



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



Rüzgâr türbini yüksek hızlı şaft rulmanının sağlık durumu aşamalarının derin öğrenme ile belirlenmesi

Identification of health status stages of wind turbine high speed shaft bearing with deep learning

Yazar(lar) (Author(s)): Gonca ÖCALAN¹, İbrahim TÜRKOĞLU²

ORCID¹: 0000-0002-3171-1871

ORCID²: 0000-0003-4938-4167

To cite to this article: Öcalan G., Türkoğlu İ., “Identification of health status stages of wind turbine high speed shaft bearing with deep learning”, *Journal of Polytechnic*, *(*) : *, (*).

Bu makaleye şu şekilde atıfta bulunabilirsiniz: Öcalan G., Türkoğlu İ., “Rüzgâr türbini yüksek hızlı şaft rulmanının sağlık durumu aşamalarının derin öğrenme ile belirlenmesi”, *Politeknik Dergisi*, *(*) : *, (*).

Erişim linki (To link to this article): <http://dergipark.org.tr/politeknik/archive>

DOI: 10.2339/politeknik.1388385

Rüzgâr Türbini Yüksek Hızlı Şaft Rulmanının Sağlık Durumu Aşamalarının Derin Öğrenme İle Belirlenmesi

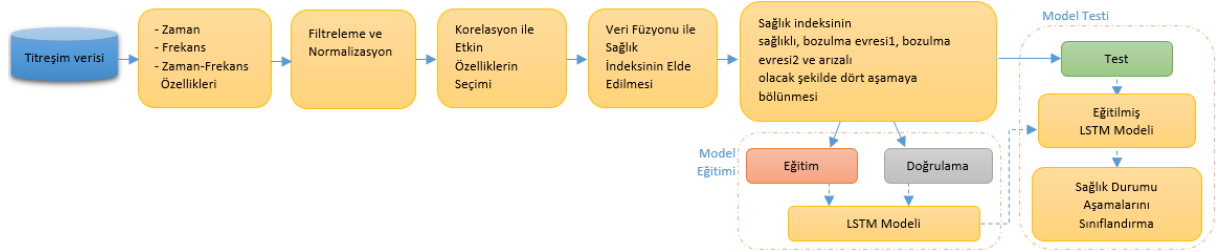
Identification Of Health Status Stages Of Wind Turbine High Speed Shaft Bearing With Deep Learning

Önemli noktalar (Highlights)

- ❖ Titreşim verilerinin ön işlenmesi / Preprocessing of vibration data
- ❖ Etkin titreşim özelliklerinin seçilmesi / Selecting active vibration features
- ❖ Veri füzyonu ile sağlık indeksinin oluşturulması / Creating a health index with data fusion
- ❖ LSTM ile sağlık durumu aşamalarının sınıflandırılması / Classification of health status stages with LSTM

Grafik Özet (Graphical Abstract)

Yapılan çalışmada, rüzgâr türbini yüksek hızlı şaft rulmanının sağlık durumu aşamalarını belirlemek amacıyla derin öğrenme modeli geliştirilmiş ve doğrulanmıştır. / In this study, a deep learning model has been developed to identify the health status stages of the wind turbine high-speed shaft bearing and validated



Şekil. Çalışmanın grafiksel özeti / Figure. Graphical summary of the study

Amaç (Aim)

Bu çalışmanın amacı, rulmana ait sağlık durumu aşamalarının, titreşim verileri kullanılarak önerilen derin öğrenme modeli ile sınıflandırılmasıdır. / The aim of this study is to classify the health status stages of the bearing with the proposed deep learning model using vibration data.

Tasarım ve Yöntem (Design & Methodology)

Çalışmada, derin öğrenme modeli, gerekli ön işlem adımlarının uygulandığı rulman titreşim verileri ile eğitilmiş ve test edilmiştir. / In the study, the deep learning model has been trained and tested with bearing vibration data, where the necessary pre-processing steps were applied.

Özgünlük (Originality)

Çalışmada önerilen derin öğrenme modeli bu probleme ilk kez uygulanmıştır. / The deep learning model proposed in the study is applied to this problem for the first time.

Bulgular (Findings)

Önerilen derin öğrenme modeli bu problem üzerinde oldukça başarılı sonuçlar elde etmiştir. / The proposed deep learning model has achieved very successful results on this problem.

Sonuç (Conclusion)

Geliştirilen derin öğrenme modeli, rulmanın sağlık durumu aşamalarını %99 doğrulukla sınıflandırabilmiştir. / The developed deep learning model is able to classify the health status stages of the bearing with 99% accuracy.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

Rüzgâr Türbini Yüksek Hızlı Şaft Rulmanının Sağlık Durumu Aşamalarının Derin Öğrenme İle Belirlenmesi

Araştırma Makalesi / Research Article

Gonca ÖCALAN^{1*}, İbrahim TÜRKOĞLU²

¹ Yazılım Mühendisliği Anabilim Dalı, Fırat Üniversitesi, Elazığ, Türkiye

² Yazılım Mühendisliği Bölümü, Fırat Üniversitesi, Elazığ, Türkiye

(Geliş/Received : 09.11.2023 ; Kabul/Accepted : 20.09.2024 ; Erken Görünüm/Early View : 03.10.2024)

ÖZ

Değişken hava koşulları altında kararsız çalışma ortamına sahip rüzgâr türbinlerinde, mekanik bileşenler oldukça yüksek yıpranma riski altındadır. Bu durum, bileşenlerde ani beklenmedik duruşları ve yüksek bakım maliyetlerini beraberinde getirmektedir. Enerji üretiminde sürekliliği sağlamak, beklenmeyen plansız duruşların önüne geçmek ve bakım maliyetlerini en aza indirmek amacıyla uygun bakım zamanlarının planlanması oldukça büyük öneme sahiptir. Bundan dolayı bileşende arıza meydana gelmeden önce sağlık durumunun dikkatli bir şekilde takip edilmesi ve bakım periyotlarının yıpranma sürecine göre planlanması gerekir.

Bu makalede, gerçek bir rüzgâr türbini yüksek hızlı şaft rulmanının sağlık durumunun değerlendirilmesi amacıyla, rulmanın sağlıklı, bozulma ve arızalanma aşamaları derin öğrenme tabanlı sınıflandırma modeli ile belirlenmektedir. Önerilen çalışmada gerçek bir rüzgâr türbini yüksek hızlı şaftından elde edilen titreşim verileri kullanılmaktadır. Bu çalışma, temel olarak titreşim verilerine ait özelliklerinin çıkarılması, rulmanın sağlık sürecini etkin bir şekilde ortaya çıkaracak özelliklerin seçilmesi, seçilen özelliklerin bütünleştirilerek sağlık indeksinin elde edilmesi ve sağlık indeksinin aşamalara bölünerek Uzun Kısa Süreli Bellek (Long Short Term Memory – LSTM) derin öğrenme modeli ile sınıflandırılması adımlarından oluşmaktadır. Dört farklı sağlık aşamasının belirlendiği çalışmada test verileri üzerinde %99 oranında doğruluk değeri elde edilmiştir.

Anahtar Kelimeler: rüzgâr türbini, titreşim, derin öğrenme, sağlık durumunun sınıflandırılması.

Identification Of Health Status Stages Of Wind Turbine High Speed Shaft Bearing With Deep Learning

ABSTRACT

Mechanical components in wind turbines with an unstable operating environment under variable weather conditions are at a very high risk of wear. This situation brings about sudden unexpected stops of components and high maintenance costs. It is of great importance to plan appropriate maintenance times in order to ensure continuity in energy production, prevent unexpected unplanned downtime and minimize maintenance costs. Therefore, before a component failure occurs, the health status must be carefully monitored and maintenance periods must be planned according to the wear and tear process.

In this paper, in order to evaluate the health status of a real wind turbine high-speed shaft bearing, the healthy, degradation and fault stages of the bearing are identified by a deep learning based classification model. In the proposed study, vibration data obtained from a real wind turbine high-speed shaft have been used. The study basically consists of the steps of extracting the features of the vibration data, selecting the features that will effectively reveal the health process of the bearing, obtaining the health index by integrating the selected features, and classifying the health index into stages with the LSTM deep learning model. In the study where four different health stages are defined, an accuracy of 99% has been obtained on the test data.

Keywords: wind turbine, vibration, deep learning, classification of health status.

1. GİRİŞ (INTRODUCTION)

Küresel iklim krizinin sebeplerinden biri olan karbon salınımı en fazla enerji santrallerinin fosil yakıt kullanımından kaynaklanmaktadır [1]. Doğal ekolojinin de büyük ölçüde zarar gördüğü bu durum, daha düşük karbon salımlı, çevre dostu yenilenebilir enerji kaynaklarına olan ilgiyi artırmaktadır [2–4]. Bununla birlikte, geniş alanlara yayılan kaynak yelpazesi ve enerjiyi düşük maliyetle dönüştürebilmesi, modern güç endüstrilerinde rüzgâr enerjisinin kullanımını cazip hale getirmektedir [3–5]. Rüzgâr santralleri genellikle kıyı,

dağ ve okyanus gibi rüzgâr enerjisinin yoğun fakat hava koşullarının sert ve değişken olduğu yerleşimden uzak bölgelerde kurulmaktadır [3,6]. Hava koşullarından dolayı çalışma ortamı kararsız hale gelen rüzgâr santrallerinde mekanik bileşenlerde beklenmedik arızaların, ani duruşların meydana gelmesi kaçınılmazdır [4,7]. Mekanik bileşende meydana gelen arıza kalitede bozulmaya, kapasite düşmesine, parça gereksinimine, ciddi güvenlik ve mal kaybına hatta bazı durumlarda yıkıcı hasarlara ve can kaybına neden olmaktadır [3–7]. Bununla birlikte, bakım maliyeti yüksek ve ani duruşlara

neden olan arızaların büyük bir bölümü rulmanda [7,8] veya dişli kutularında [4,5] meydana gelmektedir. Mekanik iletim sisteminde meydana gelen arızaların %30'unu rulman arızaları oluştururken [7] dişli kutularındaki arızaların önemli bir bölümü rulmandan kaynaklanmaktadır [9].

Olası bileşen arızalarını önlemenin en etkili yolu, makine sağlığı hakkında yapılan değerlendirmeler doğrultusunda bakım faaliyetlerinin uygun olacağı zamanın planlanmasıdır. Makine sağlığını değerlendirme yöntemlerini genel olarak, arıza teşhisi [2-12], arızaya yakın bileşenlerin sağlık durumu aşamalarının sınıflandırılması [13-17], kümelenmesi [18] ve kalan faydalı ömür tahmini [19] olarak sıralayabiliriz. Veri bilimi ve tahmin analitiğine dayanan bu yöntemler, gerçek zamanlı algılayıcılardan elde edilen çeşitli sinyallerin (ses [20], ısı [21], titreşim [11], görüntü [10,22], manyetik alan [23], akım[12] vb.) matematiksel [24], istatistiksel [25] veya yapay zekâ [13-17] tabanlı analizleri ile gerçekleştirilir.

Titreşim analizi, genel sağlık durumunun değerlendirilmesi ve anormal olayların tespit edilmesi amacıyla herhangi bir bileşen, makine veya yapıdan iletilen titreşimin zamansal ve mekânsal değişimlerinin araştırıldığı bir süreçtir. Titreşim analizi rulman arızası teşhisinde yaygın olarak kullanılmaktadır [11,13-17]. Rulmanda meydana gelebilecek herhangi bir kırık, çatlak veya aşınma benzeri deformasyon makineden iletilen titreşim sinyalinin oluşturduğu deseni değiştirecektir [11]. Deformasyon ilerledikçe titreşim sinyalindeki değişimin şiddeti de artacaktır. Rulmanın sağlık durumu, titreşim sinyalinde gerçekleşen bu değişim dikkate alınarak değerlendirilmektedir.

