



RULMANLARDA TİTREŞİM VERİLERİNDEN DURUM İZLEME VE ARIZA TEŞHİSİ İÇİN DERİN ÖĞRENME YÖNTEMİNİN UYGULANMASI

¹Nurhan GÜRSEL ÖZMEN , ²Yunus Emre KARABACAK 

¹Karadeniz Teknik Üniversitesi, Makina Mühendisliği Bölümü, Trabzon, TÜRKİYE

²Çay İşletmeleri Genel Müdürlüğü (ÇAYKUR), Rize, TÜRKİYE

¹gnurhan@ktu.edu.tr, ²yunus.karabacak@caykur.gov.tr

(Geliş/Received:;28.12.2021 Kabul/Accepted in Revised Form: 05.04.2022)

ÖZ: Rulmanlar, yük taşıma kapasiteleri nedeniyle endüstride pek çok alanda sıklıkla kullanılan makine elemanları olduklarından, aşırı yüklenme durumlarında adhezyon, abrazyon ve sürünme gibi aşınma türlerine ya da kırılmalara maruz kalabilirler. Bu nedenle, rulmanlarda durum izlemesi yapılması ve arızaların teşhis edilmesi, sürdürülebilirlik, yüksek performans ve güvenlik açılarından önemli bir husustur. Arıza türlerinin ayırt edilmesinde belirleyici özniteliklerin seçilmesi, farklı çalışma koşullarında bir takım öznitelikler de değişebildiğinden zor bir süreçtir. Bu nedenle, bu çalışmada sağlıklı rulmanların (SR) ve rulman arızalarının (dış bilezik arızası-AR1, iç bilezik arızası-AR2, yuvarlanma arızası-AR3) tespiti için özniteliklerin içsel dinamiklerle belirlendiği derin öğrenme yöntemi olan evrişimli sinir ağları (ESA) kullanılmıştır. Birbirinden farklı mimariyelere sahip ESA yaklaşımlarını eğitmek için Kısa Zamanlı Fourier Dönüşümü uygulanan titreşim sinyallerinin spektrogramları elde edilmiştir. Spektrogram verileri ile eğitilen GoogleNet, ResNet-50, EfficientNet-B0 ve AlexNet yaklaşımlarının sonuçları karşılaştırmalı olarak incelenmiştir. Karmaşık mimariye sahip ESA'ların (GoogleNet, ResNet-50, EfficientNet-B0) arızaları %100 doğrulukla, AlexNet'in ise %90 doğrulukla tespit ettiği görülmüştür, ancak ağ yapısı değiştikçe ve katman sayısı arttıkça eğitim süresinin de uzadığı görülmüştür. Elde edilen sonuçların literatürdeki çalışmaların sonuçlarından üstün olduğu gözlenmiştir. Sonuç olarak, farklı yaklaşımlara sahip evrişimli sinir ağları yönteminin en temel rulman arıza tespitinde yüksek sınıflandırma doğruluğu sağladığı ve arıza teşhisi için umut vadeden bir yöntem olduğu görülmektedir.

Anahtar Kelimeler: Arıza teşhisi, Rulmanlar, Derin Öğrenme, Durum İzleme, Titreşim

Application of Deep Learning Method for Condition Monitoring and Fault Diagnosis from Vibration Data in Bearings

ABSTRACT: Since bearings are machine elements that are frequently used in several industry due to their load carrying capacity, they are subjected to wear or breakage such as adhesion, abrasion and creep under overloading conditions. For this reason, condition monitoring and fault detection are an important issue for sustainability, high performance and reliability. Feature selection is a difficult task, hence, some features may change due to changing working conditions. Therefore, in this study, convolutional neural networks (ESA), which is a deep learning method in which features are determined by internal dynamics, are used for the detection of healthy bearings (SR) and bearing failures (outer ring failure-AR1, inner ring failure-AR2, rolling element failure-AR3). In order to train ESA approaches with different architectures, spectrograms of vibration signals using Short-Time Fourier Transform were obtained. The results of GoogleNet, ResNet-50, EfficientNet-B0 and AlexNet approaches that are trained with spectograms are comparatively examined. It has been seen that ESAs with complex architectures (GoogleNet, ResNet-50, EfficientNet-B0) detect failures with 100% accuracy and AlexNet with 90% accuracy, but it has been observed that the training time increases as the network structure changes and the number of layers

increases. It is observed that the results of the study are far better than the similar papers in the literature. As a result, it is seen that the convolutional neural network method with different approaches provides high classification accuracy in the most basic bearing fault detection and is a promising method for fault diagnosis.

Keywords: *Fault detection, Bearings, Deep Learning, Condition Monitoring, Vibration*

GİRİŞ (INTRODUCTION)

Endüstriyel durum izleme uygulamaları, geliştirilen izleme teknolojilerine ve yapay zeka ile karar verme yöntemlerine bağlı olarak çok gelişmiştir. Fabrikalar, üretim tesisleri ve santraller gibi çalışmanın sürekli olduğu ve üretimin kesintisiz devam ettiği yerlerde söz konusu sistemleri oluşturan ekipman ve makinelerin hatasız çalışması maliyet ve iş güvenliği açısından son derece önemlidir (Cakır ve diğ., 2021). Makinelerin bakım aralıklarının ve beklenmeyen arızalardan kaynaklanan duruş sürelerinin mümkün olduğunca düşük tutulması arzu edilir. Dolayısıyla, böyle bir arızanın yol açacağı maliyetleri en aza indirmek için, bu tür arızaların önceden tespit edilmesi önem taşımaktadır. Mühendislik uygulamalarındaki artan karmaşıklık ve hassasiyet özellikle Endüstri 4.0 , nesnelerin interneti ve büyük veri analizi kavramlarının hayatımıza girmesi nedeniyle durum izleme ve güvenilirlik sorunları daha da önemli hale gelmiştir (Caesarendra ve Tjahjowidodo, 2017). Durum izleme, makinelere ait farklı parametrelerin gerçek zamanlı olarak ölçülmesi ve makine izleme yazılımıyla birleştirilmesi yoluyla makine sağlığı ve güvenliğini bir başka deyişle makinelerin kalan kullanışlı ömrünü kestiren veya öngören bir bakım yaklaşımıdır. Toplanan ölçüm verileri yorumlanarak makinenin arızalı olup olmadığı belirlenir ve bu doğrultuda bakım planı hazırlanarak uygulamaya geçilir. Özellikle rulman ve dişli çark gibi elemanların kullanıldığı makinelerin arızalarının teşhisi için güvenilir bir durum izleme sisteminin kurulması kesintisiz ve sorunsuz bir çalışma sağlar (Correa ve Guzman, 2020).

Rulmanlar, bağlı hareketi istenen hareketle sınırlayan ve hareket eden elemanlar arasındaki sürtünmeyi azaltarak bu esnada daha az güç harcanarak, daha yüksek devirlere çıkabilen makine elemanlarıdır. Çoğu rulman, sürtünmeyi en aza indirerek istenen hareketi kolaylaştırır. Rulmanlar, çalışma şekline, izin verilen hareketlere veya parçalara uygulanan kuvvetlerin veya yüklerin yönlerine göre farklı şekillerde sınıflandırılırlar. Birçok endüstriyel uygulamada, güç ve hareket iletim sistemleri dairesel veya eksenel olan her türlü taşıt ve transport ekipmanında ve üretim makinelerinde sıklıkla kullanılmaktadırlar. Rulmanların üretimlerinde yüksek teknoloji ve yüksek kalitede malzeme kullanımı esastır. Ayrıca, kullandıkları yerlerde statik ve dinamik yüklere maruz kaldıklarından, temas noktalarında farklı deformasyonların gözlenmesi normaldir. Bu nedenle rulmanlarda durum izleme çalışmaları da söz konusu sistemlerin sağlıklı çalışabilmeleri için son derece kritiktir (Duan ve diğ., 2018). Rulmanlarda en sık karşılaşılan sorunlar yağsızlık, adhezyon aşınması, yüzey yorgunluğu, abrazyon aşınması ve kırılma şeklinde sıralanabilir. Bu hasarların meydana getireceği zaman, üretim ve para kaybını önlemek için kesitirimci bakım yöntemleri uygulanmalıdır (Geitner ve Bloch, 2012).

Rulmanlarda durum izlemesi için literatürde yaygın olarak kullanılan bazı teknikler mevcuttur. Titreşim analizi (Malla ve Panigrahi, 2019; Liu ve diğ., 2020), akustik analiz (Elforjani ve Shanbr, 2017; Hase, 2020), aşınma kalıntısı analizi (Peng ve diğ., 2019; Ranjan ve diğ., 2020), motor akım analizi (Hoang ve Kang, 2019) gibi teknikler bunlardan başlıcalarıdır. Makinelerin pek çoğunda millerin dönmesi veya dişlilerin çalışması esnasında periyodik hareket ortaya çıktığından, makinenin çalışma frekansı ve dolayısıyla titreşim frekansı tespit edilerek, olağan olmayan durumlar tespit edilebilir. Rulman durumunun titreşimler yoluyla izlenmesinde sıklıkla titreşim sensörleri kullanılır (O'Lmasov Ahadjon Akramjon, 2020). İvmeölçer olarak da bilinen titreşim sensörleri zorlu çalışma koşullarına ya da yüksek sıcaklığa maruz kalabilir. Böyle durumlarda rulmanlarda durum izleme performansının iyileştirilmesi için akustik ölçümlerden yararlanılabilir (Rezaei ve diğ., 2011). Rulmanlarda bir diğer durum izleme tekniği ise termal görüntülemedir (Choudhary ve diğ., 2018). Elektromanyetik spektrumun uzun kızılötesi aralığındaki radyasyonu algılayabilen ve termogram olarak bilinen termal görüntüler üreten kameralar

ile rulmanlar temassız ve sürekli olarak izlenebilir (Usamentiaga ve diğ., 2014). Farklı durum izleme ölçüm metodları geliştirilmesine rağmen, titreşim analizi hala daha en geçerli olan yöntemdir. Çünkü, değişikliklere duyarlıdır ve sürekli durum izleme çalışmalarında kullanılmaya da uygundur. Ayrıca, sinyal işleme yöntemlerinin gelişimiyle birlikte, titreşim verilerinin hassasiyeti de artmaktadır.

