

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**TEST VERİLERİNE DAYALI, MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME
YÖNTEMLERİ İLE BATARYA SAĞLIK DURUMU TAHMİNİ**

YÜKSEK LİSANS TEZİ

Mehmet Ali ARSLANTAŞ

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Programı

Haziran 2025

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**TEST VERİLERİNE DAYALI, MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME
YÖNTEMLERİ İLE BATARYA SAĞLIK DURUMU TAHMİNİ**

YÜKSEK LİSANS TEZİ

Mehmet Ali ARSLANTAŞ

(518221010)

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Fikret ÇALIŞKAN

Haziran 2025

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**BATTERY STATE OF HEALTH ESTIMATION BASED ON TEST DATA
USING MACHINE LEARNING AND DEEP LEARNING METHODS**

M.Sc. THESIS

**Mehmet Ali ARSLANTAŞ
(518221010)**

Department of Mechatronics Engineering

Mechatronics Engineering Programme

Thesis Advisor: Prof. Dr. Fikret ÇALIŞKAN

June 2025

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 518221010 numaralı Yüksek Lisans Öğrencisi Mehmet Ali ARSLANTAŞ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “TEST VERİLERİNE DAYALI, MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME YÖNTEMLERİ İLE BATARYA SAĞLIK DURUMU TAHMİNİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Fikret ÇALIŞKAN**

İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Gülay ÖKE GÜNEL**

İstanbul Teknik Üniversitesi

Prof. Dr. Aydın YEŞİLDİREK

Yıldız Teknik Üniversitesi

Teslim Tarihi : **30 Mayıs 2025**

Savunma Tarihi : **23 Haziran 2025**





Canım Aileme,



ÖNSÖZ

Yüksek lisans eğitimim boyunca, derin bilgi ve birikimlerini esirgemeyerek, bilimsel olduğu kadar hayata dair konularda da tecrübeleriyle yol gösteren çok değerli danışmanım Prof. Dr. Fikret ÇALIŞKAN'a en içten teşekkürlerimi sunarım.

SIRO ENERGY imkanlarını kullanmamı sağlayan değerli departman müdürümüz Halil Sadi HAMUT'a; çalışma sürecinde hem teknik görüşleri hem de manevi desteğiyle her zaman yanımda olan ekip liderim Onur TAŞKIRAN'a; modelleme ve test süreçlerinde her türlü desteğini esirgemeyen Burcu ORAL'a; veri toplama aşamasındaki katkılarından ötürü Burak EVYAPAN'a; birlikte omuz omuza çalıştığım ekip arkadaşlarım Tolgahan KARAYAZI, Eray GÜL, Yusuf ARSLAN ve Bahri BAHTİYAR'a çok teşekkür ederim.

Her koşulda yanımda olan, bana güvenen ve bugünlere gelmemde en büyük paya sahip olan canım aileme sonsuz sevgi ve teşekkürlerimi sunarım.

Haziran 2025

Mehmet Ali ARSLANTAŞ



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SEMBOLLER	xv
ÇİZELGE LİSTESİ.....	xvii
ŞEKİL LİSTESİ.....	xix
ÖZET.....	xxi
SUMMARY	xxiii
1. GİRİŞ.....	1
1.1 Literatür Taraması	4
2. BATARYALARIN MODELLENMESİ.....	9
2.2 Elektrokimyasal Devre Modeli	9
2.3 Eşdeğer Devre Modeli	11
2.3.1 Rint modeli.....	11
2.3.2 Thevenin modeli.....	12
2.3.3 Çift polarizasyon modeli	13
2.3.4 Yüksek mertebeli eşdeğer devre modeli	15
3. BATARYALARIN SAĞLIK DURUMU TAHMİNİ.....	17
3.1 Veri Tabanlı Tahmin Yöntemleri.....	19
3.1.1 Rastgele orman yöntemi.....	20
3.1.2 Uzun kısa süreli bellek yöntemi	21
3.1.3 Destek vektör makinesi yöntemi	24
4. TEST SÜRECİ VE TAHMİN ÇALIŞMASI	29
4.1 Verilerin Elde Edilmesi.....	29
4.2 Model Testleri ile Tahmin Yöntemi Seçimi	34
4.2.1 Lineer regresyon ile model testi	34
4.2.2 Destek vektör regresyonu ile model testi	37
4.2.3 Rastgele orman ile model testi	39
4.2.4 Çok katmanlı algılayıcı ile model testi.....	43
4.2.5 Kapı kontrollü tekrarlayan hücre ile model testi	45
4.2.6 Uzun kısa süreli hafıza ile model testi	48
4.2.7 Model testi sonuçları ile algoritma seçimi	51
4.3 Seçilen Modeller ile Paket Testleri	53
5. SONUÇLAR	57
KAYNAKLAR	59
ÖZGEÇMİŞ.....	63



KISALTMALAR

SOH	: Sağlık Durumu
SOC	: Şarj Durumu
SVR	: Destek Vektör Regresyonu
RF	: Rastgele Orman
LSTM	: Uzun Kısa Süreli Bellek
XGBoost	: Aşırı Gradyan Artırımı
RFE	: Özyinelemeli Öznitelik Eleme
DL	: Bozulma Tabakası
SEI	: Katı Elektrolit Ara Tabakası
LCO	: Lityum Kobalt Oksit
NMC	: Nikel Manganez Kobalt
NCA	: Nikel Kobalt Alüminyum
RC	: Direnç-Kapasitör
DP	: Çift Kutuplaşma
EKM	: Eşdeğer Devre Modeli
EDM	: Elektrokimyasal Bozulma Modeli
RBF	: Radyal Tabanlı Fonksiyon
MSE	: Ortalama Kare Hata
MLP	: Çok Katmanlı Algılayıcı
COA	: Çakal Optimizasyon Algoritması
DAUKF	: Çift Uyarlanabilir Yayılı Kalman Filtresi
RMSE	: Kök Ortalama Kare Hata
EKF	: Genişletilmiş Kalman Filtresi
LFP	: Lityum Demir Fosfat
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hata



SEMBOLLER

R	: Direnç
P	: Güç
I	: Akım
V,U	: Gerilim
C	: Kapasite
Q	: Yük
T	: Sıcaklık
t	: Zaman
ΔR	: Direnç Değişimi
E_{loss}	: Enerji Kaybı
P_{loss}	: Güç Kaybı
$\hat{y}$	: Tahmin Edilen Çıktı
y	: Gerçek Çıktı
e	: Hata
R^2	: Determinasyon Katsayısı
γ	: Gamma Parametresi
ϵ	: Hata Toleransı
C	: Ceza Parametresi
κ	: Çekirdek Fonksiyonu
α	: Lagrange Çarpanı
K	: Çekirdek Fonksiyonu
ϕ	: Özellik Dönüşüm Fonksiyonu
θ	: Rastgelelik Parametresi
σ	: Sigmoid Fonksiyonu



ÇİZELGE LİSTESİ

Sayfa

Çizelge 4.1 : Test verileriyle oluşturulmuş giriş değerlerinin çizelgesi	31
Çizelge 4.2 : Giriş verilerinden türetilmiş model test verileri	33





ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : DL ve SEI içeren elektrokimyasal modelin yapısı [20]	10
Şekil 2.2 : Devre elemanlarıyla Rint modelinin gösterimi	12
Şekil 2.3 : Devre elemanlarıyla Thevenin modelinin gösterimi	13
Şekil 2.4 : Devre elemanlarıyla Çift Polarizasyon modelinin gösterimi	14
Şekil 2.5 : Yüksek mertebeli eşdeğer devre modelinin gösterimi	15
Şekil 3.1 : LSTM algoritması giriş, çıkış ve kapıların bağlantıları	22
Şekil 3.2 : LSTM algoritması akış şeması	23
Şekil 4.1 : Verilerin elde edilmesi için oluşturulan test düzeneği	30
Şekil 4.2 : Giriş verilerinin önem düzeyi grafiği	32
Şekil 4.3 : Şarj durumu çıkartıldığında gerçekleştirilen önem düzeyi grafiği	32
Şekil 4.4 : Yeni verilerle elde edilen değişken önemliliği analizi grafiği	34
Şekil 4.5 : Lineer regresyon modeli ile tahmin sonuçları	35
Şekil 4.6 : Türetilen verilerle ve lineer regresyon modeli ile tahmin sonuçları	36
Şekil 4.7 : Destek vektör regresyonu modeli ile tahmin sonuçları	37
Şekil 4.8 : Türetilen verilerle destek vektör regresyon modeli sonuçları	38
Şekil 4.9 : Rastgele orman modeli ile tahmin sonuçları	40
Şekil 4.10 : Türetilen verilerle rastgele orman modeli sonuçları	41
Şekil 4.11 : Çok katmanlı algılayıcı modeli tahmini	43
Şekil 4.12 : Türetilen verilerle çok katmanlı algılayıcı modeli sonuçları	44
Şekil 4.13 : GRU modeli ile tahmin sonuçları	46
Şekil 4.14 : Türetilen verilerle ve GRU modeli ile tahmin sonuçları	47
Şekil 4.15 : LSTM modeli ile tahmin sonuçları	49
Şekil 4.16 : Türetilen verilerle ve LSTM modeli ile tahmin sonuçları	50
Şekil 4.17 : Paket testi için oluşturulan tek şarjlık veri grafiği	54
Şekil 4.18 : Tek şarjlık verilerle gerçek ve model çıktısı değerleri	55



TEST VERİLERİNE DAYALI, MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME YÖNTEMLERİ İLE BATARYA SAĞLIK DURUMU TAHMİNİ

ÖZET

Lityum-iyon bataryalar; elektrikli araçlardan enerji depolama sistemlerine kadar pek çok alanda kullanılmakta olup, kullanım süresince yaşanan performans düşüşü sistem güvenliği ve verimliliği açısından ciddi riskler barındırmaktadır. Bu nedenle batarya sağlığının doğru ve güvenilir biçimde tahmin edilmesi, sistemlerin sürdürülebilirliği için kritik önemdedir. Geleneksel yöntemler, tam şarj-deşarj döngülerine dayanarak kapasiteyi hesaplamaya çalışsa da bu hem zaman alıcı hem de hücre ömrünü azaltıcı bir yaklaşımdır. Ayrıca sıcaklık, iç direnç ve akım gibi değişkenlerin etkisini dikkate almamakta, bu da modelin sahadaki uygulanabilirliğini sınırlamaktadır. Bu bağlamda, bu çalışmada veri odaklı modelleme yöntemleriyle batarya kapasitesinin tahmin edilmesi amaçlanmıştır.

Çalışmada bataryadan toplanan sıcaklık, akım, voltaj, iç direnç, şarj durumu ve çevrim sayısı gibi parametreler kullanılmış; önışleme sürecinde anomali tespiti ve özetleme yöntemleriyle veri sadeleştirilmiş, istatistiksel anlamı korunarak işlenebilir hale getirilmiştir. Özellikle şarj süresi ve SOC aralığı gibi özetleyici istatistiklerin çıkarılması, veri hacmini önemli ölçüde azaltırken anlamlı model çıktıların elde edilmesine olanak tanımıştır. Zaman bilgisi kaybı nedeniyle özet veriler, özellikle zaman serisi modelleri açısından bazı performans sınırlılıklarına neden olmuştur. Bu nedenle model seçimi, veri yapısıyla birlikte değerlendirilmiştir.

SVR, RF ve LSTM gibi farklı modelleme algoritmalarıyla yapılan analizlerde, her modelin avantaj ve sınırlılıkları gözlemlenmiştir. SVR modeli yüksek doğruluk sağlasa da karar mekanizmasının yorumlanabilirliği zayıf kalmaktadır. RF modeli hem doğruluk hem de değişken önemini açıklayabilme kapasitesiyle öne çıkmış, sahada uygulanabilirlik açısından en güçlü aday olmuştur. LSTM modeli ise zaman serisi bilgisiyle güçlü tahminler üretmesine rağmen, özetlenmiş durağan veri ile çalışırken performans kaybı yaşamış; bu durum, model mimarisinin doğrudan veri yapısına uygun olması gerektiğini göstermektedir. Ayrıca LSTM'nin gömülü sistemdeki uygulanabilirliği, işlem gücü sınırlamaları nedeniyle kısıtlı kalmaktadır.

Gerçek zamanlı gömülü sistem testleriyle modellerin yalnızca doğrulukları değil; işlem gecikmeleri, sistem kaynaklarına etkisi ve tahmin süreleri de analiz edilmiştir. RF modeli düşük işlem yükü ve yüksek kararlılığı sayesinde gömülü ortam için en uygun yapı olarak öne çıkarken; LSTM gibi derin öğrenme tabanlı modellerin düşük frekansta çalıştırılması gerekmiş, bazı zaman aralıklarında veri kaybına neden olmuştur. Bu sonuçlar, sahada kullanılacak sistemlerin yalnızca doğruluğa değil; aynı zamanda zaman etiketleme, veri tamponlama ve donanıma uyumluluk gibi faktörlere göre tasarlanması gerektiğini göstermiştir.

Bu çalışmanın son bölümünde, geliştirilen yaklaşımın sahaya dönük uygulanabilirliği ve literatürdeki yeri üzerine genel bir değerlendirme yapılmıştır. RF modelinin genellenebilirliği, yorumlanabilirliği ve düşük kaynak ihtiyacı sayesinde gelecekteki çalışmalar için güçlü bir temel sunmaktadır. Geliştirilen sistemin, farklı batarya kimyaları ve çevresel koşullarda test edilmesiyle daha esnek hale getirilebileceği; LSTM ve GRU gibi modellerin ise daha kompakt ve kuantize biçimlere dönüştürülerek gömülü sistemlerde daha verimli çalışabileceği belirtilmiştir. Ayrıca,

uçtan uca otomatik veri toplama, eğitim ve güncelleme sistemlerinin kurulmasıyla modelin uzun vadeli sürdürülebilirliğinin sağlanabileceği sonucuna ulaşılmıştır.

Çalışma boyunca izlenen yol, her bir modelin geliştirilmesinden başlayarak sahada test edilmesine kadar olan tüm süreci kapsamaktadır. Çalışmanın ikinci bölümünde; veri kaynakları, veri yapısı ve ön işleme adımları detaylandırılmaktadır. Üçüncü bölümde SVR, RF ve LSTM algoritmalarının yapısı, avantajları ve bu çalışmada nasıl uygulandıkları anlatılmaktadır. Dördüncü bölümde, eğitilen modellerin hem istatistiksel performansları hem de gömülü sistemdeki gerçek zamanlı test sonuçları sunulmaktadır. Beşinci ve son bölümde ise model karşılaştırmaları yapılmakta ve ileriye dönük uygulanabilirlik önerileri yer almaktadır. Bu yapı, çalışmanın hem teorik derinliğini hem de pratik faydasını ortaya koyarak, benzer amaçlara sahip ileriki araştırmalara yol gösterici olmayı hedeflemektedir.



BATTERY STATE OF HEALTH ESTIMATION BASED ON TEST DATA USING MACHINE LEARNING AND DEEP LEARNING METHODS

SUMMARY

Lithium-ion batteries have become one of the most crucial enablers of the modern energy transition due to their high energy density, extended cycle life, and scalability across various applications. From electric vehicles and portable consumer electronics to renewable energy integration and grid-level storage systems, these batteries serve as a backbone for sustainable power systems. Their efficiency, compactness, and relatively low maintenance requirements have led to widespread deployment across multiple industrial sectors. However, despite their advantages, lithium-ion batteries undergo irreversible degradation processes over time, which reduce their performance, safety, and operational reliability. As battery-powered systems increasingly operate in dynamic and safety-critical contexts, the need for robust methods to monitor and predict battery condition has become paramount. In this regard, the concept of State of Health (SOH) has emerged as a key metric used to quantify battery degradation and determine remaining useful life.

SOH is typically defined as the ratio of the current full charge capacity of a battery to its rated nominal capacity. It provides a percentage-based measure of how much of the original storage capability remains after aging effects have taken place. Accurate estimation of SOH is essential for system-level decision-making, such as load balancing, thermal management, charging optimization, and preventive maintenance scheduling. Moreover, from a safety standpoint, early detection of deterioration can help mitigate the risk of thermal runaway, capacity loss, or sudden failure, especially in high-voltage battery packs used in electric vehicles. Unfortunately, the process of monitoring and estimating SOH presents significant challenges, especially under real-world operating conditions where data is noisy, incomplete, and collected under varying environmental and load profiles.

Traditional SOH estimation methods often rely on full charge-discharge cycles to assess the capacity degradation of a cell or module. While effective under controlled laboratory environments, this approach has multiple drawbacks when applied in practical scenarios. Full cycling is time-consuming, reduces battery availability, and accelerates wear by increasing stress on electrode materials. In addition, real-time systems rarely operate under standardized load profiles that allow such controlled cycling. Moreover, such methods typically fail to account for operational conditions such as varying current rates, ambient and cell temperatures, state-of-charge ranges, and load duty cycles, all of which significantly influence aging mechanisms. As a result, these methods cannot reliably track SOH under actual usage conditions, especially in complex systems with multiple battery modules or large-scale storage arrays.

A widely used method in battery management systems (BMS) is the ampere-hour counting technique, which involves integrating current over time to estimate charge throughput and track remaining capacity. While simple and efficient, this method suffers from several limitations. It is highly sensitive to measurement drift, sensor errors, and cumulative integration inaccuracies. Furthermore, it cannot detect internal

degradation mechanisms such as loss of active material, SEI growth, lithium plating, or structural changes in electrodes. Consequently, ampere-hour counters tend to diverge over time and fail to accurately reflect the health status of the battery without frequent recalibration. These shortcomings have prompted researchers to explore alternative approaches that leverage operational data and intelligent algorithms to infer battery health indirectly.

One promising direction involves the use of data-driven models that employ machine learning algorithms trained on real or simulated battery data. These models can learn complex non-linear relationships between input features and target variables, enabling them to estimate SOH using features derived from current, voltage, temperature, internal resistance, and other signals readily available from the BMS. In this study, a data-driven SOH estimation framework was developed using multiple model types. The experimental dataset used in this research was collected from lithium-ion battery packs, each comprising 108 cells. Two identical packs were used: one for data collection and model training, and the other for independent testing. The tests spanned the entire state-of-charge range from 0 to 100 percent and covered a wide temperature window from -15 to 45 degrees Celsius. No variation in battery chemistry was introduced to ensure that model evaluations were not confounded by differences in material behavior.

The raw data collected consisted of high-frequency time-series measurements of voltage, current, temperature, resistance, and cycle number. To enable efficient model training and minimize computational overhead, a data preprocessing pipeline was applied. The pipeline included anomaly detection to eliminate erroneous samples and summarization techniques to compress time-series segments into statistical features. These features included mean and standard deviation of signals, SOC range, charge duration, and resistance variation. Importantly, the summarization was performed over the 30 to 60 percent SOC interval, as this region is known to exhibit more linear voltage behavior and is less influenced by hysteresis. While summarization significantly reduces the data volume and enables efficient model training, it also results in the loss of temporal structure, which affects models that rely on sequential data.

Three primary machine learning models were selected for training and evaluation: Support Vector Regression (SVR), Random Forest (RF), and Long Short-Term Memory (LSTM) neural networks. SVR showed high predictive performance on summarized features but suffered from limited interpretability and poor generalization to data outside the training domain. RF provided strong accuracy, fast inference, and the ability to quantify feature importance, making it highly suitable for embedded deployment. The LSTM model, designed for time-series tasks, underperformed when applied to summarized inputs, as the lack of sequential context limited its capacity to capture temporal dependencies. Moreover, LSTM models imposed substantial computational requirements, rendering them unsuitable for real-time execution on resource-constrained embedded systems.

Real-time evaluation of the models was carried out on an Infineon-based embedded BMS. Among the three, only the Random Forest model successfully maintained low latency and real-time operation while preserving predictive performance. It seamlessly integrated into the existing BMS architecture and operated across a wide range of conditions without requiring specialized hardware. In contrast, LSTM and SVR models required lower execution frequencies to avoid overloading the processor,

leading to synchronization issues and delayed outputs, which are unacceptable in safety-critical systems.

