



Makine Öğrenmesi Metodolojisi Kullanılarak Yüksek Hızlı Rulmanlarda Sağlık Göstergesinin Belirlenmesi

Erkan Caner Özkat^{1*}

^{1*} Recep Tayyip Erdoğan Üniversitesi, Mühendislik Mimarlık Fakültesi, Makine Mühendisliği Bölümü, Rize, Türkiye, (ORCID: 0000-0003-0530-5439), erkancaner.ozkat@erdogan.edu.tr

(İlk Geliş Tarihi Aralık 2020 ve Kabul Tarihi Ocak 2021)

(DOI: 10.31590/ejosat.843465)

ATIF/REFERENCE: Ozkat, E. C. (2021). Makine Öğrenmesi Metodolojisi Kullanılarak Yüksek Hızlı Rulmanlarda Sağlık Göstergesinin Belirlenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (22), 176-183.

Öz

Makine sağlığı göstergesi, bir makine parçasının bozulma aşamalarını ve ortaya çıkacak nihai arızasını gösterir. Bu çalışmanın temel amacı, makine öğrenmesi metodolojisi kullanarak titreşim verilerinden makine sağlığı göstergesini belirlemektir. Tespit edilen bu sağlık göstergesi daha sonra kalan faydalı ömür tahmininde kullanılacaktır. Makine sağlık göstergesini hesaplamak için gerekli adımlar, özellik çıkarma, normalleştirme ve temel bileşen analizi olarak listelenmiştir. Bu çalışmada titreşim sinyalleri zaman alanından frekans alanına Welch yöntemi kullanılarak dönüştürülmüş ve ardından sıralanan öznelikler basıklık, çarpıklık, etkin değer, tepe faktörü ve etki faktörü hesaplanmıştır. Özneliklerin gürültüsü z-skor ve Savitzky-Golay yöntemleri kullanılarak azaltılmıştır. Sonrasında, temel bileşen vektörlerini hesaplamak için düzeltilmiş özneliklere temel bileşen analizi uygulanmıştır. Bu vektörlerden monoton eksponansiyel artış eğilimine en iyi uyum vektörleri kullanışlı temel bileşen vektörlerdir. Sağlık göstergesi, faydalı temel bileşen vektörlerinin ortalama değeridir ve kalan faydalı ömrü tahmin etmek için kullanılmıştır. Tahminin başarısı determinasyon katsayısı (R^2) ve kök ortalama kare hata (RMSE) değerleri ile belirlenmiştir. Sonuçlara göre, R^2 ve RMSE değerleri: prior eğitim seti için sırayla 0.6625 ve 17.8925; posterior eğitim seti için sırayla 0.9947 ve 1.7688; test seti için sırayla 0.9897 ve 2.2025'tir.

Anahtar Kelimeler: Kestirimci Bakım, Makine Öğrenmesi, Sağlık Göstergesi, Temel Bileşen Analizi, Mekanik Titreşimler.

Determination of Health Indicator in High Speed Bearings Using Machine Learning Methodology

Abstract

The machine health indicator shows the deterioration stages of a machine part and its failure. The main purpose of this study is to determine the machine health indicator from vibration data using machine learning. The determined health indicator will then be used in the remaining useful life estimation. The necessary steps to calculate the indicator are listed as feature extraction, normalization, and principal component analysis. In this study, vibration signals are transformed from time domain to frequency domain using the Welch method then the listed features kurtosis, skewness, effective value, crest factor and impact factor are calculated. The noise of these features has been reduced utilizing z-score and Savitzky-Golay methods. Subsequently, principal component analysis is applied to compute principal component vectors. Of these vectors, vectors that best match the monotone exponential upward trend are chosen as useful principal component vectors. The health indicator is the mean value of the useful principal component vectors and it has been used to estimate the remaining useful life. The success of the prediction is determined by the determination coefficient (R^2) and root mean square error (RMSE) values. According to the results, R^2 and RMSE values are: 0.6625 and 17.8925 for the prior training set, respectively; 0.9947 and 1.7688 for posterior training set, respectively; for the test set it is 0.9897 and 2.2025, respectively.

Keywords: Predictive Maintenance, Machine Learning, Health Indicator, Principal Component Analysis, Mechanical Vibrations.

* Sorumlu Yazar: erkancaner.ozkat@erdogan.edu.tr

1. Giriş

Kestirimci bakım, bir makinenin sağlık durumunu tahmin etme ve sensörler yardımıyla toplanan verileri/ölçümleri makine öğrenimi yöntemleriyle entegre ederek bakım eylemleri hakkında en iyi kararı verme süreci olarak tanımlanır. Ayrıca, kestirimci bakım ile arızayı başlangıç aşamasında tespit edildiğinden, zincir hasarları ve yıkıcı arızalar olasılığını azaltılır ve bakım planlamasında ve hangi parçaların düzeltilmesi gerektiğinin belirlenmesine yardımcı olur. Buna ek olarak, ekipmanın gelecekteki koşulu veya kalan faydalı ömrü için bir tahmin de verebilir.

Son yıllarda teknolojinin gelişmesine bağlı olarak, birçok kestirimci bakım çalışmasında sıcaklık, basınç, yağ kalitesi, gürültü ve titreşim sensör verileri kullanılmaktadır. Hangi sensör verisinin kullanılacağına ilişkin karar hem incelenecek sorunun türüne hem de makinenin çalışma koşullarına bağlıdır. Dönen ekipmanların çeşitli nedenlerle yük altında olması ve zorlanması, makinelerde güç tüketimini etkileyen ana faktörlerden biridir. Titreşim analizi, endüstride her tür dönen ekipman için kullanılan en yaygın durum izleme teknolojisidir ve rulman arızalarını teşhis etmek için etkili bir araçtır. Çünkü titreşim makinenin çalışmasını engelleyecek ve hatta rezonans ile makinenin tahrip olmasına yol açacaktır.

Rulman arızalarını etkili bir şekilde tespit etmek ve titreşim davranışlarının tam olarak anlaşılması için gelişmiş titreşim tabanlı algoritmalar geliştirmek gerekir. Literatürde makinelerde rulman arızasına yol açabilecek kusurları önceden tespit edip giderebilmeye yönelik çeşitli yöntemler anlatılmıştır. Bu titreşim analizi yöntemleri, zaman tabanlı, frekans tabanlı ve zaman-frekansa tabanlı yaklaşımlar olarak sınıflandırılabilir.

Tao vd. (2020) tarafından yürütülen bir çalışmada; dönen makinalarda yataklarda yuvarlanan elemanların durumunu belirlemek için Fourier ve Ayrık Dalgacık dönüşümü kullanılmış, önceden işlenen sinyaller birkaç seviyeye ayrılarak hatalı ve sağlıklı rulmanlar arasında bir sınıflandırma gerçekleştirmiştir. Sun vd. (2013) ayrık dalgacık dönüşümü ve zarf analizi yöntemlerini birleştirerek rulmanlı yatak titreşim verilerinden bir spektrum çıkarmayı hedeflemiştir. Rulmanlardaki farklı arızaları teşhis etmek için kullanılan yöntemin yüksek performans ve doğruluk gösterdiği tespit etmiştir. Oldukça güçlü bir analiz yöntemi olan zarf analizi; yüksek frekanslı rezonans tekniği (HFRT) olarak da adlandırılır ve klasik spektrumda belirlenen rezonansları sınıflandırmak için kullanılır (Saidi vd., 2017). Ancak özellikle ana rezonansların sınıflandırılması zor bir işlemdir ve klasik spektrumda belirlenen tüm rezonansları analiz etmemiz gerektiğinden hesaplama süreleri uzayacaktır. Basıklık bu işlemi daha kolay bir hale getiren; sinyaldeki geçici akımların yerini belirlememizi sağlayan skaler bir ölçümdür. Spektral Kurtosis (SK) ise bundan yola çıkarak geliştirilen ve optimum bant frekansını belirlememizi sağlayan bir yöntemdir (Saidi vd., 2017). Villwock vd. (2008) ise elektrikli arabalardan elde edilen sinyallerin frekans cevabının hesaplanmasında Welch yöntemini kullanmış ve deneysel sonuçlar yöntemin etkinliğini ve esnekliğini ortaya koymuştur. Bektaş (2020) ise havacılık alanında verilerin değerlendirilmesinde Welch metodu vasıtasıyla oluşturulan alt veri setlerinde titreşime dayalı olarak hesaplamayı ve fourier dönüşüm sonuçlarıyla gözlem yapabilmeyi hedeflemiştir. Öznitelik çıkarımı; ölçülmüş verilerden elde edilen bir başlangıç veri seti girdi olarak

