KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME ALGORİTMALARI İLE KESTİRİMCİBAKIM ANALİZİ

VOLKAN AK

KOCAELİ 2023

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME ALGORİTMALARI İLE KESTİRİMCİBAKIM ANALİZİ

VOLKAN AK

Dr. Öğr. Üyesi A. Burak İNNER **Danışman**	**Kocaeli Üniv.**	**.....**
Dr. Öğr. Üyesi Kaplan KAPLAN **Jüri Üyesi,**	**Kocaeli Üniv.**	**.....**
Doç. Dr. Metin TOZ **Jüri Üyesi,**	**Karamanoğlu Mehmetbey Üniv.**	**.....**

Tezin Savunulduğu Tarih: 30.10.2023

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ

Kocaeli Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez/proje çalışmasında,

- Bu tezin/projenin bana ait, özgün bir çalışma olduğunu,
- Çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı,
- Bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi,
- Bu çalışmanın Kocaeli Üniversitesi'nin abone olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun olduğunu,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Tezin/Projenin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez/proje çalışması olarak sunmadığımı, beyan ederim.

(X) Bu tez/proje çalışmasının herhangi bir aşaması hiçbir kurum/kuruluş tarafından maddi/alt yapı desteği ile desteklenmemiştir.

☐ Bu tez/proje çalışması kapsamında üretilen veri ve bilgiler ..... tarafından ..... no'lu proje kapsamında maddi/alt yapı desteği alınarak gerçekleştirilmiştir.

Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Volkan AK

.

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI

Fen Bilimleri Enstitüsü tarafından onaylanan lisansüstü tezimin/projemin tamamını veya herhangi bir kısmını, basılı ve elektronik formatta arşivleme ve aşağıda belirtilen koşullarla kullanıma açma izninin Kocaeli Üniversitesi'ne verdiğimi beyan ederim. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları bende kalacak, tezimin/projemin tamamının ya da bir bölümünün gelecekteki makale, kitap, tebliğ, lisans, patent gibi çalışmalarda kullanımı, danışmanımın isim hakkı saklı kalmak koşuluyla ve her iki tarafın bilgisi dâhilinde bana ait olacaktır.
Tezin/projenin kendi özgün çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin/projenin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim kurulu tarafından yayınlanan ***"Lisanüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge"*** kapsamında tezim aşağıda belirtilen koşullar haricinde YÖK Ulusal Tez Merkezi/ Kocaeli Üniversitesi Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

☐ Enstitü yönetim kurulu kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.

☐ Enstitü yönetim kurulu gerekçeli kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 6 ay ertelenmiştir.

☒ Tezim/projem ile ilgili gizlilik kararı verilmemiştir.

Volkan AK

ÖNSÖZ VE TEŞEKKÜR

Tez çalışmamda bana desteklerini eksik etmeyen, bilgi ve tecrübesiyle yol gösteren, sunduğu çözüm önerileriyle farklı bakış açıları kazanmamı sağlayan ve makine öğrenmesi üzerine çalışmalar yapmama imkân veren kıymetli hocam Dr. Öğr. Üyesi A. Burak INNER'e teşekkürü bir borç bilirim. Tezimiz boyunca değerli destekleri ile yol gösteren fikir veren sayın Dr. Öğr. Üyesi Kaplan Kaplan hocama teşekkür ederim.

Tüm çalışmalarım boyunca beni destekleyen değerli ailem Ayşe AK, Muhammed Emin AK ve Arya AK'a teşekkür ederim. Değerli arkadaşım Günçağ Yıldız'a tez dönemi boyunca yaptığım çalışmalarda desteklerinden dolayı teşekkür ederim.

Ekim-2023 Volkan AK

İÇİNDEKİLER

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI ii
ÖNSÖZ VE TEŞEKKÜR iii
İÇİNDEKİLER iv
ŞEKİLLER DİZİNİ vi
TABLOLAR DİZİNİ vii
SİMGELER VE KISALTMALAR DİZİNİ viii
ÖZET ix
ABSTRACT x
1. GİRİŞ 1
2. GENEL BİLGİLER 7
2.1. Regresyon Yöntemleri 7
2.1.1. Doğrusal Regresyon 7
2.1.2. Destek Vektör Makinesi 8
2.1.3. Rastgele Orman Regresyonu 9
2.1.4. XGBoost Regresyonu 10
2.1.5. Sinir Ağları Modeli 11
2.1.6. Uzun Kısa Süreli Bellek 12
2.1.7. Evrişimsel Sinir Ağları 14
2.1.8. Dalgacık Dönüşümü ve Spektrogram 14
2.1.9. Hilbert Dönüşümü ve Hilbert Huang Dönüşümü 15
2.1.10. SHapley Additive exPlanations 16
2.1.11. Local Interpretable Model-Agnostic Explanations 17
3 MATERYAL VE METOT 19
3.1. Veri Seti 19
3.2.Makine Öğrenmesi Yöntemleri 22
3.2.1. Gözetimli Öğrenme 22
3.2.2. Gözetimsiz Öğrenme 22
3.2.3. Yarı Gözetimli Öğrenme 22
3.2.4. Pekiştirmeli Öğrenme 23
3.3. Zaman ve Frekans Dönüşümleri 23
3.3.1. Zaman Serilerinde Dalgacık Dönüşümü ve Spektrogram 23
3.3.2. Zaman Serilerinde Hilbert Huang Dönüşümü 23
4. DENEYSEL SONUÇLAR 26
4.1. Veri Ön İşleme 26
4.1.1 Normalizasyon 26
4.1.2 Aykırı Değerlerin Ayıklanması 26
4.1.3. PCA (Principal Component Analysis) Analizi 27
4.1.4. Sensör Korelasyonu ile Öznitelik çıkarımı 28
4.1.5. SHapley Additive Ex. ile Öz Niteliklerin Modele Etkisi 28
4.2.Regresyon Değerlendirme Metrikleri 31
4.1.1. Kök Ortalama Kare Hata- Root Mean Square Error 31

4.2.2. R^2 (R Kare- R Squared- Determination Katsayısı) 31
4.3. Kestirimci Bakım İçin Regresyon Çalışmaları 31
4.3.1. Wavelet Dönüşümü ve Hilbert Dönüşümü ile CNN-LSTM 31
4.3.2. Wavelet Dönüşümü ile LSTM 36
4.3.3. Hilbert Dönüşümü ile SVR 38
4.3.4. Önerilen Hilbert Huang Dönüşümü ve LSTM modeli 41
5. BULGULAR VE TARTIŞMA 46
6. SONUÇLAR VE ÖNERİLER 52
KAYNAKLAR 53
KİŞİSEL YAYIN VE ESERLER 56
ÖZGEÇMİŞ 57

ŞEKİLLER DİZİNİ

Şekil 2.1. Doğrusal regresyon grafiği 8
Şekil 2.2. SVM Çalışma Mantığı 9
Şekil 2.3. Random Forest Grafiği 10
Şekil 2.4. Yapay sinir ağları URL-3 12
Şekil 2.5. Dört Katmanlı Üç Adet LSTM Hücresi 13
Şekil 2.6. Dalgacık dönüşümü çeşitleri 15
Şekil 2.7 Özniteliklerin modele etkileri 17
Şekil 2.8 Lime ile özniteliklerin modele etkisi 18
Şekil 3.1 C-MAPSS veri setinde kullanılan sensörler 21
Şekil 4.1 Motorların Kalan yaşam döngüsü Histogramı 27
Şekil 4.2 Shap tekniği ile özniteliklerin model üzerindeki etkisi 29
Şekil 4.3 Motor ve sensör verilerinin RUL'a etkisi 30
Şekil 4.4 Hilbert Dönüşümü ile CNN-LSTM Blok Diyagram 34
Şekil 4.5 Hilbert dönüşümü ve CNN-LSTM modeli kayıp grafiği 35
Şekil 4.6. Wavelet CNN-LSTM Kayıp Grafiği 35
Şekil 4.7. Wavelet Dönüşümü ve LSTM Modeli 37
Şekil 4.8. Wavelet Dönüşümü ile LSTM 38
Şekil 4.9. Hilbert Dönüşümü ile SVR Kayıp Grafiği 39
Şekil 4.10. Hilbert Dönüşümü ile SVR Mimarisi 40
Şekil 4.11. Hilbert Dönüşümü LSTM Blok Diyagramı 42
Şekil 4.12. Hilbert Huang Dönüşümü LSTM Öğrenme Eğrisi 42
Şekil 4.13. HDD LSTM Gerçek ve Öngörülen RUL Değerleri 43
Şekil 4.14. Proje aşama adımları 43
Şekil 5.1. Projeler için seçilen farklı sensör seçimleri 48
Şekil 5.2. HD ile LSTM Çapraz Doğrulama ve RMSE değerleri 49
Şekil 5.3. Veri Ön İşleme ve Öznitelik Seçimi olmadan HHT ile LSTM 49
Şekil 5.4. Güvenlik kat sayısına göre bakım gerektiren motor sayısı 50

TABLOLAR DİZİNİ

Tablo 1.1. Literatürdeki Regresyon Modellerinin karşılaştırılması 5
Tablo 1.2. Önerilen Çalışmalar..... 6
Tablo 3.1. C-MAPSS Veri setinin açıklaması..... 20
Tablo 3.2. C-MAPSS FD001 ve FD004 veri setlerinin sütun açıklamaları 21
Tablo 4.1. Sensörler için Öznitelik Seçimi..... 27
Tablo 4.2. Wavelet CNN+LSTM Metrikleri..... 32
Tablo 4.3. Hilbert Dönüşümü CNN-LSTM regresyon modeli..... 32
Tablo 4.4. Wavelet LSTM regresyon modeli..... 36
Tablo 4.5. Hilbert SRV regresyon modeli..... 39
Tablo 4.6. Hilbert LSTM Model Metrikleri 41
Tablo 4.7. LSTM Modelinin Parametreleri..... 44
Tablo 5.1. Regresyon Modellerinin Karşılaştırılması 46
Tablo 5.2. Veri Ön işleme ve Öznitelik Seçimi..... 47

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

ADAM : Adaptive Moment Estimation (Adaptip Moment Tahmini)
ANN : Artificial Neural Network (Yapay Sinir Ağı)
CMAP : Commercial Modular Aero-Propulsion (Ticari Modüler Aero-İtici)
CNN : Convolutional Neural Networks (Evrişimli Sinir Ağları)
CBM : Condition Based Monitoring (Durum Tabanlı İzleme)
CWT :Continuous Wavelet Transform (Sürekli Dalgacık Dönüşümü)
DL : Deep Learning (Derin Öğrenme)
ELM : Extreme Learning Machine (Aşırı Öğrenme Makinesi)
EMD : Empirical Mode Decomposition (Ampirik Mod Dekompozisyonu)
HHD : Hilbert Transform (Hilbert Dönüşümü)
IMF : Internal Mode Frequencies (İçsel Mod Frekansları)
KB : Predictive Maintenance (Kestirimci Bakım)
LSTM : Long Short-Term Memory (Uzun Kısa Süreli Bellek)
MAE : Mean Absolute Error (Ortalama Mutlak Hata)
MAPE : Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
ML : Machine Learning (Makine Öğrenimi)
MLP : MultiLayer Perceptron (Çok Katmanlı Algılayıcı)
MSE : Mean Squared Error (Ortalama Kare Hata)
NASA : National Aeronautics and Space Administration (Ulusal Havacılık ve Uzay Dairesi)
PCA : Principal Components Analysis (Ana Bileşenler Analizi)
PEA : Prediction Error Analysis(Tahmin Hata Analizi)
PHM : Prognostics and Health Management (Prognostik ve Sağlık Yönetimi)
ReLU : Rectified Doğrusal Unit (Doğrutulmuş Lineer Birim)
RF : Random Forest Regression (Rastgele Orman Regresyonu)
RMSE : Root Mean Squared Error (Kök Ortalama Kare Hata)
RNN : Recurrent Neural Network (Tekrarlayan Sinir Ağı)
RLS : Recursive least squares (Yinelemeli en küçük kareler)
RUL : Remaining Useful Life (Kalan Faydalı Ömür)
SSR : Sum of Squares of Regresyonu (Regresyon Kareler Toplamı)
SVR : Support Vector Regression (Destek Vektör Regresyonu)
TFT : Time-Frequency Transform (Zaman-Frekans Dönüşümü)
Wavelet : Wavelet Transform (Dalgacık Dönüşümü)
XGB : Extreme Gradient Boosting(Aşırı Gradyan Artırma)

DERİN ÖĞRENME ALGORİTMALARI İLE KESTiRİMCİ BAKIM ANALİZİ

ÖZET

Bu tezde, üretim sektöründe Kestirimci Bakım (KB) stratejilerinin maliyet azaltma potansiyeli incelenmiştir. Üretim süreçlerinden kaynaklanan büyük veri hacminin, derin öğrenme algoritmaları ile etkin bir biçimde işlenmesi durumunda, hata tahmini ve tanısı açısından önemli avantajlar sağlayarak, işletme sürelerinin azalmasına, arızaların önlenmesine ve maliyetlerin düşürülmesine olanak tanıdığı belirlenmiştir. Araştırmada, Hilbert ve Wavelet Dönüşümleri ile zenginleştirilmiş Uzun Kısa Süreli Bellek (LSTM) modeli kullanılarak Kalan Kullanılabilir Ömür (RUL) tahminleri başarıyla gerçekleştirilmiştir. NASA tarafından sağlanan 100 Turbofan motoruna ait 21 sensör verisi analiz edilmiştir. Önceki çalışmalarda bu sensör verilerinin tamamının kullanılmadığı, seçici sensör verilerinin tercih edildiği gözlemlenmiştir. Bu çalışmada, veri setinin ön işleme aşamalarında min-max ölçeklendirme ve aykırı değer analizi uygulanmış ve model performansını artırmak, yüksek boyutlu verileri yönetmek ve hesaplama maliyetini azaltmak amacıyla Temel Bileşen Analizi (PCA) kullanılmıştır. Korelasyon değerleri 0.8'in üzerinde olan sensörler, tahmin doğruluğunu artırmak için özellik seçim sürecinde önceliklendirilmiştir. Veri setinin %80'i eğitim, %20'si ise test için ayrılmıştır. LSTM modeli, bu verilerle her motorun RUL değerini başarıyla tahmin etmiştir. Modelin performansı R-Kare (R^2) ve Kök Ortalama Kare Hata (RMSE) metrikleri ile değerlendirilmiş ve elde edilen sonuçlar, Doğrusal Regresyon, Rastgele Orman Regresyonu, Destek Vektör Makinesi, XgBoost ve Sinir Ağı modelleriyle karşılaştırılmıştır. Modelimizden Eğitimde 10.141 RMSE değeri, -0.104 R2 değeri ile Test için 12.43 RMSE, -0.066 R2 değeri elde edildi Bulgular, LSTM modelinin RUL tahminlerinde diğer yöntemlere göre daha etkili ve doğru olduğunu ortaya koymuştur. Tezin bulguları, LSTM modelinin Hilbert Dönüşümü ile RUL tahminlerinde güçlü ve doğru bir yöntem olduğunu, diğer yöntemlere kıyasla tahmin doğruluğu bakımından üstünlüğünü kanıtlamış ve RUL tahmin modellerinin performansını artırma yönünde gelecek çalışmalar için sağlam bir temel oluşturmuştur.

Anahtar Kelimeler: Derin Öğrenme, Kestirimci Bakım, Öznitelik Seçimi, Temel Bileşen Analizi, Uzun-Kısa Süreli Hafıza.

PREDICTIVE MAINTENANCE ANALYSIS WITH DEEP LEARNING ALGORITHMS

ABSTRACT

In this thesis, the efficacy of Predictive Maintenance (PM) in reducing costs within the manufacturing sector is explored. The study harnesses vast datasets from manufacturing processes, applying deep learning algorithms to significantly enhance error prediction and diagnosis, thereby reducing downtimes and failures. A Long Short-Term Memory (LSTM) model, incorporating Hilbert and Wavelet Transforms, was adeptly used for predicting the Remaining Useful Life (RUL) of machinery. The research focused on analyzing 21 sensor datasets from 100 NASA-provided Turbofan engines, noting that not all sensor data were consistently utilized across studies. Through preprocessing steps including min-max scaling and outlier analysis, along with Principal Component Analysis (PCA) for dimensionality reduction, the study managed high-dimensional data efficiently. Sensors with high correlation values were given priority in feature selection to increase predictive accuracy. The LSTM model was trained with 80% of the dataset and tested with the remaining 20%, successfully estimating RUL for each engine. Performance was evaluated against various models using metrics like R^2 and RMSE, revealing LSTM's superior precision in RUL prediction. From our model we obtained an RMSE value of 10.141 and an R2 value of -0.104 for Training and an RMSE value of 12.43 and an R2 value of -0.066 for Testing The findings confirmed the Hilbert-transformed LSTM model as a strong, accurate predictor, outshining other methods. This work establishes a foundation for future research to further improve RUL prediction model performance.

Keywords Deep Learning, Predictive Maintenance, Feature Selection, Principal Component Analysis Long Short-Term Memory.

1 GİRİŞ

Günümüzde, günlük faaliyetlerimiz büyük ölçüde tarımsal proses endüstrisinden güç sistemlerine ve otomotiv sektörüne kadar uzanan geniş bir yelpazede yer alan elektrikli ve mekanik ekipmanlara bağlıdır (Ellefsen, 2019). Endüstriyel ekipmanların bakım ve onarımı, işletmelerin karlılığını önemli ölçüde etkileyen bir faktördür (Yang ve Lin, 2019). Arızalar ve aksamalar, üretim sürecinde kesintilere ve maliyet artışlarına neden olabilir. Endüstrilerde yaygın olarak uygulanan üç bakım tekniği, reaktif bakım, önleyici bakım ve kestirimci bakımdır. Reaktif bakımda, onarım yalnızca makine arızalandığında gerçekleştirilir. Önleyici bakımda ise zamana dayalı bakım işlemleri uygulanarak arızalar önlenebilir. Kestirimci bakım (KB) ise, ekipmanın arızalanma zamanını tahmin etmeye olanak tanıyan bir yaklaşımdır (Abdussalam, 2020). KB, diğer iki bakım yönteminden farklı olarak, ekipmanların durum tabanlı izlenmesini (CBM) ve çeşitli makine parametrelerinin elde edilmesini gerektirir. Bu, kestirimci bakımın ve bakım stratejilerinin optimizasyonunun önemini vurgular. Kestirimci bakım, akıllı üretim ve Endüstri 4.0'ın bir parçası olarak bakım sürelerini ve maliyetlerini optimize etmeye yardımcı olur (Lee ve diğerleri, 2017). Yapay zekâ ve derin öğrenme tekniklerinin kullanımı, bu süreci daha da ileriye taşır. Bu teknikler, modelleme yoluyla hata tahminine odaklanır ve giriş sensorları ile zaman arasındaki bozulma eğilimlerini inceleyerek makinenin arızaya ne zaman geçeceğini tahmin etmeye çalışır. Bu bakım stratejisinin faydaları arasında, plansız duruş sürelerini azaltmak, bakım maliyetlerini düşürmek ve güvenlik açısından kritik durumlarda makinenin kullanım ömrünü en üst düzeye çıkarmak yer alır. Kestirimci bakım, ekipmanın durumunu izlemek ve arızaların oluşma olasılığını belirlemek için sensör verileri gibi farklı veri kaynaklarından yararlanır. Kestirimci bakım, üretim sürecinin verimliliğini ve güvenilirliğini arttırmanın yanı sıra enerji tasarrufu, atık azaltma ve çevresel etkiyi de iyileştirilmiştir (Yang ve Lin, 2019).

Derin öğrenme algoritmaları, karmaşık ve yüksek boyutlu verilerden özellik çıkarmak ve zaman serisi analizi yapmak için güçlü yeteneklere sahiptir.

Derin öğrenme algoritmalarından en yaygın olarak kullanılanlarından biri LSTM modelidir, uzun kısa vadeli bellek ağı zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenmek için geri beslemeli bir mimari kullanır.

Özellikle LSTM modeli, turbo fan motorlarının kalan kullanım ömrünü tahmin etmede etkili bir araç olarak ortaya çıkmıştır. Bu tezde, NASA turbo fan veri setinin derin öğrenme algoritmaları ile modellenmesi ve LSTM modeliyle karşılaştırılması yapıldı. Turbo fan veri seti, temel bileşen analizi kullanılarak boyut indirgemesi, ardından sensör korelasyon analizi ve özellik seçimi yapıldı. Son olarak, veri seti Hilbert dönüşümü ile işlenerek LSTM modelimize girdi olarak sunuldu.

Kahraman (2020), Uzun Kısa Süreli Bellek (LSTM) ve WaveNet kullanılarak kalan kullanım ömrünün tahmin edilmesine yönelik çözümler üretmiştir. C-MAPSS Turbo fan motor veri setinde FD001 ve FD003 alt kümeleri kullanılarak bozulma ve arızaları içeren jet motoru sensör verileri üzerinde deneysel çalışmalar yapmıştır. Elde edilen sonuçlar çeşitli değerlendirme metrikleri ve grafikler kullanılarak analiz edilmiştir. LSTM testlerinden elde edilen ortalama karesel hata (MSE) değerleri FD001 için 11,02 ve FD003 için 26,89' bulunmuştur. WaveNet testlerinden elde edilen MSE değerleri FD001 ve FD003 için sırasıyla 10,85 ve 20,71'dir. Son olarak testler, karar seviyesi füzyonu kullanılarak ve LSTM ile WaveNet modellerine ağırlıklı toplam kuralı uygulayarak değerlendirmiştir (Kahraman, 2020).

Muneer ve diğ. (2021), turbo fan motorların doğal asimetrik yaşam döngülerini göz önünde bulundurarak, kalan faydalı ömrünü (RUL) tahmin etme zorluğunu ele almıştır. Geleneksel yöntemler genellikle zamansal verilerin önemini göz ardı ederek daha az doğru tahminlere yol açar. Bunu düzeltmek için araştırmacılar, RUL tahminleri için dikkat temelli derin evrişimli sinir ağını (DCNN) tanıtmıştır ve FD001 test veri setinde 11,81'lik kayda değer bir RMSE ve 223 puanla bunun etkinliğini göstermiştir (Müneer, Taib, Fati,2021).

Sharma ve Gupta (2022) yaptıkları çalışmada, siber-fiziksel sistemler (CPS) fiziksel ortamı siber çerçevelerle entegre etmiştir ve bu tür sistemlerdeki tahmine dayalı bakım (PdM), makine verimliliğini artırmış ve maliyetleri azaltmıştır.

Bu araştırma çalışmasında, Turbo fan motorların (RUL) tahmin etmek için Zamansal Evrişim Ağlarının (TCN'ler) uygulamasını araştırmıştır. Çalışma, TCN'lerin etkinliğini CNN-LSTM ve optimize edilmiştir LSTM ağları gibi hibrit mimarilerle karşılaştırılmıştır.

Kapsamlı test senaryoları, ikili görevler için %94,47'ye kadar doğruluk ve çoklu etiket sınıflandırması için %98,7'ye kadar doğruluk göstermiştir (Sharma, Gupta, 2022).

Kong ve Cui (2019), ekipman bozulmasını analiz etmek için bir sağlık göstergesini (HI), evrişimli sinir ağı (CNN) ve uzun kısa süreli bellek (LSTM) bileşenleriyle birleştiren hibrit bir derin sinir ağıdır. Ham sensör verilerini tek boyutlu bir HI'ya dönüştüren ve hem CNN hem de LSTM katmanlarından yararlanan model, mekansal ve zamansal Öznitelikleri etkili bir şekilde yakalamıştır (Z.Kong, Y.Cui,2019).