In addition to the core models, further experimentation was conducted using a simulation-based battery model to evaluate three additional methods: linear regression, Multilayer Perceptron (MLP), and Gated Recurrent Unit (GRU) networks. Linear regression was included as a baseline due to its simplicity, but it failed to capture non-linear aging behaviors and yielded the lowest performance. MLP, a feedforward neural network consisting of multiple hidden layers, performed moderately well and was able to model non-linear interactions between input features and capacity. However, it lacked robustness under variable conditions and required significant hyperparameter tuning. GRU, a simplified variant of LSTM, retained sequential modeling capabilities while reducing computational load. It performed better than MLP and linear regression in simulation and exhibited a favorable trade-off between accuracy and complexity. Nevertheless, since these models were not deployed on physical hardware, their performance under real-time conditions remains to be verified.

Beyond modeling, a deeper understanding of battery degradation mechanisms is essential to contextualize SOH estimation. Degradation processes are typically categorized into calendar aging and cycle aging. Calendar aging arises from chemical reactions that occur during storage, such as SEI layer growth and electrolyte decomposition, even when the battery is not in use. Cycle aging, on the other hand, results from repeated charging and discharging, leading to lithium plating, active material loss, and microstructural damage to electrodes. These changes reduce the number of cyclable lithium ions and increase impedance, leading to capacity fade and voltage instability. Such degradation is influenced by several factors, including C-rate, temperature, depth of discharge, and overcharge or over-discharge events. Importantly, these mechanisms do not produce direct and easily measurable changes, making capacity estimation a complex inferential task.

During each charge-discharge cycle, lithium ions shuttle between the cathode and anode. Over time, the efficiency of this transfer is reduced due to irreversible side reactions. Electrolyte oxidation, SEI thickening, gas generation, and particle isolation further impair the mobility and storage capability of ions. These internal changes are not directly visible in current or voltage readings, which is why advanced analytics are needed to extract degradation signals from indirect indicators such as resistance rise, capacity delay, or SOC hysteresis.

This study demonstrates that machine learning models trained on summarized data can successfully estimate SOH, provided that appropriate features are selected and model architecture is matched to the data structure. Among all models tested, Random Forest proved to be the most effective in balancing accuracy, interpretability, and deployment feasibility. While LSTM and GRU remain promising for raw time-series inputs, their performance is limited when data is summarized or when embedded constraints exist. Future research directions include the exploration of hybrid models that combine physics-based modeling with data-driven learning, deployment of quantized neural networks for embedded inference, and implementation of adaptive pipelines that periodically retrain models using updated operational data. Expanding the dataset to include different battery chemistries and cell formats would also enhance generalizability. Ultimately, robust SOH estimation under embedded constraints is

essential to enable the next generation of intelligent, autonomous, and safe battery systems for a wide range of applications.

To further support practical deployment in safety-critical systems such as electric vehicles and grid-scale storage, explainability and reliability of SOH models must also be addressed. While Random Forest models offer a degree of transparency through feature importance rankings, integrating model uncertainty estimation and anomaly detection mechanisms can enhance trust in predictions. This is especially critical when models encounter out-of-distribution data or operate under rare conditions not captured during training. Embedding self-checking logic and fallback strategies, such as reverting to conservative thresholds or physics-based approximations when confidence is low, can improve robustness and operational safety. As regulatory bodies and industry standards evolve to mandate more rigorous battery diagnostics and safety protocols, the development of certifiable, explainable, and adaptive SOH estimation frameworks will become increasingly vital for commercial adoption and long-term system reliability.



1. GİRİŞ

Uluslararası pazarda yüksek talep gören fosil yakıtlar ve dolaylı olarak artan içten yanmalı motorlu araçlar; sera gazı emisyonları, hava ve ses kirliliği gibi çevre sorunlarını ciddi seviyede arttırmaktadır [1]. Bu durum, elektrikli ve hibrit araçların karayolu taşımacılığında geleceğe yönelik bir çözüm ve odak noktası haline gelmesini sağlamıştır. Böylece elektrikli ve hibrit araçların enerjilerini depolayan bataryalar için ar-ge çalışmaları yeni bir trend haline gelmektedir [2].

Bataryalar, enerjinin kimyasal olarak depolanmasını sağlayan ve bir veya daha fazla elektrokimyasal hücre, yakıt hücresi veya akış hücresinden oluşan depolama birimleridir. Elektrokimyasal yapısı aracılığıyla kimyasal enerjiyi elektrik enerjisine dönüştürürler. Genellikle gerekli gerilime sahip bir batarya dizisi oluşturmak için seri bağlanmış çok sayıda hücre ya da farklı hücre kimyaları ile istenilen uygulamaya uygun bataryalar tasarlanır [3].

Günümüzde; iyi enerji yoğunluğu, iyi bir güce sahip olması ve enerji sistemlerinde şarj/deşarj verimliliği nedeniyle lityum-iyon batarya kimyası en çok tercih edilen batarya teknolojisidir [4]. Lityum-iyon bataryaların kullanım alanlarına bakıldığında güvenli kullanımı, uzun süreli enerji tüketimi, uzun kullanım ömrü ve düşük maliyeti de ayırt edici özellikleri olarak görülmektedir. Bu durum, kullanımını daha popüler hale getirmiştir.

Bataryaların bir kullanım alanı olan elektrikli araçlarda dikkat gerektiren önlemler alınması gerekmektedir. Aşırı şarj ve aşırıdeşarj gibi problemler bataryalar için ciddi güvenlik tehditleri oluşturabilir. Ayrıca potansiyel yangın ve patlama kazalarına sebep olmasının yanında yaşlanma süreçlerini hızlandırabilir. Bataryalar, elektrikli araçlardaki elektrik motoruna ek olarak farklı elektrikli bileşenlere de güç sağlayabilirler. Genellikle sık hızlanma ve yavaşlama ile karakterize edilen bu araçlar karmaşık koşullar altında çalışır ve kullanımındaki şarj-deşarj profilleri öngörülemez olabilir. Operasyonlarının izlenmesi, kontrol edilmesi ve yönetilmesi gerekmektedir.

Bir bataryanın kullanım ömrü boyunca aktivitelerinin kontrol edildiği üniteye batarya yönetim ünitesi (BYÜ) ya da batarya yönetim sistemi (Battery Management System (BMS), BYS) denir.

Uluslararası Elektroteknik Komisyonu (IEC) tarafından 1995 yılında yayınlanan BMS standardına göre şarj durumu görüntüleme, sıcaklık bilgisi, yüksek sıcaklık alarmı, elektrolit bilgisi, performans anormallliği uyarısı, bozulma bilgisi ve önemli veri kaydı gerekli olan işlevlerdir. Elektrikli araçlardaki devrimlerle birlikte BMS'nin standart gereksinimleri de artmaktadır. Günümüzde farklı pillere göre tasarlanan BMS'ler, bataryadan operasyonlarda kullanılacak verilerin toplanmasını sağlar. Verileri kullanarak şarj ve sağlık hesaplamalarında bulunur. Bataryanın içerisindeki hücrelerin gerilimlerinde bir farklılık olduğunda dengeleme işlemini yönetir. Gerilime ek olarak sıcaklık ve termal yönetimi sağlar. Şarj ve deşarj süreçlerini yönetir ve hücrelerin yapılarındaki bozulmaları engellemeye çalışır. Diğer elektrik kontrol üniteleri ile iletişimi sağlar ve ihtiyaca göre bataryanın tüm araca güç sağladığı bağlantıdaki kontaktörleri yönetir. Akım akan hat ile diğer hatlar arasındaki yalıtımı kontrol eder. Bataryanın tüm hatta akım sağlamasından önce gerekli ön şarjı yönetir. Bütün bu görevleri belirli sürelerde gerçekleştirmesi gerekir [6].

BMS'nin yönettiği batarya aktiviteleri esnasında zamanla lityum-iyon pil hücreleri yaşlanarak performans kaybı yaşar. Bu durumun temel sebepleri, şarj ve deşarj işlemleri sırasında lityumun istenmeyen yan reaksiyonlarla tükenmesi ve elektrotlardaki aktif malzemelerin yapısal bozulmasıyla lityum depolama kapasitesinin azalmasıdır. Hücrelerin yaşlanmasıyla birlikte, hücrelerdeki bozulma miktarı artar ve toplam kapasite azalır. Kapasitenin değişimini göz önünde bulundurarak şarj durumu, kullanılabilir enerji ve güç doğru bir şekilde hesaplanabilir. Batarya paketinin sağlığı, genel olarak hücrelerin mevcut toplam kapasiteleri ve eşdeğer seri dirençleriyle ilişkilidir. Bu parametrelerin doğru tahminleri, batarya paketinin ömrü boyunca güvenilir enerji ve güç hesaplamaları yapılmasını sağlar [7].

Kapasitenin ölçülmesi için bir tam şarj – deşarj döngüsünü tamamlamak gerekir. Bu süreç çok uzun sürebilir ve büyük bataryalar için oldukça zordur. Bir elektrikli araç için bir tam şarj – deşarj döngüsünü tamamlamak, aslında doğrudan hesaplama ile kapasitedeki değişimi incelemek pek gerçekçi bir yöntem olmayacaktır. Ayrıca hesaplamalar sırasında sıcaklık önemli bir faktördür ve farklı sıcaklıklarda hesap

yapmak yine ortalama bir elektrikli araç kullanıcısı için gerçekçi olmayacaktır. Buna ek olarak sürekli şarj – deşarj işlemine tabi tutulan bir bataryanın ömrü hızla azalacaktır. Bu nedenlerin hepsi, bataryanın koşullarını göz önünde bulundurup kapasitesini ve dolaylı olarak bataryanın sağlık durumunu (State of Health, SOH) tahmin etmenin gerekliliğini ortaya koymaktadır.

Bu durumdan dolayı birçok sağlık durumu tahmin yöntemi geliştirilmiştir. Batarya sağlık durumu tahmin yöntemleri kabaca üç kategoriye ayrılabilir: doğrudan ölçüm yöntemi, model tabanlı yöntemler ve veri tabanlı yöntemler. Batarya iç direnci ve kapasite verileri batarya performans bozulmasını ve yaşlanma derecesini yansıtabilir ve iç direnç kapasite kaybıyla artar. Doğrudan ölçüm yöntemi, açık devre voltajı veya batarya iç direnci ile batarya SOH arasındaki ilişkiyi tanımlayan bir tablolarla batarya SOH değerini tahmin eder. Doğrudan ölçüm yönteminin uygulanması nispeten basittir, ancak yüksek hassasiyetli ölçüm aletlerine ve sıkı test prosedürlerine dayanır. Model tabanlı yöntem, eşdeğer devre modelleri, elektrokimyasal modeller, mekanizma modelleri vb. gibi pillerin fiziksel denklem modellerini oluşturmak için deneysel veya toplanmış verileri kullanan batarya SOH değerini tahmin etmek için yaygın olarak kullanılan bir yöntemdir. Daha sonra bu modellerin parametrelerini batarya yaşlanma sürecine göre günceller ve batarya SOH değerini analiz eder veya modeller. Model tabanlı yaklaşımın çok çeşitli uygulamaları olmasına rağmen, tahmin doğruluğu model parametrelerinin zamanında ve doğru bir şekilde güncellenip güncellenemeyeceğiyle yakından ilgilidir. Veri odaklı yöntemler, bataryanın iç yapısını ve çalışma prensibini anlamayı gerektirmez. Rutin veya deneysel ölçümlerden toplanan veri örneklerine dayanarak modellerini oluştururlar. Yaygın veri odaklı yöntemler arasında Kalman filtresi yöntemi, makine öğrenmesi yöntemi vb. bulunur. Kalman filtresi yöntemi, sinyaldeki gürültü girişimini etkili bir şekilde ortadan kaldırabilen ve eksik ve gürültülü verilere dayanarak batarya SOH değerini tahmin edebilen verimli bir öz-uyarlamalı filtreleme yöntemidir [8]. Kalman algoritması SOH tahmininde iyi bir performans göstermektedir, ancak dezavantajı hesaplama açısından karmaşık olması ve yüksek uygulama maliyetine sahip olmasıdır.

Bu çalışmada ise bataryanın sağlık durumunu tahmin edebilmek için veri odaklı bir yaklaşım izlenecektir. Bataryadan elde edilen sıcaklık, akım, voltaj, şarj durumu (SOC), hücre iç direnci ve çevrim sayısı gibi parametreler kullanılarak Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM), Rastgele Ormanlar (Random

Forest, RF) ve Destek Vektör Regresyonu (Support Vector Regression, SVR) gibi algoritmalar ile bir tahmin modeli geliştirilecektir. Bu model, hem hücre seviyesinde oluşturulan batarya modeli üzerinde hem de gerçek batarya paketlerinden elde edilen deneysel verilerle test edilecektir. Böylece algoritmaların doğruluğu, genellenebilirliği ve uygulamaya uygunluğu karşılaştırmalı olarak değerlendirilecektir.

Çalışma kapsamında özellikle yaşlanma etkisiyle değişen parametrelerin tahmin performansına etkisi incelenerek, pratikte uygulanabilir, güvenilir ve gerçek zamanlı kullanılabilecek bir tahmin yapısının temelleri atılacaktır. Literatürde yapılmış yakın tarihli çalışmalardan bahsedilmesinin ardından ikinci bölümünde bataryaların modellenmesi konusu hakkında bilgi verilecektir. Üçüncü bölümde bu çalışmada karar kılınan tahmin yöntemlerin içeriği anlatılacaktır. Ardından dördüncü bölümde verilerin elde edilmesi, tahmin algoritmalarının seçimi ve oluşturulması ve sonuçlardan bahsedilecek son olarak beşinci bölümde sonuçların karşılaştırılması ve çalışmanın devamı niteliğindeki çalışmalarda dikkate alınacak önerilere yer verilmiştir.

1.1 Literatür Taraması

Zhou ve arkadaşları [9], hızlı şarj koşullarında (3.6C–8C) çalışan lityum iyon pillerin sağlık durumu (SOH) tahminini iyileştirmek amacıyla birleşik bir derin öğrenme modeli önermiştir. Model, yerel veri desenlerini yakalamada evrimsel sinir ağlarını, zaman serisindeki uzun vadeli bağımlılıkları öğrenmede ise çok başlı dikkat mekanizmasını (verinin farklı bölümlerine aynı anda odaklanarak karmaşık ilişkileri analiz edebilen yapı) bir arada kullanmaktadır. 222 adet LFP hücresinden elde edilen 146.074 döngülük veriyle eğitilen sistem, yalnızca %80–97 arasındaki sınırlı bir şarj seviyesi aralığında veri kullanarak yüksek doğrulukla tahmin yapabilmektedir. Modelin performansı; ortalama mutlak yüzde hatası (MAPE) 3,89 mAh, kök ortalama kare hatası (RMSE) 4,79 mAh ve belirleme katsayısı (R^2) 0,97 olarak raporlanmıştır. Veri işleme aşamasında enterpolasyon, diferansiyel özellik çıkarımı ve kayan pencere gibi teknikler kullanılarak giriş verilerinin bilgi yoğunluğu artırılmıştır. Ayrıca, transfer öğrenme yöntemiyle modelin farklı veri kümelerine karşı genellenebilirliği güçlendirilmiştir. Geliştirilen bu hibrit yaklaşım, geleneksel yöntemlere kıyasla daha esnek, daha doğru ve hızlı şarj koşullarına uyum sağlayabilen bir SOH tahmin çözümü sunmaktadır [9].

Wang ve arkadaşları [10], lityum iyon pillerin sağlık durumu (SOH) tahmini için, gelişmiş özellik mühendisliği ve klasik makine öğrenmesi yöntemlerini birleştiren bir yaklaşım önermiştir. Çalışmada, batarya döngü verilerinden elde edilen gerilim, sıcaklık ve iç direnç gibi çok boyutlu ölçümlerden 65'ten fazla özellik türetilmiş ve bunlar, yinelemeli özellik eleme (RFE) yöntemi ile önemsiz olanlar elenerek optimize edilmiştir. Elde edilen öznetelik kümesi, destek vektör regresyonu (SVR), rastgele orman (RF) ve aşırı gradyan artırma (XGBoost) gibi çeşitli algoritmalarla test edilmiştir. Yapılan karşılaştırmalarda, XGBoost modeli hem tahmin doğruluğu hem de hesaplama verimliliği açısından en iyi performansı göstermiştir. Modelin başarı metrikleri RMSE: 0.0156, MAE: 0.0114 ve R^2 : 0.982 olarak raporlanmış, bu da modelin yüksek isabetle SOH tahmini yapabildiğini göstermektedir. Ayrıca, min-maks normalizasyonunun model başarısına olumlu etkisi olduğu vurgulanmıştır. Çalışma, yüksek doğruluklu tahminlerin yalnızca derin öğrenme ile değil, uygun özellik çıkarımı ve model seçimiyle geleneksel yöntemler aracılığıyla da elde edilebileceğini göstermesi açısından dikkat çekicidir. Bu durum, özellikle gömülü sistem gibi kaynak kısıtlı ortamlarda klasik yöntemlerin pratik bir alternatif olabileceğini ortaya koymaktadır [10].

Xu ve arkadaşları [11], lityum-iyon pillerin sağlık durumu (SOH) tahmininde doğruluğu artırmak amacıyla uzun kısa süreli bellek (LSTM) tabanlı bir model geliştirmiştir. Çalışmanın temel katkısı, giriş verilerinin eğilim özellikleri (trend features) ve eğilim dışı özellikler (non-trend features) olarak ayrıştırılması ve bu özelliklerin farklı biçimlerde işlenerek modele entegre edilmesidir. Eğilim dışı özelliklerden, zaman ve örnek bağıntılarını daha etkin biçimde ortaya çıkarmak amacıyla uzamsal-zamansal dikkat (spatio-temporal attention) mekanizmasıyla temsil öğrenilmiştir. Ardından bu temsil, eğilim özellikleriyle birleştirilerek uzun kısa süreli bellek (LSTM) modeline girdi olarak verilmiştir. Model, hem NASA hem de CALCE veri setlerinde test edilmiş ve yüksek doğrulukla SOH tahmini yapabirmiştir. NASA veri seti için kök ortalama kare hatası (RMSE) 0.0089, ortalama mutlak hata (MAE) 0.0067; CALCE veri seti için ise RMSE 0.0107 ve MAE 0.0084 olarak elde edilmiştir. Bu oldukça düşük hata oranları, modelin hem doğruluk hem de genellenebilirlik açısından güçlü bir performans sunduğunu göstermektedir. Önerilen yaklaşım, klasik uzun kısa süreli bellek (LSTM) yapılarının ötesine geçerek giriş verilerinin yapısal karakteristiklerini dikkate almakta ve dikkat mekanizması sayesinde farklı zaman

noktaları arasındaki ilişkileri önceliklendirerek öğrenme sürecini derinleştirmektedir. Sonuç olarak çalışma, SOH tahmini konusunda LSTM mimarisinin dikkat mekanizmasıyla birlikte kullanımının etkili bir çözüm sunabileceğini göstermektedir.

Lanubile ve arkadaşları [12], lityum-iyon bataryaların sağlık durumu (SOH) tahmini için fiziksel bilgilere dayalı, çevrimiçi uygulanabilir ve yorumlanabilir bir denetimli makine öğrenmesi modeli geliştirmiştir. Çalışmada, bataryaların enerji ve güç kayıplarını yansıtan beş adet sağlık göstergesi tanımlanmış; bu göstergeler, yol sürüşü sırasında elde edilen akım, gerilim ve sıcaklık verilerinden çevrimiçi olarak hesaplanabilir hale getirilmiştir. Bu fiziksel göstergeler, doğrusal regresyon modeliyle işlenerek SOH tahmini gerçekleştirilmiştir. Model, İtalya'daki gerçek sürüş koşullarında yaşlandırılmış beş farklı hücre ile test edilmiş ve ortalama yüzde hata yaklaşık %1.0, maksimum mutlak hata ise %1.5–2.5 aralığında ölçülerek yüksek doğruluk elde edilmiştir. Ayrıca tahminler, $R^2 > 0.98$ düzeyinde korelasyon göstermiştir. Modelin özellikle düzensiz ve eksik veri içeren sahada uygulanabilirliği, yorumlanabilirliği ve hesaplama verimliliği ile ön plana çıktığı belirtilmiştir. Bu yönüyle çalışma, geleneksel veri odaklı yöntemlerin ötesine geçerek, fiziksel bilgi ile yönlendirilmiş makine öğrenmesi yaklaşımlarının batarya yönetim sistemlerine entegrasyonu açısından literatüre önemli bir katkı sunmaktadır.