kullanılarak bazı türetilmiş değerler (“öznitelikler”) oluşturulmasıdır. Basıklık faktörü, çarpıklık, ortalama değer, standart sapma, tepe faktörü, şekil faktörü, etki faktörü, marjinal faktörü ve tepe noktasından zirve noktasına (pikten pike) literatürde sıklıkla kullanılan özniteliklerdir (Ali vd., 2018; Muratet vd., 2014; Villwock vd., 2008). Bu özniteliklerin çıkarımı için farklı yöntemlerden faydalanılmıştır. Liu vd. (2014), yerel ortalama dekompozisyon teknolojisini kullanarak; bir makaralı yatağın durağan olmayan titreşim sinyalinin bir dizi ürün fonksiyonuna ayrıştırılmayı ve her ürünün büyük ölçekte entropisine ait fonksiyonun öznitelik vektörü olarak hesaplanmasını sağlayan bir hata özniteligi çıkarma yöntemi önermiştir. Yöntemin etkinliği ise pratik yatak titreşim sinyallerinden elde edilen analiz sonuçları ile kanıtlanmıştır. Guo vd. (2014) ise, rulmanlı yatak üzerinde öznitelik çıkarımı için bir zarf çıkarma ve bağımsız bileşen analizi (ICA) yöntemlerinin kombinasyonunu kullanmıştır. Ali vd. (2018), rüzgâr türbinlerinde yüksek hızlı şaft rulmanlarında yürüttükleri çalışmada öznitelik çıkarımı için geleneksel istatistiksel özniteliklerden faydalanmıştır.


Kestirimci bakımının amacı makinenin kalan faydalı ömrünü (KFÖ) (“*remaining useful life*”) tahmin etmektir. KFÖ hatanın erken tespitinin sağlanması, bakım planlarının düzenlenmesi bu sayede işletim maliyetlerinden tasarruf edilmesi açısından oldukça önemlidir (Elasha vd., 2019; Teng vd., 2017; Tibaduiza vd., 2011). Genel olarak, KFÖ’ü tahmin etmek için üç model vardır: (i) hayatta kalma modeli; yalnızca arıza zamanına ait veriler bilindiğinde, (ii) bozulma modeli; arıza verileri mevcut olmadığında, ancak arızayı gösteren bir güvenilir eşik bilindiğinde ve (iii) benzer modeli: makinelerin tam geçmişi yani sağlıklı durumundan arızaya kadar olan tüm veriler bilindiğinde (Ozkat, 2019).

Bu çalışmanın ana amacı, kestirimci bakım bozulma modelinde kullanılmak üzere makine öğrenmesi metodolojisi kullanılarak sağlık göstergesinin tespitidir. Bu çalışma dört bölüme ayrılmıştır. İkinci bölüm, kullanılan materyal ve metotla ilgili çalışmalar incelenecektir. Takip eden bölüm ise veri setine metodun uygulanmasını ve elde edilen sonuçların analizini içermektedir. Son kısım ise önerilen çalışmanın kısıtları ve potansiyel kullanım önerilerini içermektedir.

2. Materyal ve Metot

2.1. Deneysel Düzen ve Veri Seti

Bu çalışmada kullanılan titreşim sinyalleri, 2MW rüzgâr türbini jeneratörüne takılan yüksek hızda çalışmak için tasarlanmış şaft yatağındaki rulmandan elde edilmiştir. Bu titreşim deneyi, Green Power ABD tarafından gerçekleştirilmiş ve deney sonuçları açık kaynak olacak şekilde araştırmacılara sunulmuştur (Ali vd., 2017; Saidi vd., 2017). Bu deneyde, iç çapı 200 mm, bore çapı 100 mm, toplam uzunluğu 56 mm ve 16° açığa sahip olan 32222-J2-SKF konik rulman kullanılmıştır. Deney koşulları sayesinde 50 gün boyunca her gün 6 saniyelik bir titreşim sinyali toplanmıştır. Titreşim verileri 32 kHz bant genişliğine ve 22 kHz’de rezonansa sahip bir MEMS ivmeölçer ile ölçülmüştür. Sensör, dişli kutusu yatak desteğinin üzerine yüksek hız miline radyal olarak monte edilmiş ve şafta dik olarak titreşimi sinyalleri almıştır. Şekil 1’de Green Power ABD tarafından gerçekleştirilen deney düzeni ve rulman iç yuvasında meydana gelen arıza gösterilmiştir.



Şekil 1. Deney düzeneği **a)** Yüksek hızda dönen rulman, **b)** Rulman iç yuvasında meydana gelen arıza (Ali vd., 2017; Saidi vd., 2017).

2.2. Metot

Bu çalışmanın temel amacı meydana gelen bozulmayı makine öğrenmesi metodolojisi kullanarak sağlık göstergesinde karakterize edilme bilmektir. Tespit edilen bu sağlık göstergesi daha sonra kalan faydalı ömür tahmininde kullanılacaktır. Sağlık göstergesi hesaplamak için gerekli işlem adımları (i) öznelilik çıkarma, (ii) normalizasyon, (iii) temel bileşenlerin tespiti ve (iv) sağlık göstergesinin elde edilmesi şeklinde sıralanmaktadır.

2.2.1. Öznelilik çıkarma

Ham titreşim sinyallerden faydalı bilgilerin çıkarılması prosedürü, özellik çıkarmadır. Rulmanlar genellikle zorlu çevre koşulları altında çalışır ve bu nedenle birkaç tür hataya maruz kalırlar. Mekanik titreşimlerin analizinde ivmeölçerler tarafından zaman alanında toplanan titreşim sinyali, hataya duyarlı özellikleri ayıklamak ve yararlı bilgileri elde etmek için frekans alanı başta olmak üzere farklı alanlara dönüştürülür. Bu çalışmada, Welch yöntemi kullanılarak titreşim sinyalleri zaman alanından frekans alanına dönüştürülmüştür.

Welch yöntemi (Akçay & Türkay, 2019; Jin vd., 2019), hızlı Fourier dönüşümü temelli bir yöntem olup güç spektral yoğunluğunu elde etmek için kullanılır. Welch yöntemine göre, zaman alanındaki titreşim sinyali belirli bölümlere (*pencerelere*) ayrılır. Daha sonra her bölümün iyileştirilmiş periyodogramı alınıp, elde edilen bu bölümlere ait periyodogramların ortalaması alınarak güç spektral yoğunluğu bulunur. İyileştirilmiş periyodogramların ortalaması tüm verinin tek bir periyodogram kestirimine göre varyansını azaltır. Fakat, bölümlerin uzunluğunun önceden kestirilmesi zordur, bölümün uzunluğu artıca güç spektral yoğunluğu daha düz bir hale ("*smooth*") gelmektedir.