İleri sensör teknolojileri, kablosuz iletişim ve bilgi işlem sistemlerinin gelişimi ile büyük ivme kazanan yapay zekâ teknolojileri, makine sağlığının değerlendirilmesinde teşhis ve öngörücü model olarak yaygın bir şekilde kullanılmaktadır [11,13-19]. Literatür incelendiğinde, makine sağlığının değerlendirilmesinde genel olarak iki farklı yapay zekâ modelinin kullanıldığı görülmektedir. İlk modelde regresyon yöntemi ile sağlık indeksi (sağlık göstergesi ya da diğer bir deyişle performans bozulma eğrisi) kullanılarak kalan faydalı ömür tahmin edilmektedir [26-28]. İkinci modelde ise sağlık indeksi iki (sağlıklı, arızalı) veya daha fazla (sağlıklı, bozulma sürecinde, arızalı, vb.) aşamaya bölünerek [29], sınıflandırma [14] ya da kümeleme [18] yöntemleriyle makine sağlığının hangi aşamada olduğu tahmin edilmektedir. Sağlık durumu aşamalarının yapay zekâ ile sınıflandırıldığı titreşim analizi yöntemlerine bakıldığında, genel olarak aşağıdaki işlem adımlarından oluştuğu gözlemlenmiştir [13-17]:

- Titreşim verilerine ait özelliklerin çıkarılması
- Çıkarılan özelliklerin filtrelenmesi ve normalize edilmesi
- Sağlıklı, bozulma ve arıza süreçlerini etkin bir şekilde ortaya çıkaracak özelliklerin seçilmesi

- Seçilen özelliklerin veri füzyonu ile bütünleştirilerek sağlık indeksinin oluşturulması
- Sağlık indeksinin aşamalara bölünmesi ve yapay zekâ ile yorumlanması

Ben Ali vd. önerdikleri çalışmada [13], Cincinnati Üniversitesi Akıllı Bakım Sistemleri Merkezi (Intelligent Maintenance Systems - IMS) tarafından sağlanan rulman veri setini [30] kullanarak, geliştirdikleri yapay zekâ tabanlı sınıflandırma modelinin performansını değerlendirmektedirler. IMS titreşim verilerine ait zaman alanı istatistiksel özellikleri ve Ampirik Mod Ayrıştırması (Empirical Mode Decomposition - EMD) sonucunda elde edilen İçsel Mod Fonksiyonlarının (Intrinsic Mode Functions - IMF) enerji entropisi özellikleri, modelde kullanılan temel parametreler olarak belirlenmiştir. En etkili IMF bileşenin seçilmesi için sınıf içi varyans ile sınıflar arası varyans ilişkisine dayanan istatistiksel bir derece kullanılmıştır. İlk yedi IMF's bileşeninin seçildiği çalışmada, sınıflandırıcı olarak Yapay Sinir Ağları (YSA) kullanılmıştır. Çalışmada sağlık indeksi, sadece rulman arızasının derecesini gözlemlenmek için oluşturulmuş ve YSA'dan elde edilen sonuca göre hesaplanmıştır. İç bilezik, dış bilezik ve bilye bileşenlerine ait sağlıklı, bozulma ve arıza durumlarının sınıflandırıldığı çalışmada %93 oranında doğruluk değeri elde edilmiştir.

IMS rulman veri setinin kullanıldığı bir diğer çalışmada [14] Ben Ali vd., titreşim verilerine EMD zaman-frekans dönüşümünü uygulamış ve EMD ile elde ettikleri ilk 12 IMF's bileşenine ait enerji entropisi ile çok boyutlu özellik uzayını oluşturmuş. Çalışmada, özellik uzayını boyutsal olarak azaltmak ve bütünleştirmek için Temel Bileşen Analizi (Principal Component Analysis - PCA) ve Lineer Diskriminant Analizi (Linear Discriminant Analysis - LDA) yöntemleri kullanılmıştır. Sınıflandırma aşamasında, Basitleştirilmiş Bulanık Adaptif Rezonans Teorisi Haritası (Simplified Fuzzy Adaptive Resonance Theory Map - SFAM) ile Olasılıksal Sinir Ağı (Probabilistic Neural Network - PNN) olmak üzere iki farklı yapay zekâ modelinin performansı değerlendirilmiştir. PCA, LDA, SFAM ve PNN'nin farklı kombinasyonlarından oluşan altı farklı senaryo ile sonuçlar analiz edilmiştir. İç bilezik, dış bilezik ve bilye bileşenlerinin sağlıklı, bozulma ve arıza durumlarının sınıflandırıldığı çalışmada LDA-PNN-SFAM senaryosunda %97.82 doğruluk değeri ile en iyi başarımlar elde edilmiştir.

IMS ve FEMTO-ST Enstitüsü tarafından yayınlanan PRONOSTIA (rulmanların hızlandırılmış ömür testi için deneysel bir platform) [31] rulman veri setlerinin kullanıldığı çalışmada [15] Yan vd., özellik olarak titreşim verilerinin zaman alanı istatistiksel özelliklerinden olan Kök Ortalama Kare (Root Mean Square - RMS) kullanmışlar. Çalışmaya göre RMS, rulman bileşenlerinde hasar meydana geldiğinde artmaya başlar. Bununla birlikte hasarın yayılmasıyla birlikte RMS değerinde dalgalanmalar meydana gelir. Hasarı

oluşturan çatlakların kenarları sürekli yuvarlanma ile yumuşatıldığında RMS değeri azalır. Hasar ilerledikçe RMS tekrar yükselir. Bu dalgalanmalar yapay zekâ modelin tahmin performansını olumsuz yönde etkilemektedir. Bunu önüne geçmek için çalışmada, RMS değerinden türetilen Bağıl Ortalama Karekök (Relative Root Mean Square -RRMS) ve Ataletsel Bağıl Ortalama Karekök (Inertial Relative Root Mean Square -IRRMS) değerleri özellik olarak kullanılmış. Çalışmada, özelliklerin filtrelenmesi aşamasında basitleştirilmiş esnek üstel bir model oluşturulmuş. Model parametreleri ise Doğrusal Azalan Atalet Ağırlığına Sahip Parçacık Sürüsü Optimizasyon Algoritması (Particle Swarm Optimization Algorithm with Linearly Decreasing Inertia Weight - PSO-W) ile hesaplanmış. Sağlık göstergesi olarak kullanılacak olan bu filtrelenmiş RRMS ve IRRMS değerleri beş aşamaya bölünerek Destek Vektör Makinesi (Support Vector Machine - SVM) ile sınıflandırılmış. Doğruluk değerinde PRONOSTIA veri setinde %98.88, IMS veri setinde ise %92.99 başarımlar elde edilmiştir.

IMS rulman veri setinin kullanıldığı çalışmada [16] Dong vd., titreşim verilerine ait özelliklerin çıkarılması aşamasında derin otomatik kodlayıcı (Deep Auto Encoder – DAE) kullanmış. Doğrusal olmayan boyutsal azaltma yapısı t-Dağılımlı Stokastik Komşu Yerleştirme (t-Distribution Stochastic Neighbor Embedding - t-SNE) ile çok boyutlu özellikler iki boyutlu özellik uzayına dönüştürülmüş. Ardından iki boyutlu özelliklerin Mahalanobis mesafesi hesaplanarak sağlık göstergesi elde edilmiş. Sağlık göstergesi, 12 ile 48 arasında altı farklı aşamaya bölünerek farklı gürültü oranlarında Evrişimsel Sinir Ağı (Convolutional Neural Network - CNN) modeli ile sınıflandırılmış. Çalışmada gürültü seviyesi ve aşama sayısı arttıkça model performansında azalmalar gözlemlenmiştir.

IMS ve PRONOSTIA rulman veri setlerinin kullanıldığı bir diğer çalışmada [17] Chan vd., özellik çıkarma sürecinde titreşim verilerine Kısa Zamanlı Fourier Dönüşümünü (Short-Time Fourier transform - STFT) uygulamış. Aynı anda birden fazla sensörden toplanan titreşim verileri STFT işlemi ile zaman-frekans özelliklerine dönüştürülmüş ve elde edilen spektrogramlar çok kanallı olacak şekilde CNN modelinin girdisini oluşturmuş. Kullanılan sensör sayısı kadar kanalın oluşturulduğu çalışmada, girdi verilerinin etiketleri belirlenirken titreşim verilerinin RMS değerinden faydalanılmış. IMS veri seti için RMS grafiği dört aşamaya bölünürken PRONOSTIA veri seti için RMS grafiği 3 aşamaya bölünmüş. Girdi katmanı ile CNN katmanı arasında Sıkıştırma-Uyarma (Squeeze-Excitation - SE) katmanı oluşturularak kanallar arasındaki ilişki ortaya çıkarılmaya çalışılmış. Bununla birlikte, dikkat mekanizmaları ve düzenleme yöntemleri ile açıklanabilirliği artırılan modelde, sınıflandırıcı olarak ResNeXt mimarisi kullanılmış. Değerlendirme ölçütü olarak doğruluk değerinin kullanıldığı çalışmada, IMS için %99.88, PRONOSTIA için %98.86 başarımlar elde edilmiştir.

Ben Ali vd. önerdikleri diğer bir çalışmada [18], Rüzgâr türbini yüksek hızlı şaft rulmanına ait titreşim verilerini [32] (Wind Turbine High Speed Bearing - WTHSB) kullanarak, rulmanın sağlık durumunu belirlemek amacıyla bir kümeleme modeli geliştirmişler. Zaman bölgesi istatistiksel özellikleri (ortalama, RMS, basıklık, çarpıklık, vb.), STFT dönüşümü ile elde edilen spektrogramlara ait basıklık değerinin istatistiksel özellikleri, Ayırık Fourier Dönüşümü ile elde edilen bi-spektrum istatistiksel özellikleri ve Varyasyonel Mod Ayırıştırması (Variational Mode Decomposition - VMD) ile elde edilen ilk beş IMF bileşenine ait enerji entropisi ve enerji oranı önerilen modelin girdilerini oluşturmuş. Toplamda 45 özellik vektörünün kullanıldığı çalışmada, kümeleme aşamasında Adaptif Rezonans Teorisi 2 (Adaptive Resonance Theory 2 - ART2) ağırları kullanılmış. Başarım ölçütü olarak doğruluk değerinin kullanıldığı çalışmada %90 başarımlar elde edilmiştir.

WTHSB veri setinin kullanıldığı bir diğer çalışmada [33] Kobenko vd., titreşim sinyalini tanımlama ölçüm teknolojisini geliştirerek daha kullanılabilir sağlık göstergesi oluşturmuş. Literatürde daha önce kullanılmış olan S-Metodu, K-Metodu, AF-Metodu ve NF-Metodu teknolojileri kullanılarak titreşim verilerine ait karakteristik özellikler çıkarılmış. Burada ortalama yükseklik yöntemi olarak tanımlanan S-Metodu ile özellik S, belirli veriler arasındaki farkların oranı ile hesaplanmış. K-Metodu ile özellik K, ortalama düzeltilmiş sinyal değeri ile ortalama düzeltilmiş sinyal adım değerinin oranından elde edilmiş. NF-Metodunda özellik NF, RMS'nin varyasyon değerine oranının karesi alınarak elde edilmiş. AF-Metodunda ise K-metodu ve sinyalin ortalama düzeltilmiş değerleri kullanılarak oluşturulan mekanizma ile X_m , F_c ve A özellikleri elde edilmiş. Bu özelliklere ek olarak titreşim sinyaline ait istatistiksel özellikler (ortalama, standart sapma, RMS, basıklık, çarpıklık, vb.) ile STFT dönüşümü ile elde edilen spektrogramların basıklık değerine ait istatistiksel özellikler (ortalama, standart sapma, basıklık, çarpıklık) kullanılmış. Etkin özelliklerin seçimi için monotonluk fonksiyonunun kullanıldığı çalışmada özelliklerin filtrelenmesi aşamasında beş adımlı ortalama kayan filtre kullanılmış. Özelliklerin boyutsal olarak azaltılması ve bütünleştirilmesi aşamasında PCA'dan yararlanılmış. A , F_c , S , K ve NF özelliklerine PCA uygulanarak elde edilen sağlık göstergesi ile ortalama, basıklık, şekil faktörü, marj faktörü ve darbe faktörüne PCA uygulanarak elde edilen sağlık göstergesi karşılaştırılmış. Çalışmada tanımlama ölçüm teknolojileri ile elde edilen sağlık göstergesinin rulmanın sağlık durumunu 1.5 kat daha hassas bir şekilde yansıttığı ifade edilmiştir.

