

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



**LİTYUM İYON BATARYALARDA SAĞLIK DURUMUNUN
MAKİNE ÖĞRENMESİ İLE KESTİRİMİ**

Yüksek Lisans Tezi

Emine ÇAVUŞ

Danışman

Dr. Öğretim Üyesi İdris SANCAKTAR

SAMSUN
2022

TEZ KABUL VE ONAYI

Emine ÇAVUŞ tarafından, Dr. Öğretim Üyesi İdris SANCAKTAR danışmanlığında hazırlanan “LİTYUM İYON BATARYALARDA SAĞLIK DURUMUNUN MAKİNE ÖĞRENMESİ İLE KESTİRİMİ” başlıklı bu çalışma, jürimiz tarafından 5.9.2022 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Yüksek Lisans Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim/Ana Sanat Dalı	İmza	Sonuç
Başkan	Dr. Öğr. Üyesi Cengiz TEPE		<input checked="" type="checkbox"/>
	Ondokuz Mayıs Üniversitesi Elektrik Elektronik Mühendisliği Ana Bilim Dalı		Kabul <input type="checkbox"/> Ret
Üye	Dr. Öğr. Üyesi Ahmet TURAN		<input checked="" type="checkbox"/>
	Samsun Üniversitesi Biyomedikal Mühendisliği Ana Bilim Dalı		Kabul <input type="checkbox"/> Ret
Üye	Dr. Öğr. Üyesi İdris SANCAKTAR		<input checked="" type="checkbox"/>
	Ondokuz Mayıs Üniversitesi Elektrik Elektronik Mühendisliği Ana Bilim Dalı		Kabul <input type="checkbox"/> Ret

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

ONAY
... / ... / ...
Prof. Dr. Ali BOLAT
Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

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

Etik Kurul Gerekli mi ?

Evet (Gerekli ise ekler kısmına ekleyiniz)

Hayır

İmza
05 /09 / 2022
Emine ÇAVUŞ

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı : LİTYUM İYON BATARYALARDA SAĞLIK DURUMUNUN
MAKİNE ÖĞRENMESİ İLE KESTİRİMİ

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 10.07.2022 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 9

Tek kaynak oranı : % 2 çıkmıştır.

İmza
05 /09 /2022
Dr. Öğretim Üyesi İdris SANCAKTAR

ÖZET

LİTYUM İYON BATARYALARDA SAĞLIK DURUMUNUN MAKİNE ÖĞRENMESİ İLE KESTİRİMİ

Emine ÇAVUŞ

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

Yüksek Lisans, Eylül/2022

Danışman: Unvanı İdris SANCAKTAR

Bu çalışmada batarya sağlık durumunun belirlenmesi için makine öğrenmesi yöntemi kullanılmıştır. Bu amaçla bataryanın deşarj olması esnasında elde edilen akım, kapasite azalması, gerilim gibi değerler kullanılmıştır. Literatürdeki diğer yöntemlerden farklı olarak, deşarj gerilim grafiğindeki diz-dirsek noktaları belirlenerek gerilimdeki değişimler daha ayrıntılı olarak dikkate alınmıştır. Belirlenen giriş verileri kullanılarak batarya sağlık durumunun belirlenebilmesi için k-En Yakın Komşu yöntemi ve Rastgele Orman Regresyon yöntemi olmak üzere iki farklı makine öğrenmesi algoritması oluşturulmuştur. Gerçekleştirilen sağlık durumu belirleme yazılımı için PYTHON dili kullanılmıştır. Batarya sağlık durumunun belirlenmesi için kullanılan yöntemlerin başarısı iki farklı senaryo ile değerlendirilmiştir. İlk senaryo tüm batarya verilerinin karışık olarak değerlendirilip, tüm bataryalara ait verilerden oluşan eğitim ve test verilerinin oluşturulması ile gerçekleştirilmiştir. Diğer senaryo ise elde bulunan 12 bataryadan 11'ini eğitim verisini kalan 1 bataryanın ise test verisini oluşturduğu durumdur. Burada 12 bataryanın her biri ayrı ayrı test verisi olarak değerlendirilmiştir.

Anahtar Sözcükler: Batarya Sağlığı, k-En Yakın Komşu Yöntemi, Rastgele Orman Regresyon yöntemi, Makine Öğrenmesi

ABSTRACT

ESTIMATION OF HEALTH STATUS IN LITHIUM-ION BATTERIES BY MACHINE LEARNING

Emine ÇAVUŞ

Ondokuz Mayıs University

Institute of Graduate Studies

Department of Electrical and Electronics Engineering Programme

Master, September/2022

Supervisor: Assist. Prof. Dr. İdris SANCAKTAR

In this study, machine learning method was used to determine the battery health. For this purpose, values such as current, capacity decrease, voltage obtained during the discharge of the battery were used. Unlike other methods in the literature, the knee-elbow points in the discharge voltage graph are determined and the changes in voltage are taken into account in more detail. Two different machine learning algorithms, namely the k-Nearest Neighbor method and the Random Forest Regression method, were used in order to determine the battery health status by using the specified input data. PYTHON was used for the implemented health status determination software. The success of the methods used to determine the battery health status was evaluated with two different scenarios. The first scenario was carried out by evaluating all battery data in a mixed manner and creating training and test data consisting of data for all batteries. The other scenario is where 11 of the 12 batteries are the training data and the remaining 1 battery is the test data. Here, each of the 12 batteries is evaluated separately as test data.

Keywords: Battery Health, k-Nearest Neighbor Method, Random Forest Method Regression Method, Machine Learning

ÖN SÖZ VE TEŞEKKÜR

Çalışmalarımı her zaman destekleyen, sabırla bilgisini benimle paylaşan ve kendisi ile çalışmaktan gurur duyduğum sayın hocam Dr. Öğr. Üyesi İdris SANCAKTAR'a teşekkür ederim.

Yaşamımın her anında beni destekleyen, benim için her türlü fedakârlığı yapan anneme, babama ve kardeşlerime sonsuz teşekkür ederim.

Eylül 2022 SAMSUN

Emine ÇAVUŞ

Sevgili Eşime ve Kızıma

İÇİNDEKİLER

TEZ KABUL VE ONAYI	i
BİLİMSEL ETİĞE UYGUNLUK BEYANI	ii
TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI	ii
ÖZET	iii
ABSTRACT	iv
ÖNSÖZ VE TEŞEKKÜR	v
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	viii
ŞEKİLLER DİZİNİ	ix
TABLolar DİZİNİ	x
1. GİRİŞ	1
1.1. Tezin Amacı ve Katkısı.....	5
2. KURAMSAL TEMELLER.....	7
2.1. Batarya	7
2.1.1. Batarya Türleri	7
2.1.2. Lityum-iyon Bataryalar.....	8
2.1.3. Batarya Parametreleri.....	10
2.1.4. Batarya Sağlık Durumu.....	11
2.2. Makine öğrenmesi.....	12
2.2.1. k-En Yakın Komşu Yöntemi.....	13
2.2.2. Rastgele Orman Regresyon Yöntemi.....	15
2.2.3. Diz-Dirsek Noktasının Bulunması	16
3. MATERYAL VE YÖNTEM.....	19
3.1. Batarya Sağlık Durumunun Kestirilmesi	19
4. BULGULAR VE TARTIŞMA	25
5. SONUÇ	34
KAYNAKÇA.....	36
ÖZ GEÇMİŞ.....	41

SİMGELER VE KISALTMALAR

SOC	: Batarya şarj durumu
SOH	: Batarya sağlık durumu
SVRA	: Sınıflandırma ve regresyon ağacı
UPS	: Kesintisiz güç kaynağı
MAE	: Ortalama mutlak hata
R	: Direnç değeri
C	: Kondansatör değeri
E	: Batarya iç gerilimi
V	: Volt
A	: Amper
M	: Batarya deşarj eğrisi diz noktası
L	: Batarya deşarj eğrisi dirsek noktası
N	: Batarya deşarj eğrisi en düşük gerilim noktası
K	: Batarya deşarj eğrisi en yüksek gerilim noktası

ŞEKİLLER DİZİNİ

Şekil 2.1. Lityum-iyon batarya (a) şarj durumu (b) deşarj durumu	9
Şekil 2.2. Randle elektriksel eşdeğer modeli	10
Şekil 2.3 Rastgele orman regresyonu örnek akış şeması	15
Şekil 2.4 Batarya deşarj eğrisi	17
Şekil 3.1. Kapasite filtresiz ve filtreli durum (a) CS2 33 (b) CS2 34 (c) CS2 35 (d) CS2 36 (es) CS2 37 (f) CS2 38 (g) CX2 33 (h) CX2 34 (ı) CX2 35 (i) CX2 36 (j) CX2 37 (k) CX2 38.....	23
Şekil 3.2. Batarya sağlık durumu belirleme akış şeması.....	24
Şekil 4.1. Senaryo 1 için test ve tahmin edilem değerleri (a) k-en yakın komşu yöntemi (b) rastgele orman regresyon yöntemi.....	26
Şekil 4.2. k- en yakın komşu yöntemi için test ve tahmin değerleri (a) CS2 33 (b) CS2 34 (c) CS2 35 (d) CS2 36 (es) CS2 37 (f) CS2 38 (g) CX2 33 (h) CX2 34 (ı) CX2 35 (i) CX2 36 (j) CX2 37 (k) CX2 38	29
Şekil 4.3. Rastgele orman regresyon yöntemi için test ve tahmin değerleri (a) CS2 33 (b) CS2 34 (c) CS2 35 (d) CS2 36 (es) CS2 37 (f) CS2 38 (g) CX2 33 (h) CX2 34 (ı) CX2 35 (i) CX2 36 (j) CX2 37 (k) CX2 38.....	32

TABLÖLAR DİZİNİ

Tablo 3.1. Kullanılan bataryalar ve özellikleri.....	20
Tablo 4.1. Senaryo 1 için bataryalara ait MAE ve doğruluk oranları	26
Tablo 4.2. Senaryo 2 için bataryalara ait MAE ve doğruluk oranları	33

1. GİRİŞ

Lityum-iyon bataryalar, elektriksel enerjinin kimyasal tepkimeler ile depo edilmesi ve depo edilen enerjinin yine kimyasal tepkimeler ile elektrik enerjisine dönüşmesi için kullanılan enerji depolama birimleridir. Bir batarya hücresi temel olarak anot, katot ve elektrolit olmak üzere 3 bölümden oluşur (Linden and Reddy, 2002). Anot negatif elektrottur, dış devreye elektron verir ve burada oksidasyon tepkimesi oluşur. Katot pozitif elektrottur, dış devreden elektron alır ve burada redüksiyon tepkimesi oluşur. Elektrolit ise batarya içinde iyon iletimini sağlayan bölümdür. Lityum-iyon bataryalar cep telefonları, dizüstü bilgisayarlar, askeri ve havacılık elektroniği gibi birçok alanda yaygın olarak kullanılmaktadır (Song et al., 2017; Xiong et al., 2017; Zhang et al., 2018). Ayrıca elektrikli araçlar ve yenilenebilir enerji kaynaklarının yaygınlaşması da enerjinin depolanmasını zorunlu kılmaktadır (Saji et al., 2019; Unterrieder et al., 2013). Yüksek enerji yoğunluğu, yüksek güç yoğunluğu, güvenli olması, uzun ömürlü olması ve düşük kendi kendine deşarj, lityum-iyon bataryayı kurşun asit, sodyum sülfür ve diğer batarya türlerinden üstün kılan ana özellikleridir (Hu et al., 2017). Belirtilen avantajların yanında fosil yakıtların yakın zamanda tükenecek olmasından dolayı, Lityum-iyon bataryalar fazlaca ihtiyaç duyulacak olan enerji depolama için de gelecek vaat eden elemanlardır (Hannan et al., 2017).

Lityum-iyon bataryaların elektriksel özellikleri, doğrusal ve düzgün olmayan şarj kapasitesi vb. rağmen önemli ölçüde iyileştirilmiştir (Kim et al., 2019). Lityum-iyon bataryaların daha güvenli çalışabilmesi, tüm sistemi korumak ve enerjinin optimum kullanımını izlemek için batarya yönetim sistemi gereklidir (Xiong et al., 2018). Batarya yönetim sistemlerinin, batarya performansını ve ömrünü optimize edebilmesi için sağlık durumu (SOH) ve şarj durumu (SOC) gibi bataryaların önemli parametrelerinin takip edilmesi gerekmektedir (Ren et al., 2019; Tang et al., 2019; Zou et al., 2018). Bataryaların aşırı şarj, deşarj, ısınma gibi nedenlerden dolayı kimyasal yapısı bozulmakta, sağlık durumları olumsuz etkilenmekte ve enerji depolama işlevini yitirmektedir.

Bataryalar, farklı yapıdaki kimyasal maddelerden oluşan hücrelerin bir veya daha fazlasının bir araya gelmesi ile oluşturulmuş enerji depolama birimleridir. Sistemlerdeki görevleri belirli düzeydeki akım ve gerilim seviyesini güvenli ve sağlıklı bir şekilde temin etmesidir. Bataryalar ile beslenen sistemlerin sağlıklı

çalışabilmesi için sistemi besleyen bataryaların anlık sağlık durumu yeterli seviyede olması önemlidir. Batarya sağlık durumu, bataryadan elde edilebilecek son kapasitesinin başlangıç kapasitesine oranı olarak tanımlanabilir. Batarya sağlık durumunun belirlenmesi, batarya kapasitesinin azalma miktarının ve iç direncinin artması gibi bataryaya ait önemli parametrelerin de belirlenmesi anlamına gelmektedir (Chaoui et al., 2014). Bataryaların sağlığı, elektrikli araçlar gibi batarya ile beslenen sistemlerinde sağlıklı çalışmasını etkilemektedir (Chen et al., 2018). Bu nedenle batarya sağlık durumunun belirlenmesi önemlidir.

