

# Rulmanlarda Bilezik Arızalarının Yapay Sinir Ağları ile Tespiti ve Sınıflandırılması

## Detection and Classification of Ring Failures by Artificial Neural Networks in Bearings

Yunus Emre KARABACAK<sup>1</sup>, Hamdi Tolga KAHRAMAN<sup>2</sup>, Levent GÜMÜŞEL<sup>3</sup>, Cemal YILMAZ<sup>4</sup>

<sup>1,3</sup> Makine Mühendisliği Bölümü, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye  
y\_emre\_karabacak@hotmail.com, gumusel@ktu.edu.tr

<sup>2</sup>Yazılım Mühendisliği Bölümü, Karadeniz Teknik Üniversitesi, Trabzon, Türkiye  
htolgakahraman@ktu.edu.tr

<sup>4</sup>Elektrik Elektronik Mühendisliği Bölümü, Gazi Üniversitesi, Ankara, Türkiye  
cemal@gazi.edu.tr

**Özetçe—** Makinelerin verimini arttırmanın ve ömrünü uzatmanın etkili bir yolu rulmanların çalışma sırasında arızalarının tespit edilmesidir. Rulman arızalarının erken tespit edilmesi üretim maliyetleri açısından da kritik öneme sahiptir. Arızaları önlemek için çeşitli bakım yöntemleri kullanılmaktadır. Tüm önlemlere rağmen beklenmedik arızalar oluşabilmekte ve üretim faaliyetleri aksayabilmektedir. Bu durum geleneksel yöntemlerin dışında sıra dışı bir arıza tespit ve teşhis tekniğine ihtiyacı doğurmuştur. Bu çalışmada rulman arızalarını erkenden tespit etmek ve arıza tipini sınıflandırmak amacıyla yapay zekâ tabanlı yöntemler uygulanmakta ve modeller geliştirilmektedir. Geliştirilen modellerde farklı yüklenmelere ve rulman titreşim bilgisine bağlı olarak bilezik hatası tespiti yapılmaktadır. Ayrıca hatanın iç ya da dış bilezikten kaynaklandığına yönelik bir sınıflandırma gerçekleştirilmektedir. Gerek hatanın tespiti gerekse de sınıfının belirlenmesi özellikle kritik endüstriyel uygulamalarda kararlı çalışmayı ve verimliliği artıracaktır.

**Anahtar Kelimeler—**Rulman, Bilezik hatası, Sınıflandırma

**Abstract—** An effective way to improve the efficiency and extend the life of the machines is to determine the failures of the bearings during operation. Early detection of bearing failures also has critical importance in terms of production costs. Various maintenance methods are used to prevent the failures. Despite all the precautions, unexpected failures can occur and production operations can be failed. This situation, apart from conventional methods, requires a novel determination and diagnostic technique. In this study, artificial intelligence based methods are applied and models are developed in order to detect bearing failures early and to classify the type of failure. In the developed models, it is possible to detect the ring failures depending on different loads and bearing vibration information. In addition, a classification is carried out for the fault from the inner or outer race of the bearing. Determination of the fault, as well as the diagnosis of the class, will increase stability and productivity, especially in critical industrial applications.

**Keywords—** Bearing, Ring Failures, Classification

### I. GİRİŞ

Fabrikalar ve endüstrinin diğer çeşitli kollarında kullanılan ve en önemli makine elemanlarından olan rulmanların çalışma süresi boyunca arızalarının tespit edilmesi makinelerin verimini arttırır ve ömrünü uzatır. Fabrikanın çalışma şartları içerisinde rulmanlardan kaynaklanan arızalar üretimin verimliliği ve devamlılığı açısından da sorun teşkil ettiği bilinen bir gerçektir. Bu nedenle rulman arızalarının erken teşhisi, düzenli kestirimci ve önleyici periyodik bakım faaliyetleri, üretim süresi ve maliyeti açısından son derece önem arz etmektedir [1- 2].

