

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**LİTYUM İYON BATARYALARIN MAKİNE ÖĞRENİMİ YÖNTEMLERİ İLE
SAĞLIK DURUMU KESTİRİMİ**

YÜKSEK LİSANS TEZİ

Çetin ORAL

Elektrik Mühendisliği Anabilim Dalı

Elektrik Mühendisliği Lisansüstü Programı

TEMMUZ 2021

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**LİTYUM İYON BATARYALARIN MAKİNE ÖĞRENİMİ YÖNTEMLERİ İLE
SAĞLIK DURUMU KESTİRİMİ**

YÜKSEK LİSANS TEZİ

**Çetin ORAL
(504181015)**

Elektrik Mühendisliği Anabilim Dalı

Elektrik Mühendisliği Lisansüstü Programı

Tez Danışmanı: Dr. Öğr. Üyesi Derya Ahmet KOCABAŞ

TEMMUZ 2021

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 504181015 numaralı Yüksek Lisans Öğrencisi Çetin ORAL, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “LİTYUM İYON BATARYALARIN MAKİNE ÖĞRENİMİ YÖNTEMLERİ İLE SAĞLIK DURUMU KESTİRİMİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Dr. Öğr. Üyesi Derya Ahmet KOCABAŞ**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Emine AYAZ**
İstanbul Teknik Üniversitesi

Prof. Dr. Kamuran Nur BEKİROĞLU
Yıldız Teknik Üniversitesi

Teslim Tarihi : 11 Haziran 2021
Savunma Tarihi : 2 Temmuz 2021





Aileme ve dostlarıma,



ÖNSÖZ

Ders dönemi ve tez dönemi boyunca yardımlarını esirgemeyen, umutsuzluğa düştüğüm anlarda elimden tutup kaldıran ve motive eden sayın danışman hocam Dr. Öğr. Üyesi Derya Ahmet Kocabaş'a teşekkürlerimi sunarım.

Desteklerini ve iyi dileklerini her zaman hissettiğim sevgili annem Güner Oral ve babam Osman Oral'a ve hayatımın her anında, her konuda elinden gelen desteği esirgemeyen yol arkadaşım Gizem Söke'ye, anlık bir desteği ile çalışmama büyük hız kazandıran değerli arkadaşım M. Kerem Eren'e, beraber fikir alışverişi yaptığım ve beni motive eden Yiğit İşcanoğlu başta olmak üzere tüm dostlarıma teşekkür etmek isterim.

Ders dönemi boyunca ihtiyaç duyduğum anlarda öğrenimime öncelik tanıyıp dar zamanlarımda bana yol açan H. Kerem Erenay ve benzer şekilde tez dönemimde aynı anlayışı göstermiş olan İlhan Topkaya'ya da teşekkürlerimi sunarım.

Haziran 2021

Çetin Oral
(Elektrik Mühendisi)



İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xiii
ÇİZELGE LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1 Tezin Amacı	2
1.2 Literatür İncelemesi	3
2. LİTYUM İYON BATARYALAR	9
2.1 Batarya Terminolojileri	9
2.2 Lityum İyon Bataryaların Yapıları	11
2.2.1 Katot materyaline göre batarya türleri	12
2.2.1.1 Lityum kobalt oksit (LCO)	12
2.2.1.2 Lityum nikel manganez kobalt oksit (NMC)	13
2.2.1.3 Lityum nikel kobalt alüminyum (NCA)	13
2.2.1.4 Lityum manganez oksit (LMO)	14
2.2.1.5 Lityum demir fosfat (LFP)	14
2.2.2 Anot materyaline göre batarya türleri	14
2.2.2.1 Lityum titanat oksit (LTO)	14
2.2.2.2 Lityum metal	15
2.2.2.3 Silisyum bazlı anotlar	15
2.3 Fiziksel Yerleşim Yapısına Göre Batarya Türleri	16
2.4 Batarya Yönetim Sistemi	16
2.5 Batarya Şarj Yöntemleri	19
2.5.1 Sabit akım-sabit gerilim yöntemi	19
2.5.2 Sabit güç-sabit gerilim yöntemi	20
2.5.3 Çok seviyeli sabit akım-sabit gerilim yöntemi	20
2.5.4 Darbe akımlı şarj	21
2.6 Bataryalarda Ömür Kavramı	21
2.6.1 Bozulma durumunun temeli	22
2.6.1.1 Takvimsel sebepler	22
2.6.1.2 Kullanımsal sebepler	22
2.6.2 Bozulma durumu etmenleri	23
2.6.2.1 Lityum iyon kaybı	23
2.6.2.2 Anot aktif materyal kaybı	25
2.6.2.3 Katot aktif materyal kaybı	26

3. MAKİNE ÖĞRENİMİ	29
3.1 Makine Öğrenimi Teknikleri.....	29
3.1.1 Denetimsiz öğrenim	30
3.1.2 Denetimli öğrenim.....	30
3.1.2.1 Destek vektör makinesi regresyonu (DVR)	31
3.1.2.2 Gauss süreci regresyonu (GSR)	34
3.1.2.3 Doğrusal olmayan dışsal girdili otoregresif ağ (NARX)	38
4. BATARYA SAĞLIK DURUMU KESTİRİMİ	41
4.1 Çalışmada Kullanılan Batarya Hücresi Verileri	42
4.2 Batarya Sağlık Durumu Kestirimi Çalışması için Kullanılan Verilerin Seçimi ve Sonuçlar için Başarım Kriteri	44
4.2.1 Örnek batarya için veri derlemesi	45
4.3 DVR ile Batarya Sağlık Durumu Kestirimi.....	48
4.4 GSR ile Batarya Sağlık Durumu Kestirimi	49
4.5 NARX ile Batarya Sağlık Durumu Kestirimi.....	49
4.6 Karşılaştırmalı Sonuçlar	52
4.6.1 Batarya bazında yöntemlerin karşılaştırılması	52
4.6.2 Yöntem bazında bataryaların karşılaştırılması	60
4.7 Sonuçların Değerlendirilmesi	67
5. SONUÇLAR VE ÖNERİLER.....	69
KAYNAKLAR.....	73
EKLER	81
ÖZGEÇMİŞ.....	101

KISALTMALAR

BYS	: Batarya Yönetim Sistemi
DOD	: Depth of Discharge
DVR	: Destek Vektör Makinesi Regresyonu
GSR	: Gauss Süreci Regresyonu
KEA	: Katı Elektrolit Arayüz
LCO	: Lityum Kobalt Oksit
LMO	: Lityum Manganez Oksit
LPF	: Lityum Demir Fostat
LTO	: Lityum Titanat
MSE	: Mean Square Error
NARX	: Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ
NCA	: Lityum Nikel Kobalt Alüminyum Oksit
NMC	: Lityum Nikel Manganez Kobalt Oksit
PTC	: Positive Temperature Coefficient Thermistor
RMSE	: Root Mean Square Error
SOC	: State of Charge
SOH	: State of Health



SEMBOLLER

$^{\circ}\text{C}$	: Sıcaklık (Santigrat derece)
ξi^- ve ξi^+	: Gevşek değişkenler
A	: Akım (Amper)
Ah	: Kapasite (Amper saat)
b	: Eşik değeri
C	: Düzenleme parametresi
HF	: Hidrojen florür
kg	: Kütle (Kilogram)
l	: Hacim (Litre)
L	: Lagrange fonskiyonu
LiPF₆	: Lityum heksaflorofosfat
mAh	: Kapasite (mili Amper saat)
mV	: Gerilim (mili Volt)
V	: Gerilim (Volt)
w	: Ağırlık vektörü
Wh	: Enerji (Watt saat)
Wh/kg	: Spesifik enerji
Wh/l	: Enerji yoğunluğu



ÇİZELGE LİSTESİ

Sayfa

Çizelge 4.1 : Örneklem aralığı için DVR başarımları	47
Çizelge 4.2 : Örneklem aralığı için GSR başarımları.....	47
Çizelge 4.3 : Örneklem aralığı için NARX başarımları	47
Çizelge 4.4 : Eğitim ve test için kullanılan bataryalar	49
Çizelge 4.5 : Batarya 1 ve Batarya 2 için kestirim rmse sonuçları.....	54
Çizelge 4.6 : Batarya 3 ve Batarya 4 için kestirim rmse sonuçları.....	56
Çizelge 4.7 : Batarya 5 ve Batarya 6 için kestirim rmse sonuçları.....	58
Çizelge 4.8 : Batarya 7 ve Batarya 8 için kestirim rmse sonuçları.....	60



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Lityum iyon batarya hücresinin iç yapısına ait şema gösterimi (Palacin, 2018).	11
Şekil 2.2 : NCA kimyada bataryaya sahip ticari ürünler. Solda Dyson V8, sağda Tesla Model S gösterilmektedir.....	13
Şekil 2.3 : Fiziksel yapılarına göre batarya tipleri. Solda kese tipi, ortada silindirik, sağda prizmatik tip gösterilmiştir (Löbberding ve diğ, 2020).	16
Şekil 2.4 : Lityum iyon batarya paketi ve entegre haldeki batarya yönetim sistemi (Löbberding ve diğ, 2020).	17
Şekil 2.5 : Lityum iyon bataryalar için temel dengeleme yöntemleri (Özdemir, 2017).	19
Şekil 2.6 : Şarj yöntemlerinin akım gerilim karakteristiği a) Sabit akım-sabit gerilim, b) Sabit güç-sabit gerilim, c) Çok seviyeli sabit akım-sabit gerilim, d) Darbe akımlı şarj (Tomaszewska ve diğ, 2019).	20
Şekil 2.7 : Bozulma mekanizması ile ilgili sebep sonuç bağlantıları (Birkel ve diğ, 2017).	24
Şekil 3.1 : Makine öğrenmesi teknikleri sınıflandırılması (“What Is Machine Learning? 3 Things You Need To Know”, ty).	30
Şekil 3.2 : Kayıp fonksiyonları.....	32
Şekil 3.3 : ϵ -duyarsız kayıp fonksiyonu için doğrusal destek vektör regresyonu (Nuhic ve diğ, 2013).	33
Şekil 3.4 : NARX şema gösterimi (Khaleghi ve diğ, 2021).	39
Şekil 3.5 : NARX yapıları şema gösterimi a) Seri-paralel tür, b) paralel tür (Boussaada ve diğ, 2018).	40
Şekil 4.1 : Batarya sağlık durumu kestirimi elde etmek için oluşturulan iş akış diyagramı.	42
Şekil 4.2 : Deşarj akım profili (Birkel, 2017, veri).	43
Şekil 4.3 : Çalışmada kullanılan bataryaların çevrim sayısına göre sağlık durumu değişimleri.	44
Şekil 4.4 : 1. bataryanın çevrim sayısına göre zamana bağlı şarj gerilimi grafiği.....	45
Şekil 4.5 : 1. bataryanın çevrim sayısına göre gerilime bağlı şarj kapasitesi grafiği.	46
Şekil 4.6 : 3.8-4V giriş verisi için 1,2,5,6,7,8 numaralı batarya veri setleri eğitim verileri başarı grafiği.....	51
Şekil 4.7 : Batarya 1 için 3,60-3,65 V gerilim aralığı giriş verileri için kestirim sonuçları.....	52
Şekil 4.8 : Batarya 1 için 3,60-3,80 V gerilim aralığı giriş verileri için kestirim sonuçları.....	53
Şekil 4.9 : Batarya 1 için 3,80-4,00 V gerilim aralığı giriş verileri için kestirim sonuçları.....	53
Şekil 4.10 : Batarya 3 için 3,60-3,65 V gerilim aralığı giriş verileri için kestirim sonuçları.....	54

Şekil 4.11 : Batarya 3 için 3,60-3,80 V gerilim aralığı giriş verileri için kestirim sonuçları.....	55
Şekil 4.12 : Batarya 3 için 3,80-4,00 V gerilim aralığı giriş verileri için kestirim sonuçları.....	55
Şekil 4.13 : Batarya 5 için 3,60-3,65 V gerilim aralığı giriş verileri için kestirim sonuçları.....	56
Şekil 4.14 : Batarya 5 için 3,60-3,80 V gerilim aralığı giriş verileri için kestirim sonuçları.....	57
Şekil 4.15 : Batarya 5 için 3,80-4,00 V gerilim aralığı giriş verileri için kestirim sonuçları.....	57
Şekil 4.16 : Batarya 7 için 3,60-3,65 V gerilim aralığı giriş verileri için kestirim sonuçları.....	58
Şekil 4.17 : Batarya 7 için 3,60-3,80 V gerilim aralığı giriş verileri için kestirim sonuçları.....	59
Şekil 4.18 : Batarya 7 için 3,80-4,00 V gerilim aralığı giriş verileri için kestirim sonuçları.....	59
Şekil 4.19 : 3,60-3,65 V gerilim aralığı için NARX ile kestirim sonuçları.....	61
Şekil 4.20 : 3,60-3,80 V gerilim aralığı için NARX ile kestirim sonuçları.....	61
Şekil 4.21 : 3,80-4,00 V gerilim aralığı için NARX ile kestirim sonuçları.....	62
Şekil 4.22 : 3,60-3,65 V gerilim aralığı için DVR ile kestirim sonuçları. (batarya 8 sonucu ilk veri %100'ü geçmeli).	63
Şekil 4.23 : 3,60-3,80 V gerilim aralığı için DVR ile kestirim sonuçları.....	64
Şekil 4.24 : 3,80-4,00 V gerilim aralığı için DVR ile kestirim sonuçları.....	64
Şekil 4.25 : 3,60-3,65 V gerilim aralığı için GSR ile kestirim sonuçları.....	65
Şekil 4.26 : 3,60-3,80 V gerilim aralığı için GSR ile kestirim sonuçları.....	66
Şekil 4.27 : 3,80-4,00 V gerilim aralığı için GSR ile kestirim sonuçları.....	66
Şekil B.1 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,65 V aralığında DVR ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.	83
Şekil B.2 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,65 V aralığında DVR ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.	84
Şekil B.3 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,80 V aralığında DVR ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.	85
Şekil B.4 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,80 V aralığında DVR ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.	86
Şekil B.5 : Batarya sağlık durumunun gerçek değeri ve 3,80-4,00 V aralığında DVR ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.	87
Şekil B.6 : Batarya sağlık durumunun gerçek değeri ve 3,80-4,00 V aralığında DVR ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.	88
Şekil B.7 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,65 V aralığında GSR ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.	89
Şekil B.8 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,65 V aralığında GSR ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.	90

Şekil B.9 :	Batarya sağlık durumunun gerçek değeri ve 3,60-3,80 V aralığında GSR ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.	91
Şekil B.10 :	Batarya sağlık durumunun gerçek değeri ve 3,60-3,80 V aralığında GSR ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.	92
Şekil B.11 :	Batarya sağlık durumunun gerçek değeri ve 3,80-4,00 V aralığında GSR ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.	93
Şekil B.12 :	Batarya sağlık durumunun gerçek değeri ve 3,80-4,00 V aralığında GSR ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.	94
Şekil B.13 :	Batarya sağlık durumunun gerçek değeri ve 3,60-3,65 V aralığında NARX ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.	95
Şekil B.14 :	Batarya sağlık durumunun gerçek değeri ve 3,60-3,65 V aralığında NARX ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.	96
Şekil B.15 :	Batarya sağlık durumunun gerçek değeri ve 3,60-3,80 V aralığında NARX ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.	97
Şekil B.16 :	Batarya sağlık durumunun gerçek değeri ve 3,60-3,80 V aralığında NARX ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.	98
Şekil B.17 :	Batarya sağlık durumunun gerçek değeri ve 3,80-4,00 V aralığında NARX ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.	99
Şekil B.18 :	Batarya sağlık durumunun gerçek değeri ve 3,80-4,00 V aralığında NARX ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.	100



LİTYUM İYON BATARYALARIN MAKİNE ÖĞRENİMİ YÖNTEMLERİ İLE SAĞLIK DURUMU KESTİRİMİ

ÖZET

Yüksek enerji yoğunlukları, nispeten yüksek güç yoğunlukları, uzun kullanım ömürleri, yüksek hücre gerilimleri ve düşük kendi kendine deşarj özellikleri gibi güçlü yanları ile birlikte lityum iyon bataryalar günümüzde, taşınabilir cihazlar, elektrikli taşıtlar, savunma ve uzay uygulamalarında, kendine oldukça yaygın kullanım alanları bulmaktadır ve gelecekte, hayatımızda daha da çok yer alacağı düşünülmektedir.

Bir lityum iyon bataryanın üretilmesini takiben, depolanması ya da kullanımı durumunun her ikisi için de geçerli olmak üzere, bataryanın sağlık durumu giderek azalma eğilimi göstermektedir. Bataryaların sağlığı azaldıkça, sağlayabildikleri kapasitenin ve gücün de azaldığı bilinmektedir. Belirli sağlık durumunun altında, bataryanın artık kullanıldığı sistem için yeterince güç veremediği ve/veya yeterli enerjiyi sağlayamadığı, kullanım süresi sunamadığı görülür. Ayrıca sağlık durumunun çok düştüğü durumlarda, hem bataryanın hem de bataryanın çevresinin tahrip olabileceği kazalarla karşılaşmaktadır. Bu sebeplerden dolayı, bataryaların sağlık durumu takibinin yapılması, güvenlik ve güvenilirlik anlamında önemli bir konudur.

Batarya yönetim sistemleri, lityum iyon bataryalar ile beraber kullanılan önemli sistemlerdir. Bu sistemler, bataryanın gerilim, akım, sıcaklık parametrelerini izler, şarj durumu ve sağlık durumu kestirimlerinde bulunur. Batarya yönetim sistemi, bataryanın güvenli ve güvenilir bir şekilde çalışmasını sağlamakla görevlidir.

Bataryaların sağlık durumunun tespiti için çok sayıda yöntem bulunmaktadır. Bu yöntemlerden bir kısmı, laboratuvar ekipmanları ile bataryaları belirli şartlar altında doğrudan test etmektir. Coulomb sayma, iç direnç ölçümü, elektrokimyasal empedans spektroskopisi gibi doğrudan test yöntemleri ile bataryaların sağlık durumu çok isabetli bir şekilde ölçülebilir. Fakat bu ölçüm için özel cihazlara ihtiyaç duyulması, bataryanın test şartları altında, sadece ölçüme özel olarak çalıştırılmasına gerek duyulması bu yöntemlerin dezavantajlarıdır.

Doğrudan test yöntemleri dışında, elektriksel eşdeğer devre ve elektrokimyasal model gibi yöntemlerde, bataryaların bir modeli oluşturulmaya çalışılarak bataryaların iç parametreleri belirlenir ve bu parametreler üzerinden kestirimde bulunulur. Batarya sağlık durumu kestirimi için model tabanlı yöntemlerin, Kalman filtre tabanlı, genişletilmiş Kalman filtesi, dağılımlı Kalman filtresi, iki aşamalı genişletilmiş Kalman filtesi, parçacık filtresi gibi uyarlanabilir filtreler ile birlikte kullanımı yaygın olarak görülür. Doğrudan test yönteminden farklı olarak, bataryalara ayrı bir test uygulamak zorunda kalmadan, normal hayat döngüsü içerisinde bu yöntemleri kullanabilmek mümkündür. Elektrokimyasal sürecin matematiksel olarak tanımlanarak iç parametrelerin belirlenmesi ve gerçek zamanlı batarya sağlık durumu kestirimi oldukça karmaşık işlemlerdir. İşlemlerin karmaşıklığından dolayı büyük hesaplama gücü gerektirmesi bu yöntemlerin en belirgin dezavantajıdır.

Tüm bu yöntemlerden farklı olarak, veri tabanlı sağlık durumu kestirim yöntemleri, yalnızca gerilim, akım, örnekleme süresi ve sıklığı gibi batarya yönetim sistemi üzerinden doğrudan ulaşılabilen ya da kapasite gibi basitçe hesap edilebilen verileri kullanarak, sade yapısı ve isabetli sonuçlar elde edilebilmesi sayesinde gün geçtikçe daha da çok dikkat çekmektedir.

Bu çalışmada, gerçek uygulamalarda kullanılabilecek, bataryaların kısmi şarj aralıklarında elde edilen kapasite bilgileri kullanılarak, üç farklı makine öğrenmesi yöntemi ile sağlık durumu kestirimi yapılarak yöntemlerin başarımları karşılaştırılmıştır.

Batarya verileri olarak, Oxford Üniversitesi Howey Araştırma Grubu'nun sekiz adet lityum iyon hücrenin yıpranmasını incelemek için yaptığı deneysel çalışmanın verileri kullanılmıştır.

Çalışmada, makine öğrenimi tekniklerinden Destek Vektör Makinesi ile regresyon (DVR), Gauss Süreci Regresyonu (GSR) ve Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ (NARX) yöntemleri kullanılarak, “3,60-3,65 V”, “3,60-3,80 V” ve “3,80-4,00 V” gerilim aralıklarındaki kısmi şarj anları için kestirimler yapılmış ve sonuçlar karşılaştırmalı olarak verilmiştir.

Bataryalar, eğitim veri seti ve test veri seti olarak ayrılmıştır. Farklı eğitim veri kombinasyonları oluşturularak tüm bataryalar için doğrulamalar yöntem, gerilim aralığı ve hücre bazında karşılaştırmalı olarak gerçekleştirilmiştir. Test için ayrılan batarya veri setleri, eğitim veri setinden tamamen farklı olacak şekilde ayrıştırılmıştır. Hem gerilim aralıklarına istinaden giriş verileri değişiminin başarımlar üzerindeki etkisi, hem de kullanılan yöntemlerin farklı gerilim aralıklarında başarımlarının değişimi tespit edilmiştir. Test edilen bataryalar için kestirim sonucu başarımlar ölçütü olarak hata kareleri ortalamasının karekökü hesabı kullanılmıştır. Sekiz batarya hücresinin sağlık durumu, üç farklı gerilim aralığında, üç farklı makine öğrenmesi metoduyla hesaplanmış ve hata değerleri %0,20 ile %2,32 arasında elde edilmiştir.

Sonuç olarak gerilimin düşük ve gerilim aralığının dar olduğu 3,60-3,65 V aralığında NARX yönteminin diğer yöntemlerden, gerilim aralığı genişledikçe DVR ve GSR yöntemlerinin NARX'tan daha başarılı olduğu tespit edilmiştir.

STATE OF HEALTH ESTIMATION FOR LITHIUM-ION BATTERIES USING MACHINE LEARNING METHODS

SUMMARY

Nowadays, lithium-ion batteries are widely used in portable devices, electric vehicles, defense and aerospace applications, providing relatively high energy and power density, long cycle life, high cell voltage, and low self-discharge characteristics, indications show that lithium-ion batteries will become more popular in the future.

Following the assembly of a lithium-ion battery, degradation occurs for both storage and use conditions. This degradation affects the battery performance, such as available capacity and power. Below a certain state of health condition, the battery is no longer able to supply enough power and/or provide sufficient energy for the system in which it is supplied. In addition to that, when the state of health is too low, it is seen that accidents can occur in lithium-ion batteries, which can lead to the destruction of both cell and its environment. For these reasons, monitoring the state of health is an important measure in terms of safety and reliability.

The safe operating area of lithium-ion batteries is limited to a narrow range by temperature and voltage. Battery management systems are important elements used in lithium-ion battery packs in order to monitor the voltage, current, temperature parameters, also estimates the state of charge and state of health of the battery and ensure safe and reliable operation.

Long-lasting and reliable use of batteries are the most important parameters for battery-operated systems. Information of the state of health of the battery is essential for future operations and supply planning in maintenance-renewal processes. Recently, battery state of health estimation has become more and more important, especially with the widespread use of electric vehicles. In the last 20 years, important studies are conducted on the degradation mechanisms, state of health and remaining useful life estimation of lithium-ion batteries with different lithium-ion chemistry types.

