, $tEOP > 240$ olduğunda.	14
Şekil 2.6: Makine öğrenme algoritmaları için önerilen prognostik çerçeve.	23
Şekil 2.7: Farklı Li-ion pil kimyalarının güçlü ve zayıf yönlerine genel bakış [66].	27
Şekil 2.8: Hücre kullanımı/çevre (Seviye 4), karşılık gelen bozunma mekanizmaları (Seviye 3), bunların bozunma modlarına bağlantıları (Seviye 2) ve sonuçta ortaya çıkan kapasite/güç azalması (Seviye 1) arasındaki ilişkiyi gösteren basitleştirilmiş ağaç diyagramı [103].	33
Şekil 2.9: Örnek lityum-iyon pil sağlık profilleri. Çoğu profil küçük sayıda aşamaya ayrılabilir (a) ve birçok profil sadece doğrusal yaşlanmayı sergiler (b). Zorlu kullanım protokolleri, kapasitede bir çöküşe yol açabilir, bu da diz noktası olarak bilinir (c)[105].	33
Şekil 2.10: Lityum-iyon hücrelerde iç bozunma mekanizmaları[112].	36
Şekil 2.11: Batarya diz noktası ve etki eden ana sebepler.	50
Şekil 2.12: NASA veri setindeki LIB'ler için SOH ve Döngüleri gösteren grafik.	51
Şekil 2.13: CALCE Verisi Setindeki kapasite kaybı gösterimi.	52
Şekil 2.14: Oxford veri setinde Pil Sıcaklığı ve Pil Süresi grafiği.	53
Şekil 2.15: Oxford veri setinde bir pilin Voltaj ve Zaman grafiği.'dir.	54
Şekil 2.16: Toyota Araştırma Enstitüsü (TRI) veri setindeki lityum iyon pil bozulmasının döngülerine karşı deşarj kapasitesinin grafiği[206].	55
Şekil 2.17: Eşdeğer tam döngülerinde kalan kapasite ve darbe direnci (316,317,318,319) [212]	57
Şekil 2.18: 48 hücrenin kapasite bozulma eğrileri, diz noktalarını ve iki farklı EOL döngü sayısındaki varyasyonları vurgular[216].	58

Şekil 2.19: NASA-2014 verileri ile iyi girdi özellikleri durumu, kötü girdi özellikleri durumu ve her ikisinin kombinasyonu arasındaki tahmin performansının karşılaştırılması [220].....	60
Şekil 2.20: NASA-2014 verileri için iyi bir eğitim hücresi seçiminin tahmin performansı ile kötü bir seçimin ve her ikisinin kombinasyonunun karşılaştırılması [220].....	60
Şekil 2.21: SVM' de ϵ - duyarsız bant[234].....	66
Şekil 2.22: LSTM Hücre Mimarisi.....	67
Şekil 2.23: Bir LSTM ağında zaman içinde ileriye doğru yayılımın gösterimi	69
Şekil 3.1: Test alt yapısı ve veri toplama sistemi bilgisayar arayüzü.....	71
Şekil 3.2: Numune Hazırlama Prosesi.....	72
Şekil 3.3: SOH (%)- Toplam kat edilen mesafe (km)	75
Şekil 3.4: Bağlantı cıvatası Tork Değeri ile kontak direnci arasındaki ilişki	76
Şekil 3.5: Kontak direnci ile busbar sıcaklığı arasındaki ilişki	76
Şekil 3.6: Şarj-deşarj çevirimi akım profili.	79
Şekil 3.7: a) SOH ile C1 pilinin döngülerinin grafiği b) C1 pilinin SOC ile Döngülerinin grafiği.	79
Şekil 3.8: RUL tahmini için uygulanan LSTM modelinin mimarisi.	82
Şekil 4.1: C1, C2, C3, C4, C5, C6, C7 hücreleri için SVR modelinin RUL tahmini.....	86
Şekil 4.2: C1, C2, C3, C4, C5, C6, C7 hücreleri için LSTM modelinin RUL tahmini.	91

TABLO LİSTESİ

Sayfa No

Tablo 3.1: Test için kullanılan hücre bilgileri	71
Tablo 3.2: Veri Seti Açıklamaları	72
Tablo 3.3: Veri setindeki tüm hücrelerin maksimum Toplam mesafe km değerlerini gösteren tablo.	75
Tablo 3.4: Veri kümesindeki tüm hücrelerin maksimum Kapasite Farklı değerlerini gösteren tablo.	77
Tablo 3.5: Bu araştırmada tanımlanan bir pil döngüsünün tanımını temsil eden tablo. (Dosya Adı sütunundaki girişler değiştirilir ve kısaltma için yalnızca gerekli sütunlar gösterilir)	78
Tablo 3.6: SVR modellerinin optimal hiper parametreleri	81
Tablo 3.7: LSTM model parametreleri	82
Tablo 4.1: Takvim yaşlandırılmalı SVM regresyon modellerinin performans ölçümleri	85
Tablo 4.2: Takvim yaşlanması olmadan SVM regresyon modellerinin performans ölçümleri	85
Tablo 4.3: Takvim yaşlandırılmalı LSTM modellerinin performans ölçümleri	88
Tablo 4.4: Takvim yaşlanması olmadan LSTM modellerinin performans ölçümleri	88

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
ARD	: Otomatik alaka düzeyi belirleme
α	: β puan hesaplamasında bölgenin büyüklüğü
$\alpha\sigma$	: Yakalama değişkenliği yönteminde kesirli tolerans
βL	: Gauss hareketli ortalamasının kesirli uzunluk ölçeği
ΔQ	: Kapasitedeki değişiklikler
ε	: Gözlenen gürültü
μk	: k hücresi için parametre ortalama tahmini
μp	: Bayes popülasyon ortalama tahmini
ρP	: Pearson korelasyon katsayısı
ρs	: Veri yoğunluğu fonksiyonu
ρP	: Giriş özellikleri arasında izin verilen maksimum korelasyon katsayısı
$\sigma(x)$	: x değişkeninin standart sapması
σ_k^2	: K hücresi için parametre varyans tahmini
$\sigma l(x_s)$	: Gauss hareketli ortalamasının uzunluk ölçeği
σn	: Gözlemlenen gürültünün standart sapması
σp	: Bayes popülasyon standart sapma tahmini
σR	: ham verilere eklenen gürültünün standart sapması
Σw	: w parametrelerinin önceki varyansı
σw	: Bireysel parametre w_k 'nin önceki varyansı
θk	: k hücresi için parametre seti
θp	: Popülasyon düzeyinde model parametreleri
D	: Eğitim seti
w	: Bayes doğrusal regresyon için parametrelerin posterior ortalama tahmini
X_s	: Bölme değişkeni arasındaki gözlem vektörü
X	: Öodel girişi
f(x)	: Gerçek fonksiyon
Fs	: Kesme noktalarını bulmak için kullanılan fonksiyon

Kısaltmalar	Açıklama
AED-SDA	: Ortalama Öklid Mesafesi Yığılmış Gürültü Giderme Otomatik Kodlayıcı
ANN	: Yapay Sinir Ağı
ARIMA	: Otomatik Regresif Entegre Hareketli Ortalama
BATPFNN	: Yarasa Tabanlı Partikül Filtresi Sinir Ağı
BMS	: Batarya Yönetim Sistemi
BOL	: Yaşamın Başlangıcı
BPSO-SVM	: İkili Parçacık Sürü Optimizasyonu - Destek Vektör Makinesi
CBM	: Koşul Tabanlı İzleme
CC	: Coulomb Sayımı
CCCV	: Sabit Akım Sabit Voltaj
CNN	: Evrişimli Sinir Ağı
CTGAN	: Koşullu Üretken Çekişmeli Ağ
DCNN	: Derin Evrişimli Sinir Ağı
DCNN-EL	: Topluluk Öğrenimi ile Derin Evrişimli Sinir Ağı
DCNN-TL	: Transfer Öğrenme ile Derin Evrişimli Sinir Ağı
DNN	: Derin Sinir Ağı
DOD	: Deşarj Derinliği
DTW	: Dinamik Zaman Çarpıtma
EDA	: Keşifsel Veri Analizi
EIS	: Elektrokimyasal Empedans Spektroskopisi
ELM	: Aşırı Öğrenme Makinesi
EOL	: Kullanım Ömrü Sonu
EV	: Elektrikli Araç
GA	: Genetik Algoritma
GPR	: Gauss Süreci Regresyonu
GRU-GPR	: Geçitli Tekrarlayan Birim çekirdeği : Gauss Süreci Regresyonu
IBL	: Örnek Tabanlı Öğrenme
kNN	: k En Yakın Komşular
LCO	: Lityum Kobalt oksit
LIB	: Lityum: iyon Pil
LS-SVM	: En Küçük Kareler Destek Vektör Makinesi
LSTM	: Uzun Kısa Süreli Bellek

MLE	: Maksimum Olabilirlik Tahmini
NASA	: Ulusal Havacılık ve Uzay Dairesi
OCV	: Açık Devre gerilimi
OEM	: Orijinal Ekipman Üreticisi
PCoE	: Prognostik Mükemmeliyet Merkezi
PDF	: Olasılık Yoğunluk Fonksiyonu
PF	: Partikül Filtresi
PHM	: Prognostik ve Sağlık Yönetimi
RDR	: Kalan Sürüş Menzili
RNN	: Tekrarlayan Sinir Ağı
ROC	: Alıcı İşletim Karakteristiği
RTF	: Hataya Koş
RUL	: Kalan Kullanım Ömrü
RVM	: İlgili Vektör Makinesi
SBM	: Benzerlik Tabanlı Model
SEI	: Katı Elektrolit İnterfaz
SOC	: Şarj Durumu
SOH	: Sağlık Durumu
SVM	: Destek Vektör Makinesi

ÖZET

DOKTORA TEZİ

ELEKTRİKLİ ARAÇ BATARYALARININ PROGNOSTİK VE SAĞLIK DURUMUNUN TAHMİNİ İÇİN MAKİNE ÖĞRENMESİNE DAYALI AKILLI BİR YÖNTEMİN GELİŞTİRİLMESİ

Orçun KARADENİZ

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Elektrik- Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği, Doktora Programı

Danışman : Doç. Dr. Hasan TİRYAKİ

Bu doktora tezinde, prognostik ve diagnostik sistemlerin genel ideolojileri incelenmiştir. Prognostik tahmin yöntemlerinde kullanılan makine öğrenme modelleri ve veriye dayalı tahmin yöntemlerinde karşılaşılan zorluklar araştırılmıştır.

Çalışmada lityum bataryalar üzerine yoğunlaşmış; batarya yaşlanma mekanizmaları ve yaşlanma modellemeleri incelenmiştir. Veriye dayalı modelleme teknikleri ve literatürde açık kaynaklı veri setleri kullanılarak geliştirilmiş sağlık durumu tahmin çalışmaları ele alınmıştır.

Tez çalışması kapsamında, elektrikli araçlarda kullanılan 8 adet lityum iyon hücre laboratuvar ortamında yaşlandırılmıştır. Elde edilen veri setleri kullanılarak, Destek Vektör Makinesi (SVM) ve Uzun Kısa Süreli Bellek (LSTM) yöntemleriyle kalan kullanışlı ömür (RUL) ve prognostik sağlık durumu kestirimleri yapılmıştır. Tezin sonuç bölümünde, SVM ve LSTM yöntemlerinin tahmin başarıları karşılaştırılmış ve LSTM yönteminin prognostik sağlık durumu tahmini için SVM yönteminden daha başarılı olduğu tartışılmıştır.

Bu tezin temel amacı, elektrikli araç bataryalarının ömrünü ve sağlık durumunu doğru bir şekilde tahmin eden, güvenli ve verimli bir şekilde çalışmalarını sağlayan akıllı bir sistem geliştirmektir. Bu çalışmalar, batarya sağlığının izlenmesi ve potansiyel arızaların önceden tespit edilmesi yoluyla elektrikli araçların performansını ve güvenilirliğini artırmayı hedeflemektedir. |

Haziran 2024 , |160| sayfa.

Anahtar kelimeler: |Prognostik, RuL, SoH Kestirimi, Elektrikli Araçlar, Lityum Batarya Paketleri, Makine Öğrenmesi |



ABSTRACT

Ph.D. THESIS

DEVELOPMENT OF AN INTELLIGENT METHOD BASED ON MACHINE LEARNING FOR PROGNOSTIC AND STATE OF HEALTH ESTIMATION OF ELECTRIC VEHICLE BATTERIES

Orçun KARADENİZ

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Electrical and Electronics Engineering

Electrical and Electronics Engineering, Ph.D. Program

Supervisor : Assoc. Prof. Dr. Hasan TİRYAKİ

In this doctoral thesis, the general ideologies of prognostic and diagnostic systems were examined. The machine learning models used in prognostic prediction methods and the challenges encountered in data-driven prediction methods were investigated.

The study focused on lithium-ion batteries, exploring battery aging mechanisms and aging modeling. Data-driven modeling techniques and health status prediction studies developed using open-source datasets in the literature were reviewed.

As part of the thesis work, eight lithium-ion cells used in electric vehicles were aged in a laboratory environment. Using the datasets obtained from this process, predictions for remaining useful life (RUL) and prognostic health status were made using Support Vector Machine (SVM) and Long Short-Term Memory (LSTM) methods. In the final section of the thesis, the predictive performance of SVM and LSTM methods was compared, and it was

discussed that the LSTM method is more successful than the SVM method for prognostic health status prediction.

The primary objective of this thesis is to develop an intelligent system based on machine learning that accurately predicts the health and lifespan of electric vehicle batteries, ensuring their safe and efficient operation throughout their service life. The studies conducted aim to enhance the performance and reliability of electric vehicles by monitoring battery health and detecting potential failures in advance. |

June 2024, |160| pages.

Keywords: | Prognostic, RuL Estimation, Electric Vehicles, Lithium Battery Packs, ML |

1. GİRİŞ

1.1. ÇALIŞMANIN AMACI

Geleneksel içten yanmalı motorlu araçlar (ICEV), enerji kaynağı olarak hidrokarbon yakıtları kullanır. Bu araçlar, hidrokarbon yakıt yanmasının yan ürünleri olan karbon dioksit, azot oksit ve metan gibi zehirli gazlar üretirler[1]. Bu gazların salınımı, hava kirliliği ve küresel ısınma konusunda endişelere yol açmıştır. Bu araçların yaygın kullanımı, fosil yakıtların tükenmesine de neden olmuştur[2]. Bu nedenle, elektrik gibi alternatif yeşil enerji ile çalışan araçlara büyük bir talep bulunmaktadır[3].

Elektrikli araçların (EV) yaygınlaşması, çevresel sürdürülebilirlik ve enerji verimliliği açısından büyük bir adım olarak kabul edilmektedir[3]. Birçok otomobil üreticisi elektrikli araç üretmeye başlamış ve yıllar içinde elektrikli araçlara olan talep artmıştır. EV'ler genellikle enerji kaynağı olarak lityum-iyon bataryaları kullanmaktadır ve elektrikli araçların performansı ve güvenilirliği büyük ölçüde batarya sağlığına bağlıdır. Batarya Sağlık Durumu (State of Health, SoH), bir bataryanın mevcut durumunu ve performansını ifade eden kritik bir parametredir[4].

Bataryalar gerçek zamanlı olarak kullanıldığında, sıcaklık değişimleri, yük değişiklikleri gibi çeşitli faktörlere maruz kalırlar ve bu da doğrudan bataryanın yaşlanmasına/bozulmasına yol açabilmektedir[5]. Lityum-iyon bataryaların sınırlı bir ömrü vardır ve ömrünün sonuna ulaştığında kullanılamaz hale gelirler. Lityum-iyon bataryayı ömrünün sonuna ulaştıktan sonra kullanmak tehlikeli olabilir. Bu durum gerekli önlemler alınmadığında batarya yangını veya bataryanın patlaması gibi olaylara yol açabilir[6]. Bu yangın olaylarının çoğunun bataryanın şarj edilmesi sırasında meydana geldiği bildirilmişken, yakın zamanda bir elektrikli aracın çalışırken yangın çıkardığı bildirilmiştir[7]. Bu batarya yangınları, sürücüler ve yolcular için ölümcül olabilir. Ayrıca, bu yangın olayları sırasında salınan zararlı gazlar da zehirlidir[6].

Elektrikli bir araçtaki bataryanın kalan faydalı ömrünün ve sağlık durumunun prognostik olarak doğru ve zamanında tahmin edilmesi, sürücüyü bilgilendirerek gerekli önlemleri almasını sağlar, arıza meydana gelmeden yapılacak müdahaleler ile felaket niteliğindeki batarya kazalarının önüne geçilmesi sağlanmaktadır[8]. Bunun yanı sıra batarya sağlığının doğru bir

şekilde tahmin edilmesi, ayrıca elektrikli araçların operasyonel verimliliğini artırmak, maliyetleri düşürmek ve kullanıcı deneyimini iyileştirmek için de hayati öneme sahiptir[9].

Bu tez, elektrikli araç bataryalarının prognostik ve sağlık durumunun tahmini için makine öğrenmesine dayalı akıllı bir yöntemin geliştirilmesini amaçlamaktadır. Geliştirilecek bu yöntemler, bataryanın yaşlanma ve bozulma süreçlerini analiz ederek gelecekteki performansını öngörmeyi amaçlar. Bu hem araç üreticileri hem de kullanıcılar için birçok avantaj sunar. Öncelikle, doğru SoH tahminleri, bataryaların zamanında değiştirilmesi veya servise gitmesi gerektiğinde kullanıcıları bilgilendirerek araç güvenliğini artırır. Bataryaların ani arızaları hem güvenlik riskleri yaratabilir hem de araç kullanımında kesintilere neden olabilir. Prognostik SoH tahmini, bu tür sorunları önceden tespit ederek önleyici bakım stratejilerinin uygulanmasını sağlar.

Ayrıca, SoH tahmini, elektrikli araçların toplam sahip olma maliyetini düşürmeye yardımcı olabilir. Batarya değişimi, elektrikli araç sahipleri için en büyük maliyet kalemlerinden biridir. Bataryaların ne zaman değiştirilmesi gerektiğini doğru bir şekilde bilmek, gereksiz batarya değişimlerinin önüne geçer ve bataryaların ömrünü maksimum düzeyde kullanmayı sağlar. Bu hem kullanıcılar hem de üreticiler için maliyet tasarrufu anlamına gelir.

Prognostik SoH tahmini, aynı zamanda elektrikli araçların ikinci el piyasasında değerini korumaya da yardımcı olur[10]. Kullanılmış bir aracın batarya sağlığı hakkında güvenilir bilgiler sunabilmek, ikinci el araçların değerini artırır ve alıcıların güvenle satın alma yapmasını sağlar. Bu, elektrikli araçların pazar payını genişletmek ve sürdürülebilir ulaşım çözümlerine geçişi hızlandırmak için kritik bir faktördür[10].

SoH tahmini için makine öğrenmesi ve veri analitiği gibi ileri teknolojilerin kullanımı, bu tahminlerin doğruluğunu ve güvenilirliğini artırır[11]. Büyük veri analitiği ve yapay zekâ teknikleri, bataryaların kullanım verilerini analiz ederek karmaşık yaşlanma modellerini anlamamıza ve gelecekteki performanslarını tahmin etmemize olanak tanır. Bu teknolojiler, daha akıllı ve proaktif batarya yönetim sistemlerinin geliştirilmesini mümkün kılarak elektrikli araçların güvenilirliğini ve kullanıcı memnuniyetini artırır[12].

Sonuç olarak, elektrikli araç bataryalarının prognostik ve sağlık durumunun tahmini için makine öğrenmesine dayalı akıllı bir yöntemin geliştirilmesi, batarya performansını ve güvenliğini artırmak, maliyetleri düşürmek ve kullanıcı deneyimini iyileştirmek için kritik

öneme sahiptir[13]. Bu tez, sürdürülebilir ve verimli ulaşım çözümlerine geçişi destekleyen önemli bir adım olarak, elektrikli araçların yaygınlaşmasına ve benimsenmesine katkıda bulunmayı hedeflemektedir.

1.2. PROBLEM TANIMI

Elektrikli araçlar (EV), dünya genelinde çevresel sürdürülebilirlik ve enerji verimliliği açısından kritik bir rol oynamaktadır. Fosil yakıtlı araçların egzoz emisyonlarının çevre üzerindeki olumsuz etkileri ve artan enerji talebi, temiz ve yenilenebilir enerji kaynaklarına yönelimi hızlandırmıştır[14]. Elektrikli araçlar, sıfır emisyonlu motorları ile hava kalitesini iyileştirmekte ve enerji tüketimini azaltmaktadır[15]. Bu araçlar, içten yanmalı motorlu araçlara kıyasla daha düşük işletme maliyetleri ve daha yüksek enerji verimliliği sunar[16]. Ancak, elektrikli araçların yaygınlaşmasındaki en büyük zorluklardan biri, batarya teknolojisinin geliştirilmesi ve batarya sağlığının izlenmesidir.

Elektrikli araçların performansı ve güvenilirliği büyük ölçüde bataryalarının sağlığına bağlıdır[17]. Lityum-iyon bataryalar, elektrikli araçların ana enerji depolama birimidir ve bu bataryaların sağlık durumu (State of Health, SoH), aracın menzili, performansı ve genel kullanım ömrünü belirleyen en kritik faktördür[18]. SoH, bataryanın mevcut kapasitesi ve iç direnci gibi parametrelerin izlenmesiyle belirlenir ve bataryanın ne kadar süre daha verimli çalışabileceğini öngörmeye yardımcı olur.

Batarya sağlığının doğru bir şekilde izlenmesi ve tahmin edilmesi, elektrikli araçların operasyonel verimliliğini artırmak ve kullanıcıların güvenliğini sağlamak için hayati öneme sahiptir. Örneğin, bataryaların ani arızaları hem güvenlik riskleri yaratabilir hem de araçların kullanımında kesintilere neden olabilir[19]. Bu nedenle, batarya sağlığının doğru bir şekilde izlenmesi, kullanıcıların batarya değişim veya bakım ihtiyaçlarını önceden belirlemelerine olanak tanır[20], böylece güvenlik riskleri minimize edilir ve araçların performansı sürekli olarak yüksek seviyede tutulur.

Batarya paketlerinin SoH tahmininde karşılaşılan zorluklar, çeşitli faktörlerden kaynaklanmaktadır. İlk olarak, bataryaların yaşlanma ve bozulma süreçleri karmaşıktır ve birçok değişkene bağlıdır[21]. Bu süreçler, bataryaların kullanım koşulları, şarj ve deşarj döngüleri, sıcaklık değişimleri ve diğer çevresel faktörlerle doğrudan ilişkilidir. Ayrıca, laboratuvar ortamında elde edilen verilerle gerçek dünya kullanım koşulları arasında önemli

farklılıklar vardır[22]. Laboratuvar testleri, bataryaların performansını hızlandırılmış koşullar altında değerlendirirken, gerçek dünya verileri daha değişken ve düzensiz olabilir.

Bir diğer zorluk, batarya paketlerinin SoH tahmininde kullanılan veri kalitesidir. Gerçek dünya koşullarında, sensör verilerindeki hatalar ve veri kayıpları sıkça görülmektedir. Bu durum, batarya sağlığının doğru bir şekilde tahmin edilmesini zorlaştırır[11]. Ayrıca, batarya paketlerinin SoH tahmini, tek hücrelerin SoH tahminine kıyasla daha karmaşıktır. Paketler içindeki hücrelerin birbirinden farklı davranışlar sergilemesi ve bu hücrelerin eş zamanlı izlenmesi, tahmin süreçlerini daha da zorlaştırır[23].

Batarya paketlerinin SoH tahmini için makine öğrenmesi ve veri analitiği gibi ileri teknolojilerin kullanımı, bu tahminlerin doğruluğunu ve güvenilirliğini artırabilir. Büyük veri analitiği ve yapay zekâ teknikleri, bataryaların kullanım verilerini analiz ederek karmaşık yaşlanma modellerini anlamamıza ve gelecekteki performanslarını tahmin etmemize olanak tanır[24]. Bu teknolojiler, daha akıllı ve proaktif batarya yönetim sistemlerinin geliştirilmesini mümkün kılarak elektrikli araçların güvenilirliğini ve kullanıcı memnuniyetini artırır.

Sonuç olarak, elektrikli araç bataryalarının SoH tahmini, araçların performansını ve güvenilirliğini artırmak, maliyetleri optimize etmek ve kullanıcı deneyimini iyileştirmek için kritik bir öneme sahiptir. Bu tez, elektrikli araç bataryalarının prognostik ve sağlık durumunun tahmini için makine öğrenmesine dayalı akıllı bir yöntemin geliştirilmesini amaçlamaktadır. Bu yöntemlerin geliştirilmesi ve uygulanması, elektrikli araçların yaygınlaşmasını destekleyecek ve sürdürülebilir ulaşım çözümlerine geçişi hızlandıracaktır[25].

1.3. TEZİN KATKILARI

Bu doktora çalışması, lityum-iyon bataryaların SoH tahminine yönelik makine öğrenmesine dayalı yenilikçi bir yaklaşım geliştirmeyi amaçlamaktadır. Çalışmada aşağıdaki hedeflere ulaşılabilecektir:

- Batarya Sağlığı Modelleme: Literatürdeki modelleme tekniklerinin analiziyle, SoH ve RuL tahminleriyle prognostik sağlık durumu tespiti için kapsamlı bir çerçeve sunmak.
- Makine Öğrenmesi Yöntemlerinin Performans Değerlendirmesi: LSTM ve Destek Vektör Regresyonu (SVR) gibi modellerin, batarya ömrü tahminindeki doğruluklarını karşılaştırmak.

- Gerçek Veri Setleri Kullanımı: Elektrikli araçlardan toplanan gerçek veri setlerini kullanarak, laboratuvar ortamında oluşturulan veri setlerinin eksiklerini gidermek ve tahmin doğruluğunu artırmak.

Makine öğrenmesi tabanlı bu yaklaşım, sadece akademik katkılar sağlamakla kalmayacak, aynı zamanda batarya sağlığı izleme sistemlerinin geliştirilmesi ve endüstriyel uygulamalara entegrasyonu açısından önemli bir adım olacaktır. Sonuç olarak, bu çalışma, elektrikli araçların güvenilirlik ve verimliliğini artırmayı, kullanıcı memnuniyetini yükseltmeyi ve sürdürülebilir ulaşım çözümlerine geçişi hızlandırmayı hedeflemektedir.

2. KAVRAMSAL ÇERÇEVE

2.1. PROGNOTİK SAĞLIK YÖNETİMİ

Bilgi teknolojileri çağında, veri hemen hemen her alanda inanılmaz bir hızla üretilmekte, toplanmakta ve biriktirilmektedir. Bu hızla büyüyen veri hacimlerinden faydalı bilgiler çıkarabilmek için büyük veriyi analiz edebilen hesaplamalı araçlara ihtiyaç duyulmaktadır. Bu gereklilik, çeşitli uygulama alanlarında veri madenciliği alanında gelişmelere yol açmıştır.

Veri madenciliği, veriden desen keşfetme ve çıkarma sürecidir[26]. Bu süreç genellikle büyük miktarda verinin karakterizasyonu, genelleştirilmesi, sınıflandırılması, kümeleme, ilişkilendirme, desen eşleştirme ve görselleştirilmesini içerir[27]. Prognostik ve Sağlık Yönetimi (PHM) alanı, genellikle sistem operasyonları sırasında ekipmanlardan büyük miktarda veri toplayan Durum İzleme Sistemi (CMS) sistemlerinin bir parçası olarak yer almaktadır. PHM'deki bu büyük veri toplama, veri madenciliği yaklaşımlarının uygulanmasını faydalı kılmaktadır. Ayrıca, prognostik alanı, bir sistemin ömrünün sonuna kadar olan zaman dilimini belirlemek için arıza öncülerini tahmin etmeyi ve öngörmeyi de içerir. PHM'de bir sistemin ömrü boyunca operasyonel ömrü genellikle sistemin Kalan Kullanım Ömrü (RUL) olarak bilinir ve bu, sistemin sağlık durumunun ana göstergelerinden biridir.

Geleneksel regresyon modeli veya istatistiksel analiz gibi geleneksel yaklaşımlar kullanılarak RUL tahmininde bazı zorluklar bulunmaktadır[28]. İlk olarak, geleneksel yaklaşımlar, sistemin fiziksel davranışları hakkında az ya da hiç ön bilgiye sahip olmadığında RUL'yi doğru bir

şekilde tahmin edemez[29]. İkinci olarak, geleneksel yaklaşımlar, karmaşık veya çoklu arıza koşulları ve/veya özellikleri olan sistemleri analiz etmekte genellikle başarısız olur. Üçüncü olarak, geleneksel yöntemlerin sağladığı tahmin doğruluğu yaklaşık %45 ila %50 civarında olup, bu hala tatmin edici değildir[30]. Dördüncü olarak ise, birden fazla PHM modelini karşılaştırmada standart bir şekilde kullanılabilecek genel performans metriklerinin eksikliğidir. Veri madenciliği metodolojisi, olasılık[31], istatistik[32], makine öğrenmesi[33] ve yapay zekâ (AI) [34] gibi çok disiplinli alanlara dayanmaktadır. Ancak, PHM'deki büyük zorlukları ele alabileceği düşünülen veri madenciliği disiplinleri, makine öğrenmesi ve yapay zekâ algoritmalarıdır. Geleneksel makine öğrenme yöntemleri, aynı zamanda sığ öğrenme modelleri olarak da adlandırılır ve yapay sinir ağı (ANN) [35], destek vektör makineleri (SVM) [36], lojistik regresyon (LR) [37] ve diğerlerini içerir. Bu geleneksel yöntemlerin yıllar içinde iyi performans gösterdiği zaten kanıtlanmış olsa da RUL tahminindeki bu zorlukların üstesinden gelmede hala başarısız olurlar. Bu durum, PHM uygulamalarında modern bir makine öğrenme yaklaşımı olan derin öğrenmenin benimsenmesi için bir fırsat yaratmaktadır.

Derin öğrenmenin erken konsepti, ilk olarak 2006 yılında Geoffrey Hinton tarafından mevcut bir ANN'nin daha yüksek boyutluluğunu geliştirme ürünü olarak başlatılmıştır [38]. Derin öğrenme, sığ öğrenme yöntemlerinin birçok eksikliğini aşma potansiyeline sahiptir çünkü ham veriden daha karmaşık temsil bilgilerini yakalamak için birden çok doğrusal olmayan dönüşüm fonksiyonu kullanır [39]. Derin öğrenme yaklaşımları ayrıca, geçmiş davranışlar hakkında daha az bilgi kullanarak ve yine de kabul edilebilir bir tahmin doğruluğu sağlayarak başarılı tahmin modelleri oluşturma konusunda kanıtlanmıştır[40]. Muhtemelen kalan tek büyük zorluk, PHM'de derin öğrenmenin uygulanmasının performansını değerlendirmek için standart bir metriğin geliştirilmesidir ki bu da bu tezin ele alacağı konulardan biri olacaktır. Makine öğrenmesi ve derin öğrenme yaklaşımlarının PHM uygulamalarındaki rolü de incelenecektir.

2.1.1. PHM'nin Genel İdeolojisi

Mühendislik sistemlerinde kritik karar verme sürecini desteklemek için sistemin sağlık analizine yönelik faaliyetler gereklidir. Çoğu mühendislik sistemi, belirli bir çalışma süresi içinde bakımı yapılması veya değiştirilmesi gereken karmaşık, birbirine bağlı, çoklu bileşenler ve malzemelerden oluşur. Bir sistemin çalışmasını sürdürebilmek için, sistemin arıza ile sonuçlanan senaryolarından kaçınılmalıdır. Bu senaryoya bir çözüm, sistemin bileşenlerinin operasyon devam ederken bakımını gerçekleştirmektir. Bu bakım planı, operasyonun düzgün bir şekilde yürütülmesini garanti etmekle kalmaz, aynı zamanda operasyon, üretim ve destek


maliyetlerini azaltma açısından büyük ekonomik etkilere sahiptir. Teşhis genellikle meydana gelebilecek belirli bir arıza türünü belirlemede rol oynarken, prognostik sistemin sağlık durumunu değerlendirmek için kullanılır. Sistemin bileşenlerinin çalışma süresi genellikle ömrün sonuna kadar geçen süre olarak adlandırılır. Bu tezin ana odağı sistemin prognostiklerine ilişkin olduğundan, EOL, RUL ve SoH projeksiyonu veya tahmini terimleri birçok kez kullanılacaktır.

PHM terimi, yalnızca sağlık durumunu izlemekle kalmayıp, aynı zamanda sistemin RUL'sini tahmin etmeyi de içeren proaktif bakım kararlarını mümkün kılmak için bir yöntem olarak tanıtılmış ve geliştirilmiştir[41], [42], [43], [44], [45]. PHM teknolojisi, pasif sistem güvenilirliğini adaptif hale dönüştürebilir ve aynı zamanda sistemin yaşam döngüsü maliyetini azaltabilir[46], [47]. Bir sistemin prognostik sağlık durumu tahmini, sistemin RUL'sini değerlendirme ve tahmin etme yeteneği ile tanımlanır[48]. Geleneksel olarak, prognostik sistem için prognostik yöntem yalnızca belirli uygulamalar için RUL tahmin doğruluğuna odaklanır[49]. Ancak PHM tarafından yıllar boyunca birçok çalışma gerçekleştirildikten sonra, PHM'de başka zorluklar da bulunmuştur. Bunun en büyük nedeni prognostik tahminlerin, diagnostik teşhislere kıyasla tam olarak gelişmemiş olmasıdır. Diagnostik teşhislerde hata modları ve bu hata modlarına sebep olan problem kaynakları doğrudan sensör teknolojileri ile ölçülebiliyor iken prognostik tahminlerde kısıtlı sensör bilgisiyle gelecekteki hata modlarının tahmin edilmesi amaçlanmaktadır. Bu sebeple prognostik çalışmalar da belirli son kullanıcıların gereksinimlerini karşılamaya yönelik yeni yöntemlerin geliştirilmesini gerekli kılmıştır [50].

CBM'nin önemini göstermek için, önerilen bir sistemin operasyon bakım prosedürü Şekil 2.1'de gösterilmektedir. Diagnostik ve prognostikler CBM'de esasen yer almaktadır. Daha önce belirtildiği üzere diagnostik, arızaların veya hataların tanımlanması sürecidir, oysa prognostik, sağlık durumlarının belirlenmesi ve sistemdeki arızaya kadar geçen sürenin tahmin edilmesi sürecidir[51]. Bir arıza gözlemlenmeden önce kalan süre, sistemin RUL'si olarak tanımlanır [52].

Prognostik süreci ayrıca Şekil 2.2'de gösterildiği gibi iki aşamayı içerir: diagnostik teşhis ve prognostik kestirimdir. İlk aşamada mevcut sistemin sağlık durumu değerlendirilir. Diagnostik teşhis ve prognostik kestirimler sistem sağlık analizinde kritiktir ve birçok durumda birbirinden ayırt edilmez. Bu aşamada desen tanıma için sınıflandırma veya kümeleme teknikleri kullanılır. İkinci aşamanın amacı, sistemin veya bir bileşenin arızaya kadar geçen süresini belirleyerek,

tahmin ederek veya projekte ederek RUL'yi tahmin etmektir. Bu aşamada projeksiyon trendleri, izleme teknikleri ve zaman serisi analizi kullanılır.




Şekil 2.1: Bakım senaryolarında teşhis ve prognostik şemaların rolleri [51].

Prognostiklerin aşamaları ve rollerine ek olarak, sistemin sağlık durumunu ve RUL'yi analiz etmek için modelleme teknikleri kurulmalıdır. Prognostik veri için genellikle iki tür modelleme tekniği kullanılır. Birincisi, veri odaklı model, ikincisi ise fizik tabanlı modeldir. Veri odaklı bir model oluşturmak, sistemden yeterli arıza ile sonuçlanan örnek verilerini gerektirir, oysa fizik tabanlı model, sistemdeki arıza ilerlemesinin fiziğinin iyi anlaşılmasını gerektirir[53]. Prognostik analiz için veri odaklı ve fizik tabanlı modellerin bazı detaylı tanımları aşağıda açıklanmıştır.

Veri odaklı model, sistemin fiziksel modeline veya sistem ile ilgili uzman görüşü değerlendirmesi yerine mevcut sistemde toplanan verileri kullanarak sistem davranışını modellemeyi amaçlar [54].

Veri odaklı yaklaşımlar genellikle iki türe ayrılır. Birincisi istatistiksel yaklaşımdan, ikincisi ise makine öğrenme yaklaşımındandır. İstatistiksel yaklaşımlar kullanılarak oluşturulan modeller genellikle mevcut verilerden olasılıksal ve deterministik yöntemler üzerine kuruludur. Makine öğrenme yaklaşımlarının amacı ise tarihsel verilere dayanarak karmaşık desenleri tanımak ve yakalamaktır. Bu tezde makine öğrenme yaklaşımları kullanılacaktır.



Şekil 2.2: Prognostik aşaması ve teşhisten geçişi [40].

Fizik tabanlı model, sistemin RUL'sini tahmin edebilecek bir model oluşturmak için sistemin temel fiziği hakkında bilgi veya anlayış gerektirir. Degradasyon veya arızaya kadar geçen veriler, fizik tabanlı modelde önemli bir rol oynamaz. Bu nedenle, bu durumda sistemdeki fiziksel kurallar önceden önemli ölçüde bilinmelidir, bu da fizik tabanlı model oluşturmak için alan uzmanının temel gereksinim olduğu anlamına gelir. Fizik tabanlı modeldeki ilk adım, sistemlerin sağlık durumunu temsil eden fiziksel parametrelerin bilinen ilişkisini kullanmaktır [55].

Fizik tabanlı prognostik modellerde dikkate alınması gereken iki zorluk vardır: 1) bazı sistemlerin degradasyon fiziği belirlemek çok zor olabilir veya çoğu durumda bilinmeyebilir ve 2) böyle bir sistemdeki parametrelerin değerlerini elde etmek veya değerlendirmek imkânsız olabilir. Bir fizik tabanlı model, sistemin arıza mekanizmasının yanı sıra yüksek seviyede kalite kontrol hakkında geniş bilgi ve derin anlayış gerektirir. Bu nedenle, belirli sistemler veya konu

ile ilgili derin bilgiye sahip yetenekli uzmanlar, fizik tabanlı modeli oluşturmak ve belirlemek için temel gereksinimdir [55]. Fizik tabanlı modelin bu zorlukları, gelecekte fizik tabanlı modelin yerini alacak veri odaklı modelin geliştirilmesine yol açmıştır.

Prognostikler için veri odaklı modellerden biri olan makine öğrenme yaklaşımları bu tezin ana tartışma konusu olacaktır. Hesaplama araçlarının ilerlemesi bu yaklaşımın gelişimini büyük ölçüde etkilemiştir. Karmaşık makine öğrenme algoritmaları, yetenekli hesaplama gücü gerektirir. Modern bilgisayarların daha iyi hesaplama gücü sayesinde, makine öğrenme algoritmalarının sistem verilerinin daha karmaşık desenlerini empirik olarak öğrenip tanıyabildiği kanıtlanmıştır. Çoğu durumda, mevcut fizik tabanlı modelin yerini alacağına inanılmaktadır. Prognostik tahminlerde kullanılan makine öğrenmesi yöntemleri ilerleyen bölümlerde detaylı olarak tartışılacaktır.

2.1.2. Prognostik Terimler ve Tanımlamalar

Bu bölümde, literatürde prognostik alanında yaygın olarak kullanılan tüm terimler açıklanmaktadır. PHM araştırma topluluğunda birçok benzer terim birbirinin yerine kullanılmıştır. Ayrıca, bazı durumlarda aynı terimler farklı anlamlara atıfta bulunmuştur. Bu nedenle, bu liste, PHM topluluğu dışındaki bazı standart dışı kullanım durumlarının neden olduğu bazı tutarsızlıkları açıklığa kavuşturmaya yardımcı olmayı amaçlamaktadır[56].

Varsayımlar


- Prognostikler, arıza öncüllerini tespit edebilir ve RUL'yi tahmin edebilir. RUL tahmini büyük ölçüde mevcut sağlık durumuna ve sistemin gelecekteki çalışma koşullarına dayanır.
- Sağlık indeksi, bir sistemin sağlık durumunun tanımlanması olarak tanımlanır. Sağlık indeksi, bir sistemin özelliklerinden ve koşullarından toplanarak oluşturulabilir.
- RUL tahmini, bir öngörü, tahmin ve ekstrapolasyon prosedürüdür.
- Karşılaştırma için, kullanılan algoritmalar her tahmin için tek bir RUL değeri üretebilir. RUL dağılımları üreten algoritmalar da tek bir tahmin sayısına sıkıştırılabilir.

- Tüm sistemler genellikle (CMS) Durum İzleme Sistemi'nin bir parçası olarak sürekli izleme faaliyetleri altında kalır ve sistemin arıza durumu geliştikçe sistemden veri ölçme ve toplama yeteneğine sahiptir.

Yaygın Terminolojiler

- EOL (End-Of-Life): Gerçek yaşam sonu zamanı.
- RUL (Remaining Useful Life): Sistem sağlığı arıza eşiğinin altına düşmeden önce kalan süre.
- EOP (End-Of-Prediction): Tahminin belirlenmiş arıza eşiğine ulaştığı en erken zaman.
- UUT (Unit Under Test): Test Altındaki Birim.
- I: Zaman anı indeksi t_i
- 0: Sistemin başlangıç zamanı t_0
- F: Bir arızanın oluşmaya başladığı zaman t_F
- D: Diagnostik sisteminin sistemdeki arızayı tespit ettiği zaman t_D
- P: Prognostik sistemin ilk tahmin yaptığı zaman t_P
- $f_{n'}^I(i)$: i zaman indeksindeki l'inci UUT için n'inci özelliğin değeridir.
- $c_{n'}^I(i)$: i zaman indeksindeki l'inci UUT için n'inci çalışma koşulunun değeridir.
- $r_{n'}^I(i)$: Verilerin l'inci UUT için t_i zamanına kadar mevcut olduğu göz önüne alındığında, t_i zamanındaki RUL tahminidir.
- $\pi^I(i | j)$: l'inci UUT için t_i zamanına kadar verilen veri için i zaman indeksindeki tahmindir. Tahmin herhangi bir alanda yapılabilir.
- $\Pi^I(i)$: l'inci UUT için zaman indeksi i'deki tahminlerin yörüngesini temsil eder.
- $h^I(i)$: l'inci UUT için bir sistemin sağlığını temsil eder.

Şekil 2.3, prognostiklerde kullanılan yaygın zaman terminolojilerini göstermektedir. Bu terimler tezin geri kalanında sürekli olarak kullanılacaktır. Kırmızı kesikli çizgi, prognostik sistemin gerçek davranışını temsil ederken, mavi çizgi prognostik modelden gelen tahmin değerini temsil eder.




Şekil 2.3: Bazı önemli prognostikler, zaman tanımları ve kavramlarının gösterimi [45].

Terim Tanımları


- Zaman indeksi: Bir prognostik uygulamasında zaman, kesikli veya sürekli olabilir. Zaman indeksi, gerçek zaman yerine kesikli ölçüm olarak kullanılır. Bu, örnekleme zamanının aynı desene uymadığı durumlarda yararlıdır. Bu tezde tanımlanan zaman indeksleri, zaman ölçeklerine bağlı veya değişken değildir.
- Sağlık indeksi: $h^l(i)$ UUT için i zamanındaki sağlık indeksidir, $l = 1, 2, \dots, L$. N. Operasyonel koşullarda normalize edilmiş sağlık göstergelerinin toplamı da h olarak kabul edilir.

- Arızanın tespit zamanı: D sistemdeki arızaların tespit edildiği zaman indeksidir (t_D). D algoritmanın sistemin arıza durumundan yeterli veri toplandıktan sonra RUL tahminlerini yapmaya başlamasını tetikler. Batarya PHM gibi uygulamalar için prognostik, bir bozulma süreci olarak kullanılır. Arıza durumu tespit edilemeyebilir. Bu durumda, t_D , t_0 ile eşit kabul edilebilir.
- Tahmine başlama zamanı: Genellikle, sistemin tahmin yapmaya başladığı zaman (t_P) ile arıza durumunun tespit edildiği zaman (t_D) arasında bir fark vardır. Genellikle, $t_P \geq t_D$ 'dir, çünkü algoritmaların RUL tahminine başlamadan önce ek veri girişleriyle ayarlama yapması gerekir. Ancak, arızalar tespit edilmeden önce sistemde sürekli olarak veri toplandığı bazı durumlarda, herhangi bir zamanda RUL'yi tahmin etmek için yeterli veri mevcut olabilir, bu nedenle $t_P = t_D$ olabilir.
- Prognostik özellikler: $f_{n^l}(i)$ 'nin i zamanındaki bir özellik olduğu göz önüne alındığında, burada $n = 1, 2, \dots, N$ özellik numarasıdır ve $l = 1, 2, \dots, L$ UUT indeksidir. Özellikler, sistem parametreleri, sistem nitelikleri, bileşen değişkenleri veya sistemin prognostik ile ilgili herhangi bir işletim koşulundan ölçülebilecek, hesaplanabilecek veya hesaplanabilecek diğer nicelikler gibi birçok form alabilir. Özellikler aynı zamanda i zamanındaki l 'inci UUT'nin özellik vektörü $f_{n^l}(i)$ olarak da ifade edilebilir.
- Operasyonel koşullar: $c_{n^l}(i)$ 'nin i anındaki operasyonel koşullardan biri olduğu, $m = 1, 2, \dots, M$ 'nin durum numarası ve $l = 1, 2, \dots$ olduğu göz önüne alındığında, L UUT indeksidir. Yük aynı zamanda i zamanındaki l 'inci UUT'nin $C'(i)$ vektörü olarak da ifade edilebilecek çalışma koşullarından biri olarak da ifade edilebilir.
- Nokta tahmini: $\pi^l(i | j)$ 'nin i zamanındaki bir tahmin noktası olduğu göz önüne alındığında. Normalde bilgi, $t_j \leq t_i$ olduğu t_j zamanına kadar sağlanır. $i = \text{EOL}$ için bu durum $\pi^l(i | j)$, kritik eşikteki bir sağlık göstergesidir. Bazı durumlarda ilk adım, özelliklerin tahminini yapmak, ardından bu özellikleri toplayarak sistemin sağlık durumunu hesaplamaktır. Diğer durumlarda, RUL'u tahmin etmek için özellikler sağlık durumuna göre toplanır.
- Trend tahmini: $\Pi^l(i)$, i zamanındaki RUL tahminlerinin yörüngesidir. $\Pi^l(i) = \{\pi^l(i | j), \pi^l(i + 1 | j), \dots, \pi^l(\text{EOL} | j)\}$

- RUL tahmini: $r^I(i)$, i zamanındaki kalan faydalı ömür tahminidir. Sistemin koşulları ve sistemin özellikleri zaman anına kadar sağlanır, sistemin gelecekteki operasyonel profili mevcut olduğu varsayılır. Şekil 2.4'te gösterildiği gibi, tahmin zaman anında çizilmiş ve zaman anına kadar verilen bilgidен RUL'yi tahmin etmiştir. 1. UUT için RUL şu şekilde tahmin edilecektir: $r^I = \arg\{h(z) = 0\} - i$. Yıldız sembolünün (*) alt simgesinin, sistem değişkeninin gerçek değeri olduğuna dair en iyi inancı gösterdiğine dikkat edin. Bu durum literatürde Temel Gerçek olarak tanımlanmaktadır [56].



Şekil 2.4: RUL tahminine karşılık gelen trend tahmini [56].



Şekil 2.5: RUL tahminlerinin temel gerçeklerden karşılaştırılması [56].

t_P [70, 240]'a kadar, $t_{EOL} = 240$, $t_{EOP} > 240$ olduğunda.

2.1.3. PHM Performans Metrikleri

Literatürde birçok PHM performans metriği rapor edilmiştir. Belirli bir metrik, farklı prognostik uygulama alanlarına ve modeli oluşturmak için kullanılan algoritmalara dayanarak kullanılmıştır. Literatürde ana olarak üç kategoriye ayrılan algoritmik performans metrikleri bulunmaktadır: 1) doğruluk tabanlı metrikler, 2) kesinlik tabanlı metrikler ve 3) dayanıklılık tabanlı metrikler. Çoğu literatürde doğruluk ve kesinlik tabanlı metrikler kullanılmıştır. Bazı durumlarda dayanıklılık tabanlı metrikler de kullanılmıştır, ancak bu metriklerin, Brier Skoru, Alıcı İşletim Karakteristiği (ROC) ve duyarlılık gibi resmi tanımları sınırlıdır. Bununla birlikte, dayanıklılık metrikleri, modelin diğer metriklerle karşı stabilitesinin ölçülmesine yol açabilir. PHM modelinin dayanıklılığı ve stabilitesinin ölçülmesi gelecekte keşfedilmelidir, çünkü bu konuda ayrıntılı çalışma yapan sınırlı sayıda çalışma bulunmaktadır.

Genel olarak, algoritmik performans, gerçek ve tahmin edilen RUL arasındaki hata farkını ölçerek değerlendirilebilir. İstatistiksel, yakınsama, moment gibi diğer performans özellikleri de hataları kullanarak nicelendirilebilir. Ancak, en önemli kavramlardan biri, hataların yalnızca gerçek veri mevcut olduğunda hesaplanabileceğidir, bu her zaman mümkün olmayabilir. Gerçek veri mevcut olmadığında, tarihi veya geçmiş veriler kullanılarak ilgili çıkarımlar yapılabilir. Ancak, bu yalnızca mevcut sürecin, geçmiş verilere kıyasla benzer bir dağılıma sahip olduğu varsayımıyla geçerlidir.

Makine öğrenimi ve derin öğrenme yaklaşımları, yoğun hesaplama gerektirir. Bazı hesaplama metriklerinin, örneğin karmaşıklık[57], özgüllük[58], hesaplama süresi ve bellek alanı gibi, ölçülmesi ve nihai sonuçlara dahil edilmesi gerektiği önerilmektedir. Hesaplama performansını ölçmek için popüler bir terim "Big O" olarak adlandırılır [58]. Bu kavram, algoritmanın çalışması için gereken süreyi, girdi verilerinin veya fonksiyonun nispi boyutuna göre tanımlar.

Derin öğrenme yaklaşımına ilişkin PHM ölçütlerine ek olarak, daha fazla tartışmaya yarar sağlayabilecek diğer PHM performans ölçütleri de "maliyet-fayda ölçütleri'dir [59], [60]. Bu ölçüt grubu, İşlem Maliyetinin önceden RUL (Beklenen Kullanım Ömrü) tahmin edilebilirse nasıl azaltılabileceğine ve RUL tahmininin doğruluğunun sistemi işletme maliyetini nasıl etkilediğine odaklanmaktadır. Ölçümler genellikle operasyon başına yatırım getirisi (ROI) hakkında bilgi vermektedir. Konuyla ilgili daha fazla detay, D. L. Goodman, S. Vohnout ve S. M. Wood'un çalışmalarında bulunabilir[59][60]. Bu bölümde literatürde derin öğrenme

yaklaşımına ve kullanım senaryolarına iyi uyum sağlayan PHM metriklerinin çoğunu özetlemektedir.

- Hata: Hata, tahmin sonucunun gerçek verilerle karşılaştırıldığında farkı veya sapması olarak tanımlanan temel kavramdır. Doğruluğa dayalı metriklerin çoğu doğrudan veya dolaylı olarak bir hata ölçümüdür[61].

$$\Delta'(j) = r^* - r'(j) \quad (2.1)$$

- Ölçekten bağımsız ortalama hata: Ağırlıklar, RUL tahminlerinin hatalarını ve birkaç UUT üzerinden ortalama RUL sonucunu üstel olarak ölçeklendirir. Burada D0 normalleştirici bir sabit değerdir [61].

$$A(i) = \frac{1}{L} \sum_{l=1}^L \exp \left\{ -\frac{|A'(i)|}{D_0} \right\} \quad (2.2)$$

- Ortalama önyargı: Tahmin hatalarının ortalamaları, tahminin başlangıcından itibaren herhangi bir zamanda ve herhangi bir zamanda yapılabilir. Bu metrik, bir uygulamadaki önyargıların ortalamasını, genel UUT indeksini ve toplam önyargıyı hesaplamak için de genişletilebilir [61].

$$B_l = \frac{\sum_{i=p}^{EOP} \{\Delta A^{(i)}\}}{(EOP - P + 1)} \quad (2.3)$$

- Zamanlılık: Üstel olarak tartılır, bir tür asimetrik ağırlıklandırma işlevi aracılığıyla RUL tahmin hatalarını hesaplar. Bu genellikle erken tahminlerden ziyade geç tahminleri cezalandırır [61].

$$A(i) = \frac{1}{L} \sum_{l=1}^L \varphi\{\Delta^l(i)\}, \quad \varphi(z) = \begin{cases} \exp\{|z|/a_1\} - 1, & \text{if } z < 0 \\ \exp\{|z|/a_2\} - 1, & \text{if } z \geq 0 \end{cases} \quad (2.4)$$

$$a_1 > a_2 > 0$$

- Yanlış Pozitif (FP) ve Yanlış Negatif (FN): FP, kabul edilemez erken tahminleri belirlemeyi amaçlarken, FN, kabul edilemez geç tahminleri belirlemek için kullanılır. Kabul edilebilir aralıklar (tFN ve tFP) tahminden önce ayarlanmalıdır. Bu, genellikle gereksiz düzeltmelere neden olan gereksiz sağlama süresinin sonucu olan erken tahminleri ele almak içindir. Kritik

eşik zaman birimlerinden (tc) sonra gelen tahmin, tahmin sonucu olarak kabul edilmeyecektir [62]

$$FP(r_*^l(i)) = \begin{cases} 1, & \text{if } \Delta^l = t_{FP} \\ 0, & \text{otherwise} \end{cases}$$

$$FN(r_*^l(i)) = \begin{cases} 1, & \text{if } -\Delta^l = t_{FN} \\ 0, & \text{otherwise} \end{cases} \quad (2.5)$$

- Ortalama mutlak yüzde hatası (MAPE): Tahminlerdeki mutlak yüzde hatalarının ortalamaları, aynı tahmin zamanında birden fazla UUT için hesaplanır. Ortalama, medyan yerine, bu metrik Medyan mutlak yüzde hatasını (MdAPE) hesaplamak için de kullanılabilir [63]

$$MAPE(i) = \frac{1}{L} \sum_{l=1}^a \left| \frac{100\Delta^l(i)}{r_*^l(i)} \right| \quad (2.6)$$

- Anomali korelasyon katsayısı (ACC): ACC, tahmin ve gözlem aşaması arasındaki farkı ölçer. Bu, her tahmin noktasında tarihsel ortalamayı çıkararak yapılabilir. ACC'nin avantajı, önyargı veya hataya duyarlı olmamasıdır. Bununla birlikte, iyi bir anomali korelasyonu tahmin doğruluğunu garanti etmez. ACC normalde tP'den sonraki birkaç zaman adımında hesaplanır. Bu, uzun vadeli tahminleri değiştirmek için kullanılabilir. ACC için geçmiş verilerden taban çizgisinin hesaplanması gereklidir [54].

$$ACC = \frac{\sum (\pi^l(i|j) - z_{\#}(i)) (z_*(i) - z_{\#}(i))}{\sqrt{\sum (\pi^l(i|j) - z_{\#}(i))^2 \sum (z_*(i) - z_{\#}(i))^2}} \quad (2.7)$$

burada, $z_*(i)$ bir tahmin değişkenidir ve $z_{\#}(i)$ karşılık gelen geçmiş verileridir

- Ortalama hata karesi (MSE): Kare tahminin ortalamaları, aynı tahmin ufkunda birden fazla UUT için hatayı hesaplar. MSE'nin bir türevidir, birçok PHM uygulaması arasında da popüler olan Kök Ortalama Kare Hatasıdır (RMSE)[64].

$$MSE(i) = \frac{1}{L} \sum_{l=1}^L \Delta^l(i)^2 \quad (2.8)$$

- Ortalama mutlak yüzde hatası (MAE): Mutlak tahminin ortalamaları, aynı tahmin ufkunda birden fazla UUT için hatayı da hesaplar, ancak ortalama yerine medyan kullanır [64].

$$MAE(i) = \frac{1}{L} \sum_{l=1}^L |\Delta^l(i)| \quad (2.9)$$

- Kök ortalama kare yüzdesi hatası (RMSPE): Ortalama yüzdenin karekökü, birden fazla UUT'den gelen tahminin hatasını hesaplar. Benzer bir ölçüm, Kök ortanca kare yüzde hatasıdır (RMSPE) [64].

$$RMSPE(i) = \sqrt{\frac{1}{L} \sum_{l=1}^L \left| \frac{\Delta^l(i)}{r_*^l(i)} \right|^2} \quad (2.10)$$

2.1.4. Prognostik Tahminlerde Makine Öğrenme Modelleri Kullanmanın Zorlukları

Önceki bölümde belirtildiği üzere, prognostiklerin amacı, bir sistemin veya bileşenlerin öngörülen işlevini artık yerine getiremeyeceği süreyi, yani kalan ömür süresini (RUL) tahmin etmektir. Bu tahmin, makine öğrenmesi kullanıldığında bir regresyon şemasına uyar. Ancak, PHM toplulukları içerisinde hâlâ tartışılmakta olan birçok zorluk bulunmaktadır. Bu zorluklar, fiziksel süreçlerin karmaşıklığından, mevcut verilerden ve PHM'nin pratik çözümler için gereksinimlerinden kaynaklanmaktadır. Bu zorlukların bazıları, PHM alanında makine öğrenmesinin kullanımıyla doğrudan ilişkilidir. Literatür incelendiğinde bu zorluklar üç ana başlık altında değerlendirildiği gözlenmiştir: 1) Veri zorlukları, 2) Belirsizlik ve 3) Modellerin eğitilmesindeki zorluklar. Bu bölümde bu zorlukları ele alacağız.

2.1.4.1. Veri Seti Zorlukları

Prognostik, bir sistemin arızaya ulaşma durumuna doğru gelecekteki evrimini tahmin etme ile ilgilidir. Bu, arıza olasılığının ve kalan ömür süresinin (RUL) tahmini temelinde, gelecekteki bozulma ve işlevsel özellikleri öngörmek için verilerin işlenmesini içerir. Prognostik sonuçlar, kalan ömür tahmininin kullanılarak operasyonel eylemler ve bakım müdahaleleri hakkında karar verilmesi ve bunların uygulanması amacıyla sağlık yönetiminde kullanılır.

Mevcut sensör verilerinde belirsizliklerin bulunduğunu belirtmek önemlidir. Örneğin, sensörlerden toplanan verilerdeki gürültü, çevresel etkileşimler ve bazı operasyonel hatalar gibi belirsizlikler, bozulma durumu tahminini etkiler. Bu durum, sağlık durumunun gelecekteki

evrimini kesin olarak tahmin etmeyi pratikte imkânsız hale getirir ve prognostiği etkileyen farklı belirsizlik kaynaklarını dikkate almak gereklidir[65].

Geleneksel arıza prognostik yöntemleri, sistemdeki tetikleyici olayların meydana gelmesiyle düzensiz zaman aralıklarında toplanan eksik ve gürültülü verilerle başa çıkma zorluğu ile karşı karşıyadır. Örneğin, büyük türbin birimlerinde yatakların bozulma ve arıza süreçlerini izlemek için sinyal ölçümlerinin toplanması (örneğin titreşim sinyalleri) yalnızca birimlerin anormal davranışları, örneğin büyük gürültü ve anormal titreşim davranışı ile tetiklenir. Bu "anlık gürültü" veri setleri, genellikle veri tabanlarını depolama ve yönetme maliyetlerini azaltma ve enerji tüketimini ve bant genişliği kaynaklarını azaltma gerekliliği tarafından yönlendirilen endüstriyel uygulamalarda karşılaşırlar[25].

Arıza olayları nadir olay tabanlı veri setleri olduğundan, bu veri setleri sıklıkla eksik ölçümlerle karakterize edilir; bu durumda tüm sinyallerin değerleri genellikle aynı anda eksiktir. Bu özelliklerle birlikte, vaka silme, yerine koyma ve maksimum olabilirlik tahmini gibi eksik veri yönetimi için geleneksel yöntemler uygulanması zor hale gelir. Örneğin, vaka silme yöntemleri, bilgileri eksik olan desenleri çıkarır; bu, tüm sinyaller için desenin ya mevcut ya da yok olduğu olay tabanlı veri setleri için kullanışlı değildir. Yerine koyma teknikleri, bir sinyalin eksik değerinin, sinyalin ortalama değeri veya çok değişkenli regresyon modeli tarafından tahmin edilen bir değer gibi, veriyi üreten olasılık dağılımının istatistiksel bir göstergesi ile değiştirilebileceği fikrine dayanır[65]. Ancak, veri setinde büyük oranda eksik değer olduğunda bu yöntemler doğru sonuçlar vermez[66]. Olasılık yöntemleri, örnek veriyi üretmede olasılığı en yüksek olan dağılım aracılığıyla parametrelerinin değerlerini belirlemek için kullanılır.

Eksik veriler ile arıza prognostiklerini ele alan az sayıda araştırma bulunmaktadır. Eksik verilerle sistemlerinin arıza teşhisi ve prognostikleri için Auto-Regressive Moving Average (ARMA) ve Auto-Associative Neural Networks (AANN) tabanlı bir model geliştirilmiştir[66]. Eksik verilerle batarya verilerinin prognostikleri için Entegre Extreme Learning Machine (ELM) tabanlı bir yerine koyma-tahmin şeması ve dönen makineler prognostik uygulamasında eksik verilerle başa çıkmak için fiziksel ve veri odaklı yaklaşımların hibrit bir mimarisi önerilmiştir[67]. Tıp alanında, prognostik modeller geliştirmek için eksik verileri oluşturmak amacıyla Bayes simülatörü kullanılmış ve eksik kovaryant verilerin varlığında yumurtalık kanserinin genel sağkalımını değerlendirmek için birden fazla yerine koyma yaklaşımı bir

prognostik modele entegre edilmiştir. Bu yöntemlerin tümü, eksik veri yeniden yapılandırma ve tahminin iki ardışık adımına dayanır[68].

Teknolojideki gelişmeler ve yeni yöntemler, yalnızca tetikleyici olayların meydana geldiği durumlarda toplanan ölçümlere dayalı olarak kalan ömür süresini (RUL) tahmin etmeyi ve RUL tahminini etkileyen belirsizliğin bir tahminini sağlamayı mümkün kılmak için hala gereklidir. Örneğin, M. Xu ve diğerleri, eksik verileri yeniden yapılandırmaya gerek kalmadan doğrudan RUL'u tahmin etmek için Echo-State Networks (ESNs) tabanlı bir yöntem geliştirmiştir[69]. ESN'ler, giriş geçmişi hakkında bilgi koruma yetenekleri nedeniyle deneylerde kullanılmıştır. Ana zorluk, ESN'lerin tipik uygulamalarının aksine, verilerin kullanıma sunulduğu zaman aralıklarının düzensiz olmasıdır. Olay tabanlı veri toplama ile başa çıkmak için iki farklı strateji düşünülmüştür. Bir stratejide, ESN, bir olay meydana geldiğinde bir giriş deseni alır. Desen, ölçülen sinyaller ve olayın meydana geldiği zaman ile oluşturulur. İkinci stratejide, rezervuar durumları her zaman adımında uyarılır. Bir olay meydana gelmişse, rezervuar durumları hem önceki rezervuar durumları hem de ölçülen sinyaller tarafından uyarılır; bir olay meydana gelmemişse, yalnızca önceki rezervuar durumları tarafından uyarılır. Bu şekilde, rezervuardaki bağlantı döngüleri, olayların meydana gelmediği zaman adımlarında dinamik bozulma davranışını yeniden yapılandırmaya olanak tanır. Self-adaptive Differential Evolution with Neighborhood Search (SaNSDE) tabanlı Multi-Objective Differential Evolution (MODE) algoritması, ESN hiper-parametrelerini optimize etmek için kullanılır[70]. Elde edilen Pareto çözümlerinden en uygun çözümü seçmek için Technic for Order of Preference by Similarity to Ideal Solution (TOPSIS) kullanılır [71]. Ayrıca, bootstrap toplama (Bagging) yöntemi [72], RUL tahmin doğruluğunu artırmak ve RUL tahmin belirsizliğini tahmin etmek için uygulanır. ESN'lerin rastgele desen dizileri ile beslenememesi nedeniyle, bootstrap eğitim setlerini oluşturmak için kullanılan geleneksel Bagging örnekleme mekanizması değiştirilmiştir[72]. Önerilen çözümde, bootstrap eğitim setleri, yedeklemeyle rastgele örneklenmiş tüm arıza sürecini kapsayan yörüngelerin birleştirilmesiyle elde edilir. Önerilen yöntemlerin faydaları, bir türbin ünitesinin kaymalı yatağının RUL tahminine uygulanarak gösterilmiştir.

2.1.4.2. Belirsizlik

Belirsizlik, algılama, teşhis ve prognostiklerin PHM görevlerinde doğası gereği mevcuttur ve bu belirsizlikler, bu sistemlerin durumunun değerlendirilmesi ve davranışlarının tahmin edilmesi üzerinde olumsuz etkiler yaratarak, yanlış bilgilendirilmiş sistem sağlık yönetimi kararlarına ve dolayısıyla maliyetli, hatta felaketle sonuçlanabilecek sonuçlara yol açabilir[73].

Pratik uygulamalarda, mühendislik sistemlerinin işletimine ilişkin PHM karar alma sürecine bağlı riskin ölçülmesi için algılama, teşhis ve prognostik faaliyetlerinin sonuçlarındaki belirsizliğin ve bu sonuçlara olan güvenin tahmin edilmesi gereklidir[74]. PHM'de belirsizliğin önemi tanınmasına rağmen, belirsizliğin farklı PHM görevleri üzerindeki etkisini somut bir şekilde ele almak ve bu belirsizliği etkin bir şekilde yönetmek için hala çalışmalar yapılması gerekmektedir[75]. PHM görevlerinin kendisinden kaynaklanan anormalliklerin yanı sıra, önceki bölümde belirtildiği gibi toplanan verilerden kaynaklanan belirsizlikler de mevcuttur[76].

Zorluk, PHM'yi etkileyen farklı belirsizlik kaynaklarının mevcut olmasından kaynaklanmaktadır. Bu kaynakların etkileşimleri tam olarak anlaşılamamış olup, dolayısıyla PHM görevlerinde sistematik olarak hesaba katılmaları zordur[77]. Bazı kaynaklar içsel, bazıları ise dışsaldır ve tüm bu kaynaklar PHM'nin farklı faaliyetlerinde dikkate alınmalıdır. Bir sistemin fiziksel davranışında belirsizlik ve sensör verilerine dayalı olarak geliştirilen modellerde ve ilgili parametrelerde epistemik belirsizlik vardır. Daha önce belirtildiği gibi, sensör ölçümlerinde ve bunların işleme araçlarında belirsizlik bulunmaktadır. Prognostik görevinde ise, gelecekteki sistemin işletim profili ve durum evrimi üzerinde de belirsizlik söz konusudur[78].

PHM görevlerinde belirsizliğin önemi göz önüne alındığında, pratik uygulamalarda bu belirsizliği hesaba katmak için sistematik çerçeveler geliştirmek, karar verme süreçleri için geliştirilen çözümlerin sağlam doğrulama ve geçerliliğini sağlamak açısından gereklidir. Bu çerçeveler, farklı belirsizlik kaynaklarının sistematik olarak tanımlanmasını, temsil edilmesini, nicelleştirilmesini ve yayılmasını sağlamalıdır. Dolayısıyla, herhangi bir PHM sonucuyla birlikte belirsizlik de sağlanmalı ve bu belirsizlik, sağlam karar verme süreçlerinde dikkate alınmalıdır.

2.1.4.3. Modelleri Eğitmenin Zorluğu

Makine öğrenme yaklaşımları PHM uygulamalarında mükemmel bir şekilde uyabilse de mevcut prognostik çalışmalarda makine öğrenmesi yöntemlerinin uygulanmasını zorlaştırabilecek birkaç potansiyel sorun bulunmaktadır. Literatürde şimdiye kadar ele alınan en önemli sorun, derin ağı eğitilmesinin karmaşıklığıdır. Yaygın olarak bilindiği üzere, ağı eğitilmesinin amacı, ağı desen verilerini yakalaması ve tahmin görevini etkili bir şekilde yerine getirebilmesi için öğrenme davranışını sağlamaktır. Sığ ağı, derin ağa kıyasla daha kolay eğitilebildiği bulunmuştur. Çoğu durumda, derin ağ, basit eğitim şemasıyla verilerin


desenini öğrenemez veya tanıyamazken, aynı görev sığ ağa verildiğinde öğrenme gerçekleştirebilir. Bu sorunu çözmek için, derin ağ ile tahmin modeli oluşturmada önce bir ek adımın gerçekleştirilmesi gerekebileceği önerilmiştir. Literatürde "denetimsiz ön eğitim" olarak adlandırılan bu adım, gerçek model eğitim aşamasından önce, hedef değişken kullanılmadan eğitim verilerini eğitme (veya ön eğitim yapma) yöntemidir. Bu, derin mimari ağın uyarlanabilir bir şekilde öğrenebilmesini ve tahmin görevini etkili bir şekilde gerçekleştirebilmesini sağlamak içindir. Ayrıca, ön eğitim sürecinin derin öğrenme mimarisinin dayanıklılığını ve performansını, özellikle ağın derinliğini artırırken, iyileştirebileceği düşünülmektedir. Literatürdeki sonuçlar, ağın derinliğinin artmasının, zayıf yerel minimumlar bulma olasılığını da artırdığını göstermektedir. Ön eğitim adımı, bu sorunu çözebilir ve derin ağ için tutarlı bir şekilde daha iyi genelleme sağlar. Daha iyi genellemenin, tahmin görevinin bazı yeni girdi özniteliklerinin, eğitim verileri aralığında olmaması durumunda da yardımcı olacağına inanılmaktadır; bu, önceki bölümde de belirtildiği gibi PHM verilerinde yaygın olarak karşılaşılan bir sorundur.

Makine öğrenme algoritmaları kullanıldığında karşılaşılan bir diğer sorun ise tahmin sonuçlarının istikrarsızlığıdır. Bu durum, tahmin sonucunun geniş bir dağılım aralığına sahip olduğunda gözlemlenebilir. Tahmin sonuçlarının bu istikrarsız davranışının, derin katman modeli oluşturulduğunda başlangıçtaki rastgelelikten kaynaklandığı düşünülmektedir. Deney sonuçlarında, derin mimariye eklenen katman sayısı arttıkça daha istikrarsız sonuçların ortaya çıkabileceği gösterilmiştir. Bu nedenle, makine öğrenme kullanan çalışmaların çoğu, genellikle nihai çıktı dağılımından ortalama sonuçları veya en iyi sonucu rapor eder. Bu durum derin öğrenme modelinin değerlendirilmesini veya diğer veri madenciliği algoritmalarıyla karşılaştırılmasını zorlaştırır. Başka bir deyişle, bunu bölüm 2.1.4.2' de bahsedilen modellemede "Belirsizlik" lerden biri olarak değerlendirilebilir.

Algoritma istikrarını artırmak için istikrar eğitimi yaklaşımını uygulamak faydalı olabilmektedir[79]. Ancak, bu ek öğrenme adımı, PHM alanında tercih edilmeyebilir. Derin öğrenme modelindeki bazı sorunları çözmek için, modelleme çerçevesine yeni adımlar eklenmelidir. Bu sebeple eğitim özniteliklerinin veya modelleme parametrelerinin belirsizliklerinin nicelendirilmesi, çalışmanın başlangıç noktası olabilir.

2.1.5. Makine Öğrenmesine Dayalı Önerilen Prognostik Yaklaşım

Bu tez çalışmasının ana amacı prognostik alanında makine öğrenmenin kullanımı için genel ve evrensel bir çerçevenin tanıtılması ve gelecekte prognostik veriler için bir makine öğrenme modeli oluşturmak üzere düzenli bir prosedürün oluşturulmasıdır. Bu kapsamda önerilen prognostik yaklaşım Şekil 2.6'da gösterilmektedir. Bu çerçevede, ön işleme, özellik mühendisliği ve ön eğitim adımları vurgulanmıştır. Makine öğrenmesi tabanlı prognostik tahminlerde tüm belirtilen sorunların ele alınması için daha fazla çalışma yapılması ve yeni adımların eklenmesi gerekmektedir.



Şekil 2.6: Makine öğrenme algoritmaları için önerilen prognostik çerçeve

2.2. LİTYUM BATARYALAR

Lityum iyon (Li-ion) bataryalar, enerji depolama teknolojisinde devrim yaratarak taşınabilir elektronik cihazlardan elektrikli araçlara kadar geniş bir yelpazede kullanım alanı bulmuşlardır[80]. İlk kez 1970'lerde geliştirilmiş olan bu bataryalar, 1991 yılında Sony ve Asahi Kasei tarafından ticari olarak piyasaya sürülmüştür[81]. Bu tarihten itibaren, lityum iyon bataryalar, enerji yoğunluğu, uzun ömür, düşük kendi kendine deşarj ve hafiflik gibi üstün özellikleri sayesinde hızla popülerlik kazanmıştır[82].

Lityum İyon Bataryaların Avantajları

Lityum iyon bataryaların birçok avantajı bulunmaktadır:

- **Yüksek Enerji Yoğunluğu:** Lityum iyon bataryalar, diğer batarya türlerine kıyasla daha yüksek enerji yoğunluğuna sahiptir. Bu, daha fazla enerji depolayarak cihazların daha uzun süre çalışmasını sağlar[83].
- **Uzun Döngü Ömrü:** Bu bataryalar, yüzlerce şarj-deşarj döngüsünden sonra bile kapasitesinin büyük bir kısmını korur, bu da onları uzun ömürlü kılar [83].
- **Düşük Kendi Kendine Deşarj:** Lityum iyon bataryaların kendi kendine deşarj oranı düşüktür, bu da onları uzun süre kullanılmadan saklamayı mümkün kılar[83].
- **Hafiflik:** Lityum iyon bataryalar, enerji yoğunluğu yüksek olduğu için daha hafif ve taşınabilir cihazlar için idealdir[83].
- **Geniş Çalışma Sıcaklık Aralığı:** Bu bataryalar, geniş bir sıcaklık aralığında verimli bir şekilde çalışabilir[83].

Lityum İyon Bataryaların Dezavantajları

Bununla birlikte, lityum iyon bataryaların bazı dezavantajları da vardır:

- **Yüksek Maliyet:** Lityum iyon bataryaların üretim maliyeti, diğer batarya türlerine göre daha yüksektir[83].
- **Güvenlik Riskleri:** Aşırı şarj, kısa devre veya fiziksel hasar durumunda lityum iyon bataryalar yanabilir veya patlayabilir[83].

- Geri Dönüşüm Zorlukları: Lityum iyon bataryaların geri dönüşümü karmaşıktır ve çevresel olarak uygun yöntemlerin geliştirilmesi gerekmektedir[83].

Lityum İyon Hücre Tipleri

Lityum iyon bataryalar uygulamalar arasındaki ihtiyaçlara bağlı olarak farklı hücre geometrisinde üretilebilmektedirler. En yaygın hücre tipleri şunlardır:

- Silindirik Hücreler: Bu hücreler, genellikle 18650 ve 21700 gibi standart boyutlarda üretilir. Silindirik hücreler, yüksek enerji yoğunluğu ve mekanik sağlamlıkları nedeniyle taşınabilir elektronik cihazlar ve elektrikli araçlar gibi uygulamalarda yaygın olarak kullanılır[84].
- Prizmatik Hücreler: Dikdörtgen prizma şeklinde olan bu hücreler, daha yüksek enerji yoğunluğu sağlamak için genellikle büyük kapasitelerde üretilir. Prizmatik hücreler, otomotiv ve enerji depolama sistemlerinde kullanılır[84].
- Poşet Hücreler (Pouch Cells): Esnek ve hafif yapıları sayesinde, poşet hücreler çeşitli form faktörlerinde üretilebilir. Bu hücreler, genellikle mobil cihazlar, tabletler ve bazı elektrikli araçlarda kullanılır. Poşet hücrelerin tasarımı, yüksek enerji yoğunluğu sağlarken, mekanik olarak daha hassas olmaları bir dezavantaj olabilir[84].
- Düğme Hücreler: Küçük ve yuvarlak yapıları nedeniyle, bu hücreler genellikle düşük güç tüketen cihazlar, saatler, işitme cihazları ve bazı tıbbi cihazlar için kullanılır[84].

Sonuç olarak, lityum iyon bataryalar, yüksek enerji yoğunluğu, uzun ömür ve düşük kendi kendine deşarj oranı gibi avantajlarıyla modern enerji depolama çözümlerinin merkezinde yer almaktadır. Ancak maliyet, güvenlik ve geri dönüşüm zorlukları gibi dezavantajları da vardır.

2.2.1. Lityum Bataryaların Uygulama Alanları

Günümüzde ticari olarak temin edilebilen hemen hemen tüm Li-ion bataryalar, enerjiyi tersinir olarak depolamak için Li-interkalasyon reaksiyonlarından yararlanmaktadır[85]. Temel düzeyde, tek katmanlı bir Li-ion batarya, bir anot, bir katot, gözenekli bir ayırıcı ve Li-iyonlarının pozitif ve negatif elektrotlar arasında hareket ettiği sıvı bir elektrolitten oluşur. Elektrot malzemeleri, yükü dış devrelere aktarmak için kullanılan iki akım toplayıcıya bağlanır. Genellikle, katot malzemesi, alüminyumun ucuz ve yüksek katot voltaj penceresi boyunca


kararlı olması nedeniyle bir alüminyum akım toplayıcısına bağlanır. Ancak, genellikle grafitten oluşan anot malzemesi, daha düşük anot voltaj penceresinde kararlı olan ve korozyonu önleyen bakır bir akım toplayıcısına bağlanır[86]. Şarj sırasında, lityum iyonları katottan serbest bırakılır ve anotun içine girer. Deşarj sırasında ise lityum iyonları anottan ayrılarak katoda geri döner.

Günümüzde ticari olarak temin edilebilen Li-ion bataryalar genellikle katot malzemelerine göre adlandırılır. Popüler katot malzemeleri arasında lityum-demir-fosfat (LFP), nikel-mangan-kobalt-oksit (NMC), nikel-kobalt-alüminyum-oksit (NCA), lityum-kobalt-oksit (LCO) ve lityum-mangan-oksit (LMO) bulunmaktadır. Bataryalar genellikle katot malzemelerine göre adlandırılır çünkü yukarıda belirtilen katotlar neredeyse her zaman grafit anotlarla eşleştirilir. Katot malzemelerinin kimyasal bileşimlerinin yanı sıra, katot malzemeleri arasındaki en büyük fark, çalışma voltajları ve enerji/güç yoğunluklarıdır.

Enerji yoğunluğu genellikle watt-saat/kilogram (Wh/kg) cinsinden ölçülür ve bir hücrenin birim kütle başına ne kadar enerji depolayabileceğini yansıtır. Benzer şekilde, güç yoğunluğu watt/kilogram (W/kg) cinsinden ölçülür. Bu metrikler, kimyasal bileşimlerin kütle başına hızlı karşılaştırılması için kullanılır. Şekil 2.7, en yaygın Li-ion batarya kimyalarının yüksek düzeyde bir genel görünümünü göstermektedir. LFP kimyası, uzun ömrü nedeniyle popülerdir. NMC kimyası ise daha yüksek enerji yoğunluğu gerektiğinde otomotiv uygulamalarında yaygındır.

Tüketici ürünlerinde kullanılmak üzere bataryalar tasarlanırken, farklı batarya kimyaları arasındaki enerji ve güç yoğunluğu dengelerini dikkate alınır. Örneğin, LFP kimyası diğerlerine göre daha uzun ömür sergiler, ancak yaklaşık olarak yarısı kadar enerji yoğunluğuna sahiptir, bu da enerji ve güç açısından önemli bir denge gerektirir. Mühendisler genellikle tasarladıkları uygulamaya bağlı olarak batarya kimyalarını seçerler. Örneğin, giyilebilir saatler, gözlükler, kulaklıklar ve cep telefonları gibi küçük taşınabilir elektronik cihazlarda yüksek enerji yoğunluğu gereklidir. Bu tür cihazlarda kullanılan bataryalar genellikle en yüksek enerji yoğunluğuna sahip olan LCO veya NMC kimyasına sahiptir[87]. Yüksek enerji yoğunluklu bataryaların, özellikle LCO kimyasının, en büyük zorlukları güvenlik ve maliyettir. Küçük taşınabilir elektronik cihazlarda termal kaçak olaylarından kaynaklanan güvenlik endişesi daha azdır çünkü bataryaların toplam boyutu yaklaşık olarak sadece 12 Wh olup, bir termal kaçak olayında toplam enerji çıkışını sınırlamaktadır. Bu olaylar yine de tehlikeli olabilir, ancak

cihazlar genellikle tek hücreli olduğundan ve toplam enerji salınımı küçük olduğundan dolayı, yıkıcı bir olayın olasılığı düşüktür. LCO kimyasının malzeme maliyeti ise başka bir zorluktur. Küçük tek hücreli cihazlarda batarya, cihazın toplam maliyetinin önemli bir kısmını oluşturur, özellikle katotta kullanılan nadir toprak metali kobalt nedeniyle[88]. Pahalı tek hücreler küçük cihazlarda iyi çalışsa da bu hücreler genellikle daha büyük projelerde kullanılmaz.



Şekil 2.7: Farklı Li-ion pil kimyalarının güçlü ve zayıf yönlerine genel bakış [66].

Daha büyük kapasiteler (50 - 100 kWh) gerektiren uygulamalarda, örneğin elektrikli araçlarda (EV), batarya kimyası konusunda daha fazla seçenek bulunmaktadır. Günümüzde, NMC kimyası pazar payının büyük bir kısmını elinde tutmaktadır ve 2025 yılına kadar yollardaki yolcu araçlarının tahmini %41'inin NMC kimyası hücreleri kullanması beklenmektedir[89]. Ancak, son zamanlarda, otomotiv uygulamaları için daha güvenli ama daha az enerji yoğun olan LFP kimyasını kullanmaya yönelik sessiz ama belirgin bir itici güç vardır[89]. BMW, Chevrolet ve BYD gibi firmalar, LFP bataryalarını otomotiv uygulamalarında başarıyla ticarileştirmiştir[90]. LFP'nin yükselen kullanımının en büyük nedenlerinden biri, daha sürdürülebilir ve döngüsel bir batarya ekonomisine geçişin teşvik edilmesidir. LFP ile diğer popüler Li-ion batarya kimyaları arasındaki en belirgin fark, katotta nikel ve kobalt nadir toprak metallerinin olmamasıdır. Bu durum, hücre üreticilerinin hammadde temin etme ve tedarik

zincirlerini daha az istikrarlı ülkelere bağımlı olmadan güvence altına alma yeteneklerini önemli ölçüde artırmaktadır[90]. Ancak, daha ucuz olan LFP katot malzemesinin de bazı dezavantajları vardır. Özellikle, bu malzeme daha düşük voltaj aralıkları ile sınırlıdır ve genellikle 1.8V - 3.6V arasında çalışır, oysa NMC ve NCA kimyaları 2.8 - 4.2 V arasında çalışabilir[91]. LFP hücresinin daha düşük voltaj penceresi, NMC ve NCA (220 Wh/kg) kimyalarına kıyasla daha düşük (120 Wh/kg) enerji yoğunluğuna sahiptir[92]. Şekil 2.7, bu bölümde tartışılan çeşitli Li-ion batarya kimyalarının spesifik enerjilerini karşılaştırmaktadır. Önümüzdeki yıllarda, otomotiv üreticilerinin mevcut baskın NMC ve NCA hücrelerini LFP ve diğer daha sürdürülebilir ve daha düşük enerji yoğunluklu hücrelerle değiştirip değiştirmeyeceğine dair yeni trendler göreceğiz.

150 kWh'nin üzerindeki batarya kapasiteleri genellikle sadece sabit enerji depolama uygulamalarında görülmektedir[93]. Bu tür uygulamalarda, batarya sistemlerinin boyut sınırlamaları az veya hiç yoktur, bu da mühendislerin büyük ölçekli enerji depolama için çoklu paket ve çoklu kimya çözümleri tasarlamalarına olanak tanır. Enerji depolama sistemi tasarımı genellikle öngörülen yükler ve kullanım için optimal depolama kapasitesini, batarya kimyasını ve çalışma koşullarını öneren teknik-ekonomik analizlerle başlar. Ancak teknik ve ekonomik gereksinimleri karşılamak için belirtilen sistem ömrünün sağlanması gerekmektedir[94].

Bu nedenle, Li-ion bataryaların tasarımı ve seçimi, uygulama gereksinimlerine bağlı olarak dikkatlice yapılmalıdır. Batarya teknolojilerindeki bu çeşitlilik, farklı kullanım alanları için optimal performans ve uzun ömür sağlar.

2.2.2. Batarya Terminolojileri

- **Anot (Pozitif Elektrot):** Bataryanın şarj olurken lityum iyonlarının katottan buraya geçtiği elektrottur. Genellikle grafit gibi malzemelerden yapılır.
- **Katot (Negatif Elektrot):** Bataryanın şarj olurken lityum iyonlarının anoda geçtiği elektrottur. Genellikle lityum metal oksitlerden yapılır.
- **Elektrolit:** Lityum iyonlarının anot ve katot arasında hareket ettiği sıvı veya jel benzeri bir maddedir.
- **Ayırıcı (Separator):** Anot ve katot arasında yer alan ve kısa devreyi önleyen, ancak iyonların hareketine izin veren gözenekli bir malzemedir.

- **Döngü Ömrü (Cycle Life):** Bataryanın belirli bir kapasite kaybı yaşamadan tamamlayabileceği şarj ve deşarj döngülerinin sayısıdır.
- **Kapasite (Capacity):** Bataryanın depolayabileceği toplam enerji miktarıdır. Genellikle Amp-saat (mAh) veya watt-saat (Wh) cinsinden ölçülür.
- **Enerji Yoğunluğu (Energy Density):** Bataryanın birim kütle başına depolayabileceği enerji miktarıdır. Genellikle watt-saat/kilogram (Wh/kg) cinsinden ölçülür.
- **Güç Yoğunluğu (Power Density):** Bataryanın birim kütle başına verebileceği güç miktarıdır. Genellikle watt/kilogram (W/kg) cinsinden ölçülür.
- **İç Direnç (Internal Resistance):** Bataryanın içindeki elektrik akımına karşı gösterdiği dirençtir. Daha düşük iç direnç, daha yüksek verimlilik anlamına gelir.
- **Kendi Kendine Deşarj Oranı (SDR- Self Discharge Rate):** Bataryanın kullanılmadığında kendi kendine deşarj olma oranıdır enerjisini kaybetme oranıdır.
- **Döngü Verimliliği (Cycle Efficiency):** Bir tam şarj ve deşarj döngüsü sırasında bataryanın ne kadar enerjiyi geri verebildiğinin ölçüsüdür.
- **Nominal Gerilim (Nominal Voltage):** Bataryanın normal çalışma sırasında sağlayabileceği ortalama gerilimdir. Lityum-iyon bataryalar genellikle 3.7V nominal gerilime sahiptir.
- **Kritik Gerilim (Critical Voltage):** Bataryanın güvenli çalışması için izin verilen en yüksek ve en düşük gerilim seviyeleridir.
- **Dengesizlik (Imbalance):** Batarya hücreleri arasında voltaj veya kapasite farklılıklarıdır. Hücre dengeleme sistemleri ile düzeltilir.
- **Termal Kaçak (TR- Thermal Runaway):** Bataryanın aşırı ısınması ve kendiliğinden yanması durumudur. Güvenlik için önemli bir risk faktörüdür.
- **Derin Deşarj (DoD- Deep of Discharge):** Bir yük döngüsü sırasında batarya kapasitesinin ne kadarının boşaltıldığını gösteren yüzdelik orandır.

- **Şarj Durumu – (SoC- State of Charge):** Bataryanın mevcut şarj seviyesidir. Yüzde olarak ifade edilir.
- **Sağlık Durumu (SoH- State of Health):** Bataryanın genel durumu ve kapasitesinin orijinal kapasitesine göre ne kadarını koruduğunu gösterir.
- **Kalan faydalı ömür (RUL- Remaining Useful Life):** Bataryanın ne kadar süre daha verimli bir şekilde çalışabileceğinin tahminidir.
- **Balans (Balancing):** Batarya hücrelerinin eşitlenmesi işlemidir. Her hücrenin aynı voltaj ve kapasiteye sahip olmasını sağlar.
- **Katı Hal Bataryası (SSB- Solid-State Battery):** Sıvı elektrolit yerine katı bir elektrolit kullanan, daha güvenli ve enerji yoğunluğu yüksek batarya türüdür.
- **Başlangıç Ömrü (BoL- Beginning of Life):** Bataryanın üretildiği ve kullanıma başlandığı andan itibaren performansının en yüksek olduğu dönemdir.
- **Ömrün Sonu (EoL- End of Life):** Bataryanın ömrünün sonu, başlangıç ömründen sonra bataryanın belirtilen performans kriterlerine göre çalışmayı bıraktığı noktadır.
- **Güç Durumu (SoP- State of Power):** Bataryanın mevcut şarj seviyesinin zirve gücünün nominal gücüne oranıdır.
- **Açık Devre Gerilimi (OCV- Open Circuit Voltage):** Bir bataryanın uçları arasında hiçbir yük bağlı olmadığında (yani, batarya devreye bağlı olmadığında) ölçülen gerilimdir. OCV, bataryanın doluluk seviyesi hakkında bilgi verir ve bataryanın iç kimyasal durumunu yansıtır.
- **Aşırı Gerilim (OV- Over Voltage):** Bataryanın nominal gerilim seviyesinin üzerine çıkması durumudur. Bu durum, bataryanın güvenliğini ve ömrünü olumsuz etkileyebilir.
- **Aşırı Sıcaklık (OT- Over Temperature):** Bataryanın çalışma sıcaklığının güvenli sınırların üzerine çıkması durumudur. Bu durum, bataryanın kimyasal dengesini bozabilir ve güvenlik riskleri oluşturabilir.

- **Düşük Gerilim (UV- Under Voltage):** Bataryanın gerilim seviyesinin nominal değerin altına düşmesi durumudur. Bu, bataryanın performansını olumsuz etkileyebilir ve kullanım ömrünü kısaltabilir.
- **Aşırı Akım (OC-Over Current):** Bataryadan çekilen veya bataryaya verilen akımın nominal değerin üzerine çıkması durumudur. Bu, bataryanın ısınmasına ve potansiyel olarak zarar görmesine neden olabilir.
- **C Rate:** Bir bataryanın kapasitesinin ne kadar hızlı şarj edildiğini veya deşarj edildiğini belirten bir orandır. Örneğin, 1C oranında şarj edilen bir batarya, kapasitesinin tamamını bir saatte şarj eder. 2C oranında ise bu süre yarıya iner.

2.3. LİTYUM BATARYALARDA YAŞLANMA MEKANİZMALARI

Elektrikli araçlar ve güvenilir şebeke uygulamalarına olan artan ilgi, modern dünyada lityum-iyon pillerin önemini artırmaktadır. Lityum-iyon piller, kullanım sırasında gözlemlenen döngüsel yaşlanma ve dinlenme veya depolama sırasında meydana gelen takvim yaşlanması gibi iki ana mekanizma aracılığıyla sağlık durumlarında bozulmaya uğramaktadır. Bu pillerin güvenli ve etkin bir şekilde kullanılması, onların Sağlık Durumu (SoH) hakkında doğru bilgiye dayanmaktadır. Örneğin, aşırı şarj sonucunda oluşan aşırı ısınma, sonuçta termal kaçışa yol açabilecek fazla ısı üretir.

Pil sağlığının en yaygın ölçütlerinden biri olan kapasite, iç dirençle birlikte değerlendirilmektedir. Kapasitenin azalması ve iç direncin artması, bozulmanın temel göstergeleri olarak kabul edilir ve bu göstergeler çeşitli olası bozulma mekanizmalarıyla ilişkilendirilmiştir[95]. Bozulma mekanizmalarının çeşitliliği, iç ve dış birçok farklı faktörle bağlantılıdır. Üretim sırasındaki değişkenlikler, yani aynı kimyaya, forma, modele ve hatta partiye ait hücrelerin bile farklı başlangıç kapasitelerine sahip olması ve zamanla bağlantısız oranlarda yaşlanması, durumu daha da karmaşık hale getirmektedir[95].


Lityum bataryalarda yaşlanma (SoH) veya bozulmasının tanımlanması veya tespit edilebilmesi güvenlik açısından da önemli bir gerekliliktir. Bugüne kadar birçok batarya yangını haberlere konu olmuştur. Samsung Galaxy Note 7'den [96], henüz sevkiyat halindeki Tesla araçların tır üstünde yanmasına kadar[97] batarya yangınları yaygındır ve birçok nedenle meydana gelebilir.

Bu nedenle, bu daha yıkıcı olayları tetikleyebilecek hücre yaşlanma koşullarını anlamak ve modellemek son derece önemlidir.

Lityum bataryaların bozulma mekanizmaları genel olarak 4 seviyede incelenebilmektedir (Şekil 2.8). İlk seviyede, bir hücrenin yaşlanması, döngü kapasitesinin ve güç yeteneğinin azalması (artmış direnç) olarak gözlemlenebilir. Geleneksel SoH tahmin yöntemleri, genellikle standart döngü yaşlanma testleri sırasında kapasite ve güç değişikliklerinin doğrudan ölçülebilmesi nedeniyle, SoH'yi Seviye 1'de tahmin etmeye odaklanır. Seviye 2, kapasite ve güç bozulmasına katkıda bulunan üç ana bozulma modunu içerir. Bu üç mod, LAM_{PE} , LAM_{NE} ve LLI, bir hücreden doğrudan ölçümle nicelenemez. Bozulma modlarını nicelendirmek için daha ileri analizler, örneğin yarım hücre eğrisi analizi ve otopsi analizi gereklidir. Yapılan literatür incelemeleri sonucunda [98], [99], [100], [101], [102], [103] SoH tahmin yöntemleri, hem hücre kapasitesini (Seviye 1) hem de üç bozulma modunun durumunu (Seviye 2) tahmin edilebileceği tespit edilmiştir. Seviye 3, bozulma modlarına yol açan farklı istenmeyen kimyasal ve fiziksel süreçleri içerir. Bu kimyasal süreçler, operasyon süresi, sıcaklık, şarj vedeşarj akımı ve kesme voltajı gibi farklı stres faktörleri (Seviye 4) tarafından tetiklenir veya hızlandırılır.


Bir Li-ion hücresinin bozulma süreci, kullanım şekline ve çevresine büyük ölçüde bağlıdır. Örneğin, yüksek sıcaklıklarda çalışan bir hücre, oda sıcaklığında olduğundan daha hızlı elektrolit bozunması yaşayabilir. Yüksek sıcaklığı uzun çalışma süreleriyle birleştirdiğinizde, hücrenin kullanılabilir lityum envanterinde önemli bir kayıp yaşanması muhtemeldir. Bu lityum envanteri kaybı, hücrenin kullanılabilir kapasitesinde bir azalmaya neden olacaktır. LLI bozulma modu, lityum plakalanması ve SEI büyümesi gibi lityum iyonlarının tüketilmesine yol açan mekanizmaları içerir[104]. Bu mekanizmalar lityum iyonlarını tüketir ve bu iyonlar artık elektrotlar arasında döngü için kullanılamaz hale gelir, sonuç olarak kapasite kaybına yol açar.

Şekil 2.8'te gösterildiği gibi, LAM_{PE} ve LAM_{NE} bozulma modları, partikül çatlaması ve elektriksel temas kaybı gibi elektrot bozulma mekanizmalarını tanımlar. Bu mekanizmalar, artık lityum girişine açık olmayan küçük ölü aktif malzeme bölgeleri yaratır. Hem pozitif hem de negatif elektrotlarda aktif malzeme kaybı, hücre kapasitesinin ve gücünün azalmasına neden olur. Genel olarak, bir hücrenin ömrü boyunca üç bozulma mekanizmasının durumunu anlamlandırabilmek, hücre sağlığı hakkında çok daha zengin bilgi sağlayabilir ve bu da hücre geliştirme, ikinci yaşam kullanımı ve önleyici bakım teknolojilerini daha da iyileştirebilir.



Şekil 2.8: Hücre kullanımı/çevre (Seviye 4), karşılık gelen bozunma mekanizmaları (Seviye 3), bunların bozunma modlarına bağlantıları (Seviye 2) ve sonuçta ortaya çıkan kapasite/güç azalması (Seviye 1) arasındaki ilişkiyi gösteren basitleştirilmiş ağaç diyagramı [103].

Hücre yaşlanma mekanizmalarını tespit etmek her ne kadar karmaşık olmasına rağmen, çoğu kapasite azalma profili, Şekil 2.9a'da gösterildiği gibi, iki veya üç aşamaya ayrılabilir. İlk aşamada, erken kapasitede hızlı bir değişiklik gözlemlenebilir. Bazı laboratuvar hücrelerinde kısa vadeli artışlar görülse de kapasite katı elektrolit arayüzey büyümesi nedeniyle hızla azalabilir. Bu ilk aşama genellikle kısa sürer ve daha yavaş bir yaşlanma süreci takip eder. Bu sürecin, genellikle zaman ve kapasite kaybı arasında bir karekök bağımlılığı oluşturan katı elektrolit arayüzeyinin gelişimiyle ilişkili olduğu düşünülmektedir.



Şekil 2.9: Örnek lityum-iyon pil sağlık profilleri. Çoğu profil küçük sayıda aşamaya ayrılabilir (a) ve birçok profil sadece doğrusal yaşlanmayı sergiler (b). Zorlu kullanım protokolleri, kapasitede bir çöküşe yol açabilir, bu da diz noktası olarak bilinir (c)[105]

Şekil 2.9b'de gösterildiği gibi, tekrarlı kullanım döngüleri sırasında, hücreler yaklaşık olarak sabit bozulma oranları sergileyebilir. Takvim yaşlanmasına maruz kalan hücreler, uzun süreler boyunca düşük ve sabit bir yaşlanma deneyimler. Bu bozulma oranı sıcaklık ve şarj durumu tarafından belirlenir ve kapasiteleri genellikle basit matematiksel işlevlerle modellenebilir.

Zorlu kullanım koşullarında, Şekil 2.9c'de görülen gibi, hücrelerde felaket sonuçlara yol açabilecek kapasite kayıpları yaşanabilir. Bu durum genellikle "diz noktası" olarak adlandırılır ve hızlandırılmış yaşlanma süreci, sıklıkla lityum kaplama ile ilişkilendirilir. Ayrıca, bazen gözenek tıkanıklığı ve düzensiz sıkıştırma gibi diğer bozulma mekanizmalarına da bağlanabilir. Diz noktasının başlangıcını tahmin etmek zor olsa da bu, herhangi bir pil sisteminin güvenliği için hayati öneme sahiptir.

Altta yatan süreçlerin doğal karmaşıklığına rağmen, bu basit profiller, lityum-iyon pil yaşlanmasının başarılı bir şekilde modellenebileceği umudunu vermektedir. Bu tez, pil sağlığı ve yaşlanma süreçlerinin daha iyi anlaşılmasını hedefleyerek, bu alandaki karmaşık sorunlara çözümler sunmayı amaçlamaktadır.

2.3.1. Pil Degradasyonunu Etkileyen İç (Hücresel) Faktörler

2.3.1.1. Katı Elektrolit Ara Yüzeyi (SEI) Tabakası Oluşumu

SEI tabakasının elektrot-elektrolit ara yüzeyinde oluşumu ilk olarak 1979'da tanıtılmıştır[106]. Elektrolit çözücüler (interkale olmuş lityum) ve lityum tuzu (elektrolit), aktif elektrot yüzeyinde pasif bir tabaka (dekompoze olmuş elektrolit ürünleri) oluşturur ve bu tabaka, ardışık şarj ve deşarj döngüleri ile genişler. Bu tabaka, lityum iyonlarının elektrot ve elektrolit arasında taşınmasına izin verir ve sürekli elektrolit parçalanmasını önleyerek elektron tünellemesini kısıtlar. SEI tabakası ayrıca anot korozyonuna karşı koruma sağlar ve döngü sırasında elektrolit azalmasını engelleyerek bataryanın kimyasal ve elektrokimyasal stabilitesini korur.

SEI tabakasının avantajlarına rağmen, tabaka oluşumu sırasında aktif lityum ve elektrolit malzemeleri tüketilir ve iç direnç artar, bu da kapasite kaybına ve düşük güç yoğunluğuna neden olan faktörlerdir. SEI tabakası, bataryanın ilk şarj-deşarj döngüleri sırasında anotta (karbon elektrotlar) oluşur ve bu, grafit elektrotların (anot olarak en yaygın tercih) ana yaşlanma faktörlerinden biridir[107]. Anot malzemelerinin redüksiyon reaksiyonları ve önemli hacim genişlemesi, SEI'nin katot üzerindeki daha dengesiz olmasına neden olur [108].

Yıllar boyunca, anot SEI filmleri üzerine kapsamlı çalışmalar literatürde rapor edilmiştir. SEI'nin karmaşık yapısı, elektrot yüzeyine yakın elektrolit redüksiyon reaksiyonları ve yapısal-özellik ilişkileri, SEI tabakasının modellenmesinde önemli bir rol oynar. Bu faktörler, modelleme sürecini karmaşık hale getirir ve deneme-yanılma tabanlı yaklaşımlara yol açar [108]. [106]'de, SEI'yi modelleme yönünde ilk girişim yapılmıştır. SEI tabakası boyunca elektron sızıntısı, SEI büyümesi için bir kısıtlama olarak kabul edilir. Bir SEI tabaka büyüme modeli [106] tarafından verilmiştir:

$$\frac{dL}{dt_{storage}} \equiv \frac{\bar{K}V_{OC}}{\rho_e L} \quad (2.11)$$

Burada, L SEI tabakasının kalınlığı/büyümesi, $t_{storage}$ depolama süresi, $\bar{K}$ sabit, V_{OC} açık devre gerilimi ve ρ_e SEI'nin elektronik direncidir. SEI, bataryanın ilk şarj-deşarj döngüsü sırasında oluştuğundan, katı fazlardaki lityumun kütle taşınımını tanımlayan model denklemlerini de dikkate almak gereklidir. Aktif katı bir partiküldeki lityum iyonlarının difüzyonu, genel olarak Fick'in yasası kullanılarak ifade edilir [109]:


$$\frac{\partial C_{\bar{k}}}{\partial t} = D_{\bar{k}} \left(\frac{\partial^2 C_{\bar{k}}}{\partial z^2} + \frac{2}{z} \frac{\partial C_{\bar{k}}}{\partial z} \right) \quad (2.12)$$

Burada, $\bar{k}$ türün konsantrasyonu $C_{\bar{k}}$, $D_{\bar{k}}$ SEI fazındaki çözücünün difüzyon katsayısı, z anoda dik olan koordinat yönü ve t zaman değişkenidir. SEI tabakası boyunca çözücü difüzyonunun bir boyutlu modeli [110]'de benimsenmiştir. Film büyüme hızı, direnç ve geri dönüşümsüz kapasite kaybı (ICL), hem lityum iyonlarının hem de elektronların SEI içinden taşınımını dikkate alarak basitleştirilmiş seyreltilmiş çözüm teorisi kullanılarak tahmin edilmiştir. [109]'deki malzeme denge denklemi, değişken film kalınlığını ($L(t)$) hesaba katacak şekilde [110]'de değiştirilmiştir:

$$\frac{\partial C_{\bar{k}}}{\partial t} + \left(\frac{\partial L}{\partial t} \right) \left(\frac{\partial C_{\bar{k}}}{\partial \xi} \right) \left(\frac{1}{L(t)} \right) + \frac{1}{L(t)} \frac{\partial N_{\bar{k}}}{\partial \xi} - \sum_l s_{kl} R_l = 0 \quad (2.13)$$

Burada, $\frac{\partial L}{\partial t}$ film büyüme hızı, $N_{\bar{k}}$ molar akı, R_l filmdeki homojen reaksiyon hızı, $s_{\bar{k}l}$ reaksiyondaki türlerin stokiyometrik katsayısı ve ξ filmin elektriksel geçirgenliğidir. Eğer film büyüme hızı $\frac{\partial L}{\partial t}$ yavaşsa, (2.13)'teki ikinci terim ihmal edilebilir ve (2.12) yalnızca katı difüzyona sınırlı çözüm türlerinin taşınımını tanımlamak için geri kazanılır[109]. Benzer bir boyutlu model, çözücü difüzyonu ve SEI oluşumlarının kinetiklerini dikkate alarak [111]'te geliştirilmiştir.

Yukarıda tartışılan SEI tabakası oluşum sürecine odaklanan modeller, LIB'nin farklı çalışma koşullarında döngü davranışını tahmin etmede yetersiz kalmaktadır. Taşınım süreçlerini (yük dengesi, kütle dengesi, enerji dengesi) elementer reaksiyon tabanlı SEI büyümesiyle birleştiren çok fiziksel sahte 2D (P2D SEI tabakası modeli, [111]'te geliştirilmiştir. Burada, pasif film kalınlığını belirleyen difüzyon hızı şu şekilde verilmiştir:



Şekil 2.10: Lityum-iyon hücrelerde iç bozunma mekanizmaları[112].

$$L(t) = 2\lambda\sqrt{D_s^0 e^{\frac{-E_a}{R_g T}} t} \quad (2.14)$$

Burada, D_s^0 Arrhenius difüzyon sabiti, E_a aktivasyon enerjisi, R_g evrensel gaz sabiti, T sıcaklık ve λ SEI'deki lityum iyon konsantrasyonudur. 1-D modelin aksine, katı faz içindeki lityum konsantrasyonu her düğüm noktasında (j) radyal koordinat boyunca çözülür [113].

$$\frac{\partial C_{\bar{k},j}}{\partial t} = \left(\frac{D_{\bar{k}}}{z^2}\right) \left(\frac{1}{L(t)} \frac{\partial}{\partial z} \left(z^2 \frac{\partial C_{\bar{k},j}}{\partial z}\right)\right) \quad (2.15)$$

Önerilen çok ölçekli ve çok fiziksel modeller, difüzyon, sıcaklık ve kinetiğin SEI büyümesi üzerindeki etkilerini ortaya koymaktadır [114]. P2D modelinin en büyük sınırlaması, bağlanmış doğrusal olmayan kısmi diferansiyel denklemler ve yüksek hesaplama karmaşıklığıdır. Bu sınırlamayı aşmak için, [115] çalışmasında bir SP modeli tanıtılmıştır. Elektrotlar, gözenekli elektrottaki katı fazın aktif alanına eşdeğer yüzey alanına sahip tek bir küresel parçacık ile temsil edilir. Bu model, bir toplu parametre yaklaşımını dikkate alır ve (2.15)'i birinci dereceden kısmi diferansiyel denkleme indirger [115].

$$\frac{\partial C_{\bar{k},j}}{\partial t} + \frac{15D_{\bar{k},j}}{R_j^2} (C_{\bar{k},j} - \bar{C}_{1,j}) = 0 \quad (2.16)$$

Bu denklemde, $\bar{C}_1$, j kürenin yüzey konsantrasyonu ve R_j elektrodu oluşturan parçacıkların ortalama yarıçapıdır. Ayrıca, denklem (2.16) mekânsal değişken z 'ye olan bağımlılığı ortadan kaldırır. [116] çalışmasında, SEI tabakası modellemesinde sıcaklığı dahil etmek amacıyla termal dinamiklerle birleşik SP elektro-kimyasal model geliştirilmiştir. Bu birleşik model, düşük sıcaklıklarda kapasite kaybı, sıfırın altındaki sıcaklıklarda performans düşüşü ve yüksek sıcaklıklarda termal kaçak gibi güncel teknolojik zorlukların kontrolü hakkında bilgi sağlamak için kullanılabilir. Ayrıca, SEI büyüme hızı, elektron tünelleme modellemesi ile belirlenmiş ve [114] çalışmasında sunulmuştur.

Çift katmanlı SEI, farklı elektrolit ayrışma reaksiyonlarından kaynaklanır. Çift katmanlı SEI'ler üzerine yapılan çalışmalar, ikinci bir SEI oluşum reaksiyonunun eklenmesiyle elde edilmiştir. SEI'nin iki katmanı, kimya ve morfoloji açısından farklılık gösterir ve eşzamanlı olarak büyür. Her bir SEI katmanının analizi, SEI kalınlığındaki dalgalanmalar ve katı SEI fazındaki hız sınırlayıcı taşıma mekanizması ile ilgili bilgi sağlar. Tek katmanlı SEI'lerin aksine, çift katmanlı SEI oluşumları iki taşıma mekanizmasını dikkate alır: çözücü difüzyonu ve yük taşınımıdır. Bu

tür çift katmanlı yapıların davranışını ortaya koyan çalışmalar literatürde tartışılmıştır [117]. Yaşlanmaya bağlı süreçlerin model bazlı çalışmasında SEI-elektrolit ve parçacık-SEI arayüzünde bir çift katman dahil edilmiştir[116]. Fiziko-kimyasal SP modeli, SEI'yi içeren yeni bir yaşlanma modeli eklenerek genişletilmiştir ve bu model, LIB'nin bozulmasını analiz etmek için kullanılmıştır. SEI'nin başlangıç kalınlığı (L_0) şu şekilde temsil edilir [117]:

$$L_0 = \frac{V_{SEI} R_a}{3 \varepsilon_{s,a} A_{cell} d_a} \quad (2.17)$$

Burada $\varepsilon_{s,a}$ anot katı faz hacim fraksiyonu, R_a anot parçacık yarıçapı, d_a anot kalınlığı, A_{cell} hücre alanıdır.

Yukarıda tartışılan SEI tabaka modellemesi, LIB'lerin Sağlık Durumunu (SOH) belirlemede önemli bir rol oynamaktadır. Ancak, SEI Li-iyonlarına geçirgendir. Bu nedenle, pilin şarj ve deşarjı sırasında, anotun hacim genişlemeleri ve daralmaları nedeniyle büyük stresler oluşur. Ayrıca, döngü sırasında, SEI'den geçtikten sonra çözücü ile grafit arasındaki etkileşim nedeniyle grafit eksfoliyasyonu meydana gelir. Bu fenomenler, elektrotun kırılmasına ve yeni SEI'nin daha fazla büyümesine neden olur, bu da pilin kapasite kaybına yol açar. Bataryaların kırılma mekanizması ve mekanik yorulması bir sonraki bölümde tartışılmaktadır.

2.3.1.2. Kırılma

Pil şarj ve deşarj işlemleri sırasında elektrotların hacim genişlemesi ve daralması, iç stres oluşturarak elektrotlarda çatlaklara neden olur. Pilin döngüsü devam ettikçe, elektrot yüzeylerindeki çatlaklar kademeli olarak büyür. Yeni ortaya çıkan elektrot yüzeylerinde SEI tabakası oluşur ve Li tüketir. Bu durum, mevcut SEI kalınlığını artırır, ek Li kaybına ve direnç artışına yol açar. Dolayısıyla, difüzyon kaynaklı streslerin (DIS) neden olduğu bu mekanik bozulma, kapasite kaybının bir diğer önemli nedenidir[118].

Elektrotlardaki DIS [118], [119] çalışmalarında incelenmiş ve modellenmiştir. Çalışmasında, Lityum-iyon hücrelerinin aktif elektrot malzemesinde çatlakları öngörmek için iki rejime (tek fazlı ve iki fazlı malzeme) dayalı bir stres oluşturma modeli geliştirilmiştir. Bu rejimlere dayalı olarak hesaplanan stresler, yüksek hızlı uygulamaların daha küçük parçacıklar (parçacık boyutu) gerektirdiğini ve aşırı deşarjı önlemek için iki fazlı rejimden kaçınılması gerektiğini göstermektedir. [118] çalışmasında modellenen DIS, streslerin analiz edilmesinde ve mekanik dayanıklılığın artırılmasında faydalı olsa da konsantrasyon bağımlılığının modele dahil edilmemesi, elektrotlardaki maksimum stres ve stres evriminin önemli ölçüde etkilenmesine

neden olmuştur. Bu sınırlama daha sonra [119] çalışmasında ele alınmıştır. Yüksek C-oranı sırasında ana elektrot parçacıklarında büyük Li konsantrasyon gradyanlarına neden olan DIS'yi anlamaya odaklanmıştır, burada C-oranı, nominal kapasiteye göre şarj ve deşarj akımının ölçüsüdür. Ancak çalışma, depolama sırasında düşük C-oranı sırasında daha yüksek Coulomb kaybını açıklayamadı, bu durum SEI tabakasının olası mekanik bozulmasına bağlanabilir.

Elektrot parçacığının genişleme/daralma sırasında büyük ölçekte stresler nedeniyle meydana gelen SEI tabakasının çatlaması [120] çalışmasında incelenmiştir. Yazarlar, SEI'nin deneyimlediği streslerin düşük C-oranı sırasında çatlama ve yeniden oluşumun, hücre kapasite kaybının baskın mekanizması olduğunu sonucuna varmışlardır. Döngü yaşlanması sırasında SEI çatlamasının kapasite kaybı ile ilişkili matematiksel formülasyon aşağıda verilmiştir[120]:

$$C_{cycloss} = a(\Delta SOL)^2 \quad (2.18)$$

Burada, ΔSOL lityasyon salınımının durumunu, $a > 0$ ise elektrot malzemesindeki Li difüzyon özellikleri, reaksiyon hızı, sıcaklık, reaksiyona dahil olan Li atomlarının sayısı, parçacıkların yarıçapı ve SEI ile elektrot malzemesinin mekanik özelliklerinin bir fonksiyonu olan bir sabittir. Yakın zamanda [121], DIS'lerin ve Li-iyon konsantrasyonunun evrimi, SEI'lerin çatlama mekanizmasını ve LIB'lerdeki yorgunluğu belirlemek için analitik bir model kullanılarak değerlendirilmiştir. [122] çalışmasında, pilin kapasite kaybı, kapasite kaybı sapma yüzdesi (CFD) olarak incelenmiş ve CFD arttıkça, çatlak yayılmasının SEI tabakasının büyümesinin pil kapasite kaybı üzerindeki etkisiyle birlikte baskın olduğu gösterilmiştir.

SEI tabakasının oluşumu ve çatlaması dışında, mevcut birleşik kimyasal/mekanik bozulma modellerini genişletmek için dikkat gerektiren diğer bir yan reaksiyon Li kaplanmasıdır. Li kaplanmasının belirlenmesi, pilin ömrü ve güvenliği tehlikeye atmadan verimli pil işletimi için kritik öneme sahiptir. Li kaplama mekanizması ve kapasite kaybına neden olan etkilerini incelemek için modelleme yaklaşımları bir sonraki bölümde tartışılmaktadır.

2.3.1.3. Lityum Kaplaması

Lityum kaplaması, birkaç şarj ve deşarj döngüsünden sonra gerçekleşir[123]. Bu süreçte, anot üzerinde SEI tabakası büyüyerek anotların gözenekliliğini azaltır. Gözenekliliğin azalması, anot-elektrolit arayüzünde yerel bir potansiyel gradyanının artmasına neden olur ve bu da anot ile elektrolit arasındaki dar boşlukta Li metal oluşumunu teşvik eder. Li kaplaması, negatif

elektrot yüzey potansiyeli Li/Li^+ referans elektroduna göre sıfır voltun altına düştüğünde meydana gelir.

Li-iyonları, özellikle düşük sıcaklıklarda ve şarj sırasında metalik Li oluşturma eğilimindedir. Düşük sıcaklıklar (5°C), genellikle SEI ve grafit içindeki Li difüzyonunu azaltır, bu da elektrodu Li kaplamasıyla kaplayabilir[124]. Genellikle, biriken metalik Li geri döndürülebilir. Ancak, Li dendritleri oksidasyon sürecinde aktif malzemeyle temasını kaybedebilir ve hücrede ölü Li'ye neden olabilir. Ayrıca, kaplanmış metalik Li yüksek derecede reaktiftir ve elektrolitle geri dönüşümsüz bir SEI oluşturur. Buna karşılık, negatif elektrot potansiyeli deşarj işlemi sırasında pozitif bir değere ulaşırsa Li sıyrılması meydana gelir. Li kaplaması, döngüsel Li-iyon miktarını azaltır veya elektrotlar arasındaki SEI tabakasında donmuş Li miktarını artırır, bu da kapasite azalması olarak kendini gösterir. Li metali ayrıca Li kaplamasının pozitif geri beslemesini artırarak pil direncinin artmasına yol açar. Bu nedenle, Lityum kaplamasının modellenmesi, düşük sıcaklıklarda yaşlanma ve güvenlik sorunlarını analiz etmek için gereklidir. Fiziko-kimyasal modeller, Li birikiminin başlangıcını ve biriken metalik Li miktarını tahmin eder. Aşırı şarj sırasında Li birikimi koşullarını tanımlayan ilk yaklaşım [125] çalışmasında sunulmuştur. Burada, Doyle'un modeli [126] Butler-Volmer denklemi ile tanımlanan bir yan reaksiyonu içerecek şekilde genişletilmiştir. Bu modelin değiştirilmesiyle, kontrol odaklı bir hücre bozulma modeli ile geliştirilmiştir. Ayrıca, [125] çalışmasındaki model, yazarlar tarafından [127] çalışmasında sıcaklık etkilerini (Arrhenius yasası-Bölüm 2.3.1) içerecek şekilde değiştirilmiştir. Benzer fizik tabanlı bir LIB yaşlanma modeli, Li kaplaması ve SEI büyümesini dikkate alarak ve genişletilmiş döngülerden sonra doğrusal olmayan yaşlanmaya geçişi tahmin etmiştir.[123] Li-metal için kullanılan malzeme denge denklemi şu şekilde ifade edilmiştir [123]:

$$\frac{\partial C_{Li}}{\partial t} = -\frac{j_{lpl}}{F}(1 - \beta) \quad (2.19)$$

Burada, C_{Li} , elektrot birim hacmi başına Li metalin molar konsantrasyonudur, j_{lpl} Li birikim reaksiyonunun transfer akım yoğunluğudur ve β parametresi, kaplanmış Li'nin SEI haline gelen kısmını belirtir. Düşük sıcaklıklarda aynı anda gerçekleşen Li kaplaması ve Li sıyrılmasının neden olduğu bozulma etkileri ise [128] çalışmasında Li kaplaması için nicel bir tespit yöntemi geliştirmiş ve düşük sıcaklıklarda (-5°C) süreci araştırmak için hem Li kaplaması hem de sıyrılma reaksiyonlarını içeren elektrokimyasal modeller incelenmiştir. Ayrıca, [129]

çalışmasında, LLI, LAM, kaplanmış Li'nin büyümesi ve ikincil SEI ve elektrolit çözücülerinin tüketimi gibi bozulma etkilerini dikkate alarak Li kaplamasının başlangıcını tahmin etmek için negatif elektrot potansiyellerini nicelleştiren daha basit, azaltılmış-düzen modeller geliştirilmiştir.

2.3.1.4. Katot Degradasyonu

Son çalışmalara göre aktif katot malzeme kaybı da pilin bozulma sürecinde önemli bir rol oynamaktadır[130]. Katot bozulmasının nedenleri arasında, parçacıkların yüzey yapısındaki değişikliklere bağlı olarak aktif malzemelerin etkisiz hale gelmesi ve aktif malzemeler ile akım toplayıcı arasındaki elektronik bağlantının kopması bulunmaktadır. Ayrıca, DIS'lerin (difüzyon kaynaklı stresler) neden olduğu katot malzeme kaybı da bu bozulma sürecine katkıda bulunur[131]. Bu stresler, katot yüzeyinde çatlakların ve katot elektrolit arayüzü (CEI) olarak bilinen etkisiz bir tabakanın oluşmasına neden olur, bu da lityum kaybı (LLI) ile sonuçlanır.

Katot üzerindeki çatlakların evrimi [132], [133] çalışmalarında ele alınmıştır. Elektrot performansının, pilin lityasyon ve delityasyon döngüleri sırasında oluşan gerilim ve basınç stresleri nedeniyle azaldığı belirlenmiştir. Ayrıca, düzensiz interkalasyon ve deinterkalasyon akımları, elektrottaki parçacıklar arasında strese neden olur. [132] çalışmasında, katot içindeki stres ve gerilim enerjisinin evrimi, elektrokimya ve mekanik entegrasyonu ile analitik olarak incelenmiştir. Çok ölçekli mekanik-elektrokimyasal modelden, elektrot içindeki elektrokimyasal olarak etkisiz bölgelerin stres birikimine neden olduğu görülmüştür[133]. Bu model ayrıca, katottaki çatlaklardan kaynaklanan sorunları da ele almaktadır.

Öte yandan, stres ile katot malzeme kaybı arasındaki nicel ilişki [134] çalışmasında diğer yan reaksiyonların, örneğin Li kaplama ve SEI tabaka oluşumlarının etkileri birlikte incelenmiştir. Yazarlar, Crate ve çevre sıcaklığı gibi dış faktörlerin etkilerini içeren bir birleşik elektrokimyasal-mekanik-termal bozulma modeli önermiştir. Katot çözünmesi, CEI büyümesi, anot ve katotta parçacık çatlaması ve SEI büyümesi arasındaki karmaşık etkileşimi anlamak için benzer ayrıntılı bir invaziv olmayan inceleme [135] çalışmasında sunulmuştur.

Yukarıda tartışılan tüm iç bozulma mekanizmalarının özeti ve bu mekanizmaların modelleme yaklaşımları için kullanılan yazılımlar Tablo 4'te verilmiştir. Mekanik bozulma (çatlaklar), Li kaplama ve katot bozulmasının, pilin kapasite kaybına katkıda bulunduğu sonucuna varılabilir. SEI büyümesi hem kapasite hem de güç kaybından sorumludur. İç bozulma mekanizmalarını pilin sağlık durumu (SOH) ile ilişkilendirmenin yanı sıra, dış faktörlerin lityum-iyon pillerde

kapasite kaybına ve direnç artışına katkısını da değerlendirmek gereklidir. Farklı dış yaşlanma faktörlerinin SOH metrikleri üzerindeki etkileri bir sonraki bölümde tartışılacaktır.

2.3.2. Pil Degradasyonunu Etkileyen Dış Faktörler

Pil degradasyonu, kullanım ve dış işletim koşullarına bağlı olarak pilin ömrünün her aşamasında farklı oranlarda meydana gelir. Pil degradasyonu, çevrim yaşlanması ve takvim yaşlanması olarak sınıflandırılabilir[136]. Takvim yaşlanması pilin depolanması ile ilgiliyken, çevrim yaşlanması kullanım ile ilişkilidir. Pil sıcaklığı, şarj/deşarj oranı (C-rate), derinlik boşalımı (DOD), zaman, çevrim sırasındaki voltaj etkileri ve dinlenme dönemlerindeki şarj durumu (SOC), pil yaşlanmasının başlıca faktörleridir[137]. Li kaybına ve iç direncin artmasına neden olan tüm bu dış yaşlanma faktörleri, aşağıdaki alt bölümlerde bağımsız olarak ele alınacaktır.

2.3.2.1. Şarj/Deşarj Oranı (C-Rate) ve Sıcaklığın Etkisi

C-rate, pilin çevrildiği şarj/deşarj oranı olarak tanımlanır. Şarj C-rate ve kesme voltajlarının pilin yaşlanması üzerindeki etkisi üzerine yapılan çalışmalar [137], [138]'da sunulmuştur. Bu çalışmalarda, şarj akımının aktif malzemenin kristal yapılarının kolayca yorulmasına ve zarar görmesine neden olarak LAM kaybının belirleyici faktörü olduğu gösterilmiştir. Yüksek şarj C-rate ayrıca anot üzerinde Li kaplamasına yol açar[139]. Benzer şekilde, yüksekdeşarj oranındadeşarj kapasitesi önemli ölçüde düşer[140], [141]. Yüksekdeşarj oranındaki degradasyon mekanizmaları, yüksek şarj oranındaki mekanizmalara benzerdir[142].

$$\bar{k}_1 = \bar{k}_0 e^{\frac{-E_a}{R_g T}} \quad (2.20)$$

Yaşlanmanın sıcaklık (T) bağımlılığı, genellikle Arrhenius denklemi ile açıklanır ve geniş bir literatürde incelenmiştir. Burada $\bar{k}_0$ bir hız sabiti, $\bar{k}_1$ kinetik reaksiyon hızıdır[143]. Yüksek sıcaklıklarda pil performansında geçici bir artış olmasına rağmen, pil içinde korozyon gibi ikincil yan reaksiyonlar meydana gelir. Bu korozyon, LLI (Lityum Kayıp İndeksi) ile pili daha hızlı bozar ve kapasite kaybına neden olur. Yüksek sıcaklıklar ayrıca SEI filminin kalınlaşmasına ve katotun bozulmasına neden olarak güç kaybının (direnç artışı) artmasına yol açar[143]. [144]çalışmasında, yazarlar, Warburg elemanları ve hücre empedansının yüksek sıcaklıkta çevrimle arttığını, ancak bunların SOH üzerinde önemli bir etkisi olduğunu bulmuşlardır. Gerçek hayattaki uygulamalarda, sıcaklık dalgalanmaları vedeşarj oranı bir araya geldiğinde, pilin kapasite kaybı üzerinde kümülatif bir etkiye sahiptir.

Öte yandan, düşük sıcaklık koşulları malzeme difüzyon kaybına ve pil kimyasının değişmesine neden olur[145]. Düşük sıcaklıkta şarj sırasında, anotun yüksek polarizasyonu nedeniyle Li kaplama, dendrit büyümesi ve aktif malzemenin kristal yapısının zarar görmesi gibi sorunlar bildirilmiştir[146]. Bu durum, yüksek deşarj oranlarında verimlilikte önemli bir düşüşe yol açarak SOC ve SOH' yi olumsuz etkiler.

2.3.2.2. Deşarj Derinliği, Şarj Durumu, Zaman ve Voltajın Etkisi

Çevrim derinliği veya DOD, pil bozulmasını belirleyen kritik bir faktördür. DOD, serbest bırakılan şarj miktarının pilin nominal kapasitesine oranı olarak tanımlanır. Yüksek DOD, ciddi yapısal ve hacimsel değişiklikler nedeniyle LAM' a (Aktif Malzeme Kaybı) yol açarak pilin çevrim ömrünü azaltır. Bu nedenle, derin çevrimler küçük çevrim derinliklerine kıyasla orantısız veya üstel yaşlanmaya neden olur[147]. DOD' un LIB' nin çevrim performansı üzerindeki etkisi, kullanılan farklı katot malzemelerine göre değişiklik gösterir

SOC (Şarj Durumu) değişkenliği, yani SOC değişimi (Δ SOC), çevrim sırasında yaşlanmayı önemli ölçüde etkiler[148]. Güç kaybı, Δ SOC değeri arttıkça yükselir. Yüksek SOC seviyelerinde, yani yüksek terminal voltajlarında, SEI tabakası elektrolit ayrışması ve lityum-iyon birikimi ile kalınlaşarak daha yüksek bir yaşlanma hızına yol açar [149]. Yüksek SOC ve düşük sıcaklıkta şarjın birleşimi, lityum-iyon birikimi yan reaksiyonunun meydana gelmesiyle yaşlanma olgusunu zamanın doğrusal olmayan bir fonksiyonu olarak hızlandırır[148]. Öte yandan, düşük SOC, anot bakır akım toplayıcılarının korozyonuna ve katot aktif malzemesinin yapısal bozulmasına neden olarak LIB' nin hızla yaşlanmasına yol açar[150]. Ayrıca, piller, aynı çalışma sıcaklıklarında farklı SOC seviyelerinde farklı yaşlanma davranışları sergiler[151]. Çevrimlerin %45 ile %55 SOC arasında gerçekleşmesinin hem kapasite kaybı hem de direnç artışı üzerinde en az etkiye sahip olduğu sonucuna varılmıştır[149].

Depolama süresi de pil degradasyonunda kritik bir rol oynar. Takvim yaşlanması genellikle karbon bazlı anotlarda SEI oluşumundan kaynaklanır[152]. Önceki bölümde tartışıldığı gibi, SEI büyümesi iç direnci artırır. SEI kalınlığı yaşlanma ile arttıkça, güç kaybı artar[153]. Literatür çalışmalarda, bu yaşlanma süreci zamanla doğrusal olarak ilerlemiştir[154]. Daha sonraki çalışmalarda, SEI büyüme hızının zamanın karekökü ($\sqrt{t}$) fonksiyonu olduğu bulunmuştur[154]. Bu $\sqrt{t}$ bağımlılığı, genellikle SEI büyümesi nedeniyle artan kapasite kaybını (ICL) temsil eder ve çoğunlukla difüzyon süreci tarafından yönetilir.

Şarj ve deşarj voltajları, pilin yaşlanma olgusu üzerinde daha fazla kapasite bozulması ve direnç artışı ile etkili olur[138]. Yüksek katot voltajları elektrolit oksidasyonuna ve katot ayrışmasına neden olur[142]. Öte yandan, düşük katot potansiyelleri pilin hızlandırılmış yaşlanmasını yavaşlatır. [138] çalışmasında, yazarlar, kesme voltajını düşürmenin kapasite kaybını ve LLI' yi nasıl yavaşlattığını tartışmışlardır. Yüksek veya düşük işletim voltajı penceresi (ΔV) de pilin içindeki yaşlanma mekanizmalarını etkiler[155]. Yüksek ΔV , grafit anotun LAM' ına (Aktif Malzeme Kaybı) neden olurken, düşük ΔV yüksek deşarj kesme voltajlarına ve grafit anotta geri dönüşümsüz yapısal değişikliklere yol açar[156].

Diğer faktörler, örneğin dış kötü kullanım, mekanik stres[157], basınç [158] ve anot, katot ve elektrolit seçimi [159], SEI tabakasının oluşumunu, büyümesini ve kalınlaşmasını hızlandırarak LIB' lerde yaşlanmayı hızlandırır. Özetle, yüksek/düşük sıcaklıklar, yüksek Crate' ler, yüksek SOC ve ΔV , LIB' nin yaygın dış yaşlanma faktörleridir[160]. Yukarıda tartışılan LIB sağlığı bozulmasına ilişkin neden-sonuç diyagramı Şekil 2.8'de gösterilmektedir.

2.4. YAŞLANMA MODELLEMESİ

Lityum-iyon pil yıpranmasının modellenmesi için çok sayıda teknik mevcut olup, bunlar genellikle iki ana kategoriye ayrılır: fizik tabanlı teknikler ve veriye dayalı teknikler. Bu teknikler, pil sağlık durumunun (SoH) şu anki durumu, gelecekteki durumu ve ne kadar süre daha kullanılabileceği gibi üç temel soruyu ele almayı hedefler.

Şu Anki Sağlık Durumu

Bir hücrenin mevcut Sağlık Durumu (SoH), literatürde tanı veya SoH tahmini olarak bilinir. Bu tezde, döngü akımında ölçülen oransal kapasite gibi sağlık metrikleri kullanılır. Alternatif olarak, açık devre gerilim seviyesi [161]veya iç direnç[162] gibi metrikler de kullanılabilir. Bu metrikler, döngü verilerinden[162] veya bir referans performans testi (RPT) [163] ile tahmin edilebilir. Lityum-iyon pil diyagnostiğine literatürde SoH prognostikten daha fazla odaklanılmıştır, fakat bu tezin ana odak noktası değildir. Buradaki çalışma, gelecekteki sağlık durumuna odaklanır, ancak sunulan teknikler SoH tahmini için de uyarlanabilir.

Gelecekteki Sağlık Durumu

Sağlık prognostik veya tahmini, hücre ömrü boyunca belirli bir sağlık metriğinin yörüngesini tahmin etmeyi amaçlar ve sağlık yönetiminin temel bir parçası olarak kabul edilir. Gelecekteki kullanım bilgisine dayalı bu tahminler, k-adım ötesi yaklaşımlarda benzer kullanım varsayımı içerir. Genel olarak, gelecekteki sağlık yörüngesini tahmin etme yaklaşımları, tahmin uzunluğu arttıkça doğruluk açısından zayıflar[163].

Kullanışlı Ömür Tahmini

Bir hücrenin ne kadar süre daha kullanılabilceğini belirlemek için kullanışlı ömrün (RUL) tahmini yapılır[164]. Bu tahmin, hücre ömrü boyunca veya belirli bir erken döngüden gerçekleştirilebilir[165]. Ömrün sonu koşulları genellikle bir kapasite veya direnç sınırı olarak belirlenir[165].

Bu genel bakış, lityum-iyon pillerin yıpranma modellemesinde kullanılan çeşitli yaklaşımların önemini ve bu yaklaşımların pillerin sağlık durumunu anlamak ve tahmin etmek için nasıl kullanılabilceğini göstermektedir. Her teknik, farklı yönleriyle pil sağlık durumunun daha iyi anlaşılmasına ve yönetilmesine katkıda bulunur.

Diz noktasının ötesinde, bir hücre uygulama için değerini kaybetmiş olarak kabul edilebilir ve bu nedenle zaman-kapasite uzayında esnek bir konumda olan EoL' ye benzer olarak kabul edilebilir[166]. Erken döngülerden diz noktasını açıkça tahmin etmeye yönelik girişimler olmuştur[167], veya iç direnç artışlarında dirsekleri inceleyen eşdeğer prosedür[168].

2.4.1. Fizik Tabanlı Yaklaşımlar

Fizik tabanlı yaklaşımlar, pil yıpranmasının modellemesi için üç ana kategoriye ayrılır: elektrokimyasal modeller, eşdeğer devre modelleri ve yarı-ampirik modeller.

2.4.1.1. Elektrokimyasal Modeller:

Elektrokimyasal modeller, pilin moleküler ölçekteki yıpranma mekanizmalarını modeller. Bu modeller, yıpranmanın katı elektrolit ara yüzey büyümesi[169] parçacık çatlaması[170] lityum kaplama [171] veya aktif materyalin kaybı [172] gibi süreçler üzerinden gerçekleştiğini varsayar. Elektrokimyasal modeller, hassas sonuçlar sunabilir, ancak hücre bileşenleri ve başlangıç koşulları hakkında ayrıntılı bilgi gerektirir ve karmaşık matematiksel çözümler gerektirir, bu da pratik uygulamalarını sınırlar [124].

2.4.1.2. Eşdeğer Devre Modelleri:

Eşdeğer devre modelleri, pilin elektriksel davranışını basitleştirilmiş bir devre ile modelleyerek daha az parametreye ihtiyaç duyar ve bu nedenle hesaplama açısından daha ucuz bir alternatif sunar [173]. Bu modeller, genellikle bir voltaj kaynağı ve çeşitli dirençler, kapasitörler, diyotlar veya transformatörler içeren basit devreler kullanarak pilin davranışını yaklaşık olarak modeller[174]. Eşdeğer devreler, Kalman filtresi gibi uygun bir parametre tahmin algoritması ile kullanım verilerine dayalı şarj durumu ve SoH tahminleri için kullanılabilir[162].

2.4.1.3. Yarı-Ampirik Modeller:

Yarı-ampirik modeller, pilin yıpranma mekanizmalarını ve bu mekanizmalar arasındaki ilişkileri belirleyerek bir model oluşturur. Bu modeller, yüksek sıcaklık, düşük sıcaklık ve yüksek şarj durumu gibi farklı yıpranma nedenlerini ve her birine karşılık gelen fiziksel stres faktörlerini içerebilir [138]. Bu modellerin performansı, seçilen modellerin uygunluğuna ve gerçekleştirilen uyarlamalara bağlıdır [175].

Fizik tabanlı yaklaşımlar, pil yıpranmasını anlama ve modelleme konusunda değerli içgörüler sunar ve yorumlanabilir olmalarıyla öne çıkar. Ancak, sabit bir yapı varsayımı ve yıpranma modeline ilişkin sınırlılıkları nedeniyle, bu yaklaşımlar karmaşık gerçek dünya durumlarında esneklikten yoksun olabilir. Pil yıpranması, özellikle aynı koşullar altında bile önemli değişkenlikler gösterebilir [176], bu nedenle laboratuvar dışı ortamlarda uygulanabilir bir sağlık modeli için daha fazla esnekliğe ihtiyaç duyulabilir.

2.4.2. Veriye Dayalı Teknikler

Veriye dayalı modelleme teknikleri, pillerin yıpranma eğrilerini veri analizi yoluyla belirlemeye yöneliktir. Bu teknikler üç ana kategoriye ayrılabilir: uyarlanabilir parametrelerle sabit ampirik modeller, makine öğrenimi modelleri ve derin makine öğrenimi modelleri.

2.4.2.1. Uyarlanabilir Parametrelerle Sabit Ampirik Modeller:

Bu yaklaşımda, yarı-ampirik yaklaşımlardan daha basit ampirik modeller kullanılır ve bu modellerin parametreleri hücre ömrü boyunca uyarlanır. Örneğin, hücre yaşlanmasını modellemek için Kalman ve parçacık filtreleme (PF) teknikleri uygulanabilir[177]. Yaşlanma eğrisi, $Q(t) = a + btc$ gibi basit bir kapasite fonksiyonu takip edebilir ve bu fonksiyonun parametreleri zaman içinde değişebilir. Bu modellerin performansı, zaman içinde belirli bir hücrenin yaşlanma sürecine uyum sağlayarak artırılmaya çalışılır[178].

2.4.2.2. Uyarlanabilir Yapı Modelleri:

Bu modeller, sabit yapıya sahip olan önceki modellerden farklı olarak, parametreleri uyarlayarak modele esneklik kazandırır. Uyarlanabilir yapı modelleri, pil sağlığı alanında nadiren kullanılsa da arıza tespiti gibi uygulamalar için faydalıdır[179]. Örneğin, fuzzy sistemler, belirsiz ve kesin olmayan verileri işleyebilen ve k-adım ötesi SoH tahmini için kullanılan kural tabanlı regresyon araçlarıdır[180]. Bu yaklaşımlar, literatürde daha az yaygın olmakla birlikte, belirsiz veri setlerini işleme konusunda etkilidir.

2.4.2.3. İstatistiksel Zaman Serisi Yöntemleri:

İstatistiksel zaman serisi yöntemleri, özellikle ARIMA (otoregresif entegre hareketli ortalama) yöntemi gibi, zaman içindeki veri ilişkilerini analiz eder[181]. Bu yöntemler, geçmiş veriler ve tahmin hataları üzerine ağırlıklar atayarak gelecek tahminler yapar. ARIMA modelleri, SoH tahmini için kullanılmıştır[181]. Wiener süreçleri ve Gamma süreçleri gibi diğer zaman serisi modelleri de SoH tahmini için uygulanmaktadır ancak bu yöntemlerin varsayımları ve esneklikleri sınırlı olabilir[182].

Bu veriye dayalı teknikler, lityum-iyon pillerin yıpranma süreçlerini anlamak ve tahmin etmek için çeşitli veri kaynaklarından yararlanır. Her bir yaklaşımın avantajları ve sınırlamaları, uygulama bağlamına ve kullanılan veri türüne bağlı olarak değişir. Özellikle, pil verilerinin karmaşıklığı ve belirsizliği, bu tekniklerin etkili bir şekilde uygulanmasında önemli bir rol oynar.

2.4.2.4. Makine Öğrenimi Yaklaşımları

Makine öğrenimi teknikleri, pil yıpranmasının modellenmesinde artan bir popüleriteye sahiptir ve literatürde giderek daha yaygın hale gelmektedir[183]. Bu modeller, bilinen girdi değerleri ve çıktı hedefleri temelinde eğitilen denetimli öğrenme modelleri olarak tanımlanır. Bunlar, çıktıların sürekli değişkenler olduğu regresyon modelleridir[184]. Genellikle, bu modellerin sabit alt temel fonksiyonları bulunur ve parametreleri içeren veya parametrik olmayan istatistiksel modeller olarak sınıflandırılırlar.

Denetimli Öğrenme Teknikleri: Denetimli öğrenme teknikleri, girdi-çıktı çiftlerinden oluşan bir eğitim seti kullanır. Girdiler, her bir ögesi bireysel bir girdi özelliği x_k temsil eden D uzunluğunda x sütun vektörleridir. Çıktılar y , yani hedefler, skalerlerdir. Eğitim verileri, $D = \{(x_k, y_k)\}_{k=1}^N$ şeklinde, N girdi-çıktı çiftinden oluşur ve bu veriler, seçilen denetimli öğrenme modelinin parametrelerini uydurmak için kullanılır.

Lineer Modeller: En basit veriye dayalı modeller, parametre vektörü w ile $y = \sum_{i=1}^D w_i x_i$ şeklinde lineer modellerdir. Bu modeller, eğitim verilerine göre w parametrelerinin uydurulduğu için denetimli öğrenme olarak sınıflandırılır. Lineer modellerin eğitimi hızlıdır, saklaması kolaydır ve anlaşılması kolaydır. Bunlar, SoH tahmini [185], sağlık prognostik ve RUL ve diz noktası tahminleri için kullanılmıştır[186].

Destek Vektör Makineleri (SVM): SVM, yapısı itibariyle lineer bir modele benzeyen, ancak çıktıları doğrudan girdilere dayalı değil, çekirdek değerlerinin ağırlıklı toplamına dayalı olan bir çekirdek tabanlı yöntemdir[187]. SVM, sıfır olmayan ağırlıkların seyrekliğiyle bilinir ve belirtilen tolerans dışında kalan noktalarda sıfır olmayan ağırlıklara sahip olabilir[187]. İlişki vektör makineleri (RVM), fonksiyonel form olarak SVM' lerle benzerdir, ancak olasılıksal çıktılar üretmek için Bayesci çıkarım kullanır. SVM' ler ve RVM' ler, SoH tahmini, SoH prognostik ve RUL tahmini için kullanılmıştır[188].

Bu makine öğrenimi yaklaşımları, lityum-iyon pillerin yıpranma süreçlerini anlamak ve modellemek için karmaşık veri setlerinden öğrenme yetenekleri sayesinde değerli araçlar sunar. Her bir modelin, uygulama alanına ve kullanılan veri türüne göre avantajları ve sınırlamaları vardır.

Rastgele Orman (RF) Regresyonu: RF regresyonu, girdileri örnekleyerek ve çıktılarının ortalamasını alarak çok sayıda model üreten bir yöntemdir[189]. RF, eğitim veri setine aşırı uydurma riskini azaltır ve genellikle SoH tahmini için kullanılır. RF' nin birden fazla karar ağacı eğitme gereksinimi, modellerin yorumlanmasını zorlaştırabilir.

Gaussian Süreç Regresyonu (GPR): GPR, belirli koşullar altında ilgili vektör makinesi regresyonuna eşdeğer olabilen bir parametrik olmayan denetimli öğrenme aracıdır[190]. GPR, iyi veri kullanılabilirliği durumunda etkili bir araçtır ancak önemli ölçüde ekstrapolasyon yapmaya zorlandığında sınırları vardır[190]. GPR, SoH tahmini, SoH prognostik ve RUL tahmini için kullanılmıştır[191].

2.4.2.5. Derin Modelleme, Parametresiz


GPR ve RVM' lerin önemli bir zayıflığı, artan girdi boyutuyla nasıl ölçeklendikleriyle ilgilidir. Sinir ağları (NN' ler), daha ölçeklenebilir bir çözüm sunar ve tipik olarak $O(N^3)$ karmaşıklığına sahiptir[192]. Ancak, sinir ağları genellikle çok katmanlı yapılara sahiptir ve bu, büyük miktarda veri gerektirir. NN' ler, lityum-iyon pil sağlığını döngü verilerine dayanarak

modellemek için kullanılır. NN yaklaşımları, özellikle derin öğrenme için, kara kutu modeller olarak eleştirilir, bu da girdiler ve çıktılar arasındaki ilişkilerin anlaşılmasını zorlaştırır[193]. Bu nedenle, bu çalışmada GPR ve Bayesci lineer regresyon gibi daha ön görümlü yaklaşımlar tercih edilmiştir.

Bu bölümde ele alınan makine öğrenimi teknikleri, pil yıpranmasının anlaşılması ve tahmin edilmesi için çeşitli araçlar sunar. Her teknik, veriye dayalı bir yaklaşımla, pil yıpranmasının karmaşık dinamiklerini modellemeye çalışır ve bu süreçte farklı avantajlar ve sınırlamalar sunar.

2.4.3. KNEE Noktası Tahmini

Bataryaların yaşlanma süreçlerine bağlı olarak ortaya çıkan kilit nokta, direnç artışı, lityum plakalanması ve elektrot doyumu gibi mekanizmalara atfedilebilir. Bu karmaşık mekanizmalar, Şekil 2.9'da görsel olarak gösterilmiştir. Kısaca özetlemek gerekirse, lityum plakalanması, batarya bozulmasının ve kilit noktanın ortaya çıkmasının başlıca nedenlerinden biridir [194]. Bu olgu, özellikle yüksek şarj akımları ve/veya düşük sıcaklık koşullarında belirgin hale gelir. Bu durumda, metalik lityum, lityum iyonları ile elektrot yüzeyinde oluşur; bu iyonlar normalde elektrotta interkale olmalıdır[194], [195]. Bu süreç, yan reaksiyonlar veya gaz oluşumu nedeniyle elektrolitin tükenmesine, aktif madde kaybına ve nihayetinde lityum plakalanmasına yol açarak kilit noktanın ortaya çıkmasına neden olabilir[196]. Ayrıca, katkı maddelerinin tükenmesi, direnç artışı ve lityum plakalanması gibi mekanizmalar aracılığıyla kilit noktanın başlangıcını etkileyebilir. Mikroskobik ve makroskobik basınçlar tarafından yönlendirilen mekanik deformasyon, yaşlanmayı hızlandırabilir ve kilit nokta fenomenine katkıda bulunabilir [197], [198]. Yan reaksiyonların ağırlıklı olarak katotta gerçekleştiği durumlarda, elektrot doyumu önemli bir faktör olarak ortaya çıkar. Bu doyum, aktif madde kaybı hızı, lityum envanterindeki azalmayı aştığında meydana gelir [194]. Bataryalar yaşlandıkça, iç dirençleri, öncelikle SEI (Solid Electrolyte Interphase) tabakasının büyümesi ve yan reaksiyonların yan ürünleri nedeniyle artar. Son olarak, perkolasyon teorisine dayanan ve elektrolit kuruması mekanizmalarını açıklayan perkolasyon sınırlı bağlantılılık, kilit noktayı tetikleyen faktörlerden biridir[194], [199].



Şekil 2.11: Batarya diz noktası ve etki eden ana sebepler

Kilit noktaların belirlenmesi için çeşitli yöntemler mevcuttur ve bu yöntemler [194] numaralı kaynakta geniş bir şekilde özetlenmiştir. Bu yöntemlerin çoğu, genellikle çevrim dışı tespitler için kullanılan tam bozulma eğrisini gerektirir. Yaşlanma hızı, öngörülen SOH' nin (State of Health) farkı alınarak veya doğrudan öngörülerek belirlenebilen eğri eğimi ile tanımlanır, böylece çevrim içi uygulamalara olanak tanır. Gerçek zamanlı hızlandırılmış yaşlanmayı değerlendirmek için Kneedle yöntemi kullanılmaktadır. Bu yöntem, kilit noktanın eğiminin, başlangıçtan EOL (End of Life) noktasına kadar çizilen bir çizgi ile tutarlı olduğunu varsayar, Şekil 2.11'da gösterildiği gibi. Bu yaklaşım, hızlanan yaşlanma dinamiklerini değerlendirmek için bir yol sağlar ve araç üzerinde uygulanabilir [200]. Özellikle, yaklaşımımız, 10. döngüden (adaptasyon [201] kaynaklı) EOL noktasına çizilen bir çizgi ile kilit nokta eğiminin hesaplanmasını içerir ve bu sembolik olarak temsil edilir.


2.5. AÇIK KAYNAKLI VERİ SETLERİ VE ÖZELLİKLERİ

Lityum iyon piller (LIB) ile ilgili bozulma veri setleri, pil sağlık durumunu ve bozulma modellerini anlamak için önemli bir kaynaktır. Bu bölüm, genel kullanıma açık olan ve sıklıkla kullanılan LIB bozulma veri kümelerinden bazılarını incelemektedir.

2.5.1. Nasa Ames Veri Seti

NASA Ames Prognostics Center of Excellence (PCoE) tarafından yayınlanan bu veri seti, Şarj Durumu (SOC), Sağlık Durumu (SOH) ve Kalan Kullanım Ömrü (RUL) tahminleri için makine öğrenimi modelleri geliştirmek amacıyla sıkça kullanılır. Veri seti, B0005, B0006, B0007 ve B0018 olarak etiketlenen 4 LIB' in başarısız olana kadar yapılan testlerin verilerini içerir. Bataryalar, 1.5A sabit akımda (CC) şarj edilmiş, voltajları 4.2V' a ulaştığında sabit voltaj (CV) modunda şarj edilmeye devam edilmiştir. Şarj akımı 20mA' ya düşene kadar bu işlem sürdürülmüştür.

Deşarj işlemi sırasında, bataryalar sırasıyla 2.7, 2.5 ve 2.2 V'a düşene kadar B0005, B0006 ve B0007 için 2A sabit akım seviyesinde deşarj edilmiştir. Bataryaların empedans değerleri, 0.1 Hz'den 5 kHz'e kadar frekans aralığında Elektrokimyasal Empedans Spektroskopisi (EIS) kullanılarak ölçülmüştür. Deney süresince, her bir bataryanın voltaj, akım ve sıcaklık değerleri her döngü için kaydedilmiştir.




Şekil 2.12: NASA veri setindeki LIB'ler için SOH ve Döngüleri gösteren grafik

Bu yoğun şarj ve deşarj döngüleri, bataryaların hızlandırılmış yaşlanmasına neden olmuştur. Bataryaların kapasiteleri başlangıç kapasitesinin %70'ine (2Ah'dan 1.4Ah'a) ulaştığında, yani son ömürlerine (EOL) ulaştıklarında, deneyler ve ölçümler durdurulmuştur[202] NASA veri setindeki 4 LIB'in kapasite bozulması Şekil 2.12'de gösterilmiştir.

Bu veri seti, makine öğrenimi modellerinin geliştirilmesinde ve pil bozulması modellerinin anlaşılmasında önemli bir kaynak olarak kullanılmaktadır. Bataryaların detaylı şarj ve deşarj verileri, makine öğrenimi algoritmalarının eğitiminde kullanılarak, bataryaların gelecekteki performanslarının tahmin edilmesine olanak tanır. Bu veriler, özellikle pil sağlığının dinamiklerini ve yaşlanma süreçlerini anlamak için kritik öneme sahiptir.

2.5.2. Calce Veri Seti

Maryland Üniversitesi'ndeki Yaşam Döngüsü Mühendisliği Merkezi (CALCE) tarafından yayınlanan CALCE veri seti, çeşitli pil gruplarının tekrarlanan şarj ve deşarj işlemleriyle yaşadığı bozulma süreçlerini içermektedir[203]. Bu veri seti, lityum-iyon pil bozulmasının çeşitli yönlerini analiz etmek için kullanılmaktadır. İlk pil grubu, 15 adet Lityum Kobalt (LCO) prizmatik hücre üzerinde yapılan testleri içerir. Bu hücreler, 6 gruba ayrılarak, 23 °C'de döngüsel işlemlere tabi tutulmuş ve çeşitli kısmi şarj ve deşarj işlemlerine maruz bırakılmıştır. Bu grup için elde edilen veriler arasında voltaj, akım, pil iç direnci, empedans, deşarj kapasitesi ve şarj kapasitesi ölçümleri yer almaktadır. Her pil döngüsü için ayrıntılı ölçüm verileri kaydedilmiştir ve pil ömrünün sonuna, yani Sağlık Durumu (SOH) %80'e ulaşana kadar ölçümler devam etmiştir.




Şekil 2.13: CALCE Verisi Setindeki kapasite kaybı gösterimi.

İkinci grup, 12 adet LCO prizmatik hücrenin ölçümünü içerir. Bu hücrelerin nominal kapasitesi 1.35Ah olup, ilk gruba benzer şekilde 6 gruba ayrılmış ve aynı parametreler ölçülmüştür.

Üçüncü grup ise, 16 adet LCO kılıf hücresinin ölçümünü içerir. Bu hücrelerin nominal kapasitesi 1.5Ah olup, 23°C ile 27°C arasındaki sıcaklık aralığında döngüsel işlemlere tabi tutulmuşlardır. Bu grup için elde edilen veriler, voltaj, akım ve pil kapasitesi ölçümünü içerir.

2.5.3. Oxford Veri Seti


Oxford Pil Bozulması veri seti, 8 küçük lityum-iyon kılıf hücrelerinden alınan pil yaşlanma verilerini içerir. Tüm testler 40°C'de gerçekleştirilmiş ve test sırasında gereken sıcaklık, bir termal oda yardımıyla korunmuştur. Test altındaki hücreler, sabit akım sabit voltaj (CCCV) şarj profiline tabi tutulmuş ve ardından kentsel Artemis profiline dayanan bir sürüş döngüsü deşarj profili ile izlenmiştir. Ölçümler her 100 döngüde bir alınmıştır[102] .



Şekil 2.14: Oxford veri setinde Pil Sıcaklığı ve Pil Süresi grafiği.

Şekil 2.14, Oxford veri setindeki bir pil için çeşitli pil döngülerinde pil sıcaklığının zamanla nasıl değiştiğini gösterir. Bu grafikten, pilin tekrarlanan şarj deşarj döngülerine maruz kaldıkça sıcaklığının arttığı görülebilir. Bu sıcaklık artışı, pil yaşlanmasının bir göstergesi olarak değerlendirilebilir [204]. Şekil 2.15 ise, Oxford veri setindeki bir pil için farklı pil döngülerinde voltajın zamanla nasıl değiştiğini gösteren grafiği sunar. Bu grafikler, pil parametrelerinin

değişimini görselleştirerek, pil bozulması ve yaşlanması süreçlerinin daha iyi anlaşılmasına katkı sağlar.




Şekil 2.15: Oxford veri setinde bir pilin Voltaj ve Zaman grafiği.'dir.

2.5.4. Toyota Araştırma Enstitüsü Veri Seti

MIT ve Stanford ile ortaklık içinde, Toyota Araştırma Enstitüsü (TRI), iki önemli ve kullanımı kolay yüksek verimliliğe sahip döngü veri seti yayımlamıştır. Birleştirildiğinde, bu veri setleri, A123 Systems (APR18650M1A) tarafından üretilen ve nominal kapasitesi 1.1 Ah olan 357 ticari LFP/grafit hücresi için verileri içermektedir. Bu iki veri seti, deneysel açıklamalarla birlikte 'CC BY 4.0' lisansı altında çevrimiçi olarak [205] adresinde barındırılmaktadır. Veri setleri, '.csv', MATLAB struct ve (sadece ikinci veri seti) JSON struct formatlarında sağlanmakta olup, başlangıç betikleri için bir GitHub deposuna bağlantı ile sunulmaktadır. Bu veri setlerinin dosya yapısı, hücre döngüsü kaydedilen verilere göre düzenlenmiş olup, gelecekteki çalışmalar için referans olarak kullanılmalıdır. Verileri kullanan makalelerin ilgili yayını kaynak göstermesi gerekmektedir.

Bu veri setlerinin ilki [5] (124 hücre), hızlı şarj protokollerinin hücre yaşlanması üzerindeki etkisini keşfetmek için tasarlanmıştır. Her hücre, 72 farklı profil arasından seçilen bir veya iki adımlı hızlı şarj protokolü ve ortak bir CC-deşarj protokolü ile döngüye tabi tutulmuştur. Hücreler, sıcaklık kontrollü bir ortamda (30 °C) döngüye alınmıştır. Veriler, hücreler EOL'a (80% SOH) ulaşana kadar döngü 2'den itibaren kaydedilmiştir – 150 ila 2300 döngü arasında.

Veri seti, döngü içi sıcaklık, akım, voltaj, şarj ve deşarj kapasitesi ölçümleri ile döngü başına kapasite, iç direnç ve şarj süresi ölçümlerini içermektedir. Veri seti, ayrı ayrı yürütülen üç deney bloğuna karşılık gelen üç partiye ayrılmıştır. Eşlik eden makalede [5], ilk 100 döngüden elde edilen verilere dayalı olarak EOL' u tahmin eden özellik tabanlı bir model oluşturulmuştur. Veri setinin yayımlanmasından bu yana, bu veri ile çalışan birçok başka makale yayımlanmıştır.



Şekil 2.16: Toyota Araştırma Enstitüsü (TRI) veri setindeki lityum iyon pil bozulmasının döngülerine karşı deşarj kapasitesinin grafiği[206].

Bu veri setlerinin ikincisi [13] (233 hücre), ilk setin üzerine inşa edilmiştir: hızlı şarj protokollerini hızlı bir şekilde optimize etme yaklaşımını tasarlamak. Yine, hücreler sıcaklık kontrollü bir ortamda (30 °C) ortak bir deşarj protokolü ile döngüye alınmıştır. Veri seti, her biri 45 ila 48 hücreden oluşan beş partiye ayrılmıştır; bu partiler sırasıyla test edilmiştir: ilk parti için, 224 farklı altı adımlı şarj protokolünden biri her hücre için rastgele seçilmiştir, hücreler 100 döngü boyunca test edilmiştir ve ardından daha önce toplanan verilerle eğitilmiş bir model kullanılarak bu verilere dayanarak EOL tahmin edilmiştir. Bu tahmin, bir sonraki hücre partisinin şarj protokollerinin seçimine rehberlik etmek için kullanılmıştır. Bu işlem, ilk dört parti ile tekrarlanmıştır; son parti ise seçilen optimal şarj protokollerinin birkaç diğer protokol ile karşılaştırıldığı EOL' un ötesine kadar test edilmiştir. Veri seti, 124 hücrelik ilk veri seti [5] ile aynı ölçümleri içermektedir, ancak IR ölçümleri hariç tutulmuştur. Kayıp verileri kurtarmak için bir girişim yapılmış [207], IR' nin ilk veri seti ile eğitilmiş bir CNN modeli kullanılarak tahmin edilmiştir; bu tahmin edilen IR verileri çevrimiçi olarak bulunabilir [208].

Pil ömrünün sonuna (EOL) kadar, yani SOH %80 seviyesine ulaşana kadar, akım, voltaj, şarj kapasitesi, deşarj kapasitesi ve sıcaklık gibi döngü içi ölçümler kaydedilmiştir. Ayrıca, dahili direnç, kapasite ve şarj süresi gibi her döngü için ölçümler de elde edilmiştir. Şekil 2.16, bu veri setindeki deşarj kapasitesinin döngüler boyunca nasıl değiştiğini göstermektedir.

2.5.5. Raj-2020

Raj-2020 veri seti, Şekil 1.1b'de doğrusal yaşlanmanın bir örneği olarak sunulmuştur. Bu veri seti, yol bağımlılığı üzerine yapılan bir çalışmanın parçası olan 12 hücreyi içermektedir [209], [210]. Hücreler, nikel kobalt alüminyum oksit pozitif elektrotlar ve grafit negatif elektrotlar kullanılarak Panasonic tarafından üretilmiştir ve 18650 form faktörüne sahiptirler. 12 hücre, her biri üç hücreden oluşan dört gruba ayrılmıştır. Bu dört grup, etkin olarak iki çift oluşturacak şekilde düzenlenmiştir; her çiftin grupları, uzun zaman aralıklarında aynı şarj ve akım miktarına maruz kalmış, ancak döngüler farklı desenlerde gerçekleştirilmiştir. Çalışmanın sonuçları, lityum-iyon bataryaların bozulmasında yol bağımlılığının mevcut olduğunu önermektedir [209].

Bu hücreler, sınırlı veri seti boyutu, doğrusal yaşlanma ve yaşlanmanın sınırlı kapsamı nedeniyle yaygın olarak kullanılmamıştır. Yol bağımlılığı, batarya yaşlanma sürecinde, bataryaların kullanım geçmişi ve şarj/deşarj döngülerinin desenine bağlı olarak farklı yaşlanma paternleri sergileyebileceğini ifade eder. Raj-2020 veri seti, bu bağlamda önemli bulgular sunmakla birlikte, sınırlı veri kapsamı ve doğrusal yaşlanma özellikleri nedeniyle daha geniş kapsamlı çalışmalarda sınırlı bir kullanım alanına sahip olmuştur.

Raj-2020 veri seti, lityum-iyon bataryaların yaşlanma süreçlerinde yol bağımlılığını araştırmak için kullanılmış önemli bir veri setidir. Bu veri seti, batarya sağlığı ve performansı ile ilgili çalışmalar için referans niteliğinde olup, bataryaların farklı kullanım koşullarına nasıl tepki verdiğini anlamak için kritik bilgiler sağlamaktadır. Bu tür çalışmalar, batarya ömrünü uzatmak ve güvenilirliğini artırmak için yeni stratejilerin geliştirilmesine katkıda bulunabilir.


2.5.6. Dechent-2017 ve Dechant-2020

Dechent-2017 veri seti, Samsung tarafından üretilmiş ve nominal kapasitesi 1.5 Ah olan 21 adet 18650 hücreyi içermektedir. Bu hücreler, lityum nikel mangan kobalt oksit pozitif elektrotlara ve grafit negatif elektrotlara sahiptir. Hücreler, döngü derinliğinin %90'ı boyunca sürekli olarak döngüye tabi tutulmuştur ve akım oranları yaklaşık olarak 1C şarj ve 6Cdeşarj çevresinde değişkenlik göstermiştir. Bu veri seti, hücreler arasındaki performans ve yaşlanma farklılıklarını incelemek için önemli bir kaynak sunmaktadır.

Dechent-2020 veri seti, Samsung tarafından üretilmiş ve nominal kapasitesi 3.4 Ah olan 22 adet 18650 hücreyi içermektedir. Bu hücreler, lityum nikel kobalt alüminyum oksit pozitif elektrotlara ve grafit negatif elektrotlara sahiptir. Hücreler, yaklaşık %50 doluluk durumunda

döngü derinliğinin %20'si boyunca C/2 oranında (yani tam bir şarj ve deşarjın 2 saatte gerçekleştiği oran) sürekli olarak döngüye tabi tutulmuştur. Bu veri seti, farklı döngü koşullarında hücre performansını ve yaşlanmasını incelemek için kullanılmıştır.

Dechent-2017 ve Dechent-2020 veri setleri, hücreler arası değişkenlik çalışmaları için değerli veriler sağlamaktadır. Bu veri setleri, bataryaların performansını ve yaşlanmasını farklı koşullar altında inceleyerek, hücreler arasındaki tutarsızlıkların nedenlerini ve bu tutarsızlıkların batarya ömrü üzerindeki etkilerini anlamak için kullanılmıştır [211].



Şekil 2.17: Eşdeğer tam döngülerinde kalan kapasite ve darbe direnci (316,317,318,319) [212]


2.5.7. Sauer-2021

Sauer-2021 veri seti[213], nominal kapasitesi 2.05 Ah olan 48 adet aynı şekilde kullanılan, nominal olarak aynı Sanyo/Panasonic UR18650E hücrelerini içermektedir. Bu hücreler, lityum nikel mangan kobalt oksit pozitif elektrotlara ve grafit negatif elektrotlara sahiptir [95] [214]. Bu veri seti, hücreler arası değişkenlik çalışmasının bir parçası olarak Bölüm 4'te ve Ek C.4'te incelenmiştir.

Bu veri seti, ilk olarak Baumhöfer-2014 olarak adlandırılan bir çalışmada kullanılmış ve yazarın adı ile yayının tarihine atıfta bulunulmuştur [215]. Ancak, 2021 yılında veri setinin tamamı ayrı olarak yayınlandığı için bu çalışmada Sauer-2021 olarak adlandırılmıştır [213].

Sauer-2021 veri seti, batarya hücrelerinin performans ve yaşlanma süreçlerindeki hücreler arası değişkenliği incelemek için kullanılmıştır. Bu veri seti, hücreler arasındaki tutarsızlıkların nedenlerini anlamak ve bu tutarsızlıkların batarya ömrü üzerindeki etkilerini değerlendirmek

için değerli veriler sunmaktadır. Bu veri seti, batarya araştırmalarında önemli bir referans olarak kullanılmıştır.



Şekil 2.18: 48 hücrenin kapasite bozulma eğrileri, diz noktalarını ve iki farklı EOL döngü sayısındaki varyasyonları vurgular[216].

Bu veri setinin yayınlanması, batarya teknolojilerinin gelişimine katkıda bulunmakta ve araştırmacıların hücreler arası değişkenliği daha iyi anlamalarına olanak tanımaktadır. Sauer-2021, batarya performansını optimize etmek ve güvenilirliğini artırmak için yeni stratejilerin geliştirilmesine yardımcı olmaktadır.

2.6. GİRİŞ PARAMETRE ÖZELLİKLERİ

Denetimli regresyon biçimindeki veriye dayalı modelleme, girdi-çıkı çiftlerine dayanarak girdileri çıktılarına eşleştirir. Genellikle, bu girdiler ham verinin kendisi yerine özelliklerdir. Pil literatüründe kullanılan giriş özellikleri, çeşitli özellik setlerinden oluşur ve bu özelliklerin seçimi, modellerin performansını önemli ölçüde etkileyebilir.

2.6.1. Literatürde kullanılan Giriş Özellikleri

Girdi özellikleri, x sütun vektörünün girişlerini oluşturur. Makine öğrenme yöntemleri genellikle doğrudan ham döngü verilerini kullanırken[217], regresyon araçları için özet özellikler gereklidir. Ham veriler genellikle yüksek frekansta kaydedilir ve bu nedenle veriler özetlenmelidir.

Zaman, döngü sayısı, şarj geçişi gibi girdi özellikleri sıklıkla kullanılır[218]. Örneğin, bir veri setinde zaman ile döngü sayısı arasında yüksek korelasyon olabilir[219]. Şarj geçişi de regresyon sağlık modellerinde önemli bir değişkendir. NASA-2014 veri setinde zaman ve şarj geçişi, yaşlanmanın en iyi tahmin edicileri olarak bulunmuştur[220].

Sıcaklık, lityum iyon bozulmasında bilinen bir faktördür ve yaygın olarak bir girdi özelliği olarak kullanılmaktadır[221]. Sıcaklık temelli girdi özellikleri genellikle ya hücre sıcaklığını açıkça kullanmayı ya da belirli şarj/deşarj koşullarına karşı sıcaklık tepkisini ölçmeyi içerir[222]. Ancak, lityum iyon hücresi testlerinin gerçekleri, test boyunca ortam sıcaklığının kontrol altında ve tutarlı olduğu anlamına gelir ve ayrıca sıcaklığı doğru bir şekilde ölçmekle ilgili önemli sorunlar olabilir.

Gerilim tabanlı özellikler, özellikle Sağlık Durumu (SoH) tahmini için, pil sağlığı modelleri için en yaygın girdiler arasındadır. Sürekli akım (de)şarj profilleri rutin olarak kullanılmakta, verilerde varsa sabit gerilim aşamaları da değerlendirilmektedir. Gerilim tabanlı değişkenler arasında belirli bir zaman aralığında gerilim farkı[223], belirli bir gerilim değişimi için zaman farkı[223], sabit akım altında gerilim eğrisinin eğimi [224]ve sabit gerilim işlemi sırasında belirli bir akım aralığını kat etmek için geçen süre bulunmaktadır[225]. Başka bir gerilim tabanlı girdi özelliği, belirli şarj durumu aralıklarına maruz kalma durumudur, bu durum gerilim, şarj durumu veyadeşarj derinliği ölçümleri kullanılarak gözlemlenebilir[226].


Akım ve güç, herhangi bir hücrenin ana kontrolleridir, ancak bu özellikler literatürdeki Sağlık Durumu (SoH) modellerinde sadece nispeten az sayıda kullanılmıştır[227]. Bu tezde, akım ve güç özellikleri, akım veya güçten en az birinin bilgisinin uygulama tarafından yönlendirileceği düşüncesiyle girdiler olarak dahil edilmiştir. Akım, SoH tahmin modellerinde dolaylı olarak yer almıştır. Bu modeller, tam kapasiteyi tahmin etmek için bir şarj döngüsünün bir alt kümesinden kapasiteyi girdi olarak kullanır[228].

Diferansiyel gerilim analizi ve artımsal kapasite analizi, sağlık durumunu anlamak için sabit (de)şarj sırasında gerilim ve şarj geçişi arasındaki ilişkinin türevlerini kullanan tekniklerdir. Zirve konumu, zirve yüksekliği ve belirli aralıklar boyunca integraller, bozulma modellemesi için girdi olarak değerlendirilmiştir[229]. Türev tabanlı girdiler detaylı içgörüler sağlayabilir ancak yüksek kalitede veri gerektirir[230]. Enerji-sinyali veya örnek entropi gibi karmaşık özellikler de kullanılmıştır[222] ancak veri kalitesi üzerindeki talepleri nedeniyle burada benzer şekilde dikkate alınmamıştır.

2.6.2. Giriş Parametre Seçiminin Etkisi


Veri odaklı yaklaşımlar kullanıma bağlı işlevleri olan ve farklı kullanım durumlarına uygun girdi özellikleri üretmeyi amaçlar. Örneğin, bir elektrikli araç (de)şarj olmadan uzun süreler bekleyebilirken, bir şebeke depolama sistemi sürekli olarak kullanılabilir. Girdi özellikleri, veri

kalitesinin düşmesine karşı dayanıklı olması ama ana bozulma faktörlerini yakalamak için yeterince detaylı kalmaları gereken bir şekilde tasarlanmalıdır.



Şekil 2.19: NASA-2014 verileri ile iyi girdi özellikleri durumu, kötü girdi özellikleri durumu ve her ikisinin kombinasyonu arasındaki tahmin performansının karşılaştırılması [220].

Girdi özelliği seçimi, bir regresyon modelinde girdi verilerinin x içinde hangi unsurlarının olacağını tanımlama sürecidir. Şekil 2.19, veri tabanlı bir regresyon modeli kullanarak NASA-2014 verileri üzerinde kötü bir girdi özelliği seçiminin etkisini göstermektedir. Şekil 2.19'daki özellikler, tümü referans [231]'den olup 'iyi' ve 'kötü', daha önce daha önemli veya daha az önemli bulunan özellikler olarak tanımlananlardır. Şekil 2.19, kötü bir veri odaklı modelin bile makul sonuçlar üretebileceğini güzel bir şekilde göstermektedir.



Şekil 2.20: NASA-2014 verileri için iyi bir eğitim hücresi seçiminin tahmin performansı ile kötü bir seçimin ve her ikisinin kombinasyonunun karşılaştırılması [220].

Her eğitim hücresi, girdi veri dizisinin birkaç satırına katkıda bulunur. Girdi özelliklerinin seçimine karar verme yeteneğinin aksine, genellikle hangi hücrelerin eğitim setinde olacağına karar verme şansımız olmaz, ancak eğitim hücrelerinin uygunluğu eşit derecede etkileyici olabilir. Şekil 2.20, 'iyi' ve 'kötü' hücrelerin sırasıyla test hücresine benzer veya farklı kullanım protokollerine tabi tutulduğu kötü hücre seçiminin olası etkisini göstermektedir. Sonuç, 'kötü' hücreleri modeli eğitmek için kullanırken farklı bir bozulma eğrisine sahip oldukları için kötü bir tahmin olmuştur.

Bu tezde Sağlık Durumu (SoH) tahminine yönelik tüm denemeler, bir SoH geçiş modeli kullanılarak gerçekleştirildi, bu nedenle hedef değişkeni ardışık zaman değerleri arasındaki hücre kapasitesindeki değişiklikler ΔQ idi. Eğitim seti, yalnızca belirli bir test noktasına eşit yaşta olan hücrelerden veri noktalarını içermesi durumunda iyi bir tahmin üretebilir. Bu, bazı ayrık zaman dilimlerindeki bozulmanın hücre geçmişinin bir işlevi olmadığını varsayar, ancak geçmiş kullanımı bir girdi olarak eklenmediği sürece geçiş modelleri, aynı şekilde kullanılan eğitim ve test hücrelerini gerektirmediği için iyi eşleşmiş hücrelere duyulan ihtiyacı azaltır. ΔQ 'yi hedefleme, literatürde SoH tahmini için başarılı olmuştur[218], ancak açıklayıcı girdi özellikleri üretme ihtiyacını ortadan kaldırmaz.

2.7. TAHMİN PERFORMANSININ NİCELENDİRİLMESİ

Bu bölümde, uygulanan tahmin modellerinin performansını değerlendirmek amacıyla kullanılan bazı model değerlendirme ölçümleri tartışılmaktadır. Literatürde çok sayıda model değerlendirme ölçütü önerilmiştir, ancak her bir metriğin bir modeli yorumlamak için kendi avantajları ve dezavantajları bulunmaktadır. Bu nedenle, sonuçların önemine ve açıklanabilirliğine göre bu model değerlendirme ölçütlerinden bazıları seçilmiştir.

Model değerlendirme ölçütlerinin seçimi, tahmin modellerinin performansının doğru ve kapsamlı bir şekilde anlaşılması açısından kritik bir öneme sahiptir. Her bir değerlendirme metriği, modelin belirli yönlerini vurgulamakta ve farklı performans özelliklerini ortaya koymaktadır. Bu çalışmada, literatürde yaygın olarak kullanılan ve kabul görmüş model değerlendirme ölçütleri dikkate alınmış ve bu ölçütlerin uygulanabilirliği ve sonuçların açıklanabilirliği göz önünde bulundurularak seçim yapılmıştır.

Bu yaklaşımla, tahmin modellerinin performansının daha objektif ve derinlemesine analiz edilmesi hedeflenmiştir. Seçilen değerlendirme ölçütlerinin, modelin genel performansını, doğruluğunu, genelleme yeteneğini ve istikrarını kapsamlı bir şekilde yansıtması amaçlanmıştır. Bu şekilde, tahmin modellerinin farklı senaryolarda nasıl performans gösterdiği daha iyi anlaşılabilir ve iyileştirilmesi gereken alanlar daha net bir şekilde belirlenebilir.

2.7.1.1. Ortalama Mutlak Hata (MAE)

MAE, tahmin edilen değerler ile gerçek değerler arasındaki ortalama mutlak farkı ölçer. Bu metriğin hesaplanması, tüm tahmin hatalarının mutlak değerlerinin ortalamasının alınmasıyla gerçekleştirilir. MAE, tahmin hatalarının büyüklüğünü doğrudan yansıtır ve kolay anlaşılabilir

bir hata ölçüsüdür. Ancak, büyük hatalar ile küçük hatalar arasındaki farkı ayırt edemez. y_i ve $\hat{y}_i$ sırasıyla i . örnek için gerçek ve tahmin edilen veriyi ifade etmektedir.

$$MEA = \sum_{k=1}^N \frac{|y_i - \hat{y}_i|}{N} \quad (2.21)$$

2.7.1.2. Ortalama Mutlak Yüzde Hatası (MAPE)

MAPE, tahmin edilen değerlerin gerçek değerlere olan yüzdesel hata oranlarının ortalamasını hesaplar. Bu metrik, hataların yüzde cinsinden ifade edilmesiyle değerlendirme yapar ve farklı ölçeklerdeki veri setleri arasında karşılaştırma yapmayı kolaylaştırır. MAPE, gerçek değerın sıfıra yakın olduğu durumlarda büyük hata yüzdeleri üretebilir ve bu nedenle dikkatli kullanılmalıdır.

$$MAPE = \frac{100}{N} \sum_{k=1}^N \frac{|y_i - \hat{y}_i|}{|y_i|} \quad (2.22)$$

2.7.1.3. Kök Ortalama Kare Hatası (RMSE)

RMSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların karesinin ortalamasının karekökü olarak hesaplanır. Bu metrik, büyük hataları daha fazla vurgular çünkü hataların karesi alınır. RMSE, modelin tahminlerinde büyük sapmalar olup olmadığını belirlemek için kullanışlıdır. Ancak, hataların büyüklüğüne karşı daha duyarlıdır ve bu nedenle MAE ile birlikte kullanılması önerilir.

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_i - \hat{y}_i)^2} \quad (2.23)$$

2.7.1.4. Determinasyon Katsayısı (R^2)

R^2 , modelin tahmin ettiği değerlerin gerçek değerlere olan uyumunu ölçen bir metriktir. 0 ile 1 arasında bir değer alır ve 1'e ne kadar yakınsa, modelin tahminlerinin gerçek değerlere o kadar yakın olduğu anlamına gelir. R^2 , modelin açıklayabildiği toplam varyansın oranını gösterir.

Ancak, yalnızca belirli bir veri seti için geçerli olup, modelin genelleme yeteneğini doğrudan yansıtmayabilir.

$$\bar{y} = \frac{1}{N} \sum_{k=1}^N y_i \quad (2.24)$$

$$SS_{tot} = \sum_{k=1}^N (y_i - \bar{y})^2 \quad (2.25)$$

$$SS_{res} = \sum_{k=1}^N (y_i - \hat{y}_i)^2 \quad (2.26)$$

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (2.27)$$

2.7.1.5. Model Çalışma Süresi (MRT)

Modelin çalışma süresi, modelin eğitimi ve tahminleri gerçekleştirme süresini ifade eder. Bu metrik, modelin hesaplama verimliliğini ve pratik uygulanabilirliğini değerlendirmek için önemlidir. Özellikle büyük veri setleri ve gerçek zamanlı uygulamalar için modelin çalışma süresi kritik bir faktördür. Çalıştırma süresi, modelin karmaşıklığını ve performansını değerlendirirken dikkate alınmalıdır.

Bu ölçütler, tahmin modellerinin performansını kapsamlı bir şekilde değerlendirmek için kullanılacak ve her bir modelin güçlü ve zayıf yönlerini belirlemek amacıyla detaylı analizler yapılacaktır.

2.8. MAKİNE ÖĞRENMESİ MODELLERİ

Bu bölümde, lityum iyon pillerin (LIB) kalan kullanım ömrünü (RUL) tahmin etmek için Destek Vektörü Regresyon (SVR), Uzun Kısa Süreli Bellek (LSTM) Ağı ayrıntıları açıklanacaktır.

2.8.1. Destek Vektör Regresyonu (SVR) Genel Bakış

Destek Vektör Makineleri (SVM), en çok kullanılan makine öğrenimi modellerindendir ve gözetimli öğrenme algoritmaları oldukları için regresyon ve sınıflandırma sorunlarını çözmek

için kullanılabilirler[232]. Bu modeller, regresyon için destek vektörleri olarak bilinen bazı giriş özellik noktalarını belirleyerek ve maksimum marj sınıflandırıcısı oluşturularak iki sınıfı birbirinden ayırır. Sınıflar doğrusal olarak ayrılabilir olmadığında, doğrusal olmayan etiketleri sınıflandırabilen bir çekirdek fonksiyonu ile SVM sınıflandırıcısı birlikte eğitilebilir.

Destek Vektör Regresyonunda (SVR), sınıflandırma için optimize edildiği gibi bir genelleme sınırı oluşturulur ve bu sınırı optimize etmek hedeflenir. SVR kayıp fonksiyonu, gerçek değerlerin belirlenmiş bir aralığı içindeki hataları göz ardı eden ε -duyarsız fonksiyonudur. 2.17 denklemi, eğitim gözlemleri için hata maliyetlerini temsil eder. Hata, ε bandı içindeki gözlemler için sıfırdır.

$D(X, Y)$ kümesine ait n adet giriş ve çıkış veri çiftinin gözlemine sahip olduğunda, giriş veri vektörü x_i için, ideal durumda y_i 'ye eşit olması gereken bir çıktı değeri olan $\hat{y}_i$ tahmin edilir. Burada $y_i \in Y$ ve x_i , k özellikleri temsil eden k boyutlu giriş vektörüdür $x_i = (x_{i1}, x_{i2}, \dots, x_{ik})$, böylece $x_i \in X$.

Destek Vektör Regresyonu ile ilgili matematiksel arka plan ve denklemler, araştırma çalışmalarından elde edilmiştir [232], ve [233].Girdi x , çekirdekler olarak bilinen doğrusal olmayan eşleştirmeler kullanılarak m boyutlu bir özellik alanında temsil edilir. SVR algoritması daha sonra bu m boyutlu uzayda bir doğrusal model oluşturur. Bu aşağıda gösterildiği gibi ifade edilebilir.

$$f(x, w) = \sum_{j=1}^m w_j g_j(X) + b \quad (2.28)$$

Burada $j = 1, \dots, m$ için $g_j(x)$ doğrusal olmayan dönüşümlerin kümesidir, w_j her birinin ağırlığıdır ve b sabit terimi temsil eder. SVR eğitiminde kullanılan bir ε -duyarsız kayıp fonksiyonu vardır. Bu kayıp fonksiyonu, y ile $f(x, w)$ arasındaki farkın ε 'den küçük veya buna eşit olduğu durumlarda sıfır, aksi takdirde y ile $f(x, w)$ arasındaki farkın ε 'den çıkarılmış değeri olarak tanımlanır.

$$L(y, f(x, w)) = \begin{cases} 0, & \text{eğer } |y - f(x, w)| \leq \varepsilon \\ |y - f(x, w)| - \varepsilon, & \text{diğer} \end{cases} \quad (2.29)$$

Giriş x , m boyutlu bir uzaya eşlendiğinde, SVR algoritması en küçük kareler regresyon modeline uygun bir çizgi bulmaya çalışır. Dolayısıyla, en küçük kareler regresyonundan kayıp

minimizasyon fonksiyonu kullanılabilir ve bu fonksiyon, en küçük kareler regresyonunun kayıp fonksiyonu olan $\|w\|^2$ ile, ε -duyarsız bandın dışındaki eğitim örneklerinin sapmalarını hesaplamak için kullanılan slack değişkenleri içerir. Ana amaç, slack değişkenleri kullanarak ε -duyarlı bandın dışındaki eğitim örneklerinin sapmalarını hesaplamaktır. SVR optimizasyon problemi, y ile $f(x, w)$ arasındaki farkın ε ile $\varepsilon + \xi_i^*$ arasında olmasını sağlayacak şekilde, w 'nin normunun karesinin yarısı ile C 'nin çarptığı ξ_i ve ξ_i^* toplamalarının minimizasyonunu içerir. ξ_i ve ξ_i^* 'nin her biri için sıfırdan büyük veya buna eşit olması koşulu altında.

$$\begin{aligned} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\ y - f(x, w) \leq \varepsilon + \xi_i^* \\ f(x, w) - y \leq \varepsilon + \xi_i \\ \xi_i, \xi_i^* \geq 0, i = 1, \dots, n \end{aligned} \quad (2.30)$$

C parametresi, model karmaşıklığını kontrol etmek için seçilebilir. Aynı zamanda hedef fonksiyon optimizasyonundaki sapmaların izin verilen aralığını da kontrol edebilir. Kısıtlı optimizasyon teorisinden yararlanarak, bu optimizasyon problemi çift probleme dönüştürülebilir ve Lagrange çarpanı kullanılarak nihai çözüm elde edilir.


$$f(x) = \sum_{i=1}^{n^*} (a_i - a_i^*) \langle x_i, x \rangle \quad (2.31)$$

Lagrange çarpanları a_i ve a_i^* olan n^* seti, destek vektörleri olan giriş örneklerinin kümesidir ve $\langle x_i, x \rangle$; x_i ve x gözlemlerinin iç çarpımıdır. Lagrange çarpanlarından tam olarak birinin sıfırdan büyük olduğu girdi örnekleri, destek vektörleridir. Denklem 2.20'deki iç çarpım, şu şekilde tanımlanan çekirdek fonksiyonu aracılığıyla eşlenir:

$$K(x_i, x) = \sum_{j=1}^m g(x) g(x_i) \quad (2.32)$$

SVR algoritması tarafından döndürülen çözüm seyrek, yani sadece birkaç giriş örneği destek vektörleri olarak tanımlanır. a_i ve a_i^* , ε -duyarlı bandın içindeki örnekler için sıfır olacak şekilde tüm örneklerde sıfır olur. Bir SVR modelinin hiper parametreleri C , ε ve çekirdek(kernel)


tipidir. Yaygın olarak kullanılan çekirdekler doğrusal çekirdek, polinom çekirdek, hiperbolik tanjant çekirdek ve radyal taban fonksiyonu (RBF) çekirdeğidir.



Şekil 2.21: SVM' de ϵ - duyarsız bant[234].

2.8.2. Uzun Kısa Süreli Bellek (LSTM) Ağı Genel Bakış

Uzun Kısa Süreli Bellek sinir ağı (LSTM), RNN' nin bir uzantısı veya iyileştirilmiş versiyonudur. RNN kullanmanın belirgin sorunlarından biri, orijinal RNN' nin geri yayılım sürecinde aktivasyon fonksiyonunun türevlerini biriktirebilmesi ve bu durumun doğru bir modelden sapmalara neden olabilmesidir. Daha da önemlisi, RNN genellikle "hafıza kaybı" sorunu ile karşı karşıya kalır. Bu durum, RNN' nin "gelecek" zaman adımlarının, ilk girdilerin sanal hafızasını artık içermemesine yol açar. Bu sorunların tümü, RNN ağındaki 'zaman adımlarının sayısı' bağlantı ve katman sayısı için çok büyük olduğunda ortaya çıkar. LSTM bu problemleri ortadan kaldırmak için RNN üzerine geliştirilmiş bir sinir ağıdır. Bir giriş sinyal katmanı, bir LSTM hücresinden oluşan gizli katman ve gizli katmandaki hücrelerin çıktıları ile beslenen bir çıkış katmanından oluşur. Bir LSTM ağı tipik olarak birçok LSTM hücresi içerir. Bir LSTM hücresinin mimarisi Şekil 2.22'de gösterilmiştir.



Şekil 2.22: LSTM Hücre Mimarisi

Şekil 2.22'de, x_t zaman noktasındaki giriş sinyal vektörünü, C_{t-1} ve C_t sırasıyla t-1 ve t zaman noktalarındaki hücre durumlarını temsil eder. Aynı şekilde, h_{t-1} ve h_t sırasıyla t-1 ve t zaman noktalarındaki hücrenin çıkış sinyalleridir. Sembol “x” sinyallerin çarpımını, sembol “+” ise sinyallerin toplamını temsil eder.

Bir LSTM hücresi, hücrenin çıktısının üretildiği zaman noktası olan t zaman noktasında çalışır ve hücrenin önceki durumunu temsil eden önceki zaman noktası t-1 de çalışır. LSTM, matematiksel olarak Denklem 2.32 gösterildiği gibi bir L fonksiyonu olarak modellenenir.

$$(h_t, C_t) = L(h_{t-1}, C_{t-1}, x_t) \quad (2.33)$$

- x_t : t anındaki giriş sinyal vektörüdür. LSTM hücresine beslenen girişlerden biridir.
- C_{t-1} : t-1 anındaki hücrenin hafızadaki değeridir. Aynı zamanda hücrenin t-1 noktasındaki durumudur. LSTM hücresine beslenen diğer giriş parametresidir.
- h_{t-1} : t-1 anındaki hücrenin çıkış değeridir. LSTM hücresinin giriş parametresidir.
- C_t : t anındaki hücrenin hafıza durumudur. LSTM hücresinin bir çıktısıdır.

- h_t : t anındaki hücrenin çıkış sinyalidir. LSTM hücresinin bir diğer çıktısıdır.

LSTM hücresinin t zaman noktasında ürettiği çıktılar, t+1 zaman noktasında aynı hücreye tekrar giriş olarak verilir. Ayrıca, giriş vektörü x_t unsurları, herhangi bir zaman noktasında hücreye beslenir.

LSTM hücresindeki çarpma kapıları (x ile gösterilen) bilgi yayılımının kontrolü ve çıktı üretiminde önemli bir rol oynar. Soldan ilk çarpma kapısı, önceki zaman noktasından mevcut zaman noktasına aktarılabilecek bellek miktarını hesaplar. Önceki zaman noktasından mevcut zaman noktasına aktarılabilecek bu bellek miktarı, y_1 sinyalinin değerlerine bağlıdır. İkinci çarpma kapısı, mevcut zaman noktasındaki C_t hücre durumunu temsil eden bilgi miktarını kontrol eder. Üçüncü çarpma kapısı, hücrenin C_t ve y_4 'ün hiperbolik tanjant aktif değerinin ürünü olan h_t 'ti hesaplar.

Bu süreçte, hücrenin bellek durumu ve çıktıları, zaman içinde hatırlama ve öğrenme kapasitesini optimize etmek amacıyla düzenlenir. Bu kapı mekanizmaları, LSTM hücresinin uzun süreli bağımlılıkları etkin bir şekilde öğrenmesini ve unutma sorunlarını aşmasını sağlar. Böylece, LSTM ağları, tekrarlayan sinir ağlarının (RNN) yaşadığı vanishing gradient (kaybolan gradyan) sorununu büyük ölçüde çözer ve daha derin ve uzun süreli dizilerle çalışabilir.

Bir LSTM hücresi, oluşturulan ara sinyallere dayanarak hesaplama birimlerine ayrılabilir. Şekil 2.22'de gösterildiği gibi, bir LSTM hücresi dört hesaplama birimine ayrılabilir. Ara sinyaller y_1, y_2, y_3 ve y_4 ile çıktı sinyalleri C_t ve h_t , ağırlıklar ve vektörler kullanılarak matematiksel olarak temsil edilebilir. Ağırlıklar, çift indeks kullanılarak ifade edilebilir; burada birinci indeks, ara sinyallerin kimlik belirleyicisini ($y_i, i \in [1,2,3,4]$) temsil eder. İkinci indeks ise giriş sinyalinin sembolüdür. Örneğin $w_{2h}; h_{t-1}$ 'in giriş sinyalini alan ikinci kapının ağırlığını temsil eder. Bu notasyonla, ara sinyaller y_1, y_2, y_3 ve y_4 aşağıdaki gibi matematiksel olarak temsil edilebilir.

$$y_1 = \sigma(w_{1h}h_{t-1} + w_{1x}x_t + w_{10}) \quad (2.34)$$

$$y_2 = \sigma(w_{2hc}C_{t-1} + w_{2h}h_{t-1} + w_{2x}x_t + w_{20}) \quad (2.35)$$

$$y_3 = \tanh(w_{3c}C_{t-1} + w_{3h}h_{t-1} + w_{3x}x_t + w_{30}) \quad (2.36)$$


$$y_4 = \sigma(w_{4hc}C_t + w_{4h}h_{t-1} + w_{4x}x_t + w_{40}) \quad (2.37)$$

Denklem 2.35 da tanh hiperbolik aktivasyon fonksiyonunu temsil eder ve σ sigmoid aktivasyon fonksiyonunu temsil eder. Çıkış sinyali h_t ve hücresinin hafıza durumu C_t matematiksel olarak aşağıdaki gibi temsil edilir:

$$C_t = y_2 y_3 + C_{t-1} y_1 \quad (2.38)$$

$$h_t = (y_4) \tanh(C_t) \quad (2.39)$$

Şekil 2.23, LSTM' nin yinelenen işlemini, zaman içinde sinyallerin derin ileri beslemeli yayılımı olarak temsil eder. Bir LSTM ağı eğitildiğinde, kayıp fonksiyonunun gradyanı, zaman içinde geri yayılım (Back Propagation Through Time- BPTT) kullanılarak hesaplanır. BPTT, farklı zaman noktalarındaki belirli bir giriş sinyali için Şekil 2.23'te gösterildiği gibi, bir zaman penceresi T içinde gerçekleştirilir. Ağ eğitimi sırasında, bireysel LSTM hücrelerinin ağırlıkları ve önyargıları (bias) uyarlanır.



Şekil 2.23: Bir LSTM ağında zaman içinde ileriye doğru yayılımın gösterimi

Bir LSTM ağı, ağı bir dizi özellik ve bunların karşılık gelen etiketleri giriş olarak vererek denetimli bir modda eğitilir. Genellikle Adam, AdaGrad veya Stokastik Gradyan İnişi (SGD) gibi gradyan iniş algoritmaları eğitimde kullanılır. Giriş vektörleri LSTM ağına beslenir, daha sonra gizli katmanlarda işlenir ve çıktı hesaplanır. Hesaplanan çıktı ile gerçek çıktı arasındaki hata temel alınarak bir kayıp fonksiyonu oluşturulur ve bu hata, gradyan hesaplamasının bir parçası olarak LSTM ağı boyunca geri yayılır.

3. YÖNTEM

Elektrikli araçlarda yaşlanmaya neden olabilecek içsel ve dışsal faktörler literatürde kapsamlı bir şekilde ele alınmıştır. Bu tez çalışmasında, elektrikli araçlarda karşılaşılabilecek dış kaynaklı bir hata modu olan busbar bağlantı cıvatalarındaki tork kaybının, batarya hücrelerinin yaşlanma dağılımlarına etkileri değerlendirilecektir. Çalışmanın temel amacı, busbar bağlantı noktalarında tork kaybı nedeniyle oluşan yüksek kontak direnci ve buna bağlı yüksek sıcaklık koşulları altında batarya hücrelerini dışsal etkilerle yaşlandırmak, bu durumun modül içindeki hücreler arası homojen ısı dağılımını bozma potansiyelini analiz etmek ve yüksek sıcaklık altında yaşlanan hücrelerin modül yapısında bozulmayı hızlandırıcı etkilerini incelemektir. Modüllerin yaşlanma eğilimlerinin prognostik tahmini için Destek Vektör Regresyonu (SVR) ve Uzun Kısa Süreli Bellek (LSTM) yöntemleri kullanılacak olup, araç sağlık durumu maksimum kat edilebilir mesafe cinsinden öngörülme çalışılacaktır.

3.1. TEST ALTYAPISI VE VERİ TOPLAMA SİSTEMİ

Bu tez çalışması kapsamında, Tablo 3.1'de bilgileri verilen NMC (Nikel Manganez Kobalt) kimyasına sahip 8 adet lityum iyon hücre hızlandırılmış yaşlanma testine tabi tutulmuştur. Hücre test sistemi için Neware marka iklimlendirme kabinleri ve Chroma marka cyclerlar kullanılmıştır.

Test sistemi, belirlenen profillere göre bataryaların şarj ve deşarj işlemlerini gerçekleştirmektedir. Şarj ve deşarj sürecinde, bataryalardan sıcaklık, gerilim ve akım ölçümleri yapılmakta ve bu veriler test bilgisayarı tarafından TCP/IP protokolü toplanarak kaydedilmektedir. Normal koşullarda sistemin ölçüm frekansı 1Hz olarak ayarlanmıştır. Ancak her 10 çevrimde bir, bataryaların iç direnci ve kapasite ölçümlerini yeniden gerçekleştirmek için RPT (Rutin Performans Test) uygulanmaktadır. RPT testleri sırasında 1kHz frekansta veri toplama işlemi gerçekleştirilmektedir. Bu sayede, bataryaların performansındaki değişiklikler düzenli aralıklarla izlenebilmekte ve yaşlanma süreçleri daha detaylı bir şekilde analiz edilebilmektedir.

Bu çalışmada kullanılan test sistemi, bataryaların şarj ve deşarj işlemleri sırasında oluşabilecek olası anormalliklerin tespit edilmesine ve hücrelerin yaşlanma süreçlerinin daha doğru bir şekilde analiz edilmesine olanak tanımaktadır. Neware marka iklimlendirme kabinleri,

bataryaların sabit sıcaklık koşullarında test edilmesini sağlarken, Chroma marka cyclerlar ise yüksek hassasiyetli şarj ve deşarj işlemlerini gerçekleştirmektedir. Bu kombinasyon, bataryaların gerçek kullanım koşullarına yakın bir ortamda test edilmesini ve elde edilen verilerin güvenilirliğini artırmaktadır.

Tablo 3.1: Test için kullanılan hücre bilgileri

Performans	Özellikler
Kapasite (+/- %1.5)^	74.8 Ah
Enerji (+/- %1.5)^	273 Wh
Nominal Gerilim	3.65 V
Döngü Ömrü (80% BOL)^	>1000 döngü
Çalışma Sıcaklığı	-30°C ila 60°C
Enerji Yoğunluğu	287 Wh/Kg
Enerji Yoğunluğu*	625 Wh/L

Deşarj Özellikleri	Özellikler
Minimum Gerilim	2.75 V
Maksimum Akım (sürekli @25°C)	220 A
Maksimum Akım (tepe, 10 sn. @25°C)	325 A

Şarj Özellikleri	Özellikler
Şarj Yöntemi	CC-CV
Maksimum Akım (sürekli @25°C)	36.5 A
Sabit Gerilim	4.15 - 4.20 V
Şarj Kesme	3.65 A



Şekil 3.1: Test alt yapısı ve veri toplama sistemi bilgisayar arayüzü

Ayrıca, her 10 çevrimde bir yapılan iç direnç ve kapasite ölçümleri, bataryaların performansında zamanla meydana gelen değişikliklerin yakından izlenmesine olanak tanımaktadır. Bu sayede, bataryaların ömrü boyunca performans kaybı eğilimleri belirlenebilmekte ve yaşlanma sürecine etki eden faktörler daha detaylı bir şekilde incelenebilmektedir.



Şekil 3.2: Numune Hazırlama Prosesi

3.2. VERİ SETİNİN ÖZELLİKLERİ

Tez çalışması kapsamında elektrikli araçlarda kullanılan 8 adet lityum iyon batarya (C1, C2, C3, C4, C5, C6, C7, C8) çeşitli şarj ve deşarj döngülerine tabi tutularak yaşlandırılmıştır. Genel olarak, bataryaların ilk kapasite değerlerinin %80'ine düştüğü zaman ömrünün sonuna geldiği kabul edilir. C8 hariç, diğer tüm bataryalar ömürlerinin başlangıcından (BOL) sonuna (EOL) kadar döngülere maruz bırakılmıştır. C8 test sırasında yüksek basınç ve sıcaklıktan dolayı izolasyon kaçağı yaşayarak kapasite kaybı yaşamadan ömrünün sonuna ulaşmıştır. Veri setindeki pillerin her biri için veri özellikler aşağıdaki tabloda sıralanmıştır:

Tablo 3.2: Veri Seti Açıklamaları

Time:	Kaydedilen bitiş zamanını ifade eden bir zaman girdisidir.
SOC_init_p:	İlk Şarj Durumu (SOC) değeri, SOC ile Açık Devre Voltajı (OCV) ilişkisine dayanır. Yüzde olarak ifade edilir.

SOC_avg_p:	Ortalama Şarj Durumu (SOC), ortalama SOC değerine dayanır. Yüzde olarak ifade edilir.
SOC_end_p:	Son Şarj Durumu (SOC) değeri, Coulomb Sayımına (CC) dayanır. Yüzde olarak ifade edilir.
DOD_p:	Deşarj Derinliği (DOD), ilk SOC değeri ile son SOC değeri arasındaki farktır. Yüzde olarak ifade edilir.
T_cell_min_C:	Döngünün minimum hücre sıcaklığıdır. Derece Celsius olarak ifade edilir.
T_cell_avg_C:	Döngünün ortalama hücre sıcaklığıdır. Derece Celsius olarak ifade edilir.
T_cell_max_C:	Döngünün maksimum hücre sıcaklığıdır. Derece Celsius olarak ifade edilir.
T_amb_avg_C:	Döngünün ortalama çevre sıcaklığıdır. Derece Celsius olarak ifade edilir.
Crate_avg:	Döngüdeki ortalama akım değeri, başlangıç kapasitesine göre hesaplanır. Saat başına olarak ifade edilir.
Crate_RMS:	Döngüdeki ortalama kare kök (RMS) akım değeri, başlangıç kapasitesine göre hesaplanır. Saat başına olarak ifade edilir.
Crate_max:	Döngüdeki maksimum akım değeri, başlangıç kapasitesine göre hesaplanır. Saat başına olarak ifade edilir.
Ctp_CC_Ah:	Döngüdeki sabit akımlı şarj geçişinin Coulomb Sayımına (CC) dayalı bölümüdür. Amper saat (Ah) olarak ifade edilir.
Ctp_Ah:	Döngünün Coulomb Sayımına (CC) dayalı şarj geçişi. Amper saat (Ah) olarak ifade edilir.
Capacity_Ah:	Bataryanın son kaydedilen kapasitesidir. Amper saat (Ah) olarak ifade edilir.
Resistance_Ohm:	%50 SOC' de son kaydedilen direnç, hücre sıcaklığı 22.5-25.5 °C arasında olduğunda. Ohm olarak ifade edilir.
TempCellResistance_mea_C:	Direnç Ohm' un kaydedilen hücre sıcaklığıdır. Derece Celsius (°C) olarak ifade edilir.

Dist_km:	Şarj geçişi ve toplam mesafeye dayanarak tahmini seyahat mesafesidir. Kilometre (km) olarak ifade edilir.
Total_dist_km:	Kümülatif mesafedir. Kilometre (km) olarak ifade edilir.
Total_Ctp_Ah:	Kümülatif şarj verimi. Amper saat (Ah) olarak ifade edilir.
Duration:	Döngünün süresidir. Bir zaman girdisi olarak ifade edilir.
Total_Duraron:	Kümülatif süredir. Bir zaman girdisi olarak ifade edilir

Buna ek olarak veri seti, 8 adet lityum iyon bataryanın (LIB) bozulma verilerinin yanı sıra, şarj ve deşarj sırasında çok yüksek örnekleme hızında elde edilen verileri de içermektedir. Tüm bataryaların her şarj ve deşarj olayı için elde edilen veriler ayrı blf (Binary Logging Format) dosyalarında kaydedilmiştir. Yaklaşık 45000 adet blf dosyası bulunmaktadır. Her blf dosyası aşağıdaki özellikleri içermektedir:

- Hücre Adı: Verinin elde edildiği bataryanın adını temsil eder.
- Zaman: Belirli bir örneğin ölçüldüğü zamanı temsil eder.
- Akım: Ölçülen akım değerini temsil eder. Amper (A) olarak ifade edilir.
- Gerilim: Ölçülen voltaj değerini temsil eder. Volt (V) olarak ifade edilir.
- Sıcaklık: Ölçülen sıcaklık değerini temsil eder. Derece Celsius (C) olarak ifade edilir.
- Şönt Sıcaklığı: Akım ölçümünde kullanılan şönt direncin sıcaklığını temsil eder. Derece Celsius (C) olarak ifade edilir.


3.3. KEŞİFSEL VERİ ANALİZİ

Bir önceki bölümde belirtildiği üzere veri seti 8 adet lityum iyon bataryanın (LIB) tam bozulma geçmişini içerir. Bu bataryalar C1, C2, C3, C4, C5, C6, C7 ve C8 olarak adlandırılmıştır. Bu bataryalar, ömürlerinin sonuna (EOL) ulaşana kadar tekrarlanan şarj, deşarj döngüsüne maruz bırakılmıştır. LIB' ler hakkındaki çoğu araştırmada, %80 SOH' ye kadar bozulmuş bir batarya, ömrünün sonuna ulaştığı kabul edilir.

Bu araştırmada, bir bataryanın %81 SOH' ye kadar bozulduğunda ömrünün sonuna ulaştığını kabul ediyoruz. Veri setindeki C8 bataryası %92 SOH' ye kadar bozulmaya maruz kalmış ve bu batarya ömrünün sonuna kadar bozulmamıştır. Şekil 3.1'den görülebileceği üzere, C8 bataryasının SOH' si (koyu kırmızı ile vurgulanmış) yalnızca %92 SOH' ye kadar bozulmuştur. Bu nedenle, C8 hücresi RuL tahmini çalışmalarının dışında tutulmuştur.

Tablo 3.3: Veri setindeki tüm hücrelerin maksimum Toplam mesafe km değerlerini gösteren tablo.


Batarya_ID	C1	C2	C3	C4	C5	C6	C7
EoL öncesi <i>Total_dist_km</i> değerleri	59.822	55.715	89.100	160.405	179.100	96.400	90.859




Şekil 3.3: SOH (%) - Toplam kat edilen mesafe (km)

Yapılan fiziksel ölçümler sonucunda, farklı tork değerleriyle sıkılmış busbarlarda kontak direnci değerlerinin değiştiği ve bu değişimin batarya hücrelerinin termal performansını etkilediği tespit edilmiştir. Şekil 3.4'te, bağlantı noktası tork değerinin azalması durumunda iki busbar arayüzündeki kontak direncinde meydana gelen artış gösterilmektedir. Artan kontak direnci, şarj ve deşarj döngüleri sırasında ilgili busbarlar üzerinde beklenenden daha yüksek sıcaklık artışlarına yol açmaktadır. Şekil 3.5'te de görüldüğü üzere, busbar sıcaklığı ile kontak direnci arasında güçlü bir korelasyon bulunmaktadır. Bu durum, busbar bağlantı noktasına en

yakın hücrenin diğer hücrelere kıyasla daha hızlı yaşlanmasını tetiklemekte ve modül içerisindeki yaşlanma dengesizliğini artırmaktadır.



Şekil 3.4: Bağlantı civatası Tork Değeri ile kontak direnci arasındaki ilişki



Şekil 3.5: Kontak direnci ile busbar sıcaklığı arasındaki ilişki

3.4. VERİ ÖN İŞLEME VE ÖZELLİK MÜHENDİSLİĞİ

3.4.1. İstenmeyen sütunları kaldırma

Bataryalar C5, C6 ve C7'nin bozulma geçmişlerinde bazı yinelenen özellikler bulunmaktaydı. Bu yinelenen sütunlar kaldırıldı. Yinelenen sütunların kaldırılmasının ardından, tüm bataryaların bozulma geçmişlerinde aynı sayıda özellik bulunmaktadır.

3.4.2. Eksik değerleri işleme

Veri setinde herhangi bir eksik veri bulunmamaktadır. Ancak, veri setinde bazı 'Inf' (Sonsuz) değerleri mevcuttu. Bu değerler, 3'lük hareketli ortalama pencere uzunluğu kullanılarak hesaplanan ortalama değerlerle değiştirildi.

3.4.3. Kapasite değerlerinin normalleştirilmesi

Veri setinde yer alan farklı bataryaların bozulma geçmişlerindeki Capacity_Ah özelliğinin değer aralıkları farklıdır. Veri setindeki tüm bataryaların Capacity_Ah özelliğinin maksimum değerleri Tablo 3.4'te gösterilmektedir. Veri setindeki tüm bataryaların Capacity_Ah özelliği, 0 ile 1 arasında değişecek şekilde normalize edilmiştir. Bu, Min-max ölçeklendirme kullanılarak gerçekleştirilir. Min-max ölçeklendirme, verilen bir özelliği öyle bir ölçeklendirir ki, ölçeklendirilmiş özellik 0 ile 1 arasında değişir. Min-max ölçeklendirmenin denklemi Denklem 3.1'de gösterilmiştir.

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3.1)$$

Burada X' ölçeklendirilmiş özellik, X giriş özelliği, X_{max} giriş özelliği X 'in maksimum değeri ve X_{min} giriş özelliği X 'in minimum değeridir. Normalizasyondan sonra tüm hücrelerin Capacity_Ah değerleri [0, 1] aralığında değişir. Normalizasyon sırasında Capacity_Ah değerleri maksimum değere bölüldüğü için, ölçeklendirilmiş Capacity_Ah değerleri hücrelerin sağlık durumunu (SOH) temsil eder.

Tablo 3.4: Veri kümesindeki tüm hücrelerin maksimum Kapasite Farklı değerlerini gösteren tablo.

Batarya_ID	C1	C2	C3	C4	C5	C6	C7
Maksimum Capacity_Ah değeri	73.743	73.530	72.019	71.426	72.468	72.660	71.866

3.4.4. Pil döngüsünün tanımlanması

Bir bataryanın kalan kullanım ömrü (RUL), genellikle bataryanın bir EV' ye güç sağlayabileceği kalan mesafe veya bataryanın ömrünün sonuna ulaşmadan önceki kalan şarj-deşarj döngü sayısı olarak ifade edilir. Bu araştırmada, bir batarya döngüsü, iki ardışıkdeşarj olayı arasında kaydedilen batarya geçmişindeki olaylar kümesi olarak tanımlanmıştır. Tablo 3.5, yaşlandırma test geçmişinin dosya isimleri ile nasıl ifade edildiğini gösterilmiştir.

Tablo 3.5: Bu araştırmada tanımlanan bir pil döngüsünün tanımını temsil eden tablo. (Dosya_Adı sütunundaki girişler değiştirilir ve kısaltma için yalnızca gerekli sütunlar gösterilir)

Dosya_Adı	Battery_Cycle_No
REST	1
Charge_1.blf	1
REST	1
Discharg_1.blf	1
REST	2
Charge_2.blf	2
REST	2
Discharge_2.blf	2
REST	3
Charge_3..blf	3
REST	3
Discharge_3.blf	3

3.4.5. Yeni özellikler ekleme


Herhangi bir hücre dinlenmeye bırakıldığında, bu Dosya_Adı sütununda "REST" olarak kaydedilir. Bir hücrenin dinlenme süresi, süre ve Dosya Adı sütunları kullanılarak hesaplanır ve yeni bir özellik olan dinlenme süresi oluşturulur.

Batarya bozulma geçmişi veri setindeki Total_dist_km özelliği, EV tarafından kat edilen simüle edilmiş toplam mesafeyi kilometre cinsinden temsil eder. Ortalama C-SUV bir elektrikli aracın 100km yaklaşık 17 kWh harcadığı varsayımına göre, bu çalışmada hücre seviyesinde kWh-km ilişkisi 0,17 kWh/km olarak kabul edilmiştir.

3.4.6. Özellik seçimi ve Toplama


Bir bataryanın kalan kullanım ömrü (RUL), çeşitli faktörlerden etkilenmektedir. Batarya sağlık durumu (SOH) ve şarj durumu (SOC), bir LIB'nin RUL'ini etkileyen önemli faktörler arasındadır (Nuhic ve diğerleri, 2013). Bu nedenle, RUL tahmin modelimiz için girdi özellikleri olarak SOC ve SOH'yi de seçiyoruz. Bu değerler genellikle batarya yönetim sistemi (BMS) tarafından hesaplanır. Batarya iç direnci, bir bataryanın SOH'sini çıkarabileceğimiz önemli sağlık göstergelerinden biridir. Ancak, bir EV'de batarya iç direnci, bataryayı darbe testlerine

tabi tutarak ara sıra ölçülür. Dolayısıyla batarya iç direnci sık sık hesaplanmamaktadır. Bu nedenle, bu özelliği RUL tahmin modelimizi geliştirmek için seçmiyoruz.



Şekil 3.6: Şarj-deşarj çevirimi akım profili.

Bir LIB'in SOC'si, bataryanın voltajına, akımına ve sıcaklığına bağlıdır[235]. Bu nedenle, RUL tahmin modelimiz için voltaj, akım, sıcaklık ve dinlenme süresi gibi girdi özelliklerini de seçiyoruz. Batarya döngü tanımlayıcısına göre gruplandırarak aşağıdaki özellikleri toplanıp-SOC, SOH, voltaj, akım, sıcaklık, dinlenme süresi ve Rul_km. Batarya C1'in voltaj, akım, sıcaklık, SOC ve SOH değerleri batarya döngü tanımlayıcısı ile gruplandırılmıştır. Elde edilen özellikler Şekil 3.7, Şekil 3.8'de gösterilmiştir.



Şekil 3.7: a) SOH ile C1 pilinin döngülerinin grafiği b) C1 pilinin SOC ile Döngülerinin grafiği.

3.4.7. Standart Özellikleri ölçeklendirme

Standart ölçeklendirme, verilen bir özelliği, ölçeklendirilmiş özelliğin sıfır ortalama ve birim standart sapmaya sahip olacak şekilde ölçeklendiren bir veri ön işleme tekniğidir. Standart ölçeklendirmeyi gerçekleştirmek için kullanılan denklem 3.2 denkleminde gösterilmiştir.

$$X' = \frac{X - \mu}{\sigma} \quad (3.2)$$

Burada X' ölçeklendirilmiş özellik, X giriş özelliği, μ X 'in ortalaması ve σ X 'in standart sapmasıdır. Sinir ağları ve k-NN, SVM gibi mesafe tabanlı algoritmalar gibi gradyan inişi tabanlı algoritmaları uygularken, özelliklerin standart ölçeklendirilmesi veri ön işlemenin önemli bir adımıdır.

Gradyan inişi tabanlı modellerde, giriş özelliklerinin standart ölçeklendirilmesi, tüm giriş özelliklerinin aynı adım boyutuna sahip olmasını sağlar. Bu, gradyanın minimuma doğru düzgün ve hızlı bir şekilde iniş yapmasını ve tüm giriş özellikleri için gradyan iniş adımlarının aynı oranda güncellenmesini de sağlar. Giriş özelliklerinin standart ölçeklendirilmesi, model eğitimi daha hızlı hale getirir ve gradyan inişinin yerel minimumlarda sıkışmasını önler. Mesafe tabanlı modellerde, standart ölçeklendirme, tüm özelliklerin tahmin üzerinde eşit etkiye sahip olmasını sağlar[236].

3.4.8. Özet

Veri, yukarıda belirtilen ön işleme adımları kullanılarak işlendikten sonra, RUL tahmin modellerine beslenebilir. Bataryalar üzerinde takvim yaşlanmasının etkisini test etmek istiyoruz. Bu nedenle, X_{CA} ve X_{no_CA} olmak üzere iki giriş seti tanımlıyoruz; burada X_{CA} ve X_{no_CA} sırasıyla takvim yaşlanma etkileri ile ve olmadan giriş özelliklerini temsil eder. Y-RUL hedef özelliktir. X_{CA} , X_{no_CA} ve y_{RUL} 'de bulunan giriş özellikleri aşağıda gösterilmiştir.

$$X_{CA} = \{\text{voltage; current; temperature, SOC, SOH, rest_duration}\} \quad (3.3)$$

$$X_{no_CA} = \{\text{voltage; current; temperature; SOC; SOH}\} \quad (3.4)$$

$$y_{RUL} = \{\text{rul_km}\} \quad (3.5)$$

Giriş özelliklerinin, batarya döngü tanımlayıcısı ile gruplandırılmış toplanmış özellikler olduğuna dikkat etmek önemlidir. Bu giriş özellikleri setlerini X_{CA} ve X_{no_CA} ve hedef özellik y_{RUL} 'yi raporun sonraki bölümlerinde kullanacağız.

3.5. MAKİNE ÖĞRENMESİ UYGULAMALARI

3.5.1. Destek Vektör Regresyonu (SVR)

Veri setinde (C8 hariç tüm hücreler için) iki set deney yapılmıştır. İlk deneyde, X_{CA} giriş olarak beslenmiş ve ikinci deneyde X_{no_CA} deney girişi olarak kullanılmıştır. Her iki deneyde de, SVR modelleri her bir hücre için y_{RUL} hedef değişkeni ile eğitilmiştir. SVR modelleri hücrenin bozulma geçmişi verilerinin %70'lik kısmı üzerinde eğitilmiş ve kalan %30'luk veri üzerinde test edilmiştir.

SVR modeller, otomatik hiper parametre optimizasyonu ile eğitilmiştir. Optimal hiper parametreler, Bayesci optimizasyon yardımı ile seçilmiştir [237]. Bayes optimizasyonu, bir fonksiyonun global maksimum veya minimumunu bulmak için yaygın olarak kullanılan bir optimizasyon algoritmasıdır[238]. SVR modelleri için optimal hiper parametreler Tablo 3.6 listelenmiştir.

LSTM ağ modelleri tarafından yapılan tahminler, ilgili standart sapma değerleri ile çarpılarak ve ortalama değer eklenerek geri dönüştürülmüştür.


Tablo 3.6: SVR modellerinin optimal hiper parametreleri

Battery_Id	Kernel	Polynomial Derece	Epsilon
C1	Polynomial	2	0.0026
C2	Doğrusal	-	0.0955
C3	Polynomial	2	0.0024
C4	Doğrusal	-	0.0008
C5	Polynomial	3	0.0009
C6	Polynomial	2	0.001
C7	Polynomial	2	0.04

3.5.2. Uzun Kısa Süreli Bellek (LSTM)

Veri setindeki her hücre için (C8 hücresi hariç) iki set deney gerçekleştirilmiştir. İlk deneyde, giriş olarak X_{CA} kullanılmıştır ve ikinci deneyde giriş olarak X_{no_CA} verilmiştir. Her iki deneyde de y_{RUL} hedef değişkeni ile her hücre için ayrı LSTM modelleri eğitilmiştir. LSTM

modelleri, hücrenin bozunma geçmişi verilerinin %70'i üzerinde eğitilmiş ve kalan %30'luk veri üzerinde test edilmiştir.



Şekil 3.8: RUL tahmini için uygulanan LSTM modelinin mimarisi.

Uygulanan LSTM ağının mimarisi Şekil 3.10'te gösterilmiştir. Her LSTM hücre için aynı mimari kullanılmıştır. LSTM ağı bir giriş katmanından oluşur. Giriş katmanı, 150 LSTM hücresinden oluşan ilk LSTM katmanına bağlıdır. Bu LSTM katmanı bir dropout katmanına bağlanmıştır. Dropout, Srivastava tarafından önerilen ve derin öğrenme modellerinin aşırı öğrenmesini önlemek için yaygın olarak kullanılan bir düzenleme tekniğidir[239]. Dropout olasılığı 0.1 olarak ayarlanmıştır. Dropout katmanı, 300 LSTM hücresine sahip bir LSTM katmanına bağlıdır. Bu LSTM katmanı daha sonra bir yoğun (dense) katmana ve ardından tahmini üreten bir regresyon katmanına bağlanmıştır.

Tablo 3.7: LSTM model parametreleri

Parametreler	Değerleri
Epoch Sayısı	500
Dropout Olasılığı	0.1
Öğrenme Oranı	0.005
Beta 1	1
Batch Boyutu	8
Aktivasyon Fonksiyonu	tanh
Optimizasyon Algoritması	Adam

LSTM ağı üzerinde iki deney yapılmıştır. Her iki deneyde de her model 500 epoch boyunca çalıştırılmıştır. Burada geçen epoch ifadesi tüm eğitim veri setinin modele bir kez sunulup öğrenme sürecinin tamamlanmasını ifade eder. Epoch sayısı, modelin kaç kez eğitim verileri üzerinden geçeceğini belirler. Daha fazla epoch sayısı genellikle modelin daha iyi öğrenmesine yardımcı olabilir, ancak çok yüksek epoch sayıları aşırı öğrenme (overfitting) riskini artırabilir. Modelin öğrenme oranı 0.005 olarak ayarlanmıştır. Öğrenme oranı, her 250 epoch' tan sonra 0.2 faktörü ile çarpılmıştır.

İkinci deneyde, takvim yaşlanmasının etkileri göz önünde bulundurulmadan, ağı farklı katmanlarındaki eğitilebilir parametrelerin sayısı şu şekildedir: Birinci LSTM katmanı 93.600, ikinci LSTM katmanı 541.200 ve yoğun (dense) katman 300 eğitilebilir parametreye sahiptir. Toplamda, eğitilebilir parametrelerin sayısı 635.100'dür.

4. BULGULAR

Bu bölümde, elektrikli araç bataryalarının kalan kullanım ömrü (RUL) tahmin performanslarının değerlendirilmesinde kullanılan Destek Vektör Regresyonu (SVR) ve Uzun Kısa Süreli Bellek (LSTM) modellerinin sonuçları sunulmuştur. Model, kullanılan hücreler (C1, C2, C3, C4, C5, C6 ve C7) üzerinde farklı performans metrikleri (MAE, MAPE, RMSE, R^2 , MRT) ile değerlendirilmiştir.

4.1. DESTEK VEKTÖR REGRESYON MODELİ (SVR)

Bu bölümde, Destek Vektör Regresyonu (SVR) modelinin elektrikli araç bataryalarının kalan faydalı ömrü (RUL) tahmininde sağladığı performans, Tablo 4.1 ve Tablo 4.2’de sunulan veriler ışığında analiz edilmiştir. Genel olarak, SVR modeli düşük MRT (Model Çalışma Süresi) değerleriyle hızlı tahminler sağlasa da doğruluk açısından sınırlı bir performans sergilemiştir.

C1 hücresinde, R^2 değeri yaklaşık **0.90** ile SVR modelinin bu hücredeki tahmin doğruluğunun yüksek olduğunu göstermektedir. Ayrıca, MAE ve RMSE değerlerinin düşük olması, tahminlerin genel doğruluğunu artırmıştır. Bu durum, C1 hücresinde modelin kullanılan veri setine iyi bir şekilde uyum sağladığını göstermektedir.

C2 hücresinde, tahmin doğruluğunda önemli bir sorun gözlemlenmiştir. Gerçek RUL değerinin son döngüde sıfır olması nedeniyle, MAPE metriği sonsuz bir değer almıştır. Bu, MAPE’nin sıfır gerçek değerlerde güvenilir bir metrik olmadığını ve alternatif bir ölçüm yöntemi gerektiğini göstermektedir.

C3 hücresinde, RMSE değeri oldukça yüksek (9707.3 km) bulunmuştur. Bu, modelin büyük tahmin hataları yaptığını göstermektedir. R^2 değeri ise bu hücrede düşüktür ve modelin verilerle yeterince iyi bir uyum sağlayamadığını ortaya koymaktadır.

C4 ve C5 hücrelerinde SVR modelinin performansı nispeten daha dengelidir. MAE ve RMSE değerleri orta düzeydedir ve R^2 değerleri makul bir doğruluk göstermektedir. Ancak, son döngülerde modelin hata oranında artış gözlemlenmiştir.

C6 ve C7 hücrelerinde, modelin performansı düşük bulunmuştur. R^2 değerleri, modelin verilerin varyansını açıklamakta yetersiz olduğunu göstermektedir. Özellikle C7 hücresinde RMSE ve MAE değerleri diğer hücelere kıyasla daha yüksektir, bu da modelin tahmin performansında ciddi bir düşüş olduğunu göstermektedir.

Tablo 4.1: Takvim yaşlandırılmalı SVM regresyon modellerinin performans ölçümleri


Battery_Id	MAE (km)	MAPE	RMSE	R^2	MRT (s)
C1	1383.1	99.8	1609.3	0.922	633
C2	3273.7	INF	3405.1	0.584	663
C3	7620.8	331.7	9707.3	0.023	571
C4	8587.4	80.9	10158.2	0.454	543
C5	6675.1	525.9	10247.5	0.592	1640
C6	4234.6	173.9	5218.3	0.450	460
C7	4570.1	222.4	5783.0	0.114	404

Tablo 4.2: Takvim yaşlanması olmadan SVM regresyon modellerinin performans ölçümleri

Battery_Id	MAE (km)	MAPE	RMSE	R^2	MRT (s)
C1	1432.6	121.1	1681.3	0.895	711
C2	2871.6	INF	2994.2	0.612	819
C3	21046.7	759.1	27219.3	0.180	605
C4	9290.4	95.3	10687.3	0.351	644
C5	6880.2	147.3	8407.7	0.724	962
C6	15116.9	635.6	19608.3	0.365	399
C7	6073.1	285.3	7606.5	0.343	477

Çoğu batarya için (C5 ve C6 hariç), takvim yaşlanma etkileri olan SVR modelinin model çalışma süresi (MRT), takvim yaşlanma etkisi olmayan SVR modelinden daha düşüktür. Bu da SVR modelin takvim yaşlanması etkileriyle daha başarılı çalıştığını göstermektedir.

SVR modelinde, MAE ve RMSE değerleri genellikle paralel bir seyir izlemektedir. Ancak, C3 hücresinde olduğu gibi büyük hata değerleri durumunda, RMSE'nin MAE'den daha yüksek bir artış gösterdiği gözlemlenmiştir. Bu, modelin bazı hücrelerde büyük hataları telafi etmekte zorlandığını göstermektedir.



Şekil 4.1: C1, C2, C3, C4, C5, C6, C7 hücreleri için SVR modelinin RUL tahmini.

R^2 'nin yüksek olduğu durumlarda (örneğin C1 hücresi), modelin tahmin süresi de nispeten kısa kalmıştır. Ancak, C7 gibi hücrelerde düşük R^2 değerleri ve nispeten kısa MRT süreleri, modelin

tahmin doğruluğunu artırmak için daha fazla işlem süresine ihtiyaç duyabileceğini göstermektedir.

MAPE metriğinin C2 hücresindeki performans problemi, bu metriğin sıfır gerçek değerlerde kullanılmasının sınırlı olduğunu açıkça ortaya koymuştur. Bu gibi durumlarda, farklı hata ölçümleri (örneğin, Medyan Hata veya Normalize Edilmiş RMSE) tercih edilmelidir.

Destek Vektör Regresyonu (SVR) modeli, elektrikli araç bataryalarının RUL tahmininde hızlı çalışmasıyla dikkat çekmiştir. Ancak, tahmin doğruluğu açısından özellikle bazı hücrelerde sınırlamalar olduğu tespit edilmiştir. Bu model, hızlı tahmin gerektiren durumlarda kullanılabilir olsa da yüksek doğruluk gerektiren uygulamalar için ek optimizasyonlar ve farklı metriklerin kullanımı gereklidir.

4.2. UZUN KISA SÜRELİ BELLEK MODELİ (LSTM)

Bu bölümde, LSTM modelinin elektrikli araç bataryalarının kalan kullanım ömrü (RUL) tahmin performansı, her bir hücre bazında iki farklı senaryoda (Takvim Yaşlanma Etkileri Dikkate Alınarak ve Dikkate Alınmadan) karşılaştırılmıştır. Performans değerlendirmesi, Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hatası (MAPE), Ortalama Karekök Hata (RMSE), Belirleme Katsayısı (R^2) ve Model Çalışma Süresi (MRT) gibi metrikler üzerinden yapılmıştır. Aşağıda her hücre için detaylı analiz yer almaktadır.

Tablo 4.3: Takvim yaşlandırılmalı LSTM modellerinin performans ölçümleri

Battery_Id	MAE (km)	MAPE	RMSE	R^2	MRT (s)
C1	2520.4	192.0	2923.1	0.678	113
C2	1753.4	INF	2131.4	0.793	114
C3	3143.2	109.9	3791.5	0.711	86
C4	7108.0	114.9	7760.4	0.672	156
C5	7456.4	173.5	8278.1	0.701	384
C6	3309.0	158.1	4115.4	0.670	77
C7	3380.6	165.6	4404.1	0.487	76

Tablo 4.4: Takvim yaşlanması olmadan LSTM modellerinin performans ölçümleri

Battery_Id	MAE (km)	MAPE	RMSE	R^2	MRT (s)
C1	1801.1	156.9	2239.9	0.823	124
C2	1969.9	INF	2412.1	0.744	139
C3	1591.7	41.5	1908.0	0.906	164
C4	8320.4	127.5	8723.7	0.575	324
C5	6724.8	160.2	7733.5	0.755	849
C6	3241.4	157.9	4046.6	0.672	179
C7	3493.2	166.8	4534.8	0.458	195

C1 hücresi için takvim yaşlanması dikkate alındığında; MAE değeri **2520.4 km**, RMSE değeri **2923.1 km** ve R^2 değeri **0.678** olarak ölçülmüştür. Bu değerler, modelin iyi bir tahmin performansı sergilediğini ancak tahminlerin bazı döngülerde hedef değerden sapmalar gösterebileceğini işaret etmektedir. Takvim yaşlanması dikkate alınmadığında hem MAE hem de RMSE değerleri belirgin şekilde azalmış, doğruluk artmıştır (R^2 : 0.823). Ancak MRT süresi

yaklaşık %10 oranında uzamıştır. Bu durum, doğruluk öncelikli senaryolar için takvim yaşlanmasının dikkate alınmamasının daha uygun olduğunu göstermektedir.

C2 hücresi için takvim yaşlanma etkileri dikkate alındığında MAPE metriği sıfır gerçek RUL değerleri nedeniyle hesaplanamamıştır. Ancak, RMSE değeri **2131.4 km**, R^2 değeri **0.793**, ve MRT değeri **114 saniye** olarak ölçülmüştür. Bu, modelin yüksek doğruluk sağladığını göstermektedir. Takvim yaşlanmasının dikkate alındığı durumda model, C2 hücresinde daha iyi bir R^2 değeri (0.793) ile performans göstermiştir. Takvim yaşlanmasız durumda ise RMSE ve MAE değerleri artmış, MRT de uzamıştır. Bu hücre için takvim yaşlanmasının dikkate alınması daha uygundur.

C3 hücresi için takvim yaşlanma etkileri dikkate alındığında MAE değeri 3143.2 km, RMSE değeri 3791.5 km, R^2 değeri 0.711 ve MRT değeri 86 saniye olarak ölçülmüştür. Model, bu durumda makul bir doğruluk sağlasa da tahmin hataları döngü sonlarında artış göstermiştir. Takvim yaşlanmasının dikkate alınmadığı durumda ise MAE değeri 1591.7 km, RMSE değeri 1908.0 km, R^2 değeri 0.906 ve MRT değeri 164 saniye olarak ölçülmüştür. Bu, modelin doğruluğunu önemli ölçüde artırmış ve tahmin hatalarını azaltmıştır. Ancak MRT süresi neredeyse iki katına çıkmıştır. Bu hücre için doğruluğun öncelikli olduğu durumlarda takvim yaşlanmasının dikkate alınmaması önerilmektedir.

C4 hücresi için takvim yaşlanma etkileri dikkate alındığında MAE değeri 7108.0 km, RMSE değeri 7760.4 km, R^2 değeri 0.672 ve MRT değeri 156 saniye olarak ölçülmüştür. Modelin bu senaryoda doğruluğu, veri setinin genel varyansını açıklamada yeterli düzeyde bulunmuştur. Takvim yaşlanmasının dikkate alınmadığı durumda ise MAE değeri 8320.4 km, RMSE değeri 8723.7 km, R^2 değeri 0.575 ve MRT değeri 324 saniye olarak ölçülmüştür. Bu durumda doğruluk düşmüş, tahmin hataları artmıştır. MRT süresindeki artış ise ek bir işlem maliyeti getirmiştir. Bu hücre için takvim yaşlanmasının dikkate alınması daha uygundur.


C5 hücresi için takvim yaşlanma etkileri dikkate alındığında MAE değeri 7456.4 km, RMSE değeri 8278.1 km, R^2 değeri 0.701 ve MRT değeri 384 saniye olarak ölçülmüştür. Modelin doğruluğu, veri setinin genel eğilimlerini açıklamak için yeterli bulunmuştur. Takvim yaşlanmasının dikkate alınmadığı durumda ise MAE değeri 6724.8 km, RMSE değeri 7733.5 km, R^2 değeri 0.755 ve MRT değeri 849 saniye olarak ölçülmüştür. Bu senaryoda doğruluk artmış ve tahmin hataları azalmıştır. Ancak MRT süresi önemli ölçüde uzamıştır. C5 hücresinde

işlem süresi yerine doğruluk öncelikli ise takvim yaşlanmasının dikkate alınmaması önerilmektedir.

C6 hücresi için takvim yaşlanma etkileri dikkate alındığında MAE değeri 3309.0 km, RMSE değeri 4115.4 km, R^2 değeri 0.670 ve MRT değeri 77 saniye olarak ölçülmüştür. Model, bu senaryoda iyi bir doğruluk sağlamıştır. Takvim yaşlanmasının dikkate alınmadığı durumda ise MAE değeri 3241.4 km, RMSE değeri 4046.6 km, R^2 değeri 0.746 ve MRT değeri 179 saniye olarak ölçülmüştür. Doğruluk artarken işlem süresinin uzaması gözlemlenmiştir. Bu hücre için doğruluk öncelikli durumlarda takvim yaşlanmasının dikkate alınmaması önerilmektedir.

C7 hücresi için takvim yaşlanma etkileri dikkate alındığında MAE değeri 3380.6 km, RMSE değeri 4404.1 km, R^2 değeri 0.487 ve MRT değeri 76 saniye olarak ölçülmüştür. Model, düşük doğruluk seviyesinde çalışmış ve tahmin performansı sınırlı kalmıştır. Takvim yaşlanmasının dikkate alınmadığı durumda ise MAE değeri 3493.2 km, RMSE değeri 4534.8 km, R^2 değeri 0.458 ve MRT değeri 195 saniye olarak ölçülmüştür. Doğruluk artmamış ve işlem süresi uzamıştır. Bu hücrede model parametrelerinin optimize edilmesi ve veri ön işleme tekniklerinin uygulanması gerekmektedir.

Takvim yaşlanması dikkate alındığında işlem süreleri (MRT) daha kısa, ancak doğruluk (R^2) genellikle daha düşüktür. C1 ve C3 gibi hücrelerde takvim yaşlanmasının dikkate alınmaması, modelin doğruluğunu önemli ölçüde artırmıştır. Bazı hücrelerde ise C2 ve C7 takvim yaşlanmasının dikkate alınması gerektiği gözlenmiştir. Bu sebeple modelde hücre bazlı bir optimizasyon gerekliliği vardır. Sıfır gerçek değerlerin bulunduğu durumlarda (C2 gibi), MAPE metriği yerine Normalize Edilmiş RMSE veya Medyan Mutlak Hata kullanılmalıdır. Takvim yaşlanma etkilerinin dikkate alınması, işlem süresini önemli ölçüde kısaltmış ancak bazı hücrelerde doğruluk açısından sınırlamalar yaratmıştır. Öte yandan, takvim yaşlanma etkilerinin dikkate alınmadığı durumda doğruluk artarken, MRT değerlerinde ciddi artışlar gözlenmiştir. Bu durum, modelin kullanım amacına göre farklı senaryolar için optimize edilmesi gerektiğini ortaya koymaktadır.



Şekil 4.2: C1, C2, C3, C4, C5, C6, C7 hücreleri için LSTM modelinin RUL tahmini.

5. TARTIŞMA

Elektrikli araçların (EV) giderek yaygınlaşması ve bu araçlarda kullanılan lityum-iyon bataryaların kritik bir bileşen haline gelmesi, kalan kullanım ömrü (RUL) tahmininin önemini artırmıştır. RUL tahmini, yalnızca bataryaların işlevselliğini optimize etmekle kalmaz, aynı zamanda bataryaların ekonomik ömrünün uzatılması, geri dönüşüm süreçlerinin planlanması ve enerji yönetim sistemlerinin iyileştirilmesi gibi geniş bir uygulama yelpazesine katkıda bulunur. Bu tezde, lityum-iyon bataryaların RUL tahmini için Destek Vektör Regresyonu (SVR) ve Uzun Kısa Süreli Bellek (LSTM) modelleri değerlendirilmiş ve sonuçlar kapsamlı bir şekilde analiz edilmiştir. Bulgular, bu iki yöntemin avantajlarını ve sınırlamalarını ortaya koymuş ve her bir yöntemin belirli koşullarda ne derece etkili olabileceğini göstermiştir.

5.1. BULGULARIN GENEL DEĞERLENDİRİLMESİ

Bu çalışmada kullanılan veri seti, farklı koşullarda yaşlandırılmış lityum-iyon bataryaların bozulma profillerini içermektedir. Elde edilen bulgular, SVR ve LSTM algoritmalarının tahmin performanslarını farklı metrikler üzerinden analiz etmeyi mümkün kılmıştır. Performans değerlendirmesi için Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hatası (MAPE), Ortalama Karekök Hata (RMSE), Belirleme Katsayısı (R^2) ve Model Çalışma Süresi (MRT) metrikleri kullanılmıştır. Takvim yaşlanma etkilerinin dikkate alındığı ve alınmadığı iki farklı senaryoda gerçekleştirilen bu analiz, her iki modelin belirli koşullarda nasıl performans sergilediğini detaylı bir şekilde ortaya koymuştur.

Takvim yaşlanma etkileri dikkate alındığında, LSTM modelinin genellikle daha yüksek doğruluk sağladığı ancak işlem süresinin (MRT) arttığı görülmüştür. Öte yandan, SVR modeli daha kısa işlem süreleriyle çalışmış ancak özellikle bazı hücrelerde doğruluk açısından yetersiz kalmıştır. Takvim yaşlanma etkilerinin dikkate alınmadığı durumda, her iki modelin performansı değişiklik göstermiş ve bu durum kullanım senaryosuna bağlı olarak model seçiminin önemini ortaya koymuştur.

5.2. SVR VE LSTM SONUÇLARININ KARŞILAŞTIRILMASI

5.2.1. Doğruluk Karşılaştırması

LSTM modeli, SVR modeline kıyasla genel olarak daha yüksek doğruluk sağlamıştır. Özellikle C3 hücresinde LSTM modelinin R^2 değeri 0.906'ya ulaşırken, SVR modeli için bu değer

yalnızca 0.023 olarak ölçülmüştür. Bu durum, LSTM'nin doğrusal olmayan ilişkileri daha iyi öğrenme kapasitesine sahip olduğunu göstermektedir. Ayrıca, MAE ve RMSE değerlerinde de LSTM modelinin daha düşük hata oranlarına sahip olduğu görülmüştür. Örneğin, C1 hücresinde LSTM modeli için RMSE değeri 2239.9 km iken, SVR modeli için bu değer 1609.3 km olarak ölçülmüştür. Ancak, bu farklılık bazı hücrelerde belirgin değildir ve her iki modelin doğruluk seviyeleri yakın sonuçlar vermiştir.

5.2.2. İşlem Süresi Karşılaştırması

SVR modeli, genellikle daha kısa işlem süreleriyle çalışmıştır. Örneğin, C1 hücresinde SVR modeli için MRT değeri 633 saniye iken, LSTM modeli için bu süre 113 saniye olarak ölçülmüştür. LSTM modelinin daha yüksek işlem süresi, modelin karmaşık veri yapılarını öğrenme kapasitesinin bir sonucudur. Ancak, gerçek zamanlı uygulamalar için bu durum, LSTM modelinin kullanımını sınırlayabilecek bir faktör olarak değerlendirilmektedir. SVR modeli, daha kısa işlem süresi gerektiren durumlarda avantaj sağlamaktadır.

5.2.3. MAPE ve Alternatif Metriklerin Kullanımı

MAPE metriği, özellikle sıfır gerçek değerlerin bulunduğu hücrelerde güvenilir sonuçlar sağlamamaktadır. Örneğin, C2 hücresinde hem SVR hem de LSTM modellerinde MAPE metriği sonsuz bir değer almıştır. Bu durum, sıfır gerçek değerlerin bulunduğu veri setlerinde MAPE yerine Normalize Edilmiş RMSE veya Medyan Mutlak Hata gibi alternatif metriklerin kullanılmasının daha uygun olduğunu göstermektedir. LSTM modelinin daha düşük MAE ve RMSE değerleri, genel hata seviyesini daha iyi temsil etmektedir.

5.3. MODELLERİN GÜÇLÜ VE ZAYIF YANLARI

Model	Güçlü Yanlar	Zayıf Yanlar	Fırsatlar	Tehditler
SVR	1. Daha kısa işlem süresi (MRT). 2. Basit veri yapılarında yüksek doğruluk. 3. Gerçek zamanlı uygulamalara uygun.	1. Karmaşık veri setlerinde düşük doğruluk. 2. Büyük hatalarda performans düşüşü. 3. Bazı hücrelerde düşük R^2 değerleri.	1. Parametre optimizasyonu ile doğruluk artırılabilir. 2. Daha geniş veri setlerinde performans artışı. 3. Gerçek zamanlı tahminler için ideal.	1. Karmaşık veri yapılarına uyumda yetersizlik. 2. Veri ön işleme gereksinimi artabilir. 3. Alternatif modellerin üstünlük sağlaması.
LSTM	1. Karmaşık veri yapılarını öğrenme kapasitesi. 2. Doğrusal olmayan ilişkilerde üstün performans. 3. Düşük MAE ve RMSE değerleri.	1. Yüksek işlem süresi (MRT). 2. Gerçek zamanlı uygulamalar için optimizasyon ihtiyacı. 3. Küçük veri setlerinde düşük doğruluk riski.	1. Daha büyük ve çeşitli veri setlerinde daha iyi sonuçlar. 2. Optimize edilmiş işlem süresiyle uygulama avantajı. 3. Derin öğrenme gelişmeleriyle uyumlu.	1. Yüksek işlem süreleri rekabet dezavantajı yaratabilir. 2. Daha karmaşık veri setlerinde aşırı uyum riski. 3. Optimize edilmemiş modellerde genel kullanılamazlık.

6. SONUÇ VE ÖNERİLER

6.1. SONUÇ

Lityum-iyon bataryaların kalan kullanım ömrünün (RUL) tahmini, elektrikli araçların yaygınlaşmasıyla birlikte önem kazanan bir konudur. Elektrikli araçların enerji verimliliği, güvenliği ve operasyonel sürekliliği, bataryaların sağlığı ve performansına bağlıdır. Ancak, bataryaların yükleme, akım, voltaj ve çevresel faktörlere bağlı olarak gösterdiği karmaşık bozulma davranışı, RUL tahminini zorlu bir süreç haline getirmiştir. Bu tez çalışmasında, elektrikli araçlarda kullanılan lityum-iyon bataryaların RUL tahminine yönelik Destek Vektör Regresyonu (SVR) ve Uzun Kısa Süreli Bellek (LSTM) modelleri karşılaştırmalı olarak analiz edilmiştir.

Çalışma kapsamında kullanılan veri seti, farklı koşullarda yaşlandırılmış lityum-iyon bataryaların bozulma profillerini içermektedir. Bu veriler, tahmin modellerinin doğruluğunu ve performansını değerlendirmek amacıyla MAE, MAPE, RMSE, R^2 ve MRT gibi metriklerle analiz edilmiştir. Elde edilen sonuçlar, LSTM modelinin doğrusal olmayan ilişkileri öğrenme kapasitesi sayesinde genel olarak daha yüksek doğruluk sağladığını göstermektedir. Özellikle karmaşık veri setlerinde LSTM'nin üstün performans sergilediği, SVR modelinin ise daha kısa işlem süreleriyle gerçek zamanlı uygulamalar için uygun olduğu belirlenmiştir.

Takvim yaşlanma etkilerinin dikkate alınması ve alınmaması durumlarında yapılan analizler, modellerin performansını etkileyen faktörleri daha iyi anlamamızı sağlamıştır. LSTM modeli, takvim yaşlanma etkilerinin dikkate alınmadığı senaryolarda doğruluğunu artırırken, SVR modeli genellikle daha düşük hata oranları ve kısa işlem süreleriyle öne çıkmıştır. Bununla birlikte, her iki modelin de hücresel düzeyde farklı performans sergilediği ve kullanım amacına göre optimize edilmesi gerektiği görülmüştür.

Sonuç olarak, bu tez çalışması, elektrikli araç bataryalarının kalan kullanım ömrünü tahmin etmek için hem SVR hem de LSTM modellerinin güçlü ve zayıf yönlerini kapsamlı bir şekilde ortaya koymuştur. LSTM modeli, doğruluk öncelikli senaryolar için uygun bir yöntem iken, SVR modeli kısa işlem süresi gerektiren durumlar için tercih edilebilir.

6.2. ÖNERİLER

Bu tez çalışmasında elde edilen bulgular, lityum-iyon bataryaların kalan kullanım ömrü (RUL) tahmini konusunda önemli katkılar sunmuş, ancak bu alandaki gelecekteki çalışmalar için yeni araştırma alanları da ortaya koymuştur. Aşağıda, bu çalışmadan elde edilen sonuçlar ışığında geliştirilmiş öneriler ve gelecekte üzerinde çalışılabilecek başlıca yönler birleştirilmiş ve detaylandırılmıştır.

6.2.1. Veri Setinin Genişletilmesi ve Çeşitlendirilmesi

Mevcut çalışma, yalnızca 8 lityum-iyon bataryanın bozulma profillerine dayanmaktadır ve bu bataryalardan yalnızca 7 tanesi makine öğrenimi algoritmalarında kullanılabilir durumdadır. Daha geniş bir veri setinin oluşturulması, modellerin genel performansını iyileştirmek ve genelleme kapasitesini artırmak açısından kritik öneme sahiptir. Gelecekteki çalışmalar, farklı üreticilere ait batarya türlerini, çeşitli çevresel koşullarda yaşlandırılmış bataryaları ve farklı kullanım senaryolarını içerecek şekilde veri setlerini genişletmeyi hedeflemelidir.

6.2.2. Hücre Bazlı Optimizasyon ve Kişiselleştirilmiş Modeller

SVR ve LSTM modellerinin performansı, hücre düzeyinde belirgin farklılıklar göstermektedir. Özellikle C7 gibi düşük doğruluk sergileyen hücreler için özel optimizasyon süreçleri gereklidir. Her hücrenin kendine özgü bozulma profiline uygun şekilde model parametrelerinin optimize edilmesi, tahmin doğruluğunu artırabilir. Ayrıca, hücre bazlı kişiselleştirilmiş modellerin geliştirilmesi, her bataryanın spesifik özelliklerine daha iyi uyum sağlayabilir.

6.2.3. Alternatif Metriklerin Kullanımı

Sıfır gerçek değerlerin bulunduğu veri setlerinde, MAPE metriği kullanışlılığını kaybetmektedir. Gelecekte, Normalize Edilmiş RMSE, Medyan Mutlak Hata veya benzeri metriklerin kullanımı, özellikle uç değerlerin ve sıfır gerçek değerlerin bulunduğu durumlarda daha güvenilir sonuçlar elde edilmesini sağlayabilir. Bu alternatif metriklerin sistematik olarak değerlendirilmesi, modellerin performans analizini daha kapsamlı hale getirecektir.

6.2.4. Gerçek Zamanlı Optimizasyon

LSTM modeli, karmaşık veri yapılarını öğrenme kapasitesi nedeniyle doğruluk açısından üstün performans göstermektedir. Ancak, yüksek işlem süreleri (MRT), gerçek zamanlı uygulamalar için sınırlayıcı bir faktör olabilmektedir. Bu nedenle, gerçek zamanlı tahminler için daha düşük işlem süresine sahip modellerin geliştirilmesi gereklidir. Bu doğrultuda, hafif derin öğrenme

modelleri veya hibrit algoritmaların kullanılması, gerçek zamanlı sistemlerde daha etkili çözümler sunabilir.

6.2.5. RUL Tahmini için Ek Değişkenlerin Dahil Edilmesi

Bu çalışmada kullanılan veri seti, yalnızca bataryaların bozulma durumları, kat edilen mesafe ve süre gibi sınırlı değişkenleri içermektedir. Ancak, RUL tahminini etkileyen diğer faktörlerin de göz önünde bulundurulması önemlidir. Gelecekteki çalışmalar, şarj yöntemi, sürüş davranışları, güzergâh, çevresel koşullar gibi değişkenleri veri setine dahil ederek modellerin doğruluğunu artırabilir. Bu değişkenler, bataryaların gerçek dünyadaki kullanım senaryolarına daha iyi uyum sağlamasını sağlayacaktır.

6.2.6. Derin Öğrenme Modellerinin Geliştirilmesi

LSTM gibi derin öğrenme modelleri, doğrusal olmayan ilişkileri öğrenme kapasitesi sayesinde etkili tahminler sunmaktadır. Gelecekte, LSTM ile diğer derin öğrenme tekniklerinin (örneğin, Convolutional Neural Networks - CNN) hibrit kullanımı araştırılabilir. Bu tür hibrit modeller, zaman serisi verileri ve uzaysal ilişkileri birlikte değerlendirerek daha kapsamlı sonuçlar üretebilir.

6.2.7. Enerji Yönetim Sistemleri ile Entegrasyon

Bataryaların kalan kullanım ömrü tahminine yönelik geliştirilen modellerin, elektrikli araçların enerji yönetim sistemleriyle entegre edilmesi, daha etkin bir batarya yönetimi sağlayabilir. Bu entegrasyon, hem araç performansını optimize edebilir hem de kullanıcı deneyimini iyileştirebilir. Ayrıca, bu sistemlerin tahmin verilerini gerçek zamanlı olarak kullanabilmesi, enerji tüketiminin daha verimli bir şekilde yönetilmesine olanak tanır.

6.2.8. Geri Dönüşüm ve Yeniden Kullanım Uygulamaları

Lityum-iyon bataryaların geri dönüşüm süreçlerinde kullanılabilecek bozulma tahmin modellerinin geliştirilmesi, sürdürülebilirlik açısından önemli bir katkı sağlayabilir. Geri dönüşüm süreçlerinde kullanılmak üzere batarya sağlığına dayalı yeniden kullanım senaryoları oluşturulabilir. Bu yaklaşımlar, bataryaların ömrünü uzatarak ekonomik ve çevresel faydalar sunacaktır.

Bu öneriler ve gelecekteki çalışmalar, lityum-iyon bataryaların kalan kullanım ömrü tahmini ve elektrikli araçların enerji yönetimi alanında daha kapsamlı ve etkili çözümler geliştirilmesine katkıda bulunacaktır. Daha geniş veri setleri, optimize edilmiş modeller ve yenilikçi

teknolojilerle bu alanda önemli ilerlemeler kaydedilebilir. Böylece, elektrikli araçların yaygınlaşması ve sürdürülebilir enerji yönetimi hedeflerine daha hızlı ulaşılması mümkün olacaktır.



KAYNAKLAR

- [1] P. F. Flynn *et al.*, “The inevitability of engine-out NO_x emissions from spark-ignited and diesel engines,” *Proceedings of the Combustion Institute*, vol. 28, no. 1, pp. 1211–1218, Jan. 2000, doi: 10.1016/S0082-0784(00)80332-X.
- [2] A. M. K. P. Taylor, “Science review of internal combustion engines,” *Energy Policy*, vol. 36, no. 12, pp. 4657–4667, Dec. 2008, doi: 10.1016/j.enpol.2008.09.001.
- [3] S. E. de Lucena, “A Survey on Electric and Hybrid Electric Vehicle Technology,” in *Electric Vehicles – The Benefits and Barriers*, InTech, 2011. doi: 10.5772/18046.
- [4] K. Akbar, Y. Zou, Q. Awais, M. J. A. Baig, and M. Jamil, “A Machine Learning-Based Robust State of Health (SOH) Prediction Model for Electric Vehicle Batteries,” *Electronics (Basel)*, vol. 11, no. 8, p. 1216, Apr. 2022, doi: 10.3390/electronics11081216.
- [5] K. A. Severson *et al.*, “Data-driven prediction of battery cycle life before capacity degradation,” *Nat Energy*, vol. 4, no. 5, pp. 383–391, Mar. 2019, doi: 10.1038/s41560-019-0356-8.
- [6] P. Sun, R. Bisschop, H. Niu, and X. Huang, “A Review of Battery Fires in Electric Vehicles,” *Fire Technol*, vol. 56, no. 4, pp. 1361–1410, Jul. 2020, doi: 10.1007/s10694-019-00944-3.
- [7] C. Stave and A. Carlson, “A case study exploring firefighters’ and municipal officials’ preparedness for electrical vehicles,” *European Transport Research Review*, vol. 9, no. 2, p. 25, Jun. 2017, doi: 10.1007/s12544-017-0240-1.
- [8] M. Ali Lskaafi and M. Ali, “Fault Diagnosis and Failure Prognostics of Lithium-ion Battery Fault Diagnosis and Failure Prognostics of Lithium-ion Battery based on Least Squares Support Vector Machine and Memory based on Least Squares Support Vector Machine and Memory Particle Filter Framework Particle Filter Framework Recommended Citation Recommended Citation.” [Online]. Available: https://trace.tennessee.edu/utk_graddiss
- [9] L. Huang and C. Yao, “Failure Prediction Modeling of Lithium Ion Battery toward Distributed Parameter Estimation,” *Chinese Journal of Chemical Physics*, vol. 30, no. 5, pp. 547–552, Oct. 2017, doi: 10.1063/1674-0068/30/cjcp1705088.
- [10] X. Hu, Y. Che, X. Lin, and Z. Deng, “Health Prognosis for Electric Vehicle Battery Packs: A Data-Driven Approach,” *IEEE/ASME Transactions on Mechatronics*, vol. 25, no. 6, pp. 2622–2632, Dec. 2020, doi: 10.1109/TMECH.2020.2986364.

- [11] D. Roman, S. Saxena, V. Robu, M. Pecht, and D. Flynn, "Machine learning pipeline for battery state-of-health estimation," *Nat Mach Intell*, vol. 3, no. 5, pp. 447–456, May 2021, doi: 10.1038/s42256-021-00312-3.
- [12] F. Wen and C. S. Chang, "A new approach to fault diagnosis in electrical distribution networks using a genetic algorithm," 1998.
- [13] P. M. Attia *et al.*, "Closed-loop optimization of fast-charging protocols for batteries with machine learning," *Nature*, vol. 578, no. 7795, pp. 397–402, Feb. 2020, doi: 10.1038/s41586-020-1994-5.
- [14] B. Bilgin *et al.*, "Making the Case for Electrified Transportation," *IEEE Transactions on Transportation Electrification*, vol. 1, no. 1, pp. 4–17, Jun. 2015, doi: 10.1109/TTE.2015.2437338.
- [15] E. Helmers and P. Marx, "Electric cars: technical characteristics and environmental impacts," *Environ Sci Eur*, vol. 24, no. 1, p. 14, Dec. 2012, doi: 10.1186/2190-4715-24-14.
- [16] L. Canals Casals, E. Martinez-Laserna, B. Amante García, and N. Nieto, "Sustainability analysis of the electric vehicle use in Europe for CO2 emissions reduction," *J Clean Prod*, vol. 127, pp. 425–437, Jul. 2016, doi: 10.1016/j.jclepro.2016.03.120.
- [17] N. C. Onat, M. Kucukvar, and S. Afshar, "Eco-efficiency of electric vehicles in the United States: A life cycle assessment based principal component analysis," *J Clean Prod*, vol. 212, pp. 515–526, Mar. 2019, doi: 10.1016/j.jclepro.2018.12.058.
- [18] C. Filote, R. Felseghi, M. S. Raboaca, and I. Aşchilean, "Environmental impact assessment of green energy systems for power supply of electric vehicle charging station," *Int J Energy Res*, vol. 44, no. 13, pp. 10471–10494, Oct. 2020, doi: 10.1002/er.5678.
- [19] E. E. Michaelides, "Primary Energy Use and Environmental Effects of Electric Vehicles," *World Electric Vehicle Journal*, vol. 12, no. 3, p. 138, Aug. 2021, doi: 10.3390/wevj12030138.
- [20] A. Ghosh, "Possibilities and Challenges for the Inclusion of the Electric Vehicle (EV) to Reduce the Carbon Footprint in the Transport Sector: A Review," *Energies (Basel)*, vol. 13, no. 10, p. 2602, May 2020, doi: 10.3390/en13102602.
- [21] V. A. Katkar and P. Goswami, "Review on Energy Management Systems for Hybrid E Vehicles," in *2020 International Conference on Power, Energy, Control and Transmission Systems (ICPECTS)*, IEEE, Dec. 2020, pp. 1–6. doi: 10.1109/ICPECTS49113.2020.9336977.
- [22] T. R. Hawkins, B. Singh, G. Majeau-Bettez, and A. H. Strømman, "Comparative Environmental Life Cycle Assessment of Conventional and Electric Vehicles," *J Ind Ecol*, vol. 17, no. 1, pp. 53–64, Feb. 2013, doi: 10.1111/j.1530-9290.2012.00532.x.

- [23] C. Vidal, P. Malysz, P. Kollmeyer, and A. Emadi, "Machine Learning Applied to Electrified Vehicle Battery State of Charge and State of Health Estimation: State-of-the-Art," *IEEE Access*, vol. 8, pp. 52796–52814, 2020, doi: 10.1109/ACCESS.2020.2980961.
- [24] X. Feng *et al.*, "Online State-of-Health Estimation for Li-Ion Battery Using Partial Charging Segment Based on Support Vector Machine," *IEEE Trans Veh Technol*, vol. 68, no. 9, pp. 8583–8592, Sep. 2019, doi: 10.1109/TVT.2019.2927120.
- [25] E. Lelli, A. Musa, E. Batista, D. A. Misul, and G. Belingardi, "On-Road Experimental Campaign for Machine Learning Based State of Health Estimation of High-Voltage Batteries in Electric Vehicles," *Energies (Basel)*, vol. 16, no. 12, p. 4639, Jun. 2023, doi: 10.3390/en16124639.
- [26] R. Agrawal and G. Psaila, "Active Data Mining.," May 1995, pp. 3–8.
- [27] S.-H. Liao, P.-H. Chu, and P.-Y. Hsiao, "Data mining techniques and applications – A decade review from 2000 to 2011," *Expert Syst Appl*, vol. 39, no. 12, pp. 11303–11311, Sep. 2012, doi: 10.1016/j.eswa.2012.02.063.
- [28] S. Tang, C. Yu, X. Wang, X. Guo, and X. Si, "Remaining Useful Life Prediction of Lithium-Ion Batteries Based on the Wiener Process with Measurement Error," *Energies (Basel)*, vol. 7, no. 2, pp. 520–547, Jan. 2014, doi: 10.3390/en7020520.
- [29] X. Zheng and X. Deng, "State-of-Health Prediction for Lithium-Ion Batteries with Multiple Gaussian Process Regression Model," *IEEE Access*, vol. 7, pp. 150383–150394, 2019, doi: 10.1109/ACCESS.2019.2947294.
- [30] J. Yu, "State of health prediction of lithium-ion batteries: Multiscale logic regression and Gaussian process regression ensemble," *Reliab Eng Syst Saf*, vol. 174, pp. 82–95, Jun. 2018, doi: 10.1016/j.ress.2018.02.022.
- [31] M. Karegar, A. Isazadeh, F. Fartash, T. Sadari, and A. Habibizad Navin, "Data-mining by probability-based patterns," in *ITI 2008 - 30th International Conference on Information Technology Interfaces*, IEEE, Jun. 2008, pp. 353–360. doi: 10.1109/ITI.2008.4588435.
- [32] S. A. Hill, "Statistics," in *Foundations of Anesthesia*, Elsevier, 2006, pp. 207–217. doi: 10.1016/B978-0-323-03707-5.50024-3.
- [33] I. Witten and I. H. Frank, "Data Mining - Practical Machine Learning Tools and Techniques with JAVA Implementations," *Morgan Kaufmann*, vol. 31, May 2002.
- [34] D. K. Bhattacharyya and S. M. Hazarika, "Networks, Data Mining and Artificial Intelligence: Trends and Future Directions," 2006. [Online]. Available: <https://api.semanticscholar.org/CorpusID:60130783>
- [35] B. Samanta, "Artificial neural networks and genetic algorithms for gear fault detection," *Mech Syst Signal Process*, vol. 18, no. 5, pp. 1273–1282, Sep. 2004, doi: 10.1016/j.ymssp.2003.11.003.

- [36] J. Yang, Y. Zhang, and Y. Zhu, "Intelligent fault diagnosis of rolling element bearing based on SVMs and fractal dimension," *Mech Syst Signal Process*, vol. 21, no. 5, pp. 2012–2024, Jul. 2007, doi: 10.1016/j.ymssp.2006.10.005.
- [37] D. Liu, Y. Luo, Y. Peng, X. Peng, and M. Pecht, "Lithium-ion Battery Remaining Useful Life Estimation Based on Nonlinear AR Model Combined with Degradation Feature," *Annual Conference of the PHM Society*, vol. 4, no. 1, Sep. 2012, doi: 10.36001/phmconf.2012.v4i1.2165.
- [38] G. E. Hinton and R. R. Salakhutdinov, "Reducing the Dimensionality of Data with Neural Networks," *Science (1979)*, vol. 313, no. 5786, pp. 504–507, Jul. 2006, doi: 10.1126/science.1127647.
- [39] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural Networks*, vol. 61, pp. 85–117, Jan. 2015, doi: 10.1016/j.neunet.2014.09.003.
- [40] D. S. Chaplot, C. MacLellan, R. Salakhutdinov, and K. Koedinger, "Learning Cognitive Models Using Neural Networks," 2018, pp. 43–56. doi: 10.1007/978-3-319-93843-1_4.
- [41] Chaochao Chen, Bin Zhang, G. Vachtsevanos, and M. Orchard, "Machine Condition Prediction Based on Adaptive Neuro-Fuzzy and High-Order Particle Filtering," *IEEE Transactions on Industrial Electronics*, vol. 58, no. 9, pp. 4353–4364, Sep. 2011, doi: 10.1109/TIE.2010.2098369.
- [42] K. Medjaher, D. A. Tobon-Mejia, and N. Zerhouni, "Remaining Useful Life Estimation of Critical Components With Application to Bearings," *IEEE Trans Reliab*, vol. 61, no. 2, pp. 292–302, Jun. 2012, doi: 10.1109/TR.2012.2194175.
- [43] E. Ramasso and R. Gouriveau, "Prognostics in switching systems: Evidential markovian classification of real-time neuro-fuzzy predictions," in *2010 Prognostics and System Health Management Conference*, IEEE, Jan. 2010, pp. 1–10. doi: 10.1109/PHM.2010.5413442.
- [44] L. Peel, "Data driven prognostics using a Kalman filter ensemble of neural network models," in *2008 International Conference on Prognostics and Health Management*, IEEE, Oct. 2008, pp. 1–6. doi: 10.1109/PHM.2008.4711423.
- [45] Chao Hu, B. D. Youn, and Pingfeng Wang, "Ensemble of data-driven prognostic algorithms for robust prediction of remaining useful life," in *2011 IEEE Conference on Prognostics and Health Management*, IEEE, Jun. 2011, pp. 1–10. doi: 10.1109/ICPHM.2011.6024361.
- [46] B. D. Youn, C. Hu, and P. Wang, "Resilience-Driven System Design of Complex Engineered Systems," *Journal of Mechanical Design*, vol. 133, no. 10, Oct. 2011, doi: 10.1115/1.4004981.
- [47] E. Scanff, K. L. Feldman, S. Ghelam, P. Sandborn, M. Glade, and B. Foucher, "Life cycle cost impact of using prognostic health management (PHM) for helicopter avionics," *Microelectronics Reliability*, vol. 47, no. 12, pp. 1857–1864, Dec. 2007, doi: 10.1016/j.microrel.2007.02.014.

- [48] L. Li, Y. Peng, Y. Song, and D. Liu, "Lithium-Ion Battery Remaining Useful Life Prognostics Using Data-Driven Deep Learning Algorithm," in *Proceedings - 2018 Prognostics and System Health Management Conference, PHM-Chongqing 2018*, Institute of Electrical and Electronics Engineers Inc., Jan. 2019, pp. 1094–1100. doi: 10.1109/PHM-Chongqing.2018.00193.
- [49] G. Vachtsevanos, F. Lewis, M. Roemer, A. Hess, and B. Wu, *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*. Wiley, 2006. doi: 10.1002/9780470117842.
- [50] R. J. Hogan and I. B. Mason, "Deterministic Forecasts of Binary Events," in *Forecast Verification*, Wiley, 2011, pp. 31–59. doi: 10.1002/9781119960003.ch3.
- [51] O. F. Eker, F. Camci, and I. K. Jennions, "A New Hybrid Prognostic Methodology," *Int J Progn Health Manag*, vol. 10, no. 2, Jun. 2019, doi: 10.36001/ijphm.2019.v10i2.2727.
- [52] Jennions Ian K., *Integrated Vehicle Health Management: Essential Reading*. Society of Automotive Engineers, 2012.
- [53] H. Meriem, H. Nora, and O. Samir, "Predictive Maintenance for Smart Industrial Systems: A Roadmap," *Procedia Comput Sci*, vol. 220, pp. 645–650, 2023, doi: 10.1016/j.procs.2023.03.082.
- [54] A. Cubillo, S. Perinpanayagam, and M. Esperon-Miguez, "A review of physics-based models in prognostics: Application to gears and bearings of rotating machinery," *Advances in Mechanical Engineering*, vol. 8, no. 8, p. 168781401666466, Aug. 2016, doi: 10.1177/1687814016664660.
- [55] H. Zhang, R. Kang, and M. Pecht, "A hybrid prognostics and health management approach for condition-based maintenance," in *2009 IEEE International Conference on Industrial Engineering and Engineering Management*, IEEE, Dec. 2009, pp. 1165–1169. doi: 10.1109/IEEM.2009.5372976.
- [56] A. Saxena *et al.*, "Metrics for evaluating performance of prognostic techniques," in *2008 International Conference on Prognostics and Health Management*, IEEE, Oct. 2008, pp. 1–17. doi: 10.1109/PHM.2008.4711436.
- [57] E. Zio, "Prognostics and Health Management of Industrial Equipment," in *Diagnostics and Prognostics of Engineering Systems*, IGI Global, 2013, pp. 333–356. doi: 10.4018/978-1-4666-2095-7.ch017.
- [58] G. Vachtsevanos, "Performance metrics for fault prognosis of complex systems," in *Proceedings AUTOTESTCON 2003. IEEE Systems Readiness Technology Conference.*, IEEE, pp. 341–345. doi: 10.1109/AUTEST.2003.1243597.
- [59] D. L. Goodman, S. Wood, and A. Turner, "Return-on-investment (ROI) for electronic prognostics in mil/aero systems," in *IEEE Autotestcon, 2005.*, IEEE, pp. 73–75. doi: 10.1109/AUTEST.2005.1609105.

- [60] S. M. Wood and D. L. Goodman, "Return-on-Investment (ROI) for Electronic Prognostics in High Reliability Telecom Applications," in *INTELEC 06 - Twenty-Eighth International Telecommunications Energy Conference*, IEEE, Sep. 2006, pp. 1–3. doi: 10.1109/INTLEC.2006.251619.
- [61] G. Vachtsevanos, F. Lewis, M. Roemer, A. Hess, and B. Wu, *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*. Wiley, 2006. doi: 10.1002/9780470117842.
- [62] K. Goebel and P. Bonissone, "Prognostic information fusion for constant load systems," in *2005 7th International Conference on Information Fusion*, IEEE, 2005, p. 9 pp. doi: 10.1109/ICIF.2005.1592000.
- [63] S. Makridakis *et al.*, "The accuracy of extrapolation (time series) methods: Results of a forecasting competition," *J Forecast*, vol. 1, no. 2, pp. 111–153, Apr. 1982, doi: 10.1002/for.3980010202.
- [64] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *Int J Forecast*, vol. 22, no. 4, pp. 679–688, Oct. 2006, doi: 10.1016/j.ijforecast.2006.03.001.
- [65] S. Sankararaman and K. Goebel, "Uncertainty in Prognostics and Systems Health Management," *Int J Progn Health Manag*, vol. 6, no. 4, Nov. 2020, doi: 10.36001/ijphm.2015.v6i4.2319.
- [66] J. Honaker and G. King, "What to Do about Missing Values in Time-Series Cross-Section Data," *Am J Pol Sci*, vol. 54, no. 2, pp. 561–581, Apr. 2010, doi: 10.1111/j.1540-5907.2010.00447.x.
- [67] A. N. Baraldi and C. K. Enders, "An introduction to modern missing data analyses," *J Sch Psychol*, vol. 48, no. 1, pp. 5–37, Feb. 2010, doi: 10.1016/j.jsp.2009.10.001.
- [68] D. Vergouw *et al.*, "The search for stable prognostic models in multiple imputed data sets," *BMC Med Res Methodol*, vol. 10, no. 1, p. 81, Dec. 2010, doi: 10.1186/1471-2288-10-81.
- [69] M. Xu, P. Baraldi, S. Al-Dahidi, and E. Zio, "Fault prognostics by an ensemble of Echo State Networks in presence of event based measurements," *Eng Appl Artif Intell*, vol. 87, p. 103346, Jan. 2020, doi: 10.1016/j.engappai.2019.103346.
- [70] Weishan Dong and Xin Yao, "NichingEDA: Utilizing the diversity inside a population of EDAs for continuous optimization," in *2008 IEEE Congress on Evolutionary Computation (IEEE World Congress on Computational Intelligence)*, IEEE, Jun. 2008, pp. 1260–1267. doi: 10.1109/CEC.2008.4630958.
- [71] Zhenyu Yang, Ke Tang, and Xin Yao, "Self-adaptive differential evolution with neighborhood search," in *2008 IEEE Congress on Evolutionary Computation (IEEE World Congress on Computational Intelligence)*, IEEE, Jun. 2008, pp. 1110–1116. doi: 10.1109/CEC.2008.4630935.

- [72] C.-L. Hwang and K. Yoon, *Multiple Attribute Decision Making*, vol. 186. Berlin, Heidelberg: Springer Berlin Heidelberg, 1981. doi: 10.1007/978-3-642-48318-9.
- [73] E. Zio, "Reliability engineering: Old problems and new challenges," *Reliab Eng Syst Saf*, vol. 94, no. 2, pp. 125–141, Feb. 2009, doi: 10.1016/j.ress.2008.06.002.
- [74] X. Yang and F. Chen, "Deep Uncertainty Quantification of Prognostic Techniques for Proton Exchange Membrane Fuel Cell," Feb. 2022. doi: 10.4271/2022-01-7001.
- [75] J. C. Helton and F. J. Davis, "Illustration of Sampling-Based Methods for Uncertainty and Sensitivity Analysis," *Risk Analysis*, vol. 22, no. 3, pp. 591–622, Jun. 2002, doi: 10.1111/0272-4332.00041.
- [76] A. K. S. Jardine, D. Lin, and D. Banjevic, "A review on machinery diagnostics and prognostics implementing condition-based maintenance," *Mech Syst Signal Process*, vol. 20, no. 7, pp. 1483–1510, Oct. 2006, doi: 10.1016/j.ymssp.2005.09.012.
- [77] P. Baraldi and E. Zio, "A Combined Monte Carlo and Possibilistic Approach to Uncertainty Propagation in Event Tree Analysis," *Risk Analysis*, vol. 28, no. 5, pp. 1309–1326, Oct. 2008, doi: 10.1111/j.1539-6924.2008.01085.x.
- [78] O. Kammouh, P. Gardoni, and G. P. Cimellaro, "Probabilistic framework to evaluate the resilience of engineering systems using Bayesian and dynamic Bayesian networks," *Reliab Eng Syst Saf*, vol. 198, p. 106813, Jun. 2020, doi: 10.1016/j.ress.2020.106813.
- [79] S. Zheng, Y. Song, T. Leung, and I. Goodfellow, "Improving the Robustness of Deep Neural Networks via Stability Training," Jun. 2016.
- [80] M. Winter, B. Barnett, and K. Xu, "Before Li Ion Batteries," *Chem Rev*, vol. 118, no. 23, pp. 11433–11456, Dec. 2018, doi: 10.1021/acs.chemrev.8b00422.
- [81] G. E. Blomgren, "The Development and Future of Lithium Ion Batteries," *J Electrochem Soc*, vol. 164, no. 1, pp. A5019–A5025, Dec. 2017, doi: 10.1149/2.0251701jes.
- [82] M. V. Reddy, A. Mauger, C. M. Julien, A. Paolella, and K. Zaghib, "Brief History of Early Lithium-Battery Development," *Materials*, vol. 13, no. 8, p. 1884, Apr. 2020, doi: 10.3390/ma13081884.
- [83] B. Diouf and R. Pode, "Potential of lithium-ion batteries in renewable energy," *Renew Energy*, vol. 76, pp. 375–380, Apr. 2015, doi: 10.1016/j.renene.2014.11.058.
- [84] K.-H. Pettinger, A. Kampker, C.-R. Hohenthanner, C. Deutschens, H. Heimes, and A. vom Hemdt, "Lithium-ion cell and battery production processes," in *Lithium-Ion Batteries: Basics and Applications*, Berlin, Heidelberg: Springer Berlin Heidelberg, 2018, pp. 211–226. doi: 10.1007/978-3-662-53071-9_17.
- [85] M. M. Rahman, A. O. Oni, E. Gemechu, and A. Kumar, "Assessment of energy storage technologies: A review," *Energy Convers Manag*, vol. 223, p. 113295, Nov. 2020, doi: 10.1016/j.enconman.2020.113295.

- [86] G. E. Blomgren, "The Development and Future of Lithium Ion Batteries," *J Electrochem Soc*, vol. 164, no. 1, pp. A5019–A5025, Dec. 2017, doi: 10.1149/2.0251701jes.
- [87] D. Aurbach *et al.*, "A short review on the comparison between Li battery systems and rechargeable magnesium battery technology," *J Power Sources*, vol. 97–98, pp. 28–32, Jul. 2001, doi: 10.1016/S0378-7753(01)00585-7.
- [88] K. Chayambuka, G. Mulder, D. L. Danilov, and P. H. L. Notten, "From Li-Ion Batteries toward Na-Ion Chemistries: Challenges and Opportunities," *Adv Energy Mater*, vol. 10, no. 38, Oct. 2020, doi: 10.1002/aenm.202001310.
- [89] Y. Ding, Z. P. Cano, A. Yu, J. Lu, and Z. Chen, "Automotive Li-Ion Batteries: Current Status and Future Perspectives," *Electrochemical Energy Reviews*, vol. 2, no. 1, pp. 1–28, Mar. 2019, doi: 10.1007/s41918-018-0022-z.
- [90] D. Andre *et al.*, "Future generations of cathode materials: an automotive industry perspective," *J Mater Chem A Mater*, vol. 3, no. 13, pp. 6709–6732, 2015, doi: 10.1039/C5TA00361J.
- [91] T. Li, X.-Z. Yuan, L. Zhang, D. Song, K. Shi, and C. Bock, "Degradation Mechanisms and Mitigation Strategies of Nickel-Rich NMC-Based Lithium-Ion Batteries," *Electrochemical Energy Reviews*, vol. 3, no. 1, pp. 43–80, Mar. 2020, doi: 10.1007/s41918-019-00053-3.
- [92] "BU-205: Types of Lithium-ion," <https://batteryuniversity.com/article/bu-205-types-of-lithium-ion>.
- [93] A. G. Olabi *et al.*, "Battery energy storage systems and SWOT (strengths, weakness, opportunities, and threats) analysis of batteries in power transmission," *Energy*, vol. 254, p. 123987, Sep. 2022, doi: 10.1016/j.energy.2022.123987.
- [94] M. Schimpe, M. Edler von Kuepach, M. Naumann, H. C. Hesse, K. Smith, and A. Jossen, "Comprehensive Modeling of Temperature-Dependent Degradation Mechanisms in Lithium Iron Phosphate Batteries," *ECS Trans*, vol. 80, no. 10, pp. 147–170, Oct. 2017, doi: 10.1149/08010.0147ecst.
- [95] T. Baumhöfer, M. Brühl, S. Rothgang, and D. U. Sauer, "Production caused variation in capacity aging trend and correlation to initial cell performance," *J Power Sources*, vol. 247, pp. 332–338, Feb. 2014, doi: 10.1016/j.jpowsour.2013.08.108.
- [96] Shawn L. Minter, "Samsung Finally Explains the Galaxy Note 7 Exploding Battery Mess," <https://www.nbcnews.com/tech/tech-news/samsung-finally-explains-galaxy-note-7-exploding-battery-mess-n710581>.
- [97] Suat Vilgen / Kaynak: İhlas Haber Ajansı, "Tıra yüklü Tesla'lar cayır cayır yandı! Yangın tek araçta başladı," <https://www.tgrthaber.com/gundem/tira-yuklu-teslalar-cayir-cayir-yandi-yanin-tek-aracta-basladi-2909232>.
- [98] A. C. Thelen, S. Hu, and Z. Wang, "Machine learning-based aging models for estimating battery state of health and predicting future degradation."

- [99] M. Dubarry, M. Bercebar, A. Devie, D. Anseán, N. Omar, and I. Villarreal, “State of health battery estimator enabling degradation diagnosis: Model and algorithm description,” *J Power Sources*, vol. 360, pp. 59–69, Aug. 2017, doi: 10.1016/j.jpowsour.2017.05.121.
- [100] X. Han, M. Ouyang, L. Lu, J. Li, Y. Zheng, and Z. Li, “A comparative study of commercial lithium ion battery cycle life in electrical vehicle: Aging mechanism identification,” *J Power Sources*, vol. 251, pp. 38–54, Apr. 2014, doi: 10.1016/j.jpowsour.2013.11.029.
- [101] G. E. Karniadakis, I. G. Kevrekidis, L. Lu, P. Perdikaris, S. Wang, and L. Yang, “Physics-informed machine learning,” *Nature Reviews Physics*, vol. 3, no. 6, pp. 422–440, May 2021, doi: 10.1038/s42254-021-00314-5.
- [102] C. R. Birkl, M. R. Roberts, E. McTurk, P. G. Bruce, and D. A. Howey, “Degradation diagnostics for lithium ion cells,” *J Power Sources*, vol. 341, pp. 373–386, Feb. 2017, doi: 10.1016/j.jpowsour.2016.12.011.
- [103] A. Thelen *et al.*, “Integrating physics-based modeling and machine learning for degradation diagnostics of lithium-ion batteries,” *Energy Storage Mater*, vol. 50, pp. 668–695, Sep. 2022, doi: 10.1016/j.ensm.2022.05.047.
- [104] P. M. Attia, W. C. Chueh, and S. J. Harris, “Revisiting the $t^{0.5}$ Dependence of SEI Growth,” *J Electrochem Soc*, vol. 167, no. 9, p. 090535, Jan. 2020, doi: 10.1149/1945-7111/ab8ce4.
- [105] K. Liu, Y. Wang, and X. Lai, “Green Energy and Technology Data Science-Based Full-Lifespan Management of Lithium-Ion Battery.” [Online]. Available: <http://ebookcentral.proquest.com/lib/iuc/detail.action?docID=6950332>.
- [106] E. Peled, “The Electrochemical Behavior of Alkali and Alkaline Earth Metals in Nonaqueous Battery Systems—The Solid Electrolyte Interphase Model,” *J Electrochem Soc*, vol. 126, no. 12, pp. 2047–2051, Dec. 1979, doi: 10.1149/1.2128859.
- [107] C. Uhlmann, J. Illig, M. Ender, R. Schuster, and E. Ivers-Tiffée, “In situ detection of lithium metal plating on graphite in experimental cells,” *J Power Sources*, vol. 279, pp. 428–438, Apr. 2015, doi: 10.1016/j.jpowsour.2015.01.046.
- [108] A. Wang, S. Kadam, H. Li, S. Shi, and Y. Qi, “Review on modeling of the anode solid electrolyte interphase (SEI) for lithium-ion batteries,” *NPJ Comput Mater*, vol. 4, no. 1, p. 15, Mar. 2018, doi: 10.1038/s41524-018-0064-0.
- [109] M. Doyle and J. Newman, “The use of mathematical modeling in the design of lithium/polymer battery systems,” *Electrochim Acta*, vol. 40, no. 13–14, pp. 2191–2196, Oct. 1995, doi: 10.1016/0013-4686(95)00162-8.
- [110] J. Christensen and J. Newman, “A Mathematical Model for the Lithium-Ion Negative Electrode Solid Electrolyte Interphase,” *J Electrochem Soc*, vol. 151, no. 11, p. A1977, 2004, doi: 10.1149/1.1804812.

- [111] Y. Xie, J. Li, and C. Yuan, "Multiphysics modeling of lithium ion battery capacity fading process with solid-electrolyte interphase growth by elementary reaction kinetics," *J Power Sources*, vol. 248, pp. 172–179, Feb. 2014, doi: 10.1016/j.jpowsour.2013.09.059.
- [112] C. R. Birkl, M. R. Roberts, E. McTurk, P. G. Bruce, and D. A. Howey, "Degradation diagnostics for lithium ion cells," *J Power Sources*, vol. 341, pp. 373–386, Feb. 2017, doi: 10.1016/j.jpowsour.2016.12.011.
- [113] S. Santhanagopalan, Q. Guo, P. Ramadass, and R. E. White, "Review of models for predicting the cycling performance of lithium ion batteries," *J Power Sources*, vol. 156, no. 2, pp. 620–628, Jun. 2006, doi: 10.1016/j.jpowsour.2005.05.070.
- [114] L. Liu and M. Zhu, "Modeling of SEI Layer Growth and Electrochemical Impedance Spectroscopy Response using a Thermal-Electrochemical Model of Li-ion Batteries," *ECS Trans*, vol. 61, no. 27, pp. 43–61, Oct. 2014, doi: 10.1149/06127.0043ecst.
- [115] S. Santhanagopalan and R. E. White, "Online estimation of the state of charge of a lithium ion cell," *J Power Sources*, vol. 161, no. 2, pp. 1346–1355, Oct. 2006, doi: 10.1016/j.jpowsour.2006.04.146.
- [116] A. M. Colclasure and R. J. Kee, "Thermodynamically consistent modeling of elementary electrochemistry in lithium-ion batteries," *Electrochim Acta*, vol. 55, no. 28, pp. 8960–8973, Dec. 2010, doi: 10.1016/j.electacta.2010.08.018.
- [117] M. Heinrich *et al.*, "Physico-Chemical Modeling of a Lithium-Ion Battery: An Ageing Study with Electrochemical Impedance Spectroscopy," *Batter Supercaps*, vol. 2, no. 6, pp. 530–540, Jun. 2019, doi: 10.1002/batt.201900011.
- [118] J. Christensen and J. Newman, "A Mathematical Model of Stress Generation and Fracture in Lithium Manganese Oxide," *J Electrochem Soc*, vol. 153, no. 6, p. A1019, 2006, doi: 10.1149/1.2185287.
- [119] R. Deshpande, Y. Qi, and Y.-T. Cheng, "Effects of Concentration-Dependent Elastic Modulus on Diffusion-Induced Stresses for Battery Applications," *J Electrochem Soc*, vol. 157, no. 8, p. A967, 2010, doi: 10.1149/1.3454762.
- [120] R. D. Deshpande and D. M. Bernardi, "Modeling Solid-Electrolyte Interphase (SEI) Fracture: Coupled Mechanical/Chemical Degradation of the Lithium Ion Battery," *J Electrochem Soc*, vol. 164, no. 2, pp. A461–A474, Jan. 2017, doi: 10.1149/2.0841702jes.
- [121] A. Karger *et al.*, "Modeling Particle Versus SEI Cracking in Lithium-Ion Battery Degradation: Why Calendar and Cycle Aging Cannot Simply be Added," *J Electrochem Soc*, vol. 171, no. 9, p. 090512, Sep. 2024, doi: 10.1149/1945-7111/ad76da.
- [122] J. Li, K. Adewuyi, N. Lotfi, R. G. Landers, and J. Park, "A single particle model with chemical/mechanical degradation physics for lithium ion battery State of Health (SOH) estimation," *Appl Energy*, vol. 212, pp. 1178–1190, Feb. 2018, doi: 10.1016/j.apenergy.2018.01.011.

- [123] X.-G. Yang, Y. Leng, G. Zhang, S. Ge, and C.-Y. Wang, "Modeling of lithium plating induced aging of lithium-ion batteries: Transition from linear to nonlinear aging," *J Power Sources*, vol. 360, pp. 28–40, Aug. 2017, doi: 10.1016/j.jpowsour.2017.05.110.
- [124] A. Barré, B. Deguilhem, S. Grolleau, M. Gérard, F. Suard, and D. Riu, "A review on lithium-ion battery ageing mechanisms and estimations for automotive applications," *J Power Sources*, vol. 241, pp. 680–689, Nov. 2013, doi: 10.1016/j.jpowsour.2013.05.040.
- [125] P. Arora, M. Doyle, and R. E. White, "Mathematical Modeling of the Lithium Deposition Overcharge Reaction in Lithium-Ion Batteries Using Carbon-Based Negative Electrodes," *J Electrochem Soc*, vol. 146, no. 10, pp. 3543–3553, Oct. 1999, doi: 10.1149/1.1392512.
- [126] M. Doyle, T. F. Fuller, and J. Newman, "Modeling of Galvanostatic Charge and Discharge of the Lithium/Polymer/Insertion Cell," *J Electrochem Soc*, vol. 140, no. 6, pp. 1526–1533, Jun. 1993, doi: 10.1149/1.2221597.
- [127] R. Xiong *et al.*, "Revealing the onset condition of Li plating on graphite electrodes under fast-charging," *J Mater Chem A Mater*, vol. 11, no. 31, pp. 16605–16615, 2023, doi: 10.1039/D3TA02968A.
- [128] D. Ren *et al.*, "Investigation of Lithium Plating-Stripping Process in Li-Ion Batteries at Low Temperature Using an Electrochemical Model," *J Electrochem Soc*, vol. 165, no. 10, pp. A2167–A2178, Jul. 2018, doi: 10.1149/2.0661810jes.
- [129] C. von Lüders, J. Keil, M. Webersberger, and A. Jossen, "Modeling of lithium plating and lithium stripping in lithium-ion batteries," *J Power Sources*, vol. 414, pp. 41–47, Feb. 2019, doi: 10.1016/j.jpowsour.2018.12.084.
- [130] K. Ando, T. Matsuda, and D. Imamura, "Degradation diagnosis of lithium-ion batteries with a $\text{LiNi}_{0.5}\text{Co}_{0.2}\text{Mn}_{0.3}\text{O}_2$ and LiMn_2O_4 blended cathode using dV/dQ curve analysis," *J Power Sources*, vol. 390, pp. 278–285, Jun. 2018, doi: 10.1016/j.jpowsour.2018.04.043.
- [131] R. Xu, H. Sun, L. S. de Vasconcelos, and K. Zhao, "Mechanical and Structural Degradation of $\text{LiNi}_x\text{Mn}_y\text{Co}_z\text{O}_2$ Cathode in Li-Ion Batteries: An Experimental Study," *J Electrochem Soc*, vol. 164, no. 13, pp. A3333–A3341, Nov. 2017, doi: 10.1149/2.1751713jes.
- [132] B. Wu and W. Lu, "A battery model that fully couples mechanics and electrochemistry at both particle and electrode levels by incorporation of particle interaction," *J Power Sources*, vol. 360, pp. 360–372, Aug. 2017, doi: 10.1016/j.jpowsour.2017.05.115.
- [133] Y. Zhang, C. Zhao, and Z. Guo, "Simulation of crack behavior of secondary particles in Li-ion battery electrodes during lithiation/de-lithiation cycles," *Int J Mech Sci*, vol. 155, pp. 178–186, May 2019, doi: 10.1016/j.ijmecsci.2019.02.042.
- [134] S. Yang, Y. Hua, D. Qiao, Y. Lian, Y. Pan, and Y. He, "A coupled electrochemical-thermal-mechanical degradation modelling approach for lifetime assessment of

- lithium-ion batteries,” *Electrochim Acta*, vol. 326, p. 134928, Dec. 2019, doi: 10.1016/j.electacta.2019.134928.
- [135] C. Fan, X. Tian, and C. Gu, “Perturbation-Based Battery Impedance Characterization Methods: From the Laboratory to Practical Implementation,” *Batteries*, vol. 10, no. 12, p. 414, Nov. 2024, doi: 10.3390/batteries10120414.
- [136] C. Lin, A. Tang, and W. Wang, “A Review of SOH Estimation Methods in Lithium-ion Batteries for Electric Vehicle Applications,” *Energy Procedia*, vol. 75, pp. 1920–1925, Aug. 2015, doi: 10.1016/j.egypro.2015.07.199.
- [137] Z. Ren and C. Du, “A review of machine learning state-of-charge and state-of-health estimation algorithms for lithium-ion batteries,” *Energy Reports*, vol. 9, pp. 2993–3021, Dec. 2023, doi: 10.1016/j.egyr.2023.01.108.
- [138] Y. Gao, J. Jiang, C. Zhang, W. Zhang, Z. Ma, and Y. Jiang, “Lithium-ion battery aging mechanisms and life model under different charging stresses,” *J Power Sources*, vol. 356, pp. 103–114, Jul. 2017, doi: 10.1016/j.jpowsour.2017.04.084.
- [139] S. S. Zhang, “The effect of the charging protocol on the cycle life of a Li-ion battery,” *J Power Sources*, vol. 161, no. 2, pp. 1385–1391, Oct. 2006, doi: 10.1016/j.jpowsour.2006.06.040.
- [140] S. S. Choi and H. S. Lim, “Factors that affect cycle-life and possible degradation mechanisms of a Li-ion cell based on LiCoO₂,” *J Power Sources*, vol. 111, no. 1, pp. 130–136, Sep. 2002, doi: 10.1016/S0378-7753(02)00305-1.
- [141] S. Saxena, C. Hendricks, and M. Pecht, “Cycle life testing and modeling of graphite/LiCoO₂ cells under different state of charge ranges,” *J Power Sources*, vol. 327, pp. 394–400, Sep. 2016, doi: 10.1016/j.jpowsour.2016.07.057.
- [142] A. I. Pózna, K. M. Hangos, and A. Magyar, “Design of Experiments for Battery Aging Estimation,” *IFAC-PapersOnLine*, vol. 51, no. 28, pp. 386–391, 2018, doi: 10.1016/j.ifacol.2018.11.733.
- [143] R. P. Ramasamy, R. E. White, and B. N. Popov, “Calendar life performance of pouch lithium-ion cells,” *J Power Sources*, vol. 141, no. 2, pp. 298–306, Mar. 2005, doi: 10.1016/j.jpowsour.2004.09.024.
- [144] F. Leng, C. M. Tan, and M. Pecht, “Effect of Temperature on the Aging rate of Li Ion Battery Operating above Room Temperature,” *Sci Rep*, vol. 5, no. 1, p. 12967, Aug. 2015, doi: 10.1038/srep12967.
- [145] S. S. Zhang, K. Xu, and T. R. Jow, “Electrochemical impedance study on the low temperature of Li-ion batteries,” *Electrochim Acta*, vol. 49, no. 7, pp. 1057–1061, Mar. 2004, doi: 10.1016/j.electacta.2003.10.016.
- [146] M. Ouyang *et al.*, “Low temperature aging mechanism identification and lithium deposition in a large format lithium iron phosphate battery for different charge profiles,” *J Power Sources*, vol. 286, pp. 309–320, Jul. 2015, doi: 10.1016/j.jpowsour.2015.03.178.