Batarya sağlık durumunu belirlemek için literatürdeki yöntemler üç grup altında toplanabilir; doğrudan ölçüm yöntemi, model tabanlı yöntem ve veri tabanlı yöntemler (Berecibar et al., 2016; Hu et al., 2015; Ungurean et al., 2017). Doğrudan ölçüm yöntemini kullanarak batarya sağlığını belirlemek için literatürde çalışmalar yapılmıştır (Goud et al., 2020; Wang et al., 2020; Yu, 2013; Zhang et al., 2020). Doğrudan ölçüm yönteminde bataryanın tamamen şarj ve deşarj esnasında batarya kapasitesi ölçülür (Hu et al., 2015). Ayrıca sağlık durumunun belirlenebilmesi için batarya direncinin ölçülmesi gerekmektedir (Bi et al., 2016). Temelinde basit olan bu yöntem özel laboratuvar şartları gerektirmesi gibi durumlardan dolayı uygulanabilirliği düşüktür.

Model tabanlı yöntemini kullanarak batarya sağlığını belirlemek için literatürde birçok çalışma yapılmıştır (Allam et al., 2015; Gao et al., 2021; Kim et al., 2011; Ning et al., 2018; Noura et al., 2020; Qiuting et al., 2015; Rozaqi and Rijanto, 2016; Rozaqi et al., 2017; Sierra et al., 2019; Topan et al., 2016; Yu, 2015). Model tabanlı yöntemlerde, deşarj sırasında elde edilen bataryanın akım, gerilim vb. sinyalleri kullanılır (Ma et al., 2019). Ayrıca ölçülen sinyallerin dışında sağlık durumunun belirlenmesi için batarya modeline (elektro-kimyasal ve elektriksel model) de ihtiyaç vardır. Ancak kullanılan batarya modellerinde bulunan kısmi diferansiyel denklemlerin çözümünün zor olması nedeniyle uygulanması zordur (You et al., 2016). Bu ise, model tabanlı yaklaşımın tercih edilmeme nedenlerindedir. Ancak karmaşık hesaplamalar gerektiren bu yöntem ile sağlık durumu yüksek doğrulukla kestirilebilmektedir. Bu konuda yapılmış bazı çalışmalar aşağıdaki gibidir.

(Qiuting et al., 2015) yaptıkları çalışmada batarya sağlık durumunu belirlemek için model tabanlı yöntemlerden birisi olan kalman filtresi yöntemini kullanmışlardır. Bu çalışmada hem şarj hem de sağlık durumunu belirlemek için bataryanın

elektriksel ve kimyasal modeli kullanılmıştır. Çalışma sonucunda bataryanın iç direnci ile sağlık durumu arasındaki ilişki ortaya konmuştur. (Topan et al., 2016)'nin yapmış olduğu çalışma batarya sağlık durumunun belirlenmesi için kalman filtresi kullanımına bir diğer örnektir. Bu çalışma temelinde batarya yönetim sistemini esas almaktadır. Batarya yönetim sistemi için gerekli olan şarj durumu ve sağlık durumu ise kalman filtresi yardımıyla belirlenmiştir. Bu çalışmada sağlık durumunun belirlenmesi için ayrıca en küçük kareler yöntemi kullanılmıştır. Sonuç olarak iki yöntemin karşılaştırılması yapılmıştır. (Rozaqi and Rijanto, 2016; Rozaqi et al., 2017) yaptıkları çalışmalarda, batarya sağlık durumunu belirlemek için diğer bir model tabanlı yöntem olan parçacık sürü optimizasyon yöntemini kullanmışlardır. İlk çalışmada açık devre gerilimi ile şarj durumu, batarya iç direnci ile, ikinci çalışmada ise bataryanın RC Thevenin eşdeğer devresinden türetilen performans ölçütü ile batarya sağlık durumu kestirimi gerçekleştirilmiştir. Bu çalışmalarda parçacık sürü optimizasyonu ile en küçük kareler yönteminin hibrit bir şekilde uygulanmasının bir örneği gerçekleştirilmiştir. Parçacık sürü optimizasyon yöntemi, diğer yapay zeka yöntemleri ile kıyaslandığı zaman oldukça basit bir yapıya sahip olduğu için tercih edilebilmektedir. (Ning et al., 2018) ise adaptif gözleyici ile model tabanlı sağlık kestirim çalışması yapılmıştır. Bu çalışmada kayan kipli gözlemci ile bataryanın hem şarj durumu ve hem de batarya sağlık durumu tahmin edilmiştir. Burada RC Thevenin eşdeğer devre modelinden faydalanılmıştır. Uygulanan yöntemde kestirim sonucu elde edilen batarya kapasitesi ile sağlık durumunun belirlendiği ifade edilmiştir.

Veri tabanlı yöntemler, yalnızca bataryanın ne kadar ömrünün kaldığı ile değil ne kadar süre kullanıldığı ile ilgilenir. Bu yöntem kullanılarak gerçekleştirilen çalışmalar incelendiği zaman, genellikle bataryanın elektriksel eşdeğer devre modelinin kullanıldığı görülmektedir. Veri tabanlı yöntemler sisteme ait daha önceden kaydedilen verilerin kullanılmasına dayanır. Bataryanın sağlık durumunun belirlenebilmesi için gerekli olan veriler, batarya belirli sayıda şarj/deşarj edilerek, kestirim için eğitilecek olan makinelerde kullanılmak üzere elde edilir. Bu yöntemin en büyük avantajı üzerinde çalışılan sisteme ait herhangi bir matematiksel yapıya ihtiyacının olmamasıdır.

Sağlık durumunu belirlemek için kullanılan veri tabanlı yöntemler arasında; bulanık mantık (Shahriari and Farrokhi, 2010), uzay vektör makinesi (Feng et al.,

2019; Shu et al., 2020; Weng et al., 2014), zaman serisi (Lin et al., 2020), akıllı algoritmalar (genetik algoritma, yapay sinir ağıları, en küçük kare polinom regresyonu ve parçacık filtreleri) (Bhagavatula et al., 2020; Chaoui and Ibe-Ekeocha, 2017; Hu et al., 2018; Khan et al., 2020; Li et al., 2020; Lin et al., 2012; Liu et al., 2018; Pan et al., 2018; Polatöz, 2019; Sheikh et al., 2020; Shen et al., 2017; Ungurean et al., 2020; Yang et al., 2017) sayılabilir. Bu yöntemlerde ölçüm sonucu elde edilen veriler ile sistem sağlığı arasında karmaşık bağlantılar oluşturulur. Bu şekilde batarya ömründeki değişiklikler tespit edilir (Goebel et al., 2008; Pascoe and Anbuky, 2005; Yu, 2013). Bu yöntemin doğruluğu, veri kümesinin boyutuna bağlıdır, veri kümesi ne kadar büyük olursa sağlık kestirim işlemi o kadar başarılı olur (Wu et al., 2016). Bahsedilen yöntemler yüksek verimlilik sağlamasına rağmen, hesaplama sürecinde ön işleme aşamaları bakımından oldukça masraflıdır. Bataryaya ait farklı ölçümlerde oluşan belirsizliklerin birleşmesi, dikkatli bir şekilde düzenlenmezse, tahmin işlemi oldukça başarısız olur. Bu konuda yapılmış bazı çalışmalar aşağıdaki gibidir.

(Shahriari ve Farrokhi, 2010) batarya sağlık durumunu belirlemek için bulanık mantık tabanlı bir algoritmadan faydalanmışlardır. Bu çalışmada, batarya şarj durumu ve sağlık durumu belirlemek için batarya akımı ve gerilimi bilgisi kullanılmıştır. Şarj durumu kestirimi için genişletilmiş Kalman filtresi kullanılmıştır. Çalışmada gerçekleştirilen bulanık mantık sisteminin iki farklı girişi vardır. Bu girişler şarj ve deşarj süreçlerinden elde edilmiştir. Tasarlanan bulanık sistemin giriş parametreleri şarj ve deşarj süreçlerinden elde edilen kapasite ve açık devre gerilimi değerleridir.

(Tan et al., 2020) yaptıkları çalışmada eşdeğer iç dirence tabanlı destek vektör regresyonu modeli kullanarak bataryanın ömrünü belirlemişlerdir.

(Sheikh et al., 2020) yapay sinir ağlarını kullanarak batarya sağlığının kestirimini gerçekleştirmişlerdir. Burada deşarj sürecine ait diz-dirsek noktalarının etkisinden bahsedilmiştir.

(Polatöz, 2019) bataryanın deşarj sürecindeki veriler kullanılarak yapay sinir ağı ile batarya sağlık durumu kestirimi yapılmıştır.

Yapay sinir ağlarını kullanılarak yapılan çalışmalarda; (Yang et al., 2017) bataryanın iç direnci ve kapasite parametrelerini, (Chaoui and Ibe-Ekeocha, 2017)

batarya gerilimi, şarj/deşarj akımları ve ortam sıcaklığı gibi deęişkenleri, (Bhagavatula et al., 2020) farklı sıcaklıklarda gerilim, akım, şarj çevrimlerini, (Chen et al., 2018) sabit akım altında deşarj süresi, şarj ve deşarj sayısı ve şarj kapasitesine ilişkin deęerleri model girişı olarak kullanmışlardır.

1.1. Tezin Amacı ve Katkısı

Literatürde gerçekleştirilen yöntemler incelendięi zaman, tüm yöntemler ile başarılı sonuçlar elde edildięi görülmektedir. Bu yöntemlerden model tabanlı yöntemler incelendięi zaman, özellikle kalman filtresi ve türevleri, gözlemleyici yapılar, en küçük kareler yöntemi vb. yöntemler başarılı sonuçlar vermelerine rağmen kullandıkları modellerin oldukça karmaşık olması, işlem yükünün çok fazla olması gibi dezavantajlara sahiptir (Bhagavatula et al., 2020). En küçük kareler yöntemi gibi basit yapılı modellerin kullanıldığı yöntemler ise daha karmaşık yapılı kontrolöre ihtiyaç duymaktadır (Noura et al., 2020). Benzer durum gözleyici tabanlı kestirim sistemleri için de geçerlidir. Gözleyici tabanlı kestirim sistemleri gelişmiş kontrolör ihtiyacı ve işlemsel yük fazlalığı gibi dezavantajlara sahiptir.

Veri tabanlı yöntemler ile yapılan batarya sağlık durumunu belirleme çalışmaları incelendięi zaman, veri tabanlı yöntemlerin matematiksel modele ihtiyaç duymamalarından dolayı işlem yükünün az olduęu görülmektedir. Veri tabanlı yöntemlerden bulanık mantık tabanlı ve destek vektör tabanlı yöntemlerde herhangi bir matematiksel yapı kullanılmamasına rağmen yüksek başarı için gelişmiş kontrolör yapısına ihtiyaç vardır. Ayrıca bu yöntemlerde, girdi olarak kullanılan verilerin çeşitlilięi ve kalitesine bağımlılık oldukça fazladır (Noura et al., 2020). Yapay sinir aęı tabanlı yöntemler ise hem matematiksel yapıya ihtiyaç duymamaları hem de giriş veri miktarının az olması nedeniyle oldukça avantajlıdır. Ancak bulanık mantık ve destek vektör tabanlı yöntemlerdekine benzer olarak gelişmiş kontrolöre ihtiyaç duyarlar. Ayrıca girdi olarak kullanılan verilerin kalitesi sistemin başarısında oldukça etkilidir (Noura et al., 2020).

Bu tez çalışmasında, batarya sağlık durumunun belirlenmesi için, matematiksel yapıya ihtiyaç duyulmaması, doğrusal olmayan batarya yapısına uygun olması, doğruluğunun yüksek olması ve yapısının karmaşık olmamasından dolayı, veri tabanlı yöntemlerden makine öğrenmesi yöntemi kullanılmıştır. Böylece yapay sinir aęlarında ve dięer veri tabanlı yöntemlerin ihtiyaç duyduęu gelişmiş kontrolör yapısı ortadan kaldırılmıştır. Bataryanın deşarj olması durumunda elde edilen akım,

kapasite azalması, gerilim gibi deęerler kullanılmıřtır. Batarya saęlık durumu belirleme s¼recinde deřarj esnasında elde edilen gerilim deęerleri doęrudan kullanılmıřtır. Bu alıřmada ise dięer alıřmalardan farklı olarak, deřarj gerilim grafięindeki diz-dirsek noktaları belirlenerek gerilimdeki deęiřimler daha ayrıntılı olarak ele alınmıřtır. Bunun yanı sıra diz-dirsek noktalarındaki deęiřimlerin zaman farkı, deřarj eęrisi ¼zerindeki en y¼ksek ve en d¼ř¼k gerilim deęerleri ve aralarındaki zaman farkı da hesaba katılmıřtır. Belirlenen giriř verileri kullanılarak batarya saęlık durumunun belirlenebilmesi iin iki farklı makine ¼ęrenmesi algoritması oluřturulmuřtur. Makine ¼ęrenmesi y¼ntemini sınıflandırma, k¼meleme, eęri uydurma (regresyon), ¼zellik seimi/ıkarımı ve iliřki belirleme olmak ¼zere beř farklı alt bařlıkta sınıflandırmak m¼mk¼nd¼r. Bu tez alıřmasında kullanılan bataryalara ait veriler sınıflandırma ve eęri uydurma (regresyon) alt bařlıklarına uygun olduęu iin batarya saęlık durumunu belirlemek amacıyla, k-En yakın Komřu Y¼ntemi ve Orman Regresyon Y¼ntemi kullanılmıřtır.