There are many methods for determining the state of health of batteries. Some methods directly test batteries with laboratory equipments under certain experimental conditions. Thanks to direct test methods such as Coulomb counting and electrochemical impedance spectroscopy, the state of health of batteries can be measured very accurately. However, the need for special devices and specific test conditions are the disadvantages of these methods.

Apart from direct test methods, in methods such as electrical equivalent circuit and electrochemical model, a model of the batteries is created and the internal parameters of the batteries are determined. The battery state of health is estimated with determined parameters. It is common to use model-based methods for the state of health estimation together with adaptive filters such as Kalman filter-based, extended Kalman filter, unscented Kalman filter, dual extended Kalman filter, particle filter. Defining the electrochemical process, determining the internal parameters mathematically and

estimating the real-time state of health of battery are complex processes and the most obvious disadvantage of these methods is that they require high computational power.

Unlike these methods, data-driven state of health estimation methods gain attention day by day with their simple structure and accurate results with the use of directly accessible data from battery management system such as voltage, current, sample time and sampling frequency or simply calculated data such as capacity. Moreover, data-driven methods effectively reflect the non-linear relationship between various battery parameters without define any complex electrochemical process. Fuzzy logic, support vector machines (SVM), Gaussian process regression (GPR) and artificial neural network are some of the data-driven methods used for the state of health estimation.

Machine learning algorithms use computational methods to learn by directly processing the data obtained without a predetermined equation or a formulation. It is possible to process a very complex problem, a large amount of multivariate data, and find a solution with the machine learning method without any equations or formulations.

Machine learning methods create a suitable model by using the data they have obtained before. When new data is received, the data is analyzed and a solution is estimated using a model created with one of the machine learning methods. The larger the dataset used when creating the model, the better the performance of the model created with machine learning.

In real-world applications, although the batteries are exposed to different discharge currents and different load profiles, they are usually stably charged with a certain charging equipment during the charging process.

The use cases of the batteries are generally not in a fixed scenario. Batteries may not always be used by the user to be fully charged and fully discharged. Apart from this, the number of records of the information obtained by the battery management system during the full charging process can be in the thousands. The full charging process can make situations such as managing, transferring and processing the data very difficult.

In this study, battery state of health is estimated using three different supervised machine learning methods, using the capacity information obtained at partial charge intervals of the batteries, suitable for use in real-world applications. The performance of the methods are compared based on the estimation results.

Degradation dataset of eight lithium-ion cells published by Oxford University Howey Research Group is used for machine learning models and test subjects.

Six batteries are used as the training set, and two different batteries are used for validation. By creating different training data combinations, validations for all batteries are performed comparatively on the basis of method, voltage range and cell.

In this study, measured charging capacity of the batteries for voltage intervals “3.60-3.65 V”, “3.60-3.80 V” and “3.80-4.00 V” are used as the input data. The state of health of the battery is defined as the ratio of discharge capacity in the present condition to the discharge capacity in the first cycle. In the study, experimental data are used for between 100% and 80%. The state of the health for all batteries and estimations are made for this range. Different machine learning techniques, such as regression with SVM, GPR and nonlinear autoregressive exogenous neural network (NARX) are used. The performance effect of both the variation of the input data

according to the voltage ranges and the sampling number of the input data on the methods used are determined. MATLAB 2020a is used for modelling.

In the examination of the model performance, the root mean squared error (RMSE) are used as the performance criterion. Three different machine learning methods are compared with three different voltage ranges for eight battery cells. Root mean squared errors are calculated between 0,20% and 2,32%.

As a result, it is determined that the NARX method is more successful than other methods in the 3,60-3,65 V range where the voltage is low and voltage range is narrow. However, as the voltage range increases, it is calculated that DVR and GSR methods are more successful than NARX.





1. GİRİŞ

1990'lı yılların başında ticarileştirilmeye başlandığından beridir, lityum iyon batarya teknolojisi büyük bir gelişme göstermiş ve gün geçtikçe hayatımızın her alanına dahil olmaya başlamıştır. Enerji depolama teknolojileri içerisinde de, yakın gelecek için en umut verici teknoloji olarak gözükmektedir. Yüksek enerji yoğunlukları ile birlikte nispeten yüksek güç yoğunlukları bu teknolojinin cep telefonları, bilgisayarlar gibi kişisel elektronik aletler; matkap, kesim makineleri gibi el aletleri; bisiklet, scooter gibi hafif ulaşım araçları ile birlikte otomobil, tır ve otobüs gibi büyük ulaşım araçları; yenilenebilir enerji santrali enerji depolama sistemleri ve şebeke yardımcı sistemlerinden, savunma sanayi ve uzay çalışmaları ürünlerine kadar çok geniş alanlarda kullanılmasına yol açmıştır.

Bataryalar, doğrusal olmayan davranış gösteren, karmaşık elektrokimyasal elemanlardır. Güvenilirlik ve başarımları, yapım esnasında kullanılan malzeme teknolojisi ve üretim tekniği gibi iç etkenlere bağlı olduğu kadar, kullanma ve depolama koşulları, süreleri ve kullanım şartları gibi dış etkenlere de bağlıdır. Lityum iyon bataryalar tek bir hücre veya birçok hücrenin birleşimi ile oluşan batarya paketi şeklinde kullanılırlar. Hata durumunda yangın tehlikesine sahip oldukları için, öncelikle kullanıcıyı, daha sonra kullanıldıkları sistemi ve kendilerini korumak önemlidir. Bu sebeplerden dolayı bataryalar, genellikle bir Batarya Yönetim Sistemi (BYS) ile birlikte çalışırlar. BYS'lerin görevi, bataryaların güvenli çalışma aralığı içerisinde kaldığını kontrol etmek ve mümkünse bataryaları bu aralıkta tutmaya çalışmaktır. Ayrıca bataryaların sağlık durumunu, şarj durumunu ve güç durumunu kullanıcıya gösterebilmektir. Sağlık durumu, şarj durumu ve güç durumu parametrelerini gerilim ya da akım gibi anlık olarak doğrudan ölçebilmek mümkün değildir, ancak bu parametreler çeşitli yöntemler ile kestirim yapılarak elde edilebilirler. Bataryaların doğrusal olmayan karmaşık elektrokimyasal yapıları yüzünden bu kestirimlerde bulunmak oldukça zordur; fakat aynı zamanda gereklidir.

Lityum iyon bataryaların enerji kapasiteleri ve verebildikleri güçler zaman ya da kullanım ile azalma göstermektedir. Bu durum, bataryanın kullanıldığı sistemin

işlevini yerine getirebilme yeteneğini doğrudan etkilemektedir. Ayrıca, kullanıldıkları alanlara göre lityum iyon bataryalar, sistemin büyük maliyet kalemlerinden biri olabilmektedir. Bu nedenle, bataryaların enerji kapasitesi ve verebildiği gücü gösteren bir belirteç olarak batarya sağlık durumu, gözlemlenmesi ve kestirilmesi önemli bir faktördür.

1.1 Tezin Amacı

Literatürde batarya sağlık durumu kestirimi için kullanılan çeşitli yöntemler bulunmaktadır. Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ (Nonlinear Autoregressive Exogenous model –NARX) yöntemi ile doğrusal olmayan sistemler için başarılı modeller oluşturulabilmesine karşılık, batarya sağlık durumu kestirimi için bu yöntem ile literatürde kısıtlı sayıda çalışma yapıldığı görülmüştür. Yapılan çalışmalarda lityum demir fosfat, lityum titanat oksit ve lityum nikel manganez kobalt oksit bataryalar kullanılmıştır. Ayrıca bu çalışmalarda, ağ için giriş verisi olarak batarya gerilimi ya da gerilim, akım ve sıcaklıktan oluşan bir kümenin seçildiği takip edilmiştir.

Literatürde ayrıca Destek Vektör Makinesi Regresyonu (DVR) ve Gauss Süreci Regresyonu (GSR) ile de sağlık durumu kestirimlerine dair çeşitli çalışmalar bulunmaktadır.

Bu çalışmanın amacı, bataryaların sağlık durumu kestirimini kısmi bir şarj gerilimi aralığında, batarya şarj kapasite verileri kullanarak NARX, DVR ve GSR yöntemleri ile elde etmek ve hem hücre bazında yöntemlerin başarımını hem de yöntemlerin çalışmadaki tutarlılığını karşılaştırmaktır. Çalışmada, NARX ile yapılan diğer çalışmalardan farklı olarak lityum kobalt oksit katot kimyasına sahip bir batarya incelenmiştir. Bataryanın sağlık durumu, kapasitesindeki değişim üzerinden ifade edilmiştir. Bataryanın şarj olma esnasında akım, gerilim ve zaman bilgileri kullanılarak hesaplanabilen, belirli şarj gerilim değerleri arasındaki şarj kapasitesi verilerinin kullanılması ile bataryanın sağlık durumu kestirilmiş ve sonuçlar incelenmiştir. Kestirim, NARX, DVR, GSR yöntemleri ile ayrı ayrı yapılmış ve sonuçlar karşılaştırılmıştır. Kestirim modeli oluşturmak için seçilen özellik vektörüne girdi yapan, kısmi şarj için belirlenen gerilim değerlerinin ve alınan örnek sayısının da kestirim başarımına etkisi ayrıca incelenmiştir.

1.2 Literatür İncelemesi

Bataryaların uzun ömürlü ve güvenilir bir şekilde kullanılabilir olması, batarya ile çalışan sistemler için en önemli konulardandır. Bir sistemde, kullanılan bataryanın sağlık durumunu bilmek, gelecekte yapılacak operasyonlarda sistemin güvenilirliği, başarımı ve bakım-yenileme süreçlerinde tedarik planlaması için elzemdir. Bataryaların sağlık durumu kestirimi, özellikle elektrikli taşıtların kullanımının yaygınlaşmaya başlaması ile birlikte son dönemde gittikçe daha ilgi çekici hale gelmektedir. Özellikle son 20 yıl içerisinde, farklı kimya teknolojilerine sahip lityum iyon bataryaların ömür kavramı, sağlık durumu ve kalan ömür kestirimi üzerine önemli çalışmalar yapılmıştır.

Lityum iyon bataryaların yıpranma sebepleri, şekilleri ve sonuçları üzerine literatürde birçok çalışma bulunmaktadır. Lityum iyon bataryaların yıpranmasının sebepleri, türleri, etkilerini anlamak ve fiziksel incelemelerde bulunmak üzerine Ning ve diğ. (2003) farklı seviyedeki deşarj akımları ile yapılan batarya çevrimlerinin, bataryanın anodu üzerindeki etkileri ve kapasite azalımı ile ilişkisini incelemişlerdir.

Kapasite azalmasında; şarj sırasında anot üzerinde oluşan yan reaksiyonlar, elektrolit oksidasyonu, faz dönüşümü vb. etkilerin matematiksel modelinin oluşturulması üzerine 2004 yılında bir çalışma yapılmıştır (Ramadass ve diğ, 2004). 2013 yılında yapılan bir başka çalışmada yıpranma mekanizması incelenmiş ve elektrikli taşıt uygulamaları için batarya sağlık durumu ve kalan ömür kestirim yöntemleri başarımları karşılaştırılmıştır (Barré ve diğ, 2013).

Farklı bir çalışmada, lityum iyon bataryaların ömür kavramının teorik argümanlarını kanıtlamak üzerine deneysel çalışmalar yürütülmüş ve yıpranma etkileri bataryanın açık devre gerilimi üzerinden incelenmiştir (Birkel ve diğ, 2017). Ayrıca 2018 yılında lityum iyon bataryaların başarımının düşmesinde tasarımsal ve çevresel etkiler M. Rosa Palacín (2018) tarafından gösterilmiştir.

Sağlık durumu kestirimi için öne sürülmüş ve üzerine çalışılmış çok sayıda yöntem bulunmaktadır. Bu yöntemler arasında Coulomb sayma yöntemi en yaygın yöntemlerden biridir. Şarj durumu kestirimi ile beraber sağlık durumu kestirimini yüksek doğrulukla yapmak üzere Ng ve diğ. (2009) bu yöntem üzerinde geliştirme çalışmalarında bulunmuşlardır.

Birçok araştırmacının üzerine çalışmalar yürüttüğü ve batarya ömür kestirimi için kullanılan bir diğer yöntem Ohm yasasının kullanımı ile batarya iç direncinin ölçülmesidir (Wei ve diğ, 2009; Chen ve diğ, 2018). Bu konu üzerine 2011 yılında elektrikli taşıtlarda araç üzerinde uygulanabilecek, iç direnç kestirimi ile batarya sağlık durumu gözlemi üzerine bir yapılan bir çalışma da bulunmaktadır (Remmlinger ve diğ, 2011).

Elektrokimyasal empedans spektroskopisi ise sağlık durumu kestirimi için kullanılan diğer bir yöntemdir (Galeotti ve diğ, 2015; Pastor-Fernández ve diğ, 2016).

Model tabanlı yaklaşımlar da batarya sağlık durumu kestirimi için kullanılmaktadırlar. Kestirim çalışmalarında genellikle üzerine çalışmaların yapıldığı iki modelleme yöntemi bulunmaktadır. Bu yöntemlerin ilki; bataryanın yapısının direnç, kondansatör ve gerilim kaynağı gibi bileşenlerden oluşturulduğu elektriksel eşdeğer devre modelidir. Elektriksel eşdeğer devre modeli üzerinden sağlık kestirimi elde edilmesi üzerine yapılmış çok sayıda çalışma bulunmaktadır (Grandjean ve diğ, 2017; Bian ve diğ, 2019). Bir diğer model tabanlı yaklaşım, elektrokimyasal model ile sağlık kestirimi yapılmasıdır. Bu modelin amacı bataryanın elektrolit konsantrasyonu, elektrolit hacmi, elektrotlardaki aktif materyal durumu gibi elektrokimyasal davranışlarının benzetimi ile sağlık durumu kestirimi yapabilmektir (Huang ve Kumar, 2018).

Sağlık kestiriminde model tabanlı yaklaşımların uyarlanabilir filtreler ile kullanılması da yaygın yöntemlerden bir diğeridir. Bataryanın gerçek zamanlı elektriksel eşdeğer devre parametrelerini belirlemek amacı ile oluşturulmuş çeşitli uyarlanabilir filtre algoritmaları bulunmaktadır. Elde edilen devre parametreleri, sağlık durumu ve şarj durumu kestirimlerinde kullanılmaktadır. Kalman filtre tabanlı, Plett (2004a) tarafından bahsedilen genişletilmiş Kalman filtesi, Fei ve diğ. (2009) tarafından kullanılmış olan dağılımlı Kalman filtresi, Wassiliadis ve diğ. (2018) ile Plett (2004b, 2004c) tarafından çalışmaların yayınlandığı iki aşamalı genişletilmiş Kalman filtesi; ayrıca Saha ve Goebel (2008) ile Schwunk ve diğ. (2013) tarafından çalışılan parçacık filtresi sağlık durumu kestiriminde kullanılan uyarlanabilir filtre yöntemlerindendir.

En küçük kareler yöntemi de batarya sağlık durumu kestirimi için kullanılan yöntemlerden birisidir. Plett (2011) ağırlıklandırılmış toplam en küçük kareler

yöntemi isimli geliştirilmiş bir yöntem üzerinde çalışma yürütmüş ve batarya kapasitesi hesaplamasında kullanmıştır.

Batarya durum kestirimleri için kullanılan bir diğer temel yöntem ise veri tabanlı yaklaşımdır. Bataryanın gerilim, akım, sıcaklık gibi parametrelerinin toplanıp, gelişmiş öğrenme algoritmaları ile batarya sağlık kestiriminin yapıldığı çeşitli yöntemler mevcuttur. 2013 yılında bulanık mantık sistemi ile batarya sağlık durumu kestirimi üzerine bir çalışma yapılmıştır. Sıcaklık ve akım verileri bulanık mantık sistemi için giriş verileri olarak kullanılmış, kapasite ve iç direnç kestirimi ile batarya sağlık durumu kestirimi elde edilmeye çalışılmıştır (Ananto ve diğ, 2013).

Destek vektör makineleri, regresyon algoritmaları kullanarak, doğrusal olmayan sistemlerin modellenmesinde kullanılan yöntemlerden birisidir. 2013 yılında yapılan bir çalışmada; başlangıç kapasitesi, şarj durumları, sıcaklık gibi batarya verileri girdi olarak kullanılıp, destek vektör regresyonu ile sağlık durumu ve kalan kullanım ömrü kestirimleri elde edilmiştir (Nuhic ve diğ, 2013). Verena Klass ve diğ. (2014) akım, sıcaklık ve şarj durumu verilerini giriş olarak kullanıp destek vektör makinesi ile gerilim çıkışı elde etmeye çalışmış ve buradan kapasite ve iç direnç değerlerini türeterek batarya sağlık durumu çıkarımında bulunmuşlardır. 2018 yılında yapılan bir çalışmada, bataryanın sabit akımla şarj edildiği belirli gerilim noktaları arasındaki gerilimin karesinin integrali ile elde edilen enerji sinyali, şarj kapasitesi ve zaman verileri girdi olarak kullanılıp, destek vektör makinesi regresyonu yöntemi ile batarya sağlık durumu kestirimi elde edilmiştir (Chen ve diğ, 2018). 2017 yılında yapılan bir diğer çalışmada, çok çekirdekli destek vektör makinesi yöntemi ile parçacık sürü optimizasyonu yöntemlerinin birleşimi kullanılıp, belirli deşarj anlarındaki gerilim seviyesi gözlenerek batarya kalan ömür kestiriminde bulunulmuştur (Gao & Huang, 2017).

Veri tabanlı yaklaşımlardan bir diğeri Gauss süreci regresyonudur. Bir çalışmada, arttırımsal kapasite eğrileri için Gauss süreci regresyonu uygulanmış ve sağlık durumu kestirimi yapılmıştır (Li ve diğ, 2019). Başka bir çalışmada, bataryanın şarj esnasındaki sabit akım modundaki şarj süresi, 3,9 V ve 4,2 V arası sabit akım şarj süresi ve sabit akım ile şarj esnasında gerilimin zamana integrali verileri ile Gauss süreci regresyonu yöntemi uygulanmış ve sağlık durumu kestirimi incelenmiştir (Zheng & Deng, 2019). 2020 yılında yapılan başka çalışmalarda, bataryaların depolama altında ve çalışma koşulları altında yıpranma durumu kestirimi Gauss süreci

regresyonu ile elde edilmiştir. Depolama altında yıpranma durumu depolama süresi, sıcaklık cevabı ve şarj durumu verileri kullanılarak; çalışma koşulları altında yıpranma durumu ise kapasite değişimi, sıcaklık cevabı, deşarj derinliği, orta nokta şarj durumu ve deşarj kapasite oranları verileri kullanılarak hesaplanmıştır. (Lucu ve diğ, 2020a, Lucu ve diğ, 2020b).

Yapay sinir ağları ise son dönemlerde üzerine çokça çalışmanın yürütüldüğü bir diğer veri tabanlı yaklaşımdır. Yapay sinir ağlarında batarya sağlık kestirimi için kullanılan çeşitli yöntemler mevcuttur. Bu yöntemlerden birisi olan geri yayımlı yapay sinir ağları yöntemi ile batarya parametreleri ve aralık kapasitesi temelli sağlık kestirimi çalışması yapılmıştır (Yang ve diğ, 2020).

Yapılan bir çalışmada, bataryanın şarj esnasında belirli bir gerilim noktasından itibaren, Coulomb sayma yöntemi ile her %1.5 kapasite artışı noktasına denk gelen 10 adet gerilim verisi ve ortalama sıcaklık bilgisi ile özellik vektörü oluşturularak yapay sinir ağları yöntemi ile batarya sağlık kestirimi elde edilmiştir (Naha ve diğ, 2020).

Chaoui ve Ibe-Ekeocha (2017) lityum demir fosfat ve lityum titanat oksit iki farklı katot kimyasına sahip hücre üzerinde NARX yöntemini kullanmışlar, bataryanın gerilim, akım ve sıcaklık değerlerini gözlemleyerek bataryanın şarj durumu ve sağlık durumu için kestirimlerde bulunmuşlardır.

2021 yılında lityum nikel manganez kobalt oksit katot yapısında bir hücre kullanılarak NARX yöntemi ile batarya sağlık kestiriminin yapıldığı bir çalışma bulunmaktadır. Bu çalışmada, bataryanın şarj anındaki kısmi gerilim değer aralıkları giriş verisi olarak kullanılmış ve sağlık durumu kestirimi yapılmıştır (Khaleghi ve diğ, 2021).

2021 yılında lityum nikel manganez kobalt oksit katot yapısındaki 40 adet hücre ile batarya sağlık kestirimi üzerine bir çalışma yapılmıştır. Şarj ve deşarj esnasındaki hücre yüzey sıcaklığı, şarj deşarj kapasite oranı (C-rate), çevrim sayısı, dinlenme sıcaklığı, dinlenme şarj durumu ve dinlenme süreleri giriş verileri olarak kullanılıp, yarı ampirik bir model, Gauss süreci regresyonu ve NARX yapay sinir ağları yöntemleri ile başarımlar karşılaştırmasında bulunulmuştur (Hosen ve diğ, 2021).

Batarya sağlık durumu kestirimi dışında, Anandhi ve Chezian (2013) tarafından destek vektör makinesi regresyonu ile kağıt hamuru için arz ve talep kestirimi, Suganyadevi ve Babulal (2014) tarafından şebekenin yüklenilebilme payı tahmini, Yasin ve diğ. (2016) tarafından ham petrol fiyatlarının tahmini, Lui ve Cen (2019) tarafından Clash

Royale oyununda en başarılı destenin yaratılması gibi konularda yapılmış çalışmalar da mevcuttur. Gauss süreci regresyonu ile Caywood vs diğ. (2017) tarafından işitsel-sözel, görsel-mekansal ve görsel-sayısal gibi görevler karşısında zihinsel iş yükünün kestirimi, Liu ve diğ. (2020) tarafından toprağın neminin kısa dönemli tahmini gibi konularda çalışmalar gerçekleştirilmiştir. Ruslan ve diğ. (2013) tarafından NARX yöntemi ile de sel tahmini sistem modeli, Boussaada ve diğ. (2018) tarafından güneş panelleri için günlük güneş ışığı alma durumu için tahmin, Katic ve diğ. (2018) tarafından kişiselleştirilmiş ısıtma sistemlerinin kontrolü gibi konular çalışılmıştır.





2. LİTYUM İYON BATARYALAR

Batarya sistemlerini primer, sekonder ve rezerv olmak üzere üç sınıfta değerlendirmek mümkündür. Primer bataryalar, tam şarjlı olarak üretilirler ve kullanıldıktan sonra tekrar şarj edilmeleri mümkün değildir, tek kullanımlık olarak tasarlanırlar. Rezerv bataryalar, primer bataryalar gibi tek kullanımlık ve tam şarjlı olarak tasarlanırlar. Primer bataryalardan farklı olarak, anot ve katotları birbirlerinden iyon aktarımı yapamayacak şekilde ayrı tutulurlar ve güç üretebilmeleri için aktive edilmeleri gerekmektedir. Aktive edilmediği bekleme süresince kendi kendine deşarj olmamaları en büyük avantajlarıdır. Sekonder bataryalar ise şarj edilebilir yapıdadırlar ve tekrar tekrar kullanılabilirler.

Sekonder batarya teknolojileri arasında lityum iyon bataryalar yüksek enerji yoğunluğu, yüksek güç yoğunluğu, yüksek çalışma gerilimi, uzun kullanım ömrü, düşük kendi kendine deşarj oranı özellikleri ile birlikte en avantajlı teknoloji olarak gözükmektedir.

2.1 Batarya Terminolojileri

Lityum iyon bataryalarda literatürde genellikle kullanılan ve tezin ilerleyen kısımlarında da geçecek olan terimlerin bir kısmı bu başlık altında açıklanmıştır.

