

Rulman Titreşim Verilerinden Derin Öğrenme Tabanlı Arıza Tespiti

Engin OĞUZAY^{1*} , Murat BALTA² 

Öz

Rulman titreşimlerinin analizi, bir makinenin mekanik bileşenlerinin genel sağlığı hakkında bilgi sağlayabilir. Bu çalışmada, endüstride yaygın olarak kullanılan motor mekaniklerindeki kusurları tespit etmek ve üretim verimliliğini artırmak için derin öğrenme algoritmaları hem 1 boyutlu hem de 2 boyutlu veri uzaylarına entegre edilmiştir. Popüler ve kapsamlı Case Western Reserve Üniversitesi (CWRU) rulman veri kümesi kullanılarak on farklı sınıf üzerinde çalışılmıştır; bu veri kümesi üç tür hata (dış bilezik, bilye ve iç bilezik) ve sağlıklı bir sınıf içermektedir. Rulman titreşim sinyali dört şekilde ele alınmıştır: orijinal titreşim verilerinin kullanılması, orijinal verilerden özelliklerin çıkarılması, orijinal verilere STFT uygulanması ve STFT uygulanmış verilerden özelliklerin çıkarılması. KNN, SVM ve 1D WDCNN gibi makine öğrenimi yaklaşımları 1 boyutlu verilere uygulanmıştır. Ayrıca 2 boyutlu veri uzayında STFT dönüşümü uygulanmış ve EfficientNetB0, EfficientNetB1, ResNet18 ve 2D WDCNN kullanılarak farklı istatistiksel metriklerle performans ölçümleri yapılmıştır. 2 boyutlu uzayda derin öğrenme yöntemleri %100 doğruluk elde etmiştir.

Anahtar Kelimeler: Motor Yatağı Titreşimi, Derin Öğrenme, Sinyal Sınıflandırma, Endüstriyel Arıza Tanıma.

Deep Learning Based Fault Detection from Bearing Vibration Data

Abstract

Analysis of bearing vibrations can provide information on the overall health of a machine's mechanical components. In this study, deep learning algorithms were integrated in both 1-D and 2-D data spaces to detect defects in motor mechanics commonly utilized in industry, and to increase production efficiency. Ten different classes were studied using the popular and comprehensive Case Western Reserve University (CWRU) bearing dataset, which includes three types of faults - the outer race, the ball, and the inner race - as well as a healthy class. The bearing vibration signal was handled in four ways: using the original vibration data, extracting features from the original data, applying STFT to the original data, and extracting features from the STFT-applied data. Machine learning approaches such as KNN, SVM, and 1D WDCNN were applied to the 1-D data. Additionally, STFT transformation was applied in the 2-D data space, and performance measurements were made with different statistical metrics using EfficientNetB0, EfficientNetB1, ResNet18, and 2D WDCNN. In the 2-D space, deep learning methods achieved 100% accuracy.

Keywords: Motor Bearing Vibration, Deep Learning, Signal Classification, Industrial Fault Recognition.

¹Maltepe Üniversitesi, Meslek Yüksek Okulu, Bilgisayar Programcılığı Bölümü, İstanbul, Türkiye, enginoguzay@maltepe.edu.tr

²Maltepe Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği, İstanbul, Türkiye, muratballta@gmail.com

*Sorumlu Yazar/Corresponding Author

Geliş/Received: 09.02.20234

Kabul/Accepted: 29.06.2024

Yayın/Published: 15.09.2024

1. Giriş

Algılayıcı ölçüm teknolojilerinin ilerlemesi ve dünya çapında Endüstri 4.0 kavramının yaygınlaşmasıyla birlikte, akıllı ölçüm uygulamaları ve akıllı arıza teşhis yöntemleri endüstriyel ortamlarda büyük ilgi çekmeye başlamıştır. Bu akıllı ölçüm uygulamaları (Berghian-Grosan ve ark., 2024), makine öğrenmesi ve veri işleme algoritmaları (Oğuzay, 2013) ile desteklenerek, endüstriyel makineler ve cihazlardaki anormalliklerin tespit edilmesi (Anagün ve ark., 2023) ve arızaların yüksek başarı oranlarıyla önceden tahmin edilmesine imkân tanımaktadır. Böylelikle de yakın zamanda arızalanma riski olan endüstriyel cihazlar önceden tespit edilebilmekte, gerekli önlemler alınabilmekte ve bakımları en efektif şekilde yapılabilmektedir. Özellikle üretimde kullanılan makinelerin bakımlarının yapılması hem üretimin devam etmesine hem de makinelerde yaşanabilecek arızaların önlenmesine yardımcı olabilmektedir. Mevcut teknolojik gelişmeler altında endüstride yaygın olarak kullanılan bakım yaklaşımları 3 temel kategoride incelenmektedir (Ran ve ark., 2019):

Reaktif Bakım (Reactive Maintenance) yaklaşımında, bakım işlemi cihazda bir arıza oluşuktan sonra gerçekleştirilir. Cihazın bozulana kadar çalışmasına izin verilir.

