T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

HAVA ARAÇLARINDA UZUN KISA VADELİ BELLEK YÖNTEMİYLE KESTİRİMCİ BAKIM ANALİZİ

Erhan GÜL

YÜKSEK LİSANS TEZİ

Aviyonik Mühendisliği Anabilim Dalı

Aviyonik Mühendisliği Programı

Danışman

Doç. Dr. Serkan KURT

Mart, 2025

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

HAVA ARAÇLARINDA UZUN KISA VADELİ BELLEK YÖNTEMİYLE KESTİRİMCİ BAKIM ANALİZİ

Erhan GÜL tarafından hazırlanan tez çalışması 07.03.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Aviyonik Mühendisliği Anabilim Dalı, Aviyonik Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Serkan KURT
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Serkan KURT, Danışman
Yıldız Teknik Üniversitesi _____

Doç. Dr. Peyman MAHOUTİ, Üye
Yıldız Teknik Üniversitesi _____

Prof. Dr. Aysel ERSOY, Üye
İstanbul Üniversitesi, Cerrahpaşa _____

Danışmanım Doç. Dr. Serkan KURT sorumluluğunda tarafımca hazırlanan “Hava Araçlarında Uzun Kısa Vadeli Bellek Yöntemiyle Kestirimci Bakım Analizi” başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Erhan GÜL

İmza

Eşime

ve

Aileme

TEŞEKKÜR

Tez çalışmamın tamamlanmasında bana rehberlik eden, değerli zamanını ve bilgisini esirgemeyen, her aşamada bana yön veren danışmanım Doç. Dr. Serkan KURT' a teşekkürlerimi sunarım.

Bu tezin tamamlanmasında bana her zaman sonsuz destek veren, sabrıyla, sevgisiyle ve inancıyla her an yanımda olan sevgili eşime en derin teşekkürlerimi sunuyorum.

Tez çalışmam süresince eşimin, ailemin ve arkadaşlarımın sonsuz destek, emek ve sabrı benim için kıymetli birer kaynak olmuştur. Kendilerine her zaman yanımda oldukları ve bana güç verdikleri için minnettarlığımı sunar, bu süreçte bana eşlik ettikleri için teşekkür ederim.

Erhan GÜL

İÇİNDEKİLER

SİMGE LİSTESİ vii
KISALTMA LİSTESİ viii
ŞEKİL LİSTESİ x
TABLO LİSTESİ xii
ÖZET xiii
ABSTRACT xv
1 GİRİŞ 1
1.1 Literatür Özeti 1
1.2 Tezin Amacı 4
1.3 Hipotez 5
2 KESTİRİMCİ BAKIMIN HAVA ARAÇLARIYLA ENTEGRASYONU 6
2.1 Hava Aracı Yapısal Bütünlüğü 9
2.2 Motor Sistemleri 11
2.3 Aviyonik Sistemler 13
2.4 Hava Aracı Sistemleri 15
3 DERİN ÖĞRENME TEKNİKLERİ 19
3.1 Makine Öğrenimi 20
3.2 Yapay Sinir Ağları (Artificial Neural Networks, ANN) 21
3.3 Derin Öğrenme 23
3.3.1 Konvolüsyonel Sinir Ağları 23
3.3.2 Tekrarlayan Sinir Ağları 24
3.3.3 Sınırlı Boltzmann Makineleri 24
3.3.4 Derin İnanç Ağları 25
3.3.5 Uzun Kısa Vadeli Bellek 25
4 METODOLOJİ 28
4.1 Batarya Veri Seti 28
4.2 Uzun Kısa Vadeli Bellek Tekniği ile Tahmin Modeli Geliştirilmesi 33
4.3 Çapraz Doğrulama Uygulanması 34

4.4 Min- Max Normalizasyonu Uygulanması 35
4.5 Kutu Filtreleme Uygulanması 36
4.6 Hiper Parametre Optimizasyonu 37
4.7 Model Performansı Değerlendirme Kriterleri 39
5 BULGULAR VE TARTIŞMA **41**
5.1 Bulgular 41
5.1.1 Çok Kanallı ve Tek Kanallı Uzun Kısa Vadeli Bellek Modellerinin Karşılaştırılması 42
5.1.2 Min-Max Normalizasyonu Uygulanmamış ve Uygulanmış Uzun Kısa Vadeli Bellek Modellerinin Karşılaştırılması 43
5.1.3 Kutu Filtresi Uygulanmamış ve Uygulanmış Uzun Kısa Vadeli Bellek Modellerinin Karşılaştırılması 43
5.1.4 Normalizasyon ve Filtreleme Uygulanan Uzun Kısa Vadeli Bellek Modellerinde Hiper Parametre Optimizasyonu 44
5.1.5 Geliştirilen Yöntemin Farklı Veri Seti Üzerinde Test Edilmesi 45
5.2 Bulguların Değerlendirilmesi 48
5.3 Tartışma 51
6 SONUÇ **55**
KAYNAKÇA **57**
TEZDEN ÜRETİLMİŞ YAYINLAR **62**

SİMGE LİSTESİ

$\tilde{c}_t$	Aday Hücre Durumu
$C_{nominal}$	Bataryanın nominal kapasitesi
C_{mevcut}	Bataryanın şimdiki kullanım durumundaki mevcut kapasitesi
o_t	Çıkış Kapısı
y_i	Gerçek Değerler
i_t	Giriş Kapısı
h_t	Gizli Durum
n	Gözlem Sayısı
c_t	Hücre Durumu
Ort_1	Kutu Filtreleme ile Bulunan Ortalama Değer
$t_{şimdiki}$	Mevcut Zaman veya Sistemin Şu Anki Durumunun Ölçüldüğü zaman.
$\widehat{y_i}$	Modellerden Tahmin Edilen Değerler
°C	Santigrat– Sıcaklık Birimi
t_{EOL}	Sistemin veya Bileşenin Arıza Yapacağı Tahmini Zaman
y_t	t Anında Normalizasyon Sonucu Elde Edilen Yeni Değer
f_t	Unutma Kapısı
x_t	Veri Setindeki Verilerin t Anındaki Değeri
max (x_t)	Verinin t Anındaki Maksimum Değeri
min (x_t)	Verinin t Anındaki Minimum Değeri

KISALTMA LİSTESİ

AEPHM	Aircraft Electrical Power Systems Prognostics and Health Management (Uçak Elektrik Güç Sistemleri Prognostik ve Sağlık Yönetimi)
AFRL	Air Force Research Laboratory (Hava Kuvvetleri Araştırma Laboratuvarı)
ASIP	Airrcraft Structural Integrity Program (Uçak Yapısal Bütünlük Programı)
BiLSTM	Bidirectional Long Short Term Memory (Çift Yönlü Uzun Kısa Vadeli Bellek)
CBM	Condition Based Maintenance (Durum Bazlı Bakım)
CBM	Condition Based Monitoring (Durum Bazlı İzleme)
CNN	Convolutional Neural Networks (Konvolüsyonel Sinir Ağları)
CMAPPS	Commercial Modular Aero-Propulsion System Simulation (Ticari Modüler Havacılık İtki Sistemi Simülasyonu
DBN	Deep Belief Networks (Derin İnanç Ağları)
DL	Deep Learning (Derin Öğrenme)
DSR	Dempster-Shafer Regresyonu
EASA	European Union Aviation Safety Agency (Avrupa Havacılık Emniyet Ajansı)
EOL	End of Life (Ömür Sonu)
FAA	Federal Aviation Administration (Federal Havacılık İdaresi)
ICAO	International Civil Aviation Organization (Uluslararası Sivil Havacılık Örgütü)
IVHM	Integrate Vehicle Health Management (Bütünleşik Araç Sağlık Yönetimi)
İHA	İnsansız Hava Aracı
LSTM	Long Short Term Memory (Uzun Kısa Vadeli Bellek)
LSTM-ED	Long Short Term Memory Encoder/Decoder (Uzun Kısa Vadeli Bellek Kodlayıcı/Kod çözücü)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
MAX	Maksimum
MIN	Minimum
ML	Machine Learning (Makine Öğrenmesi)
MRO	Mainteance, Repair, Overhaul (Bakım, Onarım, Revizyon)

MSE	Mean Squared Error (Ortalama Kare Hata)
NAE	Nonlinear Adaptive Estimators (Doğrusal Olmayan Uyarlanabilir Tahminciler)
NASA	National Aeronautics and Space Administration (Ulusal Havacılık ve Uzay İdaresi)
NLP	Natural Language Processing (Doğal Dil İşleme)
PCA	Principle Component Analysis (Temel Bileşenler Analizi)
PCoE	Prognostics Excellence Center (Prognostik Mükemmeliyet Merkezi)
PDU	Power Distribution Unit (Güç Dağıtım Birimi)
PHM	Prognostic Health Management (Prognostik Sağlık Yönetimi)
RBM	Restricted Boltzmann Machines (Kısıtlı Boltzmann Makineleri)
ReLU	Rectified Linear Unit (Düzeltmeli Doğrusal Birim)
RMSE	Root Mean Squared Error (Kök Ortalama Kare Hata)
RNN	Recurrent Neural Network (Tekrarlayan Sinir Ağı)
RUL	Remaining Useful Life (Kalan Kullanılabilir Ömür)
SBA	Similarity-Based Approach (Benzeşim Temelli Yaklaşım)
SHM	Structural Health Monitoring (Yapısal Sağlık İzleme)
SOH	State of Health (Sağlık Durumu)
SVM	Support Vector Machines (Destek Vektör Makineleri)
YSA	Yapay Sinir Ağları (Artifical Neural Networks)

ŞEKİL LİSTESİ

Şekil 2.1 Bütünleşik hava aracı sağlık yönetimi **8**

Şekil 2.2 F-14 Uçağındaki birincil yapısal parçalar..... **10**

Şekil 2.3 General Electric (GE) Aviation tarafından üretilen F110 jet motoru **12**

Şekil 3.1 Yapay zekâ ve alt dallarının hiyerarşik yapısı **20**

Şekil 3.2 Yapay sinir ağı katmanları **22**

Şekil 4.1 NASA tarafından veri toplamak için kurulan test düzeneği **28**

Şekil 4.2 Batarya 18'e ait .csv dosyalarının filtrelenmesi..... **30**

Şekil 4.3 Batarya 18 için sadece bir deşarj döngüsüne ait ".csv" dosyasının içindeki veri formatı (Şekil 4.2'de gösterilen 6355 numaralı .csv'ye ait) **31**

Şekil 4.4 Çapraz doğrulama metodu ile verilerin ayrıştırılması **34**

Şekil 4.5 Çalışmada optimizasyonu yapılan hiper parametrelerin gösterimi..... **38**

Şekil 5.1 Batarya 18 gerçek kapasite değerleri ve tek kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği..... **42**

Şekil 5.2 Batarya 18 Gerçek kapasite değerleri ve çok kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği **42**

Şekil 5.3 Gerçek kapasite değerleri ve min-max normalizasyonu uygulanarak geliştirilen çok kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği..... **43**

Şekil 5.4 Batarya 18 gerçek kapasite değerleri ve min-max normalizasyonuna ek olarak kutu filtreleme uygulanarak geliştirilen çok kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği..... **44**

Şekil 5.5 Hiper parametre optimizasyonunun uygulanması ile tahmin edilen değerler ve gerçek değerler grafiği **45**

Şekil 5.6 Batarya 5 gerçek kapasite değerleri ve tek kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği..... **45**

Şekil 5.7 Batarya 5 gerçek kapasite değerleri ve çok kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği..... **46**

Şekil 5.8 Gerçek kapasite değerleri ve min-max normalizasyonu uygulanarak geliştirilen çok kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği..... **47**

Şekil 5.9 Batarya 5 gerçek kapasite değerleri ve min-max normalizasyonuna ek olarak kutu filtreleme uygulanarak geliştirilen çok kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği **47**

Şekil 5.10 Batarya 5 normalizasyon ve filtreleme uygulanan uzun kısa vadeli bellek modelinde hiper parametre optimizasyonunun çıktıları **48**

TABLO LİSTESİ

Tablo 4.1 Bataryaların şarj ve deşarj özellikleri **29**
Tablo 5.1 Batarya 18 için oluşturulan modeller ve özellikleri **41**
Tablo 5.2 Batarya 18 için oluşturulan modellerin RMSE ve MAE çıktıları **49**
Tablo 5.3 Batarya 5 için oluşturulan modellerin RMSE ve MAE çıktıları **50**

ÖZET

Hava Araçlarında Uzun Kısa Vadeli Bellek Yöntemiyle Kestirimci Bakım Analizi

Erhan GÜL

Aviyonik Mühendisliği Anabilim Dalı
Aviyonik Mühendisliği Programı
Yüksek Lisans Tezi

Danışman: Doç. Dr. Serkan KURT

Havacılık alanında bakım, hava araçlarının performansı, güvenilirliği ve sürdürülebilirliği açısından büyük önem taşımaktadır. Reaktif bakım anlayışı, arızalar ortaya çıktıktan sonra düzeltici müdahaleler yapılmasını sağlamaktadır ancak bu yaklaşım endüstrinin ihtiyaçlarını tam olarak karşılayamamaktadır. Bu nedenle, arızalar ortaya çıkmadan önce önlem almayı hedefleyen proaktif bakım stratejileri giderek daha fazla benimsenmektedir. Proaktif bakım stratejilerinden biri olan kestirimci bakım, bir hava aracının ya da alt bileşenlerinin arıza yapmadan önceki sağlık yönetimi kapsamındaki verilerini takip ederek, olası arızaların zamanını tahmin etme çalışmaları olarak değerlendirilmektedir. Kestirimci bakım yöntemi, gerçekleşmek üzere olan bir arızayı belirlemenin yanında ekipman veya alt sistemlerin kalan kullanılabilir ömrünün tahmin edilebilmesini de sağlamaktadır. Bu kazanımların sonucu olarak hava araçlarının bakım ve operasyon kabiliyetlerinin daha planlı, az maliyetli, daha çok güvenilir olabileceği altyapı sağlanmaktadır. Bu çalışmada, kestirimci bakımın havacılık uygulamalarına entegrasyonunun önemi ve gelişiminin yanında Uzun Kısa Vadeli Bellek (Long

Short Term Memory, LSTM) derin öğrenme yöntemi aracılığıyla gerçek değerlere yakınsayan Kalan Kullanılabilir Ömür (Remaining Useful Life, RUL) değerleri belirlenerek bakımda elde edilebilecek kazanımlar açıklanmaktadır. Uzun Kısa Vadeli Bellek modelleri arasında gerçek değerlere en çok yaklaşan tahmin modellerinin belirlenmesinde veri ön işleme tekniklerinin uygulanmasının önemi vurgulanmaktadır. Normalizasyon, filtreleme ve hiper parametre ayarları gibi farklı özelliklerin birlikte uygulandığı kombinasyon ile yapılan testlerin sonucunda elde edilen modelden daha yüksek doğruluk oranıyla tahminler elde edilebildiği gözlemlenmiştir. Bu model farklı bir veri seti üzerinde de aynı yöntemlerle geliştirilerek daha yüksek doğruluk oranına sahip farklı bir model daha elde edilmiştir. Gelecekteki araştırmalar için, farklı hava aracı sistemleri ve alt bileşenlerinin performansına odaklanarak, benzer veri üretim kapasitesine sahip sistemlerin belirlenmesi ve karşılaştırılması önerilmektedir. Ayrıca, geliştirilen modellerin RUL tahmini gibi uygulamalarla entegrasyonu ile, bakım süreçlerinin daha etkin yönetilmesine ve sistem arızalarının önceden tespit edilerek uçuş güvenliğinin ve operasyonel kullanılabilirliğin artırılmasına katkı sağlayabileceği vurgulanmaktadır.

Anahtar Kelimeler: Havacılık, kestirimci bakım, kalan kullanılabilir ömür, derin öğrenme, uzun kısa vadeli bellek.

ABSTRACT

Predictive Maintenance Analysis Using Long Short Term Memory Method in Air Vehicles

Erhan GÜL

Department of Avionics Engineering
Master of Science Thesis

Supervisor: Assoc. Prof. Dr. Serkan KURT

In the field of aviation, maintenance plays a crucial role in the performance, reliability, and sustainability of air vehicles. The reactive maintenance approach involves corrective interventions after failures occur; however, this approach does not fully meet the industry's needs. Therefore, proactive maintenance strategies, which aim to take preventive measures before failures arise, are increasingly being adopted. One of these proactive maintenance strategies, predictive maintenance, is regarded as the process of monitoring the data within the health management system of an aircraft or its components to predict the timing of potential failures. The predictive maintenance method not only helps identify imminent failures but also enables the prediction of the remaining useful life (RUL) of equipment or subsystems. As a result of these advantages, it provides a foundation for making aircraft maintenance and operational capabilities more planned, cost-effective, and reliable. This study draws attention to the importance and development of integrating predictive maintenance into aviation practices, along with determining

the RUL converging to real values through the Long Short-Term Memory (LSTM) deep learning method, thereby explaining the potential benefits in maintenance. The importance of applying data preprocessing techniques in determining the predictive models that most closely approach real values among LSTM models is emphasized. Tests conducted with combinations of different features, such as normalization, filtering, and hyperparameter tuning, showed that predictions with higher accuracy could be achieved from the model obtained. Additionally, a different model with higher accuracy was developed using the same methods on a different dataset. For future research, it is recommended to focus on the performance of different aircraft systems and subcomponents, identifying and comparing systems with similar data production capabilities. Furthermore, it is emphasized that integrating the developed models with applications such as RUL prediction can contribute to more efficient management of maintenance processes and the early detection of system failures, ultimately improving flight safety and operational availability.

Keywords: Aviation, predictive maintenance, remaining useful life, deep learning, long short term memory.

1
GİRİŞ

1.1 Literatür Özeti

Havacılıkta bakım, hava araçlarının ve diğer havacılık ekipmanlarının emniyetli, verimli ve idame ettirilebilir bir şekilde çalışmasını sağlamak için yapılan planlı veya plansız tüm teknik süreçleri ifade etmektedir. Bu süreçler, uçakların tasarım özelliklerine, üretici talimatlarına ve uluslararası havacılık standartlarına uygun şekilde gerçekleştirilmektedir. Havacılık bakımı, hava araçlarının ömrünü uzatmak, güvenilirliğini artırmak ve operasyonel verimliliği sağlamak amacıyla kritik bir rol oynamaktadır. Bu kritikliğinin yanı sıra bakımı yapılmış hava araçlarının daha verimli çalışabildiği ve operasyonel maliyetlerinin düştüğü gözlemlenmektedir. Ayrıca Federal Havacılık İdaresi (Federal Aviation Administration, FAA), Avrupa Birliği Havacılık Güvenliği Ajansı (European Union Aviation Safety Agency, EASA) ve Uluslararası Sivil Havacılık Örgütü (International Civil Aviation Organization, ICAO) gibi havacılık otoriteleri de hava araçlarının belirli periyotlarla bakımının yapılmasını zorunlu kılmaktadır. Bu düzenlemelere uyulmaması cezalara ve uçuş yasaklarına neden olabilmektedir (Turan ve Yüksel, 2022).

Havacılıkta bakım işlemleri, hava aracının türüne, kullanım amacına ve havacılık otoritelerinin belirlediği düzenlemelere göre değişiklik gösterebilmektedir. Reaktif Bakım ve Proaktif Bakım, bakım yönetimi stratejilerinin iki temel yaklaşımı olarak değerlendirilmektedir. Bu iki yöntem, ekipman veya sistemlerin bakımının nasıl ve ne zaman yapılacağına dair farklı yaklaşımları temsil etmektedir. Reaktif bakım, bir ekipman veya sistem arızalandıktan sonra yapılan bakım türü olarak ifade edilmektedir. Bu yaklaşımda, bakım işlemleri arıza meydana geldikten sonra gerçekleştirilmektedir. Proaktif Bakım ise, ekipman veya sistemlerde olası arızaları

önceden tespit ederek, sorunlar ortaya çıkmadan önce önlem almayı hedefleyen bir bakım stratejisi olarak değerlendirilmektedir. Bu yaklaşım, arızaların önlenmesi, ekipman ömrünün uzatılması ve operasyonel verimliliğin artırılması için kullanılmaktadır. Proaktif bakım, reaktif bakımın aksine genellikle daha planlı, sistematik ve veri odaklı bir süreci kapsamaktadır (Arıkan ve Yağlı, 2018; Özdemir Kanat, 2023).

Havacılığın ilk dönemlerinde bakım uygulamaları, daha çok reaktif stratejilerle, hava aracından gelen arızalardan sonra uygulanan düzeltici bakım (corrective maintenance) işlemleriyle sınırlı kalmaktaydı. Reaktif bakımın bir alt kümesi olarak değerlendirilen düzeltici bakım genellikle rutin operasyonlarda meydana gelen öngörülemeyen arızaları gidermek için uygulanan, ortaya çıkmış arızanın çıktığı yerin belirlenmesi, arızalı ekipmanların onarımı ya da yeni bir ürünle ikame edilmesi, bu çalışmaları takiben operasyonel veya fonksiyonel testlerin icra edilmesi, asıl arıza çıkış yerinin ve nedeninin belirlenmesi için inceleme yapılması ve teknik dokümantasyonunun revize edilmesi gibi faaliyetleri içermektedir. Özellikle acil durumlarda arıza hızlı bir şekilde giderilebildiği ve sistem yeniden çalışır hale getirildiği özellikleriyle avantajlı olarak değerlendirilmektedir. Ancak sürekli beklenmedik arızalar ve acil müdahaleler, ekipman ömrünü kısaltarak emniyeti doğrudan olumsuz etkileyebileceği gibi plansız bakımların artışı da operasyonel verimliliği düşürebilmektedir (U.S. Department of Defense, 2008).

Önleyici bakım (preventive maintenance) anlayışının ön plana çıkması, önemli bir dönüm noktası olarak değerlendirilmektedir. Önleyici bakım, belirli periyotlarla veya kullanım parametrelerine göre planlanmaktadır ve arızaların meydana gelmeden önce önlenmesini hedeflemektedir. Amaç, ekipmanın verimliliğini artırmak, arıza risklerini azaltmak ve olası maliyetli bakım işlemlerinin önüne geçmek olarak ifade edilmektedir (Özdemir Kanat, 2023). Önleyici bakım uygulamalarına örnek olarak periyodik kontroller ve testler, yağ değişimleri, filtrelerin temizlenmesi, parça değişimi veya onarımı, hava aracı veya makinelerin düzenli temizliği ve bakımı, performans izleme ve analizler verilebilmektedir.