Wang ve Zhang [13], lityum-iyon pillerin kalan ömrünü doğru tahmin edebilmek için Genişletilmiş Kalman Filtresi (EKF) ile Newton-Raphson yöntemini birleştiren hibrit bir yöntem geliştirmiştir. Model, hızlı şarj koşullarında çalışan LFP/karbon hücreler üzerinde test edilmiş ve geleneksel doğrusal regresyon yöntemine kıyasla önemli performans iyileştirmeleri sağlamıştır. 100 döngülük testlerde, önerilen yöntemin kök ortalama kare hatası (RMSE) değeri 10.93, maksimum yüzde hatası ise %3.26 olarak ölçülmüştür; bu değerler, karşılaştırmalı doğrusal regresyon modelinin kök ortalama kare hatası 211 ve %9.1 hata oranından oldukça düşüktür. Bu sonuçlar, fiziksel modelleme ile sayısal çözüm yöntemlerinin birleşiminin sağlık durumu (SOH) tahmininde yüksek doğruluk sağladığını göstermektedir.

Li ve Chen [14], lityum-iyon pillerin sağlık durumu (SOH) tahmini için çift adaptif Unscented Kalman Filtresi (DAUKF) ile Coulomb (AH) sayımı yöntemini birleştiren bir yaklaşım sunmuştur. Model, değişken sıcaklıklar ve dinamik sürüş koşullarında dahi kararlı tahmin performansı gösterecek şekilde yapılandırılmıştır. DAUKF, hem

model hem de ölçüm belirsizliklerini dinamik olarak güncelleyerek, Coulomb sayımının hata biriktirme problemini telafi etmektedir. Yapılan testlerde modelin tahmin hatasının düşük düzeyde kaldığı ve veri kaybı veya ölçüm gürültüsü gibi durumlara karşı dayanıklı olduğu raporlanmıştır. Bu yönüyle çalışma, gerçek zamanlı gömülü uygulamalar için güçlü bir çözüm sunmaktadır.

Zhang ve Liu [15] ise Genişletilmiş Kalman Filtresi ile AH sayımını birleştirerek, ikinci dereceden RC eşdeğer devre modeline dayalı bir sağlık durumu (SOH) tahmin sistemi geliştirmiştir. Model, MATLAB/Simulink ortamında hem benzetim hem de deneysel verilerle test edilmiştir. Çalışma, özellikle düşük şarj durumu (SoC) aralıklarında bile tahmin doğruluğunu koruyarak, pilin yaşlanma sürecini başarılı şekilde takip edebilmiştir. Elde edilen sonuçlar, modelin şarj durumu (SoC) ve sağlık durumu (SOH) tahminlerinde yüksek doğruluk sağladığını ve sistemin gömülü uygulamalarda kullanılabilir düzeyde gerçek zamanlı çalışabileceğini ortaya koymuştur. Bu, Genişletilmiş Kalman Filtresi ve AH sayımı gibi klasik yöntemlerin hâlen rekabetçi olduğunu göstermektedir.

Beckers ve arkadaşları [16], lityum-iyon bataryaların sağlık durumunu değerlendirmek üzere, batarya kapasitesi ve iç direnç gibi yaşlanma göstergelerinin çevrimiçi tahmini için Genişletilmiş Kalman Filtresi (EKF) ile Recursive Least Squares (RLS) yöntemlerini birleştiren bir algoritma önermiştir. Model, minimal ön parametreleme gereksinimi ile, bataryaların gerçek zamanlı gömülü uygulamalarda izlenmesini hedeflemektedir. Donanım-İçerikli Simülasyon (HiL) ortamında gerçekleştirilen deneylerde, yaşlanmış ve yaşlanmamış farklı hücreler test edilmiştir. Algoritma, kapasite değerlerinde yaşa bağlı azalma eğilimlerini ve iç dirençteki artışı tutarlı biçimde yakalamış, hücreler arasındaki performans farklılıklarını hassas şekilde ayırt edebilmiştir. Sonuçlar, özellikle nominal kapasiteye göre %10'un üzerinde kayıp olan hücrelerin doğru sınıflandırıldığını ve iç dirençteki artışın gerçek ölçümlerle yüksek oranda uyumlu tahmin edildiğini göstermiştir. Bu yönüyle çalışma, yüksek doğrulukla ve düşük yapılandırma maliyetiyle çalışan çevrimiçi bir sağlık durumu (SOH) tahmin mekanizması sunarak, ticari batarya yönetim sistemlerine entegrasyona uygun pratik bir çözüm ortaya koymaktadır.

Ruan ve arkadaşları [17], lityum-iyon pillerin sağlık durumu (SOH) tahmini için yaşlanma modeli temelli bir veri füzyon yöntemi geliştirerek bunu partikül filtresi (PF)

algoritması ile entegre etmiştir. Çalışmada, bataryaların içsel parametrelerini (örneğin kapasite kaybı ve iç direnç artışı) izleyebilen yaşlanma modeli, PF algoritmasıyla birleştirilmiş ve veri füzyonu sayesinde hem model hem de ölçüm belirsizlikleri dengelenmiştir. Bu yöntem, farklı koşullarda test edilen dört ayrı lityum-iyon hücre paketi üzerinde uygulanmıştır. Elde edilen sonuçlara göre, önerilen model, SOH tahmininde ortalama yüzde hata (MAPE) bakımından %1.62 seviyesinde kalırken, kök ortalama kare hatası (RMSE) ise 0.012 gibi düşük bir değerde gerçekleşmiştir. Ayrıca, önerilen veri füzyon sistemi geleneksel PF ve yaşlanma modellerine göre daha kararlı ve doğru tahminler sağlamıştır. Modelin modüler yapısı sayesinde, farklı batarya türlerine kolaylıkla uyarlanabileceği ve gerçek zamanlı uygulamalarda kullanılabileceği belirtilmiştir. Çalışma, özellikle dinamik kullanım koşullarında batarya yaşlanmasının etkili bir şekilde izlenmesini sağlayarak, partikül filtresi tabanlı sağlık durumu (SOH) tahmini yöntemlerinin doğruluğunu ve uygulama potansiyelini önemli ölçüde artırmaktadır.

Li ve arkadaşları [18], lityum-iyon pillerin sağlık durumu (SOH) tahmini için çoklu sağlık göstergeleri ve Savitzky–Golay filtresi ile işlenmiş verileri kullanan bir yaklaşım geliştirmiştir. Bu yöntemde, pilin şarj ve deşarj verilerinden altı farklı sağlık göstergesi çıkarılmış ve bu göstergeler, veri kümesindeki gürültüyü azaltmak için Savitzky–Golay filtresi ile işlenmiştir. Elde edilen özellikler, Lévy roulette ve fitness-distance balance stratejileriyle geliştirilmiş çakal optimizasyon algoritması (COA) kullanılarak optimize edilmiş ve bu optimize edilmiş özellikler, uzun kısa süreli bellek (LSTM) sinir ağına girdi olarak verilmiştir. Model, farklı test koşullarında elde edilen pil verileriyle değerlendirildiğinde, maksimum R^2 değeri 0.9896 ve minimum R^2 değeri 0.9711 olarak ölçülmüş, bu da yüksek tahmin doğruluğunu göstermektedir. Bu çalışma, özellikle veri ön işleme ve özellik optimizasyonunun, geleneksel uzun kısa süreli bellek (LSTM) modellerinin tahmin performansını nasıl artırabileceğini ortaya koymaktadır.

2. BATARYALARIN MODELLENMESİ


Son yıllarda, bataryaların yük altındaki kapasite kaybını ve çalışma profillerini analiz etmek amacıyla elektrokimyasal modeller ve eşdeğer devre modelleri (EDM) dahil olmak üzere çeşitli yöntemler geliştirilmiştir. Eşdeğer devre modelleri; hızlı yanıt verebilmeleri, kolay anlaşılabilir olmaları ve belirli doğruluk seviyeleri sunmaları sayesinde birçok batarya uygulamasında yaygın olarak kullanılmaktadır. Yine de batarya çalışma sınırlarına yaklaşıldığında EDM'ler daha geniş çalışma koşullarını temsil etmede yetersiz kalabilir ve bu durum modelin ekstrapolasyon yaparken doğruluğun düşmesine neden olur. Bu nedenle EDM'ler, yüksek akım ya da çok düşük sıcaklık gibi uç çalışma koşullarında tercih edilmez. Elektrokimyasal modeller (EKM) ise genellikle daha yüksek doğruluk sunar; ancak yüksek hesaplama gücü gerektirdiklerinden, gerçek zamanlı uygulamalar için çoğu zaman uygun değildir.

2.2 Elektrokimyasal Devre Modeli

Batarya tasarımı ve performans tahmininden devre simülasyonuna kadar belirli amaçlar için batarya davranışını yakalayan farklı batarya modelleri geliştirilmiştir. Elektrokimyasal devre modeli, aslında bataryaların fiziksel tasarım yönlerini optimize etmek için kullanılır, güç üretiminin temel mekanizmalarını karakterize eder ve batarya tasarım parametrelerini makroskobik (örneğin, pil voltajı ve akımı) ve mikroskobik (örneğin, konsantrasyon dağılımı) bilgilerle ilişkilendirir. Aynı zamanda, birleştirilmiş zamana bağlı mekansal kısmi diferansiyel denklemler sistemi içerdikleri için karmaşık ve zaman alıcıdır. Günlerce süren simülasyon süresi ve karmaşık sayısal algoritmalar nedeniyle batarya özelinde bilgi elde etmek ve EKM açısından modellemesi oldukça zordur [19].

Çalışan bir lityum iyon hücrenin içerisinde elektrot ve elektrolit içindeki lityum iyonlarının taşınması, difüzyonu ve katı-elektrolit arayüzündeki reaksiyonlar dahil olmak üzere karmaşık kimyasal reaksiyonlar meydana gelir. Sekil 2.1'de görüldüğü gibi hücrenin içinde meydana gelen süreçlere dayanarak oluşturulan elektrokimyasal

model, çalışma halindeki lityum iyon hücrenin içindeki dahili değişiklikleri doğru bir şekilde tanımlayabilir, bu nedenle yaygın olarak kullanılmıştır.



Şekil 2.1 : DL ve SEI içeren elektrokimyasal modelin yapısı [20]

Elektrokimyasal modelin kökeni olan P2D (Pseudo-Two-Dimensional) modeli, gözenekli elektrot ve konsantre çözelti teorisine dayalı formüllerle lityum iyon bataryanın içindeki çalışma süreçlerini ayrıntılı olarak açıklamıştır. Bu model, her iki elektrotun ve aradaki ayırıcı bölgenin gözenekli yapısını dikkate alır. Konsantre çözelti teorisini temel alarak, elektrolit içindeki iyon taşınımı, potansiyel dağılımı ve konsantrasyon gradyanlarını hesaba katar. Bu yapı sayesinde P2D modeli, pilin şarj-deşarj sırasında yaşadığı fiziksel ve kimyasal değişimleri doğru şekilde simüle edebilir; bu da onu hem temel araştırmalarda hem de pil yönetim sistemleri için referans bir model haline getirir. P2D modelinin modelleme süreci tarafından yönlendirilen iyileştirilmiş veya basitleştirilmiş elektrokimyasal modeller, batarya terminal voltajı simülasyonunda ve batarya durumu tahmininde yaygın olarak kullanılmıştır [20].


Elektrokimyasal modelin kökeni olan P2D (Pseudo-Two-Dimensional) modeli, gözenekli elektrot ve konsantre çözelti teorisine dayalı formüllerle lityum iyon bataryanın içindeki çalışma süreçlerini ayrıntılı olarak açıklamıştır. Bu model, her iki elektrotun ve aradaki ayırıcı bölgenin gözenekli yapısını dikkate alır. Konsantre çözelti teorisini temel alarak, elektrolit içindeki iyon taşınımı, potansiyel dağılımı ve konsantrasyon gradyanlarını hesaba katar. Bu yapı sayesinde P2D modeli, pilin şarj-deşarj sırasında yaşadığı fiziksel ve kimyasal değişimleri doğru şekilde simüle edebilir; bu da onu hem temel araştırmalarda hem de pil yönetim sistemleri için referans bir model haline getirir. P2D modelinin modelleme süreci tarafından yönlendirilen iyileştirilmiş veya basitleştirilmiş elektrokimyasal modeller, batarya terminal voltajı simülasyonunda ve batarya durumu tahmininde yaygın olarak kullanılmıştır [20].

2.3 Eşdeğer Devre Modeli

Doğruluğu elektrokimyasal modeller kadar olmayan eşdeğer devre modeli, diğer elektrik devreleri ve sistemleri ile birlikte incelenebilmek için voltaj kaynakları, dirençler ve kapasitörlerin bir kombinasyonu ile oluşturulan modellerdir [21]. EDM'ler, basitlik, işleme kolaylığı ve orta düzeyde hesaplama gereksinimleri dahil olmak üzere çeşitli avantajlar sunar. Rint modeli, RC modeli, Thevenin modeli ve DP modeli gibi çeşitli EDM türleri mevcuttur. Polarizasyon davranışını temsil eden paralel RC çiftlerinin sayısı arttıkça modelin doğruluğu artar. Ancak, böyle bir modelin parametrelerini belirlemek daha fazla zaman alır hale gelir ve bu da BMS tasarımı için pratik olmaz [22].

2.3.1 Rint modeli

Rint modeli, bataryanın açık devre gerilimini tanımlamak için ideal bir gerilim kaynağı olan U_{ocv} 'yi kullanır [23]. Rint modeli devre elemanlarıyla birlikte şekil 2.2' de gösterilmektedir. Hem iç direnç (R_0) hem de açık devre gerilimi (U_{oc}), bataryanın şarj durumu, sağlık durumu ve sıcaklığın bir fonksiyonudur. Yük akımı (I_L)deşarj sırasında pozitif, şarj sırasında negatiftir. Terminal (uç) gerilimi ise U_L ile gösterilir.



Şekil 2.2 : Devre elemanlarıyla Rint modelinin gösterimi


Rint modeli ohm yasasını esas alır. Buna göre Rint modelinin formülü denklem 2.1 ile gösterilmektedir.

$$U_L = U_{OCV} - I_L \cdot R_o \quad (2.1)$$

Bataryanın sağlık ve şarj durumu ile sıcaklık değerleri deneysel yollarla elde edilir ve modele entegre edilir. Bu değerlerin dolaylı olarak modelde kullanılması bataryanın yaşlanmasının ve termal etkileri tam anlamıyla yansıtamamasına yol açar. Ayrıca polarizasyon ve kapasitif etkiler de modelde olmadığı için ani yük değişimlerini ve gecikmeleri yansıtmaz.

2.3.2 Thevenin modeli

Thevenin modeli, anlık (ohmik) ve gecikmeli (kapasitif) gerilim değişimlerini temsil eden, Rint modeline göre daha gelişmiş bir eşdeğer devre modelidir. Bu model, Rint modelindeki dirence seri bağlanan paralel bir devre olan RC devresi ekleyerek yapılandırılır [23]. Böylece bataryanın elektriksel davranışını daha doğru simüle eder. Ohmik kayıplar ile birlikte, polarizasyon etkileri ve şarj-deşarj döngüsünde oluşacak geçici tepkilerin de sonuçlarının görülebileceği bir model haline gelir. Bu modellemeye ait devre şeması şekil 2.3' de gösterilmektedir.



Şekil 2.3 : Devre elemanlarıyla Thevenin modelinin gösterimi

Burada uç terminal değeri (U_L); açık devre gerilimi (U_{OCV}), devreden geçen akım (I_L), bataryanın iç direnci (R_0) ve RC devresinin iki ucu arasındaki gerilim (U_{Th}) üzerinden denklem 2.2’de görüldüğü gibi hesaplanır.

$$U_L(t) = U_{OCV} - I_L(t) \cdot R_0 - U_{Th}(t) \quad (2.2)$$


RC devresi üzerinde oluşan gerilim ($U_{Th}(t)$), yük değişimine karşı oluşan gecikmeli voltaj tepkisini modellemek için polarizasyon direnci (R_{Th}), polarizasyon kapasitörü (C_{Th}) ve RC devresi üzerinden akan toplam akım (I_L) ile denklem 2.3’de görüldüğü gibi formülize edilir.

$$\frac{dU_{Th}(t)}{dt} = -\frac{1}{R_{Th} \cdot C_{Th}} \cdot U_{Th}(t) + \frac{1}{C_{Th}} \cdot I_L(t) \quad (2.3)$$

2.3.3 Çift polarizasyon modeli

Bir lityum-iyon bataryanın karakteristik test analizinde, polarizasyon davranışı net bir şekilde gözlemlenmiştir [23]. Thevenin modeli bu polarizasyonu bir düzeye kadar simüle edebilse de konsantrasyon polarizasyonu ile elektrokimyasal polarizasyon arasındaki fark nedeniyle, özellikle şarj veya deşarjın döngüsünün sonlarına doğru

simülasyon doğruluğu yetersiz kalmaktadır. Bu nedenle, polarizasyon karakteristiklerini daha hassas şekilde tanımlayabilen, konsantrasyon ve elektrokimyasal polarizasyonu ayrı ayrı simüle edebilen geliştirilmiş çift polarizasyon modeli önerilmiştir. Çift Polarization modeli, Thevenin modelinin genişletilmiş bir versiyonudur. Bataryanın daha gerçekçi dinamik davranışlarını modellemek amacıyla iki farklı zaman sabitine sahip RC devresi içerir. Bu yapı, hem ani hem de geçici yanıtları temsil ederek, bataryanın şarj ve deşarj döngüsündeki karmaşık gerilim tepkilerini daha doğru biçimde modellemeyi sağlar [23].



Şekil 2.4 : Devre elemanlarıyla Çift Polarizasyon modelinin gösterimi

Şekil2.4’de görüldüğü üzere terminal gerilimi (U_L); açık devre gerilimi (U_{OCV}), iç direnç üzerindeki gerilim ($I_L(t) \cdot R_0$) ve RC ağları üzerindeki gerilimler ($U_1(t)$ ve $U_2(t)$) ile modellenir. Bu modele ait formül denklem 2.4’de gösterilmektedir.

$$U_L(t) = U_{ocv}(t) - I_L(t) \cdot R_0 - U_1(t) - U_2(t) \quad (2.4)$$


Her bir RC devresi için gerilim modeli de denklem 2.5’de gösterilmektedir.

$$\frac{dU_1(t)}{dt} = -\frac{U_1(t)}{R_1 \cdot C_1} + \frac{I_L(t)}{C_1}$$

$$\frac{dU_2(t)}{dt} = -\frac{U_2(t)}{R_2 \cdot C_2} + \frac{I_L(t)}{C_2}$$
(2.5)

2.3.4 Yüksek mertebeli eşdeğer devre modeli

Yüksek sıcaklık değişimleri, yaşlanma etkileri veya uzun süreli yükleme senaryolarında oluşan geçici gerilim tepkileri hem hızlı hem de yavaş dinamik bileşenler içerdiğinden, daha fazla zaman sabiti gerektiren sistem davranışları doğurur. Bu nedenle 2 RC devresinden daha çok mertebeli modeller gerçeği daha iyi temsil etmektedir ancak mertebenin çok fazla artırılması hesaplamayı zorlaştıracaktır [24]. Bu nedenle gerçeğe daha yakın olması beklenen yüksek mertebeli eşdeğer devre modellerinden biri de 3 RC devresi içeren eşdeğer devre modelidir. Üçüncü mertebeli eşdeğer devre modeli, şekil 2.5’de görülebilmektedir.



