

Motor Yataklarında Meydana Gelen Arızaları Tespit Etmek için Yeni Bir Tek Boyutlu Konvolüsyonel Sinir Ağı Modeli

Merve ERTARĞIN^{1*}, Özal YILDIRIM², Ahmet ORHAN³

¹ Elektrik Elektronik Mühendisliği, Mühendislik Fakültesi, Munzur Üniversitesi, Tunceli, Türkiye

² Yazılım Mühendisliği, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

³ Elektrik Elektronik Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

*¹ merveboydak@munzur.edu.tr, ² ozal@firat.edu.tr, ³ aorhan@firat.edu.tr

(Geliş/Received: 04/05/2023;

Kabul/Accepted: 14/07/2023)

Öz: Elektrik motorları, çeşitli işlemleri otomatikleştirme ve kolaylaştırma yeteneklerinden dolayı endüstride önemli bir yere sahiptir. Elektrik motorlarında meydana gelen arızalar, cihazın veya sistemin çalışmasını etkileyebilmekte ve büyük maddi kayıplara neden olabilmektedir. Bu nedenle arızaların erken aşamada tespit edilmesi kritik bir öneme sahiptir. Arızaların tespitinde bilgisayar destekli yazılımlar kullanılması maliyetten ve zamandan tasarruf etme potansiyeli nedeniyle ön plana çıkmaktadır. Bu çalışmada, motor yatağı arıza türlerini tespit etmek için derin öğrenme tabanlı bir model önerilmiştir. Tek boyutlu konvolüsyonel sinir ağı (1D-CNN) mimarisi kullanan bu model ile sadece titreşim verileri kullanılarak arıza tipi tespiti sağlanmaktadır. Önerilen mimari, titreşim sinyallerini motor arıza teşhisinde hızlı ve güvenilir olarak kullanan etkin bir modeldir. Çalışma kapsamında farklı hız senaryoları kullanılarak eğitim ve test aşamalarının detaylı performans değerlendirmeleri sağlanmıştır. Genelleme kabiliyeti yüksek olan bu model ile, farklı senaryolarda yüksek doğruluk oranları ile arıza tespiti yapılmıştır.

Anahtar kelimeler: Derin öğrenme, konvolüsyonel sinir ağı, motor arıza tespiti.

A New One-Dimensional Convolutional Neural Network Model for Detecting Motor Bearing Failures

Abstract: Electric motors have an important place in industry due to their ability to automate and facilitate various processes. Faults that occur in electric motors may affect the operation of the device or system and cause great financial losses. It is therefore critical to detect faults at an early stage. The use of computer-aided software in the detection of faults comes to the fore due to its cost and time saving potential. In this study, a deep learning-based model is proposed to detect engine bearing failure types. With this model, which uses one-dimensional convolutional neural network (1D-CNN) architecture, fault type detection is provided by using only vibration data. The proposed architecture is an efficient model that uses vibration signals to diagnose engine faults quickly and reliably. Within the scope of the study, detailed performance evaluations of the training and testing stages were provided by using different speed scenarios. With this model, which has a high generalization ability, fault detection has been made with high accuracy rates in different scenarios.

Key words: Deep learning, convolutional neural network, motor fault detection.

1. Giriş

Elektrik motorları, birçok farklı tesisat ve cihazda, güç üretim tesislerinde kullanılır ve bu tesislerin çalışması için gereklidir. Elektrik motorları, endüstriyel makine ve ekipmanların çalışması için gerekli olan gücü sağlar. Ayrıca, elektrik makineleri, endüstriyel üretimde kullanılan sistemlerin ve cihazların çalışmasını otomatikleştirir ve bu sayede üretim hızını ve verimliliğini artırır. Endüstride üretim aşamasında birçok kullanım alanına sahip elektrik makineleri zaman zaman elektriksel ve mekaniksel arızalara maruz kalırlar. Meydana gelen bu arızalar üretimin devamlılığı konusunda sıkıntı yaratabilir. Sistemin dengesinin ve güvenilirliğinin sağlanması açısından, makina arızalarının yerinin ve şiddetinin erken tespit edilmesi önemlidir.

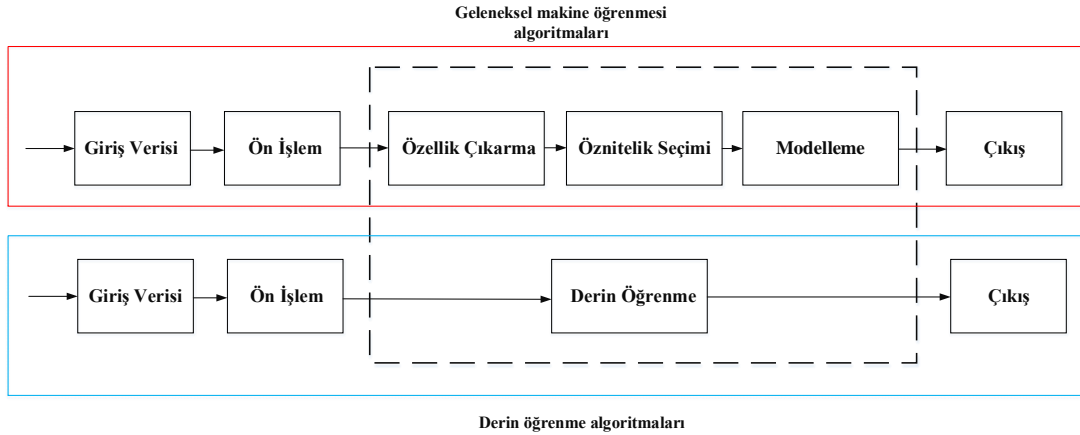
Son yıllarda, bilgisayar destekli yazılımların motor arızalarının tespitinde kullanılmasına yönelik yapılan çalışmalar önem kazanmıştır. Bu yazılımlar, motorun çalışma verilerini toplar ve bu verileri analiz eder. Analiz sonucunda, motorun hangi parçasında arıza olduğu tespit edilebilir. Bilgisayar destekli yazılımlar sayesinde arızanın tespiti ve tamir süreci çok daha hızlı ve etkin bir şekilde gerçekleştirilebilir. Bu yazılımlar, aynı zamanda

