

**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**



**LİTYUM İYON BATARYA KAPASİTESİNİN GENETİK ALGORİTMA
DESTEKLİ YAPAY SİNİR AĞI YÖNTEMLERİ İLE TAHMİNİ**

Doktora Tezi

Fatih DURMUŞ

Danışman

Doç. Dr. Serap KARAGÖL

Bu çalışma Ondokuz Mayıs Üniversitesi tarafından PYO.MUH.1904.23.004 proje numarası ile desteklenmiştir.

SAMSUN
2024

TEZ KABUL VE ONAYI

Fatih DURMUŞ tarafından, Doç. Dr. Serap KARAGÖL danışmanlığında hazırlanan “LİTYUM İYON BATARYA KAPASİTESİNİN GENETİK ALGORİTMA DESTEKLİ YAPAY SİNİR AĞI YÖNTEMLERİ İLE TAHMİNİ” başlıklı bu çalışma, jürimiz tarafından 5.8.2024 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Doktora Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim/Ana Sanat Dalı	Sonuç
Başkan	Doç. Dr. Begüm KORUNUR ENGİZ Ondokuz Mayıs Üniversitesi Elektrik-Elektronik Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Doç. Dr. Serap KARAGÖL Ondokuz Mayıs Üniversitesi Elektrik-Elektronik Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Dr. Öğr. Üyesi Canan ORAL Amasya Üniversitesi Elektrik-Elektronik Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Dr. Öğr. Üyesi Gaye Yeşim TAFLAN Samsun Üniversitesi Uçak Bakım ve Onarım Bölümü	☒ Kabul ☐ Ret
Üye	Dr. Öğr. Üyesi Mustafa Hakan BOZKURT Karadeniz Teknik Üniversitesi Yazılım Mühendisliği Bölümü	☒ Kabul ☐ Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

Prof. Dr. Ahmet TABAK
Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım Doktora tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

Etik Kurul Gerekli mi?

Evet ☐ (Gerekli ise ekler kısmına ekleyiniz)

Hayır ☒

01/07/ 2024
Fatih DURMUŞ

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı: LİTYUM İYON BATARYA KAPASİTESİNİN GENETİK ALGORİTMA DESTEKLİ YAPAY SİNİR AĞI YÖNTEMLERİ İLE TAHMİNİ

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 05.07.2024 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 7

Tek kaynak oranı : % 2 çıkmıştır.

05 /07/ 2024
Doç. Dr. Serap KARAGÖL

ÖZET

LİTYUM İYON BATARYA KAPASİTESİNİN GENETİK ALGORİTMA DESTEKLİ YAPAY SİNİR AĞI YÖNTEMLERİ İLE TAHMİNİ

Fatih DURMUŞ

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

Doktora, Ağustos/2024

Danışman: Doç. Dr. Serap KARAGÖL

Lityum-iyon bataryaların sundukları kullanım kolaylığı ve maliyet avantajları, bu bataryaların yaygınlaşmasına katkı sağlamış, ancak ömür ve güvenilirlik konusundaki endişeler, doğru kapasite ve sağlık bilgilerine erişimin önemini artırmıştır. Bu çalışma, lityum-iyon bataryaların kapasitesini yüksek doğrulukla tahmin etmek için iki farklı veri seti kullanarak geliştirilen yöntemleri sunmaktadır. İlk olarak, NASA'nın deneysel veri seti kullanılmıştır. Şarj ve deşarj döngüleri sırasında elde edilen akım ve gerilim verileri kullanılarak dört temel özellik çıkarılmıştır. Bu özellikler ile batarya kapasiteleri arasındaki ilişki, Pearson korelasyon katsayısı ile analiz edilmiştir. Korelasyon analizi sonucunda bazı bataryalarda özellik sayısı üçe indirilmiş ve tahmin doğruluğunu artırmak için uygun özellikler seçilmiştir. Genetik Algoritma (GA) kullanılarak Evrişimli Sinir Ağı (CNN), Geriye Yayılım (BP) ve Tekrarlayan Sinir Ağı (RNN) algoritmalarının parametre optimizasyonu gerçekleştirilmiştir. GA, doğal seçim ve genetik süreçleri kullanarak en iyi performans sağlayan parametreleri daha kısa sürede belirlemiştir. Bu yöntemin performansı, beş farklı metrik kullanılarak değerlendirilmiştir: Ortalama Kare Hata (MSE), Ortalama Karekök Hata (RMSE), Normalleştirilmiş Ortalama Karekök Hata (NRMSE), Ortalama Mutlak Hata (MAE) ve Kare Korelasyonu (R²). 100 eğitim verisi kullanılarak yapılan tahminlerde, %0.1176 RMSE değeri ile 68 veri tahmini yapılmıştır. Bu sonuç, literatürdeki benzer çalışmalara kıyasla 2.5 katlık bir iyileşme düzeyini temsil etmektedir. İkinci çalışmada ise, Oxford'un deneysel veri seti kullanılarak şarj ve deşarj çevrimlerinden elde edilen gerilim verilerinden üç karakteristik özellik çıkarılmıştır. Bu özellikler ile pil kapasiteleri arasındaki ilişki, Pearson korelasyon katsayısı ile analiz edilmiş ve tüm bataryalar için uygun olduğu görülmüştür. Yine CNN, BP ve RNN algoritmalarının parametre optimizasyonu, %25, %50 ve %75 eğitim verisi kullanılarak GA ile gerçekleştirilmiştir. GA, en iyi performans sağlayan parametreleri belirlemek için doğal seçim ve genetik süreçleri kullanmıştır. Bu yöntemin doğruluğu da MSE, RMSE, NRMSE, MAE ve R² metrikleri ile değerlendirilmiştir. Cell1 için, %0.0068 Ah RMSE değeri ile 60 eğitim verisi kullanılarak 23 veri tahmini yapılmıştır. Bu çalışma, lityum-iyon bataryaların kapasitesini yüksek doğrulukla tahmin etmek için GA ile optimize edilmiş sinir ağı modellerinin kullanımının etkinliğini göstermektedir. NASA ve Oxford veri setleri üzerinde yapılan tahminler, yöntemlerin üstün doğrulukta sonuçlar verdiğini ve pil ömrü ve güvenilirliği konusundaki endişelerin giderilmesine katkıda bulunduğunu ortaya koymaktadır.

Anahtar Sözcükler: Batarya Sağlık Durumu, Genetik Algoritma, Evrişimsel Sinir Ağı, Geriye Yayılım, Tekrarlayan Sinir Ağı, NASA, Oxford

ABSTRACT

Prediction of Lithium-Ion Battery Capacity with Genetic Algorithm-Assisted Artificial Neural Network Methods

Fatih DURMUS

Ondokuz Mayıs University

Institute of Graduate Studies

Department of Electrical and Electronics Engineering Programme

Ph.D., August/2024

Supervisor: Assoc. Prof. Dr. Serap KARAGOL

The ease of use and cost advantages of lithium-ion batteries have contributed to their widespread adoption, but concerns about lifespan and reliability have increased the importance of access to accurate capacity and health information. This study presents methods developed using two different data sets to predict the capacity of lithium-ion batteries with high accuracy. First, NASA's experimental data set was used. Four key features were extracted using current and voltage data obtained during charge and discharge cycles. The relationship between these characteristics and battery capacities is analysed with Pearson correlation coefficient. As a result of the correlation analysis, the number of features was reduced to three in some batteries and appropriate features were selected to improve the prediction accuracy. Genetic Algorithm (GA) was used to optimize the parameters of Convolutional Neural Network (CNN), Back Propagation (BP) and Recurrent Neural Network (RNN) algorithms. GA uses natural selection and genetic processes to determine the parameters that provide the best performance in a shorter time. The performance of this method was evaluated using five different metrics: Mean Square Error (MSE), Root Mean Square Error (RMSE), Normalized Root Mean Square Error (NRMSE), Mean Absolute Error (MAE) and Correlation of Squares (R²). Using 100% training data, 68 data predictions were made with an RMSE of 0.1176%. This result represents a 2.5- times improvement compared to similar studies in the literature. In the second study, three characteristics were extracted from the voltage data obtained from charge and discharge cycles using Oxford's experimental dataset. The relationship between these characteristics and battery capacities was analysed with Pearson correlation coefficient and found to be appropriate for all batteries. Again, parameter optimization of CNN, BP and RNN algorithms was performed with GA using 25%, 50% and 75% training data. The GA used natural selection and genetic processes to determine the parameters that provide the best performance. The accuracy of this method was evaluated by MSE, RMSE, NRMSE, MAE and R² metrics. For Cell1, 23 data predictions were made using 60 training data with an Ah RMSE of 0.0068%. This study demonstrates the effectiveness of using GA-optimized neural network models to predict the capacity of lithium-ion batteries with high accuracy. The predictions on NASA and Oxford datasets reveal that the methods provide results with superior accuracy and contribute to addressing concerns about battery life and reliability.

Keywords: State of Health, Convolutional Neural Network, Back Propagation, Recurrent Neural Network, NASA, Oxford

ÖN SÖZ VE TEŞEKKÜR

Bu çalışmayı yürütürken beni yönlendiren, bilgi ve deneyimlerini benimle paylaşan kıymetli hocam Doç. Dr. Serap KARAGÖL'e, gösterdiği ilgi ve destekten dolayı teşekkür ederim. Tez çalışmamda her türlü yardımlarını esirgemeyen Giresun Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü Dr. Öğr. Üyesi Ferdi ÖZBİLGİN'e ve Amasya Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü Arş. Gör. Dr. Burak Kürşat GÜL'e en derin şükranlarımı sunarım. Ayrıca, her zaman manevi destekleriyle yanımda olan sevgili eşim Büşra Nur DURMUŞ'a, kıymetli aileme ve değerli mesai arkadaşlarıma sonsuz teşekkürlerimi sunmayı bir borç bilirim.

Fatih DURMUŞ

İÇİNDEKİLER

TEZ KABUL VE ONAYI	i
BİLİMSEL ETİĞE UYGUNLUK BEYANI	ii
TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI	ii
ÖZET	iii
ABSTRACT	iv
ÖNSÖZ VE TEŞEKKÜR	v
İÇİNDEKİLER	vi
SİMGELER VE KISALTMALAR	vii
ŞEKİLLER DİZİNİ	viii
TABLolar DİZİNİ	ix
1. GİRİŞ	1
2. KURAMSAL TEMELLER VE KAYNAKÇA ÖZETİ.....	7
2.1. Lityum-İyon Bataryalar	7
2.1.1. Gelişimi ve Tarihçesi	7
2.1.2. Çalışma Prensibi	7
2.1.3. Bileşenleri	8
2.1.4. Performans Faktörleri	9
2.1.5. Güvenlik Hususları	10
2.1.6. Eşdeğer Devre Modeli	10
2.1.7. Gelecekteki İhtiyaçlar ve Yenilikçi Yaklaşımlar.....	12
2.2. Kaynakça Özeti	13
3. YÖNTEM	19
3.1. Pearson Korelasyon Analizi	22
3.2. Normalizasyon.....	23
3.3. Batarya Sağlık Durumu	23
3.4. Genetik Algoritma	23
3.5. Evrimsel Sinir Ağı	26
3.6. Çok Katmanlı Perseptron	28
3.7. Tekrarlayan Sinir Ağı.....	30
3.8. Değerlendirme Parametreleri.....	31
4. VERİ SETLERİ VE ÖZELLİK ÇIKARMA	32
4.1. NASA Veri Seti Bilgisi	32
4.2. NASA Veri Seti Özellik Çıkarma	34
4.3. Oxford Veri Seti Bilgisi.....	37

4.4. Oxford Veri Seti Özellik Çıkarma.....	38
4.5. Verilerin Eğitim ve Test Verisi Olarak Ayrılması	40
5. BULGULAR VE TARTIŞMA.....	41
5.1. NASA Veri Seti için Sonuçlar.....	41
5.1.1. Genetik Algoritma Sonuçları	41
5.1.2. B0005 Bataryası Kapasite Tahmin Sonuçları.....	45
5.1.3. B0006 Bataryası Kapasite Tahmin Sonuçları	49
5.1.4. B0007 Bataryası Kapasite Tahmin Sonuçları.....	53
5.1.5. B0018 Bataryası Kapasite Tahmin Sonuçları.....	57
5.1.6. Genel Değerlendirme ve Literatür Kıyaslaması	60
5.2. Oxford Veri Seti için Sonuçlar	64
5.2.1. Genetik Algoritma Sonuçları	64
5.2.2. Cell1 Bataryası Kapasite Tahmin Sonuçları.....	66
5.2.3. Cell2 Bataryası Kapasite Tahmin Sonuçları.....	70
5.2.4. Cell3 Bataryası Kapasite Tahmin Sonuçları.....	74
5.2.5. Cell4 Bataryası Kapasite Tahmin Sonuçları.....	78
5.2.6. Cell5 Bataryası Kapasite Tahmin Sonuçları.....	82
5.2.7. Cell6 Bataryası Kapasite Tahmin Sonuçları.....	86
5.2.8. Cell7 Bataryası Kapasite Tahmin Sonuçları.....	90
5.2.9. Cell8 Bataryası Kapasite Tahmin Sonuçları.....	94
5.2.10. Genel Değerlendirme ve Literatür Kıyaslaması	98
6. SONUÇLAR VE ÖNERİLER.....	102
KAYNAKLAR	104
ÖZ GEÇMİŞ.....	109

SİMGELER VE KISALTMALAR

ACO	:Karıncı Koloni Optimizasyonu
ARIMA	:Oto regresif Entegre Hareketli Ortalama
BiLSTM	:Çift Yönlü Uzun Kısa Süreli Bellek
BMS	:Batarya Yönetim Sistemi
BP	:Geri Yayılım
BSD	:Batarya Sağlık Durumu
BŞD	:Batarya Şarj Durumu
CNN	:Evrişimli Sinir Ağı
EDM	:Eşdeğer Devre Modeli
EHO	:Fil Sürü Optimizasyonu
ELM	:Aşırı Öğrenme Makinesi
FNN	:İleri Beslemeli Sinir Ağı
GA	:Genetik Algoritma
GPR	:Gauss Regresyon Süreçleri
GRU	:Geçitli Tekrarlayan Birim
KKÖ	:Kalan Kullanılabilir Ömür
LSTM	:Uzun ve Kısa Süreli Bellek Ağı
MAE	:Ortalama Mutlak Hata
MLP	:Çok Katmanlı Perceptron
MSE	:Ortalama Kare Hatası
NRMSE	:Normalize Kök Ortalama Kare Hatası
PSO	:Parçacık Sürü Optimizasyonu
R ²	:Kare Korelasyon
RMSE	:Kök Ortalama Kare Hatası
RNN	:Tekrarlayan Sinir Ağı
SVM	:Destek Vektör Makinesi

ŞEKİLLER DİZİNİ

Şekil 1.1. Genel akış şemasının batarya durum tahmini için gösterimi	3
Şekil 2.1. Lityum-iyon bataryanın yapısı (MEB, 2024).....	8
Şekil 2.2. Eşdeğer devre modelleri (a) Rint modeli (He vd., 2011) (b) Thevenin modeli (Raël vd., 2014; Wu ve Chen, 2014) (c) PNGV modeli (Feng vd., 2013) (d) GNL modeli (Fang vd., 2017).....	11
Şekil 3.1. NASA veri seti için genel akış diyagramı.....	19
Şekil 3.2. Oxford veri seti için genel akış diyagramı.....	21
Şekil 3.3. Tek çaprazlama örneği.....	25
Şekil 3.4. Roulette seçim fonksiyonu.....	25
Şekil 3.5. CNN mimarisi örneği.....	26
Şekil 3.6. 1D CNN mimarisi.....	27
Şekil 3.7. MLP mimarisi	30
Şekil 3.8. RNN mimarisi.....	31
Şekil 4.1. Şarj-deşarj döngüsü.....	33
Şekil 4.2. Dört batarya için kapasite-döngü grafiği	34
Şekil 4.3. B0005 için şarj esnasında a) akım-zaman grafiği b) gerilim-zaman grafiği	35
Şekil 4.4. B0005 içindeşarj esnasında gerilim-zaman grafiği.....	36
Şekil 4.5. OXFORD veri seti kapasite-döngü grafiği	38
Şekil 4.6. Cell-1 için şarj esnasında gerilim-zaman grafiği	38
Şekil 4.7. Cell-1 içindeşarj esnasında gerilim zaman grafiği.....	39
Şekil 5.1. Genetik Algoritma Matlab çıktı örneği.....	43
Şekil 5.2. B0005 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği	45
Şekil 5.3. B0005 bataryası 70 eğitim verisi a) kapasite tahminleri b) hata grafiği	46
Şekil 5.4. B0005 bataryası 100 eğitim verisi a) kapasite tahminleri b) hata grafiği ..	47
Şekil 5.5. B0006 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği	49
Şekil 5.6. B0006 bataryası 70 eğitim verisi a) kapasite tahminleri b) hata grafiği	50
Şekil 5.7. B0006 bataryası 100 eğitim verisi a) kapasite tahminleri b) hata grafiği ..	51
Şekil 5.8. B0007 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği	53
Şekil 5.9. B0007 bataryası 70 eğitim verisi a) kapasite tahminleri b) hata grafiği	54
Şekil 5.10. B0007 bataryası 100 eğitim verisi a) kapasite tahminleri b) hata grafiği ..	55
Şekil 5.11. B0018 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği ..	57

Şekil 5.12. B0018 bataryası 70 eğitim verisi a) kapasite tahminleri b) hata grafiği...	58
Şekil 5.13. B0018 bataryası 100 eğitim verisi a) kapasite tahminleri b) hata grafiği	59
Şekil 5.14. Cell1 bataryası 20 eğitim verisi a) kapasite tahminleri b) hata grafiği....	66
Şekil 5.15. Cell1 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği....	67
Şekil 5.16. Cell1 bataryası 60 eğitim verisi a) kapasite tahminleri b) hata grafiği....	68
Şekil 5.17. Cell2 bataryası 20 eğitim verisi a) kapasite tahminleri b) hata grafiği....	70
Şekil 5.18. Cell2 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği....	71
Şekil 5.19. Cell2 bataryası 60 eğitim verisi a) kapasite tahminleri b) hata grafiği....	72
Şekil 5.20. Cell3 bataryası 20 eğitim verisi a) kapasite tahminleri b) hata grafiği....	74
Şekil 5.21. Cell3 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği....	75
Şekil 5.22. Cell3 bataryası 60 eğitim verisi a) kapasite tahminleri b) hata grafiği....	76
Şekil 5.23. Cell4 bataryası 13 eğitim verisi a) kapasite tahminleri b) hata grafiği....	78
Şekil 5.24. Cell4 bataryası 25 eğitim verisi a) kapasite tahminleri b) hata grafiği....	79
Şekil 5.25. Cell4 bataryası 37 eğitim verisi a) kapasite tahminleri b) hata grafiği....	80
Şekil 5.26. Cell5 bataryası 13 eğitim verisi a) kapasite tahminleri b) hata grafiği....	82
Şekil 5.27. Cell5 bataryası 25 eğitim verisi a) kapasite tahminleri b) hata grafiği....	83
Şekil 5.28. Cell5 bataryası 37 eğitim verisi a) kapasite tahminleri b) hata grafiği....	84
Şekil 5.29. Cell6 bataryası 13 eğitim verisi a) kapasite tahminleri b) hata grafiği....	86
Şekil 5.30. Cell6 bataryası 25 eğitim verisi a) kapasite tahminleri b) hata grafiği....	87
Şekil 5.31. Cell6 bataryası 37 eğitim verisi a) kapasite tahminleri b) hata grafiği....	88
Şekil 5.32. Cell7 bataryası 20 eğitim verisi a) kapasite tahminleri b) hata grafiği....	90
Şekil 5.33. Cell7 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği....	91
Şekil 5.34. Cell7 bataryası 60 eğitim verisi a) kapasite tahminleri b) hata grafiği....	92
Şekil 5.35. Cell8 bataryası 20 eğitim verisi a) kapasite tahminleri b) hata grafiği....	94
Şekil 5.36. Cell8 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği....	95
Şekil 5.37. Cell8 bataryası 60 eğitim verisi a) kapasite tahminleri b) hata grafiği....	96

TABLÖLER DİZİNİ

Tablo 2.1. Eşdeğer devre modellerinin gerilim denklemleri.....	12
Tablo 2.2. Literatür özet tablosu	18
Tablo 3.1. CNN eğitim seçenekleri.....	28
Tablo 4.1. NASA veri setinde kullanılan bataryalara ait özellikler	32
Tablo 4.2. Kapasiteler ile çıkarılan özellikler arasındaki korelasyon katsayıları	37
Tablo 4.3. Oxford veri setinde kullanılan bataryalara ait özellikler	37
Tablo 4.4. Kapasiteler ile çıkarılan özellikler arasındaki korelasyon katsayıları	40
Tablo 4.5. Eğitim ve test verilerinin sayıları.....	40
Tablo 5.1. Genetik Algoritma seçenekleri	42
Tablo 5.2. NASA veri seti Genetik Algoritma sonuçları parametre değerleri.....	44
Tablo 5.3. NASA veri seti Genetik Algoritma sonuçları en iyi RMSE (%) değerleri	44
Tablo 5.4. B0005 bataryasının performans parametreleri.....	48
Tablo 5.5. B0006 bataryasının performans parametreleri.....	52
Tablo 5.6. B0007 bataryasının performans parametreleri.....	56
Tablo 5.7. B0018 bataryasının performans parametreleri.....	60
Tablo 5.8. En iyi performans gösteren algoritmalar	61
Tablo 5.9. NASA veri seti tahminlerini literatürdeki çalışmalar ile kıyaslama.....	62
Tablo 5.10. Oxford veri seti Genetik Algoritma sonuçları parametre değerleri.....	65
Tablo 5.11. Oxford veri seti Genetik Algoritma sonuçları RMSE (%) değerleri	65
Tablo 5.12. Cell1 bataryasının performans parametreleri.....	69
Tablo 5.13. Cell2 bataryasının performans parametreleri.....	73
Tablo 5.14. Cell3 bataryasının performans parametreleri.....	77
Tablo 5.15. Cell4 bataryasının performans parametreleri.....	81
Tablo 5.16. Cell5 bataryasının performans parametreleri.....	85
Tablo 5.17. Cell6 bataryasının performans parametreleri.....	89
Tablo 5.18. Cell7 bataryasının performans parametreleri.....	93
Tablo 5.19. Cell8 bataryasının performans parametreleri.....	97
Tablo 5.20. Oxford veri seti en iyi tahmin performansları	99
Tablo 5.21. Oxford veri seti tahminlerini literatürdeki çalışmalar ile kıyaslama	100

1. GİRİŞ

Lityum-iyon bataryaların kullanımı, diğer bataryalara kıyasla düşük maliyeti, yüksek enerji yoğunlukları, düşük kendi kendine deşarj oranı ve uzun ömürleri nedeniyle hızla artmıştır (Huang vd., 2017). Dolayısıyla mobil iletişim, ulaşım, elektrik enerjisi depolama, depolamada yeni enerji kaynakları ve havacılıkta yaygın olarak uygulanmaktadır (Shen ve Gao, 2019). Kapasiteyi doğru bir şekilde izlemek ve tahmin etmek çok önemlidir çünkü aşırı şarj veya aşırı deşarj, bataryada kalıcı hasara neden olabilir (Dai vd., 2021). Lityum-iyon bataryaların yaygın kullanımı da göz önüne alındığında, lityum-iyon bataryaların güvenli çalışmasına büyük önem verilmelidir. Kapasite ve Batarya Sağlık Durumu (BSD), lityum-iyon bataryaların mevcut durumunu ve performansını değerlendirmek için en kritik parametredir (Shen vd., 2017).

Çalışmalar BSD'yi doğru tahmin edebilmek için yoğunlaşmıştır. Bu çalışmalar model tabanlı yöntemler ve veri tabanlı yöntemler olarak iki ana başlıkta toparlanabilir (H. Tian vd., 2020).

Model tabanlı yöntemler, bataryayı modelleyip iç bozulma sürecini göz önünde bulundurarak bataryanın BSD'sini tahmin eder (Z. Zhang vd., 2022). Modelin temel mekanizması, bataryanın çalışması sırasında lityum pil içindeki reaksiyonun performans değişim modunu analiz etmektir. Bu modeller dahili ve harici pil durumu değişkenleri üzerindeki performans etkisini dikkate alır ve ardından bir hücre bozulma modeli oluşturur (Xiong vd., 2018). Modele dayalı tahminde ilerlemeler olmasına rağmen, bazı sınırlamalar devam etmektedir (Y. Li vd., 2019). Lityum-iyon bataryalar içindeki karmaşık kimyasal reaksiyonlar içeren bir yapıdır. Dolayısıyla doğru bir yaşlanma modeli tasarlamak zordur. Ayrıca çalışma sıcaklığı, anot ve katot malzemeleri gibi çevresel faktörler büyük ölçüde bataryaların durumunda etkiye sahiptir (Ren vd., 2018). Sonuç olarak kapasite tahminin doğru bir şekilde yapılması için gereken parametreler model tabanlı yöntemlerle belirlenememektedir (Zhao vd., 2022).

Kapasite tahmininde veri tabanlı yöntemler, doğrusal olmayan gözlemlenebilirlikteki etkinlikleri ve esneklikleri nedeniyle son zamanlarda daha fazla ilgi görmektedir. Ana hedef, bataryaların güvenli kullanımını, bakımını, değiştirilmesini ve atık olarak ayrılmasını sağlayarak batarya yönetimini desteklemek ve bataryanın durumunu doğru bir şekilde öngörmektir. Bu hedefe ulaşmak için

araştırmacılar, BSD tahmin yöntemleri üzerine çok sayıda etkili araştırma yapmış ve verimli sonuçlar elde etmişlerdir. Araştırmacılar, batarya durumlarını tahmin etmek için farklı iş akışları tasarlamışlardır (Catelani vd., 2021; You vd., 2022). Şekil 1.1 genel akış diyagramını göstermektedir. Bu iş akışları genellikle dört adımdan oluşur: veri toplama ve ön işleme, özellik çıkarma ve seçme, batarya modeli oluşturma ve sonuçlandırma.

