



**SAVUNMA SANAYİNDE YÜKSEK GÜÇLÜ PİLLERDE ŞARJ DURUMU
TAHMİNİ İÇİN MAKİNE ÖĞRENMESİ KULLANILMASI**

Kübra KAYAPINAR

**YÜKSEK LİSANS TEZİ
SAVUNMA TEKNOLOJİLERİ ANA BİLİM DALI**

**SİVAS BİLİM VE TEKNOLOJİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

NİSAN 2025

ETİK BEYAN

Sivas Bilim ve Teknoloji Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

.....
Kübra KAYAPINAR
05/04/2025

Savunma Sanayinde Yüksek Güçlü Pillerde Şarj Durumu Tahmini için Makine Öğrenmesi
Kullanılması

(Yüksek Lisans Tezi)

Kübra KAYAPINAR

SİVAS BİLİM ve TEKNOLOJİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Nisan 2025

ÖZET

Lityum iyon piller, yüksek enerji yoğunluğu, hafif yapısı ve uzun ömrü nedeniyle enerji depolama sistemlerinde yaygın olarak tercih edilmektedir. Bu piller, ulaşım sektörü, tüketici elektroniği ve yenilenebilir enerji uygulamaları gibi çeşitli alanlarda kullanılmaktadır. Ancak, SoC'nin doğru bir şekilde tahmin edilmesi, bu pillerin verimli ve güvenli bir şekilde kullanılabilmesi için büyük öneme sahiptir.

Bu çalışmada, farklı işletim koşullarında 500 şarj-deşarj döngüsüne tabi tutulan 8 lityum iyon pilden elde edilen bir veri seti kullanılmıştır. Veri seti, pil sıcaklığı, uygulanandeşarj akımı ve şarj-deşarj döngüsü sayısı gibi parametreleri içermektedir. Veri ön işleme aşamasında, eksik veriler işlenmiş, aykırı değerler tespit edilmiş ve özellik mühendisliği görevleri gerçekleştirilmiştir. Bu veri seti ile çeşitli makine öğrenmesi algoritmaları uygulanmıştır. Uygulanan makine öğrenmesi yöntemlerinden Random Forest Regressor modeli en başarılı sonucu elde etmemizde etkin model olmuştur.

Bilim Kodu : [Bilim Kodu]

Anahtar Kelimeler : Lityum-İyon Piller, Şarj Durumu (SoC) Tahmini, Makine Öğrenmesi

Sayfa Adedi : 53

Danışman : Prof. Dr. Emre BİÇER

Using Machine Learning for Charge State Prediction in High Power Batteries in Defense
Industry

(M. Sc. Thesis)

Kübra KAYAPINAR

SİVAS UNIVERSITY OF SCIENCE AND TECHNOLOGY
INSTITUTE OF GRADUATE STUDIES

April 2025

ABSTRACT

Lithium-ion batteries are widely preferred in energy storage systems due to their high energy density, lightweight structure, and long lifespan. These batteries are utilized in various fields such as the transportation sector, consumer electronics, and renewable energy applications. However, the accurate estimation of the State of Charge (SoC) is of great importance to ensure the efficient and safe utilization of these batteries.

In this study, a dataset obtained from eight lithium-ion batteries subjected to 500 charge-discharge cycles under different operating conditions was used. The dataset includes parameters such as battery temperature, applied discharge current, and the number of charge-discharge cycles. During the data preprocessing phase, missing values were handled, outliers were identified, and feature engineering tasks were carried out. Various machine learning algorithms were applied to the dataset. Among the implemented machine learning methods, the Random Forest Regressor model was found to be the most effective in achieving the highest prediction performance.

Science Code : [Science Code]

Key Words : Lithium-Ion Batteries, State of Charge (SoC) Estimation, Machine Learning

Page Number : 53

Supervisor : Prof. Dr. Emre BICER

TEŐEKKÜR

Bu tez alıőmasının her aőamasında bana yol gősteren, bilgi ve tecrübeleriyle araőtırmamın őekillenmesine byk katkı saėlayan deėerli danıőmanım Prof. Dr. Emre Bier'e en iten teőekkrlerimi sunarım. Hocamın akademik rehberliėi, sabrı ve destekleyici yaklaőımı, alıőmamın her aőamasında bana ilham kaynaėı olmuőtur. Sorularımı titizlikle yanıtlayarak beni bilimsel dőnmeye teővik etmiő, araőtırmamı daha ileriye taőımam iin srekli motive etmiőtir. Kendisine, bilgi ve birikimlerini benimle cmerte paylaőtıėı, bu srecin her anında yanımnda olduėu ve beni cesaretlendirdiėi iin minnettarım. Bu alıőmanın ortaya ıkmasında emeiėi geen herkese teőekkr ederim.



İÇİNDEKİLER

	Sayfa
ÖZET	vii
ABSTRACT.....	viii
TEŞEKKÜR.....	ix
İÇİNDEKİLER	x
ÇİZELGELERİN LİSTESİ.....	xii
ŞEKİLLERİN LİSTESİ	xiii
RESİMLERİN LİSTESİ	xiv
SİMGELER VE KISALTMALAR.....	xv
1. GİRİŞ.....	1
2. KAYNAK ARAŞTIRMASI	5
2.1. State of Charge (SoC)	5
2.2. SoC Belirleme Yöntemleri.....	6
2.2.1. Gerilim Tabanlı Yöntemler (Voltage-Based Methods).....	6
2.2.2. Kapasite Tabanlı Yöntemler (Capacity-Based Methods)	8
2.2.4. Kalman Filtresi (Kalman Filter).....	10
2.2.5. Makine Öğrenmesi	14
2.2.5.1 Denetimli Öğrenme (Supervised Learning).....	15
2.2.5.2 Sınıflandırma ve Regresyon.....	16
2.2.5.3 Denetimsiz Öğrenme (Unsupervised Learning).....	17
3. MATERYAL ve YÖNTEM.....	23
3.1. Materyal	23
3.2. Yöntem.....	25

3.2.1. k-En Yakın Komşu (KNN) Algoritması	25
3.2.2. Random Forest Algoritması	27
3.2.3. Linear Regression (Doğrusal Regresyon)	30
3.2.4. Support Vector Machine (SVR) - Destek Vektör Regresyonu	33
4. BULGULAR ve TARTIŞMA	38
4.1. Algoritmalar	40
4.1.1. K-En Yakın Komşu (K-NN):	40
4.1.2. Doğrusal Regresyon	41
4.1.3. Random Forest	43
4.1.4. Support Vector Machine (SVR)	45
5. SONUÇ VE ÖNERİLER	47
KAYNAKLAR	50
ÖZGEÇMİŞ	53

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1	40



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1: KNN SoC Tahmini	41
Şekil 2: Linear Regression SoC Tahmini.....	43
Şekil 3: Random Forest SoC Tahmini	44
Şekil 4: Support Vector Machine SoC tahmini.....	46



RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 1: Batarya Test Cihazı	24
Resim 2: Isı Kabini	24



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

A	Akım
Ah	Kapasite
V	Voltaj
C	Coulomb

Kısaltmalar

Açıklamalar

AI	Yapay zeka
ANN	Yapay sinir ağı
BYS	Batarya yönetim sistemi
LSTM	Uzun-kısa süreli bellek ağları
KNN	En Yakın Komşu Algoritması
MAE	Mean Absolute Error
ML	Makine öğrenmesi
MSE	Mean Squared Error
RAE	Relative Absolute Error
RMSE	Root Mean Squared Error
RRSE	Root Relative Squared Error
SMO	Sekansiyel minimal optimizasyon
SoC	Şarj durumu (State of Charge)
SoH	Sağlık durumu (State of Health)
SVR	Destek Vektör Regresyonu

1. GİRİŞ

Lityum iyon piller, günümüzde enerji depolama alanında en yaygın kullanılan teknolojilerden biri haline gelmiştir. Lityum, düşük ağırlığı, yüksek enerji yoğunluğu ve uzun ömrü ile batarya teknolojileri için ideal bir bileşen olarak öne çıkmaktadır. İlk olarak 1980'li yıllarda keşfedilen ve 1991 yılında ticari olarak piyasaya sürülen lityum iyon bataryalar, kısa sürede büyük bir gelişim göstermiştir. Bu teknolojinin gelişimi, farklı endüstrilerde enerji depolama için temel bir bileşen olmasını sağlamıştır. Lityum iyon piller, şarj edilebilirlikleri ve yüksek enerji verimlilikleri ile öne çıkmakta, bu da onları mobil cihazlar, elektrikli araçlar, yenilenebilir enerji sistemleri gibi pek çok farklı uygulama alanında vazgeçilmez kılmaktadır.

Lityum iyon pillerin en önemli avantajlarından biri, yüksek enerji yoğunluğudur. Bu, bataryaların daha küçük ve daha hafif olmalarına rağmen daha fazla enerji depolamalarına imkan tanır. Ayrıca, düşük kendi kendine deşarj oranı, uzun ömür ve hızlı şarj olabilme gibi özellikler de lityum iyon pillerin cazibesini artırmaktadır. Ancak, tüm bu avantajların yanı sıra, sürdürülebilirlik, maliyet ve güvenlik gibi zorluklarla da karşı karşıya kalmaktadır. Örneğin, bataryaların üretimi çevresel etkiler doğurabilir, çünkü lityum ve kobalt gibi hammaddelerin çıkarılması ekolojik dengenin bozulmasına yol açabilir.

Yenilenebilir enerji kaynaklarının kullanımının artmasıyla birlikte, lityum iyon pillerin önemi daha da belirginleşmiştir. Güneş ve rüzgar enerjisi gibi yenilenebilir kaynaklar, enerji üretiminde kesintilere neden olabileceği için bu enerjilerin depolanması gerekmektedir. Lityum iyon piller, bu enerji depolama ihtiyacını en verimli şekilde karşılayabilen teknolojiler arasında yer almaktadır. Ayrıca, elektrikli araçlar pazarının hızla büyümesi, lityum iyon bataryaların önemini artırmaktadır. Elektrikli araçlar için lityum iyon bataryalar, uzun menzil, hızlı şarj ve düşük ağırlık gibi özellikleriyle mükemmel bir uyum göstermektedir. Bu bataryaların popülaritesi, çevre dostu politikaların artan önemi ve fosil yakıtlara olan bağımlılığın azalması ile daha da pekişmiştir.

Endüstriyel alanlarda da lityum iyon piller önemli bir yer tutmaktadır. Özellikle askeri ve ticari uygulamalarda yüksek güçlü bataryalar kullanımı yaygındır. Elektrikli uçaklar, insansız hava araçları ve denizaltılar gibi alanlarda, lityum iyon pillerin yüksek enerji yoğunluğu, güvenlik ve dayanıklılık gibi özellikleri büyük bir avantaj sağlamaktadır. Savunma sanayisinde, yüksek enerji gereksinimlerini karşılayabilen bataryalar, çevresel

koşullara dayanıklı, güvenli ve verimli enerji kaynakları sağlamaktadır. Ayrıca savunma sanayisinde SoC takibi, bataryaların etkin kullanımını sağlamak, güvenliği artırmak ve operasyonel sürekliliği temin etmek açısından son derece önemlidir. Lityum iyon bataryaların yüksek güç gereksinimlerini karşılama kapasitesi, doğru yönetim ve SoC tahmini ile savunma sistemlerinin daha güvenilir ve verimli bir şekilde çalışmasını sağlar. Bu süreç, askeri araçların ve donanımların operasyonel başarılarını doğrudan etkileyen önemli bir faktördür.

Bununla birlikte, lityum iyon pillerin geleceği, sürdürülebilirlik açısından zorlu bir yolculuk olacaktır. Lityum ve kobalt gibi kaynakların çıkarılması çevresel etkiler yaratabilir, bu nedenle daha sürdürülebilir batarya teknolojileri geliştirmek büyük bir önem taşımaktadır. Lityum iyon bataryaların geri dönüşümü, çevresel etkilerini azaltmanın en önemli adımlarından biri olarak karşımıza çıkmaktadır. Ayrıca, batarya üretim süreçlerinin daha çevre dostu ve daha az enerji tüketen hale getirilmesi için sürekli olarak inovasyon yapılmaktadır. Gelecekte, katı hal bataryalar, sodyum iyon bataryalar gibi alternatif teknolojilerin gelişimi, lityum iyon pillerin yerine geçmeye aday olabilir. Ancak lityum iyon bataryaların sağladığı enerji yoğunluğu ve dayanıklılık hala bu alandaki en önemli avantajları sunmaktadır.

Batarya yönetim sistemleri (BYS), lityum iyon pillerin güvenli ve verimli bir şekilde kullanılabilmesi için kritik öneme sahiptir. Bu sistemler, bataryaların şarj durumu, sağlık durumu, voltaj ve sıcaklık gibi parametrelerini izler ve bataryaların performansını optimize eder. Bu sayede bataryaların ömrü uzar ve güvenlikleri sağlanır. Özellikle yüksek enerji yoğunluğuna sahip bataryalar, dikkatli bir yönetim gerektirir ve BYB, bataryaların uzun süre verimli çalışmasını sağlamak için çok önemlidir. Elektrikli araçlar, yenilenebilir enerji sistemleri ve taşınabilir cihazlar gibi alanlarda batarya yönetim sistemlerinin etkinliği, bataryaların güvenliği ve performansı açısından kritik bir rol oynar.

BYB'nin en önemli işlevlerinden biri, bataryaların şarj durumu (SoC) tahminidir. Bataryanın ne kadar süre çalışabileceği hakkında bilgi veren SoC tahmini, bataryanın aşırı şarj veya aşırı deşarj edilmesini engeller. Geleneksel yöntemlerle SoC tahmini genellikle bataryanın voltaj, akım ve sıcaklık gibi parametrelerinin izlenmesiyle yapılırken, son yıllarda makine öğrenmesi teknikleri bu tahminin doğruluğunu büyük ölçüde artırmıştır. Makine öğrenmesi, büyük veri kümesi üzerinde algoritmaların eğitim almasını sağlayarak SoC tahminini daha hassas ve dinamik hale getirir. Bu, bataryaların performansını daha

dođru bir şekilde takip etmek ve daha güvenli bir kullanım sađlamak için önemli bir geliřmedir.

Makine öğrenmesi tekniklerinin kullanımı, batarya yönetim sistemlerinin verimliliđini önemli ölçüde artırmaktadır. Bu teknikler sayesinde bataryaların geçmiş verileri analiz edilerek daha dođru tahminlerde bulunulabilir. Bataryaların sađlık durumu (SoH) ve ömrü daha dođru tahmin edilebilir ve batarya yönetim sistemleri daha verimli hale gelir. Bu da bataryaların daha uzun süre dayanıklı ve güvenli bir şekilde kullanılmasını sađlar. Elektrikli araçlar ve yenilenebilir enerji sistemleri gibi uygulamalarda, batarya yönetim sistemleri, bataryaların řarj seviyelerini, sıcaklıklarını ve voltajlarını sürekli izler. Bu, bataryanın ömrünü uzatırken, aynı zamanda enerji verimliliđini artırır.

Bu çalışmanın temel hedeflerinden biri, lityum iyon bataryaların řarj ve deřarj kapasitelerinin, döngü sayısına bađlı olarak nasıl deđiřtiđini analiz etmektir. Bataryaların her bir řarj ve deřarj döngüsünde enerji depolama kapasitelerinde meydana gelen deđiřiklikler, bataryanın sađlığı ve ömrü hakkında kritik bilgiler sunar. Döngü sayısına bađlı olarak bataryanın kapasitesinde meydana gelen kayıplar, özellikle elektrikli araçlar ve yenilenebilir enerji sistemleri gibi uzun vadeli kullanım gerektiren uygulamalarda büyük bir öneme sahiptir. Bu bađlamda, çalışmada kapasite kaybı oranlarının detaylı bir şekilde incelenmesi, lityum iyon bataryaların ömrünü optimize etmek ve maliyet etkin bir kullanım sađlamak için önemli veriler sunacaktır.