* Sorumlu yazar: merveboydak@munzur.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0003-4493-7260, ² 0000-0001-5375-3012, ³ 0000-0003-1994-4661

motorun önceden arıza olma olasılığını tahmin etme ve bu sayede arızayı önleyici önlemler alma imkânı da sağlar. Bu nedenle, motor arızalarının tespitinde bilgisayar destekli yazılımların kullanılması oldukça önemlidir.

Elektrik motorlarında meydana gelen arızaları tanımlamak ve sınıflandırmak amacıyla frekans [1], akım [2, 3, 9, 13], titreşim [4, 7, 8, 10, 11, 14, 15, 16, 17, 18, 19, 22, 25, 26] gibi bazı giriş verileri kullanılır. Titreşim sinyalleri, mekanik sisteme ait önemli bilgiler sağlamasından ve kullanım kolaylığından dolayı arıza teşhisinde yaygın olarak tercih edilmektedir [4]. Genel olarak, giriş verisi boyutunun büyüklüğü arızaların doğru olarak belirlenmesi açısından avantaj sağlar [5]. Ancak, veri ne kadar büyükse o kadar karmaşık olduğu söylenebilir [6]. Yapay zeka tekniklerini makine sağlık durumlarını ayırt etmede kullanan akıllı arıza teşhis yöntemleri ile bu büyük ve karmaşık veriler kolaylıkla işlenebilir ve arızaların otomatik olarak tespit edilmesi sağlanabilir.

Akıllı arıza teşhis yöntemlerinden olan klasik makine öğrenmesi ile motor arıza tespiti, özellik çıkarımı ve arıza tespiti için faydalı özniteliklerin seçimi aşamalarını içerir. Dalgacık tabanlı öznitelik çıkarımı (Wavelet-Based Feature Extraction) [7, 8], Sınır analizi (Boundary Analysis) [9], Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform-STFT) [10, 11], Hızlı Fourier Dönüşümü (Fast Fourier Transform-FFT) [19,22] öznitelik çıkarma yöntemlerinin bazılarıdır. Sınıflandırma için kullanılan sinyalleri karakterize etmek amacıyla doğru öznitelikleri seçmek kritik ve aynı zamanda zahmetlidir. Manuel olarak seçilen özellikler, motor yatak verilerini en iyi şekilde tanımlamayabilir [5]. Ayrıca, belirli bir sinyal için hangi özelliklerin çıkarılmasının en uygun olduğu sorusu bugüne kadar cevapsız kalmıştır [12, 13]. Derin öğrenme modelleri ile yapılan arıza tespitinde bu aşamalar otomatikleştirilmiş ve bir uzmana olan ihtiyaç minimuma indirilmiştir. Makine öğrenmesi teknikleri, önce problem ifadelerini farklı parçalara ayırmaya ve son olarak sonuçlarını birleştirmeye ihtiyaç duyarken derin öğrenme teknikleri uçtan uca öğrenme yapısına sahiptir. Makine öğrenmesi ve derin öğrenme algoritmaları Şekil 1'de bir blok diyagramı ile gösterilmiştir.



Şekil 1. Geleneksel makine öğrenmesi ve derin öğrenme algoritmaları

Sinir ağlarının bir çeşidi olan Konvolüsyonel Sinir Ağı (Convolutional Neural Network-CNN) görüntü ve ses işleme, biyomedikal gibi birçok alanda teşhis ve sınıflandırmada başarılı olduğu kanıtlanmış bir yapıdır [31]. Motor arızalarını tespit etmek için de araştırmacılar tarafından tercih edilen bir mimari olmuştur [14-19]. Shen ve ark. yaptıkları çalışmada fiziksel bilgiyi 1D-CNN modele dahil eden bir yaklaşım geliştirmişlerdir [16]. Özelleştirilmiş veri ve fizik güdümlü bir kayıp fonksiyonu kullanarak modeli gerçekleştirmiş değişik hata sınıfları ve seviyeleri için başarılı sonuçlar elde etmişlerdir. Hu ve ark. veri toplama için yenilikçi bir şekilde kablosuz sensör ağı kullanmıştır [17]. Toplanan zaman alanı sinyallerini, görüntü sinyallerine dönüştürmüş ve kablosuz ağ yapısını optimize ederek rulman arıza teşhisini CNN modeli kullanarak %99.8 doğruluk oranı ile gerçekleştirmiştir.

Derin İnanç Ağı (Deep Belief Network-DBN), bir tür çok katmanlı sinir ağıdır ve girdi verilerini çok sayıda katman arasında işleyerek öğrenme yapar. Makinalarda oluşan arızaların DBN ile etkili bir biçimde tespit edildiği araştırmacılar tarafından yapılmış çalışmalarla ispatlanmıştır [20-23].