İstatistiksel öznelilikler, arıza meydana geldiğinde makine titreşim sinyallerinin değişimini karakterize eden güçlü bir araçtır (Liu & Zhang, 2020). Bununla beraber, istatistiksel özneliliklerin çıkarmanın basitliği, düşük hesaplama süresi ve hem frekans alanında hem de zaman alanında doğrudan kullanılabilir (Elasha vd., 2019; Teng vd., 2017). Bu çalışmada kullanılan zaman alanı sinyallerinden ve güç spektrumundan türetilen istatistiksel özneliliklerle ilgili daha fazla matematiksel ayrıntı Tablo 1'de verilmiştir (Teng vd., 2017). Burada zaman veya frekans alanında örneklenen titreşim sinyalini $x(k)$, örnek indeksi k , toplam örnek sayısı N_k , örneklenmiş sinyalin ortalamasını x_m ve standart sapmasını x_{std} ile gösterilmiştir.

Tablo 1. Çalışmada kullanılan istatistiksel öznelilikler

İstatistiksel Öznelilik	Denklem
Basıklık	$x_{kurtosis} = \frac{\sum_{k=1}^{N_k} (x(k) - x_m)^4}{(N_k - 1)x_{std}^4}$ (1)
Çarpıklık	$x_{skewness} = \frac{\sum_{k=1}^{N_k} (x(k) - x_m)^3}{(N_k - 1)x_{std}^3}$ (2)
Etkin Değer	$x_{rms} = \sqrt{\frac{1}{N_k} \sum_{k=1}^{N_k} (x(k))^2}$ (3)
Tepe Faktörü	$CF = \frac{\max(x(k))}{x_{rms}}$ (4)
Etki Faktörü	$IF = \frac{\max(x(k))}{(1/N_k \sum_{k=1}^{N_k} x(k))}$ (5)

2.2.2. Normalizasyon

Her bir zaman adımı için elde edilen öznelilikler farklı ölçeklerdedir. Bozulma davranışının doğruluğunu en üst düzeye çıkarmak için uygun ortak bir ölçeğe göre tüm özneliliklerin normalizasyonu gerekmektedir. Bu alanda yaygın olarak kullanılan z-skoru normalizasyon uygulanmış ve Denk (6) gösterilmiştir (Kappal, 2019). Burada $z(k)$, $x(k)$ sinyalinin z-skoru yöntemine göre dönüştürülmüş halidir.

$$z(k) = \frac{x(k) - x_m}{x_{std}} \quad (6)$$

Tablo 1'de verilen öznelilik, arıza teşhisinde kullanılacak önemli bilgileri ifade eder. Ancak genellikle hataya karşı hassasiyeti artıracak gürültü içerir. Böylelikle, kalan faydalı ömür tahmininde hatalara neden olabilir. Bu nedenle, literatürde sıklıkla karşılaşılan hareketli ortalama (Banerjee vd., 2020), hareketli medyan (Kollmann vd., 2020) ve Savitzky-Golay (Abdelli vd., 2020) yöntemleri kullanılarak özneliliklere düzeltme işlemi uygulanır. Sinyal eğilimini bozmadan verilerin hassasiyetini artırmak amacıyla Savitzky-Golay yöntemi bu çalışmada esas alınmıştır. Savitzky-Golay yöntemi ile sinyal üzerine belirli genişlikte bir pencere oluşturulur ve bu pencere içerisinde bir polinomyal regreasyon yapılır. Bunu sonucunda sinyal içerisindeki gürültü uniform olarak temizlenir (Abdelli vd., 2020).

2.2.3. Temel bileşenlerin tespiti

Bir makinenin ve makine parçasının kalan faydalı ömrü mevcut sağlık durumundan arızaya kadar olan süre olarak tanımlanır. Uygulamada, makinenin tüm yaşam döngüsünün (*başlangıçtan arızaya kadar*) verileri mevcut değildir, ancak yaşam döngüsünün erken aşamasında bazı verilerin toplandığını varsaymak mantıklıdır. Buna ilave olarak makine öğrenmesindeki temel yaklaşım deneysel olarak el edilen veri setini, eğitim seti ve test seti diye ikiye bölünmesidir. Çünkü tüm veri setine yüksek uyumluluk göstermiş modeller yani veri setini gereğinden fazla iyi öğrenmiş (*ezberlemiş*) modeller, yeni bir örnek ile karşılaştığında yüksek hata yapmaya başlarlar. Bu nedenle, 50 gün boyunca toplanan titreşim sinyallerinin ve Tablo 1'de bulunan özneliliklerin %60'ı eğitim verileri olarak kabul edilmiştir. İlk önce, z-skoru ile normalleştirilmiş daha sonra da Savitzky-Golay yöntemiyle düzeltilmiş tüm öznelilikleri (z) Denk.7'deki gibi bir küme altında toplayalım.

$$\mathbf{z} = \{z_{i,j}\} \quad i = 1, \dots, N_i \quad j = 1, \dots, N_j \quad (7)$$

Burada, i ölçümün yapıldığı günü, N_i ölçümün yapıldığı toplam gün sayısını, j öznelilik indeksini ve N_j toplam öznelilik sayısını ifade etmektedir. Bu çalışmada toplam gün sayısı 50 ve toplam öznelilik sayısı 4 zaman alanında ve 4 frekans alanında olmak üzere 8'dir. İkinci adım olarak herbir öznelilikler için Denk 8, 9 ve 10 yardımıyla eğitim veri setinde kullanmak üzere ortalama değer ve standart sapma bulunmuştur. Burada, N_i^* toplam gün sayısının %60'ı kadarıdır.

$$\mathbf{z}_{\text{Train}} = \{z_{i^*,j}\} \quad i^* = 1, \dots, N_i^* \quad j = 1, \dots, N_j \quad (8)$$

$$\mu_{z_{\text{Train},j}} = \frac{1}{N_i^*} \sum_{i^*=1}^{N_i^*} z_{i^*,j} \quad (9)$$

$$\sigma_{z_{\text{Train},j}} = \sqrt{\frac{\sum_{i^*=1}^{N_i^*} (z_{i^*,j} - \mu_{z_{\text{Train},j}})^2}{N_i^*}} \quad (10)$$

Kestirimci bakım, sinyal işleme, biyoinformatik gibi alanlarda boyut indirgenmesi için sıkça kullanılan yöntemlerden biri temel bileşen analizi (TBA)'dır (Yıldız vd., 2010). TBA'nın amacı, değişkenler arasındaki ilişkiyi tanımlamak ve tespit etmektir. Güçlü bir korelasyon varsa boyutluluğu azaltabilirsiniz. TBA yöntemi ile yüksek boyutlu orijinal veriseti maksimum varyans yönüne dönüştürülerek ifade edilebilir. Böylece yüksek boyutlu orijinal veriseti, daha küçük boyutlu bir alt uzaya yansıtılır. Ek olarak, TBA'nın bir zayıflığı ise verilerdeki aykırı değerlerden oldukça etkilenir.