Ayrıca, bu çalışma, bataryaların performansını etkileyen çevresel faktörleri de kapsamlı bir şekilde ele alacaktır. Özellikle sıcaklık, lityum iyon bataryaların kimyasal süreçlerini ve genel performansını doğrudan etkileyen kritik bir parametredir. Yüksek sıcaklıklar, bataryanın kimyasal dengesini bozarak termal kaçak riskini artırırken, düşük sıcaklıklar bataryanın řarj ve deřarj verimliliđini olumsuz etkileyebilir. Bu çalışma, farklı sıcaklık koşulları altında bataryaların performansındaki deđiřimleri inceleyerek, çevresel faktörlerin batarya sađlığı üzerindeki etkilerini nicel olarak deđerlendirecektir. Elde edilen bulgular, bataryaların farklı çevresel koşullarda nasıl daha verimli kullanılabileceđine dair stratejiler geliřtirilmesine katkı sađlayacaktır.

Çalışmanın bir diğer önemli bileşeni, makine öğrenimi algoritmalarını kullanarak bataryaların mevcut şarj durumunun (State of Charge) tahmin edilmesidir. SoC tahmini, bataryaların performans yönetiminde hayati bir rol oynar ve bataryanın ne kadar enerji depolayabileceği hakkında bilgi verir. Geleneksel SoC tahmin yöntemleri, genellikle bataryanın gerilim ve akım gibi ölçülebilir parametrelerine dayanır. Ancak bu yöntemler, çevresel koşullar, döngü sayısı ve batarya yaşlanması gibi dinamik faktörleri tam olarak hesaba katamayabilir. Bu çalışmada, makine öğrenimi algoritmaları kullanılarak bu parametrelerin entegre bir şekilde değerlendirilmesi hedeflenmektedir. Özellikle zaman serisi analizi ve regresyon modelleri gibi tekniklerle, bataryanın geçmiş performans verilerinden gelecekteki SoC tahminleri yapılacaktır. Bu yaklaşım, daha doğru ve güvenilir tahminler sunarak batarya yönetim sistemlerinin etkinliğini artırmayı amaçlamaktadır.

Çalışmanın nihai amacı, lityum iyon bataryaların verimli bir şekilde şarj edilmesi ve uzun ömürlü bir kullanım sağlanması için gerekli stratejileri önermektir. Elde edilen bulgular, batarya üreticileri ve kullanıcıları için pratik rehberlik sağlayacak ve enerji depolama sistemlerinin daha verimli kullanılmasına yönelik çözümler sunacaktır. Bu kapsamda, farklı şarj protokollerinin batarya ömrü üzerindeki etkileri analiz edilecek ve en uygun şarj stratejileri belirlenecektir. Ayrıca, kapasite kaybını minimize etmek ve bataryaların daha uzun süreli performans göstermesini sağlamak için çevresel faktörlerin optimize edilmesine yönelik öneriler sunulacaktır.

Çalışmanın sonuçları, yalnızca lityum iyon bataryalar için değil, aynı zamanda diğer enerji depolama teknolojileri için de geniş bir uygulama potansiyeline sahiptir. Özellikle yenilenebilir enerji kaynaklarının entegrasyonunda, elektrikli araçların performans yönetiminde ve taşınabilir cihazların batarya ömrünün optimize edilmesinde kullanılacak veriler sağlayacaktır. Bu çalışma, enerji depolama sistemlerinin daha sürdürülebilir, ekonomik ve güvenilir bir şekilde kullanılmasına yönelik önemli bir adım olarak değerlendirilmektedir. Ayrıca, batarya teknolojilerinde yapılacak ileri çalışmalar için bir temel oluşturarak, bu alandaki yenilikçi araştırmalara ilham kaynağı olmayı hedeflemektedir.

2. KAYNAK ARAŞTIRMASI

Lityum İyon Piller ve Kullanım Alanları

Lityum-iyon piller, yüksek enerji yoğunluğu, uzun çevrim ömrü ve düşük kendi kendine deşarj oranları gibi üstün özellikleri sayesinde enerji depolama teknolojileri arasında öne çıkmaktadır. İlk olarak 1991 yılında ticari olarak kullanılmaya başlanmalarından bu yana, taşınabilir elektronik cihazlardan elektrikli araçlara, yenilenebilir enerji sistemlerinden medikal cihazlara kadar geniş bir kullanım alanı bulmuşlardır (Goodenough ve Kim, 2010). Bu piller, hafif yapıları sayesinde enerji yoğunluğu bakımından daha yüksek verimlilik sunmakta ve diğer batarya türlerine kıyasla daha uzun ömürlü olmaları ile dikkat çekmektedir. Özellikle taşınabilir elektronik cihazlarda, enerji yoğunluğunun artışı, cihazların boyutlarının küçülmesine ve ağırlıklarının azalmasına olanak sağlamıştır (Nitta et al., 2015).

Lityum-iyon pillerin popülaritesi, yenilenebilir enerji kaynaklarının artan kullanımına paralel olarak daha da büyümüştür. Güneş ve rüzgar gibi kesintili enerji kaynaklarından üretilen enerjinin depolanmasında kilit rol oynayan bu bataryalar, şebekeye entegre edilen enerji depolama sistemlerinde verimliliği artırmaktadır (Zhao et al., 2020). Ayrıca, elektrikli araçlarda fosil yakıtlara bağımlılığı azaltma potansiyeli ile çevresel sürdürülebilirlik açısından önemli katkılar sunmaktadır (Tarascon ve Armand, 2001). Lityum iyon pillerden birçok alanda fayda sağlanılmaktadır. Özellikle savunma sanayi alanında batarya ile entegre çalışan neredeyse tüm ekipmanlarda lityum pil paketleri kullanılmaktadır. Lityum iyon pillerin belirli sıcaklık, şarj eğrilerinde çalışması gerekir. Eğer uygun ortam koşulları olmazsa yapılarında bozulma meydana gelir. Pilin bulunduğu ortam koşulları BYS dediğimiz Batarya Yönetim Sistemleri ile dengelenir. State Of Charge (SoC) da BYS'nin önemli bileşenlerindedir. Cihazların menzil bilgisi, kapasite ve kalan ömürleri SoC ile hesaplanır.

2.1. State of Charge (SoC)

State of Charge (SoC), bir enerji depolama sisteminin, özellikle de lityum-iyon bataryaların, mevcut enerji seviyesini tanımlayan bir parametredir. Bataryaların SoC değeri, bataryanın tam şarj kapasitesine (yani %100 kapasite) kıyasla ne kadar enerji depoladığını gösterir. Bu parametre, batarya yönetim sistemlerinin (BMS) doğru

çalışabilmesi, batarya ömrünün uzatılması ve güvenli operasyonun sağlanması açısından kritik öneme sahiptir.

SoC, bataryanın mevcut kapasitesinin, tasarım kapasitesine oranı olarak matematiksel bir şekilde tanımlanabilir:

Burada:

$$SoC = \frac{C_{mevcut}}{C_{max}} \times 100$$

C_{mevcut} = Mevcut kapasite

C_{max} = Tam şarjda olan kapasite

SoC genellikle yüzde (%) olarak ifade edilir ve bu değeri belirlemek için bataryanın şarj ve deşarj durumu, sıcaklık, akım ve gerilim gibi parametreler dikkate alınır.

SoC, bir bataryanın ne kadar enerji sağlayabileceğini ve ne kadar süreyle çalışabileceğini belirlemek için kritik bir ölçüttür. Özellikle taşınabilir elektronik cihazlar, elektrikli araçlar ve enerji depolama sistemleri gibi uygulamalarda, bataryanın SoC değeri, bataryanın verimli ve güvenli bir şekilde çalışmasını sağlamak için sürekli izlenir. SoC'nin doğru tahmini, bataryanın aşırı şarj edilmesi veya aşırı deşarj edilmesinin önüne geçerek batarya ömrünü uzatır ve güvenlik risklerini azaltır

2.2. SoC Belirleme Yöntemleri

SoC'nin doğru bir şekilde tahmin edilmesi, batarya yönetim sistemlerinde çok önemli bir rol oynamaktadır. SoC tahmin yöntemleri genellikle aşağıdaki başlıca tekniklerle gerçekleştirilir:

2.2.1. Gerilim Tabanlı Yöntemler (Voltage-Based Methods)

Gerilim tabanlı SoC tahmin yöntemleri, bataryanın şarj durumunu belirlemek için bataryanın uçlarındaki gerilimi ölçer ve bu gerilim değerine dayalı olarak bataryanın SoC'sini tahmin eder. Bu yöntem, özellikle bataryaların temel elektriksel özelliklerine dayandığı için genellikle basit, hızlı ve düşük maliyetli bir çözüm sunar. Ancak, gerilim tabanlı yöntemler belirli koşullar altında bazı kısıtlamalarla karşılaşabilir.

Gerilim Tabanlı SoC Tahmin Yöntemlerinin Kısıtlamaları

Gerilim tabanlı yöntemlerin en büyük zorluklarından biri, bataryanın voltajının çeşitli faktörlerden etkilenmesidir. Öne çıkan bu faktörler şunlardır:

- **Yük Koşulları:** Bataryanın gerilimi, uygulanan akıma bağlı olarak değişir. Yük arttıkça bataryanın gerilimi düşer ve bu da voltajın SoC'yi doğru bir şekilde yansıtmasını engeller.
- **Sıcaklık:** Bataryanın sıcaklığı, kimyasal reaksiyonların hızını etkiler ve bu da bataryanın voltajını etkiler. Düşük sıcaklık, bataryanın iç direncini artırarak voltajın düşmesine neden olabilir.
- **Hızlı Deşarj ve Şarj:** Bataryalar, hızlı şarj ve deşarj durumlarında voltajda keskin dalgalanmalar gösterir. Bu durum, özellikle yüksek akımla yapılan şarj/deşarj işlemlerinde gerilim-SoC ilişkisinin doğruluğunu zayıflatabilir.
- **Histerezis:** Batarya şarj ve deşarj döngülerinde gerilim eğrisi genellikle histerezis gösterir. Yani, şarj ve deşarj işlemleri sırasında voltaj seviyeleri aynı SoC seviyesinde farklı değerler gösterebilir.

Gerilim-SoC Eğrileri

Gerilim tabanlı yöntemlerin doğruluğu büyük ölçüde bataryanın voltaj-SoC eğrisine dayanır. Bu eğriler, bataryanın şarj durumu arttıkça gerilimin nasıl değiştiğini gösterir. Ancak, bu eğrilerin doğruluğu bataryanın kimyasal yapısına, sıcaklık koşullarına ve yük türüne bağlı olarak değişir. Bu nedenle, her batarya türü için belirli bir voltaj-SoC eğrisinin oluşturulması gereklidir.

Şarj ve Deşarj Eğrileri

Gerilim-SoC eğrisinin, bataryanın şarj ve deşarj döngülerine göre farklılık gösterebileceği göz önünde bulundurulmalıdır. Şarj sırasında gerilim artarken, deşarj sırasında gerilim düşer. Bu nedenle, bataryanın yalnızca şarj veya yalnızca deşarj durumları dikkate alınarak tahmin yapılması gerekebilir.

Batarya Kimyası

Lityum-iyon, kurşun-asit veya nikel-metal hidrit gibi farklı batarya kimyaları, gerilim-SoC ilişkisinde farklı eğriler oluşturur. Bu nedenle her batarya türü için farklı gerilim-SoC eğrisi kullanılması gerekebilir.

Avantajları:

- **Basitlik ve Hız:** Gerilim ölçümü, bataryanın SoC'sini tahmin etmek için basit ve hızlı bir yöntemdir. Bu yöntem, cihazların donanım gereksinimlerini en aza indirger.
- **Düşük Maliyet:** Gerilim ölçümü için özel bir ekipman gerekmemektedir. Çoğu batarya yönetim sistemi (BMS) bu parametreyi izleyebilir.
- **Gerçek Zamanlı İzleme:** Gerilim ölçülmesi, sürekli olarak ve gerçek zamanlı olarak yapılabilir, bu da bataryanın şarj durumu hakkında anlık bilgi sağlar.

Dezavantajları:

- **Hassasiyet Kaybı:** Gerilim tabanlı yöntemler, bataryanın şarj durumu ile gerilim arasındaki doğrusal olmayan ilişki nedeniyle hassasiyet kaybı yaşayabilir.
- **Çevresel Faktörler:** Sıcaklık, yük ve akım gibi çevresel faktörler, gerilim-SoC ilişkisini etkileyebilir ve bu da doğru SoC tahminini zorlaştırabilir.
- **Histerezis Etkisi:** Bataryaların şarj ve deşarj işlemleri sırasında gerilimde görülen histerezis, doğru tahminler yapılmasını engelleyebilir. Yani, aynı SoC değerinde farklı voltajlar ölçülebilir.

2.2.2. Kapasite Tabanlı Yöntemler (Capacity-Based Methods)

Kapasite tabanlı yöntemler, bir bataryanın şarj durumunun (State of Charge - SoC) tahmin edilmesinde bataryanın kapasitesinin izlenmesine dayalı yaklaşımlardır. Bu yöntemler, bataryanın enerji depolama kapasitesini ve bunun zaman içindeki değişimini dikkate alarak SoC tahminleri yapmayı amaçlar. Bataryaların kapasitesi, genellikle depoladıkları enerji miktarına karşılık gelir ve bataryanın şarj durumunun belirlenmesinde önemli bir

parametre olarak kabul edilir. Kapasite tabanlı yöntemler, bataryanın başlangıç kapasitesinin bulunduğu durumlarda, SoC tahmini için doğrudan bir gösterge sunar.

Kapasite ve SoC İlişkisi

Bataryanın kapasitesi, genellikle ampere-saat (Ah) veya miliampere-saat (mAh) cinsinden ölçülür ve bu, bataryanın belirli bir voltajda sağlayabileceği toplam enerji miktarını temsil eder. SoC, bataryanın mevcut kapasitesinin, tam dolu kapasitesine oranı olarak ifade edilir. Kapasite tabanlı yöntemlerde, bataryanın şarj durumu, bataryanın tam dolu kapasitesine göre oranlanarak hesaplanır. Bu oran genellikle şu şekilde tanımlanır:

$$\text{SoC} = \frac{\text{Mevcut Kapasite}}{\text{Tam Dolu Kapasite}} \times 100$$

Bu ilişki, teorik olarak oldukça basit olmakla birlikte, kapasite tabanlı yöntemlerin doğruluğu, bataryanın kapasitesinin zamanla nasıl değiştiği ve bataryanın çalışma koşullarına nasıl tepki verdiğine bağlı olarak önemli ölçüde etkilenebilir.

Kapasite Kaybı ve Değişimi

Bataryaların kapasitesi zaman içinde değişir ve bu değişim, bataryaların SoC tahminlerinin doğruluğu üzerinde önemli bir etkiye sahiptir. Bataryaların kapasitesindeki bu değişim, birkaç ana faktöre bağlıdır:

Yaşlanma ve Döngüsel Yıpranma: Bataryalar, her şarj ve deşarj döngüsünde bir miktar kapasite kaybederler. Bu durum, bataryanın kimyasal bileşenlerinde meydana gelen bozulmalar ve elektrotların zayıflaması gibi süreçlerden kaynaklanır. Yaşlanan bir bataryanın kapasitesi, başlangıçtaki kapasitesine göre daha düşük olacaktır ve bu da SoC tahminlerinin doğruluğunu etkileyebilir.

- **Termal Yük ve Sıcaklık Etkisi:** Sıcaklık, bataryaların kimyasal reaksiyonlarını etkileyerek kapasite kaybına neden olabilir. Yüksek sıcaklıklar, bataryaların kapasitesinde hızla bir azalmaya yol açabilir. Bu nedenle, kapasite tabanlı yöntemlerde sıcaklık koşullarının dikkate alınması önemlidir.
- **Derin Deşarj ve Aşırı Şarj:** Bataryaların aşırı deşarj edilmesi veya aşırı şarj edilmesi, bataryanın kapasitesinde geri dönüşü olmayan kayıplara yol açabilir. Bu

tür işlemler, bataryanın kimyasal yapısında kalıcı değişikliklere yol açarak kapasiteyi azaltabilir.