Seyrek Otomatik Kodlayıcı (Sparse Auto Encoder-SAE), bir tür oto-kodlayıcıdır ve veri setlerinden özetler çıkararak bu veri setlerinin özelliklerini kodlar. [24,25]. [25]'teki çalışmada asenkron motor arıza teşhisi için SAE tabanlı bir derin sinir ağı yaklaşımı sunulmuştur. Bu yaklaşımda, SAE kısa ve öz özellikleri denetimsiz bir şekilde yüksek boyutlu verilerden otomatik olarak öğrenir. Özellik öğrenmenin sağlamlığını artırmak için SAE'nin


girişine bir gürültü giderici kodlama eklenmiştir. Elde edilen %97.61 doğruluk oranı, SAE tabanlı derin sinir ağının, asenkron motorun arıza teşhisi için iyi bir kararlılığa sahip olduğunu göstermektedir.

Uzun Kısa Süreli Bellek (Long short-term memory-LSTM) ağları, girdi verilerinin zamana göre değişim gösterdiği durumlarda özellikle etkilidir ve çok sayıda girdi verisini birbirleriyle bağlantılı olarak işleyebilir. [26]'daki çalışmada, üç eksenli ham titreşim verilerini kullanarak gerçek zamanlı motor arıza tespiti yapılmıştır. Önceki çalışmalarla karşılaştırıldığında bu çalışma, titreşim verileri ile gerçek zamanlı yatak arıza tespiti için Raspberry-Pi mikrobilgisayarındaki derin öğrenme algoritmalarını kullanmıştır. Sınıflandırmada kullanılan LSTM modelinin performansını iki farklı veriseti kullanılarak test edilmiştir. %75.33 ve %88.08 doğruluk oranıyla motor yatakları sağlıklı ve arızalı olmak üzere sınıflandırılmıştır.

Bu çalışmada, motor yatak arızası teşhisi için derin öğrenme mimarilerinden olan CNN tabanlı yeni bir model tasarlanmıştır. Önerilen modelde giriş verisi olarak titreşim sinyalleri kullanılmıştır. Bu model ile iç yatak yüzeyi ve dış yatak yüzeyinde oluşan hatalar ile bilyelerde meydana gelen hataların tespiti sağlanmıştır. Önerilen modelin performansı farklı senaryolar oluşturularak test edilmiş ve arıza tespitinde kullanılacak genelleme yeteneği yüksek ve güvenilir bir model olduğu görülmüştür.

2. Motor Arıza Veri Seti

Çalışmada kullanılan motor arıza veri seti, Ottawa Üniversitesi tarafından oluşturulmuştur [27]. Sağlıklı, dış yatak yüzeyi arızası, iç yatak yüzeyi arızası, bilye arızası, iç yatak yüzeyi-dış yatak yüzeyi-bilye üzerindeki birleşik arızalar olmak üzere beş sınıfta veriler toplanmıştır. Veri seti oluşturulurken kullanılan deney şeması Şekil 2'de gösterilmiştir. Şaftı desteklemek için sola sağlıklı ve sağa test yatağı olmak üzere iki ER16K bilyalı rulman monte edilmiştir. Test yatağındaki titreşim sinyallerini toplamak amacıyla bir ivmeölçer (ICP ivmeölçer, Model 623C01) yerleştirilmiştir. Ayrıca şaftın dönüş hızını ölçmek amacıyla bir encoder kullanılmıştır.



Şekil 2. Çalışmada kullanılan motor arıza veri setinin elde edilmesi için kurulan deney düzeneğine ait temsili bir gösterim.

Her veri kümesi için yatak sağlık durumu ve değişen hız durumu olmak üzere iki deney ayarı vardır. Veri setine ait kısaltmalarda bulunan *C1* sembolü sağlıklı duruma ait verileri, *C2* sembolü iç yüzey hatası olan duruma ait verileri ve *C3* sembolü dış yüzey hatası olan duruma ait verileri, *C4* sembolü bilye hatası olan duruma ait verileri ve *C5* sembolü iç yatak yüzeyi-dış yatak yüzeyi-bilye üzerindeki birleşik hatalı verileri içermektedir. Kısaltmalarda *A* sembolü artan hıza ait verileri, *B* sembolü azalan hıza ait verileri, *C* sembolü artıp ardından azalan hıza ait verileri ve *D* sembolü azalıp ardından artan hıza ait verileri içermektedir.

Deney süresince 200 kHz örnekleme frekansında 10 saniye boyunca titreşim sinyalleri ivmeölçer ile elde edilmiştir. Elde edilen toplam veride $200 \text{ kHz} \times 10 \text{ sn} = 2,000,000$ örnek bulunmaktadır. Bu çalışmada, orijinal sinyaller segmentasyon işleminden geçirilerek her sinyal için 0.01 saniyelik segmentler oluşturulmuştur. Böylece tek bir kayıttan 2000 (2,000,000/1000) örnek elde edilmiştir. Daha sonra, orijinal veri setindeki *C1-A-1*, *C1-A-2* ve *C1-A-3* verileri *C1A* olarak birleştirilmiş olup toplam 6000 örnek içermektedir. Aynı işlem diğer sağlık ve hız durumları için tekrarlanmıştır. Tablo 1'de, sağlık durumları ve değişen hız durumlarında alınan veriler ve bu verilere ait sayısal bilgiler gösterilmiştir.

Tablo 1. Her sınıf için segmentlere ayrılmış veri seti ve örnek sayıları.