Açık Devre Gerilimi: Batarya terminallerine bağlı bir devre olmadığı ya da harici akımların akmadığı durumda, batarya terminalleri üzerindeki ölçülen gerilimdir.

Anot (negatif elektrot): Bataryanın temel birimlerinden biridir. Yer değiştirme reaksiyonları sırasında lityum iyonları ve elektronlar için ev sahipliği görevi görür.

Amper-saat (Ah): Bataryaların kapasitesi için kullanılan bir birimdir. Akımın zamana göre integrali ile elde edilir, akımın saat biriminden zamanla çarpılması ile ifade edilir.

Batarya Yönetim Sistemi (BYS): Bir hücre ya da bir çok hücreden oluşmuş batarya paketlerinde bataryanın şarj, deşarj ve beklemesi anında akım, gerilim, sıcaklık, şarj durumu, sağlık durumu, güç durumu gibi parametrelerini gözleyen ve dengeleme, ısıt

yönetim gibi fonksiyonlara sahip olabilen, dışarıdaki bir sistem ile haberleşebilen, kullanıcıyı, sistemi ve bataryaları güvenli tutmaktan sorumlu birimdir.

Çevrim: Sekonder bataryalar için geçerli bir terimdir. Deşarj işlemi sonrasındaki şarj ya da şarj sonrasındaki deşarj sekansını ifade eder ve aynı sekansın düzenli olarak tekrarı ile takip edilir.

Deşarj: Elektronların ve lityum iyonlarının anottan katoda geçtiği, katottan anota akım akacak şekilde, dış devreye batarya tarafından enerjinin aktarılan operasyondur.

Deşarj Derinliği (DOD): Bataryanın üreticisi tarafından beyan edilen kapasitesinin yüzde cinsinden deşarj oranıdır. Örneğin %60 DOD, bir batarya için kapasitesinin %60'ının deşarj olduğu anlamına gelmektedir.

Elektrolit: Elektrotlar arasında iyon geçişini sağlayan, bataryanın elemanlarından biridir.

Enerji yoğunluğu (Wh/l): Bataryanın birim hacmine düşen enerji miktarı olarak tanımlanır.

İlk çevrim: Sekonder bir bataryanın üretim, formasyon şarjı ve kalite kontrol işlemleri sonucu yapılan başlangıç çevrimidir.

Kapasite: Bataryanın içerdiği enerjiyi ifade eder. Genellikle Ah ya da Wh birimi olarak ifade edilir.

Kapasite oranı (C-Rate): Bataryanın oda sıcaklığında üretici tarafında belirlenen kapasitesinin 1 saat içerisinde deşarjına karşılık gelen akım değeridir. Örneğin 10 Ah kapasite değerinde bir batarya için 1 C değeri 10 A, 2 C değeri 20 A akıma karşılık gelmektedir.

Katot (pozitif elektrot): Bataryanın temel birimlerinden birisidir. Yer değiştirme reaksiyonları sırasında lityum iyonları ve elektronlar için ev sahipliği görevi görür.

Nominal Gerilim: Bataryayı tanımlamak için kullanılan gerilimin uygun yaklaşık değeridir.

Sağlık Durumu (SOH): Bataryanın güvenilir ve işlevsel olarak kullanılabilirliği için ölçülür. Bataryanın ilk çevrimindeki, genellikle kapasite ya da iç direnç durumuna göre mevcut durumdaki kapasite ya da iç direnç değerini oransal olarak tanımlar.

Separatör: Anot ile katotun batarya içerisinde kısa devre olmasını engelleyen batarya birimlerinden biridir.

Spesifik Enerji (Wh/kg): Bataryanın birim kütlesine düşen enerji olarak tanımlanır.

Şarj: Elektronların ve lityum iyonlarının katottan anota geçtiği, dışarıdan bir güç kaynağı ile anottan katota akımın aktığı ve güç kaynağından bataryaya enerji verilen operasyondur.


Şarj Durumu (SOC): Deşarj derinliği tanımının tersidir. Bataryanın erişilebilir, şarjlı durumdaki kapasitesini tanımlar.

Tam Deşarjlı: Bataryanın %100 DOD ya da %0 SOC durumundaki halini tanımlar.

Tam Şarjlı: Bataryanın %0 DOD ya da %100 SOC durumundaki halini tanımlar.

2.2 Lityum İyon Bataryaların Yapıları

Lityum iyon pillerde, hücre içerisinde diğer pil sistemlerinde olduğu gibi enerjiyi üretmek ve depolamaktan birilcil derecede sorumlu üç ana bileşen bulunmaktadır: pozitif elektrot, negatif elektrot ve elektrolit. Şekil 2.1’de bir bataryanın yapısı ana hali ile gösterilmiştir.



Şekil 2.1 : Lityum iyon batarya hücresinin iç yapısına ait şema gösterimi (Palacin, 2018).

Lityum iyon bataryalarda kullanılan pozitif elektrotlar, genelde tünel veya tabakalı yapılara sahip metal oksitlerden oluşurlar. Negatif elektrotlar ise genellikle grafit gibi karbon tabanlı malzemelerden ya da lityum titanat oksitten ($\text{Li}_4\text{Ti}_5\text{O}_{12}$) yapılırlar. Negatif elektrotlarda yeni teknoloji olarak silisyum katkılı karbon ve lityum metal kullanımı ile yapılan çalışmalar da bulunmaktadır. Elektrolit kullanımı, elektrotların materyaline göre belirlenir. Elektrolitler genellikle lityum tuzları ve organik bir çözücünden oluşan çözeltilerdir. Elektrolitlerin arasında iyon transferini sağlarlar. Bunun dışında katı hal elektrolit de son zamanlarda büyük ilgi gören ve yakın zamanda çalışmaların olgunlaşmaya başladığı bir teknolojidir. Katı hal elektrolitlerin, üzerinde lityum plakalaşmasına izin vermemesi sayesinde lityum metal anot kullanımına imkan tanınması, düşük sıcaklık koşullarında şarja ya da yüksek hızlı şarja izin vermesi, ayrıca batarya şişmesi gibi fiziksel bozulmalar göstermemesi gibi avantajları bulunmaktadır. Elektrotlar ve elektrolit dışında hücre içerisinde kullanılan bir diğer eleman ise separatördür. Separatör elektrotlar arasında kısa devre olmasını engellerken, lityum iyonlarının geçişini sağlayan yapıdadır (Hannan ve diğ, 2018). Separatörlerde iyon geçirgenliğinin yüksek olması, ısıl sürüklenme yaşanmasının önlenmesi için bataryanın aşırı ısınması sonrası bu sıcaklığa dayanabilir olması ve ısıl kesmeye gidebilir olması aranan özelliklerdendir (Arora & Zhang, 2004; Lagadec ve diğ, 2019; Bandhauer ve diğ, 2011).

2.2.1 Katot materyaline göre batarya türleri

Anodu karbon tabanlı yapıda olan batarya türleri, isimlerini genellikle katotun yapıldığı malzemeden alırlar. Farklı katot malzemeleri ile geliştirilmiş çok sayıda batarya türü bulunmaktadır. Bu türlerden lityum kobalt oksit (LCO), lityum nikel mangan kobalt oksit (NMC), lityum nikel kobalt alüminyum oksit (NCA), lityum mangan kobalt oksit (LMO), lityum demir fosfat (LPF) ticarileşmiştir ve günümüzde birçok üründe kullanılmaktadır.

2.2.1.1 Lityum kobalt oksit (LCO)

1991 yılında Sony tarafından geliştirilmiş bu batarya türü, ilk ticarileşen lityum iyon batarya türüdür (Hannan ve diğ, 2018). Tüketici elektroniğinde sıkça kullanılmaktadır. Spesifik kapasitesi 145-150 mAh/g civarındadır. Düşük kendi kendine deşarj, yüksek nominal gerilim ve uzun çevrim başarımı bu teknolojinin avantajlarındandır.

Isıl stabilitesinin düşük olması, kobaltın yüksek maliyeti ve yüksek deşarj akımları altında kapasitesindeki düşüşün yüksek olması bu teknolojinin dezavantajlarından (Nitta ve diğ, 2015).

2.2.1.2 Lityum nikel mangan kobalt oksit (NMC)

Elektrikli taşıtlarda sıkça kullanılır. Nikel, yüksek enerji yoğunluğuna fakat düşük ısıl stabiliteye sahiptir. Mangan ve kobalt elementlerinin eklenmesi ile yüksek enerji yoğunluğu ile beraber ortalama seviyelerde ısıl stabilite elde edilir.

LCO bataryalara göre daha düşük oranda kobalt içerdiği için daha ucuzdur. Element oranlarına göre NMC111, NMC442, NMC622, NMC811 gibi çeşitleri bulunmaktadır.

Spesifik kapasitesi 155-185 mAh/g civarındadır (Nitta ve diğ, 2015).

2.2.1.3 Lityum nikel kobalt alüminyum (NCA)

Ticari ürünler ve ticari araçlarda kullanılmaktadır. Nikel, yüksek enerji yoğunluğuna fakat düşük ısıl stabiliteye sahiptir. Alüminyum ve kobalt elementlerinin eklenmesi ile yüksek enerji yoğunluğuyla beraber ortalama seviyelerde ısıl stabilite elde edilir. LCO bataryalara göre daha uzun depolama ömrü bulunmaktadır. Spesifik kapasitesi 200 mAh/g civarındadır (Nitta ve diğ, 2015).

40-70 °C gibi yüksek ortam sıcaklıkları altında katı elektrolit arayüz (KEA) büyümesi ve elektrotlar üzerinde oluşan mikro çatlaklar yüzünden kapasitesinde düşüşün ciddi seviyelerde olabildiği bildirilmiştir (Nitta ve diğ, 2015). Şekil 2.2’de NCA katotlu bataryaların kullanılmış olduğu ticari ürün örnekleri gösterilmiştir (“Dyson V8” 2021; Ayre, 2017).



Şekil 2.2 : NCA kimyada bataryaya sahip ticari ürünler. Solda Dyson V8, sağda Tesla Model S gösterilmektedir.

2.2.1.4 Lityum manganez oksit (LMO)

Lityum Manganez Oksit bataryalar 1980'lerin başında tanıtılmasına rağmen, teknolojinin ticarileşmesi 15 seneyi bulmuştur (Miao ve diğ, 2019).

3 boyutlu spinel yapıya sahiptir. Bu spinel yapı sayesinde, iyon akışı daha iyi yapılır ve daha düşük hücre iç direnci elde edilir. Manganez doğada bol bulunan bir maden olması ile Kobalta göre maliyeti daha düşüktür, ayrıca daha çevrecidir.

LMO bataryaların şarj ve deşarj akım değerleri yüksektir. 18650 paket bir hücrede 20-30 A civarı deşarj akımı verebilir. LCO bataryalara göre ısı stabilitesi daha iyidir (Miao ve diğ, 2019).

LCO bataryalara göre kapasitesi daha düşüktür ve çevrim ömrü daha kısadır. Spesifik kapasitesi yaklaşık 120 mAh/g civarındadır (Nitta ve diğ, 2015).

2.2.1.5 Lityum demir fosfat (LFP)

Düşük iç direnci sayesinde yüksek deşarj akımları verebilen bataryalardır.

Aşırı şarj olmaya karşı tahammülü yüksektir. -30°C ile +60°C arasında çalışabilirler. Isıl stabiliteyi yüksektir ve ısı sürüklenme durumu bu bataryalarda daha zor gerçekleşir. Uzun çevrim ömrüne sahiptirler.

Kendi kendine deşarj oranı, diğer teknolojilere göre daha yüksektir. Ömürlerini doldurdukça, dengeleme ile ilgili sorunlar LFP bataryalarda daha belirgin görülür. Ortalama gerilimi diğer teknolojilere göre daha düşüktür (Miao ve diğ, 2019).

Spesifik kapasitesi 165 mAh/g civarındadır (Nitta ve diğ, 2015).

2.2.2 Anot materyaline göre batarya türleri

Piyasada kullanılan bataryalar genelde karbon tabanlı anot yapıya sahip olsalar da, özel çalışma koşulları için tasarlanmış ya da gelişimi henüz sürmekte olan yeni anot materyallerinin kullanıldığı bataryalar, isimlerini yapıldıkları materyalden alırlar.

2.2.2.1 Lityum titanat oksit (LTO)

Bu anot yapısındaki bataryalar, ısı stabilite anlamında çok başarılıdır. Çok yüksek (on binler mertebesinde) çevrim ömrüne sahiptirler. Lityum dentrit oluşumu yüksek şarj akımlarında bile bu bataryalarda gerçekleşmez. LTO bataryalar, yüksek akımlı

şarj ve deşarj için çok uygundur. Şarj/deşarj esnasında hacim değişimi %0.2 gibi çok az miktarda gerçekleşir (Nitta ve diğ, 2015).

Birim hacimdeki kapasitesi yüksek olmasına rağmen spesifik kapasitesi karbon tabanlı anotlu bataryalara göre daha düşüktür (Nitta ve diğ, 2015).

Kullanılan titanyum sebebi ile pahalıdırlar ve kullanıldıkları hücrenin nominal gerilimi düşük olur (Nitta ve diğ, 2015).

Hızlı şarj edilmek üzere tasarlanan şehir içi otobüsler ya da taşınabilir medikal cihazlarda kullanım örnekleri mevcuttur (Miao ve diğ, 2019).

2.2.2.2 Lityum metal

Çok yüksek spesifik kapasiteye sahiptirler. Kullanıldıkları bataryaların nominal gerilimleri karbon tabanlı anotlara göre daha yüksektir.

Lityum dentrit oluşumu bu bataryaların en büyük dezavantajıdır. Bu sebeple kısa çevrim ömrüne sahiptirler ve güvenlik anlamında da zayıftırlar (Miao ve diğ, 2019).

Dentrit oluşumuna karşı önlem olarak, katı halde elektrolitler, elektrolitlere katkı maddesi ekleme, yapay koruyucu katman ekleme gibi yöntemler üzerine çalışmalar devam etmektedir.

2.2.2.3 Silisyum bazlı anotlar

Silisyum bazlı anotlar ile tasarlanan bataryaların spesifik kapasitesi lityum metalinden (3860 Ah kg⁻¹) bile daha yüksektir. Silisyum doğada bolca bulunur, ucuzdur ve zehirli değildir (Miao ve diğ, 2019).

Şarj anında materyal malzemesinin hacminin çok büyük oranda artması (~ %280) en büyük dezavantajıdır. Bu hacim artışı, beraberinde getirdiği mekanik gerilim ile beraber malzeme üzerinde çatlama ve kırılmalar sebep olur. Her bir şarj deşarj çevriminde bataryanın ömrü ciddi ölçüde azalır ve batarya kapasitesi düşer (Miao ve diğ, 2019).

Silisyum nanoyapılar ile, malzemenin bu dezavantajlı durumu üzerinde çalışmalar yapılmaktadır. Cep telefonları ve elektrikli taşıtlarda ticari kullanım için tasarlanan ürünler yavaş yavaş piyasada yerini almaktadır.

2.3 Fiziksel Yerleşim Yapısına Göre Batarya Türleri

Lityum iyon bataryalar farklı yerleşim yapılarında olacak şekilde üretilebilirler. Genel olarak silindirik, prizmatik ve kese tipi olmak üzere üç tipte batarya yapısı üreticiler tarafından tercih edilmektedir.

Silindirik yapıda olan bataryalar için 18650, 21700 gibi belirli standart boyutlar bulunmaktadır. Bu bataryalar mekanik bütünlük anlamında daha dayanıklıdır. Birden çok hücre ile batarya paketi oluşturulduğunda, silindirik hücreler ile oluşturulan paketin ısı yönetimi diğer yapıdaki bataryalara göre daha zordur.

Prizmatik bataryalar silindirik bataryalar gibi mekanik bütünlük ve dışarıdan gelecek mekanik baskılara daha dayanıklıdır. Anot, katot, elektrolit ve separatör gibi elemanlar sert bir dış kap içerisinde bulunurlar.

Kese tipi bataryalar mekanik bütünlük olarak diğer yapıdaki bataryalara göre nispeten daha zayıftır. Fakat dış kapları diğerlerine göre daha az hacim ve kütleye sahiptir. Spesifik enerji ve enerji yoğunluğu anlamında diğer yapıdakilere göre daha başarılıdır. Ayrıca çoklu hücre kullanımı ile oluşturulan batarya paketlerinde ısı yönetim silindirik yapıdaki bataryalara göre daha kolaydır (Miao ve diğ, 2019). Şekil 2.3'te batarya yapıları sunulmuştur.



Şekil 2.3 : Fiziksel yapılarına göre batarya tipleri. Solda kese tipi, ortada silindirik, sağda prizmatik tip gösterilmiştir (Löbberding ve diğ, 2020).

2.4 Batarya Yönetim Sistemi

Lityum iyon bataryaların güvenli çalışma bölgesi sıcaklık ve gerilim ile dar bir aralıkta sınırlıdır. Bu çalışma aralığı tek bir lityum iyon batarya hücresi için geçerli olduğu gibi seri ya da paralel bağlı olan batarya hücreleri ile oluşturulmuş batarya paketleri için de geçerlidir. Fakat hücreler batarya paketi haline geldiğinde ek güvenlik noktaları da

ortaya çıkmaktadır. Seri bağlı hücre dizininde, dizinin performansı, en zayıf hücrenin durumuna bağlıdır. Seri bağlı olan batarya hücrelerinden bazıları, diğer batarya hücrelerine kıyasla daha yüksek ya da daha düşük gerilim değerine sahip olabilirler. Bu durum hem batarya hücrelerinin eşit şekilde şarj/deşarj olmasına, hem de batarya paketinin tam kapasitesinin kullanılmasına engel olur. Ayrıca hücrelerin üzerindeki stresi artırır ve ömrünün kısılmasına ya da kimyasal yapısının bozulmasına sebep olabilir. Bu sebeplerden dolayı bataryanın ilgili parametrelerini takip etmek ve gerekli durumlarda önlem alabilmek için BYS devreleri kullanılmaktadır. Şekil 2.4'te örnek bir batarya paketi ve batarya yönetim sistemi görseli sunulmuştur.



Şekil 2.4 : Lityum iyon batarya paketi ve entegre haldeki batarya yönetim sistemi (Löbberding ve diğ, 2020).

BYS'nin parametre gözlemi, koruma, durum kestirimi ve haberleşme gibi ana işlevleri bulunmaktadır. BYS, batarya paketi içerisindeki her seri sıradaki hücrenin gerilimini gözler. Paket içerisinde, tasarımın ihtiyacı doğrultusundaki noktalardan akım ölçümü gerçekleştirir. Hücre yüzeylerinden, paketin en çok ısındığı bilinen noktalarından, ayrıca dış ortamdan sıcaklık gözlemi yapar.

Lityum iyon bataryalar hata durumlarında aşırı ısınarak yanabilir, yangına sebep olabilir ve gaz salınımında bulunabilirler. Bu durumlara karşı BYS, batarya hücresinin güvenli aralık dışına çıkmasını önlemek için bir takım koruma fonksiyonları içerir.

Akım koruması için batarya paketi oluşturulurken pasif koruma önlemleri alınmaktadır. Batarya içinde oluşabilecek hatalara karşı her hücre çıkışına sigorta ya da PTC, batarya dışında oluşabilecek hatalara karşı ana bara üzerine sigorta

bağlanabilmektedir. Buna ilave olarak, BYS ile paket ana barası akımı okunarak, ana bara üzerinde sigortadan önce devreye girebilecek, yarı iletken anahtar ya da kontaktör BYS tarafından kontrol edilebilir.

Lityum iyon batarya hücrelerinin, güvenli gerilim sınırları içerisinde kalması önemlidir. Fazla şarj edilen hücrelerin içerisindeki sıvı elektrolit, geri döndürülemez bir reaksiyon ile gaz hale geçer. Bu durum hücrenin mekanik yapısını bozduğu gibi performansını da düşürür. Aşırı düşük gerilime deşarj edilmeleri aktif materyal parçacıklarının kaybına ve akım kollektörlerinin korozyonuna sebep olur. Bu durum bataryanın tekrar şarj olamamasına sebep olmaktadır.

Batarya sıcaklığı, ayarlanan değerin üzerine çıktığında, BYS, ısıl yönetim sistemini devreye sokarak batarya sıcaklığını düşürmeye çalışır. Bu sırada şarj akımı sınırlanır veya deşarj yükü ayarı için dış haberleşme hattı üzerinden sistemi bilgilendirir. Kritik sıcaklık değerinin üzerine çıkıldığında, BYS, bataryayı çıkıştan ayırır.


Batarya sıcaklığı, ayarlanan değerin altına indiğinde ise, BYS, yine ısıl yönetim sistemini devreye sokar ve bu kez batarya sıcaklığını arttırmaya çalışır. Bu sırada şarj akımı sınırlanır.

BYS, bataryanın şarj durumu ve sağlık durumu kestirimini yapar ve genelde yüzde olarak bir sonuç hesaplar.

Batarya hücreleri, üretim aşamasındaki süreçler gereği, birbirlerinden farklılıklar gösterirler. Bunun yanında, kullanım süresi boyunca, hücrelerin paket içerisinde kullanıldıkları noktadan dolayı yaşadıkları sıcaklık değişimleri ve maruz kaldıkları farklı sıcaklık değerleri, mekanik stres, elektriksel stres gibi faktörler ile beraber, batarya hücreleri arasındaki farklılıklar artar. Bu durumda birbirlerine seri bağlı hücreler, aynı akımla şarj/deşarj edilmiş olsalar bile, gerilimleri ya da SOC değerleri farklılık gösterir.

Hücrelerin farklılık gösterdiği durumda, BYS, hücreler arası gerilim seviyelerini dengeler. Aktif ve pasif olmak üzere dengeleme yöntemleri iki ana başlığa ayrılır. Aktif dengelemede gerilimi yüksek olan hücrelerin enerjisi, düşük olanlara aktarılır. Pasif dengelemede ise, gerilimi yüksek olan hücrelerin enerjisi, bir direnç üzerinde harcanır. Aktif dengelemede, batarya enerjisi daha verimli kullanılır fakat bu yöntem pahalı ve karmaşıktır. Pasif dengeleme ucuz ve basit bir yöntem olmasına karşın

batarya enerjisi ısı enerjisine dönüştürülerek harcanır. Şekil 2.5'te temel batarya dengeleme yöntemleri gösterilmiştir.



Şekil 2.5 : Lityum iyon bataryalar için temel dengeleme yöntemleri (Özdemir, 2017).

BYS, gerilim takibi sonucunda, hücrelerden birinin sınır değerlere yaklaştığını tespit ettiğinde, dengeleme fonksiyonu ile hücre gerilimlerini benzer seviyede tutmaya çalışır. Hücre gerilimlerinin benzer seviyede tutulamadığı noktada, BYS şarj/deşarj bağlantısını keser.

2.5 Batarya Şarj Yöntemleri

Lityum iyon bataryaların şarj edilmesi, bataryanın emniyeti ve sağlığı açısından önem arz eder. Bataryalar çeşitli yöntemler ile şarj edilebilirler ve şarj esnasında akımın değişimine göre değişen şarj yaklaşımlarını, sabit akım-sabit gerilim, sabit güç-sabit gerilim, çok seviyeli sabit akım-sabit gerilim ve darbe akımlı şarj olarak sınıflandırmak mümkündür. Şekil 2.6'da farklı şarj prosedürlerinin akım ve gerilim karakteristiği görülmektedir.