Diğer proaktif yöntemlerinden biri olan kestirimci bakım (predictive maintenance), bir hava aracının ya da alt bileşenlerinin arıza yapmadan önceki sağlık verilerini takip ederek, olası arızaların zamanını tahmin etme çalışmaları olarak nitelendirilmektedir. Kestirimci bakım yöntemi, gerçekleşmek üzere olan bir

arızayı belirlemenin yanında ekipman veya alt sistemlerin kalan kullanılabilir ömrünün tahmin edilebilmesini de sağlamaktadır. Bu kazanımların sonucu olarak hava araçlarının bakım ve operasyon kabiliyetlerinin daha planlı, az maliyetli, daha çok güvenilir olabileceği altyapı sağlanmaktadır. Özellikle sensör teknolojileri ve veri analizi gibi alanlardaki gelişmeler, ekipmanların sağlık durumunu gerçek zamanlı olarak izlemeyi mümkün kılmaktadır. Bu teknolojilerin hava araçlarına entegrasyonu sayesinde, ekipmanların performansı ve olası arızalar önceden tahmin edilebilmektedir (Bell, 2008; Nunes, Santos ve Rocha, 2023).

Havacılıkta uygulanan kestirimci bakım yöntemleri fizik tabanlı, veri tabanlı ve hibrit tabanlı yaklaşımlar olmak üzere üç ana grupta incelenebilmektedir. Fizik tabanlı geliştirilen modellerde bozulma mekanizmaları genellikle bir sağlık endeksine göre haritalanmaktadır. Bu sağlık endeksi, belirli referans koşullarında değerlendirilen birden fazla sağlıkla ilgili eşik değere karşı normalize edilmiş bir marj olarak tanımlanabilmektedir. Geliştirilen fizik tabanlı model ya da simülasyon bu sağlık endekslerini belirlemeyi amaçlamaktadır. 2022 yılındaki bir çalışmada bileşenin sağlıkla ilgili model parametreleri, bir kalibrasyon problemi çözülerek çıkarılmıştır. Ardından, bu bilgiler sensör okumalarıyla birleştirilip güvenilir bir hibrit prognostik model geliştirmek için derin sinir ağına girdi olarak kullanılmaktadır. Fiziksel tabanlı modellerin prognostik alanındaki gelişimine rağmen fiziksel arıza süreçleri yalnızca kritik veya basit yapıdaki bileşenler için iyi bir şekilde anlaşılmaktadır. Bu nedenle, fiziksel tabanlı modellerin pratik uygulamalarda kullanımı sınırlı kalmaktadır (Arias Chao vd., 2022; Choi vd., 2019; Erdoğan ve Mercimek, 2023).

Bir sistemin ekipmanın sağlık durumunu ya da performansını tahmin etmek için sistemden toplanan verilerden elde edilen bilgilerin işlendiği yöntem veri tabanlı olarak yaklaşım ifade edilmektedir. Bu yaklaşım, fiziksel modelleme veya teorik hesaplamalar yerine, sistemin geçmişteki verilerini analiz ederek gelecekteki durumu, sağlığı tahmin edilmektedir (Erdoğan ve Mercimek, 2023). Veri tabanlı yaklaşımlar, büyük veri setlerini, sensörlerden alınan verileri ve sistemlerden toplanan operasyonel verileri kullanarak, genellikle makine öğrenimi, derin öğrenme algoritmaları gibi yöntemlerle analiz yapmaktadır. Sistemin arıza zamanı, performans düşüşü veya kalan kullanılabilir ömrü gibi tahminler bu yöntemlerle elde edilmektedir. 2024 yılında yapılan çalışmada, lityum iyon bataryalarda

kapasite yeniden kazanımının RUL tahmini üzerindeki önemli etkisi göz önünde bulundurularak, RUL tahmini doğruluğunu artırmaya yönelik yenilikçi bir yaklaşım sunulmaktadır (Bayrı ve Akkaya, 2024; Zhu, vd., 2019).

Veri tabanlı ve fizik tabanlı yaklaşımın avantajlarını birleştirerek daha güvenilir ve etkin bir prognostik yaklaşım sunan yöntem hibrit tabanlı olarak ifade edilmektedir. Fiziksel taban yöntemler, sistemlerin bozulma süreçlerini ve arızalarını anlamak için fiziksel modeller kullanırken, veri tabanlı yöntemler ise sensör verileri ve geçmiş arıza bilgileri gibi büyük veri setlerini analiz etmektedir (Akkad ve He, 2019). Hibrit yaklaşımda fiziksel modeller hava aracı sistemlerinin temel davranışlarını ve arıza mekanizmalarını simüle etmek için kullanılmaktadır ve bu modellerin sınırlamaları ve karmaşıklıkları göz önüne alınarak veriye dayalı analizlerle de desteklenmektedir. Veriler, genellikle sensörler aracılığıyla toplanıp bu verilerden elde edilen çıkarımlar sistemin gelecekteki davranışları hakkında tahminlerde bulunmak için işlenmektedir. Hava aracı için uçuş ya da görev kritik bileşenler için daha doğru sonuçlar alma amacıyla kullanılmakta olsa da fizik tabanlı yaklaşıma ek olarak veri tabanlı yaklaşımı da içerdiği için maliyeti artırabilmektedir (Yamaçlı, 2024).

1.2 Tezin Amacı

Bu çalışma, derin öğrenme tekniklerinden biri olan Uzun Kısa Vadeli Bellek'in hava aracı kestirimci bakım yöntemlerine entegre edilmesinin yanı sıra; bu yöntemlerin, arıza tahmini ve bakımla ilgili faaliyetlerin genel verimliliğini nasıl artırabileceğini incelemektedir. Bu amaçla farklı özellik kombinasyonlarına sahip modeller geliştirilmiş, test edilmiş ve doğruluk oranları iyileştirilmiştir. Çalışmanın özel hedefleri şunlardır:

- Havacılık endüstrisindeki sağlık yönetim/izleme sistemleri ile hava aracı bakım faaliyetlerinin ilişkisini ve bu çerçevedeki yaklaşımları sunmak,
- Geliştirilen tek kanallı ve çok kanallı Uzun Kısa Vadeli Bellek tekniklerinin; normalizasyon, filtreleme ve hiper parametre ayarı gibi farklı özelliklerin eklendiği ve test edildiği kombinasyonlarının model çıktılarını doğrudan etkilediğini vurgulamak,

- Uzun Kısa Vadeli Bellek tekniği ile geliştirilen kestirimci bakım modelinin, havacılık endüstrisinde operasyonel verimliliği artırma ve bakım maliyetlerini düşürme açısından muhtemel etkilerinin önemini geniş bir çerçevede tanıtmak.

1.3 Hipotez

Aşağıda belirtilen hipotezler, çalışmanın temel varsayımlarını açıklamakta olup, araştırma sürecinde incelenmiş ve çalışmanın sonuçlarına dayanarak çıkarımlar yapılmıştır:

- **Hipotez 1:** incelenen veri seti ile geliştirilen model farklı veri grupları ve farklı ekipmanlar için de benzer yaklaşımı destekleyecektir. Bu gruplandırma ile maliyet etkin kestirimci bakım yaklaşımlarının tüm hava aracı alt sistemlerinde uygulanabilirliğini desteklemesi yönünde bir adım niteliği taşıyacaktır.
- **Hipotez 2**: Uzun Kısa Vadeli Bellek modelleri arasında en iyi Ortalama Mutlak Hata (Mean Absolute Error, MAE) ve Kök Ortalama Kare Hata (Root Mean Squared Error, RMSE) değerlerine sahip modellerin belirlenmesinde normalizasyon, filtreleme ve hiper parametre ayarları gibi farklı özelliklerin uygulanma kombinasyonları ile yapılan testlerin kıyaslamaları sonucu seçilen modelden daha yüksek doğruluk oranıyla tahminler elde edilebilecektir.

2
KESTİRİMCİ BAKIMIN HAVA ARAÇLARIYLA ENTEGRASYONU

Proaktif bakım, reaktif bakımın her ihtiyacı karşılayamaması, teknolojik gelişmeler, daha yüksek verimlilik arayışları ve yeni endüstriyel felsefelerin birleşimiyle ortaya çıkmıştır. Bu yaklaşım, ekipmanların ömrünü uzatırken, bakım maliyetlerini düşürebilmekte ve operasyonel verimliliği artırabilmektedir. Günümüzde, özellikle teknolojinin gelişimi ve dijital dönüşümle birlikte proaktif bakım içerdiği önleyici ve kestirimci bakım yaklaşımlarıyla havacılık endüstrinin de vazgeçilmez bir parçası haline gelmiştir. Önleyici bakım, arızaları önlemeyi amaçlasa da bazı ekipmanlarda bakım zamanlaması genellikle arıza meydana gelmeden önce belirlenememektedir. Kestirimci bakım ile önleyici bakım birbirini tamamlayarak, bakım stratejilerinin etkinliğini artırabilmektedir (Erdoğan, 2024; Kwakye, Jennions ve Ezhilarasu, 2024).

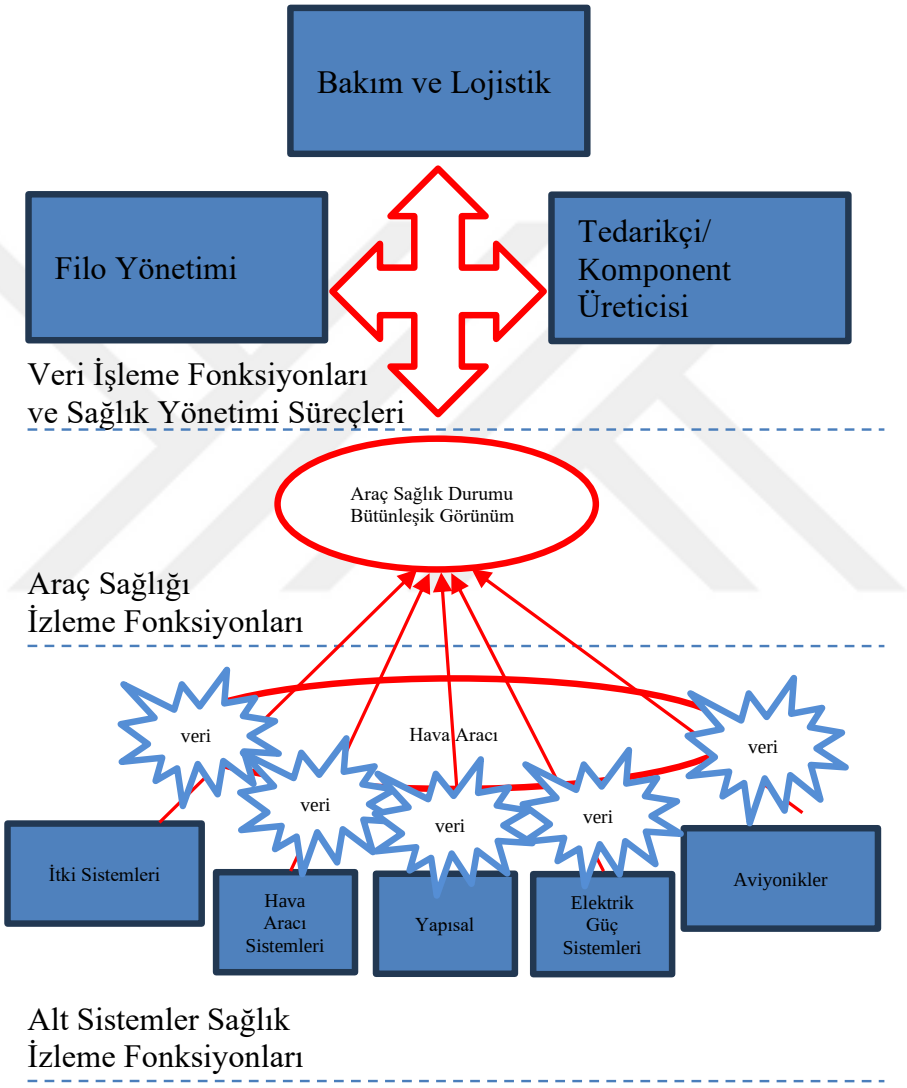
Kestirimci bakım, bir hava aracının ya da alt bileşenlerinin arıza yapmadan önceki sağlık yönetimi kapsamındaki verilerini sürekli takip ederek, olası arızaların zamanını tahmin etme çalışmaları olarak değerlendirilmektedir. Kestirimci bakım yöntemi, gerçekleşmek üzere olan bir arızayı belirlemenin yanında ekipman veya alt sistemlerin kalan kullanılabilir ömrünün tahmin edilebilmesini de sağlamaktadır. Bu kazanımların sonucu olarak hava araçlarının bakım ve operasyon kabiliyetlerinin daha planlı, az maliyetli, daha çok güvenilir olabileceği altyapı sağlanmaktadır (Dündar vd., 2021; Erdoğan ve Mercimek, 2023).

Kestirimci bakım uygulamaları için verilerin elde edilmesi ve yere aktarılması, modern hava araçlarının bakım süreçlerinin etkinliğini artıran önemli bir adım olarak değerlendirilmektedir. Bu süreç, hava araçlarının bakım ve uçuş sırasında topladığı verilerin sürekli izlenmesi ve analiz edilmesi ile gerçekleştirilmektedir. Hava araçlarında bulunan sensörler, motorlar, yakıt sistemleri, hidrolik sistemler,

batarya, elektriksel bileşenler ve diğer kritik alt bileşenlerin durumunu izlemektedir. Bu sensörler, sıcaklık, basınç, titreşim, hız, akım gibi bir dizi parametreyi ölçmektedir. Gelişmiş hava araçlarında bu verilerin kaydedilmesini sağlayan bütünleşik sağlık yönetim sistemleri ya da kayıt cihazları bulunan sistemler bulunmaktadır. Hava aracı yere indiğinde, toplanan veriler genellikle uçakla bağlantı kurulan bir bakım bilgisayarı veya veri terminali aracılığıyla indirilmektedir. Bu işlem, uçuş sonrası veri aktarmayı sağlamaktadır. Hava araçları genellikle, belirli bir uçuş sonunda bakım için gerekli verileri yer istasyonuna aktarmak amacıyla havayolu şirketinin yer ekipmanlarıyla bağlantıya geçmektedir. Yerde bulunan kestirimci bakım algoritmaları, bu verileri kullanarak uçak bileşenlerinin kullanım ömrünü ve olası arıza noktalarını tahmin etmektedir. Bu sayede, bakım öncesi önlemler alınabilmekte ve uçaklar arızalanmadan önce bakım yapılabilmektedir. Ayrıca indirilen bu veriler ekipman sağlayıcıları, kaynak yönetimi ve lojistik birimler, filolardaki ilgili birimlerle de paylaşılmaktadır (Kwakye, Jennions ve Ezhilarasu, 2024; Scott vd., 2022; Stanton vd., 2023). Şekil 2.1 de gelişmiş hava araçlarına ait hava aracı ve alt sistemlerinin bütünleşik sağlık yönetimine ait fonksiyonlarını içeren şema gösterilmektedir. Hava aracı ve alt sistemlerin yanı sıra filo yönetimi, bakım ve lojistik, tedarikçi ve komponent üreticileri de bu sistemin çıktılarını kullanabilmekte ve elde edilen verilerden tasarım geri besleme kazanımları elde edebilmektedir.

Hava araçlarının özellikle aviyonik sistemleri, tüm uçuş parametrelerini ve sistem durumlarını izlemektedir. Her bir bileşen, performansını izlemek için kendi kontrol birimlerine sahiptir. Hava aracı sistemlerinin çalışma verimliliği, uçuş kontrol sistemlerinin durumu, sistemdeki potansiyel arızalar ve daha fazlasını sürekli olarak takip edilmekte ve bu veriler kaydedilmektedir (Hunt ve Hebden, 1998; Tunç ve Erdem, 2024). Bunun örneklerini özellikle Lockheed Martin tarafından üretilen beşinci nesil bir savaş uçağı olan F-35'te Prognostik Sağlık Yönetim Sistemi (Prognostics Health Management System), helikopterlerde Sağlık ve Kullanım İzleme Sistemi (Health and Usage Monitoring System, HUMS), Eurofighter Typhoon savaş uçağı için Bütünleşik İzleme, Test ve Kayıt Alt Sistemi (Integrated Monitoring, Test and Recording Sub-system, IMRS), Airbus şirketinin ticari uçaklarında ve birçok ülkenin insansız hava araçlarında Bütünleşik Sağlık Yönetim Sistemi (Integrated Vehicle Health Management, IVHM) gibi farklı kavramlarla

ortaya konulmaktadır. Bu yönüyle kestirimci bakım, filo yönetimi ve kaynak yönetimi gibi birçok bağlı birime etkisiyle de bakım maliyetlerini azaltırken hava aracının operasyona hazırlık oranını iyileştirmektedir. Kestirimci bakımın havacılık uygulamalarına entegrasyonunun bu sebeplerle gelişeceği ve daha birçok hava aracına entegre edileceği değerlendirilmektedir (Erdoğan, 2024; McCollom ve Brown, 2011; Zaman ve Bayoumi, 2016).



Şekil 2.1 Bütünleşik hava aracı sağlık yönetimi (Jennions, 2014)

Prognostik yaklaşım ve kestirimci bakımın bir gereği olarak sağlık yönetim ve sağlık takip sistemleri, hava aracı üzerindeki sistemler için bakım ile ilgili gereksinimlerini belirleyerek, uçaklardaki verilerin daha verimli şekilde kullanılmasını sağlamaktadır. Bu sistemler ayrıca uçuş sonrasında herhangi bir aksaklık yaşanması durumunda, yer ekiplerine hızlı bir şekilde bilgi verilmesini

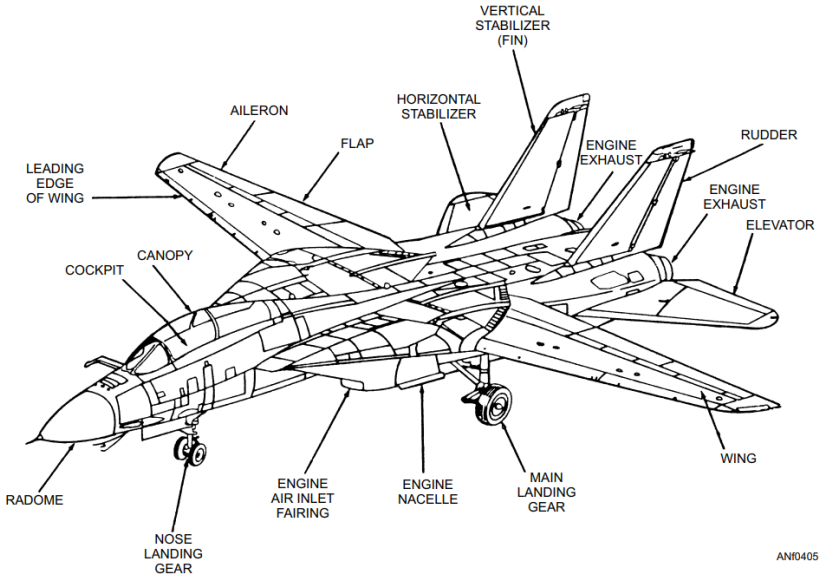
sağlamaktadır. Bu sistemlerden gelen veriler yer bakım yönetim merkezlerine gönderilmektedir. Veriler, uçak filosu için merkezi bir bakım stratejisi oluşturulmasına yardımcı olarak genel uçuş verimliliği ile bakım süreçleri hakkında kararlar alınmasına olanak tanımaktadır. Bu yönüyle bakım faaliyetlerini hızlandırıcı ve maliyetleri azaltıcı yönde katkılar sağlamaktadır (Erdoğan, 2024; Koschlik vd., 2023; McCollom ve Brown, 2011).

2.1 Hava Aracı Yapısal Bütünlüğü

Bir hava aracının iskeleti ve yapısal parçaları, uçuş güvenliği, aerodinamik verimlilik ve dayanıklılık, kullanım ömrü gibi çok çeşitli faktörler göz önünde bulundurularak inşa edilmektedir. Belirlenen bu faktörler hesaba katılarak tasarlanan hava aracı, testlerini başarıyla tamamladıktan sonra kullanıcıya hizmete verilmekte ve yeni filolarında uçmaya başlamaktadırlar. Hava aracı, imalatçı firma tarafından kullanıcıya teslim edilmeden önce yapısal bütünlüğünü kanıtlamak için tasarım kriterlerine göre hasar tolerans ve tam ölçekli dayanıklılık gibi testleri yapılmaktadır. Bu testlerle hava aracı yapısal parçalarının, gereksinimlerine uygun güvenilirlik değerlerini koruyacağı ispatlanmaktadır. Bu noktada, özellikle askeri hava araçları söz konusu olduğunda belirgin bir sorun yaşanmaktadır. Bu sorun hava aracının tasarım kriterlerinden farklı profillerdeki özelliklerde kullanılması olarak ortaya çıkmaktadır. Bu nedenle, hava aracının kullanımının verilerle izlenmesi ve maruz kaldığı değişikliklere göre gerekli bakım, onarım planlamalarının yapılmasını sağlayacak bir program olan Uçak Yapısal Bütünlük Programı (Aircraft Structural Integrity Program, ASIP) uygulanmaya başlanmıştır ASIP, bir hava aracının tasarımının başladığı ilk gününden itibaren planlanan ve servis dışı kalana kadar süren aktivitelerin tamamını ifade etmektedir. Bu kapsamda,

- Uçak yapısının bütünlüğünün kurulması, kullanım bilgilerinin toplanması,
- Uçakların kullanım özelliklerine, göre hasar meydana gelmeden önce tespit edilmesi için bakım planlamaları, kontroller, tadilat öncelikleri ve buna bağlı olarak ömür tayini ile kullanımlarına yönelik kararlara destek sağlayacak sayısal verilerin elde edilmesi ve bakım maliyetlerinin azaltılması,

- Lojistik planlama gibi gereksinimler için (bakım, yedek parça temini, hizmet dışı bırakma programları vb.) bir veri tabanı geliştirilmesi,
- Hava aracının verilerinin her operasyonu için izlenmesiyle, uçakların yorulma kaynaklı kritik noktalarda oluşabilecek çatlaklar nedeniyle beklenmedik şekilde hizmet dışı kalmasının önüne geçilmesi,
- Her bir hava aracı için en verimli ve en ekonomik şekilde uçuş güvenliğinin sağlanması gibi ana amaçlara hizmet etmesi hedeflenmektedir (Candan, 1997).