WTHSB veri setinin rulmanın kalan faydalı ömrünü tahmin etmek için kullanıldığı çalışmada [19] Özkat, titreşim verilerindeki arıza karakteristiğini ortaya çıkarabilmek amacıyla verilerin zaman alanı istatistiksel özelliklerine ek olarak Welch metodu ile elde edilen frekans bölgesi güç spektral yoğunluklarına ait istatistiksel özelliklerini kullanmış. Özelliklerin gürültüden arındırılması ve düzeltilmesi (yumuşatılması)

için Savitzky-Golay filtresinin kullanıldığı çalışmada normalizasyon aşamasında z-skoru yöntemi kullanılmış. Zaman ve frekans bölgesi istatistiksel değerlerinden oluşan özellik uzayını boyutsal olarak azaltmak amacıyla PCA kullanılmış. PCA ile elde edilen temel bileşen vektörlerinin seçimi aşamasında eksponansiyel artışı ifade eden eğim değerinden yararlanılmış. Sağlık göstergesi, seçilen temel bileşen vektörlerinin ortalaması alınarak oluşturulmuş. Elde edilen sağlık göstergesi ile eksponansiyel bozulma modeli kullanılarak kalan faydalı ömür tahmin edilmiş.

Bu çalışmanın amacı, gerçek bir rüzgâr türbini yüksek hızlı şaftından elde edilen WTHSB titreşim verilerini kullanarak, yüksek hızlı şaft rulmanının sağlıklı, bozulma ve arızalanma aşamalarını derin öğrenme ile belirlemektir. WTHSB, rulmanın iç bileziğinde meydana gelen bir çatlakın zamanla arızaya dönüştüğü 50 günlük kısıtlı verilerden oluşmaktadır. Veri setinin azlığından dolayı daha önce yapılan çalışmalarda genellikle makine öğrenmesi teknikleri kullanılmıştır. Bu çalışmada ise iç bilezikteki çatlak yayılmasıyla titreşim verilerinde meydana gelen değişimin çözünürlüğü artırılarak WTHSB verileri derin öğrenme ile analize müsait hale getirilmiştir. WTHSB verilerine ait zaman, frekans ve zaman-frekans özelliklerinin kullanıldığı çalışmada, rulmanın sağlık durumunu daha hassas bir şekilde belirlemek amacıyla, korelasyon yöntemi kullanılarak özellik seçimi yapılmış ardından seçilen özelliklere PCA uygulanarak sağlık indeksi elde edilmiştir. Elde edilen sağlık indeksi rulmanın sağlık durumunu değerlendirmek amacıyla dört aşamaya bölünmüş ve bu aşamalar derin öğrenme mimarilerinden LSTM ile sınıflandırılmıştır. Önerilen derin öğrenme modeli test verilerinde doğruluk, kesinlik, hassasiyet ve Fskor değerlerinde %99 başarımla sınıflandırma işlemini gerçekleştirmiştir.

2. MATERYAL VE METOD (MATERIAL and METHOD)

Yapılan çalışma, gerçek bir rüzgâr türbini yüksek hızlı şaft rulmanına ait sağlık durumu aşamalarının LSTM derin öğrenme modeliyle belirlenmesi amacıyla gerçekleştirilmiştir. Önerilen modelin prensip şeması Şekil.1’de verilmiştir.

Çalışmada önerilen modelin aşamalarını aşağıdaki gibi sıralayabiliriz:


- Özelliklerin çıkarılması: Rulmanın sağlık durumunu etkin bir şekilde belirleyebilmek

amacıyla kullanılacak olan çok boyutlu özellik uzayı, WTHSB verilerine ait zaman alanı istatistiksel özellikleri, WTHSB verilerine Fourier dönüşümü uygulanarak elde edilen frekans alanı özellikleri ve STFT ile elde edilen zaman-frekans alanı özelliklerinin çıkarılmasıyla elde edilmiştir.

- Filtreleme ve normalizasyon: Eksponansiyel filtre ile gürültüden arındırılan özellikler, 0 1 aralığında normalize edilmiştir.
 - Korelasyon ile etkin özelliklerin seçimi: Arızalanma karakteristiğini ortaya çıkarabilecek etkin özelliklerin seçimi için Spearman korelasyon yöntemi kullanılmıştır. Bu yöntem ile zaman eksenini en yüksek korelasyona sahip özellikler seçilmiştir.
 - Veri Füzyonu ile sağlık indeksinin elde edilmesi: Seçilen özellik uzayının boyutunu azaltmak ve verileri bütünleştirmek için PCA yöntemi kullanılmıştır. PCA ile elde edilen ilk temel bileşen sağlık indeksi olarak kullanılmıştır.
 - Sağlık indeksinin aşamalara bölünmesi: Rulmanın sağlık durumunu değerlendirmek amacıyla sağlık indeksi dört aşamaya bölünmüş ve her bir aşama için %80 eğitim, %10 doğrulama ve %10 test olacak şekilde veriler üçe ayrılmıştır.
- Modelin eğitimi: Eğitim ve doğrulama verileri ile LSTM modeli eğitilmiştir
- Modelin testi: Eğitilen LSTM modeli test verileri ile test edilmiştir.


2.1 Veri Elde Edilmesi (Obtaining Data)

Bu çalışmada, açık kaynaklı olarak yayınlanan gerçek bir rüzgâr türbinine ait WTHSB veri seti kullanılmıştır. Veri seti, Amerika’daki Green Power Monitoring Systems tarafından sağlanan 2 MW’lık rüzgâr türbininin yüksek hızlı şaftından elde edilen titreşim verilerinden oluşmaktadır [18]. Veriler, dişli kutusu rulmanının desteklediği yüksek hızlı şaft üzerine radyal olarak monte edilen ivmeölçerler ile 97656Hz örnekleme frekansında kaydedilmiştir [18]. Ardışık 50 gün boyunca her gün 6 saniyelik süreler ile veriler toplanmıştır. Bu süre zarfında rulmanın iç bileziğinde meydana gelen çatlak gelişerek arızaya sebep olmuştur. Şekil.2’de WTHSB veri seti için



Şekil.1 Önerilen modelin prensip şeması (Principle diagram of the proposed model)

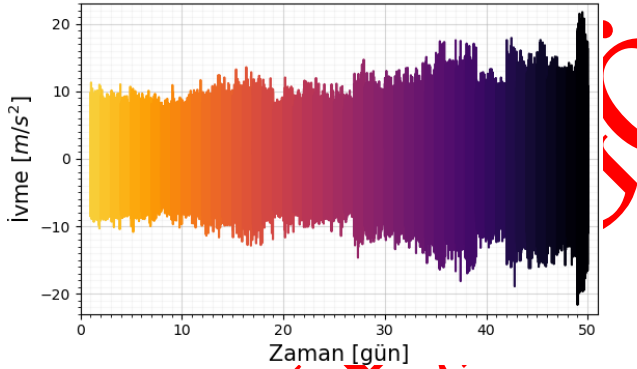
kullanılan test düzeneği ve iç bilezikte meydana gelen çatlak verilmiştir.



Şekil.2 (a) Rulman test düzeneği, (b) iç bilezikte meydana gelen çatlak. ((a) Bearing test setup, (b) crack occurring in the inner ring) [18]

2.2 Özelliklerin Çıkarılması (Extracting Features)

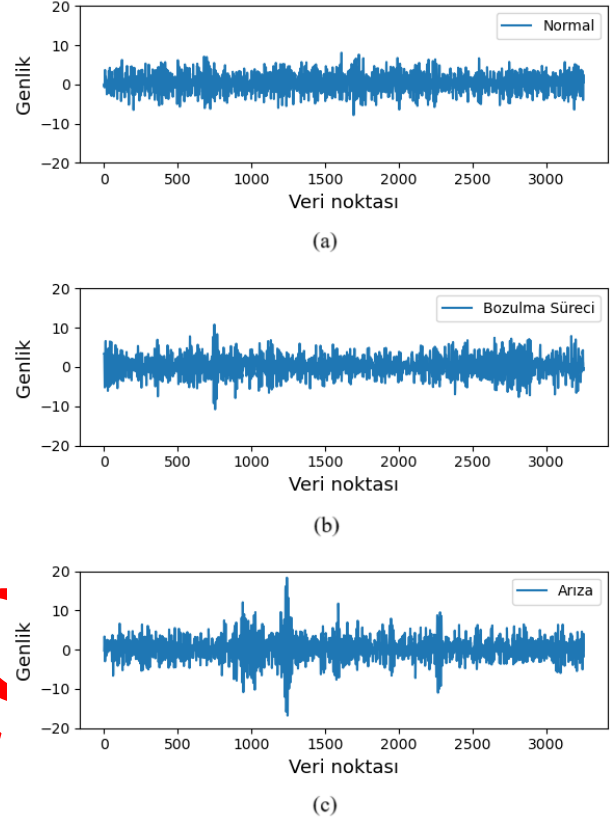
50 gün boyunca kaydedilen ve sonunda iç bilezik arızası ile sonuçlanan WTHSB titreşim verileri Şekil.3'de verilmiştir. Şekil.3 incelendiğinde, iç bilezikteki çatlak yayıldıkça titreşim verilerinin genliğinde artış gözlemlenmektedir.



Şekil.3 50 gün boyunca toplanan titreşim verileri (Vibration data collected for 50 days)

WTHSB veri seti oluşturulurken her gün 6 saniyelik süreler ile veriler kaydedilmiştir. Bu veri seti ile yapılan çalışmalara [18,19,33] bakıldığında özellikler çıkarılırken 6 sn'nin tamamını kapsayacak şekilde veri boyutu seçilmiştir. Bu da veri uzunluğunun 6x97656 veri noktasından oluştuğu anlamına gelmektedir. Veri uzunluğu bu şekilde seçilirse çıkarılan her bir özellik vektörü sadece 50 elemandan oluşacaktır. Bu değer derin öğrenme ile analiz gerçekleştirebilmek için yetersizdir. Bu çalışmada şimdiye kadar yapılan çalışmalardan farklı olarak veri uzunluğu rulmanın tam bir turuna denk gelecek şekilde seçilmektedir. Rulmanın çalışma frekansı yaklaşık 30Hz dir [18]. Dolayısıyla rulmanın bir turuna denk gelen veri sayısı yaklaşık 3255 (97656/30) olacaktır. Bu boyuttaki veri uzunluğu ile çıkarılan her bir özellik vektörü 9000 elemandan oluşmaktadır. Bu da derin öğrenme ile analiz için yeterli bir rakamdır.

Bu çalışmada, rulmanın sağlık durumuna ait sağlıklı, bozulma ve arıza süreçleri değerlendirilmektedir. Şekil.4' de bu süreçlere karşılık gelen titreşim örnekleri verilmiştir. Örneklere bakıldığında, sağlıklı durumdan arızaya doğru ilerledikçe titreşim verilerinde iç bilezikteki çatlaktan kaynaklanan darbelerin genliğinde gözle görülür bir artış meydana gelmektedir.



Şekil.4 Rulmanın (a) sağlıklı, (b) bozulma ve (c) arıza süreçlerine ilişkin veri örnekleri (Data examples of the bearing's (a) healthy, (b) degradation and (c) failure processes)

Bu çalışmada, rulmanın sağlığı hakkında değerlendirme yapabilmek adına sağlıklı, bozulma ve arıza durumlarına ilişkin ayırt edici nitelikler titreşim verilerine ait zaman, frekans ve zaman-frekans bölgesi özellikleri çıkarılarak elde edilmektedir. Zaman bölgesinde titreşim sinyaline ait Tablo.1'de verilen istatistiksel özellikler kullanılmaktadır. Bu özellikler içerisinde RMS hem dalganın zaman geçmişini hem de enerjiyi hesaba katmaktadır. Dolayısıyla titreşimin yıkıcı etkileriyle doğrudan ilişkilidir [34]. Basırlık değeri ise geçici tepe noktalarının sayısına karşılık gelir. Geçici tepe noktaları sayısındaki artış yüksek basırlığa karşılık gelirken bu durum aşınmanın göstergesidir [35]. Tepe faktörü ise zaman sinyalinde mevcut olan darbelerin sayısıdır. Rulman arızaları titreşimde ani darbeler ile kendini göstermektedir. Bundan dolayı tepe faktörü bu tarz arızaların teşhisinde basit ve hızlı bir çözüm olarak görülmektedir [36].

