TURBOFAN MOTORUNUN UZUN-KISA SÜRELİ BELLEK YÖNTEMİ YAKLAŞIMI İLE KESTİRİMCİ BAKIMI

Volkan AK,

Kocaeli Üniversitesi, Mühendislik Fakültesi / Bilgisayar Mühendisliği

ORCID ID: https://orcid.org/0009-0009-7815-3115

Dr. Öğr. Üyesi A. Burak İNNER

Kocaeli Üniversitesi, Mühendislik Fakültesi / Bilgisayar Mühendisliği

ORCID ID: https://orcid.org/0000-0003-0933-654X

Özet

Bu çalışmada, özellikle üretim sektörü bağlamında Kestirimci Bakım (KB) stratejisinin maliyetleri azaltma potansiyelini ortaya çıkarmak için çalışmalar yürütülmüştür. Üretim süreçlerinden elde edilen büyük miktarda veri, doğru bir şekilde derin öğrenme algoritmalarıyla kullanıldığında, hata tahmini ve teşhisi konusunda çok büyük avantajlar sunabilir. Bu sayede kaynaklar optimize edilir ve durma süreleri azaltılır. Bu çalışmanın ana hedefi, Uzun Kısa Vadeli Bellek (LSTM) modeli kullanılarak Kalan Kullanılabilir Ömür (RUL) tahmininin yüksek başarı oranı ile hesaplamaktır. LSTM, bir tür tekrarlayan sinir ağıdır ve uzun süreler boyunca öğrenme ve hatırlama yeteneği ile geleneksel sinir ağlarının eğitiminde yaygın bir sorun olan kaybolan gradyan problemini çözmek için seçilmiştir. Bu modelin etkinliğini test etmek için, NASA tarafından sağlanan 100 Turbofan motorunun 21 sensör verisi kullanılmıştır. Bu verisetini kullanan bazı çalışmalarda sensör verilerinin tamamını kullanmak yerine sadece bazı sensör verilerinin tercih edildiği görülmüştür. Bu çalışmada yüksek boyutlu verilerle başa çıkmak, hesaplama maliyetini azaltmak ve model performansını iyileştirmek için boyut indirgeme adımlarında Temel Bileşenler Analizi (PCA) kullanılmıştır. Ayrıca, korelasyon değerleri 0.8'den yüksek olan sensörler, tahmin doğruluğunu artırmadaki önemleri nedeniyle öznitelik seçim sürecinde önceliklendirilmiştir. Eğitim için toplam 20631 veri varken, test için 13096 veri kullanılmıştır. Veriler "sağlam" ve "bakım gerekli" olmak üzere iki kategoride etiketlenmiştir. RUL değeri 150'nin altında olan motorlar bakıma ihtiyaç duymaktadır diye etiketlenmiştir. Model, bu verileri girdi olarak alır ve her motor için RUL değerini çıktı olarak verir. LSTM modelinin performansı, Ortalama Mutlak Hata (MAE), R-Kare (R2) ve Kök Ortalama Kare Hata (RMSE) gibi birkaç metrik ile değerlendirilmiştir. Sonuçlar, Linear Regresyon, Random Forest, Support Vector Machine, XgBoost ve Neural Network Modeli gibi diğer popüler RUL tahmin modelleri ile karşılaştırılmıştır. Araştırmanın bulguları, LSTM modelinin diğer yöntemlere kıyasla RUL tahmininde etkili ve doğru bir yöntem olduğunu göstermektedir. Ayrıca Temel Bileşenler Analizi yapılarak seçilen sensör verileri kullanıldığında mevcut çalışmalardan daha başarılı LSTM sonuçları elde edilmiştir. Araştırmadan elde edilen

bulgular, LSTM modelinin RUL tahmininde güçlü ve doğru bir yöntem olduğunu, tahmin doğruluğu açısından diğer yöntemlerden üstün olduğunu göstermektedir. Bu makale, KB stratejileri üzerindeki devam eden tartışmalara katkıda bulunur ve LSTM modellerinin RUL tahmini için kullanılabilirliği hakkında değerli bilgiler sunar. Ayrıca, benzer konulardaki gelecekteki araştırmalar için sağlam bir çerçeve sağlar ve RUL tahmin modellerinin daha iyi performans için daha da geliştirilme olasılığını önerir.