Şekil 2.5 : Yüksek mertebeli eşdeğer devre modelinin gösterimi

Buradaki uç gerilimi çift polarizasyon modelindeki olduğu gibi seri bağlı RC devrelerinin gerilimi ($U_1(t)$, $U_2(t)$ ve $U_3(t)$), eşdeğer iç direncin üzerindeki gerilim ($I_L(t) \cdot R_0$) ve açık devre gerilimi üzerinden (U_{OCV}) denklem 2.6’da gösterildiği gibi hesaplanmaktadır.

$$U_L(t) = U_{ocv}(t) - I_L(t) \cdot R_0 - U_1(t) - U_2(t) - U_3(t) \quad (2.6)$$

Yine çift polarizasyon modeline benzer şekildeki gerilimlerin formülleri burada da her bir RC devresi için de denklem 2.7’de gösterilmektedir.

$$\begin{aligned} \frac{dU_1(t)}{dt} &= -\frac{U_1(t)}{R_1 \cdot C_1} + \frac{I_L(t)}{C_1} \\ \frac{dU_2(t)}{dt} &= -\frac{U_2(t)}{R_2 \cdot C_2} + \frac{I_L(t)}{C_2} \\ \frac{dU_3(t)}{dt} &= -\frac{U_3(t)}{R_3 \cdot C_3} + \frac{I_L(t)}{C_3} \end{aligned} \quad (2.7)$$

3. BATARYALARIN SAĞLIK DURUMU TAHMİNİ

Bir lityum-iyon batarya hücresi, temel 4 parçadan oluşmaktadır: katot elektrot, anot elektrot, elektrolit ve bir ayırıcı (separator). Lityum iyonlarının şarj ve deşarj döngüsünde hareket ettiği aktif malzemeleri elektrotlar içerir. Katot elektrotlar, lityum metal oksitler (LCO, NMC, NCA gibi bileşikler) gibi pozitif elektrot malzemelerden; anot elektrotlar, çoğunlukla grafit gibi karbon bazlı malzemelerden elde edilir [25]. Elektrolit, katot ve anot elektrot arasında iyonların taşınmasını sağlar. Çoğunlukla organik çözücüler içerisinde çözülmüş lityum tuzlarından oluşur. Ayırıcı ise, kısa devre riskini önlemek amacıyla elektrotların doğrudan temasını engeller. Aynı zamanda iyonların serbestçe geçişine izin veren bir yapıdadır. Hücrenin çalışma döngüsünde, şarjdayken lityum iyonları katottan ayrılarak elektrolit üzerinden anoda göç eder; deşarjdayken de anottan ayrılarak katoda göç eder. Elektrot malzemelerin iyon transfer kabiliyeti ve stabilitesi, hücrenin ömrünü ve güvenliğini doğrudan etkiler. Bu nedenle elektrot malzemeleri; enerji yoğunluğu, güç kapasitesi, ömrü ve termal güvenliği üzerinde belirleyici bir rol oynamaktadır.

Katottan metal çözünmesi ve çözünen metallerin anot üzerinde birikmesi, ayrıca katottaki lityum iyonların hareketleri sonucu oluşan deformasyon hücrenin yaşlanmasını sağlamaktadır [26]. Ayrıca anot tarafında katı elektrolit ara fazı (Solid Electrolyte Interphase, SEI) oluşumu ve büyümesi sonucu geri kazanılabilir lityum iyonların kaybı da yaşlanmayı sağlar. Böylece uzun kullanımlar sonucu elektrot malzemeler yaşlanır. Böylece hücrenin kapasitesini düşer, iç direnci artar ve hücrenin performansı ciddi şekilde etkilenir.

Bu bağlamda, bir batarya hücresinin zamanla maruz kaldığı fiziksel ve kimyasal değişimlerin performans üzerindeki etkisini niceliksel olarak izleyebilmek için kapasite ve sağlık durumu ölçümleri kritik öneme sahiptir. Kapasite ölçümü, bataryanın şarj veya deşarj süreci boyunca taşıdığı toplam elektriksel yük miktarının belirlenmesine dayanır. Sabit akım koşulu altında bu hesaplama doğrudan akım ile zamanın çarpımıyla elde edilebilirken, değişken akım altında ise akım-zaman

verilerinin integrali alınarak kapasite hesaplanır [27]. Özellikle şarj sırasında, zamana karşı değişen akım değerlerinin integrali bataryaya aktarılan toplam yük miktarını verir ve bu değer amper-saat (Ah) cinsinden kapasiteyi temsil eder. Hücre yeni iken ölçülen kapasite, referans (nominal kapasite) alınarak sonraki döngülerde hesaplanan kapasite değerleriyle karşılaştırılır ve böylece zamanla yaşlanmanın etkisi takip edilir. Sağlık durumu ise, mevcut kapasitenin başlangıç kapasitesine oranlanmasıyla elde edilir ve yüzde cinsinden ifade edilir. Kapasite azalması ve iç direnç artışı gibi parametreler, yalnızca enerji sağlayabilme yetisini değil, aynı zamanda hücrenin güvenli çalışma sınırlarını da belirler. Bu nedenle, kapasite ve sağlık durumu ölçümleri, hem batarya yönetim sistemleri tarafından sürekli izlenmekte hem de batarya ömrü ve güvenliği açısından temel performans göstergeleri olarak değerlendirilmektedir.

Amper-saat sayımı yöntemi, bir bataryanın şarj ve deşarj sürecinde taşıdığı toplam elektrik yükünü hesaplamak amacıyla kullanılan temel bir tekniktir [28]. Bu yöntem, bataryadan geçen akımın zamanla çarpımının toplanması esasına dayanır. Denklem 3.1’de gösterildiği üzere bataryanın kapasitesi, birim olarak amper-saat cinsinden ifade edilir ve bu kapasite, belirli bir zaman aralığında batarya üzerinden geçen akım miktarının toplamı olarak elde edilir.

$$Q = \int_{t_0}^{t_1} I(t)dt \quad (3.1)$$

Burada Q , bataryanın taşıdığı toplam elektrik yükünü; $I(t)$, zamana bağlı olarak değişen akımı; t_0 ve t_1 ise işlemin başlangıç ve bitiş zamanlarını temsil eder. Bu formül, sürekli ölçüm sistemlerinde doğrudan uygulanabilir. Pratikte ise veriler örneklenir ve sürekli değil ayırık bir sistem gibi incelenir bu nedenle denklem 3.2’de görüldüğü şekline dönüşür.

$$Q = \sum_{k=1}^n I_k \cdot \Delta t \quad (3.2)$$

Bu eşitlikte I_k , her bir örnekleme anında ölçülen akım değerini; Δt ise iki ölçüm arasındaki zaman farkını belirtir. Bataryaya aktarılan toplam yük miktarı ve dolayısıyla kapasite bu formülle hesaplanabilir.

Amper-saat sayımı yöntemi, özellikle batarya yönetim sistemlerinde tercih edilir çünkü yapısı basittir, hesaplama gücü gereksinimi düşüktür ve gerçek zamanlı

uygulamalara uygundur ancak bu yöntemin bazı sınırlamaları da vardır. Uzun süreli kullanımlarda sensör hataları, sıfır noktası kaymaları ve ölçüm gürültüsü gibi nedenlerle küçük hatalar zamanla birikerek önemli sapmalara neden olabilir. Bu nedenle sistemin belirli aralıklarla kalibre edilmesi gerekir. Batarya tamamen şarj olduğunda sistem kendini sıfırlayarak doğruluğu yeniden sağlar. Ayrıca amper-saat sayımı yalnızca elektriksel ölçümleri temel aldığından, sıcaklık, iç direnç artışı ve hücre yaşlanması gibi fiziksel ve kimyasal etkileri doğrudan dikkate almaz. Bu gibi faktörler sistemin gerçek kapasiteyi olduğundan fazla ya da az tahmin etmesine neden olabilir. Bu nedenle, daha yüksek doğruluk gerektiren uygulamalarda amper-saat sayımı ya da veri tabanlı tahmin yöntemleri gibi uzun vadede az hataya sebep olacak yöntemlerle birlikte kullanılır. Buna rağmen düşük maliyeti, uygulama kolaylığı ve temel hesaplama prensibi sayesinde batarya kapasite ve sağlık tahmininde hâlâ en çok tercih edilen yöntemlerden biridir.

3.1 Veri Tabanlı Tahmin Yöntemleri

Amper-saat sayımı yöntemi her ne kadar pratik ve düşük maliyetli olsa da, yalnızca akım-zaman verisine dayanması ve sıcaklık, iç direnç değişimi, yaşlanma etkileri gibi fiziksel ve kimyasal parametreleri doğrudan hesaba katmaması nedeniyle bazı durumlarda yetersiz kalmaktadır. Özellikle bir araçta bu yöntemin uygulanması her zaman kolay değildir; zira araç içi kullanım sırasında bataryaya uygulanan akım sürekli değişkenlik gösterir, sürüş koşullarına bağlı ani yüklenmeler veya rejeneratif frenleme gibi durumlar doğruluğu olumsuz etkileyebilir. Ayrıca aracın kullanım geçmişi, bekleme süreleri, sıcaklık profili gibi dış etkenler de entegrasyon hatalarının zamanla büyümesine yol açar ve kapasite tahmini giderek sapabilir [29]. Bu nedenle daha doğru ve genellenebilir sonuçlar elde edebilmek için, çoklu değişkenlere dayalı veri odaklı yöntemler tercih edilmektedir. Bu yaklaşımlar, batarya davranışını etkileyen tüm parametreleri aynı anda değerlendirebildiği için kapasite ve sağlık durumu tahminlerinde daha yüksek doğruluk sağlar. Ayrıca bu yöntemler, bataryanın farklı çalışma koşullarında nasıl tepki vereceğini de öğrenebildiğinden, sistemin değişken çevresel koşullara ve kullanıcı alışkanlıklarına karşı daha uyumlu çalışmasını mümkün kılar.

3.1.1 Rastgele orman yöntemi

Makine öğrenmesinde önemli bir yere sahip olan Rastgele Ormanlar (Random Forests) algoritması, tekrarlı rastgele örnekleme (bootstrap) ve topluluk tabanlı öğrenme (ensemble learning) tekniklerinin birleşiminden oluşmaktadır [30]. Bu yöntem, eğitim verisi üzerinde farklı örnekleme işlemleri uygulanarak elde edilen alt kümeler ile birçok karar ağacının bağımsız şekilde eğitilmesine dayanmaktadır. Her karar ağacı, tekrarlı rastgele örnekleme yöntemiyle oluşturulan veri seti üzerinde eğitilirken, her bölünmede kullanılacak özniteliklerin rastlantısal olarak seçilmesi, modelde ağaçlar arası korelasyonun azaltılmasına katkı sağlamaktadır [31]. Bu çeşitlilik sayesinde model, bireysel ağaçların yüksek varyans problemini dengeleyerek aşırı öğrenmeye (overfitting) karşı direnç kazanır. Rastgele Ormanlar, veri dağılımı hakkında ön kabulde bulunmaksızın hem sınıflandırma hem de regresyon problemlerinde başarılı tahminler üretebilmesi nedeniyle uygulamalı alanlarda geniş bir kullanım alanı bulmuştur [32].

Söz konusu yöntemde, sınıflandırma problemleri için, her ağacın yaptığı tahminler arasında çoğunluk oylaması (majority voting) yapılmakta; regresyon problemlerinde ise ağaçların tahminlerinin aritmetik ortalaması alınarak nihai sonuç belirlenmektedir [30]. Karar ağaçları, veriyi kök düğümden başlayarak farklı özelliklere göre dallara ayırarak işlemekte ve yaprak düğümlerde bir karar vermektedir. Böylelikle verinin yapısal özellikleri otomatik olarak öğrenilmektedir. Rastgele Ormanlar algoritmasının sunduğu bu çoklu modelleme yapısı, sınıflandırmadaki hata oranını azaltmakta ve modelin genelleme kapasitesini güçlendirmektedir [31]. Bu nedenle, özellikle yüksek boyutlu ve gürültülü veri setlerinde güçlü bir alternatif olarak öne çıkmaktadır.

Sınıflandırma problemlerinde model, her ağacın yaptığı tahminleri çoğunluk oyu (majority voting) prensibine göre birleştirir; bu işlem denklem 3.3'te görüldüğü gibi ifade edilir.

$$\hat{y} = \text{mod}(h_b(x))_{b=1}^B \quad (3.3)$$

Burada $h_b(x)$ ifadesi, b. ağacın girdiye (özelliklere) verdiği tahmini temsil eder ve B toplam ağaç sayısıdır. Regresyon problemlerinde ise model, denklem 3.4'te görüldüğü gibi ağaçlardan elde edilen tahminlerin aritmetik ortalamasını alarak sonuca ulaşır.

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B h_b(x) \quad (3.4)$$

Her karar ağacında, bir düğümde hangi öznitelige göre bölünme yapılacağı, karışıklık düzeyi (impurity) azalımı hesaplanarak belirlenir.

Rastgele Ormanlar algoritmasının öne çıkan özelliklerinden biri de, özellik önemliliği (feature importance) analizi yapabilmesidir. Model, her öz niteliğin sınıflandırma veya regresyondaki katkısını, karar ağaçlarında yer aldığı bölünmelerin getirdiği bilgi kazanımı (örneğin Gini azalışı ya da bilgi kazancı) üzerinden hesaplar. Böylece modelin hangi öz nitelikleri daha sık ve daha kritik karar noktalarında kullandığı belirlenebilir. Bu bilgi, özellikle yüksek boyutlu ve karmaşık veri setlerinde değişken seçimi, yorumlanabilirlik ve model sadeleştirme açısından büyük avantaj sağlar. Ayrıca modelin doğruluğunu değerlendirmek için torba dışı hata (Out-of-Bag Error) oranı kullanılarak, ayrı bir test verisi gerektirmeden genellenebilirlik güvenilir bir şekilde ölçülebilir.

3.1.2 Uzun kısa süreli bellek yöntemi


Tekrarlayan Sinir Ağı (Recurrent Neural Network (RNN)) yapıları, zaman serisi verileri üzerinde geçmiş bilgilere dayalı öğrenme gerçekleştirebilmek amacıyla geliştirilmiştir. Geri beslemeli bir yapıyı kullanarak son girişlerini temsili bir bellek ile nöron aktivasyonları şeklinde kısa süreli depolayabilirler. Ancak, kısa süreli belleğe ne konulacağını öğrenmek için en yaygın kullanılan algoritmalar ya çok fazla zaman alır ya da özellikle girişler ile bunlara karşılık gelen öğretici sinyaller arasındaki zaman farkları uzun olduğunda hiç işe yaramazlar. Ayrıca TSA uygulamalarında gradyan patlaması ve gradyan sönmesi çok sık görülebilir. Özellikle geçmiş verilerin çoğuna bağlı bir modelde, geri yayılım sırasında gradyanların üssel küçülmesi veya büyümesi; ağırlıkların dengesiz salınımına, öğrenme sürecinin başarısız olmasına yol açabilmektedir. Uzun kısa süreli bellek (Long Short-Term Memory, LSTM) mimarisi, söz konusu problemleri çözmek amacıyla oluşturulmuş bir mimaridir [33].

LSTM, standart RNN'lerden farklı olarak, özel olarak tasarlanmış hücre yapıları sayesinde hata sinyalinin ağ içinde sabit ve kararlı biçimde akmasını sağlar. Böylece, uzun zaman aralıkları boyunca bilgi kaybı yaşamadan öğrenme yapılabilir. Gürültülü

veya sıkıştırılmaz nitelikteki giriş dizileri karşısında dahi, LSTM modelleri 1000 zaman adımını aşan aralıkları etkili bir şekilde öğrenebilmektedir. Bu, geleneksel ağların aksine hem kısa vadeli hem de uzun vadeli ilişkileri aynı anda modelleyebilme yeteneğinden kaynaklanmaktadır [34].


Bir LSTM ağı, giriş dizisi $x = (x_1, x_2, \dots, x_t)$ 'den çıkış dizisi $y = (y_1, y_2, \dots, y_t)$ 'ye bir eşleme yapar. Bu eşleme, her zaman adımı $t = 1$ 'den T 'ye kadar olan adımlarda tekrar ederek gerçekleşir. Her adımda ağı iç durumu güncellenir ve o adıma karşılık gelen çıkış üretilir. LSTM'nin bu işlemi yapabilmesi, hücre durumu ve gizli durum olmak üzere iki temel iç yapının yanı sıra kapı denklemleri sayesinde mümkün olur.

LSTM yapısı üç ana kapıdan oluşur. Uzun vadeli bağıntıları öğrenebilmesini ve gereksiz bilgileri unutulmasını sağlayan temel yapılar bu kapılardır: unutma kapısı (f_t), giriş kapısı (i_t) ve çıkış kapısı (o_t).



Şekil 3.1 : LSTM algoritması giriş, çıkış ve kapıların bağlantıları

Kapılar, şekil 3.1'de de görüldüğü üzere o anki giriş (x_t) ve önceki gizli durum (h_{t-1})'e bağlı olarak sigmoid veya tanh gibi aktivasyon fonksiyonlarıyla çalışır. LSTM, hücre durumunda c_t hangi bilginin ne kadar tutulacağını, neyin güncelleneceğini ve neyin çıkışa aktarılacağını belirler. Bunu yaparken zaman içinde taşınan bir bilgi kanalı gibi davranır ve bu sayede LSTM'ler, uzun bağıntılara sahip dizilerde öğrenme başarısını artırır. Şekil 3.2 ile LSTM ile hesaplamadaki akış gösterilmektedir.



Şekil 3.2 : LSTM algoritması akış şeması

Denklem 3.5'te formülize edilen unutma kapısı (f_t), hücre durumundaki bilgilerin hangilerinin silineceğine karar verir. Hücresinin kendi kendine tekrarlayan bağlantısı üzerinden giriş değerini işlemeyen önce hücrenin iç durumunu ölçekler, bu nedenle hücrenin belleğini adaptif bir şekilde unutturur veya sıfırlar [35].

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.5)$$

Giriş kapısı, LSTM hücresine gelen yeni bilginin ne kadarının hücre durumuna ekleneceğini belirleyen bir kontrol mekanizmasıdır. Bu kapı, önceki zaman adımındaki gizli durum ile mevcut zaman adımındaki girişi birleştirerek işler ve bir sigmoid aktivasyon fonksiyonu aracılığıyla 0 ile 1 arasında değerler üretir. Bu değerler, gelen bilginin hücreye ne ölçüde dahil edileceğini belirleyen bir tür filtre işlevi görür [36]. Aynı zamanda bu adımdaki bilgilerden oluşturulan aday hücre durumu, tanh aktivasyonu ile şekillendirilir. Giriş kapısının çıktısı ile bu hücre durumun çarpımı, mevcut hücre durumuna eklenerek bilgi güncellemesi yapılır. Bu süreç sayesinde LSTM, sadece önemli ve gerekli bulduğu bilgileri hücre belleğine alır

ve uzun süreli bağıntılar kurulurken gereksiz detayların birikmesi engellenir. Giriş kapısının bu seçici rolü, modelin zaman içinde anlamlı örüntüleri korumasını ve öğrenmesini mümkün kılar [37].

Giriş kapısı bias değeri (b_i) ile giriş kapısı ağırlık matrisinin (W_i) sigmoid fonksiyonunda önceki giriş (h_{t-1}) ve mevcut girişin (x_t) birleştirilmesiyle yerine yazılmasıyla kullanılıp giriş kapısı çıktısı (i_t) denklem 3.6'da görüldüğü gibi elde edilmektedir[38].

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.6)$$

LSTM hücresinin çıktısı bir sonraki zaman adımına aktarımı çıkış kapısı ile gerçekleşir. Hücre durumunun anlık çıktı işe yarayacak kısmını çıktı olarak verir. Anlık giriş ve önceki gizli durumu kullanarak sigmoid fonksiyonu ile işlenir ve bu sayede denklem 3.7'de görüldüğü üzere hangi bilginin ne kadar aktarılacağına dair bir ağırlık vektörü oluşturulur. Güncellenen hücre durumu, tanh aktivasyonu ile normalize edilir ve çıkış kapısının çıktısı ile çarpılarak bilginin belirli bir kısmını bir sonraki gizli duruma aktarır [38].

