

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ TEZLİ YÜKSEK
LİSANS PROGRAMI**

**AKILLI BATARYA KAPASİTESİNİN DERİN ÖĞRENME
YÖNTEMLERİYLE TAHMİNİ**

HAZIRLAYAN

TUĞHAN TUNÇ

YÜKSEK LİSANS TEZİ

ANKARA-2024

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ TEZLİ YÜKSEK
LİSANS PROGRAMI**

**AKILLI BATARYA KAPASİTESİNİN DERİN ÖĞRENME
YÖNTEMLERİYLE TAHMİNİ**

HAZIRLAYAN

TUĞHAN TUNÇ

YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI

PROF. DR. HAMİT ERDEM

ANKARA-2024

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektrik-Elektronik Mühendisliği Tezli Yüksek Lisans Programı çerçevesinde Tuğhan Tunç tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 19 / 01 / 2024

Tez Adı: Akıllı Batarya Kapasitesinin Derin Öğrenme Yöntemleriyle Tahmini

Tez Jüri Üyeleri (Unvanı, Adı- Soyadı, Kurumu)

İmza

Prof. Dr. Hamit Erdem, Başkent Üniversitesi

.....

Doç. Dr. Selda Güney, Başkent Üniversitesi

.....

Doç. Dr. Derya Yılmaz, Gazi Üniversitesi

.....

ONAY

Prof. Dr. Ömer Faruk Elaldı
Fen Bilimleri Enstitüsü Müdürü

Tarih: ... / ... / 2024

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 30/01/2024

Öğrencinin Adı, Soyadı: Tuğhan TUNÇ

Öğrencinin Numarası: 22020048

Anabilim Dalı: Elektrik-Elektronik Mühendisliği

Programı: Tezli Yüksek Lisans

Danışmanın Unvanı/Adı, Soyadı: Prof. Dr. Hamit ERDEM

Tez Başlığı: Akıllı Batarya Kapasitesinin Derin Öğrenme Yöntemleriyle Tahmini

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 95 sayfalık kısmına ilişkin, 30/01/2024 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %6'dır. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimedenden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:

ONAY

Tarih: 30/01/ 2024

Öğrenci Danışmanı Unvan, Adı, Soyadı, İmza:

Prof. Dr. Hamit ERDEM

ÖZET

Tuğhan TUNÇ

AKILLI BATARYA KAPASİTESİNİN DERİN ÖĞRENME YÖNTEMLERİYLE TAHMİNİ

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

2024

Günümüzde lityum iyon bataryalar, verimli bir enerji depolama elemanı olarak üretimin ve yaşamın çeşitli alanlarında yeri doldurulamaz bir rol oynamaktadır. Lityum iyon bataryaların sağlık durumu (SOH), enerji depolama sisteminin güvenli çalışması için kritik öneme sahiptir. Lityum iyon bataryaların sağlık durumunun bozulması batarya performansının düşmesine, mevcut maksimum kapasitenin azalmasına, hizmet ömrünün kısılmasına, elektrikli araçların sürüş menzilin azalmasına ve hatta elektrikli araç kullanımında güvenlik açıkları meydana gelmesine yol açabilmektedir. Bu tez çalışmasında batarya yönetim sisteminden gelen, yaşlanmaya bağlı olarak değişen gerilim, akım ve sıcaklık profilleri gibi ölçülebilir veriler kullanılmış bu veriler ile kapasite değişim vektörü elde edilmiş ve Dikkat Mekanizmalı Geçitli Tekrarlayan Birim yöntemi ile bir kapasite tahmin çerçevesi önerilmiştir. Bu verilere dayanarak kapasite ile şarj profilleri arasındaki ilişki sinir ağları tarafından öğrenilir. Bu çalışmada ulaştığımız deneysel sonuçlar hem soğuk hem sıcak hem de oda sıcaklığı koşullarından NASA lityum iyon batarya veri setlerine dayanır. Önerilen dikkat mekanizmalı GRU yöntemi, bataryanın sağlığının tahmininde ortalama mutlak yüzde hata açısından derin öğrenme yöntemlerinden olan LSTM, GRU, BiLSTM, LSTM-AM ve BiLSTM-AM yöntemlerine kıyasla sırasıyla %35, %27, %20, %16 ve %10'a kadar daha başarılı olduğu görülmüştür. Yapılan benzetim çalışmaları MATLAB ortamında derin öğrenme toolbox'ı kullanılarak gerçekleştirilmiştir. Son yıllarda dikkat mekanizmaları, zaman serisi tahmin modellerinin performansını artırmak için güçlü bir araç olarak ortaya çıkmıştır. Bu çalışmada, zaman serisi problemlerinin çözümlerinde kullanılan LSTM, BiLSTM ve GRU aynı NASA veri setleri üzerinde denenmiş ve her biri dikkat mekanizması ile birleştirilerek performansları ölçülmüştür. Bu üç yöntemden daha hızlı ve basit olmasıyla GRU tercih edilmiştir. Bu çalışmada önerilen mekanizma GRU ile Dikkat Mekanizmasını birleştirerek oluşturulmuş SoH öngörüm mekanizmasıdır.

ANAHTAR KELİMELEER: Lityum iyon pil, sinir ađı, kalan kullanım 6mr6 (RUL), kapasite tahmini, pilin sađlık durumu (SoH), LSTM, GRU, ift Y6nl6 LSTM, Dikkat Mekanizması

ABSTRACT

Tuğhan TUNÇ

ESTIMATION OF SMART BATTERY CAPACITY USING DEEP LEARNING METHODS

Başkent University Institute of Science and Engineering

Department of Electrical and Electronics Engineering

2024

Lithium-ion batteries play an irreplaceable role in various areas of production and life as an efficient energy storage element. The state of health (SOH) of lithium-ion batteries is critical to the safe operation of the energy storage system. Deterioration of the health status of lithium-ion batteries can lead to a decrease in battery performance, a decrease in the current maximum capacity, a shortening of the service life, a decrease in the driving range of electric vehicles and even security vulnerabilities in the use of electric vehicles. In this paper, measurable data such as voltage, current and temperature profiles coming from the battery management system, which change due to aging, were used to obtain the capacity change vector with these data and a capacity estimation framework was proposed with the Gated Recurrent Unit with Attention Mechanism method. Based on these data, the relationship between capacity and charging profiles is learned by neural networks. The experimental results we reached in this study are based on NASA lithium-ion battery data sets from both cold, hot and room temperature conditions. The proposed GRU with attention mechanism method has been found to be successful in terms of average absolute percentage error in estimating the health of the battery up to 35%, 27%, 20%, 16% and 10% better than the deep learning methods LSTM, GRU, BiLSTM, LSTM-AM and BiLSTM-AM, respectively. The simulation studies were carried out using the deep learning toolbox in the MATLAB environment. In recent years, attention mechanisms have emerged as a powerful tool to improve the performance of time series forecasting models. In this work, LSTM, BiLSTM and GRU, which are used in solving time series problems, were tested on the same NASA data sets and their performances were measured by combining each with the attention mechanism. GRU was preferred because it is faster and simpler than these three methods. The mechanism proposed in this study is the SoH prediction mechanism created by combining GRU and Attention Mechanism.

KEYWORDS: Lithium-ion battery, neural network, remaining useful life (RUL), capacity estimation, battery state of health (SoH), LSTM, GRU, Bi-directional LSTM, Self-Attention Mechanism

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
İÇİNDEKİLER.....	i
TABLolar LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
SİMGELER VE KISALTMALAR LİSTESİ	vii
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	3
3. ELEKTRİKLİ ARAÇLARIN GENEL BİLEŞENLERİ	6
3.1. Yüksek Voltaj Cer Bataryası	6
3.2. Güç Dönüştürücü İnvörtör	6
3.3. Güç Elektroniği Kontrolcüsü	6
3.4. Elektrikli Cer Motoru	7
3.5. Yardımcı Batarya	7
3.6. Şarj Bağlantı Noktası	7
3.7. Şarj Cihazı.....	8
3.8. DC/DC Dönüştürücü	9
3.9. Şanzıman	9
3.10. Termal Sistem Soğutma	10
3.11. Bileşenlerin Ara Bağlantısı	10
4. ELEKTRİKLİ ARAÇLARDAKİ CER BATARYALARI	11
4.1. Pil Parametreleri/Teknik Özellikler	11
4.1.1. Hücre Gerilimi.....	11
4.1.2. Şarj Kapasitesi.....	12
4.1.2.1. Depolanan Enerji.....	12
4.1.2.2. Özgül Enerji ve Enerji Yoğunluğu	13
4.1.2.3. Özgül Güç.....	13
4.1.2.4. Kendiliğinden Deşarj Oranları	13
4.1.2.5. Pil Sıcaklığı, Soğutma İhtiyaçları ve Isıtma.....	13
4.1.2.6. Pil Ömrü ve Derin Döngü Sayısı.....	14
4.2. Farklı Pil Türleri	14

4.2.1. Lityum İyon Piller	16
4.2.1.1. Lityum Kobalt Oksit ($LiCoO_2$).....	18
4.2.1.2. Lityum Manganez Oksit ($LiMn_2O_4$).....	18
4.2.1.3. Lityum Demir Fosfat ($LiFePO_4$) (LFP)	19
4.2.1.4. Lityum Nikel Manganez Kobalt Oksit (NMC)	19
4.2.1.5. Lityum Nikel Kobalt Alüminyum Oksit (NCA)	19
4.2.1.6. Lityum Titanat (LTO)	20
4.2.2. Li-İyon Pillerin Fiziksel Uygulaması	20
4.2.3. Elektrikli Araçlarda Kullanılan Farklı Li-İyon Pil Türlerinin Karşılaştırmaları	21
4.2.4. Lityum İyon Pil Ömrü	22
4.2.4.1. Sıcaklık	23
4.2.4.2. Şarj ve Deşarj Oranı	25
4.2.4.3. Şarj ve Deşarj Derinliği	26
5. BATARYA SOC VE SOH TAHMİNİ.....	28
5.1. Coulomb Sayımı.....	28
5.2. Doğrudan Direnç Tahmin Algoritması	29
5.3. Açık Devre Gerilimi (OCV).....	30
5.4. Kalman Filtreleme.....	31
5.5. Kayan Mod Gözlemcisi	32
5.6. Bulanık Mantık.....	33
5.7. En Küçük Kareler	33
6. YAPAY ZEKA	34
6.1. Makine Öğrenmesi	36
6.2. Klasik Makine Öğrenimi Yöntemleri	36
6.2.1. Doğrusal Regresyon (Linear Regression).....	36
6.2.2. Lojistik Regresyon (Logistic Regression).....	37
6.2.3. Karar Ağaçları ve Rastgele Ormanlar (Decision Trees ve Random Forests)	38
6.3. Sinir Ağları ve Derin Öğrenme	39
6.3.1. İleri Beslemeli Sinir Ağları (Feedforward Neural Networks).....	39
6.3.2. Tekrarlayan Sinir Ağları (Recurrent Neural Networks).....	41
6.3.3. Kaybolan Gradyan Sorunu (Vanishing Gradient Problem)	43

6.3.4. Uzun Kısa Süreli Bellek ve Geçitli Tekrarlayan Birimler (Long Short-Term Memory ve Gated Recurrent Units).....	44
6.4. GRU ve LSTM Karşılaştırması.....	47
6.4.1. LSTM.....	47
6.4.2. GRU	47
6.4.3. Performans Kıyaslaması.....	48
6.4.4. Benzerlikleri.....	48
6.4.5. Farklılıkları.....	48
7. MATERYAL VE METOT.....	49
7.1. Nasa'nın Lityum İyon Batarya Verisi	49
7.2. Şarj/Deşarj Sürecinde Veri Toplama	50
7.3. Voltaj, Akım ve Sıcaklık Verileri ile Şarj Profilleri	52
8. MODEL SEÇİMİ.....	54
8.1. Önerilen Yapı.....	54
8.2. Veri Ön İşleme	55
8.3. Uzun Kısa Dönemli Bellek (Long Short-Term Memory)	58
8.4. Çift Yönlü Uzun Kısa Dönemli Bellek (Bi-Directional Long Short-Term Memory).....	58
8.5. Geçitli Tekrarlayan Birim (Gated Recurrent Units)	59
8.6. Öz Dikkat Mekanizması (Self Attention Layer)	60
9. DENEY ORTAMI, PARAMETRE AYARI VE PERFORMANS ÖLÇÜTÜ.....	63
10. SONUÇLAR	64
11. DEĞERLENDİRME VE ÖNERİLER.....	82
KAYNAKLAR.....	83

TABLULAR LİSTESİ

	Sayfa
Tablo 4.1. Pillerin karşılaştırılması	15
Tablo 4.2. Çağrı tasarımları ve göreceli güçlü ve zayıf yönler	21
Tablo 4.3. BMS'nin bileşenleri ve rolleri	24
Tablo 4.4. Deşarj derinliğinin bir fonksiyonu olarak çevrim ömrü 1	27
Tablo 7.1. NASA Prognostics Center of Excellence veri havuzunun bataryalarının özellikleri	50
Tablo 10.1. Batarya 5 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU).....	65
Tablo 10.2. Batarya 5 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM)	66
Tablo 10.3. Batarya 6 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU).....	67
Tablo 10.4. Batarya 6 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM)	68
Tablo 10.5. Batarya 7 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU).....	69
Tablo 10.6. Batarya 7 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM)	70
Tablo 10.7. Batarya 18 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU).....	71
Tablo 10.8. Batarya 18 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM).....	72
Tablo 10.9. Batarya 29 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU).....	73
Tablo 10.10. Batarya 29 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM).....	74
Tablo 10.11. Batarya 30 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU).....	75
Tablo 10.12. Batarya 30 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM).....	76
Tablo 10.13. Batarya 46 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU).....	77
Tablo 10.14. Batarya 46 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM).....	78
Tablo 10.15. Batarya 47 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU).....	79
Tablo 10.16. Batarya 47 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM).....	80
Tablo 10.17. Tüm tahmin hatalarının ortalaması.....	81
Tablo 10.18. Önerilen GRU-AM yönteminin diğer yöntemlere kıyasla yüzdelerik başarısı	81

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 3.1. Güç elektroniği kontrol cihazı.....	7
Şekil 3.2. Elektrikli aracın bileşenleri	9
Şekil 3.3. Bir EV'de enerji akışı	10
Şekil 4.1. Pilin devre şeması.....	12
Şekil 4.2. Pilleri özgül güç ve enerjilerine göre karşılaştırması	15
Şekil 4.3. Pozitif ve negatif elektrotları gösteren bir Li-ion pilin şematik yapısı	17
Şekil 4.4. Elektrikli araçlarda kullanılan farklı Li-ion pil türlerinin aşağıdaki açılardan karşılaştırması.	22
Şekil 4.5. Lityum iyon pil kimyası için SOC-OCV eğrileri: (a) LFP, (b) NMC, (c) LMO ve (d) NCA	25
Şekil 4.6. Örnek sabit akım, sabit gerilim (CC-CV) akü şarjı yaklaşıyor	26
Şekil 5.1. Batarya SOC ve SOH tahmin yöntemleri	28
Şekil 5.2. NMC bataryası için OCV kullanılarak SOC tahmini.....	30
Şekil 5.3. EKF kullanılarak SOC tahmini	32
Şekil 6.1. Veri bilimi tekniklerinin şemsiyesi. Yapay zeka (AI), veri bilimi alanına girer ve klasik programlama ve makine öğrenimini (ML) içerir. ML, derin öğrenme (DL) ve yapay sinir ağları (ANN) dahil olmak üzere birçok model ve yöntemi içerir	35
Şekil 6.2. Doğrusal ve lojistik regresyon kullanılarak örnek sınıf olasılık tahmini	37
Şekil 6.3. Karar ağacının yapısı.....	39
Şekil 6.4. Bir sinir ağının bileşenleri [101]	40
Şekil 6.5. Örnek bir ileri beslemeli ağ (solda) ve örnek bir tekrarlayan sinir ağı (sağda). Tekrarlanan örnekte, f fonksiyonu ve onun parametreleri θh zaman içinde paylaşılmaktadır	42
Şekil 6.6. Çıktı katmanı.....	43
Şekil 6.7. Sigmoid fonksiyonu ve türevi	44
Şekil 6.8. RNN, LSTM ve GRU'lar için yolların çizimi	45
Şekil 7.1. Yaşlı ve genç batarya hücresi voltaj, akım ve sıcaklık şarj grafikleri.....	51

Şekil 7.2.	Yaşlı ve genç batarya hücresi voltaj, akım ve sıcaklık deşarj grafikleri	52
Şekil 8.1.	Önerilen kapasite tahmininin genel çerçevesi	55
Şekil 8.2.	Önerilen çerçevenin adımları ve veri ön işleme sonuçları	56
Şekil 8.3.	Batarya 5, 6, 7 ve 18 için döngüye bağlı kapasite düşüşü.....	57
Şekil 8.3.	Batarya 29 ve 30 için döngüye bağlı kapasite düşüşü.....	57
Şekil 8.4.	Batarya 46 ve 47 için döngüye bağlı kapasite düşüşü.....	58
Şekil 8.5.	Tipik GRU yapısı	59
Şekil 8.6.	Öz-Dikkat Mekanizması girdiden çıktıya basit gösterim.....	61
Şekil 10.1.	Batarya 5 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)	65
Şekil 10.2.	Batarya 5 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM).....	66
Şekil 10.3.	Batarya 6 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)	67
Şekil 10.4.	Batarya 6 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM).....	68
Şekil 10.5.	Batarya 7 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)	69
Şekil 10.6.	Batarya 7 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM).....	70
Şekil 10.7.	Batarya 18 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)	71
Şekil 10.8.	Batarya 18 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM).....	72
Şekil 10.9.	Batarya 29 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)	73
Şekil 10.10.	Batarya 29 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM).....	74
Şekil 10.11.	Batarya 30 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)	75
Şekil 10.12.	Batarya 30 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM).....	76
Şekil 10.13.	Batarya 46 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)	77
Şekil 10.14.	Batarya 46 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM).....	78
Şekil 10.15.	Batarya 47 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)	79
Şekil 10.16.	Batarya 47 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM).....	80

SİMGELER VE KISALTMALAR LİSTESİ

A	Amper
AC	Alternatif Akım
Ah	Amper saat
AI	Yapay Zekâ
B	Batarya Hücresi
BMS	Pil Yönetim Sistemi
C	Kapasite
CCCV	Sabit Akım Sabit Voltaj
CE	Coulombic Verimlilik
Const	Sabit Değerler
D	Diyot
DC	Doğru Akım
DL	Derin Öğrenme
DOD	Batarya Deşarj Derinliği
ED	Elektrikli Sürücü
EKF	Genişletilmiş Kalman Filtresi
EV	Elektrikli Araç
GRU	Geçitli tekrarlayan birimler
HV	Yüksek Gerilim
Hz	Hertz
I	Akım
Kg	Kilogram
L	İndüktör
L	Litre
LFP	LiFePO - Lityum Demir Fosfat
Li-ion	Lityum İyon
LMO	Lityum Manganez Oksit
LSTM.	Uzun kısa süreli bellek
LTO	Lityum Titanat
mA	Mili Amper
mAh	Mili Amper Saat
ML	Makine Öğrenimi
mV.	Mili Volt
NMC.	Lityum Manganez Kobalt Oksit
OCV	Açık Devre Gerilimi
Q	Anahtarlama Elemanı
R	Direnç
RNN	Tekrarlayan Sinir Ağları
RPM	Dakikadaki devir sayısı
S	Anahtar
SMO	Kayan Mod Gözlemcisi
SOC	Batarya Şarj Durumu
SOH	Batarya Sağlık Durumu
V	Volt
W	Watt

YSA	Yapay Sinir Ağları
a	Alfa
β	Beta
γ	Gama
δ	Delta
π	Pi
Ω	Ohm
%	Yüzde

1. GİRİŞ

İlk elektrikli arabalar 1830'larda, ilk elektrikli makinelerin geliştirilmesinden hemen sonra üretilmiştir. Sonraki dönemde çok sayıda elektrikli araç üretilmiştir, ama bu elektrikli araçların ulaşımında kullanımında ciddi bir atılım yapılamamıştır. [1]

İlk zamanlar motorlu araçlar üzerine buharlı ve elektrikli araçlar olmak üzere iki yaklaşım mevcuttu. 19. yüzyılın sonlarında buharlı ve elektrikli otomobiller arasında ciddi bir rekabet yaşandı ve aynı dönemde insanlar, buharlı rakiplerinden daha iyi performans gösteren elektrikli arabaları buharlı makineler yerine tercih etti.

Elektrikli otomobil üretimi 1912'de zirveye ulaştı. O dönemde yalnızca en önemli elektrikli araç üreticilerinden biri olan Oliver P. Fritchle Company yılda 200'e yakın otomobil üretiyordu [2]. Sonraki yıllarda içten yanmalı motora sahip otomobillerin hızlı gelişimi nedeniyle elektrikli otomobiller araç pazarındaki payını kaybetmeye başladı. Amerika Birleşik Devletleri'nde üretilen elektrikli otomobillerin yüzdesi 1925'te %4'e düştü [3].

Ucuz, bol benzin ve kalıcı içten yanmalı motor gelişmeleri, önümüzdeki 30 yıl boyunca alternatif yakıtlı araçlara olan ihtiyacı ve bunlara olan ilgiyi önemli bir ölçüde azalttı. Ancak 1960'lı ve 1970'li yıllarda petrol fiyatları kalıcı olarak arttı. Petrol piyasasındaki en önemli şok, 1973 yılında OPEC'in küresel petrol ambargosu ilan etmesiyle yaşandı. Altı ayda akaryakıt fiyatları üç kat arttı ve bu şok dünya ekonomisi üzerinde hem acil hem de uzun vadeli sonuçlar doğurdu. İnsanlık ilk kez sınırlı kaynaklara ne kadar bağımlı olduklarını fark etti ve buna ek olarak, ICE kaynaklı hava kirliliği konusu da dikkat çekmeye başladı [4].

1990'lı yıllardan itibaren, özellikle sıkı çevre düzenlemeleri ve çevresel farkındalıklar sayesinde elektrikli otomobillere olan ilgi yeniden canlandı. Çoğu üretici, içten yanmalı motorlu modellerini elektrikli veya hibrit modellere dönüştürmeye başladı; bu da onların hız, performans ve menzil açısından benzinle çalışan arabalarla rekabet edebilmesine olanak sağladı.

Elektrikli araların kullanıldıđı ve ođunlukta olduđu bir ulařımın insanlık iin daha srdrlebilir bir geleceđin anahtarı olduđu n grlyor. En geliřmiř lkeler, elektrikli aralara geerek yabancı ham petrole bađımlılıklarını azaltabilir ve gezegendeki karbon kirliliđini en aza indirebilirler ve bunun zerine geliřmeler de alıřmalar da devam ediyor [5].

2. LİTERATÜR TARAMASI

Giriş kısmında bahsedildiği üzere, içten yanmalı motorların kullanmış olduğu fosil yakıtların çevreye zararlarına olan bilincin artması ve aynı zamanda bu yakıtların tükenbilir kaynak olması temiz yakıt kullanan araçlara olan ilgiyi arttırmıştır. Elektrikli araçlar (EV) bu konuda en çok ilgiyi üzerine toplayan seçenek olmuştur.

Elektrikli araçlarda enerjinin depolanabilmesi için bataryalar tercih edilmektedir. Kullanılan bu bataryaların pek çok türü ve çeşidi olmasına karşın; son zamanlarda geniş sıcaklık aralığında çalışabilmesi, yüksek enerji yoğunluğuna sahip olması, kendi kendine deşarj oranının az olması ve uzun çevrim ömrü gibi özellikleri sayesinde lityum iyon bataryalar ulaşım, elektronik, taşınabilir mobil cihazlar ve havacılık gibi çeşitli endüstriyel sektörlerde yaygın olarak kullanılmaktadır [6].

E.İ Tezde ve H.İ. Okumuş'a göre bataryalarda yaşanan öncelikli sorun batarya şarj durumunu belirlemek olmuştur. Bataryalar gözle görülür bir fiziksel depolama yapmadıkları için pek çok farklı şarj durumu belirleme (SoC) yöntemi üzerinde çalışılmış ve bu bağlamda pek çok yöntem ortaya konmuştur. Günümüzde en çok kullanılmakta olan Coulomb Sayma Yöntemi gibi farklı SoC belirleme yöntemleri ayrıntılı bir şekilde incelenmiş ve ortaya konmuştur [7].

Bataryaların şarj durumunu belirleme sorununa farklı yöntemler geliştirdikten sonra insanlık bataryanın sağlık durumunu (SoH) ve bataryanın kalan faydalı ömrünü belirleme sorunu ile karşı karşıya kalmıştır. E. Zio'nun ortaya koymuş olduğu Prognostik ve sağlık yönetimi (PHM), bileşenlerin bozulmasını tam zamanında tahmin eden ve böylece geleneksel bakım paradigmasını basitleştiren bir yöntemdir [8]. Bunu yaparken kalan faydalı ömür (RUL), bileşen veya sistemin güvenlik kriteri sınırına ulaşılan kadar geçen süre olarak tanımlanır. Bataryaların prognostik ve sağlık yönetimi ise batarya sağlığı ve korunumunun da dahil olduğu, PHM yöntemlerinin batarya alanına uygulanması etkinliğini ifade eder. Arızalara karşı kararlı çalışma perspektifinden sistemin durumunu yüksek güvenilirlikle tahmin etmek önemlidir. ISO 13381-1'e göre prognostik, "tasarım parametreleri dahilinde gelecekteki durumu ve kalan ömrü tahmin etmek için arıza belirtilerinin analizi" olarak tanımlanır [9].

Bu bağlamda pek çok araştırma yapılmış bataryanın ömrünün önceden tahmin edilebilmesi için pek çok farklı yöntem ve metot ortaya konulmuştur. T. Sarıkurt ve A. Balıkçı'nın ortaya koymuş olduğu bu metotlardan biri olan göreceli kapasite kestirim yöntemi, bir batarya hücresinin terminal voltajını incelemek için aynı yük sinyali altında farklı döngü sayıları veya yaşlardaki değişiklikleri kullanır [10].

Yapay Zekânın günümüzdeki gelişimi ile tahmin, öngörü hesaplamalarında alt başlığı olan makine öğrenmesinin yeri artmıştır. E. Çavuş ve İ. Sancaktar'ın makalesinde batarya sağlık durumunun makine öğrenmesi ile tahmin edilmesi için tanımlı girdi değerleri kullanılarak k-En Yakın Komşu (kNN) ve Rastgele Orman Regresyon (Random Forest) yöntemleri önerilen yöntemler arasındadır [11]. Buna ek olarak, [12] Y. Jiang, Y. Chen, F. Yang, ve W. Peng'in makalesinde ise Makine Öğrenmesinin alt başlığı olarak Sinir Ağlarından ise geleneksel manuel özellik mühendisliği sürecinden önemli ölçüde zaman ve iş gücü tasarrufu sağlayan, batarya ham verilerinden özellikleri otomatik olarak çıkarmak için evrişimli bir otomatik kodlayıcı önerilir [12].

Batarya ömrünün önceden tahmin edilebilmesi problemi bir zaman serisi tahmin modelidir. Zaman serisi tahmin modelleri, doğrulanmış geçmiş verilere dayanarak olayları tahmin etmek için kullanılır [13]. Zaman serisi modellerinde daha önce yapılan çalışmalarda Sinir Ağlarının Alt başlığı olan Derin Öğrenme yöntemlerinden Uzun Kısa Dönemli Bellek (Long Short-Term Memory) kullanımının daha başarılı olduğu görülmüştür.

Lityum iyon batarya için ise Y. Choi, S. Ryu, K. Park, ve H. Kim tarafından yapılan çalışmada NASA Prognostics Centre of Excellence tarafından yayınlanan veri setinin çok kanallı V, I, T verilerini içeren FNN, CNN ve LSTM'e dayalı bir kapasite tahmin çerçevesi önerilir. FNN ve CNN yöntemlerinden farklı olarak LSTM, kapasiteyi veride anormallikler olmasına rağmen doğru bir şekilde tahmin etmektedir. Bunun nedeni LSTM'nin uzun süreli bilgi depolayan hafıza hücreli yapısından kaynaklanmaktadır [14, 15]

I. Jorge, T. Mesbahi, A. Samet, ve R. Boné tarafından hazırlanan makalede ise NASA veri setinin yanı sıra, MIT tarafından yayınlanan veri seti de LSTM ile SoH hesaplanması için ele alınmıştır [15].

Bu çalışmada kullanılan Dikkat Mekanizmaları (Attention Mechanism), farklı parçalara atanan farklı ağırlıklara dayalı olarak dikkatin verinin belirli bölümlerine odaklanmasını sağlamak için derin öğrenme modellerine eklenen bir sinir ağı katmanıdır.

Yapılan çalışmada dikkat mekanizması ile LSTM'in beraber çalıştığı bir SoH öngörüm mekanizması ortaya konulmuştur [16]. Buna ek olarak, BiLSTM (Çift Yönlü Uzun Kısa Dönemli Bellek) zıt yönlerde iki LSTM'den oluştuğundan sıra ile ilgili problemlerde daha iyi performansa sahiptir. BiLSTM, verileri iki LSTM üzerinden zıt yönlerde iletebilir ve tersine çevirebilir, böylece hem geçmiş hem de gelecek bilgileri kullanabilir. BiLSTM sinir ağı ile Dikkat Mekanizması beraber kullanımının NASA veri seti ile SoH analizi incelenmiştir [17]. Geçitli Tekrarlayan Birim (GRU), Uzun Kısa Süreli Bellek (LSTM) ağlarına daha basit bir alternatif olarak 2014 yılında tanıtılan bir tür tekrarlayan sinir ağıdır (RNN). LSTM gibi GRU da metin, konuşma ve zaman serisi verileri gibi sıralı verileri işleyebilir [18].