Rulmanlarda arıza teşhisi çalışmaları için kullanılacak verinin yanında, bu verilerin değerlendirileceği yöntemler de büyük önem taşımaktadır. Geçmişten günümüze rulmanlarla ilgili birçok arıza teşhis ve durum izleme çalışmasında sınıflandırma algoritması olarak, yapay sinir ağları (Karabacak ve diğ., 2022; Karabacak ve Özmen, 2021), destek vektör makineleri (Goyal ve diğ., 2020; Zhang ve Zhou, 2013), k en yakın komşu algoritması (Dong ve diğ., 2017) ve karar ağaçları algoritması (Amarnath ve diğ., 2013) kullanılmıştır. Bu yöntemlerin veri boyutuna ve tipine göre sınıflandırma performansları değişiklik göstermektedir. Bu alanda destek vektör makineleri ve yapay sinir ağları en yaygın kullanılan ve yüksek doğruluk elde edilen yöntemlerin başında gelmektedir. Sınıflandırma algoritmalarının üstün performans göstermesindeki önemli etkenlerden biri de ayırt edici özniteliklerin ele alınan probleme uygun seçilmesidir. Son yıllarda, kestirimci bakım çalışmalarındaki veri seti boyutları büyüdükçe, ayırt edici özniteliklerin sayısı da artmış ve bu özniteliklerin belirlenmesi zorlaşmıştır. Dolayısıyla, öz niteliklerin dışardan belirlenmesine gerek kalmadan, problemin iç yapısında özniteliklerin belirlenerek ve ağırlıklandırılarak sınıflandırma işleminin yapıldığı etkili bir algoritma olan evrimsel sinir ağları (ESA) kullanılmıştır (Karabacak ve diğ., 2020; Zhu ve diğ., 2018). ESA en kolay uygulanabilen ve sıklıkla tercih edilen bir derin öğrenme algoritmasıdır.

Rulmanlarda yapay zeka tekniklerinin kullanımı makinelerde durum izleme amacıyla, farklı değişken parametreler altındaki karmaşık sistemlerin modellenmesi amacıyla veya da sistemlerin optimizasyonu, kestirimi ve kontrolü gibi amaçlarla sıklıkla kullanılmaktadır (Eren ve diğ., 2021). Bu bağlamda derin öğrenme, en yeni makine öğrenme tekniklerinden biridir ve son yıllarda durum izleme amacıyla da uygulamalar yapılmıştır. Derin öğrenmenin rulman ve redüktör gibi elemanların kestirimci bakımında güvenilir ve etkili bir metodoloji olduğu farklı araştırmacılar tarafından ortaya koyulmuştur (Li, X. ve diğ., 2019). Yoo ve Baek sürekli dalgacık dönüşümü ve ESA yaklaşımına dayalı olarak rulmanların kalan faydalı ömrünün tahmini için yeni bir görüntü özniteliği hesabı geliştirmiştir (Yoo ve Baek, 2018). Sadoughi ve Hu yuvarlanma elemanlı rulmanlarda arıza teşhisi için fizik tabanlı bir ESA kullanmıştır (Sadoughi ve Hu, 2019). Zhu ve arkadaşları rulmanlarda arıza teşhisi için güçlü genellemeye sahip bir kapsül ağına dayalı ESA üzerinde çalışmış ve geliştirdikleri modeli geleneksel yöntemlerle karşılaştırmıştır (Zhu ve diğ., 2019). Zhang ve arkadaşları gürültülü ortamda ve farklı çalışma yükleri altında çalışan rulmanların arızalarının teşhisi için yeni eğitim metodları ile eğitilen bir ESA yaklaşımı geliştirmiştir (Zhang ve diğ., 2018). Kumar ve arkadaşları rotatif makinelerde rulman arızalarının teşhis edilmesi için yeni bir ESA yaklaşımı geliştirmiştir (Kumar ve diğ., 2021). Huang ve arkadaşları rulmanlarda arıza teşhisi için çok ölçekli enfomasyona sahip gelişmiş bir derin ESA yaklaşımı kullanmıştır (Huang ve diğ., 2019). Zhang ve arkadaşları rulman arızalarının teşhisi için zaman-fekans görüntüsüne dayalı olarak gelişmiş bir ESA yaklaşımı sunmuştur (Zhang ve diğ., 2020). Zhao ve arkadaşları derin ESA yaklaşımına dayalı olarak planet dişli mekanizmasındaki rulmanların arızasını teşhis etmiştir (Zhao ve diğ., 2019). Hoang ve Kang ESA ve titreşim görüntüsü kullanarak rulmanlarda arıza teşhisi yapmıştır (Hoang ve Kang, 2019). Xu ve arkadaşları geliştirilmiş çok ölçekli bir ESA yaklaşımı ile öznitelik çıkarım mekanizmasına dayalı olarak rulmanlarda azıra teşhisi yapmıştır (Xu ve diğ., 2021). Li ve arkadaşları derin öğrenme ve ESA teknikleri ile bir öznitelik füzyonu metodu kullanarak rulmanlarda arıza teşhisi yapmıştır (Li, H. ve diğ., 2019). Kumar ve arkadaşları dalgacık dönüşümüne dayalı bir ESA yaklaşımı kullanarak rulman kusurunun boyutlarının değerlendirmesini yapmıştır (Kumar ve diğ., 2020). Xiong ve arkadaşları dalgacık paket dönüşümünü ESA yapısına entegre ederek makaralı rulmanlar için yeni bir uçtan uca arıza teşhis yaklaşımı geliştirmiştir (Xiong ve diğ., 2020). Islam ve Kim dalgacık paket dönüşümü ve ESA yaklaşımının iki boyutlu temsilini kullanarak otomatik bir rulman arıza teşhis şeması önermiştir (Islam ve Kim, 2019). Shao ve arkadaşları modifiye edilmiş ESA ve termal görüntüler kullanarak farklı çalışma koşulları altında rotor ve rulman sistemlerinin akıllı arıza teşhisine yönelik bir yaklaşım geliştirmiştir (Shao ve diğ., 2020). She ve Jia üstel olarak azalan öğrenme

oranına sahip çok kanallı bir ESA yaklaşımına dayalı olarak rulmanlı yatakların aşınma yapısını göstermiştir (She ve Jia, 2019). Ma ve arkadaşları iki boyutlu görüntü temsili kullanarak transfer öğrenme ve ESA yaklaşımına dayalı olarak yeni bir rulman arıza teşhisi yöntemi önermiştir (Ma ve diğ., 2019). Cheng ve arkadaşları çoklu arıza davranışları altında rulmanların kalan faydalı ömrünün tahmini için aktarılabılır ESA tabanlı bir yaklaşım önermiştir (Cheng ve diğ., 2021). Guo ve arkadaşları rulmanlarda arıza teşhisi ve lokalizasyonu için enformasyon füzyonuna dayalı çok görevli bir ESA yaklaşımı önermiştir (Guo ve diğ., 2019). Wu ve arkadaşları yarı denetimli bir ESA yöntemi ile rulmanlarda arıza teşhisi yapmıştır (Wu ve diğ., 2021). Schwendemann ve arkadaşları rulmanlarda arıza sınıflandırması için en güncel durumu ele almış ve taşıma makinelerindeki rulmanlara yönelik durum değerlendirmesi yapmıştır (Schwendemann ve diğ., 2021).

Arıza teşhisi çalışmalarında, ideal öznelikleri belirlemek için öznelik uzayı üzerinde farklı öznelik seçim teknikleri gerekmekte ve klasik sınıflandırma algoritmalarında özellik uzayındaki özneliklerin sayısı, çeşitli hataları beraberinde getirmektedir. Dolayısıyla, derin öğrenme yöntemleri bu zorluğu ortadan kaldırmaktadır ayrıca sınırlı veri olması durumunda da başarılı sonuçlar vermektedir (Karabacak ve diğ., 2020; Yamashita ve diğ., 2018). Her ne kadar derin öğrenme yaklaşımının kullanımında veri sayısının fazla olması ve geçmiş öğrenme bilgisi gerekse de, gelecekte de işlemci kapasitesi yüksek bilgisayarlar vasıtasıyla, derin öğrenme yöntemindeki eksikliklerin üstesinden gelineceği düşünülmektedir. Bu çalışmada CWRU titreşim verilerinden (Randall, 2021) arıza teşhisi yapabilmek amacıyla sağlıklı rulmanların (SR) ve rulman arızalarının (dış bilezik arızası-AR1, iç bilezik arızası-AR2, yuvarlanma arızası-AR3) tespiti için bir derin öğrenme yöntemi olan evrişimli sinir ağları (ESA) kullanılmıştır. Literatürde ilk kez birbirinden farklı mimariye sahip ESA yaklaşımları ağ yapısı ve eğitim süresi açısından değerlendirilmiştir. Ham titreşim verilerine Kısa Zamanlı Fourier Dönüşümü uygulandıktan sonra spektrogramları elde edilmiştir. Bu spektrogram görüntüleri ile farklı ağlar eğitilmiştir. GoogleNet, ResNet-50, EfficientNet-B0 ve AlexNet yaklaşımlarının sonuçları ağ yapısı ve eğitim süresi açısından değerlendirilmiştir. Sonuçlar doğruluk ve performans değerleri açısından karşılaştırmalı olarak ve literatürdeki benzerleri ile kıyaslamalı olarak sunulmuştur.


Çalışmanın devamı rulman arızalarının ve veri setinin tanıtıldığı Materyal ve Yöntem başlığı ile sürdürülmüştür. Bu bölümde Kısa zamanlı Fourier Dönüşümü ve Evrişimli Sinir Ağları tanıtılmıştır. Üçüncü bölümde zaman ve frekans analizlerine ait bulgular farklı değerlendirme kriterleri açısından sunulmuştur. Ayrıca CWRU (Randall, 2021) rulman titreşim verileri kullanılan çalışmalar ile sonuçlar kıyaslamalı şekilde verilmiştir. Son olarak dördüncü bölümde çalışmanın sonuçları açık bir şekilde ifade edilmiştir.