Anahtar Kelimeler: Kestirimci Bakım, Derin Öğrenme, Uzun Kısa Vadeli Bellek (LSTM), Temel Bileşen Analizi (PCA), Öznitelik Seçimi

Predictive Maintenance of Turbofan Engines Using Long-Short-Term Memory Method Approach

Abstract

In this study, studies have been carried out to reveal the potential of Predictive Maintenance (PM) strategy to reduce costs, especially in the context of the manufacturing sector. Large amounts of data from manufacturing processes, when properly utilized with deep learning algorithms, can offer enormous advantages in fault prediction and diagnosis. In this way, resources are optimized and downtime is reduced. The main objective of this study is to calculate the Remaining Usable Life (RUL) estimation with high success rate using the Long Short Term Memory (LSTM) model. LSTM is a type of recurrent neural network and was chosen to solve the vanishing gradient problem, which is a common problem in training traditional neural networks with its ability to learn and remember over long periods of time. To test the effectiveness of this model, 21 sensor data of 100 Turbofan engines provided by NASA were used. It has been observed that in some studies using this dataset, only some of the sensor data is preferred instead of using all of the sensor data. In this study, Principal Component Analysis (PCA) was used in the dimensionality reduction steps to deal with high dimensional data, reduce computational cost and improve model performance. Furthermore, sensors with correlation values higher than 0.8 were prioritized in the feature selection process due to their importance in improving prediction accuracy. A total of 20631 data were used for training, while 13096 data were used for testing. The data was labeled in two categories: “intact” and “maintenance required”. Engines with a RUL value below 150 are labeled as in need of maintenance. The model takes this data as input and outputs the RUL value for each engine. The performance of the LSTM model is evaluated by several metrics such as Mean Absolute Error (MAE), R-Square (R2) and Root Mean Square Error (RMSE). The results are compared with other popular RUL forecasting models such as Linear Regression, Random Forest, Support Vector Machine, XgBoost and Neural Network Model. The findings of the study show that the LSTM model is an effective and accurate method for RUL forecasting compared to other methods. In addition, when the sensor data selected by Principal Component Analysis is used, LSTM results are more successful than the existing studies. The findings of the study show that the LSTM model is a powerful and accurate method for RUL prediction and is superior to other methods in terms of prediction accuracy. This paper contributes to the ongoing debate on KB strategies and provides valuable insights into the usability of LSTM models for RUL forecasting. It also provides a solid framework for future research on similar topics and suggests the possibility of further development of RUL forecasting models for better performance.

Keywords: Predictive Maintenance, Deep Learning, Long Short-Term Memory (LSTM), Principal Component Analysis (PCA), Feature Selection

1. GİRİŞ (INTRODUCTION)

Kestirimci bakım (PdM), endüstriyel ekipmanların arızalanmasını veya bozulmasını önceden tahmin ederek maliyetleri azaltmayı amaçlayan bir stratejidir

1. PdM, ekipmanın durumunu izlemek ve arızaların oluşma olasılığını belirlemek için sensör verileri gibi farklı veri kaynaklarından yararlanır. PdM, üretim sürecinin verimliliğini ve güvenilirliğini arttırmanın yanı sıra enerji tasarrufu, atık azaltma ve çevresel etkiyi de iyileştirir.