İlk adım olan veri toplama ve ön işleme, veri toplama sistemi ile batarya durumları verilerinin elde edilmesine ve veri temizleme, veri filtreleme ve düzenleme gibi veri ön işlemlerinin gerçekleştirilmesine odaklanır. İkinci adım, toplanan verilerin özelliklerini seçme ve çıkarma, veri boyutunu azaltma, batarya durumlarıyla yakından ilişkili veri özelliklerini belirleme ve gereksiz veri fazlalığından kaçınma sürecini kapsayan özellik mühendisliğidir. Bu süreçte temel bileşen analizi, korelasyon katsayısı analizi ve kosinüs benzerlik analizi gibi ana yöntemler kullanılır. Üçüncü adım, iş akışının merkezini oluşturan bir tahmin modeli geliştirmek ve girdi verileri ile çıktı verileri arasında bir eşleme ilişkisi kurmaktır. Son adım ise, değerlendirme sonuçlarına ve kriterlerine bakarak anormal durum uyarıları, aktif müdahaleyi tetikleme ve imha prosedürleri gibi durumları uygulamaktır.

Genellikle kullanılan modeller makine öğrenimi modelleri, derin öğrenme modelleri ve hibrit modelleri kapsamaktadır.

Bazı örnekler şunlardır:


- İleri beslemeli bir sinir ağı (FNN) ve çevrimiçi alternatif akım (AC) kompleks empedansı kullanan uyarlanabilir bir BSD tahmin yöntemi (Xia ve Qahouq, 2019)

Avantajları: Hızlı ve uyarlanabilir tahminler sağlar. Gerçek zamanlı izleme yapabilir.

Dezavantajları: Yüksek hesaplama maliyeti. Eğitim verilerine duyarlılık.

- Dinamik olarak çalışan bir tekrarlayan sinir ağı (DDRN) kullanarak lityum-iyon bataryaların BSD'sini tahmin eden basit bir tekrarlayan sinir ağı (RNN) tabanlı yaklaşımlar (Chaoui ve Ibe-Ekeocha, 2017)

Avantajları: Zaman serisi verilerini iyi işler. Geçmiş verilerden öğrenme yeteneği.



Şekil 1.1. Genel akış şemasının batarya durum tahmini için gösterimi

Dezavantajları: Hesaplama süresi uzun olabilir. Eğitim verilerine aşırı duyarlılık.

Metrik Değerleri: LiFePO4 bataryası BSD tahmini RMSE (%10.13 - %45.47)

- Destek vektör makinesi (SVM) (Stighezza vd., 2021; Xiong vd., 2020)

Avantajları: Yüksek doğruluk. Küçük veri setleriyle çalışabilme.

Dezavantajları: Hiperparametre seçimi zorluğu. Eğitim süresi uzun olabilir.

Metrik Değerleri: Batarya şarj durumu (BŞD) tahmini RMSE %1.4 (Stighezza vd., 2021) BSD tahmini RMSE: %7.6 (Xiong vd., 2020)

- Gauss regresyon süreçleri (GPR) (Feng vd., 2020; Zhou vd., 2018)

Avantajları: Esneklik ve belirsizlik yönetimi. Küçük veri setleriyle çalışabilme.

Dezavantajları: Hesaplama maliyeti yüksek. Büyük veri setlerinde verimlilik düşebilir.

Metrik Değerleri: BSD tahmini RMSE: %2-%10 (Feng vd., 2020), %13-%22 (Zhou vd., 2018)

- Otoresif entegre hareketli ortalama (ARIMA) (Zhou ve Huang, 2016)
Avantajları: Zaman serisi verilerinde iyi performans. Modelin kolay yorumlanabilir olması.
Dezavantajları: Karmaşık model seçimi. Sezonluk verilerde düşük performans.
Metrik Değerleri: BSD tahmini RMSE: %1-%5
- Aşırı öğrenme makinesi (ELM) (Jia vd., 2022; Yang vd., 2018)
Avantajları: Hızlı eğitim süresi. Yüksek genel doğruluk.
Dezavantajları: Overfitting (aşırı öğrenme) riski. Modelin açıklanabilirliği düşük.
Metrik Değerleri: BSD tahmini RMSE: %0.93-%2.63 (Jia vd., 2022), kalan kullanılabilir ömür (KKÖ) tahmini MSE: %0.1-%4.8 (Yang vd., 2018)
- Uzun ve kısa süreli bellek ağı (LSTM) (X. Li vd., 2019; Zhao vd., 2022)
Avantajları: Uzun süreli bağımlılıkları iyi işler. Yüksek doğruluk.
Dezavantajları: Eğitim süresi uzun. Hesaplama maliyeti yüksek.
Metrik Değerleri: KKÖ tahmini hata oranı: %3.21-%3.3 (X. Li vd., 2019), kapasite tahmini RMSE: %0.71-%1.33 (Zhao vd., 2022)
- Geçitli tekrarlayan birim (GRU) (Ding vd., 2022; Wang vd., 2022)
Avantajları: LSTM'ye benzer doğrulukta daha düşük hesaplama maliyeti. Zaman serisi verilerinde iyi performans.
Dezavantajları: Hiperparametre ayarı zorlu olabilir. Düşük performans riski.
Metrik Değerleri: KKÖ tahmini RMSE: %2 (Ding vd., 2022), BSD tahmini RMSE %1.12-%1.86 (Wang vd., 2022)

Bunların yanı sıra, akım ve gerilim ölçüm verileriyle derin bir evrişimli sinir ağı (CNN) önerilmiştir (Shen vd., 2019). Veriye dayalı yöntemler, bataryanın iç yapısı ve eskime mekanizmaları hakkında elektrokimyasal bilgi olmadan bir bataryanın BSD'sini tahmin edebilir. Bir bataryanın elektrokimyasal özellikleri ve çevresel faktörler hakkında bilgi olmadan yukarıda geçen yöntemler kolaylıkla uygulanabilir.

Yapılan çalışmalarda, tahmin doğruluğunu artırmak için model parametrelerini belirlerken tipik olarak deneme yanılma yoluyla veya standart değerlerle kullanılan çeşitli modeller önerilmiştir. Bu yaklaşımlar genellikle iyi sonuçlar vermiştir. Fakat sistematik bir parametre optimizasyonu yapılmadığı için genellikle en yüksek performansa ulaşamazlar. Bu parametrelerin optimize edilmesi, modelin batarya sağlığını ve ömrünü doğru bir şekilde tahmin edebilmesi açısından kritik öneme

sahiptir. Geleneksel parametre seçimi yöntemleri hem zaman alıcı olabilir hem de modelin mimarisinin tüm potansiyelini keşfetmekte yetersiz kalabilir. Bunu ele almak için, parametre optimizasyonu için bir Genetik Algoritma (GA) kullanılması önerilmektedir. Genetik algoritmalar, doğal seleksiyon sürecini taklit eder. Modellere en uygun konfigürasyonları belirlemek için geniş bir parametre uzayını etkin bir şekilde araştıran güçlü arama sezgiselleridir. Bu sebeple, GA kullanılarak bu parametrelerin optimize edilmesiyle, modellerin performansı ve doğruluğu artırılabilir. Ayrıca yapılan çalışmalarda tahmin işlemi yapılırken yüksek sayıda özellik kullanılmıştır. Fazla sayıda özellik çıkarma ve seçme işlemi genel olarak işlem yükü oluşturacak ve olası yanlış riskleri oluşturacaktır. Çok sayıda özellik çıkarmak yerine yeterli ve az sayıda özellik çıkarılarak hem işlem yükü azaltılıp hem de doğruluk artırılabilir.

Bu çalışmada, CNN, RNN ve geri yayılım (BP) gibi önceki araştırmalarda kullanılan algoritmaların parametreleri GA ile ayarlanmış ve tahmin doğruluğunda belirgin iyileşmeler sağlanmıştır. Sonuç olarak aşağıdaki katkılar elde edilmiştir:

1. GA aracılığıyla kullanılan algoritmaların parametreleri oluşturulurken rastgele veya standart parametreler yerine en uygun parametreler kullanılarak doğruluk artırılır.
2. GA sayesinde doğru parametreleri bulmak için harcanan zaman kaybı en aza indirilir.
3. Şarj ve deşarj süreleri için toplam dört özellik çıkarılmıştır. Literatüre kıyasla özellik sayısı daha az kullanılarak işlem yükü ve hata oluşma ihtimalleri azaltılmıştır. Yüksek performans elde edilerek sürecin önemi ortaya çıkmıştır.
4. Kapasite tahmini, bataryanın noktasal olarak her döngüdeki kapasitesini tahmin etmek için gerçekleştirilir. Sonuç olarak, bu veriler hem batarya sağlığı hem de kalan batarya ömrü hakkında bilgi sağlar.
5. Literatürdeki çalışmalara göre daha az eğitim verisi ile yüksek doğrulukta sonuçlara ulaşılmıştır. Bu da yaklaşımın kullanışlılığı ve doğruluğu onaylamıştır.

Tezin bundan sonraki kısımlarında anlatım şu şekilde yapılacaktır. İkinci kısımda kullanılan yöntem NASA ve Oxford veri setleri için ayrı ayrı anlatılmış, iki veri setinde de kullanılan algoritmalara yer verilmiş ve değerlendirme parametrelerinden bahsedilmiştir. Veri setlerinin ayrıntılı anlatımına ve özellik

ıkarma kriterlerinin aıklamalarına nc blmde yer verilmiřtir. Bulgular ve tartiřma blm olan drdnc kısımda tahmin sonuları ve bu sonuların literatrdeki alıřmalarla kıyaslanması, her bataryanın ayrı ayrı tahmin ve hata grafikleri gsterilmiřtir. Son olarak yapılan alıřmaların yorumlanarak gelecek alıřmalarda neler yapılabileceėi anlatılmıřtır.



2. KURAMSAL TEMELLER VE KAYNAKÇA ÖZETİ

Bu bölümün ilk kısmında lityum-iyon bataryalar ile ilgili genel bilgiler verilmiştir. İkinci kısımda BSD, KKÖ ve kapasite tahminleri ile ilgili yapılan çalışmalar özetlenmiştir.

2.1. Lityum-İyon Bataryalar

Genel olarak, lityum-iyon bataryalar, lityum-iyonlarının her iki elektrottan hareket ederek enerji taşıdığı ekleme reaksiyonlarına dayalı enerji depolama sistemleri olarak tanımlanabilir. Bu tanıma uygun olarak, lityum-iyon bataryalar için birçok hücre kimyası türü vardır, bu nedenle lityum-iyon batarya terimi kurşun asit veya nikel kadmiyum gibi tek hücreli bir kimyayı ifade etmez, ancak tanımın kapsamındaki bir hücre kimyası ailesini ifade eder (Horiba, 2014).

2.1.1. Gelişimi ve Tarihçesi

Lityum-iyon bataryaların gelişimi, enerji depolama teknolojilerindeki büyük ilerlemelerin bir sonucudur. İlk lityum tabanlı bataryalar üzerinde çalışmalar 20. yüzyılın başlarında başlamış olup, 1970’li yıllarda lityum metali kullanılan şarj edilemeyen hücreler geliştirilmiştir. Ancak, bu hücreler güvenlik sorunları nedeniyle ticari olarak sınırlı kalmıştır. Lityum metalinin yerine lityum-iyonlarını kullanan şarj edilebilir bataryaların geliştirilmesi ise 1990’ların başında tamamlanmış ve 1991 yılında Sony tarafından ticari olarak piyasaya sürülmüştür (Nagaura, 1990). Bu bataryalar, yüksek enerji yoğunluğu ve güvenlik açısından üstün performansları sayesinde kısa sürede yaygın olarak benimsenmiştir.

2.1.2. Çalışma Prensibi

Lityum-iyon bataryalar, temel olarak pozitif elektrot (katot), negatif elektrot (anot), bu iki elektrot arasında yer alan bir elektrolit ve ayırıcıdan oluşur. Bataryanın çalışması sırasında lityum-iyonları, bu bileşenler arasında hareket ederek elektrik enerjisinin depolanmasını ve serbest bırakılmasını sağlar. Bu hareket, bataryanın şarj ve deşarj süreçlerini temsil eder.


Şarj Süreci: Şarj sırasında, lityum-iyonları katot malzemesinden ayrılarak elektrolit aracılığıyla anota doğru hareket eder. Anot genellikle grafit gibi karbon bazlı bir malzemeden yapılmıştır ve lityum-iyonlarını burada katmanlar arasında depolar. Aynı zamanda, elektronlar dış devre üzerinden anota doğru akar ve bu süreçte

bataryada enerji depolanır.

Deşarj Süreci: Deşarj sırasında, bu süreç tersine döner. Lityum-iyonları anottan ayrılarak katota geri dönerken, elektronlar da dış devre üzerinden katota doğru akar. Bu elektron akışı, elektrik enerjisi sağlar ve bataryanın dış bir yükü (örneğin bir cihazı) beslemesine olanak tanır.

2.1.3. Bileşenleri

Lityum-iyon bataryaların performansı ve güvenliği, kullanılan malzemelerin türüne ve yapılarına bağlıdır. Örnek bir lityum-iyon bataryası Şekil 2.1’de verilmiştir.



Şekil 2.1. Lityum-iyon bataryanın yapısı (MEB, 2024)

Bu bataryaların temel bileşenleri şunlardır:

Anot: Anot, genellikle grafit veya lityum titanat ($\text{Li}_4\text{Ti}_5\text{O}_{12}$) gibi karbon bazlı malzemelerden yapılır. Anotun temel işlevi, lityum-iyonlarını şarj sırasında depolamak ve deşarj sırasında bu iyonları serbest bırakmaktır. Grafit, yüksek teorik kapasitesi ve iyi döngü kararlılığı nedeniyle yaygın olarak kullanılan bir anot malzemesidir (Goodenough ve Kim, 2010).

Katot: Katot, genellikle lityum metali oksitleri gibi malzemelerden yapılır. En yaygın kullanılan katot malzemeleri arasında lityum kobalt oksit (LiCoO_2), lityum demir fosfat (LiFePO_4), ve lityum nikel mangan kobalt oksit (LiNMC) bulunur. Katot, deşarj sırasında lityum-iyonlarını serbest bırakır ve şarj sırasında bu iyonları

tekrar alır.

Elektrolit: Elektrolit, lityum-iyonlarının anottan katota ve katottan anota hareket etmesini sağlayan bir iletken ortamdır. Genellikle lityum tuzları ve organik çözücüler karışımından oluşur. Elektrolit, iyon hareketini kolaylaştırırken, aynı zamanda elektriksel olarak yalıtkan olmalıdır (Zhang, 2006).

Ayırıcı: Ayırıcı, anot ve katot arasında yer alır ve bu iki elektrotun doğrudan temasını engeller, böylece kısa devreleri önler. Aynı zamanda lityum-iyonlarının elektrolit aracılığıyla serbestçe hareket etmesine izin verir. Ayırıcı malzemesi genellikle mikroporöz bir polimerdir.

2.1.4. Performans Faktörleri

Lityum-iyon bataryaların performansı, çeşitli faktörlere bağlıdır ve bu faktörler bataryanın enerji yoğunluğu, döngü ömrü, güvenliği ve sıcaklık dayanıklılığı gibi özelliklerini etkiler.

Enerji Yoğunluğu: Lityum-iyon bataryaların yüksek enerji yoğunluğu, bu bataryaların hafif ve kompakt cihazlarda kullanımını mümkün kılar. Enerji yoğunluğu, bataryanın birim ağırlık başına depolayabileceği enerji miktarını ifade eder ve bu özellik bataryaların taşınabilir elektronik cihazlar ve elektrikli araçlar gibi uygulamalarda tercih edilmesinin ana nedenlerinden biridir.

Döngü Ömrü: Döngü ömrü, bir bataryanın şarj ve deşarj döngüleri boyunca ne kadar süre boyunca işlevsel kalabileceğini ifade eder. Lityum-iyon bataryalar, uzun döngü ömrü sayesinde yüzlerce, hatta binlerce şarj-deşarj döngüsü boyunca performanslarını koruyabilirler. Bu özellik, özellikle uzun ömürlü enerji depolama çözümleri gerektiren uygulamalarda kritik öneme sahiptir.

Güvenlik: Lityum-iyon bataryaların güvenliği, bataryaların tasarımına ve kullanılan malzemelere bağlıdır. Termal kaçak gibi olaylar, bataryaların aşırı ısınması durumunda meydana gelebilir ve bu da bataryaların yangın veya patlama riskini artırabilir. Bu nedenle, güvenliği artırmak için bataryalarda çeşitli güvenlik önlemleri (örneğin, ayırıcılar, termal sigortalar ve aşırı şarj koruma devreleri) uygulanır.

Sıcaklık Dayanıklılığı: Lityum-iyon bataryaların performansı, sıcaklık koşullarına oldukça duyarlıdır. Aşırı düşük sıcaklıklar, bataryanın iç direncini artırarak performansını düşürürken, yüksek sıcaklıklar bataryanın iç yapısında bozulmalara neden olabilir. Bu nedenle, lityum-iyon bataryaların sıcaklık dayanıklılığının iyileştirilmesi, özellikle zorlu çevre koşullarında çalışan uygulamalar için önemlidir.

2.1.5. Güvenlik Hususları

Lityum-iyon bataryaların yaygın kullanımı, güvenlik konularını da beraberinde getirmiştir. Bu bataryalar, yüksek enerji yoğunluğu ve yanıcı elektrolit bileşenleri nedeniyle potansiyel güvenlik riskleri taşır. Bataryaların aşırı şarj edilmesi, aşırı deşarj edilmesi, kısa devre veya fiziksel hasar gibi durumlar, bataryanın aşırı ısınmasına ve termal kaçak riskinin artmasına neden olabilir. Termal kaçak, bataryanın iç sıcaklığının kontrolsüz bir şekilde artması durumunda meydana gelir ve bu, bataryanın yanmasına veya patlamasına yol açabilir.


Bu tür risklerin minimize edilmesi için, lityum-iyon bataryalar çeşitli güvenlik önlemleri ile donatılır. Örneğin, batarya yönetim sistemleri (BMS), bataryanın şarj ve deşarj süreçlerini sürekli olarak izleyerek aşırı durumları önceden tespit eder ve gerekli önlemleri alır. Ayrıca, ayırıcılar ve termal sigortalar gibi donanım tabanlı güvenlik önlemleri de bataryaların güvenli bir şekilde çalışmasını sağlar.

2.1.6. Eşdeğer Devre Modeli

Eşdeğer devre modeli (EDM), batarya şarj durumu (BŞD) ile ilişkili bir gerilim kaynağı, bir iç direnç ve girişler (akım, BŞD ve sıcaklık) ile terminal gerilimi arasındaki elektriksel ilişkiyi tanımlayabilen direnç-kapasitans (RC) ağlarından oluşur (Hageman, 1993). Ayrıca, EDM, devre elemanlarının ve bunların kombinasyonlarının bolluğu nedeniyle araştırmacılara uygulamaları için uygun bir yapı tasarlamak için yeterli özgürlük sağlamaktadır. Genellikle, EDM’de direnç, kendi kendine deşarjı temsil eder. Yüksek değerli kapasitör veya gerilim kaynağı ise açık devre gerilimini (OCV) temsil eder. Farklı zaman sabitlerine sahip RC çiftleri, elektrolit ve gözenekli elektrotlardaki difüzyon sürecini ve elektrottaki yük transferini ve çift katman etkisini temsil eder. Rint modeli, Thevenin modeli, yeni nesil araçlar için ortaklık (PNGV) modeli ve genel doğrusal olmayan (GNL) modeli literatürdeki dört yaygın EDM’dir ve Şekil 2.2’de gösterilmiştir.

Tablo 2.1 EDM yapılarının gerilim denklemlerini göstermektedir. Burada U_t , terminal gerilimini, U_{oc} , OCV’yi, I , deşarj akımını, R_0 , iç direnci, R_1 ve R_2 kutuplanma dirençlerini, C_1 ve C_2 kutuplanma kapasitanslarını, U_1 , RC ağının gerilimini, C_{cap} , yığın (*bulk*) kapasitansını göstermektedir. Rint modeline ek bir RC ağı eklenerek Thevenin modeli elde edilir ve bataryanın dinamik terminal gerilimini daha iyi yakalayabilir. OCV varyasyonunun etkileri göz önüne alındığında, Thevenin modeline bir kapasitör C_{cap} eklenerek PNGV modeli elde edilir (Raël vd, 2014; Wu ve

Chen, 2014). C_{cap} , deşarj akımının birikimiyle OCV varyasyonunu açıklar (Liu vd, 2016). Daha fazla RC ağı eklemek, terminal gerilimini daha ayrıntılı olarak tanımlamaya yardımcı olur; PNGV modeli genellikle Rint ve Thevenin modellerinden daha iyi bir doğruluğa sahiptir. Thevenin modeliyle karşılaştırıldığında, konsantrasyon polarizasyon etkisini hesaba katarak GNL modeline bir RC ağı daha dahil edilmektedir.



Şekil 2.2. Eşdeğer devre modelleri (a) Rint modeli (He vd., 2011) (b) Thevenin modeli (Raël vd., 2014; Wu ve Chen, 2014) (c) PNGV modeli (Feng vd., 2013) (d) GNL modeli (Fang vd., 2017)

BŞD tahmin alanı açısından, bir RC veya iki RC çiftine sahip EDM'ler, bataryayı modellemek için özellikle popülerdir. Yeni Avrupa Tahrik Döngüsü (NEDC) üzerindeki deneysel sonuçlar, iki RC'li EDM'nin enerji depolama sistemi için en uygun seçim olduğunu göstermektedir. Terminal geriliminde güçlü histerezis etkisine sahip batarya için de histerezis gerilimli bir RC'li EDM'nin tercih edildiğini göstermektedir. Bu nedenle, daha fazla RC ağı eklemek genellikle modelleme doğruluğunu artırır, ancak ikiden fazla RC ağına sahip olmak da hesaplama yükünü artırır.

Tablo 2.1. Eşdeğer devre modellerinin gerilim denklemleri

Rint modeli	$U_t = U_{oc} - I \times R_0$
Thevenin modeli	$U_t = U_{oc} - U_1 - I \times R_0$
PNGV modeli	$U_t = U_{oc} - U_{cap} - U_1 - I \times R_0$
GNL modeli	$U_t = U_{oc} - U_{cap} - U_1 - U_2 - I \times R_0$

EDM’ler, terminal gerilimini tanımlama yeteneklerini geliştirmek için çeşitli değişiklikler yapılabilir. Bataryanın doğal elektrokimyasal özelliğini tanımlamak için, elektrokimyasal empedans spektroskopisi (EIS) ölçümünden Warburg elemanının analiz edilmesi yoluyla fiziksel tabanlı bir EDM önerilmiştir (Greenleaf vd., 2013). Gerçek zamanlı uygulamalarda çevrimiçi EIS ölçümünün zorluğu, fiziksel tabanlı EDM’nin doğruluğunu azaltabilir. Elektrokimyasal ve termal davranışların daha iyi yorumlanması için, (Watrin vd., 2012) tarafından 11 parametrelili çok katmanlı fiziksel bir batarya modeli önerilmiştir. Deneysel testte modelleme hatası elektriksel kısım için %2’den azdır ve termal kısım için ortalama hata %2.45’tir. Gerçek uygulamalar için, EDM’yi belirli bir uygulamaya uygulamadan önce karmaşıklık ve doğruluk arasında iyi bir denge olmalıdır.

2.1.7. Gelecekteki İhtiyaçlar ve Yenilikçi Yaklaşımlar

Lityum-iyon bataryaların gelişimi ve optimizasyonu, sadece enerji yoğunluğunu ve döngü ömrünü artırmakla sınırlı kalmamaktadır. BSD tahmini, bu bataryaların güvenilirliğini ve performansını sürdürebilmek için önemli bir araştırma alanı haline gelmiştir. BSD tahmini, bataryaların mevcut durumunu değerlendirmek ve ömrünü tahmin etmek amacıyla yapılan çeşitli çalışmaları içerir.

Batarya sağlığının doğru bir şekilde tahmin edilmesi, BMS etkinliğini artırabilir ve enerji depolama sistemlerinin güvenliğini sağlayabilir. Özellikle elektrikli araçlar ve enerji depolama sistemlerinde, bataryaların güvenli ve verimli bir şekilde çalışmasını sağlamak için BSD tahmini kritik bir öneme sahiptir. Batarya sağlığını doğru bir şekilde tahmin etmek, batarya ömrünü optimize etmek ve potansiyel arızaları önceden tespit etmek için gereklidir.

Günümüzde batarya sağlığının tahmini için çeşitli yenilikçi yaklaşımlar ve teknolojiler geliştirilmiştir. Bu yaklaşımlar, model tabanlı ve veri tabanlı yöntemleri içermektedir. Model tabanlı yaklaşımlar, bataryanın iç dinamiklerini matematiksel modellerle temsil ederken, veri tabanlı yaklaşımlar ise geçmiş performans verilerinden tahminler yapar. Özellikle makine öğrenmesi ve yapay zeka gibi ileri teknolojiler,

batarya sađlıđının tahmininde yksek dođruluk ve gerek zamanlı analiz imkanı sunmaktadır.

Bu bađlamda, batarya sađlıđı tahmini iin yapılan alıřmaların gelecekteki nemi giderek artmaktadır. Lityum-iyon bataryaların gvenli ve uzun mrl kullanımı sađlamak, enerji verimliliđini artırmak ve potansiyel riskleri en aza indirmek iin srekli olarak yeni yntemler ve teknolojiler geliřtirilmelidir. Bu, batarya teknolojilerinin srdrlebilirliđini ve gvenilirliđini artıracak, enerji depolama sistemlerinin verimli bir řekilde ynetilmesini sađlayacaktır.

2.2. Kaynaka zeti

BSD, BřD, KK ve batarya kapasitesi tahmini ile ilgili birok alıřma yapılmıřtır. Bu kısımda, yapılan alıřmalar, bu alıřmalarda kullanılan yntemler, metrik deđerleri gibi bilgilere kısaca deđerilecektir.

(J. Tian vd., 2020) batarya yzey sıcaklıđına dayalı BSD tahmin yntemi nermiřtir. Sabit řarj sırasındaki diferansiyel sıcaklık eđrileri analiz edilmiř ve BSD ile gl bir řekilde iliřkisi olduđu vurgulanmıřtır. Bir gerilim aralıđındaki diferansiyel sıcaklık eđrilerinin bir kısmı, SVR kullanılarak BSD ile bir iliřki kurmak iin benimsenir. Gerilim aralıđı ile rnekleme adımınn en iyi kombinasyonu, bir tanesini dıřarıda bırakma dođrulaması kullanılarak belirlenmiřtir. nerilen yntem Oxford ve NASA veri kmelerini kullanan artımlı kapasite analizi (ICA) tabanlı bir BSD tahmin yntemi ile karřılařtırılır. Sonular, nerilen yntemin sırasıyla %3.62 ve %2.49'lk RMSE ile BSD tahmini yapılmıřtır.