Frekans bölgesine ait özellikler Fast Fourier Transform (FFT) ile elde edilmektedir. FFT ile sinüzoidal olmayan titreşim verilerinin yapısında var olan sinüs bileşenleri hesaplanmaktadır. Harmonik dediğimiz her bir sinüs bileşeni frekans bölgesinde bir çizgiye karşılık gelirken çizginin yüksekliği genliği, konumu ise frekansı temsil etmektedir. Rulman arızalarının her biri frekans bölgesinde farklı frekans ve genlikte sinüs bileşeni şeklinde kendini göstermektedir. Bundan dolayı arıza teşhisinde yaygın bir şekilde kullanılan bir yöntemdir [37–39].

FFT, sinyalin periyodik olduğu varsayımı ile hesaplanmaktadır. Bu da bazı durumlarda frekans bölgesinde artık bileşenlerin oluşmasına yol açmaktadır. Ayrıca frekans bölgesine dönüşüm esnasında zaman bilgisi kaybolmaktadır. Bu eksiklikleri gidermek adına zaman-frekans dönüşüm yöntemleri geliştirilmiştir. Bu yöntemlerden biri olan STFT zaman bilgisini kullanabilmek için pencereleme yöntemini kullanır. Bu yöntemde veriler zaman ekseninde küçük pencerelere ayrılır ve periyodikliği sağlamak için her bir pencere sonlu enerjiye sahip türevlenebilir bir fonksiyon ile çarpılır. Elde edilen kısa zamanlı pencerelerin her birine FFT uygulanarak frekans alanına dönüşüm gerçekleştirilir. Bu çalışmada STFT gerçekleştirilirken pencere uzunluğu 64, örtüşme oranı 50 ve pencere fonksiyonu hann seçilmiştir. STFT ile elde edilen spektrogramlar, güç spektral yoğunluğunu yansıtacak şekilde ayarlanmıştır. Spektral basıklık (Spectral Kurtosis - SK), spektrogramlara ait basıklık değerinin hesaplanmasıyla elde edilmektedir. Denklem (1) ile hesaplanan SK, arıza ilerledikçe artan bir eğilimle

değişim göstermektedir [40]. Bu yüzden birçok arıza teşhisi uygulamasında [18,19,40] tercih edilen bir yöntem olmuştur.

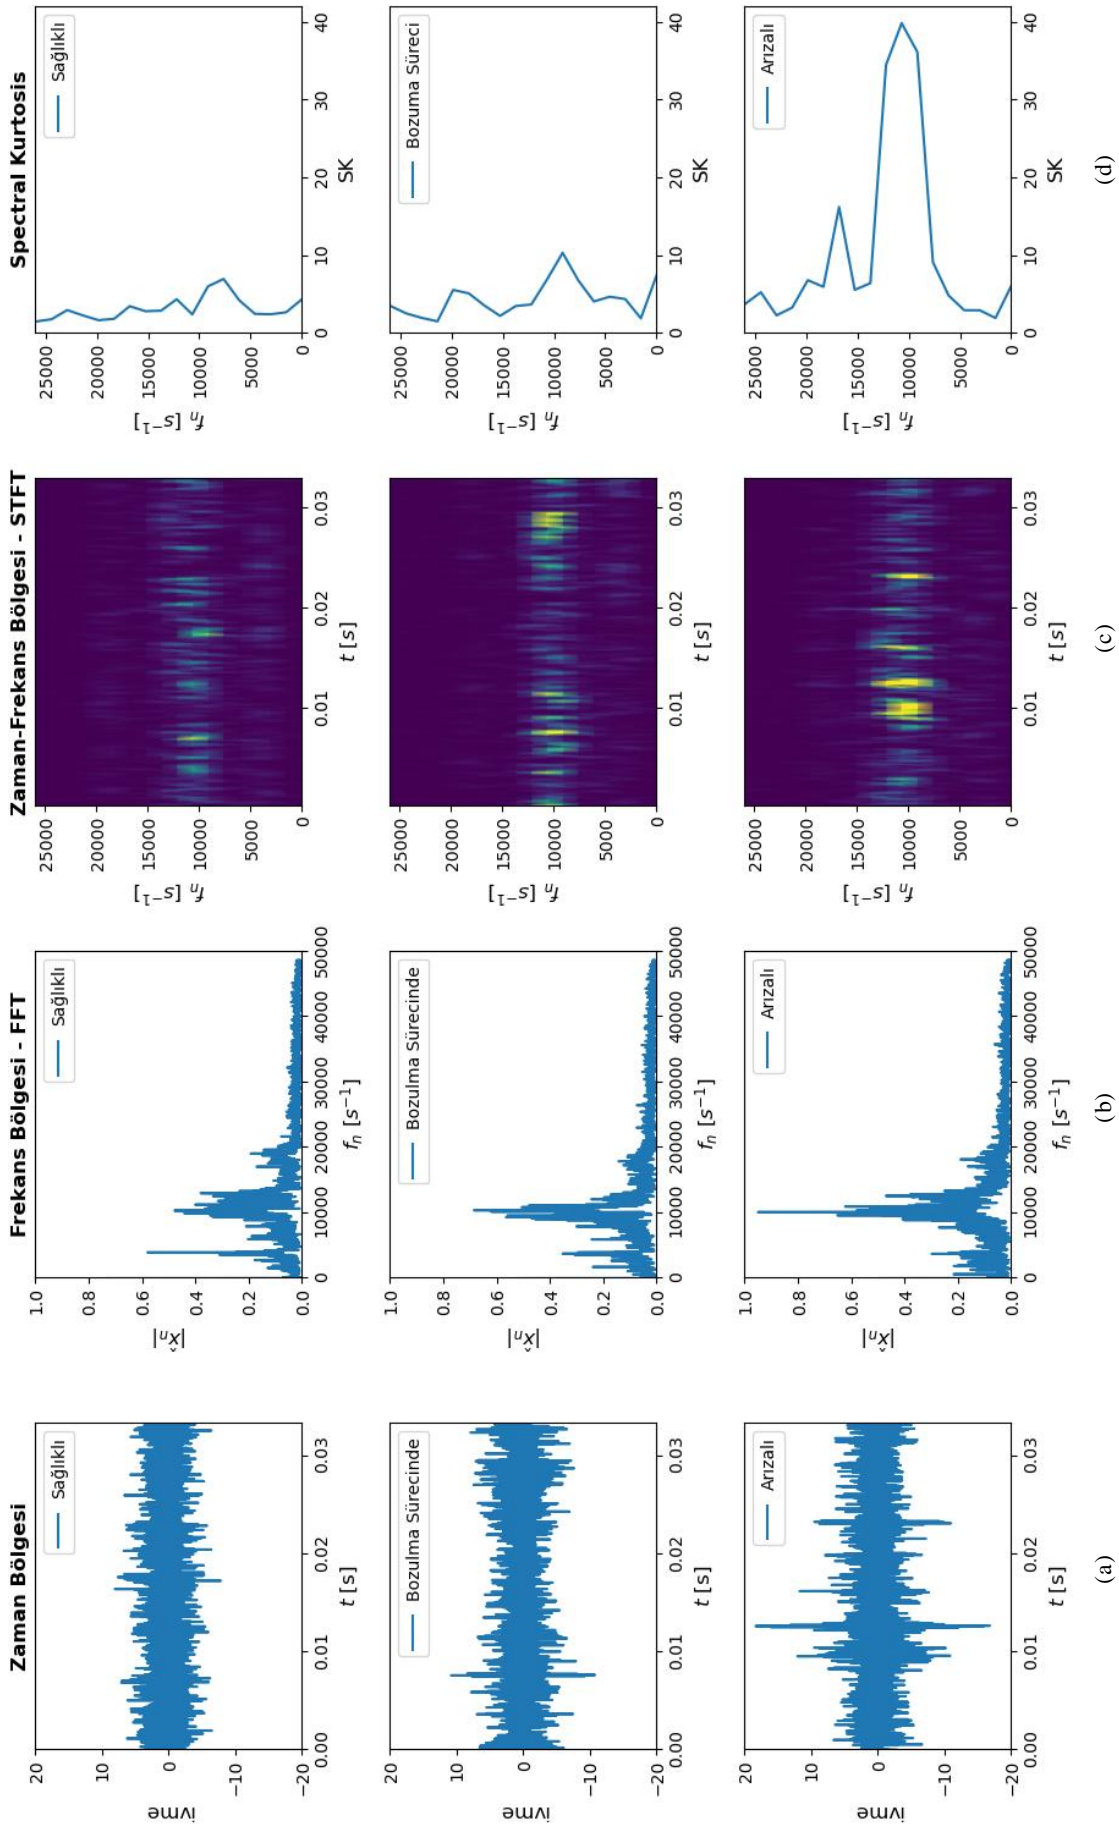
$$SK(f) = \frac{\langle |X^4(t,f)| \rangle}{(X^2(t,f))^2} - 2 \quad (1)$$

Şekli.5’de rulmanın sağlıklı, bozulma ve arıza durumlarına ait zaman bölgesi, FFT ile elde edilen frekans bölgesi, STFT ile elde edilen zaman frekans bölgesi spektrogramları ve bu spektrogramlardan elde edilen SK grafikleri verilmiştir. FFT grafiklerine bakıldığında sağlıklı durumdan arızaya doğru ilerledikçe 0-25000 Hz aralığında oldukça yoğun bir değişim gözlenmektedir. Bu yüzden STFT ve SK elde edilirken bu frekans aralığı dikkate alınarak hesaplamalar yapılmıştır. Arıza durumuna ait grafikler incelendiğinde zaman bölgesinde 0.01 sn civarında ve 0.02 ile 0.03 sn aralığında gerçekleşen darbeler STFT grafiğinde aynı zaman dilimlerinde 10000 Hz civarında kendini sarı pikseller olarak göstermektedir. Yine sağlıklı durumdan arızaya doğru 10000 Hz civarında SK değerlerindeki değişim oldukça dikkat çekicidir.

Tablo.1’de verilen istatistiksel özellikler arıza teşhisinde hem zaman hem de frekans bölgesinde kullanılacak etkili niteliklerdir [19]. Dolayısıyla bu çalışmada zaman bölgesi istatistiksel özellikleri ile FFT ve SK değerlerine ait istatistiksel özellikler, modelde kullanılacak olan özellik uzayını oluşturmaktadır. Şekil.6’da zaman bölgesi istatistiksel özellikleri ile FFT ve SK değerlerinden elde edilen istatistiksel özellikler

Tablo.1 Zaman Alanı İstatistiksel Özellikleri (Time Domain Statistical Properties)

<i>İst. Özellik</i>	<i>Denklem</i>	<i>İst. Özellik</i>	<i>Denklem</i>
<i>Minimum Değer</i>	$x_{min} = \min x_i $	<i>Maksimum Değer</i>	$x_{max} = \max x_i $
<i>Tepe Faktörü</i>	$Tf = \frac{x_{max}}{x_{rms}}$	<i>Etki Faktörü</i>	$Ef = \frac{x_{max}}{\frac{1}{N} \sum_{i=1}^N x_i }$
<i>Ortalama</i>	$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$	<i>Çarpıklık</i>	$\zeta pk = \frac{\sum_{i=1}^N (x_i - \bar{x})^3}{(N - 1)\sigma^3}$
<i>Standart Sapma</i>	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$	<i>RMS</i>	$x_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
<i>Basıklık</i>	$Bsk = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{(N - 1)\sigma^4}$		



Şekil.5 Rulmanın sağlıklı, bozulma ve arıza durumlarına ait (a) zaman bölgesi, (b) FFT ile elde edilen frekans bölgesi (c) STFT ile elde edilen zaman frekans bölgesi spektrogramı ve (d) spektrogramlardan elde edilen SK grafikleri. ((a) Time domain, (b) Frequency region obtained by FFT (c) Time-frequency domain spectrogram obtained by STFT (d) SK graphs obtained from the spectrograms of the bearing's health, degradation and failure situations)

verilmiştir. Ortalama (Ort), standart sapma (Std), minimum (Min), maksimum (Max), basıklık, çarpıklık, etkin değer (RMS), tepe faktörü (TepeF), etki faktörü (EtkiF) zaman bölgesinde çıkarılan özelliklerdir. Zaman frekans bölgesinde SK değerinden türetilen özellikler maksimum (SKmax), ortalama (SKort), basıklık (SKbsk), çarpıklık (SKcrpk), standart sapma (SKstd) ve RMS (SKrms) değerleridir. Frekans bölgesinde FFT grafiklerinden elde edilen özellikler maksimum (FFTmax), standart sapma (FFTstd), basıklık (FFTbsk), çarpıklık (FFTcrpk) ve RMS (FFTrms) değerleridir.