CNN'nin paralel dalını LSTM ile seri halinde birleştiren bir çalışmada (Mo ve diğ., 2020), çok kafalı CNN-LSTM olarak adlandırılan bir RUL tahmin modelini tanıtmışlardır. Ayrıca, zaman serisi tahmin hata analizi (PEA) ile ağın bir kombinasyonunu önermişlerdir. Yinelemeli en küçük kareler (RLS) ve tek dereceli üstel düzeltme (SES) yoluyla tüm zaman serileri üzerindeki tahmin hataları, iki tahmin hata dizisinin her birinin üstel ağırlıklı hareketli ortalama (EWMA) ile analiz edilmesi ve bunların Fisher yöntemiyle birleştirilmesiyle, PEA'nın çıktısına ek girdi olarak CNN-LSTM ağına aktarmışlardır (Mo, Lucca, Malacarne, & Iacca, 2020)

Arıza tespiti için yapılan bir çalışmada (Liu ve Zhao, 2014), HHT olarak adlandırılan, motor arıza teşhisi (EFD) için gürültü tabanlı akıllı bir yöntem olan Hilbert-Huang dönüşümü (HHT) ve destek vektör makinesi (SVM) tekniklerine dayanarak geliştirilmiştir. Normal ve çeşitli arıza durumları altındaki örnek bir motorun gürültüleri ilk olarak, gürültü seviyesini ihmal edilebilir sinyal bozulmasıyla düşürmek için dalgacık paket eşik yöntemi kullanılarak ölçülmüş ve gürültüsü giderilmiştir.

Motorun arıza Özniteliklerini çıkarmak için HHT seçilmiş ve ölçülen gürültü sinyallerine uygulanmıştır.

Ampirik mod ayrıştırmasından (EMD), HHT marjinal spektrumunun maksimum değeri ve buna karşılık gelen frekans bileşeninden gelen yedi içsel mod fonksiyonundan (IMF'ler) oluşan dokuz boyutlu bir vektör, her bir motorun arıza özelliğini kullanmıştır (Liu, X., & Zhao, L. (2014).

Kankaya (2022), veri önişleme adımında 21 sensörden oluşan verilerden deneme yanılma yoluyla 6 tanesini kullanmıştır. Doğrusal Regresyon, SVM, Karar Ağaçları, Regresyon ağaçları, DVM, Gaus süreç regresyonu, Sinir Ağları yöntemlerini kullanırken, Ortalama Mutlak Hata (MAE), kök ortalama kare hata (RMSE) kriterlerine göre tahminleme başarı oranları kıyaslamıştır, Hassas Gauss DVM metodu overfitting olduğundan en başarısız tahminlemeleri yaparken, yapar sinir ağları en başarılı kalan faydalı ömür tahminlemelerini yapmıştır. Kalan faydalı ömür tahmini için RMSE ve MAE metriklerini kullanmıştır. Kankaya, LSTM modelinin kalan faydalı ömür tahmini için etkili bir yöntem olduğunu göstermiştir. RMSE değeri 14.35 ve MAE değeri 11,29 olarak bulmuştur.

Asadzade (2022), kalan faydalı ömür tahminlemesinde bulunurken Akış öğrenmeye dayalı Adaptive Random Forests yönteminden faydalanmıştır. Kalan faydalı ömür tahmini için RMSE, MAE ve MAPE metriklerini kullanmıştır. Asadzade, DBN modelinin kalan faydalı ömür tahmini için yüksek bir doğrulukla kalan faydalı ömür tahmini sağladığını göstermiştir. RMSE değeri 13.84, MAE değeri 10.86 ve MAPE değeri 0,16 olarak bulmuştur.

Kaner (2021), kalan faydalı ömür tahmini için iç ve dış halka arızalarının zarf analizi, bayes optimize edilmiş destek vektör makineleri, üç fazlı akım sinyalinden Arıza Tespiti için önerilen yöntem, evrişimsel sinir ağı yönteminden faydalanılarak SqueezeNet ve GoogleNet kriterlerine göre tahminleme başarı oranları kıyaslanmıştır. Kalan faydalı ömür tahmini için RMSE, MAE, MAPE ve R-kare metriklerini kullanmıştır. Kaner, Hilbert Dönüşümü ve LSTM modelinin kalan faydalı ömür tahmini için yüksek bir performans sergilediğini göstermiştir. RMSE değeri 13.67, MAE değeri 10.72, MAPE değeri 0.15 ve R-kare değeri 0,97 olarak bulmuştur.

Taşcı (2022), tezinde RF, XGB, SVR, MLP yönteminden faydalanmış kalan faydalı ömür tahmini için RMSE, MAE, MAPE ve korelasyon katsayısı metriklerini kullanmıştır.

Taşcı, SVR modelinin kalan faydalı ömür tahmini için başarılı bir yöntem olduğunu göstermiştir. RMSE değeri 14.02, MAE değeri 11.01, MAPE değeri 0.16 ve korelasyon katsayısı 0,96 olarak bulmuştur. Tezinde RF, XGB, SVR, MLP yönteminden faydalanmıştır.

Türe (2021), tezinde Doğrusal Reg, SVM,Rastgele Orman,Karar Ağacı, Stacking Ensemble Learning, CNN yönteminden faydalanmış ve Accuracy, RMSE, Standart Deviation kriterlerine göre tahminleme başarı oranları kıyaslamıştır. Kalan faydalı ömür tahmini için RMSE, MAE, MAPE ve R-kare metriklerini kullanmıştır. RMSE değeri 14.02, MAE değeri 11.01, MAPE değeri 0.16 ve korelasyon katsayısı 0,97 olarak bulmuştur. Bu kaynakların hepsi, kalan faydalı ömür tahmini için farklı sonuçlar elde etmiştir. Bu sonuçlar, kullanılan yöntemlerin performansını karşılaştırmak için bir temel oluşturmaktadır. Çalışmalarda NASA tarafından sağlanan C-MAPSS veri seti kullanılmaktadır. Bu veri seti, dört farklı çalışma koşulunda 218 adet turbo fan motorunun sensör verilerini içermektedir. Veri setindeki her motor için, ilk çalıştırma zamanından başlayarak son arıza zamanına kadar olan kalan faydalı ömür (kalan faydalı ömür) değeri vermiştir. Bu çalışmalarda, kalan faydalı ömür tahmini için farklı makine öğrenmesi ve derin öğrenme yöntemleri kullanılmıştır. Makine öğrenmesi yöntemleri, verilerden öğrenerek tahmin yapabilen algoritmaları ifade etmektedir. Derin öğrenme yöntemleri ise makine öğrenmesinin bir alt kümesi olarak, çok katmanlı yapay sinir ağları kullanarak karmaşık verilerden öğrenen algoritmaları ifade etmişlerdir.

Tablo 1.1. Literatürdeki Regresyon Modellerinin karşılaştırılması

Yazar	**Methodlar**	**Veri Ön İşleme**	**FD001 RMSE**	**FD004 RMSE**
(Z. Kong, Y. Cui,2019)	CNN+LSTM	Varyans Eşiği, Min-Max Normalizasyon	16.16	23.25
(H. Mo, F. Lucca,2020)	CNN+LSTM	Z Skor Normalizasyon	12.19	22.89
(H. Liu, Z. Liu,2020)	SVM	Desimal Ölçeklendirme, Min-Max Normalizasyon	12.42	21.50
(Liu, Xiong, Zhang, 2021)	TCN	Min-Max Normalizasyon	18.01	
(Muneer, Taib, Fati,2021)	DCNN	Öngörülebilirlik Metriği	11.81	19.88
(Sharma, Gupta, 2022)	TCN	Z Skor Veri Normalizasyon	18.44	29.15

Tablo 1.1'de gösterilen Literatürdeki Regresyon Modellerinin karşılaştırılması, RUL tahmini için farklı makine öğrenmesi ve derin öğrenme yöntemlerinin kullanıldığını ve farklı veri ön işleme adımları kullandıklarını göstermektedir. Bu kaynaklardan elde edilen sonuçlar, kullanılan yöntemlerin performanslarının karşılaştırılmasına imkân sağlamaktadır.

Tablo 1.2'de görüldüğü gibi Hilbert Dönüşümü ve LSTM modelinin RUL tahmini için en iyi performansı sergilemiştir. Hilbert Dönüşümü ve LSTM modeli, RMSE, MAE, MAPE ve R-kare değerleri açısından diğer yöntemlerden daha iyi sonuçlar vermiştir. Bu sonuçlar, Hilbert Dönüşümü ve LSTM modelinin zaman serisi verilerini işlemek için uygun bir yöntem olduğunu ve verilerdeki uzun vadeli bağımlılıkları öğrenebildiğini göstermektedir.

Tablo 1.2. Önerilen Çalışmalar

Yazar	**Metotlar**	**Veri Ön İşleme Teknikleri**	**FD001 RMSE**	**FD004 RMSE**
Çalışma	LSTM with Wavelet	Min-Max veri normalizasyonu, Korelasyon ve Temel bileşen analizi	12,64	35.29
Önerilen Çalışma	LSTM with Hilbert	Min-Max veri normalizasyonu,Korelasyon ve Temel bileşen analizi, Shap Tekniği	**12,4349**	21.08

Tez çalışmasının birinci bölümünde bakım, bakım çeşitleri, kestirimci bakım ile ilgili genel bilgiler verilirken literatürdeki diğer uçak motorları için yapılan kalan faydalı ömür tahminleme çalışmalarına yer verildi. İkinci bölümde klasik ve derin öğrenme regresyonları ile ilgili temel bilgilere yer verildi. Üçüncü bölümde kullanılan veri setinin analizi, açıklanması ve makine öğrenmesi yöntemleri hakkında temel bilgiler verildi. Dördüncü bölümde turbo jet motoru verileri kullanılarak Wavelet ve Hilbert Dönüşümleri ile kullanılan regresyon algoritma deneylerinin ve sonuçların değerlendirilmesinin yapılmasına yer verildi.

2 GENEL BİLGİLER

Bu çalışmada, temel istatistiksel regresyon yöntemleri ve gelişmiş makine öğrenmesi algoritmaları kapsamlı bir şekilde ele alınmıştır. İlk olarak, bağımlı ve bağımsız değişkenler arasındaki doğrusal ilişkiyi inceleyen Doğrusal Regresyon metodolojisi incelenmiştir. Ardından, SVM ve Rastgele Orman Regresyonu gibi daha karmaşık yöntemlerle modellemeye geçilmiştir. Bu modeller, veri setleri üzerinde doğrusal olmayan ilişkileri çözümlemek için kullanılır ve genellikle sınıflandırma ve regresyon görevlerinde etkilidirler. XGBoost regresyonu ise, gradient boosting yöntemini temel alarak güçlendirilmiş bir regresyon modeli sunar ve performansı arttırmak için optimize edilmiştir.

Sinir Ağları Modeli, biyolojik nöronların işleyişinden esinlenerek geliştirilen ve özellikle karmaşık veri yapılarını modellemek için kullanılan bir öğrenme modelidir. LSTM ve CNN gibi derin öğrenme yapıları ise, özellikle zaman serisi verileri ve görüntü işleme gibi alanlarda başarılı sonuçlar verir.

Çalışmanın bir diğer önemli kısmı, zaman ve frekans dönüşümlerine ayrılmıştır. Burada, sinyallerin zamanla değişen frekans ve genlik Özniteliklerini analiz etmek için kullanılan Wavelet ve Hilbert Huang Dönüşümleri gibi matematiksel işlemler açıklanmıştır. Son olarak, modelin açıklana bilirliği üzerinde durulmuş, SHAP ve LIME gibi tekniklerle modellerin karar verme süreçlerinin şeffaflaştırılması ve yorumlanabilir hale getirilmesi amaçlanmıştır. Bu sayede, karmaşık modellerin tahminleri daha anlaşılır ve güvenilir bir biçimde sunulabilir. Bu teknikler, özellikle "kara kutu" olarak adlandırılan modellerin iç işleyişini açığa çıkarmak için hayati önem taşır.

2.1. Regresyon Yöntemleri

2.1.1 Doğrusal Regresyon

Doğrusal Regresyon, bir bağımlı değişkenin bir veya daha fazla bağımsız değişkenle doğrusal ilişkisini modelleyen istatistiksel bir regresyon yöntemidir. Bu yöntem, veri noktaları arasındaki ilişkiyi bir doğru çizgi ile temsil ederek, bağımlı değişkenin değerini tahmin etmeyi amaçlamıştır (Field, 2018).

Doğrusal Regresyon, bir bağımsız değişkenin kullanıldığı durumdur. Bağımlı değişken ile bağımsız değişken arasındaki ilişkiyi en iyi açıklayan bir doğru çizgi bulunmaya çalışılır. Bu doğru, bağımlı değişkenin tahmin edilmesi için kullanılır.

Çoklu Doğrusal Regresyon, birden çok bağımsız değişkenin kullanıldığı durumdur. Bu yöntemde, bağımlı değişkenin değeri, birden çok bağımsız değişkenin doğrusal kombinasyonu ile tahmin edilmeye çalışılır. Her bir bağımsız değişkenin katsayısı, regresyon modelinin parametrelerini temsil eder.

Şekil. 2.1'de Doğrusal regresyon örnek grafiği verilmiştir. Doğrusal Regresyon modeli, veri setindeki ilişkileri analiz etmek, değişkenler arasındaki etkileri ölçmek ve tahminler yapmak için kullanılır. Modelin başarı ölçütü, hata kareler toplamını (RSS) veya açıklanan varyansı (R-kare) gibi istatistiksel metriklerle değerlendirmiştir (Field, 2018).

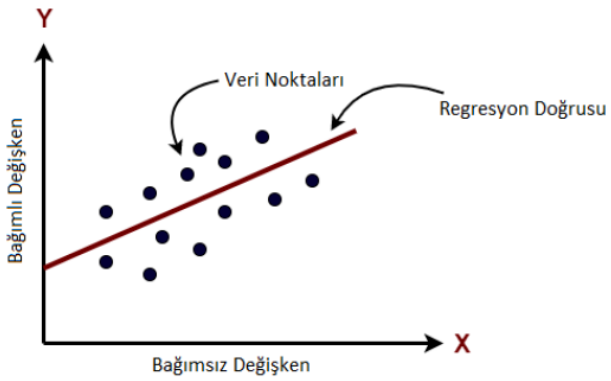

Şekil 2.1. Doğrusal regresyon grafiği (URL-1)

2.1.2 SVM (Destek Vektör Makinesi)

Destek Vektör Makinesi, bir makine öğrenmesi algoritmasıdır ve sınıflandırma ve regresyon problemlerini çözmek için kullanılır (Vapnik, 1997).

SVM'nin temel amacı Şekil 2.2'deki grafikteki gibi veri noktalarını sınıflara ayıran bir hiper düzlemi bulmaktır. Hiper düzlem, veri setini en iyi şekilde bölebilen bir düzlem, doğru veya çoklu boyutlu uzayda bir düzlemdir.

SVM, bu hiper düzlemi bulurken maksimum marjinal ayrımı hedefler. Marjin, hiper düzlemle en yakın veri noktaları arasındaki mesafeyi temsil eder. SVM, bu mesafeyi maksimize ederek, sınıflar arasında bir "boşluk" oluşturmaya çalışır.

SVM, sınıflandırma, regresyon, görüntü sınıflandırma, metin sınıflandırma, biyoinformatik analiz ve el yazısı tanıma gibi birçok uygulama alanında kullanılan güçlü bir makine öğrenmesi algoritmasıdır (Christ, 1997).

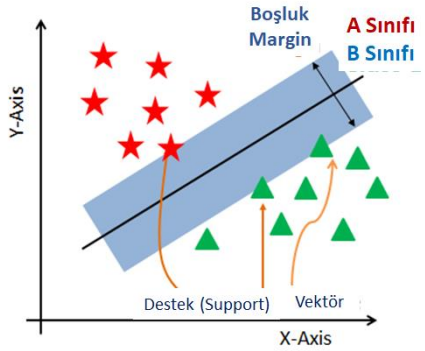

Şekil 2.2. SVM Çalışma Mantığı (URL-2)

2.1.3 Rastgele Orman Regresyonu

Rastgele Orman, sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan bir Denetimli Makine Öğrenimi Algoritmasıdır. Sınıflandırma için çoğunluk oylamasını ve regresyon için ortalama değerleri kullanarak farklı örnekler üzerinde karar ağaçları oluşturur. Algoritma, temel yapı taşı olarak karar ağaçları ile topluluk tabanlı bir yöntem oluşturur. Karar ağaçları, veri kümesini belirli kurallara bölerek ve bilgi kazancını en üst düzeye çıkararak tahminler yapar; ancak verilere aşırı uyum sağlaması ana sorunlarından biridir.

Bu sorunu çözmek için Rastgele Orman modeli, hem özellik kümesinden hem de veri kümesinden rastgele birden fazla alt küme seçer ve bunları ayrı ayrı eğitirken, sırasıyla bir regresyon veya sınıflandırma problemi olup olmadığına bağlı olarak tüm bu alt ağaçlar arasında en çok oy alan tahmini seçen veya ortalamasını alan yüzlerce bireysel karar ağacı oluşturur (Hastie, 2021).

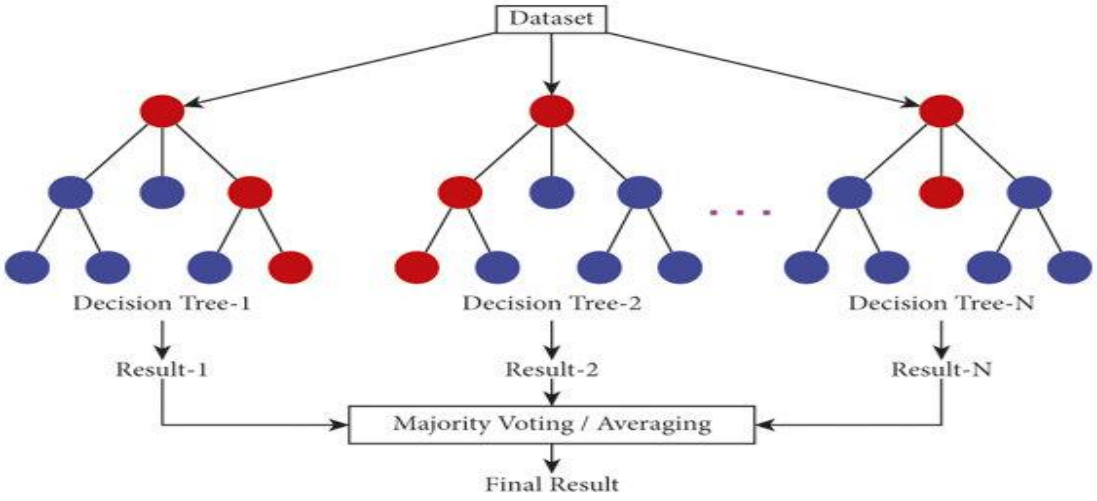

Şekil 2.3. Random Forest Grafiği (Khan ve Nızami, 2021)

Şekil 2.3'te grafiği verilen rastgele orman modelinin ayırt edici Özniteliklerinden biri, bir niteliğin bağımlı değişkendeki varyansı açıklamaya ne kadar katkıda bulunduğunu gösteren niteliklerin önemi hakkında bilgi sağlama yeteneğidir. Bu, algoritmaya x sayıda nitelik arasından y'yi seçmesi talimatını verebileceğimiz ve gerekirse bu bilgiyi istenen başka bir modelde kullanabileceğimiz anlamına gelir. Random Forest modeli, makine öğrenimi alanında sınıflandırma ve regresyon problemlerini çözmek için kullanılan bir topluluk öğrenimi (ensemble learning) algoritmasıdır. Bu model, birden fazla karar ağacını bir araya getirerek bir tahmin yapar ve bu nedenle "orman" olarak adlandırılır (Loh, 1999).

Random Forest modeli, ağaçları birleştirerek, bir veri noktasının sınıflandırılması için tüm ağaçların tahminlerini bir araya getirir. Sınıflandırma problemlerinde, bir veri noktası sınıflandırılırken, hangi sınıfa daha fazla ağaç tarafından tahmin edildiği belirlenir ve bu sınıf seçilir. Regresyon problemlerinde, bir veri noktası için tüm ağaçların tahminleri alınarak bir ortalama veya medyan hesaplanır (Hastie, 2021).

2.1.4 XGBoost Regresyonu

XGBoost, "Extreme Gradient Boosting" anlamına gelir ve makine öğrenmesi için kullanılan bir algoritmadır. Gradient boosting'in bir şekli olan XGBoost, birden çok ağaç modelini birleştirerek ve her birini öncekilerin hatalarını düzeltmek için kullanarak bir tahmin yapar.

Bu, birçok zayıf öğreniciyi (ağaçları) birleştirerek bir güçlü öğrenici oluşturur. Verimliliği ve etkililiği artırmak için çeşitli teknikleri ve optimizasyonları içeren bir gradyan artırma çeşididir (Pan, 2018).

Gradient boosting, hatalarını azaltmak ve doğruluğunu artırmak için modelin daha önceki tahminlerini kullanır. XGBoost, bu süreci daha verimli ve etkili hale getiren bir dizi teknik ve optimizasyon kullanır. Örneğin, paralel işleme ve ağaç dallanmasını etkin bir şekilde yönetme yeteneği, XGBoost'un büyük veri kümeleri üzerinde hızlı ve etkili olmasını sağlar (Chakraborty, 2021).

2.1.5 Sinir Ağları Modeli

Sinir ağları, biyolojik sinir ağlarının yapısından ve işlevinden ilham alan bir tür makine öğrenimi algoritmasıdır. Sinir ağları, bilgiyi işleyen ve ileten birbirine bağlı "nöron" adı verilen birimlerden oluşur. Her nöron, girdi olarak aldığı sinyalleri işler ve çıktı olarak başka nöronlara sinyal gönderir. Her bağlantıda bir ağırlık vardır ve bu ağırlık öğrenme sürecinde ayarlanır. Ağırlık, bağlantıdaki sinyalin gücünü arttırır veya azaltır. Nöronların çıktısı, girdilerinin toplamının bir doğrusal olmayan fonksiyonu ile hesaplanır (Butte et al., 2018).

Sinir ağları, verilerden öğrenebilir, tahminlerde bulunabilir, verileri kalıplara göre sınıflandırabilir ve eğitildikleri örneklerin ötesinde genellemeler yapabilir. Sinir ağlarının ana avantajlarından biri, verilerden öğrenme yetenekleridir; bu, daha fazla örnek gördükçe zaman içinde gelişebilecekleri anlamına gelir. Bu özellikle, konuşma tanıma, görüntü tanıma ve doğal dil işleme gibi verilerin karmaşık veya dinamik olduğu uygulamalar için kullanışlıdır. Sinir ağlarının bir diğer avantajı da genelleme yapma yetenekleridir. Yani eğitim verilerinden öğrendikleri kalıplara dayalı olarak yeni ve görünmeyen veriler üzerinde tahminler veya sınıflandırmalar yapabilir.

Bu, sistemin yeni ve öngörülemeyen durumlara dayalı kararlar alması gereken sürücüsüz araçlar gibi çok çeşitli uygulamalarda kullanışlı olmalarını sağlar (Hopfield, 1982).

Sinir ağlarının eğitimi, Sinir ağına bilinen bir "girdi" ve "sonuç" içeren bir örnek verilir. Sinir ağı girdiyi işleyerek bir "çıktı" üretir.

Bu çıktı ile sonuç arasındaki fark hata olarak hesaplanır. Sinir ağı daha sonra hatayı kullanarak ve bir öğrenme kuralına göre bağlantılardaki ağırlıkları ayarlar. Bu ayarlamalar tekrarlandıkça sinir ağı ürettiği çıktıyı sonuca yaklaştırır. Belirli kriterlere göre eğitim sonlandırılır. Bu gözetimli öğrenme olarak adlandırılır.

