

PAPER DETAILS

TITLE: Batarya saglik durumunun makine öğrenmesi ile kestirimi

AUTHORS: Emine ÇAVUS,Ildris SANCAKTAR

PAGES: 601-610

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/2412841>



Batarya sağlık durumunun makine öğrenmesi ile kestirimi

Determining battery health with machine learning

Emine Çavuş^{1,*} , İdris Sancaktar² 

^{1,2} Ondokuz Mayıs Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, 55200, Samsun Türkiye

Öz

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

Anahtar kelimeler: Batarya sağlığı, k-En yakın komşu yöntemi, Rastgele orman regresyon yöntemi

1 Giriş

Lityum-iyon bataryalar, elektriksel enerjinin kimyasal tepkimeler ile depo edilmesi ve depo edilen enerjinin yine kimyasal tepkimeler ile elektrik enerjisine dönüşmesi için kullanılan enerji depolama birimleridir. Bir batarya hücresi temel olarak anot, katot ve elektrolit olmak üzere 3 bölümden oluşur [1]. Anot negatif elektrottur, dış devreye elektron verir ve burada oksidasyon tepkimesi oluşur. Katot pozitif elektrottur, dış devreden elektron alır ve burada redüksiyon tepkimesi oluşur. Elektrolit ise batarya içinde iyon iletimini sağlayan bölümdür. Lityum-iyon bataryalar cep telefonları, dizüstü bilgisayarlar, askeri ve havacılık elektroniği gibi birçok alanda yaygın olarak kullanılmaktadır [2-4]. Ayrıca elektrikli araçlar ve yenilenebilir enerji kaynaklarının yaygınlaşması da enerjinin depolanmasını zorunlu kılmaktadır [5, 6]. Yüksek enerji yoğunluğu, yüksek güç yoğunluğu, güvenli olması, uzun ömürlü olması ve düşük kendi kendine deşarj, Lityum-iyon bataryayı kurşun asit, Sodyum Sülfür ve diğer batarya türlerinden üstün kılan

Abstract

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

Keywords: Battery health, k-Nearest neighbor method, Random forest method regression method

ana özellikleridir [7]. Belirtilen avantajların yanında fosil yakıtların yakın zamanda tükenecek olmasından dolayı, Lityum-iyon bataryalar fazlaca ihtiyaç duyulacak olan enerji depolama için de gelecek vaat eden elemanlardır [8].

Lityum-iyon bataryaların elektriksel özellikleri, doğrusal ve düzgün olmayan şarj kapasitesi vb. rağmen önemli ölçüde iyileştirilmiştir [9]. Lityum-iyon bataryaların daha güvenli çalışabilmesi, tüm sistemi korumak ve enerjinin optimum kullanımını izlemek için batarya yönetim sistemi gereklidir [10]. Batarya yönetim sistemlerinin, batarya performansını ve ömrünü optimize edebilmesi için sağlık durumu (SOH) ve şarj durumu (SOC) gibi bataryaların önemli parametrelerinin takip edilmesi gerekmektedir [11-13]. Bataryaların aşırı şarj, deşarj, ısınma gibi nedenlerden dolayı kimyasal yapısı bozulmakta, sağlık durumları olumsuz etkilenmekte ve enerji depolama işlevini yitirmektedir.

Batarya sağlık durumunu belirlemek için literatürdeki yöntemler üç grup altında toplanabilir; doğrudan ölçüm yöntemi, model tabanlı yöntem ve veri tabanlı yöntemler

* Sorumlu yazar / Corresponding author, e-posta / e-mail: eminekose18@gmail.com (E. Çavuş)

Geliş / Recieved: 06.05.2022 Kabul / Accepted: 21.06.2022 Yayınlanma / Published: 18.07.2022

doi: 10.28948/ngumuh.1112985

[14-16]. Doğrudan ölçüm yöntemini kullanarak batarya sağlığını belirlemek için literatürde çalışmalar yapılmıştır [17-20]. Doğrudan ölçüm yönteminde bataryanın tamamen şarj ve deşarj esnasında batarya kapasitesi ölçülür [15]. Ayrıca sağlık durumunun belirlenebilmesi için batarya direncinin ölçülmesi gerekmektedir [21]. Temelinde basit olan bu yöntem özel laboratuvar şartları gerektirmesi gibi durumlardan dolayı uygulanabilirliği düşüktür. Model tabanlı yöntemini kullanarak batarya sağlığını belirlemek için literatürde birçok çalışma yapılmıştır [22-25]. Model tabanlı yöntemde, deşarj sırasında elde edilen bataryanın akım, gerilim vb. sinyalleri kullanılır [26]. Ayrıca ölçülen sinyallerin dışında sağlık durumunun belirlenmesi için batarya modeline (elektro-kimyasal ve elektriksel model) de ihtiyaç vardır. Ancak kullanılan batarya modellerinde bulunan kısmi diferansiyel denklemlerin çözümünün zor olması nedeniyle uygulanması zordur [27]. Veri tabanlı yöntemler, yalnızca bataryanın ne kadar ömrünün kaldığı ile değil ne kadar süre kullanıldığı ile ilgilenir. Sağlık durumunu belirlemek için kullanılan veri tabanlı yöntemler arasında; bulanık mantık [28], uzay vektör makinesi [29-31], zaman serisi [32], akıllı algoritmalar (genetik algoritma, yapay sinir ağları, en küçük kare polinom regresyonu ve parçacık filtreleri) [33-39] sayılabilir. Bu yöntemlerde ölçüm sonucu elde edilen veriler ile sistem sağlığı arasında karmaşık bağlantılar oluşturulur. Bu şekilde batarya ömründeki değişiklikler tespit edilir [18, 40, 41]. Bu yöntemin doğruluğu, veri kümesinin boyutuna bağlıdır, veri kümesi ne kadar büyük olursa sağlık kestirim işlemi o kadar başarılı olur [42]. Bahsedilen yöntemler yüksek verimlilik sağlamasına rağmen, hesaplama sürecinde ön işleme aşamaları bakımından oldukça masraflıdır. Bataryaya ait farklı ölçümlerde oluşan belirsizliklerin birleşmesi, dikkatli bir şekilde düzenlenmezse, tahmin işlemi oldukça başarısız olur.

Bu çalışmada veri tabanlı batarya sağlık durumu belirlemesi makine öğrenmesi ile gerçekleştirilmiştir. Bu amaçla bataryanın deşarj olması durumunda elde edilen akım, kapasite azalması, gerilim gibi değerler kullanılmıştır. Batarya sağlık durumu belirleme sürecinde deşarj esnasında elde edilen gerilim değerleri doğrudan kullanılmıştır. Bu çalışmada ise diğer çalışmalardan farklı olarak, deşarj gerilim grafiğindeki diz-dirsek noktaları belirlenerek gerilimdeki değişimler daha ayrıntılı olarak ele alınmıştır. Bunun yanı sıra diz-dirsek noktalarındaki değişimlerin zaman farkı, deşarj eğrisi üzerindeki en yüksek ve en düşük gerilim değerleri ve aralarındaki zaman farkı da hesaba katılmıştır. Belirlenen giriş verileri kullanılarak batarya sağlık durumunun belirlenebilmesi için iki farklı makine öğrenmesi algoritması oluşturulmuştur. Tasarlanan ilk algoritma k-En Yakın Komşu yöntemi kullanılarak gerçekleştirilmiştir. Kullanılan diğer yöntem ise Rastgele Orman regresyon yöntemidir. Bu çalışmada CALCE'nin internet ortamında açık olarak yayınladığı batarya verilerinden yararlanılmıştır [43]. CALCE'den alınan 12 adet bataryaya ait veriler (her bir bataryaya ait 50 şarj-deşarj döngüsü), çalışma hedefleri doğrultusunda düzenlenmiştir. Burada, tasarlanan sistemin başarısını değerlendirebilmek için iki farklı çalışma gerçekleştirilmiştir.


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

Her iki değerlendirme sonucunda da tasarlanan sistemin başarılı olduğu görüldü. İki yöntem birbiri ile karşılaştırıldığı zaman K-En Yakın Komşu yöntemi, Rastgele Orman Regresyon yönteminin gerisinde kalmıştır.

2 Materyal ve metot

2.1 Diz-dirsek noktalarının belirlenmesi

Batarya sağlığının makine öğrenmesi vb. yöntemlerle sağlıklı bir şekilde belirlenebilmesi için bataryaya ait verilerden, batarya sağlığını temsil edecek özelliklerin çıkartılması önemlidir [44]. Bu amaçla kullanılabilecek en önemli verilerden birisi batarya deşarj sürecine ait gerilim verileridir [45]. Bu çalışmada, kullanılan bataryaların sağlık durumunu belirlemek için deşarj eğrilerinin diz-dirsek noktalarından faydalanılmıştır. Diz (M) ve dirsek (L) noktaları dışında deşarj eğrisi üzerindeki en düşük (N) ve en yüksek (K) gerilim değeri noktaları da kullanılmıştır. Bir bataryaya ait genel deşarj eğrisi ve eğri üstündeki maksimum, minimum ve diz-dirsek noktaları Şekil 1'de görülmektedir. Şekil 1'de deşarj sürecinde bataryanın en yüksek ve en düşük gerilime sahip olduğu noktalar sırasıyla K ve N'dir. Ayrıca Dirsek noktası L, diz noktası ise M noktası olarak gösterilmiştir.



Şekil 1. Batarya deşarj eğrisi

Şekil 1'de verilen diz-dirsek noktalarının hesabı iki aşamadan oluşmaktadır [45].

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

L ve M noktalarını belirlemek için gerekli olan iki eğri arası en uzak noktayı belirlemek amacıyla Şekil 1'de görüldüğü gibi, K-N arasındaki doğru A ve K noktası ile deşarj eğrisi üzerindeki herhangi bir noktaya doğru olan doğru ise B ile ifade edilebilir. Bu durumda, n adet noktadan oluşan deşarj eğrisi üzerindeki her bir nokta için aşağıdaki eşitlik elde edilir.

$$B_i^{dik} = B_i \sin \theta \quad (1)$$

θ değeri ise aşağıda verildiği gibi skaler çarpım yoluyla bulunabilir.

$$\theta_i = \cos^{-1}\left(\frac{A \cdot B_i}{|A||B_i|}\right) \quad (2)$$

Bu durumda M noktası ise aşağıdaki gibi bulunabilir.

$$M = \max(B_1^{dik}, B_2^{dik}, B_3^{dik} \dots B_n^{dik}) \quad (3)$$

Şekil 1’de verilen noktalar belirlendikten sonra, noktalar arası ilişkiler bataryanın sağlık durumunu ile ilişkilendirilebilir. Bu nedenle makine öğrenmesi yönteminde kullanılmak üzere gerekli olan özellik çıkartma işleminde K - L , L - M ve M - N noktaları arasındaki öklit uzunlukları göz önüne alınmıştır. Belirtilen üç öklit uzunluğunun batarya sağlığı ile ilişkisi incelendiği zaman, diz-dirsek noktaları (L - M noktaları) arası öklit uzaklığı sağlıkla doğrudan ilişkilidir [45]. Bu uzunluk değeri ne kadar yüksek ise batarya o kadar sağlıklıdır. Diğer iki öklit uzunluğunun (K - L ve M - N arası) batarya sağlığına etkisi incelendiği zaman, M - N arası öklit uzunluğunun batarya sağlığına etkisi L - M uzunluğu ile paralel olduğu görülmektedir. Bu nedenle gereksiz veri karmaşasından kurtulmak için M - N uzunluğu göz ardı edilmiştir ve L - M öklit uzunluğu ile beraber K - L öklit uzunluğu sağlık durumu belirlemek için özellik olarak seçilmiştir.