PdM uygulamalarında derin öğrenme (DL) algoritmalarının kullanılması son yıllarda giderek popüler hale gelmiştir. DL algoritmaları, karmaşık ve yüksek boyutlu verilerden özellik çıkarmak ve zaman serisi analizi yapmak için güçlü yeteneklere sahiptir. DL algoritmalarından en yaygın olarak kullanılanları evrişimli sinir ağları (CNN) ve uzun kısa vadeli bellek ağları (LSTM)dir. CNN'ler, verilerden yerel ve küresel özellikler çıkarmak için çok katmanlı bir mimari kullanırken, LSTM'ler zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenmek için geri beslemeli bir mimari kullanır.

Endüstride kullanılan bakım yöntemleri aşağıdaki gibidir.

a)Periyodik Bakım: Bu yaklaşımın amacı, arıza oluşmadan önce makinenin arızalanmasına sebep olabilecek bileşenlerinin bakımının yapılmasıdır(Gedikli,2021).Çok sık yapılırsa işletme maliyetlerini artıran gereksiz bakımlara yol açabilir.

b)Duruma Dayalı Bakım: Klasik bir yaklaşım olan arızalandıktan sonra bakım yapılan uygulamalardan, arıza gerçekleşmeden önce önleme yaklaşımına geçiş için etkili bir yöntem olduğu genel olarak kabul edilmektedir. (Tahan, 2017).

c) Önleyici Bakım: Arızaların kök nedenlerini tespit etmek ve ortadan kaldırmak için gerçekleştirilen bakım faaliyetidir. Kestirimci bakım ve önleyici bakım tanımları göz önünde bulundurulduğunda, kestirimci bakımın veri odaklı bir strateji olduğu, önleyici bakımın ise model tabanlı bir çözüme odaklandığı söylenebilir (Wang, 2020).

d) Kestirimci Bakım(Predictive Maintenance)

Kestirimci bakım, sistemlerin en olası arıza sonucunu tahmin etmek için verilerin, makine öğrenme tekniklerinin ve istatistiksel algoritmaların kullanılması olarak adlandırılır. (Kimera ve Nangolo, 2020)

Kestirimci Bakım RUL (Remaining Useful Life), bir makine veya ekipmanın kullanım ömrünün ne kadar kaldığını tahmin etmek için kullanılan bir yöntemdir. Bu tahminler, makinenin geçmiş performans verileri ve diğer faktörler gibi çeşitli girdiler kullanılarak yapılır.

Mevcut literatür incelendiğinde Kestirimci Bakım Yaklaşımıyla Bir Turbofan Motorunun Çözümlenmesi isimli tezde RUL tahminlemesinde bulunmuştur. Veri önişleme adımında 21 sensörden oluşan verilerden 3 tanesini kullanmıştır. Doğrusal Regresyon,SVM,Karar Ağaçları, Regresyon ağaçları, DVM, Gaus süreç reg, Sinir Ağları yöntemlerini kullanırken, Max.Pos. Min.Neg. MAE RMSE SD kriterlerine göre tahminleme başarı oranları kıyaslamış Hassas Gauss DVm metodu overfitting olduğundan en başarısız tahminlemeleri yaparken Yapar sinir ağları en başarılı RUL tahminlemelerini yaptığı tespit edilmiştir. 54 adet motora ait verilerden oluşan doğrulama setine uygulanmıştır. Bu veri kümesindeki motorların gerçek kalan faydalı ömürleri bilinmekte olduğu için yapılan tahminlerden yola çıkılarak her bir algoritma için maksimum pozitif hata, minimum negatif hata, MAE, RMSE ve standart sapma hesaplanmış ve sonuçlar Tablo 5.1'de verilmiştir.(**KANKAYA,2022)**

Akıllı Endüstri İçin Kestirimci Bakım tezinde RUL tahminlemesinde bulunurken Akış öğrenmeye dayalı Adaptive Random Forests yönteminden faydalanmış ve MSE, MAE, RMSE kriterlerine göre tahminleme başarı oranları kıyaslanmıştır.(**ASADZADE, 2022**)

Endüstri 4.0 İçin Derin Öğrenme Kullanan Durum İzleme Ve Kestirimci Bakım Yöntemlerinin Geliştirilmesi tezinde Rulman İç 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 faydalanmış ve SqueezeNet ve GoogleNet kriterlerine göre tahminleme başarı oranları kıyaslanmıştır. (**KANER**, 2022)

Remaıning Useful Lıfetıme Predıctıon For Predıctıve Maıntenance In Manufacturıng tezinde RF, XGB, SVR, MLP yönteminden faydalanmış ve R2, MAE, MAPE, RMSE kriterlerine göre tahminleme başarı oranları kıyaslanmıştır. (**TAŞCI**, 2022)

Desıgn Of Predıctıve Maıntenance Model Usıng Artıfıcıal Intellıgence Methods tezinde Linear Reg, SVM, Random Forest, Decision Tree, Stacking Ensemble Learning , CNN yönteminden faydalanmış ve Accuracy , RMSE, Standart Dweviation kriterlerine göre tahminleme başarı oranları kıyaslanmıştır.(**TÜRE**, 2022)

Uçak Motoru Sağlığı için Uzun-Kısa Süreli Bellek Yöntemi ile Öngörücü Bakım tezinde Uzun-Kısa Süreli Bellek (LSTM),CNN,SVR yapısı kullanılarak, uçak motorlarının kalan yaşam ömürlerinin tahmin edilmiştir.Ortalama Mutlak hata, Ortalama Karesel hata kriterlerine göre en başarılı metodun LSTM(%98,8) olduğunu açıklamıştır.**(KIZRAK,2019)**

Bu çalışmada derin öğrenme modelleri LSTM (Long-Short Term Memory) olan uzun-kısa süreli bellek mimarisi kullanımının ANN(neural network), XGBoost ve diğer temel regresyon ve yapay sinir ağı modelleri ile karşılaştırılarak, RUL tahmininde sadece daha doğru değil, aynı zamanda sınıflandırmada daha iyi bir performans gösterdiğini değerlendirmesi yapılması amaçlanmıştır.

Veri kümesi olarak NASA tarafından ücretsiz olarak dağıtılan C-MAPSS veri kümesi kullanılmıştır.

2. VERİ KÜMESİ (DATASET)

Veri kümesi içerisinde, arızanın oluştuğu farklı senaryolara sahip her 100 motorun çalışma ayarlarını ve sensör okumalarını içeren 100 motorun zaman serisi verilerini ve toplam 20631 eğitim örneğini elde ediyoruz. Bu çalışmada kullanılan 100 adet motordan alınan 21 sensör verisi mevcuttur. Eğitim için toplam 20631 veri varken, test için 13096 veri kullanılmıştır. Veriler Sağlam ve bakıma ihtiyaç duymaktadır diye iki kategoride etiketlenmiştir. RUL değeri 150'nin altında olan motorlar bakıma ihtiyaç duymaktadır diye etiketlenmiştir.

Dataset	FD001	FD002	FD003	FD004
Fault mode	1	1	2	2
Operational condition	1	6	1	6
Engines in train set	100	260	100	249
Engines in test set	100	259	100	248
Train minimum lifespan(cycles)	128	128	145	128
Train maximum lifespan(cycles)	362	378	525	543
Minimum test length(cycles)	31	21	38	19
Maximum test length(cycles)	303	367	475	486

Şekil 1 – C-MAPSS veri kümesinin temel bilgileri

PCA(Principal Component Analysis) Analizi

PCA analizi, veri setindeki değişkenlerin varyansını en üst düzeye çıkarmak için kullanılır.

Boyut azalmada PCA, SVD, LASSO en çok bilinen yöntemler olarak kullanılmaktadır. PCA, veri kümelerindeki varyasyonları temsil etmeyi hiyerarşik bir koordinat sistemi kullanarak yapabilmektedir. SVD, veriye dayalı Fourier dönüşümü yöntemidir. LASSO ise öznitelik seçimi için kullanılan diğer yöntemlerden biridir.

Makaleye atıfta bulunarak bizim yaptıklarımız referanslanacak.

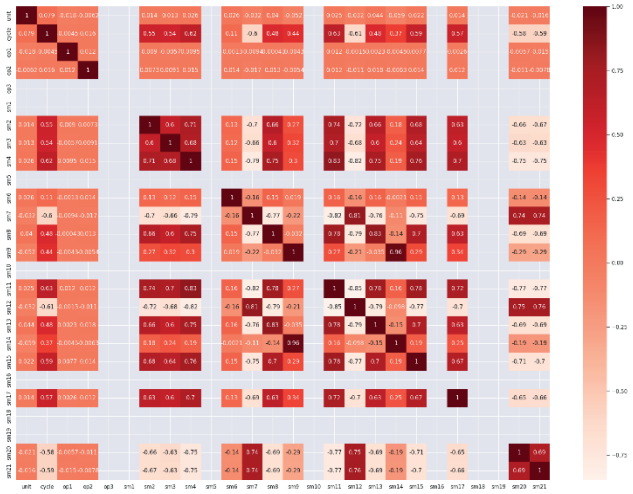

Şekil 2 – Sensör Kolarasyon Grafiği

Yukarıdaki şekilden görüldüğü üzere korelasyonları 0.8'den büyük olarak yansıyan (s2, s3, s4, s7, s8, s11, s12, s13, s15, s17, s20, s21) sensörleri öznitelik seçiminde kullanılmaktadır.

	s_2	s_3	s_4	s_7	s_8	s_11	s_12	s_13	s_15	s_17	s_20	s_21
0	641.82	1589.70	1400.60	554.36	2388.06	47.47	521.66	2388.02	8.4195	392	39.06	23.4190
1	642.15	1591.82	1403.14	553.75	2388.04	47.49	522.28	2388.07	8.4318	392	39.00	23.4236
2	642.35	1587.99	1404.20	554.26	2388.08	47.27	522.42	2388.03	8.4178	390	38.95	23.3442
3	642.35	1582.79	1401.87	554.45	2388.11	47.13	522.86	2388.08	8.3682	392	38.88	23.3739
4	642.37	1582.85	1406.22	554.00	2388.06	47.28	522.19	2388.04	8.4294	393	38.90	23.4044

Şekil 3 – Data Örneği

Kurulan modellerin değerlendirilmesi için skor olarak MAE ve R2 değerleri ele alınmaktadır.

Ortalama Mutlak Hata(MAE)

$$MAE = \frac{1}{n}\sum_{k=1}^{n}(x_k - x)$$ ta, Regresyon modellerinde kullanılan değerlendirme metriklerinden biridir.

MAE Formülü

R-Kare(R2)

Regresyon modellerindeki değişkenlerin bir bağımlı değişken için varyansın oranını temsil eden istatistiksel bir ölçüdür.

$$R^2 = 1 - \frac{Unexplained\ Variation}{Total\ Variation}$$

R-Kare Formülü

RMSE (Root Mean Square Error)

RMSE bir ölçüm metriğidir. RMSE, bir modelin tahmin ettiği değerler ile gerçek değerler arasındaki ortalama mesafeyi gösterir. RMSE ne kadar düşükse, model veriye o kadar iyi uyar

$$RMSE = \sqrt{(f - o)^2}$$

3. Regresyon ve Derin Öğrenme Algoritmaları

Linear Regresyon

Doğrusal regresyon algoritması, bir veri setindeki değişkenlerin birbirleriyle olan ilişkisini analiz eder ve bu ilişkiyi kullanarak bir hedef değişkenin değerini tahmin etmek için bir model oluşturur. Bu model, veri setindeki değişkenlerin doğrusal birleşimini kullanarak hedef değişkenin değerini tahmin eder. Turbofan datasetine Linear Regresyon Modeli uygulandığında elde edilen değerler aşağıdaki tablo 1 de verilmiştir.