MATERYAL ve YÖNTEM (MATERIAL and METHOD)

Rulman Arızaları (Bearing Faults)


Rulmanlar, makinelerin yüksek hızlarda verimli çalışmasını ve ağır yükleri güvenli bir şekilde taşımasını sağlayan hassas bir şekilde üretilmiş makine elemanlarıdır. Birçok farklı tip ve boyutta rulman standart olarak hassas ve titiz bir işçilikle üretilmektedir. Yapılan bir çok çalışmada rulmanlı yataklardaki titreşim mekanizması açıklamıştır (Al Shorman ve diğ., 2020; Gupta ve Pradhan, 2017). Sağlıklı çalışan bir rulmanda bile titreşimler oluşur, titreşim seviyelerinin artışı bir arızanın varlığı ile açıklanabilir. Yüzey yorgunluğu, adhezyon veya abrazyon aşınması, plastik deformasyon, korozyon, zayıf ya da yanlış yağlama, hatalı montaj ve uygunsuz tasarım gibi çok sayıda faktör rulmanların erkenden arızalanmasına neden olabilir. Arızaların yol açtığı titreşim miktarının tespit edilmesi ve onu yaratan arızaların belirlenmesi rulmanların durum izleme çalışmalarında araştırılan en önemli konulardır.

Şekil 1’de, en çok kullanılan rulman türlerinden biri olan sabit bilyalı rulmanın temel boyutları ve elemanları gösterilmektedir. Sabit bilyalı rulman, iç bilezik, dış bilezik, bilyeler (yuvarlanan elemanları) ve kafesten oluşur. Burada OD dış bilezik çapı; D adım çapı; ID iç çap veya delik çapı; d yuvarlanma elemanı çapı; W kanal genişliği ve α ise temas açısıdır (Nguyen-Schäfer, 2016).



Şekil 1. Rulman elemanları ve temel boyutlar
Figure 1. Bearing components and basic dimensions

Bu çalışmada, Case Western Reserve Üniversitesi (CWRU), ABD'den Randall'ın rulman titreşim verileri kullanılmıştır (Randall, 2021). Veri setinin elde edildiği deney düzeneği Şekil 2'de sunulmuştur. Düzenek üzerinde 2 hp elektrik motorunun döndürdüğü bir mil bulunmaktadır. Mile monte edilmiş bir tork dönüştürücü ve enkoder yer alır. Dinamometre ve elektronik kontrol sistemi ile mile tork uygulanmaktadır. Testler için, tahrik ve fan yatağı rulmanlarına 0,18 ila 0,71 mm arasında değişen çaplarda hatalar (SKF sabit bilyalı rulmanlar: sırasıyla 6205-2RS JEM ve 6203-2RS JEM) elektro-deşarj işleme (EDM) yöntemi ile işlenmiştir. Farklı durumlar için 161 adet veri seti oluşturulmuştur. Tüm veriler için mil dönüş hızı 6 rad/s'dir. Örnekleme frekansı ise 48000 örnek/s'dir. Sinyal uzunluğu her bir rulman için 200000 örnektir (Randall, 2021; Smith ve Randall, 2015). Deney düzeneği ve veri setlerine ait daha fazla detaya CWRU Rulman Veri Merkezi web sitesinden erişilebilir (CWRU Rulman Veri Merkezi Web sitesi.). CWRU veri seti içerisinde 1 sağlıklı ve 3 arızalı rulmana ait (6203-2RS) titreşim verileri seçilmiştir. Bunlar SR (sağlıklı rulman), AR1 (dış bilezik arızası), AR2 (iç bilezik arızası) ve AR3 (yuvarlanma elemanı arızası) olarak gösterilmiştir. Bu veriler seçilen dört farklı durum için [200000x1] boyutundadır. Çizelge 1'de, test rulmanlarının temel boyutları gösterilmektedir. Şekil 3 sağlıklı ve arızalı rulmanlara ait temsili görsellerdir.



Şekil 2. Rulman deney düzeneği (Smith ve Randall, 2015)
Figure 2. Bearing test setup (Smith and Randall, 2015)

Çizelge 1. Deney rulmanlarının temel boyutları (Smith ve Randall, 2015)*Table 1. Basic dimensions of test bearings (Smith and Randall, 2015)*

Sembol	Açıklama	Değer
D	Adım çapı	38.5 [mm]
ID	İç bilezik çapı	25 [mm]
OD	Dış bilezik çapı	52 [mm]
d	Yuvarlanma elemanı çapı	7.12 [mm]
W	Kanal genişliği	15 [mm]
n	Yuvarlanma elemanlarının sayısı	12 [-]
α	Kontak açısı	0 [°]
f_s	Rulman dönüş hızı	6 [Hz]



Şekil 3. Sağlıklı ve arızalı rulman gösterimleri (Skf Rulman Kataloğu) SR (sağlıklı rulman), AR1 (dış bilezik arızası), AR2 (iç bilezik arızası), AR3 (yuvarlanma elemanı arızası)

Figure 3. Healthy and faulty bearing representations (Skf Rolling Bearings) SR (healthy), AR1 (outer race fault), AR2 (inner race fault), AR3 (Rolling element fault)


Rulmandaki bilye (yuvarlanma elemanı) çalışma sırasında iç veya dış yuvadaki yerel bir arızaya çarptığında, dış bilezik bilye geçiş frekansı (BPFO), iç bilezik bilye geçiş frekansı (BPFI), temel dizi frekansı (FTF) ve bilye spin frekansı (BSF) gibi rulman arıza frekanslarından birine bağlı olarak özel bir darbe sinyali (pals) çıkar (Kim ve diğ., 2020). Frekans spektrumunda görülen bu sinyal arızanın türü hakkında bilgi verir.

Metodoloji (Methodology)

Bir makineye ait rulmandan gelen titreşim verilerinin analizinde zamana dayalı analiz yöntemleri, frekans alanı yöntemleri ve zaman-frekans alanı analizinin bir kombinasyonuna dayanır. Zaman alanı analizi, sistemin titreşim seviyelerindeki genel artıştaki eğilimleri tespit etmek için kullanışlıdır. Ancak bu analiz arızanın türünü tespit edebilmek için yetersiz kalabilmektedir. Bu nedenle frekans alanı analizi veya zaman-frekans analizi yapılması faydalı olacaktır (Mohd Ghazali ve Rahiman, 2021). Bu doğrultuda bu çalışmada zaman-frekans analizine dayalı olarak ham titreşim verilerine kısa zamanlı Fourier Dönüşümü (KZFD) uygulanmıştır. Bu KZFD uygulanan rulmanlara ait spektrogram görüntüleri elde edilmiştir. Ele alınan her bir veri setine ait spektrogramlar görüntü olarak kaydedildikten sonra derin öğrenme algoritması için veri seti olarak kullanılmıştır.

Kısa Zamanlı Fourier Dönüşümü (KZFD) ve Titreşim Sinyallerinin Spektrogramları (Short-Time Fourier Transform and Vibration Signals Spectrograms)

Kısa Zamanlı Fourier dönüşümü (KZFD), zaman içinde değişen sinyalin yerel bölümlerinin sinüzoidal frekansını ve faz içeriğini belirlemek için kullanılan Fourier temelli bir dönüşümdür. Uygulamada, KZFD, uzun bir zaman sinyalini eşit uzunlukta daha kısa parçalara ayırarak her kısa parça üzerinde ayrı ayrı Fourier dönüşümünün hesaplanması ile elde edilir (Şekil 4). Bu, her kısa segmentteki Fourier spektrumunu ortaya çıkarır ki buna spektrogram adı verilir. Spektrogramda, değişen spektrumlar zamanın bir fonksiyonu olarak çizilir. Bu ifadeye işaretin (sinyalin) spektrogramı adı verilir (Sharma ve Parey, 2017).



Şekil 4. Kısa Zamanlı Fourier Dönüşümü (Jeon ve diğ., 2020)

Figure 4. Short-Time Fourier Transform (Jeon et al, 2020)

Sürekli zaman durumunda, KZFD işlemi uygulanırken sinyal bir pencere fonksiyonu ile çarpılır (Eşitlik 1). Burada, $x(t)$ zaman sinyalini, $p(t)$ pencere fonksiyonunu, τ zaman eksenini ve ω frekansı göstermektedir. $X(t)$ ise $x(t)$ 'nin Fourier dönüşümüdür, sinyalin zaman ve frekans üzerinden fazını ve büyüklüğünü temsil eden karmaşık bir fonksiyon olarak dikkate alınır (Vashisht ve Peng, 2018).

$$KZFD \{x(t)\}(\tau, \omega) = \int_{-\infty}^{+\infty} x(t) p(t - \tau) e^{-j\omega t} dt \quad (1)$$

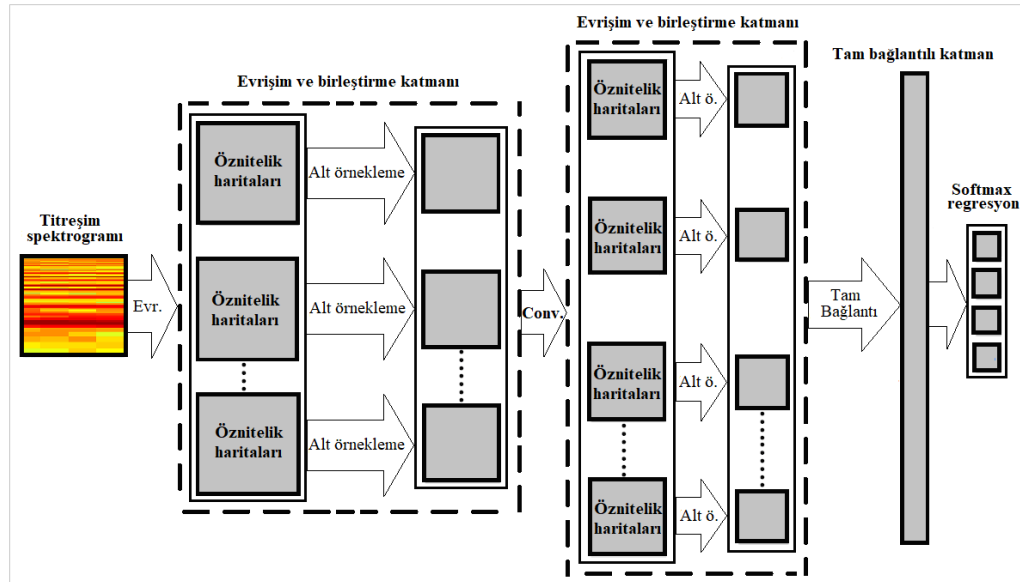
Ayrık zaman durumu için KZFD, Eşitlik 2'deki gibi hesaplanmaktadır. Burada $x[n]$ ayrık sinyali, $p[n]$ pencere fonksiyonunu, m ve n ise ayrık durum için zaman aralıklarını temsil etmektedir. Buna göre, KZFD fonksiyonunun spektrogramı Eşitlik 3'de gösterildiği gibi hesaplanır (Vashisht ve Peng, 2018).