2.5.1 Sabit akım-sabit gerilim yöntemi


Şarj yöntemleri arasında, kullanılan en yaygın yöntem sabit akım-sabit gerilim ile şarjdır. Bu yöntemde bataryalar, belirli bir sabit akım ile, üst gerilim limit değerine kadar şarj edilir. Ardından üst gerilim limitinde sabit bir gerilim ile, şarj akımı azalacak şekilde şarj işlemi devam eder. Sabit akım modunda batarya daha hızlı şarj olurken, akım azaldıkça şarj hızı yavaşlamaya başlar (Tomaszewska ve diğ, 2019). Sabit gerilim modunda şarj, şarj akımı belirli bir eşik değerinin altına düşünceye dek ya da belirli bir şarj süresine ulaşıncaya dek devam eder (Ayoub ve Karami, 2015).

2.5.2 Sabit güç-sabit gerilim yöntemi

Bu yöntemle yapılan şarj işleminde, şarj akımı yüksek bir değer ile başlar, zamanla batarya gerilimi yükselirken, şarj akımı da, şarj gücü sabit kalacak şekilde azalır. Sabit güç ile şarj evresi, batarya geriliminin, üst gerilim limit değerine ulaşmasına kadar devam eder (Zhang, 2006). Daha sonra, batarya sabit gerilim modunda, şarj akımı belirli bir eşik değer altına düşünceye dek ya da belirli bir şarj süresine ulaşınca dek devam eder. Şarj işleminde kullanılan güç elektroniği devrelerinin tasarlanan en yüksek güçte şarj işlemini gerçekleştirebilmeleri, bu yöntemin tercih nedenlerindendir.

2.5.3 Çok seviyeli sabit akım-sabit gerilim yöntemi

Bu yöntemde iki ya da daha fazla sabit akım seviyesi, belirli gerilim değerlerine ulaşana kadar uygulanır. Batarya geriliminin, üst gerilim limit değerine ulaşmasıyla, şarj sabit gerilim modunda devam eder. Bataryayı daha hızlı şarj etmek, ya da batarya bozulmasını yavaşlatmak amacı ile tercih edilebilir. Batarya içinde ısınmayı azaltmak, lityum kaplaması ve dendrit oluşumundan kaçınmak, mekanik zorlanmayı azaltmak için önce yüksek sabit akım ile şarja başlayıp, devamında daha düşük seviyede sabit akım ile şarjın devam ettiği uygulamalar bulunmaktadır (Tomaszewska ve diğ., 2019).



Şekil 2.6 : Şarj yöntemlerinin akım gerilim karakteristiği a) Sabit akım-sabit gerilim, b) Sabit güç-sabit gerilim, c) Çok seviyeli sabit akım-sabit gerilim, d) Darbe akımlı şarj (Tomaszewska ve diğ., 2019).

2.5.4 Darbe akımlı şarj

Darbe akımlı şarj yönteminde, şarj akımı periyodik olarak kısa dinlenme aralıkları ile kesintiye uğrar ya dadeşarj darbe akımları uygulanır. Bu yöntemde amaç, lityum iyonlarının elektrot içerisine eşit bir şekilde yerleşmesini sağlamak, mekanik zorlanmayı azaltmak, sabit gerilim modu olmadığı için batarya şarj hızının artmasını sağlamak ve batarya kullanım ömrünü arttırmaktır (Tomaszewska ve diğ, 2019; Ayoub ve Karami, 2015).

2.6 Bataryalarda Ömür Kavramı

Lityum iyon bataryalar, kullanım ömürleri boyunca, üretimden sonraki ilk durumlarına göre, başarımlarında kademeli olarak zayıflamaya başlar. Bu zayıflama ve bataryadaki bozulma durumu, hem kullanım esnasında hem de depolama esnasında görülür. Bataryalardaki bu bozulma durumu birbirleri ile ilişkili bir dizi fiziksel ve kimyasal mekanizmalar sonucu oluşmaktadır. Bataryada yaşanan bu bozulmalar, kapasitede ve güçte bataryanın başarımlarının azalmasına neden olur. Kapasite kaybı, enerjisini bataryadan alan sistemin çalışma süresinin kısalmasına neden olurken, güç kaybı, yüksek güç talep eden uygulamalarda sistemin ya yeterli düzeyde ya da hiç çalışamamasına neden olur.

Literatürde bataryanın sağlık durumu genelde kapasite ve iç direnç üzerinden olmak üzere iki farklı şekilde tanımlanır. Denklem 2.1’de kapasite üzerinden tanımı ifade edilmiştir.

$$SOH = \frac{\text{Bataryanın son durumdaki kapasitesi}}{\text{Bataryanın ilk çevrimindeki kapasitesi}} \quad (2.1)$$

Berecibar ve diğ. (2016) tarafından bahsedildiği üzere kapasitenin %80’e düşmesi, ya da Meissner ve diğ. (2012) ile Noura ve diğ. (2020) tarafından bahsedildiği üzere iç direncin %160 ile %200 civarında yükselmesi ile bataryanın kullanım ömrünün sonuna geldiği kabul edilir.

Bataryadaki bozulma durumu negatif elektrot, pozitif elektrot, elektrolit, separatör ve akım kollektörleri üzerinde görülür (Birk1 ve diğ,2017).

2.6.1 Bozulma durumunun temeli

Bataryadaki bozulma durumunu temelini takvimsel sebepler ve kullanımsal sebepler olarak iki başlık altında incelemek mümkündür.

2.6.1.1 Takvimsel sebepler

Bataryaların depolama sürecinde yaşadıkları bozulma durumunu takvimsel sebepler altında incelemek mümkündür. Depolama koşulları, bataryanın bozulmasındaki sürecin hızı hakkında belirleyici sebebi oluşturur (Barre ve diğ, 2013).

Literatürde çeşitli ortam sıcaklığı, bataryanın şarj durumu ve şarj kesme geriliminin etkileri üzerine çeşitli çalışmalar mevcuttur (Bloom ve diğ, 2001; Writght ve diğ, 2002; Ramasamy ve diğ, 2005). Yapılan çalışmalarda ortam sıcaklığının yükselmesinin, korozyon ve ayrışma gibi reaksiyonları kolaylaştırdığı, bu durumun da lityum kaybına yol açtığı ve kapasite kaybının yaşandığı görülmüştür.

Bataryanın bozulmasını etkileyen bir diğer konu, batarya şarj durumu seviyesidir. Eşit sıcaklık altında farklı şarj durumu seviyesindeki bataryalar incelendiğinde, şarj durum seviyesinin yükselmesi ile batarya bozulmasında artış görülmüştür. Şarj durumunu batarya elektrotlarındaki iyon dağılımı şeklinde düşünmek mümkündür. Şarj durumu yüksek seviyelerde iken, elektrot ve elektrolit arayüzünde büyük bir dengesizlik oluşmaktadır ve bu durum bataryanın bozulmasına sebebiyet veren reaksiyonlara sebep olmaktadır. Sıcaklık ve şarj durumu seviyesinin değişik kombinasyonları sonucu, kapasite ve iç direnç değerindeki değişim birbirine bağlı olarak, doğrusal olmayan şekilde zamanla değişmektedir. (Barre ve diğ, 2013).

2.6.1.2 Kullanımsal sebepler

Bataryanın kullanımsal olarak bozulması hem şarj hem de deşarj esnasında yaşanan bir süreçtir. Takvimsel sebeplerde anlatılan sıcaklık ve şarj durumu konularının kullanımsal süreçte etkilerinin incelenmesi üzerine çalışmalar bulunmaktadır. Ortam sıcaklığına ilave olarak bataryalar kullanım esnasında ısı açığa çıkarmaya yatkındırlar ve kullanımda bu konu da değerlendirmeye alınır (Barre ve diğ, 2013).

Yüksek sıcaklığın etkileri dışında, bataryaların şarj edilmesi anına özel olarak, düşük sıcaklığın da batarya ömrü konusunda olumsuz etkilerinin olduğu bilinmektedir. Düşük sıcaklıkta şarj işlemi, anot üzerinde lityum kaplaması ve lityum dendrit

oluşumu gibi etkiler yaratır ve bu durum kapasite kaybına sebebiyet verir (Weicker, 2014).

Şarj ve deşarj akımı büyüklüğü batarya bozulmasına etki eden sebeplerden biridir. Yüksek kapasite oranı ile yapılan şarj ve deşarj işlemleri, batarya bozulmasında hızlanmaya neden olur (Weicker, 2014).

Çevrim sırasında batarya şarj durumu değişimi Δ SOC batarya bozulmasında bir başka etkidir. Aynı başlangıç şarj durumu seviyesinde, aynı hücreler ile yapılan çevrim testlerinde Δ SOC yükseldikçe, bataryada güç kaybının daha fazla olduğu görülmektedir (Bloom ve diğ, 2001). Bu kaybın sebebi genellikle yüksek ve düşük şarj durumu seviyesi ile birlikte KEA büyümesidir. Ayrıca, elektrotlarda oluşacak bozulmalara sebebiyet veren reaksiyonlar da güç kaybına neden olurlar (Barre ve diğ, 2013).

Batarya ömür mekanizmasına etki eden konulardan bir diğeri, kullanım ömrü sırasında bataryanın görmüş olduğu yüksek/düşük gerilim değerleridir. Gerilim değerlerinin etkileri, mekanizması ve sonuçları Δ SOC ile benzerlik gösterir (Barre ve diğ, 2013).

2.6.2 Bozulma durumu etmenleri

Bataryanın bozulmasının etmenleri bir dizi kimyasal reaksiyonlara ve bu reaksiyonların etkileşimlerine dayanmaktadır. Bu reaksiyonlar batarya içinde aktif olmayan akım kollektörleri, yapıştırıcılar, iletken katkılar gibi batarya elemanlarını da etkilemektedir (Palacín, 2018).

Yan reaksiyonların kritik etkileri daha çok elektrotlar ve elektrolitin oluşturduğu arayüzde görülmektedir. Genel olarak, bozulma durumu mekanizmalarını iki elektrot arasında şarj deşarj reaksiyonu içerisinde konuk olan lityum iyonun kaybı ile birlikte katot ve anot üzerinde aktif materyal kaybı olarak sınıflandırmak mümkündür (Palacín, 2018). Bozulma mekanizması ile ilgili sebep, mekanizma, yıpranma türleri ve sonuçların birbirleri ile bağlantısı Şekil 2.7’de gösterilmiştir.

2.6.2.1 Lityum iyon kaybı

Lityum iyonları, elektrolit içerisinde şarj deşarj çevrimi sırasında bir elektrottan diğerine geçerler. Bu lityum iyonlarının batarya içindeki miktarı bataryanın kapasitesini belirleyen unsurlardan biridir.

KEA oluşumu ve büyümesi, elektrolit ayrışması, lityum kaplaması ve dendrit oluşumu gibi parazitik reaksiyonlar sonucu, batarya içerisinde bulunan lityum iyonlarının bir kısmı şarj deşarj çevriminde elektrotlara yerleşemeyecek duruma evrilir ve kapasite kaybına neden olur. Bunun dışında, lityum iyonlarının elektrotlar içindeki aktif materyallerin elektriksel izole parçacıkları arasına sıkışarak kaybolması durumu da yaşanmaktadır (Birkel ve diğ., 2017).



Şekil 2.7 : Bozulma mekanizması ile ilgili sebep sonuç bağlantıları (Birkel ve diğ., 2017).

Ticari olarak kullanılan lityum iyon bataryalarda en yaygın kullanılan anot aktif materyali grafitir. Grafitin en büyük avantajlarından birisi, şarj sonucu lityum ile dolduğunda, lityum metal referansına göre oldukça düşük gerilime sahip olması ve bu sayede yüksek hücre gerilimi elde edilebilmesidir.

Grafit anot materyaline göre daha nadir kullanılan fakat ticarileşebilmiş bir diğer materyal LTO'dur. LTO'nun çalışma durumunda stokiometri değişimine göre lityum metal referans gerilimi çok daha sabittir, fakat aynı zamanda daha yüksektir. Bu nedenle LTO anot kullanan hücrelerin gerilimleri bu nedenle daha düşüktür.

Elektrolit içerisinde bulunan organik çözücülerin elektrokimyasal gerilim kararlılık penceresi bulunmaktadır. Şarjlı haldeki grafitin düşük gerilimi bu pencerenin dışına çıkar ve grafit etrafındaki elektrolit ayrışarak grafiti kaplayacak şekilde bir KEA oluşturur. Bu arayüzün oluşumu fabrikada yapılan ilk şarj (formasyon şarjı) ile başlar ve kullanım ile birlikte KEA büyümeye devam eder. Grafit anot üzerinde olabilecek çatlama, elektrolit içerisindeki lityum tuzlarının hücre içindeki nem ile birlikte reaksiyona girerek oluşturduğu asitlerin KEA'yı aşındırması sonucu grafit tabakasının elektrolitle tekrar karşılaşması gibi durumlar yüzünden elektrolit üzerinde ayrışma ve KEA büyümesi devam eder.

KEA büyümesi, elektrolit içerisindeki lityum iyonlarının tekrar kullanılamaz şekilde bozulmasına sebep olur ve kapasite kaybına yol açarken, ayrıca anot üzerindeki aktif materyale lityum iyonlarının ulaşmasını zorlaştırarak güç kaybına da sebep olur.

Lityum kaplaması ve lityum dendrit oluşumu, lityum kaybına yol açan bir diğer sebeptir. Düşük sıcaklık altında, batarya içerisindeki lityum iyonlarının elektrot içerisine nüfuz etme hızı daha düşüktür. Düşük sıcaklıkta yüksek kapasite oranı ile şarj işlemi için batarya zorlandığında, dış devre üzerinden elektronlar hızla hareket ederken, lityum iyonları aynı hızda anot içine yerleşemez ve lityum metali olarak anot üzerine kaplanmaya ve dendritler oluşturmaya başlarlar. Dendrit oluşumu bir noktadan sonra separatörü delerek hücre içi kısa devreye yol açabilmektedir. (Plett, 2015).

LTO yapıdaki anotun şarjlı halde bile gerilimi, elektrolitin kararlılık penceresi dışına çıkmadığı için KEA oluşumu LTO hücrelerde gözlenmez. Benzer şekilde lityum kaplaması ve lityum dendrit oluşumu da gözlenmediği için LTO hücreler çok daha hızlı şarj edilebilir ve ömürleri de grafit anotlu hücrelere göre çok daha uzun olur (Tomaszewska ve diğ, 2019).

2.6.2.2 Anot aktif materyal kaybı

Şarj ve deşarj sonucu lityum iyonlarının anot aktif parçacıklarının içine girmesi ve çıkması sonucu anotun hacminde değişim meydana gelir. Zamanla, bu hacim değişiklikleri anotta çatlamalara ve bölünmelere neden olur. Grafit elektrotlarda, bu

çatlama ve bölünmeler sonucu elektrot yüzeyi ile temas eden elektrolit, KEA oluşumuna neden olur. Bu hacim değişimleri, sadece KEA üzerinde de çatlamaya yol açabilir. Bu durumda da yine anot, elektrolite maruz kalır ve KEA büyümesi oluşur.

Anot üzerinde hacim değişikliklerinin yaratmış olduğu mekanik zorlanma, anot içerisinde bulunan, aktif materyalleri birbirlerine ve akım kollektörlerine bağlayan yapıştırıcıların da işlevini yitirmesine neden olur. Elektriksel olarak akım kollektörlerinden kopan aktif materyaller kapasite kaybına sebep olur.

Eğer batarya fazla deşarj olursa, anottaki bakır akım kollektörü korozyona uğrar ve Cu^{2+} iyonlarının elektrolite karışmasına neden olur. Bu durum hem iç direncin artışı hem de Cu^{2+} iyonlarının dendrit oluşturması ile sonuçlanır (Plett, 2015).

2.6.2.3 Katot aktif materyal kaybı

Katot üzerinde, elektrot aktif materyal parçacıklarının yüzeyini kaplayan bir film bulunmaktadır. Elektrolit içerisindeki çözücüler ve katot aktif materyali arasında gerçekleşen kimyasal reaksiyon bu filmin oluşmasına neden olur, fakat bu film, anot üzerindeki film kadar batarya ömür mekanizmasında öncül bir etken değildir.

Lityum iyon kaybında anlatıldığı gibi, elektrolit içerisindeki LiPF_6 gibi lityum tuzları, su ile tepkimeye girerek HF asidi oluştururlar ve bu asit katot metallerinde çözünmeye yol açar. Asit saldırısı ile metal çözünmesi, katotta yaşanan kapasite kaybının büyük sebeplerinden biridir. LMO katotlar bu durumdan en çok etkilenen tipler arasındadır. LCO katotlarda da kobalt kaybına dayalı kapasite kaybı olur fakat LMO'ya göre daha yavaş bir süreçtir. Yüksek sıcaklık, asit saldırısının etkisini arttırıcı etki yaratır.

Bir diğer yan etki, çözünen iyonize metallerin, separatör ve anot üzerine taşınması ve buralarda bozulmalar yaratmasıdır. Bu durum hücre iç direncini arttırır ve kapasite kaybına neden olur.

Şarj ve deşarj sırasında katot içerisindeki aktif malzemeler, faz geçişi denilen, genel yapının bozulmadığı fakat elektrot materyal yapısının değişimi yönünde zorlanmaya maruz kalırlar. Bu faz geçişi genelde normal bir süreçtir ve geri döndürülebilir şekilde çalışır. Fakat aşırı şarj gibi özel durumlarda, katot içerisinde bulunan lityumdan büyük bir miktar katottan ayrılır ve katot içerisinde çökmelere neden olur. Bu durum geri döndürülemez hasara neden olur ve ani kapasite kayıpları gözlenir.

Şarjdeşarj çevriminin yarattığı zorlanma ayrıca yapısal düzensizlik adı verilen fenomene neden olur. Katot materyalinin atomlar arası kimyasal bağlarının bozulması ve farklı atomlar ile yeni form alması sonucu lityum hareketine izin veren tünel benzeri yapıda çökmeler ve bozulmalar meydana gelir. Bu durumda hem katotun bu bölümü artık kullanılamaz hale gelir, hem de bu bölüm içerisinde kalmış lityum iyonu varsa, geri döndürülemez şekilde sıkışıp kalmış olur.

LFP tipteki katotlarda, özel olarak birbirine bitişik parçacıklarda zamanla sinterlenme oluşur. Bu durum, katot aktif materyalinin toplam yüzey alanının küçülmesine ve iç direncin yükselmesine neden olur.

Son olarak, anotta olduğu gibi katotta da hacim değişikliklerinin yaratmış olduğu mekanik zorlanma, katot içerisinde bulunan, aktif materyalleri birbirlerine ve akım kollektörlerine bağlayan yapıştırıcıların işlevini yitirmesine neden olur. Elektriksel olarak akım kollektörlerinden kopan aktif materyaller kapasite kaybına sebep olur. Alüminyum akım kollektörü korozyona uğrar ve aktif materyalin elektriksel temasında azalma meydana gelir (Plett, 2015).



3. MAKİNE ÖĞRENİMİ


Bilgi teknolojilerindeki ilerlemeler ile birlikte, pek çok farklı alanda, büyük veri kaydedilebilme imkanına kavuşulmuştur. Elde edilen büyük verinin işlenmesi konusunda makine öğrenmesi kilit rol oynamaktadır. Finans sektöründe, görüntü işlemede, tıbbi tanı işlemlerinde, enerji üretimi ve gelecekte şebekeden talep edilecek yük kestiriminde; otomotiv, havacılık sektörlerinde üretim ve bakım planlamasında; ses, parmak izi, el yazısı tanımlamaları gibi pek çok alanda makine öğrenmesi yöntemleri kullanılmaktadır.

Makine öğrenmesi, insanların ve hayvanların doğal yoldan yapmış oldukları tecrübe ile öğrenme işleminin, makine tarafından veri analizi ile yapılması işlemidir. Makine öğrenimi algoritmaları, önceden belirlenmiş bir denklem ya da formülasyon olmadan, doğrudan elde edilen verilerin işlenmesi ile öğrenmek üzerine hesaplama yöntemleri kullanırlar. Çok karmaşık bir problemi, çok fazla değişkeni olan büyük miktarda veriyi, herhangi bir denklem ya da formülasyon bulunmadığı durumda, makine öğrenmesi yöntemi ile işlemek ve çözüm bulmak mümkündür.

Makine öğrenmesi yöntemleri, önceden elde edilen verileri kullanarak, bu veriler için uygun bir model oluştururlar. Yeni bir veri alındığında, makine öğrenmesi yöntemlerinden birisi ile oluşturulmuş model kullanılarak veri analiz edilir ve bir çözüm tahmininde bulunulur. Model oluşturulurken kullanılan veri seti ne kadar büyük olursa, makine öğrenmesi ile yaratılan modelin başarımı da o ölçüde iyi olur (“What Is Machine Learning? 3 Things You Need To Know”, ty).

3.1 Makine Öğrenimi Teknikleri

Makine öğrenimi tekniklerini iki ana kategori altında incelemek mümkündür. Giriş ve çıkış verilerinin bulunduğu ve bu verilere göre bir modelin eğitildiği teknik, denetimli öğrenim olarak tanımlanır. Yalnızca giriş verileri bulunan ve bu giriş verileri içerisindeki gizli kalıplar veya iç yapılar ile bir modelin eğitildiği teknik, denetimsiz öğrenim olarak tanımlanır. Şekil 3.1’de makine öğrenimi tekniklerinin sınıflandırılma şeması gösterilmiştir.



Şekil 3.1 : Makine öğrenmesi teknikleri sınıflandırılması (“What Is Machine Learning? 3 Things You Need To Know”, ty).

3.1.1 Denetimsiz öğrenim

Denetimsiz öğrenim yönteminde makine, model eğitimi, çıkışı belirli olmayan, çıkış örneği bulunmayan giriş örnek verileri ile yapar. Bu yöntemde, eldeki verilerde gizli düzenler ya da iç yapılar bulunmaya çalışılır.

Kümeleme yöntemi en yaygın kullanılan denetimsiz öğrenim yöntemidir. Bir sınıfı ya da etiketi olmayan giriş verilerinin, birbirlerine benzeyenler aynı kümede yer alacak şekilde gruplandırılması işlemidir. Kümelenme işlemi bittiğinde, model hala kümelediği verilerin hangi sınıfa ait ya da hangi etikete sahip olduğunu bilmez, sadece birbirine benzeyen verileri Grup A, Grup B mantığı ile birbirlerinden ayırabilir (Allen, 2020).

Kümeleme analizi pazar araştırması, gen dizisi analizi ve nesne tanımlama gibi uygulamalarda kullanılmaktadır (“What Is Machine Learning? 3 Things You Need To Know”, ty).

3.1.2 Denetimli öğrenim

Denetimli öğrenim yönteminde, belirsizliğin olduğu durumda, kanıta dayalı tahminlerin yapıldığı bir model oluşturulur. Denetimli öğrenme algoritmasında, bilinen bir giriş verisi seti ve bu giriş verilerine verilen yanıtı içeren çıkış verileri alınır. Yeni bir giriş veri seti girileceğinde, makul çıkış verisi tahminlerinde bulunacak bir

model eğitilir. Sınıflandırma ve regresyon, denetimli makine öğrenmesi modeli geliştirmek için kullanılan yöntemlerdir.

Sınıflandırma tekniği, ayrık yanıtların tahmininde kullanılır. Sınıflandırma probleminde hedef, verilen giriş verisinin hangi gruba ait olduğunu bulmaktır. Bir tümörün selim mi yoksa habis mi olduğu, bir fotoğraftaki canlının kedi mi ya da köpek mi olduğunun gruplandırılması, sınıflandırma tekniği için örnek olarak gösterilebilir. Bilinen bir giriş veri seti, her bir veriye uygun bir şekilde etiketlenir. Çokça veriden oluşan bir set ile model eğitilir ve yeni bir giriş verisi, eğitilmiş model kullanılarak sınıflandırılabilir (Allen, 2020; “What Is Machine Learning? 3 Things You Need To Know”, ty).