Bu bağlamda çeşitli kestirimci bakım yöntemleri ile rulman arızaları meydana gelmeden önce periyodik kontroller gerçekleştirilmekte makinenin üretim dışı kalmasının önüne geçilmektedir. Uygulamada kullanılan yöntemlerin ilki bir tornavida ile rulman yatağının dinlenmesidir. Bu yöntem kullanılırken arıza meydana gelene kadar rulman çalışmaya devam eder ve nihayet arıza oluştuğunda yenisi ile değiştirilir. Bilimsel olmayan bu bakım yaklaşımı, üretim akışının kesintisiz olması istenen işletmeler için uygun değildir. Sürekli üretim akışının olduğu tesis ve fabrikalarda kestirimci bakım için genellikle deneyimli operatörler görevlendirilir ve işe özel kestirimci bakım cihazları ile belirli periyotlarda rulmanların kontrolü yapılır ve rapor tanzim edilir. Nihai noktada, toplanan veriler belirli bir referans seviyenin üstünde ise arıza meydana gelip makine durmadan önce rulmanlar değiştirilir. Bu şekilde fazladan yedek parça, enerji ve işçilik israfının, ayrıca plansız üretim aksaklıklarının önüne geçilir [3-4].

Bir rulmanda arıza olmasa bile mil, dönme hareketi ve yükleme durumuna bağlı olarak düşük frekanslı titreşim sinyalleri meydana gelir. Arıza oluştuğunda, rulman

yuvarlanma elemanlarının arızalı bölgenin üzerinden geçişiyle birlikte sağlam rulmanda oluşmayan periyodik sinyaller gözlenir. Bu periyodik sinyallerin frekansları, arızanın karakteristiğini hakkında bize bilgi verir. Söz konusu arızalı rulmanlardan elde edilen sinyallerin analiz edilmesi ve arıza karakteristiğinin ortaya konulabilmesi için çeşitli yöntemler mevcuttur (zarf analizi, spektral basıklık ve tek değer ayırıştırma yöntemleri vb.) [4].

Rulman arızalarının tespiti ile ilgili yapılan çalışmalarda, makine veya ekipmandan toplanan titreşim verilerinin zaman, frekans ve(veya) her ikisinin birlikte meydana getirdiği düzlemlerden elde edilen özellikler ile arızalar tespit ve teşhis edilemeye çalışılır. Titreşim verilerinin zaman düzlemindeki istatistiksel bilgileri ile frekans düzlemindeki, arızanın türüne göre meydana gelen hata karakteristiği elde edilerek sinyal özelliklerinin çıkartılması ile ilgili çeşitli çalışmalar yapılmıştır. Ayrıca dalgacık dönüşümü ile istatistiksel bilgileri içeren özelliklerin çıkartılarak arıza karakteristiği hakkında bilgi elde edilmesi de sağlanmıştır [4].

Uygulamada arızalı ve arızasız rulmanlardan elde edilen titreşim verilerinin modellenmesi için yapay sinir ağları [5-8], destek vektör makineleri, bulanık sınıflandırma ve karar ağaçları kullanılmaktadır [9-11]. Bu çalışmada rulman arızalarının tespiti ve sınıflandırılması için gerek hassasiyeti gerekse de doğruluk oranının yüksekliği sebebiyle literatürde en sık kullanılan yöntemlerden biri olan çok katmanlı ileri beslemeli geri yayımlı yapay sinir ağ modeli benimsenmiştir. Ağ girişleri rulman yükü ve titreşim genliği olarak belirlenmiş iken çıkışları ise hata durumu ve sınıfı olmaktadır. Deneysel çalışmalara ait veriler [12-13] numaralı referans ile verilen veri havuzundan elde edilmiştir. Rulmandaki hatanın %100 doğrulukla belirlendiği deneysel çalışmalarda iç ve dış bilezik hatasının ise başarılı bir şekilde birbirinden ayırt edilemediği görülmüştür. Bu problemin sebepleri ve çözüm önerileri sonuçlar bölümünde verilmektedir.

## II. YÖNTEM

Literatürde sınıflandırma problemlerinin modellenmesi amacıyla kullanılan algoritmalarından bir kaç k-en yakın komşu sınıflandırıcı (k-nn) [14], karar ağaçları [15], destek vektör makineleri [16], yalın bayes sınıflandırıcı [17] ve yapay sinir ağlarıdır [18]. Bunların arasında sürekli değerli giriş niteliklerine sahip problemler için etkili ve doğal çözüm yolu olarak k-nn ve YSA öne çıkmaktadır. k-nn sınıflandırıcının bir model oluşturmaması ve hesaplama zamanının veri örneklerinin sayısına bağlı olmasından dolayı büyük veri setlerinde ve çok boyutlu karmaşık problemlerde YSA modelinin tercih edilmesine yol açmaktadır.


Rulmanlardaki hatanın modellendiği bu problem 2 adet giriş ve bir adet çıkış parametresinden oluşmaktadır. Tablo 1'de probleme ait nitelikler ve değer aralıkları verilmektedir.

