

Yayın Geliş Tarihi (Submitted): 17/05/2022

Yayın Kabul Tarihi (Accepted): 29/11/2022

Makele Türü (Paper Type): Araştırma Makalesi – Research Paper

Please Cite As/Atıf için:

Keskin, B., Günal, Ş. E., Urazel, B. ve Keskin K. (2022), Elektrikli araç bataryalarının şarj durumu tahmini için bir model, *Nicel Bilimler Dergisi*, 4(2), 161-175. doi:10.51541/nicel.1117756

ELEKTRİKLİ ARAÇ BATARYALARININ ŞARJ DURUMU TAHMİNİ İÇİN BİR MODEL

Büşra Keskin¹, Efnan Şora Günal², Burak Urazel³ ve Kemal Keskin⁴

ÖZ

Bataryaların şarj durumunun doğru tahmini, yalnızca elektrikli araçlarda değil, aynı zamanda hibrit elektrikli araçlarda, insansız hava araçlarında ve akıllı şebeke sistemlerinde yer alan batarya paketlerinin güvenilir çalışması için kritik öneme sahiptir. Bu çalışmada, elektrikli araç bataryalarının şarj durumunun değerini tahmin etmek için Torbalama-Rastgele Orman yaklaşımına dayalı bir model önerilmiştir. Önerilen yöntem ile bataryaya ait şarj değeri, bataryanın anlık akım, gerilim ve sıcaklığı ile ilişkilendirilmiştir. Çalışmada BMW i3 aracının bataryasına ait gerçek sürüşlerden elde edilen 32067 adet veri kullanılmıştır. Önerilen yöntemin etkinliğini göstermek amacıyla, popüler makine öğrenmesi yöntemlerinden Doğrusal Regresyon ve Destek Vektör Makinesi yaklaşımlarıyla da testler gerçekleştirilmiştir. Kök Ortalama Kare Hata ve Ortalama Mutlak Hata metriklerine dayanan deneysel sonuçlar, önerilen modelin literatürdeki diğer yöntemlere göre daha üstün olduğu ortaya koyulmuştur.

Anahtar Kelimeler: Batarya Şarj Durum Tahmini, Elektrikli Araç, Torbalama-Rastgele Orman, Makine Öğrenmesi

¹ Sorumlu yazar, Eskişehir Osmangazi Üniversitesi, Elektrik – Elektronik Mühendisliği Bölümü, Eskişehir, Türkiye. Türkiye Raylı Sistem Araçları Sanayii Anonim Şirketi, Eskişehir, Türkiye. ORCID ID: <https://orcid.org/0000-0003-4378-7758>.

² Dr. Öğr. Üyesi, Bilgisayar Mühendisliği Bölümü, Eskişehir Osmangazi Üniversitesi, Eskişehir, Türkiye. ORCID ID: <https://orcid.org/0000-0001-6236-174X>.

³Dr. Öğr. Üyesi, Elektrik – Elektronik Mühendisliği Bölümü, Eskişehir Osmangazi Üniversitesi, Eskişehir, Türkiye. ORCID ID: <https://orcid.org/0000-0002-3221-9854>.

⁴Dr. Öğr. Üyesi, Elektrik – Elektronik Mühendisliği Bölümü, Eskişehir Osmangazi Üniversitesi, Eskişehir, Türkiye. ORCID ID: <https://orcid.org/0000-0002-3969-2396>.

SOC ESTIMATION FOR BATTERY OF ELECTRIC VEHICLES

ABSTRACT

Accurate estimation of the state of charge of batteries is critical for the reliable operation of battery packs, not only in electric vehicles, but also in hybrid electric vehicles, unmanned aerial vehicles and smart grid systems. In this study, a model based on the Bagging-Random Forest approach is proposed to predict the value of the state of charge of electric vehicle batteries. With the proposed method, the charge value of the battery is associated with the instantaneous current, voltage and temperature of the battery. In the study, 32067 data obtained from real driving of the battery of the BMW i3 vehicle were used. In order to demonstrate the effectiveness of the proposed method, tests were also carried out using popular machine learning methods including Linear Regression and Support Vector Machine. The experimental results based on the Root Mean Square Error and Mean Absolute Error Metrics revealed that the proposed model is superior to the other methods in the literature.

Keywords: Battery State of Charge Estimation, Electric vehicle, Bagging, Random Forest, Machine Learning

1. GİRİŞ

Yeniden kullanılabilir ve güvenli enerji kaynağı olarak kabul edilen bataryalar, elektrikli ve hibrit araçlar, yenilenebilir enerji sistemleri ve akıllı şebeke sistemlerine ek olarak güç yedekleme gibi sistemlerde gün geçtikçe daha fazla kullanılmaktadır. Zamanla değişen bir parametre olan batarya şarj durumu (İng. State of Charge: SOC), batarya sisteminden alınabilecek maksimum şarjın bir ölçüsüdür. Elektrikli araçlara, hibrit araçlara veya taşınabilir cihazlara yönelik uygulamalarda SOC değerinin belirlenmesi ve kontrol edilmesi kritik öneme sahiptir. Bu uygulamalar, kullanıcılara mevcut çalışma süresi hakkında fikir verebilmesi için batarya SOC değerinin doğru bir şekilde ölçülmesini gerektirir. Aynı zamanda doğru SOC tahmininin amacı, batarya sisteminde aşırı şarj veya aşırı deşarjdan kaynaklanan potansiyel hasarı azaltmaktır. Bu nedenle, tahmin edilen SOC değerinin kesinliğinin iyileştirilmesi, hücre hasarını azaltmada, çevrim ömrünü uzatmada ve bakım maliyetini düşürmede fark yaratır. Batarya kullanım profiline bağlı olarak SOC'deki dalgalanmalar genellikle hızlı bir zaman ölçeğinde (örneğin birkaç saniyeden birkaç dakikaya kadar) gerçekleşir. Bu nedenle, iki ardışık SOC parametresi tahmini arasındaki sürenin nispeten kısa olması istenir (Nuhic vd., 2013).

2. BİLİMSEL YAZIN TARAMASI

Literatürde batarya hücrelerinin SOC değerini ölçmek veya tahmin etmek için çeşitli algoritmalar yer almaktadır. Amper-saat yöntemi (Jeong vd., 2014) ve açık devre voltajı (İng. Open Circuit Voltage: OCV) tabanlı yöntem (Petzl ve Danzer, 2013) dahil olmak üzere geleneksel doğrudan ölçüm yöntemleri (Zhang vd., 2015), ölçüm hatalarından dolayı kolaylıkla birikmiş sapmalara neden olabilir. Bu algoritmalar, ölçüm belirsizlikleri altında SOC tahmininin sağlamlığını artırmak için oluşturulmuş olsa da, genel performansları, batarya sisteminin modelleme doğruluğuna güçlü bir şekilde bağlıdır.

Diğer yaklaşımların aksine, veriye dayalı yöntem, SOC tahmin algoritmasını oluşturmada giriş ve çıkış verilerini ilişkilendirdiği için daha basit bir yöntem olarak görülmektedir. Bu kapsamda batarya SOC tahmini üzerine birçok güncel çalışma bulunmaktadır. Yapılan bir çalışmada, temel kavram, sembolize edilmiş zaman serilerinden dinamik bilgiyi çıkararak sembolik dinamik filtreleme teorisi üzerine inşa edilmiştir (Ray, 2004). Hauser ve arkadaşlarının 2016 yılında gerçekleştirdikleri bir başka çalışmada ise batarya voltajı zaman serisi analiz edilerek SOC değerinin tahmin edilmesi için dinamik veriye dayalı bir yöntem önerilmiştir. Daha önce yapılan çalışmalarda, giriş uyarılama özelliklerini elde etmek için senkronize girişlerin (akım) ve çıkışların (voltaj) sembol dizilerinin aynı anda dikkate alındığı yeni bir analiz yöntemi önerilmiştir (Hauser, vd. 2016).

Veriye dayalı yaklaşımlarda, verilerden ilişkiler ve kurallar elde etmeye yardımcı olan makine öğrenmesi tekniği kullanılır. Veriye dayalı yöntem, kapsamlı alan bilgisi gerektirmeyerek, yüksek doğruluk ve düşük maliyetle birlikte daha kısa geliştirme süresine sahiptir. Bu yöntem, süreçten elde edilen verilerin analiz edilmesiyle geliştirilmiştir. Dolayısıyla, diğer makine öğrenmesi yaklaşımlarına kıyasla, SOC tahmini daha az zaman ve bilgi ile yapılabilir (Satyan ve Sutar, 2020). Çeşitli veri güdümlü yöntem türleri, temel olarak Destek Vektör Makinesi (İng. Support Vector Machine: SVM), Bulanık Mantık, Yapay Sinir Ağı, Derin Sinir Ağı, Pekiştirmeli öğrenme ve daha fazlasını içerir. Alvarez Anton, vd. (2013) çalışmalarında, deneysel bir veri setinde yüksek kapasiteli lityum demir mangan fosfat (LiFeMnPO₄) batarya hücresinin SOC değerini, SVM yaklaşımı kullanarak tahmin edilmiştir. Geleneksel LS-SVM yöntemi, bir dizi lineer denklemi çözerek çözümleri hızlı bir şekilde bulabilir, ancak zayıf seyreklik ve model doğruluğu eksikliği problemleri bulunmaktadır (Chen ve Zhou, 2018; Mall ve Suykens, 2015).

İlgi çekici bir makine öğrenimi yaklaşımı olarak bulanık mantık, genellikle batarya SOC gösterge problemini çözmek için kullanılan karmaşık ve doğrusal olmayan dinamik sistemleri

modellemek için güçlü bir araçtır. Çevrimdışı eğitim, hesaplama açısından yoğun olsa da yerleşik bulanık modeller, batarya SOC değerini gerçek zamanlı olarak kolayca tahmin edebilir. Han ve Chen (2008), kurşun-asit bir bataryanın SOC değerini tahmin etmek için bulanık bir Mamdani muhakeme sistemi sentezlemiştir. Bir başka çalışmada, Federal Şehir İçi Sürüş Programı (FUDS) testi veri tabanındaki veriler kullanılarak, genetik algoritma tabanlı bulanık C-ortalama kümeleme algoritması uygulanmış olup, ardından elde edilen parametreler, en küçük kareler yöntemi ve geri yayılım algoritması kullanılarak optimize edilmiştir (Hu vd., 2016). Genel paylaşıma açık bulunan bir veri seti kullanılan bir çalışmada, on günlük bir seyahat için 7 elektrikli araçtan oluşan küçük bir filonun sonraki 59 saatlik toplam kullanılabilir kapasitesini tahmin etmek için Uzun Kısa Süreli Bellek ve Doğrusal Olmayan Otoregresif Sinir Ağı geliştirilmiştir (Nogay, 2022).

Bizim çalışmamızda ise SOC tahmin problemini çözmek için yeni bir model önerilmiştir. Önerilen model, elektrikli bir aracın gerçek sürüşlerinden elde edilen ve Nogay (2022) tarafından da kullanılan veri setine uygulanmıştır. Çalışmamızda, elektrikli bir araca ait 47 sürüş verisinden oluşan veri kümesindeki batarya voltaj, akım ve sıcaklık verileri, bir topluluk yöntemi olan Torbalama-Rastgele Orman modeliyle birlikte kullanılmıştır. Deneysel sonuçlar, önerilen yöntemin, doğrusal regresyon, destek vektör makinesi gibi popüler makine öğrenmesi yaklaşımlarından daha başarılı olduğunu ortaya koymuştur.

3. YÖNTEM

Çalışmada, BMW i3 (60Ah) ile yapılan gerçek sürüşlerden kaydedilen veri kümesi kullanılmıştır (Battery and Heating Data in Real Driving Cycles | IEEE DataPort, y.y.). Söz konusu veriler, 1 saniye aralıklarla kaydedilmiştir. Doğruluğun sağlanması için döngü verileri örnekleme süresi 0,1 saniyeye ayarlanmıştır. Sürüş bilgilerine ait parametreler Tablo 1’de listelenmiştir.

Gerçekleştirilen sürüşe ait özniteliklerin (akım, gerilim, sıcaklık ve ölçülen SOC değerleri) grafikleri Şekil 1’de verilmiştir.

Tablo 1. Elektrikli araç sürüş bilgileri

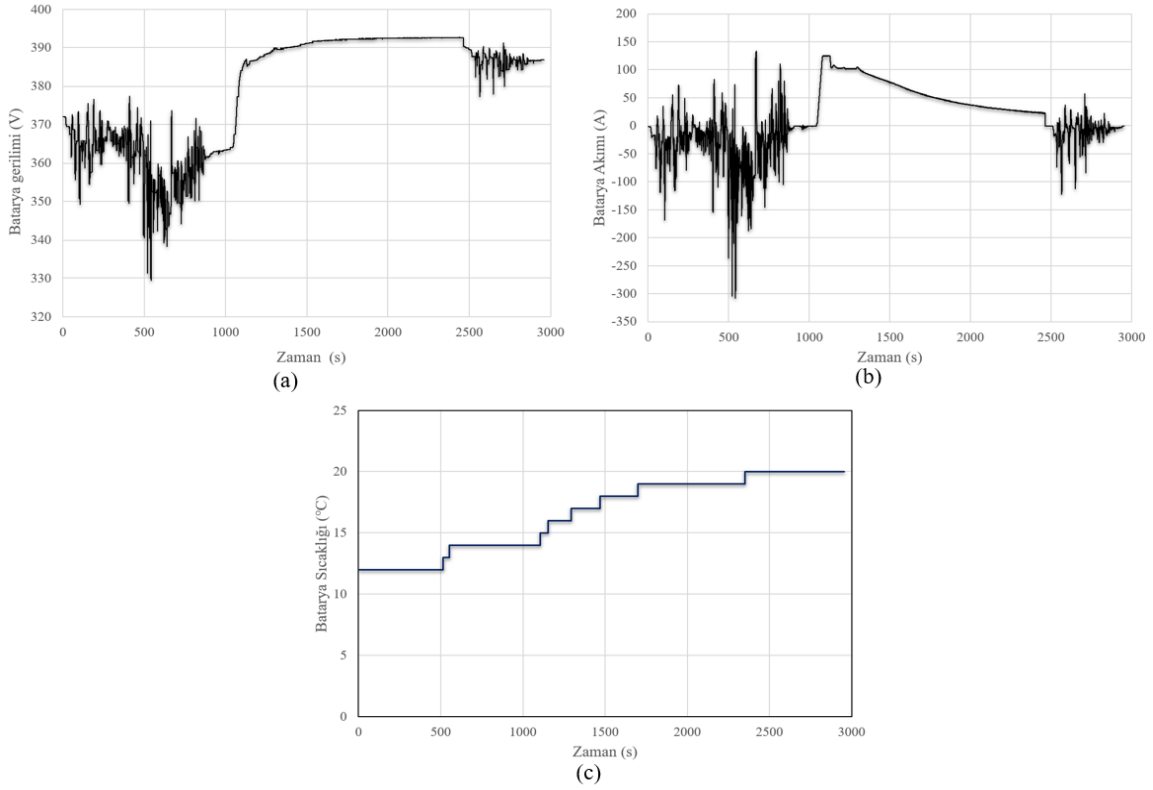
Rota/Alan	Münih
Hava Durumu	Bulutlu
Hava Sıcaklığı (Başlangıç) [°C]	9,0
Batarya Sıcaklığı (Başlangıç) [°C]	12,0
Batarya Sıcaklığı (Son) [°C]	20,0
Batarya Şarj Durumu (Başlangıç)	45,1%
Batarya Şarj Durumu (Durumu)	69,2%

3.1. Min-Maks Normalizasyonu

Normalizasyon, veriler arasındaki farkı azaltmanın ve öğrenme hızını artırmanın iyi bir yoludur. Rutin veriler çok büyük olduğu için normalizasyon yöntemi, basit kurallara sahip ve hızlı olmalıdır. Min-maks normalizasyon, orijinal veriler üzerinde doğrusal bir değişiklik gerçekleştirir. Değerler verilen aralıkta normalize edilir. Min-Maks normalizasyonunun faydası, tüm değerlerin belirli bir aralığa ölçeklendirilmesidir(Saranya ve Manikandan, 2013).

$$x = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Eşitlik (1)'de x_{min} , x_{max} ve x girdi vektöründeki minimum ve maksimum değerlerdir. Test adımında, test verileri, eğitim verilerinde kullanılan aynı x_{min} ve x_{max} değerleri kullanılarak ölçeklendirilmiştir.



Şekil 1. Zamana bağlı sürüş öznitelikleri: (a) batarya gerilimi, (b) batarya akımı, (c) batarya sıcaklığı

Batarya karakteristik verilerinin doğrusal olmaması ve veri boyutunun büyük olması nedeniyle, karakteristik verileri normalleştirilmelidir. Çalışmamızda, [0-1] değer aralığında Min-Maks Normalizasyon yöntemi kullanılmıştır.

3.2. Doğrusal Regresyon Yöntemi

Doğrusal regresyon (İng. Linear Regression: LR), bir nümerik çıktı ile bir veya daha fazla açıklayıcı değişken arasındaki ilişkiyi modellemek için kullanılan doğrusal bir yaklaşımdır. Doğrusal regresyonda ilişkiler, bilinmeyen model parametreleri ve verilerden tahmin edilen doğrusal tahmin fonksiyonları kullanılarak modellenir (Hutter, 2011). Sayısal bir bağımlı değişkenin değerini tahmin etmek için birden fazla bağımsız değişken kullanılıyorsa, böyle bir doğrusal regresyon algoritmasına Çoklu Doğrusal Regresyon denir.

$$y_i = \alpha_0 + \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_n x_n \quad (2)$$

Eşitlik (2)'de y_i bağımlı değişkeni, n öznitelik sayısını, x_i 'ler bağımsız değişkenleri göstermektedir.

3.3. Destek Vektör Makinesi

SVM, hem sınıflandırma hem de regresyon problemleri için kullanılabilen denetimli bir makine öğrenme algoritmasıdır. Deneyim riskini ve güven aralığını en aza indirgemeyerek makinenin genelleme yeteneğini geliştirmek için yapılandırılmış riski en aza indirmeyi amaçlar. Böylece, istatistiksel örneklerin sayısı az olduğunda bile iyi bir istatistiksel kural elde edilebilir.

SVM algoritmasında, her bir veri ögesini, her özelliğin değeri belirli bir koordinatın değeri olacak şekilde n boyutlu uzayda (n , sahip olunan bir dizi özelliktir) bir nokta olarak çizilir ve iki sınıfı çok iyi ayıran hiper düzlemi bularak sınıflandırma yapılmaktadır. Destek vektörleri, basitçe bireysel gözlem koordinatlarıdır. SVM sınıflandırıcısı, iki sınıfı (hiper düzlem/çizgi) en iyi şekilde ayıran bir sınırdır. SVM, doğrusal olmayan ve yüksek boyutlu batarya modellemede oldukça yaygın kullanılmaktadır (Eren ve Yılmaz, 2019). Bataryanın SOC değerini doğru bir şekilde tahmin edebilir, ancak hesaplama karmaşıklığını artırır. Önerilen algoritmanın deneye dayalı denklemi şu şekildedir;

$$Z_i = \sum_i^N W \cdot K(x_i, x) + B \quad (3)$$

Eşitlik (3)'de Z_i tahmin edilen çıktıyı, W ağırlığı, K çekirdek hilesini, (x_i, x) destek vektörlerini, B ise yanlılık değerini ifade etmektedir.