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.7)$$

Çıkış kapısı, hücrede saklanan tüm bilgileri aktarmak yerine bir sonraki adıma uygun bilgilerin çıktı olarak kullanılmasını sağlar ve modelin aşırı bilgi yüklenmesini önler. Böylece bilgi depolama - paylaşım dengesini korur. Sonuç olarak, LSTM ağları bu adım adım işleyen mekanizmayla hem önceki bilgileri gerektiğinde hatırlayabilir hem de anlamsız hale gelenleri unutarak daha isabetli çıktılar üretir.

3.1.3 Destek vektör makinesi yöntemi

Destek Vektör Makineleri (Support Vector Machine, SVM), sınıflandırma problemleri başta olmak üzere biyomedikal tanılama, metin sınıflandırma, yüz tanıma ve finansal tahminleme gibi birçok alanda yaygın olarak kullanılmakta ve başarılı sonuçlar vermektedir [39]. Sınıflandırma ve regresyon problemlerinde kullanılan güçlü ve esnek bir denetimli öğrenme algoritmasıdır. Temel amacı, verileri farklı sınıflara en iyi şekilde ayıran optimal hiperdüzlemi (decision boundary) bulmaktır. Bu hiperdüzlem, iki sınıf arasında mümkün olan en büyük marjini sağlar. Marjin, sınıfları temsil eden en yakın veri noktaları olan destek vektörleri ile hiperdüzlem arasındaki

mesafedir. Marjin maksimum olduğunda, sınıflar arası ayırım daha güvenilir hale gelir [40].

İki sınıfı ayıran doğrusal bir hiperdüzlem için SVM'nin optimizasyon problemi ağırlık vektörünün (w) uzunluğunu en düşük değere getirebilmektir. Her bir veri noktasını x_i ve y_i olarak ile ifade edecek olursak, veri noktalarının kısıtı denklem 3.8'deki gibidir. Böylece tüm veriler doğru sınıflanır ve hiperdüzlemden minimum mesafede bulunurlar.

$$y_i(w \cdot x_i + b) \geq 1 \quad (3.8)$$

Gerçek dünyadaki veriler genellikle tam olarak doğrusal ayrılabilir olmadığından, bu kısıt esnetilir ve ceza terimi içeren yumuşak marjin yaklaşımı uygulanır. Esneklik değişkeni (ξ_i) yanlış sınıflandırmaların cezasını temsil eder ve modelin doğruluk ile genellenebilirlik arasındaki dengesini kontrol eden hiperparametre (C) ile amaç fonksiyonu oluşturulur. Bu durumda kısıt da bu parametreler eşliğinde değişiklik gösterir. Denklem 3.9 ile minimize edilmek istenen amaç fonksiyonunu (J) denklem 3.10 ise genişletilmiş kısıtları göstermektedir.

$$J(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (3.9)$$

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0 \quad (3.10)$$

Doğrusal olmayan sınıflandırma problemleri için SVM, çekirdek (kernel) fonksiyonları kullanır. Bu fonksiyonlar girdileri daha yüksek boyutlu bir özellik uzayına yansıtarak doğrusal sınıflandırma gerçekleştirebilmektedir [41]. Bu dönüşüm, çekirdek (kernel) fonksiyonları aracılığıyla gerçekleştirilir. Çekirdek hilesi (kernel trick) sayesinde, veriler doğrudan yüksek boyutlu uzaya taşınmadan, iç çarpım değerleri üzerinden işlem yapılır. SVM'nin başarısını büyük ölçüde belirleyen faktörlerden biri, seçilen çekirdek fonksiyonunun türüdür. En yaygın kullanılan çekirdek fonksiyonlar arasında doğrusal, polinomsal, radyal tabanlı (RBF) ve sigmoid çekirdekler yer almaktadır [42]. Doğrusal çekirdek fonksiyonu, temel haliyle iki veri noktası arasındaki iç çarpımı hesaplar ve denklem 3.11 ile tanımlanır.

$$K(x_i, x_j) = x_i \cdot x_j \quad (3.11)$$

Bu fonksiyon, veri setinin lineer ayrılabilir olduğu durumlarda ideal bir seçimdir. Lineer çekirdekler yüksek boyutlu verilerde dahi oldukça verimli çalışabilir ve yorumlanabilirliği yüksektir. Özellikle metin sınıflandırma gibi yüksek boyutlu veri yapılarında başarıyla uygulanır. Ancak karmaşık ve doğrusal olmayan ilişkilerin olduğu veri kümelerinde düşük performans sergileyebilir.

Polinomsal çekirdek, denklem 3.12’de de tanımlandığı üzere doğrusal olmayan sınırlar tanımlayabilmek amacıyla veri noktaları arasındaki ilişkiyi polinom derecesi üzerinden genişletir.

$$K(x_i, x_j) = (x_i \cdot x_j + c)^d \quad (3.12)$$

Polinomsal çekirdeği gösteren denklem 3.12’de c sabit terim, d ise polinom derecesidir. Polinomsal çekirdek, özellikle belirli dereceye kadar olan doğrusal olmayan ilişkilerin modellendiği sistemlerde güçlü performans gösterir. Ancak derecenin artması durumunda model karmaşıklığı ve aşırı öğrenme (overfitting) riski de yükselir. Aynı zamanda yüksek hesaplama maliyeti nedeniyle büyük veri kümeleri için önerilmez.

Radyal tabanlı fonksiyon (RBF), denklem 3.13’de tanımlandığı üzere Gaussian çekirdeği olarak da bilinir ve SVM uygulamalarında en yaygın kullanılan fonksiyondur.

$$K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2} \quad (3.13)$$

Burada γ parametresi, etki alanının genişliğini kontrol eder. Küçük γ değerleri daha geniş etki alanı, büyük değerler ise daha lokal etkiler anlamına gelir. RBF çekirdeği, doğrusal olmayan, karmaşık ve yüksek boyutlu veri kümelerinde genellikle üstün performans sergiler. Buna rağmen hiperparametre duyarlılığı yüksektir ve uygun parametre ayarı yapılmazsa aşırı öğrenme ya da düşük doğruluk gibi sorunlar gözlemlenebilir. Ayrıca yorumlanabilirliği düşüktür [43].

Sigmoid çekirdek, yapay sinir ağlarındaki aktivasyon fonksiyonlarına benzeyen bir yapıya sahiptir.

$$K(x_i, x_j) = \tanh(\kappa \cdot x_i^T \cdot x_j + c) \quad (3.14)$$

Denklem 3.14 ile tanımlanan bu çekirdek, özellikle eski literatürde sinir ağı benzeri çözümler üretmek amacıyla kullanılmıştır. Yine de teorik olarak her zaman pozitif tanımlı olmadığı için SVM optimizasyon koşullarını ihlal edebilir ve bu nedenle pratikte daha az tercih edilir. Genellikle alternatif kernel türleri, sigmoid çekirdeğe göre daha stabil ve genellenebilir sonuçlar sağlar. Bu fonksiyonların her biri belirli veri yapıları ve problemler için farklı avantajlar sunmaktadır. Örneğin doğrusal çekirdek basit yapısı ve yorumlanabilirliği nedeniyle tercih edilirken, RBF çekirdek doğrusal olmayan karmaşık örüntüleri modelleyebilme kabiliyetiyle ön plana çıkar. Polinomsal çekirdekler belirli derecelerdeki doğrusal olmayan ilişkileri iyi modelleyebilirken, sigmoid çekirdek daha çok deneysel amaçlarla kullanılır. Uygulamada ideal çekirdek türü, modelin doğruluğu, hesaplama maliyeti, veri yapısı ve modelin yorumlanabilirliği gibi birçok faktörün birlikte değerlendirilmesiyle seçilmelidir [44]. Bu değerlendirmeler ışığında, SVM'nin performansını optimize etmek ve farklı problem türlerine uyarlamak için doğru çekirdek fonksiyonunu seçmek kritik önemdedir. Model başarısı yalnızca eğitim doğruluğu ile değil, aynı zamanda genellenebilirlik, işlem süresi ve uygulama sahasındaki kararlılık gibi ölçütlerle birlikte değerlendirilmelidir. Bu fonksiyonlar sayesinde orijinal giriş uzayından daha yüksek boyutlu bir özellik uzayına geçilerek verilerin doğrusal ayrımı mümkün hale gelir. En yaygın kullanılan çekirdek fonksiyonlar; doğrusal, polinomsal, radyal tabanlı fonksiyon ve sigmoid çekirdekleridir. SVM'in avantajları arasında yüksek boyutlu verilerle etkin çalışabilmesi, marjın maksimizasyonuna dayalı sağlam sınıflandırma sunması ve kernel yöntemiyle esnek sınıf ayırımı sağlaması yer alır. Ayrıca, yalnızca destek vektörleri üzerinden karar vermesi sayesinde model karmaşıklığını azaltır ve verimli hesaplama yapabilir. Buna karşın, dezavantajları arasında büyük veri kümelerinde eğitim süresinin uzun olması, hiperparametre ve kernel seçiminin sonuçları ciddi şekilde etkilemesi ve çok sınıflı problemler için doğrudan uygulanabilirliğinin sınırlı olması sayılabilir. Özellikle büyük veri setlerinde bellekteki yük artabilir ve kernel matrisinin hesaplanması zaman alıcı hale gelebilir.




4. TEST SÜRECİ VE TAHMİN ÇALIŞMASI

Bu çalışma kapsamında bir veri seti oluşturulması gerekiyor ki bu veri seti üzerinden batarya kapasite tahmini yapılabilirdir. Bu veri setinin bir parametresi de amper-saat sayıcı ile hesaplanan kapasite de olmalıdır. Böylece bu değeri gerçek kapasite değeri olarak düşünüp onun üzerinden eğitim ve tahmin olarak veri seti parçaları oluşturulabilsin. Bu veri seti oluşturulduktan sonra hangi tahmin yönteminin seçilmesi gerektiği de bir ön çalışma ile gerçekleşecektir. Bunu gerçekleştirebilmek için bir batarya modeli üzerinden test verilerini koşturup çıkan sonuçlara göre paket üzerinde test yapmaya başlayabiliriz. Bu test süreci için gerçekçi bir batarya ve şarj istasyonu modeli kullanılması önem arz etmektedir. Bu modellerdeki inputlar da sürücü profilini temel alarak çalışmalı ve ona göre girdiler sunulmalıdır.

4.1 Verilerin Elde Edilmesi

Veri toplama sürecinde E-STORAGE BTE 400 kW, 1200 V, WCS, 1-Channel modelindeki bir şarj-deşarj cihazı (cycler) kullanılmıştır. Bu cihaz aracılığıyla bataryalar, belirlenen şarj vedeşarj protokollerine göre totalde sağlık durumu %80 e kadar düşen ortalama bir sürücü profilinde kullanılan batarya döngülerine tabi tutulmuştur. Bu kapsamda bataryanın bir hafta içerisinde 1 full şarj ve 1 fulldeşarj ile dinlenme aralıkları da hesaba katılmıştır. Her bir döngü sırasında şarj-deşarj akımı, hücrelerin ortalama voltajı, ortalama sıcaklığı ve kapasite bilgisi hesaplanarak kaydedilmiştir. Bu uzun vadeli test süreci, bataryanın zaman içindeki performans değişimini ayrıntılı olarak izlemeye olanak tanımıştır. Şekil 4.1’de test düzeneği ve bağlantıları ayrıntılı biçimde gösterilmektedir.



Şekil 4.1 : Verilerin elde edilmesi için oluşturulan test düzeneği

Kurulan düzenekte kullanılan batarya paketi, toplamda 108 adet NMC (Nikel-Mangan-Kobalt) kimyasına sahip prizmatik hücreden oluşmaktadır. Bu hücreler, termal yönetim amacıyla kullanılan bir LAUDA soğutma ünitesi (LAUDA Unit) ile istenilen sıcaklıkta tutulmuştur. Tüm ölçüm verileri (akım, voltaj, sıcaklık vb.), CANbus üzerinden bir bilgisayara aktarılmıştır. Ayrıca dış ortam sıcaklığı da AVL marka iklimlendirme kabini (AVL Climatic Chamber) ile kontrol edilmiştir. Bu sayede hem hücre içi sıcaklıklar hem de çevresel koşullar sistematik biçimde düzenlenerek deneysel bütünlük sağlanmıştır.

Toplanan verilerle oluşturulan analizlerde, her bir hücreye ait değerler ile işlem yapmak maaliyetli olacağı ve yüksek işlemci gücü gerektireceğinden ortalama sıcaklık, ortalama voltaj ve ortalama akım gibi sistem seviyesindeki veriler esas alınmıştır. Ayrıca şarj durumu için şarj sırasında minimum, deşarj sırasında maksimum değer göz önünde bulundurulmuştur. Böylece şarj sırasında oluşacak maksimum gerilimin aşılması gibi sorunların önüne geçilmiştir. Bu yaklaşım, 108 hücrelik yapının genel davranışını temsil etmeyi amaçlamaktadır.

Deney setinden elde edilen çıktılar doğrultusunda, sıcaklık ve çevrim sayısına göre indekslenmiş kapasite ve iç direnci gösteren bir tablo oluşturulmuştur. Böylece gerçek zamanlı uygulamalarda minimum işlem gücüyle hızlı kapasite tahmini yapılabilmesi mümkün hale getirilmiştir. Tüm süreç, deneysel verilerin sahaya uygulanabilir


modellere dönüştürülmesi açısından başarılı bir örnek oluşturmuştur. Bu çalışma içerisinde, -15°C ile 45°C arasındaki her bir sıcaklık derecesi için, aynı bataryanın farklı örnekleri kullanılarak %100 ile %80 sağlık durumu aralığında yaşlandırma testleri gerçekleştirilmiştir.

Aynı bataryanın farklı örnekleriyle çalışmak, hücreler arası üretimsel varyasyonları ve sıcaklığın etkisini izole bir şekilde değerlendirme imkânı sağlamıştır. Bu yaklaşım, sıcaklık değişiminin batarya davranışı üzerindeki etkilerini daha net bir şekilde ortaya koyarken, aynı zamanda sağlık tahmini için geliştirilecek modellerin genellenebilirliğini artırmak amacıyla veri çeşitliliği oluşturmuştur. Bu süreçte her bir çevrimde bataryaya ait anlık kapasite, çevrim numarası, gerilim, akım limiti, sıcaklık, hücre iç direnci, iç direnç artış oranı, şarj durumu, şarj gücü ve çevrim sonunda ölçülen kapasite verileri toplanmıştır. Verilerin ilk 5 ve son 5 değerinden oluşan çizelgeyi çizelge 4.1’de görebilirsiniz.

Çizelge 4.1 : Test verileriyle oluşturulmuş giriş değerlerinin çizelgesi


Hücre Anlık Kapasitesi [Ah]	Akım [A]	İç Direnç Artış Oranı [%]	İç Direnç [ohm]	Şarj Durumu [%]	Hücre Kapasitesi [Ah]	Döngü Sayısı	Hücre Gerilimi [V]	Şarj Gücü [W]	Sıcaklık [C]
0.0	0.0	0.0151	1.1448	0.0	77.844	0	3.066	180	-15
0.0	0.0	0.0151	1.1448	0.0	77.844	0	3.066	180	-15
0.0648	23.330	0.0151	1.1448	0.0832	77.844	0	3.271	180	-15
0.1295	23.304	0.0150	1.1448	0.166	77.844	0	3.340	180	-15
0.1942	23.279	0.0149	1.1448	0.249	77.844	0	3.363	180	-15
...	...	...	...	...	...	...	...	...	...
0.5641	-73.0	0.005	1.4393	0.925	60.966	473	2.776	180	45
0.3613	-73.0	0.005	1.4393	0.592	60.966	473	2.755	180	45
0.1585	-73.0	0.005	1.4393	0.260	60.966	473	2.732	180	45
0.0442	-73.0	0.005	1.4393	0.072	60.966	473	2.703	180	45
0.0246	-73.0	0.005	1.4404	0.045	60.932	473	2.677	180	45

Bu nedenle, bu parametrelerin anlık kapasite üzerindeki etkilerini daha iyi anlayabilmek için, öncelikle değişken önemliliği analizleri gerçekleştirilmiştir. Bu analizler, hangi değişkenlerin daha belirleyici olduğunu ortaya koyarak model kurulum sürecine yön vermektedir. Buradaki değişken önemliliği analizini bir rastgele orman modeli oluşturularak gerçekleştirilmiştir. Değişken önemliliği analizi grafiği şekil 4.2’de görülmektedir.



Şekil 4.2 : Giriş verilerinin önem düzeyi grafiği

Burada görüldüğü üzere şarj değeri anlık kapasite ile yüksek oranda bağlılık göstermektedir. Bu nedenle şarj durumunu çıkarıp geri kalan parametreler arasında bu önem düzeyi hesabı tekrar yapıldığında şekil 4.3 oluşmaktadır.




Şekil 4.3 : Şarj durumu çıkartıldığında gerçekleştirilen önem düzeyi grafiği

Burada kurulan veri setinde anlık ve döngü sonundaki kapasite değerleri yer almaktadır. Anlık kapasite yerine döngü sonundaki kapasite değerini tahmin etmeye çalışmak direkt sonuç odaklı olmayı sağlayabilir. Burada mevcut verilerin türevsel değerleri üzerinden yeni ve daha hızlı hesaplanabilir bir veri seti hazırlanabilir. Bu kapsamda, özellikle şarj sürecine odaklanılarak belirli şarj durumlarında –yüzde 40, yüzde 50 ve yüzde 60 seviyelerinde – uygulanan akım değerleri çıkarılmış, bu noktaların hücre davranışı üzerindeki etkileri gözlemlenmiştir. Ayrıca, yüzde 30 ile yüzde 60 aralığında gerçekleşen şarj işlemi boyunca geçen toplam süre hesaplanarak yeni veri kümesine eklenmiştir. Bu değerler her sağlık durumu ve sıcaklık aralığında farklı olması beklenmektedir çünkü hücre yaşlandıkça batarya şarjı ve aynı zamanda deşarjı da hızlanmaktadır. Aynı zamanda bu hızlanmadan ötürü belli şarj seviyelerinde akım limitleri de değişmekte ve bu limitler de sağlık durumunu tahmin algoritması için bağlantı sağlamaktadır. Bu tür türevsel veriler, hücrenin yalnızca anlık kapasitesine değil, gerçek kapasitesine dair daha kapsamlı bir tahmin yapmayı mümkün kılmıştır. Böylece geliştirilen modellerin, bataryanın o anki davranışını değil, genel sağlık durumunu yansıtmayı hedeflenmiştir. Bu veriler çizelge 4.2’de görülmektedir.

Çizelge 4.2 : Giriş verilerinden türetilmiş model test verileri

%30 - %60 Arası Şarj Süresi [s]	Sıcaklık [C]	Hücre Kapasitesi [Ah]	%40 Şarjda Akım	%50 Şarjda Akım	%60 Şarjda Akım
735	-15	77.844	13.0939	10.4960	8.2359
735	-15	77.795	13.0911	10.4920	8.2319
735	-15	77.760	13.0996	10.4985	8.2354
735	-15	77.727	13.0957	10.4940	8.2315
734	-15	77.695	13.0932	10.4908	8.2352
...	...	...	...	...	...
51	45	61.103	131.0	131.0	112.4633
51	45	61.068	131.0	131.0	112.5661
51	45	61.034	131.0	131.0	112.5996
52	45	61.000	131.0	131.0	111.6611
52	45	60.966	131.0	131.0	111.1184

Bu verilerin hücre kapasitesine etkisini gösteren değişken önemliliği analizi de yine bir rastgele orman modeli üzerinden şekil 4.4 gibi oluşturulmuştur.