Şekil 2.2 F-14 uçağındaki birincil yapısal parçalar (Galstyan ve Zhuravlova, 2011)

Şekil 2.2'de F-14 savaş uçağına ait yapısal parçaların bir kısmı gösterilmektedir. Yapısal sağlık izleme kapsamında kritikliği belirlenen bu yapısal parçalar ve diğerleri ile ilgili veriler yukarıdaki hedefler doğrultusunda sürekli olarak izlenmektedir.

Bu hedefleri sağlamak amacıyla hava aracının ilgili verilerinin sürekli olarak izlenmesi ve bu verilerin analizi kapsamında kestirimci bakım faaliyetlerinin sürdürülmesi büyük önem arz etmektedir. Derin Öğrenme teknikleri gibi birçok yapay zekâ tekniği ile uçakların geçmiş performans verilerini analiz ederek yapısal arıza olasılıklarını tahmin etmek ve gelecekteki arızaları öngörmek mümkün olabilmektedir. Bu kapsamda,

- Uçak yapısındaki titreşimlerin titreşim ya da ivmeölçer sensörler ile izlenmesi ve yapısal bozulmaların veya aşınmaların erken tespiti için kullanılması,
- Gerinim ölçer (Strain gauge) sensörler kullanarak, uçak yapısındaki stres, gerilmelerin izlenmesi ve uçak bileşenlerinin ne kadar gerildiğini ve hangi bölümlerin daha fazla stres altında olduğunun belirlenmesi gibi amaçlarla Yapısal Sağlık İzleme (Structural Health Monitoring, SHM) Sistemleri, kestirimci bakım ile entegre edilerek hava araçlarına uygulanmaktadır (SAE, 2013).

Aynı zamanda uçak yapısının dinamik davranışını modelleyerek, stres altındaki bileşenlerin nasıl tepki vereceğini ve potansiyel arıza noktalarını önceden belirlemek için yapısal bütünlük simülasyonları gibi fizik tabanlı yaklaşımlar da kestirimci bakım için kullanılmaktadır (SAE International, 2019).

2.2 Motor Sistemleri

Hava aracı motor sistemleri, bir uçağın hareket etmesini, diğer sistemleri için gerekli enerjinin üretilmesini sağlayan en önemli unsurlardan biri olarak ifade edilmektedir. Hava aracının uçuş performansını belirlerken aynı zamanda güvenli, verimli ve kontrollü bir şekilde çalışmasını sağlamaktadır. Hava aracı motor sistemlerinin temel amacı, uçağa gerekli itkiyi sağlayarak hava aracının havada kalmasını sağlamak ve çeşitli uçuş koşullarında yüksek performans sunmak olarak değerlendirilmektedir (Kumar, Shankar ve Thakur, 2018).

Şekil 2.3'teki General Electric (GE) Aviation tarafından üretilen F110 jet motorunun görseli paylaşılmaktadır. Hava aracı motorunun tasarımı da bakımı gibi karmaşık, daha çok zaman ve kaynak gerektiren işlemler bütünü olarak değerlendirilmektedir. Motor bakımı maliyetleri toplam uçak bakımının maliyetinin yaklaşık %30'unu oluşturabilmektedir. Geçişte hava aracı motoru bakımı, sabit periyotlarla planlanarak uygulanmıştır ancak havacılık sektöründeki gelişmelerle birlikte bu yaklaşımın ihtiyaçları tamamen karşılamadığı fark edilmiştir. Günümüzde motor bakım planlamaları için Durum Bazlı İzleme (Condition Based Monitoring, CBM) geliştirilmekte ve sabit zamanlı bakımların yerini günden güne almaktadır. Modern hava aracı motor sistemlerinde motorun durumunu izlemek ve kaydedebilmek için motor kontrolcü birimleri de dahil çok

fazla ekipman ve sensör yer almaktadır. Bu ekipmanlardan ve sensörlerden elde edilen veri setleri işlenerek RUL tahmini yapılmaya çalışılmaktadır. Bu çalışmalarda yapılan RUL tahminindeki amaç, motorda meydana gelebilecek hasar ve arızaların henüz arıza ya da hasar gerçekleşmeden önce belirlenebilmesi ve bakım faaliyetlerinin uygulanabilmesi olarak değerlendirilmektedir (Erdoğan, 2024; Fornlöf, 2016).



Şekil 2.3 General Electric (GE) Aviation tarafından üretilen F110 jet motoru (General Electric Aerospace, 2023)

Literatürdeki çalışmalar analiz edildiğinde birçok farklı yöntemin denenerek kestirimci bakım çalışmaları yürütüldüğü gözlemlenmektedir. 2014 yılında yapılan bir çalışmada 100 farklı motordan 21 adet sensör aracılığıyla toplanan veriler ile motorun sağlığını izlemeye ve analiz etmeye çalışmışlardır. Toplanan verilerin analizleri sonucunda 7 sensörün motorun sağlık durumuyla ilgili bilgi verdiği gözlemlenmiştir. Kalan veriler Dempster-Shafer Regresyonu (DSR), Destek Vektör Makinesi (Support Vector Machines, SVM) ve Tekrarlı Sinir Ağından (Recurrent Neural Network, RNN) oluşan bir model ile analiz edilerek kestirimci bakım uygulanmaya çalışılmıştır. Modelin ortalama karesel hatası (Mean Square Error, MSE) 3,49 olarak elde edilmiştir (Xu, Wang ve Xu, 2014).

2014 yılında yapılan bir araştırmada Ticari Modüler Hava-Tahrik Sistemi Simülasyonu (Commercial Modular Aero-Propulsion System Simulation, C-MAPSS) veri setinden seçtikleri bir alt kümenin üzerinde Doğrusal Olmayan Uyarlanabilir Kestiriciler (Nonlinear Adaptive Estimators, NAE) tekniği ile motorun sağlık durumunu kullanılan verilerle analiz etmişlerdir (Zhang vd., 2013). 2016 yılında yapılan bir çalışmada araştırmacılar NASA C-MAPSS veri setinden rastgele olarak seçtikleri 80 farklı motorun verilerini Uzun-Kısa Süreli Bellek Kodlayıcı/Kod Çözücü (LSTM-Encoder Decoder, LSTM ED) tekniği ile analiz etmişlerdir (Malhotra, 2016).

2014 yılında yapılan araştırmada PHM (Prognostic Health Management, Öngörücü Sağlık Yönetimi) konferansı kapsamında yapılan tahmin algoritmaları çalışmaları arasında en iyi performansı sergileyen çalışmalar, Benzerlik Temelli Yaklaşım (Similarity-Based Approach, SBA), RNN, Kalman Filtresi ve Çok Katmanlı Almaca Dayalı Bileşik Metot çalışmaları olarak belirtilmiştir (Ramasso ve Saxena, 2014).

2.3 Aviyonik Sistemler

"Aviyonik" terimi, "aviation" (havacılık) ve "electronics" (elektronik) kelimelerinin birleşiminden türetilmiştir. Aviyonik sistemler; insan-bilgisayar etkileşimi sistemi, radar sistemleri, seyrüsefer sistemi, haberleşme sistemleri, gibi entegre elektronik sistemleri içeren hava araçlarındaki elektronik ekipmanların genel adı olarak ifade edilmektedir. Ayrıca, alt sistemler arasında bilgi alışverişini sağlayan hava aracı yönetim sistemlerini ve görev yönetim sistemlerini de kapsamaktadır. Aviyonik sistemlerin ortaya çıkışı ile birlikte, uçakların performansı büyük ölçüde iyileştirilmiş, pilotların iş yükü azaltılmış ve pilotlara bilgi ve karar desteği sağlanmıştır (Karaman, 2004).

Aviyonik sistemlerin bileşenlerinde birçok analog devre ve birçok analog sinyal bulunmaktadır. Küresel Konumlama Sistemi (Global Positioning System, GPS) çıkışının konum sinyalleri, barometre yüksekliği sinyalleri, radar tarama sinyalleri vb. sinyaller bunlara örnek olarak gösterilebilmektedir. Analog sinyallere dayalı yerleşik testler (Built-in test, BIT) bu sinyalleri işlemek için kapsamlı bir yaklaşım benimsemektedir. Sistem durum verilerini tam olarak elde etmek, BIT'in kapsamını ve güvenilirliğini sağlamak ve bir sonraki katman için yeterli girdi sağlamak

amacıyla, analog sinyale dayalı BIT tasarımı devre çıkış değeri, güç durumu, pin bağlantı durumu (açık devre, kısa devre vb.) gibi unsurları içermektedir. Aviyonik sistemler ayrıca kontrol ve işleme devrelerinde, birçok büyük ölçekli entegre devreler bulundurmaktadır. Devre içindeki ve devreler arasındaki veri değişimi dijital sinyaller kullanılarak gerçekleştirilmektedir. Bu dijital sinyaller olmadan aviyonik sistemlerin bileşenlerinin durum bilgisi sağlanamamakta, bu nedenle dijital sinyale dayalı BIT, devre veri akışını izlemek için kullanılmaktadır. Dijital sinyale dayalı BIT, iki yönteme ayrılabilmektedir. Birincisi, dijital devrede bağımsız tespit tasarımıdır. Günümüzde birçok çip, kendi kendini tespit etme işlevine sahiptir ve aktif test yazılımı çipe gömülerek çipin kendisini test etmesine olanak tanımaktadır. İkincisi ise, tüm ekipman seviyesinde BIT tasarımıdır. Genel çiplerin otonom tespit yeteneği sınırlıdır ve tüm fonksiyonel testleri tamamlamamaktadır. Haberleşme durumunun sürekli tespiti bu duruma örnek olarak verilebilmektedir. Bu, birden fazla devrenin birlikte tespit yapmasını, tespit doğruluğunu artırmasını, yanlış alarm oranının azaltmasını ve nihayetinde devrenin normal olup olmadığının belirlenmesini gerektirmektedir (Jiang, Zhang, Cao, ve Zhan, 2022).

Hava araçlarındaki diğer tüm sistemlerde olduğu gibi sağlık yönetimi ve kestirimci bakım gereksinimleri gereği aviyonik sistemlerin de uçuş sırasındaki sağlık verileri kaydedilir. Uçuş sonrası ya da belirlenen periyotlarla indirilen bu veriler ilgili hava aracı için oluşturulan veri tabanına aktarılmaktadır. Veri tabanlı kestirimci bakım yaklaşımının bir ürünü olarak daha önceden oluşturulan yapay zekâ ya da büyük veri analizi algoritmaları ile verilerek işlenerek RUL tahmini ya da olası arızaların tespiti için kullanılabilmektedir. Fizik tabanlı kestirimci bakım yaklaşımı kapsamında da sistem simülasyonları ve istatiksel modelleme gibi yöntemler bu amaçlarla kullanılmaktadır (Jiang, Zhang, Cao, ve Zhan, 2022).

2020 yılında yapılan bir araştırmada aviyonik sistemlerin bakım, onarım ve revizyon süreçlerinde yapay sinir ağlarının matematiksel yöntemleri incelenmiştir. Bu çalışma, aviyonik sistemlerin bakım süreçlerinin etkinliğini artırmak için yapay zekâ tekniklerinin kullanılabileceğini göstermektedir. Arıza tahmininin geleneksel yöntemlerinin, karmaşık sistemlerde uygulanması zor olduğundan, Bakım, Onarım ve Revizyon (Maintenance, Repair, Overhaul, MRO) aralıklarının kısaltılması gerekliliği doğmaktadır. Bu araştırma, bu soruna olası bir çözüm olarak Yapay Sinir

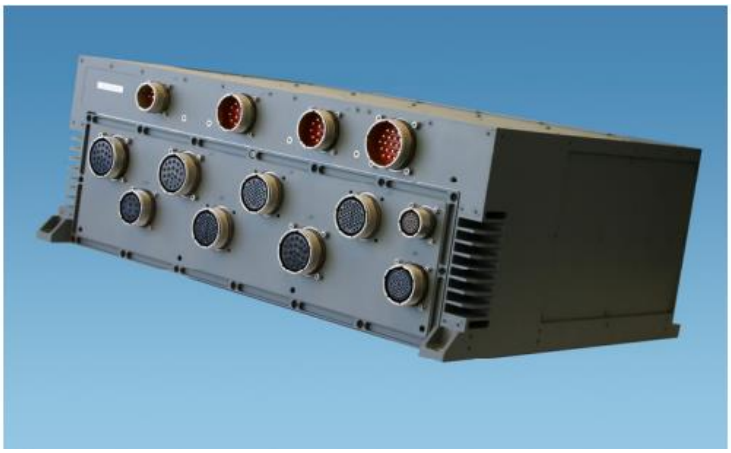
Ağları (YSA) ile matematiksel yöntemini önermektedir. Araştırma nesnesi olarak İnsansız Hava Aracı (İHA) aviyoniklerinden biri olan haberleşme ünitesi ele alınmıştır. Geleneksel ve YSA yöntemleriyle tahmin edilen arıza güvenilirliği değerleri analiz edilmeye çalışılmış ve bu iki yöntemin sonuç karşılaştırmaları elde edilmiştir. Çalışma, kullanılan YSA yönteminin bu problemi çözmek için uygun olduğunu önermektedir. Elde edilen sonuçlar yüksek bir güvenilirlik derecesi göstermektedir. İleri araştırmalar, daha karmaşık aviyonik sistemlerine ölçeklendirilmesi gerektiğini önermektedir. YSA'nın MRO sistemine entegrasyonu, dış operasyon faktörlerini dikkate alarak, aviyonik ekipmanların bakım aralıklarını artırma ve arıza tahmini yapma olanağı da dahil olmak üzere birçok avantaj sunmaktadır. Bu, kaçınılmaz olarak yaşam döngüsü maliyetlerinin azalmasına ve güvenilirliğin artmasına imkân sunmaktadır. Yapay sinir ağları, bakım süreçlerini optimize ederek, arızaların önceden tahmin edilmesine yardımcı olmaktadır. Bu tür yöntemler, aviyonik sistemlerin güvenilirliğini artırmakta ve bakım maliyetlerini azaltmaktadır. Aviyonik sistemlerde kestirimci bakım, sistemlerin güvenilirliğini artırmak ve bakım maliyetlerini azaltmak için kritik bir strateji olarak ön plana çıkmaktadır. Durum bazlı bakım, prognostik ve sağlık yönetimi uygulamaları, yapay zekâ teknikleri ve dijital eğitim yöntemleri gibi çeşitli yaklaşımlar, bu süreçlerin etkinliğini artırmaktadır. Aviyonik sistemlerin sürdürülebilirliği ve güvenliği açısından, kestirimci bakım uygulamalarının entegrasyonu büyük bir önem taşımaktadır (Gyazova ve Vlaznev 2020).

2.4 Hava Aracı Sistemleri

Hava aracı sistemlerinde kestirimci bakım entegrasyonu, uçakların güvenliğini, verimliliğini ve bakım maliyetlerini optimize etmek açısından kritik bir öneme sahiptir. Kestirimci bakım, sistemlerin durumunu sürekli izleyerek, arızaların önceden tahmin edilmesine olanak tanımaktadır. Bu bağlamda, hava aracı sistemlerinde kestirimci bakımın entegrasyonu hem operasyonel hem de mali açıdan önemli faydalar sağlamaktadır. Hidrolik sistem, Pnömatik sistem, yakıt sistemleri elektrik güç sistemleri gibi hava aracı sistemlerinin karmaşık yapısı ve yüksek güvenlik standartları, kestirimci bakım uygulamalarının gerekliliğini artırmaktadır. Askeri ve ticari uçaklar, uzay araçları ve kara araçları giderek daha

fazla elektrik enerjisine bağımlı hale gelmektedir. Araçların tüm sistemleri, özellikle uçuş kontrolü ve yakıt dağıtımı gibi kritik sistemler için elektrik enerjisine, kısmen ya da tamamen, ihtiyaç duyan sistemler haline gelmektedir. Bu sebeple elektrik güç sistemleri, bir hava aracının çeşitli elektrikli bileşenlerine güç sağlamak için tasarlanmış karmaşık sistemler olarak ifade edilmektedir. Elektrik güç sistemleri, aviyonik sistemler, uçuş kontrol sistemleri, uçuş kontrol bilgisayarları, pilot destek sistemleri de dahil birçok sistemin çalışmasını doğrudan desteklediği için hava aracının güvenli ve verimli bir şekilde çalışabilmesi için uçuş ve görev kritik olarak değerlendirilmektedir (Keller vd., 2006).

Elektrik güç sistemlerinin dijital kontrollü güç dağıtımındaki ve bu sistemlerdeki dijital denetleyicilerde yer alan mikroişlemciler, elektrikle çalışan bir aracın sistem sağlığını izlemek için uygun maliyetli bir fırsat sunmaktadır. Bu denetleyicilerden gelen ve giden veriler, sistemin ve bileşenlerin çalışma durumlarını karakterize etmek için kullanılabilmektedir. Böylece teşhis (Diagnostic) ve Prognostik (Prognostic) yeteneklerinin gelişmesine destek olmaktadır. Bu yetenekler, yüksek görev güvenilirliği oranını sağlamanın yanı sıra yaşam döngüsü maliyetlerini de azaltabilmektedir. Bu amaçla elektrik güç sistemleri üzerinde kestirimci bakım amaçlı çalışmalar yürütülmektedir:

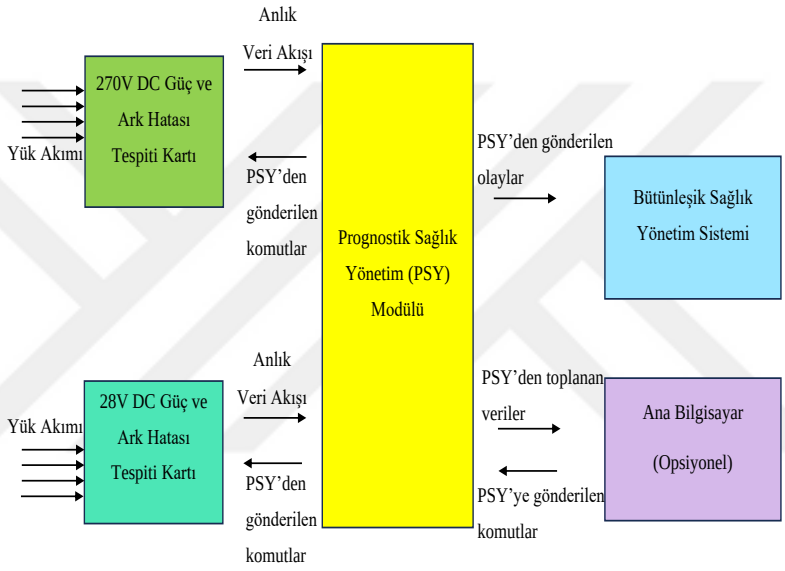


Şekil 2.4 Smiths-Aerospace güç dağım ünitesi (Power distribution unit, PDU) (Keller vd., 2006)

Uçak Elektrik Gücü Sistemleri Prognostiği ve Sağlık Yönetimi (Aircraft Electrical Power Systems Prognostics and Health Management, AEPHM) programı, Şekil 2.4’ te gösterilen PDU'nun rolünü, bir PHM veri toplama ve işleme yeteneğini

içerecek şekilde genişletmiştir. Bu, mevcut bir Smiths Aerospace PDU'yu ark hatası tespiti, gelişmiş teşhis ve prognostik fonksiyonlarını desteklemek için yüksek hızlı veri toplama ve işleme yeteneğiyle güçlendirerek başarılmıştır. Bu değişiklikler,

- Esnek yüksek hızda akım verisi toplama,
- Ark hata prognostiği için ek yerel işleme, düşük maliyetli bir programlanabilir entegre devre işlemci şeklinde
- Hızlı prototip geliştirme için hızlı yeniden programlanabilirlik,
- Yerel Prognostik verisi işleme için ayrı yüksek performanslı işlemci,
- IVHM bilgisayarına dışa veri iletimi için veri yolu alıcıları/verici ve yönlendiriciyi içermektedir.



Şekil 2.5 Modifiye güç dağıtım birimi (Keller vd., 2006)

Uçak Elektrik Gücü Sistemleri Prognostiği ve Sağlık Yönetimi (AEPHM) programı, Amerika Birleşik Devletleri Hava Kuvvetleri Araştırma Laboratuvarı (Air Force Research Laboratory, AFRL), Boeing ve Smiths Aerospace tarafından yürütülmektedir ve sağlık yönetimi (teşhis, prognostik ve karar destek araçları) algoritmalarını geliştirmiştir. Programın ilk aşaması, Temmuz 2005'te sona ermiş olup, elektrikli aktüatörler, yakıt pompaları/vanaları ve ark hatası korumasını ele almaktadır. İkinci aşama ise güç üretimi konusuna odaklanmaktadır. Algoritma geliştirme arızaya kadar testlerden elde edilen verilerle yapılmaktadır. AEPHM mimarisi, bozulma tahminlerini geliştirmek için birden fazla kaynaktan gelen kanıt ve durum bilgilerini sistem düzeyinde birleştirmeyi desteklemektedir. Sağlık yönetiminin olası veri kaynakları ve veri hızlarına bağlı olarak doğruluğu belirlenmektedir. Şekil 2.5'te yürütülen çalışmanın şematiği gösterilmektedir.

Araştırmanın ürünü, askeri, uzay ve ticari araçlar dahil olmak üzere bir dizi platforma uyarlanabilirliği olarak değerlendirilmektedir. Programın birinci aşaması, çevrim içi veri üretimiyle birlikte, donanım içinde uçtan uca (elektrik eyleyicisi, yakıt pompası, yakıt vanası, ark hatası ve güç dağıtım birimi) gösterimiyle tamamlanmış ve teknolojinin gerçekçi bir ortamda entegrasyonunu göstermiştir. Programın amacı, sağlık yönetimi teknolojilerini göstermek ve böylece askeri uçakların görev hazırlığını iyileştirmek, benzer şekilde ticari uçakların da harekât güvenilirliğini artırmaktır (Keller vd., 2006).

