

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
SİVİL HAVACILIK ANABİLİM DALI**

**BATARYALARIN KALAN FAYDALI ÖMRÜNÜN DERİN
ÖĞRENME KULLANILARAK İNCELENMESİ**

**Hazırlayan
Hava Merve ÇELİK**

**Danışman
Doç. Dr. Mehmet KONAR
Öğr. Gör. Dr. Oğuz BEKTAŞ**

Yüksek Lisans Tezi

**Haziran 2023
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
SİVİL HAVACILIK ANABİLİM DALI**

**BATARYALARIN KALAN FAYDALI ÖMRÜNÜN DERİN
ÖĞRENME KULLANILARAK İNCELENMESİ**

**Hazırlayan
Hava Merve ÇELİK**

**Danışmanlar
Doç. Dr. Mehmet KONAR
Öğr. Gör. Dr. Oğuz BEKTAŞ**

Yüksek Lisans Tezi

**Haziran 2023
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Hava Merve ÇELİK



“Bataryaların Kalan Faydalı Ömrünün Derin Öğrenme Kullanılarak İncelenmesi”
adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma
Yönergesi’ ne uygun olarak hazırlanmıştır.

Hazırlayan

Hava Merve ÇELİK

Danışman

Doç. Dr. Mehmet KONAR

Sivil Havacılık ABD Başkanı

Prof. Dr. İlke TÜRKMEN

İmza



TEŐEKKÜR

Bana alıőmalarım süresince her türlü yardımı ve fedakârlığı saęlayan, kıymetli hocalarım Do. Dr. Mehmet KONAR'a ve Öğr. Gör. Dr. Oęuz BEKTAŐ'a sonsuz teőekkürlerimi sunarım.

Tez alıőmam esnasında gösterdiği sabır ve desteęinden dolayı eőim Abdulrahim ELİK'e teőekkür ederim.

Bugünlere gelmemde maddi ve manevi her türlü desteęi saęlayıp, her zaman yanımda duran kıymetli aileme de teőekkürlerimi sunarım.

Hava Merve ELİK

Haziran 2023, KAYSERİ

BATARYALARIN KALAN FAYDALI ÖMRÜNÜN DERİN ÖĞRENME KULLANILARAK İNCELENMESİ

Hava Merve ÇELİK

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Haziran 2023
Danışman: Doç. Dr. Mehmet KONAR
İkinci Danışman: Dr. Oğuz BEKTAŞ

ÖZET

Bataryalar, taşınabilir, şarj edilebilir ve kullanışlı olması gibi birçok özellikleri sayesinde çok çeşitli elektrikli cihaz ve ekipmanlarda güç kaynağı olarak kullanılmaktadır. Kullanım süresinde kalan faydalı ömürlerin bilinmesi bataryalar için en önemli faktörün başında gelmektedir. Kalan faydalı ömür süresini, kullanım şekli, saklama ve çevre koşulları gibi çeşitli faktörler etkilemektedir. Kullanım esnasında kapasite kademeli olarak azalmaktadır. Batarya türüne bağlı olarak her bataryanın belirli bir eşik seviye bulunmaktadır. Bu eşik seviyesi aşıldığı zaman batarya yeterli güç sağlamayacak noktayı ulaşmış olacaktır. Bir bataryanın kalan faydalı ömrü, kapasitesinin kullanım süreci boyunca ölçülmesiyle ya da aynı türdeki kullanılmış veya yeni olan bataryaların performansıyla karşılaştırılmasıyla tahmin edilebilmektedir. Sıcaklık, şarj akımları ve deşarj hızı gibi faktörler de bataryanın kalan kullanım ömrünü etkilemektedir. Bir bataryanın kalan faydalı ömrünü artırmak için, bataryayı uygun şekilde kullanmak ve saklamak ve aşırı şarj veya aşırı deşarjdan kaçınmak önemlidir. Bu tez çalışmasında, bataryaların kalan faydalı ömrünün incelenmesi amaçlanmıştır. Bu amaç için, NASA Ames Prognostik Mükemmeliyet Merkezi (Prognostics Center of Excellence,PCOE) veri setlerinden Li-ion batarya verinin kalan faydalı ömrünün incelenmesi ele alınmıştır. İncelemede derin öğrenme yöntemlerinden, zaman seri şeklinde olan verilerde sıklıkla kullanılan LSTM algoritmasından yararlanılmıştır. Çalışma sonucunda elde edilen bulgular ışığında bataryanın kalan faydalı ömrünün artırılması için gerekli önlemler vurgulanmıştır.

Anahtar Kelimeler: Derin Öğrenme, Batarya, Kalan Faydalı Ömür

INVESTIGATION OF THE REMAINING LIFE OF BATTERIES USING DEEP LEARNING

Hava Merve ÇELİK

Erciyes University, Graduate School of Natural and Applied Sciences
Master Thesis, June 2023

Supervisor: Assoc. Prof. Mehmet KONAR

Co-Supervisor: Dr. Oğuz BEKTAŞ

ABSTRACT

Batteries, thanks to their many features such as being rechargeable and usable, are used as a power source in various electrical devices and in the obtained one. The useful life of the remaining useful life is one of the most important factors for batteries. The remaining useful life time affects several factors such as usage, storage and environmental conditions. During use, the capacity decreases as its capacity. A certain threshold level at which each battery exists, depending on the battery group. When this threshold level is exceeded, it will have reached the point where it cannot provide sufficient power. The remaining useful life of a battery can be estimated by measuring its capacity over the course of its use, or by comparing it to the performance of used or new batteries of the same type. Factors such as temperature, charge currents and discharge rate also affect the remaining life of the battery. To increase the remaining useful life of a battery, it is important to handle and store the battery properly and to avoid overcharging or over-discharging. In this thesis, it is aimed to examine the remaining useful life of batteries. For this purpose. Examining the remaining useful life of Li-ion battery data from NASA Ames Prognostic Excellence Center (PCOE) datasets is discussed. In the study, deep learning methods, LSTM algorithm, which is frequently used in time series data, was used. In the light of the findings obtained as a result of the study, the necessary measures to increase the remaining useful life of the battery were emphasized.

Keywords: Deep Learning, Battery, Remaining Useful Life

İÇİNDEKİLER

BATARYALARIN KALAN FAYDALI ÖMRÜNÜN DERİN ÖĞRENME KULLANILARAK İNCELENMESİ

BİLİMSEL ETİĞE UYGUNLUK	ii
YÖNERGEYE UYGUNLUK.....	iii
KABUL VE ONAY	iv
TEŞEKKÜR.....	v
ÖZET.....	vii
ABSTRACT	viii
İÇİNDEKİLER	ix
KISALTMALAR ve SİMGELER	xi
TABLolar LİSTESİ.....	xii
ŞEKİLLER LİSTESİ	xiii
GİRİŞ	1

1.BÖLÜM

GENEL BİLGİLER VE LİTERATÜR ARAŞTIRMASI

1.1. Genel Bilgiler	3
1.2. Literatür Değerlendirmesi.....	4

2. BÖLÜM

BATARYALAR VE DERİN ÖĞRENME

2.1. Bataryalar ve Türleri.....	9
2.1.1. Çinko Karbon Bataryalar	9
2.1.2. Alkali Manganez Oksit Bataryalar.....	11
2.1.3. Çinko Hava Bataryalar.....	12
2.1.4. Cıva Oksit Bataryalar	13
2.1.5. Gümüş Oksit Bataryalar	14
2.1.6. Nikel Kadmiyum Bataryalar	16
2.1.7. Nikel Metal Hidrit Bataryalar	17
2.1.8. Lityum Hava Bataryalar	19
2.1.9. Lityum Polimer Bataryalar	19
2.1.10. Lityum İyon Bataryalar	20
2.2. Enerji Yoğunluğu Noktasında Lityum İyon Bataryalar	20

2.3. Lityum İyon Bataryaların İç Yapıları ve Şarj Döngüleri	21
2.4. Derin Öğrenme	22
2.4.1. Derin Öğrenmenin Tarihi.....	23
2.5. Derin Öğrenme Mimarileri	23
2.5.1. Konvolüsyonel Sinir Ağı	23
2.5.2. Tekrarlayan Sinir Ağları	24
2.5.3. Uzun Kısa Vadeli Hafıza Ağları (LSTM).....	25
2.6. Derin Öğrenme Katmanları	26
2.6.1. Giriş Katmanı	26
2.6.2. Konvolüsyon katmanı	26
2.6.3. Havuzlama Katmanı	27
2.6.4. Tam Bağlı Katman	28
2.6.5. Sönümleme Katmanı.....	28
2.6.6. Sınıflandırma Katmanı	29

3. BÖLÜM YÖNTEM

3.1. Batarya Veri Seti Uygulaması.....	32
--	----

4. BÖLÜM TARTIŞMA-SONUÇ VE ÖNERİLER

4.1. Tartışma	46
4.2. Sonuç ve Öneriler	46
KAYNAKÇA	48
ÖZGEÇMİŞ.....	53

KISALTMALAR ve SİMGELER

Li-ion	:Lityum İyon
Li-po	:Lityum Polimer
KFÖ	:Kalan Faydalı Ömür
NiCd	:Nikel Kadmiyum
PHM	:Tahmin Sağlık Yöntemi
SOH	:Mevcut Sağlık Durumu
SVM	:Destek Vektör Makinesi
YSA	:Yapay Sinir Ağları
DÖ	:Derin Öğrenme
KF	:Kalman Filtresi
PF	:Parçacık Filtresi
EOL	:End of Limit
TCN	:Temporal Convolutional Network
GCN	:Grap Convolutional Network
ZnS	:Sfalent
SOC	:State of Charge
RNN	:Tekrarlayan Sinir Ağları
CNN	:Konvolüsyonel Sinir Ağları
LSTM	:Uzun Kısa Vadeli Hafıza Ağları
CC	:Sabit Akım
Ah	:Amper hour
RMSE	:Root Mean Square Error
PCOE	:Prognostik Mükemmeliyet Merkezi Prognostics Center of Excellence

TABLolar LİSTESİ

Tablo 3.1. 5 nolu batarya veri seti.....	33
Tablo 3.2. 6 nolu batarya veri seti.....	33
Tablo 3.3. 7 nolu batarya veri seti.....	34
Tablo 3.4. 18 nolu batarya veri seti.....	34
Tablo 3.5. Sunulan algoritmanın ve karşılaştırılabilir algoritmaların sembolleri ve açıklamaları.....	40
Tablo 3.6. Önerilen algoritmanın RMSE'si ve tüm batarya birimleri için listelenen algoritmalar.....	40

ŞEKİLLER LİSTESİ

Şekil 2. 1. Çinko bataryanın yapısı	10
Şekil 2. 2. Alkali mangan oksit batarya içyapısı	11
Şekil 2. 3. Çinko hava batarya yapısı	12
Şekil 2.4. Cıva oksit batarya yapısı	13
Şekil 2.5. Gümüş oksit batarya yapısı	15
Şekil 2.6. Gümüş oksit batarya görünümü	15
Şekil 2.7. NiCd batarya iç yapısı	16
Şekil 2.8. NiCd batarya yapısal özelliği	18
Şekil 2. 9. Nikel metal hidrit Batarya içyapısı	18
Şekil 2.10. Li-po batarya iç yapısı	19
Şekil 2.11. Li-ion batarya iç yapısı	20
Şekil 2. 12. İlk DÖ mimarisi	23
Şekil 2.13. CNN mimarisi	24
Şekil 2.14. RNN mimarisi	25
Şekil 2.15. LSTM mimarisi	26
Şekil 2.16. Konvolüsyon katmanı	27
Şekil 2.17. En büyük değer havuzlama örneği	28
Şekil 2.18. Tam bağlı katmanı	28
Şekil 2.19. a) YSA b) Sönümlenmiş sinir ağı	29
Şekil 3.1. 5 nolu bataryanın ham veri seti kapasitesinin zamana göre değişimi	35
Şekil 3.2. 6 nolu bataryanın ham veri seti kapasitesinin zamana göre değişimi	35
Şekil 3.3. 7 nolu bataryanın ham veri seti kapasitesinin zamana göre değişimi	36
Şekil 3.4. 18 nolu bataryanın ham veri seti kapasitesinin zamana göre değişimi	36
Şekil 3.5. 5 nolu bataryanın ham veri seti SOH zamana göre değişimi	37
Şekil 3.6. 6 nolu bataryanın ham veri seti SOH zamana göre değişimi	38

Şekil 3.7. 7 nolu bataryanın ham veri seti SOH zamana göre değişimi.....	38
Şekil 3.8. 18 nolu bataryanın ham veri seti SOH zamana göre değişimi.....	39
Şekil 3.9. 5 nolu bataryanın veri setinin gerçek ve eğitilmiş SOH karşılaştırılması.....	41
Şekil 3.10. 6 nolu bataryanın veri setinin gerçek ve eğitilmiş SOH karşılaştırılması....	41
Şekil 3.11. 7 nolu bataryanın veri setinin gerçek ve eğitilmiş SOH karşılaştırılması....	42
Şekil 3.12. 18 nolu bataryanın veri setinin gerçek ve eğitilmiş SOH karşılaştırılması....	42
Şekil 3.13. 5 nolu bataryanın test veri setinin ve tahmin ettiğimiz veri setinin eşik değerlerinin karşılaştırılması.....	44
Şekil 3.14. 6 nolu bataryanın test veri setinin ve tahmin ettiğimiz veri setinin eşik değerlerinin karşılaştırılması.....	44
Şekil 3.15. 7 nolu bataryanın test veri setinin ve tahmin ettiğimiz veri setinin eşik değerlerinin karşılaştırılması.....	45
Şekil 3.16. 18 nolu bataryanın test veri setinin ve tahmin ettiğimiz veri setinin eşik değerlerinin karşılaştırılması.....	45

GİRİŞ

Günümüzde teknolojisinde elektrikle çalışan araçların artması ve akıllı sistemlerin gelişmesiyle birlikte, enerji depolama ihtiyacı artış göstermiştir. Lityum-Polimer (Li-Po) ve Lityum-iyon (Li-ion) bataryalar, kimyasal ve fiziksel enerji depolama özellikleri bakımından dikkate alındığında diğer bataryalara göre daha üstün özelliklere sahip olduğu görülmektedir. Bu üstün özelliklerden dolayı, bu bataryalar kullanıcılar tarafından sıklıkla tercih edilmektedir.