Regresyon tekniği, sürekli yanıtların tahmininde kullanılır. Regresyon probleminde hedef, giriş veri seti ile çıkış veri seti arasında bir fonksiyon eğrisi ya da yüzeyi bulmaktır. Regresyonda çıkış verisi genellikle bir sayı olur. Güneşli gün sayısına göre bir panelden yıllık olarak elde edilebilecek enerji ya da gelecekte şebekeden talep edilecek yük tahmini, regresyon tekniği için örnek olarak gösterilebilir.

Doğrusal regresyon, doğrusal olmayan regresyon, Gauss süreci regresyonu, destek vektör makinesi regresyonu, genelleştirilmiş doğrusal model, regresyon için karar ağaçları ve yapay sinir ağları yaygınca kullanılan regresyon algoritmalarındandır.


3.1.2.1 Destek vektör makinesi regresyonu (DVR)

Destek Vektör Makinesi analizi, Vladimir Vapnik ve çalışma arkadaşları tarafından 1992 yılında tanıtılan, sınıflandırma ve regresyon için kullanılan bir makine öğrenmesi algoritmasıdır (Vapnik, 1995).

DVM’leri, bir kayıp fonksiyonu ekleyerek regresyon problemlerine uygulamak mümkündür. Şekil 4.2’de, dört olası kayıp fonksiyonu gösterilmektedir (Gunn, 1998).

Şekil 3.2 a, kayıp fonksiyonu, en küçük kareler, Şekil 3.2 b, Laplasyan, Şekil 3.2 c, Huber tarafından öne sürülen kayıp fonksiyonlarını gösterir. Vapnik, Şekil 3.2 d’de görülen kayıp fonksiyonunu önermiştir (Gunn, 1998).

DVR için veri seti olarak $(x_1, y_1), \dots, (x_n, y_n)$, $x \in \mathbb{R}^n$, $y \in \mathbb{R}$ gibi verilmesi mümkündür. Burada n giriş verisinin boyutu, x ise n boyutlu uzayın elemanı olan giriş verileri olarak tanımlanır. y ilgili giriş verisine karşılık gelen çıkış verisini ifade eder.




Şekil 3.2 : Kayıp fonksiyonları.

MATLAB üzerinde bulunan Machine Learning Toolbox™ uygulaması, ϵ -duyarsız DVR algoritmasını kullanmaktadır. Burada amaç, eğitim verileri içerisindeki her x noktası için, ϵ sapmasından daha büyük olmayacak bir y sağlayacak şekilde mümkün olduğunca düzenli bir $f(x)$ fonksiyonu bulmaktır. ϵ sapmasından daha küçük hatalar dikkate alınmazken, ϵ sapmasından daha büyük hatalar kabul edilemez. Bu kısıtlar altında çözüm bulmak her zaman mümkün olmadığı için, çözüme ulaşabilmek adına gevşek değişkenler adı verilen ξ_i ve ξ_i^+ tanımlanırlar. Şekil 3.3'te ϵ -duyarsız kayıp fonksiyonu için doğrusal destek vektör regresyonu fonksiyonu, ϵ kanalı ve gevşek değişkenler gösterilmiştir.

Arzu edilen fonksiyon doğrusal ise, w ağılık vektörü, b eşik değeri olmak üzere Denklem 3.1'deki gibi ifade etmek mümkündür.

$$f(x) = \langle w, x \rangle + b \quad (3.1)$$



Şekil 3.3 : ε -duyarsız kayıp fonksiyonu için doğrusal destek vektör regresyonu (Nuhic ve diğ, 2013).

C düzenleme parametresi olmak üzere, regresyon fonksiyonunda eniyileme modeli Denklem 3.2'deki gibidir:

$$\text{enküçük} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i^+ + \xi_i^-)$$

kısıtlar;

$$y_i - \|w, x_i\| - b \leq \varepsilon + \xi_i^+ \quad (3.2)$$

$$\|w, x_i\| + b - y_i \leq \varepsilon + \xi_i^-$$

$$\xi_i^+, \xi_i^- \geq 0$$

C parametresinin sıfırdan büyük olması $f(x)$ fonksiyonunun düzenli şekilde olması ile ε sapmasından daha büyük hataların kabul edilmesi arasında ödünleşmeyi belirler.

ε sınırlarına göre y değerlerinde sapmalar kayıp olarak tanımlanır ve Denklem 3.3'teki gibi ifade edilir. Doğrusal ε -duyarsız kayıp fonksiyonu ε mesafe içerisindeki sapmaları görmezden gelir ve sıfıra eşit olarak kabul eder.

$$L\varepsilon = \begin{cases} 0 & \text{eğer } |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon & \text{diğer durumlarda} \end{cases} \quad (3.3)$$

İkili eniyileştirme problemi, daha önce açıklanan eniyileştirme problemine göre daha kolay bir çözüm sunar, ayrıca DVR'nin doğrusal olmayan fonksiyonlara

uygulanabilmesini sağlar. α_i ve α_i^* , negatif olmayan Langrange çarpanları olmak üzere ikili formülasyon Denklem 3.4'teki gibi ifade edilebilir:

$$L(\alpha) = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) x_i' x_j + \varepsilon \sum_{i=1}^n (\alpha_i - \alpha_i^*) + \sum_{i=1}^n y_i (\alpha_i^* - \alpha_i)$$

$$\sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \quad (3.4)$$

$$0 \leq \alpha_n \leq C$$

$$0 \leq \alpha_n^* \leq C$$

w parametresi Denklem 3.5'teki gibi tanımlanabilmektedir:

$$w = \sum_{i=1}^n (\alpha_i - \alpha_i^*) x_i \quad (3.5)$$

Destek vektörlere dayanarak yeni değerlerin kestirimi için kullanılan fonksiyon Denklem 3.6'daki gibidir:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b \quad (3.6)$$

En iyi sonucun elde edilmesinde Karush-Kuhn-Tucker koşulları gereklidir. Doğrusal DVR için bu koşullar Denklem 3.7'de gösterilmiştir:

$$\begin{aligned} \alpha_i (\varepsilon + \xi_i^+ - y_i + x_i' w + b) &= 0 \\ \alpha_i^* (\varepsilon + \xi_i^- + y_i - x_i' w - b) &= 0 \\ \xi_i^+ (C - \alpha_i) &= 0 \\ \xi_i^- (C - \alpha_i^*) &= 0 \end{aligned} \quad (3.7)$$

Eğitimden sonra, ε kanalı içerisinde kalan veri noktaları için Lagrange çarpımları α_i ve α_i^* sıfır değerlerini alırlar. α_i veya α_i^* çarpımlarından birinin sıfır olmadığı durumda ilgili veri noktaları destek vektörü olarak adlandırılırlar.

3.1.2.2 Gauss süreci regresyonu (GSR)

GSR algoritması, çok boyutlu, küçük verisetlerinde ve doğrusal olmayan, karmaşık regresyon problemlerinde kullanılan yöntemlerden birisidir. DVR yönteminden farklı olarak, GSR, regresyon fonksiyonunu tanımlarken, verilerin eğitimi sırasında olasılık

yöntemini kullanmaktadır. GSR, bir olasılık fonksiyonunu tanımlayarak ampirik riski yansıtır ve sonsal olasılık hipotezini elde etmek için Bayes teorisini kullanmaktadır (Williams & Rasmussen, 1996).

Gauss sürecini, Gauss dağılımını izleyen sınırlı sayıda rastgele değişkenin bir birleşimi olarak ifade etmek mümkündür. Eğitim verileri için x giriş verileri, y çıkış verileri kabul edilsin. D boyutlu n tane x giriş verisi vektörü $X=\{x_1^D, x_2^D, x_3^D, \dots, x_n^D\}$ olarak ifade edilirse, bu verinin çok değişkenli Gauss dağılımını ortalama fonksiyon $m(x)$ ve kovaryans fonksiyon $k_f(x, x')$ ile birlikte $f(x)$ olarak tanımlamak mümkündür. Ortalama fonksiyon ve kovaryans fonksiyon Denklem 3.8'deki tanımlanabilir.

$$\begin{cases} m(x) = E(f(x)) \\ k_f(x, x') = E[(m(x) - f(x))(m(x') - f(x'))] \end{cases} \quad (3.8)$$

Gauss süreci, fonksiyon üzerine istatistiksel bir dağılım tanımlar ve Denklem 3.9'daki gibi gösterilir:

$$f(x) \sim GS(m(x), k_f(x, x')) \quad (3.9)$$

Çıkış verisi vektörü $y=\{y_1, y_2, y_3, \dots, y_n\}$ olarak ifade edilirse, regresyon problemi için, x giriş verileri ile y çıkış verileri arasındaki ilişki için örtülü bir $f(x)$ fonksiyonu, ε olarak gösterilen sıfır ortalamaya ve σ^2 varyansa sahip $\varepsilon \sim N(0, \sigma_n^2)$ Gauss dağılımlı gürültü verileri ile birlikte Denklem 3.10'daki gibi ifade edilebilir. Farklı giriş serisi verileri için gürültü vektörü $\varepsilon = \{\varepsilon_1, \varepsilon_2, \varepsilon_3, \dots, \varepsilon_N\}$ bağımsız ve özdeş olarak dağıtılmış bir seri oluşturur.

$$y = f(X) + \varepsilon \quad (3.10)$$

GSR algoritmasında, $f(x)$ fonksiyonu özellikleri için önsel varsayımları elde edebilmesi sebebiyle çekirdek fonksiyonu $k_f(x, x')$ önemli bir role sahiptir. Çeşitli çekirdek fonksiyonlar bulunmakla birlikte, MATLAB programı, rasyonel kuadratik, kare üstel, Matern 5/2 ve üstel çekirdek fonksiyonları kullanımına imkan vermektedir.

Denetimli öğrenim yönteminde, giriş verisi x_i 'ye benzeyen bir giriş verisinin, çıkış verisi y_i 'ye benzer şekilde yakın olması beklenir. Gauss sürecinde de kovaryans fonksiyonu bu benzerliği yansıtır ve x_i ve x_j giriş verisi vektörleri ile $f(x_i)$ ve $f(x_j)$

fonksiyonları arasındaki kovaryansı belirtir. Bir x_i noktasındaki cevabın, diğer x_j , $i \neq j$, $i = 1, 2, \dots, n$ noktalarındaki cevaplardan nasıl etkilendiğini belirler.

σ_f^2 , $f(x)$ fonksiyonu varyasyonları kontrolünü sağlayan parametreyi, l her giriş verisi vektörü için karakteristik uzunluk ölçeğini ifade eden parametreyi ifade etmek üzere kare üstel çekirdek fonksiyonu Denklem 3.11'deki gibi genel olarak ifade edilir.

$$k_f(x, x') = \sigma_f^2 \exp\left(\frac{-(x - x')^2}{2l^2}\right) \quad (3.11)$$

Her giriş verisi vektörünün D boyutlu olduğu durumda bu ifade Denklem 3.12'deki gibi düzenlenebilir:

$$k_f(x_i, x_j) = \sigma_f^2 \exp\left(\frac{-1}{2} \sum_{d=1}^D \frac{(x_i^d - x_j^d)^2}{l_d^2}\right) \quad (3.12)$$

I , n boyutlu birim matris olmak üzere, gürültü kovaryans matrisi $\sigma_n^2 I$ Denklem 3.12'ye eklendiğinde Denklem 3.13 elde edilir.

$$k(x_i, x_j) = k_f(x_i, x_j) + \sigma_n^2 I \quad (3.13)$$

Giriş verileri vektörü X ve örütülü fonksiyon f dikkate alındığında, y 'nin dağılımı Denklem 3.14'teki gibidir:

$$p(y|f, X) = N(f, \sigma_n^2 I) \quad (3.14)$$

K çekirdek matris olmak üzere, y 'nin marjinal dağılımı Denklem 3.15'teki gibidir:

$$p(y|X) = \int p(y|f, X) p(f|X) df = N(0, K + \sigma_n^2 I) \quad (3.15)$$

$p(f|X)$ dağılımını $N(0, K)$ ifadesi olarak tanımlamak mümkündür. Hiperparametre seti ençok olabilirlik yöntemi ile $\Theta = [\sigma_f, l, \sigma_n]$ olarak belirlenebilir. Ençok olabilirlik yönteminin amacı, logaritmik olabilirlik fonksiyonunu Denklem 3.16'da görüleceği üzere en çoklamaktır (Yang ve diğ, 2018).

$$L = \log p(y|X, \Theta) = -\frac{1}{2} \log(\det(K + \sigma_n^2 I)) - \frac{1}{2} y^T [K + \sigma_n^2 I]^{-1} y - \frac{n}{2} \log 2\pi \quad (3.16)$$

Logaritmik olabilirlik fonksiyonunun kısmi türevi alınarak hedef fonksiyonun en çok değeri, Θ_i hiper parametre setinin bir elemanı olmak üzere Denklem 3.17'deki gibi elde edilir.

$$\begin{cases} \frac{\partial}{\partial \Theta_i} \log p(y|x, \Theta) = \frac{1}{2} \text{tr} \left\{ \left[\alpha \alpha^T - (K + \sigma_n^2 I)^{-1} \frac{\partial (K + \sigma_n^2 I)}{\partial \Theta_i} \right] \right\} \\ \alpha = [K + \sigma_n^2 I]^{-1} y \end{cases} \quad (3.17)$$

Böylelikle GSR modeli elde edilmiş olunur. x eğitim veri seti kullanılarak hazırlanmış model için yeni x^* verisi kullanılarak y^* verisinin Denklem 3.18'deki gibi önsel dağılımı elde edilir.

$$\begin{bmatrix} y \\ y^* \end{bmatrix} \sim N \left(0, \begin{bmatrix} K_f(x, x) + \sigma_n^2 I & K_f(x, x^*) \\ K_f(x, x^*)^T & K_f(x^*, x^*) \end{bmatrix} \right) \quad (3.18)$$

Önsel dağılımını Gauss dağılımı takip ederek, sonsal dağılım Denklem 3.19, 3.20 ve 3.21'deki gibi elde edilir.

$$y^* = K_f(x, x^*)^T [K_f(x, x) + \sigma_n^2 I]^{-1} y \quad (3.19)$$

$$\text{kov}(y^*) = K_f(x^*, x^*) - K_f(x, x^*)^T [K_f(x, x) + \sigma_n^2 I]^{-1} K_f(x, x^*) \quad (3.20)$$

$$p(y|x, y, x^*) = N(y|y^*, \text{kov}(y^*)) \quad (3.21)$$

Çıkış verisinin ortalaması, test verisetinin bir tahmini sonucudur. Denklem 3.20'de gösterilen tahmini dağılım varyansı $\text{kov}(y^*)$, test çıktısının güvenilirliğinin ölçülmesinde kullanılır (Li ve diğ, 2019).

3.1.2.3 Doğrusal olmayan dışsal girdili otoregresif ağ (NARX)

Yapay sinir ağları, biyolojik sinir sisteminden uyarlanmış, esinlenilmiş matematiksel araçlardır. Bilgiyi öğrenmek, saklamak ve gerektiğinde kullanmak, hafızadan geri çağırmak için kuvvetli bir yeteneğe sahiptirler. Yapay sinir ağları, girdi ve çıktılar arasındaki ilişkinin bilinmediği durumlarda m boyutlu bir girdi uzayının, n boyutlu bir çıktı uzayına doğrusal olmayan eşleşmesini gerçekleştirme yeteneğine sahip kara kutu modelleme araçları olarak da tanımlanabilirler. Kümeleme, sınıflandırma, regresyon ve optimizasyon problemleri için kullanılırlar. NARX modelleri, doğrusal olmayan dinamik sistemlerin modellenmesi için kullanılabilir. Özellikle zaman serisi modellemeleri için tercih edilen bir yöntemdir (Boussaada ve diğ, 2018).


NARX, tekrarlayan sinir ağları yapısının bir çeşididir (Khaleghi ve diğ, 2021). Tekrarlayan sinir ağları, önceki çıktıların, girdi olarak kullanılabildiği bir sinir ağları sınıfıdır (Amidi & Amidi, t.y). Diğer tekrarlayan sinir ağlarından farklı olarak, ağın birkaç katmanını kapsayan geri bildirim bağlantılarına sahiptir (Khaleghi ve diğ, 2021). Doğrusal olmayan zaman serilerinde başarılı tahminlerde bulunmak için, gerçek ya da tahmin edilmiş önceki değerlerin kullanılabildiği hafıza yeteneği bu yöntemde kullanılmaktadır (Boussaada ve diğ, 2018).

NARX, giriş, gizli katman ve çıkış katmanı olmak üzere iki katlı ileri beslemeli (feedforward) ağ ve çıkıştan oluşur. Ayrıca öndeğer (b), giriş ağırlığı (IW), katman ağırlığı (LW) değerleri içerir. f_1 gizli katmandaki aktivasyon fonksiyonu ve f_2 çıkış katmanı aktivasyon fonksiyonudur (Khaleghi ve diğ, 2021). Gizli katmanda f_1 için ağdaki girişleri $[-1,1]$ aralığında ölçeklendirmek ve geri yayılım hesaplamaları uygulanırken hata oranını düşürmek için sigmoid fonksiyon kullanılır. Çıkış katmanında f_2 için doğrusal fonksiyon kullanılır (Katic ve diğ, 2018). Başlangıçta, ağırlıklar rastgele şekilde belirlenir. Eğitim sürecinde yapay sinir ağlarının ürettiği çıkış değer, hedef değere yakın olacak şekilde bu ağırlıklar yeniden düzenlenirler (Boussaada ve diğ, 2018).

Eğitime başlamadan önce, giriş ve geribesleme zaman gecikmeleri ile gizli katmanın boyutu, geribesleme türü ve eğitim fonksiyonu bilgilerini belirlemek gereklidir. ZGH zaman gecikmesi hattını ifade etmek üzere, NARX yapısını anlatan detaylı şema Şekil 3.4'te verilmiştir.

NARX, paralel (kapalı çevrim) ve seri-paralel (açık çevrim) olmak üzere iki geribesleme türü içermektedir. Paralel tür ile NARX tasarımı, kestirilen hedef değeri ileri beslemeli sinir ağının zaman gecikme hattına geribeslemeye bulunur. Paralel tür için matematiksel ifade, $\hat{y}(t)$ geçmişteki çıkış verilerinin devamı mahiyetinde t anındaki kestirilen çıkış verisi ve $x(t)$ t anındaki dışsal giriş verisi olmak üzere Denklem 3.22’de verilmiştir. $F(.)$ doğrusal olmayan eşleşme fonksiyonu, d_y çıkış verisindeki zaman gecikmesi, d_x giriş verisindeki zaman gecikmesini ifade eder (Boussaada ve diğ, 2018).

$$\hat{y}(t) = F [\hat{y}(t-1), \hat{y}(t-2), \dots, \hat{y}(t-d_y), x(t-1), x(t-2), \dots, x(t-d_x)] \quad (3.22)$$



Şekil 3.4 : NARX şema gösterimi (Khaleghi ve diğ, 2021).


Gerçek hedefe erişilebildiği durumda, paralel türden farklı olarak seri-paralel tür ile NARX tasarımı, kestirilen hedef yerine, ileri beslemeli sinir ağının gecikme hattına geribesleme gerçek hedef ile yapılır. Seri-paralel tür için matematiksel ifade, $y(t)$ t anındaki gerçek çıkış verisini ifade etmek üzere Denklem 3.23’te verilmiştir (Boussaada ve diğ, 2018).

$$\hat{y}(t) = F [y(t-1), y(t-2), \dots, y(t-d_y), x(t-1), x(t-2), \dots, x(t-d_x)] \quad (3.23)$$

Paralel ve seri-paralel NARX yapılarının şema gösterimi Şekil 3.5’te gösterilmiştir.

NARX eğitim başarımını denetlemek ve hatayı enküçüklemek için çeşitli başarımlar ölçütleri kullanılabilmektedir. Bu çalışmada, hataların karelerinin ortalaması (mean square error – MSE) fonksiyonu tercih edilmiştir. MSE fonksiyonu Denklem 3.24’te gösterilmiştir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (3.24)$$



Şekil 3.5 : NARX yapıları şema gösterimi a) Seri-paralel tür, b) paralel tür (Boussaada ve diğ, 2018).

MSE'yi en çabuk şekilde azaltmak için ağırlık ve öndeğer üzerinde düzenlemeler yapılır. Bu işlem için kullanılan metotlardan biri geri yayılım (back propagation) algoritmasıdır (Aşkın ve diğ, 2011). Birinci dereceden türev kullanılarak, ileri besleme hattı üzerinden geriye doğru yayılımın yapıldığı bu yöntemin hız ve verim anlamında zayıflıkları bulunmaktadır (Karaatlı ve diğ, 2020). Gradyan iniş ve Gauss-Newton iterasyon modelinin kombinasyonunu oluşturan Levenberg-Marquart (LM) yöntemi, ikinci dereceden türev gerektiren algoritmaların hızlı şekilde gerçekleştirilmesini sağlar ve özellikle az sayıda gizli nöron ve ağırlık içeren ağlarda etkili bir şekilde kullanılır (Khaleghi ve diğ, 2020). Bayes düzenlemesi (BD) yönteminde, hata fonksiyonunu en aza indirecek şekilde ağırlıkların seçildiği geleneksel eğitim yönteminden farklı olarak, ağırlıkların olasılık dağılımı mevcuttur. Bu durumda ağırlık kestirimi bir olasılık dağılımının sonucu olur (Khaleghi ve diğ, 2021). BD yönetimi ile eğitim daha uzun süre alır fakat küçük verisetleri için daha başarılı sonuç verir (Khaleghi ve diğ, 2020).

4. BATARYA SAĞLIK DURUMU KESTİRİMİ

Bataryaların sağlık durumu kestirimi için veri tabanlı yöntemler, sade bir kullanıma imkan vermeleri, pratik uygulamalarda kullanılabilir olmaları ve isabetli sonuçlar vermeleri ile gün geçtikçe daha çok ilgi görmektedirler. BYS'lerden doğrudan elde edilebilen gerilim, akım, süre, kapasite gibi bilgiler ile veri tabanlı yöntemler kullanılarak batarya sağlık durumu kestirimi yapılması mümkündür.

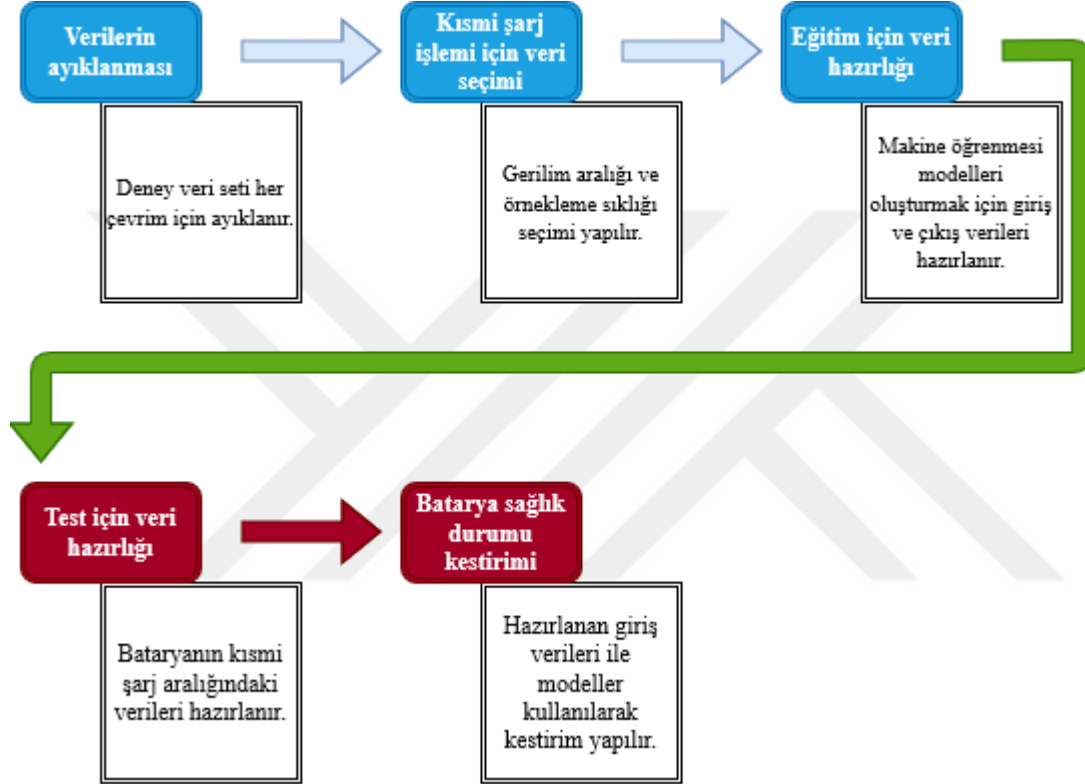
Gerçek hayat uygulamalarında, sistemlerde kullanılan bataryalar, değişik yükler altında, farklı deşarj akımları ve profillerine maruz kalmalarına karşılık, şarj işlemi sırasında, genellikle belirli bir şarj ekipmanı ile kararlı bir şekilde şarj edilirler.