$$KZFD \{x[t]\}(m, \omega) = X(m, \omega) = \sum_{-\infty}^{+\infty} x[n] p[n - m] e^{-j\omega n} \quad (2)$$

$$Spektrogram \{x[t]\}(m, \omega) = |X(m, \omega)|^2 \quad (3)$$

Evrişimli Sinir Ağları (ESA) (Convolutional Neural Networks (CNN))

Evrişimli sinir ağı (ESA-CNN veya ConvNet), yapay sinir ağlarının özel bir alt sınıfı olup, çoğunlukla görüntüler üzerinden analizler gerçekleştirilmektedir. En çok kullanılan derin öğrenme türlerinden olan ESA'lar, çok katmanlı algılayıcıların belli bir düzende geliştirilmiş şeklidirler. Çok katmanlı algılayıcılarda bir katmandaki her nöron bir sonraki katmandaki tüm nöronlara bağlıdır. ESA da, evrişimsel ve alt örnekleme katmanlarından oluşur. Bu katmanların her birinin belirli bir topografik yapısı vardır ve her katman farklı nöron kümeleri içerir. Her nöron, önceki katmanlardaki nöronlarla da bağlantılıdır. Şekil 5'te, giriş, evrişim, alt örnekleme katmanları, öznelik haritaları, tam bağlantılı katmanı ve softmax regresyondan (son aşama) oluşan tipik bir ESA mimarisi sunulmuştur. Evrişimsel ve alt örnekleme katmanları, hesaplama süresini azaltmak için özel bir şekilde düzenlemiştir (Chen ve diğ., 2015). ESA algoritması kullanıldığı durumda rulman arızası ile ilgili özneliklerin ayrıca çıkarılması gerekmez. Programın kendi içerisinde seçmiş olduğu özneliklere bağlı olarak daha iyi sonuçlar elde edilebilir ve bu sayede işlem yükü azaltılabilir. ESA, yerel ağırlık paylaşımı yoluyla ağ parametrelerinin sayısını azaltma ve örnek sayısı yetersiz olduğu durumda ağı aşırı uyum göstermesini önleme yeteneğine de sahiptir (Chen ve diğ., 2019).



Şekil 5. Tipik ESA mimarisi

Figure 5. Typical architecture of CNN

Evrişimsel katmanlar bir dizi filtreden oluşur. Bu filtreler, bir önceki katmandan gelen girdileri bir dizi ağırlıkla çarpar ve öznelik haritası adı verilen bir çıktı oluşturur. Filtrelerdeki nöronlar giriş veri noktalarına bağlanır ve bu noktalar ağırlıklarla çarpılır. Aynı filtredeki tüm nöronlar ağırlıklarını paylaştığından, ESA'nın optimizasyon süresi ve karmaşıklığı azalır (Yamashita ve diğ., 2018).

Eğer evrişim katmanına girişin $X \in R^{A \times B}$ olduğu varsayılırsa, katman çıkışı Eşitlik 4'deki gibi hesaplanır. Burada, A ve B giriş verisinin boyutları, $*$ evrişim operatörü, E_n evrişim katmanının n 'inci öznelik haritası, X giriş verisi matrisi, W_n aktüel katmanın n 'inci filtresinin ağırlık matrisi, b_n n 'inci sapma ve f sonuca uygulanan ve lineer olmayan aktivasyon fonksiyonudur (Jing ve diğ., 2017).

$$E_n = f(X * W_n + b_n) \quad (4)$$

Birleştirme katmanları evrişim katmanlarının ardından gelir ve alt örnekleme yaparak ağız özneteliklerinin ve parametrelerinin boyutunu azaltır. Aktivasyon istatistiklerini hesaplayan üç farklı birleştirme işlevi vardır: maksimum birleştirme, ortalama birleştirme ve ağırlıklı birleştirme. Bunlar arasında maksimum birleştirme, ESA mimarisinde en çok tercih edilen fonksiyondur (Sun, M. ve diğ., 2017). F birleştirme bloğu boyutu ve $E_n \in F$ olmak üzere birleştirme katmanının çıkışı G_n olarak ifade edilirse, maksimum birleştirme aktivasyonu Eşitlik 5'deki gibi yazılır (Jing ve diğ., 2017).

$$G_n = \max E_n \quad (5)$$

Son olarak, tam bağlantılı katman, evrişim ve birleştirme katmanlarının kombinasyonlarını takip eder. Tam bağlı katman, geleneksel yapay sinir ağlarına benzemektedir. Bu nedenle farklı sınıflandırma problemlerine uygulanabilir. Hızlı ve doğru sonuçlar elde etmek için son katman olarak bir gizli katman ve softmax regresyonu seçilmiştir. Bu çalışmada, sağlıklı ve arızalı olan farklı rulmanlar sınıflandırıldığından, softmax regresyonunun çıkışı Eşitlik 6'daki gibi ifade edilebilir. Burada H sınıf etiketinin numarası, W_j ağırlık matrisi, b_j sapma, R ise sınıflandırma işleminin nihai sonucudur (Jing ve diğ., 2017).

$$R = \begin{bmatrix} G(y=1|x; W_1, b_1) \\ G(y=2|x; W_2, b_2) \\ \dots \\ G(y=H|x; W_H, b_H) \end{bmatrix} = \frac{1}{\sum_{j=1}^H \exp(W_j x + b_j)} \begin{bmatrix} \exp(W_1 x + b_1) \\ \exp(W_2 x + b_2) \\ \dots \\ \exp(W_H x + b_H) \end{bmatrix} \quad (6)$$

Modifiye Edilmiş Ön Eğitimli ESA'lar ile Rulmanlarda Arıza Teşhisi (Diagnostics of Bearings with Modified Pretrained CNNs)

Ön eğitimli ve öznetelik çıkarmayı öğrenmiş bir ESA modifiye edilerek yeni sınıflandırma problemlerine uygulanabilir. Bu şekilde bir ağı eğitmek için gereken zaman ve harcanacak çaba sıfırdan bir ağı eğitmek için gerekenden çok daha azdır (Hao ve diğ., 2021). Bu çalışmada rulman arızalarının teşhisi için ön eğitimli ESA'lar kullanılmıştır. Çizelge 2'de bu ESA'lara ait özellikler verilmiştir.

ESA yöntemlerinde genellikle büyük boyutlu görsel veri kullanıldığında yüksek performans gösterdiği anlayışı hakimdir. Ancak sınırlı veri olması durumunda da derin öğrenmeden yararlanmak mümkündür. Bunun için ince ayar yapma, veri boyutlarını büyütme veya farklı bir kayıp fonksiyonu seçme gibi işlemler yapılır ve ESA'nın performansı iyileştirilebilir (Karabacak ve diğ., 2020; Yamashita ve diğ., 2018). Bu çalışmada kullanılan ön eğitimli ESA'ların performansının iyileştirilmesi için öncelikle ince ayar ile ağ parametreleri güncellenmiş ve ham verilere veri büyütme işlemi uygulanmıştır. Çizelge 3'de seçilen ESA yaklaşımlarına ait diğer parametrelerle ilgili bilgiler verilmiştir. Veriler %50 eğitim, %25 doğrulama ve %25 test verisi olacak şekilde standart gruplandırılmıştır. Doğrulama frekansı 5 Hz ve öğrenme oranı 0,001 olarak seçilmiştir.


Çizelge 2. Modifiye edilmiş ön eğitilmiş ESA'ların özellikleri*Table 2. Characteristics of modified pretrained CNNs*

	<i>GoogleNet</i>	<i>ResNet-50</i>	<i>AlexNet</i>	<i>EfficientNet-B0</i>
Katman derinliği	22	50	8	82
Katman sayısı	144	177	25	290
Bağlantı sayısı	170	192	24	362
Giriş tipi	Görüntü	Görüntü	Görüntü	Görüntü
Giriş boyutu	224x224x3	224x224x3	227x227x3	224x224x3
Çıkış tipi	Sınıflandırma	Sınıflandırma	Sınıflandırma	Sınıflandırma
Çıkış boyutu	4	4	4	4
Ağırlık öğrenme oranı faktörü	10	10	10	10
Sapma öğrenme oranı faktörü	10	10	10	10
Kayıp Fonksiyonu	Çapraz entropi	Çapraz entropi	Çapraz entropi	Çapraz entropi

Eğitim sürecinin akış şeması Şekil 6'da verilmiştir. Buna göre SR, AR1, AR2 ve AR3 için titreşim sinyallerine ait spektrogramlar ayrı ayrı elde edilmiştir. Her bir rulman için elde edilen veriler eğitim, test ve doğrulama olmak üzere üç gruba ayrılmıştır. ESA çıkışları sağlıklı ve arızalı rulmanları sınıflandırmak için değiştirilmiştir. Eğitim ve doğrulama verileri kullanılarak ESA eğitilmiş ve derin özniteliklere göre sınıflandırma yapılmıştır. Son olarak, eğitilen ağ test edilmiş ve veri etiketlerine göre arıza teşhisi yapılmıştır.