Farklı dinamik sistemlerde artan kullanım alanlarına sahip pahalı bataryaların dinamiklerindeki yaşa bağlı değişimlerinin takibi gerekmektedir. Bu takip gerekliliği, zamanımız akademik çalışmaları ve endüstriyel alanlar için fazlaca ilgiye sebep olmaktadır. Batarya gücüyle katkı sağlanan kalan sistem işlemlerinin gerçek tahminlerine ulaşmak için elektrokimya tabanlı Li-ion batarya modelinin parametrelerine uyarlanması ile yaşa bağlı farklılıkları hesaba katarak uygulanan yeni yöntemler sunulması üzerine birçok çalışma yapılmıştır. Yapılan çalışmalarda batarya yönetim sistem gerekliliğinin açığa çıktığı görülmektedir. Temel bir batarya yönetim sistemi batarya ile ilgili tüm verileri toplar devamında da gerekli modellemeyi yaparak, şarj ve deşarj durum tahminlerini gerçekleştirmektedir. Bu durum tahminlerinde hücrelerin sıcaklık gibi etmenlerini göz önüne alarak batarya hücrelerini kontrolünü ve iletişimini yapmaktadır.

Batarya yönetim sisteminin kullanılmasıyla birlikte, Li-ion bataryalar, yüksek enerji depolama kapasitesi, verimliliği, uzun süre kullanım ömrüne sahip olması, düşük bakım gerekliliği gibi sebeplerle insansız kara ve hava araçları için yaygın olarak bir güç kaynağı olarak benimsenmiştir.

Li-ion bataryalar alanındaki yapılan araştırmalar, şarj süresinin arttırılması ve enerji yoğunluğunu iyileştirmesi, üretim maliyetlerinin düşürülmesi ve batarya ömrünün uzatılması gibi çeşitli yönlere odaklanılmıştır. Ek olarak, enerji yoğunluğunu maksimize etmek için farklı katmanlı katot malzemelerinin evrimi üzerine çalışmalar yapılmıştır.

Bununla birlikte, bataryaların güvenliđi ve verimliliđi bařında en önemli etmen batarya řarj-deřarj dōngülerinin zamanla artmasının olduđu gōr÷lmektedir.

Bu alıřmada farklı bataryalar hakkında bilgi verilmesi, kullanılan veriler ışığında Li-ion bataryanın deřarj deđiřimin gōzlenmesi üzerinde durulmaktadır. Bu deđiřimin kapsamında, bataryaların Kalan Faydalı Őmr÷n÷n (Remaining Useful Life, KFŐ) incelemesi amalanmıřtır.



1.BÖLÜM

GENEL BİLGİLER VE LİTERATÜR ARAŞTIRMASI

1.1. Genel Bilgiler

Bataryalar yenilenebilir enerji kökenlerinin zaman zaman oluşturulmasını yoluna sokmak ve elektriğin ana bileşen olduğu yerlerde tercih edilmektedir. Tercih türlerine göre teknik niteliklerce sınıflandırılan değişik bataryalar bulunmaktadır. Bu farklı batarya çeşitlerinin arasında son yılların en gözde batarya çeşidi olan Li-ion bataryalar üst düzey enerji yoğunluğu ve kullanım ömrü süresinin fazlalığı ile araştırmalara sıklıkla konu olmaktadır. Elektrikli araçlar, uçaklar, deniz araçları ve tüketici elektroniğinden savunma elektroniğe kadar Li-ion bataryalar kullanılmakta ve bu da geniş bir yelpazede kullanımı sağlandığının açık bir kanıtıdır. Kullanılan bataryaların güvenliğini arttırmak, ekonomik kayıpların önüne geçmek için uzun zamandır periyodik bakımları yapılmakta olup, bu bakımların zamanlamasının tam vaktinde olup olmadığını bataryaların KFÖ'lerine bakarak çıkarabilmektedir [1-3].

Çeşitli yığıma metotlarının bilindiği ve enerji biriktirme amacıyla kullanılan yolların en kritik olan şekli, bataryalar vasıtasıyla elektrik enerjisini kimyasal enerjiye çevirerek gerçekleştirilen depolama yöntemidir. İlerleme gösteren teknoloji ile bataryalar daha gözde olmaya başlamış ve günümüzde sıklıkla tercih edilen, ticari açıdan popüler olan ve en iyi enerji yoğunluğu olan batarya türü, Li-ion bataryalardır. Nikel-kadmiyum (NiCd) ve kurşun asit bataryalar, Li-ion bataryalar gündeme gelene kadar sıklıkla tercih edilmekteydi. Li-ion bataryaların uzun süre dayanabilmeleri, yüksek potansiyel aktivitesi, yüklerinin az olması, düşük deşarj yönelimleri gibi farklı artı yönleri bu bataryaları hayatımızın pek çok yerine dahil olmasına katkısı olan etmenler arasında yer almaktadır [4-8].

Li-ion bataryalar hayatımızın çeşitli yerlerinde ve batarya kullanılan pek çok alanda tercih edilmeye başlanmış olup, kullanılan bazı yerler havacılık ve uzay sanayi, elektrikli araçlar, uydu sistemleri, dik süpürgeler, cep telefonları, taşınabilir bilgisayarlar ve daha birçok taşınabilir elektronik araçlardır. Örneklerde de gördüğü gibi pek çok hayati önem taşıyan alanda var olan Li-ion bataryaların KFÖ ve Mevcut Sağlık Durumunda (State of Health, SOH) detaylı bir şekilde incelenmesi gereken riskli konular arasında yer almaktadır. Çünkü bu batarya çeşidinin kalan döngüsünü çıkarımının yapılabilmesi, randımanlı kaynaktan fayda sağlamada ve enerjiyi depolayan aygıtlardan düzenli yararlanılması açısından avantajları oldukça yüksektir [9-10].

KFÖ ve SOH tahmin etmeyi amaçlayan ana dal Tahmin Sağlık Yönetimi (Prognostic of Health Management, PHM) olarak bilinmekte ve öncelikli amacı güvenilirliği analiz etmek, sigortalamak ve ileriye taşımaktır. Veriye dayalı ve fizik tabanlı model olmak üzere 2 temel bakış açısı mevcuttur. Veri tabanlı ele alma biçiminin yapılan araştırmalara göre daha fazla tercih edilme nedeni model tabanlı metota göre daha uygulanabilir, detaylı bilgi gerektirmeyen ve değişken olmasını bulunmaktadır. Model altyapılı ele alış biçiminde bozulmaları açıklayabilmek adına belli algoritmik açıklamalar gerekirken veri tabanlı metotta önceden meydana gelen bozulma datalarının kullanıldığı görülmektedir. Destek Vektör Makinesi (Support Vector Machine, SVM), lojistik regresyon, Yapay Sinir Ağları (Artificial Neural Network, YSA) ve Derin Öğrenme (Deep Learning, DÖ) gibi algoritmalar ile Li-ion bataryaların KFÖ çıkarımları için tercih edilen metotlardandır. Yapılan bu tez çalışmamızda ise NASA Ames PCOE veri setlerinden Li-ion batarya verinin Kalan Faydalı Ömürlerinin (KFÖ) Derin Öğrenme (DÖ) kullanılarak incelenmesi ele alınmıştır.

1.2. Literatür Değerlendirmesi

Bataryaların KFÖ, şarj durumu ve sağlık durumunun analizleri için geçmişten günümüze farklı tarzda birçok yöntem kullanılmıştır. Yapılan analizlerden elde edilen sonuçlar tatmin edici olsa da hala bu konu üzerindeki çalışmalar devam etmekte ve daha iyisi için çabalanmaktadır. Literatürdeki Li-ion bataryalar üzerine bir çok çalışma yapılmıştır [11-23].

Bole et. al. çalışmalarında, Li-ion bataryalarının elektrokimyasal modellerinde parametrelerin uyarlanması amacıyla yeni bir yöntem başvurmuşlardır [11]. Bu yöntem Kalman Filtreleme (Kalman Filter, KF) algoritmasının, yalnızca rastgele deşarj

profilleri üzerinden toplanan batarya akımı, voltaj verileri ile dahili batarya durumu tahminlerinin ve yaşa bağlı elektrokimyasal model parametre tahminlerinin yapılabildiğini göstermektedir. Ulaşılan deneysel sonuçlar önerilen algoritma ile üretilen çevrimiçi model tahminlerini, referans deşarj döngülerini çalıştırırken bataryaları periyodik olarak çevrimdışı duruma getirmiştir. Elde edilen çevrimdışı model tahminleriyle karşılaştırmışlardır. Referans deşarj döngülerinin verileri yerine, sadece rastgele deşarj profilleri üzerinden toplanan verileri kullanmışlardır.

Penna et. al. çalışmalarında, ilk olarak Li-ion havacılık bataryalarının yaşam döngüsünü sunmuşlardır [12]. Bataryanın kapasitesi ve sağlık izleme modelleri doğrultusunda deşarj oluşturmak için yöntem önermişlerdir. Bu modellerde tavsiye edilen yöntemlere göre batarya KFÖ çıkarımındaki kullanımına değinmişlerdir. Yöntem, NASA Ames PCOE'den alınan veriler kullanılarak doğrulanmıştır. Modelleri MATLAB/Simulink kullanılarak gerçekleştirmişlerdir.

Saha et. al. çalışmalarında, KFÖ tahmininin, modelleme tutarsızlıkları, sistem gürültüsü ve bozulmuş sensör doğruluğu gibi birden çok hata kaynağıyla mücadele etmesi gerektiğini göstermişlerdir [13]. Klasik KF'sinin performansının yetersiz olduğunu vurgulamışlardır. Bu sebeple bayesçi yaklaşımı kullanarak modelleme oluşturmuşlar KFÖ tahminlerini sağlamak için gürültünün istatistiksel tahminlerinin ve beklenen çalışma koşullarının kullanıldığı bir Parçacık Filtresi (Particle Filter, PF) çerçevesine dahil etmişlerdir. Çalışmalarında Li-ion bataryalardan toplanan deneysel verilerle bahsedilen yaklaşımların karşılaştırmasını sunmuşlardır. Sensörlerle erişilemeyen dahili durum değişkenleri ve operasyonel koşullarda ölçülmesi güç olan karmaşık yapılara bataryaların iyi örnek oluşturması bataryaları tercih etmelerinde etkili olmuştur.

Cheng et al. çalışmalarında, kendine özgün birden fazla prognostik algoritmayı, Li-ion bataryalarının kapasitesinin çıkarımında kullanmışlardır [14]. Bunun için bir prognostik yapı taşı oluşturmuşlardır. Yapıtasında dolu bir bataryanın deşarj döngüleri ele alınmıştır. Bireysel prognostik algoritmadansa tasarlanan toplu prognostik algoritmanın daha güvenilir olduğunu göstermişlerdir.

Bole et al. çalışmalarında, uçuşun devamında çıkış gücü ve voltaj ihtiyaçları açısından kullanılan bataryaların tahmini minimum ve maksimum belirsizlik seviyelerini belirlemek için bir çalışma yapmışlardır [15]. Bataryaların deşarj çıkarımlarında

belirsizlik aşılamayan bir problem olsa da prognostik açıdan belirsizlik söz konusu bile olduğunda uçuş güvenliği için tatmin edici çıkarımlara ulaşmışlardır.

Jing et al. çalışmalarında, ilerleyen zaman dilimi için uçak bakımı ve lojistiğin esas kabiliyetleriyle ilgili tavsiyede bulunmuşlar [16] ve aynı zamanda bu konuların zaman içindeki evrimi üzerinde tartışmışlardır. Bu değişim için prognostik ve sağlık yönetiminin gelişim ve ilerleyişine detaylı olarak değinmişlerdir.

Sharif et al. yaptıkları çalışmada, uçuşlarda sonuna kadar devamını getirebilmesi için bataryanın kullanım zamanını son anında KFÖ sorunun ne kadar önemli olduğuna değinmişlerdir [17]. KFÖ tahmini için farklı uçuş koşullarında dört ayrı makine öğrenme tekniği kullanmışlardır.

Junbo et al. çalışmalarında, bataryaların KFÖ tahminini yaparken kullanılan klasik prognostik yöntemlerden dolayı yaşanan dengesizliklere yoğunlaşmışlardır [18]. Sonrasında ise en gelişmiş prognostik yöntemleri kullanarak daha güncel bir model için çalışmalarına devam etmişlerdir.

Saha et al. yaptıkları çalışmada, Li-po bataryaların esas elektrokimyasal işleyişlerini, eş zamanlı bataryanın şarj takibini yapmak ve KFÖ alakalı çıkarımlar yapmak amacıyla Bayes modelini kullanmışlardır [19]. Benzer uçuş şekilleri ve yapılan testlerin sonuçları ile prognostik kullanımların karşılaştırmasını sunmuşlardır.

Saha et al. yaptıkları çalışmada, ilerleyen zaman dilimindeki bataryanın yük dengesizliklerine karşı gösterdiği durumları incelemek amacıyla PF'leme prognostiğini sunmuşlardır [20]. Bataryanın kapanmamasını sağlarken bunun yanında maksimum seviyeye ulaştırılan bataryanın en doğru uçuş şekli için, bataryanın KFÖ'nü araştırmışlardır.