Tasarlanan ilk algoritma k-En Yakın Komřu y¼ntemi kullanılarak gerekleřtirilmiřtir. Kullanılan dięer y¼ntem ise Rastgele Orman regresyon y¼ntemidir. Bu alıřmada CALCE'nin internet ortamında aık olarak yayınladıęı batarya verilerinden yararlanılmıřtır (Calce, 2017). CALCE'den alınan 12 adet bataryaya ait veriler (her bir bataryaya ait 50 řarj-deřarj d¼ng¼s¼), alıřma hedefleri doęrultusunda d¼zenlenmiřtir. Burada, tasarlanan sistemin bařarısını deęerlendirebilmek iin iki farklı alıřma gerekleřtirilmiřtir.

- 12 batarya (her bir bataryaya ait 50 řarj-deřarj d¼ng¼s¼) eęitim-test verisi olarak rastgele b¼l¼nd¼.
- 12 bataryadan 11 bataryaya ait veri eęitim giriři, kalan 1 batarya test verisi olarak b¼l¼nd¼.

Her iki deęerlendirme sonucunda da tasarlanan sistemin bařarılı olduęu g¼r¼ld¼. İki y¼ntem birbiri ile karřılařtırıldıęı zaman K-En Yakın Komřu y¼ntemi, Rastgele Orman Regresyon y¼nteminin gerisinde kalmıřtır.

2. KURAMSAL TEMELLER

2.1. Batarya

2.1.1. Batarya Türleri

Geçmişten günümüze kadar bilim insanları tarafından laboratuvar ortamında birçok batarya türü geliştirilmiştir ancak bazı batarya türleri sahip olduğu avantajlar ile endüstriyel uygulamalarda yaygın olarak kullanılmaktadır. Bu bataryalar arasında en çok kullanılan batarya türleri kurşun asit, nikel kadmiyum ve lityum bazlı bataryalardır. Bu bataryaların genel özellikleri ile avantaj ve dezavantajları aşağıda verilmiştir.

2.1.1.1. Kurşun-asit batarya

1859 yılında Gaston Plante tarafından geliştirilen kurşun asit batarya şarj edilebilen en eski batarya türüdür. Kurşun-asit bataryalarda artı yüklenmiş elektrotta kurşun dioksit (PbO_2), eksi yüklenmiş elektrotta ise kurşun ve elektrolit olarak hidrojen sülfür (H_2SO_4) materyalleri kullanılmaktadır

Diğer bataryalarla karşılaştırıldığında, kurşun asit batarya ağır olmasına rağmen yüksek akımlar üretebilmektedir. Batarya ağırlığın önemli olmadığı hastane, tekerlekli sandalyeler, güvenlik aydınlatmaları ve kesintisiz güç kaynaklarında (UPS) kullanılır. Kurşun asit bataryalar şarj esnasında aşırı ısınmakta ve hızlı şarj edilebilmeye uygun değildir. Kurşun-asit bataryaların bozulmaması için kullanılmadığı zamanlarda sürekli dolu şekilde depolanmalıdır. Kurşunun zehirli olması ve ekolojik sisteme verdiği zarardan dolayı kurşun asit bataryalar çok fazla tercih edilmez (Bostan, 2019).

2.1.1.2. Nikel Kadmiyum Bataryalar

1899 yılında geliştirilen Nikel kadmiyum bataryaların kapasitesi kurşun asit bataryalardan sonra önemli ölçüde arttırılmıştır. Nikel kadmiyum bataryalarda artı yüklenmiş elektrotta nikel hidroksit veya nikel oksihidroksit ($Ni(OH)_2/NiOOH$), eksi yüklenmiş elektrotta ise kadmiyum ya da kadmiyum hidroksit ($Cd/Cd(OH)_2$) ve elektrolit çözelti olarak da potasyum hidroksit (KOH) materyalleri bulunur.

$NiCd$ bataryalar en dayanıklı bataryalardır. Tıbbi cihazlar, elektrikli araç gereçler ve havacılıkta kullanılır. Kadmiyum toksik bir metal olduğundan ötürü çevreye karşı oldukça zararlı oldukları için daha çevre dostu kimyasallarla geliştirilmeye çalışılmıştır.

2.1.1.3. Nikel Metal Hidrat Bataryalar

Nikel Kadmiyum bataryaların olumsuz özelliklerine alternatif olarak Nikel Metal Hidrat (NiMH) bataryalar geliştirilmiştir. Kadmiyum yerine hidrat eklenerek geliştirilmiştir. Nikel metal hidrat bataryalar aynı anma gerilim değerlerine sahip nikel kadmiyum bataryalara göre daha yüksek enerji yoğunluğuna sahiptir. NiMH bataryalar %50-%70 BŞD(Batarya şarj durumu) de iyi verim gösterse de %70 in üstünde batarya fazla ısındığından enerjinin belirli bir kısmı ısı enerjisi olarak kaybedilir. Bu da bataryanın sahip olduğu enerji yoğunluğunu düşürür (Bostan, 2019).

2.1.1.4. Lityum Bazlı Bataryalar

Lityum bataryalar üzerine gerçekleştirilen ilk çalışmalar 1912 yılında G.N.Lewis tarafından başlatılmıştır. Günümüzde yaygın olarak kullanılan bir batarya çeşidi olan Lityum İyon bataryalar 1970'li yıllarda M. Stanley Whittingham isimli bir İngiliz kimyager tarafından geliştirilmiştir. Genel olarak lityum iyon pillerde, negatif elektrot karbon malzemedir, pozitif elektrot ise metal oksit malzemedir yapılmaktadır. Elektrolit malzeme ise lityum tuzları ile sağlanmaktadır. Lityum İyon piller sahip oldukları yüksek enerji yoğunluğu nedeniyle kurşun asit ve nikel bazlı bataryaları geride bırakmıştır.

2.1.2. Lityum-iyon Bataryalar

Lityum-iyon bataryalar elektrik enerjisini kimyasal enerjiye dönüştürerek depolayabilen elemanlardır. Lityum-iyon bataryalar defalarca şarj-deşarj edilebilme özelliğine sahiptir. Elektrik enerjisini depolamak için lityum-iyon bataryalarla beraber birçok batarya türü mevcuttur. Diğer batarya türleri ile karşılaştırıldığı zaman lityum iyon bataryaların avantajları aşağıdaki gibi sayılabilir (Linden and Reddy, 2002).

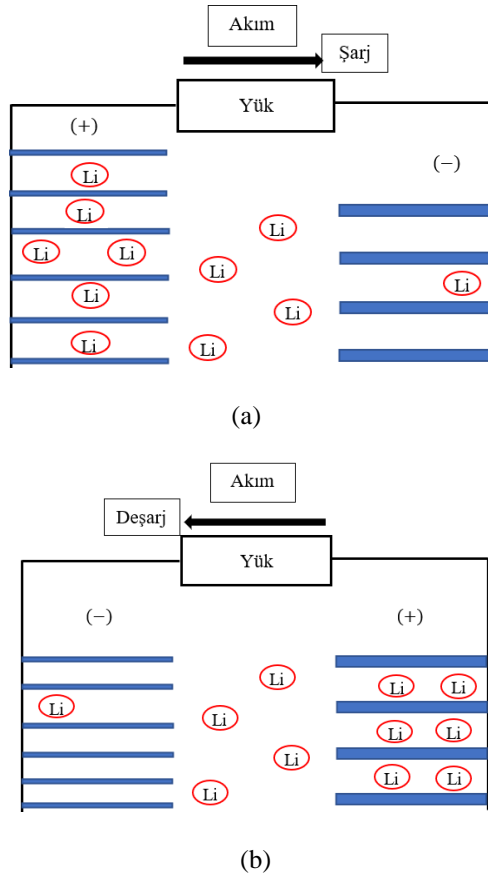
- Kullanım ömrü uzundur.
- Geniş sıcaklık aralığında çalışabilirler.
- Şarj olma süresi kısadır.
- Enerji verimi yüksektir.
- Enerji yoğunluğu yüksektir.
- Deşarj kapasitesi yüksektir.
- Raf ömrü oldukça uzundur.

Lityum-iyon bataryaların diğerk bataryalara göre dezavantajları ise ařağıdaki gibi sayılabilir (Kök, 2021).

- Fiyatı yüksektir.
- Koruyucu devre kullanılması zorunludur.
- Ařırı řarj durumu, bataryanın kimyasal yapısının bozulmasına neden olur ve kapasite kaybına neden olur.

2.1.2.1. Lityum-iyon Bataryanın Kimyasal Modeli


Bir lityum-iyon batarya hücresi temel olarak anot, katot ve elektrolit olarak üç bölüme ayrılır (Linden and Reddy, 2002). Lityum-iyon pillerin řarj-deřarj olayları sırasında Lityum iyonları anot ile katot elektrotları arasında yer değıřtirir (Matsuki ve Ozawa, 2009; Nazri ve Pistoia, 2008). Lityum iyon piller řarj etmek için tamamen boşalması durumuna gerek yoktur. İstenildiğı zaman řarj edilebilir ve istenildiğı seviyede řarjdan çekilebilir. Lityum iyon bataryaların řarj ve deřarj durumları Şekil 2.1’de gösterilmiştir.



Şekil 2.1. Lityum-iyon batarya (a) şarj durumu (b) deşarj durumu

2.1.2.2. Lityum-iyon Bataryanın Elektriksel Modeli

Lityum-iyon bataryaların matematiksel modelini geliřtirmek için farklı yöntemler önerilmiřtir. Bu yöntemler kimyasal model, eřdeęer devre modeli veya kara kutu modeli temel olarak oluřturulan yapılardır. Batarya üzerine alıřmalar yapılırken, sayısal hesabının kolay olması ve karmařıklığının az olması gibi nedenlerle çoęunlukla elektriksel eřdeęer devre kullanılır. Lityum-iyon bataryanın ikinci dereceden elektriksel eřdeęer devre modeli Őekil 2.2’de verilmiřtir (Spagnol et al., 2011) Őekil 2.2’deki devre aynı zamanda Randle Model olarak adlandırılmaktadır.



Őekil 2.2. Randle elektriksel eřdeęer modeli

Őekil 2.2’de verilen devre ideal gerilim kaynaęı, bir adet i diren, ve birbirine seri baęlı RC devrelerinden oluřmaktadır. Őekil 2.2’de;

- V_0 batarya u gerilimi
- i batarya akımı
- R_0, R_1, C_1, R_2 ve C_2 bataryanın dinamik yanıtını ve kapasitesini yansıtan parametreler
- E_0 batarya aık devre gerilimini temsil etmektedir.

2.1.3. Batarya Parametreleri

Lityum-iyon batarya ile alıřabilmek için bataryanın bazı zelliklerini bilinmelidir. Lityum-iyon bataryaya ait en nemli parametreler ve tanımlamaları ařaęıdaki gibidir.

- Batarya: Farklı kimyasal maddelerden oluřan ve elektrik enerjisini kimyasal enerji olarak depo eden rndr.
- Őarj: Bir bataryanın elektrik enerjisini kimyasal enerji olarak depolama iřlemidir.

- Deşarj: Bir bataryanın depoladığı kimyasal enerjiyi elektrik enerjisine dönüştürme işlemidir.
- Amper-saat: Bir bataryanın 1 saat boyunca verebileceği akım miktarıdır.
- C oranı: Bir bataryanın 1 saatte %100 doluluk oranına ulaşabilmesi için gerekli şarj akımına denir.
- Kapasite: Bir bataryanın depolayabildiği amper-saat cinsinden toplam enerji miktarıdır.
- Şarj durumu: Bataryanın sahip olduğu anlık kapasitenin nominal kapasiteye oranıdır.
- Bataryanın çevrim ömrü: Bir batarya ile gerçekleştirilebilecek en yüksek şarj-deşarj döngü sayısıdır.
- Kalan faydalı ömrü: Bir bataryanın belirli şartlar altında, kullanım ömrünün sonuna kadar hesaplanan gerçekleştirilebilecek şarjdeşarj çevrim sayısıdır.

2.1.4. Batarya Sağlık Durumu

Batarya sağlık durumu, bir bataryanın belirli şartlar altında, kullanım ömrünün sonuna kadar hesaplanan gerçekleştirilebilecek şarjdeşarj çevrim sayısıdır. Batarya sağlık durumu sıcaklık, şarj-deşarj akımı gibi ortam ve kullanıma bağlı olarak giderek azalmaktadır.