Bu çalışmada, temel bileşen katsayıları (TBK), ortalama ve standart sapma eğitim verilerinden elde edilmekte ve tüm veri setine uygulanarak temel bileşen vektörü (TBV) hesaplanmaktadır. Temel bileşen katsayıları (TBK) ve vektörlerini (TBV) hesaplamak için kullanılan matematiksel ifadeler kapalı olarak sırasıyla Denk. 11 ve Denk. 12'de verilmiştir.

$$TBK_j = f_{TBA}(z_{i^*,j}) \quad j = 1, \dots, N_j \quad (11)$$

$$TBV_{i,j} = \frac{z_{i,j} - \mu_{z_{\text{Train},j}}}{\sigma_{z_{\text{Train},j}}} TBK_j \quad \begin{matrix} i = 1, \dots, N_i \\ j = 1, \dots, N_j \end{matrix} \quad (12)$$

2.2.4. Makine sağlık göstergesi

Bu bölümde, kullanışlı temel bileşen vektörlerini tek bir sağlık göstergesinde birleştirilmesine odaklanılmıştır. Makine sağlık göstergesi ("health indicator"), bir makine parçasının veya sistemin, sağlıklı durumdan bozulma durumuna geçişi ve sonunda başarısızlıkla sonuçlanan aşamalarını gösterir. Ancak, eğitim aşamasından miras kalan bazı gürültüleri içerir (Orhan vd., 2003; Kızrak vd., 2019). Bu nedenle, yöntemdeki önemli bir adım, kullanışlı temel bileşen vektörleri ile sağlık göstergelerini tahmin etmektir. Bazı temel bileşen vektörleri, sağlıklı bir durumdan başarısızlığa doğru tekdüze bir artış eğilimi göstermez (bkz. Şekil 5). Genellikle bir makine parçasının veya sistemin bozulması eksponansiyel bir artış göstermektedir. Bu nedenle, kullanışlı temel bileşen vektörlerini belirlemek için Denk. 13 yardımıyla tüm öznelilikler (j) için eğim hesaplanır. Bu eğim

eksponansiyel artışı ifade etmete kullanılır. Eğimler hesaplandıktan sonra, en büyük eğimli vektörler kullanışlı temel bileşen vektörler olarak seçilirler. Sağlık göstergesi, her seferinde her bir kullanışlı temel bileşen vektörlerin ortalama değeri alınarak oluşturulur.

$$eğim_j = \frac{1}{N_i} \sum_{i=1}^{N_i} \left| \frac{TBV_{i,j} - TBV_{N_i,j}}{1 - N_i} \right| \quad j = 1, \dots, N_j \quad (13)$$

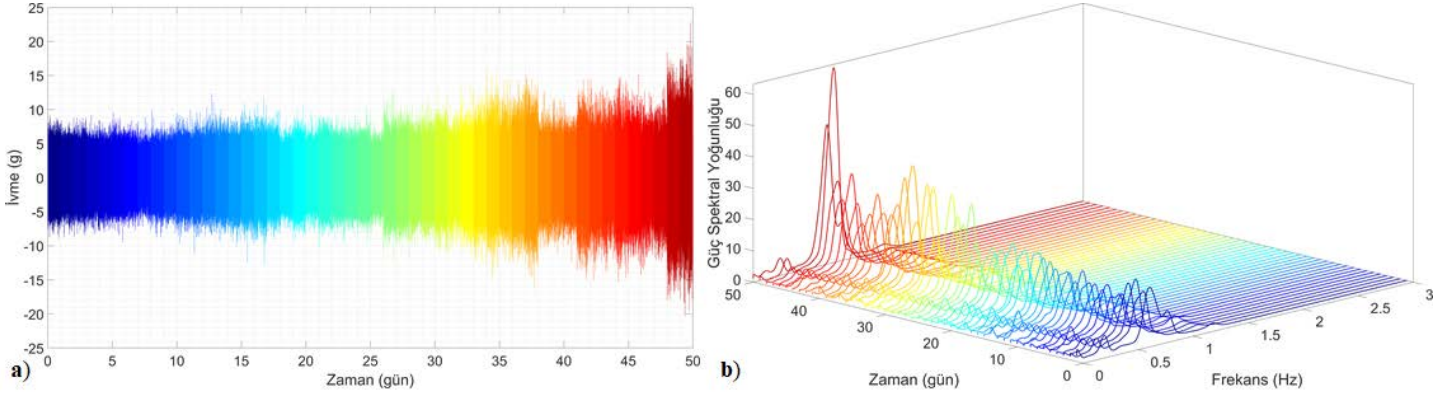
3. Araştırma Sonuçları ve Tartışma

Bu çalışmada makine öğrenimi metodolojisi kullanılarak yüksek hızlı rulmanlarda sağlık göstergesinin belirlenmesi amaçlanmıştır. Green Power ABD tarafından gerçekleştirilen ve açık kaynak olacak şekilde araştırmacılara sunulan deneysel titreşim sinyali kullanılmıştır. Bu deney koşullarına göre, her gün örnekleme hızı 97656 Hz olacak şekilde birbirlerini izleyen 50 gün boyunca yüksek hızda dönen milin shaft yatağındaki rulmandan titreşim sinyali ivme ölçer yardımıyla toplanmıştır (Bkz. Şekil 1). Kaydedilen işlenmemiş titreşim sinyali her bir renk farklı günü temsil edecek biçimde Şekil 2a'da gösterilmiştir. Şekil 2a'da görüleceği üzere titreşim sinyali sırasıyla üç gruba ayrılabilir: (i) sağlıklı çalışma aşaması (0-26 günler arası), (ii) arızalı çalışma aşaması (26-38 günler arası) ve (iii) arıza bozulma aşaması (38-50 günler arası).

Zaman alanındaki titreşim sinyalleri, artan bir sinyal eğilimini ortaya koymaktadır. Öte yandan, Welch yöntemi, frekans alanında güç spektral yoğunluğu tahmini için güçlü bir araç olarak kabul edilir. Welch yönteminde kullanılan parametreler sırasıyla; (i) uzunluğu 128 olan dikdörtgensel pencere ("window size"), (ii) 4 pencerenin çakışması ("number of overlap") ve (iii) titreşim sinyalinin örnekleme hızı 97656 Hz ("sampling frequency")'dir. Şekil 2b'de herbir gün için hesaplanan güç spektral yoğunluğu verilmiştir. Her bir gün için maksimum güç spektral yoğunluğu 0.67 Hz'de bulunmuş ve maksimum güç spektral yoğunluğu (63.318 W/Hz) 49'uncu günde elde edilmiştir.

Titreşim sinyali ivmeölçerler tarafından ölçüldükten sonra, hataya duyarlı özellikleri ayıklamak üzere titreşim sinyallerinden Tablo 1'de tanımlanan istatistiksel öznelilikleri çıkarılmış ve Şekil 3'te gösterilmiştir. Elde edilen istatistiksel öznelilikler incelendiğinde genel olarak bir artış gözükmektedir. Bu artan eğilimi iyi gözlemleyebilmek ve özellikleri birbiriyle daha iyi karşılaştırabilmek için z-skor yöntemine göre normalizasyon işlemi yapılmış ve normalize edilmiş öznelilikler Şekil 4'te gösterilmiştir.

Basıklık bir sinyalin tepe noktasının, yani pikin normal dağılımın tepe noktasından daha yüksek veya daha düşük olup olmadığını ölçer. Benzer bir şekilde, çarpıklık, sinyalinin normal durumunun dağılımının soluna veya sağına eğik olup olmadığını ölçer. Şekil 4 incelendiğinde, zaman alanında çarpıklık gün geçtikçe artarken, basıklık arıza meydana gelene kadar sabit bir değer (0 genlik değerleri) etrafında dalgalanmaktadır (Bkz. Şekil 4). Böylece erken dönemde sağlık göstergesinin tahmini zorlaştıracaktır. Deney sonuçlarından elde edilen zaman alandaki titreşim daha önce üç gruba ayrılmıştı ve frekans alanındaki basıklığa ve çarpıklığa bakıldığında sağlıklı çalışma alanından arızalı çalışma alanına geçiş (26. gün) net bir şekilde belirlenmektedir.