(Fan vd., 2020) alıřmasında sabit akım-sabit gerilim řarj modunun řarj eđrisinin kapasite perspektifinin BSD byklđn yansıtabileceđini dřnmřlerdir. nerilen yaklařım, derin đrenme teknolojisiyle řarj eđrisinin paylařılan bilgilerini ve zaman bađımlılıklarını đrenebilen kapı tekrarlayan birim evriřimli sinir ađı (GRU-CNN) adı verilen bir hibrit sinir ađına dayanmaktadır. Daha sonra BSD, gerilim, akım ve sıcaklık gibi yeni gzlemlenen řarj eđrileriyle tahmin edilebilir. Yaklařım, NASA Rastgele Batarya Kullanımı veri seti ve Oxford veri seti zerinde gsterilmiřtir ve maksimum tahmin hatası %4.3 ile sınırlıdır.

(Zhang vd., 2021) alıřmasında iyileřtirilmiř varyasyonel modal ayrıřtırma (VMD), paracık filtresi (PF) ve GPR birleřtirilerek bataryanın gelecekteki kapasitesini ve KK'y tahmin etmek iin hibrit yaklařım nerilmiřtir. VMD algoritması, kaydedilen batarya kapasitesi verilerini bir yařlanma eđilimi dizisine ve

birkaç kalıntı dizisine ayrıştırmak için kullanılır. Modal katman sayısı önerilen arka geri besleme güveni (PFC) yöntemi tarafından üretilir. Daha sonra PF ve GPR algoritmasının tahmin modelleri sırasıyla yaşlanma eğilimi dizisini ve kalıntı dizilerini tahmin etmek için oluşturulur. Önerilen hibrit yaklaşımın etkinliğini doğrulamak için batarya takımı ve batarya hücreleri için gelecekteki kapasite ve KKÖ tahmin deneyleri gerçekleştirilir. KKÖ için NASA B0005 bataryasında %1.3'lük RMSE değeri elde edilmiştir.

(Bamati ve Chaoui, 2021) çalışmasında doğrusal olmayan otoregresif harici girişli (NARX), RNN ve zaman gecikmeli sinir ağını (TDNN) kullanarak BSD ve KKÖ tahmini yapmıştır. Her döngü için, deşarj döngülerinin gerilim, akım ve sıcaklığının ortalama örnekleri, deşarj işlemi süresiyle birlikte girdi olarak kabul edilmiştir. NASA ve Oxford veri seti kullanılmıştır. BSD tahmininde NASA B0005 bataryası ile 100 eğitim verisinde %1.57, Oxford Cell1 bataryası ile %50 eğitim ile %0.46'lık RMSE değeri elde edilmiştir.

(Wei vd., 2022), KKÖ tahminini iyileştirmek ve dolaylı sağlık faktörlerini (SF) uyarlamalı olarak çıkarmak için, yığılmış oto kodlayıcı ve Gauss karışım regresyonuna (SAE-GMR) dayalı KKÖ tahmini önerilmiştir. İlk olarak, dolaylı SF'ler şarj ve deşarj verilerinden çıkarılır ve kapasite ile ilişkiyi analiz etmek için gri ilişki analizi (GRA) benimsenir. Bu çalışmada, bataryanın boyutlarını ve gürültüsünü azaltmak ve senkretik bir SF elde etmek için SAE sinir ağı önerilmiştir. Ardından, GMR modeli yalnızca KKÖ tahmininin doğruluğunu iyileştirmek için değil, aynı zamanda güvenilirliği tanımlamak için de oluşturulmuştur. NASA veri seti kullanılan çalışmada 100 eğitim verisinde % 0.65'lik RMSE değerine ulaşılmıştır.

(Tian vd., 2022) çalışmasında lityum-iyon bataryaların BSD'sini tahmin etmek için CNN, çift yönlü uzun kısa süreli bellek (BiLSTM) ve dikkat mekanizmasına (AM) dayalı bir hibrit model geliştirilmiştir. Bataryaların şarj ve deşarj sürecini analiz ederek, kapasiteyle yüksek oranda ilişkili olan dolaylı SF çıkarılmıştır. SF, CNN'nin girişi olarak alınmıştır ve CNN katmanlarının evrişim ve havuzlama işlemleri, batarya zaman serisi verilerinin özelliklerini çıkarmak için kullanılmıştır. Bu temelde, CNN'den gelen verileri ileri ve geri bağımlılıklarla toplamak ve AM tarafından seri veriler arasındaki korelasyonu daha da vurgulamak için BiLSTM derinlik modeli oluşturulmuştur. NASA veri seti kullanılan çalışmada dört adet SF çıkarılmıştır. Deşarj geriliminin minimum noktasına ulaştığı zaman, deşarj işleminin başlangıç aşamasındaki gerilim eğrisinin maksimum eğimi, deşarj gücü ve deşarj işlemi

sırasında sıcaklığın tepe değerine ulaşması için geçen süre. 98 eğitim verisi ile %0.48 RMSE değeri elde edilmiştir.

(Lyu vd., 2022) çalışmasında yeterli matematiksel desteğe sahip algoritmaları entegre ederek lityum-iyon batarya KKÖ tahmini için VPA modeli adlı yorumlanabilir bir şema önermektedir. İlk olarak, trend sinyali (TS) ve kapasite rejenerasyon sinyali (CRS), kapasite bozulma dizisinden varyasyonel mod ayrıştırma algoritması ile elde edilir. Ardından, TS ve CRS tahmini sırasıyla PF modeli ve ARIMA modeli tarafından uygulanır ve TS ve CRS'nin tahmin sonuçları, kapasite bozulma tahmini olarak üst üste bindirilir. Son olarak, KKÖ tahmini, bozulma tahmin sonucuna ve arıza eşliğine dayanarak gerçekleştirilir. NASA veri seti ile yapılan çalışmada 100 eğitim verisi ile 0.25'lik RMSE değeri elde edilmiştir.

(Bao vd., 2022) çalışmasında genişletilmiş CNN ve çift yönlü kapılı tekrarlayan birim olan genişletilmiş (BiGRU) CNN-BiGRU'ya dayalı bir hibrit sinir ağı önerilmiştir. Önerilen veri odaklı yöntem, seri veri zaman bağımlılığını ve korelasyonunu öğrenmek için çıkarılan batarya deşarj eğrisindeki gerilim dağılımını ve kapasite değişimlerini kullanır. Bu çalışmada NASA ve Oxford veri seti kullanılmıştır. MAE ve RMSE, NASA veri setinde sırasıyla %1.9 ve %3.3'tür. Cell4 ve Cell8 bataryalarının test verisi kalan altı bataryanın eğitim verisi olarak kullanıldığı tahminlerde Cell4 için RMSE %0.073, Cell8 için %0.083 elde edilmiştir.

(Lim vd., 2022) çalışmasında veri odaklı makine öğrenmesi (ML) modelleri GPR ve RNN-LSTM, bataryanın döngü endeksini ve kapasitesini girdi olarak kullanarak Oxford veri setinden şarj kapasitesini tahmin etmiştir. Tüm bataryaların kapasite değerleri ortalaması alınarak yapılan tahminlerde %15 eğitim verisi için RMSE değeri, GPR modelinde %5.98, LSTM modelinde %6.25 olmuştur.

(Yao vd., 2023) çalışmasında SF'lerin hem zamansal hem de mekansal özelliklerini dikkate alan grafik sinir ağı (GNN) tabanlı Batarya BSD'sini tahmin etmek için CL-GraphSAGE yöntemini önermiştir. Akım, gerilim, sıcaklık ve zaman verilerinden 26 adet özellik çıkarılmıştır. İlk olarak, bir grafik oluşturmak için yüksek oranda ilişkili SF'leri çıkarmak üzere SF'ler ve BSD arasındaki Pearson korelasyon katsayıları elde edilir. Daha sonra, zamansal özellikler CNN ve LSTM tarafından çıkarılır. Son olarak, mekansal özellikler, grafik örnek kümesi (GraphSAGE) tarafından elde edilir. Çalışmada MIT, NASA veri setleri ve deneysel veri setleri kullanılmıştır. NASA B0005 bataryası ile 100 eğitim verisinde %0.5808 RMSE değeri elde edilmiştir.

(Xie vd., 2023) çalışmasında CNN-LSTM kullanan yöntem önerilmiştir. Bu yöntem, kapasiteyi sağlık faktörü olarak kullanır ve kapasite dizisini ayrıştırmak için uyarlanabilir gürültülü tam topluluk ampirik mod ayrıştırmayı (CEEMDAN) kullanır. Veri yeniden yapılandırması yoluyla gürültü bileşenlerini ortadan kaldırır. Yeniden yapılandırılan kapasite dizisi verileri daha sonra CNN-LSTM sinir ağını önceden eğitmek ve ön bilgi oluşturmak için kullanılır. Gerçek zamanlı batarya kapasitesi verileri, lityum-iyon bataryaların gerçek zamanlı KKÖ tahmini için ön bilgi destekli CNN-LSTM sinir ağını eğitmek için kullanılır. B0005 bataryası ön bilgi olarak kullanılıp B0006 batarya verisinin %60 ile yapılan KKÖ tahmininde %0.2894 RMSE değeri elde edilmiştir.

(Ding ve Chen, 2023) çalışmasında ardışık varyasyonel mod ayrıştırma (SVMD) ve aquila optimize edilmiş derin aşırı öğrenme makinesini (AO-DELM) birleştiren lityum-iyon batarya kapasitesi tahmin modeli önerilmiştir. İlk olarak, SVMD kapasite sinyalini bölmek için kullanılmıştır ve özellikle bozulma süreci sırasında oluşan kapasite büyümesi için kısa vadeli eğilim tahminini iyileştirmiştir. İkinci olarak, DELM ağı, zamana bağlı özellikleri verimli bir şekilde çıkarmıştır. AO algoritması, başlangıç ağırlıklarına duyarlılık sorunu için DELM eğitim sürecinin parametrelerini bulmak için kullanılmıştır. Çalışmada NASA ve CALCE veri setleri kullanılmıştır. Metrik değerleri; MAE (%0.66Ah, %0.44Ah), RMSE (%1.13Ah, %0.78Ah), MAPE (%0.44, %0.82)'dir.

(Li vd., 2023) çalışması çok kaynaklı SF'leri çıkarma ve seyrek Bayesian öğrenmesine dayalı bir BSD tahmin modeli önermektedir. İlk olarak, şarj ve deşarj sırasında bataryaların gerilim ve sıcaklık eğrilerinden dört doğrudan SF çıkarılmış ve artımlı kapasite eğrilerinden Gauss filtreleme algoritmasıyla birlikte iki dolaylı SF çıkarılmıştır. Ardından, veri kümeleri farklı durumlarda çevrimiçi BSD tahminini simüle etmek için kullanılan üç farklı eğitim ve test kümesine bölünür. Son olarak, çıkarılan altı SF, Pearson korelasyon katsayısı yöntemi kullanılarak seçilir ve deney, üç yüksek korelasyon özelliğini kullanarak durumlardan biri için tekrarlanır ve seçimden önceki ve sonraki sonuçlar karşılaştırılır. NASA ve Oxford veri setleri ile yapılan çalışmada NASA B0005 bataryası %50 eğitim verisinde %3.56 RMSE, Oxford Cell1 bataryası %50 eğitim verisinde %2.41 RMSE elde edilmiştir.

Yapılan bu çalışmaların özeti Tablo 2.2'de verilmiştir. Literatür geneline bakıldığında tezin amacını oluşturan gereklilikler şunlardır:

1. Literatürde görüldüğü üzere SF'lerin bazıları dolaylı yoldan çıkarılmıştır.

VMD, PF gibi algoritmaların kullanılması işlem yükünü ve karmaşıklığı artırmaktadır. Doğrudan çıkarılan SF’lerde ise SF sayısındaki yükseklik bulunmaktadır. Dolayısıyla az sayıda ve basit çıkarım yapılabilen SF’ler gereklidir.

2. Doğruluğun artırılması için bazı çalışmalarda çok katmanlı hibrit algoritmalar kullanılmıştır. Doğruluğun artırılması için karışıklığı ve işlem yükünü artıran bu yöntemlerin yerine tek katmanlı, işlem yükü az algoritmalar kullanılmalıdır.
3. Ayrıca tahminler yapılırken BSD, KKÖ ya da şarj kapasitesi gibi parametre tahminler yapılmıştır. Bunlar arasında tek bir ifadeden diğerlerinin çıkarımı yapılacak değer şarj kapasitesi değeridir. Çünkü BSD ve KKÖ gibi değerler sadece belirli bir alanda bilgi verecektir. Onun yerine kapasite tahmininin yapılması, ilk kapasite bilindiği için hem BSD, hem de KKÖ ile bilgi sahibi olunmasına olanak verecektir.
4. Kullanılan algoritmaların parametreleri genellikle standart değerler kullanarak ya da deneme yanılma yoluyla belirlenmiştir. Amaç en doğru sonuca en kısa zamanda ulaşmak olduğu için algoritmaların parametrelerini de en doğru şekilde ayarlamak elzemdir. Dolayısıyla bu konuda bir optimizasyon algoritması kullanılması bu sorunu çözebilecektir.

Tüm bu bilgiler ışığında tez çalışmasının yönelimi öncelikle az işlem yükü ile yüksek değerli tahmin sonuçlarına ulaşmaktır. Bunun için parametre optimizasyonunda GA kullanılmıştır. Tahmin algoritmalarında ise literatürde kullanılıp iyi sonuç veren CNN, zaman serisi sorunlarının çözümünde başarımı ile bilinen RNN ve en genel şekilde sinir ağlarında kullanılan MLP algoritmalarının belirlenmesine karar verilmiştir. GA ile CNN’in filtre boyutu sayısı, RNN ve MLP’nin gizli katman sayısının optimizasyonları yapılmıştır. Farklı veri setlerinde, düşük, orta ve yüksek eğitim verileri ile sinir ağları eğitilerek kapasite tahmini yapılmıştır.


Tablo 2.2. Literatür özet tablosu

Kaynak	Yöntem	Veri Seti	Kullanılan Özellikler	Tahmini Yapılan Değer	Metrik Değerler
(J. Tian vd., 2020)	Diferansiyel Sıcaklık Eğrileri ve SVR	Oxford, NASA	Diferansiyel sıcaklık eğrileri, gerilim aralığı	BSD	RMSE: %3.62 (Oxford), %2.49 (NASA)
(Fan vd., 2020)	GRU-CNN Hibrit Sinir Ağı	NASA, Oxford	Gerilim, akım, sıcaklık	BSD	Maksimum hata: %4.3
(Zhang vd., 2021)	VMD, PF, GPR Hibrit Yaklaşım	NASA	Yaşlanma eğilimi, kalıntı dizileri	KKÖ	RMSE: %1.3
(Bamati ve Chaoui, 2021)	NARX, RNN, TDNN	NASA, Oxford	Gerilim, akım, sıcaklık	BSD, KKÖ	RMSE: %1.57 (NASA), %0.46 (Oxford)
(Wei vd., 2022)	SAE-GMR	NASA	Şarj ve deşarj verileri	KKÖ	RMSE: %0.65
(Tian vd., 2022)	CNN, BiLSTM, AM Hibrit Model	NASA	Gerilim eğrisi, deşarj gücü, sıcaklık verileri	BSD	RMSE: %0.48
(Lyu vd., 2022)	VPA Model	NASA	Trend sinyali, kapasite rejenerasyon sinyali	KKÖ	RMSE: %0.25
(Bao vd., 2022)	CNN-BiGRU Hibrit Sinir Ağı	NASA, Oxford	Gerilim dağılımı, kapasite değişimleri	KKÖ	MAE: %1.9, RMSE: %3.3
(Lim vd., 2022)	GPR, RNN-LSTM	Oxford	Döngü endeksi, kapasite	Şarj Kapasitesi	RMSE: %5.98 (GPR), %6.25 (LSTM)
(Yao vd., 2023)	CL-GraphSAGE	MIT, NASA	Akım, gerilim, sıcaklık, zaman verileri	BSD	RMSE: %0.5808
(Xie vd., 2023)	CEEMDAN ve CNN-LSTM	NASA	Kapasite dizisi	KKÖ	RMSE: %0.2894
(Ding ve Chen, 2023)	SVMD ve AO-DELM	NASA, CALCE	Kapasite sinyali, zamana bağlı özellikler	KKÖ	MAE: %0.66Ah, %0.44Ah, RMSE: %1.13Ah, %0.78Ah, MAPE: %0.44, %0.82
(Li vd., 2023)	Çok Kaynaklı SF ve Seyrek Bayesian Öğrenme	NASA, Oxford	Gerilim, sıcaklık eğrileri, artımlı kapasite eğrileri	BSD	RMSE: %3.56 (NASA), %2.41 (Oxford)

3. YÖNTEM

İki farklı veri seti için batarya sağlığı ve kapasitesi tahmini üzerine çalışmalar yapılmıştır. İki veri seti için de yöntem genel olarak aynıdır.

NASA veri seti için yapılan çalışmanın genel diyagramı Şekil 3.1’de verilmiştir. Akış beş adımda tamamlanmaktadır: özellik çıkarma, veri işleme aşaması, parametre optimizasyonu, kapasite tahmini ve performans değerlendirmesi.



Adım 1: NASA tarafından laboratuvar ortamında gerçekleştirilen deneylerden elde edilen veri setinde bulunan dört farklı batarya özelliği, çalışmanın ilk adımında çıkarılır. Ardından, özellik seçimi için bu özelliklerin batarya kapasitesi ile olan doğrusal ilişkisini belirleyen Pearson korelasyon analizi gerçekleştirilir.


Adım 2: Bu adımda, kullanılacak olan özellikler ve batarya kapasitesi, 0-1 aralığında normalize edilir. Range yöntemi kullanılarak bu işlem gerçekleştirilir. Normalizasyonun ardından, veriler 40, 70 ve 100 olmak üzere üç farklı eğitim seti için eğitim ve test veri setleri olarak ayrılır.

Adım 3: Genetik algoritmanın kullanıldığı bu adımda kapasite tahmininde kullanılacak CNN, BP ve RNN algoritmalarının ilgili parametreleri belirlenir. Bu belirleme sürecinde, GA tarafından en düşük RMSE değerini sağlayan parametreler seçilir. Her bir farklı eğitim seti için uygun parametreler ayrı ayrı belirlenmiş ve optimal parametre setleri belirlenir.

Adım 4: İkinci adımda belirlenen eğitim verisi, üçüncü adımda belirlenen en uygun parametreler kullanılarak, CNN, BP ve RNN ile kapasite tahmini gerçekleştirilir. Her bir algoritma için, beş kez kapasite tahmini yapılır. Ardından, bu beş tahminin ortalaması alınır. Ortalama tahminler, performans analizi için hazırlık amacıyla denormalize edilir.

Adım 5: Yapılan tahminlerin doğruluğunu ve güvenilirliğinin kontrolü ve değerlendirmesi için beş farklı performans metriği kullanılır.

NASA veri seti haricinde önerilen yöntemin doğruluğunu kanıtlamak için Oxford tarafından üretilen veri seti kullanılmıştır (Birk1, 2017). Bu veri seti için kullanılan yöntemin genel şeması Şekil 3.2’de verilmektedir. Akışın özeti, özellik çıkarma, veri işleme aşaması, parametre optimizasyonu, kapasite tahmini ve performans değerlendirmesi olmak üzere beş adımdan oluşmaktadır.



Şekil 3.2. Oxford veri seti için genel akış diyagramı

Adım 1: Çalışmanın ilk adımında, Oxford'un laboratuvar ortamında yaptığı deneylerle elde edilen veri setinden sekiz farklı batarya için üçer adet özellik çıkarılmıştır. Daha sonra bu özellikler ile batarya kapasitesi arasındaki doğrusal ilişkinin belirlenmesi için Pearson korelasyon analizi yapılmıştır.

Adım 2: Bu aşamada, özellikler ve batarya kapasitesi, değerlerin büyüklüğünden kaynaklanabilecek dalgalanmaları azaltmak için normalizasyon işlemi yapılmıştır. Normalizasyon adımı range yaklaşımıyla gerçekleştirilmiştir. Range normalizasyonunda değerlerin 0-1 aralığında dağılımı yapılır. Normalizasyon işleminin ardından, üç farklı eğitim seti için ilgili veriler, eğitim ve test veri setlerine bölünür.

Adım 3: Bu aşamada, BSD tahmini ve kapasite için BP, RNN ve CNN için en iyi parametreleri belirlemek için GA kullanılır. GA en düşük RMSE değerlerini sağlayan parametreleri seçer. Her farklı eğitim seti için bağımsız olarak uygun parametreler bulunur ve en iyi parametre setleri belirlenir.

Adım 4: İkinci adımda elde edilen eğitim verilerine ve üçüncü adımda seçilen ideal parametrelere dayanarak üç ayrı algoritma kullanılarak kapasite tahmini gerçekleştirilir: CNN, BP ve RNN. Her yöntem için, çeşitli ağırların her biri beş kez eğitilerek beş farklı kapasite tahmini elde edilir. Daha sonra bu beş tahminin ortalaması alınır. Elde edilen ortalama tahminler, performans analizine hazırlık amacıyla denormalizasyona tabi tutulur.

Adım 5: Beş farklı değerlendirme metriği tahminlerin doğruluğunu ve güvenilirliğini incelemek ve değerlendirmek için kullanılır.

3.1. Pearson Korelasyon Analizi

Pearson korelasyon analizi, iki değişken arasındaki doğrusal ilişkinin yönünü ve kuvvetini ölçen istatistiksel bir yöntemdir. Bu analiz, özellikle mühendislik, finans, tıp ve sosyal bilimler gibi alanlarda, iki değişkenin birbiriyle ne kadar ilişkili olduğunu belirlemek için sıkça kullanılır. Korelasyon katsayısı Denklem 3.1'deki gibi hesaplanır.

$$r = \frac{\sum(X-\mu_x)(Y-\mu_y)}{\sqrt{\sum(X-\mu_x)^2 \sum(Y-\mu_y)^2}} \quad (3.1)$$

Burada, X ve Y karşılaştırılan değişkenlerdir. μ_x ve μ_y sırasıyla X ve Y 'nin ortalamalarını temsil eder. Pearson korelasyon katsayısı (r), iki değişken arasındaki doğrusal ilişkinin yönünü ve gücünü ifade eden bir değerdir. Bu katsayı, -1 ile 1 arasında bir değer alır ve bu değerlerin farklı anlamları vardır:

$r = 1$: Pozitif tam korelasyon. Bu, iki değişken arasında mükemmel bir doğrusal ilişki olduğunu ve bir değişkenin artmasıyla diğerrinin de sabit bir oranda arttığını gösterir.

$r = -1$: Negatif tam korelasyon. Bu, iki değişken arasında mükemmel bir ters doğrusal ilişki olduğunu ve bir değişkenin artmasıyla diğerrinin sabit bir oranda azaldığını gösterir.

$r = 0$: Korelasyon yok. Bu, iki değişken arasında doğrusal bir ilişki olmadığını gösterir. Yani, bir değişkenin değeri, diğerrinin değeri hakkında bilgi vermez.

$0 < r < 1$: Pozitif korelasyon. r değeri 1'e yaklaştıkça, iki değişken arasındaki

pozitif doğrusal ilişki güçlenir. Ancak bu mükemmel bir ilişki anlamına gelmez.

-1 < r < 0: Negatif korelasyon. r değeri -1'e yaklaştıkça, iki değişken arasındaki negatif doğrusal ilişki güçlenir. Ancak bu da mükemmel bir ilişki anlamına gelmez.

3.2. Normalizasyon

Bu araştırmada, kapasite ve özelliklere range tipi normalizasyon yapılmıştır. Tüm veriler, 0 ile 1 arasına ölçeklendirilmiştir. Range tipi normalizasyonun formülü, Denklem 3.2'de açıklanmıştır.

$$\bar{x}_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (3.2)$$

Burada $\bar{x}_i$, normalize serideki i . değeri, x_i , serideki i . değeri, $\min(x)$ serinin en küçük, $\max(x)$ ise serinin en büyük değerini temsil etmektedir.

3.3. Batarya Sağlık Durumu

Bir bataryanın mevcut kapasitesinin, yeni olduğundaki kapasitesine oranını ifade eden bir ölçüttür. Bu değer, bataryanın genel performansını ve ne kadar ömrü kaldığını anlamak için kullanılır. Batarya yeni ve tam kapasitede çalışırken bu değer %100'dür. Kullanıldıkça bu değer azalır. BSD, şarj/deşarj döngüleri, kullanım koşulları ve çevresel faktörler gibi etkenlerle düşebilir. BSD bataryanın güvenilirliği ve kullanılabilirliği açısından kritik bir göstergedir ve doğru bir şekilde izlenmesi, batarya yönetim sistemleri ve kullanıcılar için büyük önem taşır. BSD denklemi Denklem 3.3'te gösterilmiştir.

$$BSD = \frac{Q_{gerçek}}{Q_{Nominal}} \quad (3.3)$$

burada $Q_{gerçek}$ bataryanın döngüdeki maksimum kapasitesidir ve $Q_{Nominal}$ %100 sağlıklı bir bataryanın kapasitesidir.

3.4. Genetik Algoritma

GA, doğal seleksiyon ve genetik süreçlerden ilham alınarak tasarlanmış, optimizasyon ve arama problemlerini çözmek için kullanılan bir hesaplama yöntemidir. GA, evrimsel hesaplama adı verilen bir alt disiplinin bir parçasıdır.

Genetik algoritmalar, doğal seçim ilkesine dayanır. Bu ilkeye göre, bir popülasyondaki daha uyumlu bireyler, yani sorunu daha etkili bir şekilde çözebilenler, gelecek nesillere daha fazla gen aktarımı yapma eğilimindedir. GA, bu doğal seleksiyon sürecini taklit eder ve bir popülasyon içindeki bireyleri çeşitli genetik operatörler aracılığıyla, çaprazlama, mutasyon ve seçim gibi işlemlerle birbirleriyle

etkileşime sokarak bir çözüm alanında ilerlemeyi hedefler.