Hız durumları		Artan hız	Azalan hız	Artıp ardından azalan hız	Azalıp ardından artan hız	Örnek Sayıları
Sınıflar		A	B	C	D	
Sağlıklı	C1	6000	6000	6000	6000	24000
İç yüzeyi hatası	C2	6000	6000	6000	6000	24000
Dış yüzey hatası	C3	6000	6000	6000	6000	24000
Bilye hatası	C4	6000	6000	6000	6000	24000
Birleşik hata	C5	6000	6000	6000	6000	24000
Toplam		30000	30000	30000	30000	120000

3. Materyal ve Metod

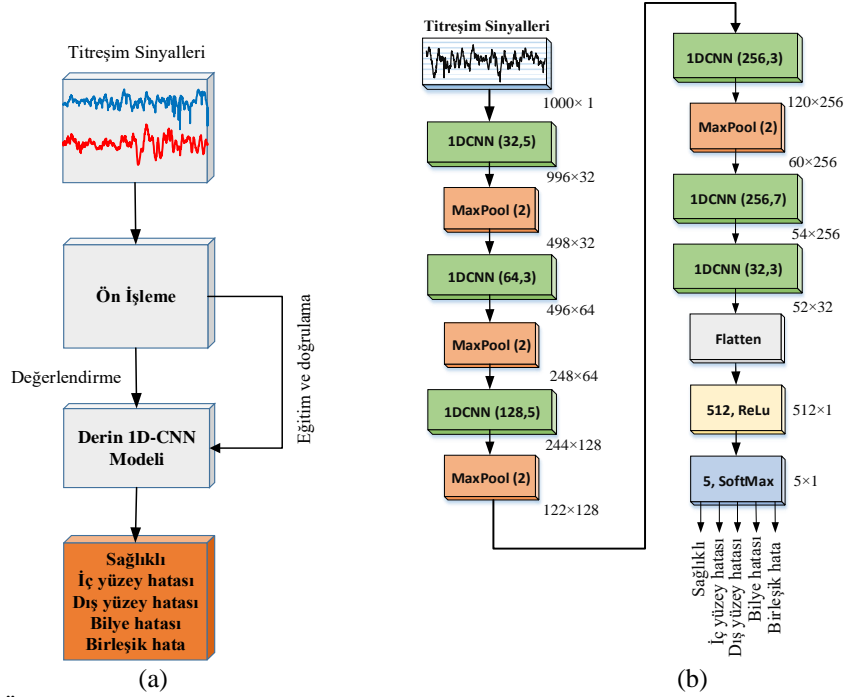
Bu çalışmada, motor sağlık durumunu değerlendirmek amacıyla 1D-CNN yapısı kullanılmıştır. Tasarlanan derin ağ modeli, öznelik çıkartma veya öznelik seçimi adımı gerektirmeden uçtan uca bir yapı ile otomatik olarak sınıflandırma sağlar [28-30]. 13 katmanlı olarak tasarlanan bu model farklı hız koşulları altında motor sağlık durumunu yüksek doğrulukla sınıflandırdığı için genelleme yeteneğinin yüksek olduğu söylenebilir. Şekil 3 (a)'da, çalışmada kullanılan yöntemin blok şeması verilmiştir.

3.1. Önerilen CNN modeli

Sinir ağlarının bir çeşidi olan CNN; konvolüsyon katmanı, aktivasyon katmanı ve havuzlama (pooling) katmanlarını içeren, birçok alanda teşhis ve sınıflandırmada başarılı olduğu kanıtlanmış bir yapıdır [31]. CNN modelinde, ağırlıkların paylaşılmasıyla tanı modellerindeki eğitim parametrelerinin sayısı azaltılarak yakınsama hızlandırılabilir ve aşırı öğrenme azaltılabilir [32]. Bu nedenlerden dolayı çalışma kapsamında CNN yapısı tercih edilmiştir.

Titreşim sinyalleri bir boyutlu olduğu için çalışma kapsamında 1D-CNN ağı tercih edilmiştir. Tasarlanan derin ağ modeli 13 katmandan meydana gelmektedir. Model, 1D Konvolüsyon (1DCNN), MaxPooling (MaxPool), flatten ve dense katmanlarına sahiptir. Şekil 3 (b)'de motor arıza tespiti için önerilen 1D-CNN modeline ait bir blok gösterim verilmiştir.

Modelin ilk katmanında giriş olan titreşim sinyallerine 5 çekirdek boyutlu 32 adet filtre ile 1D konvolüsyon gerçekleştirilir. 1D MaxPool katmanında, önceki konvolüsyon katmanından gelen özellik haritaları üzerinde maksimum değerler alınarak daha düşük boyutlu özellik haritası oluşturulur. Pooling katmanı, önceki katmana göre özellik haritalarının boyutunu küçülterek derin öğrenme yapısının hesaplama maliyetini azaltmak için eklenmiştir. Üçüncü katmanda çekirdek boyutu 3 olan 64 filtre ile konvolüsyon uygulanan sinyallere dördüncü katmanda tekrar 1D MaxPool uygulanarak kaydırma değişkeni değerine bağlı olarak boyut yarıya düşürülür. Bu işlemler sonraki 1DCNN ve 1D MaxPool katmanlarında tekrarlanır. Önerilen derin ağ, 11. katmanda bir flatten katmanına sahiptir, böylece 10. katmandan elde edilen özellik haritaları, ağın sonraki katmanlarına girdi olarak uygun boyuta dönüştürülebilir. Bu katman, çok boyutlu girdi özellik vektörlerini tek boyutlu çıktı verilerine dönüştürür. Flatten katmandan elde edilen öznelikler, 512 birimlik dense katmanına beslenir. Bu dense katmanının aktivasyon fonksiyonu yaygın olarak kullanılan Doğrultulmuş Doğrusal Ünite (Rectified Linear Unit-ReLU) olarak belirlenmiştir. Ağın son katmanı olan 13. katmanda, softmax katmanı kullanılarak girdi sinyallerinin ait olduğu sınıfın tahmini gerçekleştirilir.