Avantajları:

- Doğrudan Kapasite Ölçümü: Kapasite tabanlı yöntemler, bataryaların enerji depolama kapasitesini doğrudan ölçtüğü için, bataryanın SoC'sini tahmin etmede doğrudan bir yöntem sunar.
- Gerçek Zamanlı İzleme: Enerji izleme yöntemi, bataryanın şarj ve deşarj süreçlerinde sürekli olarak enerji akışlarını izler, bu da gerçek zamanlı SoC tahmini için uygundur.
- BMS Entegrasyonu: Batarya yönetim sistemlerinde, kapasite tabanlı yöntemler, bataryaların sağlığını izlemek ve enerji verimliliğini optimize etmek için yaygın bir şekilde kullanılmaktadır.

Dezavantajları:

- Kapasite Kaybı: Bataryaların zamanla kapasite kaybı yaşaması, kapasite tabanlı tahminlerin doğruluğunu olumsuz etkiler. Batarya yaşlandıkça, kapasiteyi doğru bir şekilde ölçmek zorlaşır.
- Çevresel Koşullara Bağımlılık: Sıcaklık, akım, yük ve diğer çevresel faktörler, bataryanın kapasitesini etkileyebilir. Bu nedenle, kapasite tabanlı yöntemlerin doğruluğu, bu faktörlere bağlı olarak değişebilir.
- Uzun Süreli İzleme Gereksinimi: Kapasite tabanlı yöntemlerin doğruluğu, bataryanın uzun süreli izlenmesini gerektirir. Bu, bazı durumlarda bataryanın performansının yeterince hızlı bir şekilde değerlendirilmesini zorlaştırabilir.

2.2.4. Kalman Filtresi (Kalman Filter)

Kalman Filtresi, dinamik sistemlerin doğrusal modellemelerinde, sistemin durumunu tahmin etmek ve bu tahminleri ölçümlerle güncellemek için kullanılan bir algoritmadır. İlk olarak Rudolf E. Kalman tarafından 1960 yılında geliştirilmiş olan bu yöntem, özellikle mühendislik ve kontrol sistemleri alanlarında, gürültülü ve belirsiz veri ile çalışırken çok etkili bir şekilde kullanılan bir teknik olmuştur. Kalman Filtresi, hem doğrusal sistemler

hem de zamanla deęişen sistemler için uygun bir çözüm sunar ve özellikle ölçüm hatalarının minimize edilmesinde önemli bir rol oynar. Kalman Filtresi, bir sistemin durumunu tahmin etmek için geçmiş ve mevcut verilere dayalı olarak en iyi tahminleri yapar.

Kalman Filtresi, temel olarak iki adımda çalışır: *Tahmin (Prediction)* ve *Güncelleme (Update)*.

- **Tahmin Adımı (Prediction Step):** Bu adımda, mevcut durumdan hareketle sistemin gelecekteki durumuna dair bir tahmin yapılır. Bu tahmin, sistemin dinamik denklemleri ve önceden bilinen giriş verilerine dayanır.
- **Güncelleme Adımı (Update Step):** Bu adımda, tahmin edilen durum, yeni elde edilen ölçümlerle güncellenir. Ölçüm hataları göz önünde bulundurularak, tahminler daha doğru hale getirilir.

Kalman Filtresi, genel olarak lineer sistemler için tasarlanmış olup, aşağıdaki denklemlerle ifade edilebilir:

- **Tahmin Denklemi:**

$$\frac{\text{Mevcut Kapasite}}{\text{Tam Dolu Kapasite}} \times 100$$

Burada, \hat{X}_k^- tahmin edilen sistem durumu, A sistemin durum geçiş matrisi, B kontrol girişi matrisi ve U_{k-1} kontrol girişidir.

- **Karmaşık Ölçüm Denklemi:**

$$\frac{\text{Mevcut Kapasite}}{\text{Tam Dolu Kapasite}} \times 100$$

Burada, y_k ölçüm vektörü, H ölçüm matrisi ve V_k ölçüm hatasıdır.

- **Durum Güncelleme Denklemi:**

$$\hat{x}_k = \hat{X}_k^- + K_k (y_k - H\hat{X}_k^-)$$

Bu denklem, sistemin tahmin edilen durumunu, ölçümle güncellemek için kullanılır. Burada K_k , alman kazancı olarak bilinen bir çarpandır.

- **Kalman Kazancı (Kalman Gain):**

$$K_k = P_k^- H^T (H P_k^- H^T + R)^{-1}$$

Burada P_k^- tahmin edilen hata kovaryans matrisi ve R ölçüm hatası kovaryans matrisidir. Kalman kazancı, tahminin ne kadar güvenilir olduğunu belirler; yüksek bir K_k değeri, daha fazla güvenilen bir ölçüm anlamına gelir.

Kalman Filtresi ve Durum Estimasyonu

Kalman Filtresi, doğrusal sistemlerin zamanla değişen durumlarının izlenmesi için oldukça etkilidir. Bu durumda, bir sistemin gerçek durumu bilinmemekte olup, yalnızca gürültülü ölçümler mevcuttur. Kalman Filtresi, bu gürültülü verilerden en doğru durumu tahmin etmeye çalışır. Özellikle robotik, navigasyon, otomatik kontrol ve finansal modelleme gibi alanlarda, Kalman Filtresi doğru ve etkili bir durum tahmin tekniği olarak geniş bir kullanım alanına sahiptir.

Kalman Filtresi, çok sayıda farklı uygulamada etkili bir çözüm sunar, ancak en yaygın uygulama alanları şunlardır:

- **Navigasyon ve Konum Takibi:** Örneğin, GPS verilerini kullanarak bir aracın veya robotun konumunun tahmin edilmesi.
- **Havaalanı Kontrol Sistemleri:** Uçakların rotalarının ve hızlarının tahmin edilmesi.
- **Otomatik Kontrol Sistemleri:** Endüstriyel robotların hareketlerinin izlenmesi ve kontrol edilmesi.

Kalman Filtresi ve Gürültü Modelleri

Kalman Filtresi, genellikle sistemdeki gürültüleri ve ölçüm hatalarını modelleyerek daha doğru tahminlerde bulunur. Bu gürültüler genellikle *beyaz gürültü* olarak kabul edilir, yani

zamanla deęişmeyen ve her bir örnekte bağımsız olan rastgele hata terimleridir. Bu tür hatalar, sistemin doğruluęunu olumsuz yönde etkileyebilir.

Kalman Filtresi, sistem modelinin ve ölçüm hatalarının kovaryans matrisleri ile gürültüyü dikkate alır ve bu bilgileri kullanarak en iyi tahmini yapar. Kalman Kazancı, bu gürültülerin etkisini dengeleyerek, tahminin doğruluęunu optimize eder.

Kalman Filtresi ve Doğrusal Olmayan Sistemler

Kalman Filtresi, başlangıçta yalnızca doğrusal sistemler için geliştirilmiş olsa da, zaman içinde doğrusal olmayan sistemler için de uzantıları geliştirilmiştir. Bu tür doğrusal olmayan sistemlerde, Kalman Filtresi'nin doğrudan uygulanması mümkün olmayabilir. Ancak, doğrusal olmayan sistemler için kullanılan bazı yaygın teknikler şunlardır:

- **Genel Kalman Filtresi (Extended Kalman Filter - EKF):** Doğrusal olmayan sistemler için, sistem modeli doğrusal bir yaklaşım kullanılarak lineerleştirilir. Bu yöntem, doğrusal olmayan sistemlerin durumlarını tahmin etmek için genişletilmiş bir Kalman Filtresi kullanır.
- **Unscented Kalman Filtresi (UKF):** EKF'ye alternatif olarak, doğrusal olmayan sistemler için daha iyi performans sağlayabilen bir yöntemdir. Bu yaklaşımda, sistemin doğrusal olmayan doğası, sistemin olasılık dağılımının bir dizi örneęiyle (sigma noktaları) modellenir.

Avantajları:

- **Zamanla Güncellenen Tahminler:** Kalman Filtresi, yeni ölçümler geldikçe sürekli olarak durumu günceller, bu da gerçek zamanlı sistemlerde faydalıdır.
- **Hata Kovaryansını Hesaplama:** Kalman Filtresi, sadece tahmin edilen durumu değil, aynı zamanda tahminin güvenilirliğini de hesaplar.
- **Verimli Hesaplama:** Kalman Filtresi, gerçek zamanlı uygulamalarda kullanılabilecek verimli bir algoritmadır ve genellikle düşük hesaplama maliyetine sahiptir.

Dezavantajları:

- **Doğrusal Sistem Varsayımı:** Kalman Filtresi, temel olarak doğrusal sistemler için tasarlanmıştır, bu da doğrusal olmayan sistemler için uygulamanın zor olmasına neden olabilir.
- **Model ve Gürültü Bilgisi Gereksinimi:** Kalman Filtresi, sistem dinamikleri ve ölçüm hataları hakkında önceden bilgi gerektirir. Bu bilgilerin doğru bir şekilde sağlanamaması, tahminlerin doğruluğunu olumsuz yönde etkileyebilir.
- **Çoklu Ölçüm Kaynağı Gereksinimi:** Kalman Filtresi genellikle çoklu ölçüm kaynaklarını ve sensör verilerini birleştirmek için kullanılır, bu da çeşitli sensörlerden gelen verilerin uyumlu ve doğru olmasını gerektirir.

2.2.5. Makine Öğrenmesi

Makine öğrenmesi (ML), bilgisayar sistemlerinin açıkça programlanmadan öğrenebilmesini sağlayan, yapay zeka (AI) ve veri biliminin önemli bir dalıdır. Bu disiplin, makinelerin veri ve deneyimlerden öğrenme, tahmin yapma ve karar verme yeteneklerini geliştirmek için algoritmalar ve matematiksel modeller oluşturulmasına odaklanır. Makine öğrenmesi, büyük veri setleriyle çalışarak karmaşık problemlerin çözümünde etkili bir araç haline gelmiştir ve günümüzde akademik araştırmalardan ticari uygulamalara kadar geniş bir yelpazede kullanılmaktadır. Temel olarak, makine öğrenmesi denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç ana yaklaşıma ayrılır. Bununla birlikte, bu yaklaşımların dışında yarı denetimli öğrenme, transfer öğrenmesi ve federatif öğrenme gibi hibrit ve özel yöntemler de vardır.

Makine öğrenmesi, istatistik, optimizasyon ve bilgisayar biliminin kesişiminde yer alır. İnsan zekasının bir parçası olan öğrenme sürecini taklit etmeye çalışan bu teknoloji, büyük veri setlerinden anlam çıkararak, çeşitli türdeki girdilerle ilişkileri modellemeyi ve gelecekteki durumları tahmin etmeyi amaçlar. Bu süreçte kullanılan algoritmalar, genellikle iteratif optimizasyon tekniklerine dayanır ve sürekli iyileştirme sağlar (Mitchell, 1997).

Makine öğrenmesinin başarısı, kaliteli veri ve güçlü hesaplama altyapısına dayanır. Günümüz dünyasında büyük veri kaynaklarının ve yüksek performanslı bilgisayarların erişilebilirliği, makine öğrenmesi modellerinin her geçen gün daha da güçlü hale gelmesini

sağlamıştır. Örneğin, dil işleme, görsel tanıma, tahmine dayalı analitik ve robotik gibi alanlarda makine öğrenmesi, insan kapasitesinin ötesinde çözümler sunabilmektedir (Jordan, 2015).

2.2.5.1 Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenme, makine öğrenmesi alanında en yaygın ve en temel yaklaşımlardan biri olarak öne çıkar. Bu yöntem, belirli bir hedefi gerçekleştirmek için kullanılan etiketli veri kümesine dayalı olarak bir modelin eğitilmesini içerir. Denetimli öğrenmenin ana fikri, giriş ve çıkış verileri arasındaki ilişkiyi öğrenerek gelecekte benzer girişlere doğru tahminler yapmaktır. Bu süreç, bir öğretmenin öğrencisine her doğru cevap için geri bildirim verdiği bir öğrenme ortamına benzetilebilir. Öğretmenin sağladığı bu geri bildirim, öğrencinin gelecekte benzer sorulara doğru yanıtlar vermesini sağladığı gibi, denetimli öğrenme algoritmalarında da veri ve hedefler arasındaki ilişki model tarafından öğrenilir.

Denetimli öğrenmede, veri kümesi iki ana bileşenden oluşur: girişler ve hedefler. Giriş verileri, modelin analiz ettiği ham bilgilerden oluşurken, hedefler bu girişlere karşılık gelen sonuçları temsil eder. Örneğin, bir görüntü tanıma sisteminde girişler, piksellerden oluşan görsel veriler olabilirken, hedefler bu görüntülerdeki nesnelere isimleri (örneğin, "kedi", "köpek") olabilir. Algoritma, bu etiketli veri seti üzerinde eğitilerek girişlerin özellikleri ile hedefler arasındaki ilişkiyi öğrenir ve daha sonra yeni, etiketlenmemiş verilere doğru tahminlerde bulunur.

Bu yöntem, genellikle iki tür problemde kullanılır: sınıflandırma ve regresyon. Sınıflandırma problemleri, verilerin önceden tanımlanmış kategorilere ayrılmasını içerir. Örneğin, bir spam filtresi, gelen e-postaları "spam" ve "spam değil" olarak sınıflandırabilir. Diğer taraftan, regresyon problemleri, sürekli bir değer tahmin edilmesini gerektirir. Örneğin, bir gayrimenkul değerlendirme sistemi, bir evin metrekare fiyatını, oda sayısı ve bulunduğu semt gibi özelliklere dayanarak tahmin edebilir. Her iki problem türü de farklı algoritmalar ve matematiksel modellerle çözülür.

Denetimli öğrenme algoritmaları, problem türüne ve veri yapısına bağlı olarak geniş bir çeşitlilik gösterir. Örneğin, lineer regresyon, doğrusal bir ilişki olduğunda etkili bir tahmin yöntemi sunarken; lojistik regresyon, sınıflandırma problemleri için yaygın olarak kullanılır. Destek vektör makineleri (SVM), karar sınırlarını tanımlama yeteneği sayesinde

hem sınıflandırma hem de regresyon problemlerinde güçlü bir performans sergiler. Karar ağaçları, kolay anlaşılabilir ve yorumlanabilir yapıları nedeniyle tercih edilirken, rastgele ormanlar gibi ansambl yöntemleri, birden çok modelin birlikte kullanılmasıyla genellikle daha yüksek doğruluk sağlar. Derin öğrenme algoritmaları ise özellikle büyük ve karmaşık veri setleriyle çalışmak için uygundur. Yapay sinir ağları, görsel ve dil verileri gibi karmaşık yapıları modellemek için etkili araçlardır.

Denetimli öğrenme, eğitim sürecinde kullanılan etiketli verinin kalitesine ve miktarına oldukça bağlıdır. Yetersiz veya hatalı etiketleme, modelin doğruluğunu olumsuz yönde etkileyebilir. Ayrıca, veri kümesinin çeşitliliği de önemlidir; model, eğitim sırasında öğrendiği ilişkileri yalnızca gördüğü verilere göre tahmin eder. Bu nedenle, modelin genelleme yeteneği, veri kümesinin eğitime uygun bir şekilde düzenlenmesine bağlıdır.

Denetimli öğrenmenin uygulama alanları oldukça geniştir. Sağlık sektöründe, tıbbi görüntülerdeki anormalliklerin tespiti ve teşhis koyma işlemleri için kullanılır. Finans sektöründe, kredi risk analizi, dolandırıcılık tespiti ve borsa tahminleri gibi kritik karar süreçlerinde etkili bir şekilde uygulanır. Pazarlama alanında, müşteri segmentasyonu ve kişiselleştirilmiş öneri sistemleri denetimli öğrenme ile güçlendirilir. Eğitimde, öğrenci performansını tahmin eden ve öğrenme materyallerini özelleştiren sistemler bu yöntemi kullanır. Ulaşımında ise trafik akışını tahmin etmek veya otonom araçların kontrol sistemlerini geliştirmek için denetimli öğrenme algoritmalarından faydalanılır.

2.2.5.2 Sınıflandırma ve Regresyon

Denetimli öğrenme iki temel problem türüne uygulanır: sınıflandırma ve regresyon. Sınıflandırma, verilerin kategorilere ayrılmasını içerir. Örneğin, bir e-posta sisteminde gelen iletileri "spam" ve "spam değil" olarak ayırmak bir sınıflandırma problemidir. Yaygın algoritmalar arasında destek vektör makineleri (SVM), karar ağaçları, rastgele ormanlar ve yapay sinir ağları bulunur. Regresyon ise sürekli bir çıktıyı tahmin etmek için kullanılır. Örneğin, bir evin fiyatını metrekare, oda sayısı ve lokasyon gibi özelliklere dayalı olarak tahmin etmek regresyon problemidir. Lineer regresyon, çoklu doğrusal regresyon ve polinomsal regresyon gibi yöntemler regresyon problemlerine çözüm sunar. Denetimli öğrenme, finans, sağlık, pazarlama ve enerji yönetimi gibi birçok sektörde yaygın olarak kullanılmaktadır. Özellikle kredi risk analizi, dolandırıcılık tespiti, görüntü

tanıma ve hasta teşhisinde öne çıkan bir yöntemdir. Örneğin, tıbbi bir sistem, X-ışını görüntülerini analiz ederek hastalık teşhisi koyabilir.

2.2.5.3 Denetimsiz Öğrenme (Unsupervised Learning)

Denetimsiz öğrenme, makine öğrenmesi alanında, algoritmaların ham verilerdeki kalıpları ve gizli yapıları keşfetmesini sağlayan önemli bir yaklaşımdır. Bu yöntemde, denetimli öğrenmenin aksine giriş verilerine eşlik eden hedef etiketler bulunmaz. Algoritma, sadece verilen veri üzerinde çalışarak belirli bir hedef olmaksızın, veriler arasındaki ilişkileri ve ortak özellikleri anlamaya çalışır. Denetimsiz öğrenme, özellikle etiketsiz veri setlerinin büyük miktarda olduğu durumlarda kullanışlıdır. Günümüzde, veri kümelerinin büyük bir kısmı etiketsiz olduğundan, denetimsiz öğrenme, veri bilimi ve makine öğrenmesi dünyasında giderek daha fazla ilgi görmektedir.

Bu yöntemin temel amacı, verilerdeki düzenleri, benzerlikleri ve farklılıkları keşfetmektir. Veriler arasındaki yapısal ilişkileri ortaya çıkararak, bu ilişkileri anlamlı bilgiye dönüştürmek için kullanılır. Denetimsiz öğrenme, bu süreci genellikle üç ana yaklaşım ile gerçekleştirir: kümeleme (clustering), boyut azaltma (dimensionality reduction) ve anomali tespiti (anomaly detection).

Kümeleme, denetimsiz öğrenmenin en yaygın kullanılan yöntemlerinden biridir. Bu teknik, veri noktalarını, benzer özelliklere sahip olanları aynı gruba (küme) yerleştirerek gruplar arasında farklılık yaratmayı amaçlar. Örneğin, müşteri segmentasyonu yapmak için kullanılan bir kümeleme algoritması, müşterileri satın alma alışkanlıklarına veya demografik özelliklerine göre gruplandırabilir. Böylece her bir grup, ortak özelliklere sahip bir müşteri kitlesini temsil eder. Kümeleme algoritmaları arasında K-Ortalamlar (K-Means), Hiyerarşik Kümeleme (Hierarchical Clustering) ve Yoğunluk Tabanlı Kümeleme (DBSCAN) en yaygın olanlardır. Bu algoritmalar, farklı problem türlerine ve veri yapısına uygun olacak şekilde uyarlanabilir.

Boyut azaltma, büyük ve karmaşık veri setlerindeki özelliklerin sayısını azaltarak, verilerin daha basit ve anlaşılabilir bir forma dönüştürülmesini amaçlar. Boyut azaltma, özellikle yüksek boyutlu veri kümelerinde, analiz ve görselleştirme sürecini kolaylaştırmak için kullanılır. Örneğin, genetik çalışmalarında, binlerce genetik özellik içeren veri setlerinin boyutunu azaltarak anlamlı gruplar oluşturmak mümkündür. Boyut azaltma yöntemleri arasında Ana Bileşen Analizi (PCA) ve T-SNE (t-distributed Stochastic Neighbor

Embedding) gibi teknikler yaygın olarak kullanılmaktadır. PCA, verilerdeki değişkenlerin varyansını maksimize eden bir dizi doğrusal kombinasyon oluştururken, T-SNE, verilerin yerel ve küresel yapılarını koruyarak düşük boyutlu görselleştirmeler sunar.

Anomali tespiti, denetimsiz öğrenmenin başka bir önemli uygulama alanıdır. Bu yöntem, veri setindeki normal kalıplardan sapma gösteren anormal veya beklenmedik veri noktalarını tespit etmek için kullanılır. Örneğin, finansal dolandırıcılık tespiti veya siber güvenlik ihlalleri gibi alanlarda, anomali tespiti kritik bir rol oynar. Anomaliler, genellikle veri setinde nadir görülen durumları ifade eder ve bu nedenle belirlenmesi zordur. Denetimsiz öğrenme, bu tür durumları tespit etmek için etkili bir araçtır.

Denetimsiz öğrenmenin gücü, yalnızca ham veri üzerinde çalışarak verilerdeki bilinmeyen yapıları ortaya çıkarabilme yeteneğinden gelir. Ancak bu yöntemlerin başarısı, kullanılan algoritmanın seçimi, veri kümesinin özellikleri ve problem bağlamı gibi faktörlere bağlıdır. Örneğin, bir kümeleme algoritması, kümelerin sayısının önceden bilinmesi gerektiğinde sınırlamalarla karşılaşabilir. Benzer şekilde, boyut azaltma yöntemleri, veri kaybını minimize etmeye çalışırken bazen önemli bilgileri de göz ardı edebilir.

Denetimsiz öğrenme, birçok sektörde geniş uygulama alanına sahiptir. Örneğin, pazarlama alanında müşteri segmentasyonu, sağlık sektöründe genetik veri analizi, endüstriyel üretimde anomali tespiti ve sosyal medya analitiklerinde kullanıcı davranışlarının gruplandırılması gibi uygulamalar denetimsiz öğrenme ile gerçekleştirilir. Ayrıca, bu yöntemler veri keşfi ve ön işleme süreçlerinde de önemli bir rol oynar. Veri bilimi projelerinde, denetimsiz öğrenme genellikle verilerin incelenmesi ve özellik mühendisliği süreçlerinde ilk adım olarak kullanılır.

Denetimsiz öğrenme, etiketsiz veri kümelerinde güçlü içgörüler sunarak, veri bilimi ve makine öğrenmesinin temel yapı taşlarından biri olmaya devam etmektedir. Bu yöntemler, karmaşık veri kümelerindeki düzenleri anlamaya yönelik güçlü araçlar sağlayarak, daha bilinçli ve doğru kararlar almayı mümkün kılar.

Bu bölümde, lityum-iyon pillerin şarj durumu (SoC) tahmini ve batarya yönetim sistemleri üzerine yapılan önceki çalışmalar incelenmiştir. Literatürde, SoC tahmini için çeşitli yöntemler ve yaklaşımlar önerilmiştir. Elektrokimyasal modelleme, makine öğrenmesi algoritmaları ve istatistiksel yöntemler bu alanda sıkça kullanılan teknikler arasında yer almaktadır. Çalışmalar, özellikle SoC tahmininde doğruluk ve güvenilirliği artırmak

amacıyla farklı modelleme ve analiz yöntemlerini ele almıştır. Bu bölümde, ilgili literatürde yer alan çalışmalar özetlenmiştir.

Gözde Özcan ve ekibi, farklı çekirdek işlevlerine sahip lityum-iyon (Li-iyon) pillerin şarj durumunu (SoC) tahmin etmek için Gauss süreç regresyonu (GPR) uygulamıştır. GPR'nin pratik avantajlarından biri, tahminlerdeki belirsizlikleri nicelleştirebilmesidir. Bu çalışmada, GPR'nin farklı çekirdek fonksiyonları kullanılarak SoC tahmini gerçekleştirilmiş ve belirsizlikler nicelleştirilmiştir (Özcan vd., 2016).

Wei He ve ekibi, lityum konsantrasyonları gibi dahili fiziksel ve kimyasal özellikleri içeren bir elektrokimyasal model sunarak lityum-iyon pil SoC tahmini yapmıştır. Model, optimize edilmiş bir yansıtma tabanlı yöntem ve hareketli pencere filtreleme algoritması kullanarak çözülmüştür. Sonuçlar, geliştirilen modelin, sonlu fark tabanlı yöntemlere kıyasla 20 kat daha az denklem ürettiğini ve doğruluktan ödün vermediğini göstermektedir. Ayrıca, önerilen yansıtma tabanlı çözüm yöntemi, geleneksel durum filtreleme yöntemlerine göre üç kat daha verimlidir (He vd., 2018).

Ramazan Menak ve ekibi, batarya yönetim sistemlerinin (BYS) incelenmesine odaklanmıştır. Çalışmada, batarya izleme, güvenlik, araç içi ve dışı haberleşme, hücre dengelemesi, durum kestirimleri, termal yönetim ve topolojiler gibi alanlardaki yöntemlerin avantaj ve dezavantajları incelenmiş ve raporlanmıştır. Bu çalışma, BYS alanında araştırma yapacak kişiler için faydalı bir Türkçe kaynak sunmaktadır (Menak vd., 2021).

Efe İsa Tezde ve Halil İbrahim Okumuş, bataryanın şarj kontrolünü sağlamak ve kullanım sırasında kalan enerjiye göre tüketimi ayarlayabilmek için batarya şarj durumunun belirlenmesi üzerine bir çalışma gerçekleştirmiştir. Coulomb sayma yöntemiyle sabit akım ve gerilimde batarya şarj-deşarj edilerek deney sonuçları elde edilmiş ve MATLAB'da bir algoritma geliştirilerek SoC belirlenmesi sağlanmıştır (Tezde ve Okumuş, 2018).

Ayetül Gelen ve Emre Tüfekçioğlu, lityum-polimer (LiPo) piller için verimli bir şarj edici ve dengeleyici devre tasarımı yapmıştır. İnsan gücünü minimize eden ve uzaktan erişim sağlayabilen devre tasarımı, yazılım ve donanım temelli olarak gerçekleştirilmiştir (Gelen ve Tüfekçioğlu, 2020).

Mehmet Sait Avgın ve arkadaşları, lityum-iyon bataryaların şarj durumu (SoC) tahmini için genetik ifade programlama (GEP) algoritmasını kullanarak bir çalışma gerçekleştirmişlerdir. Batarya akımı, çıkış voltajı ve zaman değişkenleri giriş olarak kullanılarak, lityum-iyon bataryalar için matematiksel deşarj denklemleri oluşturulmuştur. Bu sayede, batarya türüne özel deşarj bilgileriyle daha doğru ve kesin SoC tahmini yapılması amaçlanmıştır (Avgın vd., 2014).

Türev Sarıkurt ve Abdülkadir Balıkçı, elektrikli araçlarda kullanılan lityum bataryaların sağlık durumunu göreceli kapasite (GK) cinsinden ifade eden bir yöntem önermişlerdir. Bu yöntemde, bataryanın terminal geriliminin belirli sinyaller altındaki değişimine bağlı olarak bir referans çevrim sayısı modeli geliştirilmiştir. Sonuç olarak, bataryanın çalışma süresinin yaklaşık iki kat uzadığı ve enerji transferi sırasında sistem verimliliğinin %95'in üzerinde olduğu gösterilmiştir (Sarıkurt ve Balıkçı, 2018).

B. Deniz Polat ve Özgül Keleş, lityum-iyon pil teknolojisini tanıtan bir çalışma yapmışlardır. Bu çalışmada, lityum pillerin tarihçesi ve gerçekleştirilen araştırma-geliştirme çalışmalarından bahsedilmiştir. Ayrıca, lityum-iyon bataryaların yüksek enerji yoğunluğu, uzun çevrim ömrü ve düşük kendiliğinden boşalma oranları gibi avantajları vurgulanmıştır (Polat ve Keleş, 2018).

Türev Sarıkurt ve Abdülkadir Balıkçı, tam elektrikli araçlar için özgün bir enerji yönetim sistemi uygulaması geliştirmişlerdir. Önerilen sistem, aktif batarya gerilim dengelemesi yapabilmekte ve basit bir kontrol şeması içeren yarı aktif hibridizasyon stratejisi ile verimli bir enerji yönetimi sağlamaktadır. Benzetim sonuçlarına göre, sistem bataryaların çalışma süresini yaklaşık iki kat uzatmış ve enerji transferi sırasında verimliliğin %95'in üzerinde olduğu deneysel olarak gösterilmiştir (Sarıkurt ve Balıkçı, 2017).

Furkan Said Durmuş ve Habib Kaymaz, elektrikli araç bataryalarının maliyetli olması nedeniyle en uygun şarj yöntemlerini belirlemeyi amaçlamışlardır. Elektrikli araç kullanıcılarına kablosuz şarj özelliği ve şarj istasyonları sayesinde daha kısa sürede daha uzun menzil imkânı sunulabileceğini belirtmişlerdir. Ayrıca, farklı şarj yöntemlerinin batarya ömrü ve performansı üzerindeki etkileri incelenmiştir (Durmuş ve Kaymaz, 2020).

Kaypmaz ve Tuncay (2010) tarafından gerçekleştirilen çalışma, lityum-iyon polimer pillerin sađlamlık durumunu deđerlendirmek amacıyla elektrokimyasal empedans spektroskopisi yöntemini kullanmıştır. Araştırmada, hücre kinetik parametreleri elde edilerek, zorlanmış şarj ve deşarj durumlarının piller üzerindeki etkileri incelenmiştir. Sonuçlar, mevcut eşdeđer devre modellerinin arıza durumlarını yansıtmada yetersiz kaldığını göstermiştir. Bu doğrultuda, daha gerçekçi ve güvenilir tahminler sunabilen yeni bir eşdeđer devre modeli önerilmiştir. Önerilen model, özellikle batarya güvenilirliğini artırmada önemli bir adım olarak deđerlendirilmiştir (Kaypmaz ve Tuncay, 2010).

Kaysal ve arkadaşları (2021) tarafından yapılan bir başka çalışmada, lityum-iyon batarya paketlerinin dengeli ve doğru bir şekilde şarj edilmesini sađlamak amacıyla pasif dengeleme tekniđi kullanan bir batarya yönetim sistemi tasarlanmıştır. Bu sistemde, STM32F446 ve STM32F070 mikrodenetleyicileri kullanılarak bataryaların gerilim ve sıcaklık deđerleri izlenmiş, aşırı şarj, derin deşarj ve yüksek sıcaklık gibi risklerin önlenmesi hedeflenmiştir. Deneyleerde 20 seri ve 11 paralel bağlantılı, 32 Ah kapasiteye sahip lityum-iyon bataryalar kullanılmıştır. Sonuçlar, tasarlanan sistemin batarya güvenliğini ve verimliliğini önemli ölçüde artırdığını göstermektedir (Kaysal vd., 2021).

Demirkan ve Doğrusöz (2021) tarafından yürütölen bir başka araştırmada, lityum-iyon bataryalarında kullanılan silisyum (Si) içerikli malzemelerin ticari olarak yaygınlaşmasını engelleyen sorunlara odaklanılmıştır. Çalışmada, silisyum ve karbon kombinasyonundan oluşun anot malzemesine piezoelektrik özellik taşıyan PZT-8 eklenmiştir. Bu sayede kapasite kaybının azaltılması hedeflenmiştir. Araştırmanın sonuçlarına göre, PZT-8 katkısı bataryaların kapasite kaybını kısmen önlemiş ve uzun vadeli kullanım ömrünü artırmıştır (Demirkan ve Doğrusöz, 2021).

Karadađ ve Dikmen (2021) tarafından geliştirilen projede, yeni nesil, modöler ve akıllı bir batarya yönetim sistemi tasarlanmıştır. Bu sistem, bataryaların durum kestirimi, termal yönetimi ve topolojileri gibi kritik alanlarda yenilikçi çözümler sunmayı amaçlamaktadır. Ayrıca, ömrünü tamamlamış bataryaların kimyasına ve kalan ömrüne göre ayrıştırılması, ikincil hayata kazandırılması hedeflenmiştir. Çalışma kapsamında tamamen yerli yazılım, tasarım ve donanım bileşenlerinin geliştirilmesi planlanmıştır. Araştırmalar halen devam etmekte olup, sistemin verimliliđi ve güvenilirliđi ilerleyen aşamalarda daha ayrıntılı testlerle deđerlendirilecektir (Karadađ ve Dikmen, 2021).

Moralı (2020) tarafından yapılan çalışmada, ticari bir 2032 lityum-iyon madeni para hücresinin şarj durumu, şarj akımı ve akım düşme süresinin pil dinamikleri üzerindeki etkisi elektrokimyasal empedans spektroskopisi (EIS) yöntemiyle incelenmiştir. Araştırma sonuçları, şarj durumunun hem katı elektrolit arayüzey oluşumu direnci hem de katodik yük transfer direnci üzerinde istatistiksel olarak anlamlı bir etkisinin olduğunu ortaya koymuştur. Çalışma, batarya dinamiklerinin daha iyi anlaşılmasına katkıda bulunmuş ve batarya tasarımında optimizasyon için yeni yaklaşımlar sunmuştur (Moralı, 2020).

Bu çalışmalar, lityum-iyon bataryaların performansını ve güvenilirliğini artırmak adına farklı yöntemler ve tasarımlar önermektedir. Elektrokimyasal empedans spektroskopisi, piezoelektrik katkı malzemeleri ve pasif dengeleme gibi teknikler, bataryaların daha uzun ömürlü, güvenilir ve verimli kullanılabilmesi için önemli araçlar olarak öne çıkmaktadır.

3. MATERYAL ve YÖNTEM

3.1. Materyal

Bu çalışmada, lityum-iyon (Li-ion) pillerin şarj durumu (State of Charge - SoC) tahminine yönelik deneysel analizler gerçekleştirilmiştir. Kullanılan piller, Türkiye merkezli Aspilsan firmasından temin edilen sekiz adet N18650COP BAK A05 model lityum-iyon pillerdir. Bu piller, yüksek enerji yoğunlukları, uzun ömürleri ve güvenilir performansları nedeniyle özellikle tercih edilmiştir. Pil testlerinin gerçekleştirildiği cihazlar arasında, pillerin şarj ve deşarj döngülerinin kontrol edilmesini sağlayan Resim 1’de gördüğünüz bir pil test cihazı yer almaktadır. Bu cihaz, her bir pilin şarj ve deşarj süreçlerini belirli parametreler altında takip etmemizi sağlamıştır. Ayrıca, düşük sıcaklık koşullarında yapılan testlerin doğruluğunu sağlamak amacıyla Resim 2’de yer alan bir ısı kabini kullanılmıştır. Isı kabini, test edilen pillerin 0°C sıcaklıkta nasıl performans gösterdiğini gözlemlememize olanak tanımıştır. Pillerin voltaj, akım ve sıcaklık gibi kritik parametrelerinin sürekli olarak izlenebilmesi için veri kayıt cihazları kullanılmıştır. Bu cihazlar, her bir test sırasında pillerin performansını doğru bir şekilde izlememize yardımcı olmuştur.

Testlerde kullanılan piller, dört farklı akım seviyesinde (1C, 2C, 3C, 4C) test edilmiştir. Bu akım seviyeleri, pillerin farklı yük koşullarındaki performanslarını değerlendirebilmek için seçilmiştir. Testler sırasında, pil voltajı 2.5V ile 4.2V arasında tutulmuş ve toplamda 500 çevrimlik bir test uygulanmıştır. Bu çevrim, pilin uzun vadeli kullanım ömrünü simüle etmek amacıyla belirlenmiş ve pillerin enerji depolama kapasitesindeki değişimlerin gözlemlenmesi sağlanmıştır. Deneysel süreç iki aşamada gerçekleştirilmiştir; ilk aşamada, dört pil oda sıcaklığında (25°C) test edilirken, diğer dört pil ise ısı kabinine yerleştirilerek 0°C sıcaklıkta değerlendirilmiştir. Bu farklı sıcaklık koşulları, pillerin çevresel faktörlere karşı gösterdiği tepkiyi inceleyebilmek için seçilmiştir. Deney süresince, pillerin voltajı, akımı, kapasitesi (Ah), sıcaklık değişimleri ve çevrim sayıları gibi temel parametreler düzenli aralıklarla kaydedilmiştir. Bu ölçümler, pillerin şarj ve deşarj süreçlerindeki performansını detaylı bir şekilde analiz edebilmek amacıyla kullanılmıştır.



Resim 1: Batarya Test Cihazı



Resim 2: Isı Kabini

Veri işleme aşamasında, elde edilen veriler üzerinde birkaç ön işleme adımı uygulanmıştır. Bu süreçte, eksik veya tutarsız veriler tespit edilmiş ve uygun yöntemlerle düzeltilmiştir. Ayrıca, deneysel süreçlerde ortaya çıkabilecek aykırı değerler analiz edilerek uygun filtreleme teknikleri uygulanmıştır. Veri seti üzerinde öznitelik mühendisliği yapılmış ve

SoC tahmini için önemli olan parametreler seçilerek veri seti zenginleştirilmiştir. Bu aşamalar, makine öğrenmesi algoritmalarına uygun, güvenilir ve anlamlı bir veri seti oluşturulmasını sağlamıştır. Sonuç olarak, bu materyal ile elde edilen veriler, lityum-iyon pillerin şarj durumu tahmininin doğruluğunu artırmak için kullanılan makine öğrenmesi algoritmalarına uygun hale getirilmiştir.

3.2. Yöntem

3.2.1. k-En Yakın Komşu (KNN) Algoritması

k-En Yakın Komşu (KNN), denetimli öğrenme (supervised learning) yaklaşımına dayanan, örneklem verilerinin sınıflandırılmasında veya sayısal bir değerle ilişkilendirilmesinde kullanılan bir algoritmadır. Bu algoritma, bir verinin sınıfını veya değerini tahmin etmek için, veriye en yakın olan "k" komşusunun özelliklerini baz alır. KNN, sınıflandırma ve regresyon problemlerinde kullanılabilir, ancak genellikle sınıflandırma görevlerinde daha yaygın bir biçimde kullanılır.

Temel Çalışma Prensibi

KNN algoritması, test verisi ile eğitim verileri arasındaki mesafeyi hesaplayarak çalışır. Bu mesafe genellikle **Euclid mesafesi (Euclidean distance)** gibi metriklerle ölçülür, ancak Manhattan mesafesi, Minkowski mesafesi gibi diğer mesafe ölçüleri de kullanılabilir. Bu mesafeler, iki veri noktası arasındaki benzerlik derecesini gösterir. Bir veri noktası verildiğinde, KNN algoritması şu adımları izler:

Mesafe Hesaplama: Test verisi ile eğitim verisi arasındaki mesafe hesaplanır. En yaygın kullanılan mesafe ölçüsü, Euclidean mesafesidir.

$$\frac{\text{Mevcut Kapasite}}{\text{Tam Dolu Kapasite}} \times 100$$

Burada x ve y, iki veri noktasını temsil eder ve n, veri noktasındaki özellik sayısını ifade eder.

Komşu Seçimi: Test verisinin k en yakın komşusu seçilir. Bu komşular, eğitim verisi içindeki veri noktalarıdır ve mesafe ölçüsü ile belirlenen en küçük mesafelere sahip olan veriler seçilir.

Tahmin Yapma: KNN algoritması, sınıflandırma için en yakın komşuların etiketlerinin çoğunlukta olan sınıfını tahmin eder. Eğer regresyon problemi söz konusuysa, tahmin edilen değer, komşuların değerlerinin ortalaması alınarak hesaplanır.

- **Sınıflandırma:** En yakın k komşusunun etiketleri arasında çoğunluk oyunu kullanılır.
- **Regresyon:** En yakın k komşusunun değerlerinin ortalaması alınır.

KNN Algoritmasının Özellikleri

Basitlik: KNN, öğrenme aşamasında herhangi bir modelin oluşturulmasına ihtiyaç duymaz. Yani, "lazy learning" (tembel öğrenme) algoritmalarından biridir. Modelin öğrenme süreci yalnızca tahmin yapma sırasında gerçekleşir.

Hesaplama Maliyeti: KNN'nin en büyük dezavantajlarından biri, tahmin yaparken yüksek hesaplama maliyetidir. Özellikle büyük veri setlerinde, her bir tahmin için tüm eğitim verisiyle karşılaştırma yapılması gerektiğinden, algoritma zaman açısından maliyetli olabilir.

Veri Ölçeği ve Özellik Seçimi: KNN, özellikle verilerin doğru ölçeklendirilmiş olması durumunda etkili çalışır. Özelliklerin farklı ölçeklerde olduğu durumlarda, mesafe ölçümü yanıltıcı olabilir. Bu nedenle, veriler genellikle **normalizasyon** veya **standartlaştırma** gibi ön işleme adımlarına tabi tutulur.

K Parametresi: KNN algoritmasının başarısı, seçilen k parametresine bağlıdır. Küçük bir k değeri, modelin gürültüyü ve outlier'ları (aykırı değerler) dikkate almasına yol açabilir, büyük bir k değeri ise modelin aşırı genelleme yapmasına ve dolayısıyla daha düşük doğrulukla sonuçlanmasına neden olabilir. Bu nedenle, en uygun k değeri genellikle **çapraz doğrulama** yöntemleriyle belirlenir.

Komşu Sayısı (k): KNN algoritmasında k parametresi, tahmin yapılacak veriye en yakın komşuların sayısını ifade eder. Genellikle, küçük k değerleri daha hassas tahminler sağlar, ancak daha fazla gürültüye duyarlı olabilir. Büyük k değerleri ise daha genel tahminler sunar, ancak modelin doğruluğu düşebilir.

Etkili Uygulama Alanları: KNN algoritması, küçük ve orta büyüklükteki veri setlerinde etkili bir şekilde çalışabilir. Görüntü işleme, tıbbi teşhis, metin sınıflandırma ve öneri sistemleri gibi alanlarda yaygın olarak kullanılır.

Avantajları:

- **Basit ve Anlaşılır:** KNN algoritması, matematiksel olarak basit ve anlaşılması kolaydır.
- **Esneklik:** Hem sınıflandırma hem de regresyon problemleri için kullanılabilir.
- **Eğitim Aşamasında Zaman Harcamaz:** Modelin eğitilmesi gerektiği için eğitim süresi yoktur, model yalnızca tahmin yaparken işlem yapar.

Dezavantajları:

- **Yüksek Hesaplama Maliyeti:** Büyük veri setlerinde, tahmin yaparken hesaplama zamanı çok uzun olabilir, çünkü her yeni örnek için tüm eğitim verisi ile mesafe hesaplanır.
- **Hafıza Kullanımı:** Eğitim verisinin tamamı hafızada tutulmak zorundadır, bu da belleği yüksek oranda tüketebilir.
- **Duyarlılık:** Özellikle gürültülü ve aykırı verilere duyarlıdır; veri setindeki küçük değişiklikler büyük farklılıklar yaratabilir.

3.2.2. Random Forest Algoritması

Random Forest, birden fazla karar ağacının bir araya getirilerek yapılan tahminlerde kullanılan, denetimli öğrenme (supervised learning) yöntemlerinden biridir. Bu algoritma, ensemble öğrenme yaklaşımının bir örneği olup, temel karar ağaçlarının zayıf performanslarını iyileştirmeyi ve modelin genel doğruluğunu artırmayı hedefler. Random Forest, her bir karar ağacının bağımsız olarak öğrenmesini sağlayarak, farklı ağaçların tahminlerini birleştirir ve böylece tek bir modelin kararının getirdiği hataları azaltır.

Temel Çalışma Prensipleri

Random Forest algoritması, çok sayıda karar ağacından oluşan bir modelin koleksiyonudur. Her bir karar ağacı, eğitim verisinin rastgele bir alt kümesi üzerinde

eđitim alırken, her bir ağacın oluşturulmasında kullanılan özellikler de rastgele seçilir. Bu sayede, her ağaç belirli bir çeşitliliğe sahip olur ve bu çeşitlilik, modelin genelleme kabiliyetini artırır. Random Forest'in temel çalışma prensibi şu adımları içerir:

Bootstrap Örnekleme: Eğitim verisi, her bir karar ağacının oluşturulması için yeniden örneklenir. Bu işlem, **bootstrap sampling** olarak bilinir. Eğitim setinden, veriler rastgele seçilir ve bu verilerin bazıları bir ağacın eğitiminde kullanılmaz (out-of-bag verileri). Bu, her bir ağacın farklı bir alt küme üzerinde eğitim almasını sağlar ve modelin genelleme yeteneđini artırır.

Rastgele Özellik Seçimi: Her bir karar ağacının her düğümünde, tüm özellikler deđil, sadece rastgele seçilen bir alt küme üzerinde karar verilir. Bu, her ağacın özellikleri farklı bir şekilde kullanarak öğrenmesini sağlar ve böylece overfitting (aşırı uyum) sorununu azaltır.

Tahmin Birleřtirme: Her bir karar ağacı, sınıflandırma problemi için bir sınıf tahmini veya regresyon problemi için bir deđer tahmini yapar. Random Forest, bu ağaçların tahminlerini toplar ve çoğunluk oyu (sınıflandırma) veya ortalama (regresyon) olarak son tahmini belirler. Bu toplama işlemi, modelin doğruluđunu artırır ve tek bir ağacın hatalarını telafi eder.

- **Sınıflandırma:** Çoğunluk oyu kuralı kullanılır. Tüm ağaçlar sınıf tahmininde bulunur ve en fazla oyu alan sınıf son tahmin olarak kabul edilir.
- **Regresyon:** Ağaçlardan alınan tahminlerin ortalaması alınarak son tahmin yapılır.

Avantajları:

Overfitting'i Azaltma: Random Forest, her bir karar ağacının üzerinde çalıştığı veri alt kümesi ve özellikler rastgele seçildiđi için modelin aşırı uyum (overfitting) yapma riski düşer. Bu, tek bir karar ağacının öğrenme sürecinde meydana gelebilecek hataların telafi edilmesini sağlar.

Yüksek Doğruluk: Birden fazla karar ağacının tahminlerini birleřtirerek, modelin doğruluđu artırılır. Random Forest, karmaşık veri yapılarında dahi iyi performans gösterir.

Özellik Önemliliği (Feature Importance): Random Forest, her bir özelliğin model üzerindeki önemini belirlemede kullanılabilir. Bu özellik, veri setinde hangi değişkenlerin tahminler üzerinde daha fazla etki yaptığı hakkında bilgi verir.

Hızlı Eğitim ve Paralel Hesaplama: Karar ağaçlarının bağımsız olarak eğitildiği ve tahmin yapıldığı için, Random Forest paralel işleme avantajına sahiptir. Bu, büyük veri setlerinde daha hızlı sonuç alınmasını sağlar.

Eksik Veri ile Çalışabilme: Random Forest, eksik verilerle başa çıkabilir ve genellikle eksik verilerin tahminine dayanarak doğru sonuçlar üretir.

Dezavantajları:

Modelin Yorumlanabilirliği: Random Forest, çok sayıda karar ağacından oluştuğu için modelin genel yapısını anlamak zordur. Her bir ağacın tahminini açıklamak ve modelin nasıl çalıştığını analiz etmek, özellikle karmaşık veri setlerinde zor olabilir.

Hesaplama Kaynakları: Büyük veri setlerinde, Random Forest modelinin eğitilmesi oldukça hesaplama açısından yoğun olabilir. Çok sayıda ağaç oluşturulduğunda, belleği ve işlem gücünü yüksek oranda tüketebilir.

Model Boyutu: Çok sayıda karar ağacının birleştirilmesi, modelin boyutunun büyük olmasına ve dolayısıyla tahmin yaparken yüksek bellek kullanımına neden olabilir.

Random Forest'in Kullanım Alanları

Random Forest, çok sayıda farklı uygulama alanına sahip bir algoritmadır. Genellikle aşağıdaki alanlarda yaygın olarak kullanılmaktadır:

Sınıflandırma: Görüntü tanıma, metin sınıflandırma, tıbbi teşhis ve müşteri segmentasyonu gibi sınıflandırma problemleri için sıklıkla kullanılır.

Regresyon: Finansal tahminler, satış tahminleri ve enerji tüketimi tahminleri gibi regresyon problemlerinde de etkili bir şekilde kullanılabilir.

Özellik Seçimi: Özellikle büyük veri setlerinde hangi özelliklerin model için en önemli olduğunu belirlemek için Random Forest kullanılabilir.