2.2 k-En yakın komşu yöntemi

k -En Yakın Komşu yöntemi, ilk olarak 1951 yılında Fix ve Hodges tarafından örüntü (model) tanımada kullanılmak üzere önerilmiş ve daha sonra 1967 yılında Cover ve Hart tarafından geliştirilmiştir [46]. Bu yöntem hem sınıflandırma hem de regresyon problemlerinde kullanılabilir. Ayrıca bu yöntem gözlemlerin yapılacağı sınıfı ve en yakın komşuyu belirlemek için k komşu değerini kullanan bir Denetimli Makine Öğrenimi Algoritmasıdır. Diğer Denetimli Öğrenme Algoritmalarından farklı olarak geleneksel eğitim aşaması ile öğrenme işlemi yerine eğitim verilerini ezberlemesidir. Bu özelliği de tembel bir öğrenme türü olduğunu göstermektedir. Karmaşık hedef fonksiyonlarını bilgi kaybetmeden hızlı bir şekilde öğrenebilen en basit ve en çok kullanılan yöntemlerden biridir [47].

k -En Yakın Komşular yönteminin amacı, sınıfı belli olmayan bir verinin diğer verilere uzaklığının hesaplanarak hangi veriye/sınıfa yakın olduğunu belirlemektir. Sınıflandırma problemlerinde bu tahmin en yakın komşular arasında çoğunluğa bakılarak belirlenirken, regresyon problemlerinde en yakın 40 komşunun hesaplanan yakınlık derecelerinin sayısal değerlerinin ortalamasıdır. Bu şekilde yeni örneğin sınıfı belirlenir [48].


k -En Yakın Komşular yönteminin başarısı modele ait üç parametrenin doğru belirlenmesine bağlıdır. Bu parametreler en yakın komşu sayısı, ağırlık vektörü α ve uzaklık ölçüsüdür [49].

Bu yöntemin uygulanmasının ilk aşaması en yakın komşu sayısı k değerinin belirlenmesidir. k değerinin belirlenmesi aşamasında eşdeğer bias ve varyans ile belirlenir. k -En Yakın Komşular yönteminde en uygun k değerini belirlemek için çapraz doğrulama yöntemi oldukça başarılıdır. Çapraz doğrulama ile bağımsız bir veri kümesi geriye dönük kullanarak en uygun k değeri belirlenir. k değeri çoğunlukla 3 ile 10 arasında seçilebilir [50, 51]. Yöntemin ikinci aşaması, örnek veri setine eklenecek yeni gözlemin belirlenmesi ve mevcut veriler ile yeni gözlem arasındaki tüm mesafelerin hesaplanmasıdır. Komşular arası mesafeleri hesaplamak için kullanılabilen birçok yöntem vardır. Bu yöntemler içinde en çok kullanılanlar, Öklid uzaklığı ve Manhattan, Minowski ve Hamming yöntemleri sayılabilir. Sınıflandırılabilen değişkenler söz konusu olduğu zaman Hamming, sürekli değişkenler söz konusu olduğunda ise diğer üç fonksiyon kullanılır [52]. Son aşamada ise yöntemde ait değişkenler belirlendikten sonra, tahmin edilecek değer olan x değeri k ve en yakın komşular kümesi N_i ’nin fonksiyonu olarak aşağıdaki gibi yazılabilir (James ve diğerleri, 2013).

$$f(x) = \frac{1}{k} \sum_i N_i \quad (4)$$

2.3 Rastgele orman regresyon yöntemi

Rastgele Orman Regresyonu, uyarılma (regresyon) için kolektif öğrenme yöntemini kullanan denetimli bir öğrenme algoritmasıdır. Kolektif öğrenme yöntemi, birden fazla makine öğrenmesi algoritmasından gelen tahminleri birleştirerek çoklu karar verme algoritmasına sahip orman oluşturan, tek bir modele dayalı herhangi bir yöntemle göre doğruluğu daha yüksek bir tahmin etme yöntemidir. Rastgele Orman Regresyonu hem sınıflandırma hem de uyarılma problemleri için kullanılabilir. Bu yöntem ile yüksek boyutlu verilerin işlenebilmesinin yanında eksik değer ve aşırı öğrenme gibi problemlere çözüm üretir [53]. Şekil 2 Rastgele Orman Regresyonu çalışma biçimini göstermek için örnek olarak verilebilir.



Şekil 2. Rastgele Orman Regresyonu örnek akış şeması

Rastgele Orman Regresyon akış şeması incelendiği zaman, ağaç sayısı ($N_{\text{ağaç}}$) ve her bir ağaca ait düğüm sayısı ($N_{\text{düğüm}}$) olmak üzere, yönteme ait iki parametrenin belirlenmesi gerekmektedir. Karar verme ormanı oluşturulurken, kullanılacak veri setinden elde edilen eğitim veri setinin %70'i karar ağacını oluşturmak için kullanılır. Eğitim veri setinden kalan %30'luk bölümü ise geliştirilen yöntemin hata oranını hesaplamak için kullanılır [54].

Geleneksel bir karar ağacı yöntemi olan Sınıflandırma ve Regresyon Ağacı (SVRA) Algoritması kuralları, belirlenen değişkenin hangi değerine bağlı olarak ağacın dallanması gerektiğini belirlemek için kullanılır [55]. Bu kurallar, sınıflandırma ağaçları için gini indeksi olarak adlandırılır. Ancak bu işlem Rastgele Orman Regresyon yönteminde, gini indeks kriterine göre değil, elde edilen iki düğüm için tahmin edilen toplam varyansın minimize eden 'karesel artıkları azaltma algoritması'na göre yapılmaktadır [56]. Her düğümde en iyi dallanmayı sağlayacak değişken rastgele seçilir. Rastgele seçimin amacı, ağaçlar arasındaki korelasyonu en aza indirmek ve hata oranını azaltmaktır. Hata oranındaki azalma, algoritmanın etkinliğini artırır ve geliştirilen algoritmayı aşırı öğrenme durumuna karşı korur.

Karar verme ormanında oluşturulan her bir ağaç için, veri kümesinde bulunan farklı veri kümeleri kullanılır. Her ağacın eğitilmesinde kullanılan veri kümeleri birbirinden farklıdır. Böylece karar verme ormanında ağaç oluşturma sürecinde, her ağaç bağımsız olarak diğerlerinden etkilenmeden oluşturulur [57]. Oluşturulan tüm ağaçlar, ayrı ayrı test işlemine tabi tutulur ve her bir ağaç için hata oranı hesaplanır. Hesaplanan hata oranlarının ortalaması alınarak ortalama hata oranı hesaplanır [54]. Bu hata, her ağacın bireysel gücünün yanı sıra (her ağacın kendi hata oranı) ve ormandaki ağaçların aralarındaki uyuma da bağlıdır. Rastgele Orman Regresyon yönteminin en önemli özelliklerinden biri de kendi hata oranını hesaplayabilmesidir [55].

3 Batarya sağlık durumunun kestirilmesi

Bataryaların sağlık durumu kestirimi için veri tabanlı yöntemler, karmaşıklıktan uzak bir yapısının olması, deneysel çalışmalara uygulanabilir olması ve yüksek doğruluklu sonuçlar vermeleri nedeniyle son zamanlarda oldukça fazla kullanılmaktadır. Uygulamalı çalışmalarda bataryaların akım, gerilim, kapasite ve kapasite azalması gibi veriler doğrudan elde edilebilmektedir. Bu nedenle doğrudan elde edilebilen bu veriler ile veri tabanlı yöntemler kullanılarak batarya sağlık durumu kestirimi yapılması mümkündür [58].

Bu çalışmada veri tabanlı batarya sağlık durumu belirlemesi makine öğrenmesi ile gerçekleştirilmiştir. Bu amaçla öncelikle makine öğrenmesi algoritmasında kullanılmak üzere giriş verileri belirlenmiştir. Çalışmada gerekli olan batarya verileri, CALCE'nin internet ortamında açık olarak yayınladığı verilerinden elde edilmiştir. CALCE'den alınan 12 adet farklı batarya verisi kullanılmıştır. Her bir bataryaya ait alınan veriler toplam 50 şarj-deşarj döngüsünden oluşmaktadır. Kullanılan bataryalar ve özellikleri Tablo 1'de verilmiştir.


Bataryaların kapasite azalma grafikleri incelendiği zaman bazı verilerde bozukluk olduğu görülmüştür. Ölçüm işleminden kaynaklanan ve normalde mevcut olması imkansız olan bu durumların gerçekleştirilecek çalışmanın başarısını olumsuz etkilememesi için, bataryaların kapasite azalma verileri filtre kullanılarak düzenlenmiştir. Filtreleme işlemi sadece hatalı olan bölümlere uygulanmıştır. Bunun için öncelikle tüm veri yazılımsal analiz edilmiş ve anormal değerler belirlenmiştir. Filtreleme işlemi her bir adımdaki kapasite azalımı bir önceki durumdaki kapasite değeri ile karşılaştırılmıştır. Eğer iki kapasite azalma miktarı arasındaki değişim eşik değerinin üstünde ise filtreleme gerçekleştirilmiş ve bir önceki kapasite azalma miktarının %95'i kadar azalma olduğu varsayılmıştır.

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

Tablo 1. Kullanılan bataryalar ve özellikleri

Batarya İsmi	Akım (A)	Kapasite (Ah)
CS2 33	0.55	1.1
CS2 34	0.55	1.1
CS2 35	1.1	1.1
CS2 36	1.1	1.1
CS2 37	1.1	1.1
CS2 38	1.1	1.1
CX2 33	0.675	1.35
CX2 34	1.35	1.35
CX2 35	0.675	1.35
CX2 36	1.35	1.35
CX2 37	1.35	1.35
CX2 38	1.35	1.35

Belirlenen giriş verileri (bataryadeşarj sürecinden elde edilen akım, gerilim, kapasite azalımı, gerilim eğrisi dizdirsek noktaları ve eğrileri) kullanılarak batarya sağlık durumunun belirlenebilmesi için iki farklı makine öğrenmesi algoritması oluşturulmuştur. Kullanılan ilk algoritma k-En Yakın Komşu algoritması diğer yöntem ise Rastgele Orman Regresyon yöntemidir. Verilerin düzenlenmesi, işlenmesi, makine öğrenmesi algoritması vb. tüm işlemler PYTHON programlama dili kullanılarak gerçekleştirilmiştir. PYTHON programlama dilinde hazırlanan algoritmanın tüm çalışmasını anlatan blok şema Şekil 3'te verilmiştir.



Şekil 3. Batarya sağlık durumu belirleme akış şeması

4 Sonuçlar

Şekil 3'te verilen akış şemasına uygun olarak batarya sağlık durumu belirleme yazılımı hem k-En Yakın Komşu hem de Rastgele Orman Regresyonu yöntemi için PYTHON programlama dili kullanılarak hazırlanmıştır. Program çıkışında, herhangi bir bataryaya ait giriş verilerine karşılık, bu verilerin bataryanın hangi çevriminde elde edildiği tahmin edilmektedir. Tasarlanan algoritmaların başarısı iki farklı senaryo ile test edilmiştir. Gerçekleştirilen senaryolar aşağıdaki gibidir.

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


İlk senaryo ile eğitilen sistem, tüm bataryalara ait bazı verilere sahip olmuştur. Böylece test edilecek bataryalara ait güçlü bir eğitim ağı oluşturulabilmiştir. Eğitim verileri ile eğitilen sisteme test verileri uygulanmış. k-En Yakın Komşu ve Rastgele Orman Regresyon yöntemleri için elde edilen sonuçlar Şekil 4'te verilmiştir. Şekil 4'te mavi sütunlar hesaplanması gereken batarya çevrim sayısı, kırmızı sütunlar ise hesaplanan çevrim sayısıdır.

Gerçekleştirilen sistemin toplam başarısı ortalama mutlak hata (MAE) hesabı kullanılarak değerlendirilmiştir. MAE hesabı aşağıda verilmiştir, burada $C_{gerçek}$ gerçek çevrim sayısı, C_{hesap} hesaplanan çevrim sayısıdır. İlk senaryoya ait MAE değeri ve sistemin doğruluk değeri Tablo 2'de verilmiştir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |C_{gerçek} - C_{hesap}| \cdot \%100 \quad (5)$$

İkinci senaryoda 12 bataryadan 11 tanesi eğitim amacıyla kullanılmıştır. 1 batarya ise test amacıyla kullanılmıştır. Burada 12 bataryanın hepsi için bu durum tekrarlanmıştır. Bu şekilde, tasarlanan sağlık durumu belirleme algoritması,

hiçbir verisine sahip olmadığı bir bataryanın sağlık durumunu belirlemesi istenmiştir. Böylece oluşturulan algoritmaların, hiçbir bilgisi olmadığı (eğitim verilerinde bulunmayan) bir batarya için tahmin performansı değerlendirilmiştir. 12 bataryanın her birinin test grubu olduğu (dolayısıyla kalan 11 batarya eğitim verisi olarak kullanılmıştır) durum için elde edilen sonuçlar k-En Yakın Komşu ve Rastgele Orman Regresyon yöntemleri için sırasıyla Şekil 5 ve 6'da verilmiştir.




Şekil 4. Senaryo 1 için test ve tahmin edilen değerleri (a) k-En Yakın Komşu yöntemi (b) Rastgele Orman Regresyon yöntemi

Tablo 2. Senaryo 1 için bataryalara ait MAE ve doğruluk oranları


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

Tablo 3. Senaryo 2 için bataryalara ait MAE ve doğruluk oranları

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



Şekil 5. k- En Yakın Komşu yöntemi için test ve tahmin değerleri (a) CS2 33 (b) CS2 34 (c) CS2 35 (d) CS2 36 (e) CS2 37 (f) CS2 38 (g) CX2 33 (h) CX2 34 (i) CX2 35 (i) CX2 36 (j) CX2 37 (k) CX2 38



Şekil 6. Rastgele Orman Regresyon yöntemi için test ve tahmin değerleri (a) CS2 33 (b) CS2 34 (c) CS2 35 (d) CS2 36 (e) CS2 37 (f) CS2 38 (g) CX2 33 (h) CX2 34 (i) CX2 35 (j) CX2 36 (k) CX2 37 (l) CX2 38

Gerçekleştirilen sistemin toplam başarısı ortalama mutlak hata (MAE) hesabı kullanılarak değerlendirilmiştir. Her bir bataryaya ait MAE hesabı sonucu ve doğruluk oranı **Tablo 3**'te verilmiştir.

5 Değerlendirmeler

Bu çalışmada batarya sağlık durumunun belirlenmesi için makine öğrenmesi yöntemi kullanılmıştır. Bu amaçla bataryanın deşarj olması durumunda elde edilen akım, kapasite azalması, gerilim gibi değerler kullanılmıştır. Literatürdeki diğer yöntemlerden farklı olarak, deşarj gerilim grafiğindeki diz-dirsek noktaları belirlenerek gerilimdeki değişimler daha ayrıntılı olarak dikkate alınmıştır. Belirlenen giriş verileri kullanılarak batarya sağlık durumunun belirlenebilmesi için iki farklı makine öğrenmesi algoritması (k-En Yakın Komşu yöntemi ve Rastgele Orman Regresyon yöntemi) oluşturulmuştur. Bu çalışmada CALCE'nin internet ortamında açık olarak yayınladığı batarya verilerinden yararlanılmıştır. CALCE'den alınan 12 adet bataryaya ait veriler (her bir bataryaya ait 50 şarj-deşarj döngüsü), çalışma hedefleri doğrultusunda düzenlenmiştir. Gerçekleştirilen sağlık durumu belirleme yazılımı için PYTHON dili kullanılmıştır. Batarya sağlık durumunun belirlenmesi için kullanılan yöntemlerin başarısı iki farklı senaryo ile değerlendirilmiştir. İlk senaryo tüm batarya verilerinin karışık olarak değerlendirilip, tüm bataryalara ait verilerden oluşan eğitim ve test verilerinin oluşturulması ile gerçekleştirilmiştir. **Şekil 4** ve **Tablo 2**'den anlaşıldığı üzere kullanılan her iki yöntem de ilk senaryoda başarılı olmuştur. Ancak iki yöntem birbiri ile karşılaştırıldığı zaman Rastgele Orman Regresyon yönteminin daha başarılı olduğu görülmüştür. Diğer senaryo ise elde bulunan 12 bataryadan 11'ini eğitim verisini kalan 1 bataryanın ise test verisini oluşturduğu durumdur. Burada 12 bataryanın her biri ayrı ayrı test verisi olarak değerlendirilmiştir. **Şekil 5**, **6** ve **Tablo 3** değerlendirildiği zaman k-En Yakın Komşu yönteminin sadece bir batarya için daha başarılı olmuştur. Diğer bataryalarda ise Rastgele Orman Regresyon yöntemi daha başarılı olmuştur.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %9

Kaynaklar

- [1] D. Linden and T. Reddy, Handbook of Batteries, Third Edition, McGraw-Hill. 2002.
- [2] Y. Zhang, R. Xiong, H. He and M. G. Pecht, Long Short-Term Memory Recurrent Neural Network for Remaining Useful Life Prediction of Lithium-Ion Batteries, IEEE Transactions on Vehicular Technology, 67 (7), 5695-5705, 2018. <http://doi.org/10.1109/TVT.2018.2805189>.
- [3] Y. Song, D. Liu, C. Yang, Y. Peng, Data-driven hybrid remaining useful life estimation approach for spacecraft lithium-ion battery, Microelectronics Reliability, 75, 142-153, 2017. <http://doi.org/10.1016/j.microrel.2017.06.045>.

- [4] R. Xiong, Y. Zhang, H. He, X. Zhou and M. G. Pecht, A Double-Scale, Particle-Filtering, Energy State Prediction Algorithm for Lithium-Ion Batteries, IEEE Transactions on Industrial Electronics, 65 (2), 1526-1538, 2018. <http://doi.org/10.1109/TIE.2017.2733475>.
- [5] C. Unterrieder, R. Priewasser, S. Marsili and M. Huemer, Battery State Estimation Using Mixed Kalman/Hinfinity, Adaptive Luenberger and Sliding Mode Observer, IEEE Vehicle Power and Propulsion Conference (VPPC), pp. 1-6, Beijing, China, 2013.
- [6] D. Saji, P. S. Babu and K. Ilango, SoC Estimation of Lithium Ion Battery Using Combined Coulomb Counting and Fuzzy Logic Method, 4th International Conference on Recent Trends on Electronics, Information, Communication & Technology (RTEICT), pp. 948-952, Bangalore, India, 2019.
- [7] X. Hu, C. Zou, C. Zhang and Y. Li, Technological Developments in Batteries: A Survey of Principal Roles, Types, and Management Needs, IEEE Power and Energy Magazine, 15 (5), 20-31, 2017. <http://doi.org/10.1109/MPE.2017.2708812>.
- [8] M. A. Hannan, M. M. Hoque, S. E. Peng and M. N. Uddin, Lithium-Ion Battery Charge Equalization Algorithm for Electric Vehicle Applications, IEEE Transactions on Industry Applications, 53 (3), 2541-2549, 2017. <http://doi.org/10.1109/TIA.2017.2672674>.
- [9] T. Kim, W. Song, D. Son, L.K. Ono, and Y. Qi, Lithium-ion batteries: outlook on present, future, and hybridized technologies. Journal of Materials Chemistry A., Lithium-ion batteries: outlook on present, future, and hybridized technologies. Journal of materials chemistry A. 7 (7), 2942-2964, 2019. <http://doi.org/10.1039/C8TA10513H>
- [10] R. Xiong, J. Cao, Q. Yu, Reinforcement learning-based real-time power management for hybrid energy storage system in the plug-in hybrid electric vehicle, Applied energy, 211, 538-548, 2017. <http://doi.org/10.1016/j.apenergy.2017.11.072>.
- [11] C. Zou, C. Manzie and D. Nešić, Model Predictive Control for Lithium-Ion Battery Optimal Charging, IEEE/ASME Transactions on Mechatronics, 23 (2), 947-957, 2018. <http://doi.org/10.1109/TMECH.2018.2798930>.
- [12] H. Ren, Y. Zhao, S. Chen, T. Wang, Design and implementation of a battery management system with active charge balance based on the SOC and SOH online estimation, Energy, 166, 908-917, 2019. <http://doi.org/10.1016/j.energy.2018.10.133>.
- [13] X. Tang, Y. Wang, C. Zou, K. Yao, Y. Xia, A novel framework for Lithium-ion battery modeling considering uncertainties of temperature and aging, Energy conversion and management, 80, 162-170, 2019. <http://doi.org/10.1016/j.enconman.2018.10.082>.
- [14] M. Bercibar, I. Gandiaga, I. Villarreal, N. Omar, J. Van Mier, Critical review of state of health estimation methods of Li-ion batteries for real applications, Renewable and Sustainable Energy Reviews, 56, 572-587, <http://doi.org/doi.org/10.1016/j.rser.2015.11.042>.

- [15] X. Hu, J. Jiang, D. Cao and B. Egardt, Battery Health Prognosis for Electric Vehicles Using Sample Entropy and Sparse Bayesian Predictive Modeling, IEEE Transactions on Industrial Electronics, 63 (4), 2645-2656, 2016. <http://doi.org/10.1109/TIE.2015.2461523>.
- [16] L. Ungurean, G. Cârstoiu, M. V. Micea, Battery state of health estimation: a structured review of models, methods and commercial devices, International Journal of Energy Research, 41 (2), 151-181, 2016. <http://doi.org/10.1002/er.3598>.
- [17] S. Zhang, X. Guo, X. Dou, X. Zhang, A rapid online calculation method for state of health of lithium-ion battery based on coulomb counting method and differential voltage analysis. Journal of Power Sources, 479, 228740, 2020. <http://doi.org/10.1016/j.jpowsour.2020.228740>.
- [18] J. Yu, Health Degradation Detection and Monitoring of Lithium-Ion Battery Based on Adaptive Learning Method, IEEE Transactions on Instrumentation and Measurement, 63 (7), 1709-1721, 2014. <http://doi.org/10.1109/TIM.2013.2293234>.
- [19] J. S. Goud, K. R. and B. Singh, An Online Method of Estimating State of Health of a Li-Ion Battery, in IEEE Transactions on Energy Conversion, 36 (1), 111-119, 2021. <http://doi.org/10.1109/TEC.2020.3008937>.
- [20] Z. Wang, C. Yuan and X. Li, Lithium Battery State-of-Health Estimation via Differential Thermal Voltammetry With Gaussian Process Regression, IEEE Transactions on Transportation Electrification, 7(1), 16-25, 2021, <http://doi.org/10.1109/TTE.2020.3028784>.
- [21] J. Bi, T. Zhang, H. Yu, Y. Kang, State-of-health estimation of lithium-ion battery packs in electric vehicles based on genetic resampling particle filter, Applied Energy, 182, 558-568, 2016. <http://doi.org/10.1016/j.apenergy.2016.08.138>.
- [22] A. Allam, S. Onori, S. Marelli and C. Taborelli, Battery Health Management System for Automotive Applications: A retroactivity-based aging propagation study, American Control Conference (ACC), pp. 703-716, 2015.
- [23] G. Sierra, M. Orchard, K. Goebel, C. Kulkarni, Battery health management for small-size rotary-wing electric unmanned aerial vehicles: An efficient approach for constrained computing platforms, Reliability Engineering & System Safety, 182, 166-178, 2018. <http://doi.org/10.1016/j.res.2018.04.030>.
- [24] J. Yu, State-of-Health Monitoring and Prediction of Lithium-Ion Battery Using Probabilistic Indication and State-Space Model, IEEE Transactions on Instrumentation and Measurement, 64 (11), 2937-2949, 2015. <http://doi.org/10.1109/TIM.2015.2444237>.
- [25] Y. Gao, K. Liu, C. Zhu, X. Zhang and D. Zhang, Co-Estimation of State-of-Charge and State-of-Health for Lithium-Ion Batteries Using an Enhanced Electrochemical Model, IEEE Transactions on Industrial Electronics, 69 (3), 2684-2696, 2022. <http://doi.org/10.1109/TIE.2021.3066946>.
- [26] Z. Ma, R. Yang, Z. Wang, A novel data-model fusion state-of-health estimation approach for lithium-ion batteries, Applied energy, 237, 836-847, 2018. <http://doi.org/10.1016/j.apenergy.2018.12.071>.
- [27] G. You, S. Park, D. Oh, Oh, Real-time state-of-health estimation for electric vehicle batteries: A data-driven approach, Applied energy, 176: 92-103, 2016. <http://doi.org/10.1016/j.apenergy.2016.05.051>.
- [28] K.M. Tsang, W.L. Chan, Chan, State of health detection for Lithium ion batteries in photovoltaic system, Energy conversion and management, 65, 7-12, 2012. <http://doi.org/10.1016/j.enconman.2012.07.006>.
- [29] X. Shu, G. Li, Y. Zhang, J. Shen, Z. Chen, Y. Liu, Online diagnosis of state of health for lithium-ion batteries based on short-term charging profiles, Journal of Power Sources, 471, 228478, 2020. <http://doi.org/10.1016/j.jpowsour.2020.228478>.
- [30] X. Feng, C. Weng, X. He, X. Han, L. Lu, and D. Ren, Online State-of-Health Estimation for Li-Ion Battery Using Partial Charging Segment Based on Support Vector Machine, IEEE Transactions on Vehicular Technology, 68, 8583-8592, 2019. <http://doi.org/10.1109/TVT.2019.2927120>.
- [31] C. Weng, J. Sun and H. Peng, Model Parametrization and Adaptation Based on the Invariance of Support Vectors With Applications to Battery State-of-Health Monitoring, IEEE Transactions on Vehicular Technology, 64 (9), 3908-3917, 2015. <http://doi.org/10.1109/TVT.2014.2364554>.
- [32] C.P. Lin, J. C., F. Yang, M. H. Ling, K. L. Tsui, S.J. Bae, Battery state of health modeling and remaining useful life prediction through time series model, Applied Energy, 275, 115338, <http://doi.org/10.1016/j.apenergy.2020.115338>.
- [33] Li, Y., et al., State-of-health estimation of lithium-ion batteries based on semi-supervised transfer component analysis, Applied Energy, 277, 115504, 2020. <http://doi.org/10.1016/j.apenergy.2020.115504>.
- [34] Y. Li, H. Sheng, Y. Cheng, D. I. Stroe, R. Teodorescu, Novel battery state-of-health online estimation method using multiple health indicators and an extreme learning machine. Energy, 160, 466-477, 2020. <http://doi.org/10.1016/j.apenergy.2020.115504>.
- [35] P. Shen, M. Ouyang, L. Lu, J. Li and X. Feng, The Co-estimation of State of Charge, State of Health, and State of Function for Lithium-Ion Batteries in Electric Vehicles, IEEE Transactions on Vehicular Technology, 67 (1), 92-103, 2018. <http://doi.org/10.1109/TVT.2017.2751613>.
- [36] X. Hu, H. Yuan, C. Zou, Z. Li and L. Zhang, Co-Estimation of State of Charge and State of Health for Lithium-Ion Batteries Based on Fractional-Order Calculus, IEEE Transactions on Vehicular Technology, 67 (11), 10319-10329, 2018. <http://doi.org/10.1109/TVT.2018.2865664>.
- [37] D. Liu, X. Yin, Y. Song, W. Liu and Y. Peng, An On-Line State of Health Estimation of Lithium-Ion Battery Using Unscented Particle Filter, IEEE Access, 6, 40990-41001, 2018. <http://doi.org/10.1109/ACCESS.2018.2854224>.

- [38] H. Chaoui and C. C. Ibe-Ekeocha, State of Charge and State of Health Estimation for Lithium Batteries Using Recurrent Neural Networks, IEEE Transactions on Vehicular Technology, 66 (10), 8773-8783, 2017. <http://doi.org/10.1109/TVT.2017.2715333>.
- [39] N. Khan, F. U. M. Ullah, Afnan, A. Ullah, M. Y. Lee and S. W. Baik, Batteries State of Health Estimation via Efficient Neural Networks With Multiple Channel Charging Profiles, IEEE Access, 9, 7797-7813, 2021. <http://doi.org/10.1109/ACCESS.2020.3047732>.
- [40] P. E. Pascoe and A. H. Anbuky, Standby power system VRLA battery reserve life estimation scheme, IEEE Transactions on Energy Conversion, 20 (4), 887-895, 2005. <http://doi.org/10.1109/TEC.2005.853749>.
- [41] K. Goebel, B. Saha, and A. Saxena, A comparison of three data-driven techniques for prognostics, 62nd Meeting of the Society for Machinery Failure Prevention Technology (MFPT), pp. 119-131, Virginia Beach, VA, 2008
- [42] J. Wu, Y. Wang, X. Zhang, Z. Chen, A novel state of health estimation method of Li-ion battery using group method of data handling, Journal of Power Sources, 327, 457-464, 2016. <http://doi.org/10.1016/j.jpowsour.2016.07.065>.
- [43] Group, C.B. <https://web.calce.umd.edu/batteries/data.Htm#>, Erişim Zamanı:12.05.2021.
- [44] D. A. Pola et al., Particle-Filtering-Based Discharge Time Prognosis for Lithium-Ion Batteries With a Statistical Characterization of Use Profiles, IEEE Transactions on Reliability, 64 (2), 710-720, 2015. <http://doi.org/10.1109/TR.2014.2385069>.
- [45] S. S. Sheikh, M. Anjum, M. A. Khan, S. A. Hassan, H. A. Khalid, A. Gastli, L. A. Ben-Brahim, Battery Health Monitoring Method Using Machine Learning: A Data-Driven Approach, Energies 13, 3658. <https://doi.org/10.3390/en13143658>
- [46] S. Elasan, Veri Madenciliğinde Farklı Karar Ağaçları ve K-En Yakın Komşuluk Yöntemlerinin İncelenmesi: Kadın Hastalıkları ve Doğum Verisinde Bir Uygulama. Doktora Tezi, Van Yüzüncü Yıl Üniversitesi Sağlık Bilimleri Enstitüsü, Türkiye, 2019.
- [47] R. Goyal, P. Chandra, Y. Singh, Suitability of KNN regression in the development of interaction based software fault prediction models, Ieri Procedia, 6, 15-21, 2014. <http://doi.org/10.1016/j.ieri.2014.03.004>.
- [48] T. Hastie, R. Tibshirani and J. Friedman The Elements of Statistical Learning. Chapter 6, Springer Verlag, New York, 2001.
- [49] O. Anava and K. Levy, k*-nearest neighbors: From global to local, Advances in neural information processing systems, 29, 4923-4931, 2017.
- [50] D. Wettschereck and T. Dietterich, Locally adaptive nearest neighbor algorithms. Advances in Neural Information Processing Systems, 6, 184-191, 1993.
- [51] S. Sun and R. Huang, An adaptive k-nearest neighbor algorithm, Seventh International Conference on Fuzzy Systems and Knowledge Discovery, pp. 91-94, 2014.
- [52] S. Uğuz, Makine öğrenmesi teorik yönleri ve python uygulamaları ile bir yapay zeka ekolü, Nobel Yayıncılık. Ankara, 2019.
- [53] W. Sullivan, Machine Learning For Beginners Guide Algorithms: Supervised & Unsupervised Learning, Decision Tree & Random Forest Introduction, Healthy Pragmatic Solutions Inc, 2017.
- [54] G. James, D. Witten, T. Hastie, and R. Tibshirani, An introduction to statistical learning, Springer, 112, 2013.
- [55] L. Breiman, Random forests. Machine learning, 45 (1), 5-32, 2001..
- [56] K. Özkan, Sınıflandırma ve regresyon ağacı tekniği (SRAT) ile ekolojik verinin modellenmesi, Süleyman Demirel Üniversitesi Orman Fakültesi Dergisi, 13 (1), 1-4, 2012.
- [57] M. Ercire ve A. Ünsal, Kısa Süreli Güç Kalitesi Bozulmalarının Dalgacık Analizi ve Rastgele Orman Yöntemi ile Sınıflandırılması, Uludağ University Journal of The Faculty of Engineering. 26 (3), 903-920, 2021. <http://doi.org/10.17482/uumfd.976342>.
- [58] F. Rufus, S. Lee and A. Thakker, Health monitoring algorithms for space application batteries, International Conference on Prognostics and Health Management, pp. 1-8, 2008. <http://doi.org/10.1109/PHM.2008.4711430>.