Çizelge 3. Farklı ESA'lar için parametreler*Table 3. Parameters for different CNNs*

	Giriş Veri Tipi				Arıza Tipi
	Titreşim Spektrogramları				
	GoogleNet	ResNet-50	AlexNet	EfficientNet-B0	SR
Doğrulama frekansı	5 Hz				AR1
Öğrenme oranı	0.001				AR2
Maksimum epok	5				
Mini gurup boyutu	10				AR3
Giriş verisi çözünürlüğü	1458 x 718 piksel				



Şekil 6. ESA tabanlı rulman arıza teşhisi yaklaşımı ve eğitim sürecinin akış şeması

Figure 6. CNN based approach to bearing diagnostics and flowchart of the training process

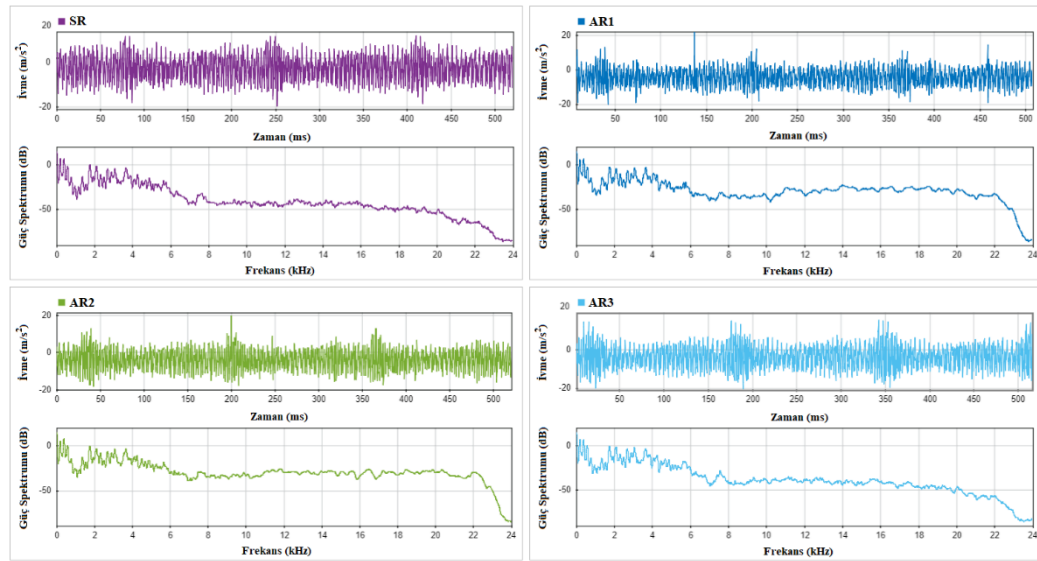
Çalışmaya ait tüm analiz ve hesaplamalar Intel Core i7-3630QM, 2.40 GHz işlemci ve 16.0 GB ram belleğe sahip bir bilgisayarda MATLAB (2021-b) programı ile gerçekleştirilmiştir. Matlab programı kullanılarak ESA'ların eğitimi gerçekleştirilmiştir. Programın içeriğindeki derin öğrenme araç kutusu yardımıyla ön eğitilmiş ESA'lar modifiye edilebilir, eğitilebilir ve görüntü, zaman serisi veya metin gibi veriler kullanılarak sınıflandırma ya da regresyon analizi gerçekleştirilebilmektedir (Matlab, Derin Öğrenme Araç Kutusu).

BULGULAR ve TARTIŞMA (FINDINGS and DISCUSSION)

Titreşim Sinyallerinin Zaman ve Frekans Analizi (Time and Frequency Analysis of Vibration Signals)

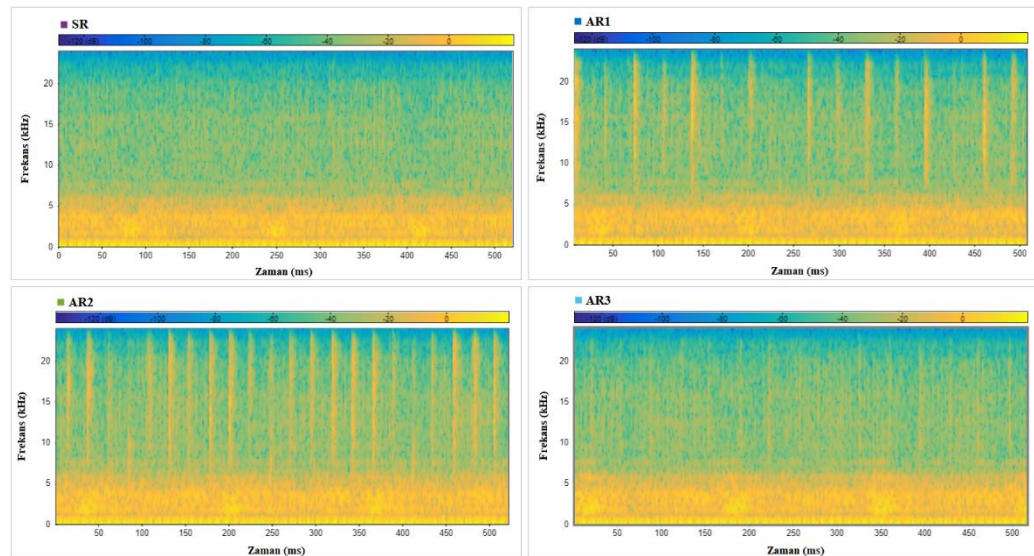
SR, AR1, AR2 ve AR3 rulmanlarından elde edilen titreşim sinyallerinin zaman ve frekans bölgesindeki gösterimleri Şekil 7'de verilmiştir. Buna göre SR rulmanının titreşim genlikleri arızalı rulmanlara göre daha düşüktür. En yüksek titreşim genlikleri AR1 (dış bilezik arızası) rulmanında gözlemlenmiştir. Her bir rulman tipi için güç spektrumun değerleri birbirine yakın görünmektedir.

Şekil 8'de, herbir rulman veri grubunun spektrogramları yani zaman-frekans dağılımları görülmektedir. Özellikle AR1 (dış bilezik arızası) ve AR2 (iç bilezik arızası) rulmanlarının frekans bileşenlerinin periyodik değişimleri belirgindir. AR3 (yuvarlanma elemanı arızası) rulmanının frekans bileşenlerinin zamanla değişimi belirgin değildir. Rulman arızalarının spektrogramlarından çıplak gözle anlam çıkarmak kolay değildir. Bu görüntüler ESA'ya ham veri olarak girilir ve program içerisinde uygun özellikler belirlenerek, işlem adımları gerçekleştirildikten sonra doğru sınıflandırma sonuçları elde edilir.



Şekil 7. Seçilen SR, AR1, AR2 ve AR3 veri setlerinin zaman ve frekans analizi

Figure 7. Time and frequency analysis of selected of datasets of healthy and faulty bearings



Şekil 8. Seçilen SR, AR1, AR2 ve AR3 veri setlerinin spektrogramları

Figure 8. Spectrograms of selected datasets of healthy and faulty bearings

Farklı ESA Yaklaşımları ile Arıza Teşhisi Sonuçları (Diagnostic Results with Different CNN Approaches)

Bu çalışmada ön eğitilmiş ESA yaklaşımları rulmanlarda arıza teşhisi problemine uygun hale getirilmiş ve titreşim verilerinden elde edilen spektrogram görüntüleri ile eğitilmiştir. Eğitim süresi boyunca doğrulama başarısı, kayıp ve gradyan değerleri hesaplanmış, ağırlıklar güncellenmiş ve yaklaşımların sonuçları analiz edilmiştir. Daha sonra, test için ayrılan veri seti ile test edilen ESA'ların başarıları birbiri ile karşılaştırılmıştır. Bunun yanında, farklı sayıdaki görsel veri ile eğitilip sonuçları analiz edilen ESA modelleri birbiriyle kıyaslanmıştır.

ESA modelleri için hedef, sağlıklı ve arızalı rulmanları tespit etmektir. Çizelge 4, rulmanların sınıf etiketlerini ve farklı ESA modellerinin eğitimi, doğrulanması ve test edilmesi için kullanılan örnek sayılarını göstermektedir.

Çizelge 4. ESA modelleri için sınıf etiketleri ve örnek sayısı*Table 4. Class labels and sample size for CNN models*