3. ELEKTRİKLİ ARAÇLARIN GENEL BİLEŞENLERİ

Elektrikli Araç (EV) sektörü önceki bölümlerde bahsedildiği üzere zamanla ilerledi ve bu ilerlemenin sonucu olarak elektrikli araç üretirken kullanılan bileşenlerin sayısı ve bu bileşenlerin karmaşıklığı da arttı [19]. Bir EV'nin ana bileşeni Motor, Pil ve Güç Elektroniği cihazları olmasına rağmen bunlar ayrıca aşağıdaki bileşenler olarak sınıflandırılabilir.

3.1. Yüksek Voltaj Cer Bataryası

Pil, elektrikli araçlarda elektrik enerjisini doğru akım (DC) biçiminde depolamak için kullanılan bir parçadır. Kontrol cihazından gelen bir sinyale yanıt olarak pil, DC elektrik enerjisini invertöre iletecek ve daha sonra bu enerjiyi motora güç sağlamak için kullanacaktır. Bir "yüksek voltaj cer batarya paketi" de, bir araya getirilmiş şarj edilebilir pillerden yapılmış bir piller bütünüdür.

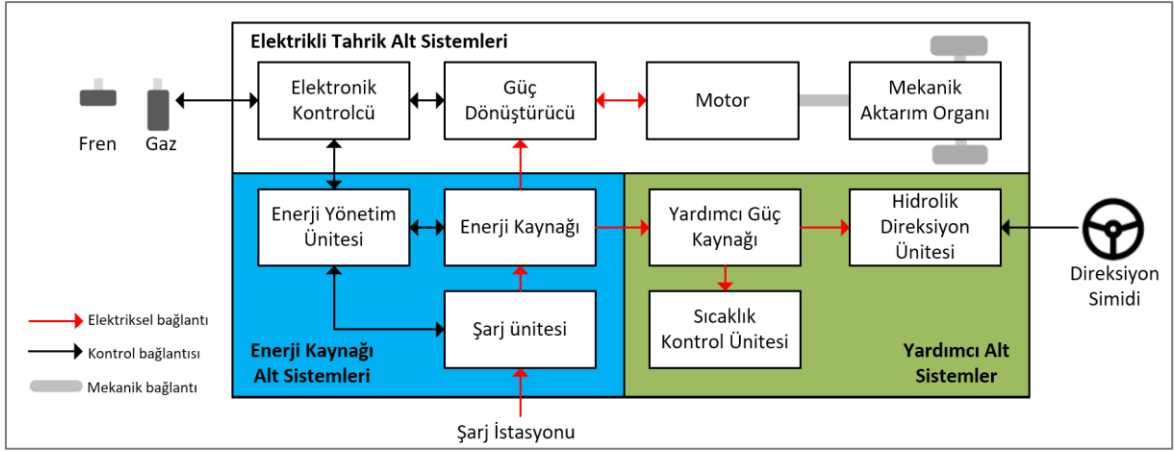
3.2. Güç Dönüştürücü İnvörtör

Aküden gelen doğru akım (DC), invertör tarafından alternatif akıma (AC) dönüştürülür ve bu daha sonra bir elektrik motoru tarafından kullanılır. Elektrikli bir otomobilin invertörü ayrıca rejeneratif frenleme sırasında üretilen AC enerjisini DC'ye dönüştürebilir ve bu daha sonra aküyü yeniden şarj etmek için kullanılabilir.

Çift yönlü invertörler kategorisi, çeşitli elektrikli otomobil modellerinde görülen invertör türünü içerir.

3.3. Güç Elektroniği Kontrolcüsü

Bu kısım motora giren frekans veya voltaj değişimini ve aynı zamanda aracın hızını belirleyecektir. Elektrikli cer motorunun torku ve hızı, aynı zamanda cer aküsünden gelen elektrik enerjisi akışını da kontrol eden bu cihaz tarafından kontrol edilir. Elektrikli otomobillerin çalışması bu unsur tarafından belirlenir. Şekil 3.1'de örnek bir güç elektroniği kontrol cihazı gösterilmektedir.



Şekil 3.1. Güç elektroniği kontrol cihazı [20]

3.4. Elektrikli Cer Motoru

Elektrik motoru, elektrik enerjisini mekanik enerjiye dönüştüren elektrikli bir cihazdır. Bir EV'deki elektrik motoru, aküden gelen gücü kullanan ve bunu, kontrolör ve tahrik tarafından verilen komutlara göre aracın tekerleklerinin dönme hareketine dönüştüren ana parçadır. EV'ler, araç konfigürasyonuna, maksimum hıza ve torka, maksimum güce, akü kapasitesine, voltaja ve maliyete bağlı olarak farklı türde çekiş motorları kullanır.

3.5. Yardımcı Batarya

Yardımcı akü, araçta bulunan ve 12 voltluk bir elektrik sisteminin çalışmasını destekleyen düşük voltajlı bir enerji kaynağıdır. Bu aksesuarlara güç sağlamak için yüksek voltajlı pil kullanmak yerine, yardımcı pil, sabit voltaj kaynağı gerektiren bir sistemin açık kalmasını sağlar. Çoğu durumda yardımcı akü, farlara, ses sistemlerine, bilgisayar kontrollerine ve pencereler, kilitler, elektrikli koltuklar, hidrolik direksiyon ve frenler, silecekler vb. dahil olmak üzere yardımcı sistemlere güç sağlar. Elektrikli araçların çoğunluğu kurşun asitli akü kullanır.

3.6. Şarj Bağlantı Noktası

Şarj portu, aracın harici bir güç kaynağına bağlanmasını kolaylaştırarak çekiş aküsü takımının şarj edilmesini sağlar. Şarj portu DC hızlı şarjı ve AC yavaş şarjı gerçekleştirebilir

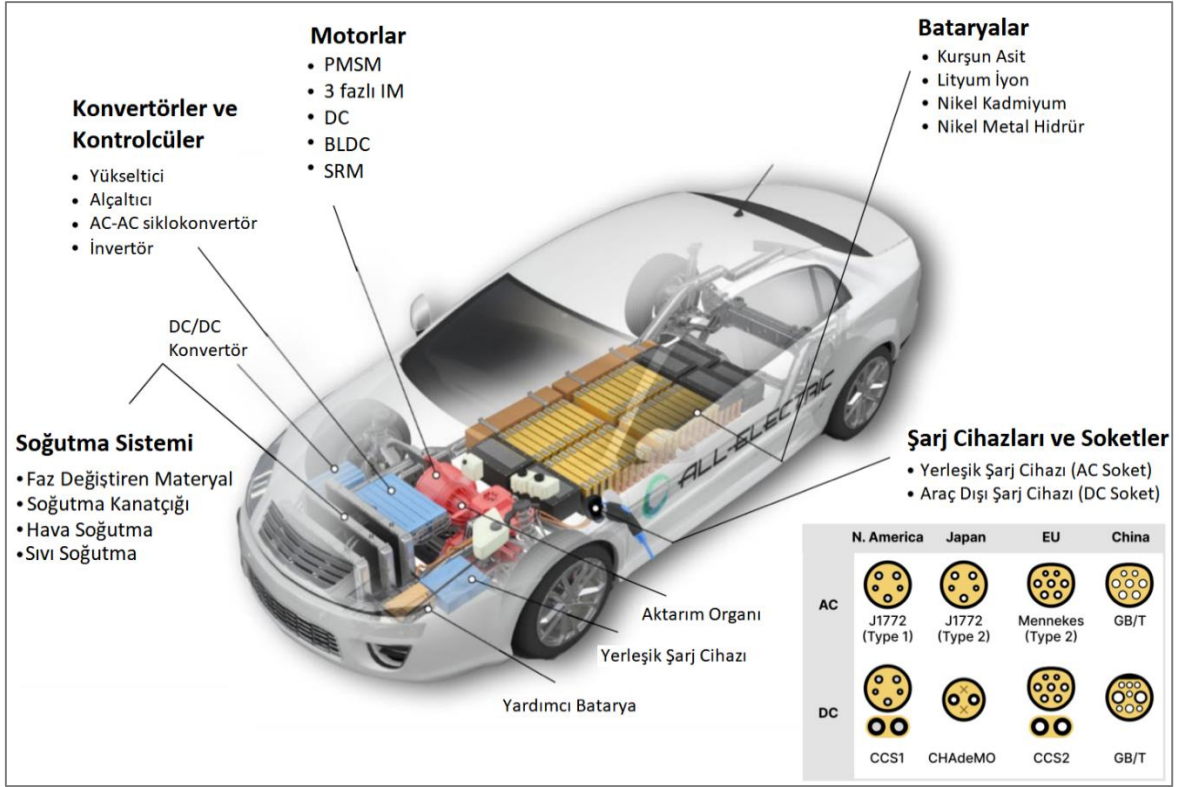
[21]. AC şarjı için şarj bağlantı noktasında AC güç pinleri, iletişim pinleri, bağlantı algılama pinleri, bir EV soketi ve bir toprak pini bulunur. Oysa DC hızlı şarj için şarj portu yalnızca yüksek güçlü şarj pinlerini ve iletişim pinlerini içerir [22]. Bazı EV'ler, hem AC hem de DC fişlerini taşıyabilen birleşik şarj bağlantı noktalarını kullanırlar.

3.7. Şarj Cihazı

Şarj cihazı, pili şarj etmek için şarj portunu mevcut enerji kaynağına bağlayan bir cihazdır. Enerji kaynağına göre, evsel veya şarj istasyonu olmasına göre, ayrı şarj cihazları kullanılır [23]. Şekil 3.2'de şarj cihazları ve soketleri gösterilmektedir.

İki tür EV şarj cihazı mevcuttur:

- Yerleşik şarj cihazı: Daha düşük kilovatlık güç aktarımı için tasarlanmıştır ve EV tasarımı nedeniyle boyut ve ağırlık sınırlamaları vardır. Yaygın olarak 3,3 kW ve 6,6 kW güç değerleri için kullanılır.
- Araç dışı şarj cihazı: Daha yüksek kilovatlık güç aktarımı için tasarlanmıştır ve EV'nin ağırlığını önemli ölçüde ortadan kaldırarak aracın genel verimliliğini artırabilir. 20 kW ile 150 kW arasında değişen güç değerlerine sahiptir.



Şekil 3.2. Elektrikli aracın bileşenleri [24]

3.8. DC/DC Dönüştürücü

Yardımcı akü DC-DC dönüştürücü yardımıyla şarj edilir. Bu elektrikli cihaz, HV akü grubundan ve yerleşik elektrikli cihazlardan 12 volt yardımcı aküye güç sağlar.

3.9. Şanzıman

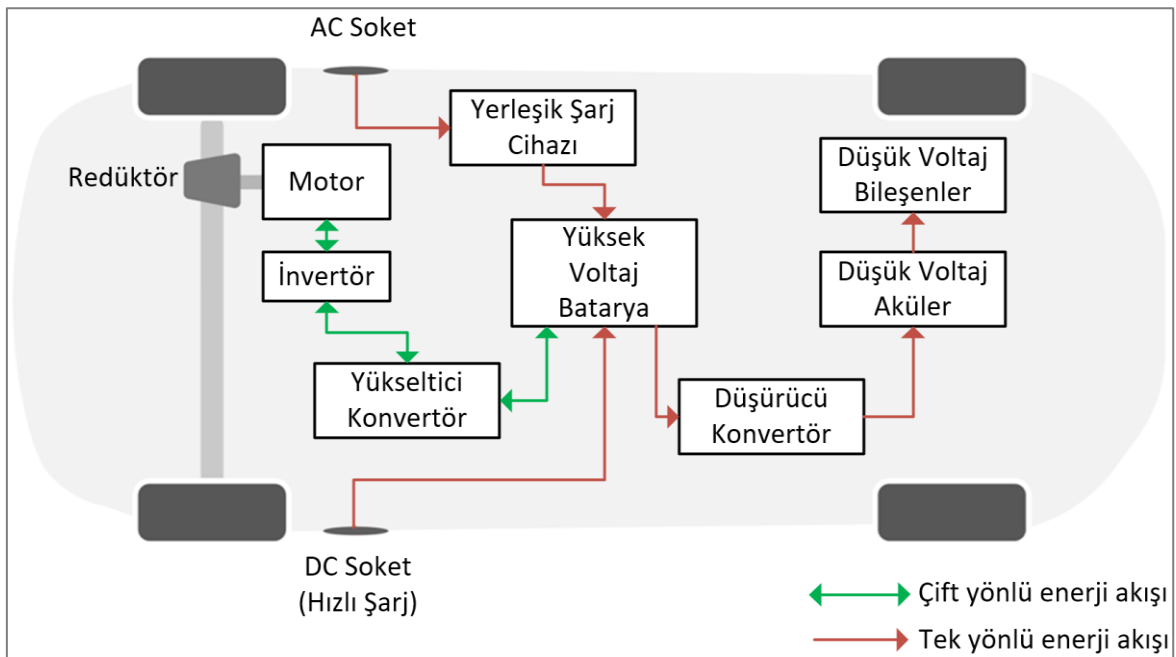
Elektrikli araçlarda motorun devrini azaltmak ve torku arttırmak için tek vitesli şanzımanlar kullanılır. Bu aynı zamanda redüktör olarak da bilinir. Ayrıca bir EV'yi tersine çevirmek için elektrik akımının yönü tersine çevrilir, bu da motordaki rotorun dönüşünü tersine çevirir. Elektrik motorları sıfır RPM'de en yüksek torka ulaşır ve 20.000 RPM'ye kadar güvenli bir şekilde çalışabilir. Tek bir dişli, geniş devir aralığı sayesinde gücü elektrik motorundan tahrik tekerleklerine tüm hız aralığı boyunca iletebilir.

3.10. Termal Sistem Soğutma

Bu sistem güç elektroniğini, elektrik motorunu ve diğer parçaları güvenli çalışma sıcaklığı aralığında tutar. Basınçlı hava soğutmayı, sıvı soğutmayı ve termoelektrik soğutmayı birleştirir.

3.11. Bileşenlerin Ara Bağlantısı

Bir EV'deki enerji akışı Şekil 3.3'te gösterilmektedir. Enerji bir veya iki yönde akabilir. Aküden elektrik motoruna güç sağlandığında tek yönlü olup, rejeneratif frenleme devreye girdiğinde elektrik motorundan aküye güç sağlanacak ve bu da yüksek gerilim aküsünü şarj edecektir.



Şekil 3.3. Bir EV'de enerji akışı

4. ELEKTRİKLİ ARAÇLARDAKİ CER BATARYALARI

Tarihte ilk elektrokimyasal pil, 1890 yılında mucit Alessandro Giuseppe Antonio Anastasio Volta tarafından tanıtıldı. Volta, tuzlu suya batırılmış bir bezle ayrılan gümüş/bakır ve çinkodan oluşan alternatif kutup yığınlarını kullanarak akımın yığının iki ucunu birbirine bağlayan bir telden aktığını keşfetti. Voltaic Pile tarihte bulunan ilk elektrokimyasal pildi. Elektrolit, her elektrotun reaksiyona girdiği ve pozitif yüklerin akışının katot üzerindeki elektronlarla nötrleştirilmesi için bir yol sağladığı kimyasal bir bileşiktir. [25] İki işlemi takip eden redoks reaksiyonuna hizmet eder: indirgeme ve oksidasyon.

4.1. Pil Parametreleri/Teknik Özellikler

Pilin genel potansiyelini azaltmak veya artırmak için bir grup hücre kullanılır. Elektrik pilleri iki tiptir:

- Birincil piller: şarj edilemeyen pillerdir. Elektronlar veya pozitif iyonlar serbest kaldıktan sonra elektrotlar tükenir.
- İkincil piller: şarj edilebilen pillerdir. Deşarj sırasında meydana gelen kimyasal reaksiyonlar tersine çevrilebilir. Süreç mükemmel değildir ve her şarj döngüsü pil ömrünün azalmasına neden olur.


Pil, parametreleriyle tanımlanır. Pilin parametrelerinin özellikleri aşağıdaki gibidir:

4.1.1. Hücre Gerilimi

Tüm elektrik hücreleri, hücre elektrik gücü sağladığında yaklaşık bir voltaj sağlayan nominal voltajlara sahiptir. Gerekli toplam voltajı sağlamak için hücreler seri veya paralel olarak bağlanabilir, bu da pratikte farklılık gösterebilir. Bir akım boşaldığında voltaj düşecek ve şarj sırasında yükselecektir.

Bu olguyu "iç direnç" ve pilin karşılaştırılabilir devresi açısından anlamak daha kolaydır. Pil tipik olarak sabit bir voltaja sahip olarak temsil edilir, ancak terminallerdeki

voltaj, iç direnç üzerindeki voltaj nedeniyle farklılık gösterir. Şekil 4.1'de gösterildiği gibi pilden bir akımın aktığını varsayarsak, temel devre teorisi şunu gösterir:



Şekil 4.1. Pilin devre şeması [26]

Akım I sıfır olduğunda, terminallerdeki voltajın açık devre voltajına E eşit olduğuna dikkat etmek önemlidir. Öte yandan, pil şarj ediliyorsa voltaj IR kadar artacaktır. Elektrikli araç (EV) aküleri için iç direnci mümkün olduğunca düşük tutmak çok önemlidir.

4.1.2. Şarj Kapasitesi

En önemli faktör pilin sağlayabileceği elektrik yüküdür. 1 A'nın 1 saniye boyunca akması sırasında oluşan yük, coulomb adı verilen SI birimleriyle ölçülür. Ancak bu birim uygunsuz derecede küçüktür. Bunun yerine ampsaat (1 saat boyunca akan 1 A) kullanılır. Örneğin bir akü "10 Ah" kapasiteye sahip olabilir. Buna göre 10 saatte 1 A, 5 saatte 2 A veya teorik olarak 1 saatte 10 A verme kapasitesine sahiptir.

4.1.2.1. Depolanan Enerji

Pilin görevi enerji depolamaktır. Bir pilin tutabileceği voltaj ve şarj, ne kadar enerji tutabileceğini belirler. SI birimi olan joule, oldukça küçük bir birimdir, bu nedenle wattsaat kullanırız. 1 W güçte bir saat çalışması için ihtiyaç duyduğu şey budur. 3600 J bir wattsaat ile karşılaştırılabilir. Aşağıdaki 4.1 numaralı formülde Wattsaat cinsinden hesaplaması verilmiştir.

$$\text{Wattsaat cinsinden enerji} = \text{Voltaj} * \text{Ampsaat} \quad (4.1)$$

4.1.2.2. Özgül Enerji ve Enerji Yoğunluğu

Gravimetrik enerji yoğunluğu olarak da bilinen ağırlık cinsinden pil kapasitesi Wh/kg cinsinden ölçülürken hacim, hacimsel enerji yoğunluğu veya enerji yoğunluğu olarak bilinen litre cinsinden ölçülür. Orta yüklerde uzun çalışma süresi gerektiren cihazlar, yüksek spesifik enerji için tasarlanmıştır.

4.1.2.3. Özgül Güç

Özgül güç, pilin kilogramı başına üretilen güç miktarıdır. Oldukça değişken olan ve akünün kendisi yerine aküye bağlanan yüke bağlı olan bu miktar alışılmadık bir durum. Pillerin maksimum gücü olmasına rağmen, bu güçte veya yakınında sık sık kullanılması önerilmez çünkü bu, verimliliği düşürebilir ve pilin ömrünü kısaltabilir. W/kg, belirli güç için kabul edilen birimdir. Piller bazen mükemmel özgül enerjiye sahipken, zayıf özgül güce sahiptir; bu, çok fazla enerji depolayabildikleri ancak bu enerjiyi yalnızca kademeli olarak salıverebildikleri anlamına gelir.

4.1.2.4. Kendiliğinden Deşarj Oranları

Piller kullanılmadığında kendi kendine deşarj olma eğilimindedir ve bu durumun önemli sonuçları olabilir. Bu önemlidir, çünkü bazı piller uzun süre şarj edilmeden bırakılamaz. Hiçbir elektrikli bileşen bağlı olmasa bile pillerin (akümülatörlerin) az ya da çok hızlı boşalmasına neden olan, kendi kendine çalışan elektrokimyasal süreçlerdir.

4.1.2.5. Pil Sıcaklığı, Soğutma İhtiyaçları ve Isıtma

Bazı piller ortam sıcaklığından daha yüksek sıcaklıklarda çalıştılarından, ilk çalıştırma sırasında ısıya ve soğutmaya ihtiyaç duyarlar. Düşük sıcaklıklarda pil performansı düşer ve bu da istenmeyen bir durumdur. Ancak aküye ısı verilerek bu sorun çözülebilir.

4.1.2.6. Pil Ömrü ve Derin Döngü Sayısı

Şarj edilebilir pillerin çoğunluğu yalnızca birkaç yüz derin şarj döngüsüne dayanabilir. Ancak kesin sayı pilin tipine, özel yapısına ve kullanım amacına bağlıdır.

4.2. Farklı Pil Türleri


EV'de kullanılan piller ikincil tiptedir. Şarj edilebilirler. İkincil pil türleri şunlardır:

- Kurşun Asit
- Nikel-kadmiyum
- Nikel Metal Hidrür
- Sodyum Sülfür
- Sodyum metal klorit
- Lityum İyon
- Alüminyum-hava
- Çinko-hava

Bu pillerin özellikleri Tablo 4.1'de verilmiştir. Bu pillerden lityum iyon, maliyeti ve yüksek enerji yoğunluğu nedeniyle çoğunlukla tercih edilmektedir. Pil Parametreleri Şekil 4.2'de özetlenmiştir.

Tablo 4.1. Pillerin karşılaştırılması [27]

Parametreler	Batarya Tipi							
	Kurşun Asit	Nikel Metal Hidrür	Sodyum Metal Klorit	Nikel Kadmiyum	Sodyum Sülfür	Alüminum Hava	Lityum İyon	Çinko Hava
Özgül Enerji (Wh/kg)	20-35	65	100	40-55	100	225	140	230
Enerji Yoğunluğu (Wh/l)	54-95	150	150	70-90	150	195	250-620	270
Özgül Güç (W/kg)	250	200	150	125	200	10	300-1500	105
Hücre Gerilimi (Volt)	2	1,2	2	1,2	2	1,4	3,5	1,2
Yaşam Döngüsü (80% Kapasite kalana kadar)	800	1000	>1000	1200	1000	>1000	>1000	>2000
Amper-Saat Verimliliği	80%	Gayet İyi	Çok yüksek	İyi	Çok İyi	-	Çok İyi	-
Kendi Kendine Deşarj (Günlük)	2%	5%	Yüksek	0.5%	Gayet Düşük	10%	0.33%	> 10%
Şarj Süresi (0 - 100%)	8sa	1sa	8sa	1sa	8sa	10 dak.	2-3sa	10 dak.
Şarj Süresi (0 - 80%)	1sa	20 dak.	-	20 dak.	-	-	<1sa	-



Şekil 4.2. Pilleri özgül güç ve enerjilerine göre karşılaştırması [28]

4.2.1. Lityum İyon Piller

Genel olarak Li-ion piller, lityum iyonlarının yük taşıyıcısı olarak görev yaptığı her iki elektrottan gelen ekleme reaksiyonlarına dayanan enerji depolama sistemleri olarak nitelendirilebilir [29].


Li-ion pil ailesinin tanımına bakılınca, birkaç değişik hücre kimyasının oluşturduğu görülür.. Lityum İyon pillerin çoğu, esas olarak grafit vs. gibi karbondan veya lityum titanattan ($Li_4Ti_5O_{12}$) kullanılarak oluşturulan negatif bir elektrot kullanır [30]. Li metali ve Li(Si) alaşımları gibi bazı yeni malzemeler de geliştirilme aşamasındadır [31].

Anot ve katotun rolü, şarj (elektrolitik) ve deşarj (galvanik) modları arasında tersine döndüğü için, bu makale kapsamında elektrotları pozitif elektrot ve negatif elektrot olarak ele alacağız. Bazı çalışmalarda, pilin çalışma moduna bakılmaksızın pozitif elektrot genellikle katot olarak adlandırılır ve negatif elektrot ise anot olarak adlandırılır.

Kullanılan elektrolit, elektrot malzemesinin seçimine bağlıdır, ancak genellikle iyon taşınmasına izin vermek için lityum tuzu (örn. LiPF₆) ve organik bir çözücünün (örn. dietil karbonat) bir karışımıdır. Dahili kısa devreleri önlerken lityum iyonlarının elektrotlar arasında aktarılmasına izin vermek için bir ara parçası kullanılır [32].

Bu düzenleme kavramsal olarak Şekil 4.3'de gösterilmiştir; pilin bir enerji kaynağı (yani galvanik cihaz) olarak çalışırken taşıma özellikleri gösterilmektedir; elektronlar negatif elektrottan pozitif elektrota doğru hareket ederken aynı anda Lityum iyonları da negatif elektrottan pozitif elektrota doğru hareket eder. Elektronötralliği korumak için negatif elektrot elektrolitten pozitif elektrota doğru iletilir. Sistem şarj modunda (bir elektrolitik cihaz olarak) çalıştırıldığında, elektron akımı ve Lityum iyon akışı tersine çevrilir.

Bu nedenle pozitif ve negatif elektrot malzemeleri, elektrolit ve ayırıcı için birçok malzeme seçeneği vardır. Çeşitli malzemelerin teknolojik sınırlamaları, aşağıda ayrıntılı olarak açıklandığı gibi işlevlerine göre belirlenir.



Şekil 4.3. Pozitif ve negatif elektrotları gösteren bir Li-ion pilin şematik yapısı [33]

Şekil 4.3'te görülebileceği üzere elektrot bağlayan elektrolit, iki elektrot arasında doğrudan teması önlemeyi amaçlayan gözenekli bir ayırıcı membran içerir. Pil galvanik bir cihaz gibi davrandığında, elektronlar negatif elektrottan akım toplayıcıya, oradan da yüke ve ardından ikinci bir akım toplayıcı aracılığıyla pozitif elektroda gider. Eş zamanlı olarak Lit iyonları, elektronötralliyeti korumak için negatif elektrottan elektrolit yoluyla pozitif elektrota doğru hareket eder.

Elektrolit, kullanım koşulları altında mümkün olan en yüksek lityum iyon taşınımını sunmalıdır. Piller genel ortamda çalışmalıdır. Çalışma aralığının $-30\text{ }^{\circ}\text{C}$ 'den (aşırı soğukta bir süre park edilmiş bir aracın pili için) $+60\text{ }^{\circ}\text{C}$ 'ye (çevresel koşulların ve şarj sırasında oluşan ısının birleşimi sonucu ısınan bir pil için) kadar uzanması muhtemeldir [34].

Ayırıcı aynı şekilde aynı çalışma koşulları altında mümkün olan en yüksek lityum iyon iletimini sağlamalı ve önemli miktarda aşırı ısınma meydana geldiğinde termal kaçak sürecini önlemek için hızlı bir termal kapatma yeteneği sunmalıdır [35-37].

Uygun maliyetli, yüksek kapasiteli bir bataryaya yol açan, negatif ve pozitif elektrot malzemelerinin uygun bir kombinasyonu mevcut olmalıdır. Nihai hücre voltajı, seçilen elektrot malzemesi çifti arasındaki farktır ve hücre kayıpları ile daha da değiştirilir.

Lityum iyon piller, şarj edilebilir piller arasında maksimum coulombic verimlilik (CE) derecelerinden birini sağlayan pillerdir (%99'dan fazla). CE, bataryaya elektronların iletilme verimliliğini ifade eder; bu, bataryadan alınan toplam şarjın, tüm döngü boyunca bataryaya iletilen toplam şarja oranıdır. Buna ek olarak, lityum iyon pilin kulombik verimliliği döngüyle birlikte artar.

4.2.1.1. Lityum Kobalt Oksit ($LiCoO_2$)

1991 yılında ilk defa Sony'de üretilip geliştirilen lityum kobalt oksit pil, elektronik (dizüstü bilgisayarlar, kameralar, tabletler vb.) için tercih edilen pildir. Bunun sebebi bu pillerin hem yüksek enerji yoğunluğu hem uzun kullanım ömrü hem de üretiminin kolay olmasıdır [32]. Lityum kobalt piller fazlasıyla reaktiftir ve bu sebeple termal stabiliteleri zayıftır ve güvenli kullanım sağlamak için çalışma sırasında izlenmelidir. Kobaltın sınırlı bulunabilirliği aynı zamanda onu daha pahalı hale getiriyor ve elektrikli araçlarda kullanım için uygun bir seçenek olmayı zorlaştırıyor. Bununla birlikte, bu yüksek enerji yoğun pil, Tesla Roadster ve Smart Fortwo elektrikli sürücüsüne (ED) güç sağlar [38].

4.2.1.2. Lityum Manganez Oksit ($LiMn_2O_4$)

Bu kimya, lityum kobalt oksit bataryaya göre daha iyi termal stabilite sağlar ancak yaklaşık %33 daha düşük kapasite ve daha kısa bir kullanım ömrüyle sonuçlanır [39]. Li-manganez pillerin çoğu, spesifik enerjiyi iyileştirmek ve kullanım ömrünü uzatmak için lityum manganez kobalt oksit (NMC) ile harmanlanır. LMO-NMC geçmişte aralarında Nissan Leaf, Chevy Volt ve BMW i3'ün de bulunduğu birden fazla EV üreticisi tarafından kullanılmıştır [32].

