

Derin Öğrenme Modelleri Kullanarak Endüstriyel Makinelerin Kalan Kullanım Ömrü Tahmini

Mustafa Ozan ÖZKÖK¹ , Rüştü AKAY^{2*} 

¹Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Mekatronik Mühendisliği Anabilim Dalı, Kayseri, Türkiye

²Erciyes Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Kayseri, Türkiye

Makale Bilgisi

Araştırma makalesi
Başvuru: 09/12/2024
Düzeltilme: 19/03/2025
Kabul: 10/04/2025

Anahtar Kelimeler

Kestirimci Bakım
Derin Öğrenme
BiLSTM-CNN
Endüstriyel Makineler

Article Info


Research article
Received: 09/12/2024
Revision: 19/03/2025
Accepted: 10/04/2025

Keywords

Predictive Maintenance
Deep Learning
BiLSTM-CNN
Industrial Machines

Grafik Özet (Graphical/Tabular Abstract)

Endüstriyel makinelerde arıza tahmini için CNN, LSTM, BiLSTM ve GRU tabanlı 36 derin öğrenme modeli karşılaştırılmıştır. CNN-3BiLSTM modeli en başarılı sonuçları vermiştir. Çalışma, doğru model yapılandırmasının bakım maliyetlerini azaltmada ve güvenliği artırmada etkili olduğunu göstermektedir. / A total of 36 deep learning models using CNN, LSTM, BiLSTM, and GRU were evaluated for fault prediction in industrial machines. The CNN-3BiLSTM model achieved the best performance. Results highlight the effectiveness of proper model design in reducing maintenance costs and improving operational safety.



Şekil A: Gerçekleştirilen metodolojilerin genel çerçevesi / Figure A: The general framework of the applied methodologies

Önemli noktalar (Highlights)

- Uçak motoru sensör verileri kullanılarak arıza tahmini için farklı derin öğrenme mimarileri test edilmiştir. / Fault prediction was performed using sensor data from aircraft engines with various deep learning architectures.
- CNN, LSTM, BiLSTM ve GRU mimarilerinden oluşan 36 farklı modelin performansı karşılaştırılmıştır. / A total of 36 models were tested by combining CNN, LSTM, BiLSTM, and GRU architectures with varying numbers of layers.
- Zaman serisi verilerinde LSTM ve BiLSTM katmanlarının kullanımı model doğruluğunu artırmıştır. / The use of LSTM and BiLSTM layers significantly improved accuracy in time-series data.

Amaç (Aim): Uçak motoru sensör verileri üzerinde derin öğrenme tabanlı modeller kullanarak arıza tahmini yapmaktır. En uygun mimari kombinasyonu belirlemek hedeflenmiştir. / To perform fault prediction using deep learning-based models on aircraft engine sensor data and to determine the most effective architecture combination.

Özgünlük (Originality): Farklı derin öğrenme mimarilerinin katman sayıları değiştirilerek 36 farklı kombinasyon test edilmiş ve en iyi performans sağlayan model yapılandırması önerilmiştir. / This study evaluates 36 model configurations by varying the number of layers in different deep learning architectures and proposes the optimal structure based on performance.

Bulgular (Results): CNN ve BiLSTM mimarilerinin birleşimiyle oluşturulan CNN-3BiLSTM modeli, en düşük RMSE değeri ile en iyi sonuçları vermiştir. / The hybrid CNN-3BiLSTM model yielded the best results with the lowest RMSE compared to other combinations.

Sonuç (Conclusion): Uçak motorlarında arıza tahmini derin öğrenme mimarileriyle başarıyla yapılmış, doğru model yapılandırmalarıyla bakım süreçleri optimize edilmiştir. / Fault prediction in aircraft engines was successfully achieved using deep learning architectures, enabling optimized maintenance processes through well-structured models.



Derin Öğrenme Modelleri Kullanarak Endüstriyel Makinelerin Kalan Kullanım Ömrü Tahmini

Mustafa Ozan ÖZKÖK¹ , Rüştü AKAY^{2*}

¹Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Mekatronik Mühendisliği Anabilim Dalı, Kayseri, Türkiye

²Erciyes Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Kayseri, Türkiye

Makale Bilgisi

Araştırma makalesi
Başvuru: 09/12/2024
Düzeltilme: 19/03/2025
Kabul: 10/04/2025

Anahtar Kelimeler

Kestirimci Bakım
Derin Öğrenme
BiLSTM-CNN
Endüstriyel Makineler

Öz

Bu çalışmada, endüstriyel makinelerde arıza tahmini için derin öğrenme tekniklerinin etkinliği incelenmiştir. Sensör verileri üzerinde Evrişimli Sinir Ağı (Convolutional Neural Network, CNN), Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM), Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short-Term Memory, BiLSTM) ve Kapalı Döngü Birim (Gated Recurrent Unit, GRU) mimarileri kullanarak kombinasyonel modeller oluşturulmuş ve 36 farklı model test edilmiştir. Bu modellerde, farklı derin öğrenme mimarilerinin katman sayıları ile performansları detaylıca değerlendirilmiştir. Özellikle, BiLSTM ve LSTM modellerinin zaman serisi verilerinde başarılı olduğu bulunmuştur. Elde edilen sonuçlar, CNN-3BiLSTM modelinin geleneksel ve makine öğrenimi yaklaşımlarına göre daha düşük hata oranlarıyla başarılı sonuçlar verdiğini göstermiştir. Literatürdeki benzer çalışmalarla karşılaştırıldığında, önerilen modelin, Çok Katmanlı Algılayıcı, Destek Vektör Regresyonu ve CNN gibi yöntemlere göre belirgin bir performans üstünlüğü sergilediği görülmüştür. Bu çalışma, derin öğrenme tabanlı arıza tahmin modellerinin endüstriyel makinelerde güvenliği artırma ve bakım maliyetlerini optimize etme potansiyelini vurgulamaktadır.

Remaining Useful Life Prediction of Industrial Machines using Deep Learning Models

Article Info

Research article
Received: 09/12/2024
Revision: 19/03/2025
Accepted: 10/04/2025

Keywords

Predictive Maintenance
Deep Learning
BiLSTM-CNN
Industrial Machines

Abstract

This study investigates the effectiveness of deep learning techniques for fault prediction in industrial machinery. Combination models were developed using Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM), Bidirectional Long Short-Term Memory (BiLSTM), and Gated Recurrent Unit (GRU) architectures on sensor data, and 36 different models were tested. The performance of these models, along with the number of layers in different deep learning architectures, was thoroughly evaluated. It was found that BiLSTM and LSTM models were particularly successful in analyzing time series data. The results show that the CNN-3BiLSTM model achieved better performance with lower error rates compared to traditional and machine learning approaches. When compared with similar studies in the literature, the proposed model demonstrated a significant performance advantage over methods such as Multi-Layer Perceptron, Support Vector Regression, and CNN. This study highlights the potential of deep learning-based fault prediction models to enhance safety and optimize maintenance costs in industrial machinery.