Bataryalar, farklı yapıdaki kimyasal maddelerden oluşan hücrelerin bir veya daha fazlasının bir araya gelmesi ile oluşturulmuş enerji depoalama birimleridir. Sistemlerdeki görevleri belirli düzeydeki akım ve gerilim seviyesini güvenli ve sağlıklı bir şekilde temin etmesidir. Bataryalar ile beslenen sistemlerin sağlıklı çalışabilmesi için sistemi besleyen bataryaların anlık sağlık yeterli seviyede olması önemlidir. Batarya sağlık durumu, bataryadan elde edilebilecek son kapasitesinin başlangıç kapasitesine oranı olarak tanımlanabilir. Batarya sağlık durumunun belirlenmesi, batarya kapasitesinin azalma miktarının ve iç direncinin artması gibi bataryaya ait önemli parametrelerin de belirlenmesi anlamına gelmektedir (Chaoui et al., 2014). Bataryaların sağlığı, elektrikli araçlar gibi batarya ile beslenen sistemlerinde sağlıklı çalışmasını etkilemektedir (Chen et al., 2018). Bu nedenle batarya sağlık durumunun belirlenmesi önemlidir.

Günümüz elektrik-elektronik sektöründe bataryalar tekli olarak kullanımdan çok birden fazla hücreden oluşan batarya paketleri halinde kullanılmaktadır. Batarya paketleri kullanıldığı zaman, batarya hücreleri arasındaki koordinasyonu sağlayarak sistemin daha sağlıklı çalışmasını sağlamak için batarya yönetim sistemleri kullanılmaktadır. Batarya sağlık durumu bilgisi ise batarya yönetim sistemleri için önemli bir parametredir.

2.2. Makine öğrenmesi

Makine öğrenmesi, yapay zeka alanının alt bölümlerinden biridir. Makine öğrenmesi, belirli denklemler ve fonksiyonlar ile bir sisteme ait sonuca ulaşmak yerine, bilgisayarların geçmiş bilgilerden elde edilen tecrübelerini kullanarak, istatistiksel yöntemler ve bazı algoritmalar kullanarak sonuç verilerini elde etme yöntemidir. Yapay zekanın bir alt dalı olan makine öğrenmesi, elde edilen verilerden anlamlı ve faydalı çıkarımlar yaparak sonuç elde etmeye çalışan bir algoritmadır (Polatöz, 2019). Yani makine öğrenimi elde edilen verilere bakarak tahmin yürütme işlemidir. Makine öğrenmesi son zamanlarda çok popüler olmuş bir çalışma alanı olmasına rağmen bu alandaki ilk çalışmalar 1959 yılında yapılmıştır. Özellikle hesaplama ve hafıza kapasitelerinin gelişmesi ile gelişmiş bir yapıya bürünen bilgisayarlar ile büyük verilerin depolanması ve işlenmesi mümkün hale gelmiştir. Yüksek hesaplama ve depolama kapasitesi olan bilgisayarlar ile birçok alanda makine öğrenmesinin uygulanmasını yaygınlaştırmıştır. Makine öğrenmesi yönteminin istatistik, olasılık kuramı, veri madenciliği, örüntü tanıma, yapay zeka, uyarlamalı denetim ve kuramsal bilgisayar bilimi gibi birçok alanda örneğini görmek mümkündür (Yardımcı, 2011).

Gelişmiş bilgisayarlar ile makine öğrenmesi uygulamalarının pek çok alanda örnekleri görülmektedir. Makine öğrenmesinin örnek uygulamaları olarak, bir alışveriş sitesinde veya sosyal medya uygulamalarında kullanıcıların tercihlerine ve ilgilendiği alanlara göre yeni ürün vb. sunabilmek, sağlık sektöründe tanı koyma ve yeni ilaçların keşfi, finans sektöründe kullanıcılara yatırım, portfolyo yönetimi gibi finansal konularda destek verebilmek gösterilebilir (Murray, 2022).

Teknolojideki gelişmeler neticesinde hem bilginin elde edilmesi hem de kaydedilip saklanması hem daha az masraflı hem de daha kolay bir hale gelmiştir. Bunun sonucunda da birçok alanda devasa boyutta bilgilere sahip olunmuştur.

Herhangi bir sisteme ait verilerin bulunması ve erişiminin kolay olması nedeniyle makine öğrenmesi yöntemi oldukça çok kullanılmaya başlanmıştır.

Sistemler ve kestirim işlemi göz önüne alındığı zaman, gerçekleştirilecek çalışmadan farklı beklentiler oluşmaktadır. Makine öğrenmesi yöntemini bu beklentiler neticesinde aşağıdaki gibi beş farklı alt başlıkta sınıflandırmak mümkündür (Alpaydin, 2020).

- Sınıflandırma: Eldeki veri kümesini oluşturan verilerin hangi sınıflara ait olduğu belli olan veri setleri ile, yeni verilerin hangi sınıfa ait olduğunun belirlenmesidir.
- Kümeleme: Eldeki veri kümesini oluşturan verilerin hangi sınıflara ait olduğu belli olmayan veri setleri ile, yeni verilerin hangi sınıfa ait olduğunun belirlenmesidir.
- Eğri uydurma (Regresyon): Veri kümesinin sürekli sayılardan oluşan bir yapıda olması durumunda, eldeki veriler kullanılarak gelecek durumdaki değerleri tahmin etmeye yönelik bir eğri uydurma (regresyon) işlemi gerçekleştirilebilir.
- Özellik seçimi/Çıkarımı: Eldeki veriler dikkate alındığı bazı durumlarda, eldeki yeni verinin tüm sınıflar/kümeler hesaba katılırsa hangi sınıfa ait olduğu belirsiz olabilmektedir. Bu durumda eldeki veri sınıfı/kümelerinden birinin seçilmesi gerekebilir.
- İlişki belirleme: Bir veri tabanında bulunan bazı özellikler ile herhangi bir özelliğe ait verinin hangi sınıfa/kümeyle ait olduğunu diğer sınıflar ile ilişkisine bakarak karar verme işlemidir.

Bu tez çalışmasında bataryaya ait veriler sınıflandırma ve eğri uydurma alt başlıklarına uygun olduğu için batarya sağlık durumunu belirlemek amacıyla, k-En Yakın Komşu Yöntemi ve Orman Regresyon Yöntemi kullanılmıştır.

2.2.1. k-En Yakın Komşu Yöntemi

k-En Yakın Komşu yöntemi, ilk olarak 1951 yılında Fix ve Hodges tarafından örüntü (model) tanımada kullanılmak üzere önerilmiş ve daha sonra 1967 yılında Cover ve Hart tarafından geliştirilmiştir (Elasan, 2019). Bu yöntem hem sınıflandırma hem de regresyon problemlerinde kullanılabilir. Ayrıca bu yöntem gözlemlerin yapılacağı sınıfı ve en yakın komşuyu belirlemek için k komşu değerini kullanan bir denetimli makine öğrenimi algoritmasıdır. Diğer denetimli öğrenme algoritmalarından farklı olarak geleneksel eğitim aşaması ile öğrenme işlemi yerine

eđitim verilerini ezberlemesidir. Bu özelliđi de tembel bir öğrenme türü olduđunu göstermektedir. Karmaşık hedef fonksiyonlarını bilgi kaybetmeden hızlı bir şekilde öğrenebilen en basit ve en çok kullanılan yöntemlerden biridir (Goyal et al., 2014).

k-En Yakın Komşular yönteminin amacı, sınıfı belli olmayan bir verinin diđer verilere uzaklıđının hesaplanarak hangi veriye/sınıfa yakın olduđunu belirlemektir. Sınıflandırma problemlerinde bu tahmin en yakın komşular arasında çođunluđa bakılarak belirlenirken, regresyon problemlerinde en yakın 40 komşunun hesaplanan yakınlık derecelerinin sayısal deđerlerinin ortalamasıdır. Bu şekilde yeni örneđin sınıfı belirlenir (Hastie ve Tibshirani, 2001). k-En Yakın Komşular yönteminin başarısı modele ait üç parametrenin dođru belirlenmesine bađlıdır. Bu parametreler en yakın komşu sayısı, ađırlık vektörü α ve uzaklık ölçüsüdür (Anava ve Levy, 2016).

Bu yöntemin uygulanmasının ilk aşaması en yakın komşu sayısı k deđerinin belirlenmesidir. k deđerinin belirlenmesi aşamasında eşdeđer bias ve varyans ile belirlenir. k-En Yakın Komşular yönteminde en uygun k deđerini belirlemek için çapraz dođrulama yöntemi oldukça başarılıdır. Çapraz dođrulama ile bađımsız bir veri kümesi geriye dönük kullanarak en uygun k deđerini belirlenir. k deđerini çođunlukla 3 ile 10 arasında seçilebilir (Sun ve Huang, 2010; Wettschereck ve Dietterich, 1993). Yöntemin ikinci aşaması, örnek veri setine eklenecek yeni gözlemin belirlenmesi ve mevcut veriler ile yeni gözlem arasındaki tüm mesafelerin hesaplanmasıdır. Komşular arası mesafeleri hesaplamak için kullanılabilen birçok yöntem vardır. Bu yöntemler içinde en çok kullanılanlar, Öklid uzaklıđı ve Manhattan, Minowski ve Hamming yöntemleri sayılabilir. Bu yöntemlerle komşular arası uzaklık belirleme işlemleri sırasıyla (Öklid uzaklıđı ve Manhattan, Minowski ve Hamming yöntemleri) aşıđıda verilmiştir;

$$d = \sqrt{\sum_{i=1}^n (p_i + q_i)^2} \quad (2.1)$$

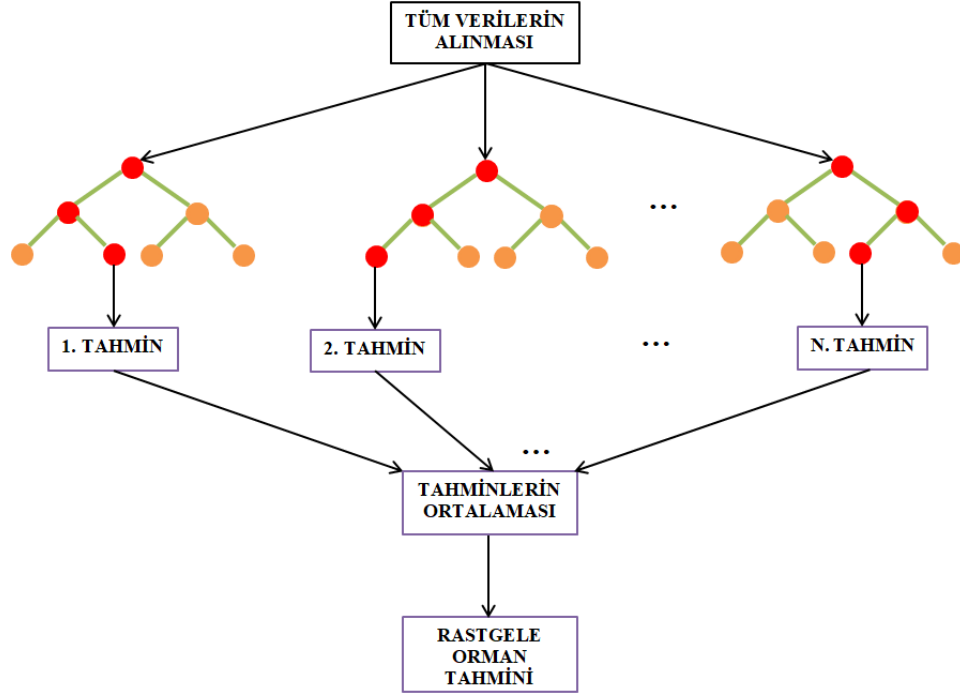
$$d = \sum_{i=1}^n |p_i + q_i| \quad (2.2)$$

Son aşamada ise yönteme ait deđişkenler belirlendikten sonra, tahmin edilecek deđer olan x deđerini k ve en yakın komşular kümesi N_i 'nin fonksiyonu olarak aşıđıdaki gibi yazılabilir (James et al., 2013);

$$f(x) = \frac{1}{k} \sum_i N_i \quad (2.3)$$

2.2.2. Rastgele Orman Regresyon Yöntemi

Rastgele Orman Regresyonu, uyarlama (regresyon) için kolektif öğrenme yöntemini kullanan denetimli bir öğrenme algoritmasıdır. Kolektif öğrenme yöntemi, birden fazla makine öğrenmesi algoritmasından gelen tahminleri birleştirerek çoklu karar verme algoritmasına sahip orman oluşturan, tek bir modele dayalı herhangi bir yönteme göre doğruluğu daha yüksek bir tahmin etme yöntemidir. Rastgele Orman Regresyonu hem sınıflandırma hem de uyarlama problemleri için kullanılabilir. Bu yöntem ile yüksek boyutlu verilerin işlenebilmesinin yanında eksik değer ve aşırı öğrenme gibi problemlere çözüm üretir (Sullivan, 2017). Şekil 2.3 Rastgele Orman Regresyonu çalışma biçimini göstermek için örnek olarak verilebilir.



Şekil 2.3 Rastgele Orman Regresyonu örnek akış şeması

Rastgele Orman Regresyon akış şeması incelendiği zaman, ağaç sayısı ($N_{\text{ağaç}}$) ve her bir ağaca ait düğüm sayısı ($N_{\text{düğüm}}$) olmak üzere, yönteme ait iki parametrenin belirlenmesi gerekmektedir. Karar verme ormanı oluşturulurken, kullanılacak veri setinden elde edilen eğitim veri setinin %70'i karar ağacını oluşturmak için kullanılır. Eğitim veri setinden kalan %30'luk bölümü ise geliştirilen yöntemin hata oranını hesaplamak için kullanılır (James et al., 2013).