Şekil 3. (a) Önerilen uçtan uca öğrenme yapısını oluşturmak için akış şemasının gösterimi (b) Önerilen 1D-CNN modeline ait bir blok gösterim.

3.2. Deneysel kurulum

Bu çalışmada üç farklı durum ile önerilen CNN modelin motor arıza tespitindeki performansı test edilmiştir.

- **Durum 1:** Tüm verilerin %80'i eğitim; %10'u doğrulama ve kalan %10'u test için kullanılmıştır.
- **Durum 2:** Artan (A) ve azalan (B) hızda alınan tüm verilerin %90'ı eğitim, %10'u doğrulama için kullanılmıştır. Test aşaması için üç farklı durum söz konusudur. Test için ilk olarak, önce artıp sonra azalan hızdaki (C) veriler kullanılarak modelin performansı değerlendirilmiştir. İkinci olarak, önce azalıp sonra artan hızdaki (D) verilerle modelin doğruluğu test edilmiştir. Son olarak bu iki durum birleştirilerek test aşaması tamamlanmıştır.
- **Durum 3:** Üçüncü durumda önce artıp sonra azalan hızdaki (C) ve önce azalıp sonra artan hızdaki (D) tüm verilerin %90'ı eğitim, %10'u doğrulama için kullanılmıştır. Test aşaması için üç farklı durum söz konusudur. İlk olarak, artan hızdaki (A) veriler kullanılarak modelin performansı değerlendirilmiştir. İkinci olarak azalan hızdaki (B) verilerle modelin doğruluğu test edilmiştir. Son olarak bu iki durum birleştirilerek test aşaması tamamlanmıştır.

Yukarıda anlatılan durumlar Tablo 2'de özetlenmiştir.

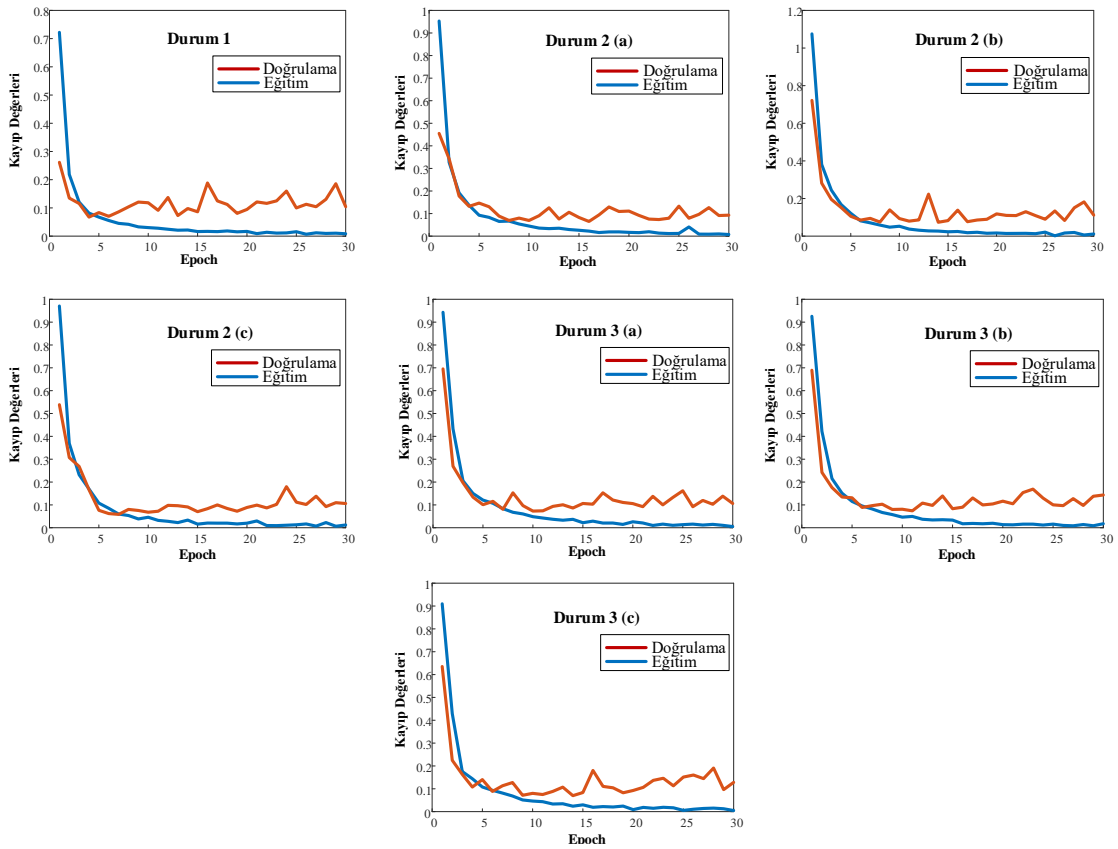
Tablo 2. Önerilen uçtan uca öğrenme yapısı için kullanılan verilerin dağılımı

Durumlar	Eğitim+Doğrulama	Test
Durum 1	A+B+C+D (%80 eğitim, %10 doğrulama)	A+B+C+D (%10 test)
Durum 2	A+B (%90 eğitim, %10 doğrulama)	(a) C (b) D (c) C+D
Durum 3	C+D (%90 eğitim, %10 doğrulama)	(a) A (b) B (c) A+B