Bataryaların kullanım durumları, genellikle sabit bir senaryoda olmamaktadır. Bataryalar, kullanıcı tarafından her zaman tam şarjlı ve tam deşarjlı olacak şekilde kullanılmayabilmektedir. Bunun dışında, tam şarj süreci boyunca BYS tarafından elde edilen bilgi kayıtlarının sayısı binler mertebesinde olabilmektedir. Bu durum verinin yönetilmesi, aktarılması, işlenmesi gibi durumları oldukça zorlu hale getirebilmektedir.

Bu çalışmada, bahsedilen durumlar dikkate alınarak, giriş verisi olarak lityum iyon bir bataryanın şarj anında ve BYS tarafından elde edilebilecek verilerden biri olan kapasite verisi kullanılmıştır. Kısmi bir şarj gerilim aralığında ve belirli örnekleme aralığında batarya verileri kullanılarak, ömür kestirimi, DVR, GSR ve NARX yöntemleri ile yapılmıştır. Bu başlık altında, bu çalışmada kullanılan hücrelerin özellikleri, batarya yıpranması deneyi sonucu paylaşılan veriler, makine öğrenmesi için giriş verilerinin seçim kararı, makine öğrenmesi yöntemleri ile model hazırlanması anlatılmıştır. Hazırlanan modellerde seçilen giriş verilerinin kullanımı ile yapılan batarya ömür kestirimi için karşılaştırmalı sonuçlar sunulmuştur.

Şekil 4.1'de bu çalışmada, batarya sağlık durumu kestirimi elde etmek için yapılmış olan işlem adımları gösterilmiştir. İşlem adımları iki ana bölüm altında ayrılmıştır. İlk bölümde deneysel olarak elde edilen batarya verileri ayıklanmış, sağlık durumu için seçilecek kısmi şarj verileri üzerinde inceleme yapılmış ve seçilen veriler eğitim için

kullanılarak her yöntem için model oluşturulmuştur. İkinci bölümde test için kullanılacak veriler ayrıştırılmış ve ilk bölümde oluşturulan modeller kullanılarak batarya sağlık durumu kestirimi yapılmıştır. Çalışma özelinde, tüm batarya verileri test edildiği için ilk bölümün son adımı ile ikinci bölümün ilk adımı ortaktır. Çalışmada kullanılanlar dışında yeni bir batarya hücresi ile yalnızca ikinci bölümdeki adımlar izlenerek batarya sağlık kestirimi yapabilmek mümkündür. İlk bölümdeki adımlar için mavi, ikinci bölümdeki adımlar için kırmızı arkaplan rengi kullanılmıştır.




Şekil 4.1 : Batarya sağlık durumu kestirimi elde etmek için oluşturulan iş akışı diyagramı.

4.1 Çalışmada Kullanılan Batarya Hücresi Verileri

Yapılan çalışmada, Oxford Üniversitesi, Howey Araştırma Grubu tarafından batarya yıpranması üzerine deneyi yapılan ve sonuçları paylaşılan batarya verileri referans alınmıştır (Birkel, 2017a). Paylaşılan veriler, 8 adet, Kokam firmasının SLPB533459H4 ürün kodlu, karbon tabanlı anot ve lityum kobalt oksit katot yapısında, 740 mAh nominal kapasiteye sahip kese tipi hücrelere ait deney sonuçlarını içermektedir.

Hücreler 40°C sıcaklıktaki ısıtılabilir kabinler içerisinde tutularak test edilmişlerdir. Verileri yayınlayan araştırmacılar, batarya çevriminin sabit akım-sabit gerilim şarj

prosedüründen sonra, ARTEMIS Avrupa şehiriçi sürüş çevrim profilindeki (Andre, 2004) hızlar için kendi hazırladıkları bir araç modeline göre, batarya test cihazının kabiliyetlerini de kısıt olarak alarak, en fazla 5A deşarj akımı sınırı ile oluşturulan bir profile göre bataryayı deşarj etmişlerdir. Deşarj profili 52 dakika boyunca uygulanmıştır. Deşarj işlemi, batarya ömrünün sonuna yaklaştığında hücrenin düşük gerilim limitine takılarak yarım kalmasını engellemek için yaklaşık %44 SOC değerine kadar olacak şekilde ayarlanmıştır (Birkel, 2017b). Deşarj akım profili Şekil 4.2’de gösterilmiştir.




Şekil 4.2 : Deşarj akım profili (Birkel, 2017a).

Araştırmacılar tarafından, bahsedilen çevrimden 100 kere yapıldıktan sonra, karakterizasyon testi olarak 1 çevrim 1-C sabit akım ile şarj, sabit akım ile deşarj testi yapılmış ve sonuç olarak bu testlerin verileri paylaşılmıştır. Karakterizasyon için yapılan testlerde, batarya üreticisinin belirtmiş olduğu alt ve üst gerilim sınır değerleri 2,7 ile 4,2 V gerilim aralığında çevrimler yapılmıştır.

Paylaşılan test verileri, test süresi, gerilim, kapasite ve sıcaklık bilgilerini içermektedir. Veriler, her 1 s sürede bir elde edilmiştir. Test verileri, ayrıca Battery Archive internet sitesi üzerinde, Excel dokümanı olarak da paylaşılmıştır ve bu çalışmada kullanım için tercih edilmiştir (“Battery Archive”, 2021).

Çalışmada kullanılan bataryalardan, birinci ve ikinci bataryaya ait 5700. çevrime kadar 53 adet, üçüncü bataryaya ait 6100. çevrime kadar 56 adet, dördüncü bataryaya ait 4600. çevrime kadar 44 adet, beşinci bataryaya ait 4800. Çevrime kadar 45 adet, altınca bataryaya ait 5000. Çevrime kadar 46 adet, yedinci bataryaya ait 8100. Çevrime kadar 77 adet, sekizinci bataryaya ait 6400. Çevrime kadar 59 adet çevrim verisi kullanılmıştır. Genel olarak her yüz çevrimde bir veri paylaşılmasına karşılık, 1500., 1700., 3400., 4700., 4900. çevrim verileri hiçbir batarya için bulunmamaktadır. Bunun dışında üçüncü batarya için 3300., sekizinci batarya için 200. Çevrim verisi bulunmamaktadır.

Bataryaların çevrim sayısına göre sağlık durumu değişimi Şekil 4.3'te gösterilmiştir.



Şekil 4.3 : Çalışmada kullanılan bataryaların çevrim sayısına göre sağlık durumu değişimleri.

4.2 Batarya Sağlık Durumu Kestirimi Çalışması için Kullanılan Verilerin Seçimi ve Sonuçlar için Başarım Kriteri

Bataryaların şarj karakteristikleri, sabit akım altında şarj gerçekleştiği durumda bile doğrusal değildir. Sabit akım ile şarj esnasında, zamana göre gerilim değerleri, doğrusal olmayan şekilde değişmektedirler. Bu duruma bağlı olarak gerilim değişimi aralığında kapasite değişimi de doğrusal olmamaktadır.


Bunun dışında, bataryanın sağlık durumu değişimine bağlı olarak, batarya şarj karakteristiği incelendiğinde, sabit akım ile gerçekleşen şarj süresi ve şarj gerilimi

değişimine göre kapasite artışında da doğrusal olmayan değişimler gözlenir. Batarya sağlık durumu düştükçe sabit akım şarj süresinin kısaldığı ve şarj kapasitesinin azaldığı görülür.

4.2.1 Örnek batarya için veri derlemesi


Çalışmada kullanılan bataryalar aynı üretici koduna sahip, aynı özellikteki bataryalardır ve bataryaların şarj işlemi esnasında gerilime göre kapasite değişimleri ve zamana göre gerilim değişimleri benzer karaktere sahiptir. Özet bir gösterim için batarya 1'e ait veriler ile oluşturulan görseller bu başlık altında sunulmuştur.

Şekil 4.4'te çalışmada verileri kullanılan bataryalardan 1. bataryanın şarj durumundaki zamana bağlı gerilimi ve bataryanın çevrim sayısına göre değişimi gösterilmiştir.



Şekil 4.4 : 1. bataryanın çevrim sayısına göre zamana bağlı şarj gerilimi grafiği.

Şekil 4.5'te 1. Bataryanın şarj esnasında gerilime bağlı olarak kapasitesi ve çevrim sayısına göre değişimi gösterilmiştir.



Şekil 4.5 : 1. bataryanın çevrim sayısına göre gerilime bağlı şarj kapasitesi grafiği.

Literatürde yapılan araştırmalara göre, batarya şarj kapasitesinin, bataryanın sağlık durumu ile ilgili önemli veriler içerdiği bilinmektedir (Stroe ve diğ, 2018; Schaltz ve diğ, 2018).

Bu çalışmada, modellerde giriş verisi olarak kullanılmak üzere bataryanın şarj esnasında belirli gerilim değerleri arasındaki şarj kapasite verileri kullanılmıştır. Bataryanın orta değerlerine yakın SOC durumunu kapsamayı, nispeten kısa süredeki şarj aralığı nedenlerine ek olarak, Şekil 4.4 ve Şekil 4.5'te görülebileceği üzere bataryanın yıpranması ile karakter değişiminin daha belirgin görüldüğü 3,60-3,80 V ve 3,80-4,00 V gerilim aralıkları çalışma için seçilmiştir. Ayrıca gerilim aralığı genişliğinin etkisini de görebilmek adına 3,60-3,65 V gerilim aralığındaki veriler üzerinde de çalışılmıştır.

Bataryanın sağlık durumu Denklem 2.1'deki gibi değerlendirilmiştir. Çalışmalar, batarya sağlık durumunun %80'e kadar düştüğü aralık için gerçekleştirilmiştir.

Başarım ölçütü için kriter olarak, Hata Kareleri Ortalamasının Karekökü (Root Mean Square Error-RMSE) kullanılmıştır. Batarya sağlık durumu verisi yüzde cinsinden ifade edilmiştir (Örnek: İlk çevrim için 100.). RMSE başarım kriteri Denklem 4.1'deki gibi hesap edilmektedir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (4.1)$$

Çalışmada kullanılmak üzere, test veri örnekleme aralığı için başlangıç gerilim değerinden itibaren 10 mV ve 50 mV gerilim artışında kapasite artış değerleri seçilmiştir. Bu artış verileri alınarak, 1. batarya için 3,60-3,65 V gerilim aralığı ve 3,60-3,7 V gerilim aralığında DVR, GSR ve NARX ile sağlık durumu kestirimi modeli yapılmış ve yine 1. batarya üzerinde başarımları incelenmiştir. Üç farklı modelde de giriş ve çıkış verisetleri ortak olarak kullanılmıştır.

Çizelge 4.1’de DVR, Çizelge 4.2’de GSR ve Çizelge 4.3’te NARX ile yapılan kestirim çalışmasında 10 mV ve 50 mV için başarımları sonuçları gösterilmiştir.

Çizelge 4.1 : Örnekleme aralığı için DVR başarımları sonuçları.

Gerilim aralığı	Örnekleme aralığı	RMSE	Veri boyutu
3,60-3,65 V	10 mV	1,0683	5 kB
3,60-3,65 V	50 mV	1,6325	2 kB
3,60-3,7 V	10 mV	0,8941	8 kB
3,60-3,7 V	50 mV	1,3979	3 kB

Çizelge 4.2 : Örnekleme aralığı için GSR başarımları sonuçları.

Gerilim aralığı	Örnekleme aralığı	RMSE	Veri boyutu
3,60-3,65 V	10 mV	1,0558	5 kB
3,60-3,65 V	50 mV	1,1649	2 kB
3,60-3,7 V	10 mV	0,9509	8 kB
3,60-3,7 V	50 mV	1,0204	3 kB

Çizelge 4.3 : Örnekleme aralığı için NARX başarımları sonuçları.

Gerilim aralığı	Örnekleme aralığı	RMSE	Veri boyutu
3,60-3,65 V	10 mV	0,3494	5 kB
3,60-3,65 V	50 mV	0,3818	2 kB
3,60-3,7 V	10 mV	0,2095	8 kB
3,60-3,7 V	50 mV	0,2381	3 kB

Yapılan incelemede, örnekleme aralığı olarak 50 mV seçmenin başarımları olarak %0,0314 gibi oldukça küçük farklar ile daha kötü sonuç vermesine karşın, veri boyutu olarak %62,5 azalma getirdiği tespit edilmiş ve çalışmanın devamında 50 mV örnekleme aralığı ile giriş verilerinin seçilmesine karar verilmiştir.

4.3 DVR ile Batarya Sağlık Durumu Kestirimi

MATLAB programı içerisindeki Regression Learner uygulaması, MATLAB çalışma alanı içerisindeki veriler ile bir veri seti oluşturan arayüze sahiptir. Veri seti değişkeni olarak öncelikle giriş verilerini, ardından bu giriş verileri ile ilgili yanıt verilerini seçtirmektedir.

Yapılan çalışmada, toplam sekiz adet bataryanın altı tanesine ait veriler, genelleştirilmiş bir model elde edebilmek amacıyla eğitim için kullanılmış, kalan iki adet batarya verisi ile de modelin başarımı test edilmiştir. Toplamda dört farklı model oluşturularak, çiftler halinde bütün bataryalar için batarya sağlık kestiriminde bulunulmuştur.

Giriş verisi olarak, öncelikle her bir batarya için, her yüz çevrimde bir elde edilen şarj anına ait kapasite verileri bir $[1 \times N]$ şeklinde matris halinde hazırlanmış, sonrasında altı adet bataryanın verileri birleştirilmiştir. Çıkış verisi olarak da, yine her bir batarya için her yüz çevrimde bir elde edilen deşarj kapasitesi ile hesaplanan batarya sağlık durumu bir $[1 \times N]$ şeklinde matris halinde hazırlanmış, sonrasında altı adet bataryanın verileri birleştirilmiştir.

Regression Learner uygulaması ile giriş ve yanıt verileri seçildikten sonra, uygulama, doğrulama yöntemi seçimi için imkan sunmaktadır. Yapılan çalışmada doğrulama yöntemi olarak beş katlamalı çapraz doğrulama yöntemi seçilmiştir. Bu doğrulama yönteminde veri seti beş parçaya bölünmekte, dört parça eğitim seti olarak, bir parça ise test seti olarak kullanılmaktadır. Her defasında beş parçaya bölünen verilerden biri test seti olarak, diğerleri eğitim seti olarak kullanılır ve beş denemenin ortalama hatası hesaplanır. Böylelikle eğitilen modelin yeni veriler için genelleşme yeteneği ölçülür ve aşırı uyuma (overfitting) karşı koruma sağlanmış olur.

Veri seti ve doğrulama yöntemi seçildikten sonra, verilerin eğitileceği yöntemin seçilmesi gerekmektedir. Regression Learner uygulaması ile Destek Vektör Makineleri için çekirdek fonksiyonu olarak, doğrusal, kuadratik, kübik fonksiyonlara ilave olarak üç farklı Gauss tabanlı çekirdek fonksiyonu ile model oluşturulabilmektedir. Yapılan denemelerde kuadratik çekirdek fonksiyonun en başarılı sonuçları verdiği görülmüş ve kestirim modeli için bu çekirdek fonksiyon kullanılmıştır.

4.4 GSR ile Batarya Sağlık Durumu Kestirimi

MATLAB programı içerisindeki Regression Learner uygulaması, DVR ile benzer şekilde GSR için de kullanılabilir. Veri seti değişkeni olarak giriş verileri ve bu giriş verileri ile ilgili yanıt verilerinin arayüz üzerinde girilmesi gerekmektedir.

Giriş verileri ve çıkış verileri olarak DVR için kullanılan ile aynı veri seti kullanılmıştır. DVR ile aynı şekilde sekiz adet bataryanın altı tanesine ait veriler eğitim amaçlı kullanılmış, kalan iki adet batarya test için saklanmıştır.

Oluşturulan eğitim ve test verisi kombinasyonları Çizelge 4.4'teki gibidir:

Çizelge 4.4 : Eğitim ve test için kullanılan bataryalar.

Eğitim Seti	Test Seti
3,4,5,6,7,8	1,2
1,2,5,6,7,8	3,4
1,2,3,4,7,8	5,6
1,2,3,4,5,6	7,8

Doğrulama yöntemi olarak, DVR ile aynı şekilde beş katlamalı çapraz doğrulama yöntemi seçilmiştir.

Regression Learner uygulaması, GSR için, rasyonel kuadratik, kare üstel, Matern 5/2 ve üstel çekirdek fonksiyonları ile model oluşturmaya izin vermektedir. Yapılan denemelerde, Matern 5/2 çekirdek fonksiyonun sonuçlarının diğerlerine göre daha başarılı olduğu görülmüş ve kestirim modeli için bu çekirdek fonksiyonu kullanılmıştır.

4.5 NARX ile Batarya Sağlık Durumu Kestirimi

MATLAB programı içerisinde bulunan Neural Net Time Series uygulaması ile NARX modellemesi yapmak mümkündür. Bu uygulamanın arayüzü ile giriş ve hedef verileri seçilebilmektedir. Ayrıca, verilerin eğitim, doğrulama ve test için bölünecek oranları ayarlanabilmekte, gizli katman ve zaman gecikmesi değeri ile birlikte eğitimde kullanılacak algoritma da seçilebilmektedir. Tüm bu işlem adımları tamamlandıktan sonra, arayüz üzerinden bir yapay sinir ağı yapısı oluşturmak mümkündür. Oluşturulan yapay sinir ağı ile, uygulamanın arayüzü üzerinden, istenirse başka veri setleri, açık çevrim ağı yapısı ile test edilebilmektedir.

Arayüz üzerinde bu işlemler yapılabilmesine karşılık, daha detaylı olarak model üzerinde değişikliklerde bulunabilmek üzere temel kodlama bilgisi de uygulama üzerinden elde edilebilmektedir. Yapılan çalışmada, bu temel kodlar kullanılarak ağ yapısının detayları belirlenmiştir. Ağ oluşturmak için kullanılan kod Ek-A bölümünde paylaşılmıştır.

Eğitim için kullanılan altı bataryaya ait giriş ve çıkış verilerinin birleştirilmesinde MATLAB’de bulunan “catsamples” fonksiyonu kullanılmıştır.


Bu çalışmada kullanılan tüm bataryalar için, elde hem giriş hem de çıkış verileri bulunmaktadır. Bu sayede denetimli öğrenim yöntemi ile çıkış verilerini hedef olarak kullanıp, yapay sinir ağını oluşturmak mümkün olmaktadır. NARX ile batarya verilerinin eğitimi aşamasında seri-paralel tür (açık çevrim) yapı kullanılmıştır. Bu sayede eğitim sonuçları daha isabetli elde edilebilmektedir. Ayrıca, açık çevrimde, sinir ağı yapısı tam anlamıyla ileri beslemeli bir yapıda olmakta ve yaygınca kullanılan geri yayımlı eğitim algoritmalarının kullanımına izin vermektedir. Bu çalışmada, yapılan denemelerde hızlı ve isabetli olduğu tespit edilen Levenberg-Marquardt algoritması kullanılmıştır.

Bu yöntemde, gelecek bağımsız çıkış verisinin kestirimi, önceki d_x sayıda bağımsız giriş verisi ve d_y sayıda çıkış verisi kullanılarak elde edilir. Bu çalışmada d_x ve d_y 1’er adet olacak şekilde seçilmiştir. Yapılan denemelerde, daha başarılı sonuçlar elde edildiği görülerek, modeldeki gizli katman sayısı 15 olarak seçilmiştir.

Eğitim verisi, eğitim için %75, doğrulama için %13, test için %12 oranda ve rastgele olacak şekilde bölünerek yapay sinir ağı eğitilmiştir. Bölünen verilerden eğitim için olan veriler, ön değer ve ağırlıkların yeniden düzenlenmesi işlemi için kullanılmaktadır. İkinci parça olan doğrulama verilerindeki hata, eğitim esnasında gözlemlenir. Normal süreçte, eğitim aşamasının başlangıcında doğrulama verilerindeki hata, eğitim verilerinde olduğu gibi düşüş eğilimi gösterir. Fakat, ağ aşırı uyum yapmaya başladığında, doğrulama verilerindeki hata yükselme eğilimi göstermeye başlar. Bu durumun tespiti, ağ eğitiminin durma kriteridir. Eğitim durdurulduğunda, ön değer ve ağırlık değerleri olarak, doğrulama verilerinin en düşük olduğu nokta anındaki değerler seçilir. Test verilerine ait hata oranı normalde eğitimde kullanılmamaktadır, fakat test verilerindeki en küçük hataya ulaşılan iterasyon sayısı ile doğrulama verilerinde en küçük hataya ulaşılan iterasyon sayısı birbirinden ciddi

derecede farklı ise, bu durum veri setinin zayıf bir şekilde bölünmüş olduğunu işaret eder.

Şekil 4.6’da 3.8-4V aralığındaki giriş verileri için 1,2,5,6,7,8 numaralı batarya veri setleri kullanılarak oluşturulan ağı, eğitim, doğrulama ve test verilerinin hata grafiği gösterilmiştir.



Şekil 4.6 : 3.8-4V giriş verisi için 1,2,5,6,7,8 numaralı batarya veri setleri eğitim verileri başarımları grafiği.

Açık çevrim türdeki ağ yapısında, önceki d_x ve d_y sayısınca veri kullanılarak, sadece bir adım sonrasındaki çıkış için kestirim yapılabilir. Çok sayıda adımın çıkış verisi kestirimi yapabilmek için, ağ yapısını kapalı çevrime çevirmek gereklidir. Kapalı çevrime geçildiğinde çıkış verisi olarak sadece d_y sayısınca ilk veri girişinde bulunmak yeterlidir. Sonrasında Şekil 3.5’te olduğu gibi, her adım sonrasında yapılacak kestirim için, bir önceki adımda kestirilen çıkış verisi kullanılmaya başlanır. Bu çalışmada d_y sayısı 1 olarak seçilmiştir. Bataryanın ilk çevrimi için sağlık durumunu %100 olarak kabul etmek mümkündür. Dolayısı ile modelin bu noktadan ilerlemesi, gerçek hayattaki uygulamalar için de bir problem oluşturmayacaktır. Çalışmanın devamında NARX ile yapılan kestirim sonuçları, ikinci veri itibarıyla gösterilmiştir.


4.6 Karşılaştırmalı Sonuçlar

Elde edilen kestirim sonuçları ile hem batarya bazında yöntemlerin başarımı hem de yöntem bazında bataryaların başarımı incelenmiştir.