GA, özellikle karmaşık, çok boyutlu, genel arama veya optimizasyon problemlerinde etkili bir yöntem olarak kullanılmaktadır. Örnek olarak, seyahat satıcı problemini, makine öğrenmesi modeli optimizasyonunu veya rota planlamasını ele almak için GA kullanılabilir.

Genetik algoritmanın çalışma süreci aşağıdaki adımlardan oluşmaktadır:

1. Başlangıç Popülasyonu Oluşturma: İlk nesil bireylerinin rastgele veya sezgisel yöntemlerle oluşturulması.
2. Uygunluk Değerlendirmesi: Her bireyin uygunluk değerinin hesaplanması, yani çözümün ne kadar iyi olduğunun ölçülmesi.
3. Seçim: Uygunluk değerlerine dayanarak bireylerin seçilmesi. Daha iyi uyumlu bireylerin daha yüksek olasılıkla seçilme şansı vardır.
4. Çaprazlama: Seçilen bireyler arasında genetik materyalin değişimini sağlayan çaprazlama işlemi. Bu, yeni bireylerin oluşturulmasını sağlar.
5. Mutasyon: Yeni oluşturulan bireylerde rastgele genetik değişikliklerin uygulanması.
6. Yeni Popülasyon Oluşturma: Çaprazlama ve mutasyon sonucunda elde edilen bireylerin bir sonraki nesil popülasyonunu oluşturması.
7. Sonlandırma Koşulunun Kontrol Edilmesi: Belirli bir sonlandırma koşulunun sağlanıp sağlanmadığının kontrol edilmesi (örneğin, maksimum iterasyon sayısına ulaşma veya istenen bir uygunluk seviyesine ulaşma).
8. Sonuçların Değerlendirilmesi: Elde edilen sonuçların analiz edilmesi ve istenilen çözüme yakınlığın değerlendirilmesi.

Bu çalışmada kullanılan GA fonksiyonları şunlardır:

Tek Çaprazlama (Single Crossover): Çaprazlama operatörünün en temel şeklidir. Bu yöntemde, seçilen iki ebeveynin genetik materyali belirli bir noktada ayrılır ve ardından bu parçalar karşılıklı olarak değiştirilir. Bu işlem, iki çocuk bireyin oluşturulmasını sağlar. Şekil 3.3 tekli çaprazlamanın örneğini göstermektedir.




Şekil 3.3. Tek çaprazlama örneği

Düzgün Mutasyon (Uniform Mutation): Bir bireyin genetik kodunda rastgele değişiklikler gerçekleştiren bir mutasyon operatörüdür. Bu operatör, her genin belirli bir ihtimalle rastgele yeni değerlerle değiştirilmesini mümkün kılar. Düzgün mutasyon, genetik çeşitliliği artırarak arama sürecinin daha geniş bir alanı kapsamasına yardımcı olur. Bu sayede genetik algoritmanın popülasyonu, potansiyel çözümleri keşfetme ve optimize etme yeteneğini artırır.

Mutasyondan Önce: 01011011 Mutasyondan Sonra: 01111011

Roulette Seçim Fonksiyonu: Bu fonksiyon, seçim operatörü olarak kullanılır ve bireylerin uygunluk değerlerine dayanarak seçimini sağlar. Bu yöntemde, her bireyin seçilme olasılığı, uygunluk değerinin toplam uygunluk değeri içindeki payına göre belirlenir. Yani, daha uyumlu bireylerin seçilme olasılığı daha yüksektir. Bu şekilde, daha uyumlu bireylerin gelecek nesle aktarılma şansı artar. Şekil 3.4, Roulette seçim fonksiyonunun örnek bir şema gösterimini sunmaktadır.




Şekil 3.4. Roulette seçim fonksiyonu

Bu çalışmada, 40, 70 ve 100 eğitim verisi ile tüm bataryalar için ayrı ayrı, CNN, BP ve RNN'nin parametrelerinin belirlenmesinde GA kullanılmıştır. CNN'de filternumber ve filtersize parametreleri, BP ve RNN için hiddenlayersize parametreleri belirlenmiştir.

3.5. Evrimsel Sinir Ağı

CNN, görüntü tanıma ve bilgisayarlı görmede sınıflandırma, bölümlendirme ve nesne tespiti için son yıllarda giderek daha fazla kullanılan bir tür ileri beslemeli sinir ağıdır (Celeghin vd., 2023). Hiyerarşik öğrenme prensibiyle çalışan bu yöntem önemli bir başarı göstermiştir. Giriş verileri birden fazla katmandan geçerken, istenen bilgilerin aşamalı bir şekilde ayrıştırılması söz konusudur. Ağın katmanları derinleştikçe bilgiler daha ince ayrıntılarla öğrenilir (Milletari vd., 2016). Şekil 3.5, Evrimsel Sinir Ağı'nın ve bunun segmentasyondaki uygulamasının mimari örneğini göstermektedir.



Şekil 3.5. CNN mimarisi örneği

CNN'ler tipik olarak bir dizi farklı bileşen içerir. Bu bileşenler probleme göre uyarlanır. Bileşenler aşağıdaki gibidir;

Evrşim katmanı: CNN'de evrşim katmanı ana katmandır ve bir dizi uyarlanabilir filtre içerir. Bu filtreler en az bir katmanda matris çarpımları yerine evrşim işlemleri gerçekleştirerek çalışır.


Havuzlama: Havuzlama işlemi, alt aralıkları birleştirmek için ortalama alma veya maksimum değerleri seçme gibi işlevler yoluyla çıktı boyutunun azaltılmasını içerir. Havuzlama, tanımlanmış bir aralıktaki maksimumun ortalamasını alarak veya hesaplayarak bir değerin çıkarılmasını içerir. Havuzlama uygulaması, girişte kayan pencere yöntemini kullanır; burada kayan pencere, belirtilen havuzlama yöntemine dayalı olarak giriş alanından bir değer üretir ve çıkış katmanına katkıda bulunur.

Düzeltilmiş Doğrusal Birim (ReLU) katmanı: Aktivasyon fonksiyonları, evrişimli sinir ağları için önemli bir faktördür ve ReLU aktivasyon fonksiyonu, derin sinir ağı modellerinde yaygın olarak kullanılır. Bu katman, Denklem 3.4'te verildiği gibi negatif giriş değerlerini sıfıra ayarlama gibi önemli bir özelliğe sahiptir. Bu özellik, ReLU işlevini kullanırken ağı öğrenme sürecini hızlandırır.

$$f(x) = \begin{cases} 0, & \text{if } x < 0 \\ x, & \text{if } x \geq 0 \end{cases} \quad (3.4)$$

Tam bağlı katman: Evrişim ve havuzlama tarafından üretilen değerler bu katman tarafından girdi olarak alınır ve çıktı katmanında bir dizi sınıf olarak işlenir.

CNN geleneksel olarak iki boyutlu verilerden özellikler çıkararak görüntüler için kullanılır. Bu çalışmada, benzer bir mimari, tek boyutlu zaman serisi verileri olan batarya kapasitesinin tahmin edilmesi amacıyla kullanılmıştır. Şekil 3.6 zaman serisi tahmin modeli için kullanılan 1D-CNN mimarisini göstermektedir.



Şekil 3.6. 1D CNN mimarisi

Bu yapı, giriş katmanı, evrişimsel katman, düzleştirme katmanı, tam bağlantılı

katman ve çıkış katmanından oluşmaktadır. Giriş özellikleri evrişimsel katmana iletilir. Evrişimsel katmanda, giriş özelliklerine filtreler uygulanarak özellik haritaları oluşturulur. Bu işlem sonuçlarına aktivasyon fonksiyonu uygulanır. Evrişimsel katmandan gelen çıktı, düzleştirme katmanı aracılığıyla tek boyutlu bir diziyi temsil edecek şekilde düzenlenir. Düzleştirme katmanının çıktısı, tam bağlantılı katmana iletilir. Tam bağlantılı katmanda, veriler üzerinde işlem yapmak için ağırlıklar uygulanır. Tam bağlı katman çıktısı çıkış katmanına beslenir. Bu çalışmada, konvolüsyon katmanında aktivasyon fonksiyonu uygulanmamıştır. Özetle CNN algoritması kullanılırken uygulanan katmanlar şöyledir: 1. Sequence input layer 2. CNN layer 3. Fully connected layer 4. Regression layer. CNN ağının eğitim seçenekleri Tablo 3.1’de detaylı olarak gösterilmiştir.

Tablo 3.1. CNN eğitim seçenekleri

Solver	Adam
MaxEpochs	1000
GradientThreshold	0.5
InitialLearnRate	0.0001

3.6. Çok Katmanlı Perseptron

MLP, bir tür yapay sinir ağıdır ve derin öğrenme modellerinin temel yapı taşlarından biridir. MLP, özellikle gözetimli öğrenme problemlerinde yaygın olarak kullanılır ve sınıflandırma ile regresyon gibi görevler için uygundur.

Katmanlar: MLP, bir giriş katmanı, bir veya daha fazla gizli katman (hidden layers) ve bir çıkış katmanından oluşur. Her katmandaki nöronlar, bir önceki katmandan gelen sinyalleri alır, işlemlerden geçirir ve bir sonraki katmana iletir.

Nöronlar: Her katmanda, nöronlar adı verilen birimlerin her biri bir ağırlık değeriyle çarpılan girdiyi alır, bir aktivasyon fonksiyonu aracılığıyla bu girdiyi işler ve çıktıyı verir.

Aktivasyon Fonksiyonu: Aktivasyon fonksiyonları, bir nöronun çıktısının ne olacağını belirler. Sigmoid, ReLU (Rectified Linear Unit) ve tanh gibi yaygın aktivasyon fonksiyonları, doğrusal olmayan ilişkileri modelleyebilmek için kullanılır.


İleri Besleme (Feedforward): MLP, ileri besleme mimarisi kullanır, yani veri giriş katmanından çıkış katmanına kadar tek bir yönde akarak işlenir. Geriye doğru bir veri akışı olmaz.

Geri Yayılım (Backpropagation): MLP’nin öğrenme süreci, geri yayılım

algoritması ile gerçekleştirilir. Bu algoritma, ağırlıkların ve önyargıların (bias) güncellenmesi için hatayı ağ boyunca geri yayar, böylece modelin performansı zamanla iyileşir.

MLP, farklı problem türleri için özelleştirilebilir, etiketlenmiş verilerle yüksek doğrulukla eğitim yapılabilir, doğrusal olmayan veri ilişkilerini modelleme yeteneği bulunmaktadır. Fakat çok katmanlı ve büyük veri kümeleriyle çalışıldığında, eğitim süreci zaman alıcı olabilir. MLP'ler, yeterince düzenlenmezse, aşırı öğrenme yapabilir ve eğitim verisine fazla uyum gösterebilir. MLP, yapay sinir ağlarının en temel ve en yaygın türlerinden biri olup, derin öğrenme modellerinin daha karmaşık versiyonlarının (CNN, RNN gibi) temelini oluşturur.

Bu çalışmada MLP'nin öğrenme süreci BP algoritması ile yapılacaktır. BP, en temsili yapay sinir ağı algoritmalarından biridir (Jin vd., 2000). Şekil 3.7 temel bir MLP ağının mimarisini göstermektedir. BP sinir ağının temel fikri, çok katmanlı ileri beslemeli bir sinir ağı oluşturmak ve hata geri yayılım algoritmasına göre yayılım sürecinde sinyal değerinin gerçek çıkış değeri ile beklenen çıkış değeri arasındaki hatayı kullanarak her katman ve her düğüm arasındaki bağlantı ağırlıklarını ve eşikleri ayarlamaktır. Bu algoritmanın girdi ve çıktı arasındaki matematiksel eşlemeyi önceden belirlemesine gerek yoktur, ancak kuralları öğrenmek ve sinyalin matematiksel simülasyonunu elde etmek için hata geri bildirimini kullanabilir. BP sinir ağının öğrenme süreci iki aşamaya ayrılır: giriş sinyalinin ileri yayılma süreci ve tahmin hatasının BP süreci (Li vd., 2012).



Şekil 3.7. MLP mimarisi

Çıktı katmanındaki nöron sayısı, BP sinir ağının çıktısı ve beklenen çıktıdır. Modelin hatası aşağıdaki gibi hesaplanır (Y. Zhang vd., 2022):

$$\varepsilon = \frac{1}{2} \sum_{j=1}^n (y_j - y'_j)^2 \quad (3.5)$$

Her ağırlığın modifikasyon değeri aşağıdaki şekildedir:


$$\Delta \omega_{ij} = -\eta \frac{d\varepsilon}{d\omega_{ij}} = -\eta \frac{d\varepsilon}{dI_j} \frac{dI_j}{d\omega_{ij}} \quad (3.6)$$

burada ω_{ij} , i giriş katmanı düğümünden j gizli katman düğümüne giden ağırlığı η ise öğrenme oranını temsil eder. I_j , j . gizli katmanın transfer fonksiyonudur. Bu çalışmada, BP ağı için Levenberg-Marquardt eğitim fonksiyonu tercih edilmiştir. Bu fonksiyon, geri yayılım eğitim fonksiyonu olarak kullanılır ve Jacobian türevlerini içerir. Levenberg-Marquardt eğitim fonksiyonları, hızlı çalışma özelliklerine sahip olmalarına rağmen, GPU donanımında desteklenmemektedirler.

3.7. Tekrarlayan Sinir Ağı

RNN, bir önceki adımın çıkışını güncel adımın girişi olarak kullanan bir sinir ağıdır. Dolayısıyla tüm girişler birbiri ile ilişkilidir. Şekil 3.8 RNN mimarisini göstermektedir. X_t , t anındaki girişi, h_t , gizli katman çıkışını ve Y_t , çıktıyı temsil eder.

$\omega_{h(t-1)}$, önceki gizli katman ile t anındaki gizli katman arasındaki ağırlığı, ω_{xt} , giriş ile gizli katman arasındaki ağırlığı, ω_{yt} , gizli katman ile çıkış arasındaki ağırlığı ifade eder. Denklem 3.7 ve 3.8, gizli durumu ve RNN çıkış formüllerini göstermektedir.



Şekil 3.8. RNN mimarisi

$$h_t = \tanh(\omega_{h(t-1)}h_{t-1} + \omega_{xt}X_t) \quad (3.7)$$

$$Y_t = \omega_{yt}h_t \quad (3.8)$$

3.8. Değerlendirme Parametreleri

Bu çalışmada, önerilen sistem tarafından üretilen tahminlerin gerçek değerlere olan benzerliğini ölçmek ve sistemin performansını çeşitli açılardan değerlendirme için ortalama kare hatası (MSE), kök ortalama kare hatası (RMSE), normalize kök ortalama kare hatası (NRMSE), ortalama mutlak hata (MAE) ve kare korelasyon (R2) olmak üzere beş farklı metrik kullanılacaktır. Bu metrikler, denklem 3.9, 3.10, 3.11, 3.12 ve 3.13'te belirtilen formüller kullanılarak hesaplanacaktır.

$$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2 \quad (3.9)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2} \quad (3.10)$$

$$NRMSE = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2}}{\max(x_i) - \min(x_i)} \quad (3.11)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_i - \hat{x}_i| \quad (3.12)$$

$$R2 = \left(\frac{\sum (x_i - \text{mean}(x))(\hat{x}_i - \text{mean}(\hat{x}))}{\sqrt{\sum (x_i - \text{mean}(x))^2 \sum (\hat{x}_i - \text{mean}(\hat{x}))^2}} \right)^2 \quad (3.13)$$

Burada x_i , gerçek değeri, $\hat{x}_i$, tahmini değeri, N , döngü sayısını, $\max(x_i)$, en büyük gerçek değeri, $\min(x_i)$, en küçük gerçek değeri, $\text{mean}(x)$, gerçek değerlerin ortalaması ve $\text{mean}(\hat{x})$ de tahmin değerlerinin ortalamasını ifade etmektedir.

4. VERİ SETLERİ VE ÖZELLİK ÇIKARMA

Bu bölümde çalışmada kullanılan veri setleri hakkında bilgi verilecektir. Bu veri setleri NASA ve Oxford veri setleri olarak iki ana başlıkta toplanmıştır. NASA veri setinde bulunan bataryalardan dört batarya verisi, Oxford veri setinde bulunan bataryalardan da sekiz batarya verisi kullanılmıştır. Ayrıca bu veri setlerinde bulunan şarj ve deşarj süresince kaydedilen akım ve gerilim değerlerinden elde edilecek özelliklerin çıkarımı anlatılacaktır. Sinir ağlarının eğitiminde ve bu ağların test edilmesinde kullanılmak üzere NASA veri setinden dört farklı özellik, Oxford veri setinden üç farklı özellik elde edilmiştir.


4.1. NASA Veri Seti Bilgisi

Lityum-iyon batarya ile hızlandırılmış ömür testi platformu, temel olarak programlanabilir bir elektronik yük, programlanabilir bir DC güç kaynağı, bir termostat, çeşitli sensörler, veri toplama ve bir elektrokimyasal empedans spektroskopisi test cihazı içerir (Saha ve Goebel, 2007). BSD tahmini için yaygın olarak kullanılan B0005, B0006, B0007 ve B0018 etiketli dört pil seçilmiştir (Choi vd., 2019; Khumprom ve Yodo, 2019; Ren vd., 2018). Bir lityum-iyon bataryanın test süreci şu adımlardan oluşur: İlk olarak, 24 °C ortam sıcaklığında şarj deneyi başlatılır ve batarya, 1.5A sabit akım ile şarj edilir. Terminal gerilimi 4.2 V'a ulaştığında, sabit gerilim moduna geçilir ve akü şarj akımı 20 mA'ya düşene kadar bu modda şarj devam eder. Şarj akımı 20 mA'ya düştüğünde şarj işlemi sona erer. Son olarak, 24 °C ortam sıcaklığında deşarj deney şemasında, B0005, B0006, B0007 ve B0018 numaraları bataryaların terminal gerilimleri sırasıyla 2.7, 2.5, 2.2 ve 2.5 V'a düşene kadar bataryaların 2 A sabit akım ile deşarjı gerçekleştirilir. Tablo 4.1 NASA veri setinden kullanılan bataryaların şarj deşarj işlemlerinde kullanılan akımları, ortam sıcaklıklarını ve başlangıç kapasitelerini göstermektedir.

Tablo 4.1. NASA veri setinde kullanılan bataryalara ait özellikler


Batarya	Şarj işlemi			Deşarj işlemi		Ortam koşulları		
	Sabit akım (A)	Üst gerilim limiti (V)	Şarj kesme akımı (mA)	Sabit akım (A)	Deşarj kesme gerilimi	Ortam sıcaklığı (°C)	Başlangıç kapasiteleri (Ah)	Bitiş kapasiteleri (Ah)
B0005	1.5	4.2	20	2	2.7	24	1.86	1.32
B0006	1.5	4.2	20	2	2.5	24	2.04	1.18
B0007	1.5	4.2	20	2	2.2	24	1.89	1.43
B0018	1.5	4.2	20	2	2.5	24	1.86	1.34

Şekil 4.1 NASA veri setinden B0005 bataryasının 15. şarj vedeşarj döngüsünü göstermektedir. Veri seti elde edilirken kullanılan şarj prosedürü, bataryanın tamamen şarj olana kadar lityum-iyon bataryanın şarj cihazı aracılığıyla şarj edilmesi sürecini ifade eder. Bu süreç esas olarak sabit akım (CC) ve sabit gerilim (CV) aşamalarından oluşur. Şarjın ilk aşamasında, sabit bir elektrik akımı kullanılarak batarya şarj edilir (sabit akım, CC). İkinci aşamada ise, sabit bir gerilim uygulanarak bataryanın şarjı tamamlanır (sabit gerilim, CV). Batarya doluluğu, aşamalı şarj ile elde edilir. Yukarıdaki şarj yöntemlerindeki gerilim ve elektrik ile çalışma ortamı sıcaklığı, lityum bataryanın ömrünü etkileyecektir.



Şekil 4.1. Şarj-deşarj döngüsü

Şekil 4.2 şarj vedeşarj döngüsü ile dört bataryanın kapasitesinin azaldığını göstermektedir. Lityum bataryanın kapasitesi %70'e düştüğünde batarya arızası olarak kabul edilmiştir (Chen vd., 2021). Dolayısıyla 2 Ah'lık bir bataryanın ölü batarya olarak kabul edilme kapasitesi 1.4 Ah olacaktır. Grafikte B0007 bataryasının verileri, bu bataryanın kullanım ömrünün tamamlanmadığını göstermektedir. B0005, B0006 ve B0018'in kullanım ömrü sırasıyla 124, 108 ve 96'dır. Her batarya veri seti, şarj,deşarj ve empedans olmak üzere üç bilgi alanı içerir.





Şekil 4.2. Dört batarya için kapasite-döngü grafiği

4.2. NASA Veri Seti Özellik Çıkarma

Bataryanın kapasitesini tahmininde NASA tarafından bataryaların şarj ve deşarjı sırasında elde edilen gerilim ve akım ölçümleri kullanılmıştır.


Şarj Esnasında: Batarya şarj edilirken sabit akım ve sabit şarj prensibine göre şarj edilir. Şarjın ilk aşaması, sabit elektrik olan sabit akımdır (CC). Ardından, sabit gerilim (CV) ikinci aşamadır. Bataryanın kapasitesine ve döngü sayısına bağlı olarak CC ve CV süreleri değişiklik göstermektedir. Bu nedenle, şarj esnasında ölçülen akımdan, akımın sabit olduğu süre birinci özellik olarak belirlenmiştir. B0005 bataryası için verilen şarj esnasındaki akım-zaman grafiğinde, Şekil 4.3.a'da görüldüğü gibi sabit akım süresinin sıralaması küçükten büyüğe 75., 50. ve 25. döngülerdeki süreler olmuştur. Döngü sayısı arttıkça bu sabit akım süresinin azalacağı öngörülmektedir. Gerilimin sabit olduğu süre de ikinci özellik olarak belirlenmiştir. B0005 bataryası için verilen şarj esnasındaki gerilim-zaman grafiğinde Şekil 4.3.b'de görüldüğü gibi sabit gerilim süresi sıralaması küçükten büyüğe 25., 50. ve 75. döngü olmuştur. Döngü sayısı arttıkça sabit gerilim süresi artacaktır.



Şekil 4.3. B0005 için şarj esnasında a) akım-zaman grafiği b) gerilim-zaman grafiği

Deşarj Esnasında: Deşarj işlemi sırasında NASA tarafından gerçekleştirilen batarya deşarjı ölçümleri neticesinde, iki önemli özellik elde edilmiştir. Bir döngü boyunca ölçülen gerilimin ortalaması, döngü sayısına bağlı olarak değişim göstermektedir. Şekil 4.4'te görüldüğü gibi, döngü sayısı arttıkça ortalama gerilim azalmaktadır. Bu nedenle, ortalama gerilim, üçüncü belirleyici özellik olarak kabul edilmiştir. Ayrıca, ölçülen gerilimlerde en düşük seviyeye ulaşılan an, döngü sayısına ve dolayısıyla batarya kapasitesine bağlı olarak değişmektedir. Yapılan gözlemlere

göre, en düşük gerilim seviyesine ulaşılan anın, sırasıyla 75., 50. ve 25. döngülerde meydana geldiği görülmüştür. Döngü sayısı arttıkça, bu en düşük gerilim anının süresinin azalacağı öngörülmüştür. Bu durum, ölçülen gerilimin en düşük olduğu anın dördüncü belirleyici özellik olarak tanımlanmasını sağlamaktadır.



Şekil 4.4. B0005 için deşarj esnasında gerilim-zaman grafiği

Bu dört özellik, NASA veri setinde yer alan dört farklı batarya için çıkarılmıştır. İki bağımsız değişken arasındaki doğrusal ilişki, yön ve güç, korelasyon katsayısı kullanılarak belirlenmiştir. Çıkarılan özelliklerin, hedef değer olarak belirlenen batarya kapasiteleri ile olan korelasyon katsayıları, Tablo 4.2’de gösterilmiştir. Burada Sağlık Faktörü (SF) özellik numaralarını temsil eder. Şarj sırasındaki özellikler şunlardır: SF1, sabit akım süresini; SF2, sabit gerilim süresini ifade eder. Deşarj sırasındaki özellikler ise şunlardır: SF3, ortalama gerilimi; SF4 ise en düşük ölçülen gerilim anını temsil eder. B0005 ve B0006 bataryaları için çıkarılan dört özelliğin yüksek korelasyon katsayısına sahip olduğu gözlemlenmektedir. Bu nedenle, bu bataryalarda kapasite tahmininde bu dört özellik kullanılmıştır. Ancak, B0007’de SF2’nin, B0018’de ise SF1’in korelasyon katsayısı değerleri düşüktür. Bu sebeple, B0007 bataryası için kapasite tahmininde SF1, SF3 ve SF4 özellikleri kullanılırken; B0018 bataryası için SF2, SF3 ve SF4 özellikleri seçilmiştir.

Tablo 4.2. Kapasiteler ile çıkarılan özellikler arasındaki korelasyon katsayıları

	SF1	SF2	SF3	SF4
B0005	-0.9057	0.9962	0.9824	0.9999
B0006	-0.9242	0.9753	0.9379	0.9817
B0007	-0.8927	0.0289	0.9611	0.9997
B0018	-0.4831	0.7462	0.9856	0.9998


4.3. Oxford Veri Seti Bilgisi

Sekiz küçük lityum-iyon kese hücresinden (nominal kapasite 740 mAh) alınan batarya yaşlanma verilerinin ölçümleri, Oxford Batarya Bozulması Veri Seti 1'e dahil edilmiştir. Hücrelerin tümü, bir termal odada 40 santigrat derecede değerlendirilmiştir. Bataryalar, sabit gerilim ve akımdan oluşan bir şarj profiline ve ardından kentsel Artemis profilinden türetilen bir sürüş döngüsü deşarj profiline göre test edilmiştir. Akü gerilimi, akımı ve yüzey sıcaklığı, MPG-205 akü test cihazı kullanılarak her 100 eskime döngüsünde bir ölçülmüş ve kaydedilmiştir. Birincil şarj/deşarj işlemi, 2C dinamik deşarj ile 1C şarjdan oluşmaktadır (Birkel, 2017). Tablo 4.3 Oxford veri setine ait bataryaların deney sırasında yapılan işlem değerlerini içermektedir. Görüldüğü gibi her bataryanın fabrikasyon kapasitesi 740 mAh olsa da gerçek başlangıç değerleri bundan farklıdır.