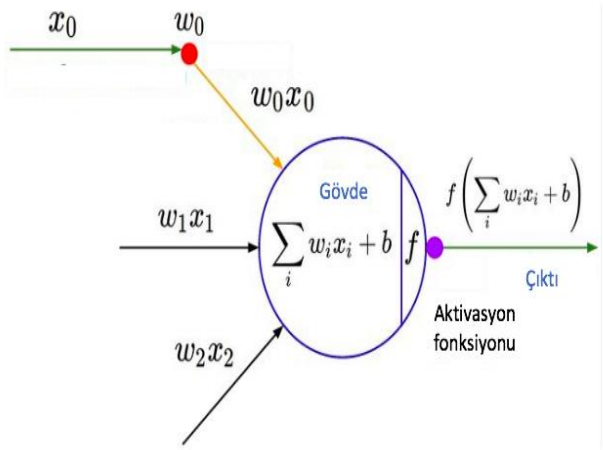

Şekil 2.4. Yapay sinir ağları URL-3

Şekil 2.4.'de ki Yapay sinir ağı (Neural Network), insan beyninin işleyişinden esinlenerek geliştirilmiş bir makine öğrenimi modelidir. Bu model, birçok sinir hücresinden oluşan ve bu hücreler arasında iletişim kuran bir ağ olarak düşünülebilir. Ancak, çok katmanlı yapay sinir ağı modelleri (deep neural network) daha yaygın olarak kullanılmaktadır. Bu modeller, girdilerin birden fazla katman üzerinde işlendiği ve son katmanda bir çıktı üretildiği bir yapıya sahiptir. Her katman, önceki katmanların çıktılarını girdi olarak alır ve kendi içindeki sinir hücreleri arasında bir iletişim kurar.

2.1.6 LSTM (Uzun Kısa Süreli Bellek)

LSTM modeli, özellikle zaman serisi verileri veya uzun bağımlılık ilişkileri içeren veri setlerinin analizinde başarılıdır. LSTM modeli, geleneksel yapay sinir ağı modellerinden farklı olarak, hafıza hücreleri ve kapı mekanizmalarıyla donatılır. Bu Öznitelikler sayesinde, LSTM modeli, geçmiş bilgileri koruyabilme yeteneğine sahiptir ve uzun vadeli bağımlılıkları daha etkili bir şekilde modelleyebilir (Liu, 2021).

Şekil 2.5'te grafiği verilen LSTM modeli, zaman serisi tahmini, metin analizi, dil işleme, konuşma tanıma ve çeviri gibi çeşitli uygulamalarda başarıyla kullanılmaktadır. Uzun vadeli bağımlılıkları ele alabilme yeteneği sayesinde, LSTM modeli, özellikle zaman içinde değişen ve karmaşık ilişkiler içeren verilerin analizinde tercih edilen bir yöntemdir.

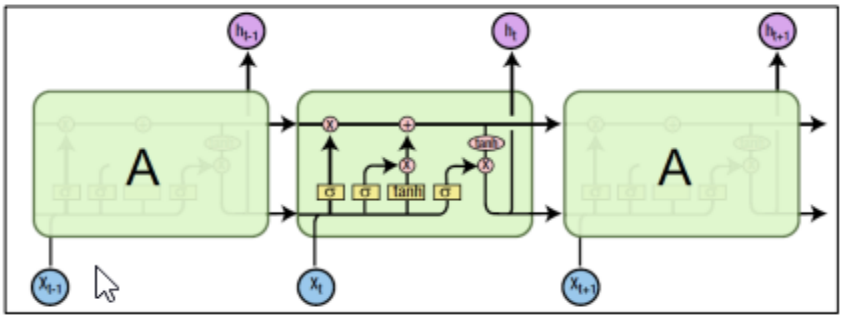

Şekil 2.5. Dört Katmanlı Üç Adet LSTM Hücresi (Olah, 2015)

Giriş verilerinin işlenmesi ilk adımda, LSTM'ye giriş olarak sıralı veriler verilir. Bu veriler, örneğin bir zaman serisi veya bir cümle gibi, adım adım işlenecek olan verilerdir.Hafıza hücresine bilgi aktarımı giriş verileri, LSTM'nin hafıza hücresine aktarılır. Hafıza hücresi, geçmiş bilgiyi saklamak ve gelecekteki analizlerde kullanmak için kullanılır.

Giriş kapısı, giriş kapısı olarak adlandırılan bir kapı mekanizması tarafından kontrol edilir. Giriş kapısı, hangi bilgilerin hafıza hücresine ekleneceğini belirler.

Unutma kapısı, hafıza hücresindeki gereksiz veya geçerli olmayan bilgilerin temizlenmesi için unutma kapısı kullanılır. Bu kapı, hangi bilgilerin hafıza hücresinden silineceğini belirler.

Hafıza güncellemesi, giriş kapısı ve unutma kapısı tarafından kontrol edilen bilgiler, hafıza hücresine gönderilir ve mevcut hafızayı günceller.

Çıkış kapısı, Hafıza hücresindeki güncellenmiş bilgiler çıkış kapısı tarafından kontrol edilir ve çıktı olarak kullanılır. Bu çıktı, tahminler, sınıflandırma sonuçları veya metin üretimi gibi çeşitli şekillerde olabilir.

2.1.7 CNN (Evrişimsel Sinir Ağları)

Evrişimsel Sinir Ağları, derin öğrenme algoritmalarının bir alt sınıfıdır.

Temel olarak görsel veri işleme görevlerinde sıklıkla kullanılan bu ağlar, özellikle görüntü tanıma, görüntü sınıflandırma, yüz tanıma ve benzeri görevlerde oldukça başarılı sonuçlar vermektedir (Alves ve diğ., 2020).

Düzgünleştirme (Convolution) katmanı, giriş verisine (genellikle bir görüntü) belirli bir filtreyi uygulayarak özellik haritaları oluşturur. Filtre, giriş verisinde belirli Öznitelikleri (örneğin kenarlar, köşeler) tespit etmek için kullanılır. Havuzlama (Pooling) katmanı, düzgünleştirme katmanından elde edilen özellik haritalarının boyutunu azaltmayı amaçlar. Bu, ağı hızlandırırken aynı zamanda aşırı öğrenmeyi (overfitting) azaltmaya yardımcı olur.

Tam bağlantı (Fully Connected) katmanı, ağın sonunda bulunur ve tüm nöronları bir önceki katmandaki nöronlara bağlar. Genellikle sınıflandırma görevlerinde, hangi sınıfa ait olma olasılığını belirlemek için kullanılır. Düzeltici Doğrusal Ünite (ReLU) aktivasyon fonksiyonu, ağa doğrusal olmayan bir dinamik kazandırır. Bu özellik sayesinde, ağ karmaşık fonksiyonları modelleme yeteneğine sahip olur. CNN'lerin avantajları arasında, yerel Öznitelikleri yakalama yeteneği, ağırlık paylaşımı sayesinde daha az parametreyle karmaşık Öznitelikleri öğrenme yeteneği ve havuzlama katmanları sayesinde ölçeklendirilebilirdik bulunmaktadır (Alves ve diğerleri, 2020).

2.1.8 Wavelet (Dalgacık) Dönüşümü ve Spektrogram

Dalgacık dönüşümü, sinyallerin zaman-frekans gösterimini elde etmek için kullanılan matematiksel bir dönüşüm fonksiyonudur. Dalgacık dönüşümü, sinyalin düşük frekanslı (yaklaşık) ve yüksek frekanslı (detay) bileşenlere ayrılmasını sağlar (Rajaee ve diğ., 2009). Bu çalışmada C-MAPSS zaman serisinde gürültü azaltımı için dalgacık dönüşümü uygulandı. Farklı dalgacık dönüşümlerini Şekil 2.6 de görebilmekteyiz. Mexican Hat dalgacık dönüşümü, bir sinyalin farklı frekans bileşenlerini analiz etmek için kullanılır.

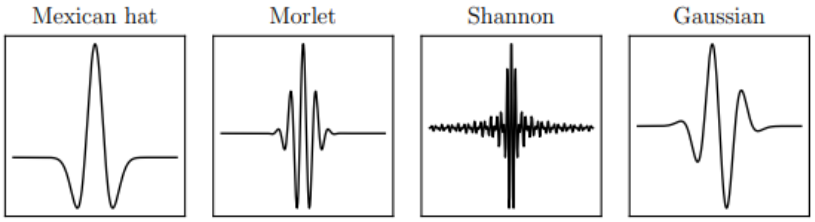

Şekil 2.6. Dalgacık dönüşümü çeşitleri

İsmi, tipik sombrero şapkasını andıran çan şekli nedeniyle konmuştur ve genellikle sinyallerdeki ani değişimleri tespit etmede kullanılır. Morlet dalgacığı, bir kosinüs dalgasının Gaussian fonksiyonu ile modülasyonu sonucu oluşur ve zaman-frekans analizinde kullanılan popüler bir dalgacık türüdür. Hem zaman hem de frekans bilgisini iyi bir çözünürlükle sağlar.Shannon dalgacığı, bilgi teorisindeki Shannon entropi kavramından türetilmiştir ve genellikle sinyal işlemede bant sınırlı sinyallerin analizi için kullanılır. Bu dalgacık, belirli frekans bantlarındaki bilgiyi izole etmede etkilidir.Gaussian dalgacık dönüşümü, Gaussian fonksiyonunun türevleri kullanılarak elde edilir. Bu dalgacık, sinyallerdeki yumuşak geçişleri ve trendleri analiz etmek için idealdir, çünkü Gaussian fonksiyonu düzgün bir geçiş sağlar.

2.1.9 Hilbert Dönüşümü ve Hilbert Huang Dönüşümü

Hilbert Dönüşümü, sinyal işlemede kullanılan matematiksel bir araçtır. Bir sinyalin zamandan frekansa dönüşümünü sağlayan Fourier Dönüşümü ile benzerlik gösterir, ancak Hilbert Dönüşümü sinyalin anlık faz ve genlik bilgisini elde etmek için kullanılır. Bu dönüşüm, herhangi bir gerçek zamanlı sinyali, orijinal sinyalin 90 derece faz kaydırılmış bir analitik sinyaline dönüştürür. Böylece, sinyalin anlık genliği ve fazı hakkında bilgi edinilebilir ki bu da modülasyon teorisi ve sinyal analizi gibi alanlarda oldukça faydalıdır.

Hilbert-Huang Dönüşümü ise, sinyal işlemede kullanılan bir başka yöntem olup, özellikle doğrusal olmayan ve durağan olmayan veri serilerinin analizi için geliştirilmiştir.

HHT, Empirical Mode Decomposition (EMD) olarak adlandırılan bir süreçle başlar. EMD, bir sinyali doğal modlarına ayırır ve bu modlar, İçsel Mod Fonksiyonları (IMF) olarak bilinir. Her IMF, Hilbert Dönüşümü uygulandığında anlık frekans bilgisine dönüştürülebilir.

Böylece, HHT, bir sinyalin zaman içindeki değişen frekans ve genlik Özniteliklerini çözümleyebilen güçlü bir araçtır ve özellikle mühendislik ve finans gibi alanlarda kullanılır (Liu ve Diğ., 2014).

2.1.10 SHapley Additive exPlanations

SHAP (Shapley Additive exPlanations), makine öğrenimi modellerinin karar verme süreçlerini açıklamak ve yorumlamak için kullanılan bir tekniktir. SHAP, oyun teorisinden türetilen Shapley değerleri konseptini kullanarak, bir modelin tahmininde her bir özelliğin ne kadar etkili olduğunu belirler. Şekil 2.7'de örnek olarak gösterilen bu teknik, özellikle karmaşık modellerin (örneğin, rastgele ormanlar, gradient boosting makineleri, derin öğrenme modelleri) "kara kutu" olarak görülen karar verme süreçlerini anlaşılır hale getirmeye yardımcı olur. SHapley Additive exPlanations(Shap) ile Öz Niteliklerin Modele Etkisi konusunda Shap grafiği detaylı açıklanacaktır.

Klasik öznitelik (Feature importance) hesaplamalarından farklı olarak, SHAP ile çoklu sınıflandırma modellerinde, özniteliklerin sınıflandırma tipine göre sonuca hangi oranda etki ettiği de gözlemlenebilir fakat özelliğin modelin tahminine katkısını veya önemini gösterirken, tahminin kalitesini değerlendirmez.

SHAP grafiklerindeki mavi ve kırmızı renkler, Özniteliklerin bir tahmin üzerindeki etkisini gösterir. Mavi renk, bir özelliğin değeri düşük olduğunda (örneğin, bir evin büyüklüğü küçükse veya bir kişinin yaşı gençse) ve bu düşük değerin model tahmini üzerindeki etkisini temsil eder. Mavi, genellikle bir özelliğin tahmini düşürdüğü veya negatif bir etkisi olduğu anlamına gelir.

Kırmızı renk, bir özelliğin değeri yüksek olduğunda (örneğin, bir evin büyüklüğü büyükse veya bir kişinin yaşı yaşlıysa) ve bu yüksek değerin model tahmini üzerindeki etkisini temsil eder. Kırmızı, genellikle bir özelliğin tahmini artırdığı veya pozitif bir etkisi olduğu anlamına gelir.

SHAP değerlerinin büyüklüğü, bir özelliğin tahmin üzerindeki etkisinin ne kadar güçlü olduğunu gösterir. Yüksek SHAP değerleri, özelliğin tahmin üzerinde daha büyük bir etkiye sahip olduğunu gösterirken, düşük SHAP değerleri daha az etkiyi gösterir.

Bu, modelin hangi Özniteliklere daha fazla "ağırlık" verdiğini ve tahminlerini nasıl şekillendirdiğini anlamamıza yardımcı olur (Lundberg ve Lee, 2017).

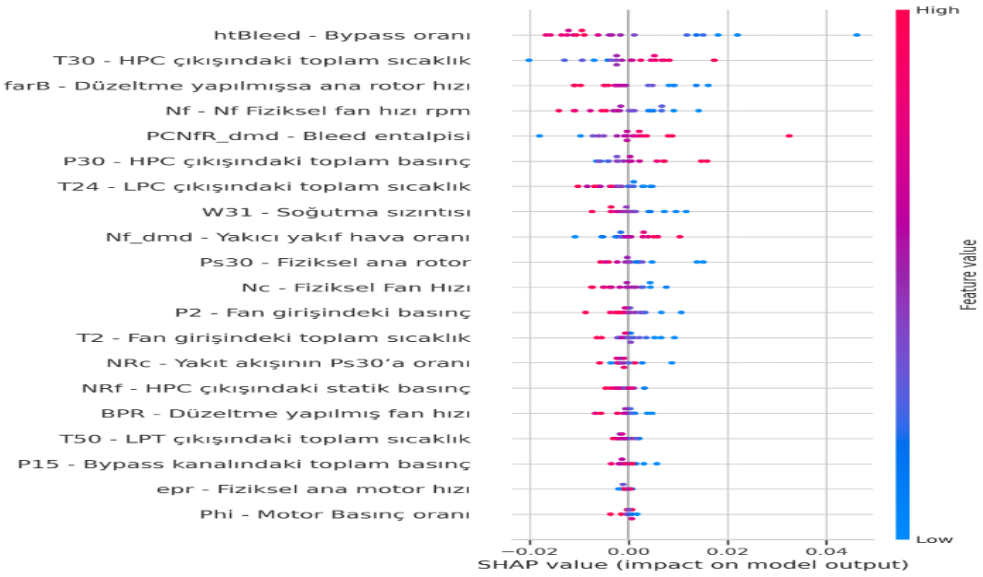

Şekil 2.7 Özniteliklerin modele etkileri

2.1.11 LIME (Local Interpretable Model-Agnostic Explanations)

LIME, bireysel tahminler için yerel yorumlar sağlamak, herhangi bir sınıflandırıcının tahminlerini yorumlanabilir ve güvenilir hale getirmek için tanıtılan bir tekniktir (Amelia ve diğ., 2016). Herhangi bir makine öğrenimi modelinin tahminlerini yerel olarak açıklamak için kullanılır. Bu yöntem, bir tahminin yapıldığı noktada modelin davranışını yakından taklit eden basitleştirilmiş bir model oluşturur. Bu basitleştirilmiş model, karar verme süreci anlaşılır.

Şekil 2.8'de gördüğünüz LIME (Local Interpretable Model-Agnostic Explanations) grafikleri, makine öğrenimi modellerinin tahminlerini açıklamak için kullanılır. Bu grafiklerde kırmızı ve mavi çubuklar, modelin bir örneği sınıflandırırken her bir özelliğin (feature) tahmin sonucuna ne ölçüde katkı sağladığını gösterir.

Genellikle, mavi çubuklar bir özelliğin verilen sınıf etiketi lehine (destekleyici) katkıda bulunduğunu, kırmızı çubuklar ise karşıt (çelişkili) etkide bulunduğunu ifade eder (Amelia ve diğ., 2016).

Her bir çubuk, ilgili özelliğin tahmin olasılığı üzerindeki "ağırlığını" temsil eder. Mavi çubuklar ("Supports" olarak etiketlenmiş), modele göre, belirli bir özelliğin değerinin, olasılığı artırma yönünde pozitif bir etkiye sahip olduğunu gösterir. Bu, modelin o özelliği göz önünde bulundurarak sınıf etiketinin olasılığını yükselttiği anlamına gelir.

Kırmızı çubuklar ("Contradicts" olarak etiketlenmiş), özelliğin değerinin, olasılığı düşürme yönünde negatif bir etkiye sahip olduğunu gösterir. Yani model, bu özelliğe dayanarak sınıf etiketinin olasılığını düşürür.

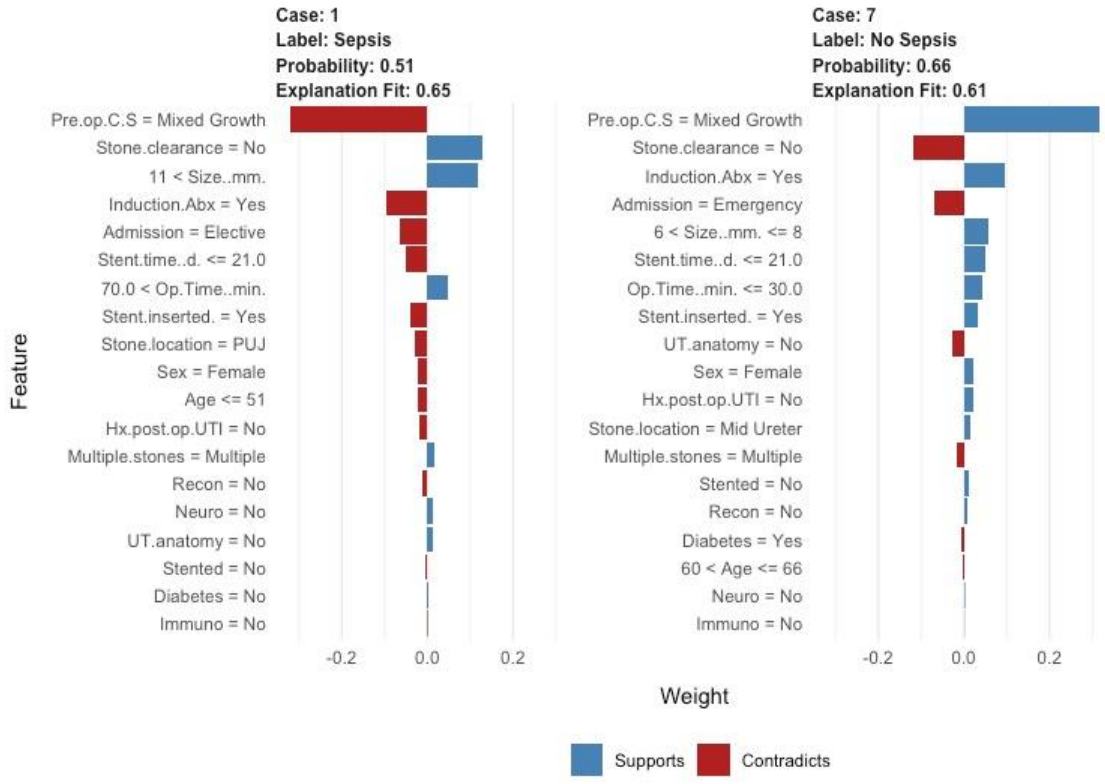

Şekil 2.8 Lime ile özniteliklerin modele etkisi (Amelia ve diğ., 2016)

3 MATERYAL VE METOT

3.1. Veri Seti

C-MAPSS (Ticari Modüler Aero-İtici Sistem Simülasyonu) veri seti, uçak motorları için prognostik ve sağlık yönetimi yöntemlerinin değerlendirilmesi ve geliştirilmesi amacıyla yaygın olarak kullanılan kıyaslama veri setidir. Tablo3.1'de gösterildiği gibi C-MAPSS veri seti dört alt setten oluşur: FD001, FD002, FD003 ve FD004, her biri farklı sayıda motor (100 ile 260 arasında) ve çevrim sayılarına (206 ile 247 arasında) göre eğitim ve test örnekleri içerir. Tüm alt setlerde 26 veri sütunu mevcuttur. Bu veri seti, özellikle havacılık motor performansı ve arıza tahmini alanında yaygın olarak kullanılmaktadır (C-MAPSS, 2008).

FD001 ve FD003 alt veri setleri, tek bir operasyonel mod altında çalışırken, FD002 ve FD004 birden fazla operasyonel mod ve farklı arıza koşulları altında çalışan motorları içerir. FD001 ve FD003, daha basit koşullar altında iken, FD002 ve FD004 daha karmaşık ve gerçek dünya uçuş senaryolarına daha yakın koşulları temsil eder. Bu ayrım, veri setlerini kullanırken araştırmacılara hangi senaryoyu simüle etmek istediklerine bağlı olarak bir seçim yapma imkânı tanır. FD001 alt veri kümesinde, 100 eğitim motoru ve 100 test motoru, FD004 alt veri kümesinde, 249 eğitim motoru ve 248 test motoru içermekte olup, bu da C-MAPSS veri setinde araştırma ve deneyler için kapsamlı ve çeşitli bir veri kaynağı haline getirmektedir. C-MAPSS programı tarafından oluşturulan bu veri seti, turbofan motor bozulma verilerini kapsar ve motor sağlığı ve bozulma modellerinin incelenmesi için değerli bir kaynaktır. Araştırmacılar, bu veri setini uzun kısa süreli bellekli sinir ağları (LSTM), derin sanal sağlık endeksi tahmini, çok değişkenli gizli Markov modelleri, aşırı öğrenme makineleri, zamansal evrişimli ağlar (Liu, Xiong, Zhang, 2021) ve derin takviyeli öğrenme gibi çeşitli prognostik yöntemleri test etmek için kullanmışlardır. Veri seti, hasar yayılım modellemesi, sensör füzyon tabanlı prognostik, tekrarlayan sinir ağı modellemesi, yorumlayıcı sinir ağı modelleri ve uçak motorlarının kalan faydalı ömür (RUL) tahmini için otomatik makine öğrenimi gibi alanlarda da kullanılmıştır (Zafar ve Khan, 2021).

C-MAPSS veri seti, prognostik yöntemlerin kıyaslama ve analizine yönelik araştırmalarda yaygın olarak kullanılmaktadır (Ramasso ve Saxena, 2020).

Simüle edilmiş çalışma koşulları ve sensör ölçümleri, denetimli ve Gözetimsiz sınıflandırma algoritmaları için bozulma seviyelerini belirlemekte kullanılabilmektedir (Ramasso ve Saxena, 2020).

Veri seti, motor bileşenlerindeki arızaların ve bozulmaların etkilerini simüle eden 21 sensör parametresinden oluşur. Bu sensörlerin sembol ve açıklamaları, metin içerisinde belirtilen tablolarda gösterilmiştir. C-MAPSS yazılım kodu, ticari bir itki motorunu temsil etmek üzere geliştirilmiştir (Garg, 2013). Araştırmacılar, evrişimli sinir ağları (CNN) gibi derin öğrenme yaklaşımlarını kullanarak turbo fan motorlarının kalan faydalı ömrünü tahmin etmek amacıyla C-MAPSS veri setini kullanmışlardır (Cheng ve diğ., 2021). Genel olarak, C-MAPSS veri seti havacılık endüstrisinde prognostik ve sağlık yönetimi çalışmaları için değerli bir kaynak olarak ön plana çıkmaktadır.

Bu tezde, C-MAPSS veri setinde FD001'de 100 motor ve FD004'ten 248 motora ait 21 sensör verisi ayrı ayrı incelenmiştir. Eğitim aşamasında veri setinin %80'i, test aşamasında ise %20'si kullanılmıştır. Bu yaklaşım, derin öğrenme modellerinin eğitiminde etkili bir veri dağılımı sağlamıştır.

Tablo 3.1. C-MAPSS Veri setinin açıklaması

Veri Seti	**FDOO1**	**FD002**	**FD003**	**FD004**
Motor Numarası	100	260	100	249
Eğitim örneklerinin sayısı	20,531	53,579	24,270	61,249
Test numunesi sayısı	100	259	100	248
Veri sütununun numarası	26	26	26	26
Ortalama ömür (çevrimler)	206	206	247	245

Tablo 3.2'de C-MAPSS FD001 ve FD004 veri setlerine ait sütunların açıklamaları yapılmaktadır. Aynı sensör verilerine sahip olmalarına rağmen veri çeşitliliği FD004 de daha fazladır ve daha fazla operasyonel koşullar altında bir veri seti sunmaktadır.

Tablo 3.2. C-MAPSS FD001 ve FD004 veri setlerinin sütun açıklamaları

Sensor No	Semboller	Açıklamalar
1	T2	Fan girişindeki toplam sıcaklık
2	T24	LPC çıkışındaki toplam sıcaklık
3	T30	HPC çıkışındaki toplam sıcaklık
4	T50	LPT çıkışındaki toplam sıcaklık
5	P2	Fan girişindeki basınç
6	P15	Bypass kanalındaki toplam basınç
7	P30	HPC çıkışındaki toplam basınç
8	Nf	Nf Fiziksel fan hızı rpm
9	Nc	Fiziksel Fan Hızı
10	epr	Fiziksel ana motor hızı
11	Ps30	Fiziksel ana rotor
12	Phi	Motor Basınç oranı
13	NRf	HPC çıkışındaki statik basınç
14	NRc	Yakıt akışının Ps30'a oranı
15	BPR	Düzeltme yapılmış fan hızı
16	farB	Düzeltme yapılmışsa ana rotor hızı
17	htBleed	Bypass oranı
18	Nf_dmd	Yakıcı yakıf hava oranı
19	PCNfR_dmd	Bleed entalpisi
20	W31	Soğutma sızıntısı
21	W32	Soğutma sızıntısı

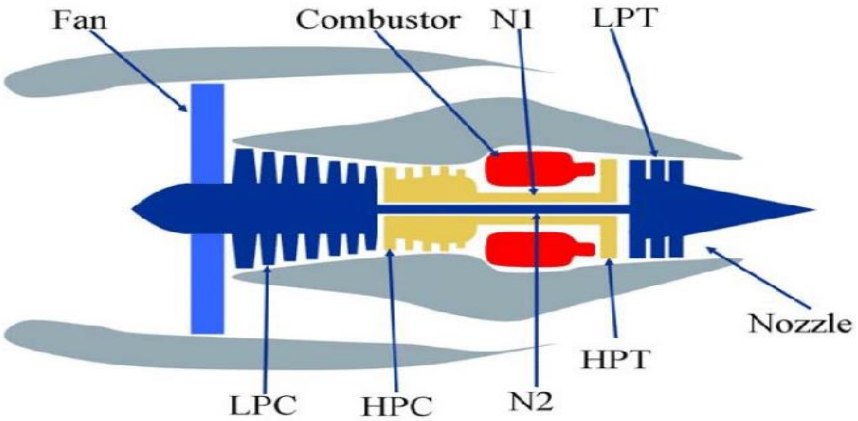

Şekil 3.1 C-MAPSS veri setinde kullanılan sensörler (Dean ve diğ., 2007)

Şekil 3.1'de bir turbofan motorunun ana bileşenleri gösterilmektedir ve her bileşen motor operasyonları sırasında çeşitli ölçümler yapmak için sensörlerle donatılmıştır. Tabloda listelenen sensörler ve semboller, motorun farklı kısımlarında ölçülen parametrelerle ilişkilidir. Örneğin, T2 sensörü fan girişindeki toplam sıcaklığı, T24 ise LPC (Düşük Basınç Kompresörü) çıkışındaki toplam sıcaklığı ölçer. P2, fan girişindeki basıncı, P30 ise HPC (Yüksek Basınç Kompresörü) çıkışındaki toplam basıncı ölçer.

Her bir sensör numarası, motorun belirli bir noktasında ölçüm yapan ve belirli bir parametreyi takip eden bir sensörü temsil eder. Bu ölçümler, motorun sağlık durumunu ve performansını izlemek için kullanılır.

3.2.Makine Öğrenmesi Yöntemleri

3.2.1. Gözetimli Öğrenme

Makine öğrenmesi alanında yaygın olarak kullanılan bir yöntemdir. Bu yöntemde, bir modelin eğitimi için etiketli verilere ihtiyaç vardır. Etiketli veriler, girdi verileri ile hedef çıktı değerlerinin birleşimidir. Model, bu verilere dayanarak girdi verileriyle hedef çıktı arasındaki ilişkiyi öğrenir ve daha sonra yeni girdi verilerine dayanarak tahminler yapabilmektedir (Konieczny, 2016).

3.2.2. Gözetimsiz Öğrenme

Etiketli verilerin olmadığı durumlarda kullanılan bir öğrenme yöntemidir. Bu yöntemde, model veri setindeki desenleri ve ilişkileri keşfetmeye çalışır. Modelin amacı, verileri gruplara veya kümelere ayırmak, benzerlikleri belirlemek veya veri setindeki yapıları ortaya çıkarmaktadır (Tekes, 2021).

Gözetimsiz öğrenme algoritmaları, veri setindeki yapıları keşfetmek için istatistiksel yöntemler, kümeleme yöntemleri veya boyut indirgeme teknikleri gibi farklı teknikleri kullanır.

Örnek olarak, kümeleme algoritmaları (K-Means, Hiyerarşik Kümeleme), boyut indirgeme algoritmaları (PCA vb.) ve birliktelik kuralı madenciliği gözetimsiz öğrenme yöntemlerine örnek olarak verilmektedir.

3.2.3. Yarı Gözetimli Öğrenme

Bu yöntemde hem etiketli verilerin hem de etiketsiz verilerin kullanılmasıyla bir modelin eğitimi gerçekleştirilir. Etiketli veriler, modelin performansını değerlendirmek ve öğrenmesini yönlendirmek için kullanılırken, etiketsiz veriler de modelin veri setindeki yapıları ve desenleri anlamasına yardımcı olmaktadır (Tekes, 2021).

3.2.4. Pekiştirmeli Öğrenme

Bu yöntemde, bir model, belirli bir görevi yerine getirmek için çevreyle etkileşime girer. Model, çevreden gelen geribildirimlere dayanarak belirli bir stratejiyi öğrenir ve görevi optimize etmektedir (Cheng, 2021).

3.3. Zaman ve Frekans Dönüşümleri

3.3.1. Zaman Serilerinde Wavelet (Dalgacık) Dönüşümü ve Spektrogram

Wavelet dönüşümü ve LSTM ile sensör verilerine dayalı olarak motorların Kalan Faydalı Ömrünü (RUL) tahmin etmek için C-MAPSS veri kümesini kullanan bir kestirimci bakım modeli geliştirildi. Süreç, veri setini yükleme, temizleme, Min-Max Normalizasyon ve Dalgacık dönüşümünü içeren veri ön işlemeyi içerir. Şekil 3.3'de Sinüs Dalgasının Dalgacık (Wavelet) Dönüşümü ile çarpılmasına bir örnek verilmiştir. Bu grafikte, sinüs dalgasının düzenli yapısı içinde dalgacık dönüşümden dolayı geçici dalga formu görülür ve bu tip sinyaller genellikle karmaşık sinyallerin analizi veya sinyal işlemede karşılaşılır.

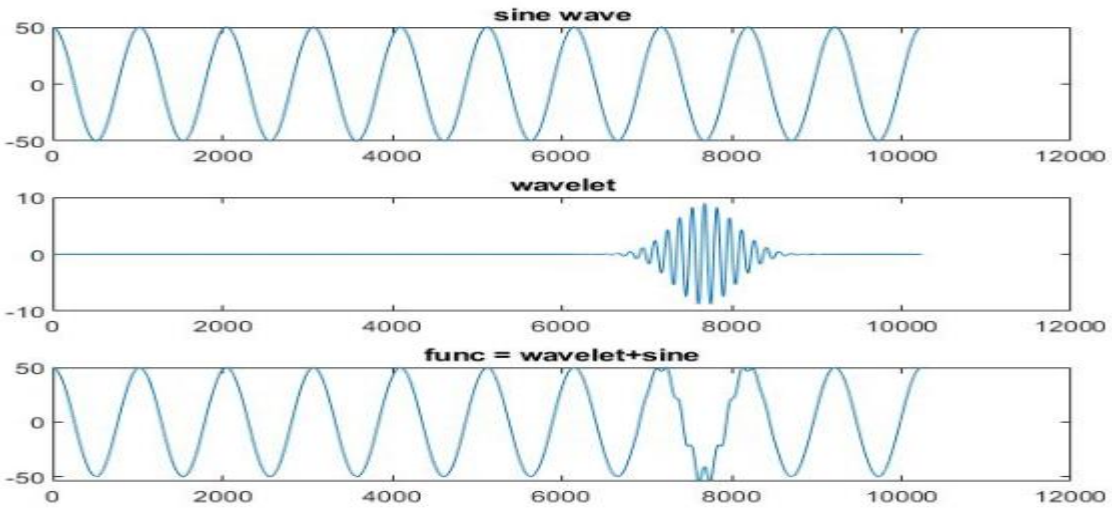

Şekil 3.2. Dalgacık Dönüşümü (URL-4)

3.3.2. Zaman Serilerinde Hilbert Huang Dönüşümü

Empirik mod dekompozisyonu (EMD), karmaşık verileri analiz etmek ve bunları daha basit, sinüzoidal bileşenlere ayırmak için kullanılan bir yöntemdir. Bu yöntem, veri setinin içerdiği farklı frekanslardaki dalga formlarını tanımlayan bir dizi İçsel Mod Fonksiyonu (IMF) elde etmek için tasarlanmıştır.

Her IMF, verideki belirli bir frekans bandını temsil eder ve bunların toplamı orijinal veriyi yeniden oluşturur. EMD, özellikle doğrusal olmayan ve durağan olmayan veri setlerinin analizinde kullanılır ve sinyal işleme, zaman serisi analizi ve çeşitli mühendislik uygulamalarında popüler bir araçtır.

C-MAPSS veri setinde sensör verilerini Empirik Mod bileşenlerine ayırdıktan sonra Hilbert-Huang dönüşümünde, her bir Empirik Mod bileşeni için Hilbert dönüşümü uygulayarak Hilbert spektrumu elde edildi ve bu spektrum ile sinyalin frekans içeriğini zaman-frekans düzleminde görselleştirmemiz sağlandı.

Şekil 3.3'te empirik dönüşümden elde edilen 7 içsel mod frekansını görülmektedir.

Empirik Mod dönüşümü ile elde edilen bu frekanslar Hilbert Huang dönüşümü ile LSTM e girdi olarak verilmektedir. Grafikteki her panelde mavi ve turuncu renkte iki sinyal görülmektedir. Mavi çizgi, her bir IMF'yi gösteriyor. Bu, orijinal sinyalin farklı zaman ölçeklerindeki dalga modlarını temsil eder. Daha yüksek numaralı IMFler genellikle daha düşük frekansa sahip trendleri temsil ederken, daha düşük numaralı IMFler yüksek frekanslı dalgalanmaları temsil eder. Turuncu çizgi, ilgili IMF'nin Hilbert dönüşümünü temsil ediyor. Hilbert dönüşümü, her bir IMF'nin anlık fazını ve anlık frekansını elde etmek için kullanılır ve genellikle sinyalin zamana bağlı Özniteliklerini daha iyi anlamak için kullanılır.

Bu grafiklerde zaman x-ekseni boyunca gösterilmiştir. Y-ekseni ise genellikle sinyalin genliği veya bir diğer deyişle şiddetini temsil eder. Her bir IMF ve onun Hilbert dönüşümü, zaman içindeki genlik değişimlerini ve dolayısıyla sinyalin zamanla nasıl değiştiğini gösterir. Frekans bilgisi ise dolaylı olarak IMF'lerin şeklinden ve Hilbert dönüşümünden anlaşılabilir, çünkü farklı IMF'ler sinyalin farklı frekans bileşenlerini temsil eder.

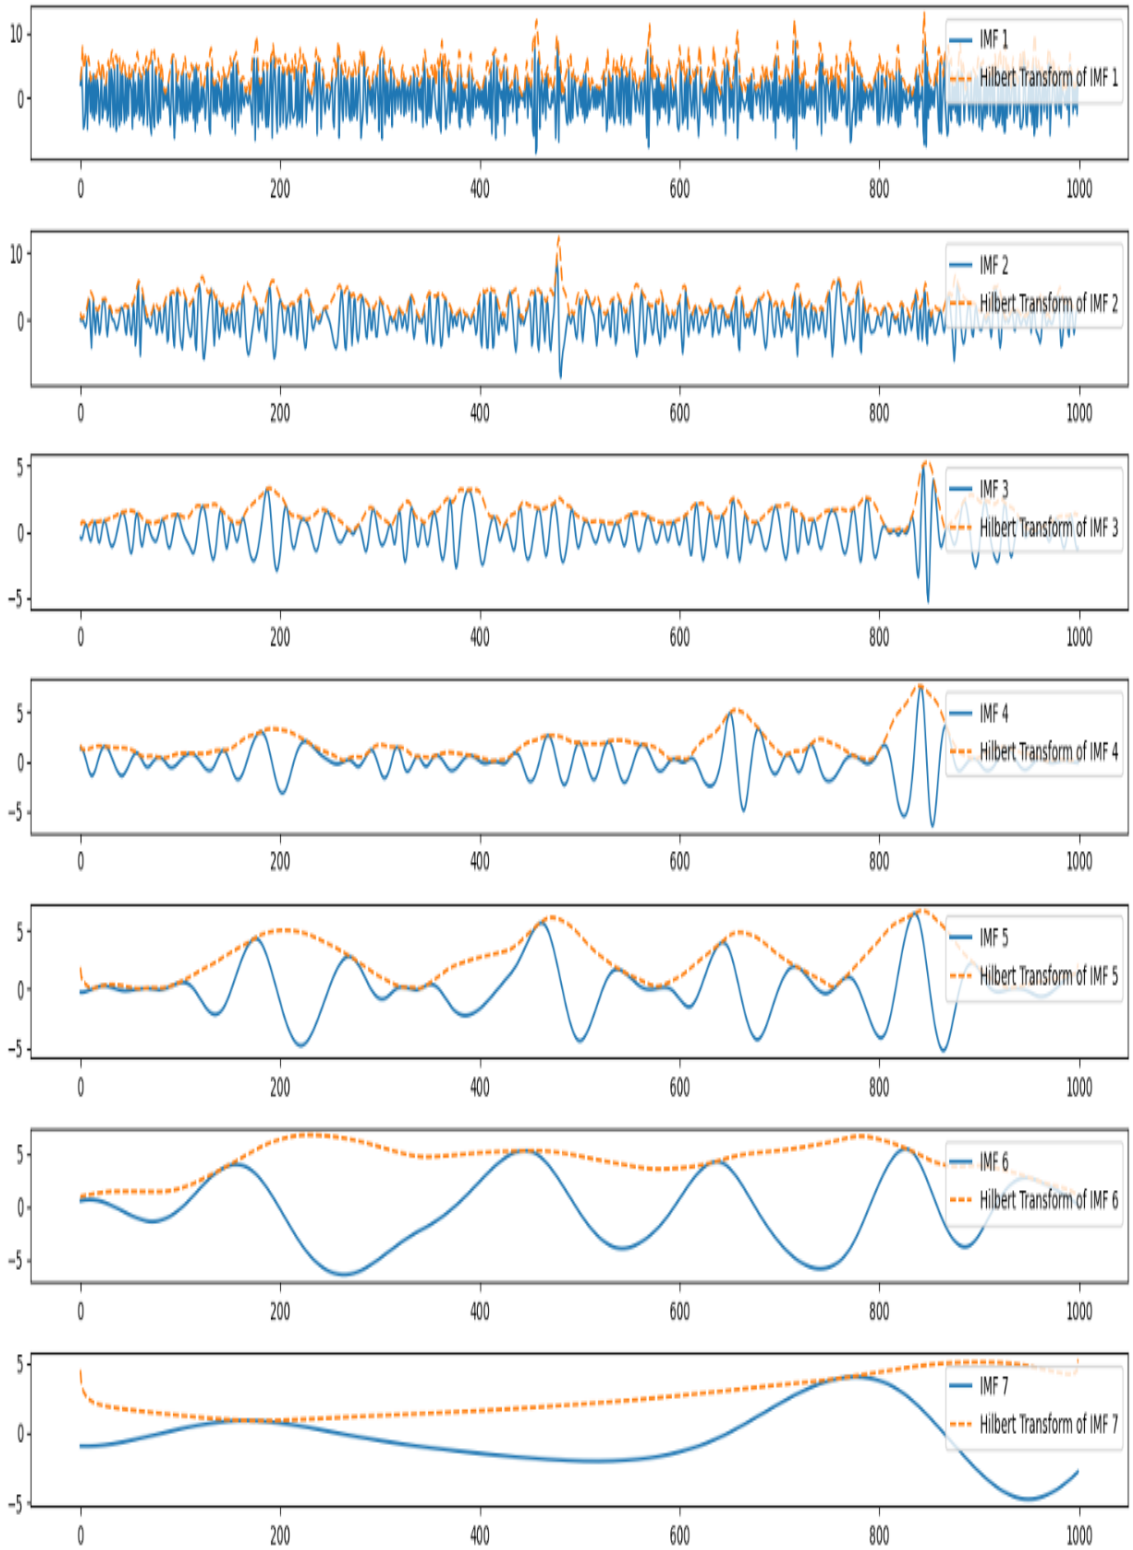

Şekil 3.3 HHT için Empirik dönüşüm ile IMF'lere ayrıştırılması

4 DENEYSEL SONUÇLAR

4.1. Veri Ön İşleme

4.1.1 Normalizasyon

C-MAPSS veri seti, uçak motorlarının çeşitli çalışma şartları ve arıza modları altında gösterdiği performansı simüle eden, her bir motorun işletme koşullarını yansıtan 21 sensör çıkışından oluşan çok boyutlu zaman serisi verilerinden meydana gelmektedir. Her bir veri noktası, sadece sensör bileşenlerinin faaliyetlerini kayıt altına alan 21 sensör sinyalinden ibaret olmayıp, aynı zamanda operasyonel ayarları, motor kimliklerini ve işletim döngülerini de kapsayan kapsamlı bir veri setidir. Bu veri setinde yer alan değişkenlerin farklı ölçeklerde ve birimlerde bulunması, makine öğrenimi modellerinin eğitim ve değerlendirme süreçlerinde üstün sonuçlar elde etmek için normalizasyon işlemini zorunlu kılmaktadır. Normalizasyon işlemi, tüm değişkenlerin aynı ölçeğe getirilmesini sağlayarak, modelin daha hızlı eğitilmesine ve genelleme yeteneğinin artmasına katkıda bulunabilir. Özellikle derin öğrenme modelleri gibi bazı algoritmaların, normalizasyon yapılmadığında yanıltıcı veya optimal olmayan sonuçlar ürettiği gözlemlenmiştir (Li, Ding, 2018). Bu araştırmada, C-MAPSS veri seti üzerinde Min-Max normalizasyon yöntemi tercih edilmiştir.

4.1.2 Aykırı Değerlerin Ayıklanması

Aykırı değerlerin ayıklanması, veri setindeki normalden sapma gösteren, beklenmeyen, tutarsız ya da hatalı olabilecek veri noktalarını tespit edip çıkarmanın sürecidir. Bu süreç, veri analizi ve modelleme için önemlidir çünkü aykırı değerler, istatistiksel analizlerin ve makine öğrenimi modellerinin doğruluğunu ve güvenilirliğini olumsuz etkileyebilir. Şekil 4.1'de görüldüğü üzere, motorların kalan yaşam ömürleri dikkate alındığında, 350 RUL değerine yakın motorların ortalamalardan önemli ölçüde farklı değerler aldığı gözlemlenmiştir. Bu nedenle, aykırı değer analizi yöntemi olan Outlier kullanılarak bu değerler veri setinden çıkarılmıştır. Modelin daha iyi performans göstermesi açısından aykırı değerlerin veri setinden çıkarılması önem arz etmektedir.

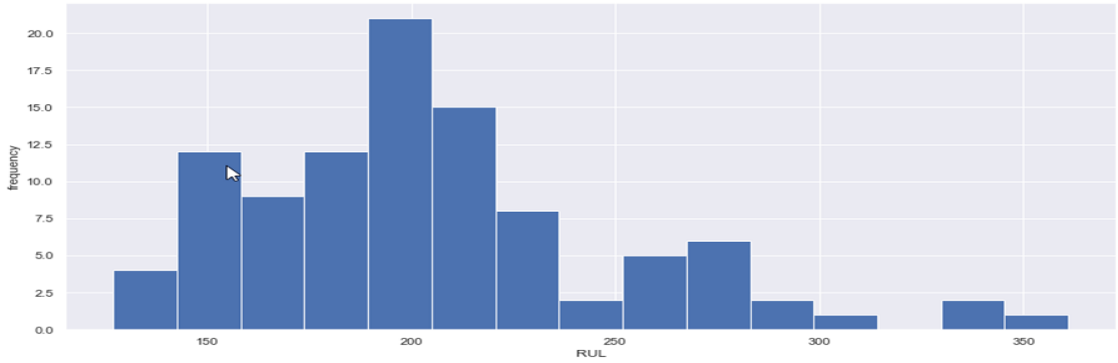

Şekil 4.1 Motorların Kalan yaşam döngüsü (RUL) Histogramı

4.1.3. PCA (Principal Component Analysis) Analizi

Veri setlerindeki değişkenler arasındaki varyansı en üst düzeye çıkarmayı hedefleyen PCA (Ana Bileşenler Analizi), bu amaçla veri setinde yer alan değişkenlerin varyanslarını hesaplayarak başlar. İkinci adımda, bu değişkenlerin birbiriyle olan ilişkilerini içeren kovaryans matrisini oluşturur. Kovaryans matrisinin özdeğerlerini ve özvektörlerini çıkarmak üzere özdeğer ayrıştırması yapılır (Kiangala ve Wang, 2020) Motor durumunun izlenmesi için hangi sensörlerin uygun olduğunu tespit etmek ve veri setinin boyutunu indirgemek amacıyla PCA analizinden yararlanılmıştır. Bu tezde, Ayar3, S1, S5, S10 ve S16 sensörlerinin analizi sonucunda bu verilerin sabit kaldığı ve standart sapmalarının düşük olduğu tespit edilmiştir; bu sebeple söz konusu sensörler veri setinden hariç tutulmuştur. Kullanılan sensörler ve örnek değerleri Tablo 4.1'de sunulmuştur. Boyut indirgeme sürecinde sıkça başvurulan yöntemlerden PCA, veri kümelerindeki varyasyonları hiyerarşik bir koordinat sistemi aracılığıyla temsil etme kapasitesine sahiptir. SVD (Singular Value Decomposition) ise, veriye dayalı bir Fourier transformasyonu yöntemi olarak karşımıza çıkar. LASSO (Least Absolute Shrinkage and Selection Operator) da boyut azaltma konusunda sıklıkla tercih edilen bir diğer yöntemdir.