Geleneksel bir karar ağacı yöntemi olan Sınıflandırma ve Regresyon Ağacı (SVRA) Algoritması kuralları, belirlenen değişkenin hangi değerine bağlı olarak ağacın dallanması gerektiğini belirlemek için kullanılır (Breiman, 2001). Bu kurallar, sınıflandırma ağaçları için gini indeksi olarak adlandırılır. Ancak bu işlem Rastgele Orman Regresyon yönteminde, gini indeks kriterine göre değil, elde edilen iki düğüm için tahmin edilen toplam varyansın minimize eden 'karesel artıkları azaltma algoritması'na göre yapılmaktadır (Özkan, 2012). Her düğümde en iyi dallanmayı sağlayacak değişken rastgele seçilir. Rastgele seçimin amacı, ağaçlar arasındaki korelasyonu en aza indirmek ve hata oranını azaltmaktır. Hata oranındaki azalma, algoritmanın etkinliğini artırır ve geliştirilen algoritmayı aşırı öğrenme durumuna karşı korur.

Karar verme ormanında oluşturulan her bir ağaç için, veri kümesinde bulunan farklı veri kümeleri kullanılır. Her ağacın eğitilmesinde kullanılan veri kümeleri birbirinden farklıdır. Böylece karar verme ormanında ağaç oluşturma sürecinde, her ağaç bağımsız olarak diğerlerinden etkilenmeden oluşturulur (Ercire ve Ünsal, 2021). Oluşturulan tüm ağaçlar, ayrı ayrı test işlemine tabi tutulur ve her bir ağaç için hata oranı hesaplanır. Hesaplanan hata oranlarının ortalaması alınarak ortalama hata oranı hesaplanır (James et al., 2013). Bu hata, her ağacın bireysel gücünün yanı sıra (her ağacın kendi hata oranı) ve ormandaki ağaçların aralarındaki uyuma da bağlıdır. Rastgele Orman Regresyon yönteminin en önemli özelliklerinden biri de kendi hata oranını hesaplayabilmesidir (Breiman, 2001).


2.2.3. Diz-Dirsek Noktasının Bulunması

Batarya sağlığının makine öğrenmesi vb. yöntemlerle sağlıklı bir şekilde belirlenebilmesi için bataryaya ait verilerden, batarya sağlığını temsil edecek özelliklerin çıkartılması önemlidir (Pola et al., 2015). Bu amaçla kullanılacak en önemli verilerden birisi batarya deşarj sürecine ait gerilim verileridir (Sheikh et al., 2020). Bu çalışmada, kullanılan bataryaların sağlık durumunu belirlemek için deşarj eğrilerinin diz-dirsek noktalarından faydalanılmıştır. Diz (M) ve dirsek (L) noktaları dışında deşarj eğrisi üzerindeki en düşük (N) ve en yüksek (K) gerilim değeri noktaları da kullanılmıştır. Bir bataryaya ait genel deşarj eğrisi ve eğri üstündeki maksimum, minimum ve diz-dirsek noktaları Şekil 3.2'de görülmektedir. Şekil 3.2'de deşarj sürecinde bataryanın en yüksek ve en düşük gerilime sahip olduğu

noktalar sırasıyla K ve N 'dir. Ayrıca Dirsek noktası L , diz noktası ise M noktası olarak gösterilmiştir.

Şekil 2.4'te verilen diz-dirsek noktalarının hesabı iki aşamadan oluşmaktadır (Sheikh et al., 2020).

- K ve N arasındaki eğrinin matematiksel eşitliği ifade edilir.
- Belirlenen $K-N$ eğrisi ile deşarj eğrisi arasındaki en uzak ilk nokta diz (M), K noktası ile iki eğrinin kesişim noktası arasındaki bölümde, iki eğri arasındaki en uzak nokta ise dirsek (L) olarak belirlenir.



Şekil 2.4 Batarya deşarj eğrisi

L ve M noktalarını belirlemek için gerekli olan iki eğri arası en uzak noktayı belirlemek amacıyla Şekil 2.4'te görüldüğü gibi, $K-N$ arasındaki doğru A ve K noktası ile deşarj eğrisi üzerindeki herhangi bir noktaya doğru olan doğru ise B ile ifade edilebilir. Bu durumda, n adet noktadan oluşan deşarj eğrisi üzerindeki her bir nokta için aşağıdaki eşitlik elde edilir.

$$B_i^{dik} = B_i \sin \theta \quad (2.4)$$

θ değeri ise aşağıda verildiği gibi skaler çarpım yoluyla bulunabilir.

$$\theta_i = \cos^{-1}\left(\frac{A \cdot B_i}{|A||B_i|}\right) \quad (2.5)$$

Bu durumda M noktası ise aşağıdaki gibi bulunabilir.

$$M = \max(B_1^{dik}, B_2^{dik}, B_3^{dik} \dots B_n^{dik}) \quad (2.6)$$

Şekil 2.4'te verilen noktalar belirlendikten sonra, noktalar arası ilişkiler bataryanın sağlık durumunu ile ilişkilendirilebilir. Bu nedenle makine öğrenmesi yönteminde kullanılmak üzere gerekli olan özellik çıkartma işleminde $K-L$, $L-M$ ve $M-N$ noktaları arasındaki öklit uzunlukları göz önüne alınmıştır. Belirtilen üç öklit uzunluğunun batarya sağlığı ile ilişkisi incelendiği zaman, diz-dirsek noktaları ($L-M$ noktaları) arası öklit uzaklığı sağlıkla doğrudan ilişkilidir (Sheikh et al., 2020). Bu uzunluk değeri ne kadar yüksek ise batarya o kadar sağlıklıdır. Diğer iki öklit uzunluğunun ($K-L$ ve $M-N$ arası) batarya sağlığına etkisi incelendiği zaman, $M-N$ arası öklit uzunluğunun batarya sağlığına etkisi $L-M$ uzunluğu ile paralel olduğu görülmektedir. Bu nedenle gereksiz veri karmaşasından kurtulmak için $M-N$ uzunluğu göz ardı edilmiştir ve $L-M$ öklit uzunluğu ile beraber $K-L$ öklit uzunluğu sağlık durumu belirlemek için özellik olarak seçilmiştir.

3. MATERYAL VE YÖNTEM

3.1. Batarya Sağlık Durumunun Kestirilmesi

Bataryaların sağlık durumu kestirimi için veri tabanlı yöntemler, karmaşıklıktan uzak bir yapısının olması, deneysel çalışmalara uygulanabilir olması ve yüksek doğrulukla sonuçlar vermeleri nedeniyle son zamanlarda oldukça fazla kullanılmaktadır. Uygulamalı çalışmalarda bataryaların akım, gerilim, kapasite ve kapasite azalması gibi veriler doğrudan elde edilebilmektedir. Bu nedenle doğrudan elde edilebilen bu veriler ile veri tabanlı yöntemler kullanılarak batarya sağlık durumu kestirimi yapılması mümkündür (Rufus et al., 2008).


Bu çalışmada veri tabanlı batarya sağlık durumu belirlemesi makine öğrenmesi ile gerçekleştirilmiştir. Bu amaçla öncelikle makine öğrenmesi algoritmasında kullanılmak üzere giriş verileri belirlenmiştir. Çalışmada gerekli olan batarya verileri, CALCE'nin internet ortamında açık olarak yayınladığı verilerinden elde edilmiştir. Calce Batarya Araştırma Grubunun yayınlamış internet ortamında açık erişimli olarak yayınladığı veriler incelendiği zaman, bataryalar sürekli olarak şarj-deşarj işlemi gerçekleştirilmiş ve bataryalara ait tüm veriler Excel dosyalarında kaydedilmiş ve elde edilen veriler ile bir veri tabanı oluşturulmuştur. Bataryalara ait tüm verileri içeren dosyalar içinden, makine öğrenmesi algoritmasının veri tabanını oluştururken gerekli olmayacak bilgilerin temizlenmesi ile çalışmada kullanılan veri tabanı oluşturulmuştur. Bu veri tabanı PYTHON programlama dilinde kullanılmak üzere EXCEL formatında kaydedilmiştir. Bataryalara ait,deşarj akımı,deşarj gerilimi, nominal kapasite, kapasite azalma miktarı bilgileri sağlık durumunun kestiriminde kullanılmıştır. CALCE'den alınan 12 adet farklı batarya verisi kullanılmıştır. Her bir bataryaya ait alınan veriler toplam 50 şarj-deşarj döngüsünden oluşmaktadır. Kullanılan bataryalar ve özellikleri Tablo 3.1'de verilmiştir.

Bataryaların kapasite azalma grafikleri incelendiği zaman bazı verilerde bozukluk olduğu görülmüştür. Ölçüm işleminden kaynaklanan ve normalde mevcut olması imkansız olan bu durumların gerçekleştirilecek çalışmanın başarısını olumsuz etkilememesi için, bataryaların kapasite azalma verileri filtre kullanılarak düzenlenmiştir. Filtreleme işlemi sadece hatalı olan bölümlere uygulanmıştır. Bunun için öncelikle tüm veri yazılımsal analiz edilmiş ve anormal değerler belirlenmiştir. Filtreleme işleminde her bir adımdaki kapasite azalımı bir önceki durumdaki kapasite değeri ile karşılaştırılmıştır. Eğer iki kapasite azalma miktarı arasındaki değişim eşik


değerin üstünde ise filtreleme gerçekleştirilmiş ve bir önceki kapasite azalma miktarının %95'i kadar azalma olduğu varsayılmıştır. Kullanılan bataryalar için kapasite azalma verileri filtresiz ve filtreli grafikleri Şekil 3.1'de verilmiştir.

Tablo 3.1. Kullanılan bataryalar ve özellikleri


Batarya İsmi	Akım (A)	Kapasite (Ah)
CS2 33	0,55	1,1
CS2 34	0,55	1,1
CS2 35	1,1	1,1
CS2 36	1,1	1,1
CS2 37	1,1	1,1
CS2 38	1,1	1,1
CX2 33	0,675	1,35
CX2 34	1,35	1,35
CX2 35	0,675	1,35
CX2 36	1,35	1,35
CX2 37	1,35	1,35
CX2 38	1,35	1,35




(a)




(b)



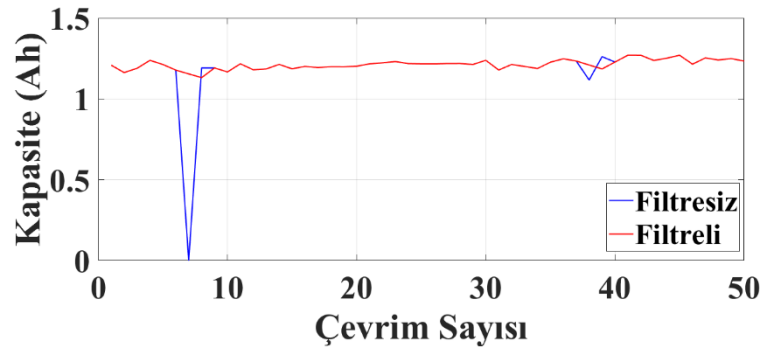
(c)



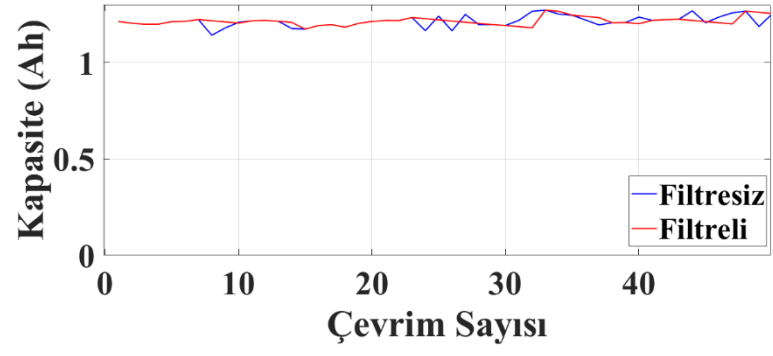
(d)




(e)




(f)




(g)




(h)



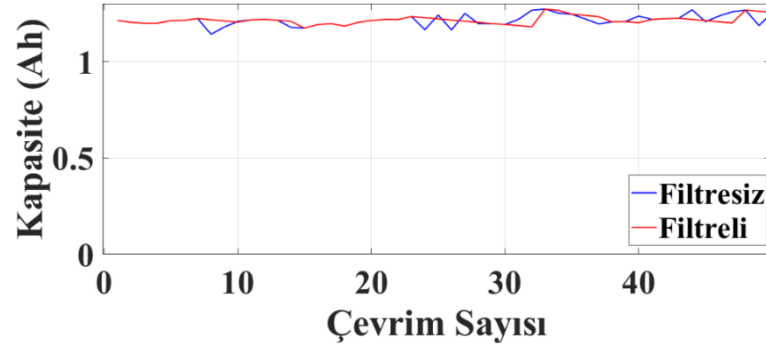
(i)



(i)