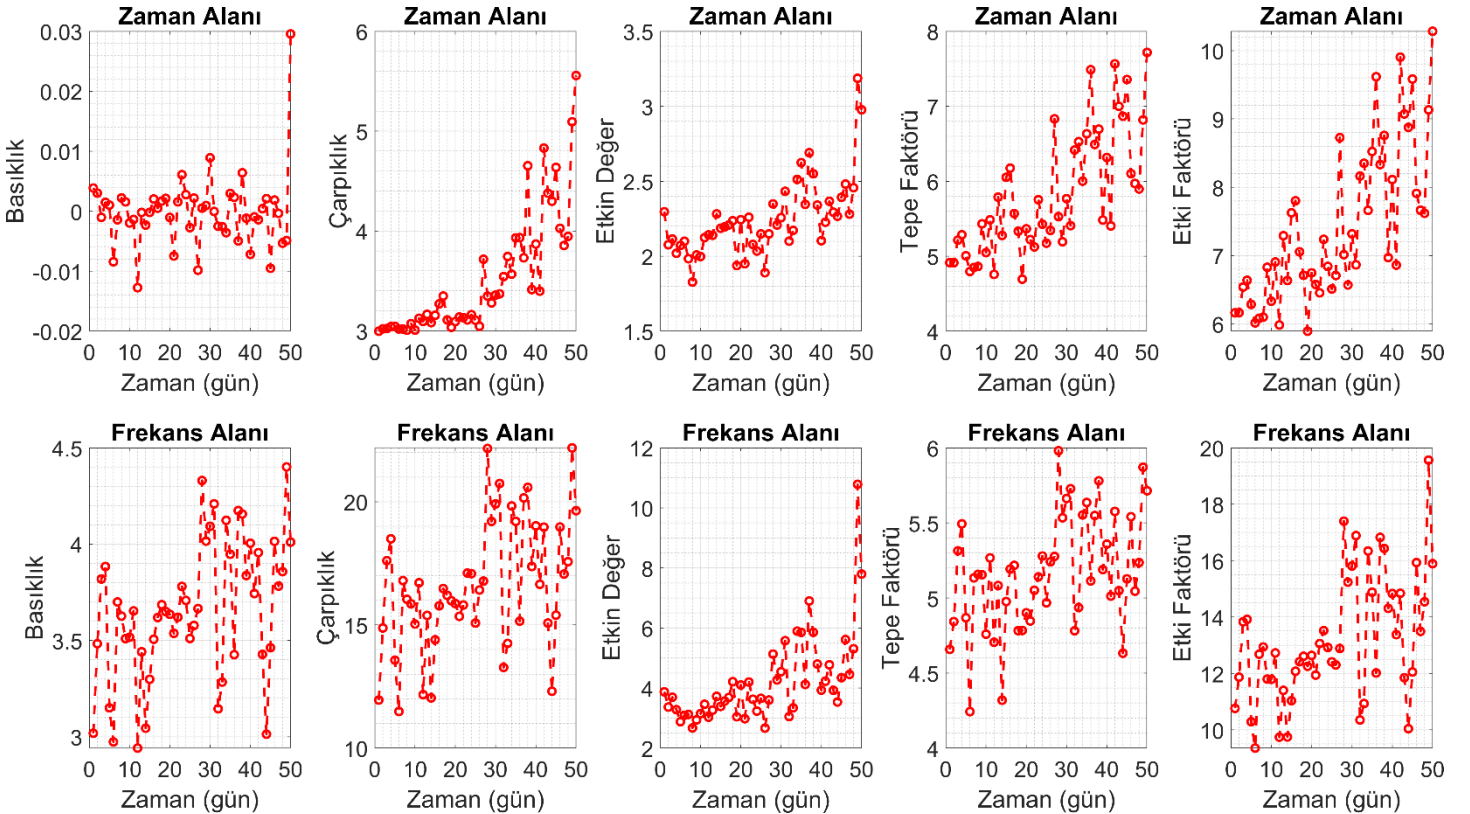
Şekil 2. a) İşlenmemiş titreşim sinyali (zaman alanı), b) güç spektral yoğunluğu (frekans alanı)

Buna ek olarak, etkin değer, bir sinyalin güç içeriğini gösterir ve hem zaman alanında hem de frekans alanında sinyalin gücü artmaktadır. Ayrıca, tepe faktörü, genellikle bir hata durumunun erken aşamalarını tespit etmede yararlıdır. Etki faktörü, titreşim sinyalinde üretilen bir hatanın etkisinin ölçülmesinde faydalıdır. Tepe ve etki faktörleri hem zaman alanında hem de frekans alanında paralellik göstermekte arıza durumuna yaklaştıkça artmaktadır. Buna ek olarak, arızanın gerçekleştiği günde (49'uncu günde) etkin değer hem zaman hem de frekans alanında en yüksek değere (11 genlik değerine) ulaşmıştır. Fakat, arıza bozulma aşamasında (42'nci günde) tüm özneliklerde ani bir düşüş görülmüştür. Bunun nedeni, rejimler arası geçişte genliğinin azalmasıdır (Bkz. Şekil 2a).