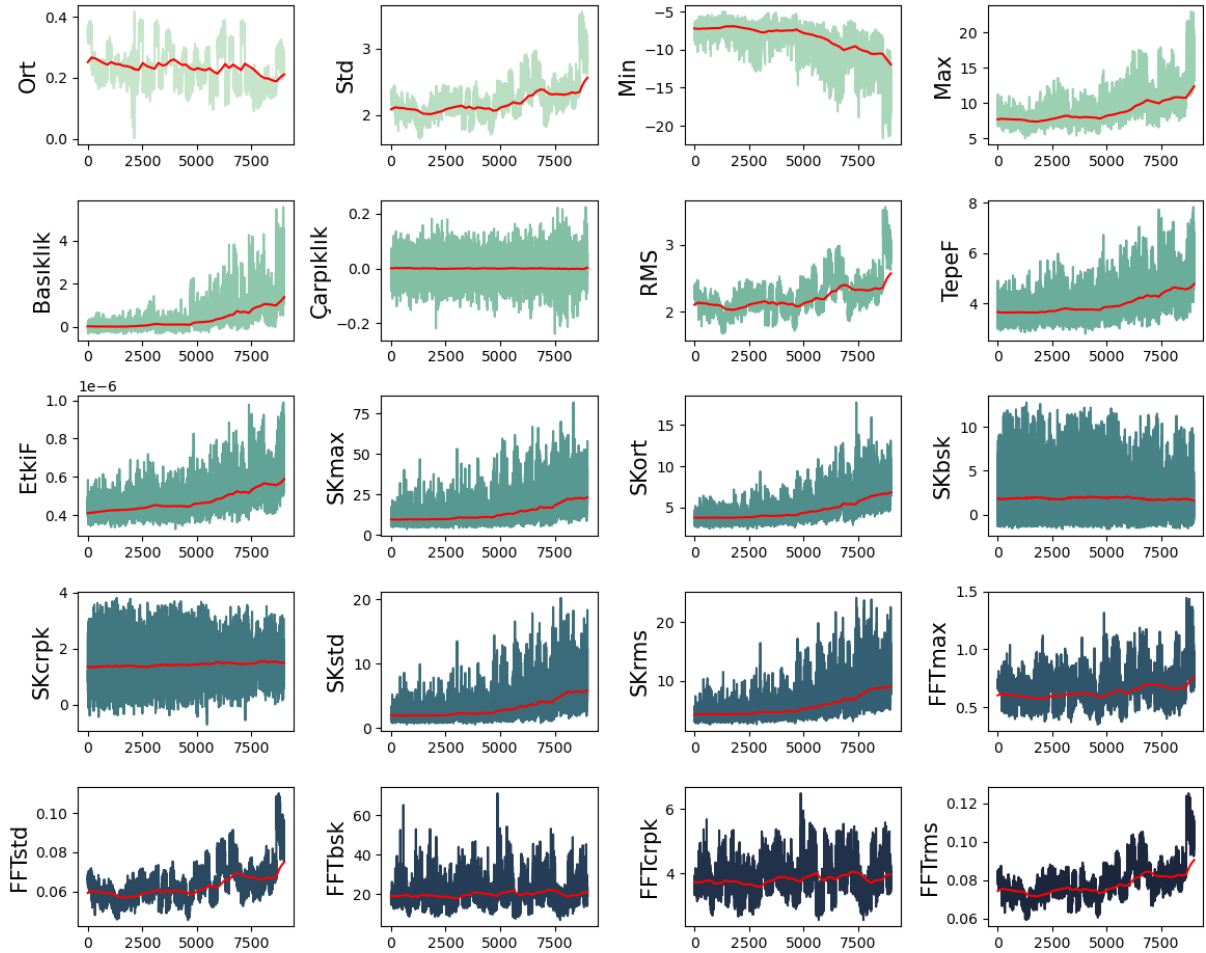
Özellikler çıkarıldıktan sonra filtreleme ile gürültüden arındırma ve yumuşatma işlemi yapılmaktadır. Literatüre bakıldığında zaman serilerinin analizinde genellikle ortalama kayan filtre [33], medyan filtresi [41], Savitzky-Golay [19], LOWESS [38], ve ekponansiyel filtre [42–44] sıklıkla karşılaşılan filtrelerdir. Ortalama kayan filtrede geçmiş gözlemlere eşit ağırlıklar atanırken, ekponansiyel filtrede zaman içinde üstel olarak azalan ağırlıklar atanmaktadır [45]. Bir diğer deyişle gözlem ne kadar yeni olursa ilgili ağırlık da o kadar yüksek olacaktır. Ayrıca ortalama kayan filtrede eski veriler unutulurken ekponansiyel filtrede eski veriler unutulmaz sadece ağırlıkları daha düşüktür. Bu

çalışmada yumuşatma işlemi için çıkarılan özelliklere ekponansiyel filtre uygulanmıştır. Şekil.6’da çıkarılan özellikler üzerindeki kırmızı eğriler ekponansiyel filtre ile elde edilen değerlerdir. Filtreleme işleminden sonra tüm elde edilen değerler Şekil.7’de verildiği gibi 0 1 aralığında normalize edilmiştir. Normalize edilmiş değer x_{norm} Denklem (2) ile hesaplanmaktadır. Burada x_i i . değeri, x_{min} veri içerisindeki minimum değeri, x_{max} veri içerisindeki maksimum değeri ifade etmektedir.

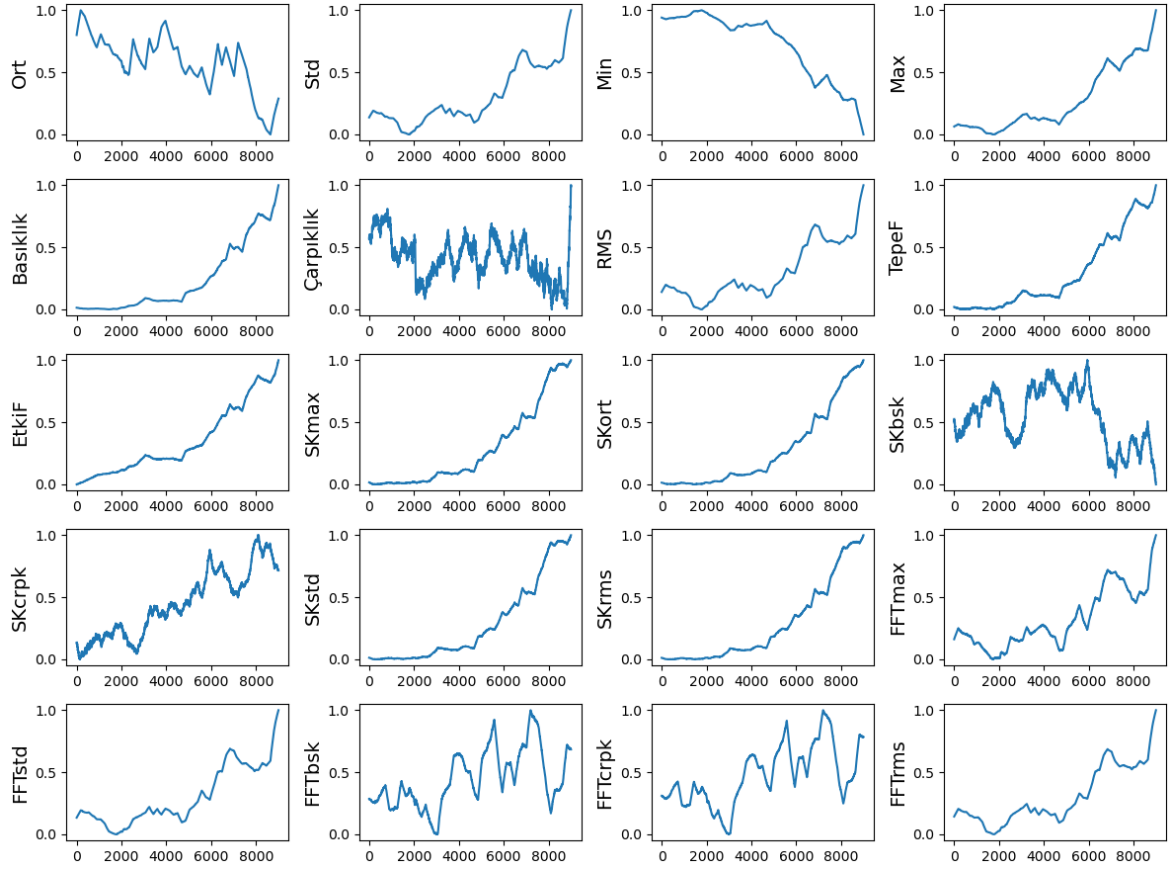
$$x_{norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (2)$$

2.3 Etkin Özelliklerin Seçimi (Selection of Active Features)

Rulmanın sağlık durumunu karakterize edebilecek özelliklerin seçimine yönelik yapılan çalışmalara bakıldığında monotonluk, eğilim, öngörülebilirlik ve korelasyon parametrelerinin sıklıkla kullanıldığı görülmektedir [29,33,46–48]. Özelliklerin seçimi esnasında bazı çalışmalarda bir parametre kullanılırken [33], bazılarında iki veya daha fazla parametrenin ağırlıklandırılmasıyla elde edilen denklemler [29,46,49] kullanılmaktadır.




Şekil.6 Zaman bölgesi, FFT ve SK değerlerinden elde edilen istatistiksel özellikler. (Statistical features obtained from time domain, FFT and SK values.)



Şekil.7 Normalize edilmiş istatistiksel özellikler (Normalized statistical features)

Bu çalışmada Spearman korelasyon yöntemi [48-51] kullanılarak zaman eksenini ile en yüksek ilişkiye sahip özellikler sağlık indeksini oluşturmak üzere seçilmektedir. Şekil.8’de özelliklerden elde edilen korelasyon değerleri verilmiştir. Elde edilen sonuçlara göre SKmax, SKrms, SKstd, SKort ve Etkif en yüksek korelasyona sahip ilk beş özelliştir. Şekil.7’deki grafiğe bakıldığında da bu özelliklerin diğerlerine kıyasla zaman eksenine göre daha monotonik bir artış sergiledikleri gözlemlenmiştir.