4.2.1.3. Lityum Demir Fosfat ($LiFePO_4$) (LFP)

LiFePO (LFP), düşük direnç, yüksek akım değeri ve uzun çevrim ömrü ile iyi bir elektriksel performansa sahiptir [40]. Fosfat, malzemenin parçalanmasını sınırlayan ısıya karşı yüksek toleransı, elektrotun fazla şarja karşı stabilize edilmesine yardımcı olarak sağlar. Bu pillerin sıcaklık aralığı geniştir. +60 °C ile -30 °C arasında çalışabilir ve termal kaçaktan etkilenme olasılıkları çok düşüktür. Fosfatlar yüksek maliyetli elektriğin dengelenmesine, ısı direncinin arttırılmasına ve kaynak kıtlığının azaltılmasına yardımcı olur. Bu piller geniş bir sıcaklık aralığına sahiptir. +60 °C ile -30 °C arasında çalıştırılabilir ve ısıl kaçaktan etkilenmeyebilir [32].

LiFePO, diğer Li-ion pillere göre daha yüksek bir kendi kendine deşarj özelliğine sahiptir ve bu da yaşlanmayla birlikte dengeleme sorunlarına neden olabilir. Bu durum, gelişmiş kontrol elektroniklerinin kullanımıyla azaltılabilir. Verimli güç-ağırlık oranları, yüksek güvenlik özellikleri ve kimyanın termal kaçaklara karşı direnci ile LiFePO4 piller, pek çok EV'de kullanım açısından popülerlik kazanıyor.

4.2.1.4. Lityum Nikel Manganez Kobalt Oksit (NMC)

Lityum Nikel Manganez Kobalt Oksit (NMC) elektrotları, fazla spesifik enerji veya yüksek yoğunluklu güç için tasarlanıp kullanılabilir. Nikel ve manganezin birleştirilmesi birbirlerinin gücünü artırarak NMC'yi en başarılı Li-iyon sistemi haline getiriyor ve EV güç aktarma organları için uygun hale getiriyor.

Bu piller, yüksek spesifik enerjileri ve mükemmel termal özellikleri nedeniyle şu anda yüksek talep görmektedir. Yukarıda belirtildiği gibi NMC, aralarında Nissan Leaf, Chevy Volt ve BMW i3'ün de bulunduğu birçok EV üreticisi tarafından kullanılmaktadır [39].

4.2.1.5. Lityum Nikel Kobalt Alüminyum Oksit (NCA)

Lityum Nikel Kobalt Alüminyum Oksit (NCA), 1999'dan beri özel uygulamalar için bulunmaktadır. Bu pil tipi NMC ile yüksek özgül enerji ve özgül güç (pilin enerji sağlama hızı) ve uzun ömür sunması sebebiyle benzerlikler paylaşmaktadır [39]. NCA yukarıda listelenenler kadar güvenli değildir ve bu nedenle elektrikli araçlarda kullanım için özel

güvenlik izleme önlemlerinin alınmasını gerektirir. Ayrıca üretimleri daha maliyetlidir, bu da diğer uygulamalarda kullanım açısından uygulanabilirliğini sınırlamaktadır [41]. Şu ana kadar Tesla, NCA kimyasını kullanan tek EV üreticisi olarak biliniyor [42,43].

4.2.1.6. Lityum Titanat (LTO)


Lityum titanat negatif elektrotlu piller 1980'lerden beri bilinmektedir. Li-titanat (LTO), standart bir Li-iyon pilin negatif elektrotundaki grafitin yerini alır ve malzeme, spinel bir yapıya dönüşür. Burada, karşı taraftaki elektrot lityum mangan oksit veya NMC olabilir [44]. Spinel lityum titanat, lityumlaştırma anındaki hacim değişimi yaşanmaması nedeniyle fazlasıyla kullanılan bir elektrot malzemesi olarak kabul edilmiştir; bu, elektrot için son derece uzun bir çalışma ömrüne yol açar ve yaklaşık 1,55 V'ta son derece düz bir deşarj ve şarj platosu sayesinde geliştirilmiş güvenlik ile birleştirilir.

Titanate piller, Mitsubishi'nin i-MiEV elektrikli aracının [45] yalnızca Japonya'ya özel bazı versiyonlarında kullanılır ve Honda bunları Fit EV'sinde [46] kullanır. LTO aynı zamanda Tosa konseptli elektrikli otobüste de kullanılmaktadır [47]. Yüksek güvenlik seviyeleri nedeniyle lityum titanat piller mobil tıbbi cihazlarda kullanılmaktadır [48].

4.2.2. Li-İyon Pillerin Fiziksel Uygulaması

Hücre tasarımı, Tablo 4.2'de görülebileceği gibi birçok farklı form ve şekilde olabilir. Bu esneklik, Li-ion pillerin kullanım alanlarının genişletilmesine yardımcı olur çünkü piller, her araç için birden fazla farklı form faktöründe tasarlanabilmektedir [29].

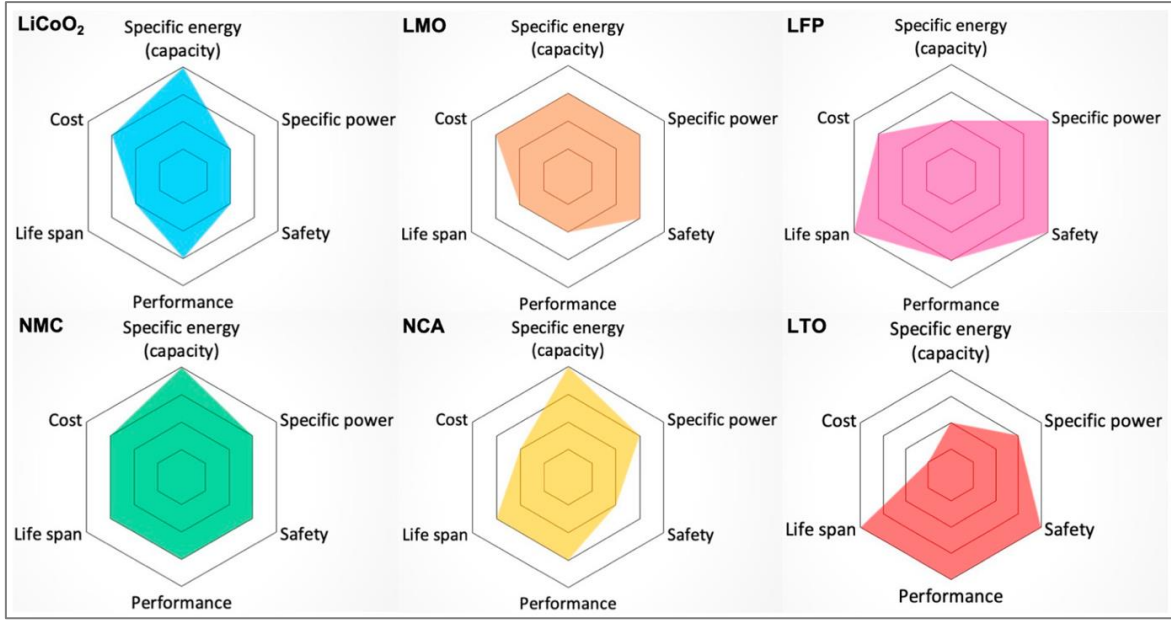
Tablo 4.2. Çağrı tasarımları ve göreceli güçlü ve zayıf yönler [49]

Biçim	Silindirik	Prizmatik	Kese
Diyagram			
Elektrot Düzeni	Yarıklı	Yarıklı	İstiflenmiş
Mekanik Dayanım	++	+	-
Isı Yönetimi	-	+	+
Özgül Enerji	+	+	++
Enerji Yoğunluğu	+	++	+

4.2.3. Elektrikli Araçlarda Kullanılan Farklı Li-İyon Pil Türlerinin Karşılaştırmaları

Elektrikli güç aktarma organları için Li-ion iyi bir seçim olmaya devam etmektedir. Şekil 4.4, EV'lerde kullanılan farklı Li-ion pil türlerini çeşitli özellikleri dikkate alarak grafiksel olarak karşılaştırmaktadır. Renkli alan büyüdükçe tercih edilmesi artmaktadır. Dikkate alınan başlıca faktörler özgül enerji, özgül güç, güvenlik, performans, kullanım ömrü ve maliyettir.

Özgül enerji, bir pilin birim ağırlık başına ne kadar enerji tutabileceğini gösterir ve bu da sürüş menziline yansır. Özgül güç, talep üzerine yüksek akım sağlama yeteneğidir ve potansiyel araç ivmesini gösterir. Elektrikli araç için pil seçerken güvenlik doğal olarak en önemli unsurlardan biridir. Performans, EV'yi aşırı sıcaklık koşullarında sürerken pilin durumunu yansır. Yaşam Süresi döngü sayısını ve ömrünü yansır. Maliyet ise güvenlik için gerekli yardımcı sistemler, şarj durumu izleme için pil yönetimi, uzun ömür için iklim kontrolü ve 8-10 yıllık garantiyle birlikte teknolojinin fizibilitesini sunar [38].



Şekil 4.4. Elektrikli araçlarda kullanılan farklı Li-ion pil türlerinin aşağıdaki açılardan karşılaştırması.

Özgül enerji (kapasite), özgül güç, güvenlik, performans, kullanım ömrü ve maliyet. En çok arzu edilen dış altıgendir. NMC, LiFePO₄ ve Lityum Manganez Oksit bu altı aday arasında üstün olarak öne çıkıyor [50].

4.2.4. Lityum İyon Pil Ömrü

Li-ion pillerin sağlığını ve ömrünü etkileyen çeşitli faktörler vardır [51]. Li-ion pillerin performans düşüşü, kapasite (diğer bir deyişle mevcutta bulunan enerji) veya güç (diğer bir deyişle reaksiyon hızı) kaybı ile açıklanabilir. Burada aktif madde aktif olmayan fazlara arazitik kimyasal reaksiyonların bir sonucu olarak dönüşür ve bu sebeple kapasite kaybolur [52], ancak konu karmaşıktır ve temel yaklaşımlardan modellenmesi kolay değildir [53].

Pil malzemelerini taşıma bariyerleri görevi gören diğer bileşiklere dönüştüren, hücrenin iç empedansını artıran ve dolayısıyla her deşarj oranında çalışma voltajını azaltan parazitik reaksiyonlar meydana geldiğinde güç de aynı şekilde azalır [54, 55]. Yakın tarihli bir rapor, muhtemelen yeni hücrenin katı elektrolit ara fazının düşük empedansından ve dolayısıyla bu ara fazın değişme hızından dolayı, kapasite azalması ile hücrenin enerji verimliliği arasındaki yüksek korelasyonu vurgulamaktadır [56, 57]. Bu bölüm, pillerin

genel Sağlık Durumunu (SOH) etkileyebilecek bazı önemli konuları incelemesini sunmaktadır.

4.2.4.1. Sıcaklık

Pillerin özellikle şarj ve deşarj sırasındaki sıcaklığı, Li-ion pilin performansını ve yaşam uzunluğunu etkileyen temel unsurlardan bir tanesidir [58]. Pillerin fazla ısınması, sıcaklıkların 500 °C'ye kadar çıkabileceği ısıl sürüklenmelere yol açabilir [37]. Tek bir hücrenin bile ısıl sürüklenmesi, diğer hücrelerle zincirleme reaksiyona yol açarak yangına ve can veya mal kaybına neden olabilir. Şirketlere düzeltilmesi milyonlarca dolara mal olmuş çok sayıda yüksek profilli pil yangını vakası yaşanmıştır [59-61].

Pil ömrünü uzatmak ve ondan da önemli olan güvenlik problemini çözmek için tüm Lityum İyon piller, şarj etme, boşaltma, hücre voltaj eşitleme, sistemin genel sıcaklığı ve izlemenin yanı sıra kontrolü de içermek üzere pillerin bütün yönlerini düzenleyen ve kontrol eden bir pil yönetim sistemine (BMS) sahiptir [32]. Elektrikli araçlarda, BMS veri kaydı gerçekleştirebilir ve Denetleyici Kontrol Modülüne (SCM) rapor verebilir. Akü performansını iyileştirebilir aynı zamanda araç çalışmasını optimize edebilir.

BMS'in genel özellikler şu şekildedir: (1) güvenlik tehlikelerinden koruma (yangın, şok vs.) [62]; (2) ortalama pil ömrünün ve verimliliğinin artırılması için en iyi pil çalışma ortamının (30–40 °C), şarj durumunun (SOC), deşarj derinliğinin (DOD), SOH, şarj/deşarj gücü ve pil hücresi dengesinin korunması [63]; (3) kalan sürüş mesafesini doğru bir şekilde tahmin etme [64]. BMS'nin bileşenleri ve rolleri aşağıda Tablo 4.3'te listelenmiştir.

Tablo 4.3. BMS'nin bileşenleri ve rolleri [65]

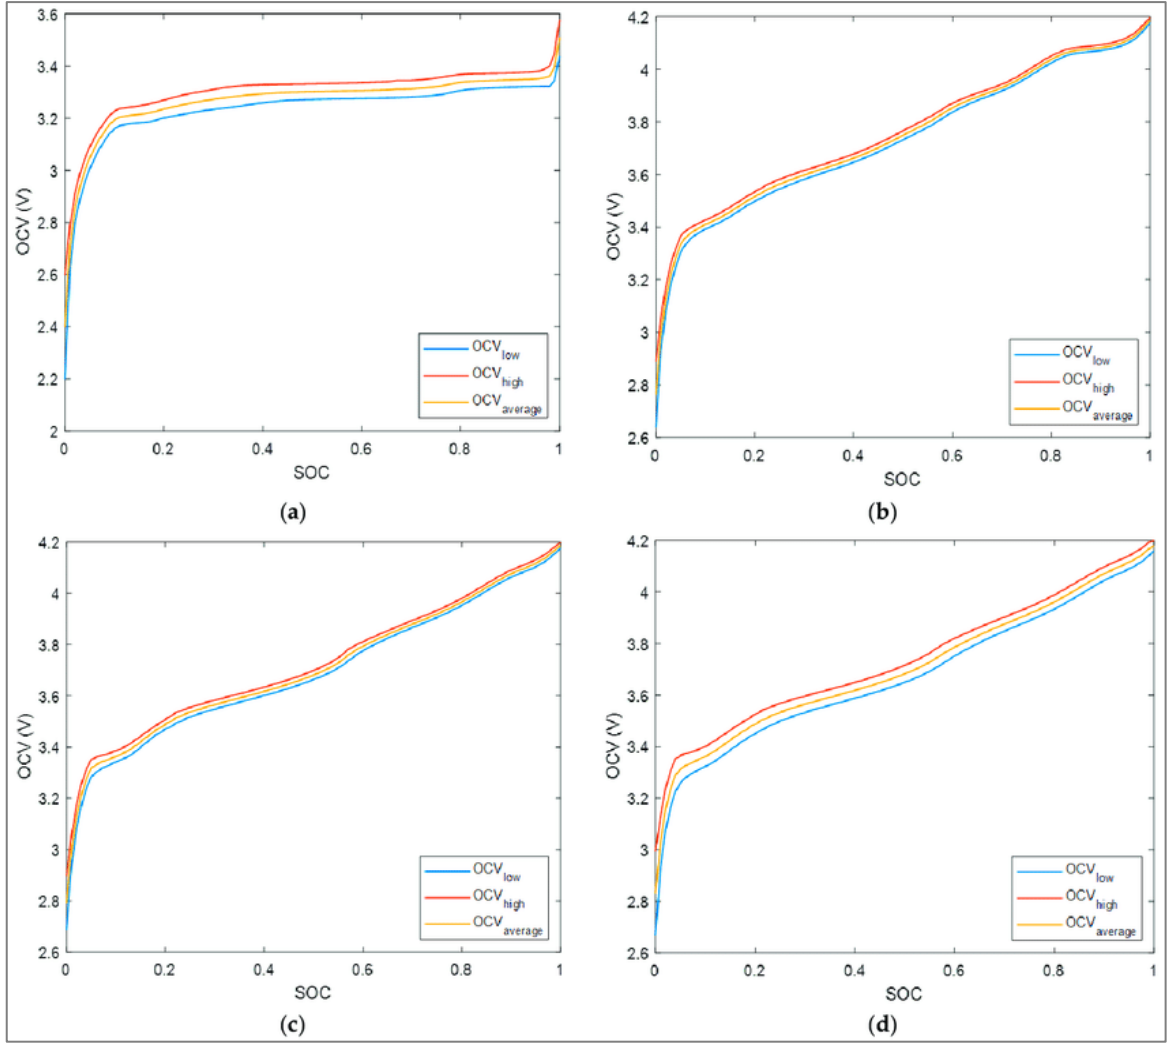
BMS'nin Bileşenleri	Her Bileşenin İşlevsel Detayları
Ölçüm Bloğu	Akü grubunun farklı noktalarındaki bireysel hücre voltajlarını, akü akımını ve akü sıcaklığını ve ayrıca ortam sıcaklığını yakalar ve bunları dijital değere dönüştürür.
Pil Algoritması Bloğu	Pil voltajı, akım ve sıcaklık gibi ölçülen pil değişkenlerini kullanarak şarj durumunu (SOC) ¹ ve sağlık durumunu (SOH) ² tahmin eder.
Yetenek Tahmin Bloğu	Akünün mevcut güvenli şarj ve deşarj akımı seviyesi hakkında motor kontrol ünitesine (ECU) bilgi gönderir.
Hücre Eşitleme Bloğu	Hücre voltajlarını karşılaştırır, en yüksek ve en düşük hücre voltajı arasındaki farkı bulur ve hücre dengeleme tekniklerini uygular.
Termal Yönetim Bloğu	Ortam ve akü sıcaklıklarını okur, soğutma veya ısıtma işlemini başlatır ve anormal sıcaklık artışı durumunda ECU'ya acil durum sinyali gönderir.

^{1,2}SOC, pilin tam kapasiteli şarjıyla karşılaştırıldığında pilde depolanan mevcut şarjı temsil eden bir göstergedir. SOC'nin doğru tahmini, yalnızca EV'lerdeki enerjinin optimum yönetimi için değil, aynı zamanda pilin sağlıksız DOD'a gitmesinden veya pil ömrünü azaltan ve potansiyel olarak tehlikeli durumlar yaratabilecek aşırı şarj koşullarından korumak için de gereklidir.

Her pilin sıcaklık aralığı, söz konusu pil içeriğinde kullanılan kimyaya göre çeşitlilik gösterir. Pilleri ideal olmayan sıcaklıklarda çalıştırmak, pilin kapasitesinde bulunan maksimum şarj düzeyini negatif yönde etkileyebilir ve pilin sağlayabileceği toplam döngü sayısını azaltabilir [66].

Şarj ve deşarj süresinde yaşanan sıcaklıklardaki büyük değişikliğin düşürülmesine yardım etmek amacıyla pek çok elektrikli araç, minimum bir termal yönetim sistemi kullanır. Bu termal yönetim sistemleri hem pasif hem de aktif soğutma sistemlerini içerebildiği gibi, sıcak olmayan iklimlerde bataryaları ısıtmak için bir veya daha fazla ısıtma kaynağı da içerebilmektedir [32]. Bu sistemler, bütün pil sisteminin sıcaklıklarını korumak için tasarlanmıştır ancak tek bir hücrenin arızalanmasının tüm pilin performansını önemli ölçüde bozabileceği göz önüne alındığında, performans düşüşünü önlemek için hücre gruplarının ve hatta tek tek tüm hücrelerin sıcaklığının izlenmesini de kapsayabilir.


Açık Devre Gerilimi (OCV) eğrisi, pilin çeşitli SOC'lerdeki elektrokimyasal süreçlerini ve termodinamiğini temsil eder. Genellikle SOC ve OCV Li-iyon ile ilgili doğrusal olmayan monotonik bir fonksiyondur ve bu nedenle SOC hesaplamalarını düzeltmek için pil yönetim sistemlerinde (BMS) yaygın olarak kullanılır [67]. OCV eğrisinin doğruluğu, SOC değeri ve pil kapasitesi tahminleri üzerinde büyük etkiye sahiptir [68]. OCV eğrisi, Şekil 4.5'de [67] gösterildiği gibi Li-ion pillerin kimyalarına bağlı olarak değişmektedir.



Şekil 4.5. Lityum iyon pil kimyası için SOC-OCV eğrileri: (a) LFP, (b) NMC, (c) LMO ve (d) NCA. [69]

4.2.4.2. Şarj ve Deşarj Oranı

Pek çok pil üreticisi, sektörde sabit akım, sabit voltaj (CC-CV) olarak da bilinen bir şarj geleneğini önerir. Tipik CC-CV şarj döngüsü Şekil 4.6'da görülebilir [70]. Bu profili kullanarak şarjı sürdürürken sistem, pil maksimum şarj voltajına ulaşana kadar sabit bir akım sağlar, sonrasında ise akımı düşürerek hücrelerin aşırı şarjını önlemek üzerine çalışır [71].



Şekil 4.6. Örnek sabit akım, sabit gerilim (CC-CV) akü şarjı yaklaşıyor [72]

Bir pilin maksimum kapasitesine göre şarj edilebileceği veya boşaltılabileceği orana C_{rate} denir:

$$C_{rate} = \frac{P_{ch}}{E_{cap}} \quad (4.2)$$

4.2 numaralı formülde P_{ch} toplam şarj gücüdür ve E_{cap} pilin toplam kapasitesidir. Bir akünün kapasitesi 75 kWh ise, 1 C'de aküyü tamamen şarj etmek için bir saat boyunca 75 kW enerji verilir [73]. Amper-saat (Ah) cinsinden nominal kapasite, genellikle bir pilin akım sağlama yeteneğini tanımlamak için kullanılır. Sabit bir süre için C_{rate} ne kadar yüksek olursa, nominal Ah kapasitesi de o kadar düşük olur [74].

4.2.4.3. Şarj ve Deşarj Derinliği

Bir Elektrikli Araçta bulunan Li-ion pil, orijinal kapasitesinin %80'inin üzerinde şarj olmayacağında kullanım ömrünün sonuna ulaşmış olur. Deşarj derinliği (DoD), bir pilin kullanım ömrü boyunca karşılayabileceği toplam şarj döngüsü sayısını etkileyebilir. DOD, pilin şarj durumunu (SOC) belirtmek için alternatif bir yöntemdir. DOD, SOC'nin tamamlayıcısıdır: biri arttıkça diğeri azalır. Dişlilerde ve pistonlarda meydana gelen mekanik aşınma, parçanın ömrünü kısaltacağı gibi, deşarj ve sonraki şarj döngüsü sırasında batarya içerisinde meydana gelen ikincil kimyasal reaksiyonlar nedeniyle bataryanın deşarj seviyesi zamanla kısalmır [75].

Tablo 4.4, tipik bir Li-ion pilden beklenebilecek döngü sayısını gösterir [76]. %100 DoD, pilin tamamen deşarj ve şarj edildiği anlamına gelmektedir.

Pil ömrünün korunmasına yardımcı olmak için üreticiler genellikle pilin belirli ayar noktalarının ötesinde şarj veya deşarj edilmesine izin vermeyecek bir yazılım kontrol sistemini BMS'lerine eklerler [77].

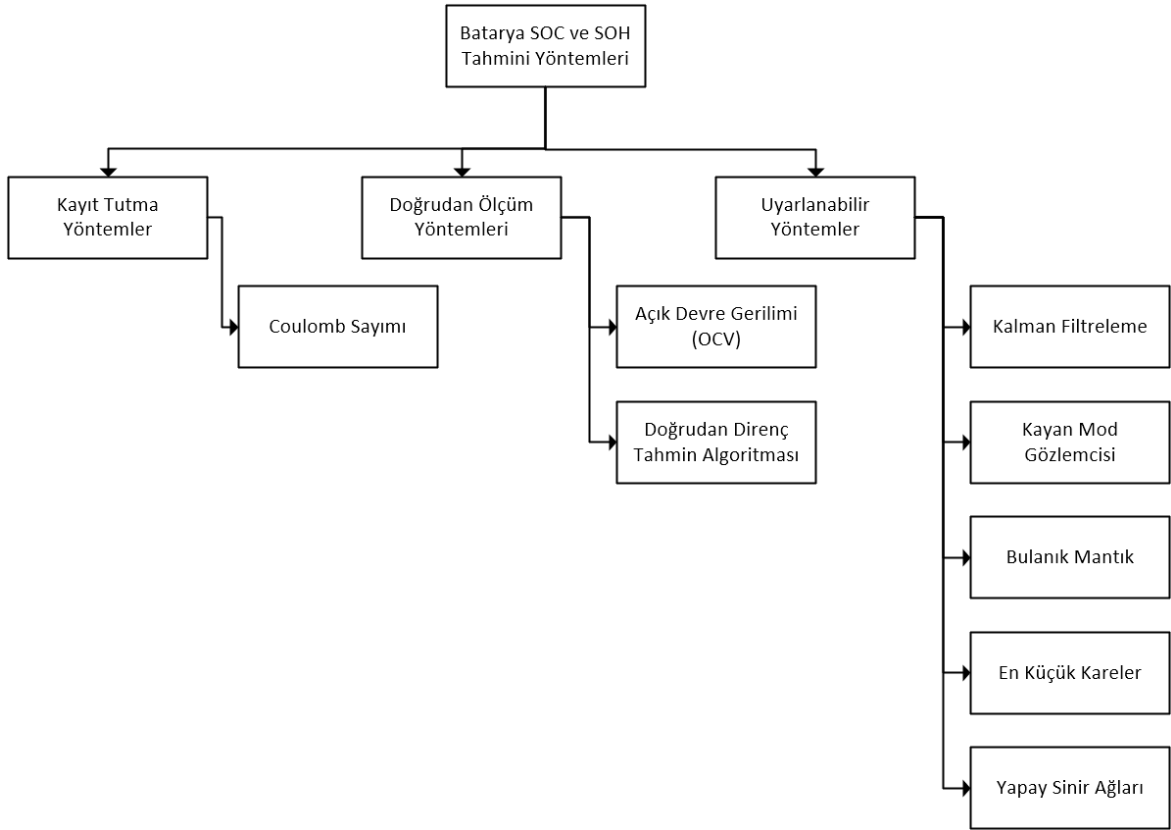
Tablo 4.4. Deşarj derinliğinin bir fonksiyonu olarak çevrim ömrü ¹ [77]

Deşarj Derinliği	Deşarj Döngüleri
100%	300-600
80%	400-900
60%	600-900
40%	1000-3000
20%	2000-9000
10%	6000-15000

¹Faydalı ömür %80 enerji performansı eşiği olarak tanımlanır.

5. BATARYA SOC VE SOH TAHMİNİ

Batarya SOC ve SOH tahmini için kullanılmakta olan yöntemler genel olarak aşağıdaki şekilde gösterilmiş ve açıklanmıştır. Şekil 5.1’de görülebilecek olan uyarlanabilir yöntemlerden yapay sinir ağları bu çalışmada kullanılmış olan tahmin yöntemidir. Kullandığımız yöntemin detayları ilerleyen başlıklarda detaylıca anlatılmıştır.



Şekil 5.1. Batarya SOC ve SOH tahmin yöntemleri

5.1. Coulomb Sayımı

Amper-saat yöntemi olarak da bilinen Coulomb sayımı, pil durumlarını ve özellikle pilin şarj durumunu tahmin etmek için kullanılan en yaygın tekniklerden biridir. Adından da anlaşılacağı gibi bu yöntem, akünün şarj durumunu (formül 5.1) [78] veya sağlık durumunu (formül 5.2) [79] belirlemek için şarj-deşarj işlemi sırasında giren veya çıkan birikmiş akımı hesaplar.

$$SOC(t) = SOC(t_0) - \frac{1}{Q_{rated}} \int_{t_0}^t \eta(t) I_{bat} dt \quad (5.1)$$

Burada $SOC(t_0)$ başlangıç SOC'yi temsil eder, Q_{rated} nominal kapasiteyi ve I_{bat} akü akımını temsil eder.

$$SOH(t) = \frac{1}{Q_{rated}} \int_{t_0}^t I(t) dt \quad (5.2)$$

Burada I deşarj akımıdır. Coulomb sayma yöntemi, pil durumlarını mümkün olduğunca doğru bir şekilde tahmin edebilmek için başlangıçtaki SOC'nin doğru bir tahminini ve pil akımının hassas bir ölçümünü gerektirir. Ancak gerçekte ölçülen akım, sensör gürültüsünü içerir ve kendi kendine deşarj akımını ve şarj ve deşarj sırasındaki akım kayıplarını dikkate almaz, bu da ölçülen akımı gerçek hücre akımından farklı kılar.

5.2. Doğrudan Direnç Tahmin Algoritması

Li-iyon pil hücrelerinin ömrünün gelişimi, ölçülebilir iki büyüklükle temsil edilebilen farklı bozulma mekanizmalarından etkilenir: kapasite kaybı ve iç direncin artması. Sonuç olarak bu iki parametrenin değişimini gözlemleyerek pilin sağlık durumunu tahmin edebiliriz.

Deşarj işlemi sırasında voltaj eğrisindeki adım değişimi gözlemlenerek, pilin iç direnci 5.3 numaralı formül kullanılarak yaklaşık olarak hesaplanabilir [80]:

$$R = \frac{\Delta U}{\Delta I} \quad (5.3)$$

Burada ΔI mevcut adım değişimini temsil eder ve ΔU aynı adım değişimine karşılık gelen voltajdır.

DRE algoritması kullanılarak pilin iç direncinin tahmini, ölçüm okumasındaki gürültü nedeniyle gürültülü sonuçlar verir.

Bu yöntemin uygulanması, herhangi bir eğitim verisine veya ilk pil karakterizasyonuna ihtiyaç duyulmadığından daha küçük bir bellek alanı gerektirir. Ayrıca


karmaşık matris hesaplaması gerektirmemesi onu gömülü sistem için uygun kılmaktadır [81].