Tablo 4.1. Sensörler için Öznitelik Seçimi

s_2	s_3	s_4	s_7	s_8	s_11	s_12	s_13	s_15	s_17	s_20	s_21
641 82	1589.70	1400.60	554_36	2388_06	47.47	521_66	2388 02	84.195	392	39_06	234190
642.15	1591.82	1403.14	553.75	2388.04	47.49	522.28	2388.07	84.318	392	39.00	234236
642.35	1587.99	1404.20	554.26	2388.08	47.27	522.42	2388.03	84.178	390	38.95	233442
642.35	1582.79	1401_87	554_45	2388_11	47.13	522_86	2388 08	83.682	392	38_88	233739
642.37	1582.85	1406.22	554.00	2388.06	47.28	522.19	2388.04	84.294	393	38.90	234044

4.1.4. Sensör Korelasyonu ile Öznitelik çıkarımı

Tez içerisinde korelasyonları 0.8'den büyük olarak yansıyan (s2, s3, s4, s7, s8, s11, s12, s13, s15, s17, s 20, s21) sensörleri öznitelik seçiminde kullanılabilmektedir. Korelasyon analizi, iki veya daha fazla değişken arasındaki ilişkinin yönünü ve derecesini belirlemek için kullanılan istatistiksel bir yöntemdir. Korelasyon katsayısı, genellikle Pearson korelasyon katsayısı olarak bilinen ve -1 ile +1 arasında değerler alan bir ölçüt aracılığıyla ifade edilir. Bu katsayı, değişkenler arasındaki ilişkinin doğrusallığını ve şiddetini ifade eder; +1 mükemmel pozitif doğrusal bir ilişkiyi, -1 mükemmel negatif doğrusal bir ilişkiyi ve 0 ise değişkenler arasında hiçbir doğrusal ilişki olmadığını gösterir.

4.1.5. SHapley Additive exPlanations ile Öz Niteliklerin Modele Etkisi

C-MAPSS data seti içerisinde SHAP (Shapley Additive exPlanations) yöntemi ile öz niteliklerin makine öğrenimi modelleri üzerindeki etkileri açıklanmıştır. SHAP değerleri, modelin her bir girdi özelliğine ne kadar "ödül" (ya da önem) verdiğini gösterdi. Şekil 4.2'te htbleed – bypass sensor oranında pozitif ve negatif yönde dağılımın geniş olması, özelliğin model çıktısı üzerinde büyük bir etkiye sahip olduğunu gösterir. Pozitif değerler, tahmini artıran etkenleri, negatif değerler ise tahmini azaltan etkenleri temsil etmektedir. Epr fiziksel ana motor hızı sensör verileri ise modele etkisinin en az olduğu grafik üzerinden anlaşılmaktadır. Görseldeki mavi noktalar her bir özelliğin SHAP değerlerini temsil ediyor ve kırmızı çizgiler bu değerlerin ortalamasını gösteriyor. Noktaların yoğunlaştığı yerler, Özniteliklerin model çıktısı üzerindeki etkisinin yoğun olduğu bölgelerdir. Bu analiz, Özniteliklerin model tahminlerine olan etkilerini anlamak için kullanılan SHAP değerlerine dayanmaktadır (Lundberg ve Lee, 2017). Shap tekniği ile öznitelikleri modele etkisi anlaşıldı ve sensör verilerinden 2, 1, 6, 7, 8, 10, 17, 19, 20, 21, 22, 23, 24, 25, 26, 27 sensör verileri çıkarıldı. Tablo 4.7'de görülebileceği gibi modelin en iyi RMSE değerlerini bu özniteliklerin çıkarılması ile elde edilmiştir.

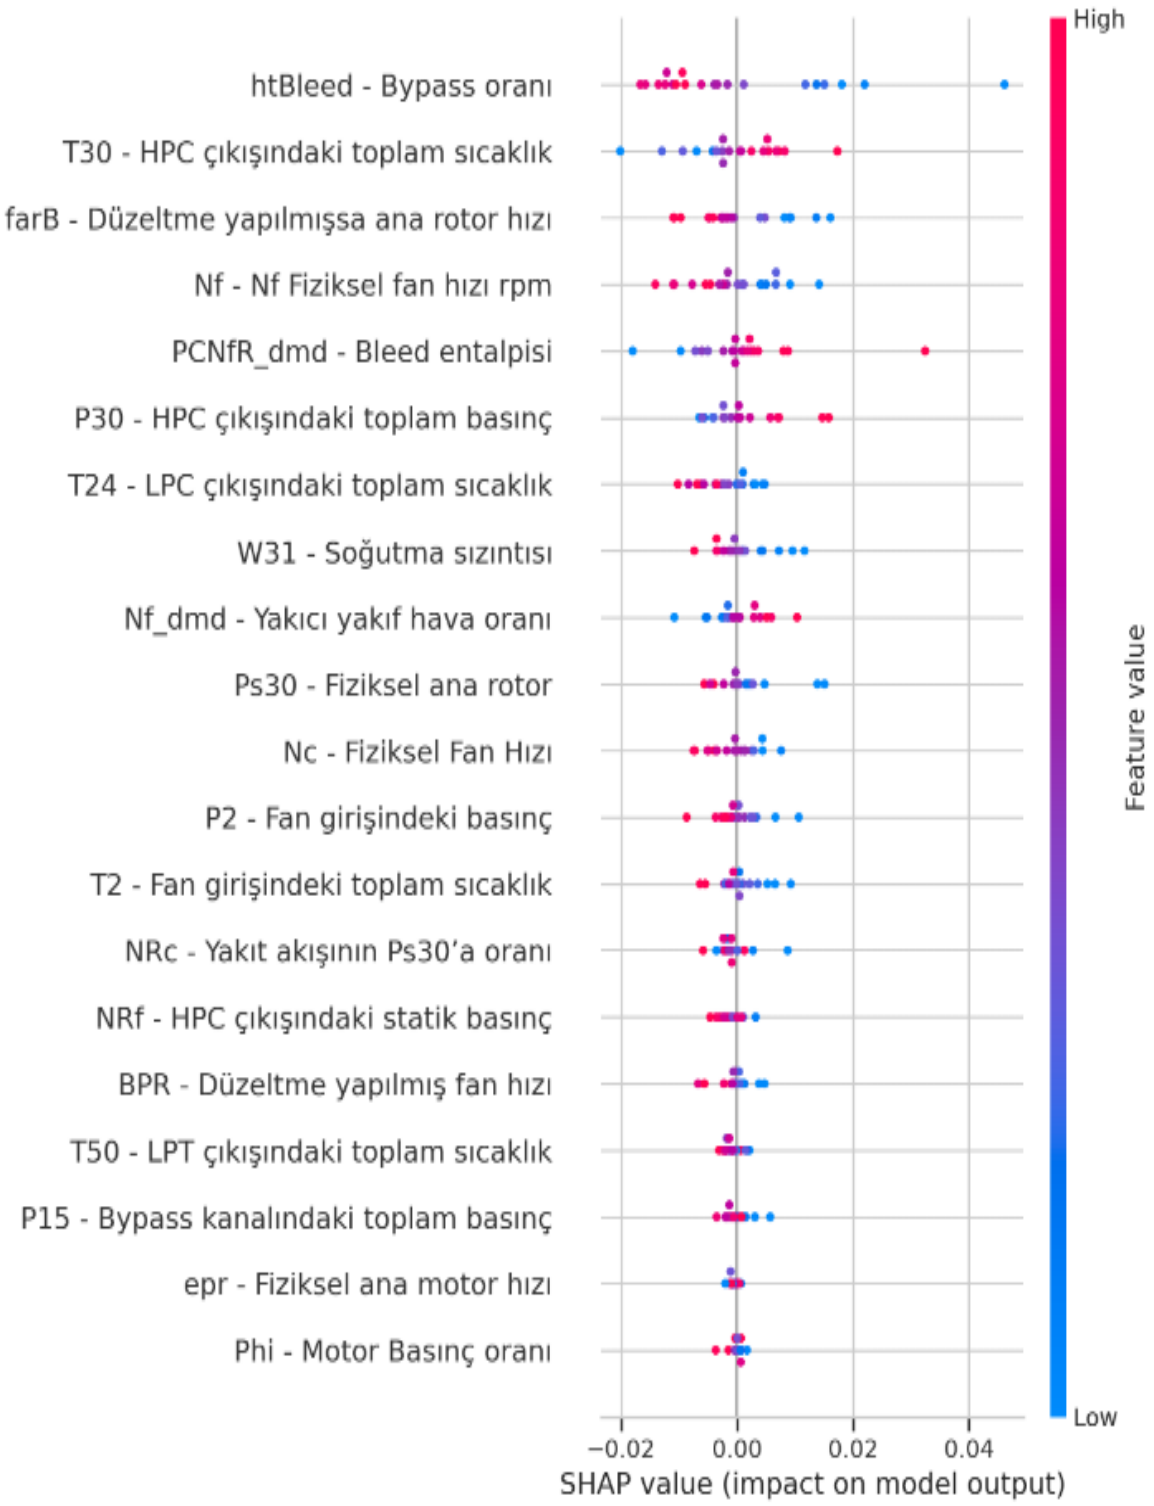

Şekil 4.2 Shap tekniği ile özniteliklerin model üzerindeki etkisi

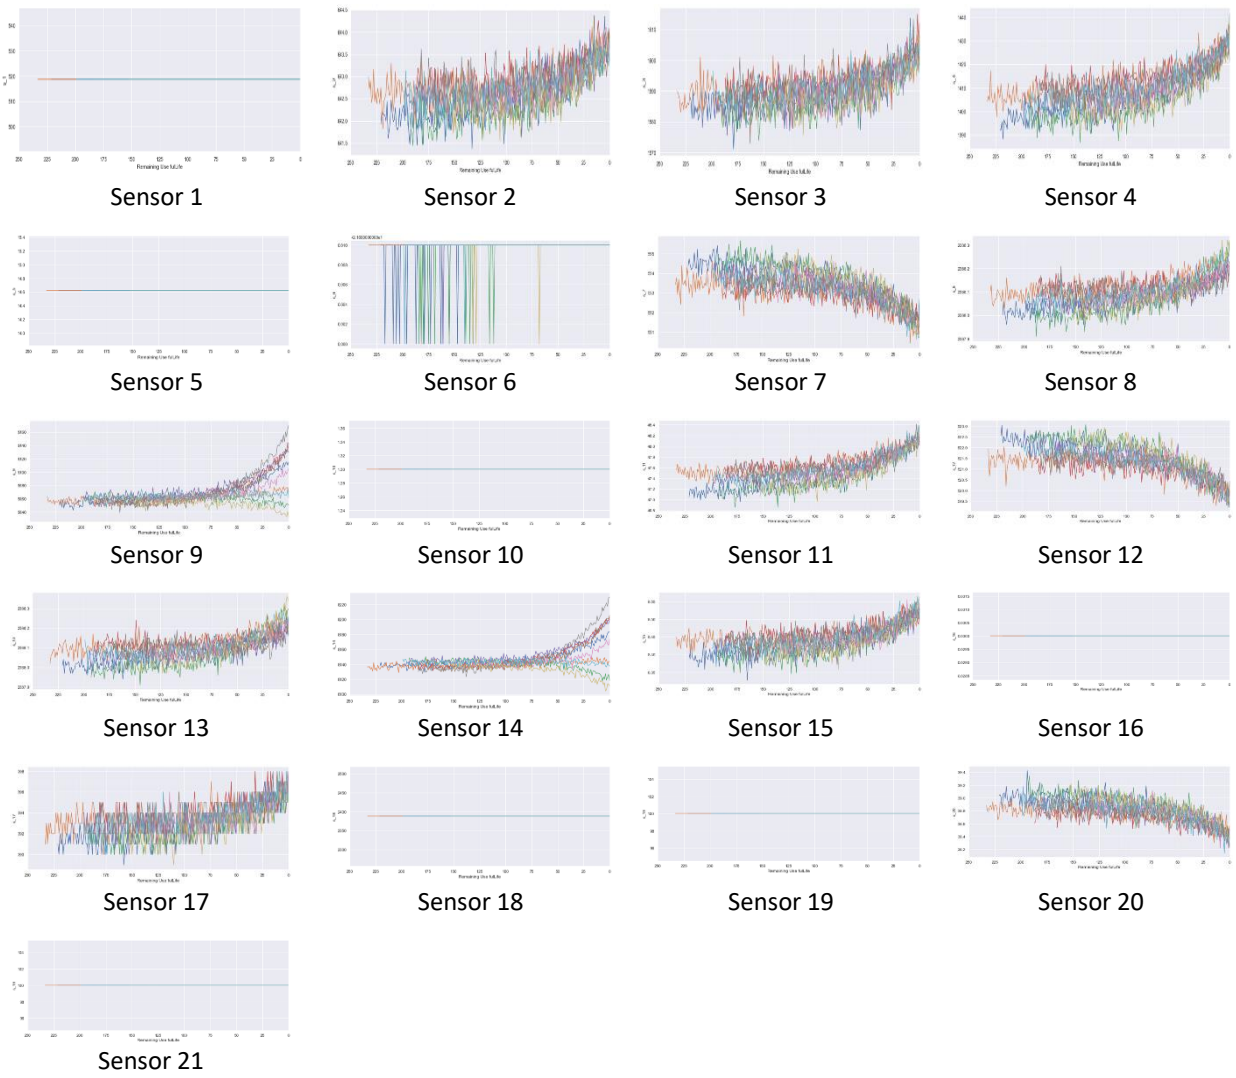

Şekil 4.3 Motor ve sensör verilerinin RUL'a etkisi

Motor ve sensör verilerinin RUL'a etkisini gösteren Şekil 4.4'ten anlaşılacağı gibi belirli motorların (2,3,4,5,7,8,9,10,11,13,16) sensör verilerinin RUL üzerindeki etkilerini görebilmekteyken, sensör numaraları (1,6,12,14,15,21) olan sensör değerlerinin RUL a bir etkisinin olmadığı aşikardır. Her zaman gözle anlaşılacak kadar az sensör ve motor sayısı olmayacağından, sensör korelasyonu ve PCA değerleri de referans alınarak SHAP tekniği ile modele en fazla etkisi olan öz nitelikler anlaşıldı.

4.2.Regresyon Değerlendirme Metrikleri

4.1.1 RMSE (Kök Ortalama Kare Hata- Root Mean Square Error)

RMSE, gözlemlenen değerlerle modelin tahmin ettiği değerler arasındaki farkların karelerinin ortalamasının kareköküdür. Denklem (4.1)'e göre hesaplanmaktadır.

$$RMSE = \sqrt{\frac{1}{n}\sum_{k=1}^{n}(y_i - y_{ii})^2} \quad (4.1)$$

Denklem (4.1)'de yi, gözlemlenen (gerçek) değerlerin i'inci elemanını, yii, tahmin edilen değerlerin i'inci elemanı, n ise değerlerin toplam sayısını ifade eder.

Denklem, gözlemlenen değerler ile model tarafından tahmin edilen değerler arasındaki farkların karelerinin ortalamasının karekökünü alarak hesaplanır. RMSE, farkların büyüklüğünü göz önünde bulundurduğu için, modelin ne kadar iyi performans gösterdiği hakkında fikir verir; daha düşük RMSE değerleri genellikle daha iyi tahmin performansını gösterir.

4.2.2. R^2 (R Kare- R Squared- Determination Katsayısı)

R^2, bağımlı değişkendeki varyansın bağımsız değişken(ler) tarafından ne kadarının açıklandığını gösterir. Değerleri 0 ile 1 arasında değişir, 1'e yakın bir R^2 değeri modelin veriyi iyi açıkladığını gösterir. Denklem (4.2)'e göre hesaplanmaktadır.

$$R^2 = 1 - \frac{SSR}{SST} \quad (4.2)$$

R^2 (R kare), modelin açıklana bilirliğini ölçen istatik iken SSR (Sum of Squares of Regression), regresyonun toplam karesel sapmaları yani modelin tahminleri ile gerçek değerler arasındaki farkların karelerinin toplamıdır. SST (Total Sum of Squares), toplam karesel sapmalar yani gözlemlerin genel ortalamadan olan farklarının karelerinin toplamıdır.

4.3. Kestirimci Bakım İçin Regresyon Çalışmaları

4.3.1. Wavelet Dönüşümü ve Hilbert Dönüşümü ile CNN-LSTM

Veri setindeki sütun adlarının tanımlanması yapıldı. Her motor için RUL değerleri veri setinden alındı ve veri kümesine yeni bir sütun olarak eklendi.

Analitik sinyali ve genlik zarfını elde etmek için her sensör sütununa Hilbert dönüşümü uygulandı ve bunlar daha sonra yeni Öznitelikler olarak veri kümesine eklendi.

Öznitelikler Min-Max kullanılarak normalleştirildi ve veriler bir CNN'ye girişe uygun olacak şekilde yeniden şekillendirildi. Model Mimarisi, her biri düzenlileştirme için bir bırakma katmanı (Dropout) tarafından takip edilen bir Conv1D katmanına sahip sıralı bir mimariden oluşur. Sensör okumalarındaki zamansal bağımlılıkları yakalamak için bir LSTM katmanı eklenir, ardından başka bir bırakma katmanı (Dropout) ve yoğun çıktı katmanı eklenir.

Model eğitimi, eğitim veri seti ve test setlerine bölünmüştür. Model, kayıp fonksiyonu olarak Adam optimizasyonu ve Ortalama Karesel Hata kullanılarak derlendi. Doğrulama kaybının azalması sona erdiğinde eğitimi durdurmak için erken durdurma kullanıldı ve aşırı uyum önlendi. Daha sonra model fit yöntemi kullanılarak eğitildi.

Eğitim verilerinin değerlendirilmesi, eğitim sonrasında model eğitim kaybının hesaplanması için eğitim verileri üzerinden değerlendirilir. Tablo 4.3'te Wavelet CNN+LSTM modelinin metriklerini görebilirsiniz. Wavelet dönüşümü ile CNN-LSTM modeli uygulanmasında aynı aşamalar yapılırken sadece Hilbert Huang dönüşümü yerine Wavelet Dönüşümü uygulanmıştır.

Tablo 4.2. Wavelet CNN+LSTM Metrikleri

Model	**RMSE-Eğitim**	**R2-Eğitim**	**RMSE-Test**	**R2-Test**
Wavelet CNN+LSTM	37.42040	-0.04320	42.29297	-0.44216

Tablo 4.3 Hilbert Dönüşümü CNN-LSTM regresyon modeli

Model	**RMSE-Eğitim**	**R2-Eğitim**	**RMSE-Test**	**R2-Test**
Hilbert CNN+LSTM	36.7606	0.7177	91.7510	-3.9144

Şekil 4.5.'te, C-MAPSS veri seti üzerinde gerçekleştirilen analiz süreci detaylandırılmaktadır. Öncelikle, öznitelik seçimi için korelasyon analizi yapılarak veri setinden en anlamlı değişkenler seçilmiştir.

Seçilen bu Öznitelikler, normalizasyon işlemine tabi tutulmuş ve daha sonra Temel Bileşen Analizi (PCA) kullanılarak boyut indirgemesi yapılmıştır. Ardından, veri setinin zaman-frekans Özniteliklerini ortaya çıkarmak için Hilbert-Huang Dönüşümü uygulanmıştır. Bu aşamalar, analizin veri hazırlık evrelerini oluşturur ve hem eğitim hem de test veri setlerinin optimizasyonunu sağlamaktadır.

Eğitim sürecinde, evrişimli sinir ağları (CNN) mimarisi kullanılarak model geliştirilmiştir. Modelin mimarisi, üç evrişimsel katman ve her biri için Dropout uygulanarak aşırı uyumun önlenmesi şeklinde tasarlanmıştır. Her evrişimsel katmanın çıktısı, 18 filtreli evrişim işleminden geçirilmiş ve bu işlem sonucunda öznitelik haritaları elde edilmiştir. LSTM katmanı, bu öznitelikler üzerinden zaman bağımlılıklarını modellemek için eklenmiş ve ardından bir kez daha Dropout uygulanarak modelin genelleştirme kabiliyeti artırılmıştır. Son olarak, model, Dense katmanı ile sonuçlandırılmıştır.

Model değerlendirme sürecinde, ortalama kareler hatası (MSE), kök ortalama kare hatası (RMSE) ve mutlak değer ortalaması (MAE) metrikleri kullanılarak modelin performansı değerlendirilmiştir. Bu metrikler, modelin tahmin başarısını ve test veri seti üzerindeki genelleştirme yeteneğini ölçmek için kritik öneme sahiptir.

Şekil 4.4'te gösterilen model mimarisi ve değerlendirme metrikleri, bu çalışmada geliştirilen prediktif bakım modelinin temelini oluşturmaktadır ve motor durum takibi için etkili bir yaklaşım sunmaktadır. Veri ön işleme adımlarında Min-Max normalizasyon ve PCA analizinden sonra Hilbert Huang Dönüşümü ile veriler CNN-LSTM modelinde işlenip RMSE, MEA metrikleri ile değerlendirildi. Tablo 4.4'te sonuçlar verilmiştir.

Şekil 4.5'te Hilbert CNN-LSTM Mavi çizgi, eğitim kaybını gösterir. Bu, modelin eğitim veri seti üzerindeki performansını ölçer. Grafiğe bakıldığında, eğitim kaybı zamanla (veya epoch sayısıyla) düşüş gösteriyor. Bu, modelin eğitim verilerini giderek daha iyi öğrendiğini ve tahminlerinin gerçek değerlere yaklaştığını gösterir. Turuncu çizgi, doğrulama kaybını gösterir. Modelin görmediği veri üzerinde ne kadar iyi performans gösterdiğini, yani genelleme yeteneğini gösterir. Doğrulama kaybının da zamanla azaldığını görüyoruz, bu da modelin genelleştirme yeteneğinin geliştiğini gösterir.

Her iki çizginin de benzer bir eğilim göstermesi olumlu bir işarettir; bu, modelin aşırı uyuma (overfitting) gitmediğini ve eğitim setine özgü kalıpları ezberlemediğini gösterir. Eğer eğitim kaybı düşerken doğrulama kaybı yükselirse, bu genellikle aşırı uydurmanın bir göstergesidir.

Grafikte epoch sayısı arttıkça her iki kayıp değerinin de düzleştiğini görebiliriz, bu da modelin belirli bir noktadan sonra daha fazla iyileşmediğini, yani eğitimde bir doygunluğa ulaştığını gösterir. İdeal olarak, doğrulama kaybı düşük bir değerde sabitlenmeli ve eğitim kaybına yakın olmalıdır, ki bu durumda grafiğe göre iyi bir durumda olduğunu söyleyebiliriz

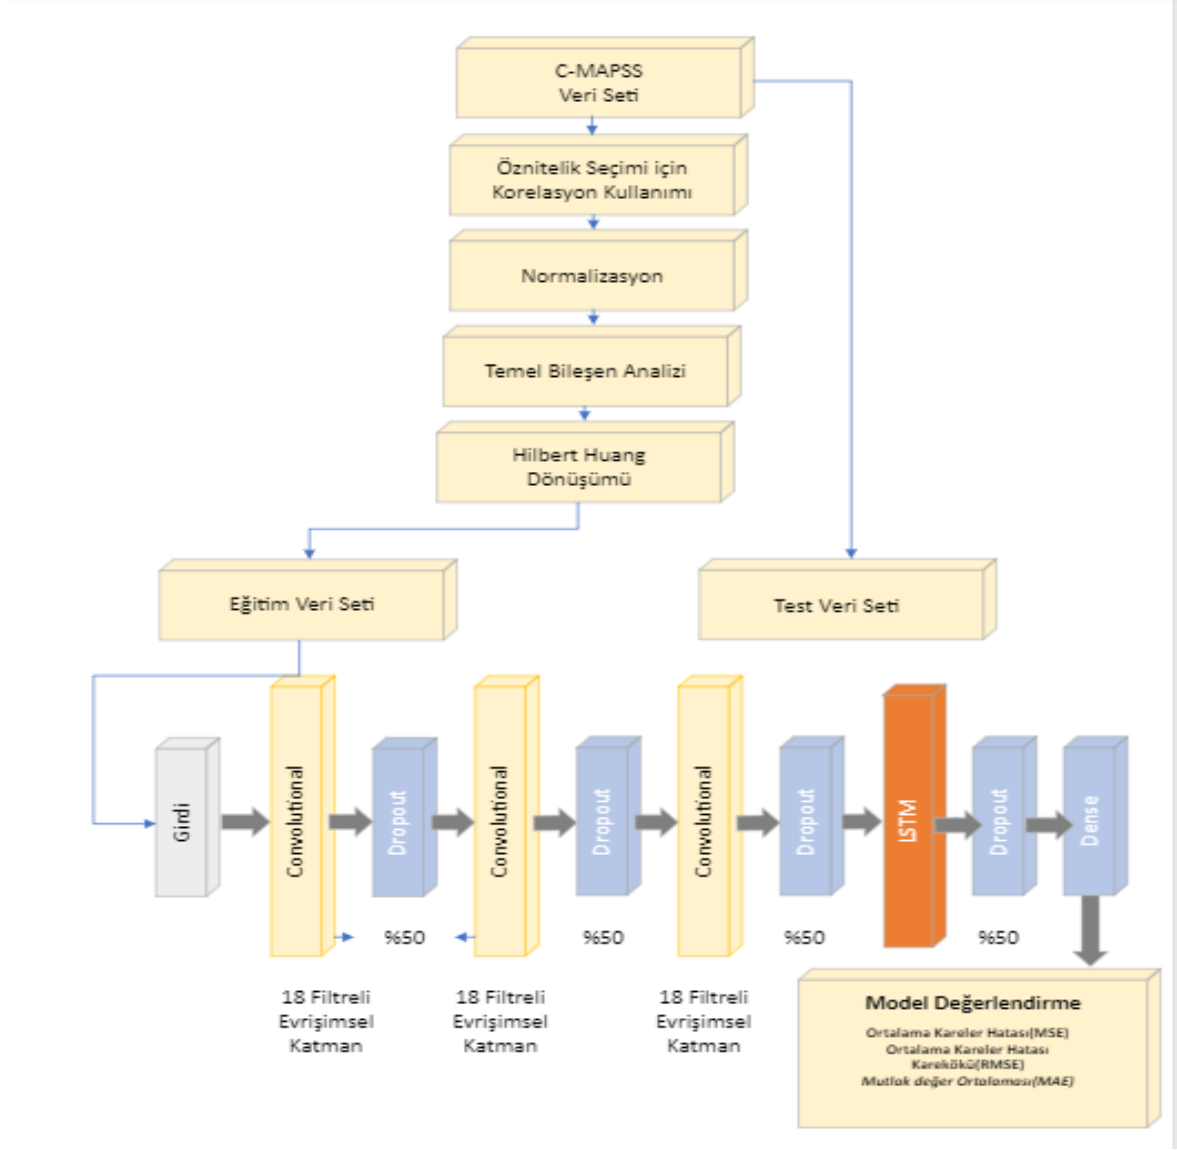

Şekil 4.4 Hilbert Dönüşümü ile CNN-LSTM Blok Diyagram

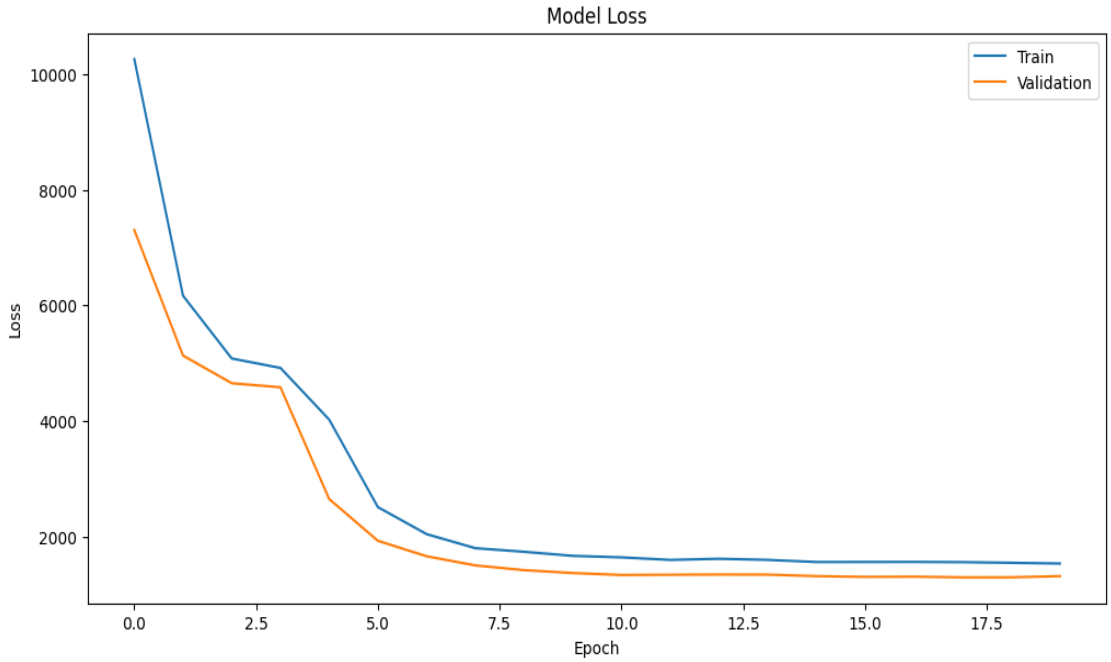

Şekil 4.5 Hilbert dönüşümü ve CNN-LSTM modeli kayıp grafiği

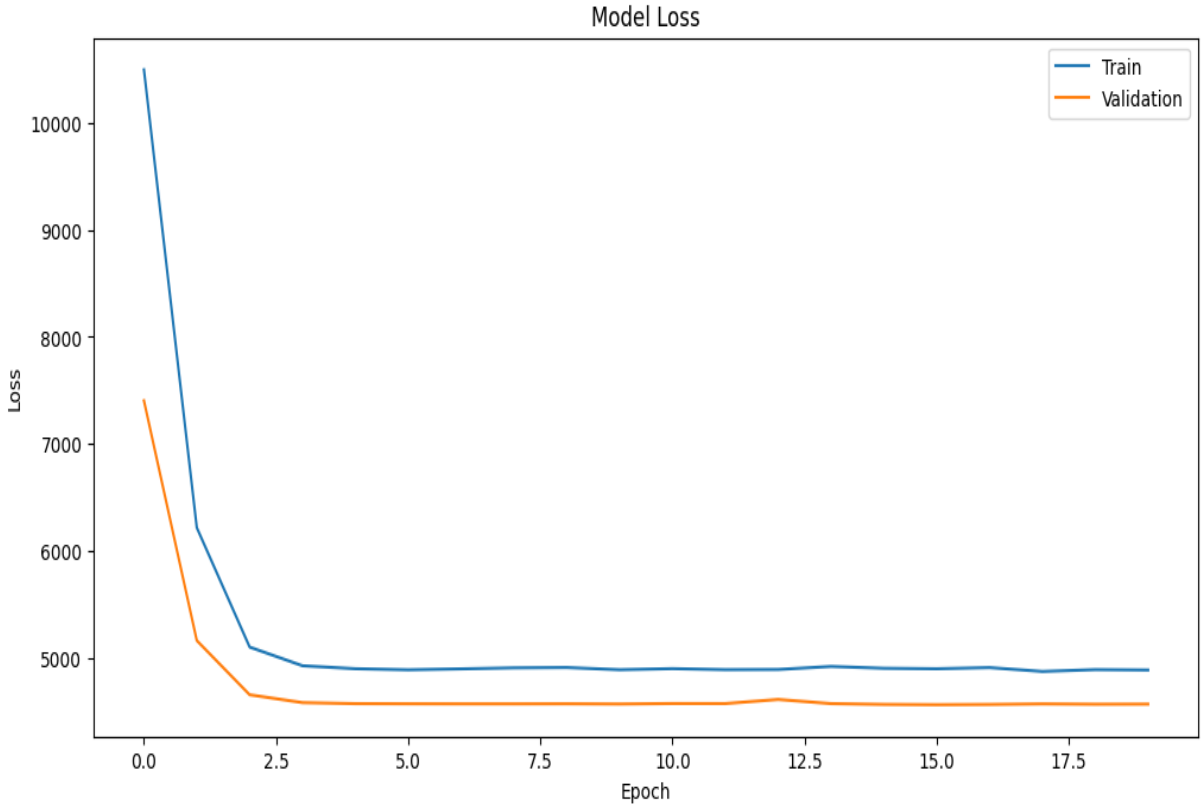

Şekil 4.6. Wavelet CNN-LSTM Kayıp Grafiği

Şekil 4.6'da Mavi çizgi, modelin eğitim veri seti üzerindeki performansını gösterir. Epoch başına eğitim kaybının hızlı bir şekilde düştüğünü ve belirli bir sayıdan sonra düzleştiğini görebiliriz. Bu, modelin eğitim verilerindeki kalıpları öğrendiğini ve eğitim kaybının minimuma ulaştığını gösterir.

Turuncu çizgi, modelin doğrulama veri seti üzerindeki performansını gösterir. Bu set, modelin eğitim sırasında görmediği verileri içerir ve genelleme yeteneğini test etmek için kullanılır. Doğrulama kaybı da benzer bir şekilde azalır ve düzleşir, bu da modelin görmediği veriler üzerinde de iyi genelleme yaptığını gösterir.

Her iki kayıp değerinin de düşüş eğilimi ve düzleşmesi modelin iyi bir eğitim sürecinden geçtiğine işaret eder. Ancak, doğrulama kaybının eğitim kaybının biraz üzerinde düzleşmiş olması, modelin eğitim verilerine göre doğrulama verilerinde biraz daha kötü performans gösterdiğini gösterir.

4.3.2. Wavelet Dönüşümü ile LSTM

Wavelet Dönüşümü ve LSTM ile sensör verilerine dayalı olarak motorların Kalan Faydalı Ömrünü (RUL) tahmin etmek için C-MAPSS veri kümesini kullanan bir kestirimci bakım modelinin geliştirilmesini özetlemektedir. Süreç, yükleme, temizleme, RUL hesaplaması ve normalleştirmeyi içeren veri ön işlemeyi içerir.

Şekil 4.7'te görüldüğü gibi Model mimarisi dalgacık dönüşümü ve LSTM katmanları, ardından eğitim ve test verileri üzerinde değerlendirme yapılır. Uzamsal ve zamansal Öznitelikleri birleştiren bu yaklaşım, diğer ölçümler ve modellerle daha fazla karşılaştırma potansiyeli ile RMSE ve Score metrikleri yoluyla değerlendirilir.

Tablo 4.4 Wavelet LSTM regresyon modeli

Model	**RMSE-Eğitim**	**R2-Eğitim**	**RMSE-Test**	**R2-Test**
Wavelet LSTM	12.659	-0.03232	12.646	-0.0199

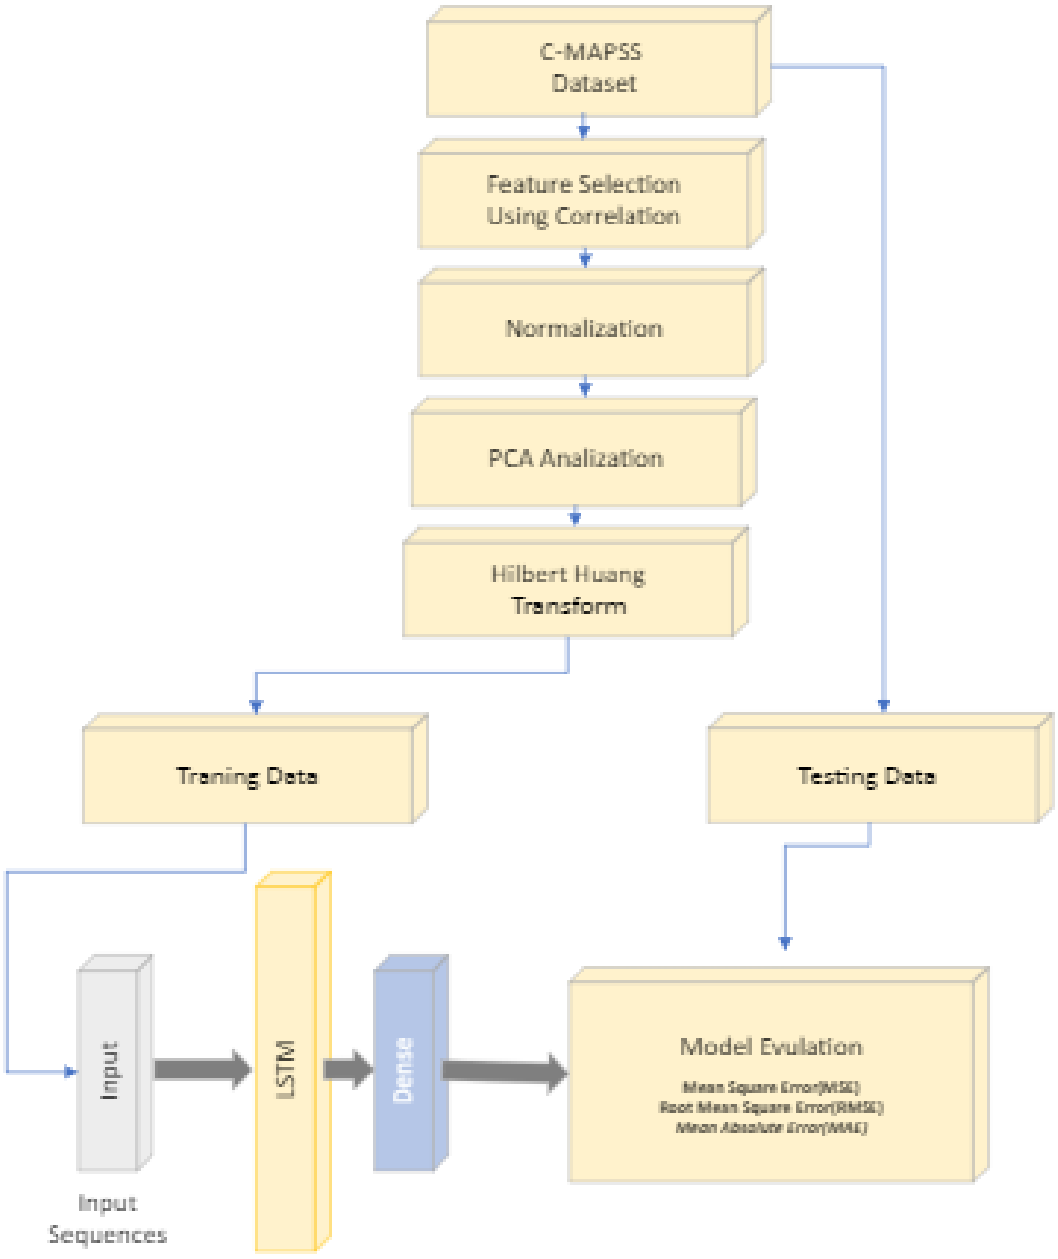

Şekil 4.7. Wavelet Dönüşümü ve LSTM Modeli

Şekil 4.7'da görüldüğü gibi veri ön işleme adımlarında Min-Max normalizasyon ve PCA analizinden sonra Hilbert Huang Dönüşümü ile veriler LSTM modelinde işlenip RMSE, MEA metrikleri ile değerlendirildi. Tablo 4.5'te sonuçlar verilmiştir.

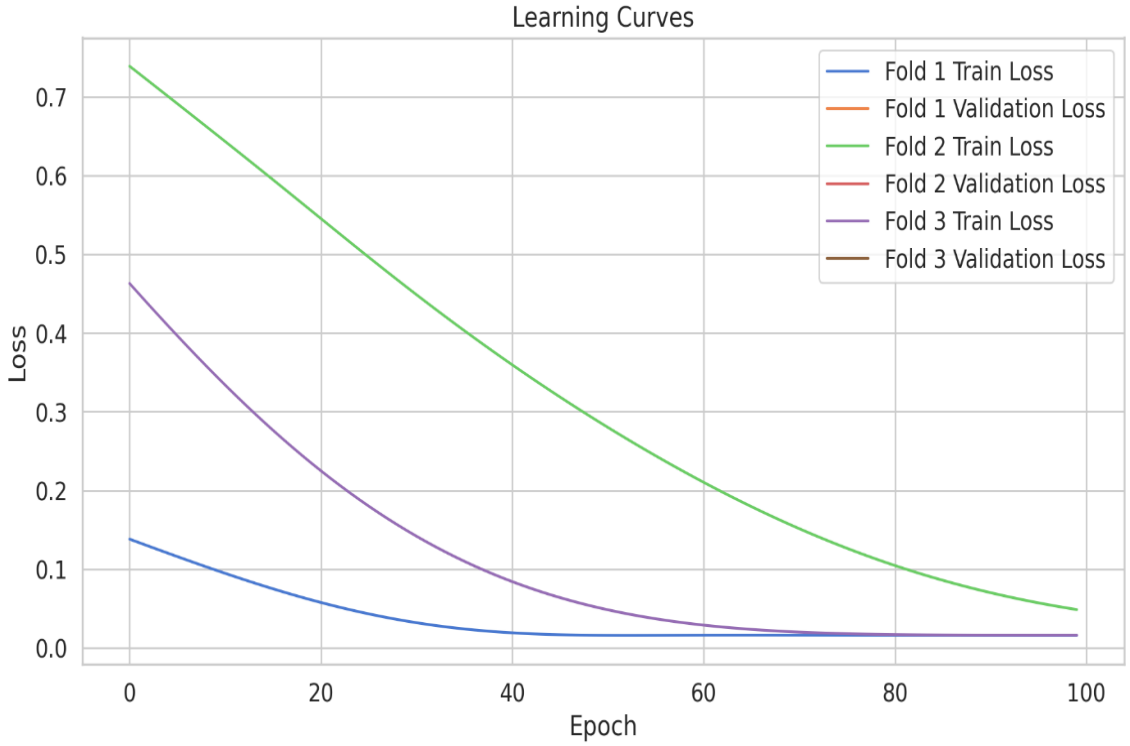

Şekil 4.8. Wavelet Dönüşümü ile LSTM

Şekil 4.8'de mavi, yeşil ve mor çizgiler her bir fold için eğitim kaybını gösterir. Tüm eğitim kayıpları, epoch sayısı arttıkça düşmektedir. Bu, modelin eğitim verilerini öğrendiğini ve her bir iterasyonda hatalarını düşürdüğünü gösterir. Turuncu, kırmızı ve gri çizgiler her bir fold için doğrulama kaybını gösterir. Doğrulama kayıpları da genellikle düşmektedir, ancak bir noktadan sonra azalma hızı yavaşlar veya durur. Bu, modelin genelleme yeteneğinin bir sınırına ulaştığını gösterir

4.3.3. Hilbert Dönüşümü ile SVR

Hilbert Dönüşümü ve SVR ile sensör verilerine dayalı olarak motorların RUL tahmini etmek için C-MAPSS veri kümesini kullanan bir kestirimci bakım modelinin geliştirilmesini özetlemektedir.

Şekil 4.9'da Mavi çizgi, modelin eğitim seti üzerindeki performansını gösterir. Eğitim hatası başlangıçta hızlıca düşer ve eğitim seti büyüklüğü arttıkça azalma hızı yavaşlar ve nihayetinde bir noktada sabitlenir. Bu, modelin eğitim verilerine göre bir doygunluk noktasına ulaştığını gösterir.

Turuncu çizgi, modelin doğrulama seti üzerindeki performansını gösterir. Doğrulama hatası da genel olarak düşüş eğilimindedir, ancak eğitim seti büyüklüğü arttıkça dalgalanmalar gösterir. Bu dalgalanmalar, doğrulama setinin belirli büyüklüklerde model tarafından ne kadar iyi genelleştirildiğini gösterir.

Tablo 4.5 Hilbert SRV regresyon modeli

Model	RMSE-Eğitim	R2-Eğitim	RMSE-Test	R2-Test
Hilbert SRV	45.68817	0.56402	45.28972	0.55105

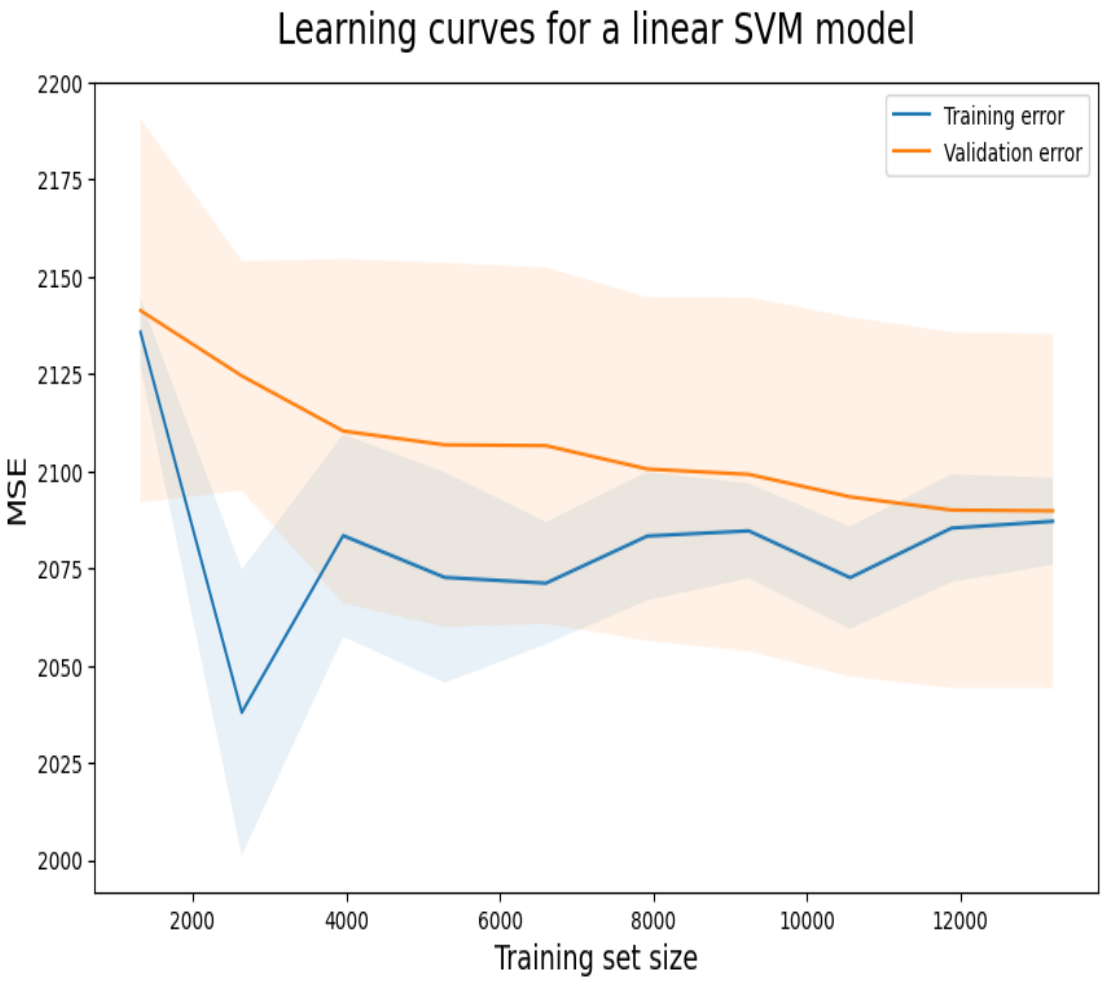

Şekil 4.9. Hilbert Dönüşümü ile SVR Kayıp Grafiği

Şekil 4.9'da grafiğin gölgeli alanları, hata metrikleri için güven aralığını veya varyansı gösterir. Gölgeli alan ne kadar genişse, modelin performansının o kadar değişken olduğu anlamına gelir.

Bu durumda, eğitim ve doğrulama hatası arasındaki gölgeli alanlar oldukça dar, bu da modelin tutarlı performans gösterdiğini gösterir.

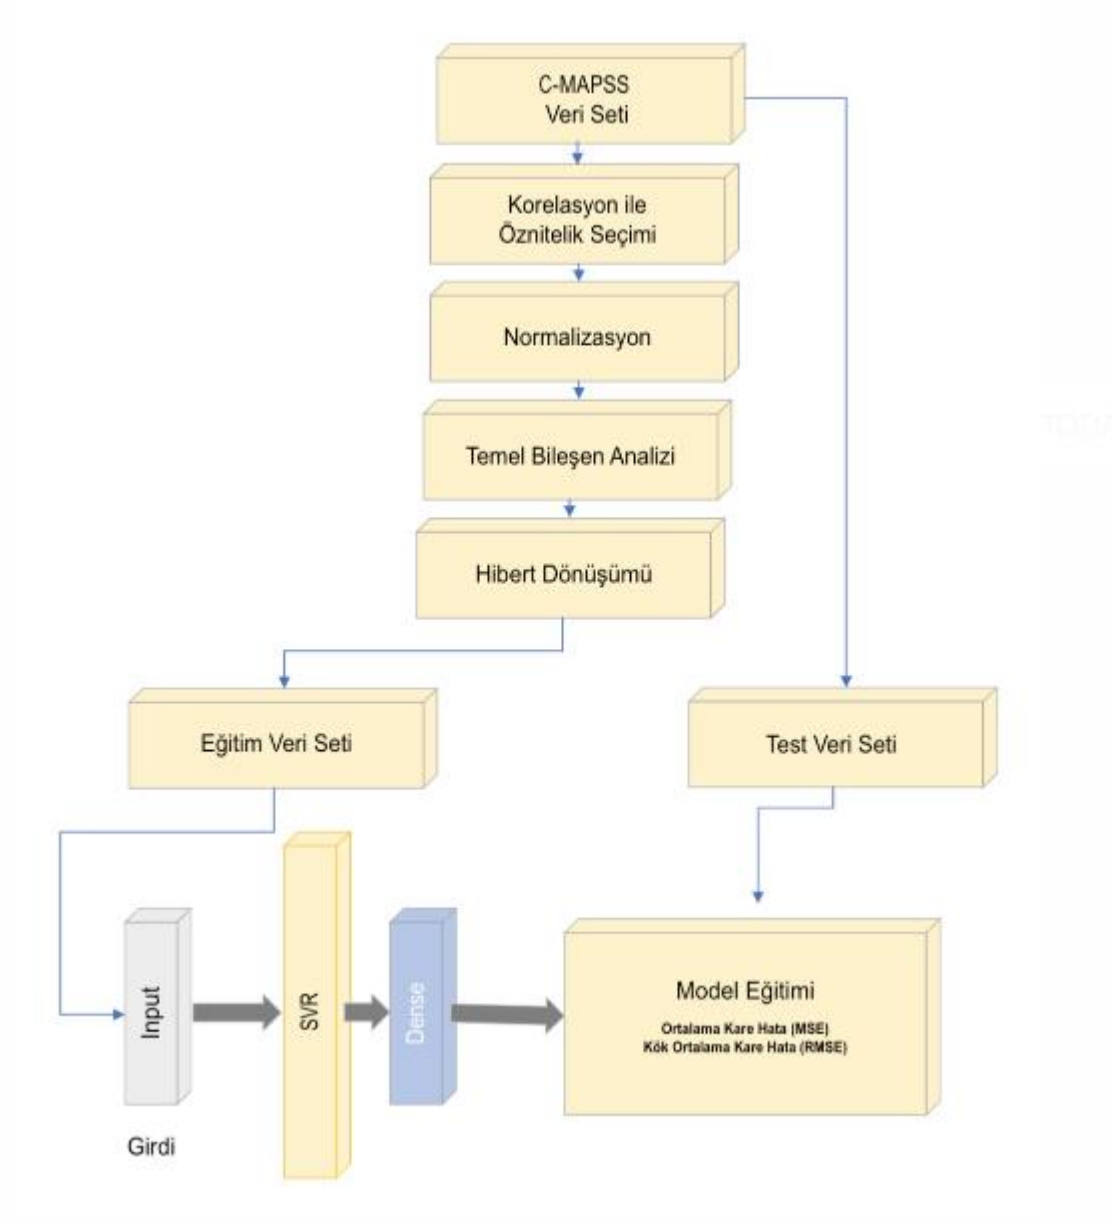

Şekil 4.10. Hilbert Dönüşümü ile SVR Mimarisi

Şekil 4.10'da görüldüğü gibi veri ön işleme adımlarında Min-Max normalizasyon ve PCA analizinden sonra Hilbert Huang Dönüşümü ile veriler SVR modelinde işlenip RMSE, MEA metrikleri ile değerlendirildi. Tablo 4.5'te sonuçlar verilmiştir.

4.3.4. Önerilen Hilbert Huang Dönüşümü ve LSTM modeli

Hilbert Huang dönüşümü, sinyalin zarfını elde etmek için sensör okumalarının her satırına uygulandı ve bu daha sonra bir özellik olarak kullanıldı. Normalleştirme için Hilbert dönüşümünden elde edilen Öznitelikler, sinir ağı modeline uyarlanmak üzere MinMaxScaler kullanılarak normalleştirildi.

LSTM, model zamansal bağımlılıkları yakalamak için bir LSTM katmanından ve çıktı için doğrusal bir katmandan oluşan standart sinir ağı modül sınıflarından türetilmiş bir alt sınıfı olarak tanımlanır. Özellik sayısı, gizli birimler, dizi uzunluğu ve katmanlar modelin parametreleridir. Dizi oluşturma modele girdi olarak kullanılacak eğitim verilerinden belirtilen uzunlukta diziler oluşturuldu. Çapraz doğrulama, modeli farklı veri bölümleri üzerinde eğitmek ve performansını doğrulamak için K-Katlamalı çapraz doğrulama gerçekleştirildi. Kayıp hesaplaması, model Adam optimizasyonu kullanılarak eğitilir ve her dönem için MSE hesaplandı.

Doğrulama verilerinin değerlendirilmesi, çapraz doğrulamada her katlamadan sonra model, doğrulama verileri üzerinden değerlendirilir ardından RMSE ve karışıklık matrisi hesaplandı. Kayıp görselleştirme, her katlama için eğitim ve doğrulama kayıpları bir grafikte görselleştirilir. Test verilerinin değerlendirilmesi, model son olarak test verileri üzerinden değerlendirilmesi için test kaybı ve RMSE hesaplandı. Gerçek ve tahmin edilen değerler bir grafikte görselleştirildi.

Tablo 4.6 Hilbert LSTM Model Metrikleri

Model	RMSE-Eğitim	R2-Eğitim	RMSE-Test	R2-Test
Hilbert LSTM	10.1414	-0.10464	12.43	-0.0662

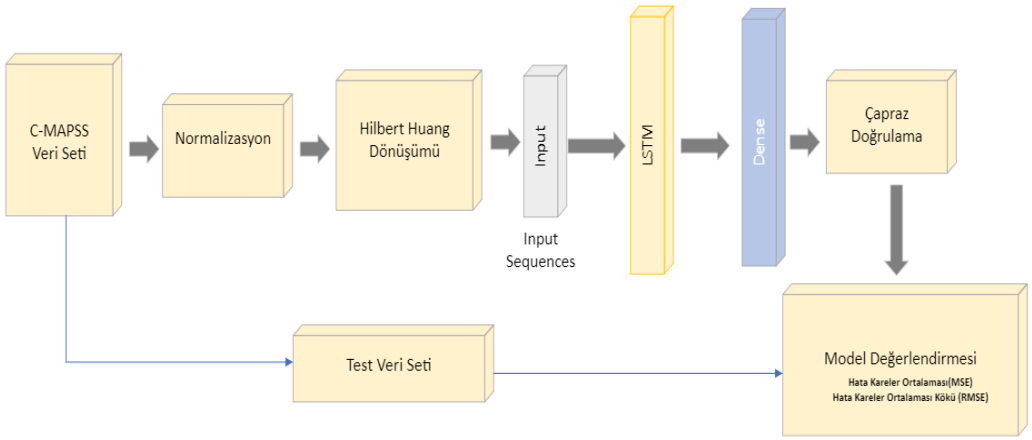

Şekil 4.11. Hilbert Dönüşümü LSTM Blok Diyagramı

Şekil 4.12'te Öğrenme Eğrisi, modelin dönem başına eğitim ve doğrulama kayıplarını çizerek modelin öğrenme süreci gözlemlendi. Bu grafik modelin iyi bir öğrenme sürecinden geçtiğini ve çoğu katlamada düşük doğrulama kaybı ile iyi genelleme yapabildiğini gösteriyor.

Ancak bazı katlamalarda yüksek doğrulama kaybı, overfitting veya veri dağılımı ile ilgili potansiyel sorunları işaret etmektedir.

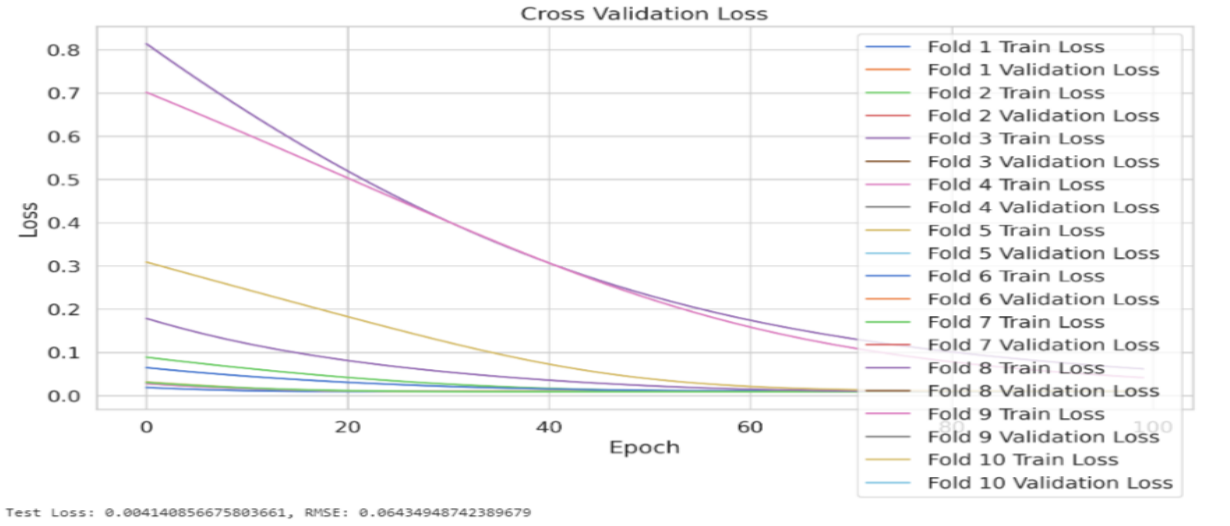

Şekil 4.12. Hilbert Huang Dönüşümü LSTM Öğrenme Eğrisi

Şekil 4.12'de eğilimler hem eğitim hem de doğrulama kayıpları genel olarak düşüyor, bu da modelin öğrenme sürecinde ilerleme kaydettiğini gösterir. Genelleme yeteneği, doğrulama kayıpları düşük ve eğitim kayıplarına oldukça yakın, bu durum modelin iyi genelleme yaptığını gösterir.

Doygunluk, epochların ilerleyen sayılarında, doğrulama kayıplarının düşüş hızı azalıyor veya sabitleniyor, bu da modelin daha fazla öğrenmeden sınırlı fayda göreceğini işaret etmektedir.

Şekil 4.13'te C-MAPSS veri setinde Hilbert Huang Dönüşümü sonrası LSTM modeli uygulandıktan sonra gerçek RUL değerleri ile tahmin edilen RUL Değerlerini göstermektedir.

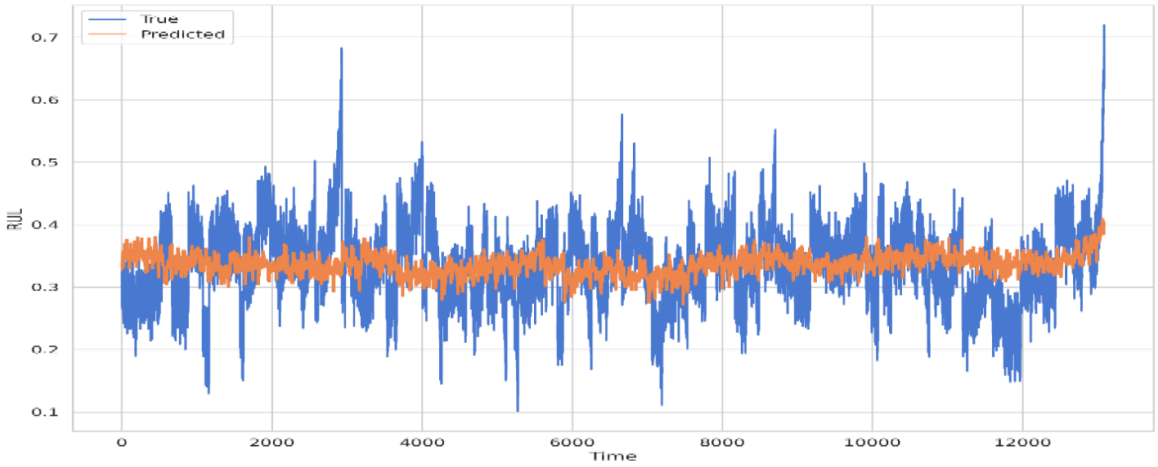

Şekil 4.13. Hilbert Huang Dönüşümü LSTM Gerçek ve Öngörülen RUL Değerleri



Şekil 4.14. Proje aşama adımları

Şekil 4.14'te görüldüğü gibi yukarıdaki işlem adımları ile LSTM derin öğrenme algoritmasına uygulanmıştır. Veri analizi süreci, öncelikle uygun bir veri setinin seçilmesi ve Google Colab ortamına yüklenmesi ile başlar. İlk incelemenin ardından veri seti, normalizasyon işlemleri ile standart bir formata dönüştürülür.

Korelasyon analizi yoluyla, model performansını artırabilecek önemli öznitelikler belirlenir ve PCA kullanılarak boyutları indirgenir, ölçeklendirilir. Eğitim ve test veri setlerinin ayrılmasını takiben regresyon ve derin öğrenme modelleri oluşturulur ve eğitilir.

Bu modellerin performansı, eğitim ve test verileri üzerindeki sonuçların karşılaştırılması ile değerlendirilir, bu da modelin gerçek dünya verileri üzerindeki uygulanabilirliği ve güvenilirliğine dair fikir verir. Bu kapsamlı süreç, veri bilimindeki standart yaklaşımlardan birini temsil eder ve anlamlı sonuçlar elde etmek için esastır.

Tablo 4.7. LSTM Modelinin Parametreleri

Parametre Adı	Açıklama	Değer
Sıra Uzunluğu (Sequence Length)	Modelin bir seferde kaç zaman adımı üzerinden öğrenme yapacağı.	seq_length=5
Özellik Sayısı (Number of Features)	Girdi veri setinin sahip olduğu özellik (sütun) sayısı.	n_features (Eğitim_FD001_scaled veri seti baz alınarak)
Gizli Birim Sayısı (Number of Hid. Units)	LSTM hücresinin sahip olduğu gizli birimlerin sayısı.	n_hidden=4
Katman Sayısı (Number of Layers)	Modelde bulunan LSTM katmanlarının sayısı.	n_layers=1
Eğitim Dönemi Sayısı (Number of Epochs)	Modelin eğitim verisi üzerinden kaç kez geçiş yaparak öğrenme gerçekleştireceği.	num_epochs=100
Yığın Boyutu (Batch Size)	Her bir eğitim adımında modelin kaç veri örneğini aynı anda işleyeceğini belirtir.	batch_size=32
Öğrenme Oranı (Learning Rate)	Modelin eğitim sırasında ağırlıklarını güncellerken ne kadar adım atacağını belirleyen parametre.	learning_rate=0.001

Tablo 4.8 LSTM modelinin parametrelerini ve bu parametrelerin ne anlama geldiğini özetlemektedir. Bu değerler, modelin eğitim süreci ve performansı üzerinde doğrudan etkilidir. Sıra Uzunluğu (Sequence Length), modelin bir defada kaç zaman adımı üzerinden öğrenme yapacağını belirler, bu çalışmada seq_length 5 olarak ayarlanmıştır. Özellik Sayısı (Number of Features), girdi veri setinin içerdiği Özniteliklerin (sütunların) toplam sayısını ifade eder ve burada Eğitim_FD001_scaled veri seti temel alınarak belirlenmiştir.

Gizli Birim Sayısı (Number of Hidden Units), LSTM hücrelerinin içerdiği gizli birimlerin toplamını gösterir ve bu model için n_hidden 4 olarak ayarlanmıştır. Modelin içerdiği LSTM katman sayısı (Number of Layers), n_layers 1 ile belirlenmiştir. Eğitim Dönemi Sayısı (Number of Epochs), modelin eğitim verisi üzerinden kaç defa geçiş yaparak öğrenme gerçekleştireceğini belirten num_epochs 100 değeri ile ifade edilir. Yığın Boyutu (Batch Size), her eğitim iterasyonunda modelin işleyeceği veri örneklerinin sayısını belirtir ve bu değer batch_size 32 olarak belirlenmiştir.

5. BULGULAR VE TARTIŞMA

Bu tez çalışmasında, Fourier transformasyonları kullanılarak motorların kalan kullanım ömürlerinin tahmini yapılmış ve bu tahminler C-MAPSS veri seti üzerinde klasik ve derin öğrenme algoritmaları ile test edildi. Analiz sonuçları Tablo 5.1'de, RMSE ve R2 değerleri ile hem eğitim hem de test verileri için raporlandı. RMSE değerlerine göre, Hilbert Dönüşümü kullanılarak geliştirilen LSTM modelinin, diğer modellere göre daha düşük hata oranlarına sahip olduğu ve böylece daha doğru tahminler sunduğu belirlendi.

R2 skoru ise, modelin bağımsız değişkenlerce açıklanan varyansın ne kadarını yakalayabildiğini gösterir. Bu skor 0 ile 1 arasında değişmekte olup, 1'e yaklaşması modelin verilerin varyansını büyük ölçüde açıklayabildiğine ve iyi bir uyuma sahip olduğuna işaret eder. Ancak, R2 değerinin çok yüksek olması her zaman olumlu bir gösterge değildir, çünkü aşırı uyum sorununa yol açabilir. Aşırı uyum, modelin eğitim verisine aşırı derecede uyum sağladığı ancak yeni verilere karşı genelleme yapma kapasitesinin düşük olduğu durumları ifade eder. Bu nedenle, yüksek R2 skorları olumlu karşılanırken, modelin performansını değerlendirirken overfitting ihtimaline karşı dikkatli olunmalı ve ek doğrulama yöntemleri kullanılmalıdır.

Tablo 5.1 Regresyon Modellerinin Karşılaştırılması

No	Model Adı	RMSE-Eğitim	R2-Eğitim	RMSE Test	R2 Test
1	Doğrusal Reg.	27.3416	0.98093	29.1426	0.97849
2	SVM	24.2864	0.73558	28.2826	0.72408
3	RF	21.1749	0.74320	20.8111	0.74919
4	XgBoost	16.4267	0.77782	16.5703	0.77624
5	NN	20.2857	0.76303	20.2579	0.76235
6	CNN	36.7974	0. 7171	36.1217	0. 7144
7	Wavelet+LSTM	12.659	0.03232	12.646	0.0199
8	Hilbert+LSTM	10.1414	0.10464	12.4349	0.0662
9	Wavelet CNN+LSTM	37.42040	0.04320	42.29297	0.4421
10	Hilbert CNN+LSTM	36.7606	0.7177	91.7510	-3.9144
11	Wavelet SVR	45.68817	0.56402	45.28972	0.55105

Tablo 5.1 de görüldüğü üzere Hilbert dönüşümü ile LSTM modeli, RMSE değerleri bakımından hem eğitim hem de test verileri için en iyi performansı göstermektedir. Özellikle test verisindeki RMSE değeri 12.4349 ile diğer tüm modellere göre oldukça düşüktür. Wavelet SVR modeli, test verisinde 45.28972 RMSE değeri ile en düşük performansı göstermiştir. Hilbert dönüşümü ile CNN+LSTM modeli, test verisinde-3.9144 ile negatif bir R2 değeri göstermektedir. Bu, modelin tahminlerinin veriye uymadığını göstermektedir. Verilere bağlı olarak, bazı modeller diğerlerinden daha iyi performans gösterebilir. Bu tezdeki CMAPSS veri seti için Hilbert dönüşümü ile CNN-LSTM modeli en iyi performansı gösterdi.

LSTM'in zaman serisi verileriyle iyi çalışmasının yanı sıra Hilbert-Huang dönüşümünün de bu tür verilere uygun olduğunu gösterir. Daha karmaşık modellerin (örn. CNN+LSTM kombinasyonları) her zaman daha iyi performans göstermediği gözlemlenmektedir. Bu, model seçiminde karmaşıklığın tek başına bir kriter olmadığı, veriye uygunluğunun da dikkate alınması gerektiği gözlemlendi. Dönüşüm yöntemleri ele alındığında Hilbert ve Wavelet dönüşüm yöntemlerinin aynı modele (CNN-LSTM) uygulandığı halde farklı sonuçlar ürettiği gözlemlenmektedir. Bu durum, dönüşüm yönteminin model performansı üzerinde önemli bir etkisi olduğunu gösterdi.

Tablo 5.2 Veri Ön işleme ve Öznitelik Seçimi

Model	**Veri Ön İşleme ve Öz Nitelik Seçimi**	**Çıkarılan Sensörler**	**RMSE-Test**
Hilbert LSTM	Veri Normalizasyonu, Ayrık Verilerin çıkarılması, Boş gelen dataların ayıklanması, Sensör koralasyonu ve Temel bileşen analizine göre Öznitelik seçimi	5,9,14,20,22,23,26,27	12.4349
Hilbert LSTM	Yapılmadı.	-	17.7429

Tablo 5.2'de 1. Sütunda Hilbert dönüşümü ve LSTM modeline Veri Önişleme ve Öznitelik adımlarından geçen birinci sütunda ortalama kare hatası (RMSE) değerinin 2. sütun da ki değerine göre çok daha iyi sonuç verdiği gözükmektedir.

Aynı dönüşüm ve model kullanıldığı halde veri önişleme ve öznitelik seçimi yapılmadan modelin eğitilmesi ve kullanılmasında RMSE değerleri yüksek çıkmıştır Buradan veri ön işleme ve öz nitelik çıkarımının ne kadar önemli olduğu ve sonuca doğrudan etki ettiği anlanmaktadır.

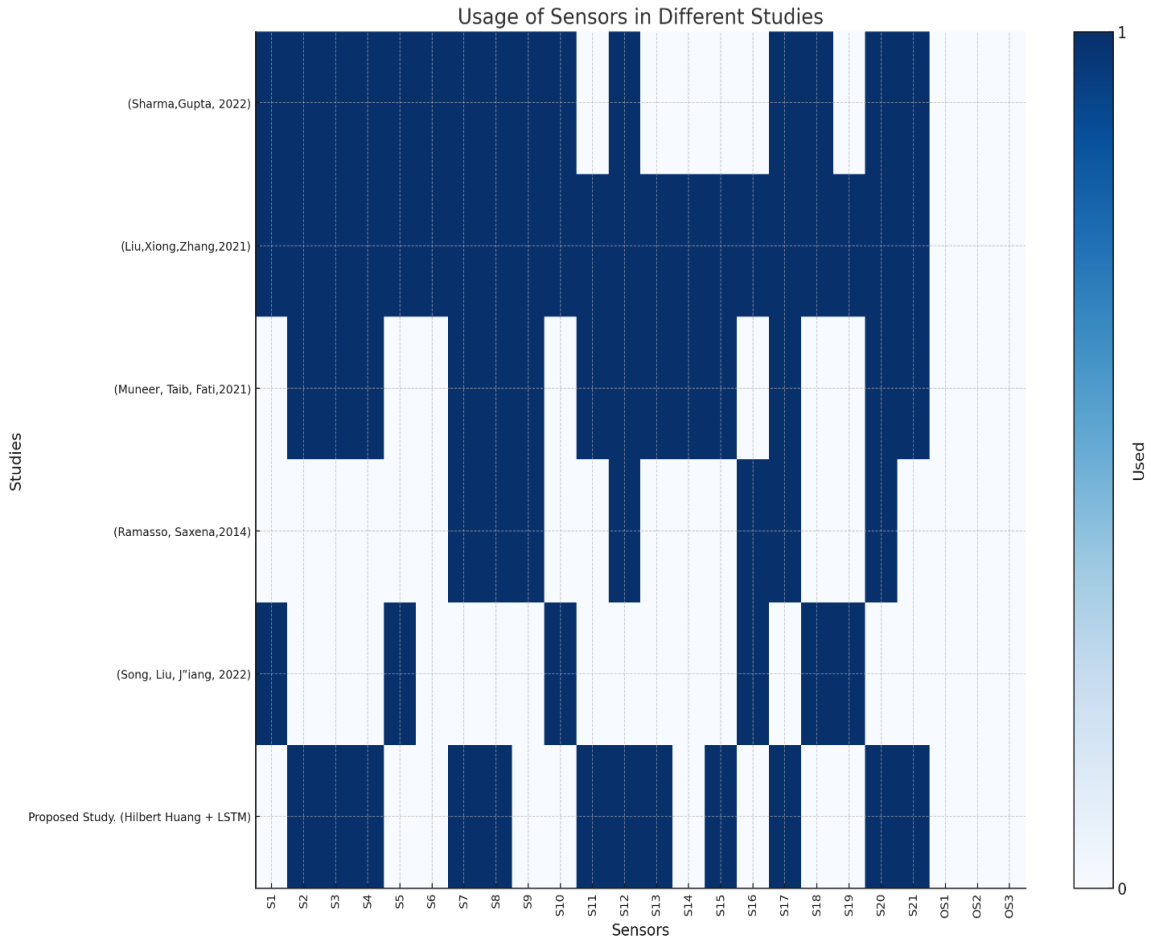

Şekil 5.1. Projeler için seçilen farklı sensör seçimleri

Şekil 5.1'de farklı çalışmaların hangi sensörleri kullandığına dair fikir sağlar ve sensör seçimindeki ortak eğilimleri veya farkları keşfetmek için kullanılmıştır.