Önleyici Bakım (Preventive Maintenance) yaklaşımında, bakım işlemi belirli sayıdaki iş parçası kullanımı sonrası ya da belirli zaman periyotlarında planlı bir şekilde gerçekleştirilir.

Kestirimci Bakım (Predictive Maintenance) yaklaşımında, bakım işlemi cihazdan çeşitli yöntemlerle toplanan verilerin analiz edilmesiyle gerçekleştirilir.

Oldukça büyük bir kısmı makine öğrenmesi modellerine dayanan veriye dayalı yöntemler, akıllı ölçüm ve arıza tespiti yaklaşımlarının merkezinde yer almaktadır (Carvalho ve ark., 2019; P. Kumar ve ark., 2020; Lei ve ark., 2020). Akıllı arıza teşhisi ve ölçüm uygulamaları için veriye dayalı yöntemlerin etkin tasarımı ve kullanımı, başarılı bir hata tespit ve teşhis süreci ihtimalini de arttırmaktadır. Kestirimci bakım uygulamalarında, akıllı bir arıza teşhisi yaklaşımı için geleneksel makine öğrenmesi algoritmaları kullanıldığında, çoğu zaman bir sensor ölçümüyle elde edilen sinyalden gelen ham veriler (örn. titreşim, akım, vb.) zaman düzleminde veya frekans düzleminde analiz edilmektedir (Hendrickx ve ark., 2020; Yoo, 2019). Fakat verilerin zaman düzleminde analiz edilmesi frekans bilgilerini, frekans düzleminde analiz edilmesi de zaman bilgilerini içermediği için birçok uygulama oldukça sınırlı kalmaktadır. Günümüzde teknolojik gelişmeler sonucu artan hesaplama kapasiteleri sayesinde zaman serilerini sadece tek bir düzlemde incelemek yerine çeşitli dönüşümlerle zaman-frekans düzlemine aktarmak ve hem zaman hem de frekans bilgilerinden faydalanmak da mümkün bir hale gelmektedir.

Klasik makine öğrenmesi modellerinde motor arıza tespiti, özellik çıkarımı ve arıza tespiti için faydalı özniteliklerin seçimi aşamalarını içerir (Ertarğın ve ark., 2023). Makine öğrenmesi modeli

aracılığıyla arıza tahmin ve teşhisi sürecinin kalitesini artırmaya yardımcı olabilecek ve toplanan veriyi en iyi şekilde temsil edebilecek olan özniteliklerin çıkarılması ve seçilmesi oldukça zahmetli ve uzmanlık gerektiren bir iştir (Caesarendra ve ark., 2017). Her ne kadar yararlı ve temsil kapasitesi yüksek öznitelikler elde edilmiş olsa da değişen çalışma koşulları veya süreç sapmaları nedeniyle arızaları önceden yüksek tutarlılıkla teşhis etmek de her zaman mümkün olmamaktadır. Son yıllarda, makine öğrenmesi modellerinin bir alt sınıfı olarak ortaya çıkan derin öğrenme modelleri, arıza tespiti ve kestirimci bakım uygulamalarında umut verici sonuçlar göstermiştir (Hoang ve ark., 2019). Derin öğrenme modellerinin bu denli yetkin çözümler üretebilmesinin temel sebebi; verilerdeki gürültüye karşı daha gürbüz ve ham verilerden herhangi bir uzmanlık gerektirmeden gerekli öznitelikleri çıkarma, eleme ve seçim prosedürlerini ortadan kaldırabilmesinden kaynaklanmaktadır. Ayrıca, derin öğrenme algoritmalarının zaman serisi analizi için güçlü birer araç olması da (Fawaz ve ark., 2019; Långkvist ve ark., 2014), üretimde kullanılan cihazlara bağlı algılayıcılardan elde edilen verilerin analizi için güçlü bir potansiyele sahiptir.

Akıllı arıza tespit ve teşhis uygulamaları için derin öğrenme yaklaşımlarının yaygın kullanımı genellikle algılayıcılar yardımıyla, uzun bir zaman çerçevesinde toplanan büyük miktardaki sinyal verileri üzerinden gerçekleştirilmektedir (Aydın ve ark., 2024). Algılayıcılardan toplanan büyük miktarda zaman serisi verileri, bir derin öğrenme modeline girdi olarak sağlanır ve eğitim sürecinde kullanılır. Daha sonra, eğitilen model ile daha önceden hiç görülmemiş olan veri örnekleri üzerinde arıza tespiti ve sınıflandırma işlemleri gerçekleştirilir. Bu çalışmada ise mevcut çalışmalardan farklı olarak, toplanan veriler Dalgacık Dönüşümü (Wavelet Transform) ve Kısa Zamanlı Fourier Transformasyonu (Short-Time Fourier Transform) ile 2 boyutlu görsellere dönüştürülecek ve sonrasında farklı Evrişimli Sinir Ağı (ESA) mimarileri yardımıyla analiz edilerek hata sınıfları tespit edilmeye çalışılacaktır.