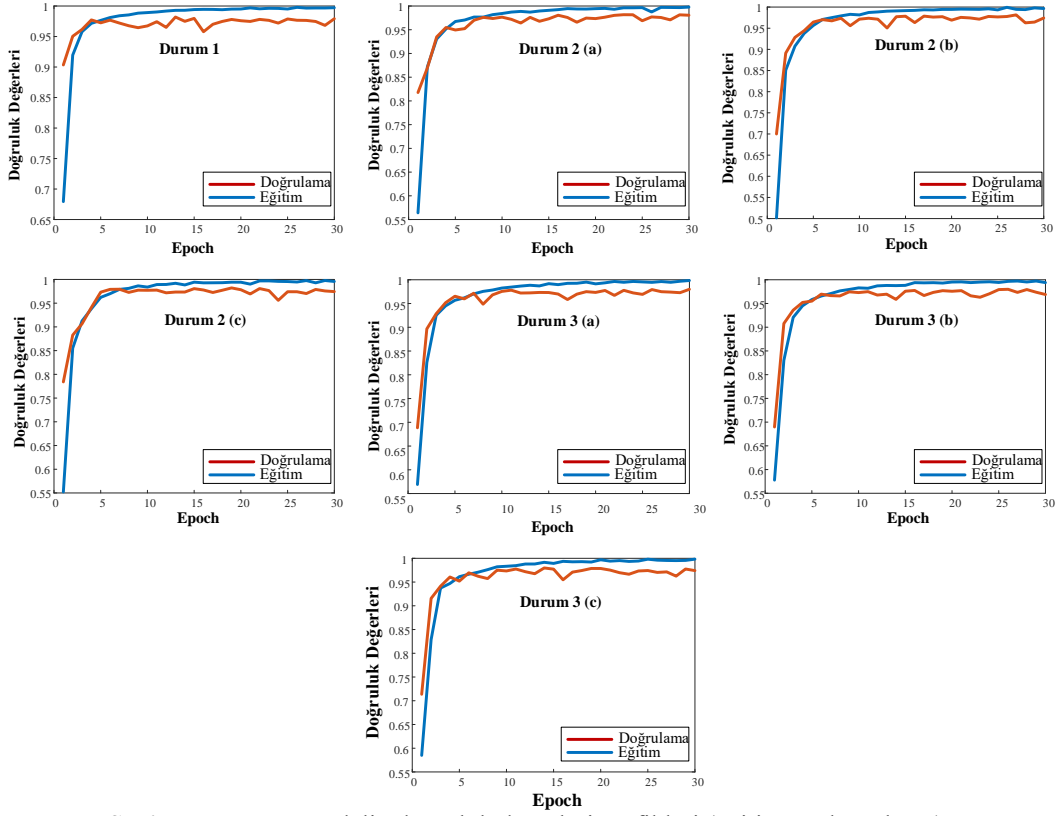
Çalışmada önerilen derin öğrenme modeli, Python programlama dili ve Keras derin öğrenme kütüphanesi kullanılarak oluşturulmuştur. Çalışmanın tamamı Intel Core i7-7700HQ 2.81 GHz CPU ve NVIDIA GeForce GTX 1050 grafik kartına sahip bir bilgisayarda gerçekleştirilmiştir. Önerilen modelin hiperparametreleri için öğrenme oranı $1e-3$ olarak ayarlanmıştır, optimizasyon algoritması için “adam optimizer” ve kayıp fonksiyonu olarak “categorical cross entropy” tercih edilmiştir. 128 yığın boyutu ile 30 tur (epoch) boyunca sonuçlar alınmıştır.

3.3. Deneysel sonuçlar

Belirlenen tüm durumlar için deneysel çalışmalar hiçbir parametre değiştirilmeden aynı 1D-CNN modeli kullanılarak gerçekleştirilmiştir. Şekil 4’te, 30 tur için modelin kayıp değerlerindeki değişiklikler verilmiştir. Bu grafiklere bakılarak veri setleri üzerinde modelin öğrenmesinin gerçekleştiği söylenebilir. Şekil 5, beş sınıflı verileri sınıflandırmak için önerilen modelin doğruluk grafiklerini göstermektedir. Performans grafiklerine bakıldığında modelin aşırı uyum sorunu olmadığı görülmektedir.



Şekil 4. 1D-CNN modelin kayıp değerleri grafikleri (eğitim ve doğrulama)



Şekil 5. 1D-CNN modelin doğruluk değerleri grafikleri (eğitim ve doğrulama)

Şekil 6, beş sınıflı verileri sınıflandırmak için önerilen modelin hata matrisini göstermektedir. Önerilen modelin %90.54 doğruluk oranı ile en düşük performans gösterdiği Durum 3 (a)'nın hata matrisi incelendiğinde, bilye arızasına sahip 6000 örneğin 2301'inin yanlış sınıflandırıldığı görülmektedir. Bu durumda, bilye hatasına sahip 2104 örnek iç yüzey hatasına sahip olarak etiketlenmiştir.

1D-CNN model en yüksek performansı %98.19 doğruluk oranıyla Durum 2 (a)'da göstermiştir. Model en iyi performansı birleşik hataya sahip verileri sınıflandırırken göstermiştir. Birleşik hataya sahip 6000 verinin yalnızca 67'sini yanlış sınıflandırmıştır. Bu durumda en fazla hata, iç yüzey hatasına sahip 95 veri birleşik hatayla karıştırılarak yapılmıştır.