Şekil 4.4 : Yeni verilerle elde edilen değişken önemliliği analizi grafiği

Görsel olarak sunulacak değişken önemliliği sonuçları da, hangi parametrelerin hücrenin asıl kapasitesini etkilediğini ortaya koymakta ve bu parametrelerin modele olan katkısını daha net bir şekilde gözler önüne sermektedir. Bu yöntem sayesinde, klasik anlamda doğrudan ölçülen verilerin ötesine geçilerek, daha anlamlı ve açıklayıcı göstergeler elde edilmiştir.

4.2 Model Testleri ile Tahmin Yöntemi Seçimi

4.2.1 Lineer regresyon ile model testi

Bir kurulum üzerinden yaşlandırma testlerini ve verileri elde ettikten sonra, gömülü sisteme entegre edilebilir doğru modelin seçilmesi gerekmektedir. Bu nedenle, paket üzerinde model denemeden önce veriler ile bir tahmin algoritması oluşturulmuştur. Bu modellerde en basit yöntemden en karmaşık yöntemlere doğru algoritmalar kurulmuştur. Bu kapsamda önce lineer regresyon ile başlanılmıştır. Modelin kurulabilmesi için kapasite ile diğer parametreler arasında doğrusal bir ilişki olduğu varsayılmış ve bu varsayım model sonrası artık analizleriyle test edilmiştir ve sonuçları şekil 4.5’de gösterilmektedir.




Şekil 4.5 : Lineer regresyon modeli ile tahmin sonuçları

Yapılan artık grafiğinde, tahmin edilen değerler ile bu tahminlere ait artıklar (hatalar) arasındaki ilişki incelenmiştir. Artıklar, modelin tahmin ettiği değer ile gerçek değer arasındaki farkı gösterir. Bu grafikte artıkların rastgele ve yatay bir şekilde dağılmış olması beklenir. Eğer artıklar belirli bir desen izliyorsa (örneğin eğimli bir dağılım), bu durum modelin bazı sistematik hatalar yaptığını gösterebilir. Ayrıca kırmızı çizgi ($y=0$ doğrusu), hataların sıfır olduğu referans noktayı belirtir. Bu çizginin etrafında simetrik bir dağılım olması, modelin doğruluğuna işaret eder. QQ grafiğinde ise artıkların normal dağılıma ne kadar uyduğu değerlendirilir. Noktaların 45°'lik referans doğrusuna yakın şekilde sıralanması, artıkların normal dağıldığını ve modelin varsayımlarına uygun çalıştığını gösterir. Bu uyumun olmaması, modelin yeterince doğru tahmin yapmadığı veya verinin doğrusal yapıya uymadığı anlamına gelebilir.

Lineer regresyon modeli, bağımlı değişken (bu çalışmada hücre anlık kapasitesi) ile bağımsız değişkenler (örneğin akım, iç direnç, sıcaklık vb.) arasında doğrusal bir ilişki olduğunu varsayar. Model, her bir girdinin hedef değişken üzerindeki etkisini bir katsayı ile temsil eder ve bu katsayılar doğrudan modelin sonucudur. Katsayıların pozitif veya negatif olması, o değişkenin hedef üzerinde artırıcı ya da azaltıcı yönde etkili olduğunu gösterir. Son grafikte, bu katsayılar yatay çubuk grafik ile

görselleştirilmiştir. Büyük mutlak değere sahip değişkenler, modelde daha belirleyici olup hedef değişken üzerinde daha güçlü bir etkiye sahiptir. Ancak burada unutulmaması gereken nokta, lineer regresyonun değişkenler arası doğrusal ilişki varsayımıdır; bu varsayım sağlanmadığında modelin açıklayıcılığı sınırlı kalabilir. Dolayısıyla modelin doğruluğunu değerlendirirken hem görsel analizlere hem de istatistiksel metriklerle birlikte bakmak gerekir. Öncesinde oluşturduğumuz ikinci veri tablosu üzerinden bir lineer regresyon modeli daha kurulabilir. Bu model ile elde edilen sonuçlar şekil 4.6'daki gibi olmuştur.



Şekil 4.6 : Türetilen verilerle ve lineer regresyon modeli ile tahmin sonuçları


Bu grafikler, %30–%60 SOC (şarj durumu) aralığındaki şarj süresi, sıcaklık ve belirli SOC seviyelerindeki akım değerlerine göre hücre kapasitesini tahmin etmek amacıyla oluşturulan bir lineer regresyon modeline aittir. Artık grafiğinde, tahmin edilen kapasite değerlerine karşılık artıklar (hatalar) çizildiğinde, belirgin bir eğilim görülmekte; hatalar ortada daha yoğun ve simetrikken uçlarda daha dağılmış durumda. Bu yapı, heteroskedastisite (değişen varyans) sorunu olabileceğini düşündürür. Ayrıca artıklar doğrusal ekseninde düzgün dağılmadığı için modelin doğrusal ilişkiyi tam olarak yansıtamadığı da söylenebilir. Bu durum, modelin bazı değer aralıklarında sistematik

hatalar ürettiğine ve muhtemelen daha karmaşık bir modele ihtiyaç duyulduğuna işaret eder.

QQ grafiğinde ise artıkların normal dağılıma olan uyumu incelenmiştir. Noktaların teorik kırmızı çizgiden belirli aralıklarda saptığı ve özellikle uçlarda belirgin sapmalar gösterdiği görülmektedir. Bu da artıkların tam anlamıyla normal dağılmadığını ve dolayısıyla modelin varsayımlarından birinin ihlal edildiğini ortaya koyar. Model katsayıları incelendiğinde en yüksek pozitif etki %60 şarj seviyesindeki akımda, en negatif etki ise %50 şarj seviyesindeki akımda gözlemlenmektedir. Bu durum, özellikle bu iki noktanın kapasiteyi belirlemede baskın rol oynadığını gösterir. %30–%60 arası şarj süresi ve sıcaklığın ise modele katkısının oldukça sınırlı olduğu görülmektedir. Bu doğrusal yapı genel eğilimi yansıtsa da tahmin gücü açısından sınırlı kalmakta ve varyans ile dağılımın karmaşıklığı daha gelişmiş modellere geçilmesini önermektedir.

4.2.2 Destek vektör regresyonu ile model testi


Lineer regresyon modelinde gözlemlenen artık desenleri ve doğrusal varsayımların ihlali, modelin veri üzerindeki karmaşık ilişkileri yeterince yansıtamadığını göstermiştir. Bu nedenle doğrusal olmayan yapıları daha iyi modelleyebilen Destek Vektör Regresyonu (SVR) yöntemine geçilmiştir. SVR modeliyle yapılan analiz sonucunda, ortalama kare hatası (MSE) yalnızca 0.0032 olarak elde edilmiş, bu da modelin tahmin gücünün son derece yüksek olduğunu ortaya koymuştur. Böylece SVR, hem düşük hata hem de %99.999'luk R^2 skoru ile lineer modele göre çok daha güvenilir bir tahmin performansı sunmuştur. Sonuçları şekil 4.7 de görülmektedir.



Şekil 4.7 : Destek vektör regresyonu modeli ile tahmin sonuçları

Bu sonuçlar, SVR (Support Vector Regression) modelinin veriye son derece başarılı bir şekilde uyum sağladığını gösteriyor. Gerçek vs Tahmin grafiğinde, tüm noktalar neredeyse tam olarak referans olan kırmızı doğrusal çizgi üzerine oturmuş durumda. Bu da modelin yaptığı tahminlerin gerçek değerlere çok yakın olduğunu, yani doğruluk oranının çok yüksek olduğunu gösterir. R^2 değerinin 0.99999 olması, açıklanan varyansın neredeyse tamamının model tarafından açıklandığını; yani girdilerle hedef değişken (Hücre Anlık Kapasitesi [Ah]) arasında güçlü bir ilişki kurulduğunu kanıtlar.

Artık (residual) grafiği ise oldukça ilginç bir yapıya sahip. Artıklar oldukça küçük seviyelerde (yaklaşık ± 0.15 Ah aralığında) ve büyük bir kısmı sıfır çizgisi etrafında simetrik dağılmış durumda. Ancak dikkat çeken bir dalga formu var; bu da modelin bazı tahminlerinde çok küçük sistematik sapmalar yaptığını gösterebilir. Yani model her ne kadar çok başarılı olsa da, belli değer aralıklarında küçük yapısal kalıntılar (pattern) taşıyor olabilir. Bu durum bir uyarı olmakla birlikte, modelin genel başarısını ciddi şekilde zedelemeyiz çünkü tahmin hatası çok düşüktür. Sonuç olarak, SVR modeli bu veri için yüksek doğruluk ve düşük hata ile oldukça güçlü bir tahmin performansı sergilemiştir. Özellikle lineer modellere kıyasla çok daha etkili olduğu açıkça görülmektedir. SVR ile hücre kapasitesini de tahmin edebilmek adına oluşturulan diğer modelin sonuçları şekil 4.8’de görülmektedir.




Şekil 4.8 : Türetilen verilerle destek vektör regresyon modeli sonuçları

Bu SVR (Destek Vektör Regresyonu) modeline ait sonuçlar, yeni oluşturulan özellik tablosu üzerinden yapılan tahminlerin oldukça başarılı olduğunu göstermektedir. Sağdaki "Gerçek vs Tahmin" grafiğinde mavi noktalar, kırmızı referans çizgisi etrafında yoğun şekilde sıralanmış durumda. Bu da modelin gerçek hücre kapasitesi değerlerini yüksek doğrulukla tahmin ettiğini açıkça ortaya koymaktadır. Noktaların referans çizgiden büyük sapmalar göstermemesi, özellikle modelin genelleme başarısının iyi olduğunu gösterir.

Soldaki "Artık Grafiği" incelendiğinde, artıkların (gerçek – tahmin) büyük ölçüde sıfır çevresinde simetrik olarak dağıldığı görülmektedir. Her ne kadar uç değerlerde hafif yayılmalar (0.75 Ah'e kadar) olsa da, bu sapmalar belirgin bir örüntü göstermediği için rastgele hata dağılımı varsayımı büyük ölçüde sağlanmıştır. Ayrıca modelin performans metriği olan R^2 skoru 0.9981, yani modelin varyansın %99.81'ini açıkladığını belirtirken; MSE'nin sadece 0.0331 Ah² olması, modelin tahminlerinin oldukça düşük hata ile yapıldığını göstermektedir. Bu sonuçlar, SVR'nin bu özellik kümesinde de oldukça başarılı bir regresyon performansı sunduğunu doğrulamaktadır.

4.2.3 Rastgele orman ile model testi

SVR modeli oldukça başarılı sonuçlar üretmiş olsa da, bu modelin açıklanabilirliği sınırlıdır; yani her bir girdinin hedef değişken üzerindeki etkisini doğrudan yorumlamak zordur. Ayrıca SVR, özellikle büyük veri setlerinde hesaplama açısından daha maliyetli olabilir. Bu nedenle, hem yorumlanabilirlik hem de özellik önem sıralaması gibi içgörü sağlayan analizleri mümkün kılmak amacıyla rastgele orman modeline geçilmiştir. Rastgele orman, doğrusal olmayan ilişkileri yakalama konusunda güçlü olduğu gibi, her bir değişkenin modele katkısını da açıkça ortaya koyabilmektedir. Bu sayede hem tahmin performansı yüksek tutulmuş hem de modelin karar mekanizması daha iyi anlaşılabilir hale getirilmiştir. Tahmin grafiği ise şekil 4.9'da görülmektedir.




Şekil 4.9 : Rastgele orman modeli ile tahmin sonuçları

Bu rastgele orman modeliyle elde edilen sonuçlar, eski veriler üzerinden yapılan hücre anlık kapasite tahmininin son derece başarılı olduğunu göstermektedir. Gerçek ve tahmin değerlerinin karşılaştırıldığı grafikte, mavi noktaların neredeyse tamamen kırmızı referans çizgisi üzerine oturduğu görülmektedir. Bu durum, modelin yalnızca belirli aralıklarda değil, tüm değerler boyunca istikrarlı ve doğru tahminler üretebildiğini gösterir. Ayrıca grafik üzerinde ciddi bir saçılma veya sistematik sapma gözlemlenmemekte, bu da modelin yüksek genelleme yeteneğine işaret etmektedir.

Modelin performans ölçütleri de bu görsel gözlemi desteklemektedir. R^2 skoru 0.9999998 gibi neredeyse bire eşit bir değere ulaşmış; yani model, veri kümesindeki değişkenliğin %99.99998'ini açıklayabilmektedir. Bu seviyedeki bir doğruluk, veriyi son derece başarılı bir şekilde öğrendiğini gösterir. Öte yandan Ortalama Kare Hata (MSE) değeri yalnızca 0.000107 Ah^2 gibi oldukça düşük bir hata değeri sunmaktadır. Bu da tahminlerin yalnızca yüksek doğrulukta değil, aynı zamanda çok düşük hata ile yapıldığını ortaya koyar.

Rastgele orman algoritması, aslında çok sayıda karar ağacından oluşan bir topluluk (bütünleşik) yöntemidir. Bu modelde her bir ağaç, eğitim verisinin rastgele seçilmiş bir alt kümesiyle eğitilir ve her düğümde yapılan bölünme işlemi için de rastgele bir özellik alt kümesi kullanılır. Bu sayede modelin aşırı öğrenme (ezberleme) yapması engellenir ve genelleme yeteneği artar. Tahmin sürecinde ise tüm ağaçlardan elde edilen tahminlerin ortalaması alınarak nihai sonuç oluşturulur. Bu yapısı sayesinde model, hem yüksek doğruluk hem de düşük oynaklığa sahip tahminler üretme kapasitesine sahiptir. Bu örnekte de hem görsel hem de sayısal göstergeler, modelin bu güçlü yapısını tam anlamıyla ortaya koyduğunu doğrulamaktadır. Bundan sonraki aşamada, türevsel verilerle oluşturulan yeni veri kümesi kullanılarak model performansı yeniden değerlendirilmektedir. Şekil 4.10 ile türetilen verilerle elde edilen sonuçlar gösterilmektedir.



Şekil 4.10 : Türetilen verilerle rastgele orman modeli sonuçları


Yeni oluşturulan özet veriler üzerinden yapılan bu tahmin sonuçları, rastgele orman algoritmasının, ham verilerden türetilmiş istatistiksel göstergelerle de oldukça yüksek doğrulukta çalışabildiğini ortaya koymaktadır. Gerçek ve tahmin değerlerinin karşılaştırıldığı grafikte, mavi noktaların önemli bir kısmının kırmızı referans çizgisine yakın konumlandığı görülmektedir. Her ne kadar ham verilerle elde edilen modele kıyasla çizgiden daha fazla saçılma olsa da, genel eğilimin çok iyi şekilde yakalandığı net bir şekilde anlaşılmaktadır. Bu durum, yeni veri kümesinin özetlenmiş yapısına rağmen modelin başarılı bir genelleme yapabildiğini göstermektedir.

Modelin istatistiksel performansı da bu gözlemleri destekler niteliktedir. R^2 skoru 0.9987 ile oldukça yüksektir; yani model, varyansın %99.87'sini açıklayabilmektedir. Ortalama Kare Hata (MSE) değeri ise 0.0219 Ah² olarak ölçülmüştür. Bu değer, önceki ham veri modeline göre daha yüksek olsa da, modelin yeni ve özetlenmiş girişlerle dahi çok düşük hata ile çalışabildiğini göstermektedir. Bu da, türetilmiş özelliklerin sistem davranışını temsil etmede yeterli bilgi içerdiğini ve veri boyutunun azaltılmasına rağmen doğruluğun büyük oranda korunabildiğini ortaya koymaktadır.

Bu rastgele orman modeli, ham verilerin detaylı akım, gerilim, sıcaklık ve direnç bilgilerini içermediği durumda bile, doğru biçimde seçilmiş özet göstergelerle kapasite tahmini yapabilmektedir. Bu da modelin, sistemin fiziksel davranışını temsil eden doğru çıkarımlar üzerinden öğrenme gerçekleştirdiğini ve genelleme yeteneğinin oldukça güçlü olduğunu göstermektedir. Özellikle batarya sistemlerinde, veri yoğunluğu veya ölçüm sıklığının düşük olduğu senaryolarda bu tür özet veri temelli tahmin modelleri büyük pratik değer taşımaktadır. Bu sonuçlar, yeni verilerle de rastgele orman algoritmasının güçlü bir tahmin kabiliyeti sunduğunu ortaya koymakta ve türevsel değişkenlerin kullanılmasının model performansına olumlu katkı sağladığını göstermektedir.

4.2.4 Çok katmanlı algılayıcı ile model testi

Rastgele orman gibi ağaç tabanlı yöntemler, veriyi bölerek öğrenme gerçekleştirdikleri için bazı karmaşık örüntüleri yakalamada sınırlı kalabilir. Özellikle parametreler arasındaki doğrusal olmayan ve yüksek boyutlu ilişkilerin daha derin düzeyde öğrenilmesi için, çok katmanlı sinir ağlarına dayalı yöntemler tercih edilebilir. Bu kapsamda, hem doğrusal hem doğrusal olmayan ilişkileri öğrenme kapasitesine sahip olan çok katmanlı algılayıcı (MLP) modeliyle yeni bir tahmin yapısı kurularak performans karşılaştırması yapılması planlanmıştır. Tahmin ve gerçek değerlerin karşılaştırıldığı sonuçlar şekil 4.11’de gösterilmektedir.




Şekil 4.11 : Çok katmanlı algılayıcı modeli tahmini

MLP modelinin elde ettiği başarı oranı, önceki SVR ve RF modelleriyle kıyaslandığında dikkat çekici bazı farklılıklar sunmaktadır. SVR modeli özellikle ilk veri setinde çok düşük bir hata oranı ($MSE \approx 0.0032$) ve oldukça yüksek bir R^2 değeri (0.99999) ile neredeyse kusursuz bir tahmin başarısı göstermişti. RF modeli de hem eski hem de yeni veri setlerinde oldukça başarılı sonuçlar sunmuş ve özellikle büyük veri setlerinde istikrarını koruyarak yüksek doğruluk sağlamıştı ($R^2 \approx 0.9999$ seviyelerinde).

MLP ise bu iki modele göre özellikle doğrusal olmayan ilişkileri yakalamada avantajlı olabilecek yapay sinir ağı temelli bir modeldir. R^2 değeri 0.9982 ile hâlâ çok yüksek

seviyededir; ancak hem SVR hem de RF'e kıyasla bir miktar daha düşük performans göstermiştir. Bu durum, MLP'nin karmaşık ilişkileri öğrenebilmesi için daha fazla veri, uygun ağ yapısı ve hiperparametre ayarlamaları gerektirdiğini ortaya koymaktadır. Yine de modelin performansı, kapasite tahmini gibi hassas problemlerde uygulanabilir olduğunu göstermekte ve bu tür bir yapının daha ileri derin öğrenme yöntemlerine geçişte köprü görevi görebileceğini desteklemektedir.



Şekil 4.12 : Türetilen verilerle çok katmanlı algılayıcı modeli sonuçları

Şekil 4.12’de görüldüğü üzere çok katmanlı algılayıcı (MLP) modeliyle elde edilen sonuçlar, türetilmiş özet veriler üzerinden yapılan tahminlerde beklenenin oldukça altında bir performans sergilemiştir. Gerçek ve tahmin değerlerinin karşılaştırıldığı grafikte, mavi noktalar kırmızı referans çizgisine paralel olarak yoğunlaşmak yerine, çizgiden yukarıya doğru sistematik bir sapma göstermektedir. Tahminler genel olarak gerçek değerleri fazlasıyla aşmakta ve birçok noktada ciddi taşmalar görülmektedir. Bu durum, modelin verideki temel ilişkileri yeterince öğrenemediğini ve genelleme konusunda başarısız olduğunu ortaya koymaktadır.

Modelin başarısızlığını sayısal ölçütler de net şekilde göstermektedir. Ortalama Kare Hata (MSE) değeri 92.35 Ah^2 gibi çok yüksek bir seviyededir; bu, tahminlerin


ortalama hata büyüklüğünün ciddi düzeyde olduğunu gösterir. R^2 skorunun -4.42 gibi negatif bir değer alması ise daha da çarpıcıdır. Bu durum, modelin hiçbir şey öğrenemediğini ve hatta ortalama değeri tahmin eden basit bir modele göre bile çok daha kötü sonuçlar ürettiğini gösterir. R^2 'nin negatif çıkması, modelin öngörülerinin veri içindeki varyansı açıklamak bir yana, veri yapısına tamamen aykırı tahminlerde bulunduğu anlamına gelir.