Tablo 1. Probleme ait nitelikler ve değer aralıkları.

	Giriş parametreleri		Hedef parametre
	Yük	Titreşim	Hata Sınıfı
Sınır Değerler	[250-300] lb	[(-30), (+30)]Gs	Yok Dış Bilezik İç Bilezik

2.1. Model 1 (hata durumunun tespiti): bu durumda problemin hedef parametresi iki sınıftan biri ile temsil edilmektedir. Bunlar rulmanda “hata yok” (1) ve “hata var” (2) şeklinde sınıflandırılır.

2.2. Model 2 (hata sınıfının tespiti): bu durumda problemin hedef parametresi üç sınıftan biri ile temsil edilmektedir. Bunlar rulmanda “hata yok” (1), “dış bilezik hatası var” (2) ve “iç bilezik hatası var” (3) şeklinde sınıflandırılır.




Şekil 1. Model 1 (a) ve Model 2 (b) için YSA blok diyagramı gösterimi

## III. DENEYSEL ÇALIŞMA

YSA'nın eğitimi, zaman düzleminde rulmana uygulanan yük ve titreşim genliği olmak üzere iki özelliğin birleştirilmesiyle oluşturulan veri seti kullanılarak gerçekleştirilmiştir. 10000 veri sağlam rulmana, 20000 veri dış bilezik arızası olan rulmana ve 20000 veri de iç bilezik arızası olan rulmana ait olacak şekilde toplam 50000 veri sınıflandırma için kullanılmıştır. Sınıflandırma çalışmaları arızanın tespiti ve türünün teşhisi için ayrı ayrı gerçekleştirilmiştir.


### A. Model 1 (hata durumunun tespiti):

YSA ile arızanın tespiti yapılırken 1 gizli katman ve bu katmanda 10 tane nöron olacak şekilde mimari denemesi gerçekleştirilmiştir (Şekil 2). Deneysel verilerin %70'i eğitim, %15'i doğrulama ve %15'i test için kullanılmıştır.




Şekil 2. Arızanın tespiti için seçilen YSA mimarisi

Logaritmik ölçekte tüm veri setinin ortalama karesel hata eğrisini gösteren YSA eğitim performansı grafiği Şekil 3'de verilmektedir. Buna göre en iyi doğrulama performansı 31 döngüde  $5.1721e-07$ 'dir.




Şekil 3. YSA performans eğrisi



Şekil 4. YSA'nın eğitim durumu ile ilgili istatistikler

Şekil 4. YSA'nın eğitim durumu ile ilgili istatistiklerini göstermektedir. Şekil 4 (a) her iterasyonda geri yayılım gradyanının değerini logaritmik ölçekte göstermektedir. 31 döngüde gradyan  $8.0974e-07$  olup burada hedef fonksiyonu yerel minimum seviyesinin altına ulaşmıştır. Şekil 4. b) ise 31 döngüde doğrulama hatalarını göstermektedir.



Şekil 5. Hata histogramı


Şekil 5. Eğitim, doğrulama ve test verileri için hata histogramını göstermektedir. Burada hata değeri hedefler ile çıktıların farkı olarak gösterilmiştir. Şekil 6. Eğitim, doğrulama, test ve tüm durumlar için karışıklık (bozulma) matrislerini göstermektedir. Bu grafiklerde yeşil kareler doğru verilen cevapları, kırmızı kareler de yanlış verilen temsil etmektedir.



Şekil 6. Hata (karışıklık) matrisleri


#### B. Model 2 (hata sınıfının tespiti):

YSA ile arızanın tespiti yapılırken 1 gizli katman ve bu katmanda 10 tane nöron olacak şekilde mimari denemesi gerçekleştirilmiştir (Şekil 7). Deneyel verilerin %70'i eğitim, %15'i doğrulama ve %15'i test için kullanılmıştır.




Şekil 7. Arıza tespiti için YSA mimarisi

Şekil 8. logaritmik ölçekte, tüm veri setinin ortalama karesel hata eğrisini gösteren YSA eğitim performansı grafiğidir. Buna göre en iyi doğrulama performansı 173 döngüde 0.18294'dir.