Tablo 4.3. Oxford veri setinde kullanılan bataryalara ait özellikler

Batarya	Şarj İşlemi		Deşarj İşlemi		Ortam koşulları		
	Sabit akım (mA)	Üst gerilim limiti (V)	Sabit akım (A)	Deşarj kesme gerilimi	Ortam sıcaklığı (°C)	Başlangıç kapasiteleri (mAh)	Bitiş kapasiteleri (mAh)
Cell1	740	4.2	740	2.7	40	724	530
Cell2	740	4.2	740	2.7	40	718	505
Cell3	740	4.2	740	2.7	40	718	536
Cell4	740	4.2	740	2.7	40	721	555
Cell5	740	4.2	740	2.7	40	720	430
Cell6	740	4.2	740	2.7	40	716	561
Cell7	740	4.2	740	2.7	40	713	553
Cell8	740	4.2	740	2.7	40	712	528

Şekil 4.5'te sekiz farklı bataryanın kapasitesinin şarj ve deşarj döngüsü sırasında azaldığı görülmektedir. Döngü sayısı ile birlikte kapasitelerin azaldığı görülmektedir.




Şekil 4.5. OXFORD veri seti kapasite-döngü grafiği

4.4. Oxford Veri Seti Özellik Çıkarma


Akü kapasitesini tahmin etmek için akülerin şarj ve deşarj döngüleri sırasındaki gerilim ve akım ölçümleri kullanılmıştır.

Şarj Esnasında: Bataryaların gerilimi 4.2 V'a ulaşana kadar şarj edilmesi için 740mA (1-C) Sabit Akım (CC) kullanılmıştır. Şarj süresi bataryanın kapasitesine ve çevrim sayısına göre değişmektedir. Bu nedenle şarj sırasında ölçülen akımdan akımın sabit kaldığı süre ilk karakteristik olarak belirlenir. Şekil 4.6 Cell1 bataryası için gösterilen şarj sırasındaki gerilim-zaman grafiğini göstermektedir. Burada şarj süresi 60., 40. ve 20. döngüler için küçükten büyüğe doğru sıralanmıştır. Döngü sayısı arttıkça bu şarj süresinin azalacağı öngörülmüştür.



Şekil 4.6. Cell-1 için şarj esnasında gerilim-zaman grafiği

Deşarj Esnasında: Bataryalar, gerilimleri 2.7 V'a düşene kadar 740mA CC kullanılarak boşaltıldı. Deşarj işlemi sırasında Oxford tarafından yapılan batarya deşarj ölçümlerinden iki önemli özellik elde edildi. Batarya geriliminin 2,7 V'a kadar olan süresi, yani deşarj süresi, bataryanın kapasitesine ve döngü sayısına bağlıdır. Şekil 4.7 açıkça gösteriyor ki sırasıyla 60., 40. ve 20. döngülerde 2.7 V gerilime ulaşılmaktadır. Bu nedenle ikinci özellik olarak her döngünün deşarj süresi belirlenmiştir. Bir döngü sırasında ölçülen ortalama gerilim, döngü sayısına bağlı olarak değişir. Bataryanın kullanımı arttıkça ortalama gerilimin azaldığı görülmektedir. Sonuç olarak üçüncü özellik olarak ortalama gerilim belirlenmiştir.



Şekil 4.7. Cell-1 için deşarj esnasında gerilim zaman grafiği

Bu üç özellik, Oxford veri setinde bulunan sekiz farklı batarya için belirlenmiştir. İki bağımsız değişken arasındaki doğrusal ilişki, korelasyon katsayısı kullanılarak incelenmiştir. Çıkarılan özelliklerin batarya kapasiteleri ile olan ilişkisi Tablo 4.4'de gösterilmektedir; burada SF'ler özellik numaralarını temsil etmektedir. Şarj sırasındaki özellik; SF1 şarj süresi bulunmaktadır. Deşarj sırasındaki özellikler; SF2 deşarj süresi, SF3 ise ortalama gerilimdir. Tüm bataryalar için çıkarılan üç özelliğin yüksek korelasyon katsayılarına sahip olduğu görülmektedir. Bu nedenle çıkarılan tüm özelliklerden kapasite tahmini yapmak için yararlanılmıştır.

Tablo 4.4. Kapasiteler ile çıkarılan özellikler arasındaki korelasyon katsayıları

	SF1	SF2	SF3
Cell1	0.9999	0.9998	0.9999
Cell2	0.9999	0.9986	0.9948
Cell3	0.9999	0.9998	0.9999
Cell4	0.9999	0.9999	0.9885
Cell5	0.9999	0.9998	0.9670
Cell6	0.9999	0.9991	0.9393
Cell7	0.9999	0.9999	0.9823
Cell8	0.9999	0.9999	0.9832

4.5. Verilerin Eğitim ve Test Verisi Olarak Ayrılması

Normalizasyonu yapılan özellikler ve kapasite verileri bu adımda eğitim ve test veri seti olarak ayrılır. NASA veri seti için her bataryanın ilk 40, 70 ve 100 verisi eğitim verisi olarak seçilir. Oxford veri setinde ise bataryalardaki döngü sayılarındaki farklılıklardan dolayı bataryaların ilk %25, %50 ve %75 verisi eğitim verisi olarak seçilir. Her veri setinde eğitim verileri dışında kalan veriler test verileridir. Özellikler kullanılarak burada kapasite değerlerinin tahmini yapılmaya çalışılır. Tablo 4.5 bu çalışmada kullanılan bataryalara ait toplam döngü sayıları ile eğitim ve test verilerinin sayılarını göstermektedir. Üç farklı eğitim-test seti oluşturulmuştur.

Tablo 4.5. Eğitim ve test verilerinin sayıları

Veri seti	Batarya	Toplam döngü sayısı	Birinci set		İkinci set		Üçüncü set	
			Eğitim	Test	Eğitim	Test	Eğitim	Test
NASA	B0005	168	40	128	70	98	100	68
	B0006	168	40	128	70	98	100	68
	B0007	168	40	128	70	98	100	68
	B0008	132	40	92	70	62	100	32
Oxford	Cell1	83	20	63	40	43	60	23
	Cell2	78	20	58	40	38	60	18
	Cell3	81	20	61	40	41	60	21
	Cell4	52	13	39	25	27	37	15
	Cell5	51	13	38	25	26	37	14
	Cell6	51	13	38	25	26	37	14
	Cell7	82	20	62	40	42	60	22
	Cell8	82	20	62	40	42	60	22

5. BULGULAR VE TARTIŞMA

Bu bölümde NASA ve Oxford veri setlerinden elde edilen GA sonuçları ile iki veri seti için de CNN, BP ve RNN algoritmaları kullanılarak yapılan tahminlerin sonuçları anlatılacaktır. Yöntem bölümünde bahsedilen özellik çıkarma, veri işleme, optimizasyon, tahmin ve performans değerlendirme adımları MATLAB programlama diliyle yapılmıştır.

5.1. NASA Veri Seti için Sonuçlar

NASA veri seti kullanılarak yapılan tahminlerde öncelikle şarj ve deşarj ölçümlerinden dört batarya için dörder tane özellik çıkarılmıştır. Pearson korelasyon analiziyle özellik seçimi yapılmıştır. Normalizasyonu yapılan kapasite ile özellikler, daha sonra eğitim ve test verisi olarak ayrılmıştır. Burada özellikler ağırlık girişi, kapasite değerleri de ağırlık çıkışı olarak ayarlanmıştır. NASA veri seti için eğitim verileri tüm verilerin ilk 40'ı, 70'i ve 100'ü alınarak oluşturulmuştur. Algoritmaların en uygun parametre değerlerini belirlemek için GA ile optimizasyon yapılmıştır. Optimizasyon işlemi her batarya için tüm eğitim setine göre ayrı ayrı yapılmıştır. Buradan elde edilen değerlere CNN, BP ve RNN algoritmalarının parametreleri ayarlanarak eğitim verileri ile ağırlık eğitilmiştir. Dört farklı batarya üzer farklı test setleri için tahminler yapılarak algoritmaların performans metrikleri elde edilmiştir.

NASA veri setine ait dört farklı bataryanın GA ile elde edilen parametre değerlerine göre kapasite tahminleri yapılmıştır. Yapılan tahminlerin her eğitim verisinde en iyi sonucuna göre yüzde hata grafikleri çıkarılmıştır. Ayrıca beş farklı hata metriğine göre performanslar belirlenmiştir. Ayrı ayrı tüm yöntemlerdeki tahminler bu değerlere göre değerlendirilerek hangi yöntemin en uygun olduğu belirlenmiştir. Burada öncelikle GA ile elde edilen parametre değerleri, sonra sırasıyla B0005, B0006, B0007 ve B0018 bataryalarının tahmin sonuçlarına yer verilecektir. Elde edilen sonuçlar literatürle kıyaslanarak kullanılan yöntemlerin doğruluğu ve kullanılabilirliği gösterilecektir.

5.1.1. Genetik Algoritma Sonuçları


Çıkarılan özellikler ile kapasitelerin normalizasyonu ve eğitim-test olarak ayrıştırılmasından sonra ilk olarak uygun parametrelerin belirlenmesi gerekmektedir. Bu nedenle, RNN, CNN ve BP algoritmalarının ilgili parametreleri, en düşük RMSE değerini elde etmek amacıyla GA kullanılarak optimize edilmiştir. Optimizasyon

yapılırken kullanılan GA özellikleri, ilgili algoritmalara göre Tablo 5.1’de sunulmuştur. Aralık değerleri dışındaki diğer parametre değerleri, tüm algoritmalar için aynı tutulmuştur. Bu kararın temel nedeni, BP ve RNN için yüksek gizli katman boyutu (`hiddenlayersize`) değerleri için RMSE yükselişi ve programın çalışmasının kesilmesine sebep olmasıdır. BP ve RNN algoritmalarında gizli katman boyutunun büyük olması, modellerin aşırı uyumuna neden olabilir ve modelin genelleme yeteneğini azaltabilir. Aynı zamanda eğitim ve tahmin süreçlerini arttırır. Daha fazla hafıza gereksinimini ortaya çıkarır. Dolayısıyla, yüksek sayıda gizli katman kullanılması, daha fazla karmaşıklığa ve zaman içinde düşük performansa yol açar. Bu parametrenin 1-100 aralığında tutulması uygun görülmüştür. CNN için filtre numarası (`filternumber`) değerinde 2000’e kadar benzer sorunlar oluşmamış, ancak 2000’den yüksek değerlerde yine RMSE için olumlu değerler elde edilememektedir. Bu nedenle `filternumber` parametresi için 1-2000 aralığı seçilmiştir.

Tablo 5.1. Genetik Algoritma seçenekleri

Algoritma	CNN	BP	RNN
Parametre	(<code>filternumber</code>)	(<code>hiddenlayersize</code>)	(<code>hiddenlayersize</code>)
Nüfus (Population)	5	5	5
En fazla nesil (Max. generation)	20	20	20
Aralık (Range)	1-2000	1-100	1-100
Tolerans (Tolerance)	10^{-6}	10^{-6}	10^{-6}

Şekil 5.1 yapılan GA sonuçlarından bir çıktı örneğini göstermektedir. Bu çıktı ekranı B0005 bataryasıyla yapılan RNN algoritmasının 100 eğitim verisine göre sonuçlarını göstermektedir. Görüldüğü gibi en iyi birey 12, RMSE değeri de %2.9’dur.



Şekil 5.1. Genetik Algoritma Matlab çıktı örneği

Yukarıda belirtilen seçimlerin ardından yapılan GA optimizasyonu sonucunda elde edilen parametreler Tablo 5.2’de sunulmuştur. GA süreci sırasında, parametreler en iyi performansı gösteren bireyden elde edilir. Bu işlem daha önce belirtildiği gibi beş bireyin 20 iterasyonu sonrasında gerçekleşmiştir. Bu optimizasyon işlemi her bir batarya için ayrı eğitim veri setleri üzerinde tekrarlanmıştır. Kullanılan performans ölçütü literatürde sıkça karşılaşılan RMSE olarak belirlenmiştir. CNN algoritması çalıştırılırken genel olarak filtre boyutu (*filtersize*) değerinin 1 olduğu durumlar daha yüksek performans sergilerken, B0006 bataryasında 70 ve 100 eğitim verisi durumlarında *filtersize* değeri sırasıyla 10 ve 3 olduğunda en uygun sonuç elde edilmiştir.

Tablo 5.2. NASA veri seti Genetik Algoritma sonuçları parametre değerleri

	CNN			BP			RNN		
	40	70	100	40	70	100	40	70	100
B0005	1969	969	1344	43	86	3	18	12	12
B0006	1719	157(10)*	63(3)*	68	3	3	18	18	92
B0007	1844	1719	157	18	3	3	86	61	68
B0018	1844	1969	844	68	3	4	49	12	4

*CNN filtersize'ı B0006 bataryası 70 ve 100 eğitim verisi için yapılan optimizasyonda sırasıyla 10 ve 3 değerleri için 1 olarak belirlenmiştir.

Tablo 5.3, tüm eğitim/test veri setlerinde beş nüfuslu dizinin 20 nesil sonunda en iyi sonucu veren bireylerin yüzde RMSE değerlerini göstermektedir. Tabloda B0006 bataryasında 70 ve 100 eğitim verisi durumlarında filtersize değeri sırasıyla 10 ve 3 olduğundaki değerleri gösterilmektedir. Filtersize değeri 1 olduğunda GA sonucunda çıkan RMSE değeri 70 eğitim için %14.1968, 100 eğitim için %4.8467 olmuştur. Yine bu değerlere göre filternumbersize parametre değerleri de sırasıyla 95 ve 63 olmuştur. Dolayısıyla RMSE değerindeki iyileşmeye filternumber parametresindeki değişikliğinin etkisi gözlenmektedir.



Tablo 5.3. NASA veri seti Genetik Algoritma sonuçları en iyi RMSE (%) değerleri

	CNN			BP			RNN		
	40	70	100	40	70	100	40	70	100
B0005	4.57	0.2760	0.1191	24.222	8.886	0.434	27.1164	7.0804	2.938
B0006	3.9571	9.1404	4.4565	14.5536	6.6272	3.0466	14.3758	7.1505	7.7017
B0007	5.8917	0.4173	0.1899	16.6525	2.7011	0.2392	13.8475	5.2044	2.05234
B0018	0.5149	0.5957	0.3669	8.7155	6.656	0.343	6.9037	3.2038	0.59

GA ile parametrelerin belirlenmesinden sonra bu parametreler kullanılarak batarya kapasite tahmini yapılmıştır. NASA veri setine ait dört bataryanın ayrı ayrı tüm eğitim-test veri setlerindeki tahminlerine, tahminlerin algoritmalarla göre performans parametrelerine bu bölümün bundan sonraki kısmında yer verilmiştir. Elde edilen sonuçlar ve performans değerleri genel olarak değerlendirilip literatürde yapılan çalışmalarla kıyaslanmıştır.


5.1.2. B0005 Bataryası Kapasite Tahmin Sonuçları

B0005 bataryası için 40 eğitim verisinde tüm yöntemlerle yapılan kapasite tahminleri ve bu yöntemde en iyi sonucu veren GA-CNN yönteminin hata grafiği Şekil 5.2’de gösterilmiştir. Burada CAP ile belirtilen eğri gerçek kapasite eğrisidir. Ayrıca noktasal olarak RMSE hatası en fazla %8 civarlarındadır. RMSE açısından performans sıralaması 40 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.




Şekil 5.2. B0005 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği

B0005 bataryası için 70 eğitim verisinde tüm yöntemlerle yapılan kapasite tahminleri Şekil 5.3.a'da verilmiştir. Yöntemler arasında RMSE açısından en iyi sonucu veren GA-CNN yönteminin hata grafiği Şekil 5.3.b'de gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %0.45 civarlarındadır. RMSE açısından performans sıralaması 70 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.




(a)




(b)

Şekil 5.3. B0005 bataryası 70 eğitim verisi a) kapasite tahminleri b) hata grafiği

B0005 bataryası için 100 eğitim verisinde tüm yöntemlerle yapılan kapasite tahminleri Şekil 5.4.a'da verilmiştir. Yöntemler arasında RMSE açısından en iyi sonucu veren GA-CNN yönteminin hata grafiği Şekil 5.4'te gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %-0.5 civarlarındadır. RMSE açısından performans sıralaması 100 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.



(a)



(b)

Şekil 5.4. B0005 bataryası 100 eğitim verisi a) kapasite tahminleri b) hata grafiği

40, 70 ve 100 eğitim verisi için beşer kez yapılan iterasyonların ortalaması alınarak elde edilen tahmin sonuçları Tablo 5.4'te sunulmuştur. Bu sonuçlara göre, en yüksek performans bütün değerler için GA-CNN modelinde elde edilmiştir. RMSE açısından performans sıralaması 40, 70 ve 100 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur. Bu modelin tüm R2 değerlerinin 0.99 civarlarında olması tahmin değerleri ile gerçek değerlerin eğilimindeki yakınlığı göstermektedir. Dolayısıyla B0005 bataryasının kapasite tahmininde tüm eğitim verisi sayıları için GA-CNN yöntemi kullanılabilir.

RMSE açısından performans sıralaması 40 eğitim verisinde GA-CNN, GA-RNN ve GA-BP, 70 eğitim verisinde GA-CNN, GA-BP, GA-RNN, 100 eğitim verisinde GA-CNN, GA-BP, GA-RNN şeklinde olmuştur.

Grafiklerden ve tablodaki değerlerden de görüldüğü gibi bu bataryada eğitim sayısındaki verinin azlığı RMSE bakımından en çok GA-BP yöntemini olumsuz etkilemiştir. R2 bakımından en kötü sonuç 40 eğitim verisinde GA-RNN için olmuştur. Dolayısıyla düşük veri sayısında GA-BP ve GA-RNN yöntemlerinin kullanılması doğru tahmine ulaşmayı zorlaştıracaktır.


Noktasal hata değerlerinin bu batarya için eğitim veri sayısı arttıkça azaldığı görülmüştür. 40 eğitim verisinde döngü sayısı arttıkça %8'lere kadar artan noktasal hata, 70 eğitim verisinde %0.2 ile %0.4 arasında yoğunlaşırken, 100 eğitim verisinde yoğunlukla %-0.1 ile %0.1 aralığındadır. Bu gözlemler tablodaki hata metrikleriyle de paralellik göstermektedir.

Tablo 5.4. B0005 bataryasının performans parametreleri


Eğitim Sayısı	Yöntem	MSE (%)	RMSE (%)	NRMSE (%)	MAE (%)	R2
40	GA-CNN	0.2766	5.2588	10.3894	4.6970	0.9999
	GA-BP	8.0148	28.3105	55.9306	24.6709	0.6640
	GA-RNN	7.0370	26.5274	52.4080	22.6094	0.3318
70	GA-CNN	0.0008	0.2794	0.8348	0.2576	0.9999
	GA-BP	0.0234	1.5281	4.5659	1.0706	0.9885
	GA-RNN	1.2446	11.1560	34.4457	8.7653	0.6568
100	GA-CNN	0.0001	0.1176	0.5635	0.0951	0.9996
	GA-BP	0.0027	0.5212	2.4981	0.4355	0.9997
	GA-RNN	0.1750	4.1839	20.0532	3.3743	0.8629

5.1.3. B0006 Bataryası Kapasite Tahmin Sonuçları

B0006 bataryası için 40 eğitim verisinde tüm yöntemlerle yapılan kapasite tahminleri ve bu yöntemde en iyi sonucu veren GA-CNN yönteminin hata grafiği Şekil 5.5 göstermiştir. Burada noktasal olarak RMSE hatası en fazla %10 civarlarındadır. RMSE açısından performans sıralaması 40 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklindedir.




(a)




(b)

Şekil 5.5. B0006 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği

Şekil 5.6.a, B0006 bataryasının 70 eğitim verisi için tüm yöntemlerle yapılan kapasite tahminlerini içermektedir. Şekil 5.6.b yöntemler arasında en iyi RMSE değerini veren GA-RNN yönteminin noktasal yüzde hata grafiğini göstermektedir. Burada noktasal olarak RMSE hatası en fazla %15 civarlarındadır. RMSE açısından performans sıralaması 70 eğitim verisinde GA-RNN, GA-BP, GA-CNN şeklinde olmuştur.




(a)




(b)

Şekil 5.6. B0006 bataryası 70 eğitim verisi a) kapasite tahminleri b) hata grafiği

Şekil 5.7.a, B0006 bataryasının 100 eğitim verisi için tüm yöntemlerle yapılan kapasite tahminlerini içermektedir. Şekil 5.7.b bu yöntemler arasında en iyi RMSE değeri veren GA-CNN yönteminin noktasal yüzde hata grafiğini göstermektedir. Burada noktasal olarak RMSE hatası en fazla %13 civarlarındadır. RMSE açısından performans sıralaması 100 eğitim verisinde GA-CNN, GA-BP, GA-RNN şeklinde olmuştur.



(a)



(b)

Şekil 5.7. B0006 bataryası 100 eğitim verisi a) kapasite tahminleri b) hata grafiği

40, 70 ve 100 eğitim verisi için beşer kez yapılan iterasyonların ortalaması alınarak elde edilen tahmin sonuçları Tablo 5.5'te sunulmuştur. 70 eğitim verisi hariç, en yüksek performans genellikle GA-CNN modelinde elde edilmiştir. 70 eğitim verisi durumunda, GA-RNN modeli MSE, RMSE ve NRMSE değerlerinde; GA-BP modeli MAE değerinde; GA-CNN modeli ise R2 değerinde en iyi performansı sergileyen modeller olarak belirlenmiştir.

RMSE açısından performans sıralaması 40 eğitim verisinde GA-CNN, GA-BP ve GA-RNN, 70 eğitim verisinde GA-RNN, GA-BP, GA-CNN, 100 eğitim verisinde GA-CNN, GA-BP, GA-RNN şeklinde olmuştur.

Bu bataryada en kötü ya da en iyi performansı veren yöntemi genellemek oldukça zordur. Çünkü en düşük R2 değeri 100 eğitim verisinde GA-RNN'de ve en kötü RMSE performansı 40 eğitim verisinde yine GA-RNN'de görülürken 70 eğitim verisinde en iyi RMSE performansını yine GA-RNN göstermektedir. Dolayısıyla kullanılan yöntemlerin bu bataryada mutlak başarı sayılabilecek bir sonucu bulunmamaktadır.


Eğitim veri sayısı arttıkça tahmin grafiklerinin gerçek değerlere yaklaştığı görülsede en iyi değeri veren algoritmanın noktasal hata değerlerinin bu batarya için eğitim veri sayısı arttıkça bariz azaldığı söylenemez. 40 eğitim verisinde %2 ile %10 arasında dağılan noktasal hatalar, 70 eğitim verisinde son döngülere doğru oransal bir artışla %15'lere çıkarken, 100 eğitim verisinde genellikle gerçek eğrinin altında kalarak %-5 civarlarında yoğunlaşmıştır. Bu gözlemler tablodaki hata metrikleriyle de paralellik göstermektedir.

Tablo 5.5. B0006 bataryasının performans parametreleri


Eğitim Sayısı	Yöntem	MSE (%)	RMSE (%)	NRMSE (%)	MAE (%)	R2
40	GA-CNN	0.1562	3.9527	5.9004	3.3071	0.9505
	GA-BP	3.5468	18.8328	28.1128	16.9141	0.8425
	GA-RNN	8.9822	29.9703	44.7385	26.9203	0.6633
70	GA-CNN	0.8756	9.3572	21.2776	8.5259	0.8548
	GA-BP	0.5710	7.5563	17.1824	5.3343	0.8038
	GA-RNN	0.4670	6.8336	15.5391	5.3855	0.7026
100	GA-CNN	0.2006	4.4784	15.0062	3.8496	0.7991
	GA-BP	1.7621	13.2744	44.4795	11.3466	0.4473
	GA-RNN	2.1116	14.5315	48.6919	13.3263	0.4031

5.1.4. B0007 Bataryası Kapasite Tahmin Sonuçları

B0007 bataryası için 40 eğitim verisinde tüm yöntemlerle yapılan kapasite tahminleri ve bu yöntemde en iyi sonucu veren GA-CNN yönteminin hata grafiği Şekil 5.8'de gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %9.5 civarlarındadır. RMSE açısından performans sıralaması 40 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.




(a)




(b)

Şekil 5.8. B0007 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği

B0007 bataryası için 70 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.9.a'da verilmiştir. Bu yöntemler arasından en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiği Şekil 5.9.b'de gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %0.6 civarlarındadır. Ayrıca RMSE açısından performans sıralaması 70 eğitim verisinde GA-CNN, GA-BP ve GA-RNN şeklinde olmuştur.




(a)




(b)

Şekil 5.9. B0007 bataryası 70 eğitim verisi a) kapasite tahminleri b) hata grafiği

B0007 bataryası için 100 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.10.a'da verilmiştir. Bu yöntemler arasından en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.10.b göstermektedir. Burada noktasal olarak RMSE hatası en fazla %-0.5 civarlarındadır. RMSE açısından performans sıralaması 100 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.



(a)



(b)

Şekil 5.10. B0007 bataryası 100 eğitim verisi a) kapasite tahminleri b) hata grafiği

40, 70 ve 100 eğitim verisi için beşer kez yapılan iterasyonların ortalaması alınarak elde edilen tahmin sonuçları Tablo 5.6’te sunulmuştur. Bu sonuçlara göre, tüm performans değerlendirme parametrelerinde en iyi değerler GA-CNN modelinde elde edilmiştir. Bu modelin tüm R2 değerlerinin 0.99 civarlarında olması tahmin değerleri ile gerçek değerlerin eğilimindeki yakınlığı göstermektedir. Dolayısıyla B0007 bataryasının kapasite tahmininde tüm eğitim verisi sayıları için GA-CNN yöntemi kullanılabilir.

RMSE açısından performans sıralaması 40 eğitim verisinde GA-CNN, GA-RNN ve GA-BP, 70 eğitim verisinde GA-CNN, GA-BP, GA-RNN, 100 eğitim verisinde GA-CNN, GA-BP, GA-RNN şeklinde olmuştur. Burada eğitim veri sayısındaki artış sıralama olarak GA-BP ye avantaj sağlamıştır.