5.3. Açık Devre Gerilimi (OCV)

Pil durumlarını tahmin etmeye yönelik bir başka basit yaklaşım, hücrenin açık devre voltajını (OCV) ölçmektir. Literatürde pil hücrelerinin OCV'si ile SOC'si arasında güçlü bir bağımlılık olduğu kanıtlanmıştır. Bu voltaj bazlı yöntem, pilin OCV ve SOC deşarj eğrisini kullanarak verilen voltaj değerinin eşdeğer SOC değerini verir. Basitleştirilmiş bir elektrik modeline dayanarak akü OCV'sini aşağıdaki 5.3 numaralı formüldeki gibi tanımlayabiliriz:

$$U_{OCV}(SOC(t)) = U(t) - R_0 I(t) \quad (5.4)$$

U_{OCV} pil OCV'sidir. $U(t)$ akü terminal voltajıdır. R_0 iç dirençtir. $I(t)$ akü akımıdır.



Şekil 5.2. NMC bataryası için OCV kullanılarak SOC tahmini [82]

OCV ayrıca pilin SOH değerini tahmin etmek için de kullanılmıştır. SOC/OCV ilişkisini bilerek iç direncin tahmini yapılabilir ve iç direnç ise bize SOH hakkında yeterli bilgiyi sağlar. Şekil 5.2’de NMC bataryasının SOC/OCV grafiği örnek olarak gösterilmektedir.

5.4. Kalman Filtreleme

Kalman filtresi, durumlarını belirlemek için doğrusal bir sistemin matematiksel temsilini kullanan model tabanlı bir algoritmadır. Literatür bu yaklaşımı iki temel adımda çalışan sağlam bir algoritma olarak tanımlamaktadır [79]:

- Tahmin aşaması: sistem durumu 5.5 ve 5.6 numaralı formüller kullanılarak tahmin edilir:

$$\hat{x}_{(t-1)} = F_t \hat{x}_{(t-1)} + B_t u_t \quad (5.5)$$

$$P_{(t-1)} = F_t P_{(t-1)} + Q_t \quad (5.6)$$

- Güncelleme aşaması: Algoritma, sistem hatalarına dayalı olarak öngörüyü 5.7, 5.8, 5.9 numaralı formülleri kullanarak günceller:

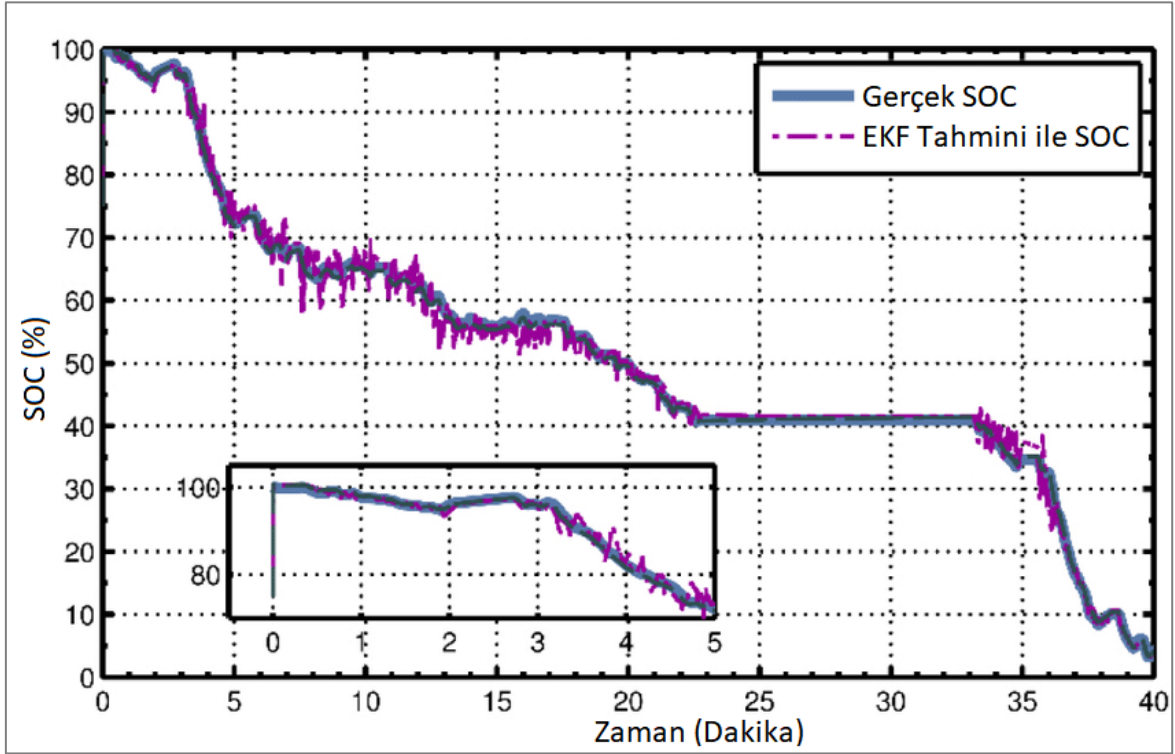
$$\hat{x}_{(t)} = \hat{x}_{(t-1)} + K_t (y_t - H \hat{x}_{(t-1)}) \quad (5.7)$$

$$K_t = P_{(t-1)} H_t^T (H_t P_{(t-1)} H_t^T + R_t)^{-1} \quad (5.8)$$

$$P_{(t)} = P_{(t-1)} - K_t H_t P_{(t-1)} \quad (5.9)$$

\hat{x} tahmini durumdur. F durum geçiş matrisidir. B kontrol matrisidir. u giriş vektörüdür. P ve Q sırasıyla durum ve süreç varyans matrisidir. y çıktı ölçümüdür. K, Kalman kazancıdır. H ölçüm matrisidir. R, ölçüm varyans matrisidir. Kalman filtresi doğrusal sistemler için sınırlı olduğundan ve bir sürecin durumlarının güvenilir bir tahminini kanıtladığından, araştırmacılar bu model tabanlı algoritmayı doğrusal olmayan sistemlere uyarlamak için farklı uzantılar geliştirdiler.

Geniřletilmiř Kalman Filtresi (EKF), pil durumu tahmini gibi dođrusal olmayan sistemlerle ilgilenen geliřtirilmiř versiyonlardan biridir. Bu yaklařım, pil SOC'sini tahmin etmek iin yaygın olarak kullanılmaktadır. Tahmin sureci, ayırık zamanda tepkisini tanımlayan pil modelinin seilmesiyle bařlar, ardından durumu tahmin etmek iin algoritma uygulanır. Pil modelinin durum aıklaması, belirlenmesi gereken istenen bilinmeyen miktarları iermelidir.



řekil 5.3. EKF kullanılarak SOC tahmini [83]

EKF'nin grltl giriř verilerinde bile dođru sonular verdiđi kanıtlanmıřtır; algoritma ok daha hafiftir ve gerek zamanlı uygulama iin uygulanabilir. Ancak sistem olduka dođrusal olmadıđında, dođrusallařtırma hatası birinci dereceden Taylor serisindeki belirsizlikler nedeniyle olduka kararsız filtrelere yol aabilir [84].

5.5. Kayan Mod Gzlemcisi

Pilin i durumlarını tahmin etmek iin kullanılan diđer bir model tabanlı yaklařım, kayan mod gzlemcisi (SMO) olarak bilinir. Bu algoritma, devre modelinin parametre deđiřimlerinden kaynaklanan modellenme hatalarını telafi etme avantajına sahiptir ve diđer

model tabanlı yöntemlerin sunduđu bazı dezavantajların üstesinden gelmeye yardımcı olabilir.

5.6. Bulanık Mantık

Bulanık mantık, uygun eğitim veri setini kullanarak doğrusal olmayan ve karmaşık sistemlerin modellenmesine olanak sağlayan kullanışlı bir matematiksel kavramdır. Ölçülen verileri kategorize etmek için net kümeler kullanan, monoton olmayan bir mantıktır. Bir kümenin bir üyesi ile üyelik derecesi arasındaki ilişki, üyelik fonksiyonu kullanılarak tanımlanır. SOH durumunda üyelik fonksiyonu çıktıları sağlıklı, tolere edilebilir ve sağlıklı değil olarak ayarlanabilir. [85]

5.7. En Küçük Kareler

En küçük kareler algoritması, ölçülen çıktı ile sistem yanıtı arasındaki ikinci dereceden hataların toplamını en aza indiren en iyi uyum fonksiyonunu tanımlayan, yaygın olarak kullanılan bir yaklaşımdır.

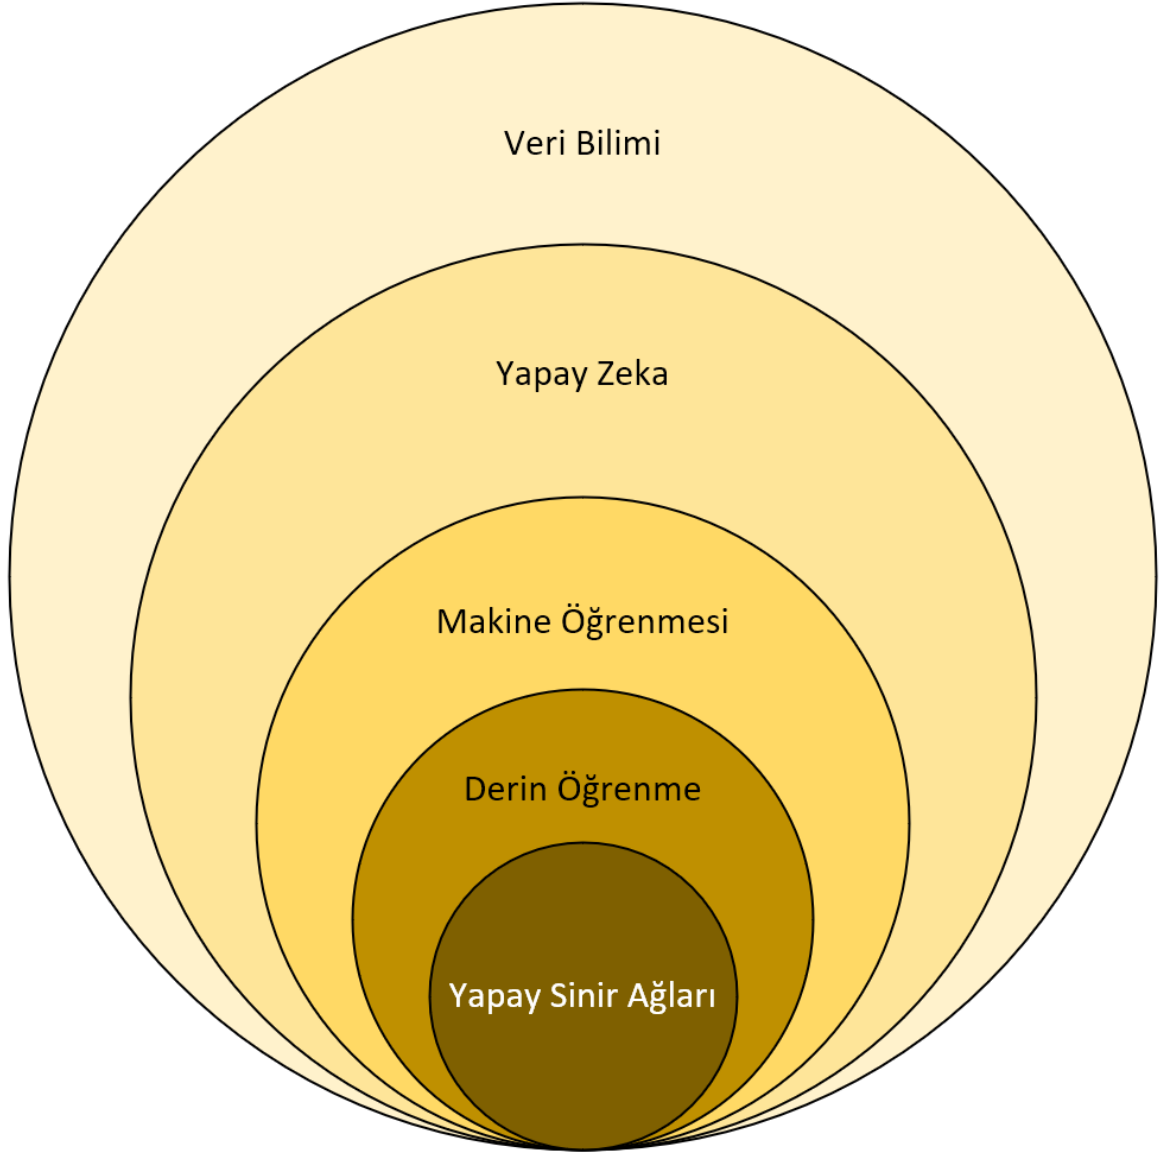
6. YAPAY ZEKA

Son on yılda yapay zekâ (AI), bilim camiasının hem içinde hem de dışında popüler bir konu haline geldi. Teknoloji ve teknoloji tabanlı olmayan dergilerdeki çok sayıda makale, makine öğrenimi (ML), derin öğrenme (DL) ve AI konularını ele almıştır. [86–91] Ancak AI, ML ve DL konusunda hâlâ kafa karışıklığı devam etmektedir. Terimler oldukça ilişkilidir, ancak birbirlerinin yerine kullanılamazlar.

1956'da bir grup bilgisayar bilimci, bilgisayarların düşünecek ve akıl yürütecek şekilde programlanabileceğini, "prensipite öğrenmenin her yönünün veya zekanın herhangi bir özelliğinin o kadar kesin bir şekilde tanımlanabileceğini ve bunu simüle edecek bir makinenin yapılabileceğini" öne sürdü. Bu prensibi "yapay zeka" olarak tanımladılar [92]. Basitçe söylemek gerekirse yapay zeka, normalde insanlar tarafından gerçekleştirilen entelektüel görevlerin otomatikleştirilmesine odaklanan bir alandır ve ML ve DL bu hedefe ulaşmanın özel yöntemleridir. Yani bunlar yapay zekanın alanı içerisinde (Şekil 6.1).

Ancak yapay zeka herhangi bir "öğrenme" biçimini içermeyen yaklaşımları içerir. Örneğin, sembolik yapay zeka olarak bilinen alt alan, belirli bir ilgi alanındaki olası her senaryo için kuralların sabit kodlanmasına (yani açıkça yazılmasına) odaklanır. İnsanlar tarafından yazılan bu kurallar, belirli bir konunun ve tamamlanması gereken görevin önsel bilgisinden gelir.

Örneğin, bir kişi bir ofisin oda sıcaklığını modüle edecek bir algoritma programlayacak olsaydı, muhtemelen insanların hangi sıcaklıklarda çalışması için rahat olduğunu zaten biliyordur. Sıcaklık belirli bir eşiğin üzerine çıkarsa odayı soğumaya ve daha düşük bir eşiğin altına düşerse ısıtmaya programlayacaktır.



Şekil 6.1. Veri bilimi tekniklerinin şemsiyesi. Yapay zeka (AI), veri bilimi alanına girer ve klasik programlama ve makine öğrenimini (ML) içerir. ML, derin öğrenme (DL) ve yapay sinir ağları (ANN) dahil olmak üzere birçok model ve yöntemi içerir

Sembolik yapay zeka, açıkça tanımlanmış mantıksal sorunları çözme konusunda uzman olmasına rağmen, konuşma tanıma veya görüntü sınıflandırma gibi daha yüksek düzeyde desen tanıma gerektiren görevlerde sıklıkla başarısız olur. Bu daha karmaşık görevler, ML ve DL yöntemlerinin iyi performans gösterdiği yerdir. Bu inceleme, kapsamlı bir teknik bilgisayar programlama geçmişi olmayan kitle için makine öğrenimi ve derin öğrenme metodolojisini özetlemektedir.

6.1. Makine Öğrenmesi

ML, bir veri kümesini en iyi temsil eden algoritmalar geliştirerek yapay zekanın öğrenme yönüne odaklanan bir alandır. Bir algoritmanın bilinen özellikler kullanılarak açık bir şekilde kodlanabildiği klasik programlamanın aksine, ML, ilk ilkelere türetilen yeni veya farklı özellik ve ağırlık kombinasyonlarını kullanabilen bir algoritma oluşturmak için veri alt kümelerini kullanır. ML'de, her biri farklı görevleri çözmek için yararlı olan, yaygın olarak kullanılan dört öğrenme yöntemi vardır: denetimli, denetimsiz, yarı denetimli ve takviyeli öğrenme [93-95].

6.2. Klasik Makine Öğrenimi Yöntemleri

6.2.1. Doğrusal Regresyon (Linear Regression)

Doğrusal regresyon tartışmasız en basit makine öğrenimi algoritmasıdır. Regresyon analizinin arkasındaki ana fikir, bir veya daha fazla sayısal özellik ile tek bir sayısal hedef arasındaki ilişkiyi belirlemektir. Doğrusal regresyon, bir veri kümesini tanımlamak için düz bir çizgi kullanarak bir regresyon problemini çözmek için kullanılan bir analiz tekniğidir. Bir hedef değeri tahmin etmek için 6.1 numaralı formül ile yalnızca tek bir özelliğin kullanıldığı bir regresyon problemi olan tek değişkenli doğrusal regresyon, eğim-kesme noktası formunda temsil edilebilir:

$$y = ax + b \quad (6.1)$$

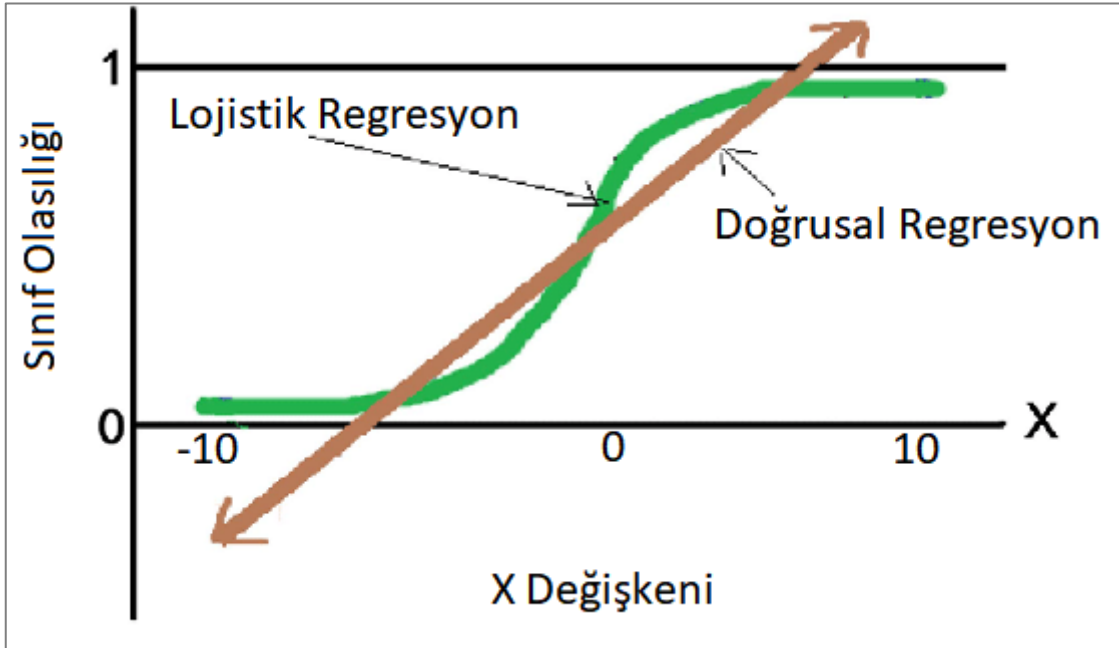
Burada a, x'teki her artış için bir çizginin y ekseninde ne kadar arttığını açıklayan eğimi tanımlayan bir ağırlıktır. Kesişme noktası b, doğrunun y eksenini kestiği noktayı tanımlar. Doğrusal regresyon, bu eğim-kesme noktası formunu kullanarak bir veri kümesini modeller; burada makinenin görevi, belirlenen çizginin sağlayan x değerleri değerlerini y değerleriyle en iyi şekilde ilişkilendirilmesini sağlayacak şekilde a ve b değerlerini tanımlamaktır. Çok değişkenli doğrusal regresyon da benzerdir. Bununla birlikte, algoritmada her biri, her bir özelliğin hedefi ne derecede etkilediğini açıklayan birden fazla ağırlık vardır [93, 94].

6.2.2. Lojistik Regresyon (Logistic Regression)

Lojistik regresyon, amacın özellikler ile belirli bir sonucun olasılığı arasındaki ilişkiyi bulmak olduğu bir sınıflandırma algoritmasıdır. Lojistik regresyon, sınıf olasılığını tahmin etmek için doğrusal regresyon tarafından üretilen düz çizgiyi kullanmak yerine, sınıf olasılığını tahmin etmek için sigmoidal bir eğri kullanır (Şekil 6.2). Bu eğri, ayrık veya sürekli sayısal özellikleri (x) 0 ile 1 arasında tek bir sayısal değere (y) dönüştüren S şeklinde bir eğri üreten 6.2 numaralı sigmoid fonksiyonu tarafından belirlenir.

$$y = \frac{1}{1 + e^{-x}} \quad (6.2)$$

Bu yöntemin en büyük avantajı olasılıkların 0 ile 1 arasında sınırlı olmasıdır. Yani olasılıklar negatif olamaz veya 1'den büyük olamaz. Yalnızca iki olası sonucun olduğu binom veya üç veya daha fazla olası sonucun olduğu multinom olabilir [93, 94].



Şekil 6.2. Doğrusal ve lojistik regresyon kullanılarak örnek sınıf olasılık tahmini [96]

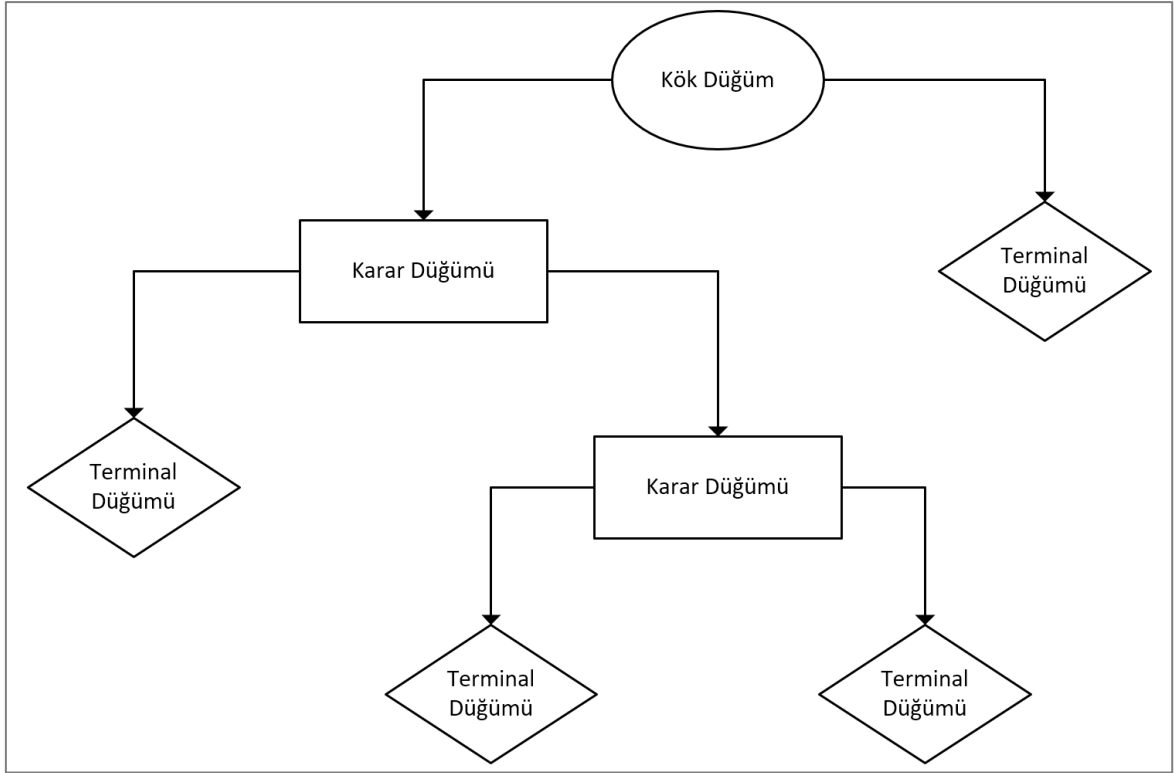
-10 ila 10 arasında değişen tek bir değişken olan X değişkenini kullanarak çeşitli örneklerin (gri daireler) belirli bir sınıfa ait olma olasılığını tahmin etmeye yönelik doğrusal (kahverengi çizgi) ve lojistik (yeşil çizgi) regresyon modelleri sunulmaktadır. Lojistik regresyonda X değişkeni, sigmoid fonksiyonu kullanılarak 0 ile 1 arasında sınırlanan sınıf

olasılıklarına dönüştürülür. Basit doğrusal regresyon, sınıf olasılıklarını tahmin etmeye çalışır, ancak 0 ile 1 arasında sınırlı değildir; dolayısıyla negatif olasılıklara veya 1'den büyük olasılıklara izin vermeyen temel bir olasılık yasasını ihlal eder.

6.2.3. Karar Ağaçları ve Rastgele Ormanlar (Decision Trees ve Random Forests)

Karar ağacı, öncelikle sınıflandırma görevleri için kullanılan, denetimli bir öğrenme tekniğidir ancak aynı zamanda regresyon için de kullanılabilir. Bir karar ağacı, veri setini bölmek için ilk karar noktası olan bir kök düğümle başlar ve verileri ilgili sınıflara en iyi şekilde bölen tek bir özelliği içerir (Şekil 6.3) [93, 94].

Her bölünmenin, verileri homojen gruplara daha fazla bölmek için başka bir özellik içeren yeni bir karar düğümüne veya sınıfı tahmin eden bir terminal düğümüne bağlanan bir kenarı vardır. Verileri iki ikili bölüme ayırmanın bu işlemi, özyinelemeli bölümlenme olarak bilinir. Rastgele orman, topluluk yöntemi olarak bilinen ve birden fazla karar ağacı üreten bu yöntemin bir uzantısıdır. Rastgele bir ormandaki her karar ağacını oluşturmak için her özelliği kullanmak yerine, her karar ağacını oluşturmak için özelliklerin bir alt örneği kullanılır. Ağaçlar daha sonra bir sınıf sonucunu tahmin eder ve ağaçlar arasındaki çoğunluk oyu modelin son sınıf tahmini olarak kullanılır [93, 94].



Veri kümesinin bölünmesi kök düğümde başlar. Her bölünme, verinin daha fazla bölünmesiyle sonuçlanan başka bir karar düğümüne veya veri sınıfını tahmin eden bir terminal düğümüne bağlanır.

Şekil 6.3. Karar ağacının yapısı

6.3. Sinir Ağları ve Derin Öğrenme

Yapay sinir ağı (YSA), biyolojik sinir ağlarından ilham alan bir makine öğrenme algoritmasıdır. Her YSA, diğer düğümlerle bağlantılar aracılığıyla iletişim kuran düğümler içerir. Nöronlar biyolojik bir sinir ağında ilişkili çıktılara sahip olduğunda, nöronlar arasındaki sinapslar büyük ölçüde güçlenir. Bir YSA'daki düğümler arasındaki bağlantılar, istenen sonucu sağlama yeteneklerine göre ağırlıklandırılır [93, 94, 97].

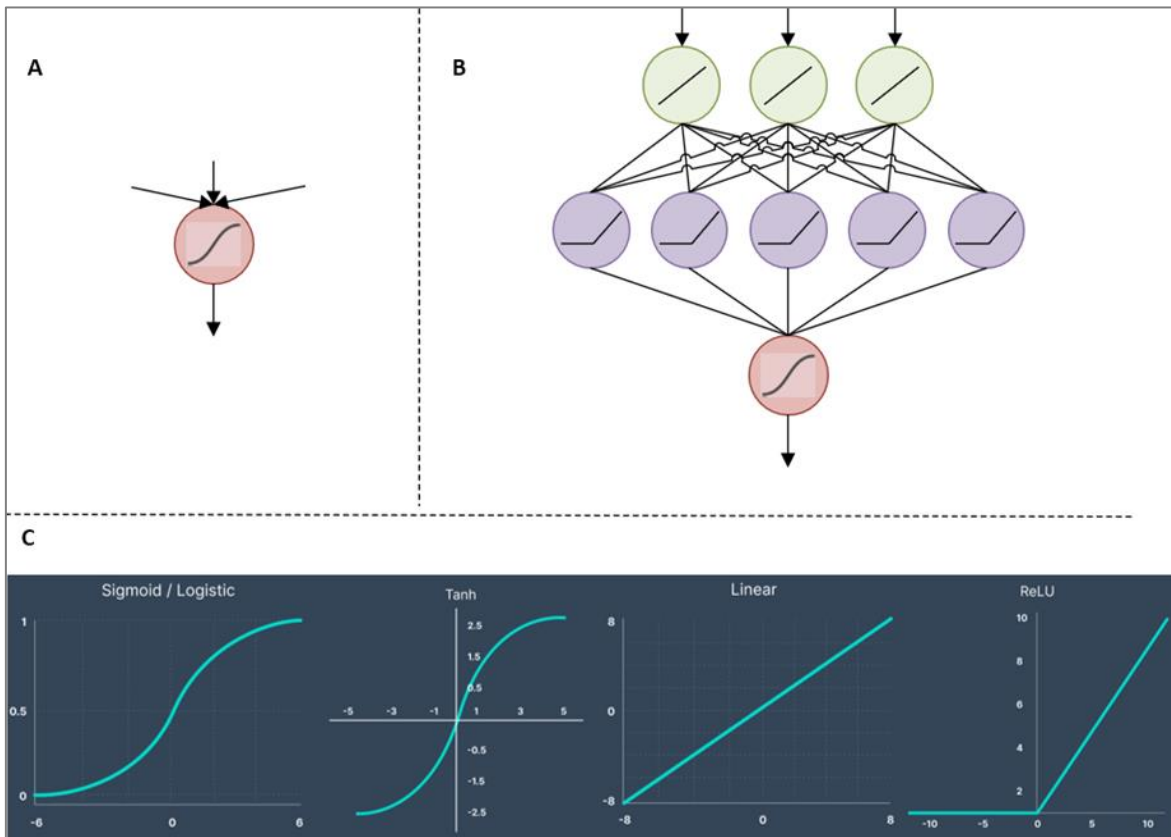
6.3.1. İleri Beslemeli Sinir Ağları (Feedforward Neural Networks)

Perceptron, bir dizi özelliği ve bunların hedeflerini girdi olarak alan ve sınıfları sırasıyla iki, üç veya hiper boyutlu uzayda ayıran bir çizgi, düzlem veya hiperdüzlem bulmaya çalışan bir makine öğrenme algoritmasıdır [94, 98, 99].