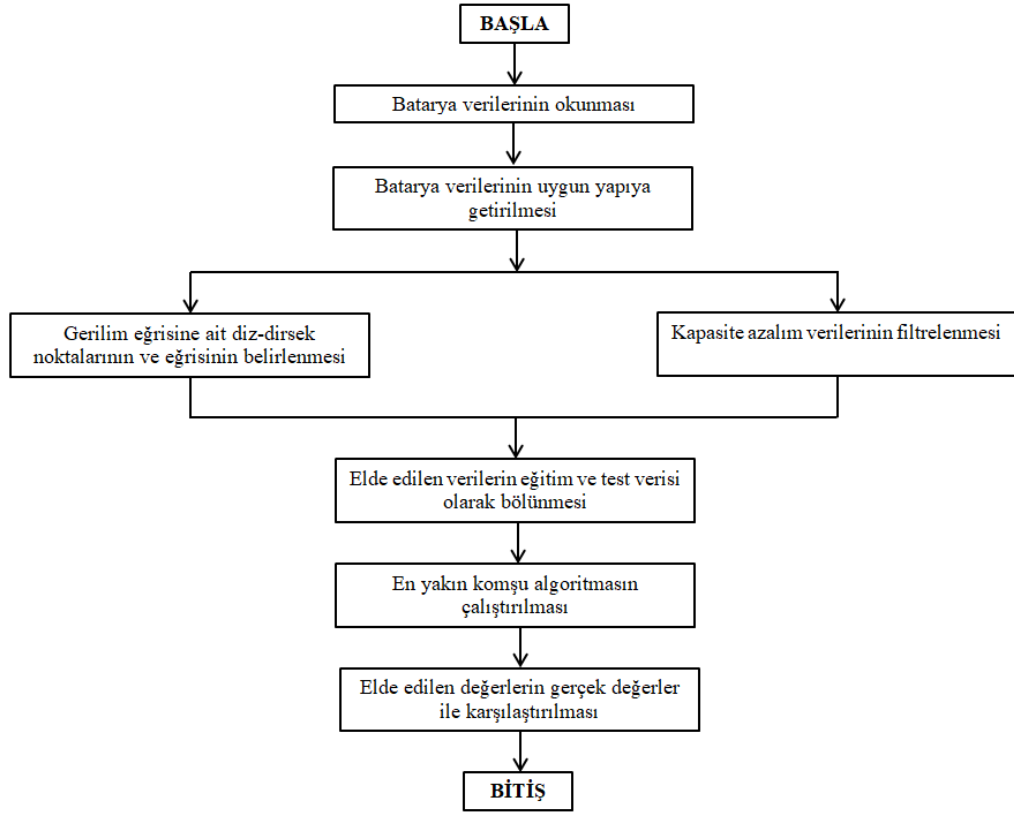
(j)



(k)

Şekil 3.1. Kapasite filtresiz ve filtreli durum (a) CS2 33 (b) CS2 34 (c) CS2 35 (d) CS2 36 (e) CS2 37 (f) CS2 38 (g) CX2 33 (h) CX2 34 (i) CX2 35 (i) CX2 36 (j) CX2 37 (k) CX2 38

Sağlık durumu kestiriminde bataryanın deşarj olması durumunda elde edilen akım, kapasite azalması, gerilim gibi değerler kullanılmıştır. Batarya sağlık durumu belirleme sürecinde deşarj esnasında elde edilen gerilim değerleri doğrudan kullanılmıştır. Bu çalışmada ise diğer çalışmalardan farklı olarak, deşarj gerilim grafiğindeki diz-dirsek noktaları belirlenerek gerilimdeki değişimler daha ayrıntılı olarak ele alınmıştır. Bunun yanı sıra diz-dirsek noktalarındaki değişimlerin zaman farkı, deşarj eğrisi üzerindeki en yüksek ve en düşük gerilim değerleri ve aralarındaki zaman farkı da hesaba katılmıştır.



Şekil 3.2. Batarya sağlık durumu belirleme akış şeması

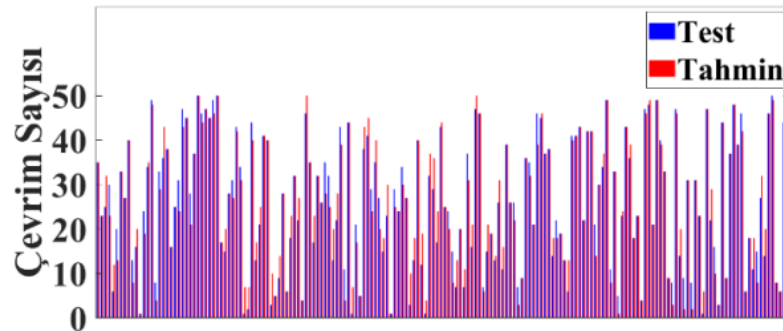
Belirlenen giriş verileri (batarya deşarj sürecinden elde edilen akım, gerilim, kapasite azalımı, gerilim eğrisi diz-direk noktaları ve eğrileri) kullanılarak batarya sağlık durumunun belirlenebilmesi için iki farklı makine öğrenmesi algoritması oluşturulmuştur. Kullanılan ilk algoritma k-En Yakın Komşu algoritması diğer yöntem ise Rastgele Orman Regresyon yöntemidir. Verilerin düzenlenmesi, işlenmesi, makine öğrenmesi algoritması vb. tüm işlemler PYTHON programlama dili kullanılarak gerçekleştirilmiştir. PYTHON programlama dilinde hazırlanan algoritmanın tüm çalışmasını anlatan blok şema Şekil 3.2’de verilmiştir. Şekil 3.2 k-En Yakın Komşu algoritması özelinde verilmiştir. Rastgele Orman Regresyon yöntemi için de aynı algoritma geçerlidir.


4. BULGULAR VE TARTIŞMA

Şekil 3.2’de verilen akış şemasına uygun olarak batarya sağlık durumu belirleme yazılımı hem k-En Yakın Komşu hem de Rastgele Orman Regresyonu yöntemi için PYTHON programlama dili kullanılarak hazırlanmıştır. Öncelikle hazırlanan yazılım bataryaya ait veri kümesini EXCEL dosyasından okumakta ve yazılım için uygun formata getirmektedir. Ölçüm işleminden kaynaklı hataların bulunduğu kapasite değerleri filtrelenerek, bu hatalı değerlerin sağlık durumu belirleme işleminde hataya sebep vermesinin önüne geçilmiştir. Ayrıca makine öğrenmesi algoritmalarının girişlerinden biri olan deşarj sürecine ait gerilim eğrisinin diz/dirsek noktaları belirlenmektedir. Hesaplamalar ve veri kümesinden elde edilen giriş verileri test ve eğitim olarak ikiye bölünmektedir. Bu aşamadan sonra her iki makine öğrenme yöntemi ile batarya sağlığı belirleme işlemi gerçekleştirilmektedir. Program çıkışında, herhangi bir bataryaya ait giriş verilerine karşılık, bu verilerin bataryanın hangi çevriminde elde edildiği tahmin edilmektedir. Tasarlanan algoritmaların başarısı iki farklı senaryo ile test edilmiştir. Gerçekleştirilen senaryolar aşağıdaki gibidir.

- 12 batarya (her bir bataryaya ait 50 şarj-deşarj döngüsü) eğitim-test verisi (sırasıyla %70-%30) olarak rastgele bölündü.
- 12 bataryadan 11 bataryaya ait veri eğitim girişi, kalan 1 batarya test verisi olarak bölündü.

İlk senaryo ile eğitilen sistem, tüm bataryalara ait bazı verilere sahip olmuştur. Böylece test edilecek bataryalara ait güçlü bir eğitim ağı oluşturulabilmiştir. Eğitim verileri ile eğitilen sisteme test verileri uygulanmış. k-En Yakın Komşu ve Rastgele Orman Regresyon yöntemleri için elde edilen sonuçlar Şekil 4.1’de verilmiştir. Şekil 4.1’de mavi sütunlar hesaplanması gereken batarya çevrim sayısı, kırmızı sütunlar ise hesaplanan çevrim sayısıdır.





Şekil 4.1. Senaryo 1 için test ve tahmin edilem değerleri (a) k-En Yakın Komşu yöntemi (b) Rastgele Orman Regresyon yöntemi


Gerçekleştirilen sistemin toplam başarısı ortalama mutlak hata (MAE) hesabı kullanılarak değerlendirilmiştir. MAE hesabı aşağıda verilmiştir, burada $\zeta_{gerçek}$ gerçek çevrim sayısı, ζ_{hesap} hesaplanan çevrim sayısıdır. İlk senaryoya ait MAE değeri ve sistemin doğruluk değeri Tablo 4.1’de verilmiştir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |\zeta_{gerçek} - \zeta_{hesap}| \cdot \%100 \quad (4.1)$$

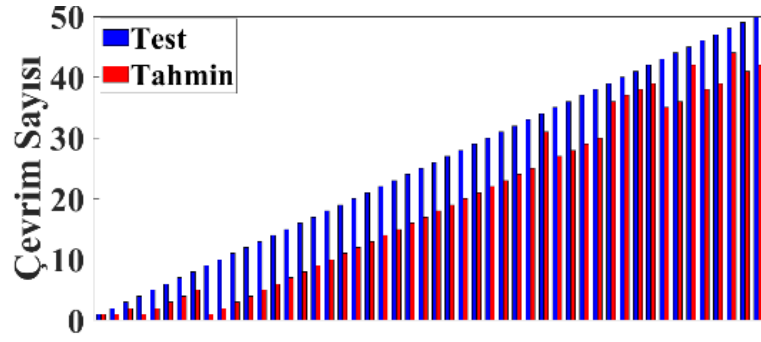
İkinci senaryoda 12 bataryadan 11 tanesi eğitim amacıyla kullanılmıştır. 1 batarya ise test amacıyla kullanılmıştır. Burada 12 bataryanın hepsi için bu durum tekrarlanmıştır. Bu şekilde, tasarlanan sağlık durumu belirleme algoritması, hiçbir verisine sahip olmadığı bir bataryanın sağlık durumunu belirlemesi istenmiştir. Böylece oluşturulan algoritmaların, hiçbir bilgisi olmadığı (eğitim verilerinde bulunmayan) bir batarya için tahmin performansı değerlendirilmiştir. 12 bataryanın her birinin test grubu olduğu (dolayısıyla kalan 11 batarya eğitim verisi olarak kullanılmıştır) durum için elde edilen sonuçlar k-En Yakın Komşu ve Rastgele Orman Regresyon yöntemleri için sırasıyla Şekil 4.2 ve Şekil 4.3’te verilmiştir.

Tablo 4.1. Senaryo 1 için bataryalara ait MAE ve doğruluk oranları


Yöntem	MAE	Doğruluk
k-En Yakın Komşu	5.2	94.8
Rastgele Orman Regresyon	3.87	96.13




(a)




(b)




(c)



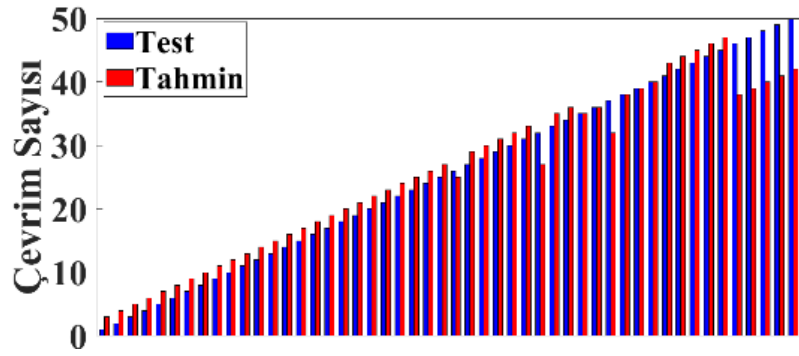
(d)



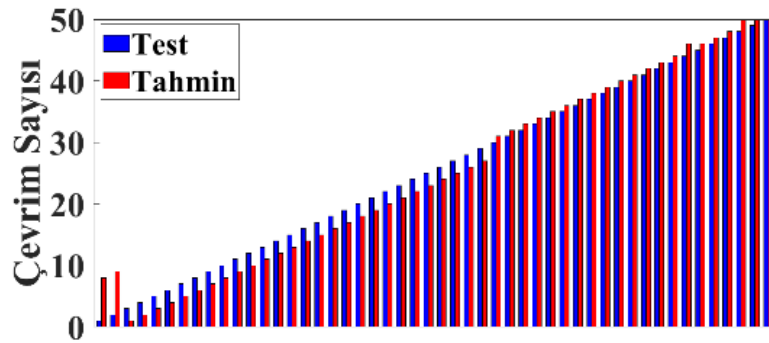
(e)




(f)




(g)




(h)




(a)



(b)




(c)




(d)


Şekil 4.2. k- En Yakın Komşu yöntemi için test ve tahmin değerleri (a) CS2 33 (b) CS2 34 (c) CS2 35 (d) CS2 36 (e) CS2 37 (f) CS2 38 (g) CX2 33 (h) CX2 34 (i) CX2 35 (j) CX2 36 (k) CX2 38




(a)




(b)




(c)




(d)




(e)




(f)



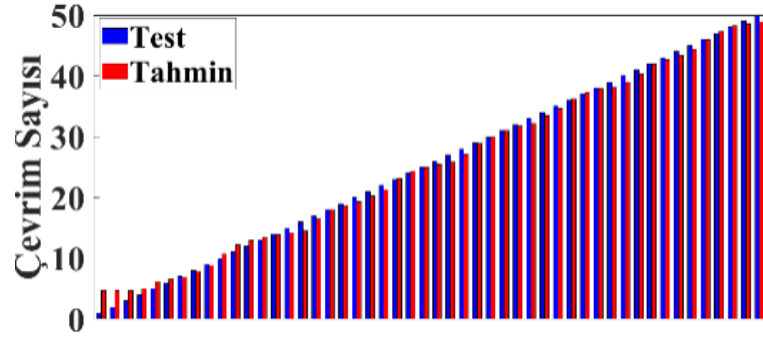
(g)




(h)




(i)



(i)



(j)



(k)

Şekil 4.3. Rastgele Orman Regresyon yöntemi için test ve tahmin değerleri (a) CS2 33 (b) CS2 34 (c) CS2 35 (d) CS2 36 (e) CS2 37 (f) CS2 38 (g) CX2 33 (h) CX2 34 (i) CX2 35 (j) CX2 36 (k) CX2 37

Gerçekleştirilen sistemin toplam başarısı ortalama mutlak hata (MAE) hesabı kullanılarak değerlendirilmiştir. Her bir bataryaya ait MAE hesabı sonucu ve doğruluk oranı Tablo 4.2’de verilmiştir. Tablo 4.2’ye göre MAE değerlerinin ortalama değerleri k-En Yakın Komşu yöntemi için 5,65 Rastgele Orman Regresyon yöntemi için 1,53 olarak hesaplanmıştır.