Grafiklerden ve tablodaki değerlerden de görüldüğü gibi bu bataryada eğitim sayısındaki verinin azlığı en çok GA-BP yönteminin kullanılabilirliğini olumsuz etkilemiştir. Her ne kadar RMSE değeri 40 eğitim verisinde GA-RNN yöntemine yakın görünse de R2 değerinin düşük olması bu yöntemde öğrenmenin başarısızlığını ayrıca ortaya koymaktadır. Dolayısıyla düşük eğitim verisinde yanlış sonuçlardan kaçınmak için GA-BP kullanılması uygun değildir.


Noktasal hata değerlerinin bu batarya için eğitim veri sayısı arttıkça azaldığı görülmüştür. 40 eğitim verisinde döngü sayısı arttıkça artan noktasal tahmin hatası %9.5’lara ulaşırken, 70 eğitim sayısında %0.4 ile %0.6 arasında yoğunlaşır, 100 eğitim verisinde ise yoğunlukla %0.2 civarlarında olmasına rağmen %-0.5 ile %0.2 arasında dağılım bulunmaktadır. Bu gözlemler tablodaki hata metrikleriyle de paralellik göstermektedir.

Tablo 5.6. B0007 bataryasının performans parametreleri


Eğitim Sayısı	Yöntem	MSE (%)	RMSE (%)	NRMSE (%)	MAE (%)	R2
40	GA-CNN	0.3505	5.9205	14.2577	5.3443	0.9996
	GA-BP	4.3393	20.8311	50.1655	18.5313	0.5727
	GA-RNN	4.1778	20.4396	49.2228	18.1883	0.9102
70	GA-CNN	0.0019	0.4320	1.4982	0.3869	0.9993
	GA-BP	0.0195	1.3976	4.8468	0.9576	0.9892
	GA-RNN	0.4683	6.8432	23.7311	5.8259	0.8097
100	GA-CNN	0.0004	0.1895	1.0859	0.1553	0.9987
	GA-BP	0.0103	1.0156	5.8193	0.8077	0.9970
	GA-RNN	0.0370	1.9231	11.0191	0.9035	0.9025

5.1.5. B0018 Bataryası Kapasite Tahmin Sonuçları

Yapılan kapasite tahminlerinin grafikleri 40 eğitim verisi için Şekil 5.11'da gösterilmiştir. Ayrıca tüm tahminlerde en başarılı olan GA-CNN algoritmasının yüzde hata grafikleri de bu şekilde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %-1.7 civarlarındadır. RMSE açısından performans sıralaması 40 eğitim verisinde GA-CNN, GA-BP ve GA-RNN şeklinde olmuştur.





(a)



(b)



Şekil 5.11. B0018 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği

B0018 bataryası için 70 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.12.a’da verilmiştir. Bu yöntemler arasından en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiği Şekil 5.12’de gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %-1 civarlarındadır. RMSE açısından performans sıralaması 70 eğitim verisinde GA-CNN, GA-BP ve GA-RNN şeklinde olmuştur.



Şekil 5.12. B0018 bataryası 70 eğitim verisi a) kapasite tahminleri b) hata grafiği

B0018 bataryası için 100 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.13.a'da verilmiştir. Bu yöntemler arasından en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.13.b göstermektedir. Burada noktasal olarak RMSE hatası en fazla %-0.6 civarlarındadır. RMSE açısından performans sıralaması 100 eğitim verisinde GA-CNN, GA-BP ve GA-RNN şeklinde olmuştur.



Şekil 5.13. B0018 bataryası 100 eğitim verisi a) kapasite tahminleri b) hata grafiği

40, 70 ve 100 eğitim verisi için beşer kez yapılan iterasyonların ortalaması alınarak elde edilen tahmin sonuçları Tablo 5.7’de sunulmuştur. Bu sonuçlara göre, en iyi performanslar GA-CNN modelinde elde edilmiştir. Bu modelin tüm R2 değerlerinin 0.99 civarlarında olması tahmin değerleri ile gerçek değerlerin eğilimindeki yakınlığı göstermektedir. Dolayısıyla B0018 bataryasının kapasite tahmininde tüm eğitim verisi sayıları için GA-CNN yöntemi kullanılabilir.

RMSE açısından performans sıralaması tüm eğitim sayılarındaki tahminlerde GA-CNN, GA-BP ve GA-RNN şeklinde olmuştur.

Grafiklerden ve tablodaki değerlerden de görüldüğü gibi bu bataryada eğitim sayısındaki verinin azlığı en çok GA-RNN yönteminin kullanılabilirliğini olumsuz etkilemiştir. Her ne kadar RMSE değeri 40 eğitim verisinde GA-BP yöntemine yakın görünse de R2 değerinin düşük olması bu yöntemde öğrenmenin başarısızlığını ayrıca ortaya koymaktadır.

Noktasal hata değerlerinin bu batarya için eğitim veri sayısı arttıkça azaldığı görülmüştür. 40 eğitim verisinde %-2'lere ulaşan ve dağınık biçimde olan noktasal hata, 70 eğitim sayısında çoğunlukla gerçek eğrinin altında kalarak en fazla %-1'e ulaşmış, 100 eğitim verisinde ise yoğunlukla %-0.3 ile %-0.6 aralığındadır. Bu gözlemler tablodaki hata metrikleriyle de paralellik göstermektedir.

Tablo 5.7. B0018 bataryasının performans parametreleri

Eğitim Sayısı	Yöntem	MSE (%)	RMSE (%)	NRMSE (%)	MAE (%)	R2
40	GA-CNN	0.0031	0.5582	1.4475	0.4225	0.9983
	GA-BP	1.4980	12.2395	31.7368	10.5903	0.5905
	GA-RNN	2.3731	15.4049	39.9446	13.0404	0.1834
70	GA-CNN	0.0035	0.5958	3.0970	0.5074	0.9959
	GA-BP	0.1404	3.7469	19.4772	3.2231	0.9706
	GA-RNN	0.2685	5.1822	28.3498	4.5856	0.6247
100	GA-CNN	0.0013	0.3670	3.0739	0.3177	0.9909
	GA-BP	0.0016	0.3956	3.3136	0.3306	0.9835
	GA-RNN	0.0382	1.9547	16.3739	1.0115	0.7096

5.1.6. Genel Değerlendirme ve Literatür Kıyaslaması

NASA veri setindeki kullanılan B0005, B0006, B0007 ve B0018 bataryaları için yapılan tüm eğitim verilerindeki en iyi tahmin sonuçları Tablo 5.8’de verilmiştir.

Tabloda B0006 bataryasının 70 eğitim verisindeki tahmini hariç tüm tahminlerde GA-CNN diğerlerine üstün gelmiştir.

Tablo 5.8. En iyi performans gösteren algoritmalar

Batarya	Eğitim Sayısı	Algoritma	RMSE (%)	R2
B0005	40	GA-CNN	5.2588	0.9999
	70	GA-CNN	0.2794	0.9999
	100	GA-CNN	0.1176	0.9996
B0006	40	GA-CNN	3.9527	0.9505
	70	GA-RNN	6.8336	0.7026
	100	GA-CNN	4.4784	0.7991
B0007	40	GA-CNN	5.9205	0.9996
	70	GA-CNN	0.4320	0.9993
	100	GA-CNN	0.1895	0.9987
B0018	40	GA-CNN	0.5582	0.9983
	70	GA-CNN	0.5958	0.9959
	100	GA-CNN	0.3670	0.9909

Bataryanın kapasite, BSD ve Kalan Kullanılabilir Ömür (KKÖ) gibi ömrüne dair tahmin türlerinde gerçekleştirilen bazı çalışmaların RMSE ve R2 değerleri Tablo 5.9'de özetlenmiştir. Burada NASA verileri kullanılarak yapılan tahminlerin sonuçları yer almaktadır. Ayrıca tahmin doğruluğunu artırmak için kullanılan yöntemler de belirtilmiştir. Önerilen yöntemlerin performansının B0006 bataryası için 100 eğitim verisi kullanılarak yapılan tahmin dışında tüm sonuçlarda üstün olduğu görülmektedir. Özellikle, B0005 bataryası için 100 eğitim verisiyle yapılan tahmin, literatürdeki çalışmalara göre iki kat daha iyi bir RMSE performansı elde edilmiştir. Benzer şekilde, B0007 bataryası için 100 eğitim verisi kullanılarak elde edilen sonuçlar literatürdeki çalışmalardan yaklaşık üç kat daha iyi iken, B0018 bataryası için 70 ve 100 eğitim verisiyle yapılan tahminler literatürdeki çalışmalardan yaklaşık iki kat daha iyi sonuçlar vermiştir. Hatta, B0007 bataryası için 70 eğitim verisiyle yapılan tahmin, literatürdeki çalışmalardan daha iyi bir performans sergileyen önerilen modelle elde edilmiştir.

Tablo 5.9. NASA veri seti tahminlerini literatürdeki çalışmalar ile kıyaslama

Veri seti	İlgili çalışma	Eğitim sayısı	Tahmin	Yöntem	RMSE (%)	R2
NASA(B0005)	Önerilen	100	Kapasite	GA-CNN	0.1176	0.9996
	(Yao vd., 2023)	100	BSD	CL-GraphSAGE	0.5808	0.958309
	(Wei vd., 2022)	100	KKÖ	GPR-GMR	0.65	-
	(Zhang vd., 2021)	85	Kapasite	VMD-PF-GPR	1.28	-
	(Xie vd., 2023)	%60	Kalan ömür	CNN-LSTM	0.9883	-
	(Tian vd., 2022)	98	BSD	CNN-BiLSTM-AM	0.481	-
	(Lyu vd., 2022)	100	Kapasite	VMD-PF-ARIMA	0.2562	-
	(Ding ve Chen, 2023)	84	Kapasite	SVMD-AO-DELM	0.75	0.9968
NASA(B0006)	Önerilen	100	Kapasite	GA-CNN	4.4784	0.7991
	(Yao vd., 2023)	100	BSD	CL-GraphSAGE	1.0859	0.924613
	(Wei vd., 2022)	100	KKÖ	GPR-GMR	1.48	-
	(Xie vd., 2023)	%60	Kalan ömür	CNN-LSTM	0.42671	-
	(Tian vd., 2022)	86	BSD	CNN-BiLSTM-AM	1.05	-
	(Lyu vd., 2022)	100	Kapasite	VMD-PF-ARIMA	0.2367	-
	(Ding ve Chen, 2023)	84	Kapasite	SVMD-AO-DELM	1.33	0.9912

Tablo 5.9'un devamı

NASA(B0007)	Önerilen	100	Kapasite	GA-CNN	0.1895	0.9987
	(Yao vd., 2023)	100	BSD	CL-GraphSAGE	0.5314	0.950810
	(Wei vd., 2022)	100	KKÖ	GPR-GMR	0.90	-
	(Xie vd., 2023)	%60	Kalan ömür	CNN-LSTM	0.52221	-
	(Lyu vd., 2022)	100	Kapasite	VMD-PF-ARIMA	0.6267	-
	(Ding ve Chen, 2023)	84	Kapasite	SVMD-AO-DELM	0.79	0.9942
NASA(B0018)	Önerilen	70	Kapasite	GA-CNN	0.5958	0.9959
	(Tian vd., 2022)	76	BSD	CNN-BiLSTM-AM	1.09	-
	Önerilen	100	Kapasite	GA-CNN	0.3670	0.9909
	(Lyu vd., 2022)	100	Kapasite	VMD-PF-ARIMA	0.6575	-
	(Ding ve Chen, 2023)	84	Kapasite	SVMD-AO-DELM	1.64	0.9753

5.2. Oxford Veri Seti için Sonuçlar

Oxford veri seti kullanılarak yapılan tahminlerde öncelikle şarj ve deşarj ölçümlerinden sekiz batarya için üçer tane özellik çıkarılmıştır. Normalizasyonu yapılan kapasite ile özellikler, daha sonra eğitim ve test verisi olarak ayrılmıştır. Burada özellikler ağın girişi, kapasite değerleri de ağın çıkışı olarak ayarlanmıştır. Oxford veri seti için eğitim verileri tüm verilerin ilk %25'i, %50'si ve %75'i alınarak oluşturulmuştur. Dolayısıyla yaklaşık 80 döngü verisi bulunan Cell1, Cell2, Cell3, Cell7 ve Cell8 bataryalarında eğitim sayıları 20, 40 ve 60 olmuş, yaklaşık 50 döngü verisi bulunan Cell4, Cell5 ve Cell6 bataryalarında eğitim sayıları 13, 25 ve 37 olmuştur.

Algoritmaların en uygun parametre değerlerini belirlemek için GA ile optimizasyon yapılmıştır. Optimizasyon işlemi her batarya için tüm eğitim setine göre ayrı ayrı yapılmıştır. Buradan elde edilen değerlere CNN, BP ve RNN algoritmalarının parametreleri ayarlanarak eğitim verileri ile ağlar eğitilmiştir. Sekiz farklı batarya üçer farklı test setleri için tahminler yapılarak algoritmaların performans metrikleri elde edilmiştir.

Burada öncelikle genetik algortmada ile elde edilen parametre değerleri, sonra sırasıyla Cell1'den Cell8'e kadar tüm bataryaların tahmin sonuçlarına yer verilecektir. Elde edilen sonuçlar literatürle kıyaslanarak kullanılan yöntemlerin doğruluğu ve kullanılabilirliği gösterilecektir.

5.2.1. Genetik Algoritma Sonuçları

Oxford veri seti için GA seçenekleri Tablo 5.1'deki gibi ayarlanmıştır. Bu seçenekler NASA veri seti için de kullanılmıştır. Buna göre Oxford veri setindeki bataryaların algoritmalara göre her eğitim veri seti için GA sonuçları Tablo 5.10'daki gibi olmuştur. Rasgele oluşturulan ilk parametre değerleri, sırasıyla single crossover, uniform mutasyon ve roulette seçilim fonksiyonları adımlarından geçerek yeni değerler üretilmiştir. Her iterasyonda bu değerlere göre oluşan RMSE değerleri kıyaslanarak en düşük RMSE değerini veren parametre bir sonraki nesle taşınmıştır. Böylelikle 20 nesil sonunda en uygun parametre değerine ulaşılmaya çalışılmıştır.

Tablo 5.10. Oxford veri seti Genetik Algoritma sonuçları parametre değerleri

Eğitim Oranı (%)	CNN			BP			RNN		
	25	50	75	25	50	75	25	50	75
Cell1	1344	844	1844	92	12	4	92	3	18
Cell2	1969	1344	1344	49	12	4	68	43	3
Cell3	1844	345	220	98	37	43	92	12	3
Cell4	220	844	1844	92	3	3	92	9	9
Cell5	1969	1344	1906	92	3	18	61	12	12
Cell6	1344	1844	220	24	37	12	92	18	12
Cell7	345	844	844	43	12	12	49	3	9
Cell8	1844	719	345	68	18	3	37	18	18

Tablo 5.11, tüm eğitim/test veri setlerinde beş nüfuslu dizinin 20 nesil sonunda en iyi sonucu veren bireylerin yüzde RMSE değerlerini göstermektedir. GA sonucunda Tablo 5.10'daki parametre değerinde Tablo 5.11'deki RMSE değerleri oluşmuştur. Bu değerler her nesilde en iyi değer aktararak gelip son nesildeki en iyi sonuçlardan elde edilmiştir.



Tablo 5.11. Oxford veri seti Genetik Algoritma sonuçları RMSE (%) değerleri

Eğitim Oranı (%)	CNN			BP			RNN		
	25	50	75	25	50	75	25	50	75
Cell1	0.1039	0.1102	0.0799	2.6978	0.3448	0.0358	2.3523	0.6614	0.5468
Cell2	0.4123	0.3598	0.1188	4.9307	1.0973	0.0357	3.4277	1.5891	1.1128
Cell3	0.2660	0.1391	0.0765	4.1316	0.8630	0.0368	3.8259	1.2236	0.4854
Cell4	0.1822	0.2529	0.0437	3.7626	0.2344	0.0186	6.4524	1.1012	0.8937
Cell5	0.5522	0.4649	0.1491	4.2809	3.0569	1.5842	6.1755	4.3531	2.8956
Cell6	0.4038	0.4891	0.1022	2.6648	1.0728	0.5135	4.4293	1.1259	0.5506
Cell7	0.2519	0.0598	0.0603	4.8115	1.3984	0.0800	4.5708	0.5687	0.8808
Cell8	0.4008	0.0681	0.0628	4.1572	1.4000	0.0025	3.0310	0.7518	0.4059

Belirlenen parametrelere ve ayarlanan eğitim-test veri setlerine göre bu işlem adımlarından sonra batarya kapasitesi tahmini yapılmıştır. Oxford veri setindeki sekiz farklı batarya için yapılan tahmin sonuçlarına, genel değerlendirme ve literatür kıyaslamasına bölümün bundan sonraki kısmında yer verilmiştir.



5.2.2. Cell1 Bataryası Kapasite Tahmin Sonuçları

20 eğitim verisi kullanılarak yapılan tahminlerin üç farklı algoritma için grafikleri Şekil 5.14'te verilmiştir. Ayrıca en iyi performansı gösteren GA-CNN algoritmanın noktasal yüzde hata grafiği de gösterilmiştir. Sıfır hata serisinden sonra test verilerindeki hatalar bu grafiklerde gösterilmiştir. Burada noktasal hata en fazla %0.3 seviyesindedir. RMSE açısından performans sıralaması 20 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.





Şekil 5.14. Cell1 bataryası 20 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell1 bataryası için 40 eğitim verisinde tüm yöntemlerle yapılan kapasite tahminlerini Şekil 5.15.a ve bu yöntemde en iyi sonucu veren GA-CNN yönteminin hata grafiğini Şekil 5.15.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 40. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %0.25 civarlarındadır. RMSE açısından performans sıralaması 40 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.



Şekil 5.15. Cell1 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell1 bataryası için 60 eğitim verisinde tüm yöntemlerle yapılan kapasite tahminlerini Şekil 5.16.a ve bu yöntemde en iyi sonucu veren GA-BP yönteminin hata grafiğini Şekil 5.16.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 60. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %0.015 civarlarındadır. RMSE açısından performans sıralaması 60 eğitim verisinde GA-BP, GA-CNN ve GA-RNN şeklinde olmuştur.



Şekil 5.16. Cell1 bataryası 60 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell1 bataryasının 20, 40 ve 60 eğitim verisi için beşer kez yapılan iterasyonların ortalaması alınarak elde edilen tahmin sonuçları Tablo 5.12’de sunulmuştur. Bu sonuçlara göre, en yüksek performans 20 ve 40 eğitim verisi için GA-CNN modelinde, 60 eğitim verisi için GA-BP modelinde elde edilmiştir. Ayrıca yüksek performans veren GA-CNN ve GA-BP modellerinin R2 değerlerinin 0.99 civarlarında olması tahmin değerleri ile gerçek değerlerin eğilimindeki yakınlığı göstermektedir. Dolayısıyla Cell1 bataryasının kapasite tahmininde düşük eğitim verisi sayıları için GA-CNN yöntemi, 60 ve yukarıdaki eğitim veri sayısında GA-BP yöntemi kullanılabilir.

RMSE açısından performans sıralaması 20 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde, 40 eğitim verisinde GA-CNN, GA-RNN, GA-BP, 60 eğitim verisinde GA-BP, GA-CNN, GA-RNN şeklinde olmuştur.

Grafiklerden ve tablodaki değerlerden de görüldüğü gibi bu bataryada eğitim sayısındaki verinin azlığı (20 eğitim verisi) RMSE performansı bakımından en çok GA-BP yöntemini olumsuz etkilemiştir. Bu yöntemin R2 bakımından en kötü sonuç vermesi düşük eğitim sayılarında bu yöntemden kaçınılması gerektiğini göstermektedir.



Noktasal hata değerlerinin bu batarya için eğitim veri sayısı arttıkça azaldığı görülmüştür. 20 eğitim verisinde döngü sayısı arttıkça %0.3'lere kadar artan noktasal hata, 40 eğitim sayısında yine döngü sayısı arttıkça %0.25 seviyesine çıkmış, 60 eğitim verisinde ise çok düşük seviyelerde olmakla birlikte yoğunlukla %-0.01 ile %0.15 değerleri arasında dağılım göstermektedir. Bu gözlemler Tablo 5.12’deki hata metrikleriyle de paralellik göstermektedir.

Tablo 5.12. Cell1 bataryasının performans parametreleri

Batarya	Eğitim veri sayısı	Yöntem	MSE (%)	RMSE (%)	NRMSE (%)	MAE (%)	R2
Cell1	20	GA-CNN	0.0002	0.1293	1.0718	0.1038	0.9998
		GA-BP	0.5149	7.1760	59.4735	6.3658	0.1007
		GA-RNN	0.0464	2.1530	18.2994	2.0841	0.9299
	40	GA-CNN	0.0001	0.1101	1.5406	0.0946	0.9998
		GA-BP	0.0319	1.7868	25.0069	1.3927	0.9332
		GA-RNN	0.0027	0.5160	7.4972	0.3453	0.9655
	60	GA-CNN	0.0001	0.0959	2.9890	0.0870	0.9991
		GA-BP	4.57E-07	0.0068	0.2109	0.0055	0.9999
		GA-RNN	0.0621	2.4915	84.2670	2.1426	0.6774



5.2.3. Cell2 Bataryası Kapasite Tahmin Sonuçları

Cell2 bataryası için 20 eğitim verisinde tüm yöntemlerle yapılan kapasite tahminlerini Şekil 5.17.a ve bu yöntemde en iyi sonucu veren GA-CNN yönteminin hata grafiğini Şekil 5.17.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 20. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %1.5 civarlarındadır. RMSE açısından performans sıralaması 20 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.





Şekil 5.17. Cell2 bataryası 20 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell2 bataryası için 40 eğitim verisinde tüm yöntemlerle yapılan kapasite tahminlerini Şekil 5.18.a ve bu yöntemde en iyi sonucu veren GA-CNN yönteminin hata grafiğini Şekil 5.18.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 40. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %0.6 civarlarındadır. RMSE açısından performans sıralaması 40 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.



Şekil 5.18. Cell2 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell2 bataryası için 60 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafiklerini Şekil 5.19.a ve bu yöntemler arasından en iyi RMSE sonucunu veren GA-BP yönteminin hata grafiğini Şekil 5.19.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 60. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %-0.37 civarlarındadır. RMSE açısından performans sıralaması 60 eğitim verisinde GA-BP, GA-CNN ve GA-RNN şeklinde olmuştur.



Şekil 5.19. Cell2 bataryası 60 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell2 bataryasının 20, 40 ve 60 eğitim verisi için beş iterasyonun ortalaması alınarak elde edilen tahminlerin performans sonuçları Tablo 5.13'te sunulmaktadır. Bu sonuçlara göre, en yüksek performans 20 ve 40 eğitim verisi için GA-CNN modelinde, 60 eğitim verisi için GA-BP modelinde elde edilmiştir. Ayrıca yüksek performans veren GA-CNN ve GA-BP modellerinin R2 değerlerinin 0.99 civarlarında olması tahmin değerleri ile gerçek değerlerin eğilimindeki yakınlığı göstermektedir. Dolayısıyla Cell2 bataryasının kapasite tahmininde düşük eğitim verisi sayıları için GA-CNN yöntemi, 60 ve yukarıdaki eğitim veri sayısında GA-BP yöntemi kullanılabilir.

RMSE açısından performans sıralaması 20 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde, 40 eğitim verisinde GA-CNN, GA-RNN, GA-BP, 60 eğitim verisinde GA-BP, GA-CNN, GA-RNN şeklinde olmuştur.

Grafiklerden ve tablodaki değerlerden de görüldüğü gibi bu bataryada eğitim sayısındaki verinin azlığı (20 eğitim verisi) RMSE bakımından en çok GA-BP yöntemini olumsuz etkilemiştir. Bu yöntemin R2 bakımından en kötü sonuç veriyor olması bu bataryanın düşük eğitim sayılarında kapasite tahmininde kaçınılması gerektiğini göstermektedir.


Noktasal hata değerlerinin bu batarya için eğitim veri sayısı arttıkça azaldığı görülmüştür. 20 eğitim verisinde en yüksek noktasal hata %1.4 görünse de yoğunlukla %0.6'larda, 40 eğitim verisinde yoğunlukla %0.4 ile %0.6 arasında, 60 eğitim verisinde ise en yüksek noktasal hata %-0.35 olmakla birlikte hata değerleri yoğunlukla %0 değerine yakındır. Bu gözlemler Tablo 5.13'teki hata metrikleriyle de paralellik göstermektedir.

Tablo 5.13. Cell2 bataryasının performans parametreleri


Batarya	Eğitim veri sayısı	Yöntem	MSE (%)	RMSE (%)	NRMSE (%)	MAE (%)	R2
Cell2	20	GA-CNN	0.0020	0.4485	2.5983	0.3295	0.9961
		GA-BP	0.9725	9.8617	57.1358	8.7790	0.0003
		GA-RNN	0.0446	2.1107	12.4479	1.6967	0.8530
	40	GA-CNN	0.0015	0.3905	3.2178	0.3405	0.9953
		GA-BP	0.0683	2.6136	21.5361	2.1861	0.9307
		GA-RNN	0.0257	1.6018	13.6151	1.2699	0.7017
	60	GA-CNN	0.0002	0.1412	2.2574	0.1241	0.9976
		GA-BP	0.0001	0.0865	1.3831	0.0237	0.9991
		GA-RNN	0.0003	0.1814	3.0307	0.0874	0.9871

5.2.4. Cell3 Bataryası Kapasite Tahmin Sonuçları

Cell3 bataryası için 20 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.20.a'da verilmiştir. Bu yöntemler arasından en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.20.b göstermektedir. Burada noktasal olarak RMSE hatası en fazla %0.55 civarlarındadır. RMSE açısından performans sıralaması 20 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.





(a)



(b)


Şekil 5.20. Cell3 bataryası 20 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell3 bataryası için 40 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.21.a’da verilmiştir. Bu yöntemler arasından en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.21.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 40. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %0.3 seviyelerindedir. RMSE açısından performans sıralaması 40 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.