Rulmanlar dönen makinenin önemli bir parçasıdır. Rulman arızalarının teşhisi, dönen makinelerde; ölümcül ve ekonomik kayıpların önlenmesi açısından önemlidir. Rulmanın arızalı olası durumunda insana ve çevreye önemli zararlar verebilmektedir. Rulmanın belirli bir kısmında bir anormallik meydana geldiğinde, rulman titreşim sensörü sinyalinin özellikleri normal durumdaki titreşim modelinden farklıdır ve bu da sinyalin frekans karakteristiğini değiştirir (Yoo ve ark., 2023). Bu çalışmada endüstride kullanılan motorlu mekaniklerin arıza tespiti bulmak için spesifik olarak rulman verisi üzerinde çalışılmış ve derin öğrenme yaklaşımı ile başarılı sonuçlar elde edilmiştir. Bu çalışmada kullanılan modelleme sistemi; otonom araçlar, güvenlik sistemleri ya da biyomedikal cihazlar gibi birçok veri toplamaya elverişli cihaz için de hayata geçirmek temelde mümkündür. Bu bağlamda incelenen literatür ışığında günümüzde oldukça popüler olan ve yüksek başarımlı sergileyen derin öğrenme yaklaşımları kullanılmıştır. Çıkış noktası endüstriyel üretim ortamları olan bu çalışmada geliştirilen modeli; otonom

araçlar, güvenlik sistemleri ya da biyomedikal cihazlar gibi birçok veri toplamaya elverişli cihaz için de hayata geçirmek temelde mümkündür. Dolayısıyla bu tez çalışmasının sonuçları uygulandığında, üretim ve lojistik gibi endüstriyel ortamlarda yaygın bir şekilde kullanılan cihaz ve araçlardan toplanan verilerin anlamlı bir şekilde işlenmesi ve olası hataları en aza indirgeyerek iş gücü, maliyet, can ve mal kaybı gibi istenmeyen unsurları minimize edilmesi mümkündür.


Bu çalışmada motor rulman titreşim verisi kesitlere bölünerek üzerine STFT uygulanarak hata teşhis hedeflenmiştir. Ayrıca 1-B ve 2-B şeklinde sinyal verisi ele alınmıştır. Veri boyutu indirgemenin performansa etkisini analiz etmek için öznitelik çıkarma uygulanmıştır. Orjinal veya STFT uygulanmış 2B veri üzerinde ESA yöntemlerinden EfficientNetB0 kullanarak 100% doğruluk oranı ile hata tespiti yapılmıştır. Ayrıca Gauss gürültüsü durumunda +5 PSNR bozulma ile doğruluk oranı orjinal veri için 95% olarak ölçülürken, -5 PSNR durumunda 75% doğruluk elde edilmiştir.

2. Materyal ve Metot

2.1. Dataset

Bu çalışmada CWRU rulman verisi tercih edilmiştir. Şekil 1 'de CWRU veri setinde rulman titreşim verileri alma sistemi (CASE University) görülmektedir. Kullanılan CWRU literatürde motor hata bozukluğu tespiti için en fazla analiz edilen verisetidir. Veriseti oluşturulurken test rulmanları farklı motor milini kullanarak ölçümler yapılmıştır. Kusurlar Elektrik Deşarjlı İşleme (EDM) yöntemi ile tek bir noktadan verilerek oluşturulmuştur. Kullanılan millerin çapları inç (milimetre) ile kusurlar adlandırılmıştır. Toplamda 3 farklı mil tercih edilmiştir:

- 0.007 inç (0.178 milimetre)
- 0.014 inç (0.356 milimetre)
- 0.021 inç (0.533 milimetre)



Şekil 1. CWRU veri setinde rulman titreşim verileri alma sistemi (CASE University).

Rulmanın 3 parçasından 1'inde bulunan her bir kusur için bir zaman serisi vardır:

- Bilye
- İç yuva
- Dış yuva

Telemetri ölçümleri, sistemdeki 3 konuma yerleştirilmiş 3 hızlandırıcıdan gelmektedir:

- Tahrik ucu (DE)
- Fan ucu (FE)
- Baz (BA)

Bu tezde kullanılan veri seti aşağıdaki özellikleri barındırmaktadır:

- Motora uygulanan 1 HP yük
- Şaft dönüş hızı 1772 revolutions per minute (RPM)
- İvme ölçerlerin 48 khz örnekleme frekansı
- Toplamda 10 çeşit sinyal vardır. Sinyallerin uzunluğu tablo 1'de gösterilmiştir.