3
DERİN ÖĞRENME TEKNİKLERİ

Yapay zekâ, insan zihnini örnek alarak geliştirilen makinelerin eğitilme, öğrenme ve karar alarak uygulayabilme gibi karmaşık işlemleri gerçekleştirmesini sağlayan, farklı bilim dallarını bir araya getiren bir alan olarak ifade edilmektedir (Chakir vd., 2024; İşcan ve Kaygısız, 2024).

Günümüzde teknolojik gelişmelerin en önemli alanlarından biri haline gelmiş olan bu alan, geniş kapsamıyla pek çok endüstride büyük değişimlerin başlangıcını oluşturmaktadır. Yapay zekâ, teorik temelleri doğrultusunda makine öğrenimi algoritmaları, yapay sinir ağları ve derin öğrenme gibi alt alanlara ayrılmakta ve hem klasik hem de modern yöntemleri bir arada sunmaktadır. Makine öğrenimi, veri tabanlı tahmin ve modelleme süreçlerine dayanan bir yöntemken, yapay sinir ağlarıyla daha ileri düzeydeki bir anlayışa ulaşmış ve insan beynindeki nöron işleyişini taklit eden bir yapı geliştirilmiştir. Bu teknolojik gelişmelerin ardından derin öğrenme algoritmaları, çok katmanlı sinir ağları kullanılarak görüntü işleme, doğal dil işleme ve otonom sistemler gibi alanlarda devrim niteliğinde yeniliklerin önünü açmaktadır. Bu katmanlı yapı, yapay zekânın temellerini oluştururken, aynı zamanda uygulama alanındaki güncelleme ve değişimlerin potansiyelini de gözler önüne sermektedir (Goodfellow vd., 2016; İşcan ve Kaygısız, 2024; Nilsson, 2010; Russell ve Norvig, 2020).

Yapay zekâ ile makine öğrenimi ve alt alanları arasındaki hiyerarşik yapı, Şekil 3.1'de görsel olarak sunulmaktadır. Bu şema, yapay zekânın genel yapısını ve içindeki alt disiplinlerin birbirleriyle nasıl ilişkili olduğunu görsel bir şekilde temsil etmektedir. Şekilde, yapay zekâ en üst seviyede yer alırken, altında makine öğrenimi algoritmaları ve yapay sinir ağları konumlandırılmıştır. Derin sinir ağları ise, yapay sinir ağlarının bir alt dalı olarak gösterilmektedir.



Şekil 3.1 Yapay zekâ ve alt dallarının hiyerarşik yapısı (İşcan ve Kaygısız, 2024)

3.1 Makine Öğrenimi

Makine öğrenimi (Machine Learning, ML), bir bilgisayarın, deneyim ve veriler yoluyla herhangi bir açık programlamaya gerek kalmadan öğrenmesini sağlayan bir yapay zekâ alt alanı olarak ifade edilmektedir. Makine öğrenimi, algoritmalar ve istatistiksel yöntemler kullanarak, veri setlerinden örüntüler ve ilişkiler keşfeder ve bu keşifleri kullanarak gelecekteki durumu içeren tahminler yapmayı veya kararlar almayı sağlamaktadır. Makine öğrenimi veri seti oluşturabilmek için sırasıyla veri toplama, hatalı ve gürültülü verileri temizlemek için veri ön işleme, veriye bağlı olarak çıkarımlar yapacak algoritmaları içeren modeller oluşturma, seçilen modeli veri setindeki örüntülerle eğitme, model performansını, hata oranları değerlendirme ve iyileştirme ve eğitim tamamen tamamlandıktan sonra geliştirilen bu modelle tahminlerde bulunma veya karar alma işlemlerini içermektedir. İncelenen problem ve analiz edilen verilere bağlı olarak, makine öğrenimi üç temel alt sınıfa ayrılmaktadır: denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning) ve pekiştirmeli öğrenme (reinforcement learning) (İşcan ve Kaygısız, 2024).

Denetimli Öğrenmede veriler, hem girdi (özellikler) hem de doğru çıktı (etiket) ile birlikte sunulmakta ve değerlendirilmektedir. Bu modellere giriş verilerinden çıkışa ilişkin bir model oluşturmak ve bu modelin doğru tahminler yapmasını sağlamak hedeflenmektedir. Literatürde denetimli öğrenmede sıklıkla regresyon ve

sınıflandırma yöntemleri tercih edilmektedir. Bu yöntemler, genellikle veri tipine, problemin yapısına ve çözülmek istenen soruna göre tercih edilmektedir. En yaygın kullanılan yöntemlerden birkaç tanesi şöyle özetlenebilir: Lineer Regresyon ve Ridge Regresyon, Destek Vektör Makineleri, Karar Ağaçları, Rastgele Orman Yaklaşımı Random Forest, RF), Naive Bayes, K-En Yakın Komşu (K-Nearest Neighbors, KNN) (İşcan ve Kaygısız, 2020).

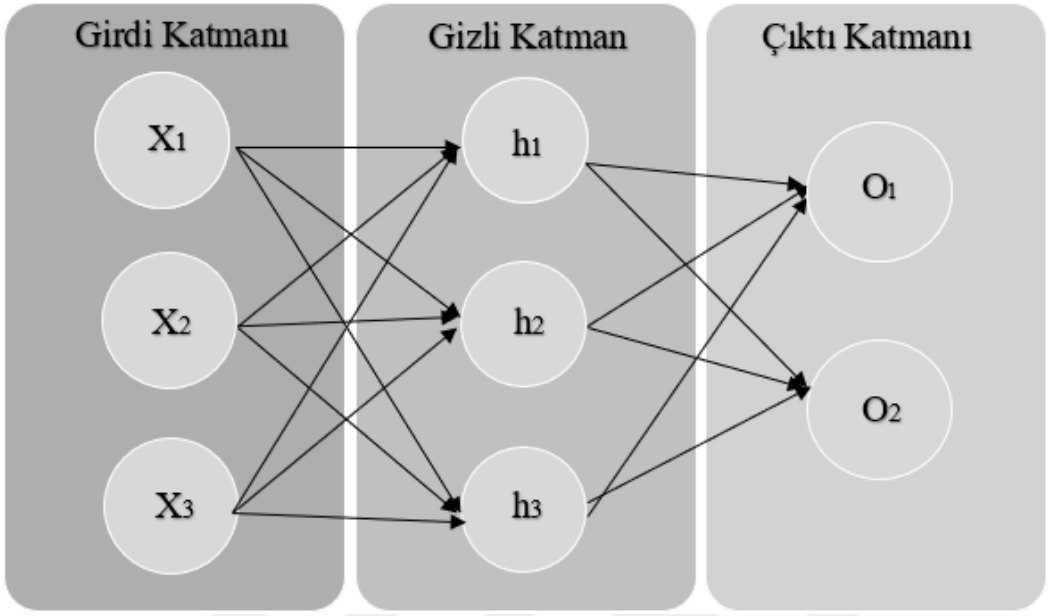
Denetimsiz Öğrenmede modelde işlenen veriler yalnızca girişlerden oluşmaktadır. Çıkış etiketleri geliştirilen modelde mevcut değildir. Verilerdeki örüntüleri veya yapıları keşfederek çıktıları tahmin etmek ve kararlar almayı amaçlamaktadır. Denetimsiz öğrenme yöntemi, özellikle akıllı makinelerin büyük miktarda etiketlenmemiş veri temelinde bağımsız sonuçlarda çıkarım yapabilmesi gerekliliğinden dolayı kritik öneme sahiptir. Bu yöntem daha karmaşık problemleri çözmek için denetimli öğrenme modellerinden daha başarılı sonuçlar verebilmektedir. Ancak, denetimli öğrenme algoritmaları, analizcinin sisteme istediği veriyi tanımlayabilmesi ve onu bulması gerektiğini öğretmesi sebebiyle doğruluk oranı daha yüksek sonuçlar üretmektedir. K-Means Kümeleme (K- Means Clustering), Ana Bileşen Analizi (Principle Component Analysis, PCA), Otomatik Kodlayıcılar (Autoencoders) gibi algoritmalar bu alanda en çok kullanılan yöntemlerdir (Russell ve Norvig, 2020).

Pekiştirmeli Öğrenme, bir ajanın bulunduğu ortamda etkileşimde bulunarak ödül, ceza alması ya da ödülü artırmaya çalışarak ve bu geri bildirimlere dayanarak en iyi stratejiyi öğrenmesini hedefleyerek çalışan makine öğrenmesi olarak ortaya çıkmaktadır. Q-Öğrenme, Derin Pekiştirmeli Öğrenme, Monte Carlo Yöntemleri, Asenkron Avantajlı Aktör-Eylem en sık kullanılan algoritmalar olarak ifade edilmektedir (İşcan ve Kaygısız, 2024; Kaelbling, 1996).

3.2 Yapay Sinir Ağları

Yapay Sinir Ağları (Artificial Neural Networks, ANN), insanın biyolojik sistemlerinden biri olan sinir ağları temel alınarak çalışmalarına başlanılmış ve eğitim, modelleme, öğrenme ve tahmin yapma amacıyla tercih edilebilen bir yapay zekâ tekniklerinden biri olarak değerlendirilmektedir. Yapay sinir ağları, özellikle karmaşık veri yapılarını anlamak ve öğrenmek için kullanılmaktadır. Sinir ağları, çok sayıda basit işlem biriminin (nöronlar) bir araya gelmesiyle çalışmaktadır ve

her bir nöron, girdiler alarak çıktılar üretmektedir. Bu sistemdeki nöronlar arasındaki bağlantılar ise öğrenme sürecinin geliştirilmesine önemli rol oynamaktadır (İşcan ve Kaygısız, 2024; Öztemel, 2012). Yapay Sinir Ağı katmanları Şekil 3.2'de görsel olarak verilmiştir.



Şekil 3.2 Yapay sinir ağı katmanları

Bu modelde toplam 3 adet katman bulunur. Bunlar girdi katmanı, gizli katman ve çıkış katmanıdır: Girdi katmanı yapay sinir ağları algoritmasında nöronların eğitilmesi için veri girişinin yapıldığı noktadır. Modele verilecek veriler ya da özellikler burada verilmektedir. Girdi katmanındaki her özellik (x_1, x_2, x_3,) gizli katmandaki her elemana (h_1, h_2 , h_3) giden bir sinir ağı bulunmaktadır. Gizli katman, girdi katmanından gelen verinin ağırlıkları ile çarpılıp aktivasyon fonksiyonuna sokularak bulunan ara sonuçları içermektedir. Son olarak çıktı katmanında bu veriler işlenerek ağ tahminlerde bulunmaktadır. Yapay sinir ağlarında çok giriş ve bir çıkışlı olabildiği gibi şekil 3.2'de görülebileceği üzere çok girişli ve çok çıkışlı (O_1, O, O_3) modeller de geliştirilebilmektedir. Yapay sinir ağları, karmaşık verileri işleyebilme ve örüntüleri tanıyabilme yetenekleri nedeniyle pek çok farklı alanda yaygın olarak kullanılmaktadır. Yapay sinir ağları görüntü işleme, doğal dil işleme, otonom araçlar, sağlık teşhisi, finansal tahminler, oyun tasarımı, ses tanıma ve pazarlama gibi geniş bir yelpazede uygulama alanlarına yayılmıştır (Maçin, 2019).

3.3 Derin Öğrenme

Derin öğrenme (Deep Learning, DL), verilerin birden fazla katman üzerinde hiyerarşik bir yapıda modellendiği bir makine öğrenmesi yöntemi olarak ifade edilmektedir. Bu yöntemde, verilerin temel özellikleri ilk katmanlarda öğrenilirken, daha üst katmanlarda bu özellikler birleştirilerek daha karmaşık ve soyut temsiller elde edilmektedir. Bu süreç, verilerin farklı soyutlama düzeylerinde anlamlandırılmasını sağlamaktadır. Bu yöntem, özellikle büyük ve karmaşık veri setlerinden anlamlı bilgiler çıkarmak ve tahminler yapmak için kullanılmaktadır. Bu sayede, derin öğrenme, geliştirilen diğer yöntemlerle karşılaştırıldığında daha yüksek değerlerde ölçülmüş anlama yeteneğiyle ön plana çıkmaktadır (Bengio, 2009).

Derin öğrenme girdi, gizli ve çıktı katmanlarından oluşan derin sinir ağları kullanarak verilerin karmaşık özelliklerini otomatik olarak öğrenerek çalışmaktadır. Geleneksel makine öğrenmesi yöntemlerinden farklı olarak derin öğrenme modelleri, verilerden özellikleri manuel olarak çıkarmak yerine, bu süreci otomatikleştirerek özellikle görüntü, ses ve metin gibi yapılandırılmamış verilerde etkili sonuçlar verebilmektedir. Büyük miktarda veri ve yüksek hesaplama gücü gerektiren derin öğrenme, bilgisayar ve yazılım teknolojilerin gelişimiyle birlikte hızla yaygınlaşmaktadır. Uygulama alanları, görüntü işleme, doğal dil işleme, ses tanıma, otonom sistemler ve tahmin modelleri gibi birçok alanı kapsamaktadır. Derin öğrenme, farklı problem türlerine ve veri yapılarına uygun çeşitli alt sınıflara veya model türlerine ayrılmaktadır. Bu alt sınıflar ve modeller aşağıdaki alt başlıklarda detaylıca incelenmiştir.

3.3.1 Konvolüsyonel Sinir Ağları

Konvolüsyonel Sinir Ağları (Convolutional Neural Networks, CNN), derin öğrenme alanında özellikle görüntü işleme ve bilgisayarla görme (computer vision) gibi görevlerde yaygın olarak kullanılan yapay sinir ağlarından biri olarak gösterilmektedir. CNN'ler, özellikle görüntülerdeki örüntüleri tanıma ve sınıflandırma gibi işlemleri gerçekleştirebilmek için tasarlanmış derin öğrenme algoritmalarıdır. Bu yöntemde esas olarak görsel verilerdeki özellikleri (kenarları, desenleri, nesneleri) tanıyabilen çok katmanlı ağlar kullanılmaktadır. 2015 yılında yapılan bir çalışmada, CNN, ters çevrilmiş yüzler ve farklı açılardaki ve farklı pozisyonlarda konumlanmış yüzleri

tanıma konusunda da başarılı bir sonuç elde etmiştir. Bu yöntem, farklı açılardaki yüz görüntülerini de barındıran 200.000 görüntü ve yüz görseli içermeyen milyonlarca görseli bulunduran bir veri dizisi kullanılarak eğitim sürecine başlatılmıştır. Bu genişletilmiş eğitim sonucu, CNN'nin hem statik görseller hem karmaşık görüntülerin olduğu varyasyonlar için de başarılı sonuçlar elde etmede kullanılabileceğini göstermiştir (Farfade vd., 2015).

3.3.2 Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağları (Recurrent Neural Networks, RNN), özellikle zaman serisi verileri, sıralı veriler ve zaman bağımlı problemler üzerinde etkili bir şekilde çalışabilen bir yapay sinir ağı türü olarak ifade edilmektedir. RNN'ler, sıralı verilerdeki ilişkileri modellemek için tasarlanmıştır ve önceki zaman adımlarının bilgisini saklama yeteneğine sahiptir. Bu, onları doğal dil işleme (Natural Language Processing, NLP), ses tanıma, RUL tahmini ve diğer sıralı verilerle çalışılması gereken uygulamalar için ön plana çıkarmaktadır. 2015 yılında yapılan bir çalışmada, RNN ile bilgisayarla görme ve doğal dil işleme kabiliyetlerini birlikte kullandıran bir model elde edilmiştir. Bu model, görüntülerin içeriğini öğrenerek doğal cümlelerle açıklamalar elde edebilmektedir. Farklı veri setleri üzerinde denenen çalışmalarda, insana yakın doğruluk ve akıcılık seviyesinde çıktılar elde edilmiştir. Bu katkısıyla, modelin hem dil üretimi hem de görsel içerik tanıma alanlarında kullanılması gerektiğini vurgulamaktadır (DiPietro, 2024; İşcan ve Kaygısız, 2024).

3.3.3 Sınırlı Boltzmann Makineleri

Sınırlı Boltzmann Makineleri (Restricted Boltzmann Machines, RBM), özellikle derin öğrenme ve özellik öğrenimi (feature learning) alanlarında kullanılan bir tür yapay sinir ağı modeli olarak adlandırılmaktadır. Bu makineler, verilerin yüksek boyutlu uzayda daha düşük boyutlu temsillerini öğrenmeyi amaçlar ve genellikle denetimsiz öğrenme (unsupervised learning) yöntemleriyle çalışmaktadır. RBM'ler, gizli katmanlar ve gözlemlenen (giriş) katmanları arasındaki ilişkiyi öğrenmek için kullanılmaktadır. Bu iki katman, simetrik bağlantılar aracılığıyla birbirine bağlanırken, aynı katman içindeki birimler arasında doğrudan bir bağlantı bulunmamaktadır (İşcan ve Kaygısız, 2024; Salakhutdinov ve Hinton, 2009).

3.3.4 Derin İnanç Ağları

Derin öğrenme alanında kullanılan bir tür yapay sinir ağı modelleri Derin İnanç Ağlarını (Deep Belief Networks, DBN) da kapsamaktadır. DBN, çok katmanlı Bayesian ağları temel alarak genellikle denetimsiz öğrenme (unsupervised learning) yöntemleriyle çalışmaktadır. Bu model, özellikle özellik öğrenimi ve görsel verilerin tanınması gibi karmaşık problemleri çözmek için tercih edilmektedir. DBN'ler, genellikle Sınırlı Boltzmann Makineleri (RBM)'nin üst üste yerleştirilmesiyle oluşturularak verinin daha soyut temsillerini öğrenmesini sağlamaktadır. Bir araştırma çalışmasında, DBN modeli kullanılarak insan hareketlerini tanımak için farklı hareket dizileri oluşturulmuştur. Bu model, hareket yakalama sistemlerinde meydana gelen eksik verilerin gerçek zamanlı olarak tamamlanmasına imkân tanıyarak, hareket analizinin kesintisiz ve doğru bir şekilde gerçekleştirilmesini mümkün kılmıştır (Taylor vd., 2006).

3.3.5 Uzun Kısa Vadeli Bellek

Uzun Kısa Vadeli Bellek (Long Short Term Memory, LSTM) ağları, 1997 yılında Hochreiter ve Schmidhuber tarafından, büyük zaman serisi verilerin ilişkilerini etkili bir şekilde öğrenebilmek amacıyla geliştirilmiştir (Hochreiter ve Schmidhuber, 1997). Uzun Kısa Vadeli Bellek'in en önemli avantajı, geleneksel tekrarlayan sinir ağları, uzun dönemli bağımlılıkları öğrenmede yaşadığı "vanishing gradient" (kaybolan gradyan) problemini çözmesi olarak değerlendirilmektedir. Vanishing gradient derin öğrenme algoritmalarında, özellikle de tekrarlayan sinir ağları gibi derin ağlarda karşılaşılan bir sorun olarak ifade edilmektedir. Bu problem, ağın eğitim sürecinde geri yayılım (back propagation) yöntemi kullanılarak gradyanların (yani, ağırlıkların güncellenmesi için kullanılan türevlerin) çok küçük değerlere düşmesiyle ortaya çıkmaktadır (Hu, Anumula ve Liu, 2018).

Derin sinir ağlarında eğitim yaparken, ağın her katmanında parametrelerin (ağırlıkların) nasıl güncelleneceğini belirlemek için geri yayılım algoritması kullanılmaktadır. Bu algoritma, hata (loss) fonksiyonunun çıktısını, giriş katmanlarına kadar geriye doğru yayarak her katmanın ağırlıklarını güncellemektedir. Ancak, bu süreç sırasında her katmandan geçtikçe gradyanlar (türevler) çok küçük değerlere düşebilmektedir. Bu, özellikle derin ağlarda daha belirgin hale gelmektedir. Gradyanlar

çok küçük bir değere düştüğünde, ağın daha derin katmanlarındaki ağırlıkların güncellenmesi neredeyse imkânsız hale gelmektedir. Sonuç olarak, modelin bu katmanları öğrenememesiyle eğitim süreci zarar görmektedir. Bu etkiyi azaltmak amacıyla geliştirilen Rectified Linear Unit (Düzeltici Doğrusal Birim, ReLU), gradyanları daha büyük tutmaya yardımcı olan aktivasyon fonksiyonları olarak seçilmektedir. ReLU, negatif değerleri sıfırlar ve pozitif değerleri olduğu gibi bırakmaktadır. ReLU'nun türevi 0 ya da 1 olduğu için gradyanlar daha az küçülmektedir, bu durum gradyanların kaybolmasını engellemeye yardımcı olmaktadır. Uzun Kısa Vadeli Bellek bu özelliğiyle ağın çok uzun veri setleriyle çalışırken bilgi kaybı yaşaması sorununu ortadan kaldırmaktadır (Hochreiter 1998).

Uzun Kısa Vadeli Bellek diğer geleneksel yöntemlerdeki gibi direkt olarak nöronları kullanmamaktadır, Uzun Kısa Vadeli Bellek ağı bellek bloklarından inşa edilmektedir. Uzun Kısa Vadeli Bellek ağı mimarisi, hücre durumunu tutan bellek, giriş kapısı, unutma kapısını ve çıkış kapısından meydana gelmektedir. Uzun Kısa Vadeli Bellek modeli kapılar aracılığıyla hücre durumuna yeni veri katabilmekte veya çıkarabilmektedir (Barış, Bilgin, ve Altan, 2021). Uzun Kısa Vadeli Bellek'i oluşturan ana birimler aşağıdaki gibi ifade edilmektedir.

- Hücre durumu (c_t): Bu bilgi, önceki zaman adımlarından gelen önemli verileri saklamak için kullanılmaktadır.
- Giriş kapısı (i_t): Hücre durumunun ne kadarının güncellenmesi gerektiği, giriş kapısının çıktısına göre karar verilerek yapılmaktadır.
- Çıkış kapısı (o_t): Hücre durumundan hangi kısmın ağın çıktısı olarak verileceğine karar vermektedir.
- Gizli durum (h_t): Önceki zaman adımlarındaki bilgiyi bir sonraki adımlara taşımaktadır.
- Aday hücre durumu ($\tilde{c}_t$): Hücre durumunu güncellemek için geçici bir değer sağlamaktadır.
- Unutma kapısı (f_t): Eski bilginin ne kadarının unutulacağını ifade etmektedir.