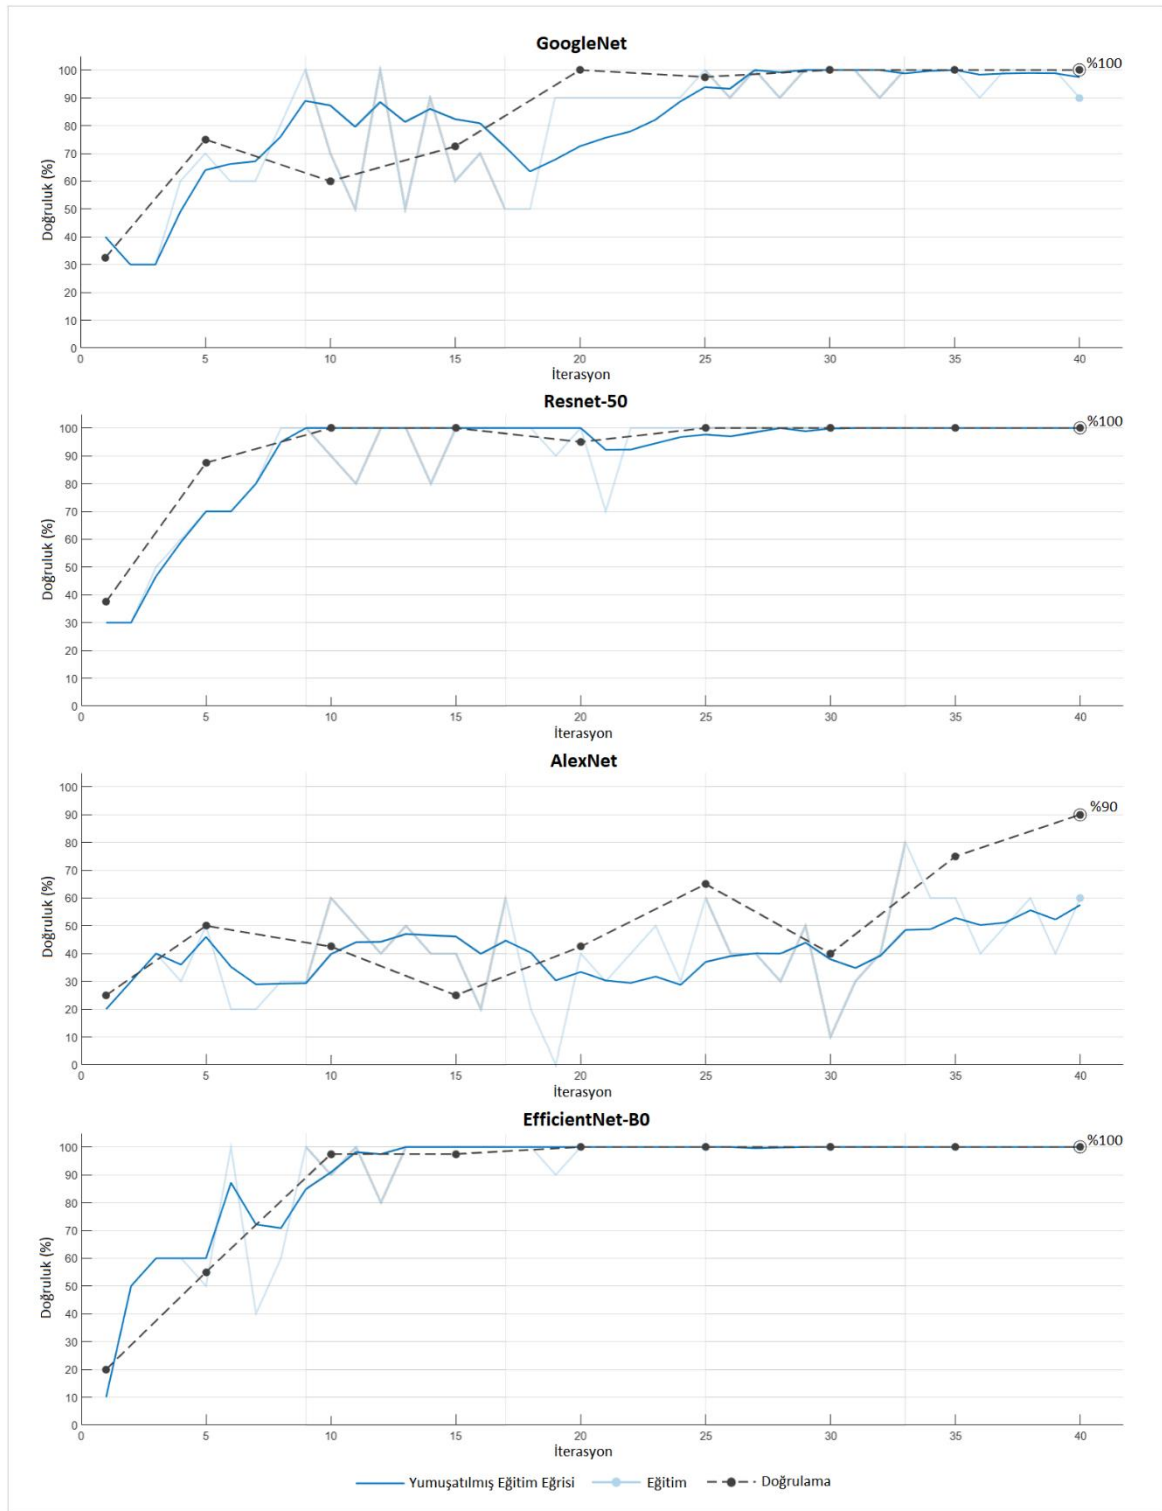
Sınıf Etiketi	Eğitim Verisi Sayısı	Doğrulama Verisi Sayısı	Test Verisi Sayısı
SR	24	8	8
AR1	24	8	8
AR2	24	8	8
AR3	24	8	8

Şekil 9, farklı ESA modelleri için doğruluk oranlarını göstermektedir. Buna göre GoogleNet, ResNet-50 ve EfficientNet-B0 yaklaşımları eğitim süreci sonunda %100 doğrulama oranına ulaşmıştır. AlexNet yaklaşımı ise %90 doğrulama oranına ulaşabilmiştir. EfficientNet-B0 ve Resnet-50 yaklaşımlarının katman ve bağlantı sayısı yüksek olduğundan ulaşılan doğruluk oranları da daha yüksek çıkmıştır. Ancak daha derin yaklaşımlarda eğitilecek parametre sayısı da artacağından eğitim süreci de uzun olmaktadır. Diğer tüm şartlar aynı kalmak koşulu ile ESA mimarisinde karmaşıklığın artışı doğruluk oranını olumlu etkilerken eğitim süresini de arttırmaktadır. AlexNet yaklaşımında eğitilecek parametre sayısı diğer ESA yaklaşımlarından daha az olduğu için eğitim süresi kısa sürmüştür ve 5 epok sonrasında %90 doğrulama oranına ulaşılmıştır. ResNet-50 ve EfficientNet-B0 yaklaşımlarının eğitim sürecinde ilk epokta yüksek bir doğruluk oranına ulaştığı görülmektedir. Bunun yanında, AlexNet ve GoogleNet yaklaşımlarının üçüncü veya dördüncü epok sonucunda doğrulama oranının ciddi bir şekilde arttığı da görülmektedir.

Şekil 10, farklı ESA yaklaşımları için eğitim ve doğrulama süreçlerindeki kayıpları göstermektedir. Kayıplar, tahmin edilen çıktı ile gerçek çıktı arasındaki farkın nicel bir ölçüsüdür ve yineleme sayısı ile azalır. Yaklaşımlara ait kayıp değerleri eğitim süresi boyunca doğrulama oranlarının değişimine bağlı olarak zamanla azalmıştır. Bunun yanında mimari olarak daha karmaşık olduğu ve büyük ESA yaklaşımlarının ilk epoklarda oldukça düşük kayıp değerlerine ulaştığı görülmektedir. GoogleNet, ResNet-50 ve EfficientNet-B0 yaklaşımlarına ait kayıplar eğitim süreci sonunda tamamen sıfırlanmıştır. AlexNet yaklaşımında ise %10 kayıp oranına kadar inilmiştir.

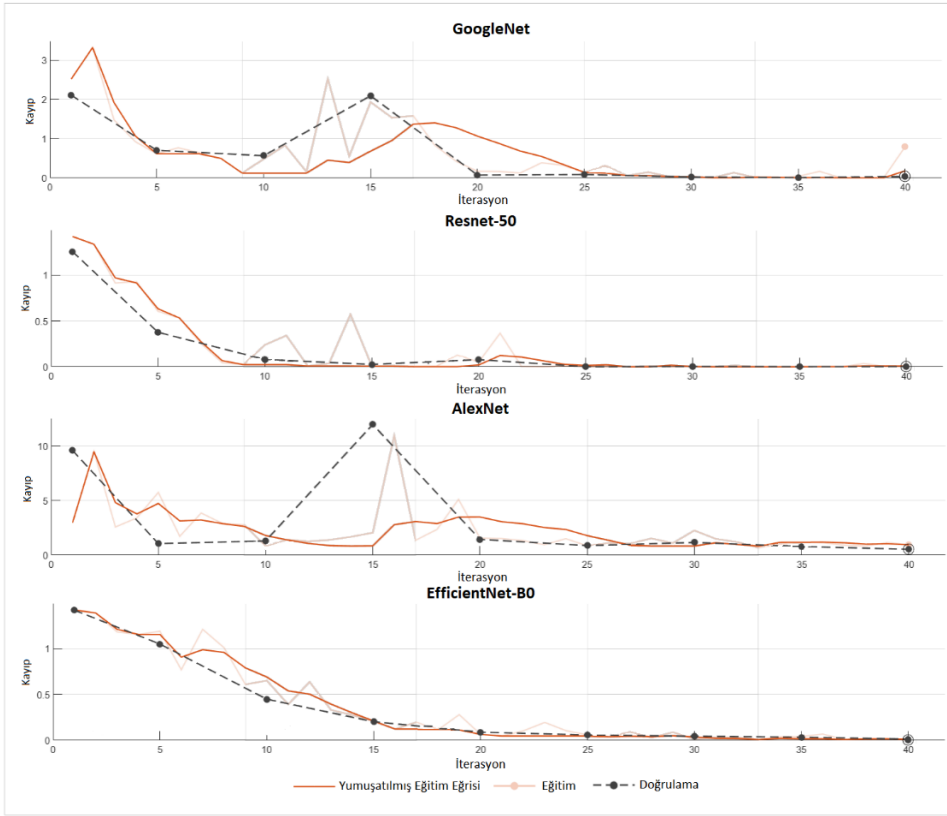
Farklı ESA yaklaşımlarına ait karışıklık matrisleri Şekil 11'de verilmiştir. Rulmanlardan toplanan spektrogram örneklerinin eğitim, doğrulama ve test oranları %50, %25 ve %25 olarak alınmıştır. Hata matrisi veya karışıklık matrisi, tipik olarak denetimli öğrenme algoritması olan bir algoritmanın performansının görselleştirilmesine izin veren belirli bir tablo düzenidir. Bu tabloda matrisin her satırı tahmin edilen bir sınıftaki örnekleri temsil ederken, her sütun gerçek bir sınıftaki örnekleri temsil eder. Çapraz hücreler ise doğru şekilde sınıflandırılan değerleri ifade etmektedir. Diğer yandan, çapraz olmayan hücreler de yanlış sınıflandırılmış gözlemleri göstermektedir. Her bir hücreye ait gözlem sayısı ve toplam gözlem sayısının yüzdesi verilmiştir. Buna göre ResNet-50 ve EfficientNet-B0 yaklaşımlarının test başarı oranlarının %100 olduğu görülebilir. Diğer taraftan, GoogleNet yaklaşımının test başarı oranı %96.9 ve AlexNet yaklaşımının test başarı oranı %93.8 olarak gerçekleşmiştir.

Çizelge 5, farklı sayıda örnekle eğitilmiş ve test edilmiş ESA yaklaşımlarının başarı oranlarını göstermektedir. Buna göre, örnek sayısı arttıkça tüm ESA yaklaşımlarının doğrulama ve test doğruluk oranları ve eğitim süreleri artmaktadır. Resnet-50 ve EfficientNet-B0 gibi daha karmaşık mimariye sahip ESA'ların eğitim süresinin daha uzun olduğu çizelgeden görülmektedir.