Bu grafikte açıkça görebileceğiniz gibi, bazı sensörler (S7, S8, S12, S17, S20 ve S21) birçok çalışma tarafından seçilirken, bazıları daha az popülerdir. Tablo 5.2 de öznitelik seçiminin model üzerinde ne kadar etkili olduğunun bir göstergesi olarak kabul edilmektedir.

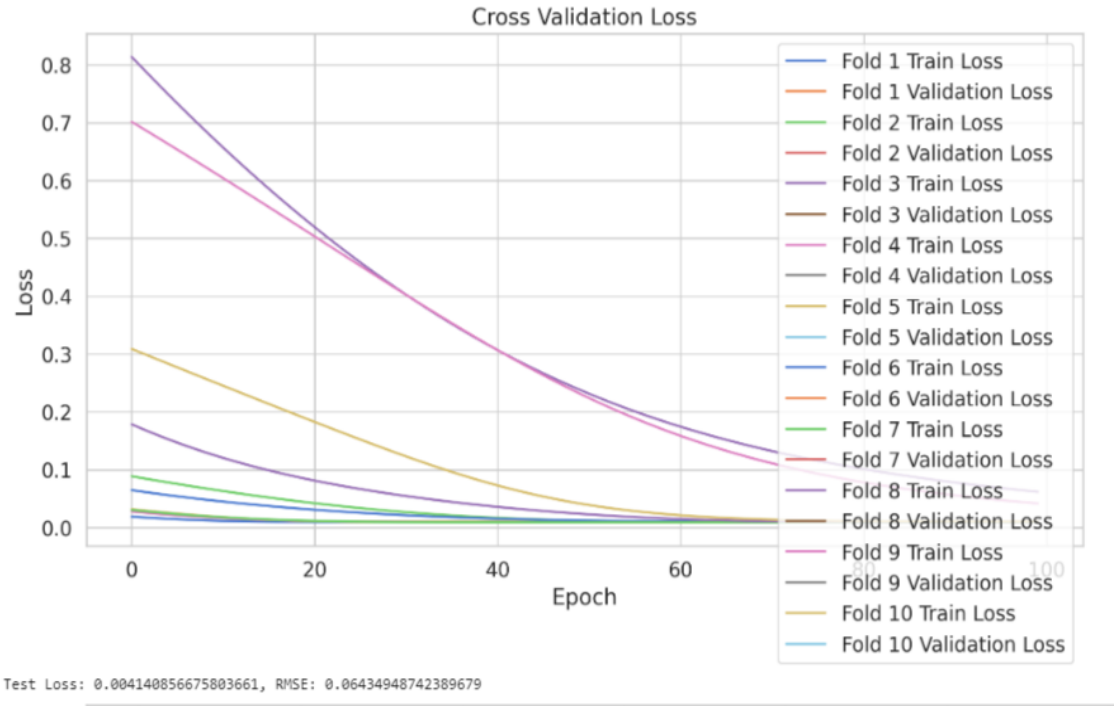

Şekil 5.2. Hilbert Dönüşümü ile LSTM Çapraz Doğrulama ve RMSE değerleri

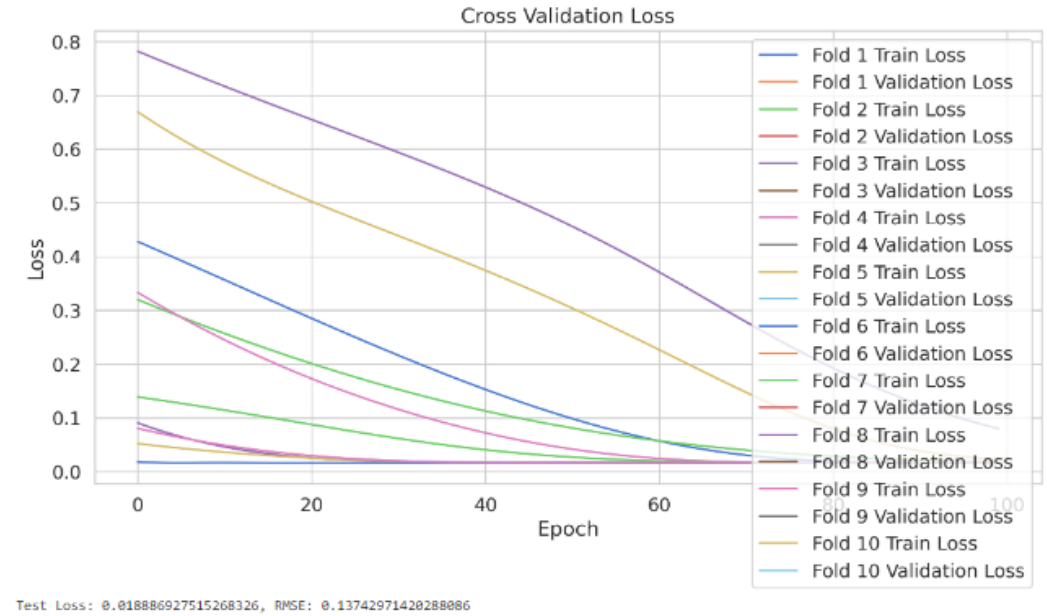

Şekil 5.3. Veri Ön İşleme ve Öznitelik Seçimi olmadan HHT ile LSTM

Şekil 5.2 ile Şekil 5.3 arasındaki fark veri ön işlemede boş değerlerin silinmesi, ayrık değer analizi ve min-max normalizasyon fonksiyonlarının kullanılmaması ve Sensör korelasyonu, temel bileşenler analizi ile öz niteliklerin seçilmemiş olmasıdır.

Hilbert Dönüşümü ve LSTM kombinasyonu, tahminlerde daha yüksek doğruluk elde etmek için klasik öğrenme yöntemlerine kıyasla daha avantajlıdır. Bu seçimler, modelin genel performansını olumlu bir şekilde etkilemiştir.

Hilbert Dönüşümü ve CNN-LSTM modelinin kombinasyonu, kestirimci bakım analizi için güçlü bir yaklaşım sunmaktadır. Bu çalışma, literatürdeki diğer çalışmalardan farklı olarak, veri setinin Özniteliklerini daha etkili bir şekilde seçerek ve işleyerek modelin performansını optimize etmesi başarıldı.

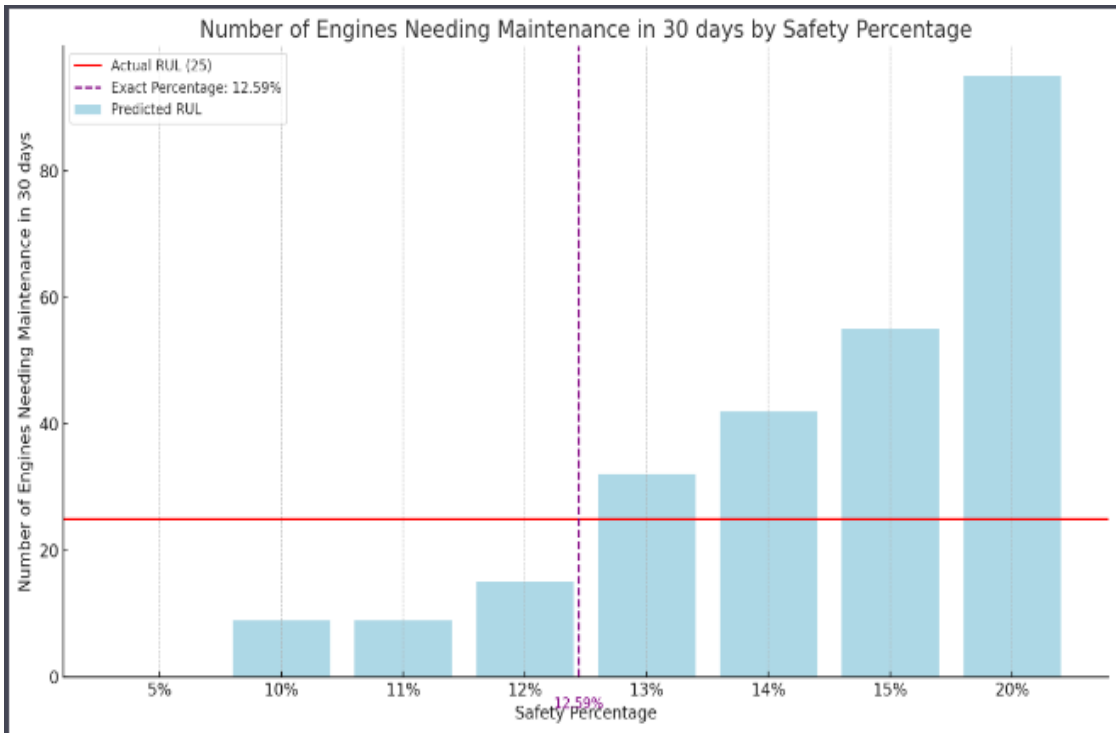

Şekil 5.4. Güvenlik kat sayısına göre bakım gerektiren motor sayısı

İlk 100 motor için 30 gün içinde bakıma ihtiyacı olan motorları bulabilmek için NASA'nın bize sağlamış olduğu RUL_FD001.txt dosyasındaki değerleri 0,30'dan küçük olanları aldığımızda bu değerin 25 olduğu bulunmuştur. Şekil 5.4'teki kırmızı çizgi bu değeri temsil etmektedir. Tahmin ettiğimiz RUL değerleri gerçek RUL değerlerine çok yakın çıkabilir.

Tahmin edilen RUL değeri gerçek RUL değerinden büyük ise motor arızalandıktan sonra bakım yapılması endüstri için yararlı olmayacağından bu tez içerisinde tahmin edilen RUL değerlerini bir güvenlik katsayısı ile çarpılması için bir çalışma yapıldı.

Şekil 5.4 ‘de görülen bar grafikleri, ilk 100 motor için 30 gün içinde Gerçek RUL dosyasındaki tahmin edilen motor bakım sayısı (25) ile modelimizin RUL bakım tahminlerinin farklı güvenlik katsayısı yüzdelikleri ile (5, 10, 11, 12, 13, 14, 15, 20) çarpımından elde edilen değeri, tahmin edilen RUL değerinden çıkarılarak elde edilen güvenlik katsayısı çarpılmış RUL değerleri ile karşılaştırılmasını gösterdi.

Bu grafik, farklı güvenlik katsayılarına göre modelin nasıl performans gösterdiğini ve gerçek RUL değeriyle (25) nasıl karşılaştığını gösterdi. Bu, modelin performansını değerlendirmek ve bakım kararları alırken dikkate alınması gereken faktörleri belirlemek için kullanıldı.30 gün içinde gerçek RUL değerine göre bakım gerektiren motor sayısı(25) değerinin altındaki ve üstündeki en yakın iki değer bulunduktan sonra bu iki nokta arasında aşağıda formülünü görebileceğiniz doğrusal bir interpolasyon gerçekleştirildi ve 30 gün içinde tahmin edilen RUL değeri hangi yüzdelik ile çarpılıp kendi değerinden çıkarıldığında 25 motoru kapsayacak şekilde bakım yapılacağı hesaplandı.

$$x = x_1 + \left(\frac{y_{hedef} - y_1}{y_2 - y_1}\right) * (x_2 - x_1) \tag{5.1}$$

5.1 denkleminden anlaşılacağı üzere, x_1 ve x_2 iki yüzdelik değeri temsil eder (örn. %12 ve %13). y_1 ve y_2 İki yüzdeliğe karşılık gelen motor sayılarıdır. y_{hedef} Tam olarak bulmaya çalıştığımız motor sayısı olan 25 adettir.

Sonuç olarak, bu tez, derin öğrenme algoritmalarının ve özellik seçimi yöntemlerinin kestirimci bakım analizinde ne kadar etkili olabileceğini göstermektedir. Bu çalışma, endüstriyel ekipmanların bakım ve onarım süreçlerini optimize etmek için Fourier dönüşümleri ile derin öğrenme yöntemlerinin nasıl kullanılabileceği konusunda önemli bir katkı sağlamaktadır.

6. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, Fourier dönüşümlerinden faydalanılarak LSTM, CNN, LSTM+CNN gibi derin öğrenme algoritmaları ile motorların faydalı ömürlerinin tahmini gerçekleştirilmiştir. Özellikle Hilbert Dönüşümü ile desteklenen LSTM modelinin, klasik öğrenme ve Wavelet dönüşümü ile kullanılan derin öğrenme yöntemlerine göre daha üstün performans sergilediği gözlemlendi.

Hilbert Dönüşümü ve LSTM kombinasyonu ile klasik öğrenme yöntemlerine göre daha düşük RMSE değeri ve daha yüksek R2 skoru elde edilmektedir. Bu yöntemin kestirimci bakım analizinde daha doğru ve tutarlı sonuçlar verdi.

Tablo 5.2 incelendiğinde veri ön işleme adımlarının yapılmasının ve özellik seçimi konusunda Temel bileşen analizi ile sensör korelasyon analizi gibi yöntemlerin etkili bir şekilde kullanılmasının, modelin performansının optimize edilmesine önemli bir katkı sağladığı ve görüldü. Özellik seçimi konusunda literatürdeki geleneksel yöntemlerin ötesine geçilerek, veri setinin Özniteliklerinin daha etkili bir şekilde seçilmesi ve işlenmesi tavsiye edildi.

Şekil 5.4 de gösterildiği gibi motorların tahmin edilen kalan faydalı ömürlerinin bir güvenlik katsayısı ile çarpılarak arızalanmadan önce bakım yapılması motorun RUL tahmini çok yakın bulunmasına rağmen arızalanma gününden sonra yapılmış bir tahminden can ve mal kaybının önüne geçilmesi için daha fazla önem arz etmektedir.

Endüstriyel uygulamalarda, kestirimci bakımın daha etkili bir şekilde gerçekleştirilmesi için Fourier dönüşümlerinden Hilbert Dönüşümü ile desteklenen LSTM modelinin kullanılması önerilmektedir.

Gelecekteki çalışmalarda, bu tezde sunulan yöntemlerin farklı endüstriyel veri setleri üzerinde de test edilerek genelleştirilmesi önerildi. Bu tez, kestirimci bakım analizinde veri ön işleme adımları ve öznitelik seçiminin önemi ve bu seçilen öz niteliklerin Fourier dönüşümleri ile derin öğrenme yöntemlerinden LSTM'in etkili bir şekilde nasıl kullanılabileceğini göstererek, bu alandaki literatüre önemli bir katkıda bulunmaktadır.

KAYNAKLAR

Ahmed (2020). Kalar'daki Hipertansiyonlu Hastaların Sayısını Tahmin Etmek İçin Yapay Sinir Ağı ve Box-Jenkins Modellerinin Karşılaştırılması. *Ibn al-Haitham Journal for Pure and Applied Science*. DOI: 10.30526/33.4.2516.

Amelia, P. ve Robert M. (2021). A Machine Learning Predictive Model for Post-Ureteroscopy Urosepsis Needing Intensive Care Unit Admission: A Case–Control YAU Endourology Study from Nine European Centres. *Journal of Clinical Medicine*, *2*(2), 170-181. https://doi.org/10.3390/jcm10173888

Chakraborty, S. ve Bhattacharya, S. (2021). CNC torna işleminde xgboost algoritmasının kestirimci aracı olarak uygulanması. *Reports in Mechanical Engineering*, *2*(2), 190-201.

Gedikli, T., Ervural, B. Ç., ve Şen, D. T. (2021). Bulanık TOPSIS ve Bulanık AHP Yaklaşımlarıyla En Uygun Bakım Stratejisinin Belirlenmesi: *Bir Gıda İşletmesinde Uygulama Avrupa Bilim ve Teknoloji Dergisi*, (22), 212-225.

H. Liu, Z. Liu, W. Jia, ve X. Lin (2021). Yenilikçi özellik-dikkat tabanlı uçtan uca yaklaşım kullanarak kalan kullanım ömrü tahmini. *IEEE Transactions on Industrial Informatics*, *17*(2), 1197–1207.

H. Mo, F. Lucca, J. Malacarne, ve G. Iacca (2020). Kalan kullanım ömrü tahmini için çok başlıklı CNN-LSTM ve tahmin hata analizi. 27. *Açık İnovasyon Derneği (FRUCT) Konferansı'nda Bildiriler*, Eylül 2020, s. 164–171.

Ju Yoon, Nguyen Minh Nhat, Hyun Lee, Jang Youn, Dang Kim, Dong Lee, ve Kyoung Kwan Ahn. (2016). Bir eppr valf solenoidinin tasarım parametrelerinin yapay sinir ağı kullanılarak optimizasyonu. *Journal of Drive and Control*, 13:34–41.

Kahraman (2020). Turbo fan Motorları için Kestirimci Bakımın LSTM ve WaveNet Uygulaması. doi: 10.1109/CINTI51262.2020.9305820.

Kankaya, G. (2022). Kestirimci bakım yaklaşımıyla bir turbofan motorunun çözümlenmesi. Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.

Kaner, S. (2021). Endüstri 4.0 için derin öğrenme kullanan durum izleme ve kestirimci bakım yöntemlerinin geliştirilmesi. Erişim adresi:https://abs.firat.edu.tr/tr/iaydin/publications

Kiangala, K. ve Wang, Z. (2020). Endüstri 4.0 ortamında konveyör motorları için çift zaman serisi görüntüleme ve evrişimli sinir ağı kullanarak etkili bir kestirimci bakım çerçevesi. *IEEE Access, 8*, 121033-121049.

Kong, Z., Y. Cui, Z. Xia, ve H. Lv (2019). Kalan kullanım ömrü prognozları için konvolüsyon ve uzun kısa süreli bellek hibrit derin sinir ağları. *Applied Sciences, 9*(19), 4156.

Kumar, S., ve Singh, A. (2019). Thingspeak IoT platformu kullanarak kompresörün prediktif bakımı. *International Journal of Innovative Technology and Exploring Engineering, 8*(12), 3621-3625.

Li, X., Ding, Q. ve Sun, J. (2018). Prognostiklerde derin evrişimli sinir ağlarını kullanarak kalan faydalı ömrün tahmini. *Güvenilirlik Mühendisliği & Sistem Güvenliği*, 172, 1-11. doi: 10.1016/j.ress.2017.11.021.

Lundberg, S. M., & Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions. *Paul G. Allen School of Computer Science*, University of Washington, Seattle, WA, 98105.

Nathaniel, E., George, N., Ibanga, J., ve Ekanem, A. (2016). Manyetoşerit'in anlık düşük frekans dalgalarının analizinde Hilbert-Huang dönüşümünün (HHT) etkinliği. *International Journal of Geosciences, 7*(01), 11-19. doi: 10.4236/ijg.2016.71002.

Özdemir, M., ve Çelikten, E. (2018). Üretim sistemlerinde makine öğrenmesi ile kestirimci bakım uygulaması ve modellemesi. *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 10*(3), 189-196.

Pan, B. (2018). Saatlik pm2,5 konsantrasyonunun tahmininde xgboost algoritmasının uygulanması. *IOP Konferans Serisi: Dünya ve Çevre Bilimi*, 113, 012127.

Q., Liu, X., ve Zhao, L. (2014). Hilbert–Huang dönüşümü ve destek vektör makinesine dayalı motor arıza teşhisi için zeki bir yaklaşım. *Applied Acoustics*, 75, 1-9. doi: 10.1016/j.apacoust.2013.07.001.

R. Konieczny ve R. Idczak (2016). Mekanik alaşımlama ile hazırlanan Fe-Re alaşımlarının Mo¨ssbauer incelemesi. *Hyperfine Interactions, 237*(1):1–8. doi: 10.1007/s10751-016-1232-6.

Saeed, M.T.M. (2020). Temel bileşenler analizi ve yapay sinir ağları kullanılarak turbo fan motorunun kalan faydalı ömür tahmini. Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.

Tahan, M., Tsoutsanis, E., Muhammad, M., ve Karim, Z. A. (2017). Performance based health monitoring, diagnostics and prognostics for condition based maintenance of gas turbines: *A review. Applied Energy*, (198), 122-144.

Taşcı, B. (2021). İmalatta kestirimci bakım için kalan kullanılabilir ömür tahmini. Yüksek Lisans Tezi, Bahçeşehir Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

Türe, B. (2021). Yapay zekâ yöntemleri kullanılarak prediktif bakım modelinin tasarımı: *BŞEÜ Fen Bilimleri Dergisi, 8*(1), 497-511, 2021.

Ünlü, M. (2006). Anahtarlı Relüktans Makinasının Modellenmesi ve Dinamik Davranışı. Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli, 154848.

Wang, Q., Bu, S., ve He, Z. (2020). High speed railway power equipment için LSTM RNN ile prediktif ve proaktif bakımın gerçekleştirilmesi. *IEEE Transactions on Industrial Informatics, 16*(10), 6509-6517. https://doi.org/10.1109/TII.2020.2966033

Yıldırım, M., ve Özçakır, F. (2019). Makine öğrenmesi ile kestirimci bakım ve anomali tespiti. Akademik Bilişim Konferansı Bildirileri, 23-25 Ocak 2019, Çanakkale Onsekiz Mart Üniversitesi.

Zafar, M. ve Khan, N. (2021). Deterministic local interpretable model-agnostic explanations for stable explainability. *Machine Learning and Knowledge Extraction, 3*(3), 525-541. https://doi.org/10.3390/make3030027

KİŞİSEL YAYIN VE ESERLER

Ak, V., İnner. B., (2023). Predictive Maıntenance Of Turbofan Engınes Usıng Long-Short-Term Memorymethod. *Approach,9th Internatıonal "Başkent" Congress On Physıcal, Engıneerıng*, Ankara, 20-23 Mayıs 2023.

ÖZGEÇMİŞ

Mercedes-Benz Türk A.Ş.'de kıdemli iş analisti ve proje yöneticisi olarak çalışıyorum. TOGG' da MES (Üretim Yönetim Sistemi) proje yöneticisi olarak çalıştım. Baykar Savunma Sanayinde haberleşme sistemleri ve HMI arayüzünden sorumlu Ekip Lideri olarak çalıştım. Robo Otomasyon Firmasında Ford Otosan için Endüstri 4.0 kapsamında MES programının yazılımında ekip lideri olarak çalıştım. Toyotetsu ve Kordsa firmalarında çeşitli IT projelerinde yazılım danışmanlığı ve MES programının üretim sahasından gerçek zamanlı veri toplanması, bu verinin işlenerek analiz edilmesi veya anlık izlenmesi çalışmalarında yer aldım.