Şekil.8 Özellikler ile zaman eksenini arasındaki korelasyon değerleri (Correlation values between features and time axis)

2.4 Sağlık İndeksinin Oluşturulması (Creating the Health Index)

Literatür incelendiğinde rulmanın sağlık durumunun genellikle sağlık indeksleri üzerinden değerlendirildiği gözlemlenmiştir [15,16,27,52]. Sağlık indeksi rulmanın tüm yaşam döngüsünü kapsayan, sağlıklı, bozulma ve arıza süreçlerinin karakteristiğini yansıtan sayısal verilerden oluşmaktadır. Literatürde, bazı çalışmalarda zaman, frekans veya zaman-frekans bölgelerine ait yalnızca bir özelliğin, örneğin RMS [53] veya basıklık gibi [54,55], sağlık indeksi olarak kullanıldığı görülmektedir. Basıklık, ani darbelerin varlığını belirlemede kullanılan en eski göstergelerden biridir [56]. Ayrıca, arızanın erken aşamasını, RMS değerine kıyasla daha erken tespit edebilmektedir [56]. Bununla birlikte hem basıklık hem de RMS gürültü ve çalışma koşullarından etkilenmektedirler [56-58]. Aynı zamanda, tek bir özellikten ziyade birden fazla özelliğin arıza karşısında gösterdiği değişimin dikkate alınması makine sağlığının değerlendirilmesinde daha başarılı sonuçlar elde edilmesini sağlamıştır [14,33,57]. Birden fazla özelliğin dikkate alındığı çalışmalarda sağlık indeksi, çok boyutlu özellik uzayının PCA [19,33], LDA [14], t-SNE [16,57] gibi veri füzyonu yöntemleri kullanılarak tek boyuta indirgenmesiyle

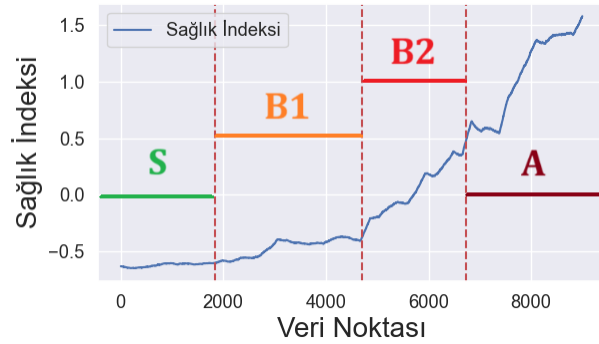
elde edilmiştir. PCA çok boyutlu verileri, varyansı maksimum olacak şekilde daha düşük boyuta indirgeyen, keşifsel veri analizlerinde ve kestirimsel modellerde kullanılan bir yöntemdir [59]. Bu çalışmada, zaman eksenini en yüksek korelasyona sahip ilk beş özelliğe (SKmax, SKrms, SKstd, SKort ve EtkiF) PCA uygulanmış ve PCA'nın ilk temel bileşeni sağlık indeksi olarak atanmıştır. Elde edilen sağlık indeksi Şekil.9'da verildiği gibi dört aşamaya bölünmüştür. Burada,

S: sağlıklı,

B1: bozulma evresi 1,

B2: bozulma evresi 2,

A: arıza aşamasını ifade etmektedir.



Şekil.9 PCA ile elde edilen sağlık indeksi (Health index obtained by PCA)

Sağlık indeksinin aşamaları belirlendikten sonra, derin öğrenme ağının girdilerini oluşturan örnekler, 10 zaman adımlı ve %90 örtüşme oranına sahip serilerle temsil edilmiştir. Her bir aşama için elde edilen örnekler %80 eğitim, %10 doğrulama ve %10 test olacak şekilde üçe ayrılmıştır. Tablo.2'de her bir aşama için elde edilen eğitim, test ve doğrulama örnek dağılımları verilmiştir. Toplamda, eğitim 7170, doğrulama 898 ve test 896 örnekten oluşmaktadır.

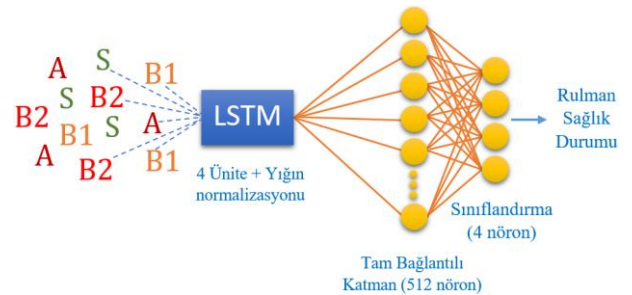
Tablo.2 Sınıflara ait eğitim, doğrulama ve test örnek dağılımları (Training, validation and test sample distributions for classes)

	Eğitim	Doğrulama	Test
S	1467	184	183
B1	2279	285	285
B2	1624	203	203
A	1800	226	225
Toplam	7170	898	896

2.5 Rulmanın Sağlıklı, Bozulma ve Arıza Aşamalarının Derin Öğrenme ile Belirlenmesi (Identification of Healthy, Degradation and Failure Stages of the Bearing by Deep Learning)

Yapay zekânın bir alt disiplini olan derin öğrenme, insan beyninin gözlemleme, analiz etme, öğrenme ve karar verme süreçlerini büyük verilerden yararlanarak taklit eden bir makine öğrenmesi tekniğidir. Günümüzde, büyük veri kümelerine doğrudan erişim imkânı ve GPU, TPU gibi yüksek hesaplama gücüne sahip teknolojilerin gelişimi, derin öğrenme alanında hızlı ilerlemelere olanak sağlamış ve bu doğrultuda yeni yaklaşımlar geliştirilmiştir. Derin öğrenme modellerinden olan LSTM metin üretme [60], metin sınıflandırma [61], el yazısı tespiti [62], sessiz videolara ses eklenmesi [63] gibi verilerin sıralı bir şekilde analizini gerektiren birçok uygulamada kullanılan [64,65] güçlü bir araçtır. Yine makine sağlığının değerlendirilmesine yönelik yayınlanan çok sayıda çalışmada LSTM modelinin kullanıldığı gözlemlenmiştir [66-71].

Bu çalışmada, rulmanın sağlıklı, bozulma ve arıza aşamaları LSTM derin öğrenme modeli ile sınıflandırılmıştır. Önerilen derin öğrenme modeli Şekil.10'da verilmiştir. Oldukça basit bir yapıya sahip model sadece girdi katmanı, 4 üniteli bir LSTM katmanı, tam bağlantılı katman ve sınıflandırma katmanından oluşmaktadır. Önerilen model girdi olarak S, B1, B2 ve A sınıflarına ait 10 adımlı zaman serilerini kullanmaktadır. Model çıkışında ise rulmanın sağlığına ilişkin dört farklı durum sınıflandırılmıştır.



Şekil.10 Uygulanan LSTM modeli (Applied LSTM model)

Önerilen LSTM modeli Python 3.11 platformunda tensorflow, keras ve scikit-learn kütüphaneleri kullanılarak geliştirilmiştir. Modelin eğitimi esnasında epok sayısı 100, yığın boyutu 16, kayıp fonksiyonu categorical_crossentropy, optimizasyon algoritması Adam, öğrenme oranı 1e-4 olacak şekilde ayarlanmıştır. Model, eğitim ve doğrulama verileri ile eğitilmiş, test verileri ile test edilmiştir. Modelin eğitimi esnasında keras kütüphanesinin ModelCheckpoint özelliği kullanılarak kayıp fonksiyonunun en düşük olduğu ağırlıklar

kaydedilmiş ve test esnasında bu ağırlıklar kullanılmıştır.

3. SONUÇLAR ve TARTIŞMA (RESULTS AND DISCUSSION)

Önerilen LSTM modelinin performansı değerlendirilirken başarımlar ölçütü olarak doğruluk (accuracy), kesinlik (precision), hassasiyet (recall), Fskor (Fscore) değerleri kullanılmıştır. Seçilen başarımlar ölçütleri karışıklık matrisi parametreleri üzerinden hesaplanmaktadır. Şekil.11'de dört sınıflı bir modelin karışıklık matrisi verilmiştir. Karışıklık matrisinde kullanılan değişkenler doğru pozitif (true positive - tp), yanlış pozitif (false positive - fp), yanlış negatif (false negative - fn) ve doğru negatif (true negative - tn) değerleridir. Herhangi bir sınıfa ait tp , fp , fn , tn değerleri hesaplanırken o sınıfa ait satır ve sütunların kesiştiği değerler dikkate alınır. Örneğin Şekil.11'de 2. sınıfa ait tp_2 , fp_2 , fn_2 , tn_2 hesaplanırken arka planı sarı olan değerler hesaplamalarda kullanılacak olan değerlerdir.

		TAHMİN EDİLEN SINIFLAR			
		1	2	3	4
GERÇEK SINIFLAR	1	tp_1	fp_{12}	fp_{13}	fp_{14}
	2	fp_{21}	tp_2	fp_{23}	fp_{24}
	3	fp_{31}	fp_{32}	tp_3	fp_{34}
	4	fp_{41}	fp_{42}	fp_{43}	tp_4

Şekil.11 Karışıklık matrisi (Confusion matrix)

Burada;

- tp_2 : 2. satır ve 2. sütunun kesiştiği hücredir
- fp_2 : 2. satırda tp_2 dışında kalan değerlerin toplamı:

$$fp_2 = fp_{21} + fp_{23} + fp_{24}$$
 (3)
- fn_2 : 2. sütunda tp_2 dışında kalan değerlerin toplamı:

$$fn_2 = fn_{21} + fn_{23} + fn_{24}$$
 (4)
- tn_2 : köşegenlerde tp_2 dışında kalan değerlerin toplamı:

$$tn_2 = tp_1 + tp_3 + tp_4$$
 (5)

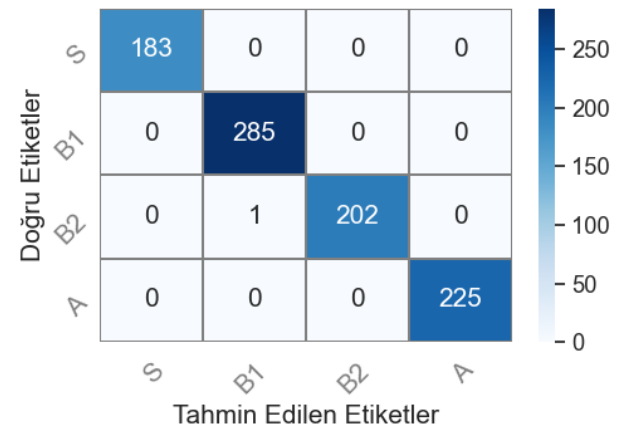
olarak ifade edilebilir. Her bir sınıfa ait tp , fp , fn , tn değerleri elde edildikten sonra başarımlar ölçütleri Tablo.3'de verildiği gibi hesaplanmaktadır [72]. Burada i sınıf numarası olmak üzere, tp_i , fp_i , fn_i , tn_i sırasıyla i . sınıfa ait doğru pozitif, yanlış pozitif, yanlış negatif ve doğru negatif değerleridir. Ayrıca avr , μ , M indisleri sırasıyla ortalama, mikro

ortalama ve makro ortalamaı ifade etmektedir. Çalışmada $\beta = 1$ olacak şekilde hesaplamalar yapılmıştır.

Tablo.3 Başarımlar ölçütleri (Performances metrics) [72]

Ölçüt	Denklem
$Accuracy_{avr}$ (Doğruluk _{ort})	$\frac{\sum_{i=1}^l \frac{tp_i + tn_i}{tp_i + tn_i + fp_i + fn_i}}{l}$
$Precision_{\mu}$ (Kesinlik _{μ})	$\frac{\sum_{i=1}^l tp_i}{\sum_{i=1}^l (tp_i + fp_i)}$
$Recall_{\mu}$ (Hassasiyet _{μ})	$\frac{\sum_{i=1}^l tp_i}{\sum_{i=1}^l (tp_i + fn_i)}$
$Fscore_{\mu}$ (Fskor _{μ})	$\frac{(\beta^2 + 1) Precision_{\mu} Recall_{\mu}}{\beta^2 Precision_{\mu} + Recall_{\mu}}$
$Precision_M$ (Kesinlik _{M})	$\frac{\sum_{i=1}^l \frac{tp_i}{tp_i + fp_i}}{l}$
$Recall_M$ (Hassasiyet _{M})	$\frac{\sum_{i=1}^l \frac{tp_i}{tp_i + fn_i}}{l}$
$Fscore_M$ (Fskor _{M})	$\frac{(\beta^2 + 1) Precision_M Recall_M}{\beta^2 Precision_M + Recall_M}$

LSTM modelinin test verileri ile test edilmesi sonucu elde edilen karışıklık matrisi Şekil.12'de verilmiştir. Sonuçlara göre sadece B2 sınıfına ait bir örnek, B1 olarak yanlış sınıflandırılmıştır. Geriye kalan diğer tüm örnekler doğru bir şekilde sınıflandırılmıştır



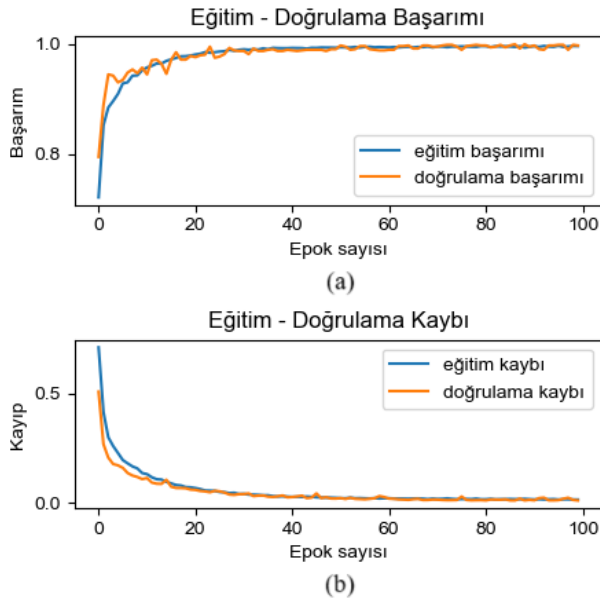
Şekil.12 LSTM modelinin test edilmesi ile elde edilen Karışıklık Matrisi / Figure.12 Confusion Matrix obtained by testing the LSTM model

Modelin test verileri ile test edilmesi sonucu elde edilen başarımlar Tablo 4’ de verilmiştir. Burada *ort* indisi ortalama anlamına gelmektedir. Tüm ölçütlerde de %99 başarımlar elde edilmiştir.