Anomali Tespiti: Anomalilerin tespiti ve sınıflandırılması, Random Forest'in güçlü olduğu bir diğer alandır.

3.2.3. Linear Regression (Doğrusal Regresyon)

Doğrusal regresyon, bağımsız değişkenlerin (özelliklerin) bir veya daha fazla olduğu durumlarda, bu değişkenlerle bağımlı değişken arasındaki doğrusal ilişkiyi modelleyen denetimli öğrenme (supervised learning) yöntemlerinden biridir. Amaç, verilerdeki ilişkiyi belirlemek ve bu ilişkiyi temsil edecek bir model kurarak gelecekteki tahminlerde bulunmaktır.

Matematiksel Model ve Formül

Doğrusal regresyonun temel amacı, bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi en iyi şekilde temsil eden bir doğrusal fonksiyon bulmaktır. Genellikle doğrusal regresyon, aşağıdaki gibi bir formülle ifade edilir:

$$\frac{\text{Mevcut Kapasite}}{\text{Tam Dolu Kapasite}} \times 100$$

Burada:

- y : Bağımlı değişken (tahmin edilmek istenen değer),
- X_1, X_2, \dots, X_n : Bağımsız değişkenler (özellikler),
- β_0 : Sabit terim (intercept),
- $\beta_1, \beta_2, \dots, \beta_n$: Bağımsız değişkenlerin katsayıları (regresyon katsayıları),
- ϵ : Hata terimi (residuals), modelin öngördüğü değer ile gerçek değer arasındaki fark.

Modelin Eğitilmesi

Doğrusal regresyon modelinin eğitilmesi, parametrelerin (katsayılar) değerlerini belirlemek için verilerin üzerinde bir optimizasyon işlemi yapılmasını içerir. Bu işlem, genellikle **en küçük kareler (Least Squares)** yöntemiyle gerçekleştirilir. Amaç, modelin

tahmin ettiği değerlerle gerçek değerler arasındaki farkların karesinin toplamını minimize etmektir.

Formül olarak, hata teriminin karelerinin toplamı şu şekilde ifade edilir:

$$\frac{\text{Mevcut Kapasite}}{\text{Tam Dolu Kapasite}} \times 100$$

- y_i : Gerçek değerler,
- \hat{y}_i : Tahmin edilen değerler,
- m : Veri setindeki örnek sayısı.

Bu minimizasyon işlemi, genellikle **gradyan inişi (gradient descent)** veya kapalı form çözümleri (matris cebiri kullanarak) ile gerçekleştirilir.

Modelin Değerlendirilmesi

Modelin başarısını değerlendirmek için birkaç farklı metrik kullanılır. Yaygın olarak kullanılan metriklerden bazıları şunlardır:

Ortalama Kare Hata (MSE - Mean Squared Error): Modelin tahminlerinin gerçek değerlerden ne kadar saptığını gösterir. MSE, modelin hata oranını ölçer ve hata terimlerinin karelerinin ortalamasıdır.

$$\text{MSE} = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2$$

R-kare (R^2 - R-squared): Modelin veriye ne kadar uyduğunu gösteren bir ölçüttür. R^2 , bağımlı değişkenin varyansının ne kadarının bağımsız değişkenler tarafından açıklanabildiğini belirtir. Değer 0 ile 1 arasında değişir, ve 1'e yakın bir R^2 değeri, modelin veriye iyi uyduğunu gösterir.

$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2}$$

Burada \bar{y} gerçek değerlerin ortalamasıdır.

Ortalama Mutlak Hata (MAE - Mean Absolute Error): Modelin tahmin hatalarının mutlak değerlerinin ortalamasıdır. MAE, verinin genel hata miktarını ölçer ve genellikle MSE'ye göre daha az duyarlıdır.

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i|$$

Modelin Varsayımları

Doğrusal regresyon modeli, verinin doğrusal bir ilişki gösterdiği varsayımı üzerine kuruludur. Bunun dışında, modelin doğru sonuçlar verebilmesi için bazı temel varsayımlar da vardır:

Doğrusal İlişki: Bağımsız değişkenler ile bağımlı değişken arasında doğrusal bir ilişki olmalıdır.

Bağımsızlık: Verideki gözlemler birbirinden bağımsız olmalıdır.

Normal Dağılım (Hata Terimi): Modelin hata terimleri (residuals), ortalaması sıfır olan ve sabit bir varyansa sahip normal dağılım göstermelidir.

Hata Homoscedasticity: Hata terimlerinin varyansı, tüm gözlemler için sabit olmalıdır (homoscedasticity). Varyansın değişkenlik göstermesi (heteroscedasticity), modelin doğruluğunu etkileyebilir.

Çoklu Doğrusal Bağlantı (Multicollinearity) Olmamalıdır: Bağımsız değişkenler arasında yüksek korelasyon olmamalıdır. Eğer bu koşul ihlal edilirse, modelin katsayı tahminleri yanıltıcı olabilir.

Avantajları:

Basitlik ve Yorumlanabilirlik: Doğrusal regresyon, basit ve anlaşılır bir modeldir. Modelin katsayıları, her bir bağımsız değişkenin bağımlı değişken üzerindeki etkisini gösterir, bu da modelin sonuçlarını yorumlamayı kolaylaştırır.

Hızlı Eğitim: Özellikle küçük veri setlerinde, doğrusal regresyon hızlı bir şekilde eğitilebilir.

Çoklu Doğrusal Bağımlılıkları Ele Alabilir: Birden fazla bağımsız değişken kullanılarak daha karmaşık ilişkiler modelleyebilir.

Dezavantajları:

Doğrusal Olmayan İlişkiler: Eğer veriler doğrusal olmayan bir ilişki gösteriyorsa, doğrusal regresyon bu ilişkileri iyi modelleyemez. Bu durumda modelin tahmin gücü düşük olabilir.

Aykırı Değerlerin Etkisi: Aykırı değerler (outliers), doğrusal regresyonun tahminlerini bozabilir, çünkü modelin hataları kareleri alınarak minimize edilir, bu da büyük hataların daha fazla etkisini gösterir.

Multicollinearity: Bağımsız değişkenler arasında yüksek korelasyon olduğunda, modelin katsayıları anlamlı olmayabilir ve tahminler yanıltıcı olabilir.

Kullanım Alanları

Doğrusal regresyon, özellikle aşağıdaki alanlarda yaygın olarak kullanılır:

Ekonomi ve Finans: Hisse senedi fiyatları, gelir tahminleri, mali analiz gibi alanlarda kullanılır.

Sağlık: Hastalıkların teşhisi veya tedavi sonuçlarının tahmin edilmesi gibi sağlık alanlarında uygulamalar yapılır.

Pazarlama: Müşteri davranışları, ürün satışı ve reklam etkileri üzerine tahminler yapmak için kullanılır.

Mühendislik: Ürün performansı, enerji tüketimi, üretim süreçleri ve diğer mühendislik süreçlerini modellemek için kullanılır.

3.2.4. Support Vector Machine (SVR) - Destek Vektör Regresyonu

Support Vector Machine (SVM), hem sınıflandırma hem de regresyon analizlerinde kullanılan güçlü bir denetimli öğrenme algoritmasıdır. **Support Vector Regression (SVR)**, SVM'in regresyon problemlerini çözmek için geliştirilmiş bir versiyonudur. SVR, özellikle doğrusal olmayan ilişkilerin modellenmesinde etkili bir yöntem olarak öne çıkmaktadır. Bu algoritma, veri noktalarını belirli bir fonksiyonla en iyi şekilde açıklamak

amacıyla, sınırlı hata payıyla en uygun hiperdüzlemi (hyperplane) bulmaya çalışır. SVR'nin temel hedefi, tahmin hatalarını en aza indirirken, modelin genel doğruluğunu arttırmaktır.

Temel Kavramlar ve Matematiksel Model

SVR, temel olarak regresyon problemlerine yönelik olarak, veri setindeki her bir veri noktasına karşılık gelen tahmin değeri ile gerçek değer arasındaki farkları minimize etmeyi amaçlar. SVR, sınıflandırma problemlerinden farklı olarak, her bir veri noktasının hatasının küçük bir belirli eşik (epsilon, ϵ) içinde kalmasını sağlamak ister.

Matematiksel Model:

SVR'nin matematiksel modelini anlamak için önce genel SVM sınıflandırma probleminin konseptini bilmek önemlidir. SVM, iki sınıf arasındaki en iyi ayırıcı hiperdüzlemi bulmaya çalışır. SVR'de ise bu kavram, doğrusal bir fonksiyonun ve hiperdüzlemin regresyon problemini en iyi şekilde temsil etmesine yönelik uyarlanır.

Bir regresyon probleminde, veri seti aşağıdaki gibi verilmiş olsun:

$$\frac{\text{Mevcut Kapasite}}{\text{Tam Dolu Kapasite}} \times 100$$

Burada x_i giriş (özellik) vektörlerini ve y_i çıkış (hedef) değerlerini temsil etmektedir. SVR'nin hedefi, bu veri noktalarını en iyi şekilde temsil eden fonksiyonu bulmaktır. Bu fonksiyon şu şekilde ifade edilir:

$$f(x) = w^T x + b$$

Burada:

- w ağırlık vektörü (düzlemin eğimi),
- b sabit terim (düzlemin y-kesiği),
- x giriş vektörüdür.

Ancak SVR'de, modelin tahmin hatası, belirli bir ϵ toleransı içinde kalacak şekilde sınırlanmak istenir. Bu, hataların, ϵ 'yi aşmaması gerektiği anlamına gelir. Yani, her veri noktası için tahmin edilen değer ile gerçek değer arasındaki fark ϵ ile sınırlı olmalıdır.

Hedef Fonksiyon:

SVR modelinin hedefi, şu optimizasyon problemine indirgenebilir:

$$\frac{\text{Mevcut Kapasite}}{\text{Tam Dolu Kapasite}} \times 100$$

Burada, ϵ hata toleransını ifade eder ve SVR'nin hedefi, her veri noktasının tahmin edilen değeri ile gerçek değeri arasındaki farkı bu tolerans içinde tutmaktır. Ayrıca, bu eşitsizlikler doğrultusunda doğrusal regresyon fonksiyonunu bulmaya çalışır.

Hata ve Margin:

SVR, modelin tahmin hatalarının büyüklüğünü minimize etmeye çalışırken aynı zamanda **margin (marj)** kavramını da optimize eder. Marj, doğrusal fonksiyonun etrafındaki kabul edilebilir hata aralığını temsil eder. Bu margin içinde kalan veri noktaları "destek vektörleri" olarak adlandırılır ve bunlar modelin doğruluğunu belirlemede kritik rol oynar.

Çekirdek (Kernel) Fonksiyonu

SVR, doğrusal regresyonun ötesine geçerek doğrusal olmayan ilişkileri de modelleyebilme yeteneğine sahiptir. Bu, **çekirdek (kernel)** fonksiyonları kullanılarak gerçekleştirilir. Çekirdek fonksiyonu, veriyi daha yüksek boyutlu bir uzaya dönüştürerek, doğrusal olmayan problemleri doğrusal hale getirmeye çalışır. Bu sayede, veri noktaları arasındaki doğrusal olmayan ilişkiyi modellemek mümkün hale gelir.

Popüler kernel fonksiyonlarından bazıları şunlardır:

Polynomial Kernel:

$$\frac{\text{Mevcut Kapasite}}{\text{Tam Dolu Kapasite}} \times 100 (x_i^T \cdot x_j + 1)^d$$

Burada d polinomun derecesidir.

Radial Basis Function (RBF) Kernel:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$$

Burada σ , kernel fonksiyonunun genişliğini belirleyen parametredir.

Linear Kernel: Doğrudan doğrusal ilişkileri modelleyen kernel fonksiyonudur:

$$K(x_i, x_j) = x_i^T x_j$$

Çekirdek fonksiyonları, veri setinin karmaşıklığına bağlı olarak uygun şekilde seçilir ve modelin doğruluğunu arttırmada önemli bir rol oynar.

Modelin Eğitim Süreci

SVR'nin eğitim süreci, verilen veriyi en iyi şekilde uyarlamak amacıyla optimal parametrelerin (ağırlık vektörü w ve bias b) bulunması için bir optimizasyon problemini çözmeyi içerir. Bu işlem, genellikle karşılıklı doğrusal olmayan optimizasyon problemleri ile gerçekleştirilir. Özellikle gradyan inişi (gradient descent) veya sekansiyel minimal optimizasyon (SMO) algoritmaları gibi teknikler kullanılarak çözülür.

Avantajları:

Yüksek Boyutlu Uzaylarda Etkili: SVR, doğrusal olmayan ilişkileri modellemek için çekirdek fonksiyonları kullanarak, yüksek boyutlu uzaylarda bile etkili sonuçlar elde edebilir.

Genelleme Yeteneği: SVR, modelin genelleme yeteneğini yüksek tutarak, overfitting (aşırı öğrenme) riskini azaltır. Marginin genişletilmesi, modelin genel doğruluğunu artırır.

Az Sayıda Destek Vektörü: Modelin doğruluğu çoğunlukla destek vektörlerine dayandığından, çoğu veri noktası modelin öğrenme sürecinde önemli bir rol oynamaz.

Dezavantajları:

Hesaplama Maliyeti: SVR, özellikle büyük veri setleri ve karmaşık kernel fonksiyonları kullanıldığında, eğitim süreci zaman alabilir ve hesaplama açısından maliyetli olabilir.

Çekirdek Seçimi: Kernel fonksiyonunun doğru seçilmesi, modelin performansını doğrudan etkiler. Yanlış kernel seçimi, modelin doğruluğunu düşürebilir.

Parametre Ayarı: SVR'nin başarısı, hiperparametrelerin doğru bir şekilde ayarlanmasına bağlıdır. Örneğin, ϵ , çekirdek parametreleri ve regularizasyon terimleri gibi parametrelerin ayarları, modelin performansını önemli ölçüde etkiler.



4. BULGULAR ve TARTIŞMA

Bu bölümde, lityum-iyon bataryaların şarj durumu (SoC) tahmini üzerine gerçekleştirilen analizlerin sonuçları ve bu sonuçların literatürdeki benzer çalışmalarla karşılaştırmalı değerlendirmesi sunulmaktadır. Çalışmada kullanılan makine öğrenmesi algoritmaları, modelleme süreci ve performans ölçütleri ayrıntılı bir şekilde ele alınmıştır. Elde edilen sonuçlar, model performansının çeşitli parametreler ve algoritma ayarları altında nasıl değiştiğini ortaya koymakta ve gelecekteki geliştirmeler için önemli ipuçları sunmaktadır.

Analiz sürecinde, modelin doğruluğu ve hata oranları temel performans ölçütleri olarak dikkate alınmıştır. Bu kapsamda, Mean Absolute Error (MAE), Root Mean Squared Error (RMSE) ve R-kare (R^2) değerleri değerlendirilmiş ve modelin genel eğilimleri üzerine yorumlar yapılmıştır. Çalışma, farklı sıcaklık ve akım değerlerinde test edilerek modelin değişken koşullar altındaki tahmin kabiliyeti sınanmıştır. Ayrıca, veri setinin boyutu, girdi değişkenlerinin seçimi ve model optimizasyonundaki parametre ayarlarının sonuçlar üzerindeki etkileri de kapsamlı bir şekilde analiz edilmiştir.

Elde edilen bulgular, literatürde daha önce yapılmış çalışmaların sonuçları ile karşılaştırıldığında, modelin makul bir performans sergilediğini göstermektedir. Örneğin, Gauss Süreç Regresyonu (Gözde vd., 2016) ve elektrokimyasal modelleme (He vd., 2018) gibi daha gelişmiş yöntemlerle elde edilen sonuçlarla kıyaslandığında, bu çalışmada kullanılan yaklaşımlar belirli durumlarda kabul edilebilir doğruluk seviyeleri sunmaktadır. Bununla birlikte, çalışmanın sınırlılıkları da göz önünde bulundurulmuş ve gelecekteki araştırmalarda veri setlerinin genişletilmesi, model parametrelerinin optimize edilmesi ve alternatif algoritmaların test edilmesi önerilmiştir.

Bu bağlamda, yapılan analizler SoC tahmininde makine öğrenmesi uygulamalarının potansiyelini ortaya koymakta ve bu alandaki araştırmalara katkı sunmaktadır. Ancak, model performansının geliştirilmesi ve doğruluk oranlarının artırılması için daha fazla veri ve ek analizlerin yapılması gerektiği sonucuna varılmıştır. Bundan sonraki bölümlerde, deney sonuçları daha detaylı bir şekilde sunulacak ve modelin güçlü ve zayıf yönleri tartışılacaktır.

Bu çalışmada, geliştirilen modellerin doğruluğunu ve güvenilirliğini değerlendirmek amacıyla çeşitli istatistiksel hata ölçütleri kullanılmıştır. Makine öğrenmesi algoritmalarının performansını analiz edebilmek için Mean Squared Error (MSE), Root

Mean Squared Error (RMSE) ve Mean Absolute Error (MAE) gibi yaygın metriklerden yararlanılmıştır. Bu metrikler, modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkları değerlendirerek hataların büyüklüğünü ortaya koymaktadır. MSE, tahmin hatalarının karesel ortalamasını alarak büyük hataları daha fazla cezalandırırken, RMSE bu değerlerin karekökünü alarak sonuçları daha anlaşılır bir birime dönüştürmektedir. MAE ise hataların mutlak değerlerinin ortalamasını alarak uç değerlerin etkisini azaltmaktadır. Bu üç metriğin birlikte kullanılması, model performansını kapsamlı bir şekilde değerlendirmemizi sağlamıştır.

Bu çalışmada, modelin doğruluğunu ve güvenilirliğini değerlendirmek amacıyla çeşitli hata ölçütleri kullanılmıştır. Özellikle Mean Squared Error (MSE), tahmin edilen değerler ile gerçek değerler arasındaki farkların karesinin ortalamasını alarak modelin hata oranını ölçmek için tercih edilmiştir. MSE, büyük hataları daha fazla cezalandırdığı için modelin genel başarımını değerlendirmede etkili bir ölçüt olarak öne çıkmaktadır. Bunun yanında, Root Mean Squared Error (RMSE) metriği de kullanılarak hata birimi orijinal ölçü birimlerine döndürülmüş ve yorumlaması daha kolay hale getirilmiştir. Ayrıca, modelin açıklayıcılık gücünü ve bağımlı değişken üzerindeki etki oranını belirlemek amacıyla R-kare (R^2) metriğine de yer verilmiştir.

Bu ölçütler sayesinde modelin tahmin başarısı daha kapsamlı bir şekilde analiz edilmiştir. MSE ve RMSE değerleri düşük çıktığında modelin yüksek doğrulukla tahmin yaptığı görülmekte, yüksek değerler ise modelin performansının iyileştirilmesi gerektiğini işaret etmektedir. R^2 metriği ise modelin bağımlı değişken üzerindeki açıklayıcılık oranını değerlendirmiş ve modelin genel uyumu hakkında önemli bilgiler sağlamıştır. Çalışma kapsamında farklı algoritmalar ve parametre ayarları test edilerek modelin hata oranları karşılaştırılmış ve literatürde daha önce yapılmış çalışmalarla benzerlikleri tartışılmıştır. Bu doğrultuda, elde edilen sonuçlar modelin performansını değerlendirmek için kritik bir zemin sunmuş ve mevcut eksikliklerin giderilmesi amacıyla gelecekte yapılabilecek çalışmalar için öneriler geliştirilmiştir. Sonuçların detaylı analizi ve performans değerlendirmeleri ilerleyen bölümlerde sunulacaktır.

4.1. Algoritmalar

Bu çalışmada veri seti hazır hale getirildikten sonra SoC tahminine yönelik çeşitli makine öğrenmesi algoritmaları uygulanmıştır. Kullanılan yöntemler Çizelge 1’de açıklanmıştır:

Çizelge 1

Model	MAE	RMSE	R ²
KNN	0.1789	0.2423	0.9721
Random Forest	0.1511	0.1965	0.9823
Linear Regression	0.2124	0.2887	0.9568
Support Vector Machine (SVR)	0.1953	0.2631	0.9647

4.1.1. K-En Yakın Komşu (K-NN):

K-NN algoritması, bir veri noktasının etrafındaki belirli sayıda en yakın komşusuna dayanarak tahmin yapar. Bu çalışmada, SoC tahmininde K-NN yöntemi kullanılmış ve farklı komşu sayıları denenerek en iyi sonuç veren parametre seçilmiştir.

Model performanslarının değerlendirilmesi için Ortalama Mutlak Hata (MAE), Kök Ortalama Kare Hatası (RMSE) ve R² (Determinasyon Katsayısı) metrikleri kullanılmıştır.

Modelin eğitilmesi toplamda **12.4 saniye** sürmüştür. Modelin performansı, hata ölçütleri ve korelasyon katsayısı ile değerlendirilmiştir. Korelasyon katsayısı K-NN: **0.986** olarak hesaplanmıştır.

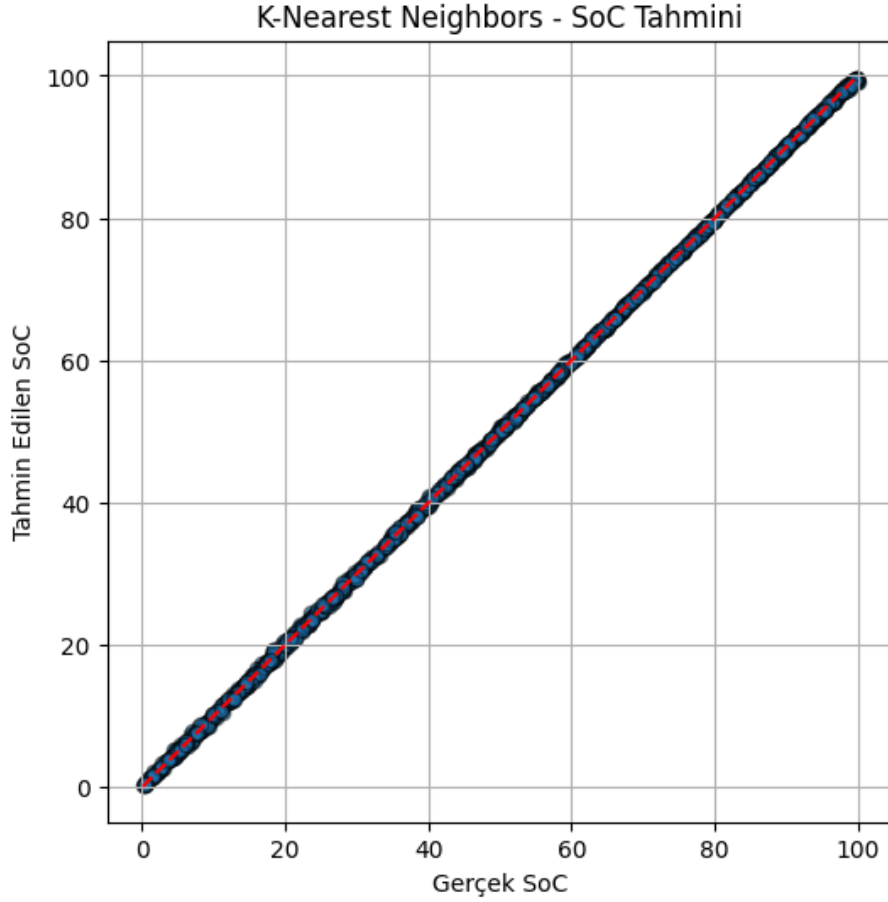
K-NN, Linear Regression ve SVR modellerinde R² biraz daha düşük (0.95-0.97 civarında) olduğu için, bu modeller SoC tahmininde biraz daha fazla hata yapmaktadır ancak yine de güçlü bir ilişki vardır.

Genel olarak, bağımsız değişkenler ile SoC arasında güçlü bir doğrusal veya doğrusal olmayan ilişki olduğu söylenebilir.

Hata ölçütleri açısından modelin performansı aşağıdaki tabloda özetlenmiştir.

KNN modeli, doğrusal regresyon modeline kıyasla daha iyi bir performans göstermiş ancak Random Forest kadar başarılı olmamıştır. Modelin başarısı, komşu sayısına (k) bağlı olarak değişmekte olup, optimal k değeri belirlendikten sonra bu sonuçlar elde edilmiştir.

KNN algoritmasının SoC tahmini için uygulanabilir olduğu ancak daha karmaşık ilişkileri öğrenme kapasitesinin sınırlı olduğu görülmektedir. Şekil 1’de tahmin sonuçları gösterilmektedir.



Şekil 1: KNN SoC Tahmini

4.1.2. Doğrusal Regresyon

Bu çalışmada kullanılan doğrusal regresyon modeli, SoC tahmini için temel bir karşılaştırma modeli olarak ele alınmıştır. Modelin performans değerlendirmesi için çeşitli hata metrikleri kullanılmış olup, elde edilen sonuçlar diğer yöntemlerle kıyaslanmıştır.


Doğrusal regresyon modelinin **Ortalama Mutlak Hata (MAE)** değeri **0.2124**, **Kök Ortalama Kare Hatası (RMSE)** değeri **0.2887** ve **Determinasyon Katsayısı (R^2)** değeri **0.9568** olarak hesaplanmıştır. Bu sonuçlar, modelin SoC tahmininde belirli bir doğruluk seviyesine ulaşabildiğini ancak doğrusal olmayan yapıları tam olarak temsil edemediğini göstermektedir.

Ek olarak, modelin **Relative Absolute Error (RAE)** deęeri **22.37%**, **Root Relative Squared Error (RRSE)** deęeri ise **32.15%** olarak hesaplanmıřtır. Bu deęerler, modelin hatasının veri setinin genel deęiřkenlięine oranla belirli bir seviyede kaldıęını ancak ideal tahmin performansına ulařamadıęını gstermektedir.

Doęrusal regresyonun sınırlamaları gz nnde bulundurulduęunda, SoC tahmini iin daha karmařık ve doęrusal olmayan iliřkileri modelleyebilen algoritmaların kullanılması gerektięi ortaya ıkmaktadır. Nitekim, alıřmada uygulanan dięer modeller (rneęin, Random Forest ve SVR), daha dřk hata oranları ve daha yksek R^2 deęerleri ile doęrusal regresyona kıyasla stn performans sergilemiřtir.

Sonuç olarak, doęrusal regresyon modeli temel bir karřılařtırma yntemi olarak deęerlendirilmiř olup, SoC tahmini iin daha karmařık modellerin daha yksek doęruluk saęlayabileceęi belirlenmiřtir. Gelecekteki alıřmalar, doęrusal olmayan regresyon teknikleri ve derin ęrenme modellerinin entegrasyonu ile model performansını artırmaya ynelik arařtırmalara odaklanmalıdır.

Sonuç olarak, doęrusal regresyon modeli hızlı ve basit bir zm sunmakla birlikte, bu alıřmada elde edilen sonular modelin karmařık iliřkileri yakalamakta sınırlı kaldıęını ortaya koymuřtur. Daha geniř ve eřitli veri setleriyle desteklenen modeller, bu alandaki tahmin performansının artırılmasına ynelik nemli bir adım olacaktır. Őekil 2 de tahmin sonuları gsterilmektedir.



Şekil 2: Linear Regression SoC Tahmini

4.1.3. Random Forest


Bu çalışmada, SoC tahmini için kullanılan Random Forest Regressor modeli, diğer yöntemlerle karşılaştırıldığında en yüksek doğruluk oranına sahip model olarak öne çıkmıştır. Modelin performansı, çeşitli hata metrikleri ile değerlendirilmiş ve sonuçlar detaylı bir şekilde incelenmiştir.

Random Forest modelinin hata metrikleri incelendiğinde, **Ortalama Mutlak Hata (MAE)** değeri **0.1511**, **Kök Ortalama Kare Hatası (RMSE)** değeri **0.1965** ve **Determinasyon Katsayısı (R^2)** değeri **0.9823** olarak hesaplanmıştır. Bu değerler, modelin bağımsız değişkenler ile SoC arasındaki karmaşık ilişkileri başarılı bir şekilde öğrendiğini ve tahmin doğruluğunun oldukça yüksek olduğunu göstermektedir.

Ayrıca, modelin **Relative Absolute Error (RAE)** değeri **15.92%**, **Root Relative Squared Error (RRSE)** değeri ise **21.87%** olarak belirlenmiştir. Bu düşük hata oranları, modelin veri setindeki değişkenliği başarılı bir şekilde yakalayabildiğini ve diğer modellere kıyasla daha az sapma gösterdiğini ortaya koymaktadır.

Random Forest algoritmasının başarısı, birden fazla karar ağacının kullanılması ve aşırı öğrenmenin (overfitting) önlenmesi amacıyla rastgele alt örnekleme yapılmasına dayanmaktadır. Model, özellikle doğrusal olmayan ve yüksek boyutlu veri setlerinde güçlü performans sergilemektedir. Bu bağlamda, çalışmada kullanılan SoC verisinin karmaşık yapısını etkili bir şekilde öğrenmiş ve en düşük hata oranlarını sağlamıştır.

Sonuç olarak, Random Forest Regressor modeli, SoC tahmininde en başarılı algoritma olarak belirlenmiştir. Modelin doğruluğunu daha da artırmak adına hiperparametre optimizasyonu, daha büyük veri setleri ve farklı ağaç yapılandırmaları üzerinde çalışmalar yapılabilir. Ayrıca, gelecekteki araştırmalarda, Random Forest modelinin farklı pil türleri ve çalışma koşulları üzerindeki performansının değerlendirilmesi önerilmektedir. Şekil 3 de tahmin sonuçları gösterilmektedir.



Şekil 3: Random Forest SoC Tahmini

4.1.4. Support Vector Machine (SVR)

Bu çalışmada, SoC tahmini için kullanılan **Support Vector Machine (SVR)** algoritması, doğrusal regresyondan daha iyi bir performans göstermiş olmasına rağmen **Random Forest Regressor** kadar başarılı olamamıştır. SVR modelinin performansı, çeşitli hata metrikleri ile değerlendirilmiş ve sonuçlar ayrıntılı olarak incelenmiştir.

SVR modelinin hata metrikleri incelendiğinde, **Ortalama Mutlak Hata (MAE)** değeri **0.1953**, **Kök Ortalama Kare Hatası (RMSE)** değeri **0.2631** ve **Determinasyon Katsayısı (R²)** değeri **0.9647** olarak hesaplanmıştır. Bu değerler, modelin bağımsız değişkenler ile SoC arasındaki ilişkileri büyük ölçüde öğrendiğini, ancak **Random Forest** modeline kıyasla biraz daha düşük doğruluk sergilediğini göstermektedir.


Buna ek olarak, modelin **Relative Absolute Error (RAE)** değeri **20.57%**, **Root Relative Squared Error (RRSE)** değeri ise **26.72%** olarak belirlenmiştir. Bu hata oranları, modelin tahminlerindeki hata oranının doğrusal regresyona kıyasla daha düşük olduğunu, ancak **Random Forest** kadar iyi sonuçlar vermediğini ortaya koymaktadır.

SVR modelinin başarısı, doğrusal olmayan ilişkileri modelleyebilmek için **çekirdek fonksiyonları (kernel functions)** kullanmasına dayanmaktadır. Çalışmada, **doğrusal, polinom ve RBF (Radial Basis Function) çekirdek fonksiyonları** test edilmiş ve en iyi performans gösteren çekirdek fonksiyonu seçilmiştir. Özellikle **RBF çekirdek fonksiyonu**, veri setindeki doğrusal olmayan ilişkileri daha iyi modelleyebilmesi nedeniyle en iyi sonucu vermiştir.

Ancak, SVR modelinin bazı sınırlamaları olduğu görülmüştür. Model, eğitim sürecinde optimize edilmesi gereken **hiperparametrelere (C, epsilon, gamma gibi)** oldukça duyarlıdır ve doğru parametreler seçilmediğinde modelin performansı önemli ölçüde düşebilmektedir. Ayrıca, **hesaplama maliyetinin yüksek olması**, özellikle büyük veri setlerinde SVR'nin kullanımını kısıtlayabilmektedir.