Literatürde birçok farklı alanda Uzun Kısa Vadeli Bellek kullanılarak RUL tahmin analizleri gerçekleştirilmiştir. Uzun Kısa Vadeli Bellek (LSTM) için BiLSTM, Peephole LSTM ve GRU, gibi modeller bulunmaktadır. 2024 yılında yapılan bir

çalışmada NASA C-MAPSS motor verileri kullanılarak, RUL tahmini için farklı özelliklerin eklendiği kombinasyonlarla Uzun Kısa Vadeli Bellek modeli kullanılmış ve bu modellerin sonuçları karşılaştırılmıştır (Erdoğan, 2024).

4
METODOLOJİ

4.1 Batarya Veri Seti

Bu tez çalışmasında, NASA'nın Prognostics Excellence Center (PCoE) tarafından bilimsel amaçlarla erişime açılan kaynaklardaki lityum iyon bataryaların zaman serili veri örnekleri analiz edilmektedir. (NASA, 2025). Bu veri setleri, bataryaların sağlıklı durumdan arızalı duruma kadar geçen süreleri içeren zaman serisi verilerini içermektedir.



Şekil 4.1 NASA tarafından veri toplamak için kurulan test düzeneği (Gobel vd., 2008)

Şekil 4.1'de deney düzeneği gösterilen lityum iyon bataryaların şarj-deşarj testleriyle yaşlandırılırken verileri kaydedilmiştir. Şarj işlemi, sabit olarak 1.5A ile akımla yapılarak lityum iyon bataryanın geriliminin 4.2V'a çıkması hedeflenmiş, ardından sabit gerilim aşamasına geçilerek şarj modunda akım 20mA değerine inene kadar sürdürülmüştür. Deşarj süreci, bataryanın gerilim değeri farklı veri setleri üzerinde 2.5V, 2.2V, 2.7V ve 2.5V değerlerine düşene kadar sabit akım modunda 2A değeri ile sürdürülmüştür. Batarya 5,6 ve 7 için 616'şar kez test uygulanırken batarya 18 için de 319 farklı test işlemi uygulanmıştır. Tablo 4.1 bataryaların tüm şarj ve deşarj özelliklerini içermektedir:

Tablo 4.1 Bataryaların şarj ve deşarj özellikleri

	Şarj Özellikleri			**Deşarj Özellikleri**		**Test Şartları**	
Batarya	**Akım (A)**	**Gerilim (V)**	**Akım (Şarj Kesme) (mA)**	**Akım (A)**	**Gerilim (Deşarj Kesme) (V)**	**Sıcaklık (Ortam) (°C)**	**Kapasite (Başlangıç Değeri) (Ah)**
5.	1.5	4.2	20	2	2.7	24	1.86
6.	1.5	4.2	20	2	2.5	24	2.04
7.	1.5	4.2	20	2	2.2	24	1.89
18.	1.5	4.2	20	2	2.5	24	1.86

Bataryaların şarj ve deşarj döngülerinden elde edilen veriler NASA tarafından "MATLAB data" türünde paylaşılmıştır. NASA'dan "MATLAB data" tipinde elde edilen dosyalar ".csv" formatına dönüştürülmüştür. Toplamda 4 batarya seti için 1281 farklı .csv formatındaki dosya ve içindeki veriler eğitim ve test modellerinde kullanılmıştır.

1	type	start_time	ambient_temperature	battery_id	test_id	uid	filename	Capacity
6354	charge	[2008. 7. 7. 12. 26. 45.75]	24	B0018	0	6353	06353.csv	
6356	discharge	[2008. 7. 7. 15. 15. 28.875]	24	B0018	2	6355	06355.csv	18.550.045.207.910.800
6358	charge	[2008. 7. 7. 18. 20. 14.25]	24	B0018	4	6357	06357.csv	
6360	discharge	[2008. 7. 7. 21. 53. 6.125]	24	B0018	6	6359	06359.csv	18.431.955.317.089.900
6362	charge	[2008. 7. 7. 23. 23. 14.531]	24	B0018	8	6361	06361.csv	
6364	discharge	[2.008e+03 7.000e+00 8.000e+00 2.000e+00 5.600e+01 8.453e+00]	24	B0018	10	6363	06363.csv	18.396.018.424.355.400
6366	charge	[2008. 7. 8. 4. 26. 2.109]	24	B0018	12	6365	06365.csv	
6652	charge	[2008. 8. 18. 22. 37. 25.296]	24	B0018	298	6651	06651.csv	
6653	discharge	[2.0080e+03 8.0000e+00 1.9000e+01 1.0000e+00 2.5000e+01 4.3656e+01]	24	B0018	299	6652	06652.csv	13.882.493.512.249.300
6654	charge	[2.008e+03 8.000e+00 1.900e+01 2.000e+00 1.400e+01 1.250e+01]	24	B0018	300	6653	06653.csv	
6655	discharge	[2008. 8. 19. 5. 17. 5.812]	24	B0018	301	6654	06654.csv	13.701.878.338.420.900
6657	charge	[2008. 8. 19. 6. 41. 7.359]	24	B0018	303	6656	06656.csv	
6658	discharge	[2008. 8. 19. 9. 39. 42.5]	24	B0018	304	6657	06657.csv	13.796.951.665.608.600
6659	charge	[2008. 8. 19. 10. 27. 54.171]	24	B0018	305	6658	06658.csv	
6660	discharge	[2008. 8. 19. 13. 17. 33.984]	24	B0018	306	6659	06659.csv	13.686.586.323.935.600
6661	charge	[2008. 8. 19. 14. 5. 26.578]	24	B0018	307	6660	06660.csv	
6662	discharge	[2008. 8. 19. 16. 54. 51.734]	24	B0018	308	6661	06661.csv	13.627.371.779.096.400
6663	charge	[2008. 8. 19. 17. 42. 47.484]	24	B0018	309	6662	06662.csv	
6664	discharge	[2008. 8. 19. 20. 32. 20.468]	24	B0018	310	6663	06663.csv	13.634.051.133.928.000
6665	charge	[2008. 8. 19. 21. 20. 19.656]	24	B0018	311	6664	06664.csv	
6667	discharge	[2008. 8. 20. 0. 43. 5.406]	24	B0018	313	6666	06666.csv	13.518.646.035.305.200
6669	charge	[2.0080e+03 8.0000e+00 2.0000e+01 2.0000e+00 6.0000e+00 3.7718e+01]	24	B0018	315	6668	06668.csv	
6670	discharge	[2.008e+03 8.000e+00 2.000e+01 5.000e+00 2.000e+00 2.960e-01]	24	B0018	316	6669	06669.csv	13.547.969.729.652.600
6671	charge	[2008. 8. 20. 5. 49. 31.828]	24	B0018	317	6670	06670.csv	
6672	discharge	[2008. 8. 20. 8. 37. 19.515]	24	B0018	318	6671	06671.csv	1.341.051.440.640.480

Şekil 4.2 Batarya 18'e ait .csv dosyalarının filtrelenmesi

Şekil 4.2'de gösterilen Batarya 18 için elde edilen dosyanın sütunlarında yer alan başlıkların açıklamaları aşağıdaki gibi verilmiştir:

- Type: Şarj ya da deşarj işlemini belirtmektedir.
- Start_time: MATLAB'da tarih vektörü (date vector), bir tarih ve saati temsil eden ve genellikle bir dizi sayısal değerden oluşan bir yapıdır. Bu vektör, yıl, ay, gün, saat, dakika ve saniye gibi bileşenleri içermektedir.
- Ambient_temperature: Test yapılan ortamın sıcaklığını belirtmektedir.
- Battery_id: Testi icra edilen batarya numarasını belirtmektedir.
- Test_id: İcra edilen testin numarasını belirtmektedir.
- Uid: Test çıktılarından oluşturulan dosyalardan kaçıncı olduğunu belirtmektedir.
- Filename: Test çıktılarından oluşturulan dosyalardan hangisi olduğunu belirtmektedir.
- Capacity: Her şarj ve deşarj işlemi sonrası ölçülen batarya kapasitesini belirtmektedir.

1	Voltage_measured	Current_measured	Temperature_measured	Current_load	Voltage_load	Time
2	4,188108651	0,000130667	23,81952025	0,0006	0	0
3	4,188195943	0,001459081	23,82880716	0,0006	4,203	9,422
4	3,977432056	-2,005671955	23,84494449	1,9988	3,029	19,578
5	3,961974218	-2,012205795	23,92557733	1,9988	3,026	29,016
6	3,949835235	-2,012004641	24,01062793	1,9988	3,015	38,485
7	3,939550065	-2,007285098	24,10319196	1,9988	3,005	47,906
8	3,930453667	-2,009340458	24,19162073	1,9988	2,997	57,328
9	3,922180353	-2,010267259	24,29434353	1,999	2,987	66,75
10	3,9146489	-2,010024055	24,38261558	1,9988	2,979	76,156
11	3,907584709	-2,008670773	24,47631464	1,9988	2,974	85,594
12	3,901267803	-2,010623719	24,57457824	1,999	2,965	95,031
13	3,895214648	-2,009617297	24,66737223	1,9988	2,96	104,391
14	3,889690143	-2,007814322	24,76058265	1,9988	2,956	113,766
15	3,884241778	-2,011540424	24,85949786	1,9988	2,953	123,125
349	3,029738537	-2,010459831	37,25910159	1,999	2,134	3262,047
350	3,002309007	-2,009620232	37,30506746	1,9988	2,108	3271,578
351	2,972286536	-2,008388941	37,35819288	1,999	2,079	3281,11
352	2,937890024	-2,007048026	37,4416445	1,999	2,047	3290,719
353	2,898600983	-2,007466284	37,52962111	1,999	2,01	3300,25
354	2,852847141	-2,009377136	37,58864202	1,999	1,968	3309,813
355	2,799188217	-2,01162789	37,66806419	1,999	1,917	3319,36
356	2,735409072	-2,009441218	37,75935224	1,999	1,858	3328,906
357	2,659657642	-2,009503103	37,8382215	1,999	1,789	3338,438
358	2,570864905	-2,01080667	37,94777435	1,999	1,707	3347,953
359	2,472160843	-2,009283763	38,07116981	1,999	1,61	3357,531
360	2,861097337	0,001324044	38,1018031	0,0006	0	3367,141
361	2,919886787	0,000621857	38,03571857	0,0006	0	3376,828
362	2,955990481	0,000945764	37,92065826	0,0006	0	3386,563
363	2,982858356	0,000811502	37,78596208	0,0006	0	3396,203
364	3,004687162	0,00106157	37,65547881	0,0006	0	3405,875
365	3,023145782	-0,000573616	37,48560274	0,0006	0	3415,578
366	3,03929258	-0,001465795	37,35113019	0,0006	0	3425,25
367	3,053230339	-0,002433415	37,2056713	0,0006	0	3434,891

Şekil 4.3 Batarya 18 için sadece bir deşarj döngüsüne ait ".csv" dosyasının içindeki veri formatı (Şekil 4.2'de gösterilen 6355 numaralı .csv'ye ait)

Şekil 4.3'de verilen Deşarj işlemi için sütunlarda yer alan başlıkların açıklamaları aşağıdaki gibi verilmiştir:

- Voltage_measured: Batarya terminal gerilimi (Volt)
- Current_measured: Batarya çıkış akımı (Amper)
- Temperature_measured: Batarya sıcaklığı (°C)
- Current_charge: Yükte ölçülen akım (Amper)
- Voltage_charge: Yükte ölçülen gerilim (Volt)
- Time: Döngü için zaman vektörü (saniye)

RUL, kalan kullanılabilir ömür ifadesi literatürdeki çalışmalarda genellikle İngilizceden gelen haliyle RUL olarak kullanılmaktadır. RUL, bir cihazın veya sistemin şu anki durumundan itibaren güvenli ve verimli bir şekilde çalışabileceği

kalan süreyi ifade etmektedir. Başka bir deyişle, bir makine veya bileşenin arızalanmadan önceki kalan çalışma süresi olarak değerlendirilmektedir. RUL tahminleri, genellikle bir cihazın bakımı veya onarımının planlanması amacıyla kullanılmaktadır. Bu özelliğiyle kestirimci bakım stratejilerinin önemli bir parçası olmaktadır çünkü erken bir uyarı ile bakım işlemleri yapılabilir ve böylece beklenmedik arızalar engellenebilmektedir. EOL (End of Life) ise bir cihazın veya sistemin kullanım ömrünün tamamlandığı noktayı ifade etmektedir. Bir bileşen veya cihazın artık verimli bir şekilde çalışamayacağı ve değiştirilmesi gerektiği nokta olarak değerlendirilmektedir. RUL ve EOL arasındaki ilişki matematiksel olarak aşağıdaki gibi ifade edilmektedir:

$$RUL = t_{EOL} - t_{şimdiki} \tag{4.1}$$

t_{EOL}: Sistemin veya bileşenin arıza yapacağı tahmini zaman.

$t_{şimdiki}$: Mevcut zaman veya sistemin şu anki durumunun ölçüldüğü zaman.

SOH (State of Health), bataryaların genel sağlığını ve performansını ifade eden bir parametre olarak kullanılmaktadır. Bataryanın nominal kapasitesine ($C_{nominal}$) göre, mevcut kapasitesinin ne kadar azaldığını gösterir. SOH, bataryanın ne kadar sağlıklı olduğunu ve ömrünün ne kadar kaldığını tahmin etmek için kullanılmaktadır. SOH, bataryanın ne kadar sağlıklı olduğunu ve kapasitesinin ne kadar azaldığını gösterdiği için, bataryanın kullanım ömrü hakkında önemli bir bilgi sağlamaktadır. Bu oran %100 olduğunda batarya tamamen sağlıklı, daha düşük bir değer ise bataryanın kapasitesinin azaldığını ve ömrünün sonuna yaklaştığını göstermektedir. SOH formülü aşağıdaki gibidir:

$$SOH = \frac{C_{mevcut}}{C_{nominal}}\ x\ 100 \tag{4.2}$$

C_{mevcut}: Bataryanın şimdiki kullanım durumundaki mevcut kapasitesi

$C_{nominal}$: Bataryanın nominal kapasitesi

Bu çalışmada kullanılan NASA veri setindeki bataryalar için nominal kapasite değerleri 2 Ah verilirken ömür sonu (EOL) kapasite değerleri 1.4 Ah olarak değerlendirilmektedir. Şarj ve deşarj döngüleri tekrar test edildikçe pillerin hızlandırılmış yaşlanmasına ve kapasite değerlerinin düşmesine yol açmaktadır.

Buna göre SOH'nin %70 e düştüğü 1.4 Ah kapasite değerinden sonraki değerler bataryaların artık verimli çalışamayacağı nokta olarak değerlendirilmiştir.

4.2 Uzun Kısa Vadeli Bellek Tekniği ile Tahmin Modeli Geliştirilmesi

Uzun Kısa Vadeli Bellek, derin öğrenme algoritmalarından biri olup, zaman bağımlılıkları bulunan verilere dayanarak tahminlerde bulunmak için kullanılmaktadır. Uzun Kısa Vadeli Bellek, bu tür verilerdeki geçmiş bilgiyi kullanarak gelecekteki değerleri tahmin etmede etkili bir yöntem olarak tercih edilmektedir. Bu çalışmada kullanılan batarya veri setlerinin içerdiği büyük zaman serisi verileri kullanılarak kapasite tahmini yapmak için Uzun Kısa Vadeli Bellek tekniği kullanılmıştır. Bu çalışmada, kapasite tahminine yönelik olarak kullanılan farklı Uzun Kısa Vadeli Bellek model geliştirme yaklaşımları ele alınmaktadır. Bu modeller geliştirilirken Python programlama dili ile Jupyter Notebook 7.2.2 sürümü kullanılmıştır. Analizler yapılırken kullanılan bu sürüm için Anaconda Navigator yazılımı da kullanılmaktadır. Python ve Jupyter Notebook, kodu izole bir şekilde çalıştırmayı mümkün kılarak, hataların hızlı bir şekilde giderilmesine olanak tanımaktadır. Ayrıca bu yazılımda, değişikliklerin ardından tüm kodu tekrar çalıştırmaya gerek kalmadan yalnızca ilgili hücreyi çalıştırarak sonuçları hızlıca görüntülemek mümkün olmaktadır.

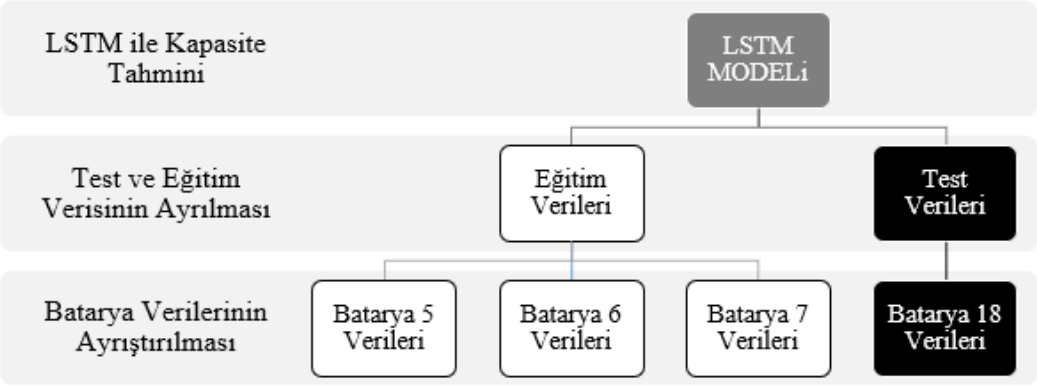
Modeller için 'tensorflow', 'pandas', ve 'scikit-learn''keras', 'numpy', 'matplotlib', 'seaborn' gibi python kütüphaneleri kullanılmıştır. TensorFlow, açık kaynaklı bir makine öğrenmesi ve derin öğrenme kütüphanesi olarak kullanılmaktadır. Pandas, Python programlama dili için geliştirilmiş, açık kaynaklı ve güçlü bir veri işleme ve analiz kütüphanesidir. Numpy ve Pandas, özellikle .csv tipindeki verileri okumak, uygun formata çevirmek, gruplandırmak ve analiz etmek için kullanılmıştır. Numpy ayrıca matematiksel işlemler için de kullanılmıştır. Scikit-learn, modeli eğitmek ve değerlendirmek için kullanılan bir makine öğrenimi ve derin öğrenme kütüphanesidir. Özellikle veri bölme, çapraz doğrulama işlevleri için kullanılmıştır. Keras, TensorFlow üzerinde çalışabilen derin öğrenme modelleri geliştirmek ve sinir ağları oluşturmak için kullanılmıştır. Elde edilen sonuçların grafiklerini çizdirebilmek için Seaborn ve Matplotlib kütüphaneleri kullanılmıştır.

NASA veri seti kullanılarak tek kanallı ve çok kanallı Uzun Kısa Vadeli Bellek modelleri geliştirilmiştir: Tek kanallı Uzun Kısa Vadeli Bellek, tek bir özelliği işleyerek modelin geliştirilmesi olarak ifade edilmektedir. Her giriş verisi tek bir kanal aracılığıyla modele girdi oluşturmaktadır. Bu yöntemde her geliştirilen batarya modeli için yalnızca gerilim verileri işlenerek kapasite belirlenmeye çalışılmıştır.

Çok kanallı Uzun Kısa Vadeli Bellek, her bir kanal için farklı türdeki verileri işleyerek, tüm kanalların çıktısını birleştirip, genel bir tahmin veya çıktı üretmektedir. Batarya veri seti içerisinde yer alan gerilim, akım ve sıcaklık parametrelerinin tümü işlenerek çok kanallı Uzun Kısa Vadeli Bellek ile kapasite tahmini yapılmıştır.

4.3 Çapraz Doğrulama Uygulanması

Çapraz Doğrulama, modellerin performansını değerlendirmek ve aşırı öğrenmeyi (overfitting) önlemek için kullanılan istatistiksel yöntem olarak ifade edilmektedir. Bu yöntem, veri kümesini birden fazla alt kümelere bölerek modelin farklı alt kümeler üzerinde eğitilip test edilmesini sağlamaktadır. Böylece, modelin genelleme yeteneği daha güvenilir bir şekilde ölçülebilmektedir. Bu yöntemde, her batarya verisi sırasıyla test seti olarak kullanılacak, geri kalan 3 batarya ise eğitim için kullanılacaktır. Şekil 4.4'de çapraz doğrulama metodu ile verilerin ayrıştırılması batarya 18 için örnek olarak gösterilmiştir:



Şekil 4.4 Çapraz doğrulama metodu ile verilerin ayrıştırılması

Batarya 18'in kapasite tahmini için model oluşturulurken batarya 5,6 ve 7'nin verileri eğitim verisi olarak kullanılmaktadır. Geliştirilen model batarya 18'in verileriyle test edilmektedir. Bu yöntem her batarya için ayrı ayrı uygulanmaktadır.

4.4 Min- Max Normalizasyonu Uygulanması

Normalizasyon**,** veri analizinde, farklı ölçü birimlerine sahip verilerin karşılaştırılabilir ve analiz edilebilir hale getirilmesi için uygulanan bir tekniktir. Normalizasyon, verileri belirli bir aralığa dönüştürerek, bu farklılıkları ortadan kaldırarak modelin daha verimli çalışmasını sağlamaktadır.