Modelin performansını ayrıntılı olarak değerlendirmek için kullanılan bazı kriterler vardır. Hata matrisi kullanılarak hesaplanan bu değerler gerçek pozitif (TP), gerçek negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) ile ilgilidir. Modele ait kesinlik değeri Denklem 1, duyarlılık değeri Denklem 2, F1-Score değeri Denklem 3, özgüllük değeri Denklem 4 ve doğruluk değeri Denklem 5'te verilen formüllerle hesaplanır.

$$\text{Kesinlik (\%)} = \frac{TP}{TP+FP} \times 100 \quad (1)$$

$$\text{Duyarlılık (\%)} = \frac{TP}{TP+FN} \times 100 \quad (2)$$

$$\text{F1 - Score} = \frac{(\text{recall}) \times (\text{kesinlik}) \times 2}{(\text{recall}) + (\text{kesinlik})} \quad (3)$$

$$\text{Özgüllük (\%)} = \frac{TN}{TN+FP} \times 100 \quad (4)$$

$$\text{Doğruluk (\%)} = \frac{TP+TN}{TP+TN+FP+FN} \times 100 \quad (5)$$

Yukarıdaki formüller kullanılarak hesaplanan performans değerleri Tablo 3'te verilmiştir.

		Durum 1					Durum 2 (a)					Durum 2 (b)						
Gerçek	C1	2273	16	13	30	1	C1	5909	36	24	31	0	C1	4486	339	300	854	21
	C2	10	2428	0	13	2	C2	30	5833	17	25	95	C2	27	5747	23	165	38
	C3	22	8	2392	6	17	C3	12	0	5929	2	57	C3	53	22	5748	106	71
	C4	31	16	2	2261	9	C4	62	39	2	5854	43	C4	33	20	4	5918	25
	C5	1	21	27	15	2386	C5	1	4	50	12	5933	C5	0	3	63	26	5908
		Tahmin edilen					Tahmin edilen					Tahmin edilen						
		Durum 2 (c)					Durum 3 (a)					Durum 3 (b)						
Gerçek	C1	10826	649	59	464	2	C1	5792	14	13	169	12	C1	5760	1	4	232	3
	C2	77	11817	11	79	16	C2	18	5906	5	32	39	C2	230	5545	0	211	14
	C3	125	66	11676	88	45	C3	43	5	5900	1	51	C3	473	43	5409	13	62
	C4	164	184	10	11625	17	C4	128	2104	11	3699	58	C4	469	110	16	5325	80
	C5	30	112	290	207	11361	C5	16	29	37	44	5874	C5	19	39	72	16	5854
		Tahmin edilen					Tahmin edilen					Tahmin edilen						
		Durum 3 (c)																
Gerçek	C1	11192	16	10	767	15												
	C2	143	11198	1	612	46												
	C3	379	45	11340	46	190												
	C4	382	1898	30	9323	367												
	C5	10	43	51	120	11776												
		Tahmin edilen																

Şekil 6. Önerilen modelin hata matrisleri

Tablo 3. Önerilen 1D-CNN modelin performans değerleri

Durumlar	Koşullar	Kesinlik (%)	Duyarlılık (%)	F1-Skor (%)	Özgüllük (%)	Doğruluk (%)
Durum 1	-	%97.82	%97.82	%97.82	%99.45	%97.83
Durum 2	(a)	%98.20	%98.19	%98.19	%99.54	%98.19
	(b)	%93.21	%92.69	%92.52	%98.17	%92.69
	(c)	%95.61	%95.50	%95.50	%98.87	%95.51
Durum 3	(a)	%91.97	90.57	%90.24	%97.64	%90.54
	(b)	%93.40	%92.97	%93.04	%98.24	%92.98
	(c)	%91.45	%91.38	%91.32	%97.84	%91.38

Bu çalışmada aşağıdaki sınırlamalar mevcuttur:

- Kullanılan veri seti içerisindeki kayıtlar sınırlı olduğu için segmentasyon ile veri sayısı artırılmıştır. Daha fazla kayıt elde edilmesi durumunda daha yüksek ve güvenilir doğruluk değerlerine ulaşılabilir.
- Kullanılan derin öğrenme modellerinin eğitimleri GPU gibi yüksek özellikte donanıma ihtiyaç duymaktadır.

4. Sonuç

Bu çalışmada, bir motordaki yataklardan farklı hızlar altında alınan titreşim verileri ile beş sınıflı kapsayan bir sınıflandırma yapmak amacıyla 1D-CNN model önerilmiştir. Önerilen yöntem uçtan uca öğrenme yapısında olduğundan öznitelik çıkarımı veya seçimi süreçleri için herhangi bir uzman müdahalesine gerek duymadan otomatik olarak arıza tespiti sağlamıştır. Farklı durum ve koşullar oluşturularak model performansı değerlendirilmiş ve önerilen modelin %90.54 ile %98.19 arasında doğruluk oranlarıyla motor yatak ve bilyelerindeki arıza tespitini sağladığı görülmüştür. Bu doğruluk oranları, modelin motor arızası tespitinde kullanılabilir etkin bir yapıda olduğunu göstermektedir. 1D-CNN ile titreşim verilerinin analizi ve sınıflandırılmasının son derece basit olması ve sonuçların verimliliği bu modelin farklı motorlardan farklı yataklar için alınan sinyallerde uygulanabilirliğini denetlemek için motive edicidir.