1. GİRİŞ (INTRODUCTION)

Endüstri devrimi, zaman içerisinde üretimde kapasite artışı ve düşük maliyetle birlikte karlılığı arttırmıştır. Böylece ekonomik büyüme ve kalkınma olumlu katkılar sağlayarak yeni iş alanlarının ortaya çıkmasına da zemin hazırlamıştır. Ayrıca teknolojinin ilerlemesi de Endüstri

devriminin hızlanmasını sağlayarak yenilikçi çözümlerle üretkenliği arttırmıştır. Endüstrideki gelişmeler her geçen gün artan bir ivmeyle devam etmiştir. Gelişmelerin ortaya çıkışında toplum ihtiyaçları ve teknoloji belirleyici rol oynamıştır. Devrimin başlangıcından günümüze gelene kadar geçen tarihsel gelişimi genel olarak 5 temel zaman dilimiyle ifade edilebilmektedir. Bu süreçler

Endüstri 1.0, Endüstri 2.0, Endüstri 3.0, Endüstri 4.0 ve Endüstri 5.0 olarak adlandırılmıştır [1-2].

Endüstri 4.0, 2011 yılında Almanya'da tanıtılan ve günümüzde de devam eden bir süreçtir. Bu süreç, yüksek teknolojinin üretim ve sanayiyle birleştirilmesini temsil etmektedir. İnternetin süreçlere dâhil edilmesi, akıllı ve yapay zekâ destekli sistemler ile veri analizi ve yorumlanması devrim niteliğinde değişikliklere yol açmıştır. Endüstri 4.0'ın oluşumunda etkili olan temel bileşenler arasında nesnelerin interneti, akıllı fabrikalar, büyük veri, robotik teknolojiler, bulut sistemler ve artırılmış gerçeklik bulunmaktadır. Nesnelerin interneti, sensörler ve yazılımlar kullanılarak cihazların birbiriyle haberleşmesini ve internete bağlanmasını ifade eden bir kavramdır. Böylece nesnelerden veri toplanarak bu verilerin analiz edilmesiyle karar alabilen sistemler oluşturulmuştur. Endüstri 4.0 ile endüstriyel makinelerin daha uzun süre verimli çalışması büyük önem kazanmıştır. Ancak makinelerde ortaya çıkabilecek arızalar üretimin durmasına ve üretim sürecinin aksamasına neden olmaktadır. Makinelerin bakımları yapılarak arızalardan kaynaklanan aksaklıklar ve maliyet kayıpları önlenabilmektedir. Bu nedenle, makinelerin performanslı çalışabilmesi ve plansız duruş sürelerinin minimize edilmesi için bakım uygulamaları düzenli ve planlı olarak yapılmalıdır.

Geleneksel yöntemlerde, makinelerin bakım işlemleri yetişmiş teknisyenler tarafından belirli zaman aralıklarında veya belirli bir çalışma saatine göre planlanmakta ve arıza durumunda onarım faaliyetleri gerçekleştirilmektedir. Gelişen teknoloji ile birlikte, makineler olası arızaları hakkında sürekli bilgi toplayan sensörlerle donatılmıştır. Bu sensörlerden düzenli olarak gelen veriler sayesinde, sorunları doğru bir şekilde tahmin etmek ve bakım yöntemlerini kolaylaştırmak mümkün olmuştur. Bu da bakım faaliyetlerinin daha etkin bir şekilde planlanmasını sağlamıştır. Kestirimci bakım, geleneksel periyodik bakım yöntemlerinin yerini tam olarak alamaz, ancak bakım görevleri için bir zamanlama aracı sağlayarak bu süreçleri daha güvenilir hale getirebilir. Sensör verileri analiz edilerek, cihazların kalan faydalı ömrü (Remaining Useful Life, RUL) tahmin edilebilir ve ne zaman bozulacakları veya arızalanacakları kullanıcılara bildirilebilir.

Aşağıda, farklı makineler için kestirimci bakım amacıyla yapılan mevcut literatür kısaca verilmiştir.

Yaman ve Karadayı, endüstride kullanılan pompalarda arızaları önlemek için kestirimci bakım

çalışması yapmış ve pareto analizi ile incelenecek ekipmanları belirlemişlerdir. Titreşim verileri FFT ile analiz edilmiştir [3]. Bektaş, döner sistemlerin arızalarını önceden belirlemek için PRONOSTIA platformu verilerini Welch ve FFT yöntemleriyle incelemiş ve bozulma eğrilerini kullanarak kestirimci bakımda faydalanmıştır [4]. Günindi ve diğerleri, soğutma hava fanlarının rulmanlarından aldıkları titreşim verilerini FFT ile inceleyerek, makine arızalanmadan önce önlem almayı hedeflemişlerdir [5]. Demir ve Müştak, sağlam ve arızalı rulmanları ses ve titreşim verileriyle analiz etmişlerdir. ORS 6208 rulmanlarının verilerini Hilbert dönüşümü ile de incelemişlerdir [6]. Orhan ve diğerleri, motor iç yatak rulmanlarındaki hasarları titreşim verileriyle tespit etmiş ve analiz etmiştir [7]. Özkat, rüzgar türbini jeneratörlerinin titreşim verilerini kullanarak, Welch yöntemi ile frekans alanında öznelilik çıkarımı yapmış ve normalizasyon ile verileri incelemiştir [8]. Calayır ve Kabak, boya makinesinin arıza öncesi bakımında çeşitli regresyon ve destek vektör makineleri yöntemlerini kullanarak polinomal yöntemin daha başarılı olduğunu belirlemiştir [9]. Güler, turbofan motorların kalan ömürlerini çeşitli sınıflandırma algoritmaları kullanarak tahmin etmiş ve doğrusal diskriminant analizinin en başarılı yöntem olduğunu bulmuştur [10]. Görgülü ve diğerleri, peron ayırıcı kapı sistemlerinin kestirimci bakımları için makine öğrenmesi yöntemlerini kullanmış ve doğrusal destek vektör makineleri ile %99,4 başarı elde etmişlerdir [11]. Wasim ve diğerleri, dinamik regresyon modelleriyle rulmanların kalan ömürlerini tahmin etmiş ve PRONOSTIA'dan alınan titreşim verileri ile yöntemin başarısını test etmişlerdir [12]. Costello ve diğerleri, gaz sirkulatörlerinin durumunu makine öğrenmesi yöntemleri ile tahmin ederek perceptron tabanlı modeller kullanmışlardır [13]. Bukhsh ve diğerleri, demiryolu makaslarının bakım planlarını ağaç tabanlı sınıflandırma yöntemleri ile yapmış ve gradyan artırıcı karar ağacı algoritmasının bakım ihtiyacında en yüksek doğruluğu sağladığını bulmuşlardır [14]. Prytz ve diğerleri, ticari otobüs ve kamyonlardaki hava kompresörlerinin bakım ihtiyaçlarını rastgele orman algoritması kullanarak tahmin etmişlerdir [15]. Saimurugan ve diğerleri, döner makinelerdeki arızaları titreşim sinyalleri ile tespit ederek karar ağaçları ve destek vektör makineleri kullanmışlardır [16]. Hsu ve diğerleri, rüzgar türbinlerindeki arızaları tahmin etmek için istatistik yöntemleri ve makine öğrenmesi algoritmaları kullanmış ve karar ağaçları ile %92,68 doğruluk elde etmişlerdir [17]. Baştürk ve diğerleri, tren sistemlerindeki pantograf boynuzlarının sorunlarını derin öğrenme ve görüntü işleme algoritmaları ile tespit ederek %95 başarımla elde

etmişlerdir [18]. Karabacak ve Özmen, rulmanların sağlıklı çalışıp çalışmadığını evrimsel sinir ağları ile analiz etmiş ve farklı arıza türlerini başarıyla sınıflandırmışlardır [19]. Çatak ve diğerleri, derin evrimsel otokodlayıcı ağı tasarlayarak rulman arızalarını sınıflandırmış ve literatürdeki diğer yöntemlerden daha yüksek performans elde etmişlerdir [20]. Santo ve diğerleri, PAKDD2020 ve NASA veri setleri kullanarak derin öğrenme algoritmalarının kestirimci bakımda etkisini değerlendirmişlerdir [21]. Wang ve diğerleri, yüksek hızlı demiryolu enerji ekipmanlarının bakım zamanlarını LSTM ve RNN derin öğrenme mimarilerinin birleşimi ile tahmin etmişlerdir [22]. Wang ve diğerleri, rulman RUL tahmini için denetimsiz bir adaptif yoğunluk kümeleme filtresi önermişlerdir. Bu yöntemle, önceden bilgi olmaksızın parametre tahmini yapılabilen ve yoğunluk parametrelerinin dinamik olarak ayarlandığı belirtilmiştir [23]. Wang ve diğerleri ayrıca, manifold öğrenmesine dayalı bir altuzay kümeleme yöntemi önermiştir. Bu yöntemle, bozulma dağılımını tanımlamak için ikili sınıf modeli kullanılarak, çok aşamalı bir üssel model entegrasyonu ile rulmanların bozulma hızı belirlenmeye çalışılmıştır [24]. Son yıllarda, desen tanıma tabanlı kestirimci bakım, rulman sağlığı izleme ve santrifüj pompaları gibi çeşitli konulara odaklanan kapsamlı literatür taramaları da yapılmıştır [25-28]. Bu çalışmalar, RUL tahmini alanındaki yenilikleri inceleyerek, istatistiksel yöntemler, gelişmiş sinir ağları, makine öğrenimi ve derin öğrenme yaklaşımlarının avantajlarını ve sınırlamalarını detaylı bir şekilde değerlendirmektedir. Derin öğrenme teknolojilerinin, özellikle CNN ve LSTM'nin yüksek boyutlu özellikleri otomatik olarak çıkarabilme yetenekleri sayesinde RUL tahmini alanında büyük bir ilerleme kaydedilmiştir [29]. Derin öğrenme, ham sensör verilerini doğrudan işleyebilir ve verilerden katmanlı ağ yapıları aracılığıyla karmaşık doğrusal olmayan özellikleri müdahale olmaksızın otomatik olarak çıkarabilmektedir. Bu yaklaşım, derin öğrenme teknolojilerini modern endüstriyel RUL tahmini alanında büyük bir uygulama potansiyeline sahip bir konuma yerleştirmektedir [30].

Sunulan mevcut yöntemler, kestirimci bakım çalışmalarında farklı yöntemlerin kullanılabildiğini göstermektedir. Bu çalışmada, derin öğrenme algoritmalarının öğrenme yeteneğini geliştirmek amacıyla doğru kombinasyonu bulmak için uçak motorlarından alınan sensör verileri kullanılarak motorların olası arızaları tahmin edilmeye çalışılmıştır. Çalışmada kullanılan CNN, LSTM, BiLSTM ve GRU yöntemlerinin farklı katman

sayıları ile oluşturulan çeşitli kombinasyonları üzerinde deneysel çalışmalar yapılmış ve bu çalışmalar sonucunda elde edilen optimum performans modeli önerilmiştir.

Çalışmanın ikinci bölümünde, kullanılan CNN, LSTM, BiLSTM ve GRU metotları hakkında bilgiler verilmiştir. Üçüncü bölümde, veri seti tanıtılmış, yapılan deneysel sonuçlar sunulmuştur. Dördüncü bölümde, araştırma sonuçları tartışılmış ve gelecek yapılabilecek çalışmalar hakkında bilgi verilerek sonlandırılmıştır.

2. MATERYAL VE METOT (MATERIAL AND METHOD)

Bu bölümde, gerçekleştirilen metodoloji, kullanılan derin öğrenme modelleri ve veri ön işleme yöntemleri açıklanmaktadır. İlk olarak, çalışmada uygulanan yöntem ve modelleme süreci sunulmuş, ardından çalışmada kullanılan derin öğrenme modelleri ve veri ön işleme için tercih edilen Parçalı Doğrusal Bozulma (Piecewise Linear Degradation, PLD) yöntemi ele alınmıştır.

2.1. Gerçekleştirilen Metodoloji (Implemented Methodology)

Çalışmada, motor arızalarının tahmini amacıyla kombinasyonel derin öğrenme yöntemleri kullanılmıştır. Bu süreç, hem uzamsal hem de zamansal bağıntıları yakalayarak modelin doğruluğunu artırmayı hedeflemektedir. Çalışmanın ilk aşaması, veri ön işleme aşamasıdır. Bu aşamada, motor verilerinin içeriğindeki sensörlerin değişim değerleri incelenmiştir. Değişim göstermeyen sensörler, veri setinden çıkarılmıştır. Bu sensörler, motorun arızalanmasına etki etmeyen veya çok az etki eden ölçümler olabileceğinden, yalnızca anlamlı özelliklerin veriye eklenmesi hedeflenmiştir.

Veri setindeki seçilen sensörler, min-max normalizasyonu kullanılarak ölçeklendirilmiştir. Bu yöntem, farklı ölçeklerdeki sensör verilerinin aynı aralıkta birleştirilmesini sağlamaktadır, böylece modelin öğrenme süreci hızlanmakta ve daha stabil hale gelmektedir. Bu adımda, Denklem (1) kullanılarak 0 ile 1 arasında bir ölçekleme yapılmış, bu da modelin daha verimli çalışmasına olanak sağlamıştır.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Burada x normalizasyon öncesinde kullanılan orijinal veri değeri, x_{max} verinin alabileceği maksimum değeri, x_{min} verinin alabileceği minimum değeri ve x_{norm} Min-Max

normalizasyonu sonrası ölçeklenmiş değeri göstermektedir.

Elde edilen veriler, eğitim ve test setlerine ayrılmadan önce RUL değeri hesaplanmıştır. Bu değer, her motorun ne kadar süre daha çalışabileceğini gösteren önemli bir metrik olup, modelin hedef değişkeni olarak kullanılmaktadır.

Modelin ilk aşamasında, CNN katmanı, giriş verisinden anlamlı özellikler çıkarmak için kullanılmaktadır. CNN katmanları, özellikle uzamsal bağıntıları yakalama konusunda güçlüdür, bu sayede sensörlerden elde edilen veriler arasındaki ilişkiler etkin bir şekilde öğrenilmektedir. CNN katmanından sonra, bu özellikler LSTM, BiLSTM ve GRU katmanlarına aktarılmaktadır. Bu katmanlar, verinin zaman bağımlılığını öğrenir ve uzun vadeli ilişkileri modelleyerek verinin dinamik yapısını anlamaya çalışır.

LSTM katmanları, zaman serisi verilerindeki geçmiş bağımlılıkları öğrenerek motor arızalarının karmaşık ilişkilerini modellemeye yardımcı olur. BiLSTM, geçmiş ve gelecekteki verileri dikkate alırken, GRU ise daha hızlı eğitim için tercih edilmiştir. Çalışmada, CNN-LSTM, CNN-BiLSTM, CNN-GRU gibi kombinasyonlarla test edilen modellerin performansları kıyaslanmıştır.

Modelin son aşamasında, elde edilen özellikler bir tam bağlantı katmanı aracılığıyla nihai model çıktısına aktarılmaktadır. Eğitim süreci sırasında, her bir katman, modelin hedefini minimize etmek amacıyla geri yayılım algoritmasıyla optimize edilmiştir. Modelin başarımı, RMSE (Root Mean Squared Error) metriği ile değerlendirilmiş, bu sayede tahmin edilen RUL değerlerinin doğruluğu ölçülmüştür.

Eğitim tamamlandıktan sonra, test seti üzerinde modelin performansı değerlendirilmiş ve tahminler gerçek değerlerle karşılaştırılmıştır. Bu adım, modelin doğruluğunu ölçmede önemli olmuştur. Gerçekleştirilen metodolojilerin genel çerçevesi Şekil 1'de, kullanılan parametreler ise Tablo 1'de sunulmuştur.

2.2. Derin Öğrenme Yöntemleri (Deep Learning Methods)

CNN, derin öğrenme alanında yaygın olarak kullanılan yapay sinir ağı mimarileridir. Ağı oluşturan temel bileşenlerin şematik diyagramı Şekil 2'de verilmiştir.

Tablo 1. Modellerde kullanılan hiperparametreler (Hyperparameters used in the models)

Hiperparametre	Değer
Zaman Adımı (time_steps)	30
Filtre Sayısı	64
Kernel Boyutu	3
Aktivasyon Fonksiyonu	ReLU
Pooling Boyutu	2
Hücre Sayısı, Dense Nöron	100
Dropout Oranı	0.2
Değerlendirme Metriği	RMSE
Optimizasyon Algoritması	Adam
Epoch Sayısı	10
Batch Size	64
Dropout Oranı	0.2

Giriş katmanı (Input), CNN modelinin giriş verisinin alınarak evrişim katmanına aktarıldığı bölümü ifade etmektedir. Giriş verisi genellikle 2 boyutlu matrisle gösterilen verileri içermektedir. Evrişim katmanı (Convolution) CNN mimarisinin en önemli katmanlarından biridir. Giriş verisinden filtreler ile özellik çıkarılmasını sağlamaktadır. Filtreler, giriş matrisinde küçük pencereler üzerinde kayarak, özellik haritaları oluşturmaktadır. Havuzlama katmanı (Pooling), evrişim katmanından alınan verinin boyutunun azaltılarak hesaplama maliyeti ve model hassasiyetinin artırılmasını sağlamaktadır. Maksimum havuzlama ve ortalama havuzlama olmak üzere 2 türü bulunmaktadır. Maksimum havuzlama da filtre büyüklüğüne göre ilgili matris parçasındaki en büyük değer seçilerek, ortalama havuzlama da ortalama değer seçilerek çıkış matrisi oluşturulmaktadır. Aktivasyon fonksiyonu nöronların çıkışını belirlemek için kullanılan bir fonksiyondur. ReLU (Rectified Linear Unit) en çok kullanılan aktivasyon fonksiyonlarından biridir. Doğrusal olmayan giriş verilerini doğrusal veriye dönüştürmektedir. ReLU, negatif değerleri sıfırlayarak, pozitif değerleri aynı bırakmaktadır. Tam bağlantılı katman (Fully Connected), evrişim ve havuzlama katmanlarından gelen özellik haritalarını düzleştirmektedir. Önceki katmandaki tüm nöronlarla bağlantılıdır. Çıktı katmanında (Output) softmax aktivasyon fonksiyonu ile her sınıfa ait olasılık değerlerinin hesaplanmasını sağlamaktadır.

Tekrarlayan Sinir Ağları (Recurrent Neural Networks, RNN), ardışık veriler üzerinde çalışan ve geçmiş bilgiyi kullanarak gelecekteki tahminler yapabilen sinir ağı modelleridir. RNN'ler, özellikle zaman serisi analizi, doğal dil işleme, konuşma tanıma ve benzeri sıralı veri işlemlerinde yaygın


olarak kullanılır. Bu ağlar, bir zaman adımındaki çıktıları bir sonraki zaman adımına girdi olarak besleyerek ardışık veriler arasında bağıntı kurabilirler. Şekil 3’de RNN mimarisinin genel yapısı verilmiştir.

LSTM, tekrarlayan sinir ağlarının bir çeşidi olup, zaman serisi verileri veya sıralı veriler üzerinde etkili bir şekilde çalışmak üzere tasarlanmıştır. Geleneksel RNN’lerin uzun dönemli bağımlılıkları öğrenmedeki zorlukları nedeniyle, LSTM’ler bu problemi çözmek üzere geliştirilmiştir. LSTM hücreleri, geleneksel RNN hücrelerinden daha karmaşıktır. Unutma kapısı (Forget gate), giriş kapısı (Input gate) ve çıkış kapısı (Output gate) olmak üzere 3 kapı içermektedir. Bu kapılar, hücre durumu (Cell) ve gizli durum (Hidden) bilgisini kullanarak bilgilerin ne zaman saklanacağını, güncelleneceğini veya unutulacağını belirlemektedir. Şekil 4’de LSTM mimarisinin genel yapısı verilmiştir.


BiLSTM, sıralı verileri hem ileri hem de geri yönlerde işlemek üzere tasarlanmış gelişmiş bir yinelemeli sinir ağı mimarisidir. Yalnızca geçmiş bağımlılıkları yakalayan standart LSTM’lerin aksine, BiLSTM’ler geçmiş ve gelecekteki bağlamlardan aynı anda öğrenmek için iki ayrı LSTM katmanı kullanır. Bu yapıda, bir katman giriş dizisini orijinal sırayla işlerken, diğeri ters sırayla işler. Bu iki katmanın çıktıları daha sonra birleştirilir (genellikle birleştirme, toplama veya

ortalama alma yoluyla) ve giriş verilerinin daha zengin bir temsili oluşturur. Bu çift yönlü yaklaşım, BiLSTM’leri doğal dil işleme, zaman serisi tahmini ve konuşma tanıma gibi sıralı bağımlılıkların kapsamlı bir şekilde anlaşılmasını gerektiren görevler için etkili hale getirir. Bir dizinin her iki tarafındaki bilgileri kullanarak BiLSTM’ler duygu analizi, metin sınıflandırması ve makine çevirisi gibi uygulamalarda performansı arttırmaktadır [33].


GRU, tekrarlayan sinir ağlarının bir çeşidi olup, uzun dönemli bağımlılıkları etkili bir şekilde öğrenmek için geliştirilmiş bir mimaridir. GRU, LSTM’ye benzer şekilde kapı mekanizmaları kullanır, ancak daha basit bir yapıya sahiptir. Bu basitlik, GRU’nun daha az hesaplama maliyeti ile çalışmasını ve daha hızlı öğrenbilmesini sağlamaktadır [34]. GRU, belleği etkili bir şekilde yönetmek için kapı mekanizmaları kullanmaktadır. Ancak, LSTM’nin aksine, GRU ayrı bir bellek hücresine sahip değildir; bunun yerine bellek işlevlerini doğrudan gizli duruma dâhil etmektedir. GRU güncelleme kapısı (Update gate) ve sıfırlama kapısı (Reset gate) olmak üzere iki temel kapıdan oluşmaktadır. Güncelleme kapısı, modelin geçmiş bilgileri ne ölçüde koruması gerektiğini belirlerken, unutma kapısı, yeni hesaplamalarda geçmiş gizli durumun hangi bölümlerinin göz ardı edileceğini kontrol etmektedir.




Şekil 1. Gerçekleştirilen metodolojilerin genel çerçevesi (The general framework of the applied methodologies)



Şekil 2. Temel bir evrişimli sinir ağı mimarisinin şematik diyagramı [31] (Diagram of a basic CNN architecture)



Şekil 3. RNN mimarisi [32] (RNN architecture)




Şekil 4. LSTM mimarisi [32] (LSTM architecture)

2.3. Parçalı Doğrusal Bozulma (Piecewise Linear Degradation)

PLD modeli, bir cihazın veya sistemin bozulma sürecini daha doğru ve esnek bir şekilde modellemek için kullanılan bir yaklaşımdır. Bu model, bozulma sürecini bir dizi doğrusal parçalara ayırarak her bir parçanın belirli bir zaman dilimindeki doğrusal davranışını temsil eder [35]. Bu yaklaşımın arkasındaki amaç, sistemin çalışmasının başlangıç aşamasında sağlıklı

olduğunu varsaymaktır. Sistem ömrünün sonuna yaklaştıkça bozulma artar. Bu nedenle, sistem nispeten yeni olduğunda RUL'u sabit bir değer olarak almak ve zaman geçtikçe doğrusal olarak azaltarak modellemek mantıklıdır. Bu çalışmada hedef RUL'u belirlemek için parça-başı doğrusal bozulma modeli kullanmıştır. Şekil 5'te RUL değerinin zamana bağlı değişimi doğrusal bozulma ve parçalı doğrusal bozulma fonksiyonlarıyla verilmiştir.



Şekil 5. Piece-wise linear degradation fonksiyonu
(Piecwise linear degradation function)

3. BULGULAR (RESULTS)


Bu bölümde, kullanılan veri seti açıklanacak ve yapılan deneylerin sonuçları sunulacaktır. İlk olarak, veri setinin kaynağı, içeriği ve özellikleri hakkında bilgi verilecektir. Daha sonra, veri seti üzerinde gerçekleştirilen ön işleme adımları ve veri setinin analize hazırlanma süreci anlatılacaktır. Son olarak, yapılan deneylerin sonuçları, elde edilen performans metrikleri ve bu sonuçların analizi ayrıntılı bir şekilde tartışılacaktır.

3.1. Veri Seti (Dataset)

Veri Seti, NASA tarafından geliştirilmiş ve yayımlanmış (Commercial Modular Aero-Propulsion System Simulation, C-MAPSS) bir veri setidir. Bu veri seti, uçak motorlarının performansını simüle ederek, motor arızalarının ve bakım ihtiyaçlarının tahmini için kullanılan bir kaynaktır. Şekil 6’te simüle edilen motorun basitleştirilmiş bir görseli verilmiştir. Modeldeki motorun temel bileşenleri kompresör, yanma odası, türbin ve egzozdur [36]. Veri seti, sensörlerin zamana bağlı değerleri uçak motorlarının farklı bileşenlerinin arıza durumu, kalan ömrü ve birbirleriyle etkileşimi hakkında bilgi vermektedir.

Simüle edilen motorun çalışma prensibi özetle şöyledir: Hava önce düşük basınçlı kompresörde (LPC) sıkıştırılır, ardından yüksek basınçlı kompresöre (HPC) geçerek daha yüksek basınca ulaşır. Bu, yakıtın yanma odasında (CC) verimli yanması için gereklidir. Yanma odasında yakıt ve hava karışarak yanma gerçekleşir ve yüksek sıcaklık ile basınç oluşur. Bu enerji, yüksek basınçlı


türbini (HPT) döndürerek mekanik enerjiye dönüştürür. Düşük basınçlı türbin (LPT) ise daha düşük basınçlı gazlardan enerji üretir. HPT, kompresör ve yüksek güç gerektiren bileşenleri çalıştırırken, LPT egzoz çıkışı ve düşük güç gerektiren sistemleri destekler.



Şekil 6. Turbofan motor modelinin şematik gösterimi [37] (Schematic representation of the turbofan engine model)

C-MAPSS veri seti, FD001, FD002, FD003 ve FD004 olmak üzere dört alt kümeden oluşur. Bu alt kümeler, farklı işletim koşulları ve arıza modlarına göre motor performansını simüle eder. Her biri, çeşitli sensörlerden alınan zaman serisi verilerini içerir. Çalışmada FD001 veri seti kullanılmıştır.

Her veri kaydı, motor kimliği (ID), zaman bilgisi, üç farklı işletim koşulu değişkeni ve 21 sensörden alınan ölçümleri içerir. Bu sensörler sırasıyla T2 (fan girişindeki sıcaklık), T24 (LPC çıkışındaki sıcaklık), T30 (HPC çıkışındaki sıcaklık), T50 (LPT çıkışındaki sıcaklık), P2 (fan girişindeki basınç), P15 (bypass kanalındaki basınç), P30 (HPC çıkışındaki basınç), Nf (fiziksel fan hızı), Nc (fiziksel çekirdek hızı), epr (motor basınç oranı, P50/P2), Ps30 (HPC çıkışındaki statik basınç), phi (yakıt akış oranı ile Ps30 oranı), NRF (düzeltme yapılmış fan hızı), NRC (düzeltme yapılmış çekirdek hızı), BPR (bypass oranı), farB (brülör yakıt-hava oranı), htBleed (bleed entalpisi), P50 (yüksek basınçlı türbin çıkışındaki basınç), T15 (bypass kanalındaki sıcaklık), P10 (fan çıkışındaki basınç) ve T40 (yüksek basınçlı kompresör çıkışındaki sıcaklık). Ayrıca, motorun arızalanana kadar geçecek süresini gösteren bir hedef değişken eklenmiştir. Veri seti kullanılmadan önce ön işleme tabi tutulmuştur. Sensör verileri analiz edilerek değişim göstermeyen sensörler çıkarılmıştır. Şekil 7’de gösterildiği üzere, sensör 1, 5, 6, 10, 16, 18 ve 19’un ölçümlerinde değişim olmadığı tespit edilmiş ve bu sensörler veri setinden çıkarılmıştır.



Şekil 7. Sensör değişim değerleri (Sensor variation values)

3.2. Deneysel Çalışmalar (Experimental Studies)

Çalışmada CNN, LSTM, BiLSTM ve GRU modelleri ile oluşturulan kombinasyonel yapılar incelenmiştir. Çalışmada CNN-LSTM, CNN-BiLSTM ve CNN-GRU modellerinin katman sayılarının etkisini belirlemek ve C-MAPSS veri seti için en uygun modeli seçmek için 36 farklı model oluşturulmuştur. Bu amaçla önce CNN katman sayısı 1 olarak seçildiğinde LSTM katman sayısının etkisinin araştırmak için CNN-LSTM, CNN-2LSTM, CNN-3LSTM, CNN-4LSTM modelleri, CNN katman sayısı 2 olarak seçildiğinde LSTM katman sayısının etkisinin araştırmak için 2CNN-LSTM, 2CNN-2LSTM, 2CNN-3LSTM, 2CNN-4LSTM modelleri, CNN katman sayısı 3 olarak seçildiğinde LSTM katman sayısının etkisinin araştırmak için 3CNN-LSTM, 3CNN-2LSTM, 3CNN-3LSTM, 3CNN-4LSTM modelleri oluşturulmuştur. Benzer mantıkla CNN-BiLSTM ve CNN-GRU modelleri için de farklı katman sayıları ile modeller oluşturulmuştur. CNN-LSTM, CNN-BiLSTM ve CNN-GRU modelleri ile elde

edilen sonuçlar ise sırası ile Tablo 2, Tablo 3 ve Tablo 4’de verilmiştir.

Tablo 2. CNN-LSTM modelleri RMSE değerleri (RMSE values of the CNN-LSTM models)

	CNN	2CNN	3CNN
LSTM	17,0108	16,6228	19,1383
2LSTM	16,6907	17,0021	20,3165
3LSTM	15,7112	17,8547	20,5627
4LSTM	16,0072	16,8976	21,0241

Tablo 2’deki sonuçlar incelendiğinde modellerin RMSE değerlerine göre, CNN katman sayısı 1 olarak seçilen modellerde, LSTM katman sayısının artması genellikle model performansını iyileştirmiştir. CNN-LSTM modelinin RMSE değeri (17,01) iken, CNN-2LSTM (16,69), CNN-3LSTM (15,71) ve CNN-4LSTM (16,00) RMSE değerleri hesaplanmıştır. Bu da daha fazla LSTM katmanının modelin doğruluğunu artırabileceğini göstermektedir. CNN katman sayısı 2 olan modellerde, 2CNN-LSTM (16,62) modelinin performansı oldukça iyi olmakla birlikte, 2CNN-

2LSTM (17,00) ve 2CNN-3LSTM (17,85) modellerinin performansı ise biraz daha düşmüştür. CNN katman sayısı 3 olan modellerde ise, genel olarak RMSE değerlerinin daha yüksek olduğu görülmektedir. Özellikle 3CNN-4LSTM modeli çok daha karmaşık yapıya sahip olmasına rağmen daha yüksek hata değerine sahiptir. Bu sonuçlar, CNN katman sayısının arttıkça modelin daha karmaşık hale geldiğini ve bu durumda LSTM katmanlarının sayısının artmasının performansa büyük bir katkı sağlamadığını göstermektedir.

Tablo 3. CNN-BiLSTM modelleri RMSE değerleri (RMSE values of the CNN-BiLSTM models)

	CNN	2CNN	3CNN
BiLSTM	17,7472	16,4851	18,2852
2BiLSTM	15,7718	16,4062	19,4516
3BiLSTM	15,6373	16,6709	18,3586
4BiLSTM	16,0459	15,7286	20,7052

Tablo 3'deki sonuçlar incelendiğinde, her bir grup için en düşük hata oranları farklı modellerde görülmektedir. CNN katman sayısı 1 seçildiğinde, CNN-3BiLSTM modeli (15,64) ile en düşük RMSE değerini elde etmiştir. Bu da modelin bu kombinasyonla en iyi performansı gösterdiğini göstermektedir. CNN katman sayısı 2 olan modellerde ise, 2CNN-4BiLSTM modeli (15,73) ile en düşük hata oranını sağlamış ve en iyi sonuç olarak öne çıkmıştır. CNN katman sayısı 3 seçildiğinde, hata oranı genellikle artmakta, ancak 3CNN-BiLSTM modeli (18,29) ile bu grup içindeki en düşük RMSE'yi elde etmiştir. Bu sonuçlar, CNN katman sayısının artmasının modelin karmaşıklığını artırmasına rağmen, BiLSTM katman sayısının doğru seçilmesiyle daha düşük hata oranlarına ulaşılabileceğini göstermektedir. Ayrıca, daha fazla CNN katmanının hata oranlarını artırdığı, özellikle 3CNN'li modellerde daha yüksek RMSE değerlerinin gözlemlendiği görülmektedir.


Tablo 4. CNN-GRU modelleri RMSE değerleri (RMSE values of the CNN-GRU models)

	CNN	2CNN	3CNN
GRU	20,7515	16,8512	18,6800
2GRU	17,1510	18,6113	18,0203
3GRU	16,5745	17,1997	19,9228
4GRU	16,0363	16,9376	18,6157

Tablo 4'deki sonuçlar incelendiğinde, CNN katman sayısı 1 olan modellerde en düşük RMSE değerini CNN-4GRU modeli (16,04) ile elde etmiştir. Bu, modelin 4 GRU katmanına sahipken en iyi performansı gösterdiğini işaret etmektedir. Diğer modeller, CNN-3GRU (16,57) ve CNN-2GRU

(17,15), sırasıyla daha yüksek hata oranları vermektedir, bu da daha fazla GRU katmanının modelin performansını iyileştirdiğini göstermektedir. CNN katman sayısı 2 olan modellerde ise, en düşük RMSE değeri 2CNN-GRU (16,85) modelinde görülmüştür. Son olarak, CNN katman sayısı 3 olan modellerde, 3CNN-2GRU (18,02) modeli en düşük RMSE'yi elde ederken 3CNN-3GRU (19,92) modeli en yüksek RMSE değerlerine sahiptir.

CNN-LSTM, CNN-BiLSTM ve CNN-GRU modellerinin katman sayılarının performans üzerindeki etkisini belirlemek ve en uygun modeli seçmek amacıyla, her bir model grubundan 12'şer farklı model oluşturulmuştur. Toplamda 36 farklı model analiz edilmiştir. Her bir model grubundaki en iyi performans gösteren modeller, diğer gruplardaki en iyi modellerle karşılaştırılmış ve bu karşılaştırmalar sonucunda en optimal değerlerin elde edilebileceği kombinasyon belirlenmiştir. Sonuçlar Şekil 8'de gösterilmiştir.



Şekil 8. En iyi modellerin karşılaştırılması (Comparison of the best models)

Şekil 8 incelendiğinde, CNN-3BiLSTM modeli tüm kombinasyonlar arasında en iyi performansı göstermiştir. Bu model, çift yönlü bilgi akışını kullanarak ileri ve geri bağımlılıkları daha iyi yakaladığı için daha üstün bir performans sergilemiştir. İkinci sırada, sadece ileri yönde bağımlılıkları modelleyen CNN-3LSTM modeli yer almış ve BiLSTM'ye oldukça yakın bir sonuç elde etmiştir. CNN-4GRU modeli ise diğer modellere göre biraz daha düşük bir performans göstermiştir. Bu sonuçlar, BiLSTM'nin C-MAPSS verilerinde daha üstün bir tahmin yeteneği sunduğunu göstermektedir.

3.3. Literatür ile Karşılaştırma (Comparison With Literature)

Tablo 5, C-MAPSS verilerini kullanarak turbofan motorunun kalan ömrünün tahmini üzerine yapılan önceki bazı çalışmalarla karşılaştırmayı göstermektedir. Önceki çalışmaların algoritmaları, ağ yapılandırmaları, yayın yılları ve tahmin edilen RMSE sonuçları verilmiştir.

Tablo 5. Literatürdeki diğer metotlarla karşılaştırma (Comparison with existing methods in the literature)

Metot	Tanım	Yıl	RMSE
MLP [38]	Multilayer Perceptron	2016	37,56
SVR [38]	Support Vector Regression	2016	20,96
RVR [38]	Relevance Vector	2016	23,79
CNN [38]	2 CNN	2016	18,45
LSTM [39]	2 LSTM	2017	18,07
BD-RNN [40]	Bi-directional RNN	2018	20,04
BD-LSTM [40]	Bi-directional LSTM	2018	15,42
CNN-GRU [41]	CNN-GRU	2023	16,29
Gerçekleştirilen Metot	CNN-3BiLSTM	2024	15,64

Tablo 5'deki sonuçlar incelendiğinde, çalışma kapsamında gerçekleştirilen CNN-3BiLSTM yöntemi, literatürdeki birçok yöntemden daha iyi performans göstermiş ve BD-LSTM yöntemi ile yakın bir performans sergilemiştir. Özellikle, Çok Katmanlı Algılayıcı, Destek Vektör Regresyonu, Relevans Vektör Regresyonu, CNN, BD-RNN ve CNN-GRU yöntemlerine kıyasla daha düşük bir RMSE değeri elde edilmiştir. Bu başarının, CNN'nin güçlü özellik çıkarma yeteneği ile 3 katmanlı BiLSTM'nin zaman serisi verilerindeki karmaşık bağımlılıkları öğrenme kapasitesinin birleşiminden kaynaklandığı söylenebilir.

4. TARTIŞMA VE SONUÇ (DISCUSSION AND CONCLUSION)

Bu çalışmada, endüstriyel makinelerde arıza kestirimi derin öğrenme yöntemleriyle yapılması amaçlanmıştır. Derin öğrenme, büyük veri setlerini işleyebilen ve karmaşık ilişkileri öğrenebilen bir yapay zeka alanı olarak, motorların sağlık durumunu izleyerek arıza risklerini önceden tespit etmede etkili bir yöntem olarak kullanılabilir. Çalışmada, uçak motorlarından alınan sensör verileri kullanarak, motorların olası arızaları tahmin edilmeye çalışılmıştır. Bu yöntem, bakım süreçlerini optimize etmeyi, planlı bakım uygulamalarını devreye sokmayı ve beklenmedik arızaları azaltmayı hedeflemiştir. Bu amaçla CNN, GRU, LSTM ve BiLSTM mimarileri ile oluşturulan farklı katman sayılarına sahip 36 model karşılaştırılmıştır. Sonuçlar genel olarak, daha fazla CNN katmanının modelin karmaşıklığını artırdığı ve hata oranlarını yükselttiğini göstermiştir. Özellikle CNN katman sayısı 3 olan modellerde yüksek RMSE değerleri elde edilmiştir. LSTM, BiLSTM ve GRU katman sayısının artışı ise çoğunlukla modelin doğruluğunu iyileştirmiştir, ancak her modelde bu artışın etkisi

farklı olmuştur. LSTM ve BiLSTM katmanları, zaman serisi verilerinde geçmiş ve geleceği daha iyi öğrenerek doğruluğu artırırken, GRU katmanları daha hızlı eğitim ve azalan parametre sayısı ile benzer başarıyı sağlamaktadır. Model yapılandırılmaları dikkatli bir şekilde seçildiğinde, doğru katman sayısı ile daha düşük hata oranlarına ulaşmak mümkün olmaktadır. Çalışma, derin öğrenme tabanlı modellerin, endüstriyel makinelerin güvenliğini artırma ve maliyetleri düşürme açısından büyük bir potansiyel sunduğunu göstermektedir.

Gelecek çalışmalarda, veri ön işleme adımlarının genişletilerek araştırılması, farklı veri kaynaklarından elde edilen verilerin birleştirilerek yeni giriş verisi üzerinde işlenmesi planlanabilir. Ayrıca, farklı veri setlerinin (örneğin, N-CMAPSS veri seti) kullanılması ve model performanslarının bu veriler üzerinde test edilmesi faydalı olabilir. Bunun yanı sıra, değerlendirme metriklerinden RMSE değerine ek olarak farklı puanlama fonksiyonları kullanılarak model performansları daha kapsamlı bir şekilde değerlendirilebilir. Bu tür değişiklikler, arıza tahmin modellerinin genel başarımını iyileştirebilir ve daha geniş veri setleriyle modelin esnekliğini artırabilir.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

The author of this article declares that the materials and methods they use in their work do not require ethical committee approval and/or legal-specific permission.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Mustafa Ozan ÖZKÖK: Yazılım geliştirme, görselleştirme, saha/araştırma çalışmaları, kaynak sağlama, veri düzenleme ve yazımın ilk taslağını hazırlama süreçlerinde görev almıştır.

He contributed to software development, visualization, field/investigation work, resource provision, data curation, and the preparation of the original draft.

Rüştü AKAY: Danışmanlık, kavramsal çerçevenin oluşturulması, yöntem geliştirme ve yazımın gözden geçirilip düzenlenmesi aşamalarına katkı sağlamıştır.

He provided supervision, contributed to the development of the conceptual framework, methodology design, and participated in the review and editing of the manuscript.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

There is no conflict of interest in this study.

KAYNAKLAR (REFERENCES)

- [1] Yong, Y., Stecke, K. E., Li, D., The evolution of production systems from Industry 2.0 through Industry 4.0. *International Journal of Production Research*. 2018; 56: 848-861.
- [2] Zizic, M. C., Mladineo, M., Gjeldum, N., Celent, L., From industry 4.0 towards industry 5.0: A review and analysis of paradigm shift for the people, organization and technology. *Energies*. 2022; 15: 1-20.
- [3] Yaman, G., Karadayı, H. M., Titreşim analizi ile pompalarda arıza tespiti ve kestirimci bakım için örnek bir çalışma. *Tesisat Mühendisliği*. 2014; 140: 37-51.
- [4] Bektaş, O., Kestirimci bakım için döner mekanizma bozulma eğrisinin tanımlanması. *Avrupa Bilim ve Teknoloji Dergisi*. 2020; 19: 420-428.
- [5] Günindi, Z. Ö., Kurban, A. O., Danışmaz, M., Soğutma fanının kestirimci bakım yöntemi uygulaması ile titreşim analizi ve yapısal esneklik arızasının giderilmesi. *Icontech International Journal*. 2022; 6: 33-41.
- [6] Demir, H. G., Müştak, O., Rulman hasarlarının titreşim ve gürültü analizi ile tespiti. *Avrupa Bilim ve Teknoloji Dergisi*. 2021; 25: 571-581.
- [7] Orhan, S., Arslan, H., Aktürk, N., Titreşim analiziyle rulman arızalarının belirlenmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*. 2003; 18: 39-48.
- [8] Özkat, E. C., Makine öğrenmesi metodolojisi kullanılarak yüksek hızlı rulmanlarda sağlık göstergesinin belirlenmesi. *Avrupa Bilim ve Teknoloji Dergisi*. 2021; 22: 176-183.
- [9] Calayır, G. N., Kabak, M., Bakım için makine öğrenme tekniklerinin analizi ve bir uygulama. *Journal of Turkish Operations Management*. 2021; 5: 662-675.
- [10] Güler, O., Turbofan motorlarının kestirimci bakımında makine öğrenimi algoritmaları performanslarının karşılaştırılması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*. 2024; 13: 99-106.
- [11] Görgülü, Ş., Koç, İ., Kırımça, N., Karaköse, M., vd., Yapay zekâ kullanımıyla peron ayırıcı kapı sisteminin sağlığını izleme ve kestirimci bakım. *Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi*. 2024; 7: 56-70.
- [12] Ahmad, W., Khan, S. A., Islam, M. M., Kim, J. M., A reliable technique for remaining useful life estimation of rolling element bearings using dynamic regression models. *Reliability Engineering & System Safety*. 2019; 184: 67-76.
- [13] Costello, J. J. A., West, G. M., McArthur, S. D. J., Machine learning model for event-based prognostics in gas circulator condition monitoring. *IEEE Transactions on Reliability*. 2017; 66: 1048-1057.
- [14] Bukhsh, Z. A., Saeed, A., Stipanovic, I., Doree, A. G., Predictive maintenance using tree-based classification techniques: A case of railway switches. *Transportation Research Part C: Emerging Technologies*. 2019; 101: 35-54.
- [15] Prytz, R., Nowaczyk, S., Rögnvaldsson, T., Byttner, S., Predicting the need for vehicle compressor repairs using maintenance records and logged vehicle data. *Engineering Applications of Artificial Intelligence*. 2015; 41: 139-150.
- [16] Saimurugan, M., Ramachandran, K. I., Sugumaran, V., Sakthivel, N. R., Multi component fault diagnosis of rotational mechanical system based on decision tree and support vector machine. *Expert Systems with Applications*. 2011; 38: 3819-3826.
- [17] Hsu, J. Y., Wang, Y. F., Lin, K. C., Chen, M. Y., Hsu, J. H. Y., Wind turbine fault diagnosis and predictive maintenance through statistical process control and

- machine learning. IEEE Access. 2020; 8: 23427-23439.
- [18] Baştürk, M. Ö., Yüksel, M., Tetik, Y. E., Yılmaz, M., Güner, M., Kaya, T., Pantograf boynuz hatalarının derin öğrenme ve görüntü işleme teknikleri ile tespiti. Demiryolu Mühendisliği. 2022; 16: 102-115.
- [19] Emre, Y., Özmen, N. G., Rulmanlarda titreşim verilerinden durum izleme ve arıza teşhisi için derin öğrenme yönteminin uygulanması. Konya Journal of Engineering Sciences. 2022; 10: 346-365.
- [20] Çatak, Y., Şahin, K., Güney, O. B., Özkan, H., Deep convolutional autoencoder architecture for predictive maintenance applications. 30th Signal Processing and Communications Applications Conference (SIU). 2022; 1-4.
- [21] De Santo, A., Ferraro, A., Galli, A., Moscato, V., Sperli, G., Evaluating time series encoding techniques for predictive maintenance. Expert Systems with Applications. 2022; 210: 118435.
- [22] Wang, Y., Long, M., Wang, J., Gao, Z., Yu, P. S., Predrnn: Recurrent neural networks for predictive learning using spatiotemporal lstms. Advances in Neural Information Processing Systems. 2017; 30.
- [23] Wang, W., Zhou, G., He, Z., Zhou, P., Ma, G., Yan, X., Ma, T., A novel unsupervised adaptive density-based clustering filter for remaining useful life prediction of bearings. Measurement Science and Technology. 2024; 35: 126121.
- [24] Wang, H., Ding, X., Huang, Z., Zhen, H., Yu, W., Huang, W., Multi-stage exponential model based on subspace clustering distribution for bearing remaining useful life prediction. Measurement Science and Technology. 2024; 35: 076129.
- [25] Adnan, A., Faris, E., Amaral, T. J., Fault diagnosis and health management of bearings in rotating equipment based on vibration analysis - a review. Journal Of Vibroengineering. 2022; 24: 46-74.
- [26] Jianghong, Z., Jiahong, Y., Quan, Q., Yi, Q., A comprehensive survey of machine remaining useful life prediction approaches based on pattern recognition: taxonomy and challenges. Measurement Science And Technology. 2024; 35: 062001.
- [27] Xianpeng, Q., Veronica, J., Seong, L., Chin L., Tiyanike, B., Advances and limitations in machine learning approaches applied to remaining useful life predictions: a critical review. International Journal Of Advanced Manufacturing Technology. 2024; 133: 4059-4076.
- [28] Salman, K., Soo-Ho, J., Yaseen, S. S., Ha, J. J., Soo, K. H., Artificial Intelligence-Driven Prognostics and Health Management for Centrifugal Pumps: A Comprehensive Review. Actuators. 2024; 13: 514.
- [29] Luo, J., Shao, H., Lin, J., Liu, B., Meta-learning with elastic prototypical network for fault transfer diagnosis of bearings under unstable speeds. Reliability Engineering & System Safety. 2024; 245: 110001.
- [30] Lei, Z., Su, Y., Feng, K., Wen, G., Interpretable operational condition attention-informed domain adaptation network for remaining useful life prediction under variable operational conditions. Control Engineering Practice. 2024; 153: 106080.
- [31] Phung, V. H., Rhee, E. J., A High-Accuracy Model Average Ensemble of Convolutional Neural Networks for Classification of Cloud Image Patches on Small Datasets. Applied Sciences. 2019; 9: 4500.
- [32] Akay, B., Karaboga, D., Akay, R., A comprehensive survey on optimizing deep learning models by metaheuristics. Artificial Intelligence Review. 2022; 55: 829-894.
- [33] Zhang, X., Shi, J., Zhu, G., Xiao, Y., Chen, H., Study of regional monthly precipitation based on CEEMD-BILSTM coupled model. Water Supply. 2022; 22: 8036-8049.
- [34] Dey, R., Salem, F. M., Gate-variants of gated recurrent unit (GRU) neural networks. IEEE 60th International Midwest Symposium on Circuits and Systems. 2017; 1597-1600.
- [35] Veloso, G. A., Loschi, R. H., Dynamic linear degradation model: Dealing with heterogeneity in degradation paths. Reliability Engineering & System Safety. 2021; 210: 107446.
- [36] Frederick, D. K., DeCastro, J. A., Litt, J. S. (2007). User's Guide for the Commercial Modular Aero-Propulsion System Simulation (C MAPSS). NASA/ARL, Technical Manual TM2007-215026.

- [37] Aydın, H., Effects of air to fuel ratio on parameters of combustor used for gas turbine engines: Applications of turbojet, turbofan, turboprop and turboshaft. *Energy*. 2024; 305: 132346.
- [38] Babu, G. S., Zhao, P., Li, X. L., Deep convolutional neural network based regression approach for estimation of remaining useful life. *International Conference on Database Systems for Advanced Applications*. Springer, Cham. 2016; 214-228.
- [39] Zheng, S., Ristovski, K., Farahat, A., Gupta, C., Long short-term memory network for remaining useful life estimation. *2017 IEEE International Conference on Prognostics and Health Management (ICPHM)*. 2017.
- [40] Zhang, J., Wang, P., Yan, R., Gao, R. X., Long short-term memory for machine remaining life prediction. *Journal of Manufacturing Systems*. 2018; 48: 78-86.
- [41] Azyus, A. F., Wijaya, S. K., Naved, M., Prediction of remaining useful life using the CNN-GRU network: A study on maintenance management. *Software Impacts*. 2023; 17: 100535.