Bu özellikler sigmoid fonksiyonu kullanılarak dönüştürülür (Şekil 6.4.A). Dolayısıyla bu yöntem lojistik regresyona benzemektedir ancak bir örneğin bir sınıfa ait olma olasılığını

değil, yalnızca sınıf ilişkilerini sağlayabilir. Birden fazla perceptron bağlandığında modele çok katmanlı algılayıcı algoritması (Multilayer Perceptron) veya YSA (ANN) adı verilir. Genellikle YSA'lar bir girdi düğümleri katmanı, bir çıktı düğümleri katmanı ve ikisi arasında bir dizi "gizli katman" (hidden layer)' dan oluşur [94].

Basit YSA'larda sıfır ila üç gizli katman bulunurken derin sinir ağlarında onlarca, hatta yüzlerce gizli katman bulunur [94, 100]. Çoğu görev için YSA'lar bilgiyi ileriye doğru besler. Bu, ileri beslemeli sinir ağı olarak bilinir; bu, önceki katmandaki her düğümden gelen bilginin bir sonraki katmandaki her düğüme iletiildiği, dönüştürüldüğü ve sonraki katmandaki her düğüme iletiildiği anlamına gelir (Şekil 6.4.B) [94]. Tekrarlayan sinir ağlarında (RNN), bilgi bir katman içindeki düğümler arasında veya çıktıların çalıştırıldığı ve bir kez daha ileriye doğru beslendiği önceki katmanlara aktarılabilir [98].



Şekil 6.4. Bir sinir ağının bileşenleri [101]

Yukarıdaki şekilde gösterildiği üzere:

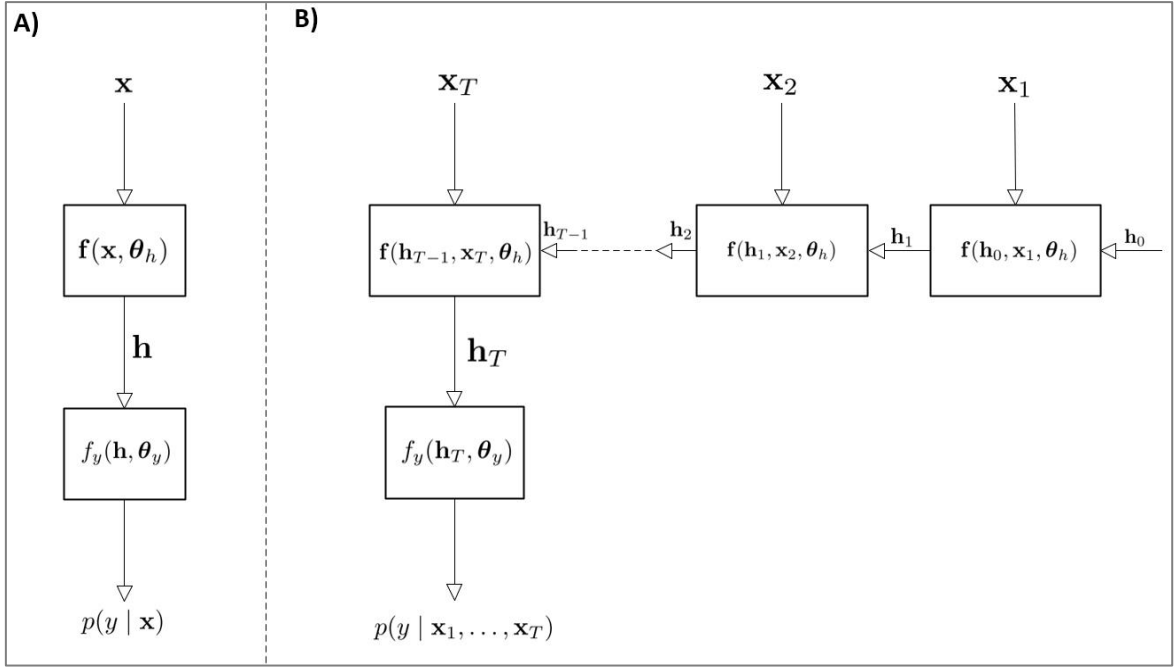
(A) Yapay sinir ağının temeli, algılayıcı (perceptron). Bu algoritma, birden fazla girişi ölçeklendirmek ve 0'dan 1'e kadar tek bir çıkışa dönüştürmek için sigmoid fonksiyonunu kullanır.

(B) Bir yapay sinir ağı birden fazla algılayıcı birimini birbirine bağlar, böylece bir birimin çıktısı diğerine girdi olarak kullanılır. Ayrıca bu birimler sigmoid aktivasyon fonksiyonunu kullanmakla sınırlı değildir.

(C) Dört farklı aktivasyon fonksiyonunun örnekleri: sigmoid, tanjant, doğrusal ve düzeltilmiş doğrusal birim (ReLU). Sigmoid, S şeklinde bir eğri kullanarak girdileri 0 ile 1 arasında ölçeklendirir. Benzer şekilde, tanjant işlevi S şeklinde bir eğri kullanır, ancak farklı olarak eksi bölgeyi de kapsayarak ölçeklendirir. Doğrusal fonksiyon, doğrusal bir çıktı üretmek için girdisini herhangi bir sayıyla çarpabilir. Düzeltilmiş doğrusal birim doğrusal fonksiyona benzer, ancak < 0 olan tüm girişlere 0 çıkış değeri verilir. Bunların dışında başka aktivasyon fonksiyonları da vardır.

6.3.2. Tekrarlayan Sinir Ağları (Recurrent Neural Networks)

Tekrarlayan sinir ağları (RNN'ler), zaman serisi verilerini ve diğer sıralı verileri işlemeye doğal olarak uygun olan bir sinir ağları sınıfıdır. İleri beslemeli sinir ağlarından tekrarlayan sinir ağlarına geçiş kavramsal olarak basittir. İleri beslemeli ağlar geleneksel olarak sabit boyutlu girişlerden sabit boyutlu çıkışlara eşlenir. Örneğin, sabit uzaysal genişliğe sahip bir görüntüden kendi sınıfına veya aynı uzaysal genişliğe sahip bir segmentasyon haritasına eşleme yapmak için kullanılır. Buna karşılık, tekrarlayan sinir ağları doğal olarak değişken uzunluklu giriş dizileri üzerinde çalışır ve örneğin bir görüntüden o görüntüyü tanımlayan çeşitli cümlelere eşleme yapmak için değişken uzunluktaki çıktı dizileriyle eşleşir. Bu yetenek, zaman içinde parametrelerin ve dönüşümlerin paylaşılmasıyla elde edilir. Şekil 6.5'te ileri beslemeli sinir ağından (A) tekrarlayan sinir ağına (B) geçişte neler değiştiği gösterilmektedir.




Şekil 6.5. Örnek bir ileri beslemeli ağ (solda) ve örnek bir tekrarlayan sinir ağı (sağda). Tekrarlanan örnekte, f fonksiyonu ve onun parametreleri θ_h zaman içinde paylaşılmaktadır [102]

Temel Tekrarlayan Sinir Ağı (RNN), dizi verileri için tasarlanmışlardır. Geleneksel ileri beslemeli sinir ağlarının aksine, RNN'ler, sıradaki önceki girişler hakkındaki bilgileri yakalayan gizli bir durumu korumalarına olanak tanıyan, yönlendirilmiş döngüler oluşturan bağlantılara sahiptirler. Bu, RNN'leri sıralı veya zaman serisi verilerini içeren görevler için çok uygun hale getirir ki bizim çalışmamızda zaman serisi verileri içerir ancak RNN'ler kaybolan gradyan sorunundan muzdariptirler.

Temel bir RNN'nin mimarisi aşağıdaki bileşenlerden oluşur [103]:

1. Giriş Katmanı: Giriş katmanı, dizideki her zaman adımı için giriş özelliklerini temsil eder.
2. Tekrarlayan Bağlantı: Bir RNN'nin temel özelliği, bilginin farklı zaman adımlarında kalıcı olmasını sağlayan tekrarlayan bağlantıdır. Her zaman adımında, bir önceki zaman adımındaki gizli durum, çıktıyı üretmek ve gizli durumu güncellemek için mevcut girişle birlikte kullanılır.
3. Gizli Durum: Gizli durum, dizideki önceki girişler hakkındaki bilgileri yakalar. Geçerli girişe ve önceki gizli duruma göre her zaman adımında güncellenir.

4. Çıktı Katmanı: Çıktı katmanı, mevcut girişe ve gizli duruma bağlı olarak mevcut zaman adımı için çıkış üretir.



Şekil 6.6. Çıktı katmanı [104]

Şekil 6.6'da görüldüğü üzere, RNN'in tam bir ağa açılmış halini göstermektedir. Açılma derken, ağıın aynı katman yapısını tüm dizi boyunca tekrarladığı kastedilmektedir.

X_t , t zaman adımıdaki girdidir. X_t herhangi bir N boyutunda bir vektördür.

A, t zaman adımıdaki gizli durumdur. Bu, ağıın “hafızasıdır”. Önceki gizli duruma ve mevcut adımdaki girişe göre hesaplanır. Aşağıdaki formül ile temsil edilir:

$$A_t = f(W X_t + U A_{t-1}) \quad (6.3)$$


Burada W ve U, giriş ve önceki durum değeri girişi için ağırlıklardır. Ve f, nihai hücre durumunu oluşturmak için toplama uygulanan doğrusal olmama durumudur [104].

Temel RNN'ler sıralı verilerdeki kısa vadeli bağımlılıkları yakalamada etkili olsa da, uzun vadeli bağımlılıkları yakalamalarını zorlaştıran yok olan gradyan probleminden muzdariptirler. Bu sorunu çözmek için Uzun Kısa Süreli Bellek (LSTM) ve Geçitli Tekrarlayan Birim (GRU) gibi daha gelişmiş mimariler geliştirilmiştir [103].

6.3.3. Kaybolan Gradyan Sorunu (Vanishing Gradient Problem)

Sigmoid fonksiyonu gibi belirli aktivasyon fonksiyonları, büyük bir giriş alanını 0 ile 1 arasındaki küçük bir giriş alanına sıkıştırır. Bu nedenle, sigmoid fonksiyonunun girişindeki

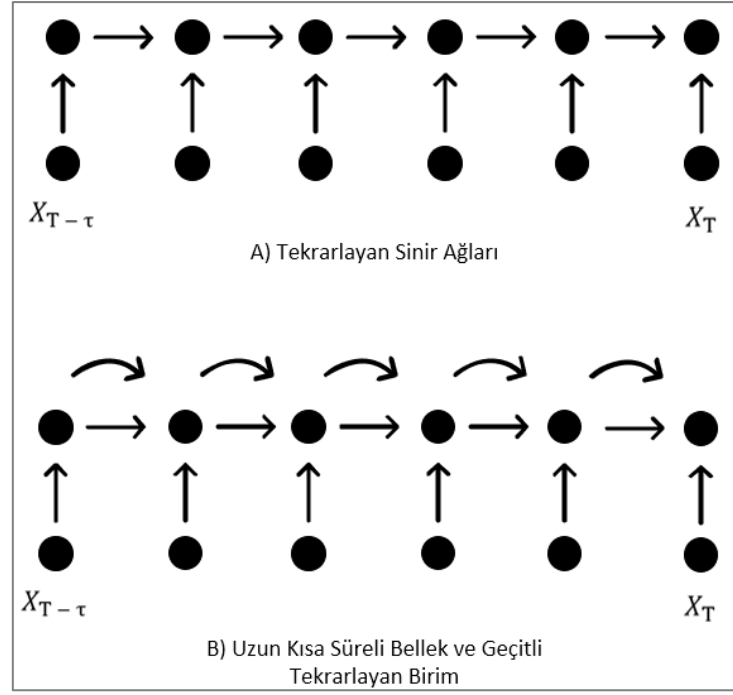
büyük bir deęişiklik, çıkışta küçük bir deęişikliğe neden olur. Dolayısıyla türev küçük olur. Sınır aęlarına belirli aktivasyon fonksiyonlarını kullanan daha fazla katman eklendikçe, kayıp fonksiyonunun eğimleri sifıra yaklaşarak aęın eğitimini zorlaştırır.



Şekil 6.7. Sigmoid fonksiyonu ve türevi [105]

6.3.4. Uzun Kısa Süreli Bellek ve Geçitli Tekrarlayan Birimler (Long Short-Term Memory ve Gated Recurrent Units)

Uzun kısa süreli bellek (LSTM), kaybolan gradyan sorununu hafifletmek için tanıtılmıştır [106] ve bugüne kadarki en popüler RNN mimarilerinden biri haline gelmiştir. Geçitli tekrarlayan birimler (GRU'lar) [107] daha sonra LSTM'ye daha basit bir alternatif olarak tanıtılmış ve o da oldukça popüler hale gelmiştir. Basit RNN'ler ile LSTM/GRU'lar arasındaki temel farkın sezgisel bir görünümü Şekil 6.7'de gösterilmektedir.



Şekil 6.8. RNN, LSTM ve GRU'lar için yolların çizimi [108]

- A) Şekil 6.8'de A şikkında RNN'ler, T ve T - τ zamanları arasında tam olarak bir yol sağlar ve her adım doğrusal dönüşümler ve doğrusal olmama durumları tarafından engellenir.
- B) Şekil 6.8'de B şikkında LSTM ve GRU'lar, T ve T - τ zamanları arasında üstel olarak birçok yol verir; bir yol ne doğrusal dönüşümler ne de doğrusal olmayan durumlar tarafından engellenir.

Literatürde LSTM ve GRU'nun birçok farklı çeşidi mevcuttur fakat performans olarak hepsi birbirlerine yakınlardır. LSTM'nin en yaygın çeşidi aşağıdaki 6.4-6.9 formülleri ile tanımlanır:

$$f_t = \sigma(W_{fh}h_{t-1} + W_{fx}x_t + b_f), \quad (6.4)$$

$$i_t = \sigma(W_{ih}h_{t-1} + W_{ix}x_t + b_i), \quad (6.5)$$

$$o_t = \sigma(W_{oh}h_{t-1} + W_{ox}x_t + b_o), \quad (6.6)$$

$$\check{c}_t = \tanh(W_{ch}h_{t-1} + W_{cx}x_t + b_c), \quad (6.7)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \check{c}_t, \quad (6.8)$$

$$h_t = o_t \odot \tanh(c_t). \quad (6.9)$$

Yüksek seviyede, LSTM genellikle unutmama kapısı f_t , giriş kapısı i_t ve çıkış kapısı o_t 'a göre sıfırlanan, yazılan ve buradan okunan bir bellek hücresinin (c_t) bakımı olarak yorumlanır. Bunların hepsi zamanla değişir.

Bu farklı kapılara yönelik güncellemeler arasında açık bir benzerlik vardır. Yalnızca farklı ağırlık matrislerine ve eğilimlere sahip olmaları bakımından farklılık gösterirler. Özellikle, üç kapının tümü basit RNN'lere çok benzer, ancak temel fark, tanh aktivasyon fonksiyonundan ziyade sigmoid aktivasyon fonksiyonudur (sigmoid fonksiyonu çıkışları 0 ile 1 arasında olacak şekilde sınırlandırır). Dolayısıyla bu kapılarda, bilgi akışını kapatan tamamen kapalı (0), ve bilgi akışına izin veren tam açık (1) arasında öğeler bulunur.

Daha sonra hafıza hücremiz olan \check{c}_t 'ye aday güncellenmenin oluşumunu görüyoruz. Bu dönüşümün basit bir RNN'nin dönüşümüyle aynı olduğu görülebilir. Sonra c_t formülünde önceki c_{t-1} hücresinin elemanları, unutmama kapısı f_t ve giriş kapısına göre aday güncelleme \check{c}_t ile birleştirilir. Ve son olarak, bellek hücresine son bir aktivasyon fonksiyonu uygulanarak elemanların çıkış kapısına göre ağırlıklandırılmasıyla yeni gizli durum h_t oluşturulur.

Yakın zamanda önerilen GRU mimarisi LSTM'den ilham alan bir mimaridir ve LSTM'in temel faydalarını korurken mimariyi basitleştirmeyi hedefler [107]. GRU'lar LSTM'den daha basittir çünkü bir kapı daha az kullanılır ve gizli durumlar ile bellek hücreleri arasında ayırım yapma ihtiyacını ortadan kaldırır. En yaygın varyant 6.10 - 6.13 formülleri şeklinde tanımlanır:

$$u_t = \sigma(W_{uh}h_{t-1} + W_{ux}x_t + b_u), \quad (6.10)$$

$$r_t = \sigma(W_{rh}h_{t-1} + W_{rx}x_t + b_r), \quad (6.11)$$

$$\hat{h}_t = \tanh(W_{hh}(r_t \odot h_{t-1}) + W_{hx}x_t + b_h), \quad (6.12)$$

$$h_t = u_t \odot h_{t-1} + (1 - u_t) \odot \hat{h}_t. \quad (6.13)$$

GRU ve LSTM çok benzer bir mekanizma kullanarak kaybolan gradyan sorununu hafifletir. h_t formülünden görüleceği üzere eğer $u_{t,i}$ 1'e yakınsa, buna karşılık gelen kısmı 6.14 numaralı formülün de 1'e yakın olduğunu görebiliriz.

$$\frac{\partial h_{t,i}}{\partial h_{t-1,i}} \quad (6.14)$$

r_t ve u_t sırasıyla sıfırlama ve güncelleme kapıları olarak anılır.

6.4. GRU ve LSTM Karşılaştırması

LSTM ve GRU, metin, konuşma veya video gibi sıralı verileri işleyebilen iki tür tekrarlayan sinir ağıdır (RNN). Standart RNN'lerin eğitimini etkileyen eğimlerin kaybolması (vanishing) veya patlaması (exploiting) sorununun üstesinden gelmek için tasarlanmışlardır. Ancak farklı mimarilere ve performans özelliklerine sahip olmaları farklı uygulamalara uygun olmalarını sağlar [109].

6.4.1. LSTM

LSTM bilgileri uzun zaman adımlarında saklayabilen ve güncelleyebilen bir dizi hafıza hücresinden oluşur. Her bellek hücresinin üç kapısı vardır: bir giriş kapısı, bir çıkış kapısı ve bir unutma kapısı. Giriş kapısı hücre durumuna hangi bilginin ekleneceğine, çıkış kapısı hücre durumundan hangi bilginin çıkarılacağına ve unutma kapısı hücre durumundan hangi bilginin atılacağına karar verir. Kapılar, girişe ve önceki gizli duruma bağlı olarak ağ tarafından öğrenilir.

6.4.2. GRU

GRU, geçitli tekrarlayan ünite anlamına gelir ve LSTM'e göre daha az karmaşık yapıdadır. Yalnızca iki kapısı vardır: sıfırlama kapısı ve güncelleme kapısı. Sıfırlama kapısı, önceki gizli durumun ne kadarının tutulacağına karar verir ve güncelleme kapısı, yeni girişin ne kadarının gizli duruma dahil edileceğine karar verir. Gizli durum aynı zamanda hücre

durumu ve çıkış görevi de görür, dolayısıyla ayrı bir çıkış kapısı yoktur. GRU'nun uygulanması daha kolaydır ve LSTM'den daha az parametre gerektirir.

6.4.3. Performans Kıyaslaması

LSTM ve GRU'nun performansı göreve, verilere ve hiper parametrelere bağlıdır. Genel olarak LSTM, GRU'dan daha güçlü ve esnektir ancak aynı zamanda daha karmaşıktır ve aşırı uyum sağlamaya (overfitting) eğilimlidir. GRU, LSTM'den daha hızlı ve daha verimlidir ancak uzun vadeli bağımlılıkları LSTM kadar yakalayamayabilir.

6.4.4. Benzerlikleri

Farklılıklarına rağmen LSTM ve GRU, her ikisini de etkili RNN varyantları yapan bazı ortak özellikleri paylaşıyor. Her ikisi de bilgi akışını kontrol etmek ve yok olan (vanishing) veya patlayan (exploding) gradyan problemini önlemek için kapıları kullanıyor. Her ikisi de uzun vadeli bağımlılıkları öğrenebilir ve verilerdeki sıralı kalıpları yakalayabilir. Ağın derinliğini ve karmaşıklığını artırmak için her ikisi de birden fazla katman halinde istiflenebilir. Performanslarını artırmak için her ikisi de evrişimli sinir ağları (CNN'ler) veya dikkat mekanizmaları gibi diğer sinir ağı mimarileriyle birleştirilebilir.

6.4.5. Farklılıkları

LSTM ve GRU arasındaki temel farklar mimarilerinde yatmaktadır. LSTM, GRU'dan daha fazla kapıya ve daha fazla parametreye sahiptir; bu da ona daha fazla esneklik ve ifade gücü kazandırır, ancak aynı zamanda daha fazla hesaplama maliyeti ve aşırı uyum riski de sağlar. GRU'nun LSTM'ye göre daha az kapısı ve daha az parametresi vardır, bu da onu daha basit ve hızlı kılar, ancak aynı zamanda daha az güçlü ve uyarlanabilir kılar.

LSTM, farklı bilgileri depolamasına ve çıktısını almasına olanak tanıyan ayrı bir hücre durumuna ve çıkışına sahipken GRU, her iki amaca da hizmet eden ve kapasitesini sınırlayabilen tek bir gizli duruma sahiptir. LSTM ve GRU ayrıca öğrenme hızı, bırakma oranı veya dizi uzunluğu gibi hiper parametrelere karşı farklı hassasiyetlere sahip olabilir.

7. MATERYAL VE METOT

7.1. Nasa'nın Lityum İyon Batarya Verisi

Bu çalışma NASA Prognostics Center of Excellence Veri Havuzu tarafından sağlanan batarya veri setlerini kullanmaktadır [110]. Bu veri setleri, oda sıcaklığında (#5, #6, #7 ve #18), soğukta (#46 ve #47) ve sıcakta (#29 ve #30) olacak şekilde 3 farklı günlük hayat ortamını simüle eden ve şarj, deşarj ve dinlenme süresi olmak üzere üç farklı çalışma profilinde çalışan sekiz lityum iyon bataryadan oluşur. Deneyler, hızlandırılmış yaşlanmayı sağlamak için ticari olarak temin edilebilen 18650 lityum iyon hücrelerine tekrarlanan şarj ve deşarj döngülerinin uygulanmasıyla oluşturulmuştur.

Bataryalar sabit akım sabit voltaj (CCCV) prensibine göre şarj edilir ve bu prensibe göre bataryalar öncelikle 4.2 V üst voltaj sınırına ulaşana kadar 1,5 A sabit akımda şarj edilmektedir. Ardından 4.2V sabit voltaj'da akım 20 mA altına düşene kadar şarj devam eder. Deşarj işlemi ise hücre voltajı #5, #6, #7 ve #18 bataryaları için sırasıyla 2.7 V, 2.5 V, 2.2 V ve 2.5 V'a düşene kadar 2 A'lik sabit akımda; #29 ve #30 bataryaları için sırasıyla 2.0 V ve 2.2 V'a düşene kadar 4 A'lik sabit akımda; #46 ve #47 bataryaları için sırasıyla 2.2 V ve 2.5 V'a düşene kadar 1 A'lik sabit akımda yapılır. Deneyler, bataryalar nominal kapasitenin %20'sini kaybedene kadar, yani 1,6 Ah kapasiteleri kalana kadar gerçekleştirilir. Bataryaların genel özellikleri ve şarj/deşarj koşulları Tablo 7.1'de özetlenmiştir.

Bu kapasite düşüşünden sonra bataryalar otomotiv sektöründe kullanılamazlar ve ikincil hayat olarak adlandırılan yerel enerji depolama uygulamalarında; yani güneş paneli, rüzgâr tribünü ve bunun gibi yerlerde kullanılabilirler. Bu veri setinde ek elektrokimyasal empedans verileri de sağlanmaktadır ancak bizim çalışmamızda kullanılmamaktadır. Şekil 8.3-8.5'de bataryaların döngü sayılarına bağlı olarak kapasite düşüşleri gösterilmektedir.

Tablo 7.1. NASA Prognostics Center of Excellence veri havuzunun bataryalarının özellikleri

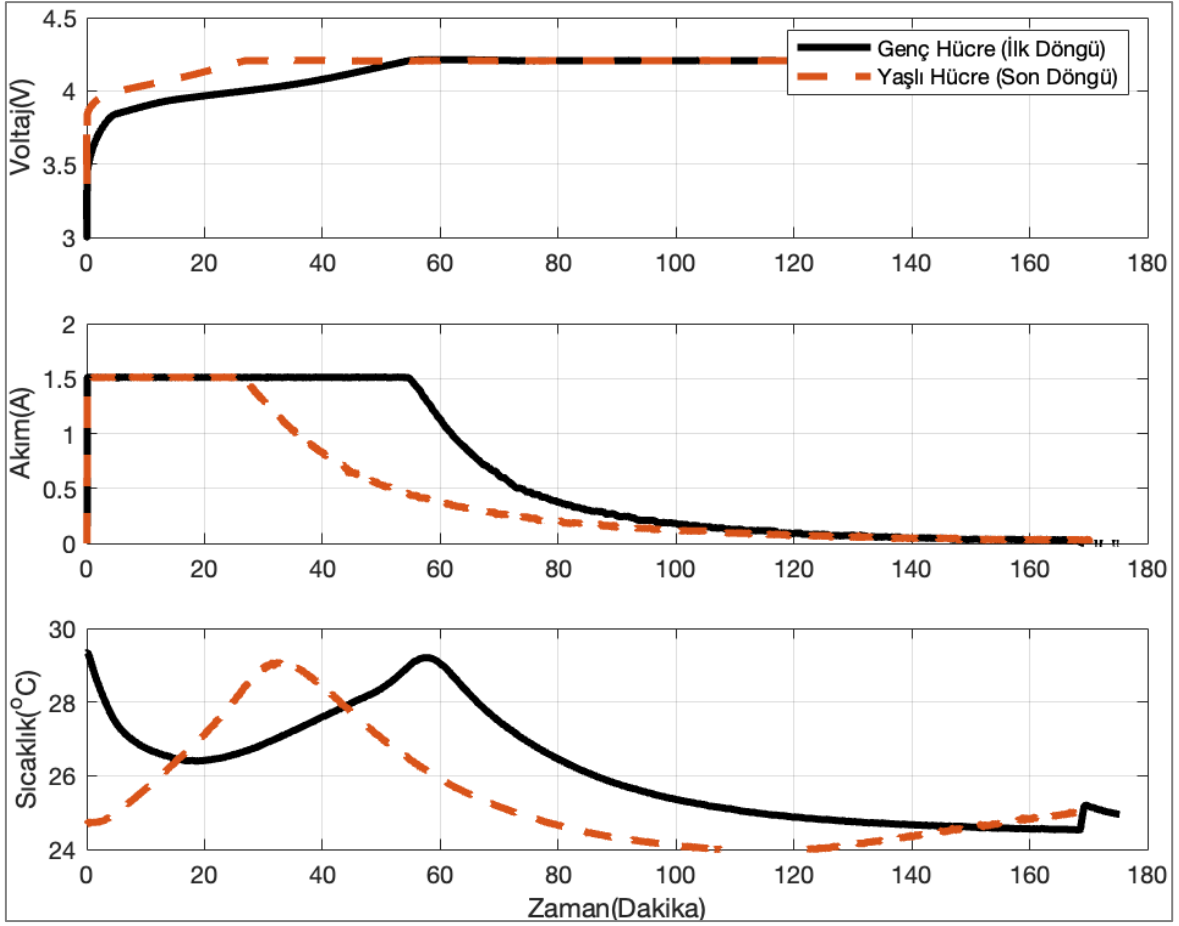
Batarya Numarası	Şarj			Deşarj		Ortam Koşulları	
	Sabit Akım (A)	Üst Voltaj Limit (V)	Şarj Kesme Akımı (mA)	Sabit Akım (A)	Deşarj Kesme Voltajı (V)	Ortam Sıcaklığı (°C)	Başlangıç Kapasiteleri (Ah)
Batarya 5	1.5	4.2	20	2	2.7	24	1.86
Batarya 6	1.5	4.2	20	2	2.5	24	2.04
Batarya 7	1.5	4.2	20	2	2.2	24	1.89
Batarya 18	1.5	4.2	20	2	2.5	24	1.86
Batarya 29	1.5	4.2	20	4	2.0	43	1.70
Batarya 30	1.5	4.2	20	4	2.2	43	1.66
Batarya 46	1.5	4.2	20	1	2.2	4	1.73
Batarya 47	1.5	4.2	20	1	2.5	4	1.67

7.2. Şarj/Deşarj Sürecinde Veri Toplama

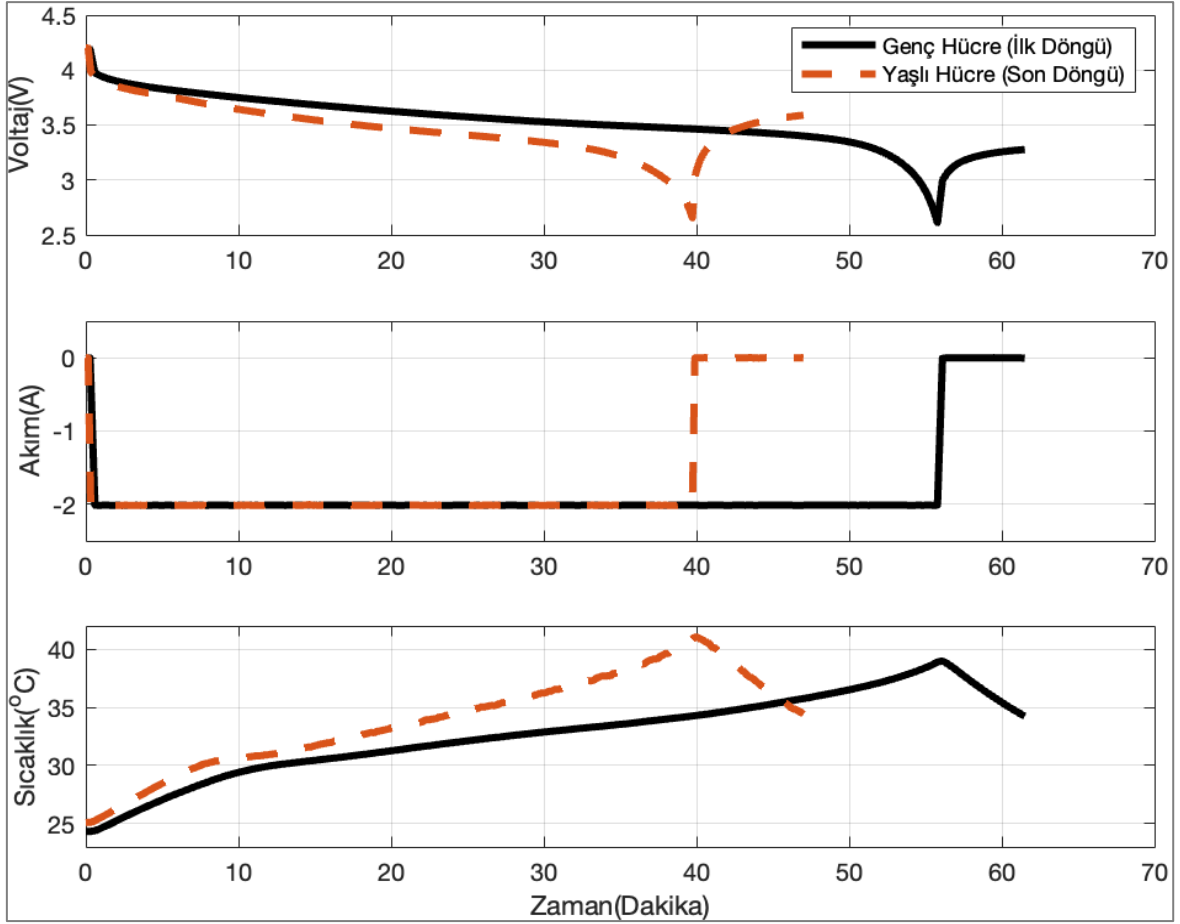
Bataryanın bozulmasını tahmin etmede kritik olan dahili batarya parametrelerinin yaşlanma boyunca nasıl değiştiğini yakalamak için voltaj, akım ve sıcaklık verilerinden yararlanılmaktadır. Bu verilerin her biri her şarj döngüsünde tekrar ölçülür. Gerçek uygulamada bataryanın üç durumu vardır: bunlar şarj, deşarj ve dinlenmedir.