Zhao et al. çalışmalarında, bataryanın şarj döngüleri vasıtasıyla ulaştığı SOH'sini doğru bir şekilde ölçebilmek için Uzun-Kısa Vadeli Bellek (Long Short-Term Memory, LSTM) algoritmasını Gauss süreciyle birleştirmiştir [21]. Sağlık etmenlerinden dolayı olan yol değişimleri takip amacıyla LSTM modelini benimsemişlerdir. Gauss süreç modeli ile yol değişiklikleri SOH çıkarımları amacıyla desteklemişlerdir. Bütün bu çalışmalarda herkesin erişebileceği veri setlerini tercih etmişlerdir.

Zhou et al. çalışmalarında, güvenilir bir SOH çıkarımı yapabilmek amacıyla istemeyen etmenleri en aza indirmek amacıyla Zamansal Evrişimli Ağ (Temporal

Convolutional Network, TCN)'ye ek olarak ampirik mod ayrışımını da kullanmıştır [22]. TCN modelinde ilk olarak büyütülmüş evrişimli basamak ve sebepsel basamak tercih etmişlerdir.

Wei et al. çalışmalarında, bir Grafik Evrişimli Ağı (Graphical Convolutional Network, GCN) algoritması sunarak SOH ve bataryalar için kalan faydalı şarj, deşarj çevrimlerine ulaşmayı amaçlamıştır [23]. Ulaşılan sonuçlar bu algoritmanın kullanıldığında şarj tamamlanırken sensör datalarına bile ihtiyaç duymadan yüksek doğruluğa sahip SOH tahminlerine ulaşıldığını görmüşlerdir.

Literatürdeki çalışmalar göz önüne alınarak, apılan bu tez çalışmamızda ise NASA Ames PCOE veri setlerinden Li-ion batarya verinin KFÖ'lerinin incelenmesi ele alınmıştır. İncelemede derin öğrenme yöntemlerinden, zaman seri şeklinde olan verilerden otomatik özellik çıkarma yeteneğine sahip olan LSTM algoritmasından yararlanılmıştır.

2. BÖLÜM

BATARYALAR VE DERİN ÖĞRENME

Bataryalar, anot (- terminal) ve katot (+ terminal) olarak iki terminale sahip, elektrik enerjisi depolayan elemanlardır. Üretildiği malzeme ve üretim şekline göre birçok sınıfa ayrılmıştır. Bu sınıf türlerinden olan Çinko-karbon bataryalar, stabil, yüksek güç yoğunluğuna, yüksek deşarj oranına, çinko sülfat ve amonyum klorür karışımına sahip şarj edilebilen bir batarya türüdür. Çinko karışımın farklı olan türleri, çinko-hava ve çinko-gümüş bataryalarda bulunmaktadır. Bunlara ek olarak, katot olarak saf cıva oksit ve anot olarak çinkodan yapılan cıva oksit bataryalar bulunmaktadır [24-28].

Günümüzde yaygın olarak kullanılan, nikelden yapılmış pozitif elektrot ve metal kadmiyumdan yapılmış negatif elektrottan oluşan nikel-kadmiyum(NiCd) bataryalar, cıva içermedikleri için çevre dostudur. NiCd bataryalar, diğer bataryalara nazaran, çok düşük kendi kendine deşarj oranına sahip olmasına rağmen ve şarj tutma özelliklerini kaybetmeden defalarca şarj edilebilmektedirler. Nikel'den yapılmış diğer bir tür olan nikel-metal hidrit bataryalarda, katodunda kadmiyum yerine hidrojen adsorblanmış bir alaşımın bulunmaktadır. Bu bataryalar, hasar görmeden ya da kimyasal reaksiyona girmeden uzun süre deşarj süresine sahiptirler.

En yıllarda en popüler batarya türü lityum serisidir. Li-ion bataryaların en eski teknoloji ürünü gümüş oksit bataryalardır. Uzun ömür, iyi bir kimyasal dayanım ve büyük güç üretimi gibi özelliklere sahiptir. Lityum serisinin diğer bir türü olan, Li-po bataryalar günümüz özellikle kara ve hava taşıtlarında, hafiflik, dayanıklılık, zorlu koşullarda çalışabilme, yüksek enerji yoğunluğu, farklı şekil ve boyutlarda üretilebilme gibi birçok üstün özelliği sayesinde kullanıcılar tarafından sıklıkla tercih edilmektedir. Ayrıca, bir Li-po batarya, NiCd gibi olan diğer bataryalara göre daha yüksek enerji yoğunluk kapasitesine sahiptir [6-9].

Li-ion ve Li-Po bataryalar, katot ve anot kutupları arasındaki Li-ion değişime dayanan benzer prensiple çalışmaktadırlar. İki tür arasındaki temel farklılık batarya üretiminde kullanılan elektrot ve oluşturulan paket yapısıdır. Bu nedenlerde dikkate alındığında bu bataryalar, özellikle insansız kara ve hava araçlarında sıklıkla tercih edilmektedir. Kullanıcılar bu bataryaların üstünlüklerinin yanında dezavantajlarını da göz ardı etmemelidir. Bu bataryalarda birtakım problemler kullanıcıların karşılaştığı sorunlar arasında gelmektedir. Şarj sorunları, hücreler arasındaki dengesizliklerin oluşması, yanma ya da patlama gibi sorunlar, depolama gereksinimi gibi birçok faktör kullanıcıların dikkat etmesi gereken konular arasında gelmektedir.

2.1. Bataryalar ve Türleri

Bataryalar, kimyasal enerjiyi elektrik enerjisine dönüştüren elektronik bir cihazdır. Anot ve katot olmak üzere iki terminale sahiptir. Bataryalar yapıldığı malzeme ve yapılış şekilleri itibarıyla birincil ve ikincil olarak iki sınıfla ayrılmaktadır [24-28].

Birincil bataryalar, tekrar şarj edilemeyen bataryalardır. Bu bataryalardan, Alkalın-Manganez, Çinko-Karbon, Cıva Oksit ve Gümüş Oksit bataryalardır.

İkincil bataryalar, tekrar şarj edilebilen bataryalardır. Li-ion, Li-po, Nikel-metal hidrür, NiCd ve Kurşun Asit bataryalar, şarj edilebilen bataryalar olarak sıklıkla kullanılmaktadır.

2.1.1. Çinko Karbon Bataryalar


Georges Leclanché tarafında 1866'da tarafından ilk batarya üretilmiştir. Bu batarya katot ile bir düşük aşındırıcı sıvı elektrolit içeren ilk hücre yapısı olarak bilinmektedir. 1886'da Carl Gassner, anot olarak bir çinko fincan kullanıp elektrolitik sıvıyı jel haline getirerek patentini almıştır. [24].

Çinko-karbon bataryalar, stabil ve ekonomik bir şarj edilemeyen batarya türüdür. Bu alkalın batarya, yüksek güç yoğunluğuna ve yüksek deşarj oranına sahip olmasıyla bilinmektedir. Çinko-karbon batarya, elektrolit olarak çinko oksit ve birincil parçacıklar olarak çinko sülfat ve amonyum klorür karışımı kullanan bir şarj edilebilir batarya türüdür.

“Zn” simgesi ile periyodik tabloda yer alan çinko, 2B grubu bir metaldir. Kaynama noktası 906°C, Ergime sıcaklığı 419,47°C, sertliği 2,5 Mohs'dür. Atom numarası 30

olup, atom ağırlığı 65,39 g/mol'dür. Dünyada birçok noktada bulunabilmekte ve genellikle bulunduğu sırada sülfür içermesiyle de bilinmektedir. Ender olarak silikatlı ve oksitli formlarına doğada da rastlanabilmektedir. Doğada örneğin Sfalerit (ZnS) şeklinde denk gelebilmektedir.

Kaynama noktasının diğer ve özellikle bulunduğu sıradaki metallere göre ısıtılarak ayrışma işlemi yapılmasına olanak sağlamaktadır. 120°C'de ve üzerinde şekil verilebilen bir metaldir. Elektrokimyasal olarak negatif özelliktedir. Bu sebeple bataryalarda anot olarak tercih edilmektedir. Çinko-karbon bataryaların katotlarında ise mangan dioksit kullanılmaktadır. Elektrolit bileşeni ise sulu çinko klorür ya da amonyum klorürdür. Elektrolite kısma pelteleşme için inert yapıda bir metal oksit ilave katkılanmaktadır. Çinko-karbon bataryanın katot kısmının hızlı sertleşmemesi adına ve iletkenliği arttırmak için karbon bileşeneler mangan dioksit ile karıştırılabilmektedir. Şekil 2.1'de Çinko-karbon batarya yapısı şematik olarak gösterilmektedir. Batarya hücresi deşarj edildiği durumlarda çinko okside (ZnO) dönüşmekte ve mangan dioksit (MnO_2) ise indirgenmektedir. Tepkime sonucu bir araya gelerek oluşan bileşen Eşitlik 2.1'de gösterilmektedir [25].




Şekil 2. 1. Çinko bataryanın yapısı

Çinko karbon bataryalar tek kullanımlık bataryalardır. Oldukça ucuz üretilebildiği gibi günümüzde de oldukça sık kullanılan ve çok hızlı erişebileceğimiz bataryalardır.

Çinko-karbon bataryalar genellikle oldukça sirküler; AAA, AA, C, D ve 9 Voltluk yassı şekillerinde üretilir, raf ömürleri (1-2 yıl ortalama oda sıcaklığında) nispeten enerjilerini etkilememekte ve genelde düşük enerji tüketen cihazlarda değiştirilerek kullanılmaktadırlar.

2.1.2. Alkali Manganez Oksit Bataryalar

Alkali bataryalarda anot kısmında çinko, katot kısmında mangan dioksit, elektrolit olarak ise potasyum hidroksitten oluşmaktadır. Alkali bataryalar tamamen yeniden şarj edilemeyen bataryalardır. Çinko-karbon bataryalara nazaran daha uzun ömürlüdürler ve tamamen şarjı bitene kadar dayanıma sahip olmaları ile bilinmektedirler. Şekil 2. 2'de de örnek olarak bir alkali manganez oksit bataryanın iç yapısı gösterilmektedir [26].



Şekil 2. 2. Alkali manganez oksit batarya iç yapısı


Manganez oksit batarya deşarjı tamamlandıktan sonra oluşan ürünler ve alkali bataryaların reaksiyon mekanizmaları Eşitlik 2.2 ve Eşitlik 2.3'de verilmiştir [27].



Çinko-karbon bataryalarla karşılaştırıldığında deşarj sürelerinin daha uzun sürmesi alkali bataryaların kullanımını teşvik etmektedir. Uzun süreli kullanım avantajı ile piyasadaki bataryaların %30 una yakını manganez oksit tabanlı olduğu bilinmektedir.

2.1.3. Çinko Hava Bataryalar

Çinko hava bataryalarda anotlarında çinko malzeme, katot olarak oksijenle hava boşluğu bırakılarak, elektrolit olarak soydum hidroksit ya da potasyum hidroksit kullanılmaktadır. Çinko hava bataryalarının ebatları nispeten küçük, enerji yoğunlukları fazladır. Çevre dostu bataryalardır. Saatler, işitme cihazları ve küçük cihazlarda daha çok tercih edilmektedir. Şekil 2. 3'de bir çinko hava bataryasının yapısı gösterilmektedir [28].




Şekil 2. 3. Çinko hava batarya yapısı

Çinko hava bataryalar, birincil ve ikinci olarak iki tipi de mevcuttur. Birincil bataryalar, şarj edilemeyen türden iken, ikincil bataryalar şarj edilebilir türdendir. Çinko hava bataryalarının enerji yoğunlukları nispeten iyidir. Yeniden şarj edilebilen ikincil tipleri daha pahalı üretilmektedir. Genel kullanımlarında işitme cihazları, kumandalar, bilgisayar kasaları, devre hafıza korumaları, saatler, hesap makineleri yer almaktadır. Büyük ölçüde üretimleri de nadiren yapılmaktadır [29].

Anot yapısında potasyum hidroksit ile alkalın elektrot absorplanmış gözenekli çinko bulunmaktadır. Katot kısmında, hava yani oksijen teması söz konusudur. Elektrolit hava ile reaksiyona girerek anot tarafında serbest bırakılan hidroksil iyonları ile zinkat ve su ortaya çıkmaktadır. Böylece ortaya çıkan elektronlar katottan anoda doğru akım oluşturabilmektedir.

Çinko Metal oksit bataryaların deşarj halindeki reaksiyonu Eşitlik 2.4'de verilmiştir.




Deşarj boyunca, çinko (Zn) çinko oksit (ZnO) hale geçerken ve elektrolitte genellikle çinko oksit (ZnO) formunu oluştururken metal oksit (MO) indirgenmektedir.

Voltajı hücre başına 1.35 V civarında ölçülebile çinko hava bataryalarda yüke geçme sırasında voltaj 1.2 volt civarına hızlı bir düşüm gösterebilir.

Çinko hava bataryalar aşırı ısıya ve neme karşı hassaslıkları ile bilinmektedir. Hava ortamında bulunan karbondioksit bataryanın iletkenliğini azaltabilmekte ve içeriği gereği karbonat oluşturmaktadır. Çinko hava bataryalarının raf ömürleri kafalı muhafazaya bağlı değişmektedir. Aynı şekilde kullanımları sırasında da ortam koşullarından etkilendikleri bilinmektedir [30].

2.1.4. Cıva Oksit Bataryalar

Cıva oksit bataryalar, 1950'lerin başından beri farklı farklı şekillerde kullanılmaktadır. Cıva oksit bataryalarda anot olarak kadmiyum ya da çinko malzeme, katot olarak manganez dioksit ve cıva oksit karışımından ya da saf cıva oksit kullanılırken, Anot malzemesine göre Kadmiyum cıva oksit ya da Çinko cıva oksit bataryalar olarak adlandırılırlar. Şekil 2.4'te de Cıva oksit batarya yapısı gösterilmektedir [31].



Şekil 2.4. Cıva oksit batarya yapısı

Cıva oksit bataryasının deşarjı sırasındaki kimyasal tepkime Eşitlik 2.5'de verilmiştir.