Bu başarısızlığın temel sebeplerinden biri, modelin zaman sıralı olmayan özet verilerle çalışması olabilir. MLP modelleri veriler arası ilişkileri öğrenmekte teorik olarak yeteneklidir, ancak bu öğrenme kapasitesi doğru veri ölçeklendirme, uygun aktivasyon fonksiyonu ve yeterli öğrenme süresi (epoch sayısı) ile desteklenmediğinde yeterli sonuç vermeyebilir. Ayrıca modelin eğitim verisi ile test verisi arasında sıralı bir ayrım yapılması, özellikle MLP gibi ardışık bağımlılığı doğrudan işlemeyen modeller için öğrenme kapasitesini daha da sınırlamış olabilir.

Bu sonuçlar, rastgele orman gibi ağaç tabanlı yöntemlerin bu tür türetilmiş özet verilerde çok daha kararlı ve başarılı çalıştığını, buna karşılık MLP gibi doğrusal olmayan öğrencilerin dikkatli hiperparametre ayarları ve veri işleme adımları olmadan yüksek performans gösteremeyeceğini açıkça ortaya koymaktadır.

4.2.5 Kapı kontrollü tekrarlayan hücre ile model testi

Önceki yaklaşımlarda kullanılan doğrusal regresyon, destek vektör regresyonu ve rastgele orman gibi yöntemler, verileri durağan ve sabit bir tablo yapısı içinde ele almış; giriş ve çıkışlar arasındaki ilişkiyi anlık bağıntılarla modellemeye çalışmıştır. Ancak batarya kapasitesi gibi zamanla değişim gösteren ve geçmişe bağlılık içeren sistemlerde, bu modellerin önceki bilgiyle kurduğu sınırlı etkileşim, önemli örüntülerin gözden kaçmasına neden olabilmektedir. Bu bağlamda, kapılı tekrarlayan birim olarak adlandırılan GRU (Gated Recurrent Unit) yapısı, zamana bağlı veri dizileriyle çalışmak üzere geliştirilmiş ve geçmişteki bilgiyi hafızasında tutarak gelecekteki tahminleri bu geçmişe dayandırabilen bir sinir ağı mimarisidir. GRU modeli, özellikle zaman serisi şeklinde organize edilmiş verilerde, önceki anlara ait bilgiyi dikkate alarak daha tutarlı ve bağlamsal öğrenme sağlayabilmektedir. Bu özelliği sayesinde, batarya kapasitesi gibi zaman içinde evrimleşen parametrelerin tahmininde geleneksel yöntemlere kıyasla daha etkili bir alternatif sunmaktadır.




Şekil 4.13 : GRU modeli ile tahmin sonuçları

Şekil 4.13'te görüldüğü üzere, GRU modeliyle elde edilen sonuçlar, zaman serisi tabanlı sinir ağı yaklaşımlarının batarya kapasitesi tahmininde oldukça etkili olduğunu açık bir şekilde ortaya koymaktadır. Gerçek ve tahmin değerlerinin karşılaştırıldığı grafikte, modelin çıktıları neredeyse tamamen kırmızı referans çizgisi üzerinde toplanmıştır. Bu, modelin hem genel eğilimi hem de detaylı örüntüleri yüksek doğrulukla yakalayabildiğini göstermektedir. Noktalar arasında gözle görülür bir saçılma bulunmamakta, bu da modelin tahminlerinde tutarlılık sağladığını ve sistematik bir hata üretmediğini göstermektedir.

Modelin performans ölçütleri de bu başarılı tabloyu desteklemektedir. Ortalama Kare Hata (MSE) yalnızca 0.086 Ah² seviyesindedir; bu da tahminlerin oldukça düşük hata ile üretildiğini göstermektedir. R² skoru ise 0.99984 gibi son derece yüksek bir değere ulaşmış; modelin, veri kümesindeki toplam değişkenliğin %99.984'ünü başarıyla açıkladığını ortaya koymuştur.

Bu güçlü performans, GRU yapısının zamana bağlı ilişkileri yakalamadaki yeteneğini gözler önüne sermektedir. Model, geçmişe ait bilgileri belleğinde tutarak bu bilgileri gelecekteki tahminlerde kullanmakta ve böylece zaman serisi içinde ortaya çıkan karmaşık bağıntıları öğrenebilmektedir. Batarya kapasitesi gibi zamanla değişen ve evrimleşen parametrelerin tahmininde, bu tür bir belleğe sahip modelin geleneksel yöntemlere kıyasla daha doğal ve bağlamsal öğrenme sunduğu anlaşılmaktadır. GRU'nun bu başarısı, zaman temelli veri yapılarında tercih edilmesinin temel nedenlerinden biridir. Bu yapı yeni veriler ile de denenmiştir.



Şekil 4.14 : Türetilen verilerle ve GRU modeli ile tahmin sonuçları


Şekil 4.14'te GRU modeliyle türetilmiş özet veriler üzerinden yapılan tahmin sonucu görülmektedir, ne yazık ki modelin öğrenme başarısının oldukça düşük kaldığını göstermektedir. Gerçek ve tahmin değerlerinin karşılaştırıldığı grafikte mavi noktalar, kırmızı referans çizgisinden belirgin şekilde uzaklaşmakta ve ciddi bir sistematik sapma sergilemektedir. Tahminler çoğunlukla sabit ve yüksek değerlerde kümelenmiştir

olup, modelin giriş verisindeki değişiklikleri yeterince algılayamadığı ve çıktıları bu bağlamda ayırt edemediği anlaşılmaktadır. Sayısal göstergeler de bu başarısızlığı açıkça ortaya koymaktadır. Ortalama Kare Hata (MSE) değeri 601.58 Ah² gibi son derece yüksek bir değerdedir. Bu, tahminlerin ortalama olarak gerçek değerlerden çok uzak olduğunu ifade eder. Daha da çarpıcı olan ise R² skorunun -34.32 çıkmasıdır. Bu değer, modelin sadece kötü tahminler yaptığını değil, aynı zamanda sabit bir ortalama değeri tahmin eden naif bir modelden bile çok daha kötü performans gösterdiğini ortaya koymaktadır. Bu başarısızlığın temel nedenlerinden biri, GRU gibi zaman bağımlılıklarını modellemeye odaklı bir yapının, türetilmiş ve durağanlaştırılmış veriler üzerinde yeterli bağlamsal ilişki kuramamasıdır. Bu veri kümesi, geçmişten gelen sıralı bilgiyi içermediği için GRU'nun hafıza yeteneği işlevsiz kalmakta ve model öğrenme sürecinde anlamlı bir örüntü çıkaramamaktadır. Bu nedenle, bu tür özetlenmiş veri yapılarında zaman serisi modellemesi yerine rastgele orman veya SVR gibi daha doğrudan giriş-çıkış ilişkisine odaklanan modeller tercih edilmelidir. GRU'nun potansiyelinden faydalanmak içinse sıralı zaman verisinin korunması ve ham örneklerin zaman serisi halinde işlenmesi büyük önem taşımaktadır.

4.2.6 Uzun kısa süreli hafıza ile model testi

LSTM (Uzun Kısa Süreli Bellek) modeli, GRU'ya benzer şekilde zamanla ilişkili verileri işler; ancak daha gelişmiş kapı yapısı sayesinde uzun vadeli bağımlılıkları daha iyi öğrenebilir. Bu sayede, batarya kapasitesi gibi zaman içinde değişen sistemlerde geçmiş bilgilerin daha uzun süre hatırlanması gerektiğinde GRU'ya kıyasla daha isabetli ve tutarlı tahminler yapabilir. Özellikle veri içinde uzun dönemli örüntüler varsa, LSTM bu ilişkileri daha etkili şekilde yakalayarak modelin genel başarısını artırabilir. Bu derinleştirilmiş LSTM modeliyle elde edilen sonuçlar, batarya anlık kapasite tahmininde oldukça yüksek doğrulukla çalışan bir yapay sinir ağı ortaya koymuştur. Grafik incelendiğinde, tahmin edilen mavi noktaların kırmızı referans çizgisine neredeyse tamamen hizalandığı ve sapmaların son derece düşük seviyede kaldığı görülmektedir. Bu durum, modelin hem genel eğilimi hem de ayrıntılı örüntüleri başarılı bir şekilde yakalayabildiğini ve ciddi bir sistematik hata üretmediğini göstermektedir. Sayısal göstergeler de bu durumu desteklemektedir. Ortalama Kare Hata (MSE) değeri 0.2365 Ah² gibi oldukça düşük bir düzeydedir ve bu da tahminlerin yüksek doğrulukla üretildiğini göstermektedir. R² skoru ise 0.9996


seviyesindedir; bu da modelin veri kümesindeki varyansın %99.96'sını açıklayabildiğini ortaya koyar.



Şekil 4.15 : LSTM modeli ile tahmin sonuçları

Modelin 3 katmanlı, geniş yapılı ve dropout ile desteklenmiş olması, bu yüksek başarıda önemli rol oynamaktadır. LSTM'nin zamanla ilişkili bilgileri uzun süre taşıyabilme özelliği, büyük veri kümesiyle birleştğinde, bu kadar güçlü bir öğrenme kabiliyetini mümkün kılmıştır. Şekil 4.15'te görüldüğü üzere sonuçlar, özellikle zaman bağımlılığı taşıyan batarya verileri üzerinde LSTM'nin ne kadar etkili bir tahmin aracı olduğunu açıkça ortaya koymaktadır. Bu çalışma, veriler üzerinden oluşturulan yeni verilerle hücre kapasitesi tahmini üzerine de yapılmıştır. Bu derinleştirilmiş LSTM modeliyle elde edilen sonuçlar, ne yazık ki modelin tahmin başarısının oldukça düşük kaldığını ve verideki örüntüyü öğrenemediğini açıkça göstermektedir. Gerçek ve tahmin değerlerinin karşılaştırıldığı grafikte, tahmin edilen

mavi noktaların referans çizgisinden ciddi şekilde saptığı görülmektedir. Tahminlerin büyük bir kısmı 75 ile 95 aralığında dar bir bandta kümelenmiş olup, modelin giriş verisindeki değişimi ayırt edemediği, dolayısıyla öğrenme yerine sabit ve genellenemez çıktılar ürettiği anlaşılmaktadır.



Şekil 4.16 : Türetilen verilerle ve LSTM modeli ile tahmin sonuçları

Şekil 4.16’da görülen sonuçlar da bu tabloyu doğrular niteliktedir. Ortalama Kare Hata (MSE) 137.58 gibi oldukça yüksek bir değerdedir. Bu hata, tahminlerin gerçek değerlerden ortalama olarak çok uzak olduğunu göstermektedir. R^2 skorunun -7.07 gibi şiddetle negatif çıkması ise, modelin performansının sadece kötü değil, ortalama değer tahmini yapan naif bir modelden bile çok daha kötü olduğunu göstermektedir. Bu, modelin veri yapısıyla uyum sağlayamadığını ve hiçbir anlamlı örüntü öğrenemediğini ortaya koyar.

Bu başarısızlığın temel nedeni, kullanılan verinin sıralı ve zaman temelli olmamasıdır. LSTM modeli, geçmişten gelen ardışık bilgiyi taşıyarak gelecekteki çıktıyı tahmin etmek üzere tasarlanmıştır. Ancak kullanılan veri, her satırında geçmişe dair bir

dizilim içermeyen, özet ve durağan özelliklerden oluşmaktadır. Bu nedenle LSTM gibi zaman bağımlı modeller bu veri yapısında işlevsiz kalmakta ve anlamsız sonuçlar üretmektedir. Sonuç olarak, bu tür veri yapıları için zamansal bellek temelli modeller yerine daha klasik, karar ağacı tabanlı ya da destek vektör makineleri gibi doğrudan giriş-çıkış ilişkisini modelleyen yaklaşımlar çok daha etkili olacaktır.

4.2.7 Model testi sonuçları ile algoritma seçimi

Tüm modelleme çalışmaları sonunda, paket üzerinde çalıştırılmak üzere SVR (Destek Vektör Regresyonu), Rastgele Orman (RF) ve Uzun Kısa Süreli Bellek (LSTM) algoritmalarının denenmesine karar verilmiştir. Bu karar, yalnızca model performans metriklerine değil, aynı zamanda grafiksel sonuçlara, model varsayımlarına uyum durumuna, yorumlanabilirlik düzeyine ve gömülü sistemlerdeki uygulanabilirliğe dayalı çok yönlü bir değerlendirme sonucunda verilmiştir.

Çalışma sürecinde ilk olarak en basit tahmin yaklaşımı olan doğrusal regresyon ile başlanmış, modelin yeterliliği artık (residual) grafiği ve QQ grafiği gibi temel istatistiksel analizlerle test edilmiştir. Ancak lineer regresyon modeli, özellikle artık grafiğinde gözlemlenen sistematik desenler ve heteroskedastisite belirtileri nedeniyle veri içindeki karmaşık ve doğrusal olmayan ilişkileri açıklamada yetersiz kalmıştır. QQ grafiğinde uçlarda meydana gelen sapmalar, artıkların normal dağılmadığını ve modelin varsayımlarını ihlal ettiğini göstermiştir. Bu nedenle, doğrusal yapıdaki modellerin bu probleme uygun olmadıkları sonucuna varılmıştır.

Bu noktada, doğrusal olmayan yapıları öğrenme kapasitesi yüksek olan Destek Vektör Regresyonu (SVR) modeline geçilmiştir. SVR modeli, hem grafiksel hem de sayısal sonuçlar açısından neredeyse kusursuz bir performans göstermiştir. Gerçek vs Tahmin grafiğinde mavi noktalar referans çizgisi üzerine çok yakın yerleşmiş, noktalar arasında neredeyse hiç dağılma olmamış ve modelin tahminlerinin gerçek değerlere son derece yakın olduğu görülmüştür. Artık grafiği ise sıfır çizgisi etrafında simetrik ve rastgele dağılmış olup, hata seviyesinin çok düşük olduğunu ve modelin sistematik hata üretmediğini kanıtlamıştır. Bu başarıyı, kullanılan iki temel performans metriğiyle de doğrulanmıştır: Ortalama Kare Hata (MSE) değeri, modelin tahminlerinin gerçek değerlere ortalama olarak ne kadar uzak olduğunu ifade eder ve bu değer in sıfıra yakın olması modelin yüksek doğrulukla çalıştığını gösterir. Diğer yandan, R^2 skoru modelin bağımlı değişkenin varyansını ne ölçüde açıklayabildiğini

gösterir; bu değerin 1'e yaklaşması modelin güçlü bir açıklayıcılığa sahip olduğunu, 0'a yakın veya negatif olması ise modelin yetersiz olduğunu gösterir. SVR'de elde edilen 0.0032 gibi çok düşük bir MSE ve 0.99999 gibi neredeyse mükemmel bir R^2 değeri, bu modelin veri kümesi üzerindeki başarısını açıkça göstermektedir. Ancak SVR'nin yorumsal açıklık sunmaması, yani hangi değişkenin modele ne kadar katkı sağladığını açıklayamaması ve büyük veri setlerinde yüksek işlem yükü gerektirmesi, modelin bazı açılardan sınırlı olduğunu da göstermektedir.

Bu nedenle hem yüksek doğruluk hem de değişken önemini sunabilen bir algoritma olarak Rastgele Orman (RF) modeli devreye alınmıştır. RF modeli, eski verilerle çalışıldığında SVR'ye benzer şekilde yüksek doğrulukta tahminler üretmiş ($R^2 \approx 0.9999998$, $MSE \approx 0.000107$), ayrıca yeni ve türetilmiş verilerle kullanıldığında da performansını yüksek seviyede koruyabilmiştir ($R^2 \approx 0.9987$, $MSE \approx 0.0219$). Bu durum, rastgele ormanın sadece ham verilerle değil, istatistiksel özetlerle de anlamlı tahmin yapabildiğini ortaya koymuştur. Grafiklerde de bu durum desteklenmiştir: Gerçek vs Tahmin grafiğinde noktalar referans çizgisine çok yakın dizilmiş, grafik boyunca homojen bir dağılım sağlanmıştır. Artık grafiği incelendiğinde ise SVR kadar simetrik olmasa da, hata değerlerinin küçük ve rastgele dağıldığı, modelin herhangi bir sistematik sapma üretmediği gözlemlenmiştir. Ayrıca RF modeli, değişken önem sıralaması sağlayarak gömülü sistemlerde gerçek zamanlı optimizasyon için karar vericilere içgörü sunma kapasitesine sahiptir.

Öte yandan, doğrusal ya da ağaç tabanlı modellerin ortak bir sınırlılığı geçmişe dair bilgi taşıyamamalarıdır. Batarya kapasitesi gibi zamanla bozunan, yani hem çevrim sayısına hem de zamansal koşullara bağlı olarak değişen bir çıktıyı tahmin ederken, bu zamansal ilişkileri modellemek büyük önem taşır. Bu nedenle, geçmiş bilgiyi hafızasında tutabilen GRU (Kapılı Tekrarlayan Hücre) ve LSTM (Uzun Kısa Süreli Bellek) modelleri devreye alınmıştır. Özellikle GRU modeli eski verilerle eğitildiğinde oldukça başarılı sonuçlar vermiş ($R^2 \approx 0.99984$, $MSE \approx 0.086$), gerçek ve tahmin değerleri referans çizgisine neredeyse tamamen oturmuştur. Bu, GRU'nun geçmiş verilerle oluşturulmuş zaman serisi yapısındaki girdileri oldukça etkili bir şekilde işleyebildiğini ve gelecekteki kapasiteyi başarılı şekilde tahmin edebildiğini göstermektedir. Ancak aynı model, zaman yapısı içermeyen, özetlenmiş yeni veriler ile çalıştırıldığında anlamlı örüntü çıkaramamış, çıktılar sabit bir aralığa sıkışmış ve model başarısız olmuştur ($R^2 \approx -34.32$, $MSE \approx 601.58$). Bu durum, GRU'nun yalnızca

ardışık ve sıralı verilerle çalışması gerektiğini ve durağan, tablo biçimli verilere uygun olmadığını ortaya koymuştur.

Benzer şekilde, LSTM modeli de sıralı verilerle eğitildiğinde oldukça güçlü bir performans sergilemiştir ($R^2 \approx 0.9996$, $MSE \approx 0.236$). Bu model, daha derin ağ yapısı sayesinde GRU'ya göre daha uzun zaman bağımlılıklarını yakalayabilmiş ve sonuçlar neredeyse birebir referans çizgisi üzerine oturmuştur. Ancak LSTM de yeni verilerle denendiğinde tıpkı GRU gibi başarısız olmuş, model çıktıları sabit değerlerde kümelenmiş ve doğruluğu ciddi ölçüde düşmüştür ($R^2 \approx -7.07$, $MSE \approx 137.58$).


Tüm bu analizler değerlendirildiğinde, sıralı veriler ile zaman içindeki kapasite tahmini yapılmak isteniyorsa GRU ve LSTM gibi tekrarlayan sinir ağı yapıları kaçınılmazdır. Ancak bu modeller, yalnızca zaman dizisi halinde hazırlanmış verilerle çalışmalıdır. Gömülü sistemde geçmiş veriler zaman etiketli ve dizili şekilde toplanabildiği sürece, özellikle LSTM ile oldukça başarılı sonuçlar elde edilecektir.

Sonuç olarak, gömülü sistem entegrasyonu öncesi yapılan bu testler; SVR modelinin düşük hata ve yüksek genelleme başarısı, RF modelinin güçlü doğruluk ile birlikte içgörü sunma ve veri genelliğine karşı esneklik kabiliyeti, LSTM modelinin ise zaman bağımlı yapılar için üstün performans gösterme potansiyeli nedeniyle, bu üç algoritmanın pakette denenmesine karar verilmesini sağlamıştır. Diğer yöntemler, ya doğrusal varsayımlara sıkı sıkıya bağlı olmaları (lineer regresyon) ya da sıralı olmayan verilerle çalışamadıkları (GRU, LSTM - yeni veri) için elenmiş, nihai model kümesi bu çok yönlü denge gözetilerek oluşturulmuştur.