Kaynaklar

- [1] Jia F, Lei Y, Lin J, Zhou X, Lu N. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mechanical systems and signal processing* 2016; 72: 303-315.
- [2] Kao IH, Wang WJ, Lai YH, Perng JW. Analysis of permanent magnet synchronous motor fault diagnosis based on learning. *IEEE Transactions on Instrumentation and Measurement* 2018; 68(2): 310-324.
- [3] Hoang DT, Kang HJ. A motor current signal-based bearing fault diagnosis using deep learning and information fusion. *IEEE Transactions on Instrumentation and Measurement* 2019; 69(6): 3325-3333.
- [4] Jing L, Zhao M, Li P, Xu X. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox. *Measurement* 2017; 111: 1-10.
- [5] Neupane D, Seok J. Bearing fault detection and diagnosis using case western reserve university dataset with deep learning approaches: A review. *IEEE Access* 2020; 8: 93155-93178.
- [6] Akbani R, Kwek S, Japkowicz N. Applying support vector machines to imbalanced datasets. In: *European conference on machine learning*; September 2004; Springer, Berlin, Heidelberg. pp. 39-50.
- [7] Lou X, Loparo KA. Bearing fault diagnosis based on wavelet transform and fuzzy inference. *Mechanical systems and signal processing* 2004; 18(5): 1077-1095.
- [8] Zhu H, He Z, Wei J, Wang J, Zhou H. Bearing fault feature extraction and fault diagnosis method based on feature fusion. *Sensors* 2021; 21(7): 2524.
- [9] Aydın I, Karaköse M, Akin E. An approach for automated fault diagnosis based on a fuzzy decision tree and boundary analysis of a reconstructed phase space. *ISA transactions* 2014; 53(2): 220-229.
- [10] Banerjee TP, Das S. Multi-sensor data fusion using support vector machine for motor fault detection. *Information Sciences* 2012; 217: 96-107.
- [11] Bera A, Dutta A, Dhara AK. Deep learning based fault classification algorithm for roller bearings using time-frequency localized features. In: *2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)*; 19-20 February 2021; Greater Noida, India. pp. 419-424.
- [12] Smith WA, Randall RB. Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study. *Mechanical systems and signal processing* 2015; 64: 100-131.
- [13] Ince T, Kiranyaz S, Eren L, Askar M, Gabbouj M. Real-time motor fault detection by 1-D convolutional neural networks. *IEEE Transactions on Industrial Electronics* 2016; 63(11): 7067-7075.
- [14] Lu C, Wang Z, Zhou B. Intelligent fault diagnosis of rolling bearing using hierarchical convolutional network based health state classification. *Advanced Engineering Informatics* 2017; 32: 139-151.
- [15] Janssens O, Slavkovikj V, Vervisch B, Stockman K, Locuffier M, Verstockt S, ... & Van Hoecke S. Convolutional neural network based fault detection for rotating machinery. *Journal of Sound and Vibration* 2016; 377: 331-345.
- [16] Shen S, Lu H, Sadoughi M, Hu C, Nemani V, Thelen A, ... & Kenny S. A physics-informed deep learning approach for bearing fault detection. *Engineering Applications of Artificial Intelligence* 2021; 103: 104295.
- [17] Hu J, Deng S. Rolling bearing fault diagnosis based on wireless sensor network data fusion. *Computer Communications* 2022; 181: 404-411.
- [18] Oh JW, Jeong J. Data augmentation for bearing fault detection with a light weight CNN. *Procedia Computer Science* 2020; 175: 72-79.
- [19] Chen Z, Li C, Sanchez RV. Gearbox fault identification and classification with convolutional neural networks. *Shock and Vibration* 2015; 2015.

- [20] Wang X, Qin Y, Zhang A. An intelligent fault diagnosis approach for planetary gearboxes based on deep belief networks and uniformed features. *Journal of Intelligent & Fuzzy Systems* 2018; 34(6): 3619-3634.
- [21] Zhao H, Liu H, Xu J, Guo C, Deng W. Research on a fault diagnosis method of rolling bearings using variation mode decomposition and deep belief network. *Journal of Mechanical Science and Technology* 2019; 33(9): 4165-4172.
- [22] Liu S, Xie J, Shen C, Shang X, Wang D, Zhu Z. Bearing fault diagnosis based on improved convolutional deep belief network. *Applied Sciences* 2020; 10(18): 6359.
- [23] Shao H, Jiang H, Zhang X, Niu M. Rolling bearing fault diagnosis using an optimization deep belief network. *Measurement Science and Technology* 2015; 26(11): 115002.
- [24] Lei Y, Jia F, Zhou X, Lin J. A deep learning-based method for machinery health monitoring with big data. *Journal of Mechanical Engineering* 2015; 51(21): 49-56.
- [25] Sun W, Shao S, Zhao R, Yan R, Zhang X, Chen X. A sparse auto-encoder-based deep neural network approach for induction motor faults classification. *Measurement* 2016; 89: 171-178.
- [26] Soother DK, Ujjan SM, Dev K, Khowaja SA, Bhatti NA, Hussain T. Towards soft real-time fault diagnosis for edge devices in industrial IoT using deep domain adaptation training strategy. *Journal of Parallel and Distributed Computing* 2022; 160: 90-99.
- [27] Huang H, Baddour N. Bearing vibration data collected under time-varying rotational speed conditions. *Data in brief* 2018; 21: 1745-1749.
- [28] Yıldırım Ö, Pławiak P, Tan RS, Acharya UR. Arrhythmia detection using deep convolutional neural network with long duration ECG signals. *Computers in biology and medicine* 2018; 102: 411-420.
- [29] Bengio Y. *Learning deep architectures for AI*. Now Publishers Inc., 2009.
- [30] Goodfellow I, Bengio Y, Courville A. *Deep learning*. MIT press., 2016.
- [31] Chollet, F. *Deep learning with Python*. Simon and Schuster, 2021.
- [32] Lei Y, Yang B, Jiang X, Jia F, Li N, Nandi AK. Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mechanical Systems and Signal Processing* 2020; 138: 106587.