Şekil 9. Farklı ESA modelleri için doğruluk oranları

Figure 9. Accuracies for different CNN models



Şekil 10. Farklı ESA yaklaşımları için kayıplar
Figure 10. Losses for different CNN approaches

		GoogleNet					ResNet-50				
Çıkış Sınıfı	AR1	8 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	8 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	AR2	0 0.0%	7 21.9%	0 0.0%	0 0.0%	100% 0.0%	0 0.0%	8 25.0%	0 0.0%	0 0.0%	100% 0.0%
	AR3	0 0.0%	0 0.0%	8 25.0%	0 0.0%	100% 0.0%	0 0.0%	0 0.0%	8 25.0%	0 0.0%	100% 0.0%
	SR	0 0.0%	1 3.1%	0 0.0%	8 25.0%	88.9% 11.1%	0 0.0%	0 0.0%	0 0.0%	8 25.0%	100% 0.0%
		100% 0.0%	87.5% 12.5%	100% 0.0%	100% 0.0%	96.9% 3.1%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
		AR1	AR2	AR3	SR	Hedef Sınıfı					
Çıkış Sınıfı	AR1	8 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	8 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	AR2	0 0.0%	7 21.9%	0 0.0%	1 3.1%	87.5% 12.5%	0 0.0%	8 25.0%	0 0.0%	0 0.0%	100% 0.0%
	AR3	0 0.0%	0 0.0%	8 25.0%	0 0.0%	100% 0.0%	0 0.0%	0 0.0%	8 25.0%	0 0.0%	100% 0.0%
	SR	0 0.0%	1 3.1%	0 0.0%	7 21.9%	87.5% 12.5%	0 0.0%	0 0.0%	0 0.0%	8 25.0%	100% 0.0%
		100% 0.0%	87.5% 12.5%	100% 0.0%	87.5% 12.5%	93.8% 6.2%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
		AR1	AR2	AR3	SR	Hedef Sınıfı					
Çıkış Sınıfı	AR1	8 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	8 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	AR2	0 0.0%	8 25.0%	0 0.0%	0 0.0%	100% 0.0%	0 0.0%	8 25.0%	0 0.0%	0 0.0%	100% 0.0%
	AR3	0 0.0%	0 0.0%	8 25.0%	0 0.0%	100% 0.0%	0 0.0%	0 0.0%	8 25.0%	0 0.0%	100% 0.0%
	SR	0 0.0%	0 0.0%	0 0.0%	8 25.0%	100% 0.0%	0 0.0%	0 0.0%	0 0.0%	8 25.0%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
		AR1	AR2	AR3	SR	Hedef Sınıfı					

Şekil 11. ESA yaklaşımlarının karışıklık matrisleri
Figure 11. Confusion matrices of CNN approaches

Çizelge 5. Örnek sayısının ESA yaklaşımlarının performansına etkisi*Table 5. Effect of sample size to the different CNNs performance*

ESA Yaklaşımları	Örnek Sayısı	Doğrulama Başarısı (%)	Test Başarısı (%)	Eğitim Süresi (s)
GoogleNet-ESA	32	75	75	29
GoogleNet-ESA	64	90	85	50
GoogleNet-ESA	128	100	100	123
ResNet-50-ESA	32	100	100	60
ResNet-50-ESA	64	100	100	125
ResNet-50-ESA	128	100	100	316
AlexNet-ESA	32	50	42	16
AlexNet-ESA	64	65	50	29
AlexNet-ESA	128	90	90	66
EfficientNet-B0-ESA	32	75	65	53
EfficientNet-B0-ESA	64	85	70	72
EfficientNet-B0-ESA	128	100	100	224

Farklı ESA Yaklaşımlarının Literatür ile Karşılaştırılması (Comparison of Different CNN Approaches with Literature)

CWRU rulman titreşim verileri literatürde pek çok kere kullanılmıştır (Randall, 2021) fakat her bir veri seti farklı yaklaşımlarla ve farklı parametrelerle ele alındığından sağlıklı ve doğru bir kıyaslama yapabilmek pek mümkün olmamaktadır. Yakın zamanda Sun ve arkadaşları sıkıştırılmış algılama ve derin öğrenme fikrinden esinlenerek, rulmanlar için yeni bir arıza tespit sistemi önermiştir (Sun, J. ve diğ., 2017). Buradan hareketle, bizim çalışmamızda kullanılan ESA yaklaşımları ile literatürdeki sonuçlara ait karşılaştırılma Çizelge 6'da verilmiştir.

Çizelge 6. Farklı ESA yaklaşımlarının literatürle karşılaştırılması*Table 6. Comparison of different ESA approaches with the literature*

ESA Yaklaşımlarının Karşılaştırılması	
Yaklaşım	Ortalama Doğrulama Başarısı
GoogleNet-ESA	1
ResNet-50-ESA	1
AlexNet-ESA	0.90
EfficientNet-B0-ESA	1
Sıkıştırma örneklemesine dayalı ESA (Sun,J. ve diğ., 2017)	0.97
Zaman bölgesi sinyaline dayalı ESA (Sun,M. ve diğ., 2017)	0.96

Görüldüğü üzere, GoogleNet-ESA, ResNet-50-ESA ve EfficientNet-B0-ESA yaklaşımlarına ait doğruluk oranları (Sun,J. ve diğ., 2017)'nin sonuçlarından daha yüksektir. Yalnızca AlexNet-ESA yaklaşımına ait ortalama doğruluk oranı literatürde daha yüksektir. Sonuçların birbirinden farklılık arz etmesinin başlıca nedeni, ESA modellerinin mimarisindeki farklılıklar ve karmaşıklık düzeyidir.

SONUÇLAR (CONCLUSIONS)

Bu çalışmada sağlam ve farklı arıza tiplerine sahip (dış bilezik arızası-AR1, iç bilezik arızası-AR2, yuvarlanma arızası-AR3) rulmanların teşhis edilmesi için ESA yönteminden faydalanılmıştır. Son yıllarda önem kazanan ESA yaklaşımları rulman arızalarının durum izleme çalışmalarında kullanılabilmesi amacıyla bu çalışmada titreşim spektrogramları üzerinde denenmiştir. Birbirinden farklı mimarilere sahip

ESA yaklaşımlarını eğitmek için kullanılan spektrogram görüntülerinden elde edilen sonuçlar karşılaştırmalı olarak incelenmiştir. Çalışmanın sonuçlarına göre daha karmaşık mimariye sahip ESA yaklaşımlarının, yani GoogleNet-ESA, Resnet-50 ve EfficientNet-B0-ESA'nın rulman arızalarını %100 doğrulukla teşhis ettikleri görülmektedir. Ancak AlexNet-ESA yaklaşımının test başarı oranı %90 olarak gerçekleşmiştir. ESA mimarisinin ağ yapısı değiştiği ve katman sayısı arttıkça eğitim süresi de uzadığından, ele alınan problemin tipine göre ESA mimarisine karar verilmelidir. Elde edilen sonuçların literatürdeki çalışmaların sonuçlarından üstün olduğu gözlenmiştir. Sonuç olarak, farklı yaklaşımlara sahip evrişimli sinir ağları yönteminin en temel rulman arıza tespitinde yüksek sınıflandırma doğruluğu sağladığı ve arıza teşhisi için umut vadeden bir yöntem olduğu görülmektedir.

KAYNAKLAR (REFERENCES)

- Al Shorman, O., Irfan, M., Saad, N., Zhen, D., Haider, N., Glowacz, A., AlShorman, A., 2020, "A review of artificial intelligence methods for condition monitoring and fault diagnosis of rolling element bearings for induction motor", *Shock and Vibration*, Cilt 2020.
- Amarath, M., Sugumaran, V., Kumar, H., 2013, "Exploiting sound signals for fault diagnosis of bearings using decision tree", *Measurement*, Cilt 46, Sayı 3, ss. 1250-1256.
- Caesarendra, W., Tjahjowidodo, T., 2017, "A review of feature extraction methods in vibration-based condition monitoring and its application for degradation trend estimation of low-speed slew bearing", *Machines*, Cilt 5, Sayı 4, ss. 21.
- Cakir, M., Guvenc, M. A., Mistikoglu, S., 2021, "The experimental application of popular machine learning algorithms on predictive maintenance and the design of IoT based condition monitoring system", *Computers & Industrial Engineering*, Cilt 151, ss. 106948.
- Chen, Z., Gryllias, K., Li, W., 2019, "Mechanical fault diagnosis using convolutional neural networks and extreme learning machine", *Mechanical systems and signal processing*, Cilt 133, ss. 106272.
- Chen, Z., Li, C., Sanchez, R. V., 2015, "Gearbox fault identification and classification with convolutional neural networks", *Shock and Vibration*, Cilt 2015.
- Cheng, H., Kong, X., Chen, G., Wang, Q., Wang, R., 2021, "Transferable convolutional neural network based remaining useful life prediction of bearing under multiple failure behaviors", *Measurement*, Cilt 168, ss. 108286.
- Choudhary, A., Shimi, S. L., Akula, A., 2018, "Bearing fault diagnosis of induction motor using thermal imaging", *2018 International Conference on Computing, Power and Communication Technologies (GUCON)*, ss. 950-955, IEEE.
- Correa, J. C. A. J., Guzman, A. A. L., 2020, *Mechanical Vibrations and Condition Monitoring*, Academic Press. CWRU Rulman Veri Merkezi web sitesi. <http://cseggroups.case.edu/bearingdatacenter/>(14.12.2022)
- Dong, S., Luo, T., Zhong, L., Chen, L., Xu, X., 2017, "Fault diagnosis of bearing based on the kernel principal component analysis and optimized k-nearest neighbour model", *Journal of Low Frequency Noise, Vibration and Active Control*, 36(4), 354-365.
- Duan, Z., Wu, T., Guo, S., Shao, T., Malekian, R., Li, Z., 2018, "Development and trend of condition monitoring and fault diagnosis of multi-sensors information fusion for rolling bearings: a review", *The International Journal of Advanced Manufacturing Technology*, 96(1), 803-819.
- Elforjani, M., Shanbr, S., 2017, "Prognosis of bearing acoustic emission signals using supervised machine learning", *IEEE Transactions on industrial electronics*, 65(7), 5864-5871.
- Eren, B., Guvenc, M. A., Mistikoglu, S., 2021, "Artificial intelligence applications for friction stir welding: A review", *Metals and Materials International*, 27(2), 193-219.
- Geitner, F. K., Bloch, H. P., 2012, *Chapter 3 machinery component failure analysis*, Machinery failure analysis and troubleshooting 4th edn. Butterworth-Heinemann, Oxford, 87-293.
- Goyal, D., Choudhary, A., Pabla, B. S., Dhama, S. S., 2020, "Support vector machines based non-contact fault diagnosis system for bearings", *Journal of Intelligent Manufacturing*, 31(5), 1275-1289.