Bu çalışmada kullanılan CWRU verisetinde toplamda 10 sınıf vardır. Normalde 3 kategoride ve farklı uzunluktaki miller kullanılarak oluşturulmuştur. Mil uzunlukları 0.007 inç, 0.0014 inç ve 0.0021 inç olarak kullanılarak dış bilezik hatası (OR), iç bilezik hatası (IR) ve bilya hatası (BA) oluşturulmuştur.

2.2. Veri Seti Ön İşleme

Öznetelik çıkarmak literatürde sinyali bölütlerken pencere uzunluğu 784 veya 1024 tercih edilmiştir. Bu 1024 veya 784 seçildiğinde kare olarak matrise dönüştürmek kolay olmaktadır. Pencere

boyutu çok küçük seçildiğinde örnek sayısı çok fazla olduğu için aşırı-öğrenme (over-fitting) durumu oluşmaktadır. Çok yüksek seçilmesi durumunda örnek sayısı çok az olmakta ve sınıflandırma performansı direkt 100% vermektedir. Bu çalışmada rulman titreşim sinyalinden 1x784 kesitler alınmıştır. STFT ile öznitelik elde edilmesi durumunda örnekleme frekansı (FS): 784, pencere: Hann, segment boyutu: 64, örtüşme oranı: 300 olarak belirlenmiştir.

Tablo 1. CWRU veriserti sınıf detayları.

Class	Details	Uzunluk
7_OR	OR_007_6_1: Outer race fault (0.007 inch, data collected from 6 O'clock position)	1454609
14_OR	OR_014_6_1: Outer race fault (0.014 inch, 6 O'clock)	484483
21_OR	OR_021_6_1: Outer race fault (0.021 inch, 6 O'clock)	505554
7_BA	Ball_007_1: Ball defect (0.007 inch)	487384
14_BA	Ball_014_1: Ball defect (0.014 inch)	486224
21_BA	Ball_021_1: Ball defect (0.021 inch)	243938
7_IR	IR_007_1: Inner race fault (0.007 inch)	486224
14_IR	IR_014_1: Inner race fault (0.014 inch)	381890
21_IR	IR_021_1: Inner race fault (0.021 inch)	244339
N	Normal_1: Normal	483903


Örtüşme (overlap) oranı 300 olarak, yaklaşık olarak 0.38* pencere boyutu oranında belirlenmiştir. Bu şekilde yapmamızın sebebi kesitlerdeki hata oranını daha iyi tespit etmektir. Düşük boyutlarda kesikler alındığında titreşim sinyalindeki anlamlı bilgi ihmal edilmektedir. Bundan dolayı sezgisel olarak tam sayı çıkması açısından pencere 0.38 ile çarpılmıştır. Deney aşamasında; 1B verilere makine öğrenmesi uygulanmadan önce standart normalizasyon yapılarak öznitelikler [0-1] aralığına çekilmiştir. Ayrıca sınıf adları CNN yöntemlere uygun hale getirmek için one-hot-encoding uygulanmıştır. Bilindiği gibi sinir ağlarının son katmanlarında sınıf sayısı kadar düğüm (node) bulunmaktadır. CNN yapılarının son katmanları da öznitelik ve sınıflandırma katmanlarından oluşmaktadır. Tablo 1’de sınıf detayları ve sinyal uzunlukları gösteren CWRU veriserti tablosunda toplamda 10 sınıf olduğu için sınıf adları 1x10 vektör şeklinde gösterilmiştir. Yani toplamda 10 düğüm kullanılacaktır.

2.3. Sınıflandırma

Makine öğrenimi ve derin öğrenme yöntemleri tüme varım ve tümünden gelim şeklinde çalışmaktadırlar. Derin öğrenme insan beyninin taklit edilmiş hali şeklinde çalışır ve metin, imge ve sinyal gibi örüntüleri benzer şekilde ele almaktadır. İlk derin öğrenme yöntemi perceptron (Minsky ve ark., 1969) algoritmasına dayanmaktadır. Daha sonraları (Lecun ve ark., 1998) LeNet5 şeklinde 2

boyutlu CNN algoritmasını doküman sınıflandırma problemi için önermiştir. CNN yöntemleri geçmişte sınıflandırma problemleri için kullanılmasına rağmen SVM ve öznelik çıkarma yöntemlerinin gölgesinde kalmışlardır.

2012 ImageNet sınıflandırma yarışmasında AlexNet yapısı LeNet5 yapısını güncelