

Elektrikli Araçlarda Otonom Batarya Yönetim Sistemi Literatür İncelemesi

Autonomous Battery Management System in Electric Vehicles Literature Review

Metin Yılmaz^{1,2}, Eyüp Çınar^{1,2}, Ahmet Yazıcı^{1,2}

¹Bilgisayar Mühendisliği Bölümü
Eskişehir Osmangazi Üniversitesi
503020211005@ogrenci.ogu.edu.tr, eyupcinar@ogu.edu.tr, ayazici@ogu.edu.tr
²Center of Intelligent Systems Applications Research (CISAR)
Eskişehir Osmangazi Üniversitesi

Özet

Elektrikli araçlar hem dünya genelinde hem de ülkemizde giderek daha yaygın hale gelmektedir. Bu araçlarda, batarya en kritik bileşenlerdir. Akıllı bir batarya yönetim sistemi (Battery Management System - BMS) için doğru prognostik ve sağlık yönetimi (Prognostics and Health Management - PHM) büyük önem taşır. PHM ve BMS, elektrikli araçların güvenliği, verimliliği ve batarya ömrü açısından kritik bir rol oynamaktadır. Bu literatür incelemesi, elektrikli araçlar için PHM ve BMS konularının önemine vurgu yapmaktadır. Lityum-iyon (Li-ion) bataryaların hala en uygun seçeneklerden biridir, ancak batarya ömrü gibi bazı zorluklarla karşılaşılabilir. Bu nedenle, doğru batarya şarj durumu (State of Charge - SoC) ve bataryanın sağlık durumu (State of Health - SoH) tahminleriyle bir BMS, batarya ömrünü uzatmak ve güvenliği sağlamak için gereklidir. Bu çalışma, elektrikli araçlar için PHM ve BMS konularında gelecekteki araştırma gündemine yönelik analitik bir incelemedir. Batarya prognostiğinin önemine vurgu yapılarak, elektrikli araçların sağlıklı çalışması için daha fazla araştırmanın yapılması gerektiği vurgulanmaktadır.

Anahtar Kelimeler: Elektrikli Araç, Batarya Yönetim Sistemi, Batarya Sağlık Yönetimi, Prognostik ve Sağlık Yönetimi

Abstract

Electric vehicles are becoming increasingly prevalent worldwide, including in our country. In these vehicles, batteries are the most critical components. Accurate Prognostics and Health Management (PHM) are of great importance for an intelligent Battery Management System (BMS). PHM and BMS play a critical role in the safety, efficiency, and battery life of electric vehicles. This literature review emphasizes the significance of PHM and BMS in the context of electric vehicles. Lithium-ion (Li-ion) batteries remain one of the most suitable options, despite facing challenges such as battery life. Therefore, a BMS with accurate State of Charge (SoC) and State of Health (SoH) estimations are necessary to extend battery life and ensure safety. This study presents an analytical review of PHM and BMS for future research agendas in electric vehicles, highlighting the importance of battery prognostics and emphasizing the need for further research to ensure the healthy operation of electric vehicles.

Keywords: Electric Vehicle, Battery Management System, Battery Health Management, Prognostics and Health Management

1 Giriş

Dünyada gün geçtikte yaygınlaşan elektrikli araçlar (EA), ulusal elektrikli otomobil TOGG'un da piyasaya çıkmasıyla ülkemizde de yaygınlaşmaya başlamıştır. Bu araçların insan hayatına daha fazla girmesi ve kullanımlarının artmasıyla birlikte araçların izlenmesi, elektrikli araç özelindeki donanımsal aksamaların güvenilirliği (reliability) ve prognostiği (tahmin) de önem arz etmektedir. Benzinli araçlara göre farklı arıza modları ve prognostik ihtiyaçları olabilen elektrikli araçlar, en son teknoloji durum izleme ve tahminleme metodlarının entegrasyonu ile zenginleştirilerek günlük hayattaki yerlerini almalıdırlar. Elektrik enerjisiyle çalışan araçlar, batarya tabanlı bir güç kaynağı kullanır. Bu araçlar arasında otonom araçlar ve robotlar gibi çeşitli teknolojik sistemler bulunur. Batarya içermeleri nedeniyle, bu araçlar elektrikli araçlar sınıfına dahil edilebilmektedir.

Elektrikli araçların durum izleme ve prognostik (condition monitoring and prognostics) açıdan en kritik bileşeni batarya sistemleridir. Batarya teknolojisindeki gelişmeler, elektrikli araçların verimliliklerini de yönlendirmektedir [1]. Verimlilikleri nedeniyle Li-ion bataryalar, EA'larda enerji kaynağı olarak yaygın bir şekilde kullanıldığı bilinmektedir [2], [3], [4]. Bu nedenle de hem akademik hem de endüstriyel alanda büyük ilgi görmektedir. EA endüstrisinin daha da gelişmesiyle birlikte, batarya performansı arızalarını mümkün olduğunca önlemek veya önceden uyararak için EV bataryalarının teşhis ve sağlık yönetimi PHM sisteminin güvenilirliği işletmelerde fazlasıyla ilgi görmüştür [5], [6]. Batarya PHM'si, bataryanın sağlık durumunun SoH doğru tahmin edilmesi ve kalan kullanım ömrünün (Remaining Useful Life - RUL) tahmini ile bataryanın güvenli ve verimli çalışmasının sağlanması için gereklidir [7].

Elektrikli araçlarda akıllı bir batarya yönetim sistemi BMS için PHM gereklidir, çünkü güvenlik tehlikelerinden kaçınmak ve kullanım ömrünü uzatmak önemlidir [8], [9]. Batarya SoH'nin doğru bir şekilde tahmin edilmesi ve RUL tahmini, batarya PHM'sinin iki önemli işlevidir. Bakım maliyetlerini en aza indirmek ve batarya ömrünü en üst düzeye çıkarmak, BMS'nin optimum çalışması için önemlidir ve güvenlik, verimlilik ve güvenilirlik gibi faktörlere katkıda bulunmaktadır. Li-ion

bataryaların elektriksel performansı önemli ölçüde iyileşmiş olsa da eskimeyle birlikte kapasite düşüşlerinin üstesinden gelmek hala mümkün değildir [4].

Li-ion bataryalar için etkili bir BMS kullanmak, bataryanın güvenli bir şekilde çalışmasını, fiziksel hasarın önlenmesini ve termal bozulma ve hücre dengesizliği ile başa çıkmayı sağlar. BMS ayrıca, bataryanın farklı durumlarını ölçebilen ve değerlendirebilen, batarya şarj durumu SoC ve SoH doğruluğu için verileri kontrol eden ve güncelleyen, arızaları tespit eden, batarya voltajını eşitleyen ve aşırı şarj/aşırı deşarjı önleyen bir batarya yönetim sistemi sunar [10].

EA'lar için tekrarlanan şarj/deşarj işlemleriyle şarj kapasitesi azaldığından, batarya ömrü gibi hala çözülmesi gereken bazı zorluklar vardır. En dikkate değer olanı ise, SoC tahmini ve EV sürücülerinin batarya SoH durumudur. Doğru SoC ve SoH tahminleriyle bir batarya yönetim sistemi, bataryadaki her bir hücrenin aşırı şarj olmasını veya aşırı deşarj olmasını önleyebilir ve tüm batarya ömrünü uzatabilir [4]. Güvenlik tehlikelerinden kaçınmak ve kullanım ömrünü uzatmak için akıllı bir BMS için PHM gereklidir [6]. Batarya SoH ve RUL tahmini, bataryanın PHM'sinin iki önemli işlevidir ve bakım maliyetlerini en aza indirip, batarya ömrünü en üst düzeye çıkararak BMS'nin optimum çalışmasına katkıda bulunur [7]. Sağlıklı durum, batarya sisteminin kararlılığını, güvenilirliğini, güvenliğini ve hatta tüm EA'yı doğrudan etkileyebilir.

Bu çalışma, elektrikli araçlar için PHM ve BMS için analitik bir inceleme yaparak fırsat ve zorluklara bir giriş sunmakta ve batarya sağlığı yönetimi konusunda geleceğe yönelik bir araştırma gündemi sunmaktadır. İnceleme yayınında sunulan sorunlarla birlikte, daha fazla araştırma yapılması önemlidir.

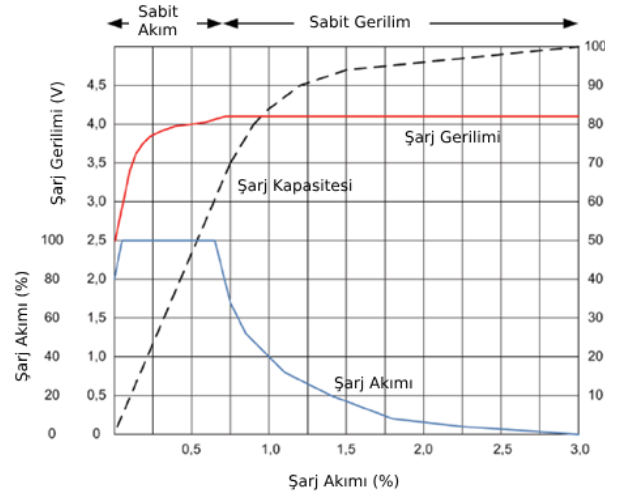
Yayın dağılımı şu şekildedir, birinci bölümde elektrik araçlar prognostik ve batarya prognostığı ile ilgili literatür çalışmaları incelenmiştir. İkinci bölümde ise batarya sağlığıyla ilgili sorunlar ve zorluklar, üçüncü bölümde batarya prognoz (öntanı) kavramları, dördüncü bölümde batarya yönetim sistemleri ve prognostik alanında yapılan çalışmalar, beşinde bölümde ise batarya alanında paylaşılan veri setleri karşılaştırmalı olarak gösterilmiştir. Son bölümde çalışmanın katkıları ve daha sonra yapılabilecek çalışmalar hakkında öneriler verilmiştir.

2 Elektrikli Araçlarda Prognostik ve Batarya Prognostığı

Li-ion bataryalar, elektrikli araçların enerji kaynağı olarak kullanılmaları için en uygun seçeneklerden biridir. Ancak, bu bataryaların ömrü sınırlıdır ve zamanla performansları azalmaktadır. Bu nedenle, batarya prognostığı elektrikli araçların sağlıklı çalışması için hayati öneme sahiptir. Batarya prognostığı, batarya ömrü, güvenilirliği ve performansını önceden tahmin etmek için kullanılan bir tekniktir. Bu teknik, bataryanın tam kapasiteye ulaşması, güvenli bir şekilde kullanılması ve araç sahiplerine uzun vadeli maliyet tasarrufu sağlaması için gereklidir. Bu nedenle, elektrikli araçların yaygınlaşması ile birlikte batarya prognostığı konusu, araştırmacıların ve endüstrinin öncelikli konularından biri haline gelmiştir.

Bataryaların şarj profilleri ve zamanları elektrikli araçlar için oldukça önemlidir. Elektrikli araçlarda kullanılan Li-ion bataryaların şarj edilmesi için üç farklı yöntem kullanılır [4]. Sabit voltaj yöntemi (Constant Voltage - CV), bataryanın şarj edilmesi için sabit bir voltaj kullanırken, sabit akım yöntemi

(Constant Current - CC), bataryanın şarj edilmesi için sabit bir akım kullanır ve bataryanın voltajı zamanla yükselir. Hızlı şarj yöntemi ise sabit akım ve sabit voltaj (Constant Current Constant Voltage - CCCV) yöntemlerinin bir kombinasyonudur ve Şekil 1.'de gösterildiği gibi hızlı şarj prosedürü, özellikle zaman kazandıran özelliği nedeniyle Li-ion bataryalar için yaygın olarak kullanılır [4].



Şekil 1. Bir Li-ion batarya için sabit akım, sabit voltaj şarj profili [4].

2.1 Batarya Sağlığıyla İlgili Sorunlar ve Zorluklar

Bataryalar için prognostik teknolojilerin geliştirilmesi ve uygulanması, bataryalarda meydana gelen elektrik-kimyasal süreçlerin doğal karmaşıklığı nedeniyle zorlu ve karmaşıktır [11]. Bu zorluklardan bazıları şunlardır:

Batarya eskimesi sorunları: Yaşlanma süreçleri, elektrolit, anot ve katodun özelliklerinde ve bataryada kullanılan bileşenlerin yapısındaki geri dönüşü olmayan değişikliklerdir. Batarya eskime süreci iki kategoriye ayrılabilir; izlenmesi mümkün olan zaman içinde kademeli bozulmayı içeren eskime süreçleri ve büyük bir sorun veya batarya performansında hızlı değişiklikler meydana gelene kadar herhangi bir özel modu veya gözlemlenebilir işareti olmayan eskime süreçleridir [12].

Bozulma faktörleri: Bu alandaki otomotiv uygulamalarındaki en önemli bozulma faktörleri; çevre sıcaklığı, boşaltma akımı oranı, şarj oranı (hızlı şarj), deşarj derinliği, tam şarj döngüleri arasındaki zaman aralıkları şeklinde tanımlanabilir [13], [14].

Batarya sağlığını izlemenin zorlukları: Batarya davranışını izlemenin en etkili ve basit yöntemi batarya voltajını, akımı, sıcaklığı ve bazı durumlarda basıncı gözlemlemeye dayanır [15]. Bu değişkenlerden bazıları, cihazın ana işlevselliği kesintiye uğramadan batarya ile çalışırken ölçülebilir; buna çevrimiçi ölçüm denir.

Batarya sağlığını izlemek için özelliklerin değerlendirilmesi: Bir bataryadan elde edilen ham verilerden birçok özellik çıkarılabilir. En kullanışlı özellikler, batarya performansı sırasında göze çarpan eğilimleri temsil etmelidir ve bataryanın içindeki elektrokimyasal reaksiyonlara dayalı bozulmanın fiziksel nedenleriyle ilişkilendirilebilir [16].

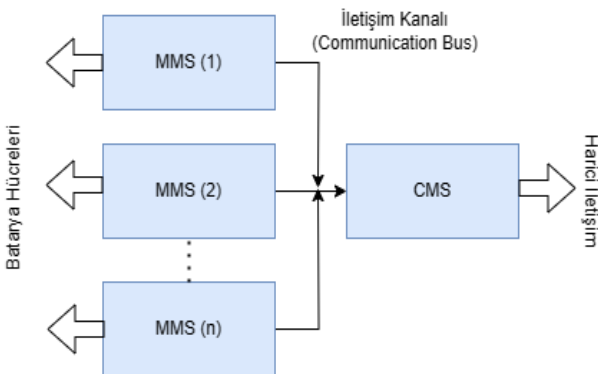
PHM, arıza olaylarını belirlemek ve sistem riskini azaltmak için gerçek yaşam döngüsü koşulları altında bileşen veya sistem güvenilirliğini değerlendirmeye yönelik araç ve tekniklerden

oluşur [11]. Batarya RUL'u, potansiyel batarya arıza süresi hakkında değerli bir tahmin sağlar. Bu, enerji depolama sistemlerinin güvenilirlik değerlendirmesi için önemlidir [7]. Bu nedenle, batarya SoH ve batarya RUL değerinin doğru tahmini, batarya çalışması için çok önemlidir.

2.2 Batarya Prognostik Kavramları

Elektrikli araçların popülaritesindeki artış, bu araçların güç kaynaklarına olan bağımlılıklarından kaynaklanan yük artışıyla birlikte elektrik şebekelerini zorlayabilir. Bu nedenle, EA'ların güç kaynaklarını tamamlamanın yenilikçi yollarına ihtiyaç vardır. Ancak, Li-ion bataryalar, yüksek kapasitelere rağmen güvenlik, dayanıklılık, tekdüzellik ve maliyetle ilgili sorunlar nedeniyle büyük seri/paralel bağlanma sayıları sınırlar. Batarya ömrünün hücre dengelemesi ile uzatılabileceği düşünülse de bunu gerçekleştirmek için zorluklarla karşılaşmaktadır. Bu nedenle, Li-ion bataryaların güvenliği ve güvenilirliği, batarya sağlık sistemlerinin etkin kontrol ve yönetimini gerektirir. Çok sayıda araştırma, teknolojinin uygulamalarda hatalara neden olmaması ve başarısızlıklarının felaketlere yol açmaması için yapılır [17].

BMS: Bir batarya takımının izlenmesi ve yönetimi için tasarlanmış, yazılım algoritmaları, sensörler, kontrolörler, iletişim ve hesaplama donanımının bir kombinasyonudur. BMS, bataryanın SoH, SoC ve RUL gibi bilgileri belirler. Ayrıca, bataryanın güvenli, verimli ve zararsız bir şekilde çalıştırılmasını sağlamak için çalışır [18], [19]. Birçok endüstriyel uygulamada, Li-ion bataryaları kullanan ana güç kaynakları için BMS'nin oldukça yararlı olduğu kanıtlanmıştır. BMS, batarya ömrü boyunca SoH, SoC, RUL tahminlerini izler ve gerçekleştirir. Bu nedenle, Li-ion bataryalar için BMS, bakım optimizasyonu desteği sağlamak için teşhis ve/veya prognostik temelinde bakım, lojistik ve sistem yapılandırma faaliyetlerini akıllıca gerçekleştirmeye yönelik bir karar sürecidir [20]. Şekil 2'te gösterildiği gibi elektrikli araçlar için BMS oluşturmak için modüler bir yaklaşımın uygun olduğu görülmüştür [21]. Her Li-ion batarya modülü, bir modüler yönetim sistemi (Modular Management System - MMS) tarafından kontrol edilir ve yönetilir. Tüm MMS'ler merkezi bir yönetim sistemi (Central Management System - CMS) tarafından kontrol edilir. BMS modülleri bağımsız bir modda çalıştığı için veri alışverişi gereklidir. BMS içinde veri alışverişi için kontrol edilebilir bir alıcı-verici gereklidir. Bu mimari esnek, ölçeklenebilir ve yaygın olarak kabul görmüştür.



Şekil 2. Batarya yönetim sisteminin modüler konsepti

Durum İzleme (Condition Monitoring - CM): Bir BMS'nin ilk ana görevi, batarya voltajı ve akımı, hücre voltajı, sıcaklık, yalıtım ve kilit (interlock) gibi bataryanın ölçülebilir durumlarını izlemektir [22]. Batarya sağlık bilgileri, belirli profillerdeki cihazların sağlığını veya durumunu gösteren

fiziksel parametreleri izleyen bir prosedür kullanılarak düzenli aralıklarla toplanır. Sıcaklık ve titreşim gibi hem dahili hem de harici parametreler bataryanın durumunu etkileyebilir. Literatür, titreşim yükünün ve sıcaklığın batarya performansını etkileyerek hücre kapasitesinde önemli azalmalara ve bozulmalara yol açtığını göstermektedir [23]. Aşırı voltaj veya aşırı ısınma gibi herhangi bir anormal durum tespit edilirse, BMS kullanıcıyı bilgilendirmeli ve önceden belirlenmiş bir düzeltici önlem almalıdır. Bu işlemlere ek olarak BMS, sistem sıcaklığını da izler ve daha iyi bir enerji tüketim sistemi sağlamak için bireysel bileşenler ve kullanıcılarla iletişim kurar [24].

RUL: Bir bataryanın çalışma gereksinimlerini karşılayabileceği kalan süre veya şarj döngüsü sayısıdır [25], [26]. RUL, azaltılmış maliyetler, geliştirilmiş doğruluk, güvenilirlik ve arızalardan kaçınma taleplerini karşılamak için araştırma ve üretim araçlarında BMS büyük önem vermiştir. RUL Eşitlik 1'deki gibi hesaplanabilir [20]:

$$RUL = T_f - T_c \quad (1)$$

Burada T_f , bozulma tespit edildiğinde arıza süresinin rastgele bir değişkenidir ve T_c , tahmin edilen sinyalin arıza süresini bir miktar geçtiği zamandır.

SoC: Kullanılabilir kapasiteyi temsil eder ve performansı optimize etmek ve batarya ömrünü uzatmak için karşılanması gereken en önemli koşullardan biridir [25].

Batarya SoC, maksimum kapasitenin yüzdesi olarak ifade edilen mevcut batarya kapasitesidir. SoC, çalışma akımı, sıcaklık ve voltaj gibi koşullara dayalı olarak tahmin edilir [27]. Batarya SoC, tam olarak şarj edildiğinde sahip olduğu enerjiye kıyasla bir hücrede kalan enerji miktarını tahmin eder ve kullanıcıya bir bataryanın şarj edilmesi gerekmeden önce ne kadar süre dayanacağına dair bir gösterge verir. SoC, zaman içinde batarya kapasitesindeki değişikliği belirlemek için geçerli entegrasyon kullanılarak tipik olarak hesaplanır ve SoC basitçe Eşitlik 2'deki şekilde ifade edilir [11]:

$$SoC(t) = \frac{\int_{t_0}^t I_b(\tau) d\tau}{Q_0} \times 100\% \quad (2)$$

Burada, şarj akımı olarak $I_b(t)$ ile tamamen boşalmış bir bataryaya iletilen şarj Q_0 'ın t zamanındaki batarya kapasitesi olduğu şarj olarak ifade edilir.

SoH: Batarya RUL ile SoH arasında ayırım yapmak önemlidir. Batarya ömrü, batarya tipi, malzemesi ve batarya üreticisinin destekleyebileceği döngülerin standart kullanımı ile tanımlanır. Kullanılmış bir bataryanın aynı türden yeni bir batarya ile karşılaştırıldığında beyan edilen performansını ve sağlık durumunu tanımlayan kavram, SoH olarak adlandırılır [11]. Batarya performansının kademeli olarak bozulması, kapasiteyi azaltan ve kalan kullanım ömrünü kısaltan geri dönüşü olmayan kimyasal reaksiyonlardan kaynaklanır. Akım ve zamanı ölçerek bir SoC tanımlamak mümkün olsa da SoH için sabit bir tanım yoktur ve her üreticinin kendi tanımı vardır. SoH'yi belirlemek için bataryanın kapasite ve iç direnç gibi çeşitli özellikleri kullanılabilir. Ancak bu kesin bir ölçümden ziyade bir değerlendirme ve tahmindir [28]. SoH; mevcut gerçek kapasitenin nominal kapasiteye oranıdır. SoH Eşitlik 3'teki şekilde gösterilebilir [6]:

$$SoH = \frac{C_t}{C_0} \times 100 \quad (3)$$

Burada C_t mevcut maksimum kullanılabilir kapasitedir ve C_0 bataryanın çalışmaya başladığı andaki kapasiteyi temsil eder.

Artımlı Kapasite (Incremental Capacity - IC): Şarj işlemi sırasında belirli bir voltaj adımı için kapasite artışı olarak tanımlanır ve Eşitlik 4'teki şekilde ifade edilir [6]:

$$IC = \frac{dQ}{dV} = \frac{I \cdot dt}{dV} \quad (4)$$

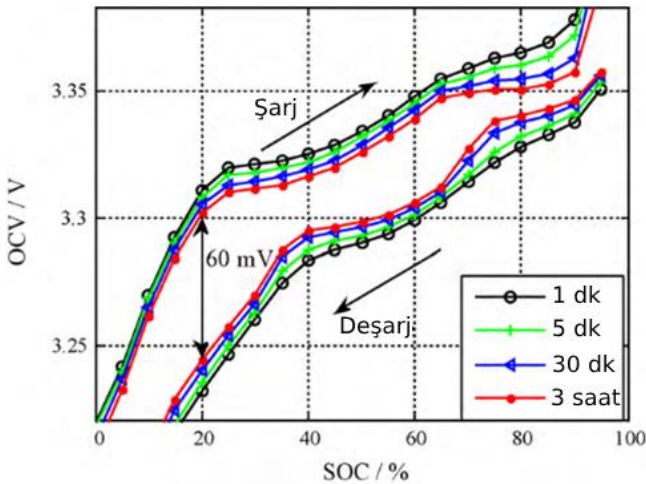
Burada I şarj akımı, dt örnekleme zaman aralığı, dV voltaj adımı olarak ifade edilir.

Ortalama Karekök Sapması (Root-Mean-Square Error - RMSE): SoH tahmin sonuçlarının RMSE'si hedeflerden biri olarak belirlenmiştir. RMSE'nin ifadesi Eşitlik 5'teki şekilde verilir [6]:

$$RMSE = \sqrt{\frac{1}{m} \sum_{j=1}^m (SOH_j - \hat{SOH}_j)^2} \quad (5)$$

Burada SOH_j ve \hat{SOH}_j , sırasıyla gerçek SoH ve tahmini SoH'dir; m doğrulama için eleman numarasıdır.

Açık devre voltajı (Open Circuit Voltage - OCV): Bir diğer SoC tahmin yöntemi, bataryanın OCV'sini ölçmektir. Bu, SoC ve OCV arasındaki statik ilişkiye dayanan basit bir yöntemdir [21]. Bununla birlikte, SoC ve OCV arasındaki ilişki batarya malzemeleri arasında değişiklik gösterdiğinden, bu yaklaşım belirli batarya türleri ile sınırlıdır [23]. Şekil 3'te görülebileceği gibi, bataryanın histerezi, batarya boşaldığında düşük OCV'ye ve batarya şarj edildiğinde yüksek OCV'ye neden olduğundan dikkate alınmalıdır [29].




Şekil 3. LiFePO4 bazlı bataryaların her adımda çeşitli dinlenme sürelerinden sonra ölçülen akım yönüne bağlı OCV eğrileri [29]

2.3 Batarya Yönetim Sistemleri ve Prognostik Alanında Yapılan Çalışmalar

Li-ion bataryalar, yüksek verimlilik, daha düşük hacim, küçük ağırlık, sıcaklık hassasiyeti ve bakım gibi avantajlar nedeniyle umut verici teknolojilerden biridir [30], [31]. Bu bataryalar, taşınabilir elektronik cihazlar, elektrikli araçlar, havacılık sistemleri ve yenilenebilir enerji kaynakları için güç depolama gibi birçok uygulamada parlak bir geleceğe sahiptir [32]. BMS, batarya ile elektrikli araçlar arasında bir bağlayıcı

görevi gördüğü için Li-ion bataryalar için RUL'un tahmininde önemli bir rol oynar. BMS'nin ana hedefleri, batarya sistemi hasarını önlemek, batarya ömrünü tahmin etmek ve artırmak ve batarya sisteminin doğru ve güvenilir bir çalışma koşulunda tutmaktır [33]. BMS, yazılım algoritmaları ile sensörler, kontrolörler, iletişim ve hesaplama donanımının bir kombinasyonudur [34].

Batarya yönetim sistemleri ve prognostik için çeşitli yöntemler bulunmaktadır. Yük akımları, uç gerilimleri ve yüzey sıcaklıkları gibi ölçülebilir değişkenlere dayalı bu yöntemleri Şekil 4'te gösterdiği gibi temel olarak aşağıdaki üç kategoride sınıflandırılabilir [7].



Şekil 4. Prognostik yöntemler

Deneysel Yöntemler: Bu yöntemler, batarya ile çalışmanın tarihsel deneysel verilerine ve bataryanın bozulmasının ana nedenleri hakkındaki önceki bilgilere bağlıdır.

Model Tabanlı Yöntemler: Deneysel yöntemlerin dezavantajlarının üstesinden gelmek için, çeşitli çalışma koşullarını ve çeşitli batarya türlerini içeren batarya sağlığı teşhis yöntemlerine ihtiyaç vardır. Bu yöntemler, fiziksel veya matematiksel modeller oluşturularak bataryanın bozulma dinamiklerini tanımlamaya ve batarya SoH'sini tahmin etmeye çalışır.

Veriye Dayalı Yöntemler: Ölçülen verilerden veya çıkarılan özelliklerden batarya bozulma dinamiklerini modellemek için bir başka çözümdür.

2.4 Model Tabanlı Yöntemler

Model tabanlı yöntemler, veriye dayalı yöntemlerden farklı olarak bir model veya matematiksel bir gösterim kullanarak sonuçlar üretirler. Bu algoritmaların avantajları şunlardır: Verilerin boyutu büyük olsa bile yüksek performans sergilerler. Bu, büyük ölçekli problemleri çözmek için idealdir. Matematiksel bir modele dayanarak sonuçlar üretirler, bu nedenle sonuçlar daha doğru ve tekrarlanabilir olabilir. Veriye dayalı yöntemlere göre daha az veri gerektirirler. Bu, küçük veri kümeleri ile çalışırken faydalıdır.

Model tabanlı yöntemlerin dezavantajları ise şunlardır: Veri dağılımındaki değişikliklere iyi uyum sağlayamaz. Modelin doğru çalışması için düzenli olarak kontrol edilmesi ve ayarlanması gerekebilir çünkü model dışında çıktıyı etkileyen anlık faktörlerin hepsini kapsayamayabilir (örn: ortam sıcaklığı, kimyasal bileşenlerin dinamiği vb.).

Model tabanlı yöntemlerde, araştırmacıların kendilerinin önerdiği özgün matematiksel modeller dışında en sık rastlanan model tabanlı yöntem KF ve EKF'dir. Plett [35] çalışmasında, hibrit elektrikli araçlarda BMS için Genişletilmiş Kalman Filtresi (Extended Kalman Filter - EKF) algoritması ile SoC tahmini yapmaktadır. Çalışma, BMS'nin batarya şarj durumu, anlık kullanılabilir güç, güç azalması ve kapasite azalması gibi sağlık durumu göstergesi olan parametreleri tahmin

edebileceğini ve zamanla hücre özelliklerine uyum sağlayabileceğini belirtmektedir. Kalman Filtresi (Kalman Filter - KF), optimum durum tahmincisi olarak kabul edilir ve açıklanan varsayımlara sahip doğrusal bir sistem için kullanılır. Doğrusal olmayan durumlar için zaman değişkenli (time-variant) bir yaklaşım kullanılarak sistem doğrusala yaklaştırılabilir. Yazarlar bu yaklaştırılan sistemi daha sonra KF'de kullanılarak, gerçek doğrusal olmayan sistemi EKF ile modellemişlerdir. Bu model Eşitlik 6 ve Eşitlik 7'de gösterilmiştir.

$$x_{k+1} = f(x_k, u_k) + w_k \quad (6)$$

$$y_k = g(x_k, u_k) + v_k \quad (7)$$

Burada x_k , k zaman indeksindeki sistem durum vektörünü temsil eder ve "durum denklemi" veya "süreç denklemi" olarak adlandırılır. Durum denklemi, sistem dinamiklerinin gelişimini yakalar. Sistem kararlılığı, dinamik kontrol edilebilirliği ve bozulmaya karşı hassasiyet, bu denklemden belirlenebilir. Sisteme bilinen ve belirleyici bir girdi olarak u_k , verilirken, w_k stokastik bir "süreç gürültüsü" veya "bozukluk" olarak adlandırılan, sistemin durumunu etkileyen bazı ölçülmemiş girdileri modellemektedir. Sistem çıktısı y_k olarak belirtilir ve bu çıktı, durumların ve girdinin doğrusal bir kombinasyonu olarak hesaplanır. Ancak, belleksiz bir sistem çıktısının ölçümünü etkileyen unsurlar da vardır. Bu unsurlar, "sensör gürültüsü" olarak adlandırılan v_k tarafından modellenir. $f(x_k, u_k)$ doğrusal olmayan bir durum geçiş fonksiyonu olarak tanımlanmakta ve $g(x_k, u_k)$ doğrusal olmayan bir ölçüm fonksiyonu olarak belirtilmektedir. Doğrusal olmayan sistem, her adımda, $f(x_k, u_k)$ ve $g(x_k, u_k)$ birinci dereceden bir Taylor serisi açılımı ile doğrusallaştırılır. $f(\cdot, \cdot)$ ve $g(\cdot, \cdot)$ 'nin tüm çalışma noktalarında (x_k, u_k) türevlenebilmektedir. Bu açılımlar Eşitlik 8 ve Eşitlik 9'da gösterilmiştir.

$$f(x_k, u_k) \approx f(\hat{x}_k, u_k) + \left. \frac{\partial f(x_k, u_k)}{\partial x_k} \right|_{x_k=\hat{x}_k} (x_k - \hat{x}_k) \quad (8)$$

$$\hat{A}_k = \left. \frac{\partial f(x_k, u_k)}{\partial x_k} \right|_{x_k=\hat{x}_k}$$

$$g(x_k, u_k) \approx g(\hat{x}_k, u_k) + \left. \frac{\partial g(x_k, u_k)}{\partial x_k} \right|_{x_k=\hat{x}_k} (x_k - \hat{x}_k) \quad (9)$$

$$\hat{C}_k = \left. \frac{\partial g(x_k, u_k)}{\partial x_k} \right|_{x_k=\hat{x}_k}$$

Eşitlik 8 ve 9 kullanılarak doğrusallaştırılmış sistem denklemleri Eşitlik 10 ve 11'deki gibi oluşturulabilir.

$$x_{k+1} \approx \hat{A}_k x_k + f(\hat{x}_k, u_k) - \hat{A}_k \hat{x}_k + w_k \quad (10)$$

$$y_k \approx \hat{C}_k x_k + g(\hat{x}_k, u_k) - \hat{C}_k \hat{x}_k + w_k \quad (11)$$

EKF, temel olarak standart KF'ye çok benzer. Başlatma adımı aynı kalır. Her tekrarda bir tahmin ve bir düzeltme adımı gerçekleştirilir. EKF'de, mevcut durumu tahmin etmek için yayılma adımı, KF'nin doğrusal modelini kullanırken doğrusal olmayan modele uygulanır. Hata kovaryans yayılımı ve Kalman kazanç denklemleri, KF ile aynıdır, ancak artık doğrusallaştırılmış \hat{A}_k matrisi A_k 'nin yerini alır ve \hat{C}_k matrisi de C_k 'nin yerini alır. Durum tahmini güncellemesi aynı şekilde yapılır, ancak $\hat{y}_k = g(\hat{x}_k, u_k)$ olarak hesaplanır ve hata kovaryans güncellemesi sadece C_k yerine \hat{C}_k 'nin kullanılmasıyla farklılık gösterir.

Chen ve ark. [36] çalışmasında, bir Lithium-polymer batarya şarj durumunun tahmini için sağlam bir kayan mod

gözlemcisi (Robust Sliding-Mode Observer - RSMO) sunmuştur. Bunun için, bir batarya eşdeğer devre modeli (Battery Equivalent Circuit Model - BECM) oluşturmuşlardır ve BECM, gerçek zamanlı olarak bir unutm faktörü özyinelemeli en küçük kareler (Forgetting-Factor Recursive Least Squares - FFRLS) algoritması kullanılarak tanımlamışlardır. Deneyler, elektrikli araç sürüş döngülerinde Lithium-polymer batarya üzerinde gerçekleştirilerek önerilen yaklaşım doğrulamışlardır.

He ve ark. [37] çalışmasında, SoH tahminlerinin önemi vurgulanarak, Li-ion bataryalar için bir çok ölçekli Gauss süreci regresyon (Gaussian Process Regression - GPR) modelleme yöntemi önermişlerdir. Yöntem, dalgacık analizi yöntemi kullanarak SoH zaman serilerinde küresel bozulma, yerel yenilenme ve dalgalanmaları ayırtmıştır. Zaman indeksinin dahil edildiği GPR, çıkarılan küresel bozulma eğilimine uyması için kullanılır ve gecikme vektörü girişi ile GPR, yerel yenilenmeyi ve dalgalanmaları tahmin etmek için tasarlanmıştır. Önerilen yöntem, Li-ion bataryaların bozulma testinden elde edilen deneysel verilerle doğrulanmış ve hem bir adım için SoH tahmin performansları değerlendirilmiştir.

Model tabanlı bir başka çalışmada Huang ve ark. [38], Li-ion bataryaların yaşam ömrü boyunca çevrimiçi, SoC ve SoH tahminleri için bir model geliştirmiş ve modelin sağlamlığının kanıtlandığı belirtmişlerdir. Pilin eskimesiyle birlikte gerilim değiştiğinden, pilin SOC'sini belirlemek için tek bir voltaj değeri yeterlidir. Bu nedenle, bu makale, SOC ve SOH modellemesi için birim zaman gerilim düşümü, V' olarak adlandırılan yeni bir parametre önermektedir. Eşitlik 12'de bu parametre gösterilmektedir.

$$V' = \frac{\Delta V}{\Delta t}, \quad V' = V_1 - V_2 \quad (12)$$

Burada ΔV deşarj esnasındaki gerilim düşüşüdür. Δt ise deşarj süresidir. Önerilen çalışma, boşaltma işlemindeki birim zaman voltaj düşüşü olan yeni bir değişken tanımlamakta ve bu değişkeni kullanan yeni bir model önermektedir. SoC, değişkenin belirlenmemiş katsayısı ile doğrusal bir ilişki olarak ifade edilmiştir. SoH, SoC'nin bir fonksiyonu olan bir modifikasyon faktörü ile değişken ile doğrusal olduğu bulunmuştur. Test hücrelerinden veri regresyonu, katsayıların değerlerini vermektedir. Bu türetilmiş model, bataryanın anlık SoC ve SoH'sini aynı anda tahmin edebilmekte ve çevrimiçi gerçek zamanlı uygulamalar için kullanılabilir. Ayrıca, bataryanın anlık SoC ve SoH'sini aynı anda tahmin edebilmekte ve çevrimiçi gerçek zamanlı uygulamalar için kullanılabilir.

Afari ve Byun [39] çalışmasında, EV bataryasının SOH ve SOC'ünü hesaplama zorluğuna bir çözüm olarak Digital Twin önerilmektedir. XGBoost modeli ve EKF kullanılarak bataryanın durumu tahmin edilir. EKF ile bataryanın durumu belirlenir ve bakım için önemli bilgiler sağlanır. Doğru SOC tahminiyle bataryanın ömrü uzatılabilir.

Wang ve ark. [40] çalışmasında, EA ve hibrit araçlar için SoC tahmini için bir yöntem önerilmektedir. Batarya yaşlanmasıyla ilgili olarak, elektrokimyasal empedans spektroskopisi (electrochemical impedance spectroscopy) tabanlı bir model güncelleme stratejisi entegre edilmiş ve bu yöntem, SoC tahmin doğruluğunu önemli ölçüde artırmaktadır, bu da şarj ve deşarj koşullarında gerçek değerlere daha yakın tahminler sağlamaktadır.

Saldaña ve ark. [41] çalışmasında, elektrikli araç teknolojisinin yaygın kullanımının önündeki engellerden biri olan batarya bozulmasının doğru bir şekilde ele alınması gerektiği vurgulanmaktadır. Ticari bir elektrikli araç bataryasının döngü yaşlanması üzerine kurulan bir

matematiksel model geliştirilmiş ve sıcaklık ile elektrik akımının hızı gibi faktörlerin batarya bozulmasında belirleyici olduğu bulunmuştur. Çalışma, farklı sürüş koşullarının batarya bozulmasına etkisini analiz eden bir model uygulaması da sunmaktadır.

Bu çalışmada incelenen model tabanlı yöntemler genel olarak bakıldığında, ortak bir algoritma ya da modeli kullanmaktan ziyade çalışmalar özgün bir matematiksel model kullandığı gözlemlenmektedir (Tablo 1).

Tablo 1. İncelenen çalışmaların model tabanlı yöntemlere göre sınıflandırılması

Yöntem
Matematiksel Model
Parçacık Filtresi
Kalman Filtresi
Regresyon Modeli
Bayes Modeli
Hücre Fark Modeli
Olasılık Fonksiyon Teorisi
Çok Ölçekli Entropi
Doğrusal Tahmin Hata Modeli

2.5 Veriye dayalı yöntemler

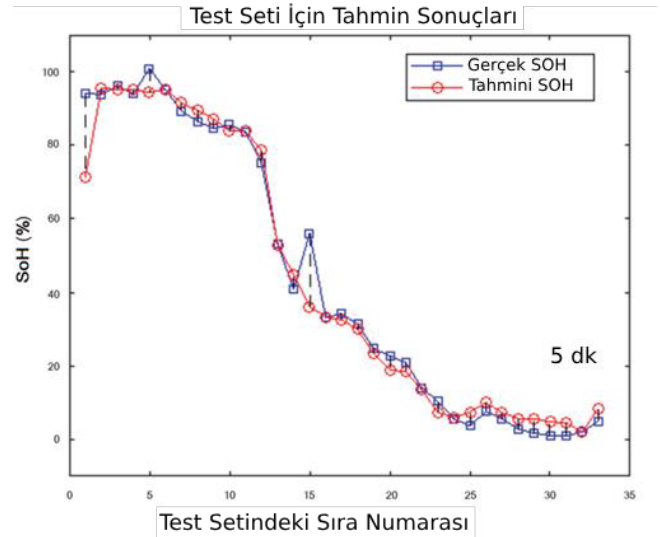
Veriye dayalı yöntemlere bakıldığında ise, Li-ion batarya hücrelerinin SoH ve RUL tahmin edebilen Rezvani ve ark. [42] çalışmasında, Uyarlanabilir Sinir Ağı (Adaptive Neural Networks - AdNN) ve Lineer Tahmin Hata Yöntemi (Linear Prediction Error Methods - L-PEM) olmak üzere iki model ile PHM geliştirmişlerdir. Çalışmada AdNN tekniği kullanılarak girdilerin ağırlıklarla çarpılması ve ardından matematiksel bir fonksiyonla hesaplanarak yapay nöronun aktivasyonu temsil edilmiştir. Yazarlar yapay sinir ağlarını, yapay nöronları birleştirerek girdiler ve çıktılar arasındaki ilişkileri bulmak için kullanmışlardır.

Dong ve ark. [7] çalışmasında, Dinamik Bayes Ağı (Dynamic Bayesian Network - DBN) kullanılarak şarj işleminden çıkarılan özelliklere dayalı olarak bataryanın bozulma modellemesi ve sağlık tahmini için olasılıksal bir yöntem sunmaktadır. Bazı CC veya CV şarj bilgilerinin olmaması durumunda bataryanın bozulma dinamiklerini karakterize etmek için CC şarjının artımlı kapasite analizi ile CV şarjının zaman sabitini birleştiren toplu bir özellik geliştirilmiştir. Benzer şekilde Hu ve ark. [8] çalışmasında, elektrikli araçlarda batarya SoH göstergesi ve prognozu için seyrek bayes tahmini modelleme (Sparse Bayesian Predictive Modeling - SBPM) metodolojisi kullanmışlardır. Yaklaşım, otomatik olarak seçilen az sayıda temel işlevi kullanarak doğru ve esnek tahminler yapan doğrusal olmayan bir model çıkarmıştır.

Elektrikli araçlarda kullanılan bir Lityum-Fer-Fosfat (LFP) bataryasında RUL ve eskime hızını tahmin etmek için Hemedani ve ark. [43] çalışmasında, Levenberg-Marquardt-Geri Yayılma Sinir Ağı (Propagation Neural Network - LM-BPNN) adlı bir AdNN algoritması kullanılmıştır. BPNN algoritması yaygın olarak kullanılan çok katmanlı sinir ağı öğrenme algoritması ve denetimli öğrenme yöntemidir. BPNN algoritmasının, nöronlar arasındaki gradyanın hesaplanması ile hata düzeltme yaparak tahmini çıktı ile istenen çıktı arasındaki farkı azalttığı ifade edilmektedir. He ve ark. [44] çalışmasında, model parametrelerini kendi kendine ayarlamak ve SoC tahmini sağlamak için Kalman filtrelemeye dayalı bir yöntem önerilmişlerdir. Önerilen yöntemin performansı, iki dinamik deşarj profili ile çevrilen LiFePO₄ bataryalarından toplanan veriler kullanılarak gösterilmiştir. Yayan ve ark. [4]

çalışmasında, batarya şarj işlemi sırasında toplanan veriler kullanılarak SoH (Durum-of-Health) tahmin edilmektedir. Çalışmada, hızlı şarj işlemi sırasında toplanan veriler kullanılarak bataryanın SoH'si tahmin edilmiş ve bunun için önerilen derin sinir ağı yapısı olarak LSTM-BiLSTM (Bidirectional LSTM) kullanılmıştır. LSTM, Recurrent Neural Network (RNN)'ye benzer ancak geçmiş verileri daha etkili bir şekilde kullanabilen ve uzun süreli bağlantıları koruyabilen bir sinir ağıdır. Bu özellikleri sayesinde, zaman serilerindeki kaybolan gradyan problemi de çözülebilir. LSTM, zaman dilimleri arasındaki bağımsızlığı sağlayarak tahmin ve sınıflandırma işlemleri için ideal bir araçtır. Şekil 5'te, test veri setindeki her dizi için tahmin edilen ve gerçek SoH değerleri ve tahmin hatası gösterilmektedir. Çalışmanın RMSE değerleri ise eğitim verisetinde 2.9022, doğrulama verisetinde 5.4212 ve test veri setinde ise 5.501 olarak hesaplanmıştır. Yazarların önerdikleri yığılı BiLSTM modeli ileri ve geri verilerin birleştirilmesini içeren bir eğitim sürecine sahiptir. Model, pillerin SoH'sini diğer tekrarlayan ağlardan veya tek yönlü LSTM modellerinden daha güvenilir bir şekilde tahmin etmede başarılıdır.

Antón ve ark. [45] çalışmasında, bir lityum demir fosfat (LiFePO₄) batarya hücresinin SoC'sini tahmin etmek için otomatik öğrenme aracı olarak destek vektör makinesi (Support Vector Machine - SVM) kullanmışlardır. SVM, sınıflandırma ve regresyon problemleri için kullanılan bir dizi ilgili denetimli öğrenme yöntemidir. SVM öncelikle sınıflandırma problemlerini çözmek için tasarlanmıştır, ancak daha sonra Support Vector Regression (SVR) adı verilen bir yöntemle regresyon problemlerini çözmek için genişletilmiştir [46].



Şekil 5. BiLSTM kullanarak Yayan ve ark. [4] SoH tahmini

Farklı döngü sayıları altında batarya terminali voltaj eğrilerinin analizi ile Li-ion batarya RUL tahmini için Wu ve ark. [26] çalışmasında ileri beslemeli sinir ağı (Feed Forward Neural Network - FFNN) kullanmışlardır. FFNN, istatistiksel modelde yaygın olarak kullanılan bir makine öğrenme yöntemidir ve doğrusal olmayan simülasyon yeteneği nedeniyle tercih edilir. Çalışmada, 3 katmanlı (giriş, gizli ve çıkış) bir FFNN önerilmiştir ve ağ parametreleri eğitim sürecinden

belirlendiğinde batarya çevrim ömrünün tahmin etmek için kullanılmıştır.

Zhang [47] ise çalışmasında, bir Li-ion batarya paketi kullanarak, bataryanın şarj veya deşarj sürecindeki yerel voltaj değişimini ve kapasite değişimini SoH indeksleri olarak kullanarak, SoH'yi tahmin etmek için bir yöntem sunmuştur. Yöntem, bir partikül filtresine (Particle Filter - PF) dayalı RUL tahmini gerçekleştirir. PF olasılık dağılımı bilinmeyen ve ölçümlerden gelen gürültülü verilere dayalı olarak bir sistemin durumunu tahmin etmek için kullanılan bir filtreleme algoritmasıdır. PF, Li-ion batarya ömrü tahmininde yaygın olarak kullanılmaktadır. Song ve ark. [48] çalışmasında, Li-ion bataryalar için doğruluk düzeltmeli XGBoost algoritmasına dayalı SoH tahmin yöntemi önermişlerdir. XGBoost modeli, eğri uydurma (over-fitting) sorununu etkili bir şekilde önleyebilen Li-ion bataryada SoH tahmin etmek için kullanılmıştır. Yazarlar ayrıca XGBoost modelinin, random forest, k-nearest neighbor (KNN), SVM, lineer regresyon yöntemleri ile karşılaştırmış ve tahmin doğruluğunu Markov zinciri ile düzeltmişlerdir.


Wu ve ark. [6] çalışmasında, yeni bir özellik seçme yöntemi önermektedir. Yöntem, gerçek elektrikli araç verilerine dayalı olarak, DFA (Difficulty of Feature Acquisition) olarak adlandırılan bir özellik edinme zorluğu kullanılarak ve parçacık sürüsü optimizasyonu (Particle Swarm Optimization - PSO) algoritması kullanılarak optimize edilmektedir. Sırt (ridge) regresyonu kullanılarak seçilen özelliklerle SoH arasındaki ilişki modellemekte ve doğru özelliklerin belirlenmesine yardımcı olmaktadır. Doğru seçilmiş özellikler ve lineer model birleştirilerek güvenilir bir SoH tahmini yapılabilmektedir. Gerçek bir elektrikli araçtaki üçlü batarya üzerinde çalışan Hong ve ark. [49], Çin Elektrikli Araçlar için Ulusal İzleme ve Yönetim Platformundan geçmiş çalışma verilerini türeten gerçek senaryo tabanlı bir termal kaçak tahmini sunmaktadır. Çalışma, batarya arızalarının teşhisi için değiştirilmiş çok ölçekli entropi (Modified Multiscale Entropy - MMSE) yönteminin kullanmıştır. MMSE, örnek entropisine dayalı olarak hesaplanır ve genellikle teşhis işlemlerinde kullanılmaktadır. Örnek entropisi, zaman serisinin karmaşıklığını ölçebilmektedir. Ayrıca, gerçek araç kazası üzerinde batarya durumlarının değerlendirilmesi ve batarya termal kaçaklarına karşı koruma sağlanması için çok düzeyli anormal katsayılar belirlemeyi de ele almaktadır.

Elektrikli araç kullanımı için küresel batarya performanslarının gerçek zamanlı tahmini için Barr' ve ark. [50] çalışmasında, performans düzeyine göre batarya sinyallerinin davranışındaki değişikliklere dayalı bir model oluşturulmuşlardır. Sunulan yöntem, gerçek zamanlı batarya performanslarının tahminini mümkün kılmak için batarya sinyallerinin davranışındaki değişikliklere dayalı bir model oluşturmaktadır. Bu model, gerçek kullanımlarda belirli hızlanma profillerine karşılık gelen batarya sinyallerinin seçilmesinden oluşmuştur. Daha sonra, her bir SoH özelliği için batarya davranışını belirlemek üzere bu voltaj ve akım modelleri kullanılmıştır. İncelenen örüntüler, sinyal işleme teknikleri kullanılarak karşılaştırılmış ve batarya performansının tahmin edilmesi için istatistiksel öğrenme yöntemleri uygulanmıştır.

Jorge ve ark. [51] çalışmasında ise, yaşlanma verilerine uygulanan makine öğrenimi regresyon yöntemlerini kullanarak Li-ion bataryaların RUL tahmini yapmışlardır. Yapay sinir ağları ile yaşlanma verilerinin temsilinin nasıl oluşturulacağı araştırılmış ve tahmin performansları elde edilmiştir. Çalışma, düşük hesaplamalı yaklaşımları kullanarak veri kümesinde ilk çalışma olduğu belirtilmiştir.

Roman ve ark. [52] çalışmasında, batarya kapasitesinin tahmin edilmesi için yeni makine öğrenimi algoritmaları ve belirsizlik ölçülmesi için metrikler tanımlamışlardır. Çalışma batarya sağlığı ve belirsizlik yönetimi akışı (Battery Health and Uncertainty Management Pipeline - BHUMP) adlı yeni bir makine öğrenimi algoritması önermektedir. Bu algoritma, batarya SoH'sinin ve belirsizliğinin gerçek zamanlı tahminini yapabilen bir veri işleme yöntemi kullanılmaktadır. BHUMP, çeşitli batarya tasarımları ve kimyaları üzerinde test edilmiş ve herhangi bir hücre kimyasına ve çalışma koşuluna uyarlanabilen, ölçeklenebilir bir SoH tahmini olarak sunulmuştur. Geliştirilen algoritma, bataryaların içsel bozulmasını yakalayabilen bir dizi mühendislik özelliği kullanarak ve batarya performansını iyileştirdiği, hücre ömrünü uzattığı gözlemlenmiştir.

Jain ve ark. [53] çalışmasında, batarya SoC tahmin edilmesi için regresyon modelleri kullanarak voltaj aralığının seçimini, bataryanın CC-CV şarjı ve sağlık faktörünü kullanarak gerçekleştirmişlerdir. Sağlık parametresinin çıkarılması ve regresyon modeli yardımıyla SoH ile sağlık parametresi arasında doğrusal bir ilişki açıklanmıştır. Şekil 6, SoH tahmini için geliştirdikleri akış şemasını göstermektedir [53]. Zhang ve ark. ise [54] çalışmasında, batarya hücresi SoH'sini tahmin etmek için çarpışma deformasyon özellikleri kullanarak bir yöntem önermektedir. Yeni batarya hücreleri çarpışma etkilerinin araştırılması için test edilmiş ve deforme olmuş hücrelerin hasar karakterizasyonu gerçekleştirilerek sınıflandırılmıştır. Deformasyona uğramış batarya hücrelerinin sınıflandırılması için, 3D tarama yöntemiyle bozulma verileri elde edilmiş ve ardından bu 3D görüntü örneklerinden geometrik özellikler türetilerek örüntü tanıma yapay sinir ağı tabanlı bir yöntem kullanılmıştır.



Şekil 6. SoH tahmini için akış şeması

Deneysel veriler kullanılarak Liu ve ark. [55] çalışmasında, Li-ion bataryaların ömür özellikleri analiz etmişlerdir. Bataryaların ömrü, döngü sayısı ile değişir ve batarya kapasitesi, deşarj verimliliği, enerji verimliliği, iç direnç ve batarya ömrü ile diğer parametrelerdeki değişiklikler incelemiştir. Çalışmada, SoH'yi tahmin etmek için voltaj eğrisi uydurma yöntemi kullanılmıştır.

Yang ve ark. [56] çalışmasında, Peukert Yasası'na dayalı dinamik bir batarya SoH tahmin yöntemi önermişlerdir. Önerilen yöntem, kapasite kaybını Peukert katsayısı ile

ilişkilendirilmiş ve bozulma tutarsızlığını ortadan kaldırmıştır. Çoklu deşarj testi ile Peukert katsayısı hesaplanarak batarya sağlığı tahmin edilmiştir.

Stroe ve Schaltz [57] çalışmasında, artımlı kapasite analizi (Incremental Capacity Analysis - ICA) tekniğinin LMO/NMC ($\text{LiMn}_2\text{O}_4/\text{LiNiMnCoO}_2$) tabanlı EA Li-ion bataryaların kapasite azalmasını ve SoH'sini tahmin etmek için kullanmışlardır. ICA tekniği kullanılarak elde edilen artımlı kapasite değerlerinden birine karşılık gelen voltaj değerleri, bataryanın kapasite kaybı ile ilişkilendirilmiştir. Chowdhury ve ark. [58] çalışmasında, seri olarak bağlanan Li-ion batarya hücrelerinin SoH'sini dengelemek için DC/DC dönüştürücüler aracılığıyla bağlanan batarya hücreleri için basitleştirilmiş bir SoH dengeleme topolojisi önermişlerdir. Yöntem, tek tek hücrelerin kontrolünü birleştirerek, sistemdeki en düşük SoH batarya hücresiyle birleştirerek, genel batarya ünitesinin SoH'sini arttırdığı ve bataryanın değiştirme maliyetlerini azalttığı gözlemlenmiştir. Pang ve ark. [59] çalışmasında, (hibrit) elektrikli araçlar için kurşun asitli batarya SoC tahmini sorununu ele almaktadır. Bu sorun, sürücü ve otomatik enerji yönetimi için doğru bir şekilde kalan batarya kapasitesini tahmin etmekle ilgilidir. Çalışma, sorunun tanımını, mevcut çözüm yöntemlerini, yeni bir çözüm yöntemi önerisini ve bu yöntemin performansının deneysel analizini içermektedir.

Zhou ve ark. [60] çalışmasında, BMS ve bulut büyük veri platformunun birleşiminin mimarisini önermektedir. Ortalama voltaj düşüşü (Mean Voltage Falloff - MVF) ölçümleri kullanılarak bir kapasite ve MVF regresyon modeli kurulmuştur. Kapasite ve MVF, bulut büyük veri platformuna yüklenmiş ve MVF'nin ortalaması ve varyansı tahmin edilmiştir, böylece Li-ion batarya sağlık durumuna ilişkin aralık tahmini ve kalan faydalı ömrün belirlenmesi için olasılık yoğunluk fonksiyonu tahmini gerçekleştirilmiştir. Çalışma NASA batarya yaşlanma veri seti [61] ile test edilmiştir.

Xu ve ark. [62] çalışmasında, Li-ion bataryaların çok tipli arıza teşhisinde kullanılabilen bir araç-bulut işbirlikçi yöntemi tanıtmaktadır. İlk olarak, normal ve arızalı batarya modüllerinin şarj-deşarj koşulları simüle edilerek batarya sisteminin simülasyon modeli oluşturulmuştur. Hücre farkı modeli kullanılarak araç tarafındaki özellik farklılıkları çıkartılmış ve karar ağacı sınıflandırıcısı eğitilerek gerçek zamanlı takip için muhakeme eşikleri belirlenmiştir. Batarya sistemleri için farklı arızaların simülasyon deneyleri sonucunda, batarya sistemleri simülasyon modeli (Battery System Simulation Model - BSSM) oluşturulmuştur. Bu model hem normal batarya modüllerinin hem de arızalı batarya modüllerinin şarj-deşarj durumlarını simüle etmek için kullanılmaktadır.

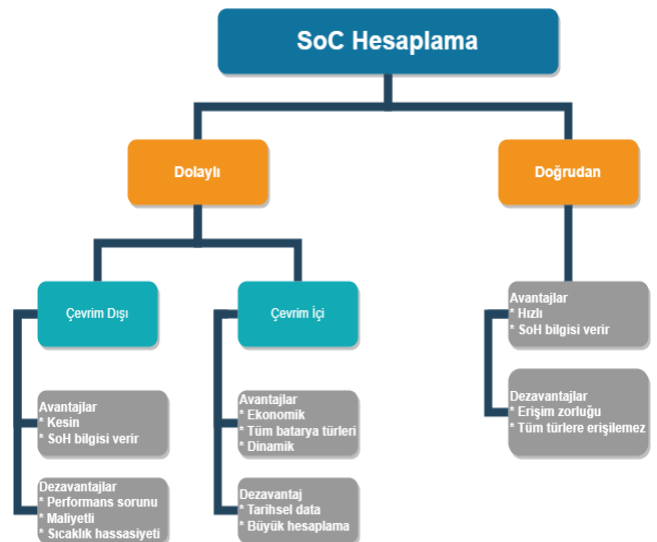
Yang ve ark. [63] çalışmasında, derin öğrenme yöntemleri kullanılarak batarya bozulma özellikleri elde edilmiş ve bataryanın kalan kullanım ömrü tahmini üzerinde deneysel sonuçlar gösterilmiştir. NASA [61] ve Oxford [64] batarya bozulma veri kümeleri kullanılarak doğrulan bir yöntem, sunulan modelin, RMSE'nin %1'den az olduğu durumlarda SoH tahmin doğruluğu ve genelliği sağladığını göstermektedir.

Sun ve ark. [65] çalışmasında, BMS çevrimiçi verilere dayanan çoklu bireysel algoritmaları önermektedir. Çalışma, ortak kapasite tahmini için indüklenmiş sıralı ağırlıklı ortalama (Induced Ordered Weighted Average - IOWA) operatörünü tanıtmaktadır. Ayrıca, genetik algoritma (Genetic Algorithm - GA) tarafından optimize edilen sinir ağının çalışması, BMS'den tarihsel durum mesajı ile güçlü sağlamlık ve doğru tahmin için büyük veri platformuna yüklenmiştir. Çalışma NASA batarya yaşlanma veri seti [61] ile test edilmiştir. Ayrıca Chehade ve Hussein [66] çalışmasında, Li-ion batarya hücrelerinin

kapasitesini tahmin etmek için bir yöntem önermişlerdir. Yöntem, bir Gauss Sürec Regresyon modelini kullanmaktadır. Önerilen yöntem, yüksek tahmin doğruluğu ve sağlamlığın yanı sıra, farklı batarya hücreleri arasındaki kapasite eğilimlerini ilişkilendirme yeteneğine sahiptir. Farklı batarya hücrelerinin çoklu kapasite eğilimlerini işbirlikçi bir şekilde modellemek için İşbirlikçi Gauss süreci regresyonu (Collaborative Gaussian process regression - CGPR) olarak adlandırılan, kovaryans işlevine sahip çok çıkışlı bir Gauss süreci önerilmiştir. Çalışma NASA batarya yaşlanma veri seti [61] ile test edilmiştir.

Wang ve ark. [67] çalışmasında, gelecekteki batarya yönetim sistemleri için bulut işbirliği ve dijital ikiz teknolojisi önermişlerdir. Batarya yönetimi için bulut tarafı iş birliğinin dört katmanlı ağ bağlantılı mimarisi sunulmuştur. Bataryanın dijital ikiz modeli oluşturulmuş ve batarya tüm yaşam döngüleri boyunca hassas ve güvenli bir şekilde yönetilmesi sağlanmıştır. Eksik veri problemlerini çözmek için, bir tahmin modeli tasarlanmıştır. Model, eksikliği sorununun üstesinden gelmek için işbirlikçi özellik çıkarıcı kullanılmış ve karmaşıklık sorunları için artırılmış gizli katmana sahip bir sinir ağı kullanılmıştır. Berghout ve ark. [68] çalışmasında, NASA batarya veri setini [61] kullanarak, doğrusal regresyon modelleri, destek vektör makinesi, Gauss süreci regresyonu, aşırı öğrenme makinesi ve yapay sinir ağları yöntemleri incelemişlerdir. Çalışmada, batarya ömrü döngülerinin bozulma modelleri ve etiketlerinin eksikliği problemlerine odaklanılmıştır.

Ayrıca BMS ve prognostik alanında yapılan gözden geçirme çalışmaları da mevcuttur. Rezvanianiani ve ark. [14], Omariba ve ark. [20] çalışmalarında, batarya PHM tekniklerinin incelemesini sunarak, batarya üreticileri, otomobil tasarımcıları ve elektrikli araç sürücülerini için bu alandaki temel ihtiyaçlara odaklanmaktadır. Literatürün analitik bir incelemesini yapan çalışmalarda, BMS fırsat ve zorluklarına giriş yapılmaktadır. Ayrıca, batarya sağlığı yönetimi konusunda geleceğe yönelik araştırma gündemi sunulmakta ve bu inceleme çalışmalarında ortaya konulan sorunlarla birlikte daha fazla araştırma yapmanın önemine dikkat çekilmektedir. BMS'inde akım, voltaj ve sıcaklık gibi doğrudan bataryadan ölçülebilen değişkenler, SoC'nin doğru bir tahminini sağlamak için kullanılabilir. Şekil 7, bazı örneklerle SoC teknikleri sınıflandırmasının özetini göstermektedir [69], [70].



Şekil 7. En önemli SoC tahmin yöntemleri

Sarmah ve ark. [28] çalışmasında, kapsamlı literatür çalışmaları yürüterek bataryaların SoH tahmini için modellerin ve yöntemlerin ilerlemesi, zorlukları, endişeleri ve fütüristik yönleri hakkında bilgi sunmaktadır. SoH tahmini için yöntemler ve modeller, avantaj ve dezavantajları ile sistematik olarak Tablo 2'de özetlenmiştir. Ayrıca, Roscher ve Sauer [21] Li-ion batarya yönetim sistemlerinin bir incelemesini yaparak, bir BMS içindeki ana ölçüm parametreleri, durum tahmin yöntemleri, hücre eşitleme sorunları, termal yönetim stratejileri ve araştırma eğilimleri ve ilerlemeleri dahil olmak üzere temel unsurları ve zorlukları önerilerle tartışmaktadır.

Tablo 2. Li-ion pilin sağlık durumu tahmini için çeşitli yöntemlerin nicel analizi

Yöntem	Tür	Gerçek SoH deneysel (%)	Tahmini SoH yaklaşık (%)	Tahmini hata yaklaşık (%)
Coulomb Sayımı	Model Tabanlı	63.85	69.78	<10
Elektrokimyasal Empedans	Model Tabanlı	85	86.27	<2.1
Spektroskopisi	Veriye Dayalı	82	82.3	<0.5
Sinir Ağı	Veriye Dayalı	60.35	59.19	<2
Destek Vektör Makinesi	Model Tabanlı	84.36	86.57	≤5
Kalman Filtresi	Model Tabanlı	90.13	90.26	<2.5
Kayan Mod Gözlemcisi	Model Tabanlı	88	91.62	1.4-9.2
Bulanık Mantık	Veriye Dayalı			

Ana batarya SoH tahmin yöntemlerinin bir incelemesini yapan Noura ve ark. [71] çalışmasında, ana avantajlarını ve gerçek zamanlı otomotiv uyumluluğu ve özellikle hibrit elektrik uygulamaları açısından sınırlamalarına işaret etmektedir. Çalışmada gerçek zamanlı fizibilitesini ve doğruluğunu göstermek için model tabanlı uyarlamalı filtreleme kullanan çevrimiçi ve yerleşik bir SoH tahmin yönteminin deneysel doğrulanması yapılmaktadır.

Bataryaların sağlık durumu ve şarj durumunu tahmin etmek, günümüzde batarya verilerinin daha fazla kullanılabilir hale gelmesi ve bilgi işlem gücü yeteneklerinin geliştirilmesi sayesinde, veriye dayalı yaklaşımların, özellikle makine öğrenimi yöntemlerinin popüler hale gelmesine neden olmuştur. Xiong ve ark. [72] çalışmasında, bu iki yaklaşımı karşılaştırmak amacıyla; ileri beslemeli sinir ağları, tekrarlayan sinir ağları, destek vektör makineleri, radyal temel fonksiyonlar ve Hamming ağları gibi makine öğrenimi yöntemlerine dayanan batarya durumu tahmin yöntemlerinin bir incelemesini sunmuşlardır. İnceleme, yöntemler arasındaki karşılaştırmaları yaparak, bataryaların şarj durumu ve sağlık durumu tahmini için makine öğrenimi yaklaşımlarını açıklamıştır. Bu karşılaştırmalar, veri kalitesi, girdiler ve çıktılar, test koşulları, batarya türleri ve belirtilen doğruluk açısından yapılmıştır.

Bataryaların şarj durumunu tahmin etmek için kullanılan tahmin yöntemleri ve algoritmaları ayrı ayrı ele alan bir başka inceleme Xiong ve ark. [73], hücre kapasitesi, direnç ve voltajdaki tutarsızlıkların mevcut olduğu batarya takımları için gelişmiş karakterize edici seçimi ve sapma düzeltme yöntemlerini tarif etmektedir. İnceleme, batarya şarj durumunun doğru tahmini için temel geri bildirim faktörlerini

de sunar ve batarya yönetim sistemleri ve enerji yönetimi stratejileri için uygun bir yöntemin seçilmesine yardımcı olmaktadır. Son olarak, inceleme, elektrikli araçlar ve batarya enerji depolama sistemleri için akıllı batarya yönetim sistemlerinin geliştirilmesi için olası öneriler sunarak, bir dizi temel faktör ve zorluğu da vurgulamaktadır.

Li-ion bataryaların güvenli ve güvenilir çalışması, BMS tarafından sağlanabilmektedir. Bu sistem, batarya SoC'sini değerlendirebilen ve aşırı şarj/aşırı deşarjdan koruyan stratejiler uygulayarak bataryanın kalan kullanılabilir enerjisini belirleyebilmektedir. SoC'nin çok önemli bir parametre olduğu için, mevcut Li-ion bataryaların SoC'lerinin şarj/deşarj kabiliyetleri, EA'ların güvenli ve verimli çalışmasına katkı sağlamaktadır. Bu nedenle, BMS'nin geliştirilmesi ve yeni nesil EA uygulamalarında SoC tahmini için olası önerilerle birlikte birçok faktörü ve zorluğu vurgulayan inceleme Hannan ve ark. [10], gelecekteki yüksek teknoloji EA uygulamaları için gelişmiş SoC tahmin yöntemlerinin ve Li-ion bataryaların enerji yönetim sistemlerinin geliştirilmesine çalışmaları göstermiştir.

Yao ve ark. [74] çalışmasında SoH'nin bozulma mekanizması ve ana tanımları, literatürler özetlenerek açıklamışlardır. Çalışmada SoH tahmini ve tahmin yöntemleri, model tabanlı yöntemler, veriye dayalı yöntemler ve füzyon teknolojisi yöntemleri tartışılmıştır. Mevcut ana akım SoH tahmin ve tahmin yöntemlerinin avantajları ve dezavantajları özetlenmiştir. Yazarlar, bulut platformu ve diğer teknolojilerle birleştirilen yenilikçi özellik çıkarma ve çoklu algoritma bağlantısının, sağlık durumu tahmini ve Li-ion batarya performansının geliştirilmesinde önemli bir rol oynadığını belirtmektedir.

Abdelaal ve ark. [75] çalışmasında, EA çekiş sistemi için Bulanık Mantık kullanarak, batarya enerji yönetimi tekniği sunmaktadır. Önerilen teknik, endirekt alan odaklı indüksiyon motoru tahrik sistemini düzenlemeyi amaçlamakta ve li-ion batarya bankasının şarj durumu azalmasını ve sağlık durumu bozulmasını en aza indirmektedir. Ayrıca sürüş profilleri veya yol bilgisi gerektirmeden çalışır ve batarya ömrünü uzatmaya yardımcı olur. Gerçek zamanlı bir prototip EV çekiş sistemi üzerinde yapılan deneyler, önerilen tekniklerin geleneksel yöntemlere kıyasla batarya SOC'unda daha az azalma ve SOH bozulması sağladığını göstermektedir.

Hong ve ark. [76] çalışmasında, EA bataryaları için gerçek zamanlı bir arıza teşhis ve izolasyon şeması sunar. Yüksek frekanslı Ayırık dalgacık ayrışımı (Discrete wavelet decomposition) kullanılarak erken arıza sinyallerinin özellikleri çıkarılır ve termal kaçış öncesinde batarya arızalarını doğru bir şekilde tespit edip izole eder. Önerilen yöntemin güvenilirliği ve stabilitesi gerçek araç işletme verileri üzerinde doğrulanmıştır. Bu, sürücülerini ve yolcuları gerçek dünya araç işletmesinde korur.

Li ve ark. [77] çalışmasında, elektrikli araç bataryalarının güvenliği için önemli olan bir batarya arıza teşhis yöntemi sunmaktadır. Bu yöntem, LSTM ve eşdeğer devre modelinin (Equivalent Circuit Model) birleşimini kullanarak, batarya arızalarını doğru bir şekilde tespit etmekte ve termal kaçış gibi ciddi olayları önceden tahmin etmektedir. Çin'deki bir araç izleme merkezinden elde edilen gerçek işletme verileri, yöntemin etkinliğini doğrulamaktadır.

Bu çalışma karşılaşılan veriye dayalı yöntemlerde ise en sık gözlemlenen algoritma Destek Vektör Makineleri olmuştur (Tablo 3).

Tablo 3. İncelenen çalışmaların veriye dayalı yöntemlere göre sınıflandırılması

Yöntem
Destek Vektör Makinesi
ANN
LSTM
İleri Beslemeli Yapay Sinir Ağı
Uyarlamalı Yapay Sinir Ağı
Rasgele Orman
Regresyon Modeli
Radyal Tabanlı Fonksiyon Ağı
Genetik Algoritmalar
DC/DC Çevirici
Anahtarlı Kapasite
Peukerts Kuralı
XGBoost
Artırımlı Kapasite Analizi
Brown Hareketi
K-En yakın Komşular
Tekrarlamalı Yapay Sinir Ağı

Tablo 4 ve Tablo 5, incelenen çalışmaların yıllara ve dergilere göre dağılımlarını göstermektedir. 2001 ile 2023 arasında incelenen çalışmalara odaklandığımızda, IEEE komitesindeki dergi ve konferanslarda yayınlanan çalışmaların batarya alanındaki araştırmalar için oldukça popüler olduğunu gözlemliyoruz. Yıllara göre yapılan bir inceleme, son dönemde yapılan çalışmaların (44 adet) eski çalışmalara göre (35 adet) daha yüksek bir yoğunlukta olduğunu ortaya koymaktadır.

Tablo 4. İncelenen çalışmaların yayınlanan yıllara göre sınıflandırılması

Yayın Yılı	Yayın Sayısı
2023	3
2022	7
2021	11
2020	12
2019	4
2018	7
Daha Eski	35

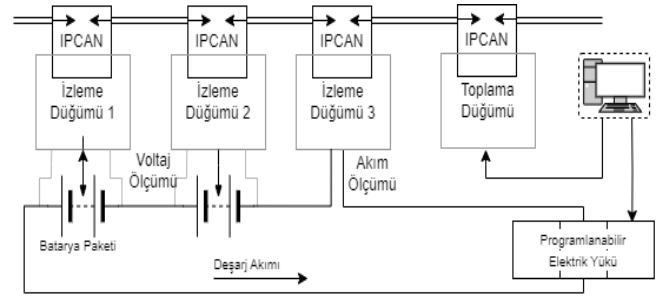
Tablo 5. İncelenen çalışmaların yayınlanan dergilere göre sınıflandırılması

Dergi Adı	Yayın Sayısı
IEEE Dergi ve Konferansları	24
Journal of Power Sources	8
Energies	5
Renewable and Sustainable Energy Reviews	3
World Electric Vehicle Journal	3
Applied Energy	2
Electronics	2
Journal of Energy Storage	2
DİĞER	29

2.6 Literatürde Kullanılan Veri Setleri

Batarya özellikleri ve performansı üzerine yapılan çalışmalarda kullanılan veri setleri literatürde sıkça karşılaşılmaktadır. Şekil 8'de genel bir batarya test sistemi blok diyagramı görülmektedir [78]. Bu çalışmada incelenen literatürde en yaygın olarak kullanılan NASA batarya veri setidir [61]. Bu veri setinin için kullanılan test tezgâhi özellikleri:

- Piyasada bulunan Li-ion 18650 boyutlu şarj edilebilir piller, (18-65-0, 18 mm çap, 65 mm uzunluk ve 0 silindirik pil)
- Programlanabilir 4 kanallı DC elektronik yük,
- Programlanabilir 4 kanallı DC güç kaynağı,
- Voltmetre, ampermetre ve termokupl sensör takımı,
- Özel ÇBS ekipmanları,
- Çeşitli çalışma koşulları empoze etmek için çevre odası,
- PXI kasa tabanlı DAQ ve deney kontrolü



Şekil 8. Batarya test sistemi blok diyagramı

Bu çalışmalarda kullanılan batarya veri setleri Tablo 6'da özetlenmiştir. Veri setleri, bataryaların farklı özellikleri ve performanslarına göre farklılık göstermektedir. Bazı veri setleri, bataryaların ömrü ve yaşlanması hakkında bilgi sağlamak amacıyla tasarlanmışken, bazıları bataryaların kapasitesi ve enerji yoğunluğu gibi performans özellikleri hakkında bilgi vermektedir. Bu veri setleri, batarya yönetim sistemleri ve batarya prognostik uygulamaları gibi batarya teknolojisi ile ilgili birçok alanda kullanılmaktadır. İnternette açık kullanıma sunulan aşağıdaki veri setleri bataryaların özellikleri ve performansı hakkında daha kapsamlı bir anlayış sağlamak için araştırmalarda yaygın olarak kullanılmaktadır. Aşağıdaki tabloda "gr", "grafit", "Cal", takvim yaşlanmasını, "Chrg" şarj protokolü ve "Dhrg" deşarjını, "E", "enerji" anlamına gelmektedir. "IR" iç direnci ve empedansı belirtir.

Tablo 6. Literatürde yaygın olarak kullanılan veri setleri

Veri seti	Batarya hücresi	Test değişkenleri	Veri içeriği	Hücre sayısı
NASA [61],[79]	18650 2 Ah	Dhrg, T	Q, IR, V, I, T	34
CALCE [80]	18650 2.2 Ah LCO	Chrg, Dhrg, T	Q, IR, V, I, T	28
	prismatic 1.1 Ah LCO	Chrg, Dhrg	Q, IR, E, V, I, T	15
	prismatic 1.35 Ah LCO	Chrg, Dhrg, T	Q, IR, E, V, I, T	12
TRI [81]	pouch 1.5 Ah LCO	Chrg, DOD	Q, V, I	16
	18650 1.1 Ah LFP/gr	Chrg	Q, IR, V, I, T	124
		Chrg	Q, V, I, T	233
Sandia [82]	18650 multiples	Dhrg, DOD, T	Q, E, V, I, T	86
Oxford [64]	18650 3 Ah NCA/gr	Chrg, Cal	Q, E, V, I, T	28
HNEI [83]	18650 2.8 Ah NMC-LCO/gr	-	Q, E, V, I	15
Berkeley [84]	18650 2.6 Ah LCO/gr	Chrg	Q, V, I, T	1
Xi'an Jiaotong [85]	pouch 27 Ah NMC/gr	-	Q, E, V, I	2
	15 Ah NMC	Chrg, Dhrg, T	Q, V, I, T	-
Automotive Li-ion Cell Usage [86]		Chrg, Dhrg, T	Q, V, I, T	-
eVTOL [87]	-			-
Cycle Life Prediction [88]	1.1 Ah	Chrg	Q, V, I, T	135
Stanford [89]	4.85 Ah NMC-LCO/gr	Chrg	Q, V, I, T	-
	1.1 Ah LFP/gr	Chrg	Q, V, I, T	
Fast-Charging [90]	1.1 Ah LFP/gr	Chrg	Q, V, I	48
Synthetic [91]	18650 2.9 Ah LFP/gr	Chrg	Q, V, I, T	-
Panasonic [92]				-

3 Sonuçlar ve Öneriler

Bu çalışma, elektrikli araçlarda akıllı bir batarya yönetim sistemi için doğru prognostik ve sağlık yönetimi konusunda literatür incelemesi yapmıştır. Bu inceleme, elektrikli araçlarda akıllı batarya yönetim sistemlerinin önemini vurgulamakta ve bu alanda çalışma yapmayı düşünen araştırmacılar ve endüstri uzmanları için sağlam bir başlangıç noktası sağlamayı amaçlamaktadır.

Mevcut çalışmalar, doğru batarya SoC ve batarya SoH tahminlerinin, batarya ömrünün uzatılması ve güvenliğinin sağlanması açısından kritik olduğunu göstermektedir. Elektrikli araç teknolojisindeki ilerlemelerle birlikte, batarya yönetim sistemlerinin doğruluğu ve güvenilirliği, araç performansı ve sürüş güvenliği açısından giderek daha büyük önem kazanmaktadır. Bu nedenle, gelecekteki araştırmaların bu alanda daha fazla odaklanması ve batarya yönetim sistemlerinin daha da iyileştirilmesi gerekmektedir. Bu bağlamda, bu çalışmanın sağladığı literatür özeti ve vurguladığı kritik noktalar, ileriki araştırmalar için önemli bir kılavuz niteliği taşımaktadır.

Ancak, bu alanda hala bazı açık problemler bulunmaktadır. Gelecekteki araştırmalar, elektrikli araçların batarya yönetim sistemlerini daha da geliştirmek için aşağıdaki konulara odaklanabilir:

Batarya Modelleri ve Prognostik Yöntemleri: Batarya davranışını daha doğru bir şekilde modelleyen ve tahmin eden yeni batarya modelleri ve prognostik yöntemlerin geliştirilmesi önemlidir. Bu, bataryanın gerçek zamanlı performansının daha iyi izlenmesini ve tahmin edilmesini sağlayacaktır.

Veri Analitiği ve Büyük Veri: Elektrikli araçlar, büyük miktarda veri üreten bir ortam oluşturur. Bu verilerin etkili bir şekilde analiz edilmesi ve kullanılması, batarya sağlık durumunun daha iyi anlaşılmasına ve gelecekteki arıza veya sorunların önceden tahmin edilmesine yardımcı olacaktır.

Optimum Şarj ve Boşaltma Stratejileri: Batarya ömrünü uzatmak için optimize edilmiş şarj ve boşaltma stratejilerinin geliştirilmesi önemlidir. Bu stratejiler, bataryanın performansını artırmak ve enerji verimliliğini optimize etmek için bataryanın çalışma koşullarını en uygun şekilde belirlemeyi hedeflemektedir.

Yeni Malzemeler ve Teknolojiler: Batarya teknolojileri sürekli olarak gelişmektedir. Gelecekteki araştırmalar, bataryaların enerji yoğunluğunu artıran ve maliyetleri düşüren yeni malzemelerin ve teknolojilerin keşfine odaklanabilir.

Bu öneriler, elektrikli araçlar için daha güvenli, daha verimli ve daha dayanıklı batarya yönetim sistemlerinin geliştirilmesine katkıda bulunacaktır.

Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur. Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

Yazar Katkıları

MY literatür incelemesi, bilimsel yayının hazırlanması, EC çalışma konsepti ve tasarım, taslağın oluşturulması, revizyon, AY çalışma konsepti ve tasarım, taslağın oluşturulması, revizyon konularında katkı sağlamıştır.

Teşekkür

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'nun (TUBİTAK) 22AG040 nolu "Sürdürülebilir Kentler için İleri Teknolojiler Platformu (SÜİT)" projesi tarafından desteklenmiştir.

Yazarlardan Metin Yılmaz 100/2000 YÖK Doktora bursu öğrencisidir.

Kaynaklar

- [1] J. Deng, C. Bae, A. Denlinger, ve T. Miller, "Electric Vehicles Batteries: Requirements and Challenges", *Joule*, c. 4, sy 3, ss. 511-515, Mar. 2020, doi: 10.1016/j.joule.2020.01.013.
- [2] A. Marongiu, F. G. W. Nußbaum, W. Waag, M. Garmendia, ve D. U. Sauer, "Comprehensive study of the influence of aging on the hysteresis behavior of a lithium iron phosphate cathode-based lithium ion battery - An experimental investigation of the hysteresis", *Applied Energy*, c. 171, ss. 629-645, Haz. 2016, doi: 10.1016/j.apenergy.2016.02.086.
- [3] M. M. Hoque, M. A. Hannan, ve A. Mohamed, *Model Development of Charge Equalization Controller for Lithium-Ion Battery*. 2016.
- [4] U. Yayan, A. T. Arslan, ve H. Yucel, "A Novel Method for SoH Prediction of Batteries Based on Stacked LSTM with Quick Charge Data", *Applied Artificial Intelligence*, c. 35, sy 6, ss. 421-439, May. 2021, doi: 10.1080/08839514.2021.1901033.
- [5] B. Yu, H. Qiu, L. Weng, K. Huo, S. Liu, ve H. Liu, "A Health Indicator for the Online Lifetime Estimation of an Electric Vehicle Power Li-Ion Battery", *World Electric Vehicle Journal*, c. 11, sy 3, Art. sy 3, Eyl. 2020, doi: 10.3390/wevj11030059.
- [6] J. Wu, X. Cui, H. Zhang, ve M. Lin, "Health Prognosis With Optimized Feature Selection for Lithium-Ion Battery in Electric Vehicle Applications", *IEEE Transactions on Power Electronics*, c. 36, sy 11, ss. 12646-12655, Kas. 2021, doi: 10.1109/TPEL.2021.3075558.
- [7] G. Dong, W. Han, ve Y. Wang, "Dynamic Bayesian Network-Based Lithium-Ion Battery Health Prognosis for Electric Vehicles", *IEEE Transactions on Industrial Electronics*, c. 68, sy 11, ss. 10949-10958, Kas. 2021, doi: 10.1109/TIE.2020.3034855.
- [8] X. Hu, J. Jiang, D. Cao, ve B. Egardt, "Battery Health Prognosis for Electric Vehicles Using Sample Entropy and Sparse Bayesian Predictive Modeling", *IEEE Transactions on Industrial Electronics*, c. 63, sy 4, ss. 2645-2656, Nis. 2016, doi: 10.1109/TIE.2015.2461523.
- [9] G. Dong, Z. Chen, J. Wei, ve Q. Ling, "Battery Health Prognosis Using Brownian Motion Modeling and Particle Filtering", *IEEE Transactions on Industrial Electronics*, c. 65, sy 11, ss. 8646-8655, Kas. 2018, doi: 10.1109/TIE.2018.2813964.
- [10] M. A. Hannan, M. S. H. Lipu, A. Hussain, ve A. Mohamed, "A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations", *Renewable and Sustainable Energy Reviews*, c. 78, ss. 834-854, Eki. 2017, doi: 10.1016/j.rser.2017.05.001.
- [11] S. M. Rezvanianiani, Z. Liu, Y. Chen, ve J. Lee, "Review and recent advances in battery health monitoring and prognostics technologies for electric vehicle (EV) safety and mobility", *Journal of Power Sources*, c. 256, ss. 110-124, Haz. 2014, doi: 10.1016/j.jpowsour.2014.01.085.
- [12] H. Wenzl vd., "Life prediction of batteries for selecting the technically most suitable and cost effective battery", *Journal of Power Sources*, c. 144, sy 2, ss. 373-384, Haz. 2005, doi: 10.1016/j.jpowsour.2004.11.045.
- [13] C. Armenta-Deu ve T. Donaire, "Determination of an ageing factor for lead/acid batteries. 1. Kinetic aspects", *Journal of Power Sources*, c. 58, sy 2, ss. 123-133, Şub. 1996, doi: 10.1016/S0378-7753(96)02371-3.
- [14] K. Qian, C. Zhou, M. Allan, ve Y. Yuan, "Modeling of Load Demand Due to EV Battery Charging in Distribution Systems", *IEEE Transactions on Power Systems*, c. 26, sy 2, ss. 802-810, May. 2011, doi: 10.1109/TPWRS.2010.2057456.
- [15] M. Urbain, S. Rael, B. Davat, ve P. Desprez, "State Estimation of a Lithium-Ion Battery Through Kalman Filter", içinde *2007 IEEE Power Electronics Specialists Conference*, Haz. 2007, ss. 2804-2810. doi: 10.1109/PESC.2007.4342463.
- [16] R. C. Kroeze ve P. T. Krein, "Electrical battery model for use in dynamic electric vehicle simulations", içinde *2008 IEEE Power Electronics Specialists Conference*, Haz. 2008, ss. 1336-1342. doi: 10.1109/PESC.2008.4592119.
- [17] Z. B. Omariba, L. Zhang, ve D. Sun, "Review on Health Management System for Lithium-Ion Batteries of Electric Vehicles", *Electronics*, c. 7, sy 5, Art. sy 5, May. 2018, doi: 10.3390/electronics7050072.
- [18] Y. Guo, X. Cai, S. Shen, G. Wang, ve J. Zhang, "Computational prediction and experimental evaluation of nitrate reduction to ammonia on rhodium", *Journal of Catalysis*, c. 402, ss. 1-9, Eki. 2021, doi: 10.1016/j.jcat.2021.08.016.
- [19] A. M. Andwari, A. Pesiridis, S. Rajoo, R. Martinez-Botas, ve V. Esfahanian, "A review of Battery Electric Vehicle technology and readiness levels", *Renewable and Sustainable Energy Reviews*, c. 78, ss. 414-430, Eki. 2017, doi: 10.1016/j.rser.2017.03.138.
- [20] K. Javed, R. Gouriveau, ve N. Zerhouni, "State of the art and taxonomy of prognostics approaches, trends of prognostics applications and open issues towards maturity at different technology readiness levels", *Mechanical Systems and Signal Processing*, c. 94, ss. 214-236, Eyl. 2017, doi: 10.1016/j.ymssp.2017.01.050.

- [21] Z. Li, "Lithium-Ion Battery Management System for Electric Vehicles", *International Journal of Performability Engineering*, c. 14, Ara. 2018, doi: 10.23940/ijpe.18.12.p28.31843194.
- [22] H. Rahimi-Eichi, U. Ojha, F. Baronti, ve M.-Y. Chow, "Battery Management System: An Overview of Its Application in the Smart Grid and Electric Vehicles", *EEE Ind. Electron. Mag.*, c. 7, sy 2, ss. 4-16, Haz. 2013, doi: 10.1109/MIE.2013.2250351.
- [23] D. Tingting, L. Jun, Z. Fuquan, Y. Yi, ve J. Qiqian, "Analysis on the influence of measurement error on state of charge estimation of LiFePO₄ power Battery", içinde *2011 International Conference on Materials for Renewable Energy & Environment*, May. 2011, ss. 644-649. doi: 10.1109/ICMREE.2011.5930893.
- [24] Y. Xing, E. W. M. Ma, K. L. Tsui, ve M. Pecht, "Battery Management Systems in Electric and Hybrid Vehicles", *Energies*, c. 4, sy 11, Art. sy 11, Kas. 2011, doi: 10.3390/en4111840.
- [25] J. P. Rivera-Barrera, N. Muñoz-Galeano, ve H. O. Sarmiento-Maldonado, "SoC Estimation for Lithium-ion Batteries: Review and Future Challenges", *Electronics*, c. 6, sy 4, Art. sy 4, Ara. 2017, doi: 10.3390/electronics6040102.
- [26] J. Wu, C. Zhang, ve Z. Chen, "An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks", *Applied Energy*, c. 173, ss. 134-140, Tem. 2016, doi: 10.1016/j.apenergy.2016.04.057.
- [27] P. Ramadass, B. Haran, R. White, ve B. N. Popov, "Mathematical modeling of the capacity fade of Li-ion cells", *Journal of Power Sources*, c. 123, sy 2, ss. 230-240, Eyl. 2003, doi: 10.1016/S0378-7753(03)00531-7.
- [28] S. B. Sarmah vd., "A Review of State of Health Estimation of Energy Storage Systems: Challenges and Possible Solutions for Futuristic Applications of Li-Ion Battery Packs in Electric Vehicles", *Journal of Electrochemical Energy Conversion and Storage*, c. 16, sy 4, Mar. 2019, doi: 10.1115/1.4042987.
- [29] M. A. Roscher ve D. U. Sauer, "Dynamic electric behavior and open-circuit-voltage modeling of LiFePO₄-based lithium ion secondary batteries", *Journal of Power Sources*, c. 196, sy 1, ss. 331-336, Oca. 2011, doi: 10.1016/j.jpowsour.2010.06.098.
- [30] E. Raszmann, K. Baker, Y. Shi, ve D. Christensen, "Modeling stationary lithium-ion batteries for optimization and predictive control", içinde *2017 IEEE Power and Energy Conference at Illinois (PECI)*, Şub. 2017, ss. 1-7. doi: 10.1109/PECI.2017.7935755.
- [31] J. Ordoñez, E. J. Gago, ve A. Girard, "Processes and technologies for the recycling and recovery of spent lithium-ion batteries", *Renewable and Sustainable Energy Reviews*, c. 60, ss. 195-205, Tem. 2016, doi: 10.1016/j.rser.2015.12.363.
- [32] M. Dubarry, A. Devie, ve B. Y. Liaw, "The Value of Battery Diagnostics and Prognostics", *Journal of Energy and Power Sources*, c. 1, ss. 242-249, Eyl. 2014.
- [33] M. Daowd, M. Antoine, N. Omar, P. Lataire, P. Van Den Bossche, ve J. Van Mierlo, "Battery Management System—Balancing Modularization Based on a Single Switched Capacitor and Bi-Directional DC/DC Converter with the Auxiliary Battery", *Energies*, c. 7, sy 5, Art. sy 5, May. 2014, doi: 10.3390/en7052897.
- [34] A. Allam, S. Onori, S. Marelli, ve C. Taborelli, "Battery Health Management System for Automotive Applications: A retroactivity-based aging propagation study", içinde *2015 American Control Conference (ACC)*, Tem. 2015, ss. 703-716. doi: 10.1109/ACC.2015.7170817.
- [35] G. L. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 1. Background", *Journal of Power Sources*, c. 134, sy 2, ss. 252-261, Ağu. 2004, doi: 10.1016/j.jpowsour.2004.02.031.
- [36] X. Chen, W. Shen, M. Dai, Z. Cao, J. Jin, ve A. Kapoor, "Robust Adaptive Sliding-Mode Observer Using RBF Neural Network for Lithium-Ion Battery State of Charge Estimation in Electric Vehicles", *IEEE Transactions on Vehicular Technology*, c. 65, sy 4, ss. 1936-1947, Nis. 2016, doi: 10.1109/TVT.2015.2427659.
- [37] Y.-J. He, J.-N. Shen, J.-F. Shen, ve Z.-F. Ma, "State of health estimation of lithium-ion batteries: A multiscale Gaussian process regression modeling approach", *AIChE Journal*, c. 61, sy 5, ss. 1589-1600, 2015, doi: 10.1002/aic.14760.
- [38] S.-C. Huang, K.-H. Tseng, J.-W. Liang, C.-L. Chang, ve M. G. Pecht, "An Online SOC and SOH Estimation Model for Lithium-Ion Batteries", *Energies*, c. 10, sy 4, Art. sy 4, Nis. 2017, doi: 10.3390/en10040512.
- [39] S. Jafari ve Y.-C. Byun, "Prediction of the Battery State Using the Digital Twin Framework Based on the Battery Management System", *IEEE Access*, c. 10, ss. 124685-124696, 2022, doi: 10.1109/ACCESS.2022.3225093.
- [40] L. Wang, X. Zhao, Z. Deng, ve L. Yang, "Application of electrochemical impedance spectroscopy in battery management system: State of charge estimation for aging batteries", *Journal of Energy Storage*, c. 57, s. 106275, Oca. 2023, doi: 10.1016/j.est.2022.106275.
- [41] G. Saldaña, J. I. S. Martín, I. Zamora, F. J. Asensio, O. Oñederra, ve M. González, "Empirical Electrical and Degradation Model for Electric Vehicle Batteries", *IEEE Access*, c. 8, ss. 155576-155589, 2020, doi: 10.1109/ACCESS.2020.3019477.
- [42] M. Rezvani, M. AbuAli PhD, S. Lee, J. Lee, ve J. Ni PhD, "A Comparative Analysis of Techniques for Electric Vehicle Battery Prognostics and Health Management (PHM)", program adı: Commercial Vehicle Engineering Congress, Eyl. 2011, ss. 2011-01-2247. doi: 10.4271/2011-01-2247.
- [43] J. Hemdani, M. Soltani, A. J. Telmoudi, ve A. Chaari, "Prediction of aging of battery for electric vehicles based on a modified version of neural networks", içinde *2021 29th Mediterranean Conference on Control and Automation (MED)*, Haz. 2021, ss. 336-341. doi: 10.1109/MED51440.2021.9480161.
- [44] W. He, N. Williard, C. Chen, ve M. Pecht, "State of charge estimation for electric vehicle batteries under an adaptive filtering framework", içinde *Proceedings of the IEEE 2012 Prognostics and System Health Management Conference (PHM-2012 Beijing)*, May. 2012, ss. 1-5. doi: 10.1109/PHM.2012.6228849.
- [45] J. C. Álvarez Antón, P. J. García Nieto, F. J. de Cos Juez, F. Sánchez Lasheras, M. González Vega, ve M. N. Roqueñí Gutiérrez, "Battery state-of-charge estimator using the SVM technique", *Applied Mathematical Modelling*, c. 37, sy 9, ss. 6244-6253, May. 2013, doi: 10.1016/j.apm.2013.01.024.
- [46] A. Mammone, M. Turchi, ve N. Cristianini, "Support vector machines", içinde *WIREs Computational Statistics*, Kas. 2009, ss. 283-289. doi: 10.1002/wics.49.

- [47] S. Zhang, "A new method for lithium-ion battery's SOH estimation and RUL prediction", içinde *2018 13th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, May. 2018, ss. 2693-2697. doi: 10.1109/ICIEA.2018.8398166.
- [48] S. Song, C. Fei, ve H. Xia, "Lithium-Ion Battery SOH Estimation Based on XGBoost Algorithm with Accuracy Correction", *Energies*, c. 13, sy 4, Art. sy 4, Oca. 2020, doi: 10.3390/en13040812.
- [49] J. Hong *vd.*, "Thermal Runaway Prognosis of Battery Systems Using the Modified Multiscale Entropy in Real-World Electric Vehicles", *IEEE Transactions on Transportation Electrification*, c. 7, sy 4, ss. 2269-2278, Ara. 2021, doi: 10.1109/TTE.2021.3079114.
- [50] A. Barr', F. Suard, M. Gérard, ve D. Riu, "A Real-time Data-driven Method for Battery Health Prognostics in Electric Vehicle Use", *PHM Society European Conference*, c. 2, sy 1, Art. sy 1, 2014, doi: 10.36001/phme.2014.v2i1.1514.
- [51] I. JORGE, A. SAMET, T. MESBAHI, ve R. BONÉ, "New ANN results on a major benchmark for the prediction of RUL of Lithium Ion batteries in electric vehicles", içinde *2020 19th IEEE International Conference on Machine Learning and Applications (ICMLA)*, Ara. 2020, ss. 1246-1253. doi: 10.1109/ICMLA51294.2020.00196.
- [52] D. Roman, S. Saxena, V. Robu, M. Pecht, ve D. Flynn, "Machine learning pipeline for battery state-of-health estimation", *Nat Mach Intell*, c. 3, sy 5, Art. sy 5, May. 2021, doi: 10.1038/s42256-021-00312-3.
- [53] P. Jain, S. Saha, ve V. Sankaranarayanan, "Novel method to Estimate SoH of Lithium-Ion Batteries", içinde *2021 Innovations in Energy Management and Renewable Resources(52042)*, Şub. 2021, ss. 1-5. doi: 10.1109/IEMRES2042.2021.9386881.
- [54] J. Zhang, X. Liu, A. Simeone, ve D. Lv, "A deformation-based approach to the SoH estimation of collided lithium-ion batteries", *IOP Conf. Ser.: Earth Environ. Sci.*, c. 463, sy 1, s. 012071, Mar. 2020, doi: 10.1088/1755-1315/463/1/012071.
- [55] X. Liu, J. Li, Z. Yao, Z. Wang, R. Si, ve Y. Diao, "Research on battery SOH estimation algorithm of energy storage frequency modulation system", *Energy Reports*, c. 8, ss. 217-223, May. 2022, doi: 10.1016/j.egy.2021.11.015.
- [56] A. Yang, Y. Wang, K. L. Tsui, ve Y. Zi, "Lithium-ion Battery SOH Estimation and Fault Diagnosis with Missing Data", içinde *2019 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, May. 2019, ss. 1-6. doi: 10.1109/I2MTC.2019.8826888.
- [57] D.-I. Stroe ve E. Schartz, "SOH Estimation of LMO/NMC-based Electric Vehicle Lithium-Ion Batteries Using the Incremental Capacity Analysis Technique", içinde *2018 IEEE Energy Conversion Congress and Exposition (ECCE)*, Eyl. 2018, ss. 2720-2725. doi: 10.1109/ECCE.2018.8557998.
- [58] S. Chowdhury, M. N. Bin Shaheed, ve Y. Sozer, "An Integrated State of Health (SOH) Balancing Method for Lithium-Ion Battery Cells", içinde *2019 IEEE Energy Conversion Congress and Exposition (ECCE)*, Eyl. 2019, ss. 5759-5763. doi: 10.1109/ECCE.2019.8912932.
- [59] S. Pang, J. Farrell, J. Du, ve M. Barth, "Battery state-of-charge estimation", içinde *Proceedings of the 2001 American Control Conference. (Cat. No.01CH37148)*, Haz. 2001, ss. 1644-1649 c.2. doi: 10.1109/ACC.2001.945964.
- [60] Y. Zhou, H. Gu, T. Su, X. Han, L. Lu, ve Y. Zheng, "Remaining useful life prediction with probability distribution for lithium-ion batteries based on edge and cloud collaborative computation", *Journal of Energy Storage*, c. 44, s. 103342, Ara. 2021, doi: 10.1016/j.est.2021.103342.
- [61] "Li-ion Battery Aging Datasets | NASA Open Data Portal". Erişim: 27 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://data.nasa.gov/dataset/Li-ion-Battery-Aging-Datasets/uj5r-zjdb>
- [62] C. Xu, L. Li, Y. Xu, X. Han, ve Y. Zheng, "A vehicle-cloud collaborative method for multi-type fault diagnosis of lithium-ion batteries", *eTransportation*, c. 12, s. 100172, May. 2022, doi: 10.1016/j.etran.2022.100172.
- [63] X. Yang *vd.*, "Lithium-Ion Battery State of Health Estimation with Multi-Feature Collaborative Analysis and Deep Learning Method", *Batteries*, c. 9, sy 2, Art. sy 2, Şub. 2023, doi: 10.3390/batteries9020120.
- [64] C. Birkel, "Oxford Battery Degradation Dataset 1", 2017, Erişim: 27 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://ora.ox.ac.uk/objects/uuid:03ba4b01-cfed-46d3-9b1a-7d4a7bdf6fac>
- [65] T. Sun *vd.*, "A cloud-edge collaborative strategy for capacity prognostic of lithium-ion batteries based on dynamic weight allocation and machine learning", *Energy*, c. 239, s. 122185, Oca. 2022, doi: 10.1016/j.energy.2021.122185.
- [66] A. A. Chehade ve A. A. Hussein, "A Collaborative Gaussian Process Regression Model for Transfer Learning of Capacity Trends Between Li-Ion Battery Cells", *IEEE Transactions on Vehicular Technology*, c. 69, sy 9, ss. 9542-9552, Eyl. 2020, doi: 10.1109/TVT.2020.3000970.
- [67] Y. Wang, R. Xu, C. Zhou, X. Kang, ve Z. Chen, "Digital twin and cloud-side-end collaboration for intelligent battery management system", *Journal of Manufacturing Systems*, c. 62, ss. 124-134, Oca. 2022, doi: 10.1016/j.jmsy.2021.11.006.
- [68] T. Berghout, M. Benbouzid, Y. Amirat, ve G. Yao, "Lithium-ion Battery State of Health Prediction with a Robust Collaborative Augmented Hidden Layer Feedforward Neural Network Approach", *IEEE Transactions on Transportation Electrification*, ss. 1-1, 2023, doi: 10.1109/TTE.2023.3237726.
- [69] S. Piller, M. Perrin, ve A. Jossen, "Methods for state-of-charge determination and their applications", *Journal of Power Sources*, c. 96, sy 1, ss. 113-120, Haz. 2001, doi: 10.1016/S0378-7753(01)00560-2.
- [70] Y.-H. Chiang, W.-Y. Sean, ve J.-C. Ke, "Online estimation of internal resistance and open-circuit voltage of lithium-ion batteries in electric vehicles", *Journal of Power Sources*, c. 196, sy 8, ss. 3921-3932, Nis. 2011, doi: 10.1016/j.jpowsour.2011.01.005.
- [71] N. Noura, L. Boulon, ve S. Jemeï, "A Review of Battery State of Health Estimation Methods: Hybrid Electric Vehicle Challenges", *World Electric Vehicle Journal*, c. 11, sy 4, Art. sy 4, Ara. 2020, doi: 10.3390/wevj11040066.
- [72] C. Vidal, P. Malysz, P. Kollmeyer, ve A. Emadi, "Machine Learning Applied to Electrified Vehicle Battery State of Charge and State of Health Estimation: State-of-the-Art", *IEEE Access*, c. 8, ss. 52796-52814, 2020, doi: 10.1109/ACCESS.2020.2980961.
- [73] R. Xiong, J. Cao, Q. Yu, H. He, ve F. Sun, "Critical Review on the Battery State of Charge Estimation Methods for Electric Vehicles", *IEEE Access*, c. 6, ss. 1832-1843, 2018, doi: 10.1109/ACCESS.2017.2780258.
- [74] L. Yao *vd.*, "A Review of Lithium-Ion Battery State of Health Estimation and Prediction Methods", *World*

- Electric Vehicle Journal*, c. 12, sy 3, Art. sy 3, Eyl. 2021, doi: 10.3390/wevj12030113.
- [75] A. S. Abdelaal, S. Mukhopadhyay, ve H. Rehman, "Battery Energy Management Techniques for an Electric Vehicle Traction System", *IEEE Access*, c. 10, ss. 84015-84037, 2022, doi: 10.1109/ACCESS.2022.3195940.
- [76] J. Hong vd., "Fault Prognosis and Isolation of Lithium-Ion Batteries in Electric Vehicles Considering Real-Scenario Thermal Runaway Risks", *IEEE Journal of Emerging and Selected Topics in Power Electronics*, c. 11, sy 1, ss. 88-99, Şub. 2023, doi: 10.1109/JESTPE.2021.3097827.
- [77] D. Li, Z. Zhang, P. Liu, Z. Wang, ve L. Zhang, "Battery Fault Diagnosis for Electric Vehicles Based on Voltage Abnormality by Combining the Long Short-Term Memory Neural Network and the Equivalent Circuit Model", *IEEE Transactions on Power Electronics*, c. 36, sy 2, ss. 1303-1315, Şub. 2021, doi: 10.1109/TPEL.2020.3008194.
- [78] B. Jiang, Z. Chen, ve F. Chen, "Influence of Sampling Delay on the Estimation of Lithium-Ion Battery Parameters and an Optimized Estimation Method", *Energies*, c. 12, sy 10, Art. sy 10, Oca. 2019, doi: 10.3390/en12101878.
- [79] "Prognostics center of excellence - data repository", NASA Ames Progn Res Center. Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: <http://www.nasa.gov/intelligent-systems-division>
- [80] "Battery Data | Center for Advanced Life Cycle Engineering", CALCE battery research group. Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://calce.umd.edu/battery-data>
- [81] "Experimental Data Platform", Toyota Research Institute. Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://data.matr.io/1/>
- [82] "Data for degradation of commercial lithium-ion cells as a function of chemistry and cycling conditions", Sandia National Lab. Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: https://www.batteryarchive.org/snl_study.html
- [83] Y. Preger vd., "Degradation of Commercial Lithium-Ion Cells as a Function of Chemistry and Cycling Conditions", *J. Electrochem. Soc.*, c. 167, sy 12, s. 120532, Oca. 2020, doi: 10.1149/1945-7111/abae37.
- [84] D. Gun, H. Perez, ve S. Moura, "Berkeley: eCal fast charging test data". Dryad, s. 293617695 bytes, 2015. doi: 10.6078/D1MS3X.
- [85] S. Zhang, "Data for: A data-driven coulomb counting method for state of charge calibration and estimation of lithium-ion battery - Mendeley Data". Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://data.mendeley.com/datasets/c5dxwn6w92/1>
- [86] M. Luzzi, "Automotive Li-ion Cell Usage Data Set". IEEE, 07 Eylül 2018. Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://iee-dataport.org/documents/automotive-li-ion-cell-usage-data-set>
- [87] "eVTOL Battery Dataset". Carnegie Mellon University, 18 Mart 2021. doi: 10.1184/R1/14226830.v3.
- [88] "Data-driven prediction of battery cycle life before capacity degradation", Cycle Life Prediction. Erişim: 29 Nisan 2023. [Çevrimiçi]. Erişim adresi: <https://data.matr.io/1/projects/5c48dd2bc625d700019f3204>
- [89] G. Pozzato, A. Allam, ve S. Onori, "Lithium-ion battery aging dataset based on electric vehicle real-driving profiles", *Data Brief*, c. 41, s. 107995, Şub. 2022, doi: 10.1016/j.dib.2022.107995.
- [90] P. M. Attia vd., "Closed-loop optimization of fast-charging protocols for batteries with machine learning", *Nature*, c. 578, sy 7795, ss. 397-402, Şub. 2020, doi: 10.1038/s41586-020-1994-5.
- [91] M. Dubarry, "Graphite//LFP synthetic training diagnosis dataset", c. 1, May. 2020, doi: 10.17632/bs2j56pn7y.1.
- [92] P. Kollmeyer, "Panasonic 18650PF Li-ion Battery Data", c. 1, Haz. 2018, doi: 10.17632/wykht8y7tg.1.

Özgeçmişler



Metin Yılmaz, Eskişehir Osmangazi Üniversitesi'nde (ESOGÜ) doktora öğrencisidir. Yedi yıl boyunca Tusaş Motor Sanayii A.Ş.'de kıdemli yazılım mühendisi olarak çalıştı. 2020 yılında bilgisayar mühendisliği alanında yüksek lisans derecesini aldı. ESOĞÜ'de Akıllı Fabrika ve Robotik Laboratuvarı'nın bir parçası olarak Türkiye Bilimsel ve Teknik Araştırma Kurumu (TÜBİTAK) doktora bursiyeri öğrencisidir. Ayrıca 100/2000 Yükseköğretim Kurulu (YÖK) doktora bursiyeridir. Araştırma çalışmaları, robotik sistemler, yapay zeka ile endüstriyel sistemlerde hata tespiti ve tahmini konularına odaklanmaktadır.



Doç. Dr. Eyüp Çınar, Fulbright Bursiyeri olarak 2010 yılında New York, ABD'deki Rochester Institute of Technology'de Elektrik ve Mikroelektronik Mühendisliği alanında yüksek lisans derecesini almıştır. Aynı üniversitenin Mikrosistem Mühendisliği bölümünde doktorasına devam etmiş ve 2015 yılında doktora derecesini almıştır. Sonrasında, ABD'de yaklaşık dört yıl boyunca çeşitli şirketlerde Kıdemli Mühendis olarak endüstriyel deneyim kazanmıştır. New York eyaletindeki dünyaca ünlü GLOBALFOUNDRIES Fab8 çip üretim tesisinde Kıdemli Gelişmiş Süreç Kontrol mühendisi olarak, yarı iletken üretiminde hata tahmini, sınıflandırma ve süreç kontrolü üzerine çalışmıştır. Daha sonra, San Jose, CA'daki ASML-HMI Ar-Ge merkezinde Kıdemli Yarı İletken Desenleme Veri Bilimcisi olarak çalışmaya devam etmiştir. 2019 yılında Dr. Eyüp Çınar, 2023'ten beri Bilgisayar Mühendisliği Doçenti ve Eskişehir Osmangazi Üniversitesi'nde öğretim üyesidir. Aynı zamanda Elektrik ve Elektronik Mühendisleri Enstitüsü'nün (IEEE) kıdemli üyesidir.



Prof. Dr. Ahmet Yazıcı, 2000 ve 2005 yıllarında Eskişehir Osmangazi Üniversitesi'nde (ESOGÜ) kontrol sistemleri alanında yüksek lisans ve doktora derecelerini almıştır. 2007 Darpa Urban Challenge'da OSU-ACT Ekibi üyesiydi. 2005 yılından beri Eskişehir Osmangazi Üniversitesi Bilgisayar Mühendisliği Bölümü'nde çalışmaktadır. Akıllı Fabrika ve Robotik Laboratuvarı'nın kurucusudur. Ayrıca ESOĞÜ'de Akıllı Sistemler Araştırma Merkezi'nin müdürüdür. Mevcut araştırma ilgi alanları arasında akıllı araçlar, Akıllı Fabrika ve Otonom Sistemler bulunmaktadır.