4.6.1 Batarya bazında yöntemlerin karşılaştırılması

Her eğitim seti sonucunda test edilen iki bataryadan birine ait batarya sağlık durumunun gerçek değeri ile NARX, DVR ve GSR kestirim değerleri karşılaştırmalı olarak grafik üzerinde gösterilmiştir. Bunun dışında test edilen bataryaların tümü için RMSE değerleri çizelgeler ile gösterilmiştir. Giriş verileri olarak gerilim aralığının genişliği ve gerilim aralıklarındaki farklılıkların başarımlar üzerindeki etkisi de ayrıca grafikler ve çizelgeler üzerinden takip edilebilmektedir.


3,4,5,6,7,8 numaralı bataryaların eğitim amaçlı kullanıldığı, 1 numaralı bataryanın test edilmesi sonucunda elde edilen kestirim grafiği Şekil 4.7-4.9’da gösterilmiştir.



Şekil 4.7 : Batarya 1 için 3,60-3,65 V gerilim aralığı giriş verileri için kestirim sonuçları.



Şekil 4.8 : Batarya 1 için 3,60-3,80 V gerilim aralığı giriş verileri için kestirim sonuçları.



Şekil 4.9 : Batarya 1 için 3,80-4,00 V gerilim aralığı giriş verileri için kestirim sonuçları.


3,4,5,6,7,8 numaralı bataryaların eğitim amaçlı kullanıldığı, 1 ve 2 numaralı bataryaların test edilmesi sonucunda elde edilen kestirim başarımları Çizelge 4.5'te gösterilmiştir.

Çizelge 4.5 : Batarya 1 ve Batarya 2 için kestirim RMSE sonuçları.


Batarya Numarası	3,60 - 3,65 V			3,60 - 3,80 V			3,80 - 4,00 V		
	NARX	DVR	GSR	NARX	DVR	GSR	NARX	DVR	GSR
Batarya 1	0,53	1,73	1,42	0,66	0,94	0,62	0,74	1,04	1,12
Batarya 2	1,19	2,32	2,16	1,11	1,71	1,18	0,76	0,65	0,80

3,60-3,65 V gerilim aralığındaki sonuçlarda NARX yönteminin diğer yöntemlerden bariz bir şekilde üstün olduğu görülmektedir. Giriş verileri zenginleşip, gerilim farkı 200 mV'a çıktığında DVR ve GSR yöntemlerinin sonuçları iyileşirken, NARX için çok anlamlı bir değişim olmamıştır.


1,2,5,6,7,8 numaralı bataryaların eğitim amaçlı kullanıldığı, 3 numaralı bataryanın test edilmesi sonucunda elde edilen kestirim grafiği Şekil 4.10-4.12'de gösterilmiştir.



Şekil 4.10 : Batarya 3 için 3,60-3,65 V gerilim aralığı giriş verileri için kestirim sonuçları.



Şekil 4.11 : Batarya 3 için 3,60-3,80 V gerilim aralığı giriş verileri için kestirim sonuçları.



Şekil 4.12 : Batarya 3 için 3,80-4,00 V gerilim aralığı giriş verileri için kestirim sonuçları.


1,2,5,6,7,8 numaralı bataryaların eğitim amaçlı kullanıldığı, 3 ve 4 numaralı bataryaların test edilmesi sonucunda elde edilen kestirim başarımları Çizelge 4.6’da gösterilmiştir.

Çizelge 4.6 : Batarya 3 ve Batarya 4 için kestirim RMSE sonuçları.



Batarya Numarası	3,60 - 3,65 V			3,60 - 3,80 V			3,80 - 4,00 V		
	NARX	DVR	GSR	NARX	DVR	GSR	NARX	DVR	GSR
Batarya 3	0,67	1,98	1,89	0,67	1,66	1,56	0,83	0,57	0,67
Batarya 4	0,88	1,53	1,16	1,70	1,35	1,24	1,41	0,26	0,47

1 ve 2 numaralı bataryaların test verilerine benzer şekilde, 3,60-3,65 V gerilim aralığındaki sonuçlarda NARX yönteminin diğer yöntemlerden bariz bir şekilde üstün olduğu görülmektedir. Giriş verileri zenginleşip, gerilim farkı 200 mV’a çıktığında DVR ve GSR yöntemlerinin sonuçları iyileşirken, NARX için özellikle 4 numaralı batarya özelinde başarımın düştüğü gözlemlenmiştir.

1,2,3,4,7,8 numaralı bataryaların eğitim amaçlı kullanıldığı, 5 numaralı bataryanın test edilmesi sonucunda elde edilen kestirim grafiği Şekil 4.13-4.15’de gösterilmiştir.



Şekil 4.13 : Batarya 5 için 3,60-3,65 V gerilim aralığı giriş verileri için kestirim sonuçları.




1,2,3,4,7,8 numaralı bataryaların eğitim amaçlı kullanıldığı, 5 ve 6 numaralı bataryaların test edilmesi sonucunda elde edilen kestirim başarımları Çizelge 4.7’de gösterilmiştir.

Çizelge 4.7 : Batarya 5 ve Batarya 6 için kestirim RMSE sonuçları.



Batarya Numarası	3,60 - 3,65 V			3,60 - 3,80 V			3,80 - 4,00 V		
	NARX	DVR	GSR	NARX	DVR	GSR	NARX	DVR	GSR
Batarya 5	0,87	2,28	2,28	0,95	1,76	1,45	0,37	0,20	0,25
Batarya 6	0,81	1,80	1,57	1,15	1,70	1,55	1,40	0,61	0,49

1,2,3 ve 4 numaralı bataryaların test verilerine benzer şekilde, 3,60-3,65 V gerilim aralığındaki sonuçlarda NARX yönteminin diğer yöntemlerden bariz bir şekilde üstün olduğu görülmektedir. Giriş verileri zenginleşip, gerilim farkı 200 mV’a çıktığında DVR ve GSR yöntemlerinin sonuçları iyileşirken, NARX için özellikle 6 numaralı batarya özelinde başarımın düştüğü gözlemlenmiştir.

1,2,3,4,5,6 numaralı bataryaların eğitim amaçlı kullanıldığı, 7 numaralı bataryanın test edilmesi sonucunda elde edilen kestirim grafiği Şekil 4.16-4.18’de gösterilmiştir.



Şekil 4.16 : Batarya 7 için 3,60-3,65 V gerilim aralığı giriş verileri için kestirim sonuçları.



1,2,3,4,5,6 numaralı bataryaların eğitim amaçlı kullanıldığı, 7 ve 8 numaralı bataryaların test edilmesi sonucunda elde edilen kestirim başarımları Çizelge 4.8’de gösterilmiştir.

Çizelge 4.8 : Batarya 7 ve Batarya 8 için kestirim RMSE sonuçları.

Batarya Numarası	3,60 - 3,65 V			3,60 - 3,80 V			3,80 - 4,00 V		
	NARX	DVR	GSR	NARX	DVR	GSR	NARX	DVR	GSR
Batarya 7	1,67	1,83	1,82	1,55	1,82	1,80	0,93	1,13	1,12
Batarya 8	1,09	1,81	1,90	0,74	1,63	1,53	0,84	1,12	1,00


3,60-3,65 V gerilim aralığındaki sonuçlarda NARX yönteminin diğer yöntemlerden biraz daha üstün olduğu görülmektedir. Giriş verileri için, gerilim farkı 200 mV’a çıktığında 3,60-3,80 V gerilim aralığı için üç yöntemde de yalnızca 8 numaralı batarya için bir miktar iyileşme gözlenmiştir. 3,80-4,00 V aralığında DVR ve GSR yöntemlerinin sonuçları her iki batarya için de iyileşirken, NARX için yalnızca 7 numaralı batarya özelinde başarımın iyileştiği gözlemlenmiştir.

4.6.2 Yöntem bazında bataryaların karşılaştırılması


Üç farklı giriş gerilim aralığı için NARX ,DVR ve GSR yöntemlerinin her biri, kendi içerisinde, sekiz bataryanın sonucu ile beraber incelenmiştir. Giriş verileri olarak gerilim aralığının genişliği ve gerilim aralıklarındaki farklılıkların modellerin başarımı tutarlılığı üzerindeki etkisi grafikler üzerinden takip edilebilmektedir.

Çalışmada kullanılan sekiz bataryanın her birinin sağlık durumu değişimi karakteristiği kendisine özgün bir davranış göstermektedir. Bataryaların sağlık durumunun %80’e düşene kadar kullanıldıkları çevrim sayılarının da aynı olmadığı görülmektedir.


Şekil 4.19-4.21’de üç farklı gerilim aralığı için NARX yöntemi bazında sekiz bataryanın deneysel olarak elde edilmiş sağlık durumu değerleri ile birlikte kestirim sonucu hesaplanmış sağlık durumu değerleri gösterilmiştir.



Şekil 4.19 : 3,60-3,65 V gerilim aralığı için NARX ile kestirim sonuçları.



Şekil 4.20 : 3,60-3,80 V gerilim aralığı için NARX ile kestirim sonuçları.



Şekil 4.21 : 3,80-4,00 V gerilim aralığı için NARX ile kestirim sonuçları.

NARX yöntemi ile kestirim sonuçları incelendiğinde, “3,60-3,65 V” ve “3,60-3,80 V” gerilim aralıklarının giriş verisi olarak kullanıldığı modellerin sonuçlarının, çevrim sayısı olarak orta değerlerde bulunan bataryaların karakteristiğine daha yakın olduğu görülmektedir.


Gerilim aralığı olarak “3,80-4,00 V”’un giriş verisi olarak kullanıldığı modellerin, diğer iki gerilim aralığına göre değerlendirildiğinde, elde edilen kestirim sonuçlarının daha dağınık olduğu görülmektedir. İki ayrı uçta bulunan batarya 4 ve batarya 7’ye ait kestirim sonuçları incelendiğinde, batarya 4 için RMSE’nin anlamlı olarak düşmediği görülmüştür. Fakat diğer iki gerilim aralığında batarya 4 için hesaplanan kestirimde, genellikle gerçek sağlık durumunun üzerinde olacak şekilde kestirim hataları görülürken, “3,80-4,00 V” gerilim aralığındaki kestirimde, gerçek sağlık durumunun altında olduğu hatalar da görülmüştür.

Batarya 7’ye ait kestirim sonuçları incelendiğinde, “3,60-3,65 V” ve “3,60-3,80 V” gerilim aralıklarında tüm veri noktaları için gerçek sağlık durumunun altında olacak şekilde kestirim hataları görülmüştür. “3,80-4,00 V” gerilim aralığındaki kestirimde, üç veri noktası için gerçek sağlık durumunun üzerinde hata görülmüş, RMSE’nin de küçüldüğü tespit edilmiştir.


Şekil 4.22-4.24’de üç farklı gerilim aralığı için DVR yöntemi bazında sekiz bataryanın deneysel olarak elde edilmiş sağlık durumu değerleri ile birlikte kestirim sonucu hesaplanmış sağlık durumu değerleri gösterilmiştir.

Gerilim aralığı olarak “3,60-3,65 V” un giriş verisi olarak kullanıldığı modellerde, tüm bataryalar için benzer şekilde yaklaşık olarak %100 ile %93 sağlık durumu aralığında, giriş verileri, modeller tarafından ayırt edilebilecek şekilde algılanmamış ve neredeyse sabit bir kestirim sonucu vermiştir. Tüm bataryalar için elde edilen kestirim sonucunda gerçek sağlık durumuna göre hem daha yüksek sağlık durumunda hem de daha düşük sağlık durumunda olacak şekilde hataların gerçekleştiği tespit edilmiştir.


“3,60-3,80 V” gerilim aralığında, sağlık durumunu %100 olduğu noktada, bazı modellerin, birden çok batarya için kestirim sonucunu gerçek sağlık durumuna göre daha yüksek olacak şekilde hesapladığı görülmüştür. “3,60-3,65 V” gerilim aralığına benzer şekilde yaklaşık olarak %100 ile %92 sağlık durumu aralığında giriş verileri, modeller tarafından ayırt edilebilecek şekilde algılanmamıştır. Modellerin, isabetlilikten bağımsız olarak, giriş verilerine karşı sert tepkiler ile kestirim sonucu olarak gerçek sağlık durumuna göre hem daha yüksek sağlık durumunda hem de daha düşük sağlık durumunda olacak şekilde hata ile cevap verdiği tespit edilmiştir.



Şekil 4.22 : 3,60-3,65 V gerilim aralığı için DVR ile kestirim sonuçları. (batarya 8 sonucu ilk veri %100’ü geçmeli).



Şekil 4.23 : 3,60-3,80 V gerilim aralığı için DVR ile kestirim sonuçları.




Şekil 4.24 : 3,80-4,00 V gerilim aralığı için DVR ile kestirim sonuçları.


Gerilim aralığı olarak “3,80-4,00 V” un giriş verisi olarak kullanıldığı DVR ile oluşturulan modelin, diğer iki gerilim aralığına göre değerlendirildiğinde, giriş verilerine daha yumuşak tepki verdiği görülmüştür. Kestirim sonuçları incelendiğinde, gerçek sağlık durumuna göre tüm veri noktalarında daha yüksek sağlık durumunda ya da tüm veri noktalarında daha düşük sağlık durumunda hatalara sahip bataryaların olduğu görülmüştür. Modellerin %100’den %80’e kadar olan sağlık durumu aralığı için, giriş verilerinin model tarafından yeterince ayırt edilebilecek şekilde algılandığı tespit edilmiştir.

Şekil 4.25-4.27’de üç farklı gerilim aralığı için GSR yöntemi bazında sekiz bataryanın deneysel olarak elde edilmiş sağlık durumu değerleri ile birlikte kestirim sonucu hesaplanmış sağlık durumu değerleri gösterilmiştir.


GSR yöntemi ile oluşturulan modellere ait kestirim sonuçları incelendiğinde, sonuçların karakterinin DVR yöntemi ile oldukça benzer olduğu görülmektedir.



Şekil 4.25 : 3,60-3,65 V gerilim aralığı için GSR ile kestirim sonuçları.



Şekil 4.26 : 3,60-3,80 V gerilim aralığı için GSR ile kestirim sonuçları.



Şekil 4.27 : 3,80-4,00 V gerilim aralığı için GSR ile kestirim sonuçları.

“3,60-3,65 V” ve “3,60-3,80 V” gerilim aralıklarının giriş verisi olarak kullanıldığı GSR yöntemi ile oluşturulmuş modellerde yaklaşık olarak %100 ile %92 sağlık durumu aralığında giriş verileri, modeller tarafından ayırt edilebilecek şekilde algılanmamıştır. “3,80-4,00 V” gerilim aralığında, diğer iki gerilim aralığına göre değerlendirildiğinde, modellerin giriş verilerine daha yumuşak tepki verdiği görülmüştür.

4.7 Sonuçların Değerlendirilmesi

Batarya bazında yöntemlerin başarımı incelendiğinde, 3,60-3,65V giriş gerilimi aralığında NARX ile elde edilen kestirimlerin, DVR ve GSR yöntemlerine göre daha isabetli olduğu görülmüştür. 3,60-3,80 V ve 3,80-4,00 V gerilim aralığı için, NARX sonuçlarında anlamlı bir iyileşme görülmezken, DVR ve GSR yöntemlerinin sonuçlarının genel olarak daha başarılı olduğu görülmüştür.

Yöntem bazında bataryalar karşılaştırılırken, sekiz batarya için aynı yöntem ile oluşturmuş dört farklı modelin kestirim sonuçları birlikte incelenmiştir. Yöntemler ile oluşturulan modeller kullanılarak kestirim sonuçları hesaplanmış ve sonuçlar karşılaştırılmıştır. Şekiller incelendiğinde, DVR, GSR ve NARX yöntemlerinin üçünün de, kendi içerisinde tutarlı bir şekilde model yaratabildiği ve modellerin de tutarlı bir şekilde kestirimde bulunabildiği sonucuna ulaşmak mümkündür.



5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, bataryanın kısmi şarj edilme anında, üç farklı denetimli makine öğrenmesi yöntemi kullanılarak belirli gerilim aralıklarındaki şarj kapasitesi verileri ile bataryanın sağlık durumu kestirimi yapılmıştır.

Çalışmada Oxford Üniversitesi, Howey Araştırma Grubu tarafından paylaşılan sekiz adet lityum iyon hücrenin verisi kullanılmıştır. Bu hücrelerin her yüz çevrimde bir, 1 kapasite oranında (C-rate) sabit şarj ve deşarj ile gerçekleştirilen deneye tabi tutularak elde edilmiş gerilim ve kapasite verileri kestirim çalışmaları için kullanılmıştır. Eğitim seti olarak altı adet, başarımlar testi için ise, eğitim setindekilerden farklı iki adet batarya ile çalışmalar gerçekleştirilmiştir. Eğitim ve test için dört farklı kombinasyon yaratılarak, sekiz adet bataryanın hepsi için başarımlar sonucu elde edilmiştir. Böylelikle, farklı eğitim setleri kullanılarak, yöntemlerin hücre bazında ve kendi içerisindeki başarımlarının karşılaştırmalı olarak elde edilmesi amaçlanmıştır.

Kestirim için kullanılacak giriş verileri olarak, “3,60-3,65 V”, “3,60-3,80 V” ve “3,80-4,00 V” gerilim aralıklarında, bataryaların şarj kapasitesi kullanılmıştır. Şarj kapasiteleri için örnekleme aralığı seçiminde, batarya 1 kullanılarak 3,60-3,65 V ve 3,60-3,70 V şarj gerilim aralıklarında 10 mV ve 50 mV gerilim artışı anındaki kapasite değerleri için, toplanan veri boyutu ve kestirim başarımlarını incelenmiş, çalışma için 50 mV örnekleme aralığının kullanılmasına karar verilmiştir.

Bataryanın sağlık durumu belirteci olarak, bataryanın ölçümü yapılan çevrimdeki deşarj kapasitesinin, bataryanın ilk çevrimindeki deşarj kapasitesine oranı seçilmiştir. Çalışmada, tüm bataryaların sağlık durumlarının %100 ile %80 arası için deney verileri kullanılmış ve kestirimler de bu sağlık durumu aralığı için yapılmıştır.

Makine öğrenimi tekniklerinden destek vektör makinesi ile regresyon (DVR), Gauss süreci regresyonu (GSR) ve doğrusal olmayan dışsal girdili otoregresif ağ (NARX) kullanılmıştır. Üç yöntemde de eğitim için aynı giriş ve çıkış veri kombinasyonları kullanılmıştır. Modellemeler için MATLAB programının 2020a sürümü altında Regression Learner ve Neural Net Time Series uygulamaları kullanılmıştır.

Modellerin başarımlarının incelenmesinde hata kareleri ortalamasının karekökü (RMSE) başarımlar ölçütü olarak belirlenmiştir. Hatalar, batarya sağlık durumu için %100 sağlık durumuna göre yüzde cinsinden hesaplanmıştır. Elde edilen sonuçlarda, belirtilen tüm gerilim aralıklarında, batarya 1 için %0,53-%1,73, batarya 2 için %0,65-%2,32, batarya 3 için %0,57-%1,98, batarya 4 için %0,26-%1,70, batarya 5 için %0,20-%2,28, batarya 6 için %0,49-%1,80, batarya 7 için %0,93-%1,83 ve batarya 8 için %0,74-%1,90 arasında hata ile kestirim yapılabildiği görülmüştür.

Tüm bataryaların sonuçları için ortak olarak, daha kısıtlı giriş verisinin olduğu 3,60-3,65V giriş gerilimi aralığında doğrusal olmayan dışsal girdili otoregresif ağ (NARX) ile elde edilen kestirimlerin, diğer iki yönteme (DVR ve GSR) göre daha başarılı olduğu görülmüştür. Bu giriş gerilimi aralığında elde edilen giriş verileri ile destek vektör makinesi regresyonu (DVR) ve Gauss süreci regresyonu (GSR) modelleri, yaklaşık olarak %100 ile %92 sağlık durumu aralığında hassas bir kestirimde bulunamamışlardır.

Giriş verilerinin zenginleştiği 3,60-3,80 V ve 3,80-4,00 V gerilim aralığı için, yöntemlerin başarımlarını birbirleri ile karşılaştırıldığında, doğrusal olmayan dışsal girdili otoregresif ağ (NARX) sonuçlarının, hücre ve gerilim aralığı bazında farklılıklar gösterdiği, anlamlı bir şekilde daha başarılı ya da daha başarısız olduğu sonucunu çıkarmanın mümkün olmadığı, fakat destek vektör makinesi regresyonu (DVR) ve Gauss süreci regresyonu (GSR) yöntemlerinin sonuçlarının genel olarak daha başarılı olduğu görülmüştür.

3,60-3,80 V ve 3,80-4,00 V gerilim aralıklarının başarıma etkisi için karşılaştırmalı olarak sonuçlar incelendiğinde, yine doğrusal olmayan dışsal girdili otoregresif ağ (NARX) sonuçlarının anlamlı bir şekilde daha başarılı ya da başarısız olduğu sonucu çıkarmak mümkün olmamakla birlikte, 3,80-4,00 V giriş gerilimi aralığında, batarya 1 haricinde, destek vektör makinesi regresyonu (DVR) ve Gauss süreci regresyonu (GSR) yöntemlerinin sonuçlarının daha başarılı olduğu görülmüştür.

Sekiz batarya verisinin birlikte incelenmesi ile, üç farklı gerilim aralığı için, yöntemlerin kendi içlerinde tutarlı olup olmadıkları incelenmiştir. DVR, GSR ve NARX yöntemlerinin üçü ile de yaratılan modeller kullanılarak kestirim sonuçları elde edilmiş ve karşılaştırılmıştır. Hesaplanan kestirim sonuçlarına göre, yöntemlerin kendi içerisinde tutarlı olduğu sonucuna ulaşmak mümkündür.

Tüm veriler için genel bir başarımlı deęerlendirmesi yapıldığında, tüm bataryaların hata kareleri ortalamasının karekökü (RMSE) toplamı olarak en başarılı kestirim %5,58 hata ile “3,80-4,00 V” aralığında Gauss süreci regresyonu (GSR) modeli kullanılarak elde edilmiştir. Aynı gerilim aralığında destek vektör makinesi regresyonu (DVR) modeli kullanılarak elde edilen toplam hata %5,92, doğrusal olmayan dışsal girdili otoregresif ağ (NARX) modeli kullanılarak elde edilen kestirim sonucu toplam hata %7,28’dir.

Çalışmada, 8 batarya hücresi, 3 gerilim aralığı ve 3 yöntem bazında elde edilen tüm sağlık durumu kestirimi sonuçları ve sonuçların hata oranı grafikler ile Ek-B’de gösterilmiştir.

Çalışmada kullanılan veriler, daha hızlı kapasite oranlarında şarj için ya da farklı sıcaklıklar için karşılaştırmalı sonuç elde etmede ne yazık ki yetersiz durumdadır. Gelecek çalışmalar için, bataryaların farklı sıcaklıklarda ve farklı kapasite oranlarında şarj edilmesi ile elde edilecek verileri kullanarak modeli test etmek mümkündür. Ayrıca yeni veriler ile daha genel bir model elde edilerek başarımın nasıl değiştięi incelenebilir ve çalışma bir adım ileriye götürebilir.

Bahsedilen şarj hızı ve sıcaklık farklılıkları ile birlikte kurulacak model, gerçek zamanlı olarak bir batarya paketi üzerinde test edilebilir. Yapılacak testte, doğrudan batarya üzerinde bulunan bir birim üzerinde hesaplama yapılabileceęi gibi, uzaktaki bir veri merkezine elde edilen verilerin aktarımı ile uzaktan hesaplama yapılarak kestirim elde edilmesi gelecek çalışmalar için düşünülebilir.