3.4. Torbalama ile Rastgele Orman Yöntemi

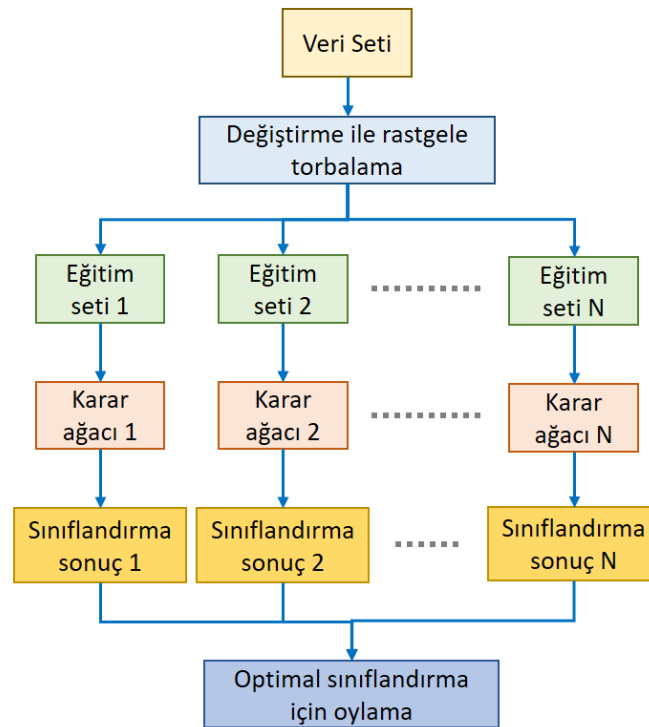
Topluluk yöntemleri, belirli bir istatistiksel öğrenme veya model tahmin tekniğinin tahmin performansını iyileştirmeyi amaçlar. Topluluk yöntemlerinin genel ilkesi, yöntemin tek bir uyumunu kullanmak yerine, bazı model tahmin yöntemlerinin doğrusal bir kombinasyonunu oluşturmaktır. Topluluğun kendisi denetimli bir öğrenme algoritması olmakla birlikte, eğitilebilir ve daha sonra tahminlerde bulunmak için kullanılabilir. Topluluk yöntemleri, tek bir karar ağacı sınıflandırıcısından daha iyi tahmin performans üretmek için, birkaç karar ağacı sınıflandırıcısını birleştirir. Topluluk modelinin arkasındaki ana ilke, bir grup zayıf öğrenicinin güçlü bir öğrenici oluşturmak için bir araya gelmesi ve böylece doğruluğu arttırmasıdır.

Rastgele orman (İng. Random Forest: RF) regresyonu, bir topluluk makine öğrenme algoritmasıdır (Breiman, 2001). Veri eğitimi ve tahmin için bir orman oluşturmak üzere temel öğrenenler olarak geniş bir regresyon ağacı seti kullanır. Regresyon ağaçlarının her biri, ilk

eğitim verilerinden türetilen ayrı bir önyükleme örneğinde büyür ve etkileşim olmadan paralel olarak çalıştırılır. Bir ağaçtaki her düğüm, tahmin değişkenine karşı ikili bir testi temsil eder. Her düğümdeki değişkenler, her iki dalın kalan karelerinin toplamını en aza indirecek şekilde seçilir.

Güçlü bir genellemeye sahip bir topluluk modeli elde etmek için, modeldeki regresyon ağacı mümkün olduğunca ilişkisiz olarak ayarlanır (Breiman, 2001). Rastgele orman, ağaçların çeşitliliğini artırmak için paralel bir topluluk modeli olan torbalamayı (Breiman, 1996) kullanır. Şekil 2’de belirtildiği gibi N adet örnekli bir ilk veri kümesi için, değiştirme ile ilk veri kümesinden N numune rastgele seçilerek bir önyükleme numunesi oluşturulur (seçilen numune bir numuneden sonra ilk veri kümesine döndürülür, bu da sonraki numune alma sırasında seçilmesini mümkün kılar). Tahmin, ormandaki her ağaçtan alınan ayrı kararların ortalaması alınarak oluşturulur. Bu özellik, girdi verilerinde küçük bir değişiklik olduğunda rastgele ormanı daha sağlam kılar. Böylece hem tahmin doğruluğu hem de kararlılık artar (Breiman, 1996).

Bu çalışmada, regresyon problemlerini çözmek için rastgele orman, torbalama algoritması ile birleştirilmiştir.



Şekil 2. Torbalama-rastgele orman metodu akış şeması

3.5. Çapraz Doğrulama

Çalışmanın doğruluğunu değerlendirmek için k-katlı çapraz doğrulama yöntemi kullanılmıştır. Söz konusu yöntemde, numuneler eşit büyüklükte k alt kümeye bölünür. Sırayla, her alt küme, geri kalan k-1 alt küme üzerinde eğitilen model kullanılarak test edilir. Böylece, tüm eğitim setinin her örneği bir kez test edilerek, genel çapraz doğrulama doğruluğu, tüm veri setinin ortalaması olur. Çapraz doğrulama ile elde edilen tahmin doğruluğu, bilinmeyen verileri daha kesin olarak sınıflandırarak performansı yansıtabilmektedir (Kohavi, 1995). Genel olarak, k değeri, tüm veri setindeki örnek sayısından küçükse, çapraz doğrulama doğruluğunu çok fazla etkilemez. Bu nedenle, çalışmamızda k=10 olarak testler yapılmıştır.

3.6. Performans Analizi

Bir model oluşturulduktan sonra, modelin kararlılığının ve güvenilirliğinin doğrulanması gerekir. Bu çalışmada iki farklı model performans indeksi, Ortalama Mutlak Hata (İng. Mean Absolute Error: MAE) ve Kök Ortalama Kare Hata (İng. Root Mean Square Error: RMSE) olarak seçilmiştir. Ortalama Mutlak Hata şu şekilde tanımlanır:

$$MAE = \frac{\sum_{i=1}^n |e_t|}{n} \quad (4)$$

Kök Ortalama Kare Hata ise şu şekilde tanımlanır:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n e_t^2}{n}} \quad (5)$$

Eşitlik (4) ve (5)'de, e_t , gözlemlenen değer ile ölçülen değer arasındaki farkı, yani hatayı, temsil etmektedir.


4. BULGULAR

Deneyler, BMW i3 (60Ah) ile yapılan gerçek sürüşlerde kaydedilen veriler kullanılarak gerçekleştirilmiştir. Veri seti üzerinde doğrusal regresyon, destek vektör makinesi ve torbalama-rastgele orman yöntemleri uygulanmış ve SOC değeri tahmin edilmeye çalışılmıştır. Elde edilen sonuçlar, Tablo 2'de karşılaştırmalı olarak sunulmuştur.

Tablo 2. Karşılaştırmalı tahmin sonuçları

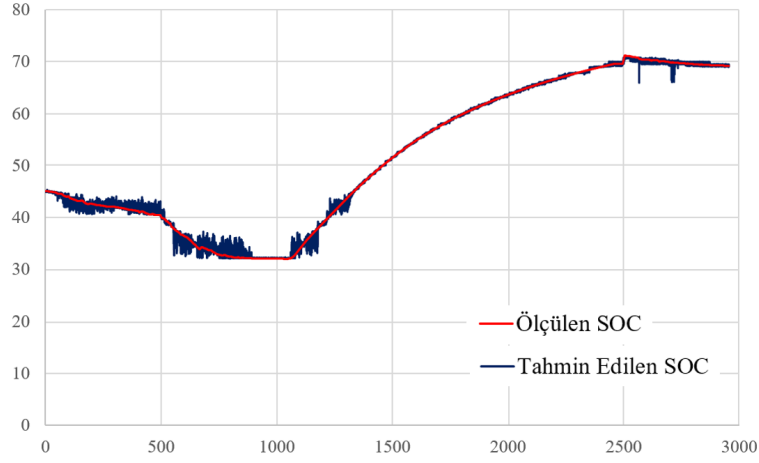
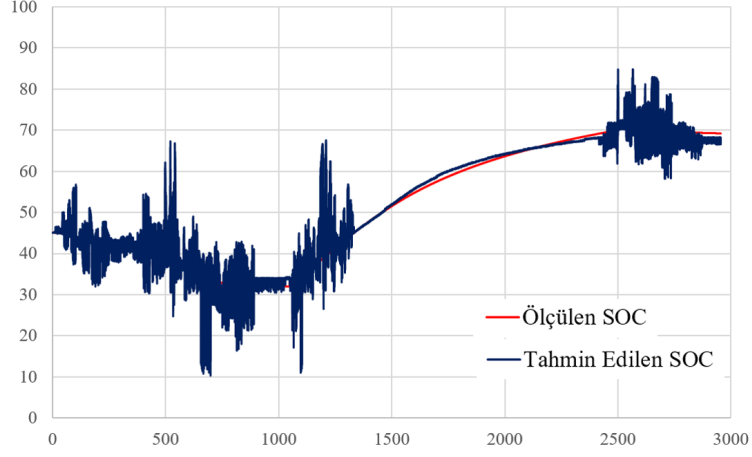
Yöntem	MAE	RMSE
Doğrusal Regresyon	2,068	2,716
Destek Vektör Makinesi	1,773	3,052
Torbalama-Rastgele Orman	0,280	0,519

Uygulanan yöntemlerle elde edilen ait tahmin grafiklerinin ölçülen SOC değerleriyle karşılaştırması ise Şekil 3'te gösterilmektedir.