Tablo 1 – Linear Regresyon Metrik Değerleri

Model	RMSE-Train	R2-Train	RMSE-Test	R2-Test
LR	22.734165	0.702385	22.914265	0.695945

SVM (Support Vector Machine)

SVM modeli, makine öğrenimi alanında sınıflandırma ve regresyon problemlerini çözmek için kullanılan bir öğrenme algoritmasıdır. SVM modeli, veri noktalarını bir uzayda görselleştirmek için bir yöntem olan boyut indirgeme kullanır ve bu verileri iki sınıfa ayırır.

SVM modeli, sınıflandırma problemlerinde, öğrenme verilerinin sınırlarının belirsiz olduğu durumlarda, yani doğrusal olarak ayrılabilir olmayan verilerde kullanılabilir. SVM modeli, verileri uygun bir şekilde dönüştürerek, daha yüksek boyutlu bir uzaya taşıyarak ve bu uzayda sınıfların arasında bir çizgi ya da hiperdüzlem belirleyerek sınıflandırma yapar.

Turbofan datasetine SVM Regresyon Modeli uygulandığında elde edilen değerler aşağıdaki tabloda verilmiştir.

Tablo 2 – SVM Regresyon Metrik Değerleri

Model	RMSE-Train	R2-Train	RMSE-Test	R2-Test
SVM	2 14.28641	0.735585	2 18.28222	0.724084

Random Forest

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.

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.

Turbofan datasetine RF Regresyon Modeli uygulandığında elde edilen değerler aşağıdaki tabloda verilmiştir.

Tablo 3 – Random Forest Metrik Değerleri

Model	RMSE-Train	R2-Train	RMSE-Test	R2-Test
RF	21.117494	0.743208	20.81115	0.749197

XGBoost

XGBoost, GB yöntemini en iyi şekilde kullanan ve endüstriyel ve akademik kullanım alanlarında yaygın olarak kullanılan bir açık kaynak kodlu kütüphanedir. XGBoost, paralel işlemciler ve dağıtık sistemlerle uyumlu bir şekilde çalışır, bu da büyük ölçekli verilerle uğraşan uygulamalar için idealdir.

XGBoost'un ana özellikleri şunlardır:

1. Özel hesaplama yöntemleri kullanarak hızlı bir şekilde çalışır.
2. Çok çeşitli hiperparametrelerle özelleştirilebilir.
3. Ayrıca, sınıflandırma, regresyon ve sıralama problemlerini çözmek için kullanılabilir.

Turbofan datasetine XgBoost Modeli uygulandığında elde edilen değerler aşağıdaki tabloda verilmiştir.

Tablo 4 – XgBoost Regresyon Metrik Değerleri

Model	RMSE-Train	R2-Train	RMSE-Test	R2-Test
XgBoost	19.642671	0.777824	19.657039	0.776243

Neural Network Model

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. Turbofan datasetine NN Regresyon Modeli uygulandığında elde edilen değerler aşağıdaki tabloda verilmiştir.

Tablo 5 – Neural Network Metrik Değerleri

Model	RMSE-Train	R2-Train	RMSE-Test	R2-Test
NN	20.285784	0.763037	20.257953	0.762353

LSTM Modeli (Long Short-Term Memory)

Derin öğrenme yöntemleri arasında bulunan LSTM (Long Short-Term Memory), özellikle zaman serilerinin işlenmesinde kullanılan bir rekürrent sinir ağı (RNN) türüdür. LSTM, birçok alanda başarılı sonuçlar veren bir yapay sinir ağı mimarisidir.

LSTM, diğer RNN türlerinden farklı olarak, zaman serileri gibi uzun süreli bağımlılıklar içeren verileri işlemek için tasarlanmıştır. Bu tür verilerde, geçmişteki olaylar, gelecekteki olayları tahmin etmek için kullanılabilir. LSTM, bu bağımlılıkları daha iyi yönetmek için özel bir hafıza hücresi kullanır.

Turbofan datasetine LSTM Modeli uygulandığında elde edilen değerler aşağıdaki tabloda verilmiştir.

Tablo 7 – LSTM Modeli Metrik Değerleri

Model	RMSE-Train	R2-Train	RMSE-Test	R2-Test
LSTM	11.99409	0. 834965	108020	0. 833753

Avantajları:

Zaman serisi verilerini işlemek için uygun bir yapay sinir ağıdır.

Verilerdeki uzun vadeli bağımlılıkları öğrenebilir ve kısa vadeli bellek sorununu çözebilir.

Farklı veri türleri ve boyutları ile çalışabilir.

Dezavantajları:

Fazla sayıda parametre değerine sahip olması ve her parametrenin çok fazla değer alabiliyor oluşu en ideal LSTM modelinin oluşturma sürecini olumsuz etkilemektedir.

- Eğitim süresi uzun olabilir ve yüksek hesaplama gücü gerektirebilir.

Bazı durumlarda istatistiksel yöntemlerden daha düşük doğruluk sağlayabilir.

4. UYGULAMA ve DENEYLER (APPLICATION AND EXPERIMENTS)

Bu çalışmada NASA tarafından hazırlanan C-MAPSS veri kümesi kullanılarak motorların kalan yaşam ömrünü tahmininin yapılması için aşağıdaki regreyon ve derin öğrenme metodları kullanılmıştır.

1- Linear Regresyon

2- SVM

3- Random Forest

4- XGBoost

5- Neural Network

6- LSTM

Google Colabs aracı yardımı ile Python 3 programlama dili kullanılarak yapılan çalışmada TensorFlow, Keras, matplotlib ve seaborn kütüphaneleri kullanılmıştır.

Veri tabanında Min-Max Normalizasyon işleminden sonra boyut indirgeme yöntemlerinden PCA, SVD, LASSO yöntemlerinden en yaygın tercih edilen PCA analizi için veriler ölçeklendirilmiş, veri setinin boyutu indirgenmiş ardından korelasyonu 0.8'den büyük olarak yansıyan sensörleri(s2, s3, s4, s7, s8, s11, s12, s13, s15, s17, s20, s21) öznitelik seçiminde kullanılmıştır. Sensörlerde yapılan Öznitelikler seçiminden sonra test ve train dataframelerinden, Setting3, S1, S5, S10 ve S16 nolu sensör verileri analiz edildiğinde verilerin değişmemekte ve standart sapmaların çok düşük olduğu anlaşılmış ve veri setinden çıkarılmıştır.3 katmanlı LSTM modelinde aktivasyon değeri Sigmoid ve optimizasyon yöntemi olarak Adam, AdaGrad, AdaDelta alındığında değerler aşağıdaki tablodaki gibidir.

Sigmoid		
Adam	AdaGrad	AdaDelta
0.973962	0.895336	0.8953362

Aktivasyon değeri Relu ve optimizasyon yöntemi olarak Adam, AdaGrad, AdaDelta alındığında değerler aşağıdaki tablodaki gibidir.

ReLu		
Adam	AdaGrad	AdaDelta
0.304587	0.138354	0.153453

5. SONUÇ (CONCLUSION)

Bu çalışmada, kestirimci bakım için bir LSTM modeli önerdik. Modelimiz, zaman serisi verilerinde boyut indirgemek için PCA Analizi ve sensörlerin kolerasyonları referans alınarak öznitelik seçilmiştir. Korelasyon zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenmek için LSTM'i kullanılmıştır. Modelimizi Nasa C-Mapss data setindeki sensör verileri ile eğittik ve test ettik. Modelimizin performansını değerlendirmek için F-Skor metriğini kullandık. Sonuçlar, modelimizin düzenli LSTM'den daha yüksek tahmin doğruluğu sağladığını ve ilgili çalışmalara göre daha iyi sonuçlar elde ettiğini gösterdi.

No	Model	RMSE-Train	R2-Train	RMSE-Test	R2-Test
1	Linear Reg.	27.34165	0.980935	29.14265	0.978494
2	SVM	24.28641	0.735585	28.28265	0.724084
3	Random Forrest	21.17494	0.743208	20.81115	0.749197
4	XgBoost	16.42671	0.777824	16.57039	0.776243
5	NN	20.28578	0.763037	20.25795	0.762353
6	LSTM	11.99409	0.834965	10.8020	0. 833753

KAYNAKLAR (REFERENCES)

1. Gedikli, T., ERVURAL, B. Ç., & 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. https://doi.org/10.31590/ejosat.838168

2.Tahan, M., Tsoutsanis, E., Muhammad, M., & Karim, Z. A.(2017). Performance based health monit oring, diagnostics and prognostics for condition based maintenance of gas turbines: A review. Applied energy, 198, 122 144. https://doi.org/10.1016/j.apenergy.2017.04.048

3.Wang, Q., Bu, S., & He, Z. (2020). Achieving predictive and proactive maintenance for high speed railway power requipment with LSTM RNN. IEEE Transactions on Industrial Informatics, 16(10), 6509 6517. https://doi.org/ 10.1109/TII.2020.2966033

4.Kimera, D., & Nangolo, F. N. (2020). Predictive maintenance for ballast pumps on ship repair yards via machine learning. Transportation En gineering, 2, 100020. https://doi.org/ 10.1016/j.treng.2020.100020

5. KANKAYA(2022) . KESTİRİMCİ BAKIM YAKLAŞIMIYLA BİR TURBOFAN MOTORUNUN ÇÖZÜMLENMESİ. http://www.openaccess.hacettepe.edu.tr:8080/xmlui/handle/11655/26

6. ASADZADE, 2022. AKILLI ENDÜSTRİ İÇİN KESTİRİMCİ BAKIM. https://gcris.iyte.edu.tr/handle/11147/11050

7. KANER, 2021 ENDÜSTRİ 4.0 İÇİN DERİN ÖĞRENME KULLANAN DURUM İZLEME VE KESTİRİMCİ BAKIM YÖNTEMLERİNİN GELİŞTİRİLMESİ https://abs.firat.edu.tr/tr/iaydin/publications

8. TAŞCI, 2022. REMAINING USEFUL LIFETIME PREDICTION FOR PREDICTIVE MAINTENANCE IN MANUFACTURING https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=tqUiYt63sTQLTpozMJ92QhUyiwTESvvf3ec28lLieznKG7XOmSXM3f0yAeX733wi

9. TÜRE, 2021. DESIGN OF PREDICTIVE MAINTENANCE MODEL USING ARTIFICIAL INTELLIGENCE METHODS https://dergipark.org.tr/en/download/article-file/1650937

10. KIZRAK. Uçak Motoru Sağlığı için Uzun-Kısa Süreli Bellek Yöntemi ile Öngörücü Bakım .

11. Asadzade, A. (2020). Akıllı endüstri için kestirimci bakım. Endüstri 4.0 Dergisi, 5(1), 14-19.

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

13. Kumar, S., & Singh, A. (2019). Predictive maintenance of compressor using thingspeak IoT platform. International Journal of Innovative Technology and Exploring Engineering, 8(12), 3621-3625.

14. Kaner, S. (2020). Endüstri 4.0 için derin öğrenme kullanan durum izleme ve kestirimci bakım yöntemlerinin geliştirilmesi. Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul. **15.**Ay Türe, B. (2019). Design of predictive maintenance model using artificial intelligence methods. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

16. Taşcı, B. (2019). Remaining useful lifetime prediction for predictive maintenance in manufacturing. Yüksek Lisans Tezi, Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.

17.Günğör Kankaya, G. (2018). Kestirimci bakım yaklaşımıyla bir turbofan motorunun çözümlenmesi. Yüksek Lisans Tezi, Eskişehir Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir.

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

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

20.Özdemir, A. (2020). Kestirimci bakım sistemlerinde veri artırma yöntemlerinin geliştirilmesi ve bir uygulaması. Doktora Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.