- Guo, S., Zhang, B., Yang, T., Lyu, D., Gao, W., 2019, "Multitask convolutional neural network with information fusion for bearing fault diagnosis and localization", *IEEE Transactions on Industrial Electronics*, 67(9), 8005-8015.
- Gupta, P., Pradhan, M. K., 2017, "Fault detection analysis in rolling element bearing: A review", *Materials Today: Proceedings*, 4(2), 2085-2094.
- Hao, X., Zheng, Y., Lu, L., Pan, H., 2021, "Research on Intelligent Fault Diagnosis of Rolling Bearing Based on Improved Deep Residual Network", *Applied Sciences*, 11(22), 10889.
- Hase, A., 2020, "Early detection and identification of fatigue damage in thrust ball bearings by an acoustic emission technique", *Lubricants*, 8(3), 37.
- Hoang, D. T., Kang, H. J., 2019, "A motor current signal-based bearing fault diagnosis using deep learning and information fusion", *IEEE Transactions on Instrumentation and Measurement*, 69(6), 3325-3333.
- Hoang, D. T., Kang, H. J., 2019, "Rolling element bearing fault diagnosis using convolutional neural network and vibration image", *Cognitive Systems Research*, 53, 42-50.
- Huang, W., Cheng, J., Yang, Y., Guo, G., 2019, "An improved deep convolutional neural network with multi-scale information for bearing fault diagnosis", *Neurocomputing*, 359, 77-92.
- Islam, M. M., Kim, J. M., 2019, "Automated bearing fault diagnosis scheme using 2D representation of wavelet packet transform and deep convolutional neural network", *Computers in Industry*, 106, 142-153.
- Jeon, H., Jung, Y., Lee, S., Jung, Y., 2020, "Area-Efficient Short-Time Fourier Transform Processor for Time-Frequency Analysis of Non-Stationary Signals", *Applied Sciences*, 10(20), 7208.
- Jing, L., Zhao, M., Li, P., Xu, X., 2017, "A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox", *Measurement*, 111, 1-10.
- Karabacak, Y. E., Gürsel Özmen, N., Gümüsel, L., 2020, "Worm gear condition monitoring and fault detection from thermal images via deep learning method", *Maintenance and Reliability*, 22(3).
- Karabacak, Y. E., Özmen, N. G., 2021, "Common Spatial Pattern-based Feature Extraction and Worm Gear Fault Detection through Vibration and Acoustic Measurements", *Measurement*, 110366.
- Karabacak, Y. E., Özmen, N. G., Gümüsel, L., 2022, "Intelligent worm gearbox fault diagnosis under various working conditions using vibration, sound and thermal features", *Applied Acoustics*, 186, 108463.
- Kim, S., An, D., Choi, J. H., 2020, "Diagnostics 101: A Tutorial for Fault Diagnostics of Rolling Element Bearing Using Envelope Analysis in MATLAB", *Applied Sciences*, 10(20), 7302.
- Kumar, A., Vashishtha, G., Gandhi, C. P., Zhou, Y., Glowacz, A., Xiang, J., 2021, "Novel convolutional neural network (NCNN) for the diagnosis of bearing defects in rotary machinery", *IEEE Transactions on Instrumentation and Measurement*, 70, 1-10.
- Kumar, A., Zhou, Y., Gandhi, C. P., Kumar, R., Xiang, J., 2020, "Bearing defect size assessment using wavelet transform based Deep Convolutional Neural Network (DCNN)", *Alexandria Engineering Journal*, 59(2), 999-1012.
- Li, H., Huang, J., Ji, S., 2019, "Bearing fault diagnosis with a feature fusion method based on an ensemble convolutional neural network and deep neural network", *Sensors*, 19(9), 2034.
- Li, X., Zhang, W., Ding, Q., 2019, "Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction", *Reliability engineering & system safety*, 182, 208-218.
- Liu, Z., Zhang, L., Carrasco, J., 2020, "Vibration analysis for large-scale wind turbine blade bearing fault detection with an empirical wavelet thresholding method", *Renewable Energy*, 146, 99-110.
- Ma, P., Zhang, H., Fan, W., Wang, C., Wen, G., Zhang, X., 2019, "A novel bearing fault diagnosis method based on 2D image representation and transfer learning-convolutional neural network", *Measurement Science and Technology*, 30(5), 055402.
- Malla, C., Panigrahi, I., 2019, "Review of condition monitoring of rolling element bearing using vibration analysis and other techniques", *Journal of Vibration Engineering & Technologies*, 7(4), 407-414.
- Matlab, Derin Öğrenme Araç Kutusu, <https://www.mathworks.com/>, 20.02.2020.

- Mohd Ghazali, M. H., Rahiman, W., 2021, "Vibration Analysis for Machine Monitoring and Diagnosis: A Systematic Review", *Shock and Vibration*, Article ID 9469318.
- Nguyen-Schäfer, H., 2016, "Contact stresses in rolling bearings", *Computational Design of Rolling Bearings*, ss. 47-61, Springer, Cham.
- O'Lmasov Ahadjon Akramjon, O. G., 2020, "New approaches in the diagnosis and monitoring of rotor oscillations using shaft sensors", *Science and Education*, 1(1), 158-166.
- Peng, Y., Cai, J., Wu, T., Cao, G., Kwok, N., Zhou, S., Peng, Z., 2019, "Online wear characterisation of rolling element bearing using wear particle morphological features", *Wear*, 430, 369-375.
- Randall, R. B., 2021, "Vibration-based condition monitoring: industrial, automotive and aerospace applications", *John Wiley & Sons*.
- Ranjan, R., Ghosh, S. K., Kumar, M., 2020, "Fault diagnosis of journal bearing in a hydropower plant using wear debris, vibration and temperature analysis: A case study", *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, 234(3), 235-242.
- Rezaei, A., Dadouche, A., Wickramasinghe, V., Dmochowski, W., 2011, "A comparison study between acoustic sensors for bearing fault detection under different speed and load using a variety of signal processing techniques", *Tribology Transactions*, 54(2), 179-186.
- Sadoughi, M., Hu, C., 2019, "Physics-based convolutional neural network for fault diagnosis of rolling element bearings", *IEEE Sensors Journal*, 19(11), 4181-4192.
- Schwendemann, S., Amjad, Z., Sikora, A., 2021, "A survey of machine-learning techniques for condition monitoring and predictive maintenance of bearings in grinding machines", *Computers in Industry*, 125, 103380.
- Shao, H., Xia, M., Han, G., Zhang, Y., Wan, J., 2020, "Intelligent fault diagnosis of rotor-bearing system under varying working conditions with modified transfer convolutional neural network and thermal images", *IEEE Transactions on Industrial Informatics*, 17(5), 3488-3496.
- Sharma, V., Parey, A., 2017, "Frequency domain averaging based experimental evaluation of gear fault without tachometer for fluctuating speed conditions", *Mechanical Systems and Signal Processing*, 85, 278-295.
- She, D., Jia, M., 2019, "Wear indicator construction of rolling bearings based on multi-channel deep convolutional neural network with exponentially decaying learning rate", *Measurement*, 135, 368-375.
- Skf, Rulman Kataloğu, <https://www.skf.com/>, 19.02.2022.
- Smith, W. A., Randall, R. B., 2015, "Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study", *Mechanical systems and signal processing*, 64, 100-131.
- Sun, M., Song, Z., Jiang, X., Pan, J., Pang, Y., 2017, "Learning pooling for convolutional neural network", *Neurocomputing*, 224, 96-104.
- Sun, J., Yan, C., Wen, J., 2017, "Intelligent bearing fault diagnosis method combining compressed data acquisition and deep learning", *IEEE Transactions on Instrumentation and Measurement*, 67(1), 185-195.
- Usamentiaga, R., Venegas, P., Guerediaga, J., Vega, L., Molleda, J., Bulnes, F. G., 2014, "Infrared thermography for temperature measurement and non-destructive testing", *Sensors*, 14(7), 12305-12348.
- Vashisht, R. K., Peng, Q., 2018, "Crack detection in the rotor ball bearing system using switching control strategy and Short Time Fourier Transform", *Journal of Sound and Vibration*, 432, 502-529.
- Wu, Y., Zhao, R., Jin, W., He, T., Ma, S., Shi, M., 2021, "Intelligent fault diagnosis of rolling bearings using a semi-supervised convolutional neural network", *Applied Intelligence*, 51(4), 2144-2160.
- Xiong, S., Zhou, H., He, S., Zhang, L., Xia, Q., Xuan, J., Shi, T., 2020, "A novel end-to-end fault diagnosis approach for rolling bearings by integrating wavelet packet transform into convolutional neural network structures", *Sensors*, 20(17), 4965.
- Xu, Z., Li, C., Yang, Y., 2021, "Fault diagnosis of rolling bearings using an improved multi-scale convolutional neural network with feature attention mechanism", *ISA transactions*, 110, 379-393.

- Yamashita, R., Nishio, M., Do, R. K. G., Togashi, K., 2018, "Convolutional neural networks: an overview and application in radiology", *Insights into imaging*, 9(4), 611-629.
- Yoo, Y., Baek, J. G., 2018, "A novel image feature for the remaining useful lifetime prediction of bearings based on continuous wavelet transform and convolutional neural network", *Applied Sciences*, 8(7), 1102.
- Zhang, W., Li, C., Peng, G., Chen, Y., Zhang, Z., 2018, "A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load", *Mechanical Systems and Signal Processing*, 100, 439-453.
- Zhang, X., Zhou, J., 2013, "Multi-fault diagnosis for rolling element bearings based on ensemble empirical mode decomposition and optimized support vector machines", *Mechanical Systems and Signal Processing*, 41(1-2), 127-140.
- Zhang, Y., Xing, K., Bai, R., Sun, D., Meng, Z., 2020, "An enhanced convolutional neural network for bearing fault diagnosis based on time-frequency image", *Measurement*, 157, 107667.
- Zhao, D., Wang, T., Chu, F., 2019, "Deep convolutional neural network based planet bearing fault classification", *Computers in Industry*, 107, 59-66.
- Zhu, J., Chen, N., Peng, W., 2018, "Estimation of bearing remaining useful life based on multiscale convolutional neural network", *IEEE Transactions on Industrial Electronics*, 66(4), 3208-3216.
- Zhu, Z., Peng, G., Chen, Y., Gao, H., 2019, "A convolutional neural network based on a capsule network with strong generalization for bearing fault diagnosis", *Neurocomputing*, 323, 62-75.