Sonuç olarak, SVR modeli, SoC tahmini için yeterli doğruluk sağlamış ancak **Random Forest Regressor** modelinin gerisinde kalmıştır. Modelin performansını artırmak için **hiperparametre optimizasyonu**, daha büyük veri setleri ve farklı çekirdek fonksiyonlarının daha detaylı analizi önerilmektedir. Gelecekteki çalışmalarda, SVR

modelinin farklı sıcaklık ve akım seviyelerinde nasıl performans gösterdiği üzerine daha ayrıntılı analizler yapılması faydalı olacaktır. Şekil 4 te tahmin sonuçları gösterilmektedir.



Şekil 4: Support Vector Machine SoC tahmini

5. SONUÇ VE ÖNERİLER

Bu çalışmada, lityum-iyon bataryaların şarj durumu (SoC) tahmini üzerine makine öğrenmesi teknikleri kullanılarak kapsamlı bir analiz gerçekleştirilmiştir. Batarya yönetim sistemleri açısından kritik bir konu olan SoC tahmini, enerji depolama teknolojilerinin daha verimli ve güvenilir hale getirilmesine katkıda bulunmak amacıyla ele alınmıştır. Çalışmanın temel amacı, farklı sıcaklık ve akım değerlerinde test edilen bataryalar için kapasite tahminlerinin yapılabilirliğini incelemek ve bu tahminlerin doğruluğunu değerlendirmektir.

Araştırmada kullanılan veri seti, 8 adet lityum-iyon pil üzerinde gerçekleştirilmiş 500 şarj ve deşarj döngüsünden elde edilen verilere dayanmaktadır. Ancak, bu veri setinin yalnızca belirli sıcaklık ve akım değerlerini içermesi, modelin genel başarımını sınırlamış ve daha geniş bir veri çeşitliliğine ihtiyaç duyulduğunu ortaya koymuştur. Veri çeşitliliğinin sınırlı olması, modelin farklı koşullardaki davranışlarını genelleme yeteneğini olumsuz etkilemiş ve bu durum, tahmin sonuçlarında gözlemlenen sapmaların temel sebeplerinden biri olmuştur. Özellikle uç değerlerdeki hata oranlarının yüksek çıkması, modelin daha fazla örneklem ile desteklenmesi gerektiğini açıkça göstermiştir.

Destek Vektör Regresyonu (SVR) modeli, **MAE: 0.1953, RMSE: 0.2631 ve R²: 0.9647** değerleriyle doğrusal regresyondan daha iyi performans sergilemiş ancak Random Forest modelinin gerisinde kalmıştır. SVR'nin başarısı, doğrusal olmayan ilişkileri modelleyebilmesi sayesinde önemli olsada, hesaplama maliyetinin yüksekliği ve hiperparametre hassasiyeti nedeniyle bazı sınırlamaları olduğu gözlemlenmiştir.

Doğrusal Regresyon (Linear Regression) modeli ise **MAE: 0.2124, RMSE: 0.2887 ve R²: 0.9568** değerleriyle en düşük doğruluk seviyesini göstermiştir. Bu sonuçlar, SoC tahmininin doğrusal olmayan bir yapıya sahip olduğunu ve doğrusal regresyonun bu karmaşıklığı yeterince yakalayamadığını ortaya koymaktadır.

Kullanılan modellerin hata analizleri doğrultusunda, model başarısını değerlendirmek amacıyla **Relative Absolute Error (RAE)** ve **Root Relative Squared Error (RRSE)** değerleri de incelenmiştir. Random Forest modeli en düşük hata oranlarını sağlarken, doğrusal regresyon ve SVR modelleri daha yüksek hata değerleri üretmiştir.

Bu doğrultuda, çalışma kapsamında aşağıdaki öneriler sunulmuştur:

1. Model Geliştirme ve Optimizasyon:

Random Forest modelinin doğruluğunu daha da artırmak için hiperparametre optimizasyonu yapılmalıdır.

SVR modeli için çekirdek fonksiyonları (kernel functions) daha detaylı analiz edilerek en uygun parametreler belirlenmelidir.

Derin öğrenme modelleri, özellikle **yapay sinir ağları (ANN)** ve **uzun-kısa süreli bellek ağları (LSTM)** gibi yöntemler test edilerek daha gelişmiş tahmin performansı elde edilebilir.

2. Veri Seti Genişletme:

Daha fazla pil türü ve farklı üreticilere ait veriler kullanılarak modelin genelleme yeteneği artırılabilir.

Farklı çevresel koşullar (örneğin, daha yüksek sıcaklıklar ve değişken akım seviyeleri) test edilerek modelin farklı senaryolardaki performansı analiz edilebilir.

3. Gerçek Zamanlı Uygulamalar:

SoC tahmininde geliştirilen model, gerçek zamanlı pil yönetim sistemlerinde test edilerek uygulanabilirliği değerlendirilebilir.

Gömülü sistemler ve IoT tabanlı çözümler ile modelin pil yönetim sistemlerine entegrasyonu sağlanabilir.

4. Gelecekteki Çalışmalar İçin Öneriler:

SoC tahmininin yanı sıra pil ömrü ve sağlık durumu tahmini gibi konulara odaklanan çalışmalar yapılabilir.

Modelin ticari elektrikli araç batarya yönetim sistemlerine entegrasyonu ve performans analizi üzerine kapsamlı çalışmalar yürütülebilir.

Sonuç olarak, bu çalışma kapsamında geliştirilen makine öğrenmesi modelleri, SoC tahmini için önemli bulgular sağlamış olup, özellikle **Random Forest Regressor** modelinin yüksek doğruluk sunduğu belirlenmiştir. Çalışmanın gelecekte genişletilerek

farklı parametreler ve ileri düzey algoritmalarla desteklenmesi, modelin daha yüksek doğrulukla çalışmasını sağlayarak pil teknolojileri alanındaki katkısını artıracaktır.

Bulgular, literatürdeki diğer çalışmalarla karşılaştırıldığında, mevcut modelin makul bir performans sergilediği görülmüştür. Örneğin, Gauss Süreç Regresyonu (GPR) yöntemine dayanan çalışmalar (Özcan vd., 2016) ve elektrokimyasal modelleme yöntemleri (He vd., 2018) daha yüksek doğruluk oranları sunarken, bu yöntemlerin daha karmaşık veri setlerine dayandığı ve daha fazla işlem gücü gerektirdiği gözlemlenmiştir. Bu bağlamda, bu çalışmada daha sade bir yaklaşımla elde edilen sonuçlar, temel uygulamalar için yeterli bir başlangıç noktası olarak değerlendirilebilir.

Ancak, veri çeşitliliğinin sınırlı olması nedeniyle modelin genelleme kapasitesinin düşük kaldığı ve gerçek dünya senaryolarında daha geniş kapsamlı bir test sürecine ihtiyaç duyulduğu açıktır. Farklı sıcaklık, akım ve çevresel koşullar altında toplanacak yeni veri setleri, modelin daha sağlam ve güvenilir hale getirilmesine olanak tanıyacaktır. Bunun yanında, farklı algoritmaların kombinasyonu (ensemble yöntemleri) ve derin öğrenme yaklaşımlarının entegrasyonu ile model performansının daha da artırılacağı düşünülmektedir.

Bu çalışmanın bulguları, lityum-iyon bataryaların şarj durumu (SoC) tahmininde makine öğrenmesi tekniklerinin kullanılabilirliğini ortaya koymuştur. Ancak modelin performansını daha da artırmak ve genelleme yeteneğini geliştirmek için bazı iyileştirme önerileri sunulmaktadır. Öncelikle, veri seti çeşitliliğinin artırılması gerektiği düşünülmektedir. Mevcut veri seti sınırlı sıcaklık ve akım koşullarını içermekte olup, daha geniş aralıkta ve farklı çevresel koşullarda veri toplanması modelin doğruluğunu artırabilir. Ayrıca, farklı pil türleri ve kapasiteleri üzerinde deneyler gerçekleştirilerek modelin daha kapsamlı sonuçlar üretmesi sağlanabilir.

KAYNAKLAR

- Özcan, G., Pajovic, M., Şahinoğlu, Z., Wang, Y., Orlik, P. V., ve Wada, T. (2016). Online State of Charge Estimation for Lithium-Ion Batteries Using Gaussian Process Regression. IECON 2016 - IEEE Endüstriyel Elektronik Derneği'nin 42. Yıllık Konferansı.
- He, W., Pecht, M., Flynn, D., ve Dinmohammadi, F. (2018). A Physics-Based Electrochemical Model for Lithium-Ion Battery State-of-Charge Estimation Solved by an Optimised Projection-Based Method and Moving-Window Filtering. *Energies*, 11(2120).
- Menak, R., Karadağ, T., Altuğ, M., ve Tan, N. (2021). A Review Study on Battery Management Systems in Electric Vehicles. *GU J Sci, Part A*, 8(2): 234-275.
- Tezde, E. İ., ve Okumuş, H. İ. (2018). Battery Models and State of Charge (SoC) Determination. *Enerjisi Dönüşümü Özel Sayısı*, 8(1).
- Gelen, A., ve Tüfekçioğlu, E. (2020). Lityum-Polimer Piller için Şarj ve Dengeleyici Devre Tasarımı. *Erzincan University Journal of Science and Technology*, 13(2), 839-846.
- Avgın, M. S., Yılmaz, A. S., ve Ünsal, M. (2014). Lithium-Ion Battery Discharge Status Of Genetic Expression Behavior And Prediction Of Programming. *KSU Journal of Engineering Sciences*, 17(1).
- Sarıkurt, T., ve Balıkçı, A. (2018). A Relative Capacity Estimation Method for Lithium Batteries Used in Electric Vehicle Applications. *Pamukkale University Journal of Engineering Sciences*.
- Polat, B. D., ve Keleş, Ö. (2018). Lityum İyon Pil Teknolojisi. *Türk Mühendis ve Mimarlar Odası Birliği Metalurji Mühendisleri Odası*.
- Sarıkurt, T., ve Balıkçı, A. (2017). Tam Elektrikli Araçlar İçin Özgün Bir Enerji Yönetim Sistemi Uygulaması. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32(2), 323-333.
- Durmuş, F. S., ve Kaymaz, H. (2020). Elektrikli Araç Şarj Yöntemleri. *Akıllı Ulaşım Sistemleri ve Uygulama Dergisi*, 3(2).
- Kaypmaz, T. C., ve Tuncay, R. N. (2010). Li-iyon Polimer Pillerde Sağlık Durumu Değerlendirmesi. *İTÜ Dergisi/D Mühendislik*, 9(1), 25-35.
- Kaysal, K., Hocaoğlu, F. O., ve Kaysal, A. (2021). Design and Experimental Implementation of Passive Battery Management Systems Using ARM-Based Microprocessors. *GU J Sci, Part C*, 9(1): 026-039.
- Demirkan, M. T., ve Doğrusöz, M. (2021). Piezoelektrik Malzemelerin Lityum İyon Batarya Anotlarında Katkı Olarak Kullanılması. *KSU J Eng Sci*, 24(4).
- Karadağ, T., ve Dikmen, İ. C. (2021). Yeni Nesil, Modüler ve Akıllı Batarya Yönetim Sistemi. *EJOSAT*.
- Moralı, U. (2020). Influence of Charge Conditions on Battery Dynamics of a Commercial Lithium-Ion Cell. *Hacettepe Journal of Biology & Chemistry*, 48(3), 203-210.
- Winter, M., ve Brodd, R. J. (2004). What are batteries, fuel cells, and supercapacitors? *Chemical Reviews*, 104(10), 4245–4269. DOI: 10.1021/cr020730k

- Li, H., ve Dahn, J. R. (2007). An in situ X-ray diffraction study of electrochemical reactions in Li-Si binary alloys. *Journal of the Electrochemical Society*, 154(3), A156. DOI: 10.1149/1.2409868
- Wu, H., Chan, G., Choi, J. W., Ryu, I., Yao, Y., McDowell, M. T., Lee, S. W., Jackson, A., Yang, Y., Hu, L., ve Cui, Y. (2012). Stable cycling of double-walled silicon nanotube battery anodes through solid-electrolyte interphase control. *Nature Nanotechnology*, 7(5), 310–315. DOI: 10.1038/nnano.2012.35
- Liu, N., Wu, H., McDowell, M. T., Yao, Y., Wang, C., ve Cui, Y. (2014). A yolk-shell design for stabilized and scalable Li-ion battery alloy anodes. *Nano Letters*, 12(6), 3315–3321. DOI: 10.1021/nl3014814
- Wang, G., Zhang, L., ve Zhang, J. (2011). A review of electrode materials for electrochemical supercapacitors. *Chemical Society Reviews*, 41(2), 797–828. DOI: 10.1039/C1CS15060J
- Chen, Z., ve Archer, L. A. (2014). Solid-state supercapacitors: A review of basic concepts, recent developments, and practical challenges. *Energy & Environmental Science*, 7(10), 3323–3333. DOI: 10.1039/C4EE01384G
- Goodenough, J. B., ve Park, K. S. (2013). The Li-Ion rechargeable battery: A perspective. *Journal of the American Chemical Society*, 135(4), 1167–1176. DOI: 10.1021/ja3091438
- Manthiram, A. (2017). An outlook on lithium ion battery technology. *Nature Communications*, 8(1), 1–9. DOI: 10.1038/ncomms15719
- Manthiram, A., Fu, Y., Chung, S. H., Zu, C., ve Su, Y. S. (2014). Rechargeable lithium-sulfur batteries. *Chemical Reviews*, 114(23), 11751–11787. DOI: 10.1021/cr500062v
- Bruce, P. G., Freunberger, S. A., Hardwick, L. J., ve Tarascon, J. M. (2012). Li–O₂ and Li–S batteries with high energy storage. *Nature Materials*, 11(1), 19–29. DOI: 10.1038/nmat3191
- Janek, J., ve Zeier, W. G. (2016). A solid future for battery development. *Nature Energy*, 1(9), 16141. DOI: 10.1038/nenergy.2016.141
- Zhang, Q., Uchaker, E., Candelaria, S. L., ve Cao, G. (2013). Nanomaterials for energy conversion and storage. *Chemical Society Reviews*, 42(7), 3127–3171. DOI: 10.1039/C2CS35323K
- Goodenough, J. B., ve Kim, Y. (2010). Challenges for rechargeable Li batteries. *Chemistry of Materials*, 22(3), 587–603. DOI: 10.1021/cm901452z
- Nitta, N., Wu, F., Lee, J. T., ve Yushin, G. (2015). Li-ion battery materials: Present and future. *Materials Today*, 18(5), 252–264. DOI: 10.1016/j.mattod.2014.10.040
- Zhao, Q., Liu, X., Stalin, S., Khan, K., ve Archer, L. A. (2020). Solid-state polymer electrolytes for high-energy lithium metal batteries. *Nature Energy*, 5(3), 291–298. DOI: 10.1038/s41560-020-0566-7
- Tarascon, J. M., ve Armand, M. (2001). Issues and challenges facing rechargeable lithium batteries. *Nature*, 414(6861), 359–367. DOI: 10.1038/35104644
- Zhang, W. J. (2011). A review of the electrochemical performance of alloy anodes for lithium-ion batteries. *Journal of Power Sources*, 196(1), 13–24. DOI: 10.1016/j.jpowsour.2010.07.020

Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.

Jordan, M. I., ve Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260. DOI: [10.1126/science.aaa8415](https://doi.org/10.1126/science.aaa8415)



ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı

Uyruğu

Doğum tarihi ve yeri

Medeni hali

Telefon

Faks

e-mail



Eğitim

Yüksek lisans	SBTÜ/ Savunma Teknolojileri	Devam ediyor
Lisans	CÜ / Elektrik Elektronik Mühendisliği	2016
Lise	Halil Rıfat Paşa Anadolu Lisesi	2012

İş Deneyimi

Yıl	Yer	Görev
2023-Halen	ÖZKA Teknoloji Müh. LTD. ŞTİ.	Şirket Yetkilisi
2020-2022	Eken Çağ Enerji	Mühendis

Yabancı Dil


İngilizce

Yayınlar

- IX. International Conference on Global Practice of Multidisciplinary Scientific Studies to be held on January 21-28, 2025 at CUBA.

Hobiler

Yüzme, Müzik, Dans



**SİVAS
BİLİM VE TEKNOLOJİ
ÜNİVERSİTESİ**

KÖKLERDEN GÖKLERE...