- [147] S. Watanabe, M. Kinoshita, T. Hosokawa, K. Morigaki, and K. Nakura, "Capacity fading of $\text{LiAl}_y\text{Ni}_{1-x-y}\text{Co}_x\text{O}_2$ cathode for lithium-ion batteries during accelerated calendar and cycle life tests (effect of depth of discharge in charge-discharge cycling on the suppression of the micro-crack generation of $\text{LiAl}_y\text{Ni}_{1-x-y}\text{Co}_x\text{O}_2$ particle)," *J Power Sources*, vol. 260, pp. 50–56, Aug. 2014, doi: 10.1016/j.jpowsour.2014.02.103.
- [148] J. R. Belt, C. D. Ho, C. G. Motloch, T. J. Miller, and T. Q. Duong, "A capacity and power fade study of Li-ion cells during life cycle testing," *J Power Sources*, vol. 123, no. 2, pp. 241–246, Sep. 2003, doi: 10.1016/S0378-7753(03)00537-8.
- [149] M. Ouyang *et al.*, "Overcharge-induced capacity fading analysis for large format lithium-ion batteries with $\text{Li Ni}_{1/3}\text{Co}_{1/3}\text{Mn}_{1/3}\text{O}_2 + \text{Li Mn}_2\text{O}_4$ composite cathode," *J Power Sources*, vol. 279, pp. 626–635, Apr. 2015, doi: 10.1016/j.jpowsour.2015.01.051.
- [150] R. Guo, L. Lu, M. Ouyang, and X. Feng, "Mechanism of the entire overdischarge process and overdischarge-induced internal short circuit in lithium-ion batteries," *Sci Rep*, vol. 6, no. 1, p. 30248, Jul. 2016, doi: 10.1038/srep30248.
- [151] S. Barcellona, L. Codecasa, S. Colnago, and L. Piegari, "Calendar Aging Effect on the Open Circuit Voltage of Lithium-Ion Battery," *Energies (Basel)*, vol. 16, no. 13, p. 4869, Jun. 2023, doi: 10.3390/en16134869.
- [152] M. Broussely *et al.*, "Main aging mechanisms in Li ion batteries," *J Power Sources*, vol. 146, no. 1–2, pp. 90–96, Aug. 2005, doi: 10.1016/j.jpowsour.2005.03.172.
- [153] J. Li, K. Adewuyi, N. Lotfi, R. G. Landers, and J. Park, "A single particle model with chemical/mechanical degradation physics for lithium ion battery State of Health (SOH) estimation," *Appl Energy*, vol. 212, pp. 1178–1190, Feb. 2018, doi: 10.1016/j.apenergy.2018.01.011.
- [154] J. Belt, V. Utgikar, and I. Bloom, "Calendar and PHEV cycle life aging of high-energy, lithium-ion cells containing blended spinel and layered-oxide cathodes," *J Power Sources*, vol. 196, no. 23, pp. 10213–10221, Dec. 2011, doi: 10.1016/j.jpowsour.2011.08.067.
- [155] T. C. Bach *et al.*, "Nonlinear aging of cylindrical lithium-ion cells linked to heterogeneous compression," *J Energy Storage*, vol. 5, pp. 212–223, Feb. 2016, doi: 10.1016/j.est.2016.01.003.
- [156] H. J. Ploehn, P. Ramadass, and R. E. White, "Solvent Diffusion Model for Aging of Lithium-Ion Battery Cells," *J Electrochem Soc*, vol. 151, no. 3, p. A456, 2004, doi: 10.1149/1.1644601.
- [157] S. Abada, M. Petit, A. Lecocq, G. Marlair, V. Sauvant-Moynot, and F. Huet, "Combined experimental and modeling approaches of the thermal runaway of fresh and aged lithium-ion batteries," *J Power Sources*, vol. 399, pp. 264–273, Sep. 2018, doi: 10.1016/j.jpowsour.2018.07.094.

- [158] J. Cannarella and C. B. Arnold, "Stress evolution and capacity fade in constrained lithium-ion pouch cells," *J Power Sources*, vol. 245, pp. 745–751, Jan. 2014, doi: 10.1016/j.jpowsour.2013.06.165.
- [159] J. Keil, N. Paul, V. Baran, P. Keil, R. Gilles, and A. Jossen, "Linear and Nonlinear Aging of Lithium-Ion Cells Investigated by Electrochemical Analysis and In-Situ Neutron Diffraction," *J Electrochem Soc*, vol. 166, no. 16, pp. A3908–A3917, Nov. 2019, doi: 10.1149/2.1271915jes.
- [160] T. C. Bach *et al.*, "Nonlinear aging of cylindrical lithium-ion cells linked to heterogeneous compression," *J Energy Storage*, vol. 5, pp. 212–223, Feb. 2016, doi: 10.1016/j.est.2016.01.003.
- [161] T. Raj, A. A. Wang, C. W. Monroe, and D. A. Howey, "Investigation of Path-Dependent Degradation in Lithium-Ion Batteries**," *Batter Supercaps*, vol. 3, no. 12, pp. 1377–1385, Dec. 2020, doi: 10.1002/batt.202000160.
- [162] G. L. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs," *J Power Sources*, vol. 134, no. 2, pp. 252–261, Aug. 2004, doi: 10.1016/j.jpowsour.2004.02.031.
- [163] W. Li, N. Sengupta, P. Dechent, D. Howey, A. Annaswamy, and D. U. Sauer, "Online capacity estimation of lithium-ion batteries with deep long short-term memory networks," *J Power Sources*, vol. 482, p. 228863, Jan. 2021, doi: 10.1016/j.jpowsour.2020.228863.
- [164] C. Su and H. J. Chen, "A review on prognostics approaches for remaining useful life of lithium-ion battery," *IOP Conf Ser Earth Environ Sci*, vol. 93, p. 012040, Nov. 2017, doi: 10.1088/1755-1315/93/1/012040.
- [165] J. Li, M. Zhang, H. Zheng, and J. Jie, "Battery remaining useful life prediction using improved mutated particle filter," *Energy Storage*, vol. 3, no. 1, Feb. 2021, doi: 10.1002/est2.218.
- [166] J. Liu, A. Saxena, K. Goebel, B. Saha, and W. Wang, "An Adaptive Recurrent Neural Network for Remaining Useful Life Prediction of Lithium-ion Batteries," *Annual Conference of the PHM Society*, vol. 2, no. 1, Oct. 2010, doi: 10.36001/phmconf.2010.v2i1.1896.
- [167] S. Atalay, M. Sheikh, A. Mariani, Y. Merla, E. Bower, and W. D. Widanage, "Theory of battery ageing in a lithium-ion battery: Capacity fade, nonlinear ageing and lifetime prediction," *J Power Sources*, vol. 478, p. 229026, Dec. 2020, doi: 10.1016/j.jpowsour.2020.229026.
- [168] K. Goebel, B. Saha, A. Saxena, J. Celaya, and J. Christophersen, "Prognostics in Battery Health Management," *IEEE Instrum Meas Mag*, vol. 11, no. 4, pp. 33–40, Aug. 2008, doi: 10.1109/MIM.2008.4579269.
- [169] V. Sulzer, P. Mohtat, S. Lee, J. B. Siegel, and A. G. Stefanopoulou, "Promise and Challenges of a Data-Driven Approach for Battery Lifetime Prognostics," in *2021*

- American Control Conference (ACC)*, IEEE, May 2021, pp. 4427–4433. doi: 10.23919/ACC50511.2021.9483312.
- [170] Y. Wen, R. Wolski, and C. Krintz, “Online Prediction of Battery Lifetime for Embedded and Mobile Devices,” 2005, pp. 57–72. doi: 10.1007/978-3-540-28641-7_5.
 - [171] C. Strange and G. dos Reis, “Prediction of future capacity and internal resistance of Li-ion cells from one cycle of input data,” *Energy and AI*, vol. 5, p. 100097, Sep. 2021, doi: 10.1016/j.egyai.2021.100097.
 - [172] W. Diao, S. Saxena, B. Han, and M. Pecht, “Algorithm to Determine the Knee Point on Capacity Fade Curves of Lithium-Ion Cells,” *Energies (Basel)*, vol. 12, no. 15, p. 2910, Jul. 2019, doi: 10.3390/en12152910.
 - [173] M. L. Baptista, E. M. P. Henriques, and K. Goebel, “More effective prognostics with elbow point detection and deep learning,” *Mech Syst Signal Process*, vol. 146, p. 106987, Jan. 2021, doi: 10.1016/j.ymssp.2020.106987.
 - [174] T. R. Ashwin, A. Barai, K. Uddin, L. Somerville, A. McGordon, and J. Marco, “Prediction of battery storage ageing and solid electrolyte interphase property estimation using an electrochemical model,” *J Power Sources*, vol. 385, pp. 141–147, May 2018, doi: 10.1016/j.jpowsour.2018.03.010.
 - [175] C. Zhang, S. Zhao, Z. Yang, and Y. Chen, “A reliable data-driven state-of-health estimation model for lithium-ion batteries in electric vehicles,” *Front Energy Res*, vol. 10, Sep. 2022, doi: 10.3389/fenrg.2022.1013800.
 - [176] T. Baumhöfer, M. Brühl, S. Rothgang, and D. U. Sauer, “Production caused variation in capacity aging trend and correlation to initial cell performance,” *J Power Sources*, vol. 247, pp. 332–338, Feb. 2014, doi: 10.1016/j.jpowsour.2013.08.108.
 - [177] C. Delacourt and M. Safari, “Life Simulation of a Graphite/LiFePO₄ Cell under Cycling and Storage,” *J Electrochem Soc*, vol. 159, no. 8, pp. A1283–A1291, Jan. 2012, doi: 10.1149/2.049208jes.
 - [178] R. Deshpande, M. Verbrugge, Y.-T. Cheng, J. Wang, and P. Liu, “Battery Cycle Life Prediction with Coupled Chemical Degradation and Fatigue Mechanics,” *J Electrochem Soc*, vol. 159, no. 10, pp. A1730–A1738, Jan. 2012, doi: 10.1149/2.049210jes.
 - [179] J. Purewal, J. Wang, J. Graetz, S. Soukiazian, H. Tataria, and M. W. Verbrugge, “Degradation of lithium ion batteries employing graphite negatives and nickel–cobalt–manganese oxide + spinel manganese oxide positives: Part 2, chemical–mechanical degradation model,” *J Power Sources*, vol. 272, pp. 1154–1161, Dec. 2014, doi: 10.1016/j.jpowsour.2014.07.028.
 - [180] J. Cannarella and C. B. Arnold, “The Effects of Defects on Localized Plating in Lithium-Ion Batteries,” *J Electrochem Soc*, vol. 162, no. 7, pp. A1365–A1373, Apr. 2015, doi: 10.1149/2.1051507jes.

- [181] S. S. Madani, E. Schaltz, and S. K. Kær, "A Review of Different Electric Equivalent Circuit Models and Parameter Identification Methods of Lithium-Ion Batteries," *ECS Trans*, vol. 87, no. 1, pp. 23–37, Nov. 2018, doi: 10.1149/08701.0023ecst.
- [182] G. L. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs," *J Power Sources*, vol. 134, no. 2, pp. 262–276, Aug. 2004, doi: 10.1016/j.jpowsour.2004.02.032.
- [183] Y. Li *et al.*, "Data-driven health estimation and lifetime prediction of lithium-ion batteries: A review," *Renewable and Sustainable Energy Reviews*, vol. 113, p. 109254, Oct. 2019, doi: 10.1016/j.rser.2019.109254.
- [184] B. YANNLIAW, "Modeling of lithium ion cells?A simple equivalent-circuit model approach," *Solid State Ion*, vol. 175, no. 1–4, pp. 835–839, Nov. 2004, doi: 10.1016/j.ssi.2004.09.049.
- [185] Z. Ma, R. Yang, and Z. Wang, "A novel data-model fusion state-of-health estimation approach for lithium-ion batteries," *Appl Energy*, vol. 237, pp. 836–847, Mar. 2019, doi: 10.1016/j.apenergy.2018.12.071.
- [186] S. B. Vilsen, S. K. Kaer, and D.-I. Stroe, "Log-Linear Model for Predicting the Lithium-ion Battery Age Based on Resistance Extraction from Dynamic Aging Profiles," *IEEE Trans Ind Appl*, vol. 56, no. 6, pp. 6937–6948, Nov. 2020, doi: 10.1109/TIA.2020.3020529.
- [187] V. N. Vapnik, "The Support Vector method," 1997, pp. 261–271. doi: 10.1007/BFb0020166.
- [188] Y. SONG, D. LIU, Y. HOU, J. YU, and Y. PENG, "Satellite lithium-ion battery remaining useful life estimation with an iterative updated RVM fused with the KF algorithm," *Chinese Journal of Aeronautics*, vol. 31, no. 1, pp. 31–40, Jan. 2018, doi: 10.1016/j.cja.2017.11.010.
- [189] Y. Li *et al.*, "Random forest regression for online capacity estimation of lithium-ion batteries," *Appl Energy*, vol. 232, pp. 197–210, Dec. 2018, doi: 10.1016/j.apenergy.2018.09.182.
- [190] X. Hu, L. Xu, X. Lin, and M. Pecht, "Battery Lifetime Prognostics," *Joule*, vol. 4, no. 2, pp. 310–346, Feb. 2020, doi: 10.1016/J.JOULE.2019.11.018.
- [191] 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, doi: 10.1109/ACCESS.2019.2905740.
- [192] S. Theodoridis, "Bayesian Learning," *Mach Learn*, pp. 639–706, 2015, doi: 10.1016/B978-0-12-801522-3.00013-6.
- [193] S. Li, H. He, and J. Li, "Big data driven lithium-ion battery modeling method based on SDAE-ELM algorithm and data pre-processing technology," *Appl Energy*, vol. 242, pp. 1259–1273, May 2019, doi: 10.1016/J.APENERGY.2019.03.154.

- [194] P. M. Attia *et al.*, “Review—‘Knees’ in Lithium-Ion Battery Aging Trajectories,” *J Electrochem Soc*, vol. 169, no. 6, p. 060517, Jun. 2022, doi: 10.1149/1945-7111/ac6d13.
- [195] H. You *et al.*, “Nonlinear health evaluation for lithium-ion battery within full-lifespan,” *Journal of Energy Chemistry*, vol. 72, pp. 333–341, Sep. 2022, doi: 10.1016/j.jechem.2022.04.013.
- [196] Z. Mao, M. Farkhondeh, M. Pritzker, M. Fowler, and Z. Chen, “Calendar Aging and Gas Generation in Commercial Graphite/NMC-LMO Lithium-Ion Pouch Cell,” *J Electrochem Soc*, vol. 164, no. 14, pp. A3469–A3483, Nov. 2017, doi: 10.1149/2.0241714jes.
- [197] J. M. Reniers, G. Mulder, and D. A. Howey, “Review and Performance Comparison of Mechanical-Chemical Degradation Models for Lithium-Ion Batteries,” *J Electrochem Soc*, vol. 166, no. 14, pp. A3189–A3200, Sep. 2019, doi: 10.1149/2.0281914jes.
- [198] Y. Chen *et al.*, “A review of lithium-ion battery safety concerns: The issues, strategies, and testing standards,” *Journal of Energy Chemistry*, vol. 59, pp. 83–99, Aug. 2021, doi: 10.1016/j.jechem.2020.10.017.
- [199] W. Diao, J. Kim, M. H. Azarian, and M. Pecht, “Degradation modes and mechanisms analysis of lithium-ion batteries with knee points,” *Electrochim Acta*, vol. 431, p. 141143, Nov. 2022, doi: 10.1016/j.electacta.2022.141143.
- [200] V. Satopaa, J. Albrecht, D. Irwin, and B. Raghavan, “Finding a ‘Kneedle’ in a Haystack: Detecting Knee Points in System Behavior,” in *2011 31st International Conference on Distributed Computing Systems Workshops*, IEEE, Jun. 2011, pp. 166–171. doi: 10.1109/ICDCSW.2011.20.
- [201] K. A. Severson *et al.*, “Data-driven prediction of battery cycle life before capacity degradation,” *Nat Energy*, vol. 4, no. 5, pp. 383–391, May 2019, doi: 10.1038/s41560-019-0356-8.
- [202] B. Saha, K. Goebel, and J. Christophersen, “Comparison of prognostic algorithms for estimating remaining useful life of batteries,” *Transactions of the Institute of Measurement and Control*, vol. 31, no. 3–4, pp. 293–308, 2009, doi: 10.1177/0142331208092030.
- [203] “Battery Data | Center for Advanced Life Cycle Engineering.” Accessed: Dec. 04, 2024. [Online]. Available: <https://calce.umd.edu/battery-data>
- [204] A. Nuhic, T. Terzimehic, T. Soczka-Guth, M. Buchholz, and K. Dietmayer, “Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods,” *J Power Sources*, vol. 239, pp. 680–688, Oct. 2013, doi: 10.1016/j.jpowsour.2012.11.146.
- [205] “Reference Toyota Research Institute. Experimental data platform,” <https://data.matr.io/1/>.

- [206] K. A. Severson *et al.*, “Data-driven prediction of battery cycle life before capacity degradation,” *Nat Energy*, vol. 4, no. 5, pp. 383–391, Mar. 2019, doi: 10.1038/s41560-019-0356-8.
- [207] C. Strange, S. Li, R. Gilchrist, and G. dos Reis, “Elbows of Internal Resistance Rise Curves in Li-Ion Cells,” *Energies (Basel)*, vol. 14, no. 4, p. 1206, Feb. 2021, doi: 10.3390/en14041206.
- [208] C. Strange, S. Li, R. Gilchrist, and G. dos Reis, “Elbows of Internal Resistance Rise Curves in Li-Ion Cells,” *Energies (Basel)*, vol. 14, no. 4, p. 1206, Feb. 2021, doi: 10.3390/en14041206.
- [209] T. Raj, A. A. Wang, C. W. Monroe, and D. A. Howey, “Investigation of Path-Dependent Degradation in Lithium-Ion Batteries**,” *Batter Supercaps*, vol. 3, no. 12, pp. 1377–1385, Dec. 2020, doi: 10.1002/batt.202000160.
- [210] T. Raj, “Path Dependent Battery Degradation Dataset Part 1,” 2020, *University of Oxford*.
- [211] P. Dechent, S. Greenbank, F. Hildenbrand, S. Jbabdi, D. U. Sauer, and D. A. Howey, “Estimation of Li-Ion Degradation Test Sample Sizes Required to Understand Cell-to-Cell Variability**,” *Batter Supercaps*, vol. 4, no. 12, pp. 1821–1829, Dec. 2021, doi: 10.1002/batt.202100148.
- [212] L. Willenberg *et al.*, “The Development of Jelly Roll Deformation in 18650 Lithium-Ion Batteries at Low State of Charge,” *J Electrochem Soc*, vol. 167, no. 12, p. 120502, Jan. 2020, doi: 10.1149/1945-7111/aba96d.
- [213] D. U. Sauer, “Time-series cyclic aging data on 48 commercial NMC/graphite Sanyo/Panasonic UR18650E cylindrical cells,” 2011.
- [214] W. Li, N. Sengupta, P. Dechent, D. Howey, A. Annaswamy, and D. U. Sauer, “One-shot battery degradation trajectory prediction with deep learning,” *J Power Sources*, vol. 506, p. 230024, Sep. 2021, doi: 10.1016/j.jpowsour.2021.230024.
- [215] A. Mistry *et al.*, “A Minimal Information Set To Enable Verifiable Theoretical Battery Research,” *ACS Energy Lett*, vol. 6, no. 11, pp. 3831–3835, Nov. 2021, doi: 10.1021/acsenerylett.1c01710.
- [216] W. Li, N. Sengupta, P. Dechent, D. Howey, A. Annaswamy, and D. U. Sauer, “One-shot battery degradation trajectory prediction with deep learning,” *J Power Sources*, vol. 506, p. 230024, Sep. 2021, doi: 10.1016/j.jpowsour.2021.230024.
- [217] W. Li, N. Sengupta, P. Dechent, D. Howey, A. Annaswamy, and D. U. Sauer, “Online capacity estimation of lithium-ion batteries with deep long short-term memory networks,” *J Power Sources*, vol. 482, p. 228863, Jan. 2021, doi: 10.1016/J.JPOWSOUR.2020.228863.
- [218] M. Lucu *et al.*, “Data-driven nonparametric Li-ion battery ageing model aiming at learning from real operation data – Part A: Storage operation,” *J Energy Storage*, vol. 30, p. 101409, Aug. 2020, doi: 10.1016/J.EST.2020.101409.

- [219] J. Xiong, T. X. Lei, D. M. Fu, J. W. Wu, and T. Y. Zhang, "Data driven discovery of an analytic formula for the life prediction of Lithium-ion batteries," *Progress in Natural Science: Materials International*, vol. 32, no. 6, pp. 793–799, Dec. 2022, doi: 10.1016/J.PNSC.2022.12.002.
- [220] R. R. Richardson, M. A. Osborne, and D. A. Howey, "Battery health prediction under generalized conditions using a Gaussian process transition model," *J Energy Storage*, vol. 23, pp. 320–328, Jun. 2019, doi: 10.1016/J.EST.2019.03.022.
- [221] M. Schimpe, M. E. von Kuepach, M. Naumann, H. C. Hesse, K. Smith, and A. Jossen, "Comprehensive Modeling of Temperature-Dependent Degradation Mechanisms in Lithium Iron Phosphate Batteries," *J Electrochem Soc*, vol. 165, no. 2, pp. A181–A193, 2018, doi: 10.1149/2.1181714JES.
- [222] X. Hu, Y. Che, X. Lin, and S. Onori, "Battery Health Prediction Using Fusion-Based Feature Selection and Machine Learning," *IEEE Transactions on Transportation Electrification*, vol. 7, no. 2, pp. 382–398, Jun. 2021, doi: 10.1109/TTE.2020.3017090.
- [223] Y. Song, D. Liu, and Y. Peng, "Data-driven on-line health assessment for lithium-ion battery with uncertainty presentation," *2018 IEEE International Conference on Prognostics and Health Management, ICPHM 2018*, Aug. 2018, doi: 10.1109/ICPHM.2018.8448707.
- [224] D. Yang, X. Zhang, R. Pan, Y. Wang, and Z. Chen, "A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve," *J Power Sources*, vol. 384, pp. 387–395, Apr. 2018, doi: 10.1016/j.jpowsour.2018.03.015.
- [225] Z. Yun and W. Qin, "Remaining Useful Life Estimation of Lithium-Ion Batteries Based on Optimal Time Series Health Indicator," *IEEE Access*, vol. 8, pp. 55447–55461, 2020, doi: 10.1109/ACCESS.2020.2981947.
- [226] M. Lucu *et al.*, "Data-driven nonparametric Li-ion battery ageing model aiming at learning from real operation data – Part A: Storage operation," *J Energy Storage*, vol. 30, p. 101409, Aug. 2020, doi: 10.1016/j.est.2020.101409.
- [227] K. S. R. Mawonou, A. Eddahech, D. Dumur, D. Beauvois, and E. Godoy, "State-of-health estimators coupled to a random forest approach for lithium-ion battery aging factor ranking," *J Power Sources*, vol. 484, p. 229154, Feb. 2021, doi: 10.1016/j.jpowsour.2020.229154.
- [228] 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 Trans Veh Technol*, vol. 68, no. 5, pp. 4110–4121, May 2019, doi: 10.1109/TVT.2018.2864688.
- [229] J. Xiong, T.-X. Lei, D.-M. Fu, J.-W. Wu, and T.-Y. Zhang, "Data driven discovery of an analytic formula for the life prediction of Lithium-ion batteries," *Progress in Natural Science: Materials International*, vol. 32, no. 6, pp. 793–799, Dec. 2022, doi: 10.1016/j.pnsc.2022.12.002.

- [230] C. R. Birkel, M. R. Roberts, E. McTurk, P. G. Bruce, and D. A. Howey, "Degradation diagnostics for lithium ion cells," *J Power Sources*, vol. 341, pp. 373–386, Feb. 2017, doi: 10.1016/j.jpowsour.2016.12.011.
 - [231] R. R. Richardson, M. A. Osborne, and D. A. Howey, "Battery health prediction under generalized conditions using a Gaussian process transition model," *J Energy Storage*, vol. 23, pp. 320–328, Jun. 2019, doi: 10.1016/j.est.2019.03.022.
 - [232] C. Cortes and V. Vapnik, "Support-vector networks," *Chem. Biol. Drug Des.*, vol. 297, pp. 273–297, Jun. 2009, doi: 10.1007/%2F00994018.
 - [233] A. Smola and B. Schölkopf, "A tutorial on support vector regression," *Stat Comput*, vol. 14, pp. 199–222, Jun. 2004, doi: 10.1023/B%3ASTCO.0000035301.49549.88.
 - [234] M. Gelfusa *et al.*, "Advanced signal processing based on support vector regression for lidar applications," L. Bruzzone, Ed., Oct. 2015, p. 96430E. doi: 10.1117/12.2194501.
 - [235] Z. Omariba, L. Zhang, and D. Sun, "Review on Health Management System for Lithium-Ion Batteries of Electric Vehicles," *Electronics (Basel)*, vol. 7, no. 5, p. 72, May 2018, doi: 10.3390/electronics7050072.
 - [236] R. Garg, S. Barpanda, G. Salanke N S, and R. Shivamadegowda, "Machine Learning Algorithms for Time Series Analysis and Forecasting," Jun. 2022. doi: 10.48550/arXiv.2211.14387.
 - [237] J. Snoek, H. Larochelle, and R. Adams, "Practical Bayesian Optimization of Machine Learning Algorithms," *Adv Neural Inf Process Syst*, vol. 4, Jun. 2012.
 - [238] A. Agnihotri and N. Batra, "Exploring Bayesian Optimization," *Distill*, vol. 5, no. 5, May 2020, doi: 10.23915/distill.00026.
 - [239] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," *Journal of Machine Learning Research*, vol. 15, pp. 1929–1958, Jun. 2014.
-
- [1] P. F. Flynn *et al.*, "The inevitability of engine-out NOx emissions from spark-ignited and diesel engines," *Proceedings of the Combustion Institute*, vol. 28, no. 1, pp. 1211–1218, Jan. 2000, doi: 10.1016/S0082-0784(00)80332-X.
 - [2] A. M. K. P. Taylor, "Science review of internal combustion engines," *Energy Policy*, vol. 36, no. 12, pp. 4657–4667, Dec. 2008, doi: 10.1016/j.enpol.2008.09.001.
 - [3] S. E. de Lucena, "A Survey on Electric and Hybrid Electric Vehicle Technology," in *Electric Vehicles – The Benefits and Barriers*, InTech, 2011. doi: 10.5772/18046.
 - [4] K. Akbar, Y. Zou, Q. Awais, M. J. A. Baig, and M. Jamil, "A Machine Learning-Based Robust State of Health (SOH) Prediction Model for Electric Vehicle Batteries," *Electronics (Basel)*, vol. 11, no. 8, p. 1216, Apr. 2022, doi: 10.3390/electronics11081216.

- [5] K. A. Severson *et al.*, “Data-driven prediction of battery cycle life before capacity degradation,” *Nat Energy*, vol. 4, no. 5, pp. 383–391, Mar. 2019, doi: 10.1038/s41560-019-0356-8.
- [6] P. Sun, R. Bisschop, H. Niu, and X. Huang, “A Review of Battery Fires in Electric Vehicles,” *Fire Technol*, vol. 56, no. 4, pp. 1361–1410, Jul. 2020, doi: 10.1007/s10694-019-00944-3.
- [7] C. Stave and A. Carlson, “A case study exploring firefighters’ and municipal officials’ preparedness for electrical vehicles,” *European Transport Research Review*, vol. 9, no. 2, p. 25, Jun. 2017, doi: 10.1007/s12544-017-0240-1.
- [8] M. Ali Lskaafi and M. Ali, “Fault Diagnosis and Failure Prognostics of Lithium-ion Battery Fault Diagnosis and Failure Prognostics of Lithium-ion Battery based on Least Squares Support Vector Machine and Memory based on Least Squares Support Vector Machine and Memory Particle Filter Framework Particle Filter Framework Recommended Citation Recommended Citation.” [Online]. Available: https://trace.tennessee.edu/utk_graddiss
- [9] L. Huang and C. Yao, “Failure Prediction Modeling of Lithium Ion Battery toward Distributed Parameter Estimation,” *Chinese Journal of Chemical Physics*, vol. 30, no. 5, pp. 547–552, Oct. 2017, doi: 10.1063/1674-0068/30/cjcp1705088.
- [10] X. Hu, Y. Che, X. Lin, and Z. Deng, “Health Prognosis for Electric Vehicle Battery Packs: A Data-Driven Approach,” *IEEE/ASME Transactions on Mechatronics*, vol. 25, no. 6, pp. 2622–2632, Dec. 2020, doi: 10.1109/TMECH.2020.2986364.
- [11] D. Roman, S. Saxena, V. Robu, M. Pecht, and D. Flynn, “Machine learning pipeline for battery state-of-health estimation,” *Nat Mach Intell*, vol. 3, no. 5, pp. 447–456, May 2021, doi: 10.1038/s42256-021-00312-3.
- [12] F. Wen and C. S. Chang, “A new approach to fault diagnosis in electrical distribution networks using a genetic algorithm,” 1998.
- [13] P. M. Attia *et al.*, “Closed-loop optimization of fast-charging protocols for batteries with machine learning,” *Nature*, vol. 578, no. 7795, pp. 397–402, Feb. 2020, doi: 10.1038/s41586-020-1994-5.
- [14] B. Bilgin *et al.*, “Making the Case for Electrified Transportation,” *IEEE Transactions on Transportation Electrification*, vol. 1, no. 1, pp. 4–17, Jun. 2015, doi: 10.1109/TTE.2015.2437338.
- [15] E. Helmers and P. Marx, “Electric cars: technical characteristics and environmental impacts,” *Environ Sci Eur*, vol. 24, no. 1, p. 14, Dec. 2012, doi: 10.1186/2190-4715-24-14.
- [16] L. Canals Casals, E. Martinez-Laserna, B. Amante García, and N. Nieto, “Sustainability analysis of the electric vehicle use in Europe for CO2 emissions reduction,” *J Clean Prod*, vol. 127, pp. 425–437, Jul. 2016, doi: 10.1016/j.jclepro.2016.03.120.

- [17] N. C. Onat, M. Kucukvar, and S. Afshar, "Eco-efficiency of electric vehicles in the United States: A life cycle assessment based principal component analysis," *J Clean Prod*, vol. 212, pp. 515–526, Mar. 2019, doi: 10.1016/j.jclepro.2018.12.058.
- [18] C. Filote, R. Felseghi, M. S. Raboaca, and I. Aşchilean, "Environmental impact assessment of green energy systems for power supply of electric vehicle charging station," *Int J Energy Res*, vol. 44, no. 13, pp. 10471–10494, Oct. 2020, doi: 10.1002/er.5678.
- [19] E. E. Michaelides, "Primary Energy Use and Environmental Effects of Electric Vehicles," *World Electric Vehicle Journal*, vol. 12, no. 3, p. 138, Aug. 2021, doi: 10.3390/wevj12030138.
- [20] A. Ghosh, "Possibilities and Challenges for the Inclusion of the Electric Vehicle (EV) to Reduce the Carbon Footprint in the Transport Sector: A Review," *Energies (Basel)*, vol. 13, no. 10, p. 2602, May 2020, doi: 10.3390/en13102602.
- [21] V. A. Katkar and P. Goswami, "Review on Energy Management Systems for Hybrid E Vehicles," in *2020 International Conference on Power, Energy, Control and Transmission Systems (ICPECTS)*, IEEE, Dec. 2020, pp. 1–6. doi: 10.1109/ICPECTS49113.2020.9336977.
- [22] T. R. Hawkins, B. Singh, G. Majeau-Bettez, and A. H. Strømman, "Comparative Environmental Life Cycle Assessment of Conventional and Electric Vehicles," *J Ind Ecol*, vol. 17, no. 1, pp. 53–64, Feb. 2013, doi: 10.1111/j.1530-9290.2012.00532.x.
- [23] C. Vidal, P. Malysz, P. Kollmeyer, and A. Emadi, "Machine Learning Applied to Electrified Vehicle Battery State of Charge and State of Health Estimation: State-of-the-Art," *IEEE Access*, vol. 8, pp. 52796–52814, 2020, doi: 10.1109/ACCESS.2020.2980961.
- [24] X. Feng *et al.*, "Online State-of-Health Estimation for Li-Ion Battery Using Partial Charging Segment Based on Support Vector Machine," *IEEE Trans Veh Technol*, vol. 68, no. 9, pp. 8583–8592, Sep. 2019, doi: 10.1109/TVT.2019.2927120.
- [25] E. Lelli, A. Musa, E. Batista, D. A. Misul, and G. Belingardi, "On-Road Experimental Campaign for Machine Learning Based State of Health Estimation of High-Voltage Batteries in Electric Vehicles," *Energies (Basel)*, vol. 16, no. 12, p. 4639, Jun. 2023, doi: 10.3390/en16124639.
- [26] R. Agrawal and G. Psaila, "Active Data Mining," May 1995, pp. 3–8.
- [27] S.-H. Liao, P.-H. Chu, and P.-Y. Hsiao, "Data mining techniques and applications – A decade review from 2000 to 2011," *Expert Syst Appl*, vol. 39, no. 12, pp. 11303–11311, Sep. 2012, doi: 10.1016/j.eswa.2012.02.063.
- [28] S. Tang, C. Yu, X. Wang, X. Guo, and X. Si, "Remaining Useful Life Prediction of Lithium-Ion Batteries Based on the Wiener Process with Measurement Error," *Energies (Basel)*, vol. 7, no. 2, pp. 520–547, Jan. 2014, doi: 10.3390/en7020520.

- [29] X. Zheng and X. Deng, "State-of-Health Prediction for Lithium-Ion Batteries with Multiple Gaussian Process Regression Model," *IEEE Access*, vol. 7, pp. 150383–150394, 2019, doi: 10.1109/ACCESS.2019.2947294.
- [30] J. Yu, "State of health prediction of lithium-ion batteries: Multiscale logic regression and Gaussian process regression ensemble," *Reliab Eng Syst Saf*, vol. 174, pp. 82–95, Jun. 2018, doi: 10.1016/j.ress.2018.02.022.
- [31] M. Karegar, A. Isazadeh, F. Fartash, T. Sadari, and A. Habibizad Navin, "Data-mining by probability-based patterns," in *ITI 2008 - 30th International Conference on Information Technology Interfaces*, IEEE, Jun. 2008, pp. 353–360. doi: 10.1109/ITI.2008.4588435.
- [32] S. A. Hill, "Statistics," in *Foundations of Anesthesia*, Elsevier, 2006, pp. 207–217. doi: 10.1016/B978-0-323-03707-5.50024-3.
- [33] I. Witten and I. H. Frank, "Data Mining - Practical Machine Learning Tools and Techniques with JAVA Implementations," *Morgan Kaufmann*, vol. 31, May 2002.
- [34] D. K. Bhattacharyya and S. M. Hazarika, "Networks, Data Mining and Artificial Intelligence: Trends and Future Directions," 2006. [Online]. Available: <https://api.semanticscholar.org/CorpusID:60130783>
- [35] B. Samanta, "Artificial neural networks and genetic algorithms for gear fault detection," *Mech Syst Signal Process*, vol. 18, no. 5, pp. 1273–1282, Sep. 2004, doi: 10.1016/j.ymssp.2003.11.003.
- [36] J. Yang, Y. Zhang, and Y. Zhu, "Intelligent fault diagnosis of rolling element bearing based on SVMs and fractal dimension," *Mech Syst Signal Process*, vol. 21, no. 5, pp. 2012–2024, Jul. 2007, doi: 10.1016/j.ymssp.2006.10.005.
- [37] D. Liu, Y. Luo, Y. Peng, X. Peng, and M. Pecht, "Lithium-ion Battery Remaining Useful Life Estimation Based on Nonlinear AR Model Combined with Degradation Feature," *Annual Conference of the PHM Society*, vol. 4, no. 1, Sep. 2012, doi: 10.36001/phmconf.2012.v4i1.2165.
- [38] G. E. Hinton and R. R. Salakhutdinov, "Reducing the Dimensionality of Data with Neural Networks," *Science (1979)*, vol. 313, no. 5786, pp. 504–507, Jul. 2006, doi: 10.1126/science.1127647.
- [39] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural Networks*, vol. 61, pp. 85–117, Jan. 2015, doi: 10.1016/j.neunet.2014.09.003.
- [40] D. S. Chaplot, C. MacLellan, R. Salakhutdinov, and K. Koedinger, "Learning Cognitive Models Using Neural Networks," 2018, pp. 43–56. doi: 10.1007/978-3-319-93843-1_4.
- [41] Chaochao Chen, Bin Zhang, G. Vachtsevanos, and M. Orchard, "Machine Condition Prediction Based on Adaptive Neuro-Fuzzy and High-Order Particle Filtering," *IEEE Transactions on Industrial Electronics*, vol. 58, no. 9, pp. 4353–4364, Sep. 2011, doi: 10.1109/TIE.2010.2098369.

- [42] K. Medjaher, D. A. Tobon-Mejia, and N. Zerhouni, "Remaining Useful Life Estimation of Critical Components With Application to Bearings," *IEEE Trans Reliab*, vol. 61, no. 2, pp. 292–302, Jun. 2012, doi: 10.1109/TR.2012.2194175.
- [43] E. Ramasso and R. Gouriveau, "Prognostics in switching systems: Evidential markovian classification of real-time neuro-fuzzy predictions," in *2010 Prognostics and System Health Management Conference*, IEEE, Jan. 2010, pp. 1–10. doi: 10.1109/PHM.2010.5413442.
- [44] L. Peel, "Data driven prognostics using a Kalman filter ensemble of neural network models," in *2008 International Conference on Prognostics and Health Management*, IEEE, Oct. 2008, pp. 1–6. doi: 10.1109/PHM.2008.4711423.
- [45] Chao Hu, B. D. Youn, and Pingfeng Wang, "Ensemble of data-driven prognostic algorithms for robust prediction of remaining useful life," in *2011 IEEE Conference on Prognostics and Health Management*, IEEE, Jun. 2011, pp. 1–10. doi: 10.1109/ICPHM.2011.6024361.
- [46] B. D. Youn, C. Hu, and P. Wang, "Resilience-Driven System Design of Complex Engineered Systems," *Journal of Mechanical Design*, vol. 133, no. 10, Oct. 2011, doi: 10.1115/1.4004981.
- [47] E. Scanff, K. L. Feldman, S. Ghelam, P. Sandborn, M. Glade, and B. Foucher, "Life cycle cost impact of using prognostic health management (PHM) for helicopter avionics," *Microelectronics Reliability*, vol. 47, no. 12, pp. 1857–1864, Dec. 2007, doi: 10.1016/j.microrel.2007.02.014.
- [48] L. Li, Y. Peng, Y. Song, and D. Liu, "Lithium-Ion Battery Remaining Useful Life Prognostics Using Data-Driven Deep Learning Algorithm," in *Proceedings - 2018 Prognostics and System Health Management Conference, PHM-Chongqing 2018*, Institute of Electrical and Electronics Engineers Inc., Jan. 2019, pp. 1094–1100. doi: 10.1109/PHM-Chongqing.2018.00193.
- [49] G. Vachtsevanos, F. Lewis, M. Roemer, A. Hess, and B. Wu, *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*. Wiley, 2006. doi: 10.1002/9780470117842.
- [50] R. J. Hogan and I. B. Mason, "Deterministic Forecasts of Binary Events," in *Forecast Verification*, Wiley, 2011, pp. 31–59. doi: 10.1002/9781119960003.ch3.
- [51] O. F. Eker, F. Camci, and I. K. Jennions, "A New Hybrid Prognostic Methodology," *Int J Progn Health Manag*, vol. 10, no. 2, Jun. 2019, doi: 10.36001/ijphm.2019.v10i2.2727.
- [52] Jennions Ian K., *Integrated Vehicle Health Management: Essential Reading*. Society of Automotive Engineers, 2012.
- [53] H. Meriem, H. Nora, and O. Samir, "Predictive Maintenance for Smart Industrial Systems: A Roadmap," *Procedia Comput Sci*, vol. 220, pp. 645–650, 2023, doi: 10.1016/j.procs.2023.03.082.

- [54] A. Cubillo, S. Perinpanayagam, and M. Esperon-Miguez, "A review of physics-based models in prognostics: Application to gears and bearings of rotating machinery," *Advances in Mechanical Engineering*, vol. 8, no. 8, p. 168781401666466, Aug. 2016, doi: 10.1177/1687814016664660.
- [55] H. Zhang, R. Kang, and M. Pecht, "A hybrid prognostics and health management approach for condition-based maintenance," in *2009 IEEE International Conference on Industrial Engineering and Engineering Management*, IEEE, Dec. 2009, pp. 1165–1169. doi: 10.1109/IEEM.2009.5372976.
- [56] A. Saxena *et al.*, "Metrics for evaluating performance of prognostic techniques," in *2008 International Conference on Prognostics and Health Management*, IEEE, Oct. 2008, pp. 1–17. doi: 10.1109/PHM.2008.4711436.
- [57] E. Zio, "Prognostics and Health Management of Industrial Equipment," in *Diagnostics and Prognostics of Engineering Systems*, IGI Global, 2013, pp. 333–356. doi: 10.4018/978-1-4666-2095-7.ch017.
- [58] G. Vachtsevanos, "Performance metrics for fault prognosis of complex systems," in *Proceedings AUTOTESTCON 2003. IEEE Systems Readiness Technology Conference.*, IEEE, pp. 341–345. doi: 10.1109/AUTEST.2003.1243597.
- [59] D. L. Goodman, S. Wood, and A. Turner, "Return-on-investment (ROI) for electronic prognostics in mil/aero systems," in *IEEE Autotestcon, 2005.*, IEEE, pp. 73–75. doi: 10.1109/AUTEST.2005.1609105.
- [60] S. M. Wood and D. L. Goodman, "Return-on-Investment (ROI) for Electronic Prognostics in High Reliability Telecom Applications," in *INTELEC 06 - Twenty-Eighth International Telecommunications Energy Conference*, IEEE, Sep. 2006, pp. 1–3. doi: 10.1109/INTLEC.2006.251619.
- [61] G. Vachtsevanos, F. Lewis, M. Roemer, A. Hess, and B. Wu, *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*. Wiley, 2006. doi: 10.1002/9780470117842.
- [62] K. Goebel and P. Bonissone, "Prognostic information fusion for constant load systems," in *2005 7th International Conference on Information Fusion*, IEEE, 2005, p. 9 pp. doi: 10.1109/ICIF.2005.1592000.
- [63] S. Makridakis *et al.*, "The accuracy of extrapolation (time series) methods: Results of a forecasting competition," *J Forecast*, vol. 1, no. 2, pp. 111–153, Apr. 1982, doi: 10.1002/for.3980010202.
- [64] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *Int J Forecast*, vol. 22, no. 4, pp. 679–688, Oct. 2006, doi: 10.1016/j.ijforecast.2006.03.001.
- [65] S. Sankararaman and K. Goebel, "Uncertainty in Prognostics and Systems Health Management," *Int J Progn Health Manag*, vol. 6, no. 4, Nov. 2020, doi: 10.36001/ijphm.2015.v6i4.2319.