Şekil 8. YSA eğitim performansı



Şekil 9. YSA'nın eğitim durumu ile ilgili istatistikler

Şekil 9. YSA'nın eğitim durumu ile ilgili istatistiklerini göstermektedir. Şekil 9. a) her iterasyonda geri yayılım gradyanının değerini logaritmik ölçekte göstermektedir. 179 döngüde gradyan 0.0011802 olup burada hedef fonksiyonu yerel minimum seviyesinin altına ulaşmıştır. Şekil 9. b) ise 179 döngüde doğrulama hatalarını göstermektedir.



Şekil 10. Hata Histogramı

Şekil 10. Eğitim, doğrulama ve test verileri için hata histogramını göstermektedir. Burada hata değeri hedefler ile çıkışların farkı olarak gösterilmiştir. Şekil 11. Eğitim, doğrulama, test ve tüm durumlar için karışıklık(bozulma) matrislerini göstermektedir. Bu grafiklerde yeşil kareler doğru verilen cevapları, kırmızı kareler de yanlış verilen temsil etmektedir (1. sınıf ile gösterilen durum iç bileziği arızalı rulman durumu, 2. sınıf ile gösterilen durum dış bileziği arızalı rulman durumu, 3. sınıf ile gösterilen durum da arızasız rulman durumudur).

Eğitim Karışıklık Matrisi				
Çıkış Sınıfı	1	2	3	
	3720 10.6%	3476 9.9%	0 0.0%	51.7% 48.3%
	10288 29.4%	10500 30.0%	0 0.0%	50.5% 49.5%
	0 0.0%	0 0.0%	7016 20.0%	100% 0.0%
Doğrulama Karışıklık Matrisi				
Çıkış Sınıfı	1	2	3	
	834 11.1%	748 10.0%	0 0.0%	52.7% 47.3%
	2175 29.0%	2242 29.9%	0 0.0%	50.8% 49.2%
	0 0.0%	0 0.0%	1501 20.0%	100% 0.0%
Test Karışıklık Matrisi				
Çıkış Sınıfı	1	2	3	
	802 10.7%	723 9.6%	0 0.0%	52.6% 47.4%
	2181 29.1%	2311 30.8%	0 0.0%	51.4% 48.6%
	0 0.0%	0 0.0%	1483 19.8%	100% 0.0%
Genel Karışıklık Matrisi				
Çıkış Sınıfı	1	2	3	
	5356 10.7%	4947 9.9%	0 0.0%	52.0% 48.0%
	14644 29.3%	15053 30.1%	0 0.0%	50.7% 49.3%
	0 0.0%	0 0.0%	10000 20.0%	100% 0.0%

Şekil 11. Hata (karışıklık) matrisleri

#### IV. SONUÇLAR VE ÖNERİLER

Bu çalışmanın araştırmacılar açısından önemli birkaç sonucu vardır. Bunlardan ilki, rulman hatalarının modellenmesinde sadece titreşim verilerini değil özellikle yük verilerini de hatanın bir parametresi olarak dikkate almak gerektiridir. Bu durum 50 bin veri üzerinde

yürütülen deneysel çalışmalardan elde edilen yüzde yüz sınıflandırma doğruluğu ile ispatlanmıştır. Bunun yanında rulmanlardaki hatanın iç bilezikten mi yoksa dış bilezikten mi kaynaklandığını tespit etmek için titreşim ve yük verilerinin yeterli olmadığı kanaati oluşmuştur. Yüklenme kademe sayısı artırılıp yeni titreşim verileri de kullanılarak iç ve dış bilezik hatasının birbirinden ayırt edilmesi hususunda çalışmalar yapılabilir. Ancak iç ve dış bilezik hatasının birbirinden ayırt edilmesine yönelik deneysel çalışmalardan elde edilen %60'lık başarı oranına dikkat etmek gerekir. Öyle anlaşılmaktadır ki bu iki hatayı etkili bir şekilde birbirinden ayırt etmek için titreşim ve yük parametrelerinin dışında da parametrelere ihtiyaç duyulmaktadır. Bu açıdan farklı yüklenmeler için hız bilgisi de dikkate alınabilir. Yük ve titreşim bilgilerine bağlı olarak rulman arızasının sıfır hata ile belirlendiği bu çalışmanın endüstriyel uygulamalar için faydalı olması beklenmektedir. Bunun yanında hata sınıfının belirlenmesi hususunda elde edilen deneyimlerin gelecek çalışmalar için de yol göstermesi umulmaktadır.