Elektrikli araçlarda deşarj işlemi sırasında, akım zaman içerisinde hızla ve düzensiz olarak değişmesi nedeniyle iç parametrelerin hassas bir şekilde ölçülmesi veya hesaplanması zordur. Yapılan son araştırmalara göre [111, 112] bataryanın dinlenme periyodunda akımın geçişine bağlı olarak aktif malzemelerin yeniden dengelenmesi ve gradyanlarının gevşemesi süreci mevcuttur. Bu süreç sayesinde kapasite yenilenmesi gerçekleşir. Bu nedenle bataryanın dahili parametreleri genellikle sabittir veya şarj veya deşarj süresine göre yavaş değişir. Bu durum, iç parametrelerin tahminini zorlaştırmaktadır çünkü bu parametreler, belirsiz veri miktarına dayalı olarak hesaplanamamaktadır [113]. Ancak bataryalar genellikle gerekli harici elektrik performansının kolayca ölçülebildiği önceden belirlenmiş protokollere dayalı, sorunsuz bir şarj sürecine sahiptir.

Ayrıca, deşarj düzeni esas olarak sahibinin rutinine bağlıdır ki bu da yüksek rastgelelik ve belirsizlik içerir. Bu sebeple batarya şarj profillerini kullanmak çok daha kolaydır. İncelemekte olduğumuz NASA veri setinde deşarj rutini rastgelelik içermeyecek sabit deşarj akımı ile yapılmış olduğundan yaptığımız çalışmada deşarj grafiğini de göz önüne serdik.



Şekil 7.1. Yaşlı ve genç batarya hücresi voltaj, akım ve sıcaklık şarj grafikleri



Şekil 7.2. Yaşlı ve genç batarya hücresi voltaj, akım ve sıcaklık deşarj grafikleri

7.3. Voltaj, Akım ve Sıcaklık Verileri ile Şarj Profilleri

Şekil 7.1-7.2’de, batarya yaşlandıkça voltaj, akım ve sıcaklığın hem şarj hem deşarj profillerinde önemli değişiklikler yarattığını gözlemliyoruz. Şarj işlemi sırasında yaşanan hücrenin voltajı, yeni hücreye göre 4,2 V'a daha erken ulaşır ve yaşlanan hücrenin akımı, yeni hücreye göre daha erken sabit akımdan düşmeye başlar. Bunlara ek olarak, yaşlanan hücre maksimum sıcaklığa genç hücreden çok daha erken ulaşır. İlk ve son döngünün sıcaklık profillerinin başlangıçlarının farklı olmasının nedeni, tekrarlanan şarj, dinlenme ve deşarj işlemlerinden kaynaklanmaktadır.

Deşarjın sonundaki sıcaklık genellikle başlangıca göre arttığından, bu durum bir sonraki şarj profilinin başlangıç sıcaklığını etkiler. Deşarj grafiklerine bakıldığında da şarj grafiklerine çok benzer bir yapı gözlenmektedir. Hem sıcaklık hem voltaj hem de akım değerleri limit değerlere genç hücreye kıyasla yaşlanmış hücre de daha erken ulaşmaktadır.

Bataryanın yařlanmasını ölçmek için SoH'yi doğru řekilde tanımlamamız gerekir. SoH'yi tanımlamanın kabul edilmiş sabit bir yolu olmamasına rağmen, genellikle 7.1 numaralı formülde görüldüğü řekilde verilen kapasite kullanılarak tanımlanır:

$$SOH(\%) = \frac{C_k}{C_0} \times 100 \quad (7.1)$$

Burada C_0 nominal kapasitedir ve C_k k döngüsündeki ölçülen kapasitedir. Ayrıca, ölçülen kapasite nominal kapasitenin %80'inin altında olduđunda batarya ömrünün bittiđini ve bu durumda güvenilir performansın garanti edilemeyeceđini belirleriz. Bu durum otomotiv sektöründe EV garantisi belirlenirken kullanılır.

8. MODEL SEÇİMİ

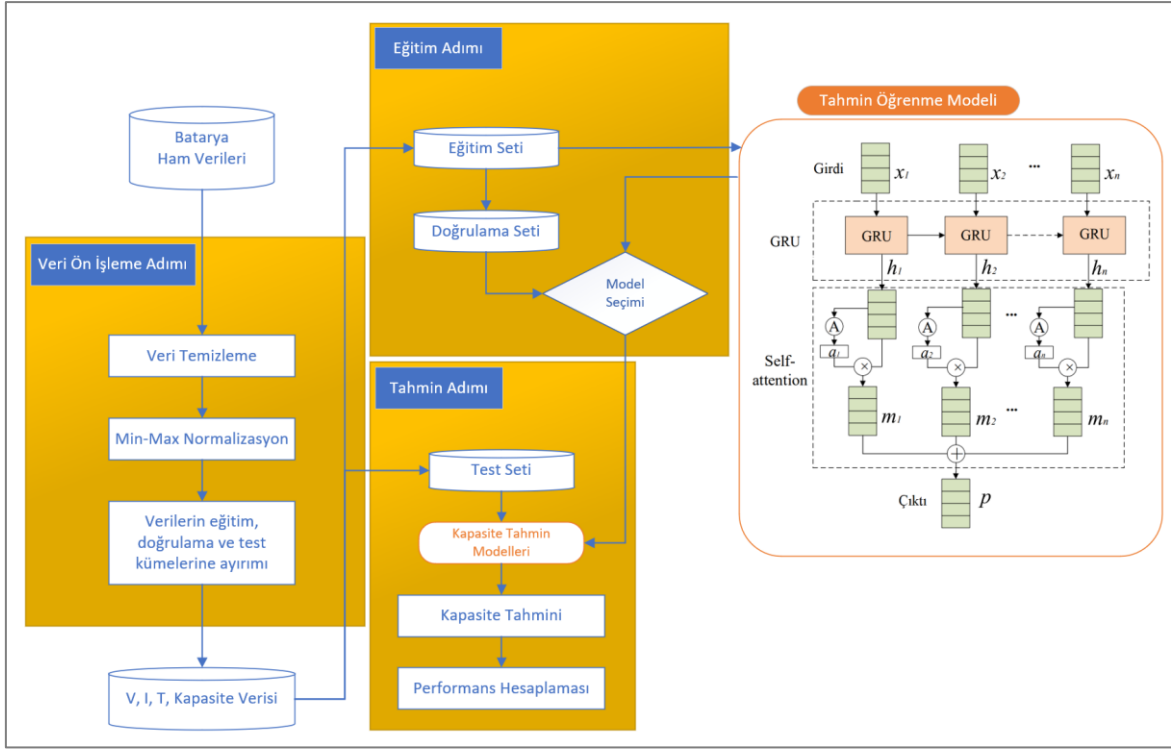
8.1. Önerilen Yapı

Şekil 8.1'de, GRU-AM'ye dayalı çok kanallı şarj profillerinden yararlanarak batarya kapasitesinin tahmin edilmesi için önerilen çerçeveye genel bir bakış sunulmaktadır. Bu çerçeve üç adımdan oluşur: veri ön işleme, eğitim ve tahmin.

Veri Ön İşleme Adımında veri temizleme ve min-max normalizasyon teknikleri uygulanarak anormal veriler kaldırılır. Veri temizleme sonrasında pek çok batarya verisinin bulunduğu (V, I, T) veri setimizden sadece batarya kapasite verisinin bulunduğu daha kompakt bir vektör elde edilir. Bu vektörün içerdiği değerler eğitim adımını kolaylaştırmak adına min-max normalizasyon yapılır ve daha sonra tahmin adımında denormalizasyon yapılarak sonuç verileri ortaya konur.

Eğitim Adımında sırasıyla LSTM, GRU, BiLSTM, LSTM-AM, BiLSTM-AM ve GRU-AM'ye dayalı uygun bir model seçmek için eğitim ve doğrulama setleri kullanılır. Mevcut veri kümeleri sınırlı olduğundan, mevcut veri kümelerinden tam olarak yararlanılması gerekir. Böylece 8 veri setinden 7 batarya seti eğitim seti, geri kalanı ise test seti olarak seçilir ve bu işlem sekiz kez tekrarlayarak sekiz test sonucu elde edilir. Önerilen GRU-AM yöntemi beş katmandan oluşur (sequenceInputLayer(30) → gruLayer(50) → selfAttentionLayer(4,12) → fullyConnectedLayer(1) → regressionLayer). Bu katmanlar ve parametre değerleri çıktı değerlerini karşılaştırma kolaylığı amacıyla tüm test edilmiş derin öğrenme yöntemleri için aynı tutulmuştur. Yöntemler arasındaki değişken sadece gruLayer yerine lstmLayer veya bilstmLayer kullanılması ve selfAttentionLayer'ın dikkat mekanizmalı olması veya olmamasına göre eklenip çıkarılmasıdır.

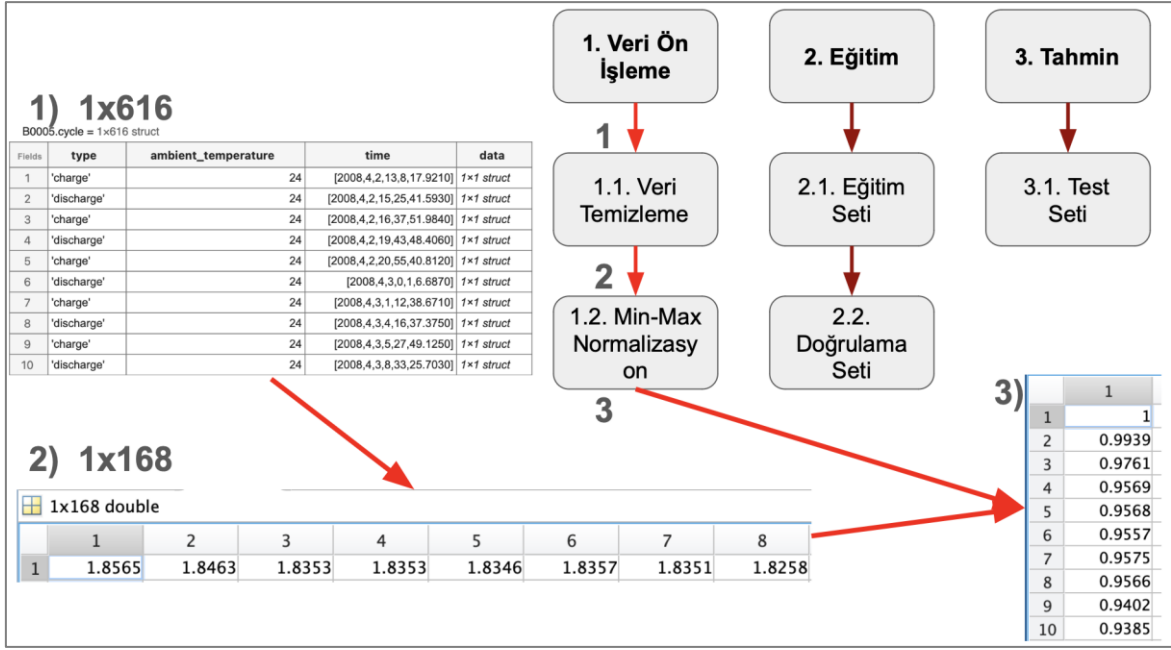
Tahmin Adımında ise bir önceki adımda belirlenen kapasite tahmin modellerini kullanarak batarya kapasitesi tahmin edilir ve önerilen yöntemin performansı değerlendirilir. Elde edilmiş olan sekiz test sonucunun performansını değerlendirmek için sekiz simülasyon örneğinin ortalaması alınır. Daha sonra önerilen GRU-AM yönteminin başarısını değerlendirmek için diğer derin öğrenme yöntemlerinin tahmin hata değerlerine kıyasla ne kadar daha düşük çıktığını yüzdelik olarak gösteren tablo çizdirilir.



Şekil 8.1. Önerilen kapasite tahmininin genel çerçevesi

8.2. Veri Ön İşleme

Batarya veri setini deneysel veri olarak kullanmadan önce, aykırı değerleri kaldıracak ve mevcut verileri güvence altına alacak veri ön işleme yapılır. Sonunda, Şekil 8.3-8.5'te olduğu gibi döngü başına bozulma özelliklerine sahip sekiz set batarya verisi elde edilmiş olur. Şekil 8.3-8.5'te deney için #5, #6, #7, #18, #29, #30, #46 ve #47 numaralı bataryalar seçilmiştir. Bataryaların genel özellikleri ve şarj/deşarj koşulları Tablo 8.2'de özetlenmiştir. Tahminde veri hassasiyeti ve karmaşıklığı nedeniyle tüm verilerin kullanılması verimli değildir. Batarya Yönetim Sisteminin (BMS) ayarına göre şarj işlemi sırasında çok sayıda veri noktası olmasına rağmen, şarj aralığı sırasında görünen değişiklikleri koruyan alt örneklenmiş verileri kullanırız.



Şekil 8.2. Önerilen çerçevenin adımları ve veri ön işleme sonuçları

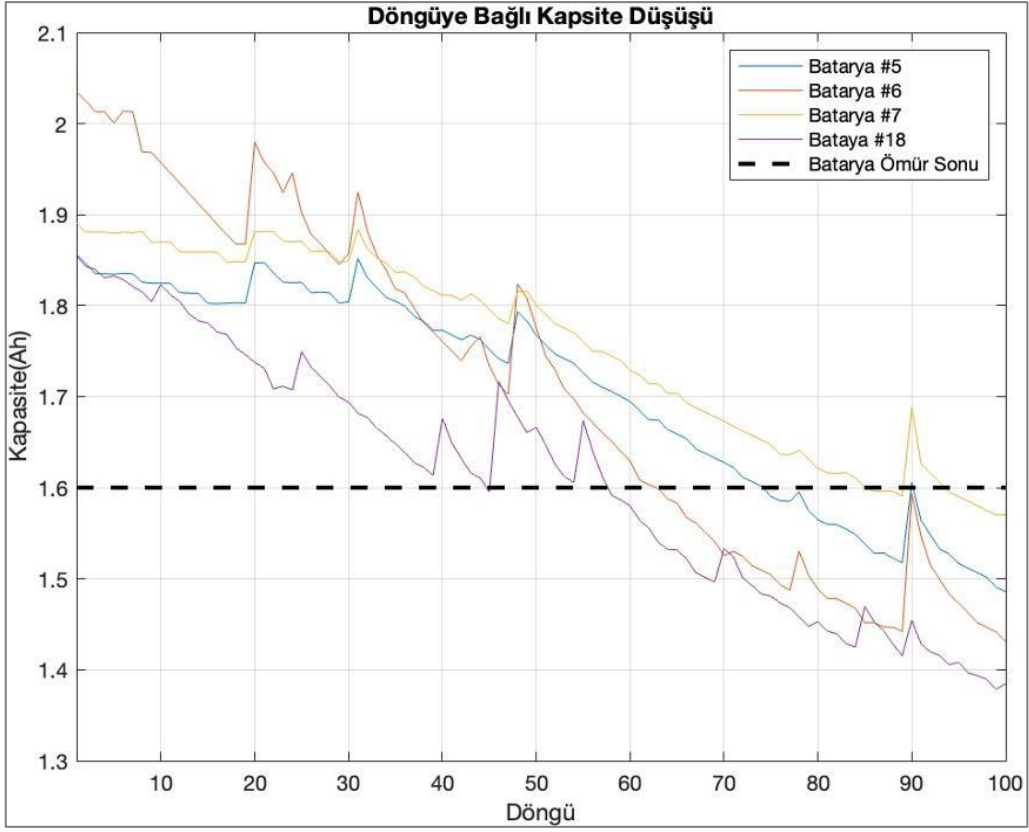
Şekil 8.2’de görülebileceği üzere ilk başta girdi olarak aldığımız 1x616’lık vektör veri temizleme aşaması sonrası 1x168’lik bir vektöre indirgenmiştir. Daha sonra 1x168’lik vektör min-max normalizasyon yapılarak 1 ile 0 arasında ölçeklendirilir ve veri setimiz eğitim aşamasına hazır hale getirilmiş olur

Önerilen modellerin girdileri çıkarılan özniteliklerdir. Bunlar, ham batarya verilerinin tekdüze örneklemeyle elde edilir. Spesifik olarak, her biri 10 örnek içeren V, I, T şarj etme profillerini birleştirerek giriş matrisini 30 boyutlu vektörler olarak yapılandırılır. Örnek sayısı, zamandaki belirgin değişiklikleri ve model karmaşıklığını dikkate alacak şekilde seçilir. Ek olarak, kısa zaman aralığında salınımı önlemek için örnekleme aralığı boyunca verilerin ortalaması alınır.

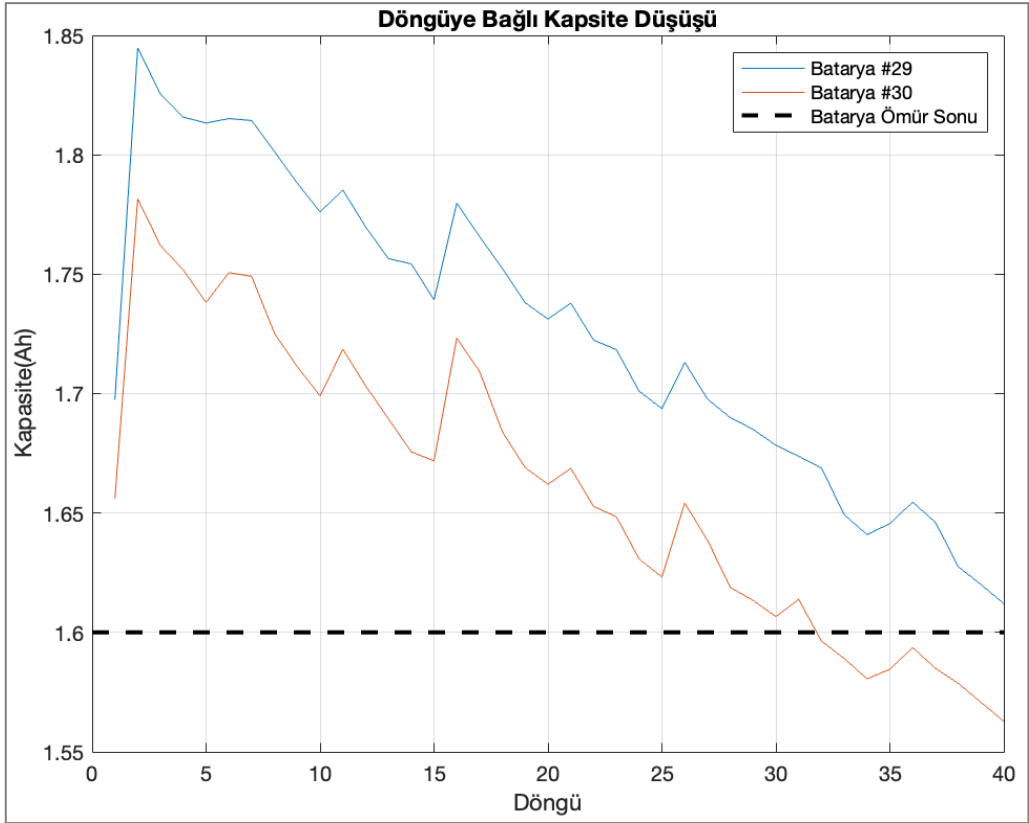
Min-max normalizasyon, ölçeklendirme faktörü dışında, verilerin orijinal dağılımını koruduğu ve daha iyi eğitim yapılabilmesine olanak sağladığı için kullanılır. Min-max normalizasyon 8.1’de görüldüğü üzere, bütün verileri [0,1] aralığına taşır.:

$$z_i^k = \frac{x_i^k - \min(x)}{(x) - \min(x)} \quad i \in \{1, \dots, n\} \quad (8.1)$$

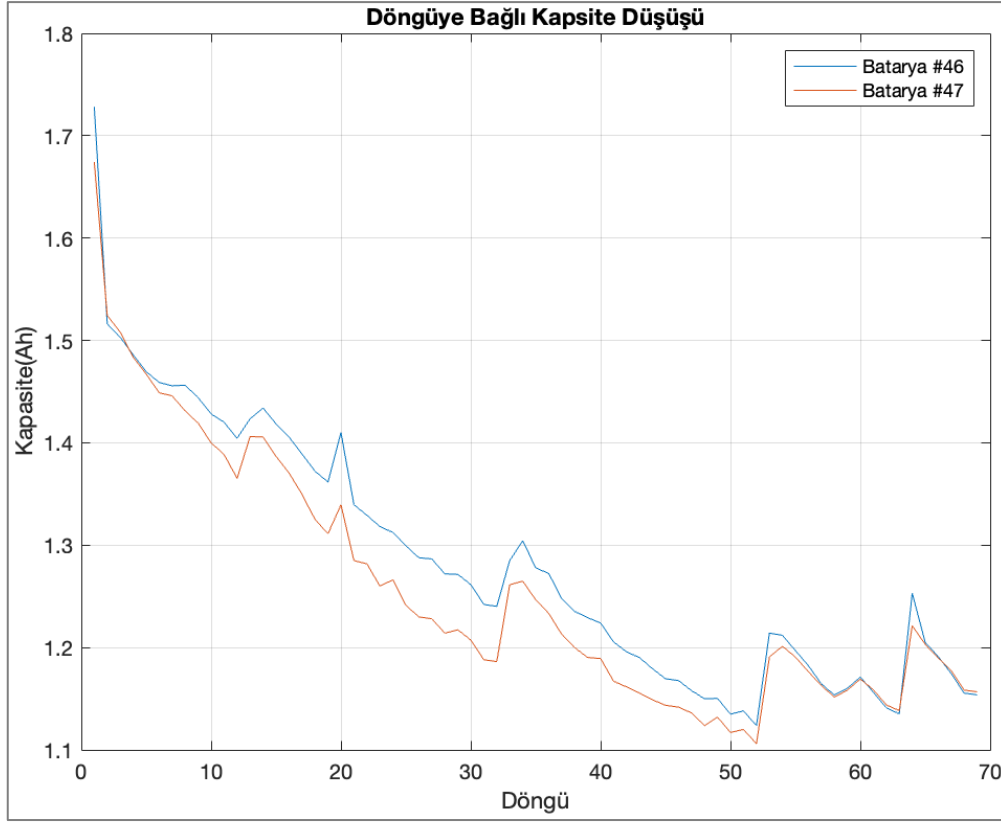
Burada x , tüm şarj döngülerinin bir toplamıdır. Yani x_i^k ve n , döngü başına örnek sayısını temsil eder. Nihai tahmin sonuçlarını sunmadan önce denormalizasyon yapılır.



Şekil 8.3. Batarya 5, 6, 7 ve 18 için döngüye bağlı kapasite düşüşü



Şekil 8.4. Batarya 29 ve 30 için döngüye bağlı kapasite düşüşü



Şekil 8.5. Batarya 46 ve 47 için döngüye bağlı kapasite düşüşü

8.3. Uzun Kısa Dönemli Bellek (Long Short-Term Memory)

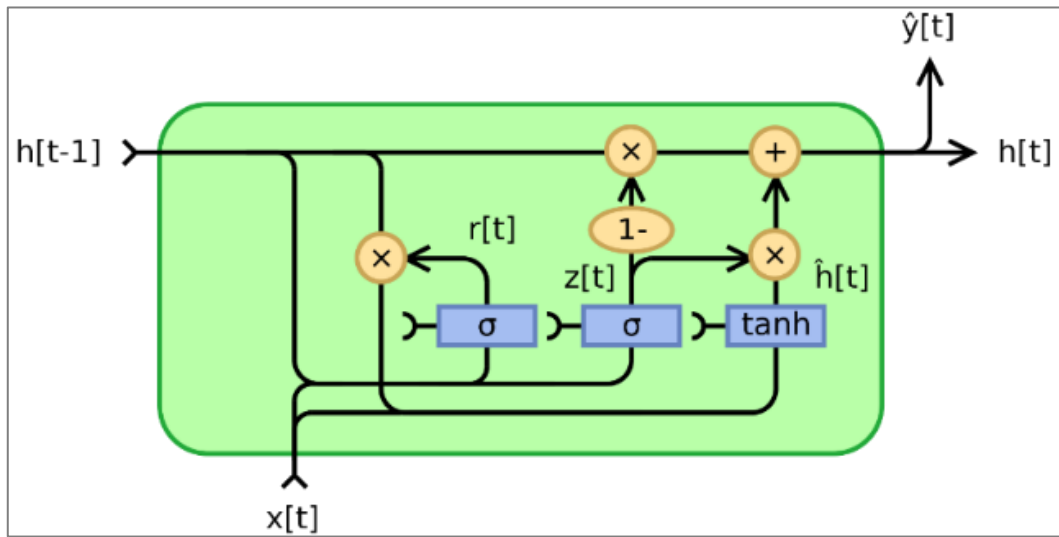
Özyinelemeli Sinir Ağı (Recurrent Neural Network), bellekte yönlendirilmiş döngüler içeren ve özellikle sıralı verilerde üstün performans gösteren bir sinir ağıdır. Kaybolan gradyan sorunu nedeniyle, zaman serisi verileri uzun vadeli bağımlılığa sahip olduğunda temel RNN yapısı doğru sonuçtan uzaklaşabilir. Bu nedenle, kaybolan gradyan problemini azaltmak için LSTM tasarlanmıştır. Ortak bir LSTM ünitesi bir hücre, bir giriş kapısı, bir çıkış kapısı ve bir unutmaya kapısı olmak üzere üç kapıdan oluşur. Hücre, değerleri rastgele zaman aralıklarında hatırlar ve bu üç kapı, hücrenin içine ve dışına bilgi akışını düzenler. LSTM, uzun vadeli bilgileri depolamak için dahili bir bellek hücresi durumunu tanımlar. Bellek hücresi durumu, dahili durum vektörünün hangi öğelerinin güncellenmesi, korunması veya silinmesi gerektiğini belirlemek için önceki çıkış ve sonraki girişle etkileşime girer.

8.4. Çift Yönlü Uzun Kısa Dönemli Bellek (Bi-Directional Long Short-Term Memory)

BiLSTM sinir ağı zıt yönlerde iki LSTM sinir ağından oluşur ve bu sayede sıra ile ilgili problemlerde daha iyi performansa sahiptir. BiLSTM sinir ağı, verileri iki LSTM üzerinden zıt yönlerde ileri ve geri işleyebilir, böylece hem geçmiş hem de gelecek bilgileri kullanarak eğitilebilmiş olur.