Tablo.4 Modelin test edilmesiyle elde edilen başarımlar (Performances obtained by testing the model)

	<i>Kesinlik</i>	<i>Hassasiyet</i>	<i>Fskor</i>	<i>Örnek</i>
<i>S</i>	1.0000	1.0000	1.0000	183
<i>B1</i>	0.9965	1.0000	0.9982	285
<i>B2</i>	1.0000	0.9951	0.9975	203
<i>A</i>	1.0000	1.0000	1.0000	225
<i>Doğruluk_{ort}</i>			0.9989	896
<i>Mikro_{ort}</i>	0.9989	0.9989	0.9989	896
<i>Makro_{ort}</i>	0.9991	0.9988	0.9989	896

Eğitim esnasında önerilen modelin doğruluk ölçütüne göre elde edilen eğitim-doğrulama kayıp ve başarımların grafikleri Şekil.13’de verilmiştir. Grafiklerde, önerilen model oldukça kararlı bir eğitim süreci gerçekleştirmiştir. Doğrulama başarımları hızlı bir şekilde eğitim başarımlarına yakınsayarak kararlı durumuna ulaşmıştır. Elde edilen bu sonuçlar LSTM modelinin rulmanın sağlık durumuna ilişkin karakteristik özellikleri yüksek başarımla öğrenildiğini göstermektedir.



Şekil.13 Önerilen LSTM modeline ait doğruluk ölçütüne göre eğitim-doğrulama sonuçları (a) Eğitim-doğrulama başarımları (b) Eğitim-doğrulama kaybı (Training-validation results according to the accuracy criterion of the proposed LSTM model (a) Training-validation performance (b) Training-validation loss)

4. SONUÇ (CONCLUSION)

Bu çalışmada, gerçek bir rüzgâr türbini yüksek hızlı şaft rulmanının sağlık durumu aşamalarını belirlemek amacıyla, derin öğrenme tabanlı sınıflandırma modeli önerilmiştir. Çalışmada kullanılan WTHSB titreşim verileri 50 günlük kısıtlı verilerden oluşmaktadır. Buna karşın derin öğrenme tabanlı analiz yöntemleri büyük miktarda veriye ihtiyaç duymaktadır. Bu çalışmada ilk defa WTHSB verilerinden türetilen örnekler, sentetik veri çoğaltma yöntemlerine başvurmadan, titreşim verilerinin orijinal doğası korunarak çoğaltılmış ve derin öğrenme ile analize uygun hale getirilmiştir. Elde edilen örneklere ait zaman bölgesi istatistiksel özellikleri ile FFT ve SK istatistiksel özelliklerinin kullanıldığı çalışmada, rulmanın sağlık durumunu daha hassas bir şekilde ortaya çıkaracak olan özellikler Spearman korelasyon yöntemi ile seçilmiştir. Elde edilen sonuçlara göre, SK_{max}, SK_{rms}, SK_{std}, SK_{ort} ve EtkiF özellikleri, zaman eksenini ile en yüksek korelasyona sahip özelliklerdir ve diğer özelliklere kıyasla zaman eksenini ile daha monoton bir artış sergilemektedirler. Bu nedenle, bu özellikler süreç boyunca zamanla orantılı bir şekilde değişim gösteren kritik parametreler olarak değerlendirilebilir ve rulmanın sağlığındaki değişimleri belirlemek için temel gösterge olarak kullanılabilirler. Çalışmada temel gösterge olarak seçilen bu özelliklere PCA uygulanarak sağlık indeksi elde edilmiştir. Elde edilen sağlık indeksi rulmanın sağlık durumunu değerlendirmek amacıyla dört aşamaya bölünmüş ve bu aşamalar LSTM derin öğrenme modeli ile sınıflandırılmıştır. Çalışmada önerilen derin öğrenme modelinde, tek katmanlı ve dört üniteli LSTM, tam bağlantılı katman ve sınıflandırma katmanı kullanılmıştır. Modelin eğitimi esnasında doğruluk ölçütüne göre elde edilen kayıp ve başarımların grafikleri oldukça kararlı bir yapı sergilemiş bu da modelin rulmanın sağlık durumuna ilişkin karakteristik özellikleri etkili bir şekilde öğrenebildiğini göstermiştir. Bununla birlikte, LSTM katmanının yapısal sadeliği, verilerin analizi sırasında bellek kullanımı ve çıkarım süresi açısından önemli avantajlar sunmaktadır. Ayrıca, önerilen modelin test verileri üzerinde tüm ölçütlerde elde ettiği %99 başarımlar, LSTM’in sıralı veriler üzerindeki etkinliğini ve başarı potansiyelini açıkça ortaya koymaktadır. Elde edilen bulgular, önerilen derin öğrenme modelinin rüzgâr santrallerinde bakım ekiplerine, bozulma eğilimi gösteren rulmanların tespiti, yedek parça temini ve bakım zamanlarının planlanması konularında önemli bir destek sağlayabileceğini göstermektedir. Bu sayede, rüzgâr santrallerindeki beklenmedik arızalar minimize edilerek operasyonel verimlilik artırılabilir. Bu durum, hem maliyetlerin düşürülmesine hem de enerji üretiminin kesintisiz sürdürülmesine katkı sağlayacaktır.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma, TÜBİTAK – BİDEB 2211/C Yurtiçi Öncelikli Alanlar Doktora Burs Programı, 100/2000 Yükseköğretim Kurulu (YÖK) Doktora Burs Programı ve Fırat Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi (FÜBAP) tarafından ADEP.22.06 numaralı proje ile desteklenmektedir. Vermiş oldukları desteklerden dolayı TÜBİTAK, YÖK ve FÜBAP'a teşekkür ederiz.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Gonca ÖCALAN: Veri toplama ve uygulama kodlamasını gerçekleştirerek bulguları analiz etmiştir. / Analysed the findings by performing data collection and application coding.

İbrahim TÜRKÖĞLU: Yapay zekâ modelinin uygulama sürecini ve başarımlerini tasarlamıştır. / Designed the implementation process and performance metrics of the artificial intelligence model

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur. / There is no conflict of interest in this study.

KAYNAKLAR (REFERENCES)

- [1] Çoban O., Kılıç N.Ş., "Yenilenebilir Enerji Tüketimi ve Karbon Emisyonu İlişkisi: Türkiye Örneği", *Sos. Bilim. Enstitüsü Derg.*, 38: 195–208, (2015).
- [2] Xuejun W., Yunpeng G., Hexu Y., Hongjuan L., Yanqing T., Bin L., "Research on Fault Diagnosis of Gearbox Bearing of Wind Turbine Generator Set Based on DNN-1.5 MW", *2021 3rd World Symp. Artif. Intell.*, 92–97, (2021).
- [3] Zhang G., Li Y., Jiang W., Shu L., "A fault diagnosis method for wind turbines with limited labeled data based on balanced joint adaptive network", *Neurocomputing*, 481: 133–153, (2022).
- [4] Liang P., Deng C., Yuan X., Zhang L., "A deep capsule neural network with data augmentation generative adversarial networks for single and simultaneous fault diagnosis of wind turbine gearbox", *ISA Trans.*, 135: 462–475, (2023).
- [5] Wu Y., Tang B., Deng L., Li Q., "Distillation-enhanced fast neural architecture search method for edge-side fault diagnosis of wind turbine gearboxes", *Expert Syst. Appl.*, 208: 118049, (2022).
- [6] Li Q., Tang B., Deng L., Xiong P., Zhao M., "Cross-Attribute adaptation networks: Distilling transferable features from multiple sampling-frequency source domains for fault diagnosis of wind turbine gearboxes", *Measurement*, 200: 111570, (2022).
- [7] Xu Z., Li C., Yang Y., "Fault diagnosis of rolling bearings using an Improved Multi-Scale Convolutional Neural Network with Feature Attention mechanism", *ISA Trans.*, 110: 379–393, (2021).
- [8] Tang Z., Wang M., Ouyang T., Che F., "A wind turbine bearing fault diagnosis method based on fused depth features in time–frequency domain", *Energy Reports*, 8: 12727–12739, (2022).
- [9] Praveen H.M., Sabareesh G.R., Inturi V., Jaikanth A., "Component level signal segmentation method for multi-component fault detection in a wind turbine gearbox", *Measurement*, 195: 111180, (2022).
- [10] Kaycı B., Demir B.E., Demir F., "Deep Learning Based Fault Detection and Diagnosis in Photovoltaic System Using Thermal Images Acquired by UAV", *Politek. Derg.*, 27: 91–99, (2024).
- [11] Öcalan G., Türkoğlu İ., "Dönen Makinelerde Ham Titreşim İşaretleri ve Derin Öğrenme Kullanılarak Arıza Teşhisi", *2021 Akıllı Sist. Yenilikler ve Uygulamaları Kong.*, 1–7, (2021).
- [12] Kaya K., Ünsal A., "Yapay Sinir Ağlarıyla Asenkron Motor Çoklu Arızalarının Tespiti ve Sınıflandırılması", *Politek. Derg.*, 25: 1687–1699, (2022).
- [13] Ben Ali J., Fnaiech N., Saidi L., Chebel-Morello B., Fnaiech F., "Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals", *Appl. Acoust.*, 89: 16–27, (2015).
- [14] Ben Ali J., Saidi L., Mouelhi A., Chebel-Morello B., Fnaiech F., "Linear feature selection and classification using PNN and SFAM neural networks for a nearly online diagnosis of bearing naturally progressing degradations", *Eng. Appl. Artif. Intell.*, 42: 67–81, (2015).
- [15] Yan M., Wang X., Wang B., Chang M., Muhammad I., "Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model", *ISA Trans.*, 98: 471–482, (2020).
- [16] Dong S., Wu W., He K., Mou X., "Rolling bearing performance degradation assessment based on improved convolutional neural network with anti-interference", *Measurement*, 151: 107219, (2020).
- [17] Chan Y.L., Shuai H.H., "Explainable Health State Prediction for Social IoTs through Multi-Channel Attention", *2021 IEEE Glob. Commun. Conf.*, 1–6, (2021).
- [18] Ben Ali J., Saidi L., Harrath S., Bechhoefer E., Benbouzid M., "Online automatic diagnosis of wind turbine bearings progressive degradations under real experimental conditions based on unsupervised machine learning", *Appl. Acoust.*, 132: 167–181, (2018).
- [19] Özkat E.C., "Makine Öğrenmesi Metodolojisi Kullanılarak Yüksek Hızlı Rulmanlarda Sağlık Göstergesinin Belirlenmesi", *Eur. J. Sci. Technol.*, 176–183, (2021).
- [20] Mian T., Choudhary A., Fatima S., "An efficient diagnosis approach for bearing faults using sound quality metrics", *Appl. Acoust.*, 195: 108839, (2022).