Cıva oranı %2 ağırlığından fazla cıva oksit batarya üretimi çevreye verdiği tehditlerden dolayı günümüzde yasaklanmıştır.

Cıva oksit bataryaların deşarj sırasındaki kimyasal işlemi Eşitlik 2.6'da verilmiştir



Cıva oksitin (HgO) su (H_2O) ile tepkimeye girip ayrışması ile cıva (Hg) ve hidroksitler (OH^-) oluşur.

İlk olarak çinko üzerinde 1. Kimyasal Eşitlik 2.7’de verildiği gibi işleme başlamaktadır.



Ardından oluşan çinko hidroksit ($Zn(OH)_4$), çinko oksit (ZnO) ve suya (H_2O) dönüşür.

Eşitlik 2.8’de Çinko (Zn), Hidroksit (OH^-) ile çinko oksite (ZnO) dönüşürken de su (H_2O) çıkmaktadır.



2.1.5. Gümüş Oksit Bataryalar


Gümüş oksit bataryalarda anot olarak toz çinko, katot olarak grafit içeren sıkıştırılmış gümüş oksit ve mangan dioksit, elektrolit olarak sodyum ya da potasyum hidroksitten kullanılmaktadır. Bu bataryaların düşük sıcaklıklardaki performansları iyi olmakla beraber titreşime ve şoka karşı dayanıklı oldukları da bilinmektedir [32].

Gümüş oksit bataryalar, lityum iyon bataryalar için en eski teknolojidir. Büyük güç üretimi ve uzun ömür, mükemmel kimyasal dayanım ve uzun hizmet ömrü için uygun olmaları ile bilinmektedirler.

Gümüş oksit bataryaların katot kısmında gümüş tozları yine gümüş çerçeve taban üzerinde ısı olarak sinterlenerek oluşturulmaktadır. Elektrolit olarak ise genellikle periyodik cetvelde 1A grubu Potasyum hidroksit bulunmaktadır. Şekil 2. 5’de Çinko gümüş oksit bataryanın yapısını göstermektedir [33].

Gümüş Oksit batarya negatif elektrotu (Anot) çinkodan, pozitif elektrotu (katot) gümüş oksitten, elektrolit olarak sodyum hidroksit veya potasyum hidroksit kullanılarak üretilmektedirler.

Tek değerlikli Gümüş Oksit Batarya bataryanın içindeki kimyasal reaksiyonu Eşitlik 2.10’da verilmiştir [33].



Şekil 2.5. Gümüş oksit batarya yapısı



Bir gümüş oksit bataryası, negatif elektrot (anot) olarak çinko, pozitif elektrot (katot) olarak gümüş oksit, artı alkalın elektrolit, çoğunlukla sodyum hidroksit veya potasyum hidroksit kullanılmaktadır.

Bu işlem 1.55 volta varıncaya kadar elektrolitin ayrışmasıdır. Voltaj seviyesi hücre başına 1.55 volta gelince daha fazla yük depolanamamaktadır. Şekil 2. 6'da da gümüş oksit bataryalarının görünümü gösterilmektedir [34].




Şekil 2.6. Gümüş oksit batarya görünümü

Gümüş oksit bataryalar, günümüzde özellikle saatlerde, işitme cihazlarında ve birçok elektronik devre ve elemanda tercih edilmekte ve birçok ebatla üretilmektedir.

2.1.6. Nikel Kadmiyum Bataryalar



NiCd bataryalar tekrar şarj edilebilen eski batarya türlerinden biri olarak bilinmekte olup ve NiCd bataryalar güvenli bataryalar olarak bilinmektedirler. Bu bataryalar, -15 °C sıcaklıklarda bile çalışabilmekte olup aynı zaman da hızlı şarj olabilme özelliği sayesinde hala aktif bir şekilde tercih edilmektedir. Fakat batarya içeriğinde olan kadmiyum oranlarından dolayı yerlerine nikel metal hidrür bataryalar tercih edilmektedir. Bu bataryaların, şarj ve deşarj sırasında bataryanın tam bitmeden şarj edilmesi neticesinde bataryaların deşarj ömrünü etkilemektedir. Bu durum en önemli dezavantajı arasında bulunmaktadır [35].

NiCd batarya, negatif elektrot olarak metalik kadmiyum pozitif elektrot olarak nikel kullanan bir tür şarj edilebilir bataryalardır. Elektrolit olarak potasyum hidroksit kullanılmaktadır. NiCd bataryalar cıva içermedikleri için genellikle daha çevre dostu olarak bilinmektedirler. NiCd bataryalar, diğer batarya türlerine göre çok düşük kendi kendine deşarj oranına sahip olup ve şarj tutma özelliklerini kaybetmeden yüzlerce kez yeniden şarj edilebilmektedirler. Şekil 2. 7'de de NiCd bataryasının iç yapısı gösterilmektedir [36].



Şekil 2.7. NiCd batarya iç yapısı

Deşarjı sırasında kimyasal reaksiyonları pozitif elektrotta Eşitlik 2.11'de, negatif elektrotta Eşitlik 2.12'de verilmiştir. Şarj durumundaki kimyasal reaksiyonlar pozitif elektrotta Eşitlik 2.13'de, negatif elektrotta Eşitlik 2.14'de verilmiştir [37].



Eşitlik 2.11'de görüldüğü gibi NiCd bataryalarda nikel oksit hidroksit (*NiOOH*) pozitif plaka üzerinde deşarj olmaktadır. Eşitlik 2.13'de şarj esnasında nikel hidroksit (*Ni(OH)₂*) bir alt düzeye inmekte ve dış çevreden elektron almaktadır. Eşitlik 2.12'de Kadmiyum metali (*Cd*) negatif plakada deşarj olmakta, şarj esnasında ise kadmiyum hidroksite (*Cd(OH)₂*) yükseltgenmektedir. Eşitlik 2.14'de elektronları dış ortama bırakmaktadır. Batarya şarj olurken reaksiyonlar tersine şekilde de gerçekleşmekte olup böylece batarya orijinal voltajına ve kapasitesine geri dönebilmektedir. (2.15)'te ise genel reaksiyon denkleminde gösterilmektedir. NiCd bataryaların şarj ve deşarj sırasında fiziksel olarak bir değişim yaşanmamaktadır. Sadece kimyasal oksidasyon ile enerji transferi sağlanır.


NiCd bataryalar bataryanın boyutuna, içerisindeki metaller ve üreticisine göre farklılık göstermektedir. Şekil 2. 8'de de NiCd bataryaların yapısal özellikleri gösterilmiştir [36].

2.1.7. Nikel Metal Hidrit Bataryalar


Nikel metal hidrit bataryalar (NiMH) NiCd bataryalara çok benzer. Bu bataryaların katotlarında hidrojen adsorblanmış bir alaşım odası dışında diğer yapıları benzerlik göstermektedir. NiMH bataryaların şarjı sırasında katotta hidrojen absorbe edilmesi ve deşarjı sırasında hidrojeni bırakması bu alaşım aracılığı ile gerçekleşmektedir.

NiMH bataryalar, hasar görmeden veya kimyasal reaksiyona girmeden uzun süre boşalabilir. Li-ion bataryalara kıyasla çok yüksek enerji yoğunluğuna sahip

olduklarından ve geç deşarj olduklarından dolayı birçok elektronik cihazda hala sık sık tercih edilmektedir. Şekil 2. 9'da da NiMH bataryanın iç yapısı gösterilmektedir [28].



Şekil 2.8. NiCd batarya yapısal özelliği



Şekil 2. 9. Nikel metal hidrit Batarya iç yapısı

NiMH hidrit bataryaların deşarjları sırasında ise aşağıdaki kimyasal reaksiyon gerçekleşir [38].




Batarya içerisinde (2.16)'daki reaksiyon gerçekleşmektedir. NiMH bataryaları, diğer NiCd bataryalardan uzun ömürlü ve daha hızlı şarj olmaktadır. Ayrıca fiyatları da nispeten NiCd bataryalara oranla daha pahalıdır.

2.1.8. Lityum Hava Bataryalar

Lityum hava bataryalar, Li-ion bataryalar benzerlik gösteren bir yapıya sahip olması ile bilinmektedir. Katot kısmında Lityum içeren alaşım yerine oksijen kullanılmıştır. Bu durum teorikte çok fazla ve sınırsız bir katot reaktansı düşünülse de bataryanın kapasitesi lityum anot ile sınırlıdır. Yine de bu durum, lityum hava bataryalarının sahip olduğu teorik yüksek enerji nedeniyle araştırmacıların ilgisini çekmektedir. [40]

2.1.9. Lityum Polimer Bataryalar

Lityum polimer batarya (Li-po), lityum şarj edilebilir batarya bilinmektedir. Günümüzde en popüler şarj edilebilir batarya türüdür. Piyasada bulunan diğer bataryalara göre daha hafif, dayanıklı ve zorlu koşullara ve darbelere dayanabilmesi için hemen hemen her şekil veya boyutta üretilebilmesi gibi bazı önemli avantajları bulunmaktadır. Ayrıca, bir Li-po batarya, yaklaşık 350 watt-saat/litre gibi mükemmel bir enerji yoğunluğu seviyesine sahiptir; bu, 116 watt-saat/litre enerji yoğunluğu seviyesine sahiptir. Şekil 2. 10'da da Li-po bataryanın iç yapısı gösterilmektedir [28].




Şekil 2.10. Li-po batarya iç yapısı

Özellikle insansız hava aracı ve drone'larda yüksek enerji yoğunluğu nedeniyle Li-po bataryalar tercih edilmektedir.


2.1.10. Lityum İyon Bataryalar

Li-ion bataryaların anot kısmı farklı tabakalı yapılara sahipken, katot kısmı delikli tabakalarla metal oksitlerden yapılarla enerji akışı Lityum iyonlarının negatif ve pozitif elektrotları arasında yer değiştirmeleri ile sağlamaktadır. Anot kısmının grafit ya da silikon karbon tabanlı bir malzeme olduğu bilinmektedir. Şekil 2. 11'de de Li-ion iç yapısı gösterilmektedir [41].



Şekil 2.11. Li-ion batarya iç yapısı

Li-ion bataryalar yüksek enerji yoğunluğuna sahip bataryalardır. Ayrıca batarya seviyesinde şarj ve deşarjları sırasında oluşabilecek hafıza etkileri bulunmamaktadır. Batarya içerisinde gerçekleşen Anot reaksiyonu Eşitlik 2.17'de ve Katot reaksiyonu Eşitlik 2.18'de verilmiştir [28].



2.2. Enerji Yoğunluğu Noktasında Lityum İyon Bataryalar

Li-ion bataryaların geliştirilmesi adına yapılan çalışmalarda; elektrolit, anot, katot üzerinde ayrı ayrı çalışmalar yapıldığı gibi, bütünü üzerine de çalışmalarında mevcut olduğu bilinmektedir. Bu geliştirmeler üzerine çok sayıda patent alınmış olup, US patent ofisinde Li-ion üzerine 10000 üzerinde patent olduğu yapılan çalışmalarda görülmüştür [1, 40].

Örneğin karbon anot malzemelerin kullanımıyla bataryanın tekrar kullanılabilir olduğu fakat karbonun kullanılması ile de bataryanın kapasitesinin düştüğünün bu sebeple bilim dünyasının yeni alternatif anot malzemesi aramakta olduğu bilinmektedir.

Bataryanın kapasitesi, malzemenin yeryüzünde bulunabilirliği, bataryanın çevreye olan etkisi (geri dönüşüm sürecine uygunluğunu, zehirli etkisinin olup olmadığı), bataryanın ömrü boyunca güvenilirliği, hücre başı maliyet analizi ve bir takım farklı sıralamalar ile bu bataryalar ile alakalı öncelikli çalışmalar yapıldığı bilinmektedir.

Yıllar içerisinde (Ca, Mg, Si, Ge, Al, Pb, Bi, Sn, As, Sb, Pt, Au, Ag, Cd, Zn) metallere Lityum'un alaşımlarının, bataryaların anotlarında karbon esaslı malzemelerle kullanılması ile anotların 372 mAhg-1 kapasite civarında değerlere varabileceği; Si, Sn, As, Pb, Al, Sb, gibi farklı alaşımların daha da yüksek enerji yoğunluğu değerlerinde oldukları fark edilmiştir.

Gravimetrik ve hacimsel kapasite değerleri alternatif anot malzemeleri ve alaşımlarına bağlı reaksiyonları Grafit elektrot kapasitesi baz alınarak gösterilmiştir.

Farklı şekillerde üretilen Lityum bataryaların elektrolit-anot-katot malzemeleri, ebat ve biçimleri batarya kullanım sürelerinde ve faydalı ömürlerinde değişiklikler ortaya koymaktadır.

2.3. Lityum İyon Bataryaların İç Yapıları ve Şarj Döngüleri

Enerji depolayan sistemlerin ve bataryaların enerji depolaması C_T yani toplam kapasitesinin denklemi Eşitlik 2.19'da verilmiştir [41,42].

$$SoC(t) = Soc(t_0) - \frac{1}{3600C_T} \int_{t_0}^t I_{batt}(t) dt \quad (2.19)$$

Şarj durumunu, bataryadaki kapasitesi (State of Charge – SoC) akımla matematiksel ilişkisini ve gelişimi olarak ele alınmaktadır.

Şarj durumunda V_{max} referans değerini kadar geçen süre ve yük ve deşarj durumunda V_{min} referans değeri ve süre ve yük değeri aşağıdaki gibi formülize edilebilir.

$$\min t(s) = SoC(t)V_{t(s)} - V_{max} > 0 \quad (2.20)$$

Şarj durumundaki Voltaj ve Maksimum Voltaj

$$\min t(s) = SoC(t)V_{t(s)} < V_{\min} \quad (2.21)$$

Deşarj durumdaki Voltaj ve Minimum Voltaj

$$\min t(s) - \max t(s') SoC(t)A_{t(s)} < A_{\text{constant}}, A_{t(s')} < A_{\min} \quad (2.22)$$

Deşarj durumundaki Akım ve Yük


$$\min t(s) = SoC(t)T_{t(s)} = \max\{T_{t(s)}, \forall s\} \quad (2.23)$$

2.4. Derin Öğrenme

Makine öğrenme kümesi olan DÖ anahtar kelimesi olan derin kelimesi ağı çok fazla katmandan meydana geldiğini vurgulamaktadır. Başlangıç araştırmalarına göre doğrusal bir algılayıcının evrensel bir sınıflandırıcı olamayacağını, ancak sınırsız genişliğe sahip bir gizli katmana sahip polinom olmayan bir aktivasyon işlevine sahip bir ağı olabileceği yönündedir. Teorik komikliğini zayıf şartlar altında sürdürürken, pratik ve uygun şartlarda yapılan uygulamalara onay veren, limitsiz sayıda limitli ebatlardaki tabakayla alakalı olan modern bir çeşitlemedir. DÖ tıpkı insan beyninin bir simülasyonu gibi verileri işleme ve karar aşamasında kullanımı için yöntemler türetmektedir. Yapay zekaya olan ilginin hızla artışı içinde bulunduğumuz zamandan makine öğrenimin temellerinin atıldığı ilk günden beri devam etmekte olup artan bu ilgi halihazırda en çok tercih edilen makine öğreniminin de bir kolu olan DÖ'nün ortaya çıkmasına zemin oluşturmuş ve endüstri, tıp, robotik, görüntü işleme, bilgisayar görmesi, nesne tespiti, ses işleme-tanıma gibi pek çok alanda kullanıldığı da görülmektedir. Etkili bir makine öğrenimi tarzıyla bilinen bu yöntem bilgisayarların görüntü ve konuşma tarzı vb. idrak meselelerini çözümlemede geniş bir alana yayılmaktadır. Birçok işlem tabakası vasıtasıyla geniş data kümelerinin biçimleri ve yapıları ortaya çıkarırken DÖ metotlarına başvurmaktadır. Ekstra olarak gizli tabakası bulunan sinir ağlarını tercih edilmesi, ortalama çıkarımlarda bulunan tek tabakalı sinir ağlarına göre uygunluk bakımından çok daha iyi sonuçlara varılmaktadır. Bu tabakaların her biri arkadan gelen tabaka üzerine inşa edilirken faydalanılan bu datalardan yeni kavramlar öğrenilmektedir. Düzey yükseldikçe öğrenilen kavramlarda bir o kadar gerçekliğe yaklaşmaktadır. DÖ; büyük ölçüde veriye gereksinim duyan ve kompleks biçimleri sebebiyle verileri işleyebilmek amacıyla şiddetli donanıma gereksinim duyan bir yöntem olması ile bilinmektedir [43-46]

2.4.1. Derin Öğrenmenin Tarihi

Kunihiko Fukushima tarafından 1980 yılında, Neocognitron çok katmanlı YSA geliştirilmiştir. 1986'da ise Rina Dechter DÖ terimini kullanmıştır. 1997'de Mike Schuster ve Kuldip Paliwal birisi negatif zaman tarafı, diğeri ise negatif zaman tarafı için olarak iki gizli tabakayı aynı sonuca bağlayan çift taraflı tekrarlayan sinir ağlarını (Recurrent Neural Network,RNN) tanıtmıştır. DÖ üzerine geçmişten günümüze daha birçok çalışma yapılmış ve DÖ bugün ki çok katmanlı halini almıştır. [46]. Zamanımız şartlarında DÖ sağlık, havacılık, eğlence, otonom sistemler ve reklamcılık gibi birçok alanda faaliyet göstermektedir. Şekil2.13.'te de İlk DÖ mimarisinin örneği gösterilmiştir [49].



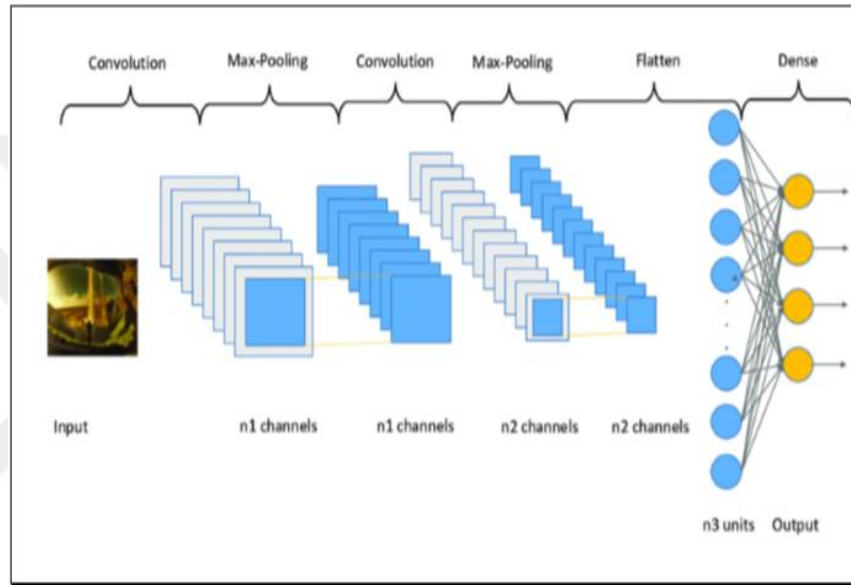
Şekil 2. 12. İlk DÖ mimarisi

2.5. Derin Öğrenme Mimarileri

2.5.1. Konvolüsyonel Sinir Ağı

Görüntü analizlerinde nerdeyse en iyi verim alınan ve tercih edilen yapay sinir ağı biçimi Konvolüsyonel Sinir Ağları (Convolutional Neural Network,CNN) çoğunlukla convnets olarak kısaltılmakta olup çok tabakalı ileri beslemeli olmaları da nitelikleri arasında yer almaktadır. CNN ilk olarak LeCun et al. tarafından gradyan altyapılı yaklaşımıyla oluşan bu yapay sinir ağın LeNet denmiştir. Birçok gizli tabakanın birleşimiyle oluşmuş olup hesaplamalara genel olarak bu tabakalarda odaklanmaktadır. CNN'ler evrişimli tabakalar kullanılarak oluşturulurken bu tabaklara ek olarak tam bağlı, aktivasyon, sınıflandırıcı, havuzlama gibi tabakalarda mevcuttur. YSA'dakinden farklı olarak önceki tabakada bulunan nöron sadece önceki tabakada bulunan

dikdörtgenle alakalı olanlara bağılı olduğunu göstermektedir. İlerideki tabakalarda düzeyi yüksek olan nitelikleri bir araya getirmeden, önceki düşük düzeyli niteliklere odaklanan farklı bir ağ yapısının mevcut olduğu bilinmektedir. Ayrıca bu ağın filtreleme odaklı yapısını kullanarak çıkarılacak görüntünün hakimliği düşük olan öznelikleri ortaya koymayı sağlar. DÖ yöntemleri içinde en yaygın olan bu sinir ağı genellikle sınıflandırma ve tespitte kullanılmaktadır. Şekil 2.14'te de CNN mimarisine bir örnek gösterilmiştir [48].




Şekil 2.13. CNN mimarisi

2.5.2. Tekrarlayan Sinir Ağları

Birimler arasında iki yönlü data döngüsü var olan Tekrarlayan Sinir Ağlarındaki (Recurrent Neural Network, RNN) döngü ağın dahili vaziyetine dinamik zamansal bir davranış görmemizi sağlamaktadır. RNN'nin alt yapısı sıralı verilere göre işlemektir. Bu ağ dataları akıntı yönünden önceki birimlerde yaydığından dolayı değişik döngü çeşitleri için dönüt uzantılarının mevcut olduğu bilinmektedir. Yani ağın çıkış verileri, evvelki zaman hamlesinde ağ vaziyetine dayalıdır yalnızca dış girişlerine bağılı değildir [49].

RNN birimlerinden birbirinin sonucu, zaman basamağı türünden tanımlanmaktadır. Çünkü tabakalardan rastgele bir tanesinin arasında irtibata sahip olabilme ihtimalleri mevcuttur. Bu ağ yapısının bazılarında önceki bir dilim basamağındaki sonucun nüshasını bağlam birimleri ileriki eğitim basamakları için veri sağlayacak şekilde tekrar

kullanıma açık olan bu sonuçları saklamaktadır. Şekil 2.15'te RNN mimarisine örnek gösterilmiştir [50].




Şekil 2.14. RNN mimarisi

2.5.3. Uzun Kısa Vadeli Hafıza Ağları (LSTM)

RNN mimarilerinde ardındaki dizinin çıkarımının yapılması zaman dizeleri aralarında kopukluk olması durumunda oldukça zor ve RNN mimarisinin de en büyük dezavantajı olarak bilinmektedir. Sepp Hochreiter ve Jürgen Schmidhuber 1997 yılında uzun zamanlı bağımlılıkları öğrenebilen kendine özgü RNN türü olan Uzun Kısa Vadeli Hafıza Ağları(Long Short-Term Memory, LSTM) ileri sürmüşler ve bu dezavantaj için bir çözüm yolu sunmuşlardır. Uzun soluklu bağımlılık sıkıntısını gidermek amacıyla yapılmıştır. Bunu; bilgiyi uzun zaman akılda tutmaktansa öğrenmenin daha pratik olması şeklinde de açıklamışlardır. LSTM de hedef önceki bellekteki bilgilerle şimdiki bilgiye anlam kazandırmak ve bu hedefe RNN mimarisinin önceki görüntüyü mevcut görev ile ilişkilendirebilmesi gibi cazip bir özellikle yola çıkarak ulaşmışlardır. LSTM ağlarından bir yapı kullanılarak gizli durumları hesaplayabilmektedirler. LSTM mimarisi giriş, unutma ve çıkış olarak 3 kapı, blok girişi, sabit hata döngüsü, çıkış aktivasyon fonksiyonu ve gözetleme olmak üzere bağlantıları vardır. Başlangıçta şekillendirilen mimarilerde gözetleme bağlantıları ve unutma kapısı yoktur. Unutma kapısı bu mimarinin vaziyetini sıfırlamak için kullanılmıştır ve bu bellek bloğunda bulunun unutma kapısının otoritesi bir nöron tarafından yapılmaktadır. Gözetleme bağlantıları ise net zamanları öğrenmeyi basitleştirmek için eklenmiştir. LSTM bloğunun basit bir nöron ve önceki bellek biriminin tesirleri aracılığı ile giriş kapısı

bölümü oluşturulmuştur [51]. LSTM mimarilerinin bir hayli başarılı olduğu alan konuşma/metin işleme olmakla birlikte bu mimari robotik kalp cerrahisinde düğümleri bağlamayı öğrenen bir sistem tasarlanması, düzensiz dillerde öğrenme, çevrimdışı el yazı tanınması gibi birçok konuda da kullanılmaktadır. Şekil 2.16'da da LSTM mimarisinin şeması gösterilmiştir [52].



Şekil 2.15. LSTM mimarisi

2.6. Derin Öğrenme Katmanları


2.6.1. Giriş Katmanı

Verilerin giriş katmanı olarak bilinen bu katmanda oluşturulacak olan veri setini ağın mimarisine göre belirlemesini sağlamaktadır. Giriş tabakasına ağın eğitimi amacıyla alınan her örneklem girdi verisi olarak kullanılmakta ve n-bunların hepsi peş peşe eklenerek bir veri setini meydana getirmektedir. Ağın hızını, test süresini bellek ihtiyacı gibi şeyler veri setinin boyutu belirlemektedir [53].

2.6.2. Konvolüsyon katmanı

Sinir ağlarının ana yapı taşı olan evrişim tabakasında genelde hesaplamalar yapılmaktadır. Bu tabakada yapılan hesaplamalar girdi verileri, filtre ve özellik haritası gibi tamamlayıcılar kullanılmaktadır. Bu tabakada girdinin göze çarpan niteliğinin ortaya çıkmasını hedeflerken girdi verisi üzerinde daha önceden belirlenmiş bir filtrenin girdi verisi üzerinde gezdirmektedir. Filtre boyutlarında değişiklikler görülebilmektedir fakat genelde 3 x 3'lük matris tercih edilmektedir. Çoğunlukla filtre matrisinden daha büyük olan giriş görüntü matrisi eğer filtre boyutuyla eşleşmiyorsa dolgu kullanılmaktadır. Filtre matrisinin giriş görüntü matrisi üstünde kaydırılması ile ortaya


çıkan sayısal yöntemler neticesinde özellik haritasına ulaşılır. Bütün evrişim tabakalarının ardından ağa doğrusal olmama durumu eklemek için aktivasyon fonksiyonu eklenmektedir. Birçok aktivasyon fonksiyonu bulunmakta, fakat çoğu zaman doğrultulmuş doğrusal birim kullanılmaktadır. Şekil 2.17’de konvolüsyon katmanına bir örnek gösterilmiştir [54].



Şekil 2.16. Konvolüsyon katmanı

2.6.3. Havuzlama Katmanı


Alt örnekleme işlemi olan havuzlama tabakası iki sıralı evrişimli tabaka boşluğuna eklenmektedir. Bu tabaka girdi verilerinin uzamsal kapsamını azaltarak ağda bulunan parametre sayısını, hafıza kullanımını ve ağdaki hesaplama niceliğini indirgemeyi amaçlar. Bu durumda ağda ki takılmaları en aza düşürmektedir. Filtre nitelik haritası matrisi üstünde kaydırılarak hesaplamalar yapılır fakat bu tabakayı evrişim tabakasında ayıran bir niteliğinde filtrenin bir ağırlığının olmamasıdır. Havuzlama işlemi için en çok tercih edilen çeşitler ortalama ve en büyük değer havuzlama işlevleridir. Ortalama havuzlama ortalama değeri hesaplarken filtreyi nitelik haritası üstünde kaydırmaktadır. En büyük değer havuzlama nitelik haritasının ise en büyük değerini seçer. Şekil 2.18’de de en büyük değer havuzlama örneği gösterilmiştir [55].



Şekil 2.17. En büyük değer havuzlama örneği

2.6.4. Tam Bağlı Katman

Tam bağlı tabakadaki bütün nöronlar bir sıra şeklinde görünmektedir. Burada bulunan nöronların hepsi bu tabakaya tabi evvelki tabakadaki aktivasyonların tamamına tam bağlı haldedir. Önceki tabakayla alakalı olarak meydana çıkan tam bağlı tabakanın niteliği olarak bilinmektedirler. Bölümlendirme işlevleri için, tam bağlantılı tabaka, önce olan tabakalardan elde edilen özniteliklere bağlı olarak bölümlendirme yapılmaktadır. Veri kümesinin sınıf sayısına eşit olan ise son tam bağlantılı tabakanın çıktısı boyutudur ve aksine, regresyon işlevleri amacıyla, cevap parametrelerinin âdetine eşit olmalıdır. CNN mimarisinin sonunda bulunan çoğunlukla tamamen bağlantılı tabakalardır. Şekil 2. 19'da da tam bağlı katmanına örnek gösterilmiştir [56].




Şekil 2.18. Tam bağlı katmanı

2.6.5. Sönümlenme Katmanı

Aşırı öğrenme isimli ağın akılda tutulması çok tabakalı YSA eğitildiği sırada gerçekleşen işlem, komplikasyon olarak değerlendirilmektedir. Ağda ezber yapan bazı

düğümün ortadan kaldırılarak bu durumu engellenmek amaçlanmıştır. Hinton et al. tavsiyesiyle sönümlenme tabakası tam bağlı katmanlara düzenleme tabakası olmaktadır. Bu tabakanın sinir ağlarının düzenlenmesinde büyük fayda sağladığı yapılan testlerde açıkça görülmektedir. Şekil 2. 20’de de YSA ve sönümlenme uygulanmış sinir ağına örnek gösterilmiştir [57].



Şekil 2.19. a) YSA b) Sönümlenme uygulanmış sinir ağı

2.6.6. Sınıflandırma Katmanı

Sınıflandırma tabakası tam bağlı tabakadan sonra gelir ve sınıflandırma yapılan eleman adetince sonuç çoğaltmakta ve sonuçların ayrı ayrı hepsi bir kümeyi simgelemektedir. Değişik çeşitte sınıflandırıcılar tercih edilse de çoğunlukla softmax sınıflandırıcı kullanılmaktadır. Sınıflandırıcı tabaka son tabaka olarak bilinmektedir.

Sınıflandırma amacıyla kullanılan ve sınıflandırma tabakası olarak softmax tabakasından önce gelen tam bağlı tabakadan giriş verilerini almaktadır. İhtimal dahilinde olan giriş verisinin belirlenen sınıfa dair olma durumunu açıklamakta ve hangi sınıfa daha yakın ise ona göre değer üretmektedir. Ayrı ayrı her sınıf için ihtimal değerini çıkarırken DÖ ağı içerisinde ortaya çıkan olasılıksal hesaplama gerçekleşmektedir. Bu işlemler için ise çapraz entropi kullanılmaktadır [58].

3. BÖLÜM

YÖNTEM

Bu çalışma kapsamında, bataryaların KFÖ incelenmesi ele alınmıştır. Bataryanın KFÖ tahmini için sezgisel yöntemlerden DÖ yönteminden yararlanılmıştır. NASA'dan alınan batarya veri setlerinin nasıl analiz edildiği ve analizinin üzerinde çalışma yapılmıştır. Bunun için öncelikle, kullanılan veri seti tanıtılmıştır. Ardından DÖ ile KFÖ tahmini gerçekleştirilmiştir.

3.1. Batarya Veri Seti Uygulaması

Batarya seti için, NASA Ames PCOE tarafından yayınlanan Li-ion batarya seti tercih edilmiştir. Batarya seti ile ilgili literatürde birçok çalışma yapılmıştır. Bu çalışmalarda farklı yöntemler tercih edilmiştir [59].

Literatürdeki yapılan çalışmalar dikkate alınarak, bu tez çalışmasında NASA Ames PCOE Li-ion bataryalarında yapılan 5, 6, 7 ve 18 numaralı testler kullanılmıştır. Bu test verilerinde, bataryaların oda sıcaklığında şarj ve deşarjları esnasında ulaştığı akım, voltaj ve sıcaklık değerleri bulunmaktadır. Şarj işlemi, 1,5 amperlik (A) sabit akım (Constant Current, CC) modun da 4,2 volt (V) voltaja erişene kadar şarj işlemi gerçekleştirilmiştir.

Deşarj işleminde CC modu, ölçülen voltaj 5, 6, 7, ve 18 numaralı batarya için sırasıyla 2.7 V, 2.5 V, 2.2 V ve 2.5 V altında olmadıkça 2A akım ile beslenmiştir. Bu dört batarya hücresinde arızaya ulaşıncaya kadar çalışma deneyi yapılmıştır. Bu süreç, batarya kapasitelerini %70'e düştüğünde test durdurulmuştur. Dört batarya hücresinin tümü için maksimum kapasite yaklaşık 2 Ah (Ampere-Hour) iken, test sonrasında 1,4 Ah'a düştüğü görülmüştür.

Tekrarlayan şarj ve deşarj döngüleri bataryaların daha hızlı eskimesine sebep olurken empedans ölçümleri yıpranma devam ettiği sürece değişim gösteren dahili batarya parametreleriyle ilgili bilgi sağlamaktadır. Bataryalarda gerçekleştirilen deneylere bataryaların kapasitesi belli bir değere ulaştığında son verilmiştir. Yapılan çalışmada kullanılan veri setinde bataryaların KFÖ çıkarımına ek olarak kalan şarj çıkarımı hakkında bilgi edinilmesi de hedeflenmiştir.

Tablo 3.1’de 5 nolu batarya veri seti ile ilgili bilgiler sunulmuştur. Şekil de maksimum ve minimum döngüler arasındaki gürültülerden arındırılarak değer okuma işleminden elde edilen değerler verilmiştir. Tablo 3.2’de 6 nolu batarya veri seti ile ilgili bilgiler sunulmuştur. Şekil de maksimum ve minimum döngüler arasındaki gürültülerden arındırılarak değer okuma işleminden elde edilen değerler sunulmuştur. Tablo 3.3’de 7 nolu batarya veri seti ile ilgili bilgiler sunulmuştur. Şekil de maksimum ve minimum döngüler arasındaki gürültülerden arındırılarak değer okuma işleminden elde edilen değerler verilmiştir. Tablo 3.4’de 18 nolu batarya veri seti ile ilgili bilgiler sunulmuştur. Şekil de maksimum ve minimum döngüler arasındaki gürültülerden arındırılarak değer okuma işleminden elde edilen değerler sunulmuştur.

Tablo 3.1. 5 nolu batarya veri seti

	İterasyon	Kapasite	Ölçülen V	Ölçülen A	Ölçülen sıcaklık
Ortalama	88.125942	1.560345	3.515268	-1.806032	32.816991
Standart sapma	45.699687	0.182380	0.231778	0.610502	3.987515
Minimum	1.000000	1.287453	2.455679	-2.029098	23.214802
%25	50.000000	1.386229	3.399384	-2.013415	30.019392
%50	88.000000	1.538237	3.511664	-2.012312	32.828944
%75	127.000000	1.746871	3.660903	-2.011052	35.920887
Maksimum	168.000000	1.856487	4.222920	0.007496	41.450232

Tablo 3.2. 6 nolu batarya veri seti

	İterasyon	Kapasite	Ölçülen V	Ölçülen A	Ölçülen sıcaklık
Ortalama	88.125942	1.524719	3.457464	-1.773513	32.844374
Standart sapma	45.699687	0.233458	0.249892	0.647669	4.143796
Minimum	1.000000	1.53818	2.120698	-2.027018	23.201272
%25	50.000000	1.347410	3.321433	-2.011178	29.653775
%50	88.000000	1.473215	3.466565	-2.010095	32.940629
%75	127.000000	1.729207	3.621686	-2.008816	36.092889
Maksimum	168.000000	2.035338	4.222516	0.008809	42.007540

Tablo 3.3. 7 nolu batarya veri seti


	İterasyon	Kapasite	Ölçülen V	Ölçülen A	Ölçülen sıcaklık
Ortalama	88.125942	1.632911	3.516153	-1.910982	32.374078
Standart sapma	45.699687	0.152751	0.268665	0.387120	4.004486
Minimum	1.000000	1.400455	1.737030	-2.006038	22.969923
%25	50.000000	1.497822	3.408859	-1.990432	29.683138
%50	88.000000	1.605663	3.520359	-1.989406	32.294479
%75	127.000000	1.785885	3.681617	-1.988328	35.230784
Maksimum	168.000000	1.891052	4.233325	0.005072	42.332522

Tablo 3.4. 18 nolu batarya veri seti


	İterasyon	Kapasite	Ölçülen V	Ölçülen A	Ölçülen sıcaklık
Ortalama	59.962657	1.584405	3.501219	-1.842923	31.083216
Standart sapma	37.957008	0.156427	0.250037	0.552445	3.649983
Minimum	1.000000	1.341051	2.278634	-2.026719	22.350256
%25	27.000000	1.428376	3.382813	-2.009485	28.462162
%50	57.000000	1.605737	3.497088	-2.008341	31.121895
%75	92.000000	1.711846	3.662815	-2.007073	33.982822
Maksimum	132.000000	1.855005	4.193543	0.014306	38.87688

Şekil 3.1'de 5 nolu bataryanın ham veri seti kapasitesinin zamana göre değişimi verilmiştir. Bataryanın kapasitesi 1.87'den zaman içerisinde 1.4'e kadar azaldığı ve ömrünü tamamladığı görülmüştür. Şekil 3.2'de 6 nolu bataryanın ham veri seti kapasitesinin zamana göre değişimi verilmiştir. Bataryanın kapasitesi 2,3'ten zaman içerisinde 1.4'e kadar azaldığı ve ömrünü tamamladığı görülmüştür.


Şekil 3.3'de 7 nolu bataryanın ham veri seti kapasitesinin zamana göre değişimi verilmiştir. Bataryanın kapasitesi 1,9'dan zaman içerisinde 1,4'e kadar azaldığı ve ömrünü tamamladığı görülmüştür. Şekil 3.4'de 18 nolu bataryanın ham veri seti kapasitesinin zamana göre değişimi verilmiştir. Bataryanın kapasitesi 1.87'den zaman içerisinde 1.44'e kadar azaldığı ve ömrünü tamamladığı görülmüştür.



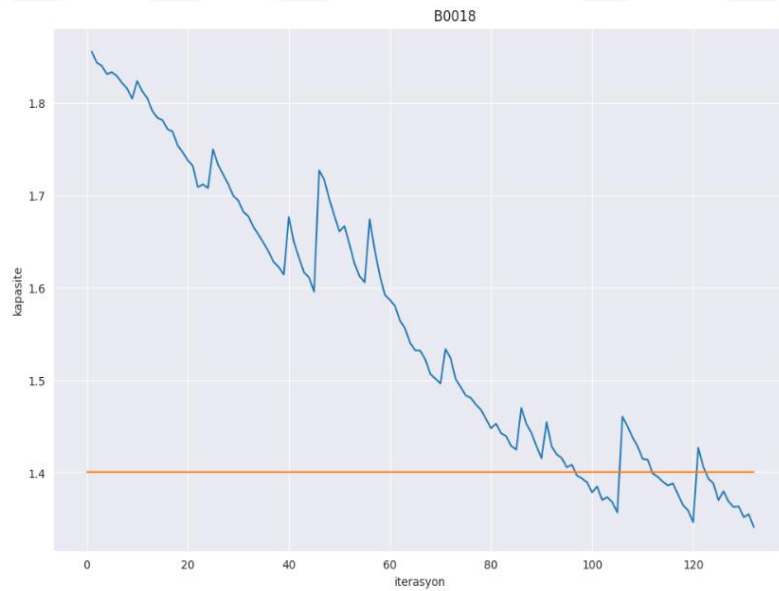
Şekil 3.1. 5 nolu bataryanın ham veri seti kapasitesinin zamana göre değişimi



Şekil 3.2. 6 nolu bataryanın ham veri seti kapasitesinin zamana göre değişimi



Şekil 3.3. 7 nolu bataryanın ham veri seti kapasitesinin zamana göre değişimi



Şekil 3.4. 18 nolu bataryanın ham veri seti kapasitesinin zamana göre değişimi

Şekil 3.1'den Şekil 3.4'e kadar, bataryaların şarj döngüleri ilerledikçe bataryaların eskime süreciyle ilgili bilgi sağlaması amacıyla gösterilmiştir. Yatay çizgi, bataryanın yaşam döngüsünün sonu olarak kabul edilmiş ve ilgili eşik için gösterilmiştir.


Yapılan çalışmada bataryaların SOH hesaplamak da gerekmektedir. Çünkü bu verilerin tahmin edilmesinde DÖ modeli kullanılmıştır.

Şekil 3.5’de 5 nolu batarya ham veri seti SOH’un zamana göre değişimi verilmiştir. Bataryanın zaman içerisinde SOH 1.00-0,70 arasında azaldığı ve ömrünü tamamladığı görülmüştür.


Şekil 3.6’da 6 nolu batarya ham veri seti SOH’un zamana göre değişimi verilmiştir. Bataryanın zaman içerisinde SOH 1.00-0,60 arasında azaldığı ve ömrünü tamamladığı görülmüştür.

Şekil 3.7’de 7 nolu batarya ham veri seti SOH’un zamana göre değişimi verilmiştir. Bataryanın zaman içerisinde SOH 1.00-0,75 arasında azaldığı ve ömrünü tamamladığı görülmüştür.


Şekil 3.8’de 18 nolu batarya ham veri seti SOH’un zamana göre değişimi verilmiştir. Bataryanın zaman içerisinde SOH 1.00-0,72 arasında azaldığı ve ömrünü tamamladığı görülmüştür.



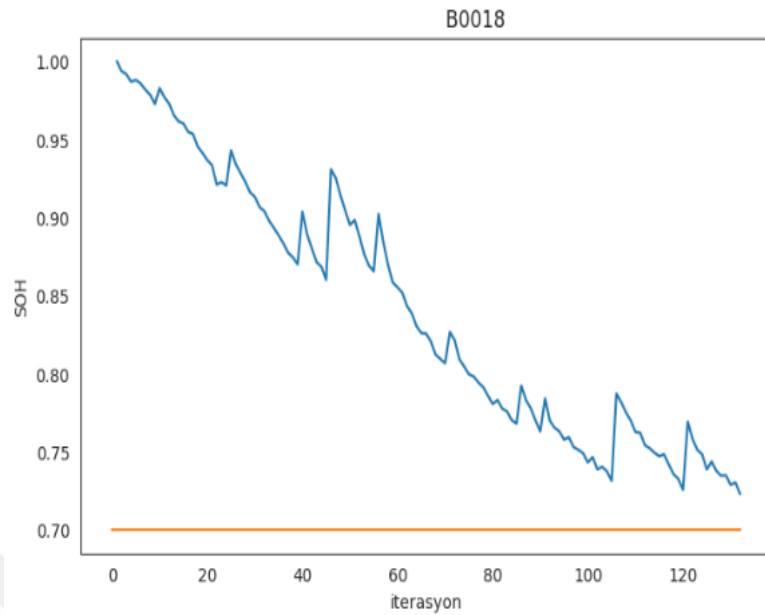
Şekil 3.5. 5 nolu bataryanın ham veri seti SOH zamana göre değişimi



Şekil 3.6. 6 nolu bataryanın ham veri seti SOH zamana göre değişimi



Şekil 3.7. 7 nolu bataryanın ham veri seti SOH zamana göre değişimi



Şekil 3.8. 18 nolu bataryanın ham veri seti SOH zamana göre değişimi

Bir önceki grafiğe benzer şekilde yine her döngü için SOH grafiği çizilmiştir. Yatay çizgi, bataryanın zaten yaşam döngüsünü tamamladığını ve %70 eşliğini temsil etmektedir. Yapılan çalışmada bu eşğin aşılması halinde batarya değişimi yapılması tavsiye edilmektedir.

Eğitim aşamasında da veri setleri Tensorflow aracılığıyla hazırlanmış ve iki yapıya denk gelecek şekilde girdi ve çıktı oluşturulmuştur. Sonrasında ise girdi verileri için veri kümesinin ilgili nitelikleri ayrıştırılmıştır. Bu ayrıştırılan nitelikler; batarya kapasitesi, gerilim, akım, sıcaklık, şarj voltajı, şarj akımı, anlık zaman gibi özelliklerden oluşmaktadır.

Bataryanın çıkış verileri için SOH hesaplanmıştır. Sonrasında ise giriş ve çıkış durumları için değerler (0-1) arasında olan değer aralığına normalleştirilebilir.

Modelin hazırlık aşamasında 3 yoğun katman kullanılmıştır. Bunlar; 3 yoğun katman ve bir dropout ve optimizer olarak ADAM tipinden biri kullanılmıştır. Modelin doğruluğunu test etmek için aynı bataryanın bilgileri yüklenmiştir. Oluşturulan tabloda gerçek SOH ve ağ tarafından tahmin edilen SOH değerlerini içermektedir ve ortalama karesel hatanın kökü hesaplanmaktadır.

Tablo 3.5’de sunulan algoritmanın ve karşılaştırılabilir algoritmaların sembolleri ve açıkları verilmiştir. Arkasından gelen Tablo 3.6’de ise LSTM’ye göre hesaplanan RMSE (Root Mean Square Error) değerlerini görülmektedir.

Tablo 3.5. Sunulan algoritmanın ve karşılaştırılabilir algoritmaların sembolleri ve açıklamaları

HI-ALSTM	Sağlık indeksi bilgilendirilmiş dikkat tabanlı LSTM modeli (Önerilen metodoloji)
HI-LSTM	Dikkat mekanizmasını kullanmadan sağlık indeksi bilgili LSTM modeli
ALSTM	Sağlık indeksini kullanmadan dikkat tabanlı LSTM tahmin modeli
LSTM	Geleneksel LSTM tahmin modeli

Tablo 3.6. Önerilen algoritmanın RMSE'si ve tüm batarya birimleri için listelenen algoritmalar

	Battery No. 5	Battery No. 6	Battery No. 7	Battery No. 18	Average
HI-ALSTM [59]	0.0165	0.0153	0.0089	0.0139	0.0136
HI-LSTM [59]	0.0399	0.0612	0.0542	0.0274	0.0457
ALSTM [59]	0.0085	0.0220	0.0145	0.0151	0.0150
LSTM	0.0137	0.3149	0.00949	0.0108	0.0335

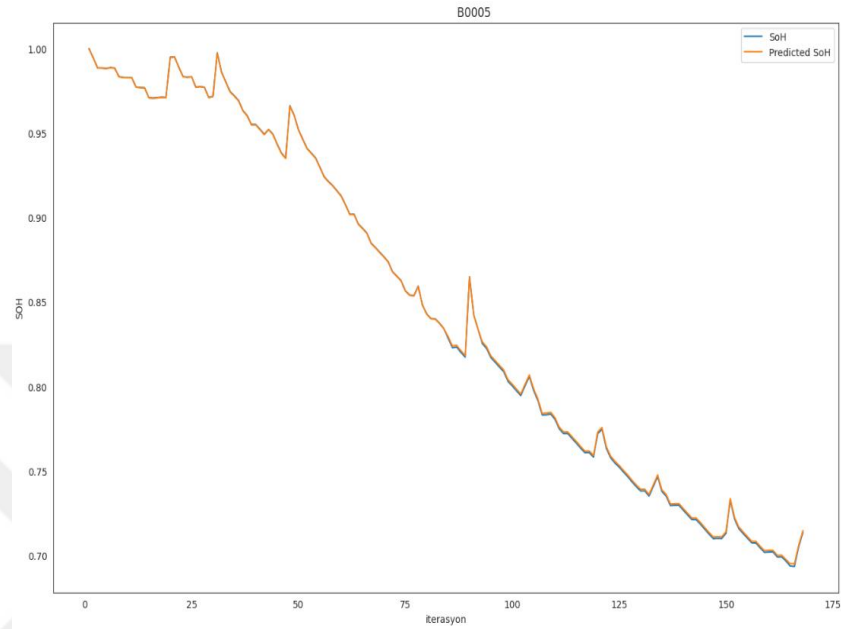
Şekil 3.9’de 5 nolu batarya veri seti eğitildikten sonra ki gerçek SOH ve tahmin edilen SOH karşılaştırılması verilmiştir. Başlangıçta birebir bir ilerleyiş göstermişler fakat sonrasında gerçek hayatta ayırt edemeyeceğimiz kadar küçük bir farklılık kaydedilmiştir.

Şekil 3.10’da 6 nolu batarya veri seti eğitildikten sonraki gerçek SOH ve tahmin edilen SOH karşılaştırılması verilmiştir. Başlangıçta bir farklılık görülmüş olsa bile sonlara doğru farklılaşma ciddi boyutta azalma göstererek bir ilerleyiş kaydedilmiştir.


Şekil 3.11’de 7 nolu batarya veri seti eğitildikten sonraki gerçek SOH ve tahmin edilen SOH karşılaştırılması verilmiştir. Başlangıçta ve sonda ufak bir farklılaşma görülmüş olsa bile kullanım zamanının ortalarında birebir bir ilerleyiş kaydedilmiştir.

Şekil 3.12’de 18 nolu batarya veri setinin eğitildikten sonraki gerçek SOH ve tahmin edilen SOH karşılaştırılması verilmiştir. Başlangıçta bir farklılaşma görülmüş olup


zamanın ortalarında bir örtüşme kaydedilmiş fakat sonlara doğru ise yine bir farklılaşma oluşturan ilerleyiş kaydedilmiştir.




Şekil 3.9. 5 nolu bataryanın veri setinin gerçek ve eğitilmiş SOH karşılaştırılması



Şekil 3.10. 6 nolu bataryanın veri setinin gerçek ve eğitilmiş SOH karşılaştırılması



Şekil 3.11. 7 nolu bataryanın veri setinin gerçek ve eğitilmiş SOH karşılaştırılması



Şekil 3.12. 18 nolu bataryanın veri setinin gerçek ve eğitilmiş SOH karşılaştırılması

Grafikleri meydana getiren SOH çıkarım eğrilerinin görüntülerinde ufak farklıklar var gibi görünmüş olsa da gerçekte bu neredeyse aynı durumu göstermektedir. Bu açıklamaya göre değerlendirecek olursak, teorik olarak çıkarımı yapılan veri örüntüsünün model tarafından düzgün öğrenildiğinin bir kanıtı olmaktadır. Teorik olarak tahmin edilen veri

örüntüsü ile gösterilen SOH aynı tutumu sergilemektedir. Bunlar gerçek hayatta algılanabilecek değerler değildir.

Eğitim ve test veri setleri hazırlanmıştır. Tıpkı SOH çıkarımındaki gibi devam eden döngülerdeki kapasite hakkında çıkarım yapabilmek amacıyla ilk 500 döngünün verileri kullanılmıştır. Bu işlem bataryanın EOL ve eşiğine ne zaman ulaştığını bilmek için kalan döngüler hakkında çıkarım yapmanın bir yolu olmaktadır.

Son kısımlara geldiğimiz de standart sinir ağlarının yerine LSTM tipi ağlar kullanılarak ağ eğitilmiştir. Ortalama RMSE 0,05 olduğunu görmekteyiz bu çeşit bir ağ tercih edildiğinde literatürde ki değerlere de daha yakın değerlere ulaşmaktayız.


Son grafiğimizi incelediğimizde ise kapasite değerinin ve zaman içindeki davranış değişiminin gerçek değere yakınlığını da görmekteyiz.

Şekil 3.13’de 5 nolu batarya test veri setinin ve tahmin ettiğimiz veri setinin eşik değerlerinin karşılaştırılması verilmiştir. Tahmin ettiğimiz veri setinin kapasitesi 1.8’in biraz daha altından başlarken gerçek veri setinin kapasitesi 1.9’dan başlamaktadır. Bu grafikte bataryanın eşik değerini aşan bir eğri görülmektedir.


Şekil 3.14’de 6 nolu bataryanın test veri setinin ve tahmin ettiğimiz veri setinin eşik değerlerinin karşılaştırılması verilmektedir. Tahmin ettiğimiz verinin kapasitesi 2.0’i biraz aşarak başlarken gerçek verinin kapasitesi 1.8’in biraz daha altından başlamaktadır. Bu grafikte bataryanın eşik değerini aşmadan kapasitesini doldurduğunu görülmektedir.

Şekil 3.15’de 7 nolu bataryanın test veri setinin ve tahmin ettiğimiz veri setinin eşik değerlerinin karşılaştırılması verilmektedir. Tahmin ettiğimiz veri setinin kapasitesi 1.8’in biraz aşağısından başlarken gerçek veri setinin kapasitesi 1.9’dan başlamaktadır. Bu grafikte bataryanın eşik değerini aşan bir eğri görülmektedir.


Şekil 3.16’de 18 nolu bataryanın test veri setinin ve tahmin ettiğimiz veri setinin ve eşik değerlerinin karşılaştırılması verilmektedir. Tahmin ettiğimiz veri setinin kapasitesi 1.6 ile 1.7 arasında bir değerden başlarken gerçek veri setinin kapasitesi 1.9 civarında başlamaktadır. Bu grafikte bataryanın eşik değerini aşan bir eğri görülmektedir.




Şekil 3.13. 5 nolu bataryanın test veri setinin ve tahmin ettiğimiz veri setinin eşik değerlerinin karşılaştırılması



Şekil 3.14. 6 nolu bataryanın test veri setinin ve tahmin ettiğimiz veri setinin eşik değerlerinin karşılaştırılması



Şekil 3.15. 7 nolu bataryanın test veri setinin ve tahmin ettiğimiz veri setinin eşik değerlerinin karşılaştırılması



Şekil 3.16. 18 nolu bataryanın test veri setinin ve tahmin ettiğimiz veri setinin eşik değerlerinin karşılaştırılması

4. BÖLÜM

TARTIŞMA-SONUÇ VE ÖNERİLER

4.1. Tartışma

Yapılan çalışmada, bataryaların sağlık indeksi ile alakalı sonuca varmak amacıyla derin öğrenmeye dayalı bir yöntem sunulmuştur. Bu şekilde bir sağlık indeksi, bataryanın bozulma davranışı ile alakalı etkili sonuçların elde edilmesi amaçlanmıştır. Bataryaların çıkarım ve sağlık yönetiminin incelenmesinde ki alt yapı, bataryanın sağlık vaziyeti ve KFÖ çıkarımına göre temellendirmektedir. Li-ion batarya üzerine yapılan bu çalışmada LSTM yönetimi kullanılarak bu bataryanın sağlık vaziyeti ve KFÖ bilgileri ile ilgili çıkarımlar yapılmak amaçlanmıştır.

4.2. Sonuç ve Öneriler

LSTM yönetimi, NASA Ames PCOE'den veritabanında bulunan ve erişimi herkes tarafından yapılabilen bir batarya veri kümesine uygulanmıştır. PCOE'nin 5, 6, 7 ve 18 nolu batarya veri setleri ile elde alınan doğrulama sonuçları, yöntemin uygulanabilirliğini ve etkinliğini göstermektedir. Yöntemin verimini yorumlamak amacıyla 5, 6, 7 ve 18 nolu bataryalardan alınan akım, voltaj ve sıcaklığı içinde bulunduran veri setini tercih etmiştir. Ulaşılan sayısal veriler, ulaşılan sağlık endekslerinin 5, 6, 7 ve 18 nolu bataryaların kapasite düşüşünü, yenilenme durumlarını net bir şekilde tespit edebildiğinin kanıtlat niteliktedirler. Bataryalar üzerine yapılan araştırmalar her geçen gün artmakta ve gelişimi süre gelmektedir. İlerleyen zaman dilimlerinde ki çalışmalarda SOH tahminlerinde farklı batarya çeşitlerine de yer verilmesi beklenmektedir. Günümüzde yapılan çalışmaların neredeyse hepsi elektrikli araçların, akıllı telefonların ve daha birçok teknolojik alette yaygın olarak Li-ion bataryalar tercih edilmektedir. Kurşun-asit, NiCd ve çinko-karbon bataryalarda etkili ve güvenilir SOH çıkarım yöntemlerinin kullanıldığı bataryalar farklı türler arasındadır.

Konu üzerinde yapılan çalışmalar yeni algoritmalar ve makine öğrenme yöntemleri türeterek bataryalar için kalan kullanım ömrü ile ilgili doğru çıkarımlar yapmayı hedeflemektedir. Değişik batarya çeşitleri için SOH çıkarımlarının eksikleri de giderilmektedir. Temelde ki düşünceye bakacak olursak, farklı belirsizliklerin etkisini tespit edip, çıkarımlar için güven katsayısı sağlamaktır. İlerde, DÖ alt yapılı belirsizlik teknolojileri, Li-ion batarya belirsizliklerinin yönetimini sağlamak amacıyla eklenmesi beklenmektedir.



KAYNAKÇA

1. Walter, A., Schalkwijk, V. and Scrosati, B., 2002. *Advances in Lithium-Ion Batteries*, Kluwer Academic/ Plenum Publishers, New York, pp. 30-42
2. Kiehne, H.A. 2003. *Battery Technology Handbook 2 nd Edition*, Marcel Dekker Inc., New York. Enerji Bilimi (Web sayfası), (Erişim tarihi: Mart 2022).
3. Özdoğan, E., 2010. atık nikel kadmiyum bataryalarının geri kazanımına yönelik proses geliştirilmesi, İstanbul teknik üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Konya, 123 s.
4. Zhang, Q., Wang, D., Yang, B., Cui, X., & Li, X. 2020. Electrochemical model of lithium-ion battery for wide frequency range applications. **Electrochimica Acta**, **343**, 136094.
5. Nejad, S., Gladwin, D. T., & Stone, D. A. 2016. A systematic review of lumped-parameter equivalent circuit models for real-time estimation of lithium-ion battery states. **Journal of Power Sources**, **316**, 183-196.
6. Romero-Becerril, A., & Alvarez-Icaza, L. 2011. Comparison of discretization methods applied to the single-particle model of lithium-ion batteries. **Journal of Power Sources**, **196**(23), 10267-10279.
7. Liu, X.; Wu, J.; Zhang, C.; Chen, Z. 2014. A method for state of energy estimation of lithium-ion batteries at dynamic currents and temperatures. **J. Power Sources** **270**, 151–157.
8. Guo, P.; Song, H.; Chen, X. 2009. Electrochemical performance of graphene nanosheets as anode material for lithium-ion batteries. **Electrochem. Commun.** **11**, 1320–1324.
9. Fu, P.; Chu, L.; Li, J.; Guo, Z.; Hu, J.; Hou, Z. 2022. State of Health Prediction of Lithium-Ion Battery Based on Deep Dilated Convolution. **Sensors** **22**, 9435.
10. Nazri, G.A. and Pistoia, G., 2009. *Lithium Batteries: Science and Technology*, Springer Science and Business Media, Newyork, pp. 8-11
11. Bole, Brian, Chetan S. Kulkarni, and Matthew Daigle. "Adaptation of an electrochemistry-based li-ion battery model to account for deterioration observed under randomized use." *Annual conference of the PHM society*. Vol. 6. No. 1. 2014..

12. Penna, José Affonso Moreira, Cairo Lúcio Nascimento, and Leonardo Ramos Rodrigues. "Health monitoring and remaining useful life estimation of lithium-ion aeronautical batteries." *2012 IEEE Aerospace Conference*. IEEE, 2012.,
13. Saha, B., ve Goebel, K. .2021. Modeling Li-ion Battery Capacity Depletion in a Particle Filtration Framework. **HSH Association Annual Conference, 1**
14. Cheng, Y., Song, D., Wang, Z., Lu, C., & Zerhouni, N., 2020. "An Ensemble Prognostic Method for Lithium-Ion Battery Capacity Estimation Based on Time-Varying Weight Allocation". *Applied Energy*, China.
15. Bole, B., Matthew D., George G. 2014. "Online Prediction of Battery Discharge and Estimation of Parasitic Loads for an Electric Aircraft".
16. Dai, J., & Wang, H., 2021. "Evolution of Aircraft Maintenance and Logistics Based on Prognostic and Health Management Technology". In *Proceedings of the First Symposium on Aviation Maintenance and Management*, Springer, Berlin, pp. 665-672.
17. Mansouri, S. S., Karvelis, P., Georgoulas, G., & Nikolakopoulos, G., 2005. "Remaining Useful Battery Life Prediction for Uavs Based on Machine Learning". **IFAC-PapersOnLine**, **50**(1), 4727-4732.
18. Son, J., Raed K., Shiyu Z. 2016, "Prognostic classification problem in battery health management." *Advances in Battery Manufacturing, Service, and Management Systems*, p. 127-150.
19. Saha, B., Saha, B., Koshimoto, E., Koshimoto, E., Quach, C., Quach, C., Storm, T., 2011. "Predicting Battery Life for Electric Uavs". In *Infotech Aerospace* p. 1517.
20. Saha, B., Cuong C. Quach, Kai G. 2012. "Optimizing Battery Life For Electric Uavs Using A Bayesian Framework", *Aerospace Conference*. IEEE,
21. Zhao, J.; Zhu, Y.; Zhang, B.; Liu, M.; Wang, J.; Liu, C.; Zhang, Y. 2022. Method for Estimating SOH and RUL of Lithium-Ion Batteries Based on Combination of LSTM and GPR. **Sustainability**, **14**, 11865.
22. Zhou, D.; Li, Z.; Zhu, J.; Zhang, H.; Hou, L. 2020. Health status monitoring and remaining useful life estimation of lithium-ion Batteries based on temporal convolutional network **IEEE Acces** **8**, 53307–53320.

23. Wei, Y.; Wu, D. 2023. Prediction of health status and remaining life of a lithium-ion battery using a dual-attention graphic convolutional network. Trustworthy. **Eng. Schist.** **230**, 108947.
24. Walter, A., Schalkwijk, V. and Scrosati, B., 2002. Advances in Lithium-Ion Batteries, Kluwer Academic/ Plenum Publishers, New York, pp. 30-42
25. McComsey, D.W., 2001: Zinc carbon batteries (Leclanche and zinc chloride cell systems), Linden, D. (Ed.), **Handbook of Batteries**, **8**, 193–237.
26. Almeida, M.F., Xara, S.M., Delgado, J., Carlos, A.C., 2006: Characterization of spent AA household alkaline batteries, **Waste Management**, **26**, 466-476.
27. De Souza, C.C.B.M., Tenorio, J.A.S., 2004: Simultaneous recovery of zinc and manganese dioxide from household alkaline batteries through hydrometallurgical processing. **Journal of Power Sources**, **136**, 191196.
28. Japanese Battery Association, <http://www.baj.or.jp/>, alındığı tarih 23.10.2010.
29. Bender, S.F., Cretzmeyer, J.W., Reise, 2001: Zinc/air batteries button configuration, Linden, D. (Ed.), **Handbook of Batteries**, **13**, 320-340.
30. Nazri, G.A. and Pistoia, G., 2009. Lithium Batteries: Science and Technology, Springer Science and Business Media, Newyork, pp. 8-11
31. Kırıl, F., M., 2019. Atık çinko-karbon batarya tozundan asidik ortamda çinko ve manganın çözündürülmesi. Konya Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Konya, 60 s.
32. Linden, D., 2001: Mercuric oxide batteries, Linden, D. (Ed.), **Handbook of Batteries**, **11**, 284-301.
33. Megahed, S.A., Passaniti, J., Springstead, 2001: Silver oxide batteries, Linden, D. (Ed.), **Handbook of Batteries**, **12**, 301-320.
34. Braam, Kyle, and Vivek Subramanian. "A stencil printed, high energy density silver oxide battery using a novel photopolymerizable poly (acrylic acid) separator." **Advanced Materials** **27.4** (2015): 689-694.
35. Öztürk, M., 2007: Pil/Akü kullanımı ve atık piller ile akülerin zararları. Çevre ve Orman Bakanlığı, <http://www.cevreorman.gov.tr/belgeler/piller.pdf>, alındığı tarih 16.10.2010.
36. Nogueira C.A., Margarido F., 2007. Chemical and physical characterization of electrode materials of spent sealed Ni-Cd batteries, **Waste Management**, **27**, 1570-1579.

37. Meisner L., 2005: Ultra Low Maintenance Nickel Cadmium Batteries, Hoppecke Batteries Inc., New Jersey.
38. Linden, D., Magnusen, D., 2001. Portable Sealed Nickel-Metal Hydride Batteries. Linden, D. (Ed.), **Handbook of Batteries**, **29**, 861-895.
39. Uludağ Akbulut, A., 2021. Lityum Hava Pillerde Enerji Depolama ve Yaşam Döngüsü Analizi. Sakarya üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Sakarya, 203 s.
40. Uludağ Akbulut, A., 2021. Lityum Hava Pillerde Enerji Depolama Ve Yaşam Döngüsü Analizi. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Sakarya, 203 s.
41. Dahlin, G.R. and Strom, K.E., 2010. Lithium Batteries: Research, Technology and Applications, Nova Science Pub Incorporated, pp. 32-51
42. Ward, I.M., Hubbard, H.V.St.A., Wellings, S.C., Thompson, G.P., Kaschmitter, J. and Wang, H.P., 2006. Separator-free rechargeable lithium ion cells produced by the extrusion lamination of polymer gel electrolytes, **Journal of Power Sources**, **162**, 818–822
43. Al Rahhal, M. M., Bazi, Y., AlHichri, H., Alajlan, N., Melgani, F., & Yager, R. R. 2016. Deep learning approach for active classification of electrocardiogram signals
44. Chollet, F. 2016. Xception: Deep learning with depthwise separable convolutions. arXiv preprint.
45. Chen, C. L., Mahjoubfar, A., Tai, L. C., Blaby, I. K., Huang, A., Niazi, K. R., & Jalali, B. 2016. Deep learning in label-free cell classification
46. Schmidhuber, J. 2015. "Deep learning in neural networks: An overview." **Neural networks** **61** 85-117.
47. Dettmers, T., 2015. Deep learning in a nutshell: history and training parallel for all. Available: <https://devblogs.nvidia.com/paralleforall/deep-learning-nutshell-history-training/> [Accessed: 12-Apr-2019].
48. K. . N. Fukushima, A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position., **Biol. Cybern.**, vol. **36**, no. 4, pp. 193–202, 1980.
49. A. Graves and N. Jaitly, "Towards End-To-End Speech Recognition with Recurrent Neural Networks.," in ICML, 2014, pp. 1764–1772.

50. Gers, F. A., & Schmidhuber, J. 2000. Recurrent nets that time and count. In *Neural Networks, 2000. IJCNN 2000, Proceedings of the IEEEINNS-ENNS International Joint Conference on. 3*, pp. 189-194.
51. Bengio, Y. 2009. Learning deep architectures for AI. **Foundations and trends® in Machine Learning**, 2(1), 1-127.
52. Gao, J., Zhang, H., Lu, P. ve Wang, Z. 2019. An effective LSTM recurrent network to detect arrhythmia on imbalanced ECG dataset. **Journal of healthcare engineering**, 1, 7-9.
53. Tamura, S. I., & Tateishi, M. 1997. Capabilities of a four-layered feedforward neural network: four layers versus three. **IEEE Transactions on Neural Networks**, 8(2), 251-255
54. Ciresan, D. C., Meier, U., Masci, J., Maria Gambardella, L., & Schmidhuber, J. 2011. Flexible, high performance convolutional neural networks for image classification. **In IJCAI Proceedings-International Joint Conference on Artificial Intelligence**, 22, No. 1, p. 1237).
55. Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. 2012. Improving neural networks by preventing coadaptation of feature detectors. **arXiv preprint arXiv:1207.0580**.
56. LeCun, Y., & Bengio, Y. 1995. Convolutional networks for images, speech, and time series. **The handbook of brain theory and neural networks**, 3361(10); 41-47.
57. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. 2014. Dropout: A simple way to prevent neural networks from overfitting. **The Journal of Machine Learning Research**, 15(1), 1929- 1958
58. Ciresan, D. C., Meier, U., Masci, J., Maria Gambardella, L., & Schmidhuber, J. (2011). Flexible, high performance convolutional neural networks for image classification. **In IJCAI Proceedings-International Joint Conference on Artificial Intelligence 22**, No. 1, p. 1237.
59. Wei, Yupeng. 2023. "Prediction of State of Health of Lithium-Ion Battery Using Health Index Informed Attention Model." **Sensors 23.5**: 41-47.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Hava Merve ÇELİK
Uyuğu: Türkiye (T.C)

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Lisans	Erciyes Üniversitesi, Uçak Elektrik Elektronik Bölümü	2019
Lise	Atatürk Anadolu Lisesi , Aydın	2013

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2019-Halen	Türk Hava Yolları	4 Yıl

YABANCI DİL

İngilizce