Bu çalışmada veri setindeki sıcaklık, akım ve gerilim, kapasite verilerinin değerleri farklı ölçeklerde olduğu için en yaygın kullanılan teknik olan min-max normalizasyonu uygulanmaktadır. Min-Max Normalizasyonu, verileri 0 ile 1 arasında yeniden ölçeklendirmek için kullanılan bir veri ön işleme tekniğini ifade etmektedir. Bu yöntem, özellikle derin öğrenme ve istatistiksel analizlerde, farklı ölçeklerdeki verileri standartlaştırmak için kullanılmaktadır. Matematiksel olarak aşağıdaki gibi ifade edilmektedir:

$$y_t = \frac{x_t - \min(x_t)}{\max(x_t) - \min(x_t)} \tag{4.3}$$

- x_t: Veri setindeki verilerin t anındaki değerler
- $\min(x_t)$: Verinin t anındaki minimum değeri
- $\max(x_t)$: Verinin t anındaki maksimum değeri
- y_t: t anında normalizasyon sonucu elde edilen yeni değer

Bu yöntemde, her bir özelliğin değeri, 0 ile 1 arasına sıkıştırılmaktadır. Bu, veri setinde kullanılan tüm parametrelerin minimum ve maksimum değerlerine dayalı olarak yapılmıştır. Batarya veri seti içerisinde yer alan 5 farklı t anına ait terminal gerilimi değerleri (3.2 V, 3.5 V, 3.7 V, 3.9 V ve 4.1 V) için bunun uygulaması aşağıdaki gibi örnek gösterilebilmektedir:

Bataryaların maksimum terminal gerilimi 4.18 V ve minimum terminal gerilimi 3.05 V olarak alındığında normalize edilmiş değerler aşağıdaki gibi hesaplanmıştır:

3.2 V olan değer için $y_t = \frac{3.2-3.05}{4.18-3.05} = 0.133$

3.5 V olan değer için $y_t = \frac{3.5-3.05}{4.18-3.05} = 0.398$

3.7 V olan değer için $y_t = \frac{3.7-3.05}{4.18-3.05} = 0.575$

3.9 V olan değer için $y_t = \frac{3.9-3.05}{4.18-3.05} = 0.752$

4.1 V olan değer için $y_t = \frac{4.1-3.05}{4.18-3.05} = 0.930$

Verilen batarya gerilim değerlerinin min-max normalizasyonu aşağıdaki şekilde olmaktadır:

- 3.2 V için → 0.133
- 3.5 V için → 0.398
- 3.7 V için → 0.575
- 3.9 V için → 0.752
- 4.1 V için → 0.930

Bu veriler, bataryanın gerilim değerlerinin 3.05 V ile 4.18 V arasından 0 ile 1 arasına normalize edilmiş hali olarak model tarafından kullanılmaktadır.

4.5 Kutu Filtreleme Uygulanması

Filtreleme, sinyal işleme ve veri analizi alanlarında kullanılan genellikle bir sinyalden gürültüyü çıkarmayı veya sinyali düzeltmeyi ifade etmektedir. Özellikle ölçümlerden veya sensör verilerinden elde edilen sinyallerdeki gürültüyü azaltmak veya istenmeyen bileşenleri filtrelemek için kullanılır. Filtreleme, verideki istenmeyen bileşenleri (gürültü, hatalar vb.) ortadan kaldırarak veya veriyi daha anlamlı bir hale getirerek daha doğru ve güvenilir sonuçlar elde etmeyi sağlamaktadır.

Bu çalışmada verilere kutu filtresi (Box Filtreing) tekniği ile filtreleme uygulanarak verilerdeki gürültüler ortadan kaldırılmaya çalışılmaktadır. Box Filtering**,** genellikle bir veri setindeki her değeri, etrafındaki komşu değerlerin ortalamasını alarak yumuşatma işlemi gerçekleştiren bir tekniktir. Bu, özellikle veri kümesindeki ani değişimleri yumuşatarak daha düzgün bir sinyal elde etmek amacıyla kullanılmaktadır. Bu işlem genellikle gürültüyü azaltmak veya veriyi pürüzsüzleştirmek için tercih edilmektedir.

Batarya 18 verisine ait 6355. Csv dosyasındaki 5 farklı gerilim değeri için box filtering uygulaması örneklendiğinde:

Alınan 5 farklı veri ile 3 noktalı bir box filtering işlemi gerçekleştirilmektedir. Bu durumda, her veri noktasına, çevresindeki 2 komşu veri ile birlikte toplamda 3 veri noktası alınarak ortalama hesaplanmaktadır. Box filtering uygulanacak 5 farklı veri $[v_1,\ v_2,\ v_3,\ v_4,\ v_5]$=[3.8745328, 3.869965576, 3.865586181, 3.861323297, 3.857541912] olarak belirlenmiştir. Buna göre:

$$Ort_1 = \frac{v_1 + v_2 + v_3}{3} = 3.87002819$$

$$Ort_2 = \frac{v_2 + v_3 + v_4}{3} = 3.86562501$$

$$Ort_3 = \frac{v_3 + v_4 + v_5}{3} = 3.86148380$$

Olarak hesaplanmaktadır ve filtrelenmiş yeni veri seti [3.87002819, 3.86562501, 3.86148380, 3.861323297, 3.857541912] olarak alınmaktadır. v_4 ve v_5 değerleri için de veri seti devam ettiği sürece ortalama alınarak filtreleme yapılmaktadır. Bu örnekte 5'li veri seti örnek olarak kullanıldığı için kenar değerler doğrudan alınmaktadır. Kutu filtreleme özellikle zaman serisi verilerinde, ani dalgalanmalara karşı veri yumuşatma işlemi sağlamasıyla da model doğruluğunu ve performansını etkilemektedir.

4.6 Hiper Parametre Optimizasyonu

Hiper parametre, derin öğrenme ve makine öğrenmesi modellerinin eğitim sürecinde modelin çıktılarını optimize etmek için farklı ayarlarla değiştirilen parametreleri ifade etmektedir. Bu parametreler, geliştirilen modelin eğitim sürecinde ayarlamalar yapabilmeyi sağlayarak model performansının iyileştirilmesine olanak tanımaktadır. Makine öğrenimi ve derin öğrenme modellerinde hiper parametreler modelin dışındaki parametreler olarak değerlendirilmektedir; model bu parametreleri kendisi öğrenemediği için model geliştirici kontrolünde optimize edilebilmektedir. Bu parametreler, modelin eğitiminin hızlanmasını ve diğer öğelerini ayarlayarak modelin performansının iyileştirilmesini mümkün kılmaktadır.

Bir Uzun Kısa Vadeli Bellek modelinin her çalışma adımında eğitim verilerinin güncellenmesindeki kullanılacak örnek sayısını Batch size değeri belirlemektedir. Küçük bir Batch Size değeri verilerin filtreleme ihtiyacını gürültü sebepleriyle

artırmaktadır ancak geliştirilen modelin öğrenme yeteneğini iyileştirmektedir. Yüksek değerlerdeki Batch Size kararlı bir yapı sunarken eğitim süresini yavaşlatmaktadır. LSTM Unit, Uzun Kısa Vadeli Bellek katmanlarındaki gizli birimlerin sayısını modelin kaç olarak alacağını ifade etmek için kullanılmaktadır. Bu değer, modelin öğrenebileceği özelliklerin karmaşıklığını ve model kapasitesini doğrudan etkileyebilmektedir. Ancak, birim sayısının gereğinden fazla artırılması, modelin aşırı öğrenmesine (overfitting) neden olmaktadır. Dense Unit sayısı ise tam bağlantılı katmanlardaki nöronların sayısını ifade etmek için kullanılmaktadır. Başka bir deyişle modelin öğrenme yeteneğini belirlemektedir. Bu katman, genellikle modelin son çıktısını üretmek için kullanılmaktadır. Epoch sayısı, modelin tüm eğitim verisi üzerinde bir tam döngü gerçekleştirmesi sürecini ifade etmektedir. Epoch sayısının çok yüksek olması, modelin veriyi fazla öğrenmesine yol açabilirken, yetersiz epoch sayısı ise modelin veriyi tam olarak öğrenememesine neden olabilmektedir. Hiper parametreler, modelin performansını etkileyen kritik unsurlar olarak değerlendirilmektedir. Bu çalışmada optimizasyonu yapılan hiper parametrelerin gösterimi Şekil 4.5'de verilmiştir:

1	Batch Size	LSTM Units	Dense Units	Epochs
2	32	32	32	50
3	32	32	32	100
4	32	32	32	200
5	32	32	32	500
6	32	32	64	50
7	32	32	64	100
8	32	32	64	200
9	32	32	64	500
85	4	64	32	500
86	4	64	64	50
87	4	64	64	100
88	4	64	64	200
89	4	64	64	500
90	4	128	32	50
91	4	128	32	100
92	4	128	32	200
93	4	128	32	500
94	4	128	64	50
95	4	128	64	100
96	4	128	64	200
97	4	128	64	500

Şekil 4.5 Çalışmada optimizasyonu yapılan hiper parametrelerin gösterimi

Çalışmanın bu kısmında sıklıkla Uzun Kısa Vadeli Bellek modeli geliştirmede kullanılan hiper parametrelerinin farklı değerlerle değiştirilmesiyle 96 farklı özellikleri içeren model eğitilerek en doğru sonuçları veren hiper parametre ayarının modelin doğruluk oranını ne kadar iyileştirebildiği öne çıkarılmaktadır.

4.7 Model Performansı Değerlendirme Kriterleri

Uzun Kısa Vadeli Bellek gibi zaman serisi modellerinin performansını değerlendirirken Ortalama Mutlak Hata (Mean Absolute Error, MAE) ve Kök Ortalama Kare Hata (Root Mean Squared Error, RMSE) sıklıkla kullanılan metrikler olarak ifade edilmektedir. Bu metrikler, modelin tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğini ölçmek ve modelin doğruluğunu karşılaştırmak için kullanılmaktadır.

MAE, modelin tahmin ettiği değerlerle gerçekte ölçülen değerler arasındaki farkların mutlak değerinin ortalaması olarak hesaplanmaktadır. Bu özelliğiyle tüm hataları eşit şekilde dikkate almaktadır. Eğer MAE küçükse, bu, modelin tahminlerinin gerçek değerlere oldukça yakın olduğunu göstermektedir. Başka bir deyişle, modelin ortalama hatası düşüktür ve model, veri kümesi üzerinde iyi bir genel performans sergiliyor demektir. Eğer MAE büyükse, bu, modelin tahminlerinin gerçek verilere uzak olduğunu göstermektedir. Başka bir deyişle, modelin ortalama hatası büyüktür ve modelin performansı, veri kümesi üzerinde daha kötü bir performans olarak değerlendirilmektedir. Formülü aşağıdaki şekildedir:

n: Gözlem sayısı

y_i: Gerçek değerler

$\widehat{y_i}$: Tahmin edilen değerler

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \widehat{y_i}| \tag{4.4}$$

RMSE, gerçek değerlerin, tahmin edilen değerlerden çıkarılıp karelerinin ortalamasının karekökünü alarak, hataların oranını belirtmektedir. RMSE'nin matematiksel olarak ifade edildiği denklem şu şekilde sunulmuştur:

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \tag{4.5}$$

RMSE, büyük hata değerlerini daha fazla cezalandırarak, modelin büyük hatalar yaptığı durumları vurgulamaktadır ve bu da modelin iyileştirilmesine yönelik önemli ipuçları sunmaktadır.

Eğer RMSE değeri büyükse modelin tahminleri ile gerçek değerler arasındaki farklar büyüktür ve modelin yeterince doğru tahminler yapamadığı çıkarımı yapılmaktadır. Bu, modelin doğruluğunun düşük olduğunu ve tahminlerinin gerçek değerlerden uzak olduğunu göstermektedir. RMSE değeri küçükse modelden elde edilen tahminlerin gerçeğe en çok yakınsayan model olduğunu göstermektedir ve modelin başarılı bir şekilde öğrenmiş olduğunu göstermektedir. Bu durumda modelin doğruluğunun yüksek ve performansının daha iyi olduğu çıkarımı yapılmaktadır.

5
BULGULAR VE TARTIŞMA

Bu tez çalışmasında, NASA'nın Prognostics Excellence Center (PCoE) tarafından bilimsel amaçlarla erişime açılan kaynaklardaki lityum iyon bataryaların zaman serili veri örnekleri analiz edilerek Uzun Kısa Vadeli Bellek modelleri oluşturulmuştur. Zaman serili veriler ile oluşturulan Uzun Kısa Vadeli Bellek modelleri geliştirilerek bataryalara ait kapasite değerleri tahmin edilmeye çalışılmıştır. Tahminlerin doğruluğunu iyileştirmede farklı uygulamalar denenerek karşılaştırılmıştır. En yüksek doğruluk oranına sahip batarya kapasite tahminlerine olanak tanıyan özellikteki Uzun Kısa Vadeli Bellek modeli belirlenmeye çalışılmıştır. Batarya 18 ve batarya 5 için oluşturulan Uzun Kısa Vadeli Bellek modellerinden elde edilen sonuçlar 5.1 Bulgular bölümünde verişmiş ve 5.2 Bulguların değerlendirilmesi bölümünde karşılaştırılmıştır.

5.1 Bulgular

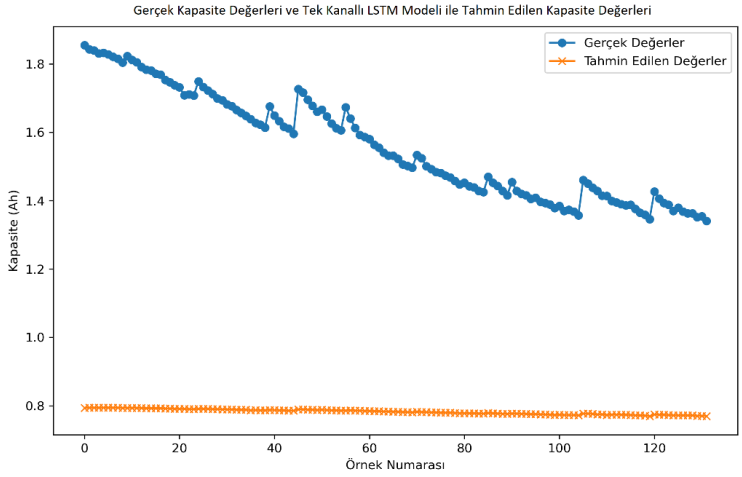
Batarya 18 için oluşturulan modeller ve özellikleri en uygun yöntem bulunmaya çalışılırken sırasıyla Tablo 5.1'de verildiği gibi oluşturulmuş ve oluşturulan modellerin çıktıları karşılaştırılmıştır.

Tablo 5.1 Batarya 18 için oluşturulan modeller ve özellikleri

Model Numarası	**Model Özelliği**
Model 1	Tek kanallı Uzun Kısa Vadeli Bellek
Model 2	Çok Kanallı Uzun Kısa Vadeli Bellek
Model 3	Çok Kanallı Uzun Kısa Vadeli Bellek ve Normalizasyon
Model 4	Çok Kanallı Uzun Kısa Vadeli Bellek, Filtreleme, Normalizasyon
Model 5	Filtreleme, Normalizasyon, Hiper Parametre Optimizasyonu ve Çok Kanallı Uzun Kısa Vadeli Bellek LSTM Units:32, Epochs:500, Batch Size:4, Dense Units:64

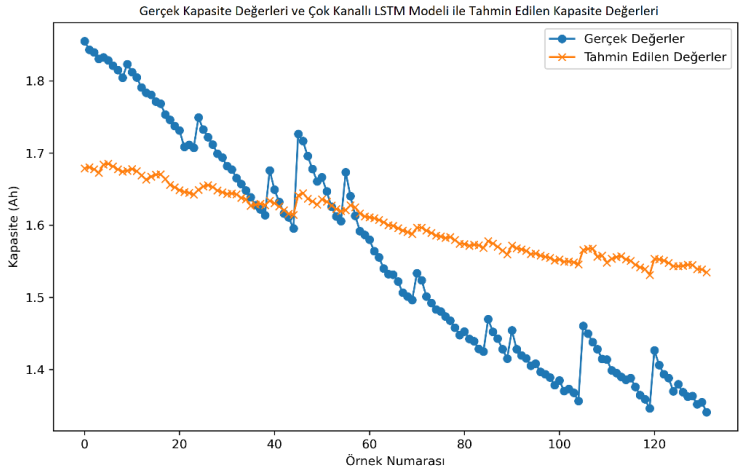
5.1.1 Çok Kanallı ve Tek Kanallı Uzun Kısa Vadeli Bellek Modellerinin Karşılaştırılması

Batarya 18 verileri ile oluşturulan çok kanallı Uzun Kısa Vadeli Bellek ve tek kanallı Uzun Kısa Vadeli Bellek modellerinin kıyaslanması için çizdirilen grafikler, MAE ve RMSE çıktıları sırasıyla şöyle elde edilmiştir:



Şekil 5.1 Batarya 18 gerçek kapasite değerleri ve tek kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği

Batarya 18 gerçek kapasite değerleri ve tek kanallı Uzun Kısa Vadeli Bellek modeli ile tahmin edilen kapasite değerleri karşılaştırılmış ve Şekil 5.1'de grafiği verilmiştir. Bu modele ait MAE ve RMSE sonuçları sırasıyla şöyle elde edilmiştir: MAE: 0.7751, RMSE:0.7889.

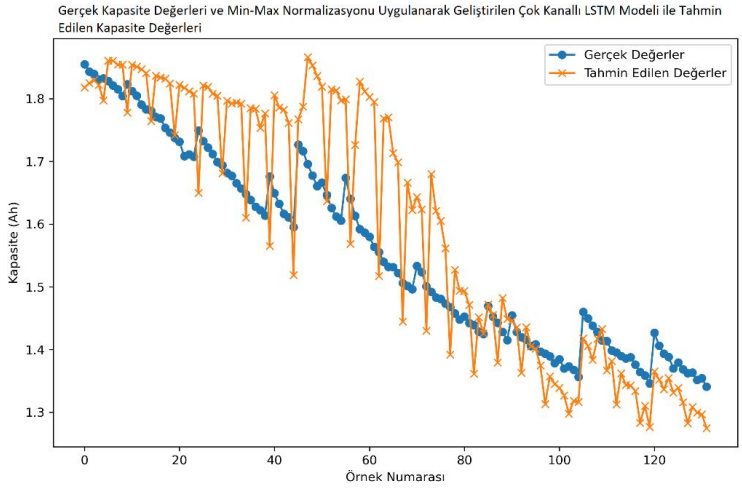


Şekil 5.2 Batarya 18 gerçek kapasite değerleri ve çok kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği

Batarya 18 gerçek kapasite değerleri ve çok kanallı Uzun Kısa Vadeli Bellek modeli ile tahmin edilen kapasite değerleri karşılaştırılmış ve Şekil 5.2'de grafiği verilmiştir. Bu modele ait MAE ve RMSE sonuçları sırasıyla şöyle elde edilmiştir: MAE: 0.1039, RMSE:0.1184.

5.1.2 Min-Max Normalizasyonu Uygulanmamış ve Uygulanmış Uzun Kısa Vadeli Bellek Modellerinin Karşılaştırılması

Batarya 18 için normalizasyon uygulanmamış çok kanallı Uzun Kısa Vadeli Bellek modeli olarak model 2 ve Şekil 5.2'deki grafiğe ait değerler temel alınmıştır. Karşılaştırma yaparken kullanılacak RMSE ve MAE değerleri Model 2'ye aittir. Batarya 18 için normalizasyon uygulanan çok kanallı Uzun Kısa Vadeli Bellek modeli (Model 3) için elde edilen grafik Şekil 5.3'te verilmiştir:



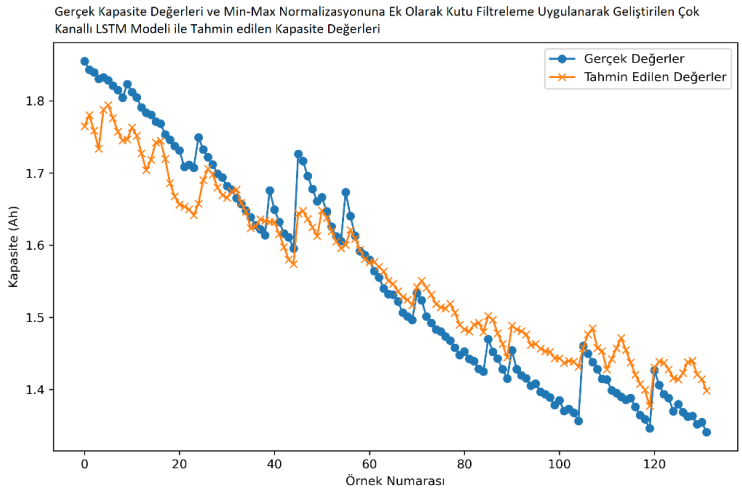
Şekil 5.3 Gerçek kapasite değerleri ve min-max normalizasyonu uygulanarak geliştirilen çok kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği

Batarya 18 için normalizasyon uygulanan çok kanallı Uzun Kısa Vadeli Bellek modeli için elde edilen RMSE, MAE sonuçları sırasıyla şöyle elde edilmiştir: MAE: 0.0808, RMSE:0.1004.

5.1.3 Kutu Filtresi Uygulanmamış ve Uygulanmış Uzun Kısa Vadeli Bellek Modellerinin Karşılaştırılması

Batarya 18 için kutu filtresi uygulanmamış çok kanallı Uzun Kısa Vadeli Bellek modeli olarak model 3 ve Şekil 5.3'deki grafiğe ait değerler temel alınmıştır. Karşılaştırma yaparken Batarya 18 için kutu filtresi uygulanmamış çok kanallı

Uzun Kısa Vadeli Bellek modeli olarak kullanılacak RMSE ve MAE değerleri Model 3'e aittir.

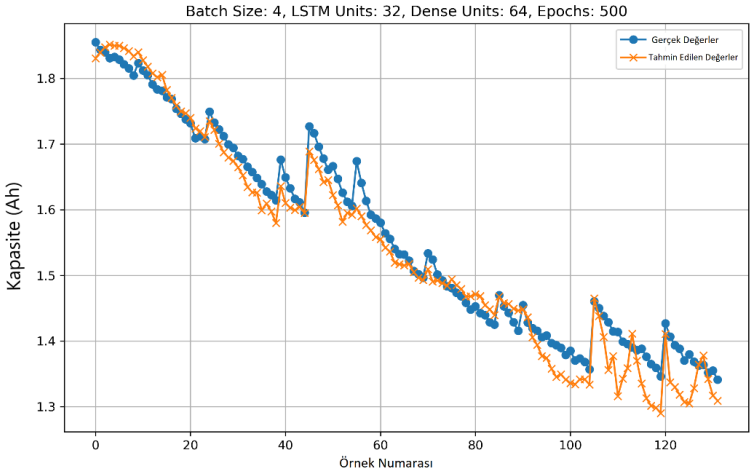


Şekil 5.4 Batarya 18 gerçek kapasite değerleri ve min-max normalizasyonuna ek olarak kutu filtreleme uygulanarak geliştirilen çok kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği

Batarya 18 gerçek kapasite değerleri ve min-max normalizasyonuna ek olarak kutu filtreleme uygulanarak geliştirilen çok kanallı Uzun Kısa Vadeli Bellek modeli ile tahmin edilen kapasite değerleri grafiği Şekil 5.4'de verilmiştir. Bu modelden (Model 4) elde edilen RMSE ve MAE sonuçları sırasıyla şöyle elde edilmiştir: MAE: 0.0409, RMSE:0.0472.