(a)

Şekil 3. SOC tahmin grafiği (a) LR (b) SVM (c) Torbalama-RF



Şekil 3 (Devam). SOC tahmin grafiği (a) LR (b) SVM (c) Torbalama-RF

5. TARTIŞMA

Torbalama-RF yönteminin doğruluğu ve sağlamlığı, geliştirilen model ve diğer öne çıkan yöntemler arasındaki SOC hata terimleri araştırılarak daha da doğrulanmaktadır. Konuya ilişkin güncel literatürden, derin öğrenme, gradyan arttırma, yapay sinir ağı, destek vektör makinesi ve topluluk optimize edicili geçitli tekrarlayan birimi gibi yaklaşımları içeren bazı çalışmalar, Tablo 3'te gösterildiği gibi karşılaştırmalı değerlendirme için ele alınmıştır. Söz konusu tabloda, benzer sıcaklık koşullarında farklı kimyasal içeriğe sahip bataryalara ait veri setleri için çeşitli veriye dayalı yöntemler kullanılmaktadır. Söz konusu tablodan anlaşılacağı üzere, Torbalama-RF yönteminin, farklı koşullar altında diğer yaklaşımlardan daha iyi performans ve sağlamlığa sahip olduğu açıktır.

Tablo 3. SOC tahmini karşılaştırmalı performans değerlendirilmesi

#	Yöntem	Kaynak	Test Bataryası	Sıcaklık	Hata Oranı
1	Destek Vektör Makinesi	(Alvarez Anton vd., 2013)	Lithium-ion	25°C	RMSE: 0,710
2	Yapay Sinir Ağları ve Sigma Bazlı Kalman Filtreleri	(He vd., 2014)	LiFePO4	0°C, 10°C, 25°C	0°C için RMSE: 2,200 10°C için RMSE: 0,500 25°C için RMSE: 0,500
3	Derin Öğrenme	(Chermali vd., 2017)	2.9 Ah Panasonic LiNiCoAlO2/ NCA	0°C, 10°C ve 25°C	RMSE: 1,110 – 2,440 MAE: 0,770 – 2,080
4	Gradyan Arttırma	(Ipek vd., 2019)	Li-Ion-Phosphate	-20°C, - 10°C ve 5°C	RMSE: 1,332 R2 Skoru: 0,998
5	Topluluk Optimize Edicili Geçitli Tekrarlayan Birim	(Xiao vd., 2019)	26650 LiFePO4/graphite cell	0°C, 30°C ve 50°C	GRE için RMSE: 1,130 GRA için RMSE: 1,940 LRE için RMSE: 1,240
6	Uzun Kısa Süreli Bellek ve Doğrusal Olmayan Otoregresif Sinir Ağı	(Nogay, 2022)	Lithium-ion	9°C	MAE: 0,617 – 2,766 RMSE: 0,548 – 1,658
7	Torbalama-Rastgele Orman	Önerilen Model	Lithium-ion	9°C	MAE: 0,280 RMSE: 0,519

6. SONUÇLAR

Güvenilir bir SOC tahmini yapmak, bataryaların doğrusal olmayan özellikleri ve karmaşık kimyası nedeniyle batarya ile çalışan elektrikli araçlar için büyük bir zorluktur. Makine öğrenmesi yöntemleri kullanılarak BMW i3 (60Ah) aracı ile 9°C hava sıcaklığında gerçekleştirilen sürüşe ait batarya verileri kullanılarak SOC tahmini yapılmıştır. LR, SVM ve Torbalama-RF yöntemi karşılaştırılmıştır. Torbalama-RF yöntemi MAE ve RMSE değerleri

sırasıyla 0,280 ve 0,519 olarak elde edilmiştir. Tablo 3’de yer alan çalışmalarla kıyaslandığında, her ne kadar veri kümeleri farklı olsa da çalışmamızda önerilen yöntemle, diğer yöntemlerin neredeyse tamamından daha iyi MAE ve RMSE değerleri elde edilmiştir. Böylece, gerçek zamanlı uygulamalar için önerilen SOC tahmin yaklaşımının uygulanabilirliği doğrulanmıştır. Ayrıca, önerilen yöntem, dinamik koşullar altında daha yüksek bir doğrulukla etkin bir şekilde çalışmakta, LR ve SVM yöntemleri gibi geleneksel yöntemlerden daha iyi performans göstermektedir. Önerilen yaklaşımın, modüler pil tasarımı için tasarlanabilir olmasıyla birlikte, elektrikli araçlar için farklı pil kimyalarında ve sürdürülebilir enerji uygulamalarında da kullanılabileceği değerlendirilmektedir.

ETİK BEYAN

“Elektrikli Araç Bataryalarının Şarj Durumu Tahmini İçin Bir Model” başlıklı çalışmanın yazım sürecinde bilimsel, etik ve alıntı kurallarına uyulmuş; toplanan veriler üzerinde herhangi bir tahrifat yapılmamış ve bu çalışma herhangi başka bir akademik yayın ortamına değerlendirme için gönderilmemiştir.

KAYNAKÇA

- Alvarez Anton, J. C., Garcia Nieto, P. J., Blanco Viejo, C. ve Vilan Vilan, J. A. (2013), Support vector machines used to estimate the battery state of charge, *IEEE Transactions on Power Electronics*, 28(12), 5919–5926.
- Battery and Heating Data in Real Driving Cycles* | *IEEE DataPort*. (2022), <https://iee-dataport.org/open-access/battery-and-heating-data-real-driving-cycles>. Erişim tarihi: 2022
- Breiman, L. (1996), Bagging predictors, *Machine Learning*, 24(2), 123–140.
- Breiman, L. (2001), Random Forests. *Machine Learning*, 45(1), 5–32.
- Chen, L. ve Zhou, S. (2018), Sparse algorithm for robust LSSVM in primal space, *Neurocomputing*, 275, 2880–2891.
- Chemali, E., Kollmeyer, P. J., Preindl, M., Ahmed, R. ve Emadi, A. (2018), Long short-term memory networks for accurate state-of-charge estimation of Li-ion batteries, *IEEE Transactions on Industrial Electronics*, 65(8), 6730–6739.

- Han, S. S. ve Chen, W. Z. (2008). The algorithm of dynamic battery SOC based on Mamdani fuzzy reasoning, *Proceedings of 5th International Conference on Fuzzy Systems and Knowledge Discovery, FSKD 2008*, 1, 439–443.
- Hauser, M., Yue L., Jihang L. Ve Ray, A. (2016), Real-time combustion state identification via image processing: A dynamic data-driven approach, *2016 American Control Conference (ACC)*, 3316–3321.
- He, W., Williard, N., Chen, C. ve Pecht, M. (2014), State of charge estimation for Li-ion batteries using neural network modeling and unscented Kalman filter-based error cancellation, *International Journal of Electrical Power & Energy Systems* 62, 783–791.
- Hu, X., Li, S. E. ve Yang, Y. (2016), Advanced machine learning approach for Lithium-Ion battery state estimation in electric vehicles, *IEEE Transactions on Transportation Electrification*, 2(2), 140–149.
- Hutter, M. C. (2011), Determining the degree of randomness of descriptors in Linear regression equations with respect to the data Size. *Journal of Chemical Information and Modeling*, 51(12), 3099–3104.
- Ipek, E., Kerem Eren, M. ve Yilmaz, M. (2019), State-of-Charge Estimation of Li-ion Battery Cell using Support Vector Regression and Gradient Boosting Techniques. *Proceedings of 2019 International Aegean Conference on Electrical Machines and Power Electronics, ACEMP 2019 and 2019 International Conference on Optimization of Electrical and Electronic Equipment, OPTIM 2019*, 604–609.
- Jeong, Y. M., Cho, Y. K., Ahn, J. H., Ryu, S. H. ve Lee, B. K. (2014), Enhanced coulomb counting method with adaptive SOC reset time for estimating OCV, *2014 IEEE Energy Conversion Congress and Exposition, ECCE 2014*, 4313–4318.
- Kohavi, R. (1995). A Study of cross-validation and bootstrap for accuracy estimation and model selection. <http://roboticsStanfordedu/%22ronnyk>, Erişim tarihi:2022.
- Mall, R. ve Suykens, J. A. K. (2015), Very sparse LSSVM reductions for large-scale data. *IEEE Transactions on Neural Networks and Learning Systems*, 26(5), 1086–1097.
- Nogay, H. (2022), Estimating the aggregated available capacity for vehicle to grid services using deep learning and nonlinear autoregressive neural network, *Sustainable Energy, Grids and Networks*, 29, 100590.

- Nuhic, A., Terzimehic, T., Soczka-Guth, T., Buchholz, M. ve Dietmayer, K. (2013), Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods, *Journal of Power Sources*, 239, 680–688.
- Petzl, M. ve Danzer, M. A. (2013), Advancements in OCV measurement and analysis for lithium-ion batteries, *IEEE Transactions on Energy Conversion*, 28(3), 675–681.
- Ray, A. (2004), Symbolic dynamic analysis of complex systems for anomaly detection, *Signal Processing*, 84(7), 1115–1130.
- Saranya, C. ve Manikandan, G. (2013), *A Study on normalization techniques for privacy preserving data mining*.
- Satyan, P. A. ve Sutar, R. (2020), A Survey on data-driven methods for state of charge estimation of battery, *2020 International Conference on Electronics and Sustainable Communication Systems (ICESC)*, 996–1004.
- Xiao, B., Liu, Y. ve Xiao, B. (2019), Accurate state-of-charge estimation approach for lithium-ion batteries by gated recurrent unit with ensemble optimizer, *IEEE Access*, 7, 54192–54202.
- Zhang, C., Li, K., Pei, L. ve Zhu, C. (2015), An integrated approach for real-time model-based state-of-charge estimation of lithium-ion batteries, *Journal of Power Sources*, 283, 24–36.