



Lityum iyon batarya için dikkat mekanizmalı geçitli tekrarlayan birim (GRU) sinir ağıni temel alan sağlık durumu (SOH) tahmini

State of health (SOH) estimation based on gated recurrent unit (GRU) neural network with attention mechanism for lithium-ion battery

Tuğhan Tunç^{1,*}, Hamit Erdem²

^{1,2} Başkent Üniversitesi, Elektrik & Elektronik Mühendisliği Bölümü, 06790, Ankara Türkiye

Öz

Günümüzde lityum iyon bataryalar, verimli bir enerji depolama elemanı olarak üretimin ve yaşamın çeşitli alanlarında yeri doldurulamaz bir rol oynamaktadır. Lityum iyon bataryaların sağlık durumu (SOH), enerji depolama sisteminin güvenli çalışması için kritik öneme sahiptir. Bu çalışmada batarya yönetim sisteminden gelen, yaşlanmaya bağlı olarak değişen gerilim, akım ve sıcaklık profilleri gibi ölçülebilir veriler kullanılmıştır. Bu verilere dayanarak kapasite ile şarj profilleri arasındaki ilişki sinir ağı tarafından öğrenilir. Bu çalışmada ulaşılan deneysel sonuçlar NASA lityum iyon pil veri setine dayanmaktadır. Önerilen dikkat mekanizmalı GRU yöntemi, bataryanın sağlığının tahmininde ortalama mutlak yüzde hata açısından derin öğrenme yöntemlerinden olan LSTM, GRU ve BiLSTM yöntemlerine kıyasla sırasıyla %35, %27 ve %20'ye kadar daha başarılı olduğu görülmüştür. Yapılan benzetim çalışmaları MATLAB ortamında derin öğrenme toolbox'ı kullanılarak gerçekleştirilmiştir. Son yıllarda dikkat mekanizmaları, zaman serisi tahmin modellerinin performansını artırmak için güçlü bir araç olarak ortaya çıkmıştır. Bu çalışmada, zaman serisi problemlerinin çözümlerinde kullanılan LSTM, BiLSTM ve GRU aynı NASA veri setleri üzerinde denenmiş ve bu üç yöntemden daha hızlı ve basit olmasıyla GRU tercih edilmiştir. Bu çalışmada önerilen mekanizma GRU ile Dikkat Mekanizmasını birleştirerek oluşturulmuş SoH öngörüm mekanizmasıdır.

Anahtar kelimeler: Lityum iyon pil, Sinir ağı, Kalan kullanım ömrü (RUL), Kapasite tahmini, Pilin sağlık durumu (SoH), LSTM, GRU, Çift yönlü LSTM, Dikkat mekanizması

1 Giriş

İçten yanmalı motorların kullanmış olduğu fosil yakıtların çevreye zararlarına olan bilincin artması ve aynı zamanda bu yakıtların tükenbilir kaynak olması temiz yakıt kullanan araçlara olan ilgiyi arttırmıştır. Elektrikli araçlar (EV) bu konuda en çok ilgiyi üzerine toplayan seçenek olmuştur.

Abstract

Lithium-ion batteries play an irreplaceable role in various areas of production and life as an efficient energy storage element. The state of health (SOH) of lithium-ion batteries is critical to the safe operation of the energy storage system. In this study, measurable data from the battery management system, such as voltage, current and temperature profiles that change due to aging, were used. Based on these data, the relationship between capacity and charging profiles is learned by neural networks. The experimental results achieved in this study are based on the NASA lithium-ion battery data set. It has been observed that compared to the LSTM, GRU and BiLSTM methods, which are deep learning methods, the proposed GRU method with attention mechanism is more successful in estimating the health of the battery in terms of average absolute percentage error by up to 35%, 27% and 20%, respectively. The simulation studies were carried out using the deep learning toolbox in the MATLAB environment. In recent years, attention mechanisms have emerged as a powerful tool to improve the performance of time series forecasting models. In this study, LSTM, BiLSTM and GRU, which are used to solve time series problems, were tested on the same NASA data sets, and GRU was preferred because it is faster and simpler than these three methods. The mechanism proposed in this study is the SoH prediction mechanism created by combining GRU and Attention Mechanism.

Keywords: Lithium-ion battery, Neural network, Remaining useful life (RUL), Capacity estimation, Battery state of health (SoH), LSTM, GRU, Bi-directional LSTM, Self-attention mechanism

Elektrikli araçlarda enerjinin depolanabilmesi için bataryalar tercih edilmektedir. Kullanılan bu bataryaların pek çok türü olmasına karşın; geniş sıcaklık aralığında çalışabilmesi, yüksek enerji yoğunluğuna sahip olması, kendi kendine deşarj oranının az olması ve uzun çevrim ömrü gibi özellikleri sayesinde lityum iyon bataryalar son zamanlarda ulaşım, elektronik, taşınabilir mobil cihazlar ve

* Sorumlu yazar / Corresponding author, e-posta / e-mail: tughantr06@gmail.com (T. Tunç)

Geliş / Received: 20.12.2023 Kabul / Accepted: 20.02.2024 Yayınlanma / Published: 15.04.2024

doi: 10.28948/ngumuh.1407480

havacılık gibi çeşitli endüstriyel sektörlerde yaygın olarak kullanılmaktadır [1].

Bataryalarda yaşanan öncelikli sorun batarya şarj durumunu belirlemek olmuştur. Bataryalar gözle görülür bir fiziksel depolama yapmadıkları için pek çok farklı şarj durumu belirleme (SoC) yöntemi üzerinde çalışılmış ve bu bağlamda pek çok yöntem ortaya konmuştur. Günümüzde en çok kullanılmakta olan Coulomb Sayma Yöntemi gibi farklı SoC belirleme yöntemleri ayrıntılı bir şekilde incelenmiş ve ortaya konmuştur [2].

Bataryaların şarj durumunu belirleme sorununa farklı yöntemler geliştirdikten sonra insanlık bataryanın sağlık durumunu (SoH) ve bataryanın kalan faydalı ömrünü belirleme sorunu ile karşı karşıya kalmıştır. Prognostik ve sağlık yönetimi (PHM), bileşenlerin bozulmasını tam zamanında tahmin eden ve böylece geleneksel bakım paradigmasını basitleştiren bir yöntemdir [3]. Bunu yaparken kalan faydalı ömür (RUL), bileşen veya sistemin güvenlik kriteri sınırına ulaşılan kadar geçen süre olarak tanımlanır. Bataryaların prognostik ve sağlık yönetimi ise batarya sağlığı ve korunumunun da dahil olduğu, PHM yöntemlerinin batarya alanına uygulanması etkinliğini ifade eder. Arızalara karşı kararlı çalışma perspektifinden sistemin durumunu yüksek güvenilirlikle tahmin etmek önemlidir. ISO 13381-1'e göre prognostik, "tasarım parametreleri dahilinde gelecekteki durumu ve kalan ömrü tahmin etmek için arıza belirtilerinin analizi" olarak tanımlanır [4]. Bu bağlamda pek çok araştırma yapılmış bataryanın ömrünün önceden tahmin edilebilmesi için pek çok farklı yöntem ve metot ortaya konulmuştur. Bu metotlardan biri olan göreceli kapasite kestirim yöntemi, bir batarya hücrelerinin terminal gerilimini incelemek için aynı yük sinyali altında farklı döngü sayıları veya yaşlardaki değişiklikleri kullanır [5].

Yapay Zekânın günümüzdeki gelişimi ile tahmin, öngörü hesaplamalarında alt başlığı olan makine öğrenmesinin yeri artmıştır. Batarya sağlık durumunun makine öğrenmesi ile tahmin edilmesi için tanımlı girdi değerleri kullanılarak k-En Yakın Komşu (kNN) ve Rastgele Orman Regresyon (Random Forest) yöntemleri önerilen yöntemler arasındadır [6]. Bunlara ek olarak batarya sağlık durumunun tahmini hesaplamalarında öz dikkat mekanizması kullanılarak geleneksel yöntemlere kıyasla önemli ölçüde zaman ve iş gücü tasarrufu sağlanmıştır. [7].

Batarya ömrünün önceden tahmin edilebilmesi problemi bir zaman serisi tahmin modelidir. Zaman serisi tahmin modelleri, doğrulanmış geçmiş verilere dayanarak olayları tahmin etmek için kullanılır [8]. Zaman serisi modellerinde daha önce yapılan çalışmalarda Sinir Ağlarının Alt başlığı olan Derin Öğrenme yöntemlerinden Uzun Kısa Dönemli Bellek (Long Short-Term Memory) kullanımının daha başarılı olduğu görülmüştür.

Lityum iyon batarya için ise yapılan çalışmalarda NASA Prognostics Centre of Excellence tarafından yayınlanan veri setinin çok kanallı V, I, T verilerini içeren FNN (İleri Beslemeli Sinir Ağları), CNN (Evrişimsel Sinir Ağları) ve LSTM (Uzun Kısa Dönemli Bellek)'e dayalı bir kapasite tahmin çerçevesi önerilir. FNN ve CNN yöntemlerinden farklı olarak LSTM, kapasiteyi veride anormallikler olmasına rağmen doğru bir şekilde tahmin etmektedir.

Bunun nedeni LSTM'nin uzun süreli bilgi depolayan hafıza hücreli yapısından kaynaklanmaktadır [9]. NASA veri setinin yanı sıra, MIT tarafından yayınlanan veri seti de LSTM ile SoH hesaplanması için ele alınmıştır [10].

Bu çalışmada kullanılan Dikkat Mekanizmaları (Attention Mechanism), farklı parçalara atanan farklı ağırlıklara dayalı olarak dikkatin verinin belirli bölümlerine odaklanmasını sağlamak için derin öğrenme modellerine eklenen bir sinir ağı katmanıdır.

Yapılan çalışmada dikkat mekanizması ile LSTM'in beraber çalıştığı bir SoH öngörüm mekanizması ortaya konulmuştur [11]. Buna ek olarak, BiLSTM (Çift Yönlü Uzun Kısa Dönemli Bellek) zıt yönlerde iki LSTM'den oluştuğundan sıra ile ilgili problemlerde daha iyi performansa sahiptir. BiLSTM, verileri iki LSTM üzerinden zıt yönlerde iletebilir ve tersine çevirebilir, böylece hem geçmiş hem de gelecek bilgileri kullanılabilir. BiLSTM sinir ağı ile Dikkat Mekanizması beraber kullanımının NASA veri seti ile SoH analizi incelenmiştir [12]. Geçitli Tekrarlayan Birim (GRU), Uzun Kısa Süreli Bellek (LSTM) ağlarına daha basit bir alternatif olarak 2014 yılında tanıtılan bir tür tekrarlayan sinir ağıdır (RNN). LSTM gibi GRU da metin, konuşma ve zaman serisi verileri gibi sıralı verileri işleyebilir [13]. Bu çalışmada önerilen mekanizma GRU ile Dikkat Mekanizmasını birleştirerek oluşturulmuş SoH öngörüm mekanizmasıdır.

2 Materyal ve metot

2.1 NASA'nın lityum iyon batarya verisi

Bu çalışma NASA Prognostics Center of Excellence Veri Havuzu tarafından sağlanan batarya veri setlerini kullanmaktadır [14]. Bu veri setleri, oda sıcaklığında şarj, deşarj ve dinlenme süresi olmak üzere üç farklı çalışma profilinde çalışan dört lityum iyon bataryadan oluşur. Deneyler, hızlandırılmış yaşlanmayı sağlamak için ticari olarak temin edilebilen 18650 lityum iyon hücrelerine tekrarlanan şarj ve deşarj döngülerinin uygulanmasıyla oluşturulmuştur.

Bataryalar sabit akım sabit gerilim (CCCV) prensibine göre şarj edilir ve bu prensibe göre bataryalar öncelikle 4.2 V üst gerilim sınırına ulaşılan kadar 1.5 A sabit akımda şarj edilmektedir. Ardından 4.2V sabit gerilimde akım 20 mA altına düşene kadar şarj devam eder. Deşarj işlemi ise hücre gerilimi #5, #6, #7 ve #18 bataryaları için sırasıyla 2.7 V, 2.5 V, 2.2 V ve 2.5 V'a düşene kadar 2 A'lik sabit akımda yapılır. Deneyler, bataryalar nominal kapasitenin %20'sini kaybedene kadar, yani 1.6 Ah kapasiteleri kalana kadar gerçekleştirilir.

Bu kapasite düşüşünden sonra bataryalar otomotiv sektöründe kullanılamazlar ve ikincil hayat olarak adlandırılan yerel enerji depolama uygulamalarında; yani güneş paneli, rüzgâr tribünü ve bunun gibi yerlerde kullanılabilirler. Bu veri setinde ek elektrokimyasal empedans verileri de sağlanmaktadır ancak bizim çalışmamızda kullanılmamaktadır.


2.2 Şarj/deşarj sürecinde veri toplama

Bataryanın bozulmasını tahmin etmede kritik olan dahili batarya parametrelerinin yaşlanma boyunca nasıl değiştiğini

yakalamak için gerilim, akım ve sıcaklık verilerinden yararlanılmaktadır. Bu verilerin her biri her şarj döngüsünde tekrar ölçülür. Gerçek uygulamada bataryanın üç durumu vardır: bunlar şarj, deşarj ve dinlenmedir.

Elektrikli araçlarda deşarj işlemi sırasında, akım zaman içerisinde hızla ve düzensiz olarak değişmesi nedeniyle iç parametrelerin hassas bir şekilde ölçülmesi veya hesaplanması zordur. Yapılan son araştırmalara göre [15, 16] bataryanın dinlenme periyodunda akımın geçişine bağlı olarak aktif malzemelerin yeniden dengelenmesi ve gradyanlarının gevşemesi süreci mevcuttur. Bu süreç sayesinde kapasite yenilenmesi gerçekleşir. Bu nedenle bataryanın dahili parametreleri genellikle sabittir veya şarj veya deşarj süresine göre yavaş değişir. Bu durum, iç parametrelerin tahminini zorlaştırmaktadır çünkü bu parametreler, belirsiz veri miktarına dayalı olarak hesaplanamamaktadır [17]. Ancak bataryalar genellikle gerekli harici elektrik performansının kolayca ölçülebildiği önceden belirlenmiş protokollere dayalı, sorunsuz bir şarj sürecine sahiptir.

Ayrıca, deşarj düzeni esas olarak sahibinin rutinine bağlıdır ki bu da yüksek rastgelelik ve belirsizlik içerir. Bu sebeple batarya şarj profillerini kullanmak çok daha kolaydır. İncelemekte olduğumuz NASA veri setinde deşarj rutini rastgelelik içermeyecek sabit deşarj akımı ile yapılmış olduğundan yapılan çalışmada deşarj durumu da incelenmiştir.

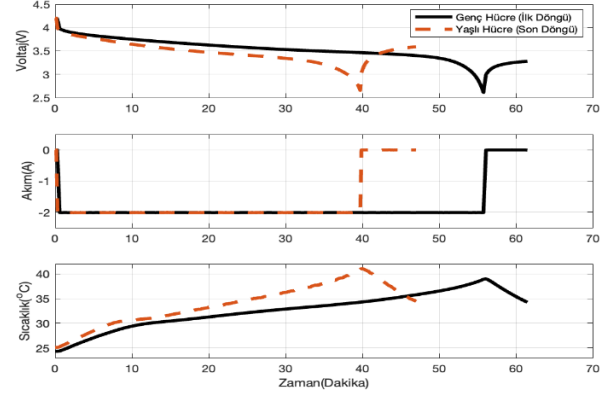


Şekil 1. Yeni ve yaşlandırılmış batarya hücresi gerilim, akım ve sıcaklık şarj grafikleri

2.3 Gerilim, akım ve sıcaklık verileri ile şarj profilleri

Şekil 1 ve 2, NASA veri setinden alınmış olan dört bataryanın yaşlandırılma sürecinde ilk döngüdeki ve son döngüdeki verilerinin çizdirilmesiyle elde edilmiştir. NASA veri seti havuzunda 40'a yakın batarya yaşlandırma veri seti bulunmaktadır. Ancak #5, #6, #7 ve #18 numaralı bataryalara benzer şartlar altında yaşlanma testi yapılmış olunması sebebiyle bu çalışma için bu bataryalar seçilmişlerdir. Bu şekillerde batarya yaşlandıkça gerilim, akım ve sıcaklığın hem şarj hem deşarj profillerinde önemli değişiklikler yarattığını gözlemliyoruz. Şekil 1'de şarj işlemi sırasında yaşlanan hücrenin gerilimi, yeni hücreye göre 4.2V'a daha erken ulaşır ve yaşlanan hücrenin akımı, yeni hücreye göre daha erken sabit akımdan düşmeye başlar. Bunlara ek olarak, yaşlandırılmış hücre maksimum sıcaklığa

yeni hücreden çok daha erken ulaşır. İlk ve son döngünün sıcaklık profillerinin başlangıçlarının farklı olmasının nedeni, tekrarlanan şarj, dinlenme ve deşarj işlemlerinden kaynaklanmaktadır.



Şekil 2. Yeni ve yaşlandırılmış batarya hücresi gerilim, akım ve sıcaklık deşarj grafikleri

Şekil 2'de deşarjın sonundaki sıcaklık genellikle başlangıca göre arttığından, bu durum bir sonraki şarj profilinin başlangıç sıcaklığını etkiler. Deşarj grafiklerine bakıldığında da şarj grafiklerine çok benzer bir yapı gözlenmektedir. Hem sıcaklık hem gerilim hem de akım değerleri limit değerlere yeni hücreye kıyasla yaşlandırılmış hücre de daha erken ulaşmaktadır. Bataryanın yaşlanmasını ölçmek için SoH'yi doğru şekilde tanımlamamız gerekir. SoH'yi tanımlamanın kabul edilmiş sabit bir yolu olmamasına rağmen, genellikle aşağıdaki şekilde verilen kapasite kullanılarak tanımlanır:

$$SOH(\%) = \frac{C_k}{C_0} \times 100 \quad (1)$$

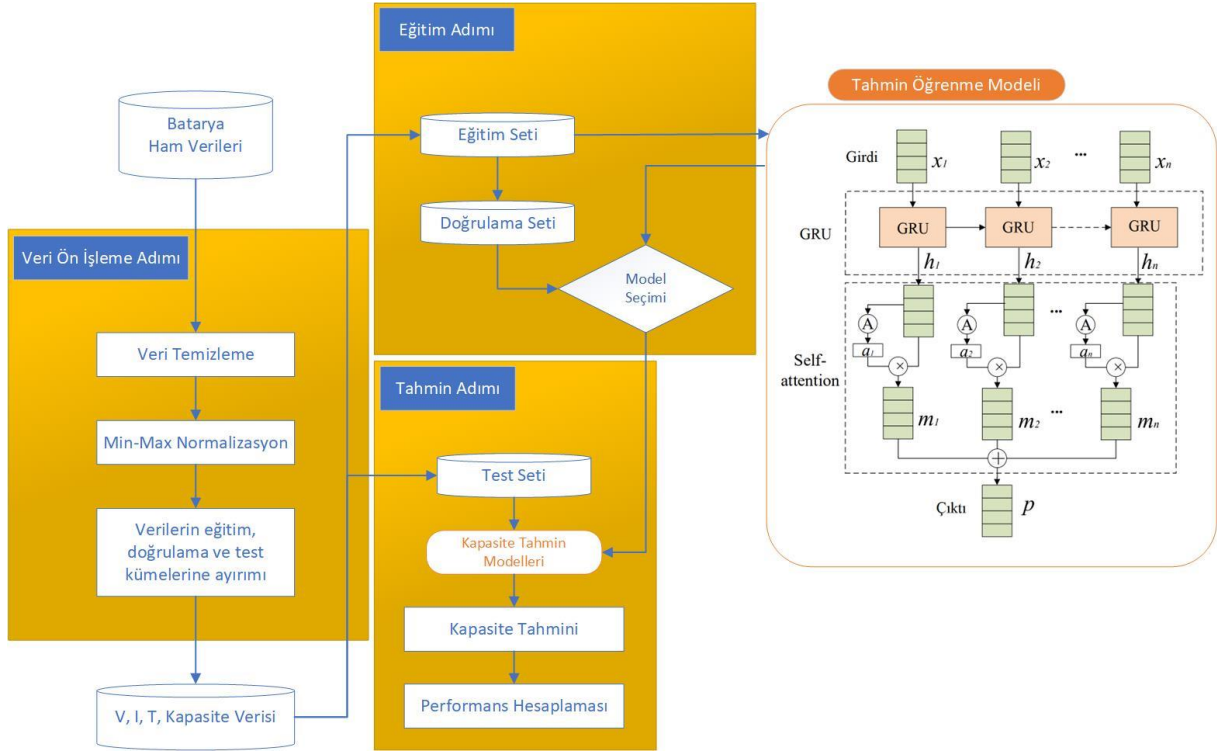
Burada C_0 nominal kapasitedir ve C_k k döngüsündeki ölçülen kapasitedir. Ayrıca, ölçülen kapasite nominal kapasitenin %80'inin altında olduğunda batarya ömrünün bittiğini ve bu durumda güvenilir performansın garanti edilemeyeceğini belirleriz. Bu durum otomotiv sektöründe elektrikli araç garantisi belirlenirken kullanılır.

3 Makine öğrenmesi tabanlı yaklaşımlar

3.1 Önerilen yapı

Şekil 3'te, GRU-AM'ye dayalı çok kanallı şarj profillerinden yararlanarak batarya kapasitesinin tahmin edilmesi için önerilen çerçeveye genel bir bakış sunulmaktadır. Bu çerçeve üç adımdan oluşur: veri ön işleme, eğitim ve tahmin. Veri ön işleme adımında veri temizleme ve min-max normalizasyon teknikleri uygulanarak anormal veriler kaldırılır. Eğitim adımında sırasıyla LSTM, GRU, BiLSTM ve GRU-AM'ye dayalı uygun bir model seçmek için eğitim ve doğrulama setleri kullanılır.

Tahmin adımında ise bir önceki adımda belirlenen kapasite tahmin modellerini kullanarak batarya kapasitesi tahmin edilir ve önerilen yöntemin performansı değerlendirilir.



Şekil 3. Önerilen kapasite tahmininin genel çerçevesi.

Tablo 1. NASA Prognostics Center of Excellence veri havuzunun bataryalarının özellikleri

Batarya Numarası	Şarj			Deşarj		Ortam Koşulları	
	Sabit Akım (A)	Üst Gerilim Limit (V)	Şarjı Kesme Akımı (mA)	Sabit Akım (A)	Deşarjı Kesme Gerilimi (V)	Ortam Sıcaklığı	Başlangıç Kapasiteleri (Ah)
Batarya 5	1.5	4.2	20	2	2.7	Oda Sıcaklığı	1.86
Batarya 6	1.5	4.2	20	2	2.5	Oda Sıcaklığı	2.04
Batarya 7	1.5	4.2	20	2	2.2	Oda Sıcaklığı	1.89
Batarya 18	1.5	4.2	20	2	2.5	Oda Sıcaklığı	1.86

3.2 Veri ön işleme


Batarya veri setini deneysel veri olarak kullanmadan önce, aykırı değerleri kaldıracak ve mevcut verileri güvence altına alacak veri ön işleme yapılır. Sonunda, Şekil 4'te olduğu gibi döngü başına bozulma özelliklerine sahip dört set batarya verisi elde edilmiş olur. Şekil 4'te deney için #5, #6, #7 ve #18 numaralı bataryalar seçilmiştir. Bataryaların genel özellikleri ve şarj/deşarj koşulları Tablo 1'de özetlenmiştir. Tahminde veri hassasiyeti ve karmaşıklığı nedeniyle tüm verilerin kullanılması verimli değildir. Batarya Yönetim Sisteminin (BMS) ayarına göre şarj işlemi sırasında çok sayıda veri noktası olmasına rağmen, şarj aralığı sırasında görünen değişiklikleri koruyan alt örneklenmiş verileri kullanırız. Önerilen modellerin girdileri çıkarılan özneliklerdir. Bunlar, ham batarya verilerinin tekdüze örneklenmesiyle elde edilir. Spesifik olarak, her biri 10 örnek içeren V, I, T şarj etme profillerini birleştirerek giriş

matrisini 30 boyutlu vektörler olarak yapılandırılır. Örnek sayısı, zamandaki belirgin değişiklikleri ve model karmaşıklığını dikkate alacak şekilde seçilir. Ek olarak, kısa zaman aralığında salınımı önlemek için örnekleme aralığı boyunca verilerin ortalaması alınır.

Min-max normalizasyon, ölçeklendirme faktörü dışında, verilerin orijinal dağılımını koruduğu ve daha iyi eğitim yapılabilmesine olanak sağladığı için kullanılır. Min-max normalizasyon, bütün verileri [0,1] aralığına taşır.

$$z_i^k = \frac{x_i^k - \min(x)}{\max(x) - \min(x)} \quad i \in \{1, \dots, n\} \quad (2)$$

Burada x , tüm şarj döngülerinin bir toplamıdır. Yani x_i^k ve n , döngü başına örnek sayısını temsil eder. Nihai tahmin sonuçlarını sunmadan önce denormalizasyon yapılır.



Şekil 4. Döngüye bağlı kapasite düşüşü

3.3 Uzun kısa dönemli bellek (Long Short-Term Memory)

Özyinelemeli Sinir Ağı (Recurrent Neural Network), bellekte yönlendirilmiş döngüler içeren ve özellikle sıralı verilerde üstün performans gösteren bir sinir ağıdır. Kaybolan gradyan sorunu nedeniyle, zaman serisi verileri uzun vadeli bağımlılığa sahip olduğunda temel RNN yapısı doğru sonuçtan uzaklaşabilirler. Bu nedenle, kaybolan gradyan problemini azaltmak için LSTM tasarlanmıştır. Ortak bir LSTM ünitesi bir hücre, bir giriş kapısı, bir çıkış kapısı ve bir unutma kapısı olmak üzere üç kapıdan oluşur. Hücre, değerleri rastgele zaman aralıklarında hatırlar ve bu üç kapı, hücrenin içine ve dışına bilgi akışını düzenler. LSTM, uzun vadeli bilgileri depolamak için dahili bir bellek hücresi durumunu tanımlar. Bellek hücresi durumu, dahili durum vektörünün hangi öğelerinin güncellenmesi, korunması veya silinmesi gerektiğini belirlemek için önceki çıkış ve sonraki girişle etkileşime girer.


3.4 Çift yönlü uzun kısa dönemli bellek (Bi-Directional Long Short-Term Memory)

BiLSTM sinir ağı zıt yönlerde iki LSTM sinir ağından oluşur ve bu sayede sıra ile ilgili problemlerde daha iyi performansa sahiptir. BiLSTM sinir ağı, verileri iki LSTM üzerinden zıt yönlerde ileri ve geri işleyebilir, böylece hem geçmiş hem de gelecek bilgileri kullanarak eğitilebilmiş olur.

3.5 Geçitli tekrarlayan birim (Gated Recurrent Units)

GRU'nun arkasındaki temel fikir, her zaman adımında ağız gizli durumunu seçici olarak güncellemek için geçit mekanizmalarını kullanmaktır. Geçit mekanizmaları, ağız içine ve dışına bilgi akışını kontrol etmek için kullanılır. GRU'nun sıfırlama kapısı ve güncelleme kapısı adı verilen iki geçit mekanizması vardır. Sıfırlama kapısı önceki gizli durumun ne kadarının unutulması gerektiğini belirlerken,

güncelleme kapısı gizli durumu güncellemek için yeni girişin ne kadarının kullanılması gerektiğini belirler. GRU'nun çıktısı, güncellenen gizli duruma göre hesaplanır. Aşağıda tipik GRU yapısı ve açıklamaları gösterilmektedir [13]:



Şekil 5. Tipik GRU Yapısı

Sıfırlama Kapısı:

$$r_t = \sum (W_r * [h_{t-1}, x_t]) \quad (3)$$

Güncelleme Kapısı:

$$z_t = \sum (W_z * [h_{t-1}, x_t]) \quad (4)$$

Aday Gizli Durum:

$$\hat{h}_t = \tanh(W_h * [r_t * h_{t-1}, x_t]) \quad (5)$$

Gizli Durum:

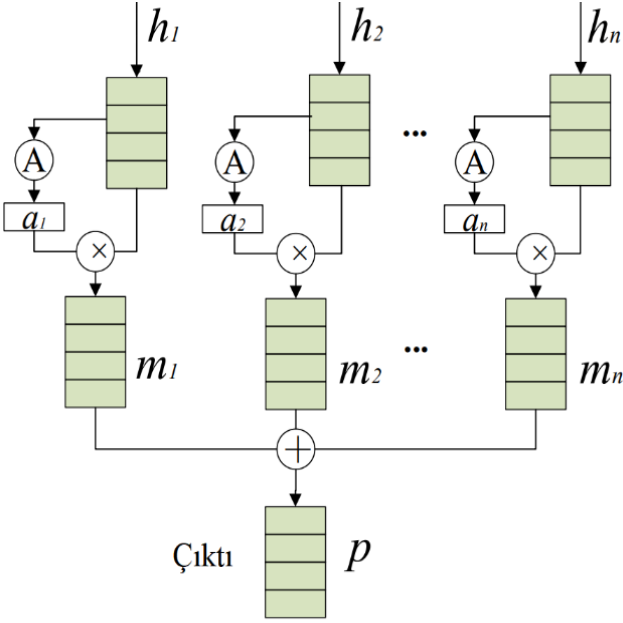
$$h_t = (1 - z_t) * h_{t-1} + z_t * \hat{h}_t \quad (6)$$

Burada W_r , W_z ve W_h öğrenilebilir ağırlık matrisleridir. x_t , t zaman adımındaki girdidir. h_{t-1} önceki gizli durumdur ve h_t mevcut gizli durumdur.

3.6 Öz dikkat mekanizması (Self Attention Layer)

Öz-dikkat mekanizması, modelin girdi verilerindeki uzun vadeli bağımlılıkları yakalamasına yardımcı olur, bu da görüntünün farklı bölümlerini birbiriyle ilişkilendirmeyi öğrenebileceği anlamına gelir. Önerilen model, bir GRU katmanından sonra öz dikkat katmanını ekleyerek, giriş görüntüsünün farklı bölgeleri arasındaki mekânsal ilişkileri dikkate alır ve özellik temsil yeteneklerini geliştirir. Aşağıdaki adımlar sırasıyla dikkat mekanizması içerisinde gerçekleşir:

1. Girişteki sorguları, anahtarları ve değerleri hesaplar.
2. Sorguları, anahtarları ve değerleri kullanarak ölçeklendirilmiş nokta çarpım dikkati hesaplar.
3. Alınan sonuçları birleştirir.
4. Birleştirilmiş sonuç üzerinde doğrusal bir dönüşüm gerçekleştirir.



Şekil 6. Öz-Dikkat Mekanizması girdiden çıktıya basit gösterim

Öz-Dikkat Mekanizması aşağıdaki şekilde tanımlanabilir [18];

$$\begin{aligned}
 e_t &= \sum (W_a \cdot h_t + b_a) \\
 a_t &= \text{softmax}(e_t) \\
 m_t &= a_t \cdot h_t \\
 p &= \sum_{t=1}^n m_t
 \end{aligned} \quad (8)$$

Burada h_t GRU modelinin çıktısı olan dikkat katmanının girdisidir. W_a eğitim sürecindeki ağırlıklı matrisleri, b_a ise sapmaları temsil etmektedir. a_t , Şekil 6'daki A'yı oluşturur, bu da dikkat matrisi anlamına gelir. p , dikkat katmanının çıktısıdır.

4 Model seçimi

Doğrulama setini kullanarak LSTM, BiLSTM, GRU ve GRU-AM yapıları test edilmiştir. Her öğrenme yöntemi MATLAB R2023b'de 3.49 GHz Apple Silicon M2 CPU ve 8 GB belleğe sahip cihaz üzerinde uygulanmıştır. Ortalama eğitim süresi 20 saniyeden azdır ve düzenleme için ayrılma süresi 0.5'tir.

Kayıp fonksiyonu olarak ortalama karesel hata (Mean Squared Error) kullanılmıştır ve Adam optimizasyonu 0.001 öğrenme oranıyla kullanılmıştır. Eğitim dönemleri (Training Epochs) 500 olarak ayarlanmıştır ve parti boyutu (Batch Size) 50 olarak kullanılmıştır. Tahmin doğruluğunu değerlendirmek için, ortalama mutlak yüzde hatası (MAPE) aşağıdaki gibi temsili bir hata indeksi olarak benimsenmiştir:

$$MAPE(\%) = \frac{100}{K} \sum_{k=1}^K \frac{|l(k) - \hat{l}(k)|}{l(k)} \quad (9)$$

Burada $l(k)$ gerçek kapasiteyi temsil eder, $\hat{l}(k)$ tahmin edilen kapasiteyi tahmin eder ve K döngü sayısını temsil eder. Ek olarak, ortalama mutlak hata (MAE) ve ortalama karekök hata (RMSE) şu şekilde hesaplanmıştır:

$$MAE = \frac{1}{K} \sum_{k=1}^K |l(k) - \hat{l}(k)| \quad (10)$$

$$RMSE = \sqrt{\frac{1}{K} \sum_{k=1}^K (l(k) - \hat{l}(k))^2} \quad (11)$$

5 Sonuçlar

Bu bölümde SOH tahmini için önerilen yöntemin performansı dört batarya (Batarya #5, Batarya #6, Batarya #7 ve Batarya #18) üzerinde test edilmiştir. Deney sonuçları Tablo 2-5'te gösterilmektedir. Bu tabloların daha kolay yorumlanabilmesi için Tablo 6'da tüm deney sonuçları tablolarının (Tablo 2-5) ortalaması alınarak toparlayıcı bir sonuç tablosu elde edilmiştir. Aynı parametre ayarları altında, dört bataryanın SOH tahmini için önerilen GRU-AM yöntemi, LSTM, GRU ve BiLSTM yöntemleri ile performans yönünden karşılaştırılmıştır. Tablo 2-5 ayrı ayrı değerlendirildiğinde görülebilmektedir ki sonuç hepsinde benzerdir. Tablo 7'de kıyaslanan her yönteme göre GRU-AM yönteminin ne kadar başarılı olduğu sırasıyla yüzdelik olarak tablo halinde gösterilmiştir. Tablo 7 oluşturulmuş Tablo 6'da elde edilmiş veriler göz önünde bulundurulmuş, GRU-AM değerleri ile LSTM, GRU ve BiLSTM değerleri arasındaki fark hesaplanarak yüzdelik biçimde yazılmıştır. LSTM, GRU ve BiLSTM'in zaman serisi tahmininde iyi bir performansa sahip olduğunu belirtmek gerekir. Bu nedenle önerilen yöntemle karşılaştırılmaları uygun olacaktır.

Şekil 7-10'dan görülebileceği gibi, öncelikle önerilen yöntemin tahmin sonuçları gerçek verilere daha yakındır ve döngü sayısı arttıkça, kapasiteler azaldıkça, tahmin sonuçları daha doğrudur. GRU-AM modeli dikkat mekanizması sayesinde, eğitim sürecinde iyileştirilir. Bu sayede kapasite tahmini nispeten düzgün olur. Bu, AM'nin tahmin performansını önemli ölçüde artırdığını göstermektedir. Şekil 7-10 ayrı ayrı değerlendirildiğinde göze çarpan BiLSTM'in yer yer gerçek değerden çok sapma yaşamasıdır. Bu durum BiLSTM'in hem gelecek hem de geçmiş bağımlılıkları sebebiyledir.

Tablo 6'da her batarya için elde edilmiş hata tahminlerinin ortalaması alınmış ve daha toparlayıcı bir sonuç elde edilmiştir. Tablo 6'da ki hata değerlerinin genel ortalaması gösteriyor ki genel başarı kıstas alındığında her hata değerinde, önerilen model en başarılı sonucu elde etmiştir. Dolayısıyla SOH tahmininde GRU-AM'nin LSTM, GRU ve BiLSTM'den daha doğru ve güvenilir olduğu kanıtlanmaktadır.

Tablo 2. Batarya #5 tahmin hataları

#5	Modeller	RMSE	MAE	MAPE (%)
1	LSTM	0.0457	0.0162	0.9951
2	GRU	0.0407	0.0159	0.9815
3	BiLSTM	0.0625	0.0164	0.9739
4	GRU-AM	0.0329	0.0136	0.8433

Tablo 3. Batarya #6 tahmin hataları


#6	Modeller	RMSE	MAE	MAPE (%)
1	LSTM	0.0375	0.0280	1.8820
2	GRU	0.0420	0.0319	2.1387
3	BiLSTM	0.0358	0.0267	1.7761
4	GRU-AM	0.0272	0.0191	1.2399

Tablo 4. Batarya #7 tahmin hataları

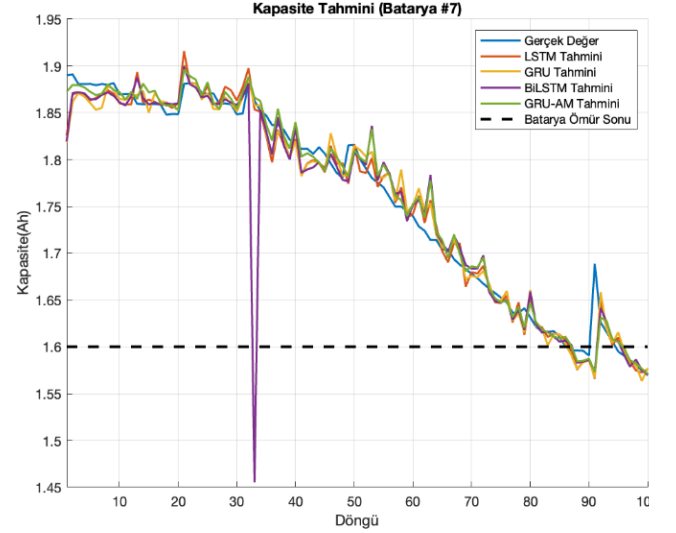
#7	Modeller	RMSE	MAE	MAPE (%)
1	LSTM	0.0197	0.0134	0.8132
2	GRU	0.0196	0.0137	0.8321
3	BiLSTM	0.0174	0.0116	0.7026
4	GRU-AM	0.0281	0.0101	0.5964

Tablo 5. Batarya #18 tahmin hataları

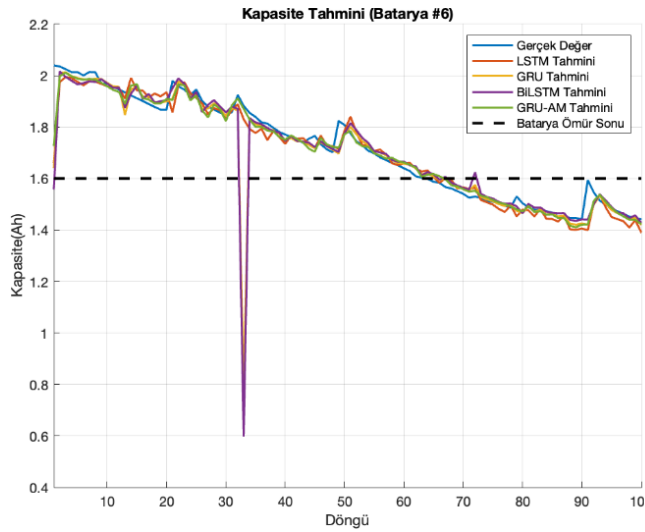
#18	Modeller	RMSE	MAE	MAPE (%)
1	LSTM	0.0758	0.0297	1.8382
2	GRU	0.0401	0.0189	1.1902
3	BiLSTM	0.0371	0.0187	1.1844
4	GRU-AM	0.0367	0.0175	1.1008



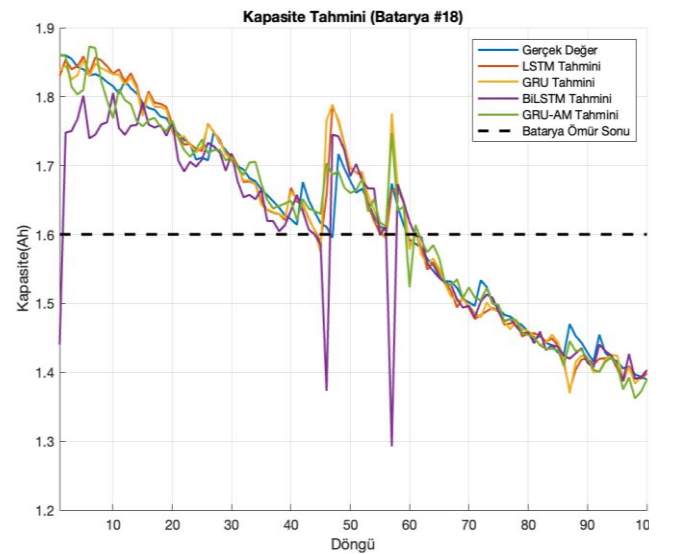
Şekil 7. Batarya #5 kapasite tahmini



Şekil 9. Batarya #7 kapasite tahmini



Şekil 8. Batarya #6 kapasite tahmini



Şekil 10. Batarya #18 kapasite tahmini

Tablo 6. Batarya #18 tahmin hataları

Ort.	Modeller	RMSE	MAE	MAPE (%)
1	LSTM	0.0336	0.0190	1.2700
2	GRU	0.0286	0.0178	1.1981
3	BiLSTM	0.0300	0.0170	1.1369
4	GRU-AM	0.0249	0.0140	0.9398

Tablo 7. Önerilen GRU-AM yönteminin diğer yöntemlere kıyasla yüzdelik başarısı

Vs	Modeller	RMSE	MAE	MAPE
1	LSTM vs GRU-AM	34.60%	35.54%	35.14%
2	GRU vs GRU-AM	14.64%	26.96%	27.48%
3	BiLSTM vs GRU-AM	20.16%	21.25%	20.97%

Önerilen modelin kıyaslanmakta olduğu modellere göre ne kadarlık bir hata tahmini iyileştirmesi yapmış olduğu **Tablo 7**'de görülmektedir. Bu tablo göstermektedir ki önerilen yöntem (GRU-AM) kıyaslandığı yöntemlere göre RMSE'de %14 ila %35, MAE'de %21 ila %36 ve MAPE'de %21 ila %35'lik iyileştirme göstermiştir. BiLSTM hem gelecek hem de geçmiş bağımlılıkları sebebiyle, LSTM ve GRU ise Dikkat Mekanizmasına sahip olmayışlarıyla önerilen yöntemin gerisinde kalmışlardır.

6 Değerlendirmeler

Bu yazıda, lityum iyon bataryalar için Dikkat Mekanizmalı Geçitli Tekrarlayan Birim yöntemi ile bir kapasite tahmin çerçevesi önerilmiştir. Bu yöntem önerisi problemimizin zaman serisi problemi olmasına dayandırılarak seçilmiştir. Zaman serisi problemlerinde başarılı olan hem Geçitli Tekrarlayan Birim hem de Dikkat Mekanizması birlikte kullanılarak daha başarılı bir yöntem geliştirilmiştir. NASA'nın lityum iyon batarya veri setini kullanarak tahmin sonuçları hata indeksleri ve döngü başına kapasite farkı perspektifinden de analiz edilmiştir.

Özellikle önerilen GRU-AM yönteminin; LSTM, GRU ve BiLSTM'e kıyasla sırasıyla %35, %27 ve %20'ye kadar MAPE iyileştirmesi ile mevcut yöntemlerden daha iyi performans verdiği gösterilmiştir. Son olarak dikkat mekanizmalı geçitli tekrarlayan birim yöntemi sonraki çalışmalarda batarya yönetim sistemine entegre edilip gerçek araçlarda test edilerek bataryanın kalan faydalı ömrü tespiti için kullanılabilir.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %13

Kaynaklar

[1] L. Zhang, T. Ji, S. Yu, and G. Liu, Accurate prediction approach of soh for lithium-ion batteries based on LSTM method. *Batteries*, 9 (3), 177, 2023. <https://doi.org/10.3390/batteries9030177>

- [2] E. İ. Tezde and H. İ. Okumuş, Batarya Modelleri ve Şarj Durumu (SoC) Belirleme. *EMO Bilimsel Dergisi*, 8 (1), 21–25, 2018.
- [3] E. Zio, Prognostics and Health Management (PHM): Where are we and where do we (need to) go in theory and Practice. *Reliability Engineering; System Safety*, 218, 108119, 2022. <http://dx.doi.org/10.1016/j.res.2021.108119>
- [4] ISO 13381-1:2004, Condition Monitoring and Diagnostics of Machines Prognostics Part1: General Guidelines. International Standards Organisation, Geneva, Switzerland, Nov. 2004.
- [5] T. Sarıkurt and A. Balıkcı, A relative capacity estimation method for lithium batteries used in electric vehicle applications. *Pamukkale University Journal of Engineering Sciences*, 24 (5), 809–816, 2018. <http://doi:10.5505/pajes.2018.58224>
- [6] E. Çavuş and İ. Sancaktar, Batarya sağlık durumunun makine öğrenmesi ile kestirimi. *NOHU J. Eng. Sci.*, 11 (3), 601–610, 2022, <https://doi.org/10.28948/ngumuh.1112985>
- [7] Y. Jiang, Y. Chen, F. Yang, and W. Peng, State of health estimation of lithium-ion battery with automatic feature extraction and self-attention learning mechanism. *Journal of Power Sources*, 556, 232466, 2023. <https://doi.org/10.1016/j.est.2023.109690>
- [8] Time Series forecasting methods, Techniques & Models, InfluxData, <https://www.influxdata.com/time-series-forecasting-methods/>, Accessed 3 December 2023.
- [9] Y. Choi, S. Ryu, K. Park, and H. Kim, Machine learning-based lithium-ion battery capacity estimation exploiting multi-channel charging profiles. *IEEE Access*, 7, 75143–75152, 2019. <https://doi.org/10.1002/er.7160>
- [10] I. Jorge, T. Mesbahi, A. Samet, and R. Boné, Time series feature extraction for lithium-ion batteries state-of-health prediction. *Journal of Energy Storage*, 59, 106436, 2023. <https://doi.org/10.1016/j.est.2022.106436>
- [11] J. Zhang, J. Hou, and Z. Zhang, Online state-of-health estimation for the lithium-ion battery based on an LSTM neural network with attention mechanism. 2020 Chinese Control and Decision Conference (CCDC), 2020. <https://doi:10.1109/ccdc49329.2020.9164547>
- [12] Y. Guo, D. Yang, K. Zhao, and K. Wang, State of Health Estimation for lithium-ion battery based on bi-directional long short-term memory neural network and attention mechanism. *Energy Reports*, 8, 208–215, 2022. <https://doi:10.1016/j.egy.2022.10.128>
- [13] Gated Recurrent Unit Networks. <https://www.geeksforgeeks.org/gated-recurrent-unit-networks/amp>, Accessed 3 December 2023.
- [14] Prognostics Center of Excellence Data Set Repository, NASA. <https://www.nasa.gov/intelligent-systems-division/discovery-and-systems-health/pcoe/pcoe-data-set-repository/>, Accessed 3 December 2023.

- [15] L. He et al., Battery-aware Mobile Data Service. IEEE Transactions on Mobile Computing, 16 (6), 1544–1558, 2017. <http://doi:10.1109/tmc.2016.2597842>
- [16] M. Rashid and A. Gupta, Effect of relaxation periods over cycling performance of a Li-Ion Battery. Journal of The Electrochemical Society, 162 (2), 2015. <https://doi:10.1149/2.0201502jes>
- [17] J. Wu, C. Zhang, and Z. Chen, An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks. Applied Energy, 173, 134–140, 2016. <https://doi.org/10.1016/j.apenergy.2016.04.057>
- [18] L. Yang, G. Liu, Y. Dai, J. Wang, and J. Zhai, Detecting stealthy domain generation algorithms using heterogeneous deep neural network framework. IEEE Access, 8, 82876–82889, 2020. <https://doi:10.1109/access.2020.2988877>