KAYNAKLAR

- Allen, R.** (2020). *A Gentle Introduction to Machine Learning Concepts*. Eriřim: 25 Nisan 2021, <https://medium.com/machine-learning-in-practice/a-gentle-introduction-to-machine-learning-concepts-cfe710910eb>
- Amidi, A. & Amidi, S.** (t.y). *Tekrarlayan Yapay Sinir Ağları El Kitabı*. . Eriřim: 25 Nisan 2021, <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-recurrent-neural-networks>
- Anandhi, V. & Manicka Chezian, R.** (2013). Support Vector Regression to Forecast the Demand and Supply of Pulpwood. *International Journal of Future Computer and Communication* (Vol. 2, no. 3 pp. 266-269).
- Ananto, P.; Syabani, F., Indra, W.D., Wahyunggoro, O., & Cahyadi, A.I.** (2013). The state of health of Li-Po batteries based on the battery's parameters and a fuzzy logic system. *2013 Joint International Conference on Rural Information & Communication Technology and Electric-Vehicle Technology (rICT & ICeV-T)*, Bandung, Indonesia: 26–28 November 2013.
- André M.** (2004). The ARTEMIS European driving cycles for measuring car pollutant emissions. *The Science of the total environment*, 334-335, 73–84. <https://doi.org/10.1016/j.scitotenv.2004.04.070>
- Ařkın, D., İskender, İ., & Mamizadeh, A.** (2011). Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformatör Sargısının Termal Analizi. *Gazi Üniv. Müh. Mim. Fak. Der. Cilt 26, No 4*, 905-913.
- Ayoub, E. & Karami, N.** (2015). Review on the charging techniques of a Li-Ion battery. *2015 Third International Conference on Technological Advances in Electrical, Electronics and Computer Engineering (TAECE)*. doi:10.1109/taeece.2015.7113599
- Ayre, J.** (2017). Tesla Batteries 101 — Production Capacity, Uses, Chemistry, & Future Plans. *CleanTechnica*. Eriřim: 20 Nisan 2021, <https://cleantechnica.com/category/clean-transport-2/electric-vehicles/>
- Barré, A., Deguilhem, B., Grolleau, S., Ge' rard, M., Suard, F., & Riu, D.** (2013). A review on lithiumion battery ageing mechanisms and estimations for automotive applications. *Journal of Power Sources*, 241, 680–689.
- Berecibar, M., Gandiaga, I., Villarreal, I., Omar, N., Van Mierlo, J., & Van den Bossche, P.** (2016). Critical review of state of health estimation methods of Li-ion batteries for real applications. *Renewable and Sustainable Energy Reviews*, 56, 572–587. doi:10.1016/j.rser.2015.11.042

- Bian, X., Liu, L., & Yan, J.** (2019). A model for state-of-health estimation of lithium ion batteries based on charging profiles. *Energy*. doi:10.1016/j.energy.2019.04.070
- Birkl, C.** (2017). Oxford Battery Degradation Dataset 1. University of Oxford.
- Birkl, C.** (2017). *Diagnosis and prognosis of degradation in lithium-ion batteries* (Doktora Tezi). University of Oxford.
- Birkl, C.R., Roberts, M.R., McTurk, E., Bruce, P.G., & Howey, D.A.** (2017). Degradation diagnostics for lithium ion cells. *Journal of Power Sources*, 341, 373–386.
- Bloom, I., Cole, B., Sohn, J., Jones, S., Polzin, E., Battaglia, V., ... Case, H.** (2001). An accelerated calendar and cycle life study of Li-ion cells. *Journal of Power Sources*, 101(2), 238–247. doi:10.1016/s0378-7753(01)00783-2
- Chaoui, H. & 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. doi:10.1109/tvt.2017.2715333
- Chen, L., Lü, Z., Lin, W., Li, J., & Pan, H.** (2018). A new state-of-health estimation method for lithium-ion batteries through the intrinsic relationship between ohmic internal resistance and capacity. *Measurement*, 116, 586–595. doi:10.1016/j.measurement.2017.11.016
- Chen, Z., Sun, M., Shu, X., Xiao, R., & Shen, J.** (2018). Online State of Health Estimation for Lithium-Ion Batteries Based on Support Vector Machine. *Applied Sciences*, 8(6), 925. doi:10.3390/app8060925
- Daowd M, Omar N, Boessche P, Mierlo J.** (2011) A review of passive and active battery balancing based on Matlab/Simulink. *International Review of Electrical Engineering (I.R.E.E.)*, Vol. xx, n. X in 2011.
- Fei Zhang, Guangjun Liu, & Lijin Fang.** (2009). Battery state estimation using Unscented Kalman Filter. *2009 IEEE International Conference on Robotics and Automation*, (Volume 3, pp. 1863-1868). Kobe, Japan, 12–17 May 2009.
- Galeotti, M., Cinà, L., Giammanco, C., Cordiner, S., & Di Carlo, A.** (2015). Performance analysis and SOH (state of health) evaluation of lithium polymer batteries through electrochemical impedance spectroscopy. *Energy*, 89, 678–686. doi:10.1016/j.energy.2015.05.148
- Gao, D, & Huang, .** (2017). Prediction of Remaining Useful Life of Lithium-ion Battery based on Multi-kernel Support Vector Machine with Particle Swarm Optimization. *Journal of Power Electronics*, 17(5), 1288–1297. <https://doi.org/10.6113/JPE.2017.17.5.1288>
- Gunn, S.** (1998). Support Vector Machines for Classification and Regression, ISISTechnical Report, 14 Mayis 1998
- Hosen, M. S., Jaguemont, J., Van Mierlo, J., & Berecibar, M.** (2021). Battery lifetime prediction and performance assessment of different modeling approaches. *iScience*, 24(2), 102060. <https://doi.org/10.1016/j.isci.2021.102060>

- Huang, M. & Kumar, M.** (2018). Electrochemical Model-Based Aging Characterization of Lithium-Ion Battery Cell in Electrified Vehicles. *ASME 2018 Dynamic Systems and Control Conference (DSCC 2018)*, (Volume 3, pp. 1–10). Atlanta, GA, USA: 30 September–3 October 2018.
- Karaathl, M., Demirci, E., & Baykaldı, A.** (2020). Ticari Kredi Faiz Oranlarının YSA NARX ve VAR Modelleri ile Öngörülmesi. *İşletme Araştırmaları Dergisi*, 12(3), 2327-2343.
- Katić, K., Li, R., Verhaart, J., & Zeiler, W.** (2018). Neural network based predictive control of personalized heating systems. *Energy and Buildings*, 174, 199–213. doi:10.1016/j.enbuild.2018.06.033
- Khaleghi, S., Beheshti, S. H., Berecibar, M., & Van Mierlo, J.** (2020). A data-driven method based on recurrent neural network method for online capacity estimation of lithium-ion batteries. In *2020 IEEE Vehicle Power and Propulsion Conference (VPPC) (pp. 1 to 7)*. [9330987] Gijon, Spain: IEEE. <https://doi.org/10.1109/VPPC49601.2020.9330987>
- Khaleghi, S., Karimi, D., Beheshti, S. H., Hosen, M. S., Behi, H., Berecibar, M., & Van Mierlo, J.** (2021). Online health diagnosis of lithium-ion batteries based on nonlinear autoregressive neural network. *Applied Energy*, 282, 116159. doi:10.1016/j.apenergy.2020.116159
- Klass, V., Behm, M., & Lindbergh, G.** (2014). A support vector machine-based state-of-health estimation method for lithium-ion batteries under electric vehicle operation. *Journal of Power Sources*, 270, 262–272. doi:10.1016/j.jpowsour.2014.07.116
- Li, X., Yuan, C., Li, X., & Wang, Z.** (2019). State of health estimation for Li-Ion battery using incremental capacity analysis and Gaussian process regression. *Energy*, 116467. doi:10.1016/j.energy.2019.116467
- Liu, C. & Cen, J.** (2019). Training Subset Selection for Support Vector Regression. *2019 Federated Conference on Computer Science and Information Systems (FedCSIS)*, pp. 11-14, doi: 10.15439/2019F363.
- Liu, M., Huang, C., Wang, L., Zhang, Y., & Luo, X.** (2020). Short-Term Soil Moisture Forecasting via Gaussian Process Regression with Sample Selection. *Water*, 12(11), 3085. doi:10.3390/w12113085
- Löbberding, H., Wessel, S., Offermanns, C., Kehrner, M., Rother, J., Heimes, H., & Kampker, A.** (2020). From Cell to Battery System in BEVs: Analysis of System Packing Efficiency and Cell Types. *World Electric Vehicle Journal*, 11(4), 77. doi:10.3390/wevj11040077
- Lucu, M., Martinez-Laserna, E., Gandiaga, I., Liu, K., Camblong, H., Widanage, W. D., & Marco, J.** (2020). Data-driven nonparametric Li-ion battery ageing model aiming at learning from real operation data – Part A: Storage operation. *Journal of Energy Storage*, 30, 101409. doi:10.1016/j.est.2020.101409
- Lucu, M., Martinez-Laserna, E., Gandiaga, I., Liu, K., Camblong, H., Widanage, W. D., & Marco, J.** (2020). Data-driven nonparametric Li-ion battery ageing model aiming at learning from real operation data - Part B:

- Cycling operation. *Journal of Energy Storage*, 30, 101410. doi:10.1016/j.est.2020.101410
- Meissner, E., & Richter, G.** (2003). Battery Monitoring and Electrical Energy Management. *Journal of Power Sources*, 116(1-2), 79–98. doi:10.1016/s0378-7753(02)00713-9
- Miao, Y., Hynan, P., von Jouanne, A., & Yokochi, A.** (2019). Current Li-Ion Battery Technologies in Electric Vehicles and Opportunities for Advancements. *Energies*, 12(6), 1074. doi:10.3390/en12061074
- Naha, A., Han, S., Agarwal, S., Guha, A., Khandelwal, A., Tagade, P., ve diğ.** (2020). An Incremental Voltage Difference Based Technique for Online State of Health Estimation of Li-ion Batteries. *Scientific Reports*, 10(1). doi:10.1038/s41598-020-66424-9
- Ng, K. S., Moo, C.-S., Chen, Y.-P., & Hsieh, Y.-C.** (2009). Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries. *Applied Energy*, 86(9), 1506–1511. doi:10.1016/j.apenergy.2008.11.021
- Ning, G., Haran, B., & Popov, B. N.** (2003). Capacity fade study of lithium-ion batteries cycled at high discharge rates. *Journal of Power Sources*, 117(1-2), 160–169. doi:10.1016/s0378-7753(03)00029-6
- Nitta, N., Wu, F., Lee, J.T. and Yushin, G.** (2015). Li-ion battery materials: present and future, *Materials today*, 18(5), 252–264.
- Noura, N., Boulon, L., & Jemeï, S.** (2020). A Review of Battery State of Health Estimation Methods: Hybrid Electric Vehicle Challenges. *World Electric Vehicle Journal*, 11(4), 66. doi:10.3390/wevj11040066
- Nuhic, A., Terzimehic, T., Soczka-Guth, T., Buchholz, M., & Dietmayer, K.** (2013). Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods. *Journal of Power Sources*, 239, 680–688. doi:10.1016/j.jpowsour.2012.11.146
- Özdemir, M.C.** (2017). Li-ion Batarya Karakterizasyonu, Modellemesi ve Batarya Yönetim Sistemi Tasarımı. (Yüksek lisans tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- P. Menezes Jr., J., & Barreto, G.** (2006). A New Look at Nonlinear Time Series Prediction with NARX Recurrent Neural Network. *2006 Ninth Brazilian Symposium on Neural Networks (SBRN'06)*. doi:10.1109/sbrn.2006.7
- Palacín, M. R.** (2018). Understanding ageing in Li-ion batteries: a chemical issue. *Chemical Society Reviews*, 47(13), 4924–4933. doi:10.1039/c7cs00889a
- Pastor-Fernández, C.; Widanage, W.D.; Marco, J.; Gama-Valdez, M.; Chouchelamane, G.H.** (2016). Identification and quantification of ageing mechanisms in Lithium-ion batteries using the EIS technique. *2016 IEEE Transportation Electrification Conference and Expo (ITEC)*, (pp, 1-6). Dearborn, MI, USA: 27–29 June 2016.

- Plett, G. L.** (2004). Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 1 *Journal of Power Sources*, 134(2), 252–261. doi:10.1016/j.jpowsour.2004.02.031
- Plett, G. L.** (2004). Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 2 *Journal of Power Sources*, 134(2), 252–261. doi:10.1016/j.jpowsour.2004.02.032
- Plett, G. L.** (2004). Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 3 *Journal of Power Sources*, 134(2), 252–261. doi:10.1016/j.jpowsour.2004.02.033
- Plett, G. L.** (2011). Recursive approximate weighted total least squares estimation of battery cell total capacity. *Journal of Power Sources*, 196(4), 2319–2331. doi:10.1016/j.jpowsour.2010.09.048
- Plett, G.** (2015). *Battery Management Systems, Volume II*. Norwood, MA.: Artech House.
- Ramadass, P., Haran, B., Gomadam, P. M., White, R., & Popov, B. N.** (2004). Development of First Principles Capacity Fade Model for Li-Ion Cells. *Journal of The Electrochemical Society*, 151(2), A196. doi:10.1149/1.1634273
- Ramasamy, R. P., White, R. E., & Popov, B. N.** (2005). Calendar life performance of pouch lithium-ion cells. *Journal of Power Sources*, 141(2), 298–306. doi:10.1016/j.jpowsour.2004.09.024
- Remmlinger, J., Buchholz, M., Meiler, M., Bernreuter, P., & Dietmayer, K.** (2011). State-of-health monitoring of lithium-ion batteries in electric vehicles by on-board internal resistance estimation. *Journal of Power Sources*, 196(12), 5357–5363. doi:10.1016/j.jpowsour.2010.08.035
- Ruslan, F. A., Samad, A. M., Zain, Z. M., & Adnan, R.** (2013). Multiple Input Single Output (MISO) ARX and NARX model of flood prediction system: A comparative study. *2013 IEEE International Conference on Control System, Computing and Engineering*. doi:10.1109/iccsce.2013.6719969
- Saha, B., & Goebel, K.** (2009). Modeling Li-ion battery capacity depletion in a particle filtering framework. In *Proceedings of the annual conference of the prognostics and health management society* (pp. 2909-2924).
- Schaltz, E., Stroe, D.-I., Norregaard, K., Johnsen, B., & Christensen, A.** (2019). Partial Charging Method for Lithium-Ion Battery State-of-Health Estimation. *2019 Fourteenth International Conference on Ecological Vehicles and Renewable Energies (EVER)*. doi:10.1109/ever.2019.8813645
- Schwunk, S., Armbruster, N., Straub, S., Kehl, J., & Vetter, M.** (2013). Particle filter for state of charge and state of health estimation for lithium–iron phosphate batteries. *Journal of Power Sources*, 239, 705–710. doi:10.1016/j.jpowsour.2012.10.058
- Spafford, A.** (t.y.). *What is a lithium-ion battery? A better power source*. Eriřim: 22 Nisan 2021, <https://www.protooolreviews.com/what-is-a-lithium-ion-battery/>

- Stroe, D-I., Knap, V., & Schaltz, E.** (2018). State-of-Health Estimation of Lithium-Ion Batteries based on Partial Charging Voltage Profiles. *ECS Transactions*, 85(13), 379-386. <https://doi.org/10.1149/08513.0379ecst>
- Tomaszewska, A., Chu, Z., Feng, X., O’Kane, S., Liu, X., Chen, J., ... Wu, B.** (2019). Lithium-Ion Battery Fast Charging: A Review. *eTransportation*, 100011. doi:10.1016/j.etrans.2019.100011
- Vapnik, V. N.** (1995). *The nature of statistical learning theory*. Springer-Verlag New York, Inc..ISBN: 0-387-94559-8
- Wassiliadis, N., Adermann, J., Frericks, A., Pak, M., Reiter, C., Lohmann, B., & Lienkamp, M.** (2018). Revisiting the dual extended Kalman filter for battery state-of-charge and state-of-health estimation: A use-case life cycle analysis. *Journal of Energy Storage*, 19, 73–87. doi:10.1016/j.est.2018.07.006
- Wei, X., Zhu, B., & Xu, W.** (2009). Internal Resistance Identification in Vehicle Power Lithium-Ion Battery and Application in Lifetime Evaluation. *2009 International Conference on Measuring Technology and Mechatronics Automation*, (pp. 388–392). Zhangjiajie, China: 11–12 April 2009.
- Weicker, P.** (2014). *A systems approach to lithium-ion battery management*. Norwood, MA.: Artech House
- What Is Machine Learning? 3 Things You Need To Know.** (t.y.). Erişim: 25 Nisan 2021, <https://www.mathworks.com/discovery/machine-learning.html#machine-learning-with-matlab>
- Williams, C. K. I., & Rasmussen, C. E.** (1996). Gaussian processes for regression. *Advances in Neural Information Processing Systems*.
- Wright, R., Motloch, C., Belt, J., Christophersen, J., Ho, C., Richardson, R., ... Sutula, R.** (2002). Calendar- and cycle-life studies of advanced technology development program generation 1 lithium-ion batteries. *Journal of Power Sources*, 110(2), 445–470. doi:10.1016/s0378-7753(02)00210-0
- Yang, D., Zhang, X., Pan, R., Wang, Y., & Chen, Z.** (2018). A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve. *Journal of Power Sources*, 384, 387–395. doi:10.1016/j.jpowsour.2018.03.015
- Yang, Q., Xu, J., Li, X., Xu, D., & Cao, B.** (2020). State-of-health estimation of lithium-ion battery based on fractional impedance model and interval capacity. *International Journal of Electrical Power & Energy Systems*, 119, 105883. doi:10.1016/j.ijepes.2020.105883
- Yasin, H., Caraka, R. & Hoyyi, A.** (2016). Prediction of Crude Oil Prices using Support Vector Regression (SVR) with grid search – cross validation algorithm. *Global Journal of Pure and Applied Mathematics*. 12. 3009-3020.
- Zhang, S. S.** (2006). The effect of the charging protocol on the cycle life of a Li-ion battery. *Journal of Power Sources*, 161(2), 1385–1391. doi:10.1016/j.jpowsour.2006.06.040

Zheng, X. & Deng, X. (2019). State-of-Health Prediction For Lithium-Ion Batteries With Multiple Gaussian Process Regression Model. *IEEE Access*.

Url-1 <<https://www.dyson.com.tr/products/cord-free/dyson-v8/overview>>, erişim tarihi 20.04.2021.

Url-2 <<https://www.batteryarchive.org/>>, erişim tarihi 21.02.2021.





EKLER

EK A: Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ (NARX) için MATLAB kodunun ana hatları

```
X = X_toplu;
T = T_toplu;

Egitim_fonksiyonu = 'trainlm'

Giris_gecikmesi = 1:1;
Cikis_gecikmesi = 1:1;
Gizli_katman_boyutu = 15;
net =
narxnet(Giris_gecikmesi,Cikis_gecikmesi,Gizli_katman
_boyutu,'open',Egitim_fonksiyonu);

net.inputs{1}.processFcns =
{'removeconstantrows','mapminmax'};
net.inputs{2}.processFcns =
{'removeconstantrows','mapminmax'};

[x,xi,ai,t] = preparets(net,X,{},T);

net.divideFcn = 'dividerand';
net.divideMode = 'time';
net.divideParam.trainRatio = 75/100;
net.divideParam.valRatio = 13/100;
net.divideParam.testRatio = 12/100;

net.performFcn = 'mse';

net.plotFcns = {'plotperform','plottrainstate',
'ploterrhist', ...
'plotregression', 'plotresponse', 'ploterrcorr',
'plotinerrcorr'};

[net,tr] = train(net,x,t,xi,ai);

kestirim = net(x,xi,ai);
hata = gsubtract(t,kestirim);
basarim = perform(net,t,kestirim);

egitimHedefi = gmultiply(t,tr.trainMask);
dogrulamaHedefi = gmultiply(t,tr.valMask);
testHedefi = gmultiply(t,tr.testMask);
```


```
egitimBasarimi = perform(net,egitimHedefi,y);
dogrulamaBasarimi = perform(net,dogrulamaHedefi,y);
testBasarimi = perform(net,testHedefi,y);

netc = closeloop(net);
netc.name = [net.name ' - Closed Loop'];


[xc,xic,aic,tc] = preparets(netc,X,{},T);
kapaliCevrimKestirimi = netc(xc,xic,aic);
kapaliCevrimBasarimi =
perform(net,tc,kapaliCevrimKestirimi);
```




EK B: Batarya Sağlık Durumu Kestirim Sonuçları




(a)



(b)




(c)




(d)


Şekil B.1 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,65 V aralığında DVR ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.




(a)



(b)




(c)




(d)


Şekil B.2 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,65 V aralığında DVR ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.




(a)



(b)




(c)




(d)


Şekil B.3 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,80 V aralığında DVR ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.




(a)



(b)




(c)




(d)


Şekil B.4 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,80 V aralığında DVR ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.




(a)



(b)




(c)




(d)


Şekil B.5 : Batarya sağlık durumunun gerçek değeri ve 3,80-4,00 V aralığında DVR ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.




(a)



(b)




(c)




(d)


Şekil B.6 : Batarya sağlık durumunun gerçek değeri ve 3,80-4,00 V aralığında DVR ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.




(a)



(b)




(c)




(d)


Şekil B.7 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,65 V aralığında GSR ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.




(a)



(b)




(c)




(d)


Şekil B.8 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,65 V aralığında GSR ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.




(a)



(b)




(c)




(d)


Şekil B.9 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,80 V aralığında GSR ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.




(a)



(b)




(c)




(d)


Şekil B.10 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,80 V aralığında GSR ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.




(a)



(b)




(c)




(d)


Şekil B.11 : Batarya sağlık durumunun gerçek değeri ve 3,80-4,00 V aralığında GSR ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.




(a)



(b)




(c)




(d)


Şekil B.12 : Batarya sağlık durumunun gerçek değeri ve 3,80-4,00 V aralığında GSR ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.




(a)



(b)




(c)




(d)


Şekil B.13 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,65 V aralığında NARX ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.




(a)



(b)




(c)




(d)


Şekil B.14 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,65 V aralığında NARX ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.




(a)



(b)




(c)




(d)


Şekil B.15 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,80 V aralığında NARX ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.




(a)



(b)




(c)




(d)


Şekil B.16 : Batarya sağlık durumunun gerçek değeri ve 3,60-3,80 V aralığında NARX ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.




(a)



(b)




(c)




(d)


Şekil B.17 : Batarya sağlık durumunun gerçek değeri ve 3,80-4,00 V aralığında NARX ile kestirimi arasındaki hata: (a) Batarya 1. (b) Batarya 2. (c) Batarya 3. (d) Batarya 4.




(a)



(b)



(c)



(d)

Şekil B.18 : Batarya sağlık durumunun gerçek değeri ve 3,80-4,00 V aralığında NARX ile kestirimi arasındaki hata: (a) Batarya 5. (b) Batarya 6. (c) Batarya 7. (d) Batarya 8.

ÖZGEÇMİŞ

Ad-Soyad

: Çetin Oral

ÖĞRENİM DURUMU:

- **Lisans** : 2017, İstanbul Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Elektrik Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2017 yılı, Elektrik Mühendisleri Odası 12. Bitirme Tasarım ve Proje Ödülleri yarışmasında “Şebekeden Beslemeli Senkron Alçaltan Çevirici” çalışması ile Elektrik-Kontrol kategorisinde ikincilik ödülü
- Pavo Tasarım Üretim Elektronik Tic. A.Ş. (Donanım Tasarım Mühendisi) –2017-2020.
- Tübitak Bilgem (Araştırmacı) – 2020-2020.
- Roketsan A.Ş (Güç Sistemleri Tasarım Mühendisi) – 2020-devam etmekte.