8.5. Geçitli Tekrarlayan Birim (Gated Recurrent Units)

GRU'nun arkasındaki temel fikir, her zaman adımında ağız gizli durumunu seçici olarak güncellemek için geçit mekanizmalarını kullanmaktır. Geçit mekanizmaları, ağız içine ve dışına bilgi akışını kontrol etmek için kullanılır. GRU'nun sıfırlama kapısı ve güncelleme kapısı adı verilen iki geçit mekanizması vardır. Sıfırlama kapısı önceki gizli durumun ne kadarının unutulması gerektiğini belirlerken, güncelleme kapısı gizli durumu güncellemek için yeni girişin ne kadarının kullanılmasını belirler. GRU'nun çıktısı, güncellenen gizli duruma göre hesaplanır. Aşağıda, şekil 8.6'da tipik GRU yapısı ve açıklamaları gösterilmektedir [114]:



Şekil 8.6. Tipik GRU yapısı

Sıfırlama Kapısı:

$$r_t = \Sigma(W_r * [h_{t-1}, x_t]) \quad (8.2)$$

Güncelleme Kapısı:

$$z_t = \Sigma(W_z * [h_{t-1}, x_t]) \quad (8.3)$$

Aday Gizli Durum:

$$\hat{h}_t = \tanh(W_h * [r_t * h_{t-1}, x_t]) \quad (8.4)$$

Gizli Durum:

$$h_t = (1 - z_t) * h_{t-1} + z_t * \hat{h}_t \quad (8.5)$$

Burada W_r , W_z ve W_h öğrenilebilir ağırlık matrisleridir. x_t , t zaman adımındaki girdidir. h_{t-1} önceki gizli durumdur ve h_t mevcut gizli durumdur.

8.6. Öz Dikkat Mekanizması (Self Attention Layer)

Öz-dikkat mekanizması, modelin girdi verilerindeki uzun vadeli bağımlılıkları yakalamasına yardımcı olur, bu da görüntünün farklı bölümlerini birbiriyle ilişkilendirmeyi öğrenebileceği anlamına gelir.

Makine öğrenimine dayalı dikkat, bilişsel dikkati sezgisel olarak taklit eden bir mekanizmadır. Bağlam penceresindeki her girdi için "yumuşak" ağırlıkları hesaplar. Bu ağırlıklar paralel veya sıralı olarak hesaplanabilir. "Yumuşak" ağırlıklar, önceden eğitilmiş, ince ayar yapılmış ve sonrasında donmuş halde kalan "sert" ağırlıkların aksine, her çalışma süresinde değişebilir.

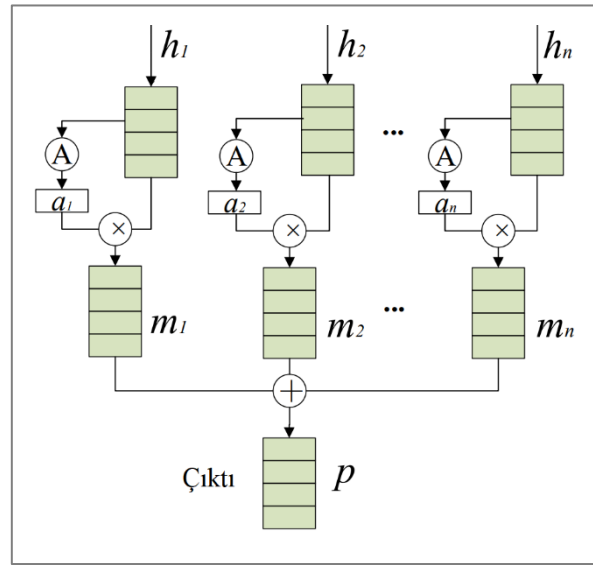
Tekrarlayan sinir ağlarının gizli çıktılarından bilgi almanın zayıf yönlerini ele almak için dikkat geliştirilmiştir. Tekrarlayan sinir ağları, son gizli durumlarda yer alan daha yeni bilgileri tercih ederken, daha önceki gizli durum bilgileri zayıflar. Dikkat yalnızca önceki gizli durumdan ziyade, bir girdinin herhangi bir bölümüne doğrudan eşit erişime izin verir [115].

Dikkat mekanizması son birkaç yıldır yapay zekanın çeşitli görevlerinde yaygın olarak kullanılmaktadır. Derin Öğrenmeden LSTM ve Bi-LSTM özelinde pek çok yapılmış öz-dikkat mekanizmalı kestirim çalışması bu mekanizmanın başarısını kanıtlamaktadır [7, 11,

12, 116]. Öz-dikkat mekanizması, bir veri setindeki her veri arasındaki korelasyon katsayısını hesapladığından modelimize uyarlanmıştır.

Önerilen model, bir GRU katmanından sonra öz dikkat katmanını ekleyerek, giriş görüntüsünün farklı bölgeleri arasındaki mekansal ilişkileri dikkate alır ve özellik temsil yeteneklerini geliştirir. Aşağıdaki adımlar sırasıyla dikkat mekanizması içerisinde gerçekleşir [117]:

1. Girişteki sorguları, anahtarları ve değerleri hesaplar
2. Sorguları, anahtarları ve değerleri kullanarak ölçeklendirilmiş nokta çarpım dikkati hesaplar
3. Alınan sonuçları birleştirir
4. Birleştirilmiş sonuç üzerinde doğrusal bir dönüşüm gerçekleştirir



Şekil 8.7. Öz-Dikkat Mekanizması girdiden çıktıya basit gösterim

Öz-Dikkat Mekanizması 8.6 - 8.9 şekilde tanımlanabilir [118];

$$e_t = \sum(W_a \cdot h_t + b_a) \quad (8.6)$$

$$a_t = \text{softmax}(e_t) \quad (8.7)$$

$$m_t = a_t \cdot h_t \quad (8.8)$$

$$p = \sum_{t=1}^n m_i \quad (8.9)$$

burada h_t GRU modelinin çıktısı olan dikkat katmanının girdisidir. W_a eğitim sürecindeki ağırlıklı matrisleri, b_a ise sapmaları temsil etmektedir. a_t , Şekil 8.7'deki A'yı oluşturur, bu da dikkat matrisi anlamına gelir. p , dikkat katmanının çıktısıdır.

9. DENEY ORTAMI, PARAMETRE AYARI VE PERFORMANS ÖLÇÜTÜ

Doğrulama setini kullanarak LSTM, BiLSTM, GRU, LSTM-AM, BiLSTM-AM ve GRU-AM yapıları test edilmiştir. Her öğrenme yöntemi MATLAB R2023b'de 3,49 GHz Apple Silicon M2 CPU ve 8 GB belleğe sahip cihaz üzerinde uygulanmıştır. Ortalama eğitim süresi 20 saniyeden azdır ve düzenleme için ayrılma süresi 0,5'tir.

Kayıp fonksiyonu olarak ortalama karesel hata (Mean Squared Error) kullanılmıştır ve Adam optimizasyonu 0,001 öğrenme oranıyla kullanılmıştır. Eğitim dönemleri (Training Epochs) 500 olarak ayarlanmıştır ve parti boyutu (Batch Size) 50 olarak kullanılmıştır. Tahmin doğruluğunu değerlendirmek için, ortalama mutlak yüzde hatası (MAPE) 9.1 numaralı formül gibi temsili bir hata indeksi olarak benimsenmiştir:

$$MAPE(\%) = \frac{100}{K} \sum_{k=1}^K \frac{|l(k) - \hat{l}(k)|}{l(k)} \quad (9.1)$$

Burada $l(k)$ gerçek kapasiteyi temsil eder, $\hat{l}(k)$ tahmin edilen kapasiteyi tahmin eder ve K döngü sayısını temsil eder. Ek olarak, ortalama mutlak hata (MAE) ve ortalama karekök hata (RMSE) 9.2 ve 9.3 formülleri kullanılarak hesaplanmıştır:

$$MAE = \frac{1}{K} \sum_{k=1}^K |l(k) - \hat{l}(k)| \quad (9.2)$$

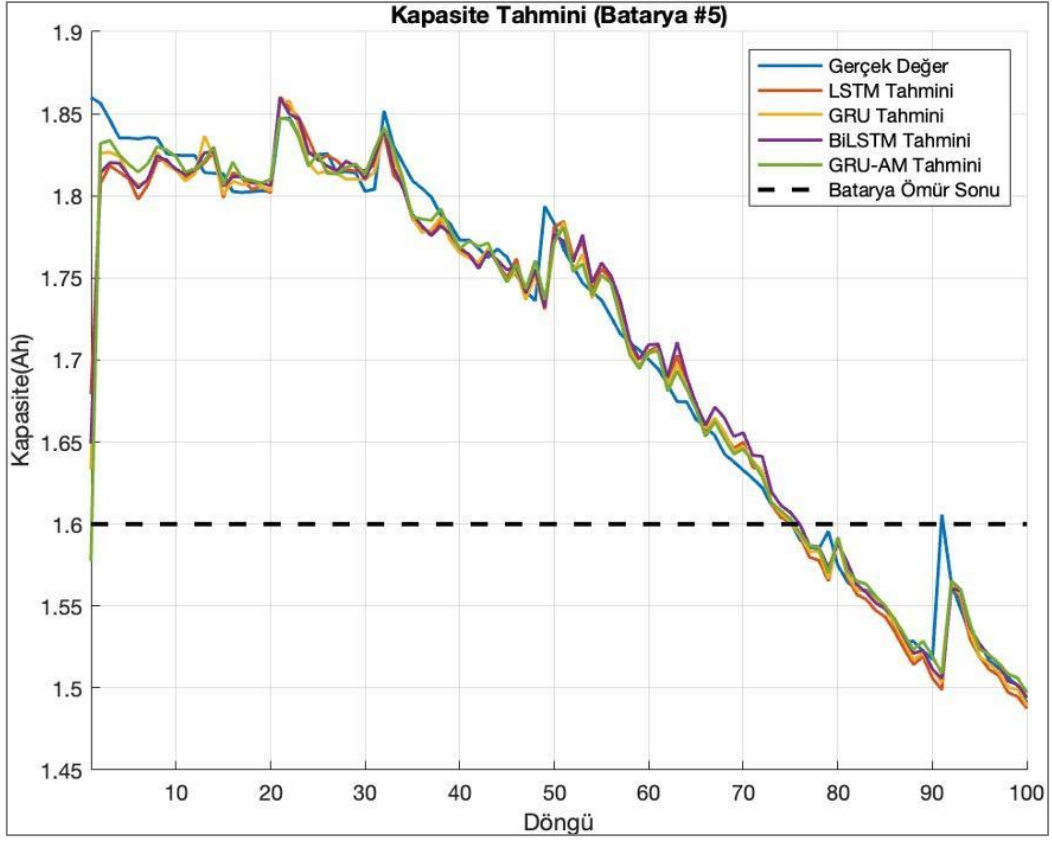
$$RMSE = \sqrt{\frac{1}{K} \sum_{k=1}^K (l(k) - \hat{l}(k))^2} \quad (9.3)$$

10. SONUÇLAR

Bu bölümde SOH tahmini için önerilen yöntemin performansı sekiz batarya (Batarya #5, Batarya #6, Batarya #7, Batarya #18, Batarya #29, Batarya #30, Batarya #46 ve Batarya #47) üzerinde test edilmiştir. Deney sonuçları Tablo 10.1-10.16'da gösterilmektedir. Bu tabloların daha kolay yorumlanabilmesi için Tablo 10.17'de tüm deney sonuçları tablolarının (Tablo 10.1-10.16) ortalaması alınarak toparlayıcı bir sonuç tablosu elde edilmiştir. Aynı parametre ayarları altında, sekiz bataryanın SOH tahmini için önerilen GRU-AM yöntemi, LSTM, GRU, BiLSTM, LSTM-AM ve BiLSTM-AM yöntemleri ile performans yönünden karşılaştırılmıştır. Tablo 10.18'de kıyaslanan her yönetime göre GRU-AM yönteminin ne kadar başarılı olduğu sırasıyla yüzdelik olarak tablo halinde gösterilmiştir. LSTM, GRU ve BiLSTM'in zaman serisi tahmininde iyi bir performansa sahip olduğunu belirtmek gerekir. Bu nedenle önerilen yöntemle karşılaştırılmaları uygun olacaktır.

Şekil 10.1-10.16'dan görülebileceği gibi, öncelikle önerilen yöntemin tahmin sonuçları gerçek verilere daha yakındır ve döngü sayısı arttıkça, kapasiteler azaldıkça, tahmin sonuçları daha doğrudur. Dikkat mekanizması sayesinde, eğitim süreci iyileştirilir. Tablo 10.17 göz önüne alındığında Dikkat Mekanizması eklenen tüm yöntemlerde benzer iyileşme yaşandığı genel olarak gözlenebilmektedir. Bu sayede kapasite tahmini nispeten düzgün olur. Bu, AM'nin tahmin performansını önemli ölçüde artırdığını göstermektedir.

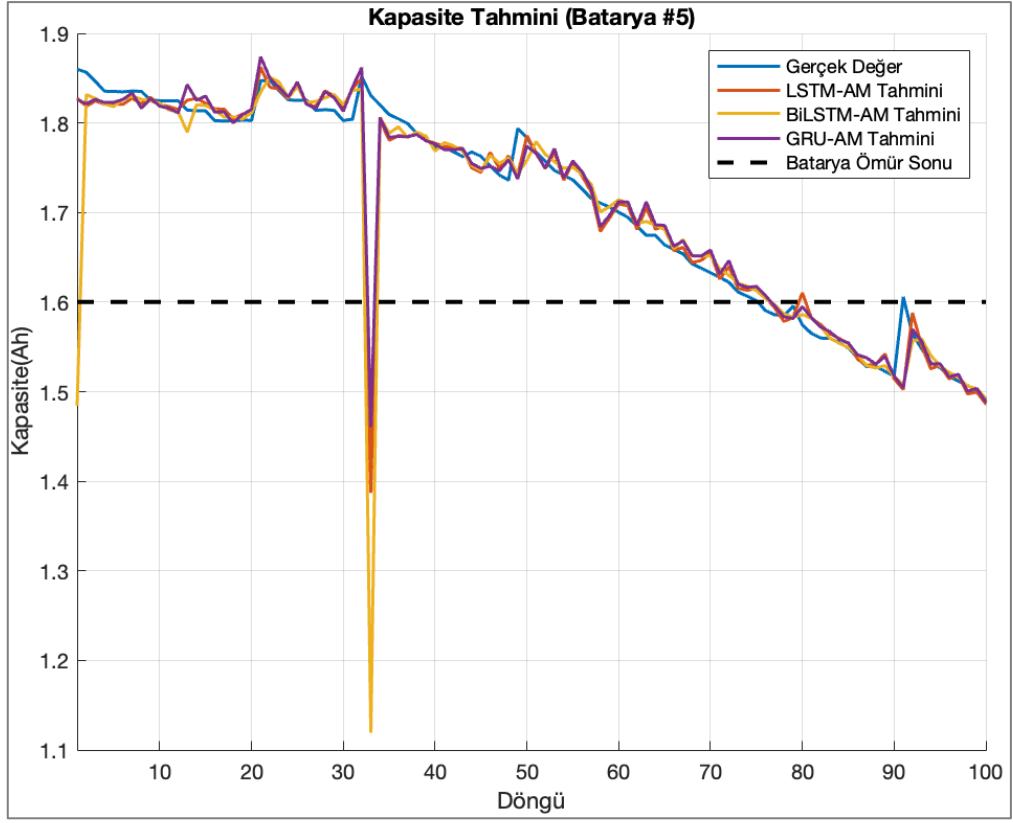
Tablo 10.17'de her batarya için elde edilmiş hata tahminlerinin ortalaması alınmış ve daha toparlayıcı bir sonuç elde edilmiştir. Tablo 10.17'de ki hata değerlerinin genel ortalaması gösteriyor ki genel başarı kıstas alındığında her hata değerinde, önerilen model en başarılı sonucu elde etmiştir. Dolayısıyla SOH tahmininde GRU-AM'nin LSTM, GRU, BiLSTM, LSTM-AM ve BiLSTM-AM'den daha doğru ve güvenilir olduğu kanıtlanmaktadır.



Şekil 10.1. Batarya 5 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)

Tablo 10.1. Batarya 5 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU)


	Modeller	RMSE	MAE	MAPE
1	"LSTM"	0.0457	0.0162	0.9951
2	"GRU"	0.0407	0.0159	0.9815
3	"BiLSTM"	0.0625	0.0164	0.9739
4	"GRU-AM"	0.0329	0.0136	0.8433



Şekil 10.2. Batarya 5 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM)

Tablo 10.2. Batarya 5 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM)


	Modeller	RMSE	MAE	MAPE
1	"LSTM_AM"	0.0379	0.0141	0.8757
2	"BiLSTM_AM"	0.0635	0.0155	0.9183
3	"GRU-AM"	0.0329	0.0136	0.8433



Şekil 10.3. Batarya 6 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)

Tablo 10.3. Batarya 6 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU)


	Modeller	RMSE	MAE	MAPE
1	"LSTM"	0.0375	0.0280	1.8820
2	"GRU"	0.0420	0.0319	2.1387
3	"BiLSTM"	0.0358	0.0267	1.7761
4	"GRU-AM"	0.0272	0.0191	1.2399



Şekil 10.4. Batarya 6 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM)

Tablo 10.4. Batarya 6 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM)


	Modeller	RMSE	MAE	MAPE
1	"LSTM_AM"	0.0923	0.0280	1.6869
2	"BiLSTM_AM"	0.0359	0.0209	1.3317
3	"GRU-AM"	0.0272	0.0191	1.2399



Şekil 10.5. Batarya 7 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)

Tablo 10.5. Batarya 7 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU)


	Modeller	RMSE	MAE	MAPE
1	"LSTM"	0.0197	0.0134	0.8132
2	"GRU"	0.0196	0.0137	0.8321
3	"BiLSTM"	0.0174	0.0116	0.7026
4	"GRU-AM"	0.0281	0.0101	0.5964



Şekil 10.6. Batarya 7 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM)

Tablo 10.6. Batarya 7 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM)


	Modeller	RMSE	MAE	MAPE
1	"LSTM_AM"	0.0160	0.0108	0.6549
2	"BiLSTM_AM"	0.0323	0.0134	0.7951
3	"GRU-AM"	0.0281	0.0101	0.5964



Şekil 10.7. Batarya 18 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)

Tablo 10.7. Batarya 18 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU)


	Modeller	RMSE	MAE	MAPE
1	"LSTM"	0.0758	0.0297	1.8382
2	"GRU"	0.0401	0.0189	1.1902
3	"BiLSTM"	0.0371	0.0187	1.1844
4	"GRU-AM"	0.0367	0.0175	1.1008



Şekil 10.8. Batarya 18 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM)

Tablo 10.8. Batarya 18 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM)


	Modeller	RMSE	MAE	MAPE
1	"LSTM_AM"	0.0647	0.0259	1.6127
2	"BiLSTM_AM"	0.0441	0.0221	1.3945
3	"GRU-AM"	0.0367	0.0175	1.1008



Şekil 10.9. Batarya 29 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)

Tablo 10.9. Batarya 29 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU)


	Modeller	RMSE	MAE	MAPE
1	"LSTM"	0.0107	0.0071	0.4091
2	"GRU"	0.0104	0.0065	0.3743
3	"BiLSTM"	0.0093	0.0060	0.3425
4	"GRU-AM"	0.0099	0.0058	0.3293



Şekil 10.10. Batarya 29 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM)

Tablo 10.10. Batarya 29 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM)


	Modeller	RMSE	MAE	MAPE
1	"LSTM_AM"	0.0097	0.0060	0.3461
2	"BiLSTM_AM"	0.0099	0.0059	0.3351
3	"GRU-AM"	0.0099	0.0058	0.3293



Şekil 10.11. Batarya 30 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)

Tablo 10.11. Batarya 30 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU)


	Modeller	RMSE	MAE	MAPE
1	"LSTM"	0.0161	0.0114	0.6716
2	"GRU"	0.0159	0.0112	0.6608
3	"BiLSTM"	0.0184	0.0131	0.7789
4	"GRU-AM"	0.0127	0.0082	0.4851



Şekil 10.12. Batarya 30 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM)

Tablo 10.12. Batarya 30 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM)


	Modeller	RMSE	MAE	MAPE
1	"LSTM_AM"	0.0128	0.0090	0.5299
2	"BiLSTM_AM"	0.0126	0.0084	0.4945
3	"GRU-AM"	0.0127	0.0082	0.4851



Şekil 10.13. Batarya 46 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)

Tablo 10.13. Batarya 46 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU)


	Modeller	RMSE	MAE	MAPE
1	"LSTM"	0.0291	0.0219	1.6761
2	"GRU"	0.0283	0.0219	1.6831
3	"BiLSTM"	0.0280	0.0212	1.6218
4	"GRU-AM"	0.0248	0.0189	1.4635



Şekil 10.14. Batarya 46 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM)

Tablo 10.14. Batarya 46 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM)

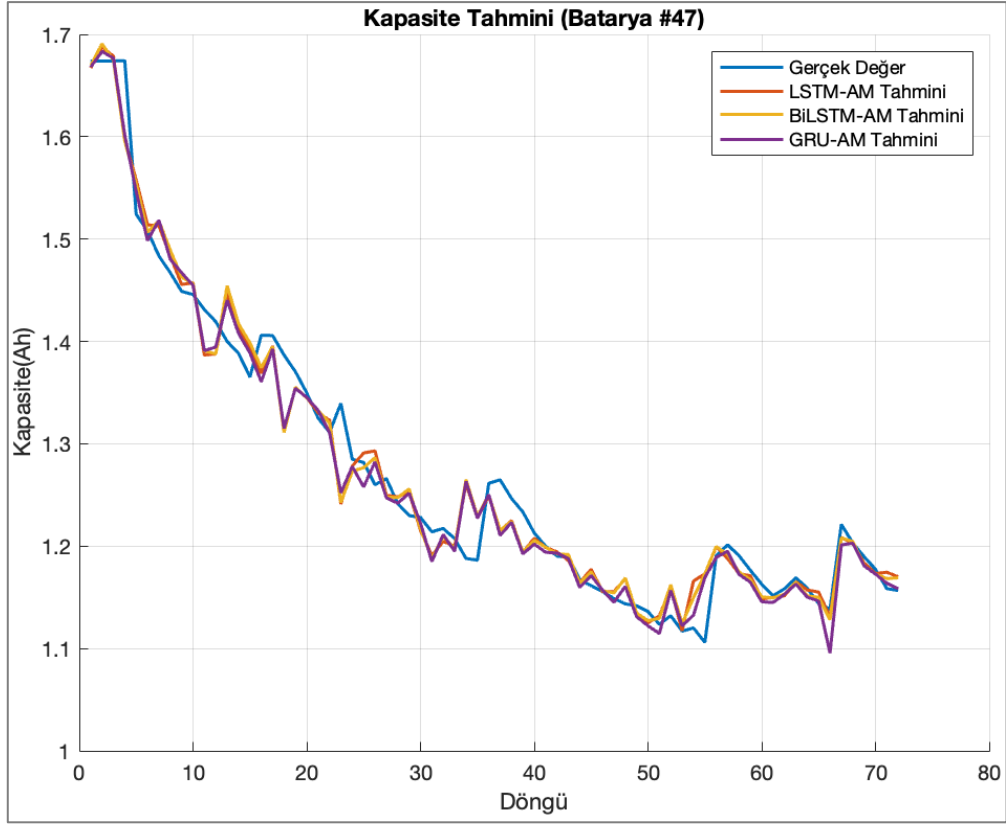
	Modeller	RMSE	MAE	MAPE
1	"LSTM_AM"	0.0252	0.0201	1.5518
2	"BiLSTM_AM"	0.0255	0.0198	1.5340
3	"GRU-AM"	0.0248	0.0189	1.4635



Şekil 10.15. Batarya 47 kapasite tahmini (GRU-AM vs LSTM, BiLSTM, GRU)

Tablo 10.15. Batarya 47 tahmin hataları (GRU-AM vs LSTM, BiLSTM, GRU)

	Modeller	RMSE	MAE	MAPE
1	"LSTM"	0.0338	0.0241	1.8749
2	"GRU"	0.0316	0.0222	1.7239
3	"BiLSTM"	0.0311	0.0221	1.7151
4	"GRU-AM"	0.0271	0.0188	1.4601



Şekil 10.16. Batarya 47 kapasite tahmini (GRU-AM vs LSTM-AM, BiLSTM-AM)

Tablo 10.16. Batarya 47 tahmin hataları (GRU-AM vs LSTM-AM, BiLSTM-AM)

	Modeller	RMSE	MAE	MAPE
1	"LSTM_AM"	0.0282	0.0195	1.5134
2	"BiLSTM_AM"	0.0283	0.0195	1.5060
3	"GRU-AM"	0.0271	0.0188	1.4601

Tablo 10.17. Tüm tahmin hatalarının ortalaması

AVG	Modeller	RMSE	MAE	MAPE (%)
1	LSTM	0,0336	0,0190	1,2700
2	GRU	0,0286	0,0178	1,1981
3	BiLSTM	0,0300	0,0170	1,1369
4	LSTM-AM	0,0359	0,0167	1,0964
5	BiLSTM-AM	0,0315	0,0157	1,0387
6	GRU-AM	0,0249	0,0140	0,9398

Tablo 10.18. Önerilen GRU-AM yönteminin diğer yöntemlere kıyasla yüzdeler başarıları

VS	Modeller	RMSE	MAE	MAPE
1	GRU-AM vs LSTM	34,60%	35,54%	35,14%
2	GRU-AM vs GRU	14,64%	26,96%	27,48%
3	GRU-AM vs BiLSTM	20,16%	21,25%	20,97%
4	GRU-AM vs LSTM-AM	43,83%	19,11%	16,67%
5	GRU-AM vs BiLSTM-AM	26,43%	12,05%	10,52%

Önerilen modelin kıyaslanmakta olduğu modellere göre ne kadarlık bir hata tahmini iyileştirmesi yapmış olduğu Tablo 10.18’de görülmektedir. Bu tablo göstermektedir ki önerilen yöntem (GRU-AM) kıyaslandığı yöntemlere göre RMSE’de %14 ila %44, MAE’de %12 ila %36 ve MAPE’de %10 ila %35’lik iyileştirme göstermiştir. BiLSTM hem gelecek hem de geçmiş bağımlılıkları sebebiyle, LSTM ve GRU ise Dikkat Mekanizmasına sahip olmayışlarıyla önerilen yöntemin gerisinde kalmışlardır.

11. DEĞERLENDİRME VE ÖNERİLER

Bu yazıda, lityum iyon bataryalar için Dikkat Mekanizmalı Geçitli Tekrarlayan Birim yöntemi ile bir kapasite tahmin çerçevesi önerilmiştir. Bu yöntem önerisini problemimizin zaman serisi problemi olmasına dayandırarak seçtik. Zaman serisi problemlerinde başarılı olan hem Geçitli Tekrarlayan Birim hem de Dikkat Mekanizması birlikte kullanılarak daha başarılı bir yöntem geliştirdik. NASA'nın lityum iyon batarya veri setlerini kullanarak hem soğuk hem sıcak hem de oda sıcaklığı koşullarında tahmin sonuçlarını hata indeksleri ve döngü başına kapasite farkı perspektifinden analiz ettik. Özellikle önerilen GRU-AM yönteminin; LSTM, GRU, BiLSTM, LSTM-AM ve BiLSTM-AM'ye kıyasla sırasıyla %35, %27, %20, %16 ve %10'a kadar MAPE iyileştirmesi ile mevcut yöntemlerden daha iyi performans verdiğini gösterdik.

Literatürde, lityum iyon batarya için NASA Prognostics Centre of Excellence tarafından yayınlanan veri setinin SoH hesaplanmasında çok kanallı (V, I, T) verilerinin tek kanallı (V) verilere karşı başarısı ve LSTM'in CNN ve FNN'e karşı olan başarısı gözler önüne serilmektedir [14, 15]. Dikkat mekanizması eklenmesi ile bu başarının ne kadar daha iyileşme gösterdiği ise hem Bi-LSTM hem de LSTM özelinde ayrıca ortaya konmaktadır [16, 17]. Bizim çalışmamızda, LSTM, BiLSTM, LSTM-AM ve BiLSTM-AM'nin doğrudan kodumuza eklenerek aynı deney ortamında GRU ve GRU-AM'nin başarısıyla ortalama mutlak yüzde hata yönünden kıyaslanması yapılmıştır. Bunu yaparken derin öğrenmede her öğrenme tekrarında farklı rakamsal sonuç çıkmasının yanlıtlılığında kaçınmak için ortalama mutlak yüzde hata verileri doğrudan literatürden çekilmek yerine önceden önerilmiş olan yöntemlerin kodumuza eklenmesi ile elde edilmiştir.

Son olarak dikkat mekanizmalı geçitli tekrarlayan birim yöntemi sonraki çalışmalarda batarya yönetim sistemine entegre edilip gerçek araçlarda test edilerek bataryanın kalan faydalı ömrü tespiti için kullanılabilir.