- [66] J. Honaker and G. King, "What to Do about Missing Values in Time-Series Cross-Section Data," *Am J Pol Sci*, vol. 54, no. 2, pp. 561–581, Apr. 2010, doi: 10.1111/j.1540-5907.2010.00447.x.
- [67] A. N. Baraldi and C. K. Enders, "An introduction to modern missing data analyses," *J Sch Psychol*, vol. 48, no. 1, pp. 5–37, Feb. 2010, doi: 10.1016/j.jsp.2009.10.001.
- [68] D. Vergouw *et al.*, "The search for stable prognostic models in multiple imputed data sets," *BMC Med Res Methodol*, vol. 10, no. 1, p. 81, Dec. 2010, doi: 10.1186/1471-2288-10-81.
- [69] M. Xu, P. Baraldi, S. Al-Dahidi, and E. Zio, "Fault prognostics by an ensemble of Echo State Networks in presence of event based measurements," *Eng Appl Artif Intell*, vol. 87, p. 103346, Jan. 2020, doi: 10.1016/j.engappai.2019.103346.
- [70] Weishan Dong and Xin Yao, "NichingEDA: Utilizing the diversity inside a population of EDAs for continuous optimization," in *2008 IEEE Congress on Evolutionary Computation (IEEE World Congress on Computational Intelligence)*, IEEE, Jun. 2008, pp. 1260–1267. doi: 10.1109/CEC.2008.4630958.
- [71] Zhenyu Yang, Ke Tang, and Xin Yao, "Self-adaptive differential evolution with neighborhood search," in *2008 IEEE Congress on Evolutionary Computation (IEEE World Congress on Computational Intelligence)*, IEEE, Jun. 2008, pp. 1110–1116. doi: 10.1109/CEC.2008.4630935.
- [72] C.-L. Hwang and K. Yoon, *Multiple Attribute Decision Making*, vol. 186. Berlin, Heidelberg: Springer Berlin Heidelberg, 1981. doi: 10.1007/978-3-642-48318-9.
- [73] E. Zio, "Reliability engineering: Old problems and new challenges," *Reliab Eng Syst Saf*, vol. 94, no. 2, pp. 125–141, Feb. 2009, doi: 10.1016/j.res.2008.06.002.
- [74] X. Yang and F. Chen, "Deep Uncertainty Quantification of Prognostic Techniques for Proton Exchange Membrane Fuel Cell," Feb. 2022. doi: 10.4271/2022-01-7001.
- [75] J. C. Helton and F. J. Davis, "Illustration of Sampling-Based Methods for Uncertainty and Sensitivity Analysis," *Risk Analysis*, vol. 22, no. 3, pp. 591–622, Jun. 2002, doi: 10.1111/0272-4332.00041.
- [76] A. K. S. Jardine, D. Lin, and D. Banjevic, "A review on machinery diagnostics and prognostics implementing condition-based maintenance," *Mech Syst Signal Process*, vol. 20, no. 7, pp. 1483–1510, Oct. 2006, doi: 10.1016/j.ymssp.2005.09.012.
- [77] P. Baraldi and E. Zio, "A Combined Monte Carlo and Possibilistic Approach to Uncertainty Propagation in Event Tree Analysis," *Risk Analysis*, vol. 28, no. 5, pp. 1309–1326, Oct. 2008, doi: 10.1111/j.1539-6924.2008.01085.x.
- [78] O. Kammouh, P. Gardoni, and G. P. Cimellaro, "Probabilistic framework to evaluate the resilience of engineering systems using Bayesian and dynamic Bayesian networks," *Reliab Eng Syst Saf*, vol. 198, p. 106813, Jun. 2020, doi: 10.1016/j.res.2020.106813.
- [79] S. Zheng, Y. Song, T. Leung, and I. Goodfellow, "Improving the Robustness of Deep Neural Networks via Stability Training," Jun. 2016.

- [80] M. Winter, B. Barnett, and K. Xu, "Before Li Ion Batteries," *Chem Rev*, vol. 118, no. 23, pp. 11433–11456, Dec. 2018, doi: 10.1021/acs.chemrev.8b00422.
- [81] G. E. Blomgren, "The Development and Future of Lithium Ion Batteries," *J Electrochem Soc*, vol. 164, no. 1, pp. A5019–A5025, Dec. 2017, doi: 10.1149/2.0251701jes.
- [82] M. V. Reddy, A. Mauger, C. M. Julien, A. Paoletta, and K. Zaghib, "Brief History of Early Lithium-Battery Development," *Materials*, vol. 13, no. 8, p. 1884, Apr. 2020, doi: 10.3390/ma13081884.
- [83] B. Diouf and R. Pode, "Potential of lithium-ion batteries in renewable energy," *Renew Energy*, vol. 76, pp. 375–380, Apr. 2015, doi: 10.1016/j.renene.2014.11.058.
- [84] K.-H. Pettinger, A. Kampker, C.-R. Hohenthanner, C. Deutskens, H. Heimes, and A. vom Hemdt, "Lithium-ion cell and battery production processes," in *Lithium-Ion Batteries: Basics and Applications*, Berlin, Heidelberg: Springer Berlin Heidelberg, 2018, pp. 211–226. doi: 10.1007/978-3-662-53071-9_17.
- [85] M. M. Rahman, A. O. Oni, E. Gemechu, and A. Kumar, "Assessment of energy storage technologies: A review," *Energy Convers Manag*, vol. 223, p. 113295, Nov. 2020, doi: 10.1016/j.enconman.2020.113295.
- [86] G. E. Blomgren, "The Development and Future of Lithium Ion Batteries," *J Electrochem Soc*, vol. 164, no. 1, pp. A5019–A5025, Dec. 2017, doi: 10.1149/2.0251701jes.
- [87] D. Aurbach *et al.*, "A short review on the comparison between Li battery systems and rechargeable magnesium battery technology," *J Power Sources*, vol. 97–98, pp. 28–32, Jul. 2001, doi: 10.1016/S0378-7753(01)00585-7.
- [88] K. Chayambuka, G. Mulder, D. L. Danilov, and P. H. L. Notten, "From Li-Ion Batteries toward Na-Ion Chemistries: Challenges and Opportunities," *Adv Energy Mater*, vol. 10, no. 38, Oct. 2020, doi: 10.1002/aenm.202001310.
- [89] Y. Ding, Z. P. Cano, A. Yu, J. Lu, and Z. Chen, "Automotive Li-Ion Batteries: Current Status and Future Perspectives," *Electrochemical Energy Reviews*, vol. 2, no. 1, pp. 1–28, Mar. 2019, doi: 10.1007/s41918-018-0022-z.
- [90] D. Andre *et al.*, "Future generations of cathode materials: an automotive industry perspective," *J Mater Chem A Mater*, vol. 3, no. 13, pp. 6709–6732, 2015, doi: 10.1039/C5TA00361J.
- [91] T. Li, X.-Z. Yuan, L. Zhang, D. Song, K. Shi, and C. Bock, "Degradation Mechanisms and Mitigation Strategies of Nickel-Rich NMC-Based Lithium-Ion Batteries," *Electrochemical Energy Reviews*, vol. 3, no. 1, pp. 43–80, Mar. 2020, doi: 10.1007/s41918-019-00053-3.
- [92] "BU-205: Types of Lithium-ion," <https://batteryuniversity.com/article/bu-205-types-of-lithium-ion>.

- [93] A. G. Olabi *et al.*, “Battery energy storage systems and SWOT (strengths, weakness, opportunities, and threats) analysis of batteries in power transmission,” *Energy*, vol. 254, p. 123987, Sep. 2022, doi: 10.1016/j.energy.2022.123987.
- [94] M. Schimpe, M. Edler von Kuepach, M. Naumann, H. C. Hesse, K. Smith, and A. Jossen, “Comprehensive Modeling of Temperature-Dependent Degradation Mechanisms in Lithium Iron Phosphate Batteries,” *ECS Trans*, vol. 80, no. 10, pp. 147–170, Oct. 2017, doi: 10.1149/08010.0147ecst.
- [95] T. Baumhöfer, M. Brühl, S. Rothgang, and D. U. Sauer, “Production caused variation in capacity aging trend and correlation to initial cell performance,” *J Power Sources*, vol. 247, pp. 332–338, Feb. 2014, doi: 10.1016/j.jpowsour.2013.08.108.
- [96] Shawn L. Minter, “Samsung Finally Explains the Galaxy Note 7 Exploding Battery Mess,” <https://www.nbcnews.com/tech/tech-news/samsung-finally-explains-galaxy-note-7-exploding-battery-mess-n710581>.
- [97] Suat Vilgen / Kaynak: İhlas Haber Ajansı, “Tıra yüklü Tesla’lar cayır cayır yandı! Yangın tek araçta başladı,” <https://www.tgrthaber.com/gundem/tira-yuklu-teslalar-cayir-cayir-yandi-yanin-tek-aracta-basladi-2909232>.
- [98] A. C. Thelen, S. Hu, and Z. Wang, “Machine learning-based aging models for estimating battery state of health and predicting future degradation.”
- [99] M. Dubarry, M. Bercebar, A. Devie, D. Anseán, N. Omar, and I. Villarreal, “State of health battery estimator enabling degradation diagnosis: Model and algorithm description,” *J Power Sources*, vol. 360, pp. 59–69, Aug. 2017, doi: 10.1016/j.jpowsour.2017.05.121.
- [100] X. Han, M. Ouyang, L. Lu, J. Li, Y. Zheng, and Z. Li, “A comparative study of commercial lithium ion battery cycle life in electrical vehicle: Aging mechanism identification,” *J Power Sources*, vol. 251, pp. 38–54, Apr. 2014, doi: 10.1016/j.jpowsour.2013.11.029.
- [101] G. E. Karniadakis, I. G. Kevrekidis, L. Lu, P. Perdikaris, S. Wang, and L. Yang, “Physics-informed machine learning,” *Nature Reviews Physics*, vol. 3, no. 6, pp. 422–440, May 2021, doi: 10.1038/s42254-021-00314-5.
- [102] C. R. Birkel, M. R. Roberts, E. McTurk, P. G. Bruce, and D. A. Howey, “Degradation diagnostics for lithium ion cells,” *J Power Sources*, vol. 341, pp. 373–386, Feb. 2017, doi: 10.1016/j.jpowsour.2016.12.011.
- [103] A. Thelen *et al.*, “Integrating physics-based modeling and machine learning for degradation diagnostics of lithium-ion batteries,” *Energy Storage Mater*, vol. 50, pp. 668–695, Sep. 2022, doi: 10.1016/j.ensm.2022.05.047.
- [104] P. M. Attia, W. C. Chueh, and S. J. Harris, “Revisiting the $t^{0.5}$ Dependence of SEI Growth,” *J Electrochem Soc*, vol. 167, no. 9, p. 090535, Jan. 2020, doi: 10.1149/1945-7111/ab8ce4.

- [105] K. Liu, Y. Wang, and X. Lai, “Green Energy and Technology Data Science-Based Full-Lifespan Management of Lithium-Ion Battery.” [Online]. Available: <http://ebookcentral.proquest.com/lib/iuc/detail.action?docID=6950332>.
- [106] E. Peled, “The Electrochemical Behavior of Alkali and Alkaline Earth Metals in Nonaqueous Battery Systems—The Solid Electrolyte Interphase Model,” *J Electrochem Soc*, vol. 126, no. 12, pp. 2047–2051, Dec. 1979, doi: 10.1149/1.2128859.
- [107] C. Uhlmann, J. Illig, M. Ender, R. Schuster, and E. Ivers-Tiffée, “In situ detection of lithium metal plating on graphite in experimental cells,” *J Power Sources*, vol. 279, pp. 428–438, Apr. 2015, doi: 10.1016/j.jpowsour.2015.01.046.
- [108] A. Wang, S. Kadam, H. Li, S. Shi, and Y. Qi, “Review on modeling of the anode solid electrolyte interphase (SEI) for lithium-ion batteries,” *NPJ Comput Mater*, vol. 4, no. 1, p. 15, Mar. 2018, doi: 10.1038/s41524-018-0064-0.
- [109] M. Doyle and J. Newman, “The use of mathematical modeling in the design of lithium/polymer battery systems,” *Electrochim Acta*, vol. 40, no. 13–14, pp. 2191–2196, Oct. 1995, doi: 10.1016/0013-4686(95)00162-8.
- [110] J. Christensen and J. Newman, “A Mathematical Model for the Lithium-Ion Negative Electrode Solid Electrolyte Interphase,” *J Electrochem Soc*, vol. 151, no. 11, p. A1977, 2004, doi: 10.1149/1.1804812.
- [111] Y. Xie, J. Li, and C. Yuan, “Multiphysics modeling of lithium ion battery capacity fading process with solid-electrolyte interphase growth by elementary reaction kinetics,” *J Power Sources*, vol. 248, pp. 172–179, Feb. 2014, doi: 10.1016/j.jpowsour.2013.09.059.
- [112] C. R. Birkl, M. R. Roberts, E. McTurk, P. G. Bruce, and D. A. Howey, “Degradation diagnostics for lithium ion cells,” *J Power Sources*, vol. 341, pp. 373–386, Feb. 2017, doi: 10.1016/j.jpowsour.2016.12.011.
- [113] S. Santhanagopalan, Q. Guo, P. Ramadass, and R. E. White, “Review of models for predicting the cycling performance of lithium ion batteries,” *J Power Sources*, vol. 156, no. 2, pp. 620–628, Jun. 2006, doi: 10.1016/j.jpowsour.2005.05.070.
- [114] L. Liu and M. Zhu, “Modeling of SEI Layer Growth and Electrochemical Impedance Spectroscopy Response using a Thermal-Electrochemical Model of Li-ion Batteries,” *ECS Trans*, vol. 61, no. 27, pp. 43–61, Oct. 2014, doi: 10.1149/06127.0043ecst.
- [115] S. Santhanagopalan and R. E. White, “Online estimation of the state of charge of a lithium ion cell,” *J Power Sources*, vol. 161, no. 2, pp. 1346–1355, Oct. 2006, doi: 10.1016/j.jpowsour.2006.04.146.
- [116] A. M. Colclasure and R. J. Kee, “Thermodynamically consistent modeling of elementary electrochemistry in lithium-ion batteries,” *Electrochim Acta*, vol. 55, no. 28, pp. 8960–8973, Dec. 2010, doi: 10.1016/j.electacta.2010.08.018.

- [117] M. Heinrich *et al.*, “Physico-Chemical Modeling of a Lithium-Ion Battery: An Ageing Study with Electrochemical Impedance Spectroscopy,” *Batter Supercaps*, vol. 2, no. 6, pp. 530–540, Jun. 2019, doi: 10.1002/batt.201900011.
- [118] J. Christensen and J. Newman, “A Mathematical Model of Stress Generation and Fracture in Lithium Manganese Oxide,” *J Electrochem Soc*, vol. 153, no. 6, p. A1019, 2006, doi: 10.1149/1.2185287.
- [119] R. Deshpande, Y. Qi, and Y.-T. Cheng, “Effects of Concentration-Dependent Elastic Modulus on Diffusion-Induced Stresses for Battery Applications,” *J Electrochem Soc*, vol. 157, no. 8, p. A967, 2010, doi: 10.1149/1.3454762.
- [120] R. D. Deshpande and D. M. Bernardi, “Modeling Solid-Electrolyte Interphase (SEI) Fracture: Coupled Mechanical/Chemical Degradation of the Lithium Ion Battery,” *J Electrochem Soc*, vol. 164, no. 2, pp. A461–A474, Jan. 2017, doi: 10.1149/2.0841702jes.
- [121] A. Karger *et al.*, “Modeling Particle Versus SEI Cracking in Lithium-Ion Battery Degradation: Why Calendar and Cycle Aging Cannot Simply be Added,” *J Electrochem Soc*, vol. 171, no. 9, p. 090512, Sep. 2024, doi: 10.1149/1945-7111/ad76da.
- [122] J. Li, K. Adewuyi, N. Lotfi, R. G. Landers, and J. Park, “A single particle model with chemical/mechanical degradation physics for lithium ion battery State of Health (SOH) estimation,” *Appl Energy*, vol. 212, pp. 1178–1190, Feb. 2018, doi: 10.1016/j.apenergy.2018.01.011.
- [123] X.-G. Yang, Y. Leng, G. Zhang, S. Ge, and C.-Y. Wang, “Modeling of lithium plating induced aging of lithium-ion batteries: Transition from linear to nonlinear aging,” *J Power Sources*, vol. 360, pp. 28–40, Aug. 2017, doi: 10.1016/j.jpowsour.2017.05.110.
- [124] A. Barré, B. Deguilhem, S. Grolleau, M. Gérard, F. Suard, and D. Riu, “A review on lithium-ion battery ageing mechanisms and estimations for automotive applications,” *J Power Sources*, vol. 241, pp. 680–689, Nov. 2013, doi: 10.1016/j.jpowsour.2013.05.040.
- [125] P. Arora, M. Doyle, and R. E. White, “Mathematical Modeling of the Lithium Deposition Overcharge Reaction in Lithium-Ion Batteries Using Carbon-Based Negative Electrodes,” *J Electrochem Soc*, vol. 146, no. 10, pp. 3543–3553, Oct. 1999, doi: 10.1149/1.1392512.
- [126] M. Doyle, T. F. Fuller, and J. Newman, “Modeling of Galvanostatic Charge and Discharge of the Lithium/Polymer/Insertion Cell,” *J Electrochem Soc*, vol. 140, no. 6, pp. 1526–1533, Jun. 1993, doi: 10.1149/1.2221597.
- [127] R. Xiong *et al.*, “Revealing the onset condition of Li plating on graphite electrodes under fast-charging,” *J Mater Chem A Mater*, vol. 11, no. 31, pp. 16605–16615, 2023, doi: 10.1039/D3TA02968A.

- [128] D. Ren *et al.*, “Investigation of Lithium Plating-Stripping Process in Li-Ion Batteries at Low Temperature Using an Electrochemical Model,” *J Electrochem Soc*, vol. 165, no. 10, pp. A2167–A2178, Jul. 2018, doi: 10.1149/2.0661810jes.
- [129] C. von Lüders, J. Keil, M. Webersberger, and A. Jossen, “Modeling of lithium plating and lithium stripping in lithium-ion batteries,” *J Power Sources*, vol. 414, pp. 41–47, Feb. 2019, doi: 10.1016/j.jpowsour.2018.12.084.
- [130] K. Ando, T. Matsuda, and D. Imamura, “Degradation diagnosis of lithium-ion batteries with a $\text{LiNi}_{0.5}\text{Co}_{0.2}\text{Mn}_{0.3}\text{O}_2$ and LiMn_2O_4 blended cathode using dV/dQ curve analysis,” *J Power Sources*, vol. 390, pp. 278–285, Jun. 2018, doi: 10.1016/j.jpowsour.2018.04.043.
- [131] R. Xu, H. Sun, L. S. de Vasconcelos, and K. Zhao, “Mechanical and Structural Degradation of $\text{LiNi}_x\text{Mn}_y\text{Co}_z\text{O}_2$ Cathode in Li-Ion Batteries: An Experimental Study,” *J Electrochem Soc*, vol. 164, no. 13, pp. A3333–A3341, Nov. 2017, doi: 10.1149/2.1751713jes.
- [132] B. Wu and W. Lu, “A battery model that fully couples mechanics and electrochemistry at both particle and electrode levels by incorporation of particle interaction,” *J Power Sources*, vol. 360, pp. 360–372, Aug. 2017, doi: 10.1016/j.jpowsour.2017.05.115.
- [133] Y. Zhang, C. Zhao, and Z. Guo, “Simulation of crack behavior of secondary particles in Li-ion battery electrodes during lithiation/de-lithiation cycles,” *Int J Mech Sci*, vol. 155, pp. 178–186, May 2019, doi: 10.1016/j.ijmecsci.2019.02.042.
- [134] S. Yang, Y. Hua, D. Qiao, Y. Lian, Y. Pan, and Y. He, “A coupled electrochemical-thermal-mechanical degradation modelling approach for lifetime assessment of lithium-ion batteries,” *Electrochim Acta*, vol. 326, p. 134928, Dec. 2019, doi: 10.1016/j.electacta.2019.134928.
- [135] C. Fan, X. Tian, and C. Gu, “Perturbation-Based Battery Impedance Characterization Methods: From the Laboratory to Practical Implementation,” *Batteries*, vol. 10, no. 12, p. 414, Nov. 2024, doi: 10.3390/batteries10120414.
- [136] C. Lin, A. Tang, and W. Wang, “A Review of SOH Estimation Methods in Lithium-ion Batteries for Electric Vehicle Applications,” *Energy Procedia*, vol. 75, pp. 1920–1925, Aug. 2015, doi: 10.1016/j.egypro.2015.07.199.
- [137] Z. Ren and C. Du, “A review of machine learning state-of-charge and state-of-health estimation algorithms for lithium-ion batteries,” *Energy Reports*, vol. 9, pp. 2993–3021, Dec. 2023, doi: 10.1016/j.egy.2023.01.108.
- [138] Y. Gao, J. Jiang, C. Zhang, W. Zhang, Z. Ma, and Y. Jiang, “Lithium-ion battery aging mechanisms and life model under different charging stresses,” *J Power Sources*, vol. 356, pp. 103–114, Jul. 2017, doi: 10.1016/j.jpowsour.2017.04.084.
- [139] S. S. Zhang, “The effect of the charging protocol on the cycle life of a Li-ion battery,” *J Power Sources*, vol. 161, no. 2, pp. 1385–1391, Oct. 2006, doi: 10.1016/j.jpowsour.2006.06.040.

- [140] S. S. Choi and H. S. Lim, "Factors that affect cycle-life and possible degradation mechanisms of a Li-ion cell based on LiCoO₂," *J Power Sources*, vol. 111, no. 1, pp. 130–136, Sep. 2002, doi: 10.1016/S0378-7753(02)00305-1.
- [141] S. Saxena, C. Hendricks, and M. Pecht, "Cycle life testing and modeling of graphite/LiCoO₂ cells under different state of charge ranges," *J Power Sources*, vol. 327, pp. 394–400, Sep. 2016, doi: 10.1016/j.jpowsour.2016.07.057.
- [142] A. I. Pózna, K. M. Hangos, and A. Magyar, "Design of Experiments for Battery Aging Estimation," *IFAC-PapersOnLine*, vol. 51, no. 28, pp. 386–391, 2018, doi: 10.1016/j.ifacol.2018.11.733.
- [143] R. P. Ramasamy, R. E. White, and B. N. Popov, "Calendar life performance of pouch lithium-ion cells," *J Power Sources*, vol. 141, no. 2, pp. 298–306, Mar. 2005, doi: 10.1016/j.jpowsour.2004.09.024.
- [144] F. Leng, C. M. Tan, and M. Pecht, "Effect of Temperature on the Aging rate of Li Ion Battery Operating above Room Temperature," *Sci Rep*, vol. 5, no. 1, p. 12967, Aug. 2015, doi: 10.1038/srep12967.
- [145] S. S. Zhang, K. Xu, and T. R. Jow, "Electrochemical impedance study on the low temperature of Li-ion batteries," *Electrochim Acta*, vol. 49, no. 7, pp. 1057–1061, Mar. 2004, doi: 10.1016/j.electacta.2003.10.016.
- [146] M. Ouyang *et al.*, "Low temperature aging mechanism identification and lithium deposition in a large format lithium iron phosphate battery for different charge profiles," *J Power Sources*, vol. 286, pp. 309–320, Jul. 2015, doi: 10.1016/j.jpowsour.2015.03.178.
- [147] S. Watanabe, M. Kinoshita, T. Hosokawa, K. Morigaki, and K. Nakura, "Capacity fading of LiAl_yNi_{1-x-y}CoxO₂ cathode for lithium-ion batteries during accelerated calendar and cycle life tests (effect of depth of discharge in charge–discharge cycling on the suppression of the micro-crack generation of LiAl_yNi_{1-x-y}CoxO₂ particle)," *J Power Sources*, vol. 260, pp. 50–56, Aug. 2014, doi: 10.1016/j.jpowsour.2014.02.103.
- [148] J. R. Belt, C. D. Ho, C. G. Motloch, T. J. Miller, and T. Q. Duong, "A capacity and power fade study of Li-ion cells during life cycle testing," *J Power Sources*, vol. 123, no. 2, pp. 241–246, Sep. 2003, doi: 10.1016/S0378-7753(03)00537-8.
- [149] M. Ouyang *et al.*, "Overcharge-induced capacity fading analysis for large format lithium-ion batteries with Li Ni_{1/3}Co_{1/3}Mn_{1/3}O₂+ Li Mn₂O₄ composite cathode," *J Power Sources*, vol. 279, pp. 626–635, Apr. 2015, doi: 10.1016/j.jpowsour.2015.01.051.
- [150] R. Guo, L. Lu, M. Ouyang, and X. Feng, "Mechanism of the entire overdischarge process and overdischarge-induced internal short circuit in lithium-ion batteries," *Sci Rep*, vol. 6, no. 1, p. 30248, Jul. 2016, doi: 10.1038/srep30248.
- [151] S. Barcellona, L. Codecasa, S. Colnago, and L. Piegari, "Calendar Aging Effect on the Open Circuit Voltage of Lithium-Ion Battery," *Energies (Basel)*, vol. 16, no. 13, p. 4869, Jun. 2023, doi: 10.3390/en16134869.

- [152] M. Broussely *et al.*, “Main aging mechanisms in Li ion batteries,” *J Power Sources*, vol. 146, no. 1–2, pp. 90–96, Aug. 2005, doi: 10.1016/j.jpowsour.2005.03.172.
- [153] J. Li, K. Adewuyi, N. Lotfi, R. G. Landers, and J. Park, “A single particle model with chemical/mechanical degradation physics for lithium ion battery State of Health (SOH) estimation,” *Appl Energy*, vol. 212, pp. 1178–1190, Feb. 2018, doi: 10.1016/j.apenergy.2018.01.011.
- [154] J. Belt, V. Utgikar, and I. Bloom, “Calendar and PHEV cycle life aging of high-energy, lithium-ion cells containing blended spinel and layered-oxide cathodes,” *J Power Sources*, vol. 196, no. 23, pp. 10213–10221, Dec. 2011, doi: 10.1016/j.jpowsour.2011.08.067.
- [155] T. C. Bach *et al.*, “Nonlinear aging of cylindrical lithium-ion cells linked to heterogeneous compression,” *J Energy Storage*, vol. 5, pp. 212–223, Feb. 2016, doi: 10.1016/j.est.2016.01.003.
- [156] H. J. Ploehn, P. Ramadass, and R. E. White, “Solvent Diffusion Model for Aging of Lithium-Ion Battery Cells,” *J Electrochem Soc*, vol. 151, no. 3, p. A456, 2004, doi: 10.1149/1.1644601.
- [157] S. Abada, M. Petit, A. Lecocq, G. Marlair, V. Sauvant-Moynot, and F. Huet, “Combined experimental and modeling approaches of the thermal runaway of fresh and aged lithium-ion batteries,” *J Power Sources*, vol. 399, pp. 264–273, Sep. 2018, doi: 10.1016/j.jpowsour.2018.07.094.
- [158] J. Cannarella and C. B. Arnold, “Stress evolution and capacity fade in constrained lithium-ion pouch cells,” *J Power Sources*, vol. 245, pp. 745–751, Jan. 2014, doi: 10.1016/j.jpowsour.2013.06.165.
- [159] J. Keil, N. Paul, V. Baran, P. Keil, R. Gilles, and A. Jossen, “Linear and Nonlinear Aging of Lithium-Ion Cells Investigated by Electrochemical Analysis and In-Situ Neutron Diffraction,” *J Electrochem Soc*, vol. 166, no. 16, pp. A3908–A3917, Nov. 2019, doi: 10.1149/2.1271915jes.
- [160] T. C. Bach *et al.*, “Nonlinear aging of cylindrical lithium-ion cells linked to heterogeneous compression,” *J Energy Storage*, vol. 5, pp. 212–223, Feb. 2016, doi: 10.1016/j.est.2016.01.003.
- [161] T. Raj, A. A. Wang, C. W. Monroe, and D. A. Howey, “Investigation of Path-Dependent Degradation in Lithium-Ion Batteries**,” *Batter Supercaps*, vol. 3, no. 12, pp. 1377–1385, Dec. 2020, doi: 10.1002/batt.202000160.
- [162] G. L. Plett, “Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs,” *J Power Sources*, vol. 134, no. 2, pp. 252–261, Aug. 2004, doi: 10.1016/j.jpowsour.2004.02.031.
- [163] W. Li, N. Sengupta, P. Dechent, D. Howey, A. Annaswamy, and D. U. Sauer, “Online capacity estimation of lithium-ion batteries with deep long short-term memory networks,” *J Power Sources*, vol. 482, p. 228863, Jan. 2021, doi: 10.1016/j.jpowsour.2020.228863.

- [164] C. Su and H. J. Chen, "A review on prognostics approaches for remaining useful life of lithium-ion battery," *IOP Conf Ser Earth Environ Sci*, vol. 93, p. 012040, Nov. 2017, doi: 10.1088/1755-1315/93/1/012040.
- [165] J. Li, M. Zhang, H. Zheng, and J. Jie, "Battery remaining useful life prediction using improved mutated particle filter," *Energy Storage*, vol. 3, no. 1, Feb. 2021, doi: 10.1002/est2.218.
- [166] J. Liu, A. Saxena, K. Goebel, B. Saha, and W. Wang, "An Adaptive Recurrent Neural Network for Remaining Useful Life Prediction of Lithium-ion Batteries," *Annual Conference of the PHM Society*, vol. 2, no. 1, Oct. 2010, doi: 10.36001/phmconf.2010.v2i1.1896.
- [167] S. Atalay, M. Sheikh, A. Mariani, Y. Merla, E. Bower, and W. D. Widanage, "Theory of battery ageing in a lithium-ion battery: Capacity fade, nonlinear ageing and lifetime prediction," *J Power Sources*, vol. 478, p. 229026, Dec. 2020, doi: 10.1016/j.jpowsour.2020.229026.
- [168] K. Goebel, B. Saha, A. Saxena, J. Celaya, and J. Christophersen, "Prognostics in Battery Health Management," *IEEE Instrum Meas Mag*, vol. 11, no. 4, pp. 33–40, Aug. 2008, doi: 10.1109/MIM.2008.4579269.
- [169] V. Sulzer, P. Mohtat, S. Lee, J. B. Siegel, and A. G. Stefanopoulou, "Promise and Challenges of a Data-Driven Approach for Battery Lifetime Prognostics," in *2021 American Control Conference (ACC)*, IEEE, May 2021, pp. 4427–4433. doi: 10.23919/ACC50511.2021.9483312.
- [170] Y. Wen, R. Wolski, and C. Krintz, "Online Prediction of Battery Lifetime for Embedded and Mobile Devices," 2005, pp. 57–72. doi: 10.1007/978-3-540-28641-7_5.
- [171] C. Strange and G. dos Reis, "Prediction of future capacity and internal resistance of Li-ion cells from one cycle of input data," *Energy and AI*, vol. 5, p. 100097, Sep. 2021, doi: 10.1016/j.egyai.2021.100097.
- [172] W. Diao, S. Saxena, B. Han, and M. Pecht, "Algorithm to Determine the Knee Point on Capacity Fade Curves of Lithium-Ion Cells," *Energies (Basel)*, vol. 12, no. 15, p. 2910, Jul. 2019, doi: 10.3390/en12152910.
- [173] M. L. Baptista, E. M. P. Henriques, and K. Goebel, "More effective prognostics with elbow point detection and deep learning," *Mech Syst Signal Process*, vol. 146, p. 106987, Jan. 2021, doi: 10.1016/j.ymssp.2020.106987.
- [174] T. R. Ashwin, A. Barai, K. Uddin, L. Somerville, A. McGordon, and J. Marco, "Prediction of battery storage ageing and solid electrolyte interphase property estimation using an electrochemical model," *J Power Sources*, vol. 385, pp. 141–147, May 2018, doi: 10.1016/j.jpowsour.2018.03.010.
- [175] C. Zhang, S. Zhao, Z. Yang, and Y. Chen, "A reliable data-driven state-of-health estimation model for lithium-ion batteries in electric vehicles," *Front Energy Res*, vol. 10, Sep. 2022, doi: 10.3389/fenrg.2022.1013800.

- [176] T. Baumhöfer, M. Brühl, S. Rothgang, and D. U. Sauer, "Production caused variation in capacity aging trend and correlation to initial cell performance," *J Power Sources*, vol. 247, pp. 332–338, Feb. 2014, doi: 10.1016/j.jpowsour.2013.08.108.
- [177] C. Delacourt and M. Safari, "Life Simulation of a Graphite/LiFePO₄ Cell under Cycling and Storage," *J Electrochem Soc*, vol. 159, no. 8, pp. A1283–A1291, Jan. 2012, doi: 10.1149/2.049208jes.
- [178] R. Deshpande, M. Verbrugge, Y.-T. Cheng, J. Wang, and P. Liu, "Battery Cycle Life Prediction with Coupled Chemical Degradation and Fatigue Mechanics," *J Electrochem Soc*, vol. 159, no. 10, pp. A1730–A1738, Jan. 2012, doi: 10.1149/2.049210jes.
- [179] J. Purewal, J. Wang, J. Graetz, S. Soukiazian, H. Tataria, and M. W. Verbrugge, "Degradation of lithium ion batteries employing graphite negatives and nickel–cobalt–manganese oxide + spinel manganese oxide positives: Part 2, chemical–mechanical degradation model," *J Power Sources*, vol. 272, pp. 1154–1161, Dec. 2014, doi: 10.1016/j.jpowsour.2014.07.028.
- [180] J. Cannarella and C. B. Arnold, "The Effects of Defects on Localized Plating in Lithium-Ion Batteries," *J Electrochem Soc*, vol. 162, no. 7, pp. A1365–A1373, Apr. 2015, doi: 10.1149/2.1051507jes.
- [181] S. S. Madani, E. Schaltz, and S. K. Kær, "A Review of Different Electric Equivalent Circuit Models and Parameter Identification Methods of Lithium-Ion Batteries," *ECS Trans*, vol. 87, no. 1, pp. 23–37, Nov. 2018, doi: 10.1149/08701.0023ecst.
- [182] G. L. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs," *J Power Sources*, vol. 134, no. 2, pp. 262–276, Aug. 2004, doi: 10.1016/j.jpowsour.2004.02.032.
- [183] Y. Li *et al.*, "Data-driven health estimation and lifetime prediction of lithium-ion batteries: A review," *Renewable and Sustainable Energy Reviews*, vol. 113, p. 109254, Oct. 2019, doi: 10.1016/j.rser.2019.109254.
- [184] B. YANNLIAW, "Modeling of lithium ion cells?A simple equivalent-circuit model approach," *Solid State Ion*, vol. 175, no. 1–4, pp. 835–839, Nov. 2004, doi: 10.1016/j.ssi.2004.09.049.
- [185] Z. Ma, R. Yang, and Z. Wang, "A novel data-model fusion state-of-health estimation approach for lithium-ion batteries," *Appl Energy*, vol. 237, pp. 836–847, Mar. 2019, doi: 10.1016/j.apenergy.2018.12.071.
- [186] S. B. Vilsen, S. K. Kaer, and D.-I. Stroe, "Log-Linear Model for Predicting the Lithium-ion Battery Age Based on Resistance Extraction from Dynamic Aging Profiles," *IEEE Trans Ind Appl*, vol. 56, no. 6, pp. 6937–6948, Nov. 2020, doi: 10.1109/TIA.2020.3020529.
- [187] V. N. Vapnik, "The Support Vector method," 1997, pp. 261–271. doi: 10.1007/BFb0020166.

- [188] Y. SONG, D. LIU, Y. HOU, J. YU, and Y. PENG, "Satellite lithium-ion battery remaining useful life estimation with an iterative updated RVM fused with the KF algorithm," *Chinese Journal of Aeronautics*, vol. 31, no. 1, pp. 31–40, Jan. 2018, doi: 10.1016/j.cja.2017.11.010.
- [189] Y. Li *et al.*, "Random forest regression for online capacity estimation of lithium-ion batteries," *Appl Energy*, vol. 232, pp. 197–210, Dec. 2018, doi: 10.1016/j.apenergy.2018.09.182.
- [190] X. Hu, L. Xu, X. Lin, and M. Pecht, "Battery Lifetime Prognostics," *Joule*, vol. 4, no. 2, pp. 310–346, Feb. 2020, doi: 10.1016/J.JOULE.2019.11.018.
- [191] 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, doi: 10.1109/ACCESS.2019.2905740.
- [192] S. Theodoridis, "Bayesian Learning," *Mach Learn*, pp. 639–706, 2015, doi: 10.1016/B978-0-12-801522-3.00013-6.
- [193] S. Li, H. He, and J. Li, "Big data driven lithium-ion battery modeling method based on SDAE-ELM algorithm and data pre-processing technology," *Appl Energy*, vol. 242, pp. 1259–1273, May 2019, doi: 10.1016/J.APENERGY.2019.03.154.
- [194] P. M. Attia *et al.*, "Review—'Knees' in Lithium-Ion Battery Aging Trajectories," *J Electrochem Soc*, vol. 169, no. 6, p. 060517, Jun. 2022, doi: 10.1149/1945-7111/ac6d13.
- [195] H. You *et al.*, "Nonlinear health evaluation for lithium-ion battery within full-lifespan," *Journal of Energy Chemistry*, vol. 72, pp. 333–341, Sep. 2022, doi: 10.1016/j.jechem.2022.04.013.
- [196] Z. Mao, M. Farkhondeh, M. Pritzker, M. Fowler, and Z. Chen, "Calendar Aging and Gas Generation in Commercial Graphite/NMC-LMO Lithium-Ion Pouch Cell," *J Electrochem Soc*, vol. 164, no. 14, pp. A3469–A3483, Nov. 2017, doi: 10.1149/2.0241714jes.
- [197] J. M. Reniers, G. Mulder, and D. A. Howey, "Review and Performance Comparison of Mechanical-Chemical Degradation Models for Lithium-Ion Batteries," *J Electrochem Soc*, vol. 166, no. 14, pp. A3189–A3200, Sep. 2019, doi: 10.1149/2.0281914jes.
- [198] Y. Chen *et al.*, "A review of lithium-ion battery safety concerns: The issues, strategies, and testing standards," *Journal of Energy Chemistry*, vol. 59, pp. 83–99, Aug. 2021, doi: 10.1016/j.jechem.2020.10.017.
- [199] W. Diao, J. Kim, M. H. Azarian, and M. Pecht, "Degradation modes and mechanisms analysis of lithium-ion batteries with knee points," *Electrochim Acta*, vol. 431, p. 141143, Nov. 2022, doi: 10.1016/j.electacta.2022.141143.
- [200] V. Satopaa, J. Albrecht, D. Irwin, and B. Raghavan, "Finding a 'Kneedle' in a Haystack: Detecting Knee Points in System Behavior," in *2011 31st International*

- Conference on Distributed Computing Systems Workshops*, IEEE, Jun. 2011, pp. 166–171. doi: 10.1109/ICDCSW.2011.20.
- [201] K. A. Severson *et al.*, “Data-driven prediction of battery cycle life before capacity degradation,” *Nat Energy*, vol. 4, no. 5, pp. 383–391, May 2019, doi: 10.1038/s41560-019-0356-8.
- [202] B. Saha, K. Goebel, and J. Christophersen, “Comparison of prognostic algorithms for estimating remaining useful life of batteries,” *Transactions of the Institute of Measurement and Control*, vol. 31, no. 3–4, pp. 293–308, 2009, doi: 10.1177/0142331208092030.
- [203] “Battery Data | Center for Advanced Life Cycle Engineering.” Accessed: Dec. 04, 2024. [Online]. Available: <https://calce.umd.edu/battery-data>
- [204] A. Nuhic, T. Terzimehic, T. Soczka-Guth, M. Buchholz, and K. Dietmayer, “Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods,” *J Power Sources*, vol. 239, pp. 680–688, Oct. 2013, doi: 10.1016/j.jpowsour.2012.11.146.
- [205] “Reference Toyota Research Institute. Experimental data platform,” <https://data.matr.io/1/>.
- [206] K. A. Severson *et al.*, “Data-driven prediction of battery cycle life before capacity degradation,” *Nat Energy*, vol. 4, no. 5, pp. 383–391, Mar. 2019, doi: 10.1038/s41560-019-0356-8.
- [207] C. Strange, S. Li, R. Gilchrist, and G. dos Reis, “Elbows of Internal Resistance Rise Curves in Li-Ion Cells,” *Energies (Basel)*, vol. 14, no. 4, p. 1206, Feb. 2021, doi: 10.3390/en14041206.
- [208] C. Strange, S. Li, R. Gilchrist, and G. dos Reis, “Elbows of Internal Resistance Rise Curves in Li-Ion Cells,” *Energies (Basel)*, vol. 14, no. 4, p. 1206, Feb. 2021, doi: 10.3390/en14041206.
- [209] T. Raj, A. A. Wang, C. W. Monroe, and D. A. Howey, “Investigation of Path-Dependent Degradation in Lithium-Ion Batteries**,” *Batter Supercaps*, vol. 3, no. 12, pp. 1377–1385, Dec. 2020, doi: 10.1002/batt.202000160.
- [210] T. Raj, “Path Dependent Battery Degradation Dataset Part 1,” 2020, *University of Oxford*.
- [211] P. Dechent, S. Greenbank, F. Hildenbrand, S. Jbabdi, D. U. Sauer, and D. A. Howey, “Estimation of Li-Ion Degradation Test Sample Sizes Required to Understand Cell-to-Cell Variability**,” *Batter Supercaps*, vol. 4, no. 12, pp. 1821–1829, Dec. 2021, doi: 10.1002/batt.202100148.
- [212] L. Willenberg *et al.*, “The Development of Jelly Roll Deformation in 18650 Lithium-Ion Batteries at Low State of Charge,” *J Electrochem Soc*, vol. 167, no. 12, p. 120502, Jan. 2020, doi: 10.1149/1945-7111/aba96d.

- [213] D. U. Sauer, "Time-series cyclic aging data on 48 commercial NMC/graphite Sanyo/Panasonic UR18650E cylindrical cells," 2011.
- [214] W. Li, N. Sengupta, P. Dechent, D. Howey, A. Annaswamy, and D. U. Sauer, "One-shot battery degradation trajectory prediction with deep learning," *J Power Sources*, vol. 506, p. 230024, Sep. 2021, doi: 10.1016/j.jpowsour.2021.230024.
- [215] A. Mistry *et al.*, "A Minimal Information Set To Enable Verifiable Theoretical Battery Research," *ACS Energy Lett*, vol. 6, no. 11, pp. 3831–3835, Nov. 2021, doi: 10.1021/acsenenergylett.1c01710.
- [216] W. Li, N. Sengupta, P. Dechent, D. Howey, A. Annaswamy, and D. U. Sauer, "One-shot battery degradation trajectory prediction with deep learning," *J Power Sources*, vol. 506, p. 230024, Sep. 2021, doi: 10.1016/j.jpowsour.2021.230024.
- [217] W. Li, N. Sengupta, P. Dechent, D. Howey, A. Annaswamy, and D. U. Sauer, "Online capacity estimation of lithium-ion batteries with deep long short-term memory networks," *J Power Sources*, vol. 482, p. 228863, Jan. 2021, doi: 10.1016/J.JPOWSOUR.2020.228863.
- [218] M. Lucu *et al.*, "Data-driven nonparametric Li-ion battery ageing model aiming at learning from real operation data – Part A: Storage operation," *J Energy Storage*, vol. 30, p. 101409, Aug. 2020, doi: 10.1016/J.EST.2020.101409.
- [219] J. Xiong, T. X. Lei, D. M. Fu, J. W. Wu, and T. Y. Zhang, "Data driven discovery of an analytic formula for the life prediction of Lithium-ion batteries," *Progress in Natural Science: Materials International*, vol. 32, no. 6, pp. 793–799, Dec. 2022, doi: 10.1016/J.PNSC.2022.12.002.
- [220] R. R. Richardson, M. A. Osborne, and D. A. Howey, "Battery health prediction under generalized conditions using a Gaussian process transition model," *J Energy Storage*, vol. 23, pp. 320–328, Jun. 2019, doi: 10.1016/J.EST.2019.03.022.
- [221] M. Schimpe, M. E. von Kuepach, M. Naumann, H. C. Hesse, K. Smith, and A. Jossen, "Comprehensive Modeling of Temperature-Dependent Degradation Mechanisms in Lithium Iron Phosphate Batteries," *J Electrochem Soc*, vol. 165, no. 2, pp. A181–A193, 2018, doi: 10.1149/2.1181714JES.
- [222] X. Hu, Y. Che, X. Lin, and S. Onori, "Battery Health Prediction Using Fusion-Based Feature Selection and Machine Learning," *IEEE Transactions on Transportation Electrification*, vol. 7, no. 2, pp. 382–398, Jun. 2021, doi: 10.1109/TTE.2020.3017090.
- [223] Y. Song, D. Liu, and Y. Peng, "Data-driven on-line health assessment for lithium-ion battery with uncertainty presentation," *2018 IEEE International Conference on Prognostics and Health Management, ICPHM 2018*, Aug. 2018, doi: 10.1109/ICPHM.2018.8448707.
- [224] D. Yang, X. Zhang, R. Pan, Y. Wang, and Z. Chen, "A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve," *J Power Sources*, vol. 384, pp. 387–395, Apr. 2018, doi: 10.1016/j.jpowsour.2018.03.015.

- [225] Z. Yun and W. Qin, "Remaining Useful Life Estimation of Lithium-Ion Batteries Based on Optimal Time Series Health Indicator," *IEEE Access*, vol. 8, pp. 55447–55461, 2020, doi: 10.1109/ACCESS.2020.2981947.
- [226] M. Lucu *et al.*, "Data-driven nonparametric Li-ion battery ageing model aiming at learning from real operation data – Part A: Storage operation," *J Energy Storage*, vol. 30, p. 101409, Aug. 2020, doi: 10.1016/j.est.2020.101409.
- [227] K. S. R. Mawonou, A. Eddahech, D. Dumur, D. Beauvois, and E. Godoy, "State-of-health estimators coupled to a random forest approach for lithium-ion battery aging factor ranking," *J Power Sources*, vol. 484, p. 229154, Feb. 2021, doi: 10.1016/j.jpowsour.2020.229154.
- [228] 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 Trans Veh Technol*, vol. 68, no. 5, pp. 4110–4121, May 2019, doi: 10.1109/TVT.2018.2864688.
- [229] J. Xiong, T.-X. Lei, D.-M. Fu, J.-W. Wu, and T.-Y. Zhang, "Data driven discovery of an analytic formula for the life prediction of Lithium-ion batteries," *Progress in Natural Science: Materials International*, vol. 32, no. 6, pp. 793–799, Dec. 2022, doi: 10.1016/j.pnsc.2022.12.002.
- [230] C. R. Birkl, M. R. Roberts, E. McTurk, P. G. Bruce, and D. A. Howey, "Degradation diagnostics for lithium ion cells," *J Power Sources*, vol. 341, pp. 373–386, Feb. 2017, doi: 10.1016/j.jpowsour.2016.12.011.
- [231] R. R. Richardson, M. A. Osborne, and D. A. Howey, "Battery health prediction under generalized conditions using a Gaussian process transition model," *J Energy Storage*, vol. 23, pp. 320–328, Jun. 2019, doi: 10.1016/j.est.2019.03.022.
- [232] C. Cortes and V. Vapnik, "Support-vector networks," *Chem. Biol. Drug Des.*, vol. 297, pp. 273–297, Jun. 2009, doi: 10.1007/%2FBBF00994018.
- [233] A. Smola and B. Schölkopf, "A tutorial on support vector regression," *Stat Comput*, vol. 14, pp. 199–222, Jun. 2004, doi: 10.1023/B%3ASTCO.0000035301.49549.88.
- [234] M. Gelfusa *et al.*, "Advanced signal processing based on support vector regression for lidar applications," L. Bruzzone, Ed., Oct. 2015, p. 96430E. doi: 10.1117/12.2194501.
- [235] Z. Omariba, L. Zhang, and D. Sun, "Review on Health Management System for Lithium-Ion Batteries of Electric Vehicles," *Electronics (Basel)*, vol. 7, no. 5, p. 72, May 2018, doi: 10.3390/electronics7050072.
- [236] R. Garg, S. Barpanda, G. Salanke N S, and R. Shivamadegowda, "Machine Learning Algorithms for Time Series Analysis and Forecasting," Jun. 2022. doi: 10.48550/arXiv.2211.14387.
- [237] J. Snoek, H. Larochelle, and R. Adams, "Practical Bayesian Optimization of Machine Learning Algorithms," *Adv Neural Inf Process Syst*, vol. 4, Jun. 2012.