- [21] Xie F., Wang G., Shang J., Liu H., Xiao Q., Xie S., "Gearbox Fault Diagnosis Method Based on Multidomain Information Fusion", *Sensors*, 23: 4921, (2023).
- [22] Choudhary A., Mian T., Fatima S., "Convolutional neural network based bearing fault diagnosis of rotating machine using thermal images", *Measurement*, 176: 109196, (2021).
- [23] Barzegaran M., Mazloomzadeh A., Mohammed O.A., "Fault Diagnosis of the Asynchronous Machines Through Magnetic Signature Analysis Using Finite-Element Method and Neural Networks", *IEEE Trans. Energy Convers.*, 28: 1064–1071, (2013).
- [24] Ottewill J.R., Ruszczak A., Broda D., "Monitoring tooth profile faults in epicyclic gearboxes using synchronously averaged motor currents: Mathematical modeling and experimental validation", *Mech. Syst. Signal Process.*, 84: 78–99, (2017).
- [25] Soave E., D'Elia G., Dalpiaz G., "Prognostics of rotating machines through generalized Gaussian hidden Markov models", *Mech. Syst. Signal Process.*, 185: 109767, (2023).
- [26] Zhu H., Huang Z., Lu B., Zhou C., "Bearing remaining useful life prediction of fatigue degradation process based on dynamic feature construction", *Int. J. Fatigue*, 164: 107169, (2022).
- [27] Du X., Jia W., Yu P., Shi Y., Cheng S., "A remaining useful life prediction method based on time–frequency images of the mechanical vibration signals", *Measurement*, 202: 111782, (2022).
- [28] Li J., Mao W., Yang B., Meng Z., Tong K., Yu S., "RUL prediction of rolling bearings across working conditions based on multi-scale convolutional parallel memory domain adaptation network", *Reliab. Eng. Syst. Saf.*, 243: 109854, (2024).
- [29] Jia X., Ji D.Y., Minami T., Lee J., "Data Quality and Usability Assessment Methodology for Prognostics and Health Management: A Systematic Framework", *IFAC-PapersOnLine*, 55: 55–60, (2022).
- [30] J. Lee, H. Qiu, G. Yu, J. Lin and R.T.S., "IMS Bearing Data Set", <https://www.nasa.gov/intelligent-systems-division/discovery-and-systems-health/pcoe/pcoe-data-set-repository/>, (2007).
- [31] Nectoux P., Gouriveau R., Medjaher K., Ramasso E., Morello B., Zerhouni N. V.C., "PRONOSTIA Bearing Data Set", <https://www.nasa.gov/intelligent-systems-division/discovery-and-systems-health/pcoe/pcoe-data-set-repository/>, (2012).
- [32] Eric Bechhoefer, "Wind Turbine High Speed Bearing Prognosis Data", <https://github.com/mathworks/WindTurbineHighSpeedBearingPrognosis-Data/>, (2020).
- [33] Kobenko V.Y., Frolov S.O., "Monitoring of the Wind Turbine Bearing Condition Using Identification Measurement Technology", *2022 Dyn. Syst. Mech. Mach.*, 1–6, (2022).
- [34] HBK, "Measuring Vibration: The Complete Guide", <https://www.bksv.com/en/knowledge/blog/vibration/measuring-vibration.>, (2022).
- [35] Mohd Ghazali M.H., Rahiman W., "Vibration Analysis for Machine Monitoring and Diagnosis: A Systematic Review", *Shock Vib.*, 2021: 1–25, (2021).
- [36] Pelioglu Ö.M., "Dişlilerdeki Hatanın Titreşim Analizi Yoluyla Belirlenmesi", *Gazi Üniversitesi Fen Bilim. Enstitüsü*, Yüksek Lisans Tezi, (2019).
- [37] Sun B., Liu X., "Bearing early fault detection and degradation tracking based on support tensor data description with feature tensor", *Appl. Acoust.*, 188: 108530, (2022).
- [38] Shi M., Ding C., Que H., Wu C., Shi J., Shen C., Huang W., Zhu Z., "Multilayer-graph-embedded extreme learning machine for performance degradation prognosis of bearing", *Measurement*, 207: 112299, (2023).
- [39] Sim J., Min J., Kim S., Lee S.W., Choi J.H., "Construction of bearing health indicator under time-varying operating conditions based on Isolation Forest", *Eng. Appl. Artif. Intell.*, 126: 107058, (2023).
- [40] Kim S., An D., Choi J.H., "Diagnostics 101: A Tutorial for Fault Diagnostics of Rolling Element Bearing Using Envelope Analysis in MATLAB", *Appl. Sci.*, 10: 7302, (2020).
- [41] Lyakhov P.A., Kialdze M.R., Kaplun D.I., Voznesensky A.S., "Removal of Ocular Artifacts from the Electroencephalogram Signal Flow using Median Filtering", *2021 Int. Conf. Autom. Informatics*, 97–100, (2021).
- [42] Zhao Z., Chen N.Z., "An exponential smoothing multi-head graph attention network (ESMGAT) method for damage zone localization on wind turbine blades", *Compos. Struct.*, 342: 118224, (2024).
- [43] Shi J., Zhong J., Zhang Y., Xiao B., Xiao L., Zheng Y., "A dual attention LSTM lightweight model based on exponential smoothing for remaining useful life prediction", *Reliab. Eng. Syst. Saf.*, 243: 109821, (2024).
- [44] Wang D.F., Feng L.X., "Fuzzy Asynchronous Fault Detection for Markov Jump Systems With Packet Loss Compensation and Partially Unknown Transition Probabilities", *2023 IEEE 2nd Ind. Electron. Soc. Annu. On-Line Conf.*, 1–6, (2023).
- [45] Wikipedia, "Exponential Smoothing", https://en.wikipedia.org/wiki/Exponential_smoothing, (2023).
- [46] Cheng Y., Hu K., Wu J., Zhu H., Lee C.K.M., "A deep learning-based two-stage prognostic approach for remaining useful life of rolling bearing", *Appl. Intell.*, 52: 5880–5895, (2022).
- [47] Baptista M.L., Goebel K., Henriques E.M.P., "Relation between prognostics predictor evaluation metrics and local interpretability SHAP values", *Artif. Intell.*, 306: 103667, (2022).
- [48] Liang Z., Gao J., Jiang H., Gao X., Gao Z., Wang R., "A Degradation Degree Considered Method for Remaining Useful Life Prediction Based on Similarity", *Comput. Sci. Eng.*, 21: 50–64, (2019).
- [49] Hou Z., Wang H., Yue Y., Xiong M., Zhang W., "A novel framework based on two-stage multi-view feature optimization and improved support vector data description for aeroengine bearing early fault detection", *Reliab. Eng. Syst. Saf.*, 245: 110027, (2024).
- [50] Shang Y., Sun F., Fang Q., Chen B., "Heliyon A novel fault diagnosis strategy for LED lamps via light output

- time-frequency characteristics analysis and machine learning", *Heliyon*, 9: e19737, (2023).
- [51] Peng S., Liao H., Liu Y., Ouyang W., Li C., He S., "State Monitoring and Fault Detection of GIS Isolation Disconnecter Based on Spearman Rank Correlation Coefficient", *2023 3rd Int. Conf. Electr. Eng. Control Sci.*, 1270–1273, (2023).
- [52] Wang Z., Zhao W., Li Y., Dong L., Wang J., Du W., Jiang X., "Adaptive staged RUL prediction of rolling bearing", *Measurement*, 222: 113478, (2023).
- [53] Chen Y., Liu Z., Zhang Y., Zheng X., Xie J., "Degradation-trend-dependent Remaining Useful Life Prediction for Bearing with BiLSTM and Attention Mechanism", *2021 IEEE 10th Data Driven Control Learn. Syst. Conf.*, 1177–1182, (2021).
- [54] Laha S.K., "Enhancement of fault diagnosis of rolling element bearing using maximum kurtosis fast nonlocal means denoising", *Measurement*, 100: 157–163, (2017).
- [55] Al-Raheem K.F., Abdul-Karem W., "Rolling bearing fault diagnostics using artificial neural networks based on Laplace wavelet analysis", *Int. J. Eng. Sci. Technol.*, 2: 278–290, (2011).
- [56] Moshrefzadeh A., "Condition monitoring and intelligent diagnosis of rolling element bearings under constant/variable load and speed conditions", *Mech. Syst. Signal Process.*, 149: 107153, (2021).
- [57] Qiu H., Niu Y., Shang J., Gao L., Xu D., "A piecewise method for bearing remaining useful life estimation using temporal convolutional networks", *J. Manuf. Syst.*, 68: 227–241, (2023).
- [58] Ding W., Li J., Mao W., Meng Z., Shen Z., "Rolling bearing remaining useful life prediction based on dilated causal convolutional DenseNet and an exponential model", *Reliab. Eng. Syst. Saf.*, 232: 109072, (2023).
- [59] Wikipedia, "Temel bileşen analizi", https://tr.wikipedia.org/wiki/Temel_bileşen_analizi, (2023).
- [60] Shilaskar S., Saitwal P., Raundal P., Rathi M., "LSTM Sequence to Sequence Model for Dynamic Title Generation", *2024 Int. Conf. Inven. Comput. Technol.*, 2083–2087, (2024).
- [61] Zhang X., "Research on Text Classification Method Based on LSTM Neural Network Model", *2021 IEEE Asia-Pacific Conf. Image Process. Electron. Comput.*, 1019–1022, (2021).
- [62] Rajyagor B., Rakholia R., "Isolated Gujarati Handwritten Character Recognition (HCR) using Deep Learning (LSTM)", *2021 Fourth Int. Conf. Electr. Comput. Commun. Technol.*, 1–6, (2021).
- [63] Adeel A., Gogate M., Hussain A., Whitmer W.M., "Lip-Reading Driven Deep Learning Approach for Speech Enhancement", *IEEE Trans. Emerg. Top. Comput. Intell.*, 5: 481–490, (2021).
- [64] Balcı S., Akkaya M., "Regression Model Extractions of a T-Equivalent Circuit Modelling for Medium-Length Transmission Line Based-on the Parametric Simulation Approach", *J. Polytech.*, 0900: (2024).
- [65] Karaca H., Tekerek A., "Enhancing Cybersecurity against Ransomware Attacks Using LSTM Deep Learning Method: A Case Study on Android Devices", *J. Polytech.*, 0900: 1–1, (2024).
- [66] Cai W., Zhang W., Hu X., Liu Y., "A hybrid information model based on long short-term memory network for tool condition monitoring", *J. Intell. Manuf.*, 31: 1497–1510, (2020).
- [67] Zhou H., Cheng L., Teng L., Sun H., "Bearing Fault Diagnosis Based on RF-PCA-LSTM Model", *2021 2nd Inf. Commun. Technol. Conf.*, 278–282, (2021).
- [68] Li W., Wang L., Lu P., Hua L., "Bearing Fault Diagnosis Research Based on Empirical Mode Decomposition and Deep Learning", *2020 35th Youth Acad. Annu. Conf. Chinese Assoc. Autom.*, 32–37, (2020).
- [69] Kumar S., Ganga D., "Classification of Rolling Bearing Fault Based on Long Short Term Memory Neural Network", *2023 2nd Int. Conf. Innov. Technol.*, 1–5, (2023).
- [70] Chen Q., Ma X., Yan B., Yanyan W., Huang G., "Remaining useful life prediction of bearings with two-stage LSTM", *2022 5th Int. Symp. Auton. Syst.*, 1–6, (2022).
- [71] Yang Y., Yang X., Sun Y., Zhang G., "Residual Life Prediction of Rolling Bearing Based on LSTM Neural Networks", *2024 IEEE 4th Int. Conf. Electron. Technol. Commun. Inf.*, 288–295, (2024).
- [72] Sokolova M., Lapalme G., "A systematic analysis of performance measures for classification tasks", *Inf. Process. Manag.*, 45: 427–437, (2009).