KAYNAKLAR

- [1] V. Iulia and S. Loránd, “A Brief History of Electric Vehicles.,” *Journal of Computer Science & Control Systems*, vol. 15, no. 1, p. 19, 2022.
- [2] M. Barber, “Before tesla: Why everyone wanted an electric car in 1905,” Curbed, archive. curbed. com/ 2017/ 9/ 22/ 16346892/ electric-car-history-fritchle (accessed Jan. 3, 2024).
- [3] “The lost history of the electric car – and what it tells us about the future of Transport,” The Guardian, theguardian. com/ technology/ 2021/ aug/ 03/ lost-history-electric-car-future-transport (accessed Jan. 3, 2024).
- [4] M. H. Westbrook, *The Electric Car: Development and future of Battery, hybrid and fuel-cell cars*, 2001. doi: 10.1049/ pbpo038e
- [5] G. E. Rickman, “Hugh Plommer, vitruvius and later Roman building manuals (Cambridge Classical Studies). Cambridge: University Press, 1973. pp. VIII + 116. 4 illus. £3·60.,” *Journal of Roman Studies*, vol. 65, pp. 222–223, 1975. doi: 10.2307/ 370111
- [6] L. Zhang, T. Ji, S. Yu, and G. Liu, Accurate prediction approach of soh for lithium-ion batteries based on LSTM method, *Batteries*, vol. 9, no. 3, p. 177, 2023. doi. org/ 10.3390/ batteries9030177
- [7] E. İ. TEZDE and H. İ. OKUMUŞ, *BataryaModelleri ve Şarj Durumu (SoC) Belirleme*, *EMO Bilimsel Dergisi*, vol. 8, no. 1, pp. 21–25, 2018.
- [8] E. Zio, *Prognostics and Health Management (PHM): Where are we and where do we (need to) go in theory and Practice*, *Reliability Engineering; System Safety*, vol. 218, p. 108119, 2022. dx. doi. org/ 10.1016/ j.res. 2021.108119
- [9] *Condition Monitoring and Diagnostics of Machines Prognostics Part1: General Guidelines*, Int. Standards Organisation, Geneva, Switzerland, Nov. 2004.

- [10] T. Sarıkurt and A. Balıkçı, A relative capacity estimation method for lithium batteries used in electric vehicle applications, Pamukkale University Journal of Engineering Sciences, vol. 24, no. 5, pp. 809–816, 2018. doi:10.5505/ pajes.2018.58224
- [11] E. Çavuş and İ. Sancaktar, Batarya sağlık durumunun makine öğrenmesi ile kestirimi, NOHU J. Eng. Sci., vol. 11, no. 3, pp. 601–610, 2022, doi.org/ 10.28948/ngumuh.1112985
- [12] Y. Jiang, Y. Chen, F. Yang, and W. Peng, State of health estimation of lithium-ion battery with automatic feature extraction and self-attention learning mechanism, Journal of Power Sources, vol. 556, p. 232466, 2023. doi.org/ 10.1016/j.est.2023.109690
- [13] Time Series forecasting methods, Techniques & Models, InfluxData, influxdata.com/ time-series-forecasting-methods/ (accessed Dec. 3, 2023).
- [14] Y. Choi, S. Ryu, K. Park, and H. Kim, Machine learning-based lithium-ion battery capacity estimation exploiting multi-channel charging profiles, IEEE Access, vol. 7, pp. 75143 – 75152, 2019. doi. org/ 10. 1002/ er. 7160
- [15] I. Jorge, T. Mesbahi, A. Samet, and R. Boné, Time series feature extraction for lithium-ion batteries state-of-health prediction, Journal of Energy Storage, vol. 59, p. 106436, 2023. doi. org/ 10.1016/ j.est.2022.106436
- [16] J. Zhang, J. Hou, and Z. Zhang, Online state-of-health estimation for the lithium-ion battery based on an LSTM neural network with attention mechanism, 2020 Chinese Control And Decision Conference (CCDC), 2020. doi: 10.1109/ccdc49329.2020.9164547
- [17] Y. Guo, D. Yang, K. Zhao, and K. Wang, State of Health Estimation for lithium-ion battery based on bi-directional long short-term memory neural network and attention mechanism, Energy Reports, vol. 8, pp. 208–215, 2022. doi: 10.1016/j.egy.2022.10.128
- [18] Gated Recurrent Unit Networks, geeksforgeeks. org/ gated-recurrent-unit-networks/ amp (accessed Dec. 3, 2023).

- [19] F. Un-Noor, S. Padmanaban, L. Mihet-Popa, M. Mollah, and E. Hossain, “A comprehensive study of key electric vehicle (EV) components, technologies, challenges, impacts, and future direction of development,” *Energies*, vol. 10, no. 8, p. 1217, 2017. doi: 10.3390/en10081217
- [20] Y. Raj, B. Agrawal, and M. Kirar, “A review on components of electric vehicle and Indian scenario of electric vehicles,” *2023 IEEE Renewable Energy and Sustainable E-Mobility Conference (RESEM)*, 2023. doi: 10.1109/resem57584.2023.10236052
- [21] O. Alatise, A. Karlsson, A. Deb, R. Wu, and J. Ortiz-Gonzalez, “Expanding EV charging capacity in distribution networks: A case study for charging evs at work,” *CIREN 2021 - The 26th International Conference and Exhibition on Electricity Distribution*, 2021. doi: 10.1049/icp.2021.1919
- [22] Y. Ma, B. Zhang, and X. Zhou, “An overview on impacts of electric vehicles integration into distribution network,” *2015 IEEE International Conference on Mechatronics and Automation (ICMA)*, 2015. doi: 10.1109/icma.2015.7237804
- [23] M. Yilmaz and P. T. Krein, “Review of battery charger topologies, charging power levels, and infrastructure for plug-in electric and hybrid vehicles,” *IEEE Transactions on Power Electronics*, vol. 28, no. 5, pp. 2151–2169, 2013. doi: 10.1109/tpe.2012.2212917
- [24] “All-Electric Vehicle Basics,” NREL, nrel.gov/research/transportation-all-electric.html (accessed Jan. 3, 2024).
- [25] (PDF) batteries for electric vehicles - researchgate, [researchgate.net/publication/37337281_Batteries_for_Electric_Vehicles](https://www.researchgate.net/publication/37337281_Batteries_for_Electric_Vehicles) (accessed Jan. 3, 2024).
- [26] Analysis of different powertrain configurations for a formula style ..., [semanticscholar.org/paper/Analysis-of-different-powertrain-configurations-for-Regas/c7c27df10826df6fbc35372149364568d7d6cbe0](https://www.semanticscholar.org/paper/Analysis-of-different-powertrain-configurations-for-Regas/c7c27df10826df6fbc35372149364568d7d6cbe0) (accessed Jan. 3, 2024).
- [27] Y. Raj, B. Agrawal, and M. Kirar, “A review on components of electric vehicle and Indian scenario of electric vehicles,” *2023 IEEE Renewable Energy and Sustainable E-Mobility Conference (RESEM)*, 2023. doi: 10.1109/resem57584.2023.10236052

- [28] Niclas, “Energy density and specific energy of Battery,” Manage risks and maximize ROI for your PV and energy storage projects, sinovoltaics.com/learning-center/storage/energy-density-and-specific-energy-of-battery/ (accessed Jan. 3, 2024).
- [29] T. Horiba, “Lithium-Ion Battery Systems,” *Proceedings of the IEEE*, vol. 102, no. 6, pp. 939–950, 2014. doi: 10.1109/jproc.2014.2319832
- [30] Components of cells and batteries, depts.washington.edu/matseed/batteries/MSE/components.html (accessed Jan. 3, 2024).
- [31] Y. Miao, P. Hynan, A. von Jouanne, and A. Yokochi, “Current Li-ion battery technologies in electric vehicles and opportunities for advancements,” *Energies*, vol. 12, no. 6, p. 1074, 2019. doi: 10.3390/en12061074
- [32] M. A. Hannan, Md. M. Hoque, A. Hussain, Y. Yusof, and P. J. Ker, “State-of-the-art and Energy Management System of lithium-ion batteries in electric vehicle applications: Issues and recommendations,” *IEEE Access*, vol. 6, pp. 19362 – 19378, 2018. doi: 10.1109/access.2018.2817655
- [33] Skill-Lync, “Week 1 understanding different battery chemistry : Skill-lync,” skill-lync.com/student-projects/week-1-understanding-different-battery-chemistry-168 (accessed Jan. 3, 2024).
- [34] Owner’s manual - tesla, tesla.com/ownersmanual (accessed Jan. 3, 2024).
- [35] P. Arora and Z. (John) Zhang, “Battery separators,” *Chemical Reviews*, vol. 104, no. 10, pp. 4419 – 4462 , 2004. doi: 10.1021/cr020738u
- [36] M. F. Lagadec, R. Zahn, and V. Wood, “Characterization and performance evaluation of lithium-ion battery separators,” *Nature Energy*, vol. 4, no. 1, pp. 16–25, 2018. doi: 10.1038/s41560-018-0295-9
- [37] T. M. Bandhauer, S. Garimella, and T. F. Fuller, “A critical review of thermal issues in lithium-ion batteries,” *Journal of The Electrochemical Society*, vol. 158, no. 3, 2011. doi: 10.1149/1.3515880

- [38] Battery University, “Is Li-ion the solution for the electric vehicle?,” Battery University, batteryuniversity.com/article/is-li-ion-the-solution-for-the-electric-vehicle (accessed Jan. 3, 2024).
- [39] Battery University, “BU - 205: Types of lithium-ion,” Battery University, batteryuniversity.com/learn/article/types_of_lithium_ion (accessed Jan. 3, 2024).
- [40] C. Sun, S. Rajasekhara, J. B. Goodenough, and F. Zhou, “Monodisperse porous LiFePO_4 microspheres for a high power Li-ion battery cathode,” *Journal of the American Chemical Society*, vol. 133, no. 7, pp. 2132 – 2135, 2011. doi: 10.1021/ja1110464
- [41] C. Atwell, “Six lithium-ion battery chemistries: Not all batteries are created equal,” *Electronic Design*, electronicdesign.com/technologies/power/alternative-energy/article/21199536/six-lithium-ion-battery-chemistries-not-all-batteries-are-created-equal (accessed Jan. 3, 2024).
- [42] K. Fehrenbacher, “Why Tesla’s grid batteries will use two different chemistries,” *Fortune*, fortune.com/2015/05/18/tesla-grid-batteries-chemistry/ (accessed Jan. 3, 2024).
- [43] G. Bower, “Tesla Panasonic quietly outmaneuver all lithium battery manufacturers,” *InsideEVs*, insideevs.com/tesla-panasonic-quietly-outmaneuvers-all-lithium-battery-manufacturers/ (accessed Jan. 3, 2024).
- [44] M. M. Thackeray, W. I. F. David, P. G. Bruce, and J. B. Goodenough, “Lithium insertion into manganese spinels,” *Materials Research Bulletin*, vol. 18, no. 4, pp. 461 – 472, 1983. doi: 10.1016/0025-5408(83)90138-1
- [45] Stephen, “Mitsubishi chooses super-efficient Toshiba SCIB Battery for evs,” *Japanese Car Auctions - Integrity Exports*, integrityexports.com/blog/mitsubishi-chooses-toshiba-scib-battery-for-evs/ (accessed Jan. 3, 2024).
- [46] Toshiba’s SCIB battery for the fit EV - green car congress, greencarcongress.com/2011/11/scib-20111117.html (accessed Jan. 3, 2024).

- [47] O. Auge, “Keynote 2: Tosa concept: A full electric large capacity urban bus system,” *2015 17th European Conference on Power Electronics and Applications (EPE'15 ECCE-Europe)*, 2015. doi: 10.1109/ epe.2015.7311790
- [48] I. Cowie and I. Cowie, “All about batteries, part 12: Lithium titanate (LTO),” *EE Times*, eetimes.com/ author.asp?section_id=36&doc_id=1325358# (accessed Jan. 3, 2024).
- [49] “Types of lithium batteries: Lithium Cell Format,” OneCharge, onecharge.biz/ lithium-cell-format/ (accessed Jan. 3, 2024).
- [50] Comparisons of different types of Li-ion batteries used in evs from the ..., researchgate.net/ figure/ Comparisons-of-different-types-of-Li-ion-batteries-used-in-EVs-from-the-following_fig1_331904470 (accessed Jan. 3, 2024).
- [51] M. R. Palacín and A. de Guibert, “Why do batteries fail?,” *Science*, vol. 351, no. 6273, 2016. doi: 10.1126/ science.1253292
- [52] J. Hall, T. Lin, G. Brown, P. Biensan, and F. Bonhomme, “Decay processes and life predictions for lithium ion satellite cells,” *4th International Energy Conversion Engineering Conference and Exhibit (IECEC)*, 2006. doi: 10.2514/ 6.2006-4078
- [53] A. El Mejdoubi *et al.*, “Lithium-ion batteries health prognosis considering aging conditions,” *IEEE Transactions on Power Electronics*, vol. 34, no. 7, pp. 6834 – 6844, 2019. doi: 10.1109/ tpel.2018.2873247
- [54] J. Vetter *et al.*, “Ageing mechanisms in lithium-ion batteries,” *Journal of Power Sources*, vol. 147, no. 1–2, pp. 269–281, 2005. doi: 10.1016/ j.jpowsour.2005.01.006
- [55] M. Broussely *et al.*, “Main aging mechanisms in Li Ion Batteries,” *Journal of Power Sources*, vol. 146, no. 1–2, pp. 90–96, 2005. doi: 10.1016/ j.jpowsour.2005.03.172
- [56] E. Redondo-Iglesias, P. Venet, and S. Pelissier, “Efficiency degradation model of lithium-ion batteries for electric vehicles,” *IEEE Transactions on Industry Applications*, vol. 55, no. 2, pp. 1932–1940, 2019. doi: 10.1109/ tia.2018.2877166
- [57] Y.-X. Lin *et al.*, “Connecting the irreversible capacity loss in Li-ion batteries with the electronic insulating properties of solid electrolyte interphase (SEI) components,”

- Journal of Power Sources*, vol. 309, pp. 221–230, 2016. doi: 10.1016/j.jpowsour.2016.01.078
- [58] R. Zhao, S. Zhang, J. Liu, and J. Gu, “A review of thermal performance improving methods of lithium ion battery: Electrode modification and Thermal Management System,” *Journal of Power Sources*, vol. 299, pp. 557–577, 2015. doi: 10.1016/j.jpowsour.2015.09.001
- [59] Q. Wang *et al.*, “Thermal runaway caused fire and explosion of lithium ion battery,” *Journal of Power Sources*, vol. 208, pp. 210–224, 2012. doi: 10.1016/j.jpowsour.2012.02.038
- [60] “Boeing 787 dreamliner battery problems,” Wikipedia, en. wikipedia. org/ wiki/ Boeing_787_Dreamliner_battery_problems (accessed Jan. 3, 2024).
- [61] Plug-in Electric Vehicle Fire Incidents. Available online: en. wikipedia. org/ wiki/ Plug-in_electric_vehicle_fire_incidents (accessed on 17 February 2019).
- [62] A. Burke, B. Jungers, C. Yang, and J. Ogden, “Battery Electric Vehicles: An Assessment of the Technology and Factors Influencing Market Readiness,” *Advanced Energy Pathway (AEP) Project; Public Interest Energy Research (PIER) Program California Energy Commission, CA, USA, 2007.*
- [63] Wang Haiying, Wu Feng, Fu Ying, Li Ran, and Zhang Qian, “Study on key technologies of lithium battery for electric vehicle,” *Proceedings of 2011 6th International Forum on Strategic Technology*, 2011. doi: 10.1109 / ifost.2011.6021025
- [64] T. B. Reddy, “Linden’s Handbook of Batteries, Fourth Edition,” McGraw-Hill Education - Access Engineering, accessengineeringlibrary . com/ content /book /9780071624213 (accessed Jan. 3, 2024).
- [65] K. W. Cheng, B. P. Divakar, H. Wu, K. Ding, and H. F. Ho, “Battery-Management System (BMS) and SOC development for electrical vehicles,” *IEEE Transactions on Vehicular Technology*, vol. 60, no. 1, pp. 76–88, 2011. doi: 10.1109/ tvt.2010.2089647

- [66] F. Leng, C. M. Tan, and M. Pecht, “Effect of temperature on the aging rate of Li ion battery operating above room temperature,” *Scientific Reports*, vol. 5, no. 1, 2015. doi: 10.1038/srep12967
- [67] C. Zhang *et al.*, “A generalized SOC-OCV model for lithium-ion batteries and the SOC estimation for LNMCO Battery,” *Energies*, vol. 9, no. 11, p. 900, 2016. doi: 10.3390/en9110900
- [68] C. Zhang *et al.*, “Robust and adaptive estimation of state of charge for lithium-ion batteries,” *IEEE Transactions on Industrial Electronics*, vol. 62, no. 8, pp. 4948 – 4957, 2015. doi: 10.1109/tie.2015.2403796
- [69] Soc-OCV curves for each lithium-ion battery chemistry tested: (A) LFP ..., [researchgate . net/ figure / SOC-OCV-curves-for-each-lithium-ion-battery-chemistry-tested-a-LFP-b-NMC-c-LMO_fig1_355021656](https://www.researchgate.net/figure/SOC-OCV-curves-for-each-lithium-ion-battery-chemistry-tested-a-LFP-b-NMC-c-LMO_fig1_355021656) (accessed Jan. 3, 2024).
- [70] Battery University, “BU-409: Charging Lithium-Ion,” Battery University, [batteryuniversity . com / learn / article / charging_lithium_ion_batteries](https://batteryuniversity.com/learn/article/charging_lithium_ion_batteries) (accessed Jan. 3, 2024).
- [71] A. A. Abdullah Al-karakchi, G. Lacey, and G. Putrus, “A method of electric vehicle charging to improve battery life,” *2015 50th International Universities Power Engineering Conference (UPEC)*, 2015. doi: 10.1109/upec.2015.7339846
- [72] Constant current/constant voltage (CC/CV) charging profile., [researchgate . net / figure/ Constant-current-constant-voltage-CC-CV-charging-profile_fig1_343693141](https://www.researchgate.net/figure/Constant-current-constant-voltage-CC-CV-charging-profile_fig1_343693141) (accessed Jan. 3, 2024).
- [73] C. Arcus, “Battery lifetime: How long can electric vehicle batteries last?,” CleanTechnica, [cleantechnica. com/ 2016/ 05/ 31/ battery-lifetime-long-can-electric-vehicle-batteries-last/](https://cleantechnica.com/2016/05/31/battery-lifetime-long-can-electric-vehicle-batteries-last/) (accessed Jan. 3, 2024).
- [74] Battery University, “BU-402: What is C-rate?,” Battery University, [batteryuniversity. com/ learn/ article/ what_is_the_c_rate](https://batteryuniversity.com/learn/article/what_is_the_c_rate) (accessed Jan. 3, 2024).
- [75] J. R. Croy, M. Balasubramanian, K. G. Gallagher, and A. K. Burrell, “Review of the U.S. Department of Energy’s ‘Deep dive’ effort to understand voltage fade in li- and

- mn-rich cathodes,” *Accounts of Chemical Research*, vol. 48, no. 11, pp. 2813 – 2821, 2015. doi: 10.1021/acs.accounts.5b00277
- [76] Battery University, “BU-808: How to prolong lithium-based batteries,” Battery University, batteryuniversity.com/learn/article/how_to_prolong_lithium_based_batteries (accessed Jan. 3, 2024).
- [77] J. Jenkins, “Ev Tech explained: Why do evs restrict the amount of battery capacity that can be used for driving?,” Charged EVs, chargedevs.com/newswire/ev-tech-explained-why-do-evs-restrict-the-amount-of-battery-capacity-that-can-be-used-for-driving/ (accessed Jan. 3, 2024).
- [78] C. Fleischer, W. Waag, Z. Bai, and D. U. Sauer, “Adaptive on-line state-of-available-power prediction of lithium-ion batteries,” *Journal of Power Electronics*, vol. 13, no. 4, pp. 516 – 527, 2013. doi: 10.6113/jpe.2013.13.4.516
- [79] L. Ungurean, G. Cârstoiu, M. V. Micea, and V. Groza, “Battery State of Health Estimation: A structured review of models, methods and commercial devices,” *International Journal of Energy Research*, vol. 41, no. 2, pp. 151–181, 2016. doi: 10.1002/er.3598
- [80] J. Yu *et al.*, “Indirect state-of-health estimation for lithium-ion batteries under randomized use,” *Energies*, vol. 10, no. 12, p. 2012, 2017. doi: 10.3390/en10122012
- [81] M. Mathew, S. Janhunen, M. Rashid, F. Long, and M. Fowler, “Comparative analysis of lithium-ion battery resistance estimation techniques for Battery Management Systems,” *Energies*, vol. 11, no. 6, p. 1490, 2018. doi: 10.3390/en11061490
- [82] Experimental soc-OCV curves at 25 • c. - researchgate, researchgate.net/figure/Experimental-SOC-OCV-curves-at-25-C_fig5_317273118 (accessed Jan. 3, 2024).
- [83] Result comparing true SOC with EKF and SVSF estimated ... - researchgate, researchgate.net/figure/Result-comparing-true-SOC-with-EKF-and-SVSF-estimated-SOC-based-on-the-second-order-RC_fig12_286102644 (accessed Jan. 3, 2024).

- [84] F. Sun, X. Hu, Y. Zou, and S. Li, “Adaptive unscented Kalman filtering for state of charge estimation of a lithium-ion battery for electric vehicles,” *Energy*, vol. 36, no. 5, pp. 3531 – 3540, 2011. doi: 10.1016/j. energy. 2011. 03. 059
- [85] An overview of state of charge(soc) and State of health(soh) estimation ..., hal. science/ hal-02471656/ file/ IMAACA_SOC_SOH_FV%20(1). pdf (accessed Jan. 3, 2024).
- [86] Brown JM;Campbell JP;Beers A;Chang K;Ostmo S;Chan RVP;Dy J;Erdogmus D;Ioannidis S;Kalpathy-Cramer J;Chiang MF; ;, “Automated diagnosis of plus disease in retinopathy of prematurity using deep convolutional neural networks,” *JAMA ophthalmology*, pubmed. ncbi. nlm. nih. gov/ 29801159/ (accessed Jan. 3, 2024).
- [87] Gulshan V;Peng L;Coram M;Stumpe MC;Wu D;Narayanaswamy A;Venugopalan S;Widner K;Madams T;Cuadros J;Kim R;Raman R;Nelson PC;Mega JL;Webster DR;;, “Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs,” *JAMA*, pubmed. ncbi. nlm. nih. gov / 27898976 / (accessed Jan. 3, 2024).
- [88] Author links open overlay panelAaron S. Coyner BS 1 et al., “Automated Fundus Image Quality Assessment in retinopathy of prematurity using deep convolutional neural networks,” *Ophthalmology Retina*, sciencedirect. com/ science/ article/ abs/ pii/ S2468653018305190 (accessed Jan. 3, 2024).
- [89] P. Rajpurkar et al., “CheXNet: Radiologist-level pneumonia detection on chest X-rays with deep learning,” *arXiv. org*, arxiv. org/ abs/ 1711. 05225 (accessed Jan. 3, 2024).
- [90] L. D. Jones, D. Golan, S. A. Hanna, and M. Ramachandran, “Artificial Intelligence, machine learning and the evolution of Healthcare,” *Bone & Joint Research*, vol. 7, no. 3, pp. 223–225, 2018. doi: 10. 1302/ 2046-3758.73.bjr-2017-0147.r1
- [91] J. De Fauw *et al.*, “Clinically applicable deep learning for diagnosis and referral in retinal disease,” *Nature Medicine*, vol. 24, no. 9, pp. 1342–1350, 2018. doi: 10.1038 / s41591-018-0107-6

- [92] J. Moor, “The Dartmouth College Artificial Intelligence Conference: The next fifty years,” *AI Magazine*, [ojs . aaai . org/ aimagazine/ index. php/ aimagazine/ article/ view/ 1911](https://ojs.aaai.org/aimagazine/index.php/aimagazine/article/view/1911) (accessed Jan. 3, 2024).
- [93] G. James, D. Witten, T. Hastie, and R. Tibshirani, “An introduction to statistical learning,” *Springer Texts in Statistics*, 2013. doi: 10. 1007 / 978-1-4614-7138-7
- [94] K. Nordhausen, “The elements of Statistical Learning: Data Mining, Inference, and prediction, second edition by Trevor Hastie, Robert Tibshirani, Jerome Friedman,” *International Statistical Review*, vol. 77, no. 3, pp. 482–482, 2009. doi: 10. 1111 / j.1751-5823.2009.00095_18.x
- [95] I. Salián, “Supervised vs. unsupervised learning,” *NVIDIA Blog*, [blogs. nvidia. com/ blog/ supervised-unsupervised-learning/](https://blogs.nvidia.com/blog/supervised-unsupervised-learning/) (accessed Jan. 3, 2024).
- [96] Comparison of linear and logistic regression. tion of the linear ..., [researchgate. net/ figure/ Comparison-of-linear-and-logistic-regression-tion-of-the-linear-regression-model-as-it_fig1_318114162](https://researchgate.net/figure/Comparison-of-linear-and-logistic-regression-tion-of-the-linear-regression-model-as-it_fig1_318114162) (accessed Jan. 3, 2024).
- [97] H. Do;, “Animal and physiological psychology,” *Annual review of psychology*, [pubmed. ncbi. nlm. nih. gov/ 14771872/](https://pubmed.ncbi.nlm.nih.gov/14771872/) (accessed Jan. 3, 2024).
- [98] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning representations by back-propagating errors,” *Nature News*, [nature. com/ articles/ 323533a0](https://nature.com/articles/323533a0) (accessed Jan. 3, 2024).
- [99] Ph. D. J. Orbach, “Principles of Neurodynamics. Perceptrons and the theory of brain mechanisms.,” *Archives of General Psychiatry*, [jamanetwork. com/ journals/ jamapsychiatry/ fullarticle/ 488205](https://jamanetwork.com/journals/jamapsychiatry/fullarticle/488205) (accessed Jan. 3, 2024).
- [100] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature News*, [nature. com/ articles/ nature14539](https://nature.com/articles/nature14539) (accessed Jan. 3, 2024).
- [101] “Activation functions in neural networks [12 types & use cases],” V7, [v7labs. com/ blog/ neural-networks-activation-functions](https://v7labs.com/blog/neural-networks-activation-functions) (accessed Jan. 3, 2024).
- [102] Author links open overlay panel Robert DiPietro and Abstract Recurrent neural networks (RNNs) are a class of neural networks that are naturally suited to processing

time-series data and other sequential data. Here we introduce recurrent neural networks as an extension to feedforward networks, “Deep learning: RNNS and LSTM,” *Handbook of Medical Image Computing and Computer Assisted Intervention*, sciencedirect. com/ science/ article/ abs/ pii/B9780128161760000260 (accessed Jan. 3, 2024).

- [103] M. Nabil, “The architecture of a basic RNN,” Medium, medium. com/ @navarai / the-architecture-of-a-basic-rnn-eb5ffe7f571e (accessed Jan. 8, 2024).
- [104] “Basic architecture of RNN and LSTM,” TAIL @ ti Deep Learning & Computer Vision, pydeeplearning. weebly. com/ blog/ basic-architecture-of-rnn-and-lstm (accessed Jan. 8, 2024).
- [105] C.-F. Wang, “The vanishing gradient problem,” Medium, towardsdatascience. com/ the-vanishing-gradient-problem-69bf08b15484 (accessed Jan. 3, 2024).
- [106] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, 1997. doi: 10.1162/ neco. 1997. 9. 8. 1735
- [107] K. Cho *et al.*, “Learning phrase representations using RNN encoder–decoder for statistical machine translation,” *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2014. doi: 10.3115/ v1/ d14-1179
- [108] R. DiPietro and G. D. Hager, “Deep learning: RNNS and LSTM,” *Handbook of Medical Image Computing and Computer Assisted Intervention*, pp. 503–519, 2020. doi: 10. 1016/ b978-0-12-816176-0. 00026-0
- [109] N. Networks, “What are the differences and similarities between LSTM and GRU in terms of architecture and performance?,” LSTM vs GRU: Architecture and Performance Comparison, linkedin. com/ advice/ 0/ what-differences-similarities-between-lstm-gru (accessed Jan. 3, 2024).
- [110] “Prognostics Center of Excellence Data Set Repository,” NASA, nasa. gov/ intelligent-systems-division/ discovery-and-systems-health/ pcoe/ pcoe-data-set-repository/ (accessed Jan. 3, 2024).

- [111] L. He *et al.*, “Battery-aware Mobile Data Service,” *IEEE Transactions on Mobile Computing*, vol. 16, no. 6, pp. 1544–1558, 2017. doi: 10.1109/tmc.2016.2597842
- [112] M. Rashid and A. Gupta, “Effect of relaxation periods over cycling performance of a Li-Ion Battery,” *Journal of The Electrochemical Society*, vol. 162, no. 2, 2015. doi: 10.1149/2.0201502jes
- [113] J. Wu, C. Zhang, and Z. Chen, “An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks,” *Applied Energy*, vol. 173, pp. 134–140, 2016. doi: 10.1016/j.apenergy.2016.04.057
- [114] “Gated Recurrent Unit Networks,” GeeksforGeeks, [geeksforgeeks.org/gated-recurrent-unit-networks/](https://www.geeksforgeeks.org/gated-recurrent-unit-networks/) (accessed Jan. 3, 2024).
- [115] “Numheads,” Self-attention layer - MATLAB, [mathworks.com/help/deeplearning/ref/nnet.cnn.layer.selfattentionlayer.html](https://www.mathworks.com/help/deeplearning/ref/nnet.cnn.layer.selfattentionlayer.html) (accessed Jan. 8, 2024).
- [116] L. Yang, G. Liu, Y. Dai, J. Wang, and J. Zhai, “Detecting stealthy domain generation algorithms using heterogeneous deep neural network framework,” *IEEE Access*, vol. 8, pp. 82876 – 82889, 2020. doi: 10.1109/access.2020.2988877
- [117] Tian, Yukai, Jie Wen, Yanru Yang, Yuanhao Shi, and Jianchao Zeng. 2022. "State-of-Health Prediction of Lithium-Ion Batteries Based on CNN-BiLSTM-AM" *Batteries* 8, no. 10: 155.
- [118] “Attention (machine learning),” Wikipedia, [en.m.wikipedia.org/wiki/Attention_\(machine_learning\)](https://en.m.wikipedia.org/wiki/Attention_(machine_learning)) (accessed Jan. 8, 2024).