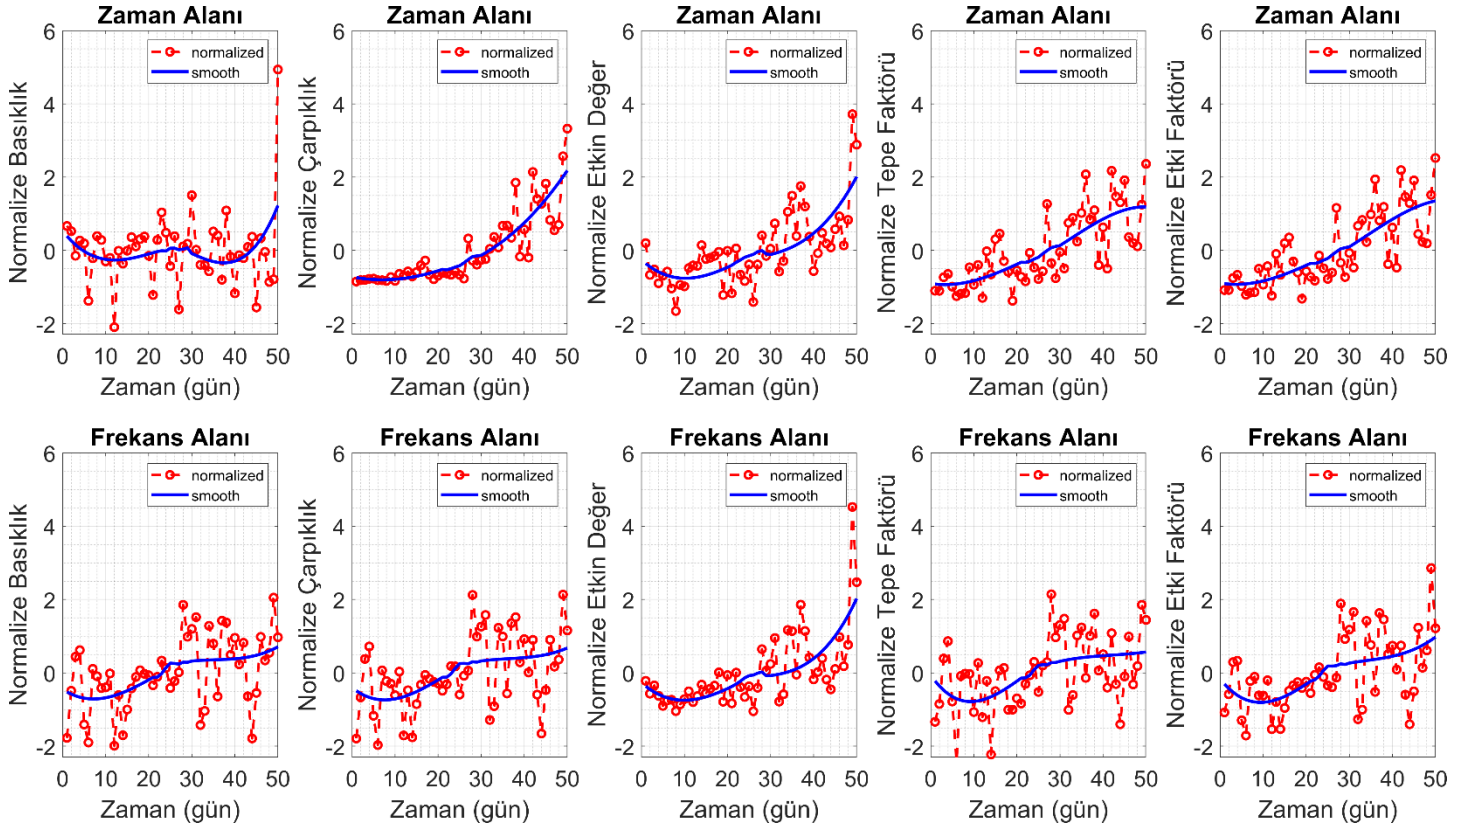
Savitzky-Golay yöntemi ile eğitim ve ölçüm aşamasından miras kalan tüm özneliklerdeki gürültüler giderilmiş ve düzeltilmiş ("smooth") öznelikler Şekil 4'te gösterilmiştir. Düzeltilmiş öznelikler esas alınarak TBA yöntemi ile TBV hesaplanmıştır. Her bir TBV, her bir özneliğe karşılık

gelmemekte, aksine Savitzky-Golay yöntemiyle düzeltilmiş tüm öznelikler TBV üzerine projeksiyon yaparak ifade edilmektedir. Denk. 11 ve Denk. 12'e göre hesaplanan TBV'ların 50 gün boyunca gelişimi Şekil 5'te verilmiştir.

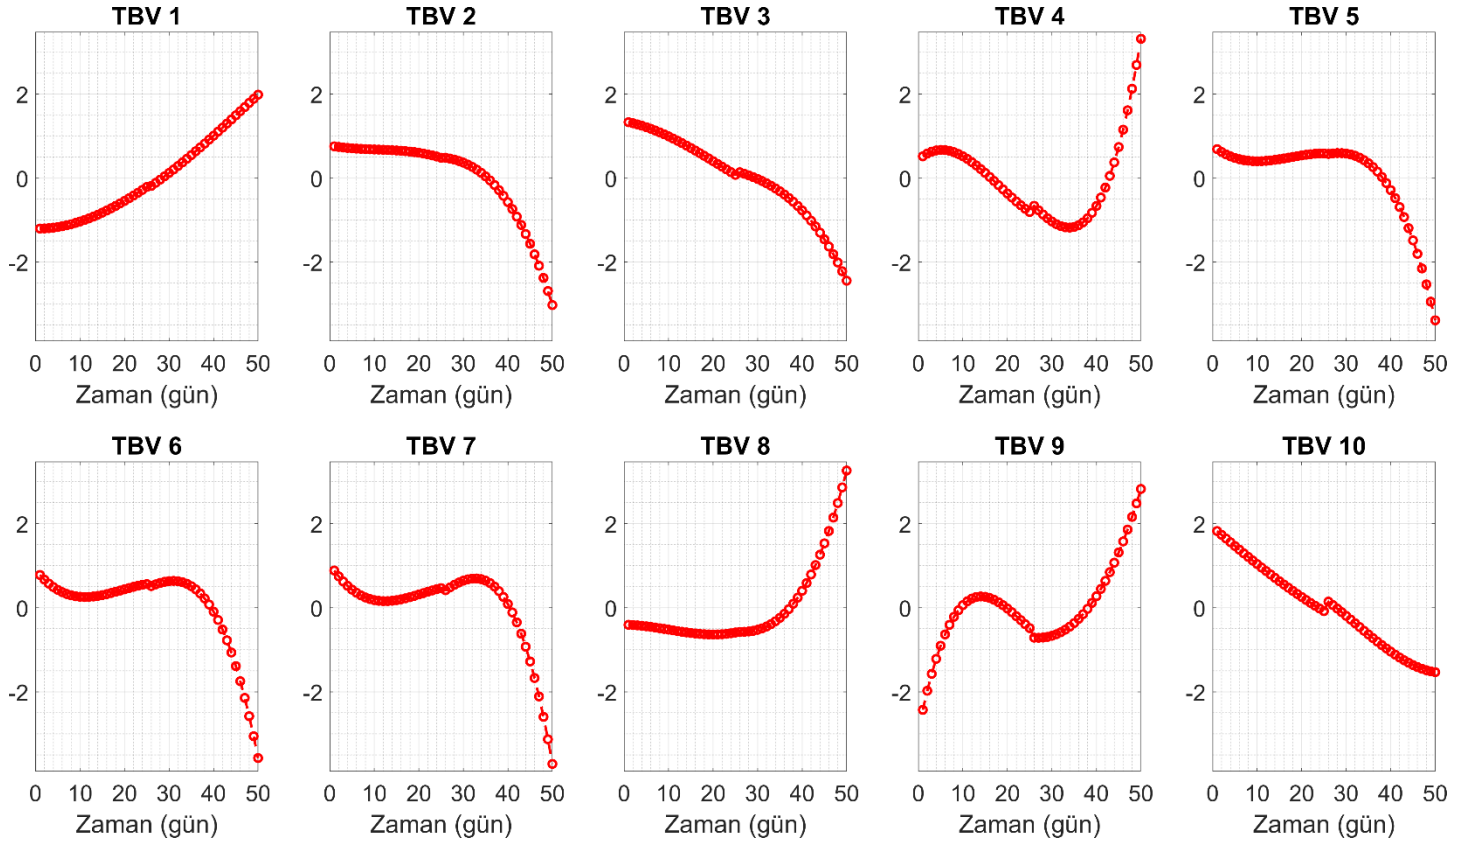
Tüm TBV'ler, Z-skoru normalizasyonu kullanılarak aynı ölçekte çizilebilir, böylece birbirleri ile karşılaştırmak daha kolay olur. TBV'ler incelendiğinde 30'uncu günde bir sıçrama gözükmektedir. Bunun sebebi eğitim için ayrılan %60'lık kısımın etkisini TBV göstermesidir. Bundan başka TBV 1,4,8 ve 9 eksponansiyel artış göstermekte olup ve potansiyel sağlık göstergeleri olarak seçilebilir. Fakat, TBV 4 ve TBV 9'da 10'uncu ve 30'uncu günler arasında, eğitim setinde olmasına rağmen, ters yönde bir eğim mevcuttur. İlaveten, TBV 8'de 30'uncu güne kadar sabit bir durum söz konusudur. Sağlık göstergesi monoton bir artış göstermesi gerekmektedir. Dolayısıyla, TBV 1 kestirimci bakım ve kalan faydalı ömür hesabında kullanılmak üzere potansiyel sağlık göstergesi olarak seçilebilir.



Şekil 3. Zaman ve frekans alanlarındaki istatistiksel özneliklerin 50 gün boyunca gelişimi



Şekil 4. Normalize edilmiş istatistiksel öznelıkların 50 gün boyunca gelişimi



Şekil 5. Temel Bileşen Vektörlerin (TBV) 50 gün boyunca gelişimi

Titreşim sinyalleri Green Power ABD tarafından gerçekleştirilen deney vasıtasıyla yüksek hızda çalışmak için tasarlanmış rulmandan elde edilmiştir (Ali vd., 2017; Saidi vd., 2017). Yürüttükleri deneyde rulmanın 5'inci günde bozulmaya başladığı, 49'uncu günde ise tamamen bozulduğu ("time to failure") tespit edilmiştir. Bu deney sonucunda ise rulmanın KFÖ'nün lineer olarak hergün 1 gün eksilecek şekilde azaldığı belirlenmiştir. Bu çalışmanın amacı, kestirimci bakımda kullanılmak için sağlık göstergesinin tespitidir. Tespit edilen sağlık göstergesi eksponansiyel bozulma modelinde kullanılarak rulman için KFÖ tahmin edilmiştir. Makine öğrenmesi metodolojisi kullanılarak tahmin edilen KFÖ, deneysel olarak belirlenen gerçek KFÖ ile karşılaştırılarak tespit edilen sağlık göstergesinin başarısı belirlenmiştir.

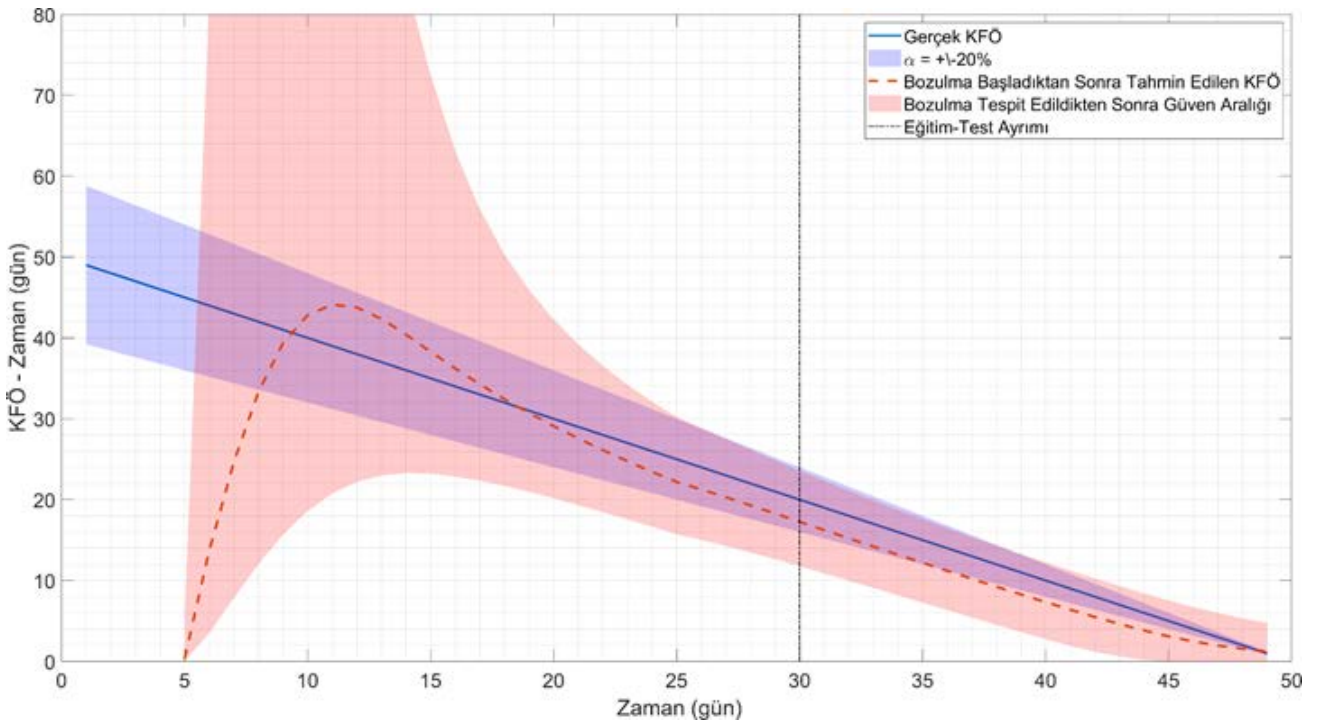
Şekil 6'da tahmin edilen ve deneysel olarak belirlenen gerçek KFÖ gösterilmiştir. Tahmin edilen KFÖ'yu iki ana bölüme; (i) eğitim veri seti kullanılarak tahmin (5'inci ve 30'uncu günler arası) ve (ii) test veri seti kullanılarak tahmin (30'uncu ve 50'nci günler) diye ayırabiliriz. Ayrıca, eğitim veri seti kullanılarak tahmini de iki sınıfa bölmekte mümkündür. Bu iki sınıf 5'inci ve 15'inci günleri kapsayan prior eğitim seti ve 15'inci ve 30'uncu günleri kapsayan posterior eğitim setidir. Şekil 6'da görüldüğü gibi 5'inci ve 15'inci günleri arasında KFÖ tahmini gerçek KFÖ'den uzakken daha fazla veri noktası mevcut oldukça tahmin daha doğru hale gelmektedir.

İstatistikte sıklıkla kullanılan determinasyon katsayısı (R^2) ve kök ortalama kare hata (RMSE) değerleri ile KFÖ tahmininin ve dolayısıyla seçilen sağlık göstergesinin başarısı prior eğitim seti, posterior eğitim seti ve test seti için tespit edilmiştir. Buna göre, prior eğitim setinin R^2 ve RMSE değerleri sırayla 0.6625 ve 17.8925; posterior eğitim setinin R^2 ve RMSE değerleri sırayla 0.9947 ve 1.7688; test setinin R^2 ve RMSE değerleri sırayla 0.9897 ve 2.2025'tir. Eğitim veri setinin için elde edilen R^2 ve RMSE değerleri, test veri seti için elde edilenlerden daha iyi olmasının sebebi 15'inci – 30'uncu günler arasında makine öğrenmesinin gerçekleşmesi ve 30'uncu günden sonra KFÖ'nün bu öğrenme ile hesaplanmasıdır.

4. Sonuç

Bu çalışmada kestirimci bakımda kullanılmak üzere sağlık göstergesi bulunması amaçlanmıştır. Arıza artış aşamalarının tanımlanması için ivmeölçer kullanılarak ölçülen titreşim sinyallerine sırasıyla Welch yöntemi, temel istatistiksel öznitelikler ve temel bileşenler analizi yöntemi uygulanmış ve temel bileşen vektörleri bulunmuştur. Sonrasında, bu vektörlerden monoton eksponansiyel artış eğilimine en iyi uyum vektör seçilerek bozulmayı temsil etmek için sağlık göstergesi belirlenmiştir. Bu çalışmada, iyi bir kalan faydalı ömür tahmini yapmak için ilk önce iyi bir sağlık göstergesini hesaplanması gerektiği belirtilmiştir. Bunu kanıtlamak içinde tahmin edilen kalan faydalı ömürü gerçek deney sonuçları ile karşılaştırılmıştır. Sonuçlardan görüleceği gibi posterior eğitim setinde oldukça yüksek neredeyse birebir korelasyon sağlanmıştır (R^2 ve RMSE değerleri sırayla 0.9947 ve 1.7688). Bunun sebebi eğitim setinin tüm verileri bu noktada makine öğrenmesinde kullanılmasıdır. Diğer yandan, test veri setine bakıldığında, R^2 ve RMSE değerleri sırayla 0.9897 ve 2.2025 elde edilmiş ve tahmin edilen KFÖ her zaman gerçek KFÖ'nün altında çıkmıştır. Böylece, herhangi bir arıza olmadan shaft yatağındaki rulmana müdahale edilebilmekte ve bakımı yapılabilmektedir.

Kestirimci bakım yöntemleri karar alıcılar açısından belirsizlik durumunu azaltmaktadır. Arızaları belirlemede sistemin ürettiği durum verileri (titreşim, akustik, termal, vb.) değerlendirme işini otomatikleştirmeye dönük çalışmalar makine öğrenmesi metodları (temel bileşenlerin tespiti, sınıflandırma, yapay sinir ağları, vb.) kullanılarak geliştirilebilir. Doğru karar sonucu yapılan işlemler; işletmelerin makine, yedek parça ve personel verimliliğine katkıda bulunmaktadır. Bu çalışmayla yüksek hızlı rulmanlar ve benzer şekilde titreşim üreten sistemlerde durum verileriyle sağlık göstergesinin tanımlanabileceği gösterilmiştir. Bu sebeple, öne sürülen metod kestirimci bakım için önemli bir potansiyele sahip olup ve kalan faydalı ömür tahmininde kullanılabilir. Dolayısıyla, gelecekteki çalışmalarda, dişli kutusu tasarımlarında arıza tespiti için bu yöntem araştırılacaktır.



Şekil 6. Sağlık göstergesi kullanılarak kalan faydalı ömür (KFÖ) tahmini ve gerçek KFÖ

Kaynakça

- Abdelli, K., Griebner, H., & Pachnicke, S. (2020). Machine Learning Based Data Driven Diagnostic and Prognostic Approach for Laser Reliability Enhancement. In *22nd International Conference on Transparent Optical Networks (ICTON)* (pp. 1-4). IEEE.
- Akçay, H., & Türkay, S. (2019). Power spectrum estimation in innovation models. *Mechanical Systems and Signal Processing*, *121*, 227-245.
- Ali Ben, J., Saidi, L., Harrath, S., Bechhoefer, E., & Benbouzid, M. (2018). Online automatic diagnosis of wind turbine bearings progressive degradations under real experimental conditions based on unsupervised machine learning. *Applied Acoustics*, *132* (2017), 167–181.
- Banerjee, A., Gupta, S. K., & Datta, D. (2020). Remaining Useful Life as a Cognitive Tool in the Domain of Manufacturing. In *Emotion and Information Processing* (pp. 171-183). Springer, Cham.
- Bektaş, O. (2020). Kestirimci Bakım İçin Döner Mekanizma Bozulma Eğrisinin Tanımlanması. *European Journal of Science and Technology*, 420–428.
- Elasha, F., Shanbr, S., Li, X., & Mba, D. (2019). Prognosis of a wind turbine gearbox bearing using supervised machine learning. *Sensors (Switzerland)*, *19*(14), 1–17.
- Guo, Y., Na, J., Li, B., & Fung, R. F. (2014). Envelope extraction based dimension reduction for independent component analysis in fault diagnosis of rolling element bearing. *Journal of Sound and Vibration*, *333*(13), 2983–2994.
- Jin, X., Wang, Y., & Hong, W. (2019). Power Spectrum Estimation Method Based on Matlab. In *Proceedings of the 3rd International Conference on Vision, Image and Signal Processing* (pp. 1-5).
- Kappal, S. (2019). Data Normalization Using Median Median Absolute Deviation MMAD based Z-Score for Robust Predictions vs. Min–Max Normalization. *London Journal of Research in Science: Natural and Formal*.
- Kızrak, M. A., & Bolat, B. (2019). Uçak Motoru Sağlığı için Uzun-Kısa Süreli Bellek Yöntemi ile Öngörücü Bakım. *International Journal of InformaticsTechnologies*, *12*(2).
- Kollmann, S., Estaji, A., Bratukhin, A., Wendt, A., & Sauter, T. (2020). Comparison of Preprocessors for Machine Learning in the Predictive Maintenance Domain. In *IEEE 29th International Symposium on Industrial Electronics (ISIE)* (pp. 49-54). IEEE.
- Liu, H., & Han, M. (2014). A fault diagnosis method based on local mean decomposition and multi-scale entropy for roller bearings. *Mechanism and Machine Theory*, *75*, 67–78.
- Liu, Z., & Zhang, L. (2020). A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings. *Measurement*, *149*, 107002.
- Muratet, L., Doncieux, S., & Meyer, J. A. (2004). A biomimetic reactive navigation system using the optical flow for a rotary-wing UAV in urban environment. *Proceedings of the International Session on Robotics*, 2262-2270.
- Orhan, S., Aktürk, N., & Çelik, V. (2003). Bir santrifüj pompa rulmanlarının çalışabilirliğinin titreşim analizi ile belirlenmesi. *Gazi Üniversitesi Fen Bilimleri Dergisi*, *16*(3), 543-552.
- Ozkat, E. C. (2019). “The Comparison of Machine Learning Algorithms in Estimation of Remaining Useful Life.” In *IX. International Maintenance Technologies Congress*. pages, 614–619. Denizli, Turkey: UCTEA CHAMBER OF MECHANICAL ENGINEERS, ISBN NO: 978-605-01-1288-7
- Saidi, L., Ben Ali, J., Bechhoefer, E., & Benbouzid, M. (2017). Wind turbine high-speed shaft bearings health prognosis through a spectral Kurtosis-derived indices and SVR. *Applied Acoustics*, *120*, 1–8.
- Sun, W., Yang, G. A., Chen, Q., Palazoglu, A., & Feng, K. (2013). Fault diagnosis of rolling bearing based on wavelet transform and envelope spectrum correlation. *JVC/Journal of Vibration and Control*, *19*(6), 924–941.
- Tao, X., Ren, C., Wu, Y., Li, Q., Guo, W., Liu, R., ... & Zou, J. (2020). Bearings fault detection using wavelet transform and generalized Gaussian density modeling. *Measurement*, *155*, 107557.
- Teng, W., Zhang, X., Liu, Y., Kusiak, A., & Ma, Z. (2017). Prognosis of the remaining useful life of bearings in a wind turbine gearbox. *Energies*, *10*(1).
- Tibaduiza, D. A., Mujica, L. E., & Rodellar, J. (2011). Structural Health Monitoring based on principal component analysis: damage detection, localization and classification. *Advances in Dynamics, Control, Monitoring and Applications, Universitat Politècnica de Catalunya, Departament de Matemàtica Aplicada*, *3*(1), 8–17.
- Villwock, S., & Pacas, M. (2008). Application of the welch-method for the identification of two- and three-mass-systems. *IEEE Transactions on Industrial Electronics*, *55*(1), 457–466.
- Yıldız, K., Çamurcu, Y., & Doğan, B. (2010). Veri madenciliğinde temel bileşenler analizi ve Negatifsiz matris çarpanlarına ayırma tekniklerinin karşılaştırmalı analizi. *Akademik Bilişim*, 10-12.