Şekil 5.21. Cell3 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell3 bataryası için 60 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.22.a’da verilmiştir. Bu yöntemler arasından en iyi RMSE sonucunu veren GA-BP yönteminin hata grafiğini Şekil 5.22.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 60. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %0.04 civarlarındadır. RMSE açısından performans sıralaması 60 eğitim verisinde GA-BP, GA-CNN ve GA-RNN şeklinde olmuştur.



(a)



(b)

Şekil 5.22. Cell3 bataryası 60 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell3 bataryasının 20, 40 ve 60 eğitim verisi için beş iterasyonun ortalaması alınarak elde edilen tahminlerin performans sonuçları Tablo 5.14’te sunulmaktadır. Bu sonuçlara göre, en yüksek performans 20 ve 40 eğitim verisi için GA-CNN modelinde, 60 eğitim verisi için GA-BP modelinde elde edilmiştir. Ayrıca yüksek performans veren GA-CNN, GA-BP modellerinin R2 değerlerinin 0.99 civarlarında olması tahmin değerleri ile gerçek değerlerin eğilimindeki yakınlığı göstermektedir. Dolayısıyla Cell3 bataryasının kapasite tahmininde düşük eğitim verisi sayıları için GA-CNN yöntemi, 60 ve yukarıdaki eğitim veri sayısında GA-BP yöntemi kullanılabilir.

RMSE açısından performans sıralaması 20 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde, 40 eğitim verisinde GA-CNN, GA-RNN, GA-BP, 60 eğitim verisinde GA-BP, GA-CNN, GA-RNN şeklinde olmuştur.

Grafiklerden ve tablodaki değerlerden de görüldüğü gibi bu bataryada eğitim sayısındaki verinin azlığı (20 eğitim verisi) RMSE bakımından en çok GA-BP yöntemini olumsuz etkilemiştir. Cell 3 bataryasında bu yöntemin R2 bakımından en kötü sonuç vermesi düşük eğitim sayılarında bu yöntemden kaçınılması gerektiğini göstermektedir.



Noktasal hata değerlerinin bu batarya için eğitim veri sayısı arttıkça azaldığı görülmüştür. 20 eğitim verisinde en yüksek noktasal hata döngü sayısı arttıkça %0.55 değerine kadar yükselmiş, 40 eğitim verisinde yine döngü sayısı ile birlikte %0.3’e kadar yükselen bir grafik oluşmuş, 60 eğitim verisinde ise noktasal hata %-0.03 ile %0.04 arasında dağılmıştır. Bu gözlemler Tablo 5.14’teki hata metrikleriyle de paralellik göstermektedir.

Tablo 5.14. Cell3 bataryasının performans parametreleri

Batarya	Eğitim veri sayısı	Yöntem	MSE (%)	RMSE (%)	NRMSE (%)	MAE (%)	R2
Cell3	20	GA-CNN	0.0009	0.2966	2.4691	0.2591	0.9999
		GA-BP	1.0968	10.4731	87.1761	9.1187	0.9056
		GA-RNN	0.3911	6.2540	53.3279	5.0405	0.1477
	40	GA-CNN	0.0002	0.1573	2.2936	0.1412	0.9998
		GA-BP	0.0984	3.1374	45.7417	2.5531	0.2894
		GA-RNN	0.0296	1.7211	25.6793	1.5672	0.8983
	60	GA-CNN	0.0001	0.0982	3.6546	0.0903	0.9991
		GA-BP	2.78E-06	0.0167	0.6211	0.0125	0.9996
		GA-RNN	0.0006	0.2413	9.2380	0.0730	0.9455



5.2.5. Cell4 Bataryası Kapasite Tahmin Sonuçları

Cell4 bataryası için 13 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.23.a'da verilmiştir. Bu yöntemler arasında en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.23.b göstermektedir. Burada noktasal olarak RMSE hatası en fazla %1.4 civarlarındadır. RMSE açısından performans sıralaması 13 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.





Şekil 5.23. Cell4 bataryası 13 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell4 bataryası için 25 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.24.a'da verilmiştir. Bu yöntemler arasında en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.24.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 25. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %1.5 seviyelerindedir. RMSE açısından performans sıralaması 25 eğitim verisinde GA-CNN, GA-BP ve GA-RNN şeklinde olmuştur.



Şekil 5.24. Cell4 bataryası 25 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell4 bataryası için 37 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafiklerini Şekil 5.25.a ve bu yöntemler arasında en iyi RMSE sonucunu veren GA-BP yönteminin hata grafiğini Şekil 5.25.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 37. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %-0.06 civarlarındadır. RMSE açısından performans sıralaması 37 eğitim verisinde GA-BP, GA-CNN ve GA-RNN şeklinde olmuştur.



Şekil 5.25. Cell4 bataryası 37 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell4 bataryasının 13, 25 ve 37 eğitim verisi için beş iterasyonun ortalaması alınarak elde edilen tahminlerin performans sonuçları Tablo 5.15'te sunulmaktadır. Bu sonuçlara göre, en yüksek performans 13 ve 25 eğitim verisi için GA-CNN modelinde, 37 eğitim verisi için GA-BP modelinde elde edilmiştir. Ayrıca yüksek performans veren GA-CNN, GA-BP modellerinin R2 değerlerinin 0.97'den yüksek olması tahmin değerleri ile gerçek değerlerin eğilimindeki yakınlığı göstermektedir. Dolayısıyla Cell4 bataryasının kapasite tahmininde düşük eğitim verisi sayıları için GA-CNN yöntemi, 60 ve yukarıdaki eğitim veri sayısında GA-BP yöntemi kullanılabilir.

RMSE açısından performans sıralaması 13 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde, 25 eğitim verisinde GA-CNN, GA-BP, GA-RNN, 37 eğitim verisinde GA-BP, GA-CNN, GA-RNN şeklinde olmuştur.

Grafiklerden ve tablodaki değerlerden de görüldüğü gibi bu bataryada eğitim sayısındaki verinin azlığı (13 eğitim verisi) RMSE bakımından en çok GA-BP yöntemini olumsuz etkilemiştir. Bu yöntemin R2 performansı bakımından en kötü sonuç vermesi düşük eğitim sayılarında bu yöntemden kaçınılması gerektiğini göstermektedir.


Noktasal hata değerlerinin bu batarya için eğitim veri sayısı arttıkça azaldığı görülmüştür. 13 eğitim verisinde en yüksek noktasal hata döngü sayısı arttıkça %0.55 değerine kadar yükselmiş, 25 eğitim verisinde yine döngü sayısı ile birlikte %0.3'e kadar yükselen bir grafik oluşmuş, 37 eğitim verisinde ise noktasal hata değeri %-0.03 ile %0.04 arasında dağılmıştır. Bu gözlemler Tablo 5.15'teki hata metrikleriyle de paralellik göstermektedir.

Tablo 5.15. Cell4 bataryasının performans parametreleri


Batarya	Eğitim veri sayısı	Yöntem	MSE (%)	RMSE (%)	NRMSE (%)	MAE (%)	R2
Cell4	13	GA-CNN	0.0006	0.2530	2.4058	0.1429	0.9956
		GA-BP	0.6288	7.9297	75.4100	6.8182	0.6347
		GA-RNN	0.0782	2.7968	27.7072	2.4512	0.8928
	25	GA-CNN	0.0009	0.3020	4.8968	0.1144	0.9752
		GA-BP	0.0050	0.7066	11.4583	0.3180	0.8576
		GA-RNN	0.0431	2.0750	36.1544	1.8458	0.9052
	37	GA-CNN	1.76E-05	0.0420	1.5719	0.0330	0.9982
		GA-BP	8.26E-06	0.0287	1.0748	0.0242	0.9999
		GA-RNN	0.0052	0.7238	28.5984	0.4094	0.8655

5.2.6. Cell5 Bataryası Kapasite Tahmin Sonuçları

Cell5 bataryası için 13 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.26.a'da verilmiştir. Bu yöntemler arasında en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.26.b göstermektedir. Burada noktasal olarak RMSE hatası en fazla %2.8 civarlarındadır. RMSE açısından performans sıralaması 13 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.





(a)



(b)



Şekil 5.26. Cell5 bataryası 13 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell5 bataryası için 25 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafiklerini Şekil 5.27.a ve bu yöntemler arasından en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.27.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 25. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %2.4 seviyelerindedir. RMSE açısından performans sıralaması 25 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.



Şekil 5.27. Cell5 bataryası 25 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell5 bataryası için 37 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafiklerini Şekil 5.28.a ve bu yöntemler arasında en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.28.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 37. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %-0.5 civarlarındadır. RMSE açısından performans sıralaması 37 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.



Şekil 5.28. Cell5 bataryası 37 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell5 bataryasının 13, 25 ve 37 eğitim verisi için beş iterasyonun ortalaması alınarak elde edilen tahminlerin performans sonuçları Tablo 5.16’da sunulmaktadır. Bu sonuçlara göre, en yüksek performans 13, 25 ve 37 eğitim verisi için GA-CNN modelinde elde edilmiştir. Ayrıca bu modelin tüm eğitim verilerindeki R2 değerlerinin 0.98’den yüksek olması tahmin değerleri ile gerçek değerlerin eğilimindeki yakınlığı göstermektedir. Dolayısıyla Cell5 bataryasının kapasite tahmininde tüm eğitim verisi sayıları için GA-CNN yöntemi kullanılabilir.

RMSE açısından performans sıralaması her üç eğitim verisinde de GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.

Grafiklerden ve tablodaki değerlerden de görüldüğü gibi bu bataryada eğitim sayısındaki verinin azlığı (13 eğitim verisi) RMSE bakımından en çok GA-BP yöntemini olumsuz etkilemiştir. Cell5 bataryasında bu yöntemin R2 performansı bakımından en kötü sonuç vermesi düşük eğitim sayılarındaki kapasite tahminlerinde bu yöntemden kaçınılması gerektiğini göstermektedir. Ayrıca tüm eğitim verisi sayılarındaki RMSE değerleri açısından en kötü performansı yine GA-BP yöntemi vermiştir.


Noktasal hata değerlerinin bu batarya için eğitim veri sayısı arttıkça azaldığı görülmüştür. 13 eğitim verisinde en yüksek noktasal hata değeri %2.8 olmasına rağmen diğer değerler %0.1 ile %0.5 arasına dağılmış, 25 eğitim verisinde en yüksek noktasal hata değeri %2.4 olmasına rağmen birkaç nokta dışında %0.1 değeri seviyelerinde, 37 eğitim verisinde ise 50. ve 51. noktalar haricinde %0.1 ile %0.1 değerleri arasında dağılmıştır. Bu gözlemler Tablo 5.16’daki hata metrikleriyle de paralellik göstermektedir.

Tablo 5.16. Cell5 bataryasının performans parametreleri


Batarya	Eğitim veri sayısı	Yöntem	MSE (%)	RMSE (%)	NRMSE (%)	MAE (%)	R2
Cell5	13	GA-CNN	0.0042	0.6488	2.7270	0.4371	0.9882
		GA-BP	0.5121	7.1563	30.0811	5.5965	0.0014
		GA-RNN	0.5097	7.1395	30.3574	5.6792	0.0101
	25	GA-CNN	0.0033	0.5739	2.8439	0.2266	0.9840
		GA-BP	0.1071	3.2721	16.2140	1.3576	0.7305
		GA-RNN	0.1067	3.2666	16.4122	1.3080	0.5706
	37	GA-CNN	0.0002	0.1491	0.8690	0.0843	0.9998
		GA-BP	0.1104	3.3222	19.3605	1.4479	0.8905
		GA-RNN	0.0895	2.9913	17.5419	1.5428	0.8769

5.2.7. Cell6 Bataryası Kapasite Tahmin Sonuçları

Cell6 bataryası için 13 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.29.a'da verilmiştir. Bu yöntemler arasından en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.29.b göstermektedir. Burada noktasal olarak RMSE hatası en fazla %2.5 civarlarındadır. RMSE açısından performans sıralaması 13 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.





(a)



(b)



Şekil 5.29. Cell6 bataryası 13 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell6 bataryası için 25 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafiklerini Şekil 5.30.a ve bu yöntemler arasında en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.30.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 25. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %2 seviyelerindedir. RMSE açısından performans sıralaması 25 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.



Şekil 5.30. Cell6 bataryası 25 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell6 bataryası için 37 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafiklerini Şekil 5.31.a ve bu yöntemler arasında en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.31.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 37. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %-0.37 civarlarındadır. RMSE açısından performans sıralaması 37 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.



Şekil 5.31. Cell6 bataryası 37 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell6 bataryasının 13, 25 ve 37 eğitim verisi için beş iterasyonun ortalaması alınarak elde edilen tahminlerin performans sonuçları Tablo 5.17’de sunulmaktadır.

Bu sonuçlara göre, en yüksek performans 13, 25 ve 37 eğitim verisi için GA-CNN modelinde elde edilmiştir. Ayrıca bu modelin tüm eğitim verilerindeki R2 değerlerinin 0.94’den yüksek olması tahmin değerleri ile gerçek değerlerin eğilimindeki yakınlığı göstermektedir. Dolayısıyla Cell6 bataryasının kapasite tahmininde tüm eğitim verisi sayıları için GA-CNN yöntemi kullanılabilir.

RMSE açısından performans sıralaması her üç eğitim verisinde de GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.

Grafiklerden ve tablodaki değerlerden de görüldüğü gibi bu bataryada eğitim sayısındaki verinin azlığı (13 eğitim verisi) RMSE bakımından en çok GA-BP yöntemini olumsuz etkilemiştir. Bu yöntemin R2 performansı bakımından en kötü sonuç vermesi düşük eğitim sayılarında bu yöntemden kaçınılması gerektiğini göstermektedir. Ayrıca tüm eğitim verilerinde RMSE açısından en kötü performansı yine GA-BP yöntemi vermiştir.


Noktasal hata değerlerinin bu batarya için eğitim veri sayısı arttıkça azaldığı görülmüştür. 13 eğitim verisinde en yüksek noktasal hata değeri %2.5 civarında olmasına rağmen yoğunluk %-0.5 ile %0.5 arasına dağılmış, 25 eğitim verisinde en yüksek noktasal hata değeri %2 seviyesinde olmasına rağmen bazı noktalar dışında %0.1 değeri seviyelerinde, 37 eğitim verisinde ise %-0.4 ile %0.1 değerleri arasında dağılmıştır. Eğitim sayısının artması tahmin gücünü artırmıştır. Bu gözlemler Tablo 5.17’deki hata metrikleriyle de paralellik göstermektedir.

Tablo 5.17. Cell6 bataryasının performans parametreleri


Batarya	Eğitim veri sayısı	Yöntem	MSE (%)	RMSE (%)	NRMSE (%)	MAE (%)	R2
Cell6	13	GA-CNN	0.0026	0.5092	4.8609	0.1838	0.9719
		GA-BP	0.2231	4.7237	45.0956	3.9341	0.5571
		GA-RNN	0.0316	1.7788	17.5102	1.3082	0.7577
	25	GA-CNN	0.0025	0.4965	7.4194	0.2074	0.9415
		GA-BP	0.0516	2.2723	33.9536	1.7542	0.5594
		GA-RNN	0.0242	1.5562	24.5091	1.3382	0.8968
	37	GA-CNN	0.0002	0.1471	4.2308	0.0913	0.9935
		GA-BP	0.0178	1.3349	38.3933	0.9501	0.5849
		GA-RNN	0.0073	0.8515	24.9269	0.6903	0.7864

5.2.8. Cell7 Bataryası Kapasite Tahmin Sonuçları

Cell7 bataryası için 20 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.32.a'da verilmiştir. Bu yöntemler arasında en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.32.b göstermektedir. Burada noktasal olarak tahmin hatası en fazla %2.25 civarlarındadır. RMSE açısından performans sıralaması 20 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.





(a)



(b)



Şekil 5.32. Cell7 bataryası 20 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell7 bataryası için 40 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.33.a'da verilmiştir. Bu yöntemler arasında en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.33.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 40. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak tahmin hatası en fazla %0.16 seviyelerindedir. RMSE değeri açısından performans sıralaması 40 eğitim verisinde GA-CNN, GA-BP ve GA-RNN şeklinde olmuştur.



Şekil 5.33. Cell7 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell7 bataryası için 60 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.34.a'da verilmiştir. Bu yöntemler arasından en iyi RMSE sonucunu veren GA-BP yönteminin hata grafiğini Şekil 5.34.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 60. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %0.04 civarlarındadır. RMSE değeri açısından performans sıralaması 60 eğitim verisinde GA-BP, GA-CNN ve GA-RNN şeklinde olmuştur.



Şekil 5.34. Cell7 bataryası 60 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell7 bataryasının 20, 40 ve 60 eğitim verisi için beş iterasyonun ortalaması alınarak elde edilen tahminlerin performans sonuçları Tablo 5.18’de sunulmaktadır. Bu sonuçlara göre, en yüksek performans 20 ve 40 eğitim verisi için GA-CNN modelinde, 60 eğitim verisi için GA-BP modelinde elde edilmiştir. Ayrıca yüksek performans veren GA-CNN, GA-BP modellerinin R2 değerlerinin 0.99 civarlarında olması tahmin değerleri ile gerçek değerlerin eğilimindeki yakınlığı göstermektedir. Dolayısıyla Cell7 bataryasının kapasite tahmininde düşük eğitim verisi sayıları için GA-CNN yöntemi, 60 ve yukarıdaki eğitim veri sayısında GA-BP yöntemi kullanılabilir.

RMSE açısından performans sıralaması 20 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde, 40 eğitim verisinde GA-CNN, GA-BP, GA-RNN, 60 eğitim verisinde GA-BP, GA-CNN, GA-RNN şeklinde olmuştur.

Grafiklerden ve tablodaki değerlerden de görüldüğü gibi bu bataryada eğitim sayısındaki verinin azlığı (20 eğitim verisi) RMSE bakımından en çok GA-BP yöntemini olumsuz etkilemiştir. GA-RNN ise R2 bakımından en kötü sonuç vermesi düşük eğitim sayılarında bu yöntemlerden kaçınılması gerektiğini göstermektedir.


Noktasal hata değerlerinin bu batarya için eğitim veri sayısı arttıkça azaldığı görülmüştür. 20 eğitim verisinde en yüksek noktasal hata %2.25 olmasına rağmen tahminin genelinde hata %-0.1 ile %0.1 aralığında, 40 eğitim verisinde hata değeri en yüksek %0.16 olmasına rağmen genel olarak döngü sayısı ile hata %0.1 civarlarına çıkmış, 60 eğitim verisinde ise noktasal hata %-0.03 ile %0.04 arasında dağılmıştır. Bu gözlemler Tablo 5.18’deki hata metrikleriyle de paralellik göstermektedir.

Tablo 5.18. Cell7 bataryasının performans parametreleri


Batarya	Eğitim veri sayısı	Yöntem	MSE (%)	RMSE (%)	NRMSE (%)	MAE (%)	R2
Cell7	20	GA-CNN	0.0012	0.3420	3.2354	0.1056	0.9883
		GA-BP	0.5364	7.3239	69.2877	6.4250	0.7599
		GA-RNN	0.3369	5.8041	56.0817	5.1071	0.3155
	40	GA-CNN	4.41E-05	0.0664	1.0224	0.0558	0.9997
		GA-BP	0.0018	0.4294	6.6118	0.3533	0.9582
		GA-RNN	0.0023	0.4835	7.7417	0.3896	0.9944
	60	GA-CNN	4.04E-05	0.0636	2.1888	0.0562	0.9985
		GA-BP	2.74E-06	0.0166	0.5704	0.0135	0.9998
		GA-RNN	0.0015	0.3823	14.2554	0.3351	0.9617

5.2.9. Cell8 Bataryası Kapasite Tahmin Sonuçları

Cell8 bataryası için 20 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.35.a'da verilmiştir. Bu yöntemler arasından en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.35.b göstermektedir. Burada noktasal olarak tahmin hatası en fazla %2.5 civarlarındadır. RMSE açısından performans sıralaması 20 eğitim verisinde GA-CNN, GA-BP ve GA-RNN şeklinde olmuştur.




(a)




(b)

Şekil 5.35. Cell8 bataryası 20 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell8 bataryası için 40 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.36.a'da verilmiştir. Bu yöntemler arasında en iyi RMSE sonucunu veren GA-CNN yönteminin hata grafiğini Şekil 5.36.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 40. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak tahmin hatası en fazla %0.17 seviyelerindedir. RMSE açısından performans sıralaması 40 eğitim verisinde GA-CNN, GA-RNN ve GA-BP şeklinde olmuştur.





(a)



(b)

Şekil 5.36. Cell8 bataryası 40 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell8 bataryası için 60 eğitim verisinde tüm yöntemlerle yapılan kapasite tahmin grafikleri Şekil 5.37.a'da verilmiştir. Bu yöntemler arasında en iyi RMSE sonucunu veren GA-BP yönteminin hata grafiğini Şekil 5.37.b göstermektedir. Sıfır hata serisinden sonra test verilerindeki hatalar 60. veriden sonra bu grafiklerde gösterilmiştir. Burada noktasal olarak RMSE hatası en fazla %0.14 civarlarındadır. RMSE açısından performans sıralaması 60 eğitim verisinde GA-BP, GA-CNN ve GA-RNN şeklinde olmuştur.



Şekil 5.37. Cell8 bataryası 60 eğitim verisi a) kapasite tahminleri b) hata grafiği

Cell8 bataryasının 20, 40 ve 60 eğitim verisi için beş iterasyonun ortalaması alınarak elde edilen tahminlerin performans sonuçları Tablo 5.19’da sunulmaktadır. Bu sonuçlara göre, en yüksek performans 20 ve 40 eğitim verisi için GA-CNN modelinde, 60 eğitim verisi için GA-BP modelinde elde edilmiştir. Ayrıca yüksek performans veren GA-CNN ve GA-BP modellerinin R2 değerlerinin 0.99 civarlarında olması tahmin değerleri ile gerçek değerlerin eğilimindeki yakınlığı göstermektedir. Dolayısıyla Cell8 bataryasının kapasite tahmininde düşük eğitim verisi sayıları için GA-CNN yöntemi, 60 ve yukarıdaki eğitim veri sayısında GA-BP yöntemi kullanılabilir.

RMSE açısından performans sıralaması 20 eğitim verisinde GA-CNN, GA-BP, GA-RNN şeklinde, 40 eğitim verisinde GA-CNN, GA-RNN, GA-BP, 60 eğitim verisinde GA-BP, GA-CNN, GA-RNN şeklinde olmuştur.

Grafiklerden ve tablodaki değerlerden de görüldüğü gibi bu bataryada eğitim sayısındaki verinin azlığı (20 eğitim verisi) RMSE bakımından en çok GA-RNN yöntemini olumsuz etkilemiştir. GA-BP ise R2 bakımından en kötü sonuç vermesi düşük eğitim sayılarında bu yöntemlerden kaçınılması gerektiğini göstermektedir.

Noktasal hata değerlerinin bu batarya için eğitim veri sayısı arttıkça azaldığı görülmüştür. 20 eğitim verisinde en yüksek noktasal hata %2.5 olmasına rağmen tahminin genelinde hata %-0.1 ile %0.3 aralığında, 40 eğitim verisinde hata değeri döngü sayısı arttıkça %0.17 değerine kadar çıkmış, 60 eğitim verisinde ise noktasal hata yine döngü sayısı arttıkça artarak %0.14 seviyelerine gelmiştir. Bu gözlemler Tablo 5.19’daki hata metrikleriyle de paralellik göstermektedir.

Tablo 5.19. Cell8 bataryasının performans parametreleri

Batarya	Eğitim veri sayısı	Yöntem	MSE (%)	RMSE (%)	NRMSE (%)	MAE (%)	R2
Cell8	20	GA-CNN	0.0015	0.3830	2.9502	0.1416	0.9911
		GA-BP	0.2535	5.0344	38.7767	3.9043	0.4036
		GA-RNN	0.2647	5.1447	40.3646	4.1576	0.4660
	40	GA-CNN	0.0001	0.0758	0.9462	0.0634	0.9999
		GA-BP	0.0412	2.0298	25.3325	1.6687	0.9087
		GA-RNN	0.0354	1.8803	24.4160	1.4647	0.7032
	60	GA-CNN	0.0001	0.0773	2.2163	0.0696	0.9995
		GA-BP	3.89E-05	0.0624	1.7896	0.0472	0.9999
		GA-RNN	0.0053	0.7303	23.2525	0.3929	0.7094

5.2.10. Genel Değerlendirme ve Literatür Kıyaslaması

Cell1, Cell2, Cell3, Cell7 ve Cell8'in sonuçlarına göre GA-CNN modeli 60 eğitim verisi dışındaki tüm değerlerde en yüksek performansı sergilemiştir. GA-BP, 60 eğitim verisini kullanarak yapılan tahminlerde en yüksek performansa sahiptir.

Cell4, Cell5 ve Cell6'ya ait 13, 25 ve 37 sayılı eğitim verileri için elde edilen tahminlerin performans değerlerine göre GA-CNN algoritması, Cell4 bataryasının 37 eğitim verisi dışındaki tahminlerde üstün çıkmıştır. GA-BP, 37 eğitim verisi ile Cell4 bataryasını tahmin etmede en üstün algoritma olmuştur.

Tüm bataryalar için tüm eğitim verilerinin en iyi tahmin sonuçları Tablo 5.20'de verilmiştir. Tüm tahminler, daha kesin sonuçlar görmek amacıyla batarya kapasitesini belirlemek üzere yapılmıştır. Ancak literatürdeki çalışmalar genel olarak Batarya Sağlık Durumu (BSD) tahmini üzerine yapıldığından, en iyi sonuçların gösterildiği Tablo 5.20'de BSD tahminlerinin RMSE ve R2 değerleri de yer almaktadır.