5.1.4 Normalizasyon ve Filtreleme Uygulanan Uzun Kısa Vadeli Bellek Modellerinde Hiper Parametre Optimizasyonu

Batarya 18 için hiper parametre optimizasyonu uygulanmamış, normalizasyon ve filtreleme uygulanan çok kanallı Uzun Kısa Vadeli Bellek modeli olarak model 4 ve Şekil 5.4'deki grafiğe ait değerler temel alınmıştır. Bu amaçla karşılaştırma yaparken kullanılacak RMSE ve MAE değerleri Model 4'e aittir. Batarya 18 için normalizasyon ve filtreleme uygulanan Uzun Kısa Vadeli Bellek modellerinde hiper parametre optimizasyonu yapılan çok kanallı Uzun Kısa Vadeli Bellek modeli (Model 5) için çizdirilen grafik Şekil 5.5'de gösterilmektedir:



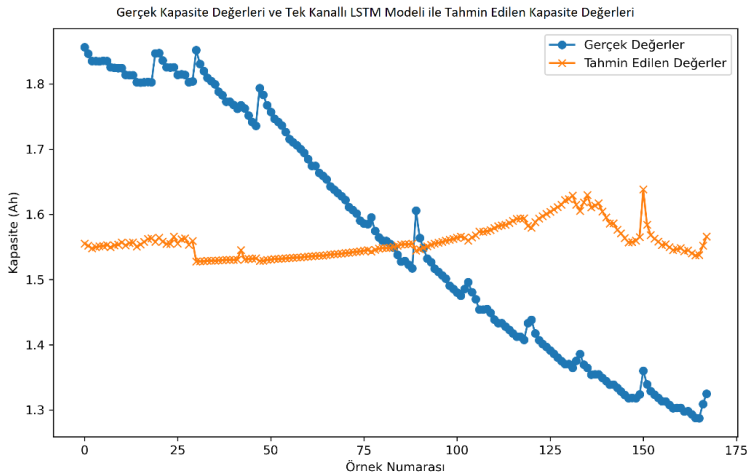
Şekil 5.5 Hiper parametre optimizasyonunun uygulanması ile tahmin edilen değerler ve gerçek değerler grafiği

Bu Modele (Model 5) ait MAE ve RMSE değerleri sırasıyla şöyle edilmiştir: MAE: 0.0260, RMSE: 0.0320.

5.1.5 Geliştirilen Yöntemin Farklı Veri Seti Üzerinde Test Edilmesi

Batarya 18 için geliştirilen modeldeki yöntemlerin tümü sırasıyla batarya 5 için de uygulanmıştır. Batarya 5'in Uzun Kısa Vadeli Bellek Modeli geliştirilirken Batarya 6, 7 ve 18 in verileri ile model eğitilerek Batarya 5 test edilmiştir. Elde edilen sonuçlara ait grafikler, MAE ve RMSE çıktıları aşağıdaki gibidir:

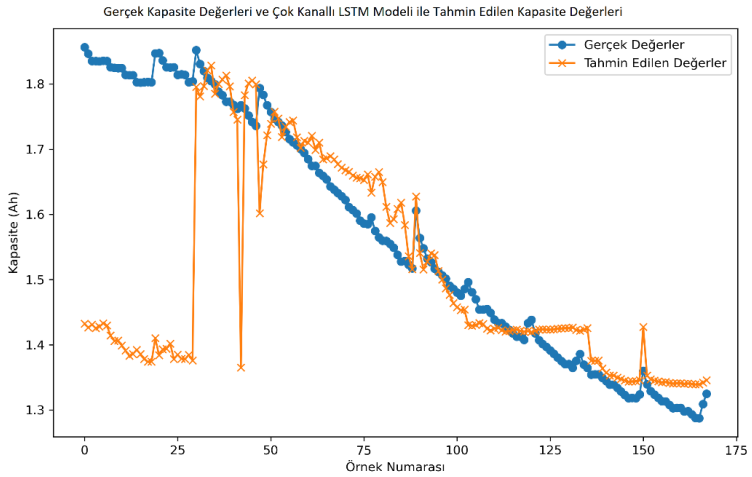
- Batarya 5 Tek Kanallı Uzun Kısa Vadeli Bellek Modelinin Çıktıları



Şekil 5.6 Batarya 5 gerçek kapasite değerleri ve tek kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği

Batarya 5 gerçek kapasite değerleri ve tek kanallı Uzun Kısa Vadeli Bellek modeli ile tahmin edilen kapasite değerleri karşılaştırılmış ve Şekil 5.6'da grafiği verilmiştir. Bu modele ait MAE ve RMSE sonuçları sırasıyla şöyle elde edilmiştir: MAE:0.1864, RMSE:0.2059.

- Batarya 5 Çok Kanallı Uzun Kısa Vadeli Bellek Modelinin Çıktıları

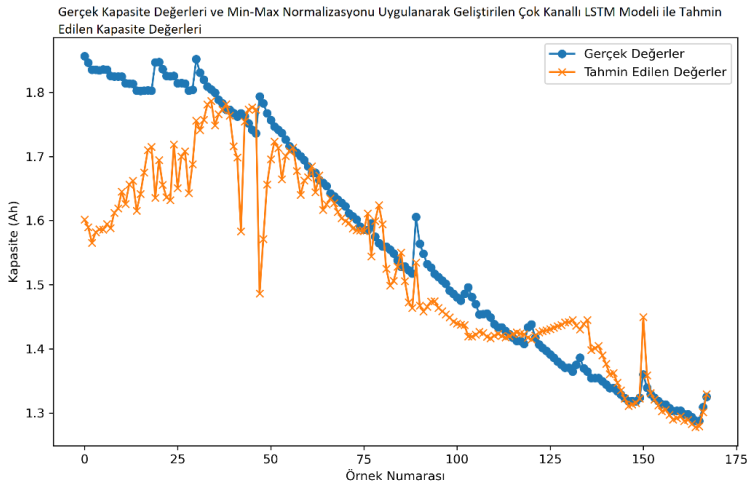


Şekil 5.7 Batarya 5 gerçek kapasite değerleri ve çok kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği

Batarya 5 gerçek kapasite değerleri ve çok kanallı Uzun Kısa Vadeli Bellek modeli ile tahmin edilen kapasite değerleri karşılaştırılmış ve Şekil 5.7'de grafiği verilmiştir. Bu modele ait MAE ve RMSE sonuçları sırasıyla şöyle edilmiştir: MAE: 0.1055, RMSE:0.1859.

- Batarya 5 Min-Max Normalizasyonu Uygulanmış Uzun Kısa Vadeli Bellek Modelinin Çıktıları

Batarya 5 için normalizasyon uygulanmamış çok kanallı Uzun Kısa Vadeli Bellek modeli olarak Model 7 ve Şekil 5.7'deki grafiğe ait değerler temel alınmıştır. Karşılaştırma yaparken kullanılacak RMSE ve MAE değerleri Model 7'ye aittir. Batarya 5 için normalizasyon uygulanan çok kanallı Uzun Kısa Vadeli Bellek modeli (Model 8) için elde edilen grafik Şekil 5.8'de verilmiştir:

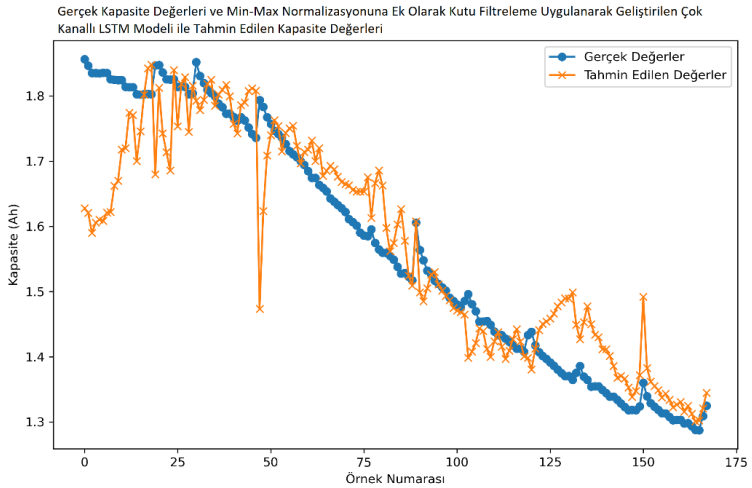


Şekil 5.8 Gerçek kapasite değerleri ve min-max normalizasyonu uygulanarak geliştirilen çok kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği

Bu modelin (Model 8) çıktılarından elde edilen RMSE, MAE sonuçları sırasıyla şöyle elde edilmiştir: MAE: 0.0625, RMSE:0.0936.

- Batarya 5 Min-Max Normalizasyonu ve Kutu Filtreleme Uygulanmış Uzun Kısa Vadeli Bellek Modelinin Çıktıları

Batarya 5 için kutu filtresi uygulanmamış çok kanallı Uzun Kısa Vadeli Bellek modeli olarak model 8 ve Şekil 5.8'deki grafiğe ait değerler temel alınmıştır. Karşılaştırma yaparken kullanılacak RMSE ve MAE değerleri Model 8'e aittir.

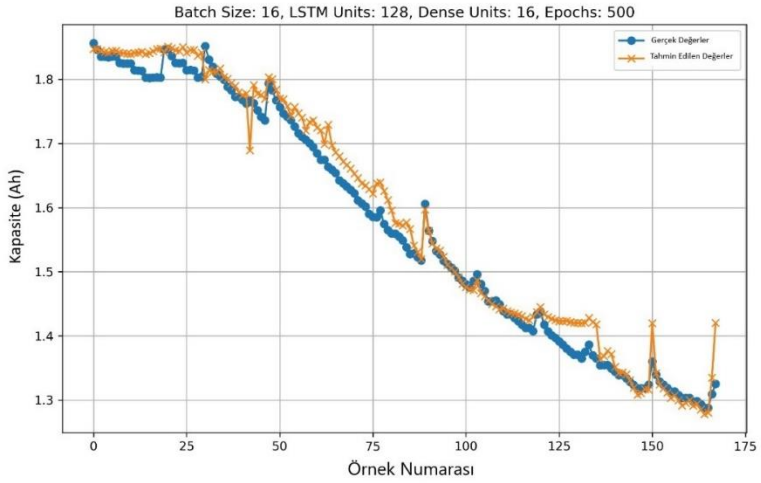


Şekil 5.9 Batarya 5 gerçek kapasite değerleri ve min-max normalizasyonuna ek olarak kutu filtreleme uygulanarak geliştirilen çok kanallı uzun kısa vadeli bellek modeli ile tahmin edilen kapasite değerleri grafiği

Batarya 5 gerçek kapasite değerleri ve min-max normalizasyonuna ek olarak kutu filtreleme uygulanarak geliştirilen çok kanallı Uzun Kısa Vadeli Bellek modeli ile tahmin edilen kapasite değerleri grafiği Şekil 5.9'da verilmiştir. Model 9'dan RMSE ve MAE sonuçları sırasıyla şöyle elde edilmiştir: MAE: 0.0558, RMSE:0.0793.

- Batarya 5 Normalizasyon ve Filtreleme Uygulanan Uzun Kısa Vadeli Bellek Modelinde Hiper Parametre Optimizasyonu Çıktıları

Batarya 5 için hiper parametre optimizasyonu uygulanmamış, normalizasyon ve filtreleme uygulanan çok kanallı Uzun Kısa Vadeli Bellek modeli olarak model 9 ve Şekil 5.9'daki grafiğe ait değerler temel alınmıştır. Karşılaştırma yaparken kullanılacak RMSE ve MAE değerleri model 9'e aittir. Batarya 5 için normalizasyon ve filtreleme uygulanan Uzun Kısa Vadeli Bellek modellerinde hiper parametre optimizasyonu yapılan çok kanallı Uzun Kısa Vadeli Bellek modeli (Model 10) için elde edilen grafik Şekil 5.10'da verilmiştir:



Şekil 5.10 Batarya 5 normalizasyon ve filtreleme uygulanan uzun kısa vadeli bellek modelinde hiper parametre optimizasyonunun çıktıları

Model 10'a ait MAE ve RMSE değerleri sırasıyla şöyle elde edilmiştir: MAE 0.0208, RMSE 0.0271.

5.2 Bulguların Değerlendirilmesi

Batarya 18 için geliştirilen Uzun Kısa Vadeli Bellek modellerinin sırası ve çıktılarına ait tablo aşağıdaki gibidir:

Tablo 5.2 Batarya 18 için oluşturulan modellerin RMSE ve MAE çıktıları

Model Numarası	**Model Özelliği**	**RMSE ve MAE Çıktıları**
Model 1	Tek kanallı Uzun Kısa Vadeli Bellek	MAE: 0.7751
		RMSE: 0.7889
Model 2	Çok Kanallı Uzun Kısa Vadeli Bellek	MAE: 0.1039
		RMSE: 0.1184
Model 3	Normalizasyon + Çok Kanallı Uzun Kısa Vadeli Bellek	MAE: 0.0808
		RMSE: 0.1004
Model 4	Filtreleme + Normalizasyon + Çok Kanallı Uzun Kısa Vadeli Bellek	MAE: 0.0409
		RMSE: 0.0472
Model 5	Filtreleme+ Normalizasyon + Hiper Parametre Normalizasyonu+ Çok Kanallı Uzun Kısa Vadeli Bellek	MAE: 0.0260
		RMSE: 0.0320

Batarya 18 için geliştirilen modellerin özellikleri ve performanslarını değerlendirilirken kullanılacak MAE ve RMSE sonuçları Tablo 5.2'deki gibi elde edilmiştir. RMSE ve MAE değerlerinin en düşük olduğu, başka bir deyişle model performansının en iyi olduğu model 5 numaralı model olarak gözlemlenmiştir. Sırasıyla modeller incelendiğinde Çok kanallı Uzun Kısa Vadeli Bellek modelinin, tek kanallı Uzun Kısa Vadeli Bellek modeline göre daha doğru sonuç verdiği, Model 2'nin Model 1'e göre daha düşük MAE ve RMSE değerlerine sahip olmasıyla ortaya konulmaktadır.

Çok kanallı modeller arasında sadece normalizasyon uygulanan Model 3'ün, normalizasyon uygulanmayan Model 2'ye göre daha doğru sonuçlar verdiği gözlemlenmektedir. Normalizasyon uygulanan 2 modelden ise filtreleme özelliği eklenerek geliştirilen Model 4'ün Model 3'e göre daha doğru sonuçlar verdiği çıkarımı elde edilen MAE ve RMSE değerlerinden yapılabilmektedir.

Tek kanallıya göre daha doğru sonuçlara sahip olan çok kanallı Uzun Kısa Vadeli Bellek yöntemi seçildikten sonra geliştirilen modeller arasında normalizasyon ve filtreleme veri ön işleme adımlarını birlikte içeren ve ardından farklı hiper parametrelerde optimizasyonu yapılarak MAE ve RMSE değeri hesaplanan 5 numaralı modelin en doğru sonucu verdiği gözlemlenmektedir. Buna göre Uzun Kısa Vadeli Bellek modelinin normalizasyon ve filtreleme veri işleme teknikleri ile desteklenerek model çıktılarının doğruluğunu artırmada bir yöntem olarak kullanılabileceği çıkarımı yapılabilmektedir. Bu işlemlerin yanı sıra uygulanacak olan hiper parametre optimizasyonu ile modelin en doğru çıktıyı vereceği hiper parametreleri bularak tahmin yapmanın da modelin sonuçlarının doğruluğunu artırdığı ortaya konulmaktadır. Batarya 5 için geliştirilen Uzun Kısa Vadeli Bellek modellerinin numarası ve çıktıları Tablo 5.3'te verilmiştir:

Tablo 5.3 Batarya 5 için oluşturulan modellerin RMSE ve MAE çıktıları

Model Numarası	**Model Özelliği**	**RMSE ve MAE Çıktıları**
Model 6	Tek kanallı Uzun Kısa Vadeli Bellek	MAE: 0.1864
		RMSE: 0.2059
Model 7	Çok Kanallı Uzun Kısa Vadeli Bellek	MAE: 0.1055
		RMSE: 0.1859
Model 8	Normalizasyon + Çok Kanallı Uzun Kısa Vadeli Bellek	MAE: 0.0625
		RMSE: 0.0936
Model 9	Filtreleme + Normalizasyon + Çok Kanallı Uzun Kısa Vadeli Bellek	MAE: 0.0558
		RMSE: 0.0793
Model 10	Normalizasyon, Filtreleme, Hiper Parametre Optimizasyon ve Çok Kanallı Uzun Kısa Vadeli Bellek Epochs 500, Dense Units 64, Batch Size 16, LSTM Units 128,	MAE: 0.0208
		RMSE: 0.0271

Batarya 5 için tek kanallıya göre daha doğru sonuçlara sahip olan çok kanallı Uzun Kısa Vadeli Bellek yöntemi seçildikten sonra geliştirilen modeller arasında normalizasyon ve filtreleme veri ön işleme adımlarını içeren ve ardından farklı hiper parametrelerde optimizasyonu yapılarak MAE ve RMSE değeri hesaplanan 10 numaralı modelin en doğru sonucu verdiği gözlemlenmektedir. Buna göre Uzun Kısa Vadeli Bellek modelinin normalizasyon ve filtreleme veri işleme teknikleri ile desteklenerek model çıktılarının doğruluğunu artırmada bir yöntem olarak kullanılabileceği çıkarımı yapılabilmektedir. Bu işlemlerin yanı sıra uygulanacak olan hiper parametre optimizasyonu ile modelin en doğru çıktıyı vereceği hiper parametreleri bularak tahmin yapmanın da modelin sonuçlarının doğruluğunu artırdığı gözlemlenmektedir. Batarya 18'den farklı olarak hiper parametre optimizasyonundaki hiper parametreler 18'den farklılık göstermektedir (Batch Size 16, LSTM Units 128, Dense Units 64, Epochs: 500).

Batarya 5 için geliştirilen modelin çıktıları incelendiğinde batarya 18 ile paralel sonuçlar verdiği gözlemlenmektedir. Buna göre; Model 5 ve Model 10 da belirlenen yöntemle geliştirilen özelliklerdeki modellerin farklı veri setleri üzerinde de yüksek doğruluk oranına sahip çıktılar verebileceği çıkarımı yapılabilmektedir.

5.3 Tartışma

Hibrit tabanlı kestirimci bakım, genellikle makine öğrenimi, yapay zekâ ve geleneksel fiziksel modellerin, simülasyonların bir birleşimini ifade etmektedir. Başka bir deyişle hem veri tabanlı hem de fizik tabanlı yaklaşımın güçlü yönlerini bir arada kullanmaya çalışma olarak nitelendirilmektedir. Ancak, havacılık endüstrisinin gelişimiyle birlikte sistemler ve bileşenleri için hem veriler hem de sistemlerin karmaşıklığı artmaktadır. Bu, farklı veri türleri ve fiziksel modellerin birleştirilmesini karmaşık ve zor hale getirebilmektedir. Bu tür hibrit sistemler, farklı analiz yöntemlerini de birleştirdiği için entegrasyon süreci karmaşık olabilir ve yüksek bilgi ve uzmanlık gerektirebilmektedir. Bu yönüyle de hibrit modeller, genellikle daha fazla hesaplama gücü gerektirmektedir çünkü fiziksel modelleme ve veri analizi bir arada icra edilmektedir. Bu, büyük veri kümeleriyle çalışırken işlem sürelerini artırabilir. Bu da her alanda olduğu gibi havacılıkta da yüksek maliyet ve zaman gerektirmektedir. Fizik tabanlı kestirimci bakım ise mühendislik ve fiziksel modelleri kullanarak arızaların tahmin edilmesine dayanmaktadır. Bu

yaklaşım, daha derin bir anlayış ve hesaplama gerektirmektedir. Fizik tabanlı modeller genellikle karmaşıktır ve çok sayıda parametreyi doğru şekilde modellere entegre etmek çok kolay olmamaktadır. Özellikle havacılık gibi yüksek emniyet seviyesi gerektiren bir alanda, fiziksel modelleme bazen çok hassas ve detaylı olabilmekte ancak pratikte bu kadar karmaşık modellerin uygulanması oldukça zor olmaktadır. Havacılıkta uygulamaları denenen ancak takvim ve maliyet etkileriyle yeni yöntemlere arayış içerisinde bırakan bir yöntem olarak ifade edilmektedir (Hess ve Calvello, 2005; Erdoğan, 2024).

Bu çalışmada, hava araçları ve sistemlerinden toplanan verilerle derin öğrenme yöntemleri kullanılarak kestirimci bakım uygulanmasının potansiyel kazanımları öne çıkarılmaktadır. Ayrıca, bir derin öğrenme tekniği olan Uzun Kısa Vadeli Bellek ile gerçeğe yakınsayan tahmin sonuçlarına sahip RUL tahmini sağlayacak model geliştirilmesinin bakım verimliliğinin artırılması için fırsatlar sunulmaktadır. Havacılık sektöründeki gereksinimlerin farklılaşması, verilerin toplanması, kaydedilmesi ve analiz edilmesi alanlarındaki teknolojilerinin kullanımının yaygınlaşmasıyla beraber ilgili hava araçları ve hava aracı bileşenlerinden toplanan ve veri tabanına kaydedilen veriler de sürekli olarak artış göstermektedir. Hem bu ihtiyaçlar hem de Fizik tabanlı ve hibrit tabanlı yaklaşımdaki yüksek ekonomik ve altyapı isterleri nedeniyle verilerin işlenerek geliştirildiği kestirimci bakım ve prognostik yaklaşımlarının yaygınlaşması beklenmektedir.

Literatürdeki son yıllarda bu alanda yapılan çalışmalar incelendiğinde özellikle veri ön işleme adımlarında normalizasyon ve filtreleme tekniklerinin sıkça kullandığı gözlemlenmektedir. 2021 yılında yapılan bir çalışmada yapılan tahmin algoritmalarından önce normalizasyon olarak min-max tekniğinden farklı olarak z-skoru normalizasyonu kullanılarak model iyileştirilmiştir (Ruan ve Wu 2021). Farklı bir çalışmada ise kutu filtresinden farklı olarak uygulanan Savitzky-Golay filtreleme tekniği ile doğruluk oranının artırıldığı gözlemlenmiştir (Ouyang ve Chi, 2023). Bu çalışmada kullanılan min-max normalizasyonu ve kutu filtresi tekniği literatür taramaları sonucu seçilmiş ve modellere uygulanmıştır. Ancak literatürdeki çalışmalar incelenerek özellikle filtreleme ve normalizasyon uygulamalarındaki farklı yöntemler de denenerek modellerin en iyi sonuçları alacak şekilde optimize edilmesi ve sonuçları karşılaştırılması yönündeki yeni çalışmalar da önerilmektedir.

Bu çalışmada kullanılan veri setlerinin işlendiği literatürdeki diğer çalışmalar incelendiğinde benzer veri ön işleme adımlarının uygulandığı gözlemlenmektedir. Bir yüksek lisans tezi çalışmasında Batarya 5 ve Batarya 18 için geliştirilen ve normalizasyon uygulanarak geliştirilen Uzun Kısa Vadeli Bellek yöntemleri incelendiğinde: Batarya 5 için 0.0457 RMSE ve Batarya 18 için 0.0758 RMSE değerine sahip olan başka bir model geliştirildiği gözlemlenmiştir (Tunç, 2024). Bir başka çalışmada ise Derin Sinir Ağları metoduyla aynı veri seti üzerinde yapılan çalışma sonucunda 0.066 RMSE değerine sahip bir model geliştirilmiştir (Ren vd., 2018). Son dönemde yapılan analizler ve sonuçları incelendiğinde normalizasyon uygulanarak geliştirilen derin öğrenme tekniğinin zaman serisi verileri için gerekliliği öne çıkarılmaktadır (Lima ve Souza, 2023).

Batarya 18 için geliştirilen en yüksek doğruluk oranına sahip olan model 5 için MAE değeri 0.0260 ve RMSE değeri 0.0320 olarak elde edilmiştir. Model 5 ile aynı yöntemle fakat farklı bir Uzun Kısa Vadeli Bellek modeli geliştirilmesi; doğrulama tekniğinin uygulandığı farklı bir veri seti olan batarya 5 için de tekrar edildiğinde MAE değeri 0.0208 ve RMSE değeri 0.0271 doğruluk oranlarına sahip Model 10 elde edilmiştir. Bu çalışma da göstermektedir ki Model 5 için belirlenen Uzun Kısa Vadeli Bellek modeli geliştirme yöntemi farklı bir veri seti üzerine uygulandığında da bir öncekinden bile daha iyi sonuçlar verebilen bir model ortaya çıkabilmektedir. Elde edilen tüm sonuçlar, araştırmanın başlangıcında öne sürülen hipotezlerin geçerliliğini ortaya koymaktadır.

Havacılıkta kestirimci bakım uygulamalarının kullanımının artırılabilmesi için, farklı hava aracı sistem ve alt bileşenlerinde kullanılabilecek yüksek doğruluk oranına sahip ve maliyet etkin veri tabanlı yöntemi belirleme kapsamında filtreleme, normalizasyon, hiper parametre optimizasyonu gibi veri ön işleme adımları ve teknikleri üzerinde çalışılması ve bu uygulamalarının sonuçlarının karşılaştırılması önerilmektedir. Hava aracı sistemlerinin benzer çalışma ve veri üretme yeteneğine sahip sistemlerinin belirlenmesi de çalışmaların sonraki adımları için faydalı olacaktır. Çünkü, veri tabanlı kestirimci bakım benzer veri setleri üzerinde geliştirilen modellerin farklı alt sistem ve bileşenleri için kullanılarak RUL tahmini yapılmasını da mümkün kılmaktadır. Uzun Kısa Vadeli Bellek gibi derin öğrenme tekniklerinin uygulandığı veri tabanlı kestirimci bakım çalışmalarının havacılık alanındaki uygulamalarda maliyet etkin bakım yeteneği kazandırabileceği

gibi arızaları önden tespit etmeye yaramasıyla operasyonel verimliliği de artırabileceği öngörülmektedir.

6
SONUÇ

Bu çalışma, Batarya 18 için farklı yöntemlerle geliştirilen Uzun Kısa Vadeli Bellek tabanlı kestirimci bakım modellerinin doğruluğunu incelemiş ve Model 5 ile elde edilen sonuçların ardından, aynı geliştirme yöntemi kullanılarak Batarya 5 için yeni bir model (Model 10) oluşturulmuştur. Model 5 için Batarya 18 verileriyle elde edilen MAE değeri 0.0260 ve RMSE değeri 0.0320 iken, aynı yöntemle Batarya 5 üzerinde geliştirilen Model 10, MAE değeri 0.0208 ve RMSE değeri 0.0271 ile daha yüksek doğruluk oranlarına ulaşmıştır. Bu bulgular, araştırmanın başlangıcında öne sürülen hipotezlerin doğruluğunu ve geçerliliğini kanıtlar niteliktedir. Çalışma, geliştirilen Uzun Kısa Vadeli Bellek modelinin farklı veri setlerinde daha iyi sonuçlar elde edebilecek potansiyele sahip olduğunu da göstermektedir.

Bu çalışmanın sonuçları göstermektedir ki Uzun Kısa Vadeli Bellek modelleri arasında en iyi RMSE değerine sahip modellerin belirlenmesinde normalizasyon, filtreleme ve hiper parametre ayarları gibi farklı özelliklerin uygulanma kombinasyonları ile yapılan testlerin kıyaslamaları sonucu seçilen modelden daha yüksek doğruluk oranıyla tahminler elde edilebilecektir.

Elde edilen sonuçlar, havacılıkta kestirimci bakım uygulamalarının doğruluk oranlarını artırma potansiyeline sahip veri tabanlı yöntemlerin geliştirilmesine yönelik önemli bulgular sunmaktadır. Özellikle, batarya ve diğer sistem bileşenlerinde yüksek doğruluk oranlarına ulaşabilen modellerin geliştirilmesi, uçuş güvenliği ve bakım maliyetlerinin optimize edilmesi açısından kritik bir önem taşımaktadır. Bu bağlamda, veri ön işleme adımlarının – filtreleme, normalizasyon ve hiper parametre optimizasyonu gibi – sistematik bir şekilde uygulanması, bu tür modellerin başarısını daha da artırabilmektedir.

Gelecekteki araştırmalar için, farklı hava aracı sistemleri ve alt bileşenlerinin performansına odaklanarak, benzer veri üretim kapasitesine sahip sistemlerin belirlenmesi ve karşılaştırılması önerilmektedir. Bu tür bir yaklaşım, veri tabanlı kestirimci bakım sistemlerinin çok daha geniş bir yelpazede, farklı alt sistemler ve bileşenler için kullanılabilmesine olanak sağlayacaktır. Ayrıca, geliştirilen modellerin RUL tahmini gibi uygulamalarla entegrasyonu, bakım süreçlerinin daha etkin yönetilmesine ve sistem arızalarının önceden tespit edilerek uçuş güvenliğinin ve operasyonel kullanılabilirliğin artırılmasına katkı sağlayabileceği öngörülmektedir.

Sonuç olarak bu çalışma, havacılık sektöründe kestirimci bakım uygulamalarının yaygınlaştırılmasına yönelik önemli bir adım atılmasına olanak tanımış ve gelecekte yapılacak çalışmalar bir temel sunmuştur. Yüksek doğruluk oranlarına sahip veri tabanlı kestirimci bakım yöntemlerinin hem ekonomik hem de operasyonel açıdan önemli faydalar sağlayacağına vurgu yapılmaktadır.

KAYNAKÇA

Akkad, K., ve He, D. (2019, Haziran). A hybrid deep learning based approach for remaining useful life estimation. *IEEE International Conference on Prognostics and Health Management (ICPHM)*.

Arıkan, F., ve Yağlı, U. (2018). Hava Kuvvetleri Komutanlığı malzeme ihtiyaç planlaması tedarik tavsiye listesinin ÇKKV yöntemleri ile analizi. *Savunma Bilimleri Dergisi, 17*(1), 47-73.

Arias Chao, M., Kulkarni, C., Goebel, K., ve Fink, O. (2022). Fusing physics-based and deep learning models for prognostics. *Reliability Engineering and System Safe*ty, 217, 107961. https://doi.org/10.1016/j.ress.2021.107961

Aydın, Y., Erkmen, B., ve Gürpınar, C. (2022). Lityum-iyon bataryaların CWT tabanlı derin öğrenme yöntemleri ile kalan sağlıklı ömür (RUL) kestirimi. *Elektronik ve Haberleşme Mühendisliği Konferansı.* http://www.eleco.org.tr/ELECO2022/eleco2022_papers/127.pdf

Barış, C., Bilgin, A. C., ve Altan, A. (2021). Ampirik Kip Ayrıştırma Yöntemi ile Elde Edilen İçsel Kip Fonksiyonlarının Derin Öğrenme Tabanlı Rüzgâr Hızı Tahmin Modeli Başarımına Etkisinin Belirlenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (31), 661-669.

Bayrı, O., ve Akkaya, S. (2024). Prediction of the remaining useful life of lithium-ıon batteries based on an empirical mode approach with artificial neural networks. C*elal Bayar Üniversitesi Fen Bilimleri Dergisi, 20*(2), 1–13. https://doi.org/10.18466/cbayarfbe.1429043

Bell, J. (2008). *Condition based maintenance plus DoD guidebook*. Department of Defense of United States of America.

Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and Trends® in Machine Learning, 2*(1), 1–127. https://doi.org/10.1561/2200000006

Candan, B. (1997). *Uçak Yapısında Yorulma Nedenli Çatlakların Takibi Için Bilgisayar Yazılımı* (Master's thesis, Anadolu University (Turkey)).

Chakir, A., Andry, J. F., Ullah, A., Bansal, R., ve Ghazouani, M. (Eds.). (2024). *Engineering applications of artificial intelligence*. Elsevier.

Choi, Y., Ryu, S., Park, K., ve Kim, H. (2019). Machine learning-based lithium-ıon battery capacity estimation exploiting multi-channel charging profiles. *Special Section On Advanced Energy Storage Technologıes And Their Applications,* 7, 75143–75152. https://doi.org/10.1109/ACCESS.2019.2920932

DiPietro, R. (2024). Recurrent neural networks (RNNs) and LSTM. In *Handbook of medical image computing and computer assisted intervention*. Elsevier. https://doi.org/10.1016/B978-0-12-816176-0.00026-0

Dündar, D. R., Sarıçiçek, İ., Çınar, E., ve Yazıcı, A. (2021). Kestirimci bakımda makine öğrenmesi: literatür araştırması. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi, 29*(2), 256-276.

Erdoğan, M. (2024). *Havacılık Endüstrisinde Prognostik Sağlık Yönetimi Ve Veri Madenciliği* (Master's thesis, Yıldız Technical University (Turkey)).

Erdoğan, M., ve Mercimek, M. (2023). A comparative study on data pre-processing techniques for remaining useful life prediction of turbofan engines. *The International Journal of Materials and Engineering Technology, 6*(2), 50-58.

Farfade, S. S., Saberian, M., ve Li, L.-J. (2015). Multiview face detection using deep convolutional neural networks. In *Proceedings of the 5th ACM on International Conference on Multimedia Retrieval*. https://doi.org/10.48550/arXiv.1502.02766

Fornlöf, V. (2016). *Improved remaining useful life estimations for on-condition parts in aircraft engines*. Doktora Tezi. Skövde Üniversitesi.

Galstyan, A., ve Zhuravlova, L. (2011). *Aviation Fundamentals Student Guide On Practical and Laboratory Activity.* NAU Aerospace Institute.

General Electric Aerospace**.** (2023). *F110 engine datasheet* [Datasheet]. https://www.geaerospace.com/sites/default/files/2023_ge_aero_f110_datasheet_digital.pdf

Goebel, K., Saha, B., Saxena, A., Celaya, J. R., ve Christophersen, J. P. (2008). Prognostics in battery health management. *IEEE instrumentation & measurement magazine, 11*(4), 33-40.

Goodfellow, I., Bengio, Y., ve Courville, A. (2016). *Deep learning*. The MIT Press.

Gyazova, M. M., ve Vlaznev, I. D. (2020). Mathematical Method of Artificial Neural Networks in Aircraft Maintenance, Repair and Overhaul. *TEM Journal*, *9*(4), 1372.

Hess, A., Calvello, M. G., ve Frith, P. (2005). Challenges, issues, and lessons learned chasing the "Big P": Real predictive prognostics part 1. *IEEE Aerospace Conference*, 3610–3619.

Hochreiter, S. (1998). The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, *6*(02), 107-116.

Hu, Y., Huber, A., Anumula, J., ve Liu, S. C. (2018). Overcoming the vanishing gradient problem in plain recurrent networks. *arXiv preprint arXiv:1801.06105*.

Hunt, S. R., ve Hebden, I. G. (1998). Eurofighter 2000: an integrated approach to structural health and usage monitoring. The NATO Reasearch and Technology Organisation Meeting, 7.

İşcan, H., ve Dursun Kaygısız, A. (2024). Yapay Zekâ: Alt dalları ve uygulama alanları. *Aksaray Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, *16*(4), 201-234. https://doi.org/10.52791/aksarayiibd.1574207

Jennions, I. K. (Ed.). (2014). *Integrated vehicle health management: implementation and lessons learned*. SAE International.

Ji, Y., Chen, Z., Shen, Y., Yang, K., Wang, Y., ve Cui, J. (2021). An RUL prediction approach for lithium-ion battery based on SADE-MESN. *Applied Soft Computing, 104*, 107195.).

Jiang, N., Zhang, C., Cao, Y., ve Zhan, R. (2022). Application of prognostic and health management in avionics system. *Highlights in Science, Engineering and Technology, 7*, 1-9.

Kaelbling, L. P., Littman, M. L., ve Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of Artificial Intelligence Research*, 4, 237-285.

Karaman, B. (2004). *Aviyonik Ünitelerin Simulatör Sistemleri İçin Modellenmesi* (Master's thesis, Anadolu University (Turkey)).

Keller, K., Swearingen, K., Sheahan, J., Bailey, M., Dunsdon, J., Przytula, K. W., ve Jordan, B. (2006). Aircraft electrical power systems prognostics and health management. *IEEE Aerospace Conference* (pp. 12-pp).

Koschlik, A. K., Meyer, H., Arts, E., Conen, P., Jacob, G., Soria-Gomez, M., Kamtsiuris, A. A., Jilke, L., Aigner, J., Raddatz, F., ve Wende, G. (2023). Towards an Integrated Vehicle Health Management for Maintenance of Unmanned Air Systems. In *2023 International Conference on Unmanned Aircraft Systems (ICUAS)* (sf. 463-470).

Kumar, A., Shankar, R., ve Thakur, L. S. (2018). A big data driven sustainable manufacturing framework for condition-based maintenance prediction. *Journal of computational science*, *27*, 428-439.

Kwakye, A. D., Jennions, I. K., ve Ezhilarasu, C. M. (2024). Platform health management for aircraft maintenance–a review. *Journal of Aerospace Engineering, 238*(3), 267-283. https://doi.org/10.1177/09544100231219736.

Lima, F. T., ve Souza, V. M. (2023). A large comparison of normalization methods on time series. *Big Data Research*, *34*, 100407.

Maçin, F. (2019). *Lityum İyon Bataryalarda Parça Ömür Kestirimi* (Master's thesis, İstanbul Technical University (Turkey)).

Malhotra, P., Ramakrishnan, A., Anand, G., Vig, L., Agarwal, P., ve Shroff, G. (2016). LSTM-based encoder-decoder for multi-sensor anomaly detection. *arXiv preprint arXiv:1607.00148.*

McCollom, N.N, ve Brown, E.R. (2011). PHM on the F-35 Fighter. *IEEE Prodnostics and Health Management Conference*.

National Aeronautics and Space Administration. (2025). Data Sets [Batteries]. Retrieved from www.nasa.gov/intelligent-systems-division/discovery-and-systems-health/pcoe/pcoe-data-set-repository adresinden edinilmiştir.

Nilsson, N. J. (2010). *The quest for artificial intelligence: A history of ideas and achievements*. Cambridge University Press.

Nunes, P., Santos, J., ve Rocha, E. (2023). Challenges in predictive maintenance–a review. CIRP *Journal of Manufacturing Science and Technology, 40,* 53-67. https://doi.org/10.1016/j.cirpj.2022.11.004

Ouyang, J., ve Chi, C. (2023). The Prediction of Residual Electrical Life in Alternating Current Circuit Breakers Based on Savitzky-Golay-Long Short-Term. *Sensors, 23*(15), 6860.

Özdemir Kanat. (2023). Hava taşımacılığında bakım yönetimi uygulamaları. Yaşar M. (Ed.) *Hava Taşımacılığı Yönetimi Üzerine Araştırmalar* içinde (s. 59-82). Ankara. Detay Yayıncılık.

Öztemel, E. (2012). *Yapay sinir ağları* (3. baskı). Papatya Yayıncılık.

Park, K., Choi, Y., Choi, W. J., Ryu, H. Y., ve Kim, H. (2020). LSTM-based battery remaining useful life prediction with multi-channel charging profiles. IEEE Access, 8, 20786-20798. https://doi.org/10.1109/ACCESS.2020.2968939

Ramasso, E., ve Saxena, A. (2014). Performance Benchmarking and Analysis of Prognostic Methods for CMAPSS Datasets. *International Journal of Prognostics and Health Management,* 5(2), 1-15.

Ren, L., Zhao, L., Hong, S., Zhao, S., Wang, H., ve Zhang, L. (2018). Remaining useful life prediction for lithium-ion battery: A deep learning approach. *Ieee Access, 6*, 50587-50598.

Ruan, D., Wu, Y., ve Yan, J. (2021, May). Remaining useful life prediction for aero-engine based on LSTM and CNN. In *2021 33rd chinese control and decision conference (ccdc)* (pp. 6706-6712). IEEE.

Russell, S., ve Norvig, P. (2020). *Artificial intelligence: A modern approach* (4th ed.). Pearson.

SAE International. (2019). *Perspectives on integrating structural health monitoring systems into fixed-wing military aircraft* (Aerospace information report). SAE International.

SAE. (2013). *Guidelines for implementation of structural health monitoring on fixed wing aircraft* (Aerospace recommended practice ARP6461). SAE International.

Salakhutdinov, R., ve Hinton, G. (2009). Deep Boltzmann Machines. In Proceedings of the International Conference on Artificial Intelligence and Statistics (AISTATS) (3–11).

Sateesh Babu, G., Zhao, P., ve Li, X. L. (2016). Deep convolutional neural network based regression approach for estimation of remaining useful life. *Database Systems for Advanced Applications Lecture Notes in Computer Science*, sf. 214-228.

Scott, M. J., Verhagen, W. J., Bieber, M. T., ve Marzocca, P. (2022). A systematic literature review of predictive maintenance for defence fixed-wing aircraft sustainment and operations. Sensors, *22*(18), 7070. https://doi.org/10.3390/s22187070

Stanton, I., Munir, K., Ikram, A., ve El-Bakry, M. (2023). Predictive maintenance analytics and implementation for aircraft: Challenges and opportunities. *Systems Engineering, 26*(2), 216–237. https://doi.org/10.1002/sys.21651

Taylor, G. W., Hinton, G. E., ve Roweis, S. T. (2006). Modeling human motion using binary latent variables. In *Advances in Neural Information Processing Systems 19* (pp. 1345–1352). MIT Press.

Tunç, T. (2024). *Akıllı Batarya Kapasitesinin Derin Öğrenme Yöntemleriyle Tahmini* (Master's thesis, Başkent University (Turkey)).

Tunç, T., ve Erdem, H. (2024). Lityum iyon batarya için dikkat mekanizmalı geçitli tekrarlayan birim (GRU) sinir ağını temel alan sağlık durumu (SOH) tahmini. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 13*(2), 639-647. https://doi.org/10.28948/ngumuh.1407480

Turan, H., ve Yüksel, E. (2022). Sivil havacılık emniyet raporlaması konusunda EASA uygulamalarının incelenmesi. *The Journal of Academic Social Science, 134*(134), 383-393. https://doi.org/10.29228/asos.64402

U.S. Department of Defense. (2008). *Condition based maintenance plus (CBM+) DoD guidebook* (May 2008). U.S. Government Printing Office.

Xu, J., Wang, Y. Xu, Y., (2014). PHM-Oriented Integrated Fusion Prognostics for Aircraft Engines Based on Sensor Data, *IEEE Sensors Journal,* 14(4).

Yamaçli, V. (2024). State-of-health estimation and classification of series-connected batteries by using deep learning based hybrid decision approach. *Heliyon, 10*(20).

Yüksel, A. S., ve Atmaca, Ş. (2019). Sürücü Davranışlarının Makine Öğrenmesi Algoritmaları ile Sınıflandırılmasında Pencereleme Yönteminin Etkisi. *Teknik Bilimler Dergisi*, *9*(2), 75-80.

Zaman, T., ve Bayoumi, A. (2016). Estimation of economic effectiveness of hums equipped AH-64 aircraft: an ROI approach. *Proceedings of the Vertical Flight Society 72nd Annual Forum,* 1–8. https://doi.org/10.4050/F-0072-2016-11516

Zhang, X., Tang, L., ve Decastro, J. (2012). Robust fault diagnosis of aircraft engines: A nonlinear adaptive estimation-based approach. IEEE Transactions on Control Systems Technology, 21(3), 861-868.

Zhu, K., Zhang, C., Lu, N., ve Jiang, B. (2019). Data-driven RUL prediction of high-speed railway traction system based on similarity of degradation feature. In *2019 CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes* (sf. 292-297). IEEE.

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirileri

Gül, E. ve Kurt, S. (2025). Havacılıkta Kestirimci Bakım Uygulamasının Derin Öğrenme Tekniği ile Analizi. IV. *International Canakkale Scientific Studies Congress*, 4, 18-33.