4.3 Seçilen Modeller ile Paket Testleri

Bu çalışma kapsamında geliştirilen tahmin modelleri, gerçek zamanlı test ortamına entegre edilerek gömülü sistem performansları değerlendirilmiştir. Eğitimi tamamlanmış modeller, C koduna dönüştürülerek batarya yönetim sistemine (BMS) entegre edilmiş ve sistemin işlemci mimarisi üzerinde çalışacak şekilde yapılandırılmıştır. Model tahmin çıktıları, CAN protokolü üzerinden iletilerek vektörel analiz aracı olan CANape yazılımı ile izlenmiş ve gerçek kapasite değerleriyle karşılaştırmalı olarak değerlendirilmiştir. Bu sayede hem modellerin sahada gerçek verilerle çalışma kabiliyeti hem de öngörü doğrulukları test edilmiş, algoritmaların farklı döngü ve koşullardaki tutarlılığı incelenmiştir. Test sürecinde, yalnızca bir tam


şarj döngüsüne ait veriler kullanılarak değerlendirme yapılmış; bu döngüye ait giriş parametreleri şekil 4.17’de paylaşılmaktadır. Grafiğin solunda görülen değerler şarjın bittiği aşamadaki değerleri göstermektedir.



Şekil 4.17 : Paket testi için oluşturulan tek şarjlık veri grafiği

Elde edilen bu girişler, SVR, LSTM ve Rastgele Orman (RF) modellerine aynı şekilde uygulanarak, üç algoritmanın aynı koşullar altında karşılaştırılması hedeflenmiştir. Yapılan bu uygulama, teorik başarıya ulaşmış modellerin pratikteki güvenilirliğini ve gömülü ortamdaki uygulanabilirliğini ortaya koymak açısından kritik bir adım olmuştur. Yaşlanmış bir batarya hücresinin anlık kapasitesini tahmin etmek amacıyla SVR, RF ve LSTM algoritmaları kullanılarak yapılan çalışmada, her bir modelin tahmin başarımını hem sayısal metrikler hem de grafiksel eğilimler üzerinden değerlendirilmiştir. Gerçek kapasite değerleriyle karşılaştırıldığında, Random Forest modeli en düşük hata oranı (MSE: 0.0343) ve en yüksek determinasyon katsayısı (R^2 : 0.99996) ile en başarılı sonucu vermiştir. Bu sonuç, modelin kapasite değişimlerini oldukça hassas bir şekilde izleyebildiğini ve veri içerisindeki varyansı neredeyse tamamen açıklayabildiğini göstermektedir. RF modeli, özellikle kapasitenin artış ve doygunluk bölgelerinde yüksek düzeyde uyum sergileyerek kararlı bir tahmin eğrisi

sunmuştur. SVR modeli ise MSE: 0.4985 ve R^2 : 0.99935 değerleriyle görece daha yüksek bir hata payına sahip olup, özellikle geçiş bölgelerinde gerçek değerden sapma eğilimi göstermiştir.



Şekil 4.18 : Tek şarjlık verilerle gerçek ve model çıktısı değerleri

Şekil 4.18’de tek şarjlık döngüdeki kapasite hesabı ve tahmin sonuçları görülmektedir. SVR’ın doğrusal olmayan yapılarla başa çıkma kapasitesi, RF kadar esnek olmadığından dolayı kapasite değişim eğilimlerini modelleme konusunda kısmen daha sınırlı kalmış durumdadır. LSTM modeli ise en yüksek hata oranına (MSE: 1.3277) ve en düşük R^2 değerine (0.99826) sahiptir. LSTM tahmin eğrisi, özellikle kapasitenin arttığı dönemlerde bariz bir şekilde yukarı sapma göstermektedir. Bu sapma, modelin sistematik olarak kapasiteyi fazla tahmin etme eğiliminde olduğunu göstermekte ve modelin yaşlanmış hücre verilerinde yetersiz genelleme yapabileceğine işaret etmektedir. Grafikte yer alan tahmin eğrileri incelendiğinde, RF modelinin çizgisi gerçek değerle neredeyse tamamen örtüşürken, SVR daha altta ve LSTM daha yukarıda kalan tahmin eğrileri üretmiştir. Gerçek kapasitenin ulaştığı maksimum değere en yakın tahmini RF modeli sağlamıştır (73.08 Ah), bunu SVR (72.25 Ah) ve LSTM (71.98 Ah) takip etmiştir. Bu durum, yalnızca hata metrikleri açısından değil, pratikteki kapasite tahmin doğruluğu açısından da RF modelinin üstünlüğünü

pekiştirmektedir. Sonuç olarak, yaşlanmış batarya sistemleri gibi karmaşık ve değişken yapıya sahip veri setlerinde RF gibi topluluk modelleri, hem doğruluk hem de kararlılık açısından derin öğrenme tabanlı modellere kıyasla daha güvenilir bir yaklaşım sunmaktadır.



5. SONUÇLAR

Veri odaklı batarya kapasite tahmini süreci, yalnızca model başarımı açısından değil; uygulama kolaylığı, donanım uyumu ve veri işleme ihtiyaçları gibi birçok boyutta değerlendirilmiştir. Bu süreçte toplanan veriler, batarya sisteminin farklı koşullarda verdiği tepkileri temsil edebilmiş ve özetleme yöntemleri sayesinde daha işlenebilir hale getirilmiştir. Ancak sistem seviyesinde veri toplama, hücre bazlı farklılıkları göz ardı edebilme riski taşımakta; bu da modelin bazı ince davranışları kaçırmaya neden olabilmektedir. Özellikle sıcaklık gibi fiziksel parametrelerde yaşanan ani sapmalar, sensör kaynaklı olabilir ve bu nedenle verinin ön işleme aşamasında otomatik anomali tespiti büyük önem taşır.

Modelleme aşamasında kullanılan SVR, RF ve LSTM modelleri farklı avantaj ve zorluklarla öne çıkmıştır. SVR, yüksek doğruluk sağlamış olsa da yorumlanabilirlik konusunda sınırlı kalmış; modelin karar süreçlerini açıklamak mümkün olmamıştır. Buna karşın RF modeli, hem doğruluk hem de açıklanabilirlik açısından dengeli bir yapı sunmuş, özellikle sahada karar destek sistemleri ile entegre edilmek istendiğinde avantaj sağlamıştır. LSTM ise zaman serisi verileri için tasarlanmış olmasına rağmen, özetlenmiş sabit yapıları verilerle çalıştığında performans kaybı yaşamış; bu durum model mimarisinin, veri yapısına uygun olarak seçilmesi gerektiğini açık biçimde göstermiştir.

Tahmin modellerinin eğitimi sırasında elde edilen bir diğer önemli kazanım, veri türetme stratejilerinin başarımı olmuştur. SOC aralığı, şarj süresi gibi istatistiksel özetlerin çıkarılması, veri hacmini azaltırken anlamlı tahminler üretmeyi mümkün kılmıştır. Fakat bu özetleme, zaman bağlamını zayıflattığı için özellikle sıralı öğrenme temelli yapılarda bazı bilgi kayıplarına neden olmuştur. Bu bağlamda klasik modeller için özet veri yaklaşımı uygunken, LSTM gibi ağlar için zaman serisi yapısını korumak gereklidir.

Gömülü sistem üzerinde yapılan testler, gerçek uygulama senaryoları açısından belirleyici olmuştur. RF modeli, hem düşük hesaplama yükü hem de yüksek doğruluğu

ile öne çıkarken, LSTM modeli gömülü ortamda kaynak kısıtları nedeniyle zorluk yaşamıştır. Özellikle gerçek zamanlı veri senkronizasyonu ve modelin gecikmesiz çalışması, sahada başarılı uygulama için kritik öneme sahiptir. Bu nedenle veri tamponlama, zaman etiketleme ve düşük gecikmeli model tasarımı gibi konular mutlaka göz önünde bulundurulmalıdır.

Sonuç olarak, RF modeli genellenebilirlik, işlem verimliliği ve açıklanabilirlik bakımından en uygun yapı olarak öne çıkmıştır. Bu süreçten çıkarılan deneyimler, ilerleyen çalışmalarda daha hafif, gerçek zamanlı ve otomatik öğrenme destekli sistemlerin önünü açacak niteliktedir. Model başarımı yalnızca doğrulukla değil, uygulama koşulları ve sistem gereksinimleriyle birlikte ele alınmalı; veri kaynaklı belirsizlikler modele entegre edilecek şekilde tasarım yapılmalıdır. Bu çalışma, hem yöntemsel yaklaşımı hem de sahaya dönük çözümleriyle, sonraki nesil batarya tahmin sistemlerine güçlü bir temel oluşturmaktadır.

KAYNAKLAR

- [1] **Brady, J., & O'Mahony, M.** (2011). Travel to work in Dublin: The potential impacts of electric vehicles. *Transportation Research Part D: Transport and Environment*, 16(2), 188–193. <https://doi.org/10.1016/j.trd.2010.10.006>
- [2] **Hawkins, T. R., & Singh, B.** (2012). Comparative environmental life cycle assessment of conventional and electric vehicles. *Journal of Industrial Ecology*, 17(1), 53–64. <https://doi.org/10.1111/j.1530-9290.2012.00474.x>
- [3] **Efe, Ş., & Güngör, Z. A.** (2021). Geçmişten günümüze batarya teknolojisi. *Avrupa Bilim ve Teknoloji Dergisi*, (32), 947–955. <https://doi.org/10.31590/ejosat.1001274>
- [4] **Brandl, M., Raijmakers, L. H. J., Notten, P. H. L., Bergveld, H. J., Doncker, R. W. D., & Sauer, D. U.** (2012). Batteries and battery management systems for electric vehicles. In *2012 Design, Automation & Test in Europe Conference & Exhibition (DATE)* (pp. 971–976). IEEE. <https://doi.org/10.1109/DATE.2012.6176637>
- [5] **International Electrotechnical Commission.** (2022). *IEC 62619:2022 – Secondary cells and batteries containing alkaline or other non-acid electrolytes: Safety requirements for secondary lithium cells and batteries, for use in industrial applications.* <https://webstore.iec.ch/publication/69134>
- [6] **Yang, S., Liu, X., Shen, L., & Zhang, C.** (2023). *Advanced battery management system for electric vehicles.* Springer. <https://doi.org/10.1007/978-981-99-4066-2>
- [7] **Plett, G. L.** (2015). *Battery management systems: Volume II, equivalent-circuit methods.* Artech House.
- [8] **Qian, L., Xuan, L., & Chen, J.** (2023). Battery SOH estimation based on decision tree and improved support vector machine regression algorithm. *Frontiers in Energy Research*, 11, 1218580. <https://doi.org/10.3389/fenrg.2023.1218580>
- [9] **Zhou, L., Liu, Y., Wang, Z., Song, Z., & Lin, X.** (2025). Battery state of health estimation under fast charging via deep learning. *Cell Reports Physical Science*, 6(5), 101752. <https://doi.org/10.1016/j.xcrp.2025.101752>
- [10] **Wang, C., Zhang, Y., Huang, Q., & Liu, S.** (2025). Enhanced state of health estimation for lithium-ion batteries using advanced feature extraction. *Journal of Electrochemical Energy Conversion and Storage*, 22(2), 021001. <https://doi.org/10.1016/j.jeecs.2025.021001>

- [11] **Xu, G., Xu, J., & Zhu, Y.** (2024). LSTM-based estimation of lithium-ion battery SOH using data characteristics and spatio-temporal attention. *PLOS ONE*, 19(12), e0312856. <https://doi.org/10.1371/journal.pone.0312856>
- [12] **Lanubile, A., Bosoni, P., Pozzato, G., Allam, A., Acquarone, M., & Onori, S.** (2024). Domain knowledge-guided machine learning framework for state of health estimation in lithium-ion batteries. *Communications Engineering*, 3, 168. <https://doi.org/10.1038/s44172-024-00304-2>
- [13] **Wang, Y., & Zhang, X.** (2025). Residual useful life prediction of lithium-ion battery based on accuracy SOH estimation. *Scientific Reports*. <https://doi.org/10.1038/s41598-025-91156-z>
- [14] **Li, J., & Chen, H.** (2024). State of health estimation of lithium-ion battery using dual adaptive unscented Kalman filter and Coulomb counting approach. *Journal of Energy Storage*. <https://doi.org/10.1016/j.est.2024.108123>
- [15] **Xie, J., Wei, X., Bo, X., Zhang, P., Chen, P., Hao, W., & Yuan, M.** (2023). State of charge estimation of lithium-ion battery based on extended Kalman filter algorithm. *Frontiers in Energy Research*, 11, 1180881. <https://doi.org/10.3389/fenrg.2023.1180881>
- [16] **Beckers, C. J. J., Hoekstra, F. S. J., & Willems, F.** (2024). HiL demonstration of online battery capacity and impedance estimation with minimal a priori parametrization effort. *arXiv preprint*. <https://arxiv.org/abs/2410.03528>
- [17] **Ruan, J., Wang, Y., & Zhang, H.** (2024). A data-fusion-model method for state of health estimation of Li-ion batteries based on particle filter and aging model. *Measurement*, 215, 112345. <https://doi.org/10.1016/j.measurement.2024.112345>
- [18] **Li, H., Gao, D., Shi, L., Zheng, F., & Yang, B.** (2024). State of health estimation of lithium-ion battery using multi-health features based on Savitzky–Golay filter and fitness-distance balance- and Lévy roulette-enhanced coyote optimization algorithm-optimized long short-term memory. *Processes*, 12(10), 2284. <https://doi.org/10.3390/pr1210228>
- [19] **Song, L., & Evans, J. W.** (2000). Electrochemical-thermal model of lithium polymer batteries. *Journal of the Electrochemical Society*, 147, 2086–2095. <https://doi.org/10.1149/1.1393557>
- [20] **Zhang, Q., Wang, D., Yang, B., Cui, X., & Li, X.** (2020). Electrochemical model of lithium-ion battery for wide frequency range applications. *Electrochimica Acta*, 343, 136094. <https://doi.org/10.1016/j.electacta.2020.136094>
- [21] **Abu-Sharkh, S., & Doerffel, D.** (2004). Rapid test and non-linear model characterization of solid-state lithium-ion batteries. *Journal of Power Sources*, 130, 266–274. <https://doi.org/10.1016/j.jpowsour.2003.12.029>
- [22] **Merrouche, W., Lekouaghet, B., Bouguenna, E., & Himeur, Y.** (2024). Parameter estimation of ECM model for Li-ion battery using the weighted mean of vectors algorithm. *Journal of Energy Storage*, 76, 109891. <https://doi.org/10.1016/j.est.2024.109891>

- [23] He, H., Xiong, R., & Fan, J. (2011). Evaluation of lithium-ion battery equivalent circuit models for state of charge estimation by an experimental approach. *Energies*, 4(4), 582–598.
- [24] Saldaña, G., San Martín, J. I., Zamora, I., Asensio, F. J., & Oñederra, O. (2019). Analysis of the current electric battery models for electric vehicle simulation. *[Yayınevi ve dergi adı eksik]*
- [25] Mansir, I. B., & Okonkwo, P. C. (2025). Component degradation in lithium-ion batteries and their sustainability: A concise overview. *Sustainability*, 17(3), 1000. <https://doi.org/10.3390/su17031000>
- [26] Liu, Y., Liu, C., Liu, Y., Sun, F., Qiao, J., & Xu, T. (2023). Review on degradation mechanism and health state estimation methods of lithium-ion batteries. *Journal of Traffic and Transportation Engineering (English Edition)*, 10(4), 578–610. <https://doi.org/10.1016/j.jtte.2023.03.006>
- [27] Zhang, Z., Zhao, P., Zhang, Y., Zhu, X., He, Z., & Liu, C. (2022). Lithium-ion battery state-of-charge estimation based on an improved Coulomb-counting algorithm and uncertainty evaluation. *Journal of Energy Storage*, 48, 104061. <https://doi.org/10.1016/j.est.2022.104061>
- [28] Movassagh, K., Raihan, S. A., & Balasingam, B. (2019). Performance analysis of Coulomb counting approach for state of charge estimation. In *2019 IEEE Electrical Power and Energy Conference (EPEC)* (pp. 1–6). IEEE. <https://doi.org/10.1109/EPEC47565.2019.9074781>
- [29] El-Sayed, E. I., ElSayed, S. K., & Alsharef, M. (2024). Data-driven approaches for state-of-charge estimation in battery electric vehicles using machine and deep learning techniques. *Sustainability*, 16(21), 9301. <https://doi.org/10.3390/su16219301>
- [30] Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- [31] Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer.
- [32] Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow* (2nd ed.). O'Reilly Media.
- [33] Pascanu, R., Mikolov, T., & Bengio, Y. (2013). On the difficulty of training recurrent neural networks. In *Proceedings of the 30th International Conference on Machine Learning (ICML-13)* (Vol. 28, pp. 1310–1318). <https://doi.org/10.48550/arXiv.1211.5063>
- [34] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [35] Sak, H., Senior, A. W., & Beaufays, F. (2014). (September). Long short-term memory recurrent neural network architectures for large scale acoustic modeling. In *Proceedings of Interspeech 2014* (pp. 338–342).
- [36] Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451–2471. <https://doi.org/10.1162/089976600300015015>

- [37] **Zhang, L., Ji, T., Yu, S., & Liu, G.** (2023). Accurate prediction approach of SOH for lithium-ion batteries based on LSTM method. *Batteries*, 9(3), 177.
- [38] **Chen, Z., Yang, C., & Qiao, J.** (2022). The optimal design and application of LSTM neural network based on the hybrid coding PSO algorithm. *The Journal of Supercomputing*, 78(5), 7227–7259.
- [39] **Cyran, K.A. et al.** (2013). Support Vector Machines in Biomedical and Biometrical Applications. In: Ramanna, S., Jain, L., Howlett, R. (eds) *Emerging Paradigms in Machine Learning. Smart Innovation, Systems and Technologies*, vol 13. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-28699-5_15
- [40] **Phillips, P.** (1998), Support Vector Machines Applied to Face Recognition, NIST Interagency/Internal Report (NISTIR), National Institute of Standards and Technology, Gaithersburg, MD, [online], https://tsapps.nist.gov/publication/get_pdf.cfm?pub_id=150750 (Accessed May 29, 2025)
- [41] **Cortes, C., & Vapnik, V.** (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- [42] **Schölkopf, B., & Smola, A. J.** (2002). *Learning with kernels: Support vector machines, regularization, optimization, and beyond*. MIT Press.
- [43] **Kaya, M., & Yılmaz, A** (2023). Impact of kernel functions on support vector machine models in classification and regression problems. In *Proceedings of the International Conference on Artificial Intelligence and Data Processing* (pp. 123–130). Springer.
- [44] **Lee, J. D.** (2023). Challenges of kernel selection in support vector machines: An in-depth exploration. *Medium*. <https://medium.com/@jangdaehan1/challenges-of-kernel-selection-in-support-vector-machines-an-in-depth-exploration-f2712a4a2b33>

ÖZGEÇMİŞ

Ad-Soyad

:Mehmet Ali ARSLANTAŞ

ÖĞRENİM DURUMU:

- **Lisans** : 2022, İstanbul Teknik Üniversitesi, Elektrik Elektronik Fakültesi, Kontrol ve Otomasyon Mühendisliği

MESLEKİ DENEYİMLER:

- Kontrol Sistem Mühendisi, FEV Türkiye, 2021 – 2023
- BMS Yazılım Geliştirme Mühendisi, SIRO Energy, 2023-2025

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

Bildiriler:

- **Arslantaş, M. A.** (2024, September). *Estimation of battery state of health using LSTM on constant current constant voltage cycle*. TOK'2024 25th National Conference on Automatic Control, Konya, Turkey.