Tablo 5.20. Oxford veri seti en iyi tahmin performansları

Batarya	Eğitim veri sayısı	Yöntem	Kapasite Tahmini		BSD Tahmini	
			RMSE (%)	R2	RMSE (%)	R2
Cell1	20	GA-CNN	0.1293	0.9998	0.1786	0.9998
	40	GA-CNN	0.1101	0.9998	0.1520	0.9998
	60	GA-BP	0.0068	0.9999	0.0093	0.9999
Cell2	20	GA-CNN	0.4485	0.9961	0.6240	0.9961
	40	GA-CNN	0.3905	0.9953	0.5433	0.9953
	60	GA-BP	0.0865	0.9991	0.1204	0.9991
Cell3	20	GA-CNN	0.2966	0.9999	0.4127	0.9999
	40	GA-CNN	0.1573	0.9998	0.2189	0.9998
	60	GA-BP	0.0167	0.9996	0.0232	0.9996
Cell4	13	GA-CNN	0.2530	0.9956	0.3508	0.9956
	25	GA-CNN	0.3020	0.9752	0.4187	0.9752
	37	GA-BP	0.0287	0.9999	0.0399	0.9999
Cell5	13	GA-CNN	0.6488	0.9882	0.9005	0.9882
	25	GA-CNN	0.5739	0.9840	0.7967	0.9840
	37	GA-CNN	0.1491	0.9998	0.2070	0.9998
Cell6	13	GA-CNN	0.5092	0.9719	0.7105	0.9719
	25	GA-CNN	0.4965	0.9415	0.6929	0.9415
	37	GA-CNN	0.1471	0.9935	0.2053	0.9935
Cell7	20	GA-CNN	0.3420	0.9883	0.4794	0.9883
	40	GA-CNN	0.0664	0.9997	0.0931	0.9997
	60	GA-BP	0.0166	0.9998	0.0232	0.9998
Cell8	20	GA-CNN	0.3830	0.9911	0.5380	0.9911
	40	GA-CNN	0.0758	0.9999	0.1065	0.9999
	60	GA-BP	0.0624	0.9999	0.0877	0.9999

Tablo 5.21’de kapasite, BSD ve KKÖ gibi batarya ömrü tahmin türlerine ilişkin çeşitli çalışmalardan elde edilen RMSE, MAE ve R2 değerleri özetlenmektedir. Bu tablodaki veriler Oxford verileri üzerine yapılan çalışmalardan elde edilen sonuçları içermektedir. Tahmin doğruluğunu artırmak için kullanılan yöntemler de çalışmalarda belirtilmiştir. Tablo 5.21’den de görülebileceği gibi önerilen yöntemlerin performansı, (Bao vd., 2022) çalışmasındaki Cell8 batarya tahmini dışında tüm sonuçlarda üstündür.

Tablo 5.21. Oxford veri seti tahminlerini literatürdeki çalışmalar ile kıyaslama

Veri Seti	Referanslar	Eğitim Yüzdesi	Tahmin	Yöntem	RMSE (%)	MAE (%)	R2
Oxford (Cell1)	Önerilen	%50	Kapasite	GA-CNN	0.1101	0.0946	0.9998
	(Li vd., 2023)	%50	Kapasite	Bayesian	2.4142	2.0255	0.8965
	Önerilen	%50	BSD	GA-CNN	0.1520	0.1306	0.9998
	(Bamati ve Chaoui, 2021)	%50	BSD	NARXNN	0.46	0.38	-
	(J. Tian vd., 2020)	8 bataryanın 7'si(%87.5)	BSD	ICA	0.65	1.55	0.9927
Oxford (Cell2)	Önerilen	%50	Kapasite	GA-CNN	0.3905	0.3405	0.9953
	(Li vd., 2023)	%50	Kapasite	Bayesian	5.4347	4.7824	0.9424
	Önerilen	%75	BSD	GA-BP	0.1204	0.0330	0.9991
	(J. Tian vd., 2020)	8 bataryanın 7'si (%87.5)	BSD	ICA	0.97	2.49	0.9869
Oxford (Cell3)	Önerilen	%75	BSD	GA-BP	0.0232	0.0174	0.9996
	(J. Tian vd., 2020)	8 bataryanın 7'si (%87.5)	BSD	ICA	0.45	1.16	0.9963
Oxford (Cell4)	Önerilen	%75	BSD	GA-BP	0.0399	0.0335	0.9999
	(Fan vd., 2020)	8 bataryanın 6'sı (%75)	BSD	GRU-CNN	-	0.61	-
	(Bao vd., 2022)	8 bataryanın 6'sı (%75)	BSD	Dilated CNN-BiGRU	0.073	0.041	-
	(J. Tian vd., 2020)	8 bataryanın 7'si (%87.5)	BSD	ICA	0.41	1.01	0.9962
Oxford (Cell5)	Önerilen	%75	BSD	GA-BP	0.2070	0.1169	0.9998
	(J. Tian vd., 2020)	8 bataryanın 7'si (%87.5)	BSD	ICA	3.51	22.81	0.7407
Oxford (Cell6)	Önerilen	%50	BSD	GA-CNN	0.6929	0.2894	0.9415
	(Bamati ve Chaoui, 2021)	%50	BSD	NARXNN	1.83	1.60	-
	Önerilen	%75	BSD	GA-CNN	0.2053	0.1273	0.9935
	(J. Tian vd., 2020)	8 bataryanın 7'si (%87.5)	BSD	ICA	0.23	1.08	0.9984

Tablo 5.21'in devamı

Oxford (Cell7)	Önerilen	%50	Kapasite	GA-CNN	0.0664	0.0558	0.9997
	(Li vd., 2023)	%50	Kapasite	Bayesian	2.95	2.6299	0.9481
	Önerilen	%50	Kapasite	GA-CNN	0.0931	0.0782	0.9997
	(J. Tian vd., 2020)	8 bataryanın 7'si (%87.5)	BSD	ICA	0.40	0.9	0.9961
Oxford (Cell8)	Önerilen	%50	Kapasite	GA-CNN	0.0758	0.0634	0.9999
	(Li vd., 2023)	%50	Kapasite	Bayesian	3.284	2.9202	0.9719
	Önerilen	%50	BSD	GA-CNN	0.1065	0.0890	0.9999
	(Bamati ve Chaoui, 2021)	%50	BSD	NARXNN	0.74	0.58	-
	Önerilen	%75	BSD	GA-BP	0.0877	0.0663	0.9999
	(Fan vd., 2020)	8 bataryanın 6'sı (%75)	BSD	GRU-CNN	-	0.65	-
	(Bao vd., 2022)	8 bataryanın 6'sı (%75)	BSD	Dilated CNN-BiGRU	0.083	0.052	-
	(J. Tian vd., 2020)	8 bataryanın 7'si (%87.5)	BSD	ICA	0.49	1.01	0.9958
Oxford (Ortalama)	(Lim vd., 2022)	%70	Kapasite	LSTM	0.74		0.9943
		%15	Kapasite	GPR	5.98		0.9755
		%15	Kapasite	LSTM	6.25		0.9898
		%70	Kapasite	GPR	1.33		0.9948

6. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında NASA ve Oxford veri setlerinin şarj ve deşarj süresince elde edilen akım ve gerilim değerleri kullanılarak batarya kapasite tahmini yapılmıştır. NASA veri setinde üç batarya için 168 şarj-deşarj döngüsü bir bataryada 132 şarj deşarj döngüsü bulunmaktadır. Oxford veri setinde sekiz adet bataryanın üçünde yaklaşık 50, beşinde ise yaklaşık 80 döngülük veri bulunmaktadır.

NASA veri seti ile bir şarj döngüsü süresince kaydedilen akım ve gerilim değerlerinden akımın sabit olduğu süre ile gerilimin sabit olduğu süre olmak üzere iki özellik elde edilmiştir. Bir deşarj döngüsü süresince kaydedilen gerilim değerlerinden ortalama gerilim ve gerilimin en düşük olduğu değer olmak üzere iki özellik daha elde edilmiştir. Toplamda dört farklı özellik çıkarılmıştır. Daha sonra Pearson Korelasyon Analizi ile özellik seçimi yapılmıştır. Seçilen özellikler ve her bataryanın kapasiteleri normalize edilerek veri eğitim ve test verisi olarak ayrılmıştır.

40, 70 ve 100 eğitim verisi olmak üzere üç farklı eğitim verisi dört batarya için de ayrı ayrı belirlenmiştir. Her bataryanın her eğitim verisi için CNN, BP ve RNN algoritmalarının parametreleri GA uygulanarak belirlenmiştir. Burada CNN `filternumbersize`, BP ve RNN algoritmalarının `hiddenlayersize` parametrelerinin RMSE'yi en düşük yapan değerleri seçilmiştir. Tahmin grafiklerinde ve performans parametrelerinde görüldüğü gibi, CNN algoritması genel olarak tüm bataryalar ve eğitim veri kümelerinde diğer algoritmalarından daha iyi performans göstermektedir. RMSE değeri açısından en iyi performans B0005 bataryası için 100 eğitim verisiyle gerçekleşmiştir. Bu tahmin için RMSE değeri % 0.1176 olmuştur. Önerilen yöntem, dört bataryadan üçü için literatürdeki çalışmalara göre üstünlük göstererek çalışmanın doğruluğunu ve güvenilirliğini vurgulamaktadır. Ancak B0006 bataryasının tahmin performansının literatürdeki çalışmalara göre düşük olması, bu spesifik bataryanın ölçüm sonuçlarının veya elektrokimyasal yapılarının yapay sinir ağları ve derin öğrenme gibi yöntemler kullanılarak tahmin edilmesinin zorluğunu göstermektedir.

Oxford veri setinden özellik çıkarımı şu şekilde yapılmıştır. Bir şarj döngüsü süresi şarj süresi olarak ilk özellik belirlenmiştir. Bir deşarj döngüsünde süresince kaydedilen gerilim değerlerinden de ortalama gerilim ve deşarj süresi olmak üzere iki özellik daha elde edilmiştir. Toplamda üç farklı özellik çıkarılmıştır. Daha sonra Pearson Korelasyon Analizi tüm özelliklerin kapasiteler ile uyumlu olduğu

görüldüğünden herhangi bir seçim yapılmamış, çıkarılan tüm özellikler kullanılmıştır. Çıkarılan özellikler ve her bataryanın kapasiteleri normalize edilerek veri eğitim ve test verisi olarak ayrılmıştır.

Oxford veri seti için de parametreler GA uygulanarak belirlenmiştir. Tahmin grafikleri ve performans parametrelerinde görüldüğü gibi CNN algoritması genel olarak tüm bataryalarda ve eğitim veri setlerinde diğer algoritmalarından daha iyi performans göstermektedir. Ayrıca BP algoritması yüksek eğitim verilerinde genel olarak CNN'den daha iyi performans gösterdi. Dolayısıyla düşük eğitim verileri için CNN'nin, yüksek eğitim verileri için ise BP algoritmasının daha verimli olduğu söylenebilir.

Tüm tahminler arasında en yüksek doğruluk, Cell1 bataryası için 60 eğitim verisi ile GA-BP yöntemiyle elde edilmiştir. Burada RMSE değeri hem kapasite tahmini hem de SOH tahmini için %0.01'den bile küçüktür. Literatürdeki çalışmalara üstünlüğü gösterilerek önerilen yöntemin doğruluğu ve güvenilirliği vurgulanmıştır.

Her iki veri setinde kullanılan 12 farklı batarya ile parametre optimizasyonunun ilgili algoritmalarla birlikte kullanımı sayesinde en doğru sonuca güvenilir bir şekilde ulaşılmıştır. Her iki veri setindeki tahmin performansları kullanılan yöntemin batarya sağlık tahmininde oldukça güvenilir ve doğru sonuçlar verdiğini göstermektedir. Sonuçlar ayrıca düşük eğitim veri setleri ile bile yüksek doğrulukta tahmin sağlayabildiğini göstererek yöntemin batarya sağlığı ve kapasite tahmininde güvenilir bir şekilde kullanılabileceğini göstermiştir.

Yapılan çalışmalara ek olarak gelecekte PSO, Karınca Koloni Algoritması (ACO), Fil Sürü Optimizasyonu (EHO) gibi farklı optimizasyon yöntemleri kullanılarak algoritmaların parametre optimizasyonu da yapılabilir. Ayrıca GA ve optimizasyonun literatürde bulunan ARIMA, Bi-LSTM, SVR gibi algoritmaların birleştirilmesiyle tahmin doğruluğu daha da artırılabilir.

KAYNAKLAR

- Bamati, S., ve Chaoui, H. (2021). Lithium-ion batteries long horizon health prognostic using machine learning. *IEEE Transactions on Energy Conversion*, 37(2), 1176-1186.
- Bao, Z., Jiang, J., Zhu, C., ve Gao, M. (2022). A new hybrid neural network method for state-of-health estimation of lithium-ion battery. *Energies*, 15(12), 4399.
- Birkel, C. (2017). Oxford battery degradation dataset 1.
- Catelani, M., Ciani, L., Fantacci, R., Patrizi, G., ve Picano, B. (2021). Remaining useful life estimation for prognostics of lithium-ion batteries based on recurrent neural network. *IEEE Transactions on Instrumentation and Measurement*, 70, 1-11.
- Celeghin, A., Borriero, A., Orsenigo, D., Diano, M., Méndez Guerrero, C. A., Perotti, A., Petri, G., ve Tamietto, M. (2023). Convolutional neural networks for vision neuroscience: significance, developments, and outstanding issues. *Frontiers in Computational Neuroscience*, 17, 1153572.
- Chaoui, H., ve Ibe-Ekeocha, C. C. (2017). State of charge and state of health estimation for lithium batteries using recurrent neural networks. *IEEE Transactions on Vehicular Technology*, 66(10), 8773-8783.
- Choi, Y., Ryu, S., Park, K., ve Kim, H. (2019). Machine learning-based lithium-ion battery capacity estimation exploiting multi-channel charging profiles. *IEEE Access*, 7, 75143-75152.
- Dai, H., Jiang, B., Hu, X., Lin, X., Wei, X., ve Pecht, M. (2021). Advanced battery management strategies for a sustainable energy future: Multilayer design concepts and research trends. *Renewable and Sustainable Energy Reviews*, 138, 110480.
- Ding, G., ve Chen, H. (2023). A novel lithium-ion battery capacity prediction framework based on SVM-D-AO-DELM. *Signal, Image and Video Processing*, 1-9.
- Ding, G., Wang, W., ve Zhu, T. (2022). Remaining useful life prediction for lithium-ion batteries based on CS-VMD and GRU. *Ieee Access*, 10, 89402-89413.
- Fan, Y., Xiao, F., Li, C., Yang, G., ve Tang, X. (2020). A novel deep learning framework for state of health estimation of lithium-ion battery. *Journal of Energy Storage*, 32, 101741.
- Fang, J., Qiu, L., ve Li, X. (2017). Comparative study of Thevenin model and GNL simplified model based on kalman filter in SOC estimation. *Int J Adv Res Comput Eng Technol*, 6(2017), 1660-1663.
- Feng, J., He, H., ve Wang, G. (2013). Comparison study of equivalent circuit model of Li-Ion battery for electrical vehicles. *Research Journal of Applied Sciences*, 6(20), 3756-3759.
- Feng, J., Jia, X., Cai, H., Zhu, F., Li, X., ve Lee, J. (2020). Cross trajectory gaussian process regression model for battery health prediction. *Journal of modern power systems and clean energy*, 9(5), 1217-1226.

- Goodenough, J. B., ve Kim, Y. (2010). Challenges for rechargeable Li batteries. *Chemistry of materials*, 22(3), 587-603.
- Greenleaf, M., Li, H., ve Zheng, J. P. (2013). Modeling of $\text{Li}_{1-x}\text{FePO}_4$ cathode li-ion batteries using linear electrical circuit model. *IEEE Transactions on sustainable energy*, 4(4), 1065-1070.
- Hageman, S. C. (1993). Simple PSpice models let you simulate common battery types. *EDN*, 38(22), 117-ve.
- He, H., Xiong, R., ve 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.
- Horiba, T. (2014). Lithium-ion battery systems. *Proceedings of the IEEE*, 102(6), 939-950.
- Huang, S.-C., Tseng, K.-H., Liang, J.-W., Chang, C.-L., ve Pecht, M. G. (2017). An online SOC and SOH estimation model for lithium-ion batteries. *Energies*, 10(4), 512.
- Jia, J., Yuan, S., Shi, Y., Wen, J., Pang, X., ve Zeng, J. (2022). Improved sparrow search algorithm optimization deep extreme learning machine for lithium-ion battery state-of-health prediction. *Iscience*, 25(4).
- Jin, W., Li, Z. J., Wei, L. S., ve Zhen, H. (2000). The improvements of BP neural network learning algorithm. WCC 2000-ICSP 2000. 2000 5th international conference on signal processing proceedings. 16th world computer congress 2000,
- Khumprom, P., ve Yodo, N. (2019). A data-driven predictive prognostic model for lithium-ion batteries based on a deep learning algorithm. *Energies*, 12(4), 660.
- Li, J., Cheng, J.-h., Shi, J.-y., ve Huang, F. (2012). Brief introduction of back propagation (BP) neural network algorithm and its improvement. *Advances in Computer Science and Information Engineering: Volume 2*,
- Li, X., Lyu, M., Li, K., Gao, X., Liu, C., ve Zhang, Z. (2023). Lithium-ion battery state of health estimation based on multi-source health indicators extraction and sparse Bayesian learning. *Energy*, 282, 128445.
- Li, X., Zhang, L., Wang, Z., ve Dong, P. (2019). Remaining useful life prediction for lithium-ion batteries based on a hybrid model combining the long short-term memory and Elman neural networks. *Journal of Energy Storage*, 21, 510-518.
- Li, Y., Liu, K., Foley, A. M., Zülke, A., Bercebar, M., Nanini-Maury, E., Van Mierlo, J., ve Hoster, H. E. (2019). Data-driven health estimation and lifetime prediction of lithium-ion batteries: A review. *Renewable and Sustainable Energy Reviews*, 113, 109254.
- Lim, L. D., Tan, A. F. J., Tomacruz, J. G. T., Castro, M. T., Remolona, M. F. M., ve Ocon, J. D. (2022). Cyclic Degradation Prediction of Lithium-Ion Batteries using Data-Driven Machine Learning. *Chemical Engineering Transactions*, 94, 787-792.
- Liu, C., Liu, W., Wang, L., Hu, G., Ma, L., ve Ren, B. (2016). A new method of modeling and state of charge estimation of the battery. *Journal of Power Sources*, 320, 1-12.

- Lyu, G., Zhang, H., Zhang, Y., ve Miao, Q. (2022). An interpretable remaining useful life prediction scheme of lithium-ion battery considering capacity regeneration. *Microelectronics Reliability*, 138, 114625.
- MEB. (2024). *İndirgenme – Yükseltgenme Tepkimelerinde Elektrik Akımı*. EBA. Retrieved 8 Ağustos 2024 from <https://ogmmateryal.eba.gov.tr/panel/upload/files/d1qvb2urckb.pdfE>
- Milletari, F., Navab, N., ve Ahmadi, S.-A. (2016). V-net: Fully convolutional neural networks for volumetric medical image segmentation. 2016 Fourth International Conference on 3D Vision (3DV),
- Nagaura, T. (1990). Lithium ion rechargeable battery. *Progress in Batteries ve Solar Cells*, 9, 209.
- Raël, S., Urbain, M., ve Renaudineau, H. (2014). A mathematical lithium-ion battery model implemented in an electrical engineering simulation software. 2014 IEEE 23rd International Symposium on Industrial Electronics (ISIE),
- Ren, L., Zhao, L., Hong, S., Zhao, S., Wang, H., ve Zhang, L. (2018). Remaining useful life prediction for lithium-ion battery: A deep learning approach. *IEEE Access*, 6, 50587-50598.
- Saha, B., ve Goebel, K. (2007). NASA Ames prognostics data repository. *NASA Ames, Moffett Field, CA, USA*.
- Shen, M., ve Gao, Q. (2019). A review on battery management system from the modeling efforts to its multiapplication and integration. *International Journal of Energy Research*, 43(10), 5042-5075.
- Shen, P., Ouyang, M., Lu, L., Li, J., ve Feng, X. (2017). The co-estimation of state of charge, state of health, and state of function for lithium-ion batteries in electric vehicles. *IEEE Transactions on Vehicular Technology*, 67(1), 92-103.
- Shen, S., Sadoughi, M., Chen, X., Hong, M., ve Hu, C. (2019). A deep learning method for online capacity estimation of lithium-ion batteries. *Journal of Energy Storage*, 25, 100817.
- Stighezza, M., Bianchi, V., ve De Munari, I. (2021). FPGA implementation of an ant colony optimization based SVM algorithm for state of charge estimation in Li-ion batteries. *Energies*, 14(21), 7064.
- Tian, H., Qin, P., Li, K., ve Zhao, Z. (2020). A review of the state of health for lithium-ion batteries: Research status and suggestions. *Journal of Cleaner Production*, 261, 120813.
- Tian, J., Xiong, R., ve Shen, W. (2020). State-of-health estimation based on differential temperature for lithium ion batteries. *IEEE Transactions on Power Electronics*, 35(10), 10363-10373.
- Tian, Y., Wen, J., Yang, Y., Shi, Y., ve Zeng, J. (2022). State-of-Health Prediction of Lithium-Ion Batteries Based on CNN-BiLSTM-AM. *Batteries*, 8(10), 155.
- Wang, Y.-X., Chen, Z., ve Zhang, W. (2022). Lithium-ion battery state-of-charge estimation for small target sample sets using the improved GRU-based transfer learning. *Energy*, 244, 123178.

- Watrin, N., Roche, R., Ostermann, H., Blunier, B., ve Miraoui, A. (2012). Multiphysical lithium-based battery model for use in state-of-charge determination. *IEEE Transactions on Vehicular Technology*, 61(8), 3420-3429.
- Wei, M., Ye, M., Wang, Q., ve Twajamahoro, J. P. (2022). Remaining useful life prediction of lithium-ion batteries based on stacked autoencoder and gaussian mixture regression. *Journal of Energy Storage*, 47, 103558.
- Wu, B., ve Chen, B. (2014). Study the performance of battery models for hybrid electric vehicles. 2014 IEEE/ASME 10th International Conference on Mechatronic and Embedded Systems and Applications (MESA),
- Xia, Z., ve Qahouq, J. A. A. (2019). Adaptive and fast state of health estimation method for lithium-ion batteries using online complex impedance and artificial neural network. 2019 IEEE applied power electronics conference and exposition (APEC),
- Xie, Q., Liu, R., Huang, J., ve Su, J. (2023). Residual life prediction of lithium-ion batteries based on data preprocessing and a priori knowledge-assisted CNN-LSTM. *Energy*, 281, 128232.
- Xiong, R., Li, L., ve Tian, J. (2018). Towards a smarter battery management system: A critical review on battery state of health monitoring methods. *Journal of Power Sources*, 405, 18-29.
- Xiong, W., Mo, Y., ve Yan, C. (2020). Online state-of-health estimation for second-use lithium-ion batteries based on weighted least squares support vector machine. *Ieee Access*, 9, 1870-1881.
- Yang, J., Peng, Z., Pei, Z., Yuan, H., ve Wu, L. (2018). Remaining useful life assessment of lithium-ion battery based on HKA-ELM algorithm. *International Journal of Electrochemical Science*, 13(10), 9257-9272.
- Yao, X.-Y., Chen, G., Pecht, M., ve Chen, B. (2023). A novel graph-based framework for state of health prediction of lithium-ion battery. *Journal of Energy Storage*, 58, 106437.
- You, M., Liu, Y., Chen, Z., ve Zhou, X. (2022). Capacity Estimation of lithium battery based on charging data and Long Short-term Memory Recurrent Neural Network. 2022 IEEE Intelligent Vehicles Symposium (IV),
- Zhang, C., Zhao, S., ve He, Y. (2021). An integrated method of the future capacity and RUL prediction for lithium-ion battery pack. *IEEE Transactions on Vehicular Technology*, 71(3), 2601-2613.
- Zhang, S. S. (2006). A review on electrolyte additives for lithium-ion batteries. *Journal of Power Sources*, 162(2), 1379-1394.
- Zhang, Y., Hu, Q., Li, H., Li, J., Liu, T., Chen, Y., Ai, M., ve Dong, J. (2022). A Back Propagation Neural Network-Based Radiometric Correction Method (BPNNRCM) for UAV Multispectral Image. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 112-125.
- Zhang, Z., Zhang, W., Yang, K., ve Zhang, S. (2022). Remaining useful life prediction of lithium-ion batteries based on attention mechanism and bidirectional long short-term memory network. *Measurement*, 204, 112093.

- Zhao, S., Zhang, C., ve Wang, Y. (2022). Lithium-ion battery capacity and remaining useful life prediction using board learning system and long short-term memory neural network. *Journal of Energy Storage*, 52, 104901.
- Zhou, D., Yin, H., Fu, P., Song, X., Lu, W., Yuan, L., ve Fu, Z. (2018). Prognostics for state of health of lithium-ion batteries based on Gaussian process regression. *Mathematical Problems in Engineering*, 2018.
- Zhou, Y., ve Huang, M. (2016). Lithium-ion batteries remaining useful life prediction based on a mixture of empirical mode decomposition and ARIMA model. *Microelectronics Reliability*, 65, 265-273.



ÖZ GEÇMİŞ

Fatih Durmuş Bursa Işıklar Askeri Hava Lisesi’ni bitirdikten sonra 2011 yılında girdiği İstanbul Üniversitesi Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği bölümünden 12.06.2015 tarihinde mezun oldu. 2016 yılı Eylül ayında Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim Dalı Yüksek Lisans programına başladı. 19.07.2019 tarihinde yüksek lisansını bitirdi. Aynı yıl Ondokuz Mayıs Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim Dalı doktora programına başladı. 2016 yılı Mart ayından bu yana Ondokuz Mayıs Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünde Araştırma Görevlisi olarak görev yapan F.. D., iyi derecede İngilizce bilmektedir (YDS:78.75).

İletişim Bilgileri

ORCID ID : 0000-0002-1488-4981

Yayınlar:

1. Özbilgin F., **Durmuş F.**, Karagöl S.; Yazılı Metni Şifreleyip LSB Yöntemi ile Gizleme, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 2018, 6 (2018) 676-685
2. **Durmuş F.**, Karagöl S.; The Effect of the Wireless Power Transfer for Electric Vehicles on State of Charge, *European Journal of Science and Technology*, 2021, (26), 447-455. (doi: 10.31590/ejosat.960364)
3. **Durmuş F.**, Karagöl S.; Mutual Inductance Calculation for Planar Square and Hexagonal Coils, *Arab J Sci Eng*, 2022, 47, 3409–3420 (doi: 10.1007/s13369-021-06271-6)
4. **Durmuş, F.**, Karagöl, S. Lithium-Ion Battery Capacity Prediction with GA-Optimized CNN, RNN, and BP. *Appl. Sci.* **2024**, *14*, 5662. (doi: 10.3390/app14135662)