#### YAZAR KATKILARI

*Birinci yazar* çalışmanın sorumlu yazarı olup deneysel çalışmalar için gerekli veri hazırlama işlemlerini yapmıştır. *İkinci yazar* yapay sinir ağı modelini kurmuştur. *Üçüncü yazar* ise çalışmanın bilimsel olarak danışmanlığını yürütmüş ve elde edilen sonuçların değerlendirmesini yapmıştır.

#### KAYNAKÇA

- [1] M. Kalyoncu, "Titreşim analizi ile makina elemanları arızalarının belirlenmesi," TMMOB Makina Mühendisleri Odası Mühendis ve Makina Dergisi, 47, 28-35, 2006.
- [2] S. Orhan, H. Arslan ve N. Aktürk, "Titreşim Analiziyle Rulman Arızalarının Belirlenmesi," Journal of The Faculty of Engineering and Architecture of Gazi University, 18 (2), 39-48, 2003.
- [3] C. Aliustaoğlu, "Rulman arızalarının gerçek zamanda analizi ve arıza kaynaklarının tespit edilmesi," Fen Bilimleri Enstitüsü, Kocaeli, Kocaeli Üniversitesi, 2008.
- [4] M. Ünal, "Sinyal İşleme ve Genetik-Yapay Sinir Ağları İle Rulman Arızalarının Tespiti", Fen Bilimleri Enstitüsü İstanbul: Marmara Üniversitesi, 2014.
- [5] B. K. N Rao, P. S. Pai, T.N. Nagabhushana, "Failure Diagnosis and Prognosis of Rolling – Element Bearings using Artificial Neural Networks: A Critical Overview", 25th International Congress on Condition Monitoring and Diagnostic Engineering, IOP Publishing, 364, 1-29, 2012.
- [6] K.U. Shridhar, S. Pradeep, "Prognosis of Rotating Machinery Using Artificial Neural Network", International Journal of Engineering Research & Technology (IJERT), 2 (8), 1433-1439, 2013.
- [7] I.M. Jamadar, D.P. Vakharia, "A novel approach integrating dimensional analysis and neural networks for the detection of localized faults in roller bearings", Measurement, 94, 177–185, 2016.
- [8] L. Guo, N. Li, F. Jia, Y. Lei, J. Kin, "A recurrent neural network based health indicator for remaining useful life prediction of bearings", Neurocomputing, 240, 98–109, 2017.
- [9] G. Zurita, V. Sanchez, D. Cabrera, "A Review Vibration Machine Diagnostics By Using Artificial Intelligence Methods", Upb - Investigacion & Desarrollo, 16(1), 102-114, 2016.
- [10] J.P. Patel, S.H. Upadhyay, "Comparison between Artificial Neural Network and Support Vector Method for a Fault Diagnostics in Rolling Element Bearings", Procedia Engineering, 144, 390-397, 2016.
- [11] X. Chen, J. Zhao, J. Xiao, X. Zhang, H. Xiao, W. Zhu, W. Fu, "Fault diagnosis based on dependent feature vector and probability neural network for rolling element bearings", Applied Mathematics and Computation, 247, 835–847, 2014.
- [12] Bechhoefer, E., "A Quick Introduction To Bearing Envelope Aalysis", Gren Power Monitoring Systems, Cornwall, VT 05752, 2012.
- [13] <http://data-acoustics.com/measurements/bearing-faults/bearing-2/>, 16.05.2017
- [14] Kahraman, H. T., "A Novel and Powerful Hybrid Classifier Method: Development and Testing of Heuristic k-nn Algorithm with Fuzzy Distance Metric", Data & Knowledge Engineering, 103, 44-59, 2016.
- [15] Rahman, G., Islam, Z., "Missing value imputation using decision trees and decision forests by splitting and merging records: Two novel techniques", Knowledge-Based Systems, 53, 51–65, 2013.
- [16] Nayak, J., Naik, B., Behera, H. S., "A Comprehensive Survey on Support Vector Machine in Data Mining Tasks: Applications & Challenges", International Journal of Database Theory and Application, 8(1), 169-186, 2015.
- [17] Colak, I., Bal, G., Demirtas, M., Kahraman, H. T., "A Parameter Determination System for Wind Turbines Based On Naive Bayes Classification Algorithm", The Eighth International Conference on Machine Learning and Applications (ICMLA 2009) Florida, USA, 611-616, 2009.
- [18] Neto, A., Bonini, C., Bisi, B., Coletta, L., Reis, A., "Artificial Neural Network for Classification and Analysis of Degraded Soils", IEEE Latin America Transactions, 15(3), 503-509, 2017