Tablo 4.2. Senaryo 2 için bataryalara ait MAE ve doğruluk oranları

Batarya İsmi	k-En Yakın Komşu		Rastgele Orman Regresyon	
	MAE	Doğruluk	MAE	Doğruluk
CS2 33	7.72	92.28	1.83	98.17
CS2 34	12.76	87.24	2.24	97.76
CS2 35	7.44	92.56	1.31	98.69
CS2 36	3.84	96.16	1.3	98.7
CS2 37	5.12	94.88	1.36	98.74
CS2 38	2.56	97.44	1.34	98.76
CX2 33	5	95	2.18	97.81
CX2 34	3.6	96.4	2.23	98.77
CX2 35	8.04	91.96	1.1	98.9
CX2 36	8.04	91.96	1.17	98.83
CX2 37	3.16	96.84	1.08	98.92
CX2 38	0.48	99.52	1.2	98.8

5. SONUÇ

Bu tez çalışmasında, batarya sağlık durumunun belirlenmesi için, matematiksel yapıya ihtiyaç duyulmaması, doğrusal olmayan olmayan batarya yapısına uygun olması, doğruluğunun yüksek olması ve yapısının karmaşık olmamasından dolayı, veri tabanlı yöntemlerden makine öğrenmesi yöntemi kullanılmıştır. Bu amaçla bataryanın deşarj olması durumunda elde edilen akım, kapasite azalması, gerilim gibi değerler kullanılmıştır. Öncelikle hazırlanan yazılım bataryaya ait veri kümesini EXCEL dosyasından okumakta ve yazılım için uygun formata getirmektedir. Ölçüm işleminden kaynaklı hataların bulunduğu kapasite değerleri filtrelenerek, bu hatalı değerlerin sağlık durumu belirleme işleminde hataya sebep vermesinin önüne geçilmiştir. Ayrıca makine öğrenmesi algoritmalarının girişlerinden biri olan deşarj sürecine ait gerilim eğrisinin diz/dirsek noktaları belirlenmektedir. Hesaplamalar ve veri kümesinden elde edilen giriş verileri test ve eğitim olarak ikiye bölünmektedir. Bu aşamadan sonra makine öğrenme yöntemi ile batarya sağlığı belirleme işlemi gerçekleştirilmektedir. Program çıkışında, herhangi bir bataryaya ait giriş verilerine karşılık, bu verilerin bataryanın hangi çevriminde elde edildiği tahmin edilmektedir.

Bu tez çalışmasında, batarya sağlığını belirlemek için deşarj sürecinden elde edilen birçok veri (deşarj gerilimi, akımı, kapasitesi) beraber kullanılmıştır. Ayrıca deşarj gerilim değişimini doğrudan kullanmak yerine gerilim grafiğindeki kırılma noktaları (diz-dirsek noktaları) belirlenerek gerilimdeki değişimler daha ayrıntılı olarak dikkate alınmıştır. Belirlenen giriş verileri kullanılarak batarya sağlık durumunun belirlenebilmesi için iki farklı makine öğrenmesi algoritması (k-En Yakın Komşu yöntemi ve Rastgele Orman Regresyon yöntemi) oluşturulmuştur. Makine öğrenmesi yöntemini sınıflandırma, kümeleme, eğri uydurma (regresyon), özellik seçimi/çıkarımı ve ilişki belirleme olmak üzere beş farklı alt başlıkta sınıflandırmak mümkündür. Bu tez çalışmasında kullanılan bataryalara ait veriler sınıflandırma ve eğri uydurma (regresyon) alt başlıklarına uygun olduğu için batarya sağlık durumunu belirlemek amacıyla, k-En yakın Komşu Yöntemi ve Orman Regresyon Yöntemi kullanılmıştır.

Bu çalışmada CALCE'nin internet ortamında açık olarak yayınladığı batarya verilerinden yararlanılmıştır. CALCE'den alınan 12 adet bataryaya ait veriler (her bir bataryaya ait 50 şarj-deşarj döngüsü), çalışma hedefleri doğrultusunda düzenlenmiştir. Gerçekleştirilen sağlık durumu belirleme yazılımı için PYTHON dili

kullanılmıştır. Batarya sağlık durumunun belirlenmesi için kullanılan yöntemlerin başarısı iki farklı senaryo ile değerlendirilmiştir. İlk senaryo tüm batarya verilerinin karışık olarak değerlendirilip, tüm bataryalara ait verilerden oluşan eğitim ve test verilerinin oluşturulması ile gerçekleştirilmiştir. Şekil 4.1 ve Tablo 4.1'den anlaşıldığı üzere kullanılan her iki yöntem de ilk senaryoda başarılı olmuştur. Ancak iki yöntem birbiri ile karşılaştırıldığı zaman Rastgele Orman Regresyon yönteminin daha başarılı olduğu görülmüştür. Diğer senaryo ise elde bulunan 12 bataryadan 11'ini eğitim verisini kalan 1 bataryanın ise test verisini oluşturduğu durumdur. Burada 12 bataryanın her biri ayrı ayrı test verisi olarak değerlendirilmiştir. Şekil 4.2, Şekil 4.3 ve Tablo 4.2 değerlendirildiği zaman k-En Yakın Komşu yönteminin sadece bir batarya için daha başarılı olmuştur. Diğer bataryalarda ise Rastgele Orman Regresyon yöntemi daha başarılı olmuştur. Tablo 4.2'ye göre tüm testlerin ortalaması alındığı zaman yine Rastgele Orman Regresyon yöntemi k-En Yakın Komşu yöntemine göre oldukça daha başarılı olmuştur.

Bu tez çalışması ile gerçek zamanlı bir çalışma için altyapı oluşturulmuştur. Bu amaçla diğer çalışmalardaki gibi MATLAB ortamı yerine PYTHON programlama dili kullanılmıştır. Bu şekilde gömülü yazılım için hazır bir sistem oluşturulmuştur. Gerçekleştirilen makine öğrenmesi algoritmasının başarısını arttırmak için sağlık durumu ile doğrudan alakalı olan deşarj gerilim eğrisinde daha fazla özellik çıkartılmıştır. Ayrıca batarya iç direnci değeri kullanılmamasına rağmen yüksek doğruluklu sonuçlar elde edilmiştir. Ölçülmesi hassas işlemler ve özel şartlar gerektiren batarya iç direnci sağlık durumunun belirlenmesinde önemli bir problemdir.

KAYNAKÇA

- Allam, A., Onori, S., Marelli, S. ve Taborelli, C. (2015). Battery health management system for automotive applications: A retroactivity-based aging propagation study. 2015 American Control Conference (ACC), IEEE, 703-716.
- Alpaydin, E. (2020). *Introduction to machine learning*. MIT press,
- Anava, O. ve Levy, K. (2016). k*-nearest neighbors: From global to local. *Advances in neural information processing systems*, 29.
- Berecibar, M., Gandiaga, I., Villarreal, I., Omar, N., Van Mierlo, J. ve 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.
- Bhagavatula, S. V., Yellamraju, V. R. B., Eltem, K. C., Bobba, P. B. ve Marati, N. (2020). ANN based Battery Health Monitoring-A Comprehensive Review. E3S Web of Conferences, EDP Sciences, 01068.
- Bi, J., Zhang, T., Yu, H. ve Kang, Y. (2016). State-of-health estimation of lithium-ion battery packs in electric vehicles based on genetic resampling particle filter. *Applied energy*, 182, 558-568.
- Bostan, E. A. (2019). Elektrikli Araçlardaki Lityum İyon Bataryalar İçin Şarj Durumu Tahmini. İstanbul Teknik Üniversitesi
- Breiman, L. (2001). Random forests. *Machine learning*, 45:1, 5-32.
- Chaoui, H., Golbon, N., Hmouz, I., Souissi, R. ve Tahar, S. (2014). Lyapunov-based adaptive state of charge and state of health estimation for lithium-ion batteries. *IEEE Transactions on Industrial Electronics*, 62:3, 1610-1618.
- Chaoui, H. ve Ibe-Ekeocha, C. C. (2017). State of charge and state of health estimation for lithium batteries using recurrent neural networks. *IEEE Transactions on Vehicular Technology*, 66:10, 8773-8783.
- Chen, Z., Song, X., Xiao, R., Shen, J. ve Xia, X. (2018). State of health estimation for lithium-ion battery based on long short term memory networks. *DEStech Transactions on Environment, Energy and Earth Sciences ICEEE*.
- Elasan, S. (2019). Veri Madenciliğinde Farklı Karar Ağaçları ve K-En Yakın Komşuluk Yöntemlerinin İncelenmesi: Kadın Hastalıkları ve Doğum Verisinde Bir Uygulama [Doktora Tezi]. Van: Van Yüzüncü Yıl Üniversitesi.
- Ercire, M. ve Ünsal, A. (2021). Kısa Süreli Güç Kalitesi Bozulmalarının Dalgacık Analizi ve Rastgele Orman Yöntemi ile Sınıflandırılması. *Uludağ University Journal of The Faculty of Engineering*, 26:3, 903-920.
- Feng, X., Weng, C., He, X., Han, X., Lu, L., Ren, D. ve Ouyang, M. (2019). Online state-of-health estimation for Li-ion battery using partial charging segment based on support vector machine. *IEEE transactions on vehicular technology*, 68:9, 8583-8592.
- Gao, Y., Liu, K., Zhu, C., Zhang, X. ve Zhang, D. (2021). Co-estimation of state-of-charge and state-of-health for lithium-ion batteries using an enhanced electrochemical model. *IEEE Transactions on Industrial Electronics*, 69:3, 2684-2696.
- Goebel, K., Saha, B., Saxena, A., Mct, N. ve Riacs, N. (2008). A comparison of three data-driven techniques for prognostics. 62nd meeting of the society for machinery failure prevention technology (mfpt), 119-131.
- Goud, J. S., Kalpana, R. ve Singh, B. (2020). An online method of estimating state of health of a Li-ion battery. *IEEE Transactions on Energy Conversion*, 36:1, 111-119.

- Goyal, R., Chandra, P. ve Singh, Y. (2014). Suitability of KNN regression in the development of interaction based software fault prediction models. *Ieri Procedia*, 6, 15-21.
- Calce Battery Group, Battery data. (2017). <https://web.calce.umd.edu/batteries/data.htm#CS2>. (Erişim:12.05.2021)
- Hannan, M. A., Hoque, M. M., Peng, S. E. ve Uddin, M. N. (2017). Lithium-ion battery charge equalization algorithm for electric vehicle applications. *IEEE Transactions on Industry Applications*, 53:3, 2541-2549.
- Hastie, T. ve Tibshirani, R. (2001). J. Friedman The Elements of Statistical Learning. Chapter 6: Springer Verlag, New York.
- Hu, X., Jiang, J., Cao, D. ve Egardt, B. (2015). Battery health prognosis for electric vehicles using sample entropy and sparse Bayesian predictive modeling. *IEEE Transactions on Industrial Electronics*, 63:4, 2645-2656.
- Hu, X., Yuan, H., Zou, C., Li, Z. ve Zhang, L. (2018). Co-estimation of state of charge and state of health for lithium-ion batteries based on fractional-order calculus. *IEEE transactions on vehicular technology*, 67:11, 10319-10329.
- Hu, X., Zou, C., Zhang, C. ve Li, Y. (2017). Technological developments in batteries: a survey of principal roles, types, and management needs. *IEEE Power and Energy Magazine*, 15:5, 20-31.
- James, G., Witten, D., Hastie, T. ve Tibshirani, R. (2013). *An introduction to statistical learning*. Springer,
- Khan, N., Ullah, F. U. M., Ullah, A., Lee, M. Y. ve Baik, S. W. (2020). Batteries state of health estimation via efficient neural networks with multiple channel charging profiles. *IEEE Access*, 9, 7797-7813.
- Kim, J., Lee, S. ve Cho, B. (2011). Complementary cooperation algorithm based on DEKF combined with pattern recognition for SOC/capacity estimation and SOH prediction. *IEEE Transactions on Power Electronics*, 27:1, 436-451.
- Kim, T., Song, W., Son, D.-Y., Ono, L. K. ve Qi, Y. (2019). Lithium-ion batteries: outlook on present, future, and hybridized technologies. *Journal of materials chemistry A*, 7:7, 2942-2964.
- Kök, A. E. (2021). Enerji Depolama Sistemlerinde Kullanılan Lityum-İyon Hücrelerin Sıfır Şarj Sonlandırma Akımı ile Şarjının Hücre Sağlık Durumuna Etkisinin İncelenmesi. Yüksek lisans, Erciyes Üniversitesi, 86
- Li, Y., Sheng, H., Cheng, Y., Stroe, D.-I. ve Teodorescu, R. (2020). State-of-health estimation of lithium-ion batteries based on semi-supervised transfer component analysis. *Applied Energy*, 277, 115504.
- Lin, C.-P., Cabrera, J., Yang, F., Ling, M.-H., Tsui, K.-L. ve Bae, S.-J. (2020). Battery state of health modeling and remaining useful life prediction through time series model. *Applied Energy*, 275, 115338.
- Lin, H.-T., Liang, T.-J. ve Chen, S.-M. (2012). Estimation of battery state of health using probabilistic neural network. *IEEE transactions on industrial informatics*, 9:2, 679-685.
- Linden, D. ve Reddy, T. (2002). Handbook of Batteries, Third Eddition, McGraw-Hill.
- Liu, D., Yin, X., Song, Y., Liu, W. ve Peng, Y. (2018). An on-line state of health estimation of lithium-ion battery using unscented particle filter. *IEEE Access*, 6, 40990-41001.
- Ma, Z., Yang, R. ve Wang, Z. (2019). A novel data-model fusion state-of-health estimation approach for lithium-ion batteries. *Applied energy*, 237, 836-847.

- Matsuki, K. ve Ozawa, K. (2009). General concepts. *Lithium Ion Rechargeable Batteries: Materials, Technology, and New Applications*, 1-9.
- Murray, D. (2022). <https://medium.datadriveninvestor.com/what-is-machine-learning-55028d8bdd53>.
- Nazri, G.-A. ve Pistoia, G. (2008). *Lithium batteries: science and technology*. Springer Science & Business Media,
- Ning, B., Cao, B., Wang, B. ve Zou, Z. (2018). Adaptive sliding mode observers for lithium-ion battery state estimation based on parameters identified online. *Energy*, 153, 732-742.
- Noura, N., Boulon, L. ve Jemeï, S. (2020). A review of battery state of health estimation methods: Hybrid electric vehicle challenges. *World Electric Vehicle Journal*, 11:4, 66.
- Özkan, K. (2012). Sınıflandırma ve regresyon ağacı tekniği (SRAT) ile ekolojik verinin modellenmesi. *Süleyman Demirel Üniversitesi Orman Fakültesi Dergisi*, 13:1, 1-4.
- Pan, H., Lü, Z., Wang, H., Wei, H. ve Chen, L. (2018). Novel battery state-of-health online estimation method using multiple health indicators and an extreme learning machine. *Energy*, 160, 466-477.
- Pascoe, P. E. ve Anbuky, A. H. (2005). Standby power system VRLA battery reserve life estimation scheme. *IEEE Transactions on Energy Conversion*, 20:4, 887-895.
- Pola, D. A., Navarrete, H. F., Orchard, M. E., Rabić, R. S., Cerda, M. A., Olivares, B. E., Silva, J. F., Espinoza, P. A. ve Pérez, A. (2015). Particle-filtering-based discharge time prognosis for lithium-ion batteries with a statistical characterization of use profiles. *IEEE Transactions on Reliability*, 64:2, 710-720.
- Polatöz, H. S. (2019). Havacılıkta Kullanılan Lityum Tabanlı Bataryaların Yapay Sinir Ağları ile Ömür Kestirimine Katkıları. İstanbul Teknik Üniversitesi
- Qiuting, W., Yinzhui, J. ve Yunhao, L. (2015). State of health estimation for lithium-ion battery based on d-ukf. *Int. J. Hybrid Inf. Technol*, 8:16.
- Ren, H., Zhao, Y., Chen, S. ve Wang, T. (2019). Design and implementation of a battery management system with active charge balance based on the SOC and SOH online estimation. *Energy*, 166, 908-917.
- Rozaqi, L. ve Rijanto, E. (2016). SOC estimation for Li-ion battery using optimum RLS method based on genetic algorithm. 2016 8th International Conference on Information Technology and Electrical Engineering (ICITEE), IEEE, 1-4.
- Rozaqi, L., Rijanto, E. ve Kanarachos, S. (2017). Comparison between RLS-GA and RLS-PSO for Li-ion battery SOC and SOH estimation: a simulation study. *Journal of Mechatronics, Electrical Power, and Vehicular Technology*, 8:1, 40-49.
- Rufus, F., Lee, S. ve Thakker, A. (2008). Health monitoring algorithms for space application batteries. 2008 International Conference on Prognostics and Health Management, IEEE, 1-8.
- Saji, D., Babu, P. S. ve Ilango, K. (2019). SoC Estimation of Lithium Ion Battery Using Combined Coulomb Counting and Fuzzy Logic Method. 2019 4th International Conference on Recent Trends on Electronics, Information, Communication & Technology (RTEICT), IEEE, 948-952.
- Shahriari, M. ve Farrokhi, M. (2010). State of health estimation of VRLA batteries using fuzzy logic. 2010 18th Iranian Conference on Electrical Engineering, IEEE, 629-634.

- Sheikh, S. S., Anjum, M., Khan, M. A., Hassan, S. A., Khalid, H. A., Gastli, A. ve Ben-Brahim, L. (2020). A battery health monitoring method using machine learning: A data-driven approach. *Energies*, 13:14, 3658.
- Shen, P., Ouyang, M., Lu, L., Li, J. ve Feng, X. (2017). The co-estimation of state of charge, state of health, and state of function for lithium-ion batteries in electric vehicles. *IEEE transactions on vehicular technology*, 67:1, 92-103.
- Shu, X., Li, G., Zhang, Y., Shen, J., Chen, Z. ve Liu, Y. (2020). Online diagnosis of state of health for lithium-ion batteries based on short-term charging profiles. *Journal of Power Sources*, 471, 228478.
- Sierra, G., Orchard, M., Goebel, K. ve Kulkarni, C. (2019). Battery health management for small-size rotary-wing electric unmanned aerial vehicles: An efficient approach for constrained computing platforms. *Reliability Engineering & System Safety*, 182, 166-178.
- Song, Y., Liu, D., Yang, C. ve Peng, Y. (2017). Data-driven hybrid remaining useful life estimation approach for spacecraft lithium-ion battery. *Microelectronics Reliability*, 75, 142-153.
- Spagnol, P., Rossi, S. ve Savaresi, S. M. (2011). Kalman filter SoC estimation for Li-ion batteries. 2011 IEEE International Conference on Control Applications (CCA), IEEE, 587-592.
- Sullivan, W. (2017). *Machine Learning For Beginners Guide Algorithms: Supervised & Unsupervised Learning. Decision Tree & Random Forest Introduction*. Healthy Pragmatic Solutions Inc,
- Sun, S. ve Huang, R. (2010). An adaptive k-nearest neighbor algorithm. 2010 seventh international conference on fuzzy systems and knowledge discovery, IEEE, 91-94.
- Tan, X., Tan, Y., Zhan, D., Yu, Z., Fan, Y., Qiu, J. ve Li, J. (2020). Real-time state-of-health estimation of lithium-ion batteries based on the equivalent internal resistance. *Ieee Access*, 8, 56811-56822.
- Tang, X., Wang, Y., Zou, C., Yao, K., Xia, Y. ve Gao, F. (2019). A novel framework for Lithium-ion battery modeling considering uncertainties of temperature and aging. *Energy conversion and management*, 180, 162-170.
- Topan, P. A., Ramadan, M. N., Fathoni, G., Cahyadi, A. I. ve Wahyunggoro, O. (2016). State of Charge (SOC) and State of Health (SOH) estimation on lithium polymer battery via Kalman filter. 2016 2nd International Conference on Science and Technology-Computer (ICST), IEEE, 93-96.
- Ungurean, L., Cârstoiu, G., Micea, M. V. ve Groza, V. (2017). Battery state of health estimation: a structured review of models, methods and commercial devices. *International Journal of Energy Research*, 41:2, 151-181.
- Ungurean, L., Micea, M. V. ve Carstoiu, G. (2020). Online state of health prediction method for lithium-ion batteries, based on gated recurrent unit neural networks. *International Journal of Energy Research*, 44:8, 6767-6777.
- Unterrieder, C., Priewasser, R., Marsili, S. ve Huemer, M. (2013). Battery state estimation using mixed kalman/hinfinity, adaptive luenberger and sliding mode observer. 2013 IEEE Vehicle Power and Propulsion Conference (VPPC), IEEE, 1-6.
- Wang, Z., Yuan, C. ve Li, X. (2020). Lithium battery state-of-health estimation via differential thermal voltammetry with Gaussian process regression. *IEEE Transactions on Transportation Electrification*, 7:1, 16-25.

- Weng, C., Sun, J. ve Peng, H. (2014). Model parametrization and adaptation based on the invariance of support vectors with applications to battery state-of-health monitoring. *IEEE transactions on vehicular technology*, 64:9, 3908-3917.
- Wettschereck, D. ve Dietterich, T. (1993). Locally adaptive nearest neighbor algorithms. *Advances in neural information processing systems*, 6.
- Wu, J., Wang, Y., Zhang, X. ve Chen, Z. (2016). A novel state of health estimation method of Li-ion battery using group method of data handling. *Journal of Power Sources*, 327, 457-464.
- Xiong, R., Cao, J. ve Yu, Q. (2018). Reinforcement learning-based real-time power management for hybrid energy storage system in the plug-in hybrid electric vehicle. *Applied energy*, 211, 538-548.
- Xiong, R., Zhang, Y., He, H., Zhou, X. ve Pecht, M. G. (2017). A double-scale, particle-filtering, energy state prediction algorithm for lithium-ion batteries. *IEEE Transactions on Industrial Electronics*, 65:2, 1526-1538.
- Yang, D., Wang, Y., Pan, R., Chen, R. ve Chen, Z. (2017). A neural network based state-of-health estimation of lithium-ion battery in electric vehicles. *Energy Procedia*, 105, 2059-2064.
- Yardımcı, T. (2011). Makine Öğrenmesi Teknikleri İle Rss Besleme Yönetimi. *Ankara: Yüksek Lisans Tezi, Bilgisayar Eğitimi, Gazi Üniversitesi, Bilişim Enstitüsü.*
- You, G.-w., Park, S. ve Oh, D. (2016). Real-time state-of-health estimation for electric vehicle batteries: A data-driven approach. *Applied energy*, 176, 92-103.
- Yu, J. (2013). Health degradation detection and monitoring of lithium-ion battery based on adaptive learning method. *IEEE Transactions on Instrumentation and Measurement*, 63:7, 1709-1721.
- Yu, J. (2015). State-of-health monitoring and prediction of lithium-ion battery using probabilistic indication and state-space model. *IEEE Transactions on Instrumentation and Measurement*, 64:11, 2937-2949.
- Zhang, S., Guo, X., Dou, X. ve Zhang, X. (2020). A rapid online calculation method for state of health of lithium-ion battery based on coulomb counting method and differential voltage analysis. *Journal of Power Sources*, 479, 228740.
- Zhang, Y., Xiong, R., He, H. ve Pecht, M. G. (2018). Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries. *IEEE Transactions on Vehicular Technology*, 67:7, 5695-5705.
- Zou, C., Manzie, C. ve Nešić, D. (2018). Model predictive control for lithium-ion battery optimal charging. *IEEE/ASME Transactions on Mechatronics*, 23:2, 947-957.

ÖZ GEÇMİŞ

Emine ÇAVUŞ, Akçaabat Anadolu Lisesi'ni bitirdikten sonra Karadeniz Teknik Üniversitesi Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği bölümünden 06.06.2015 tarihinde mezun oldu. 2019 yılında OMÜ LEE Elektrik Elektronik Mühendisliği Ana Bilim Dalı Yüksek Lisans programına girdi. Ocak 2020 yılından bu yana Milli Savunma Bakanlığında Elektronik Mühendisi olarak görev yapan Emine ÇAVUŞ, orta derecede İngilizce bilmektedir.

İletişim Bilgileri

ORCID ID : 0000-0002-0145-6961

Yayınlar:

1. Emine ÇAVUŞ, İdris SANCAKTAR Lityum-İyon Bataryalar için SOC Tahmin Yöntemlerinin Karşılaştırılması, 2. Uluslararası 19 Mayıs Yenilikçi Bilimsel Yaklaşımlar Kongresi, 12 / 2020 [Uluslararası]
2. Emine ÇAVUŞ, İdris SANCAKTAR Batarya sağlık durumunun makine öğrenmesi ile kestirimi, Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 11(3), 601-610, 07/2022.

Kazanılan Ödüller, Teşvikler ve Burslar

1. 2209-B (2241-A) - Sanayiye Yönelik Lisans Bitirme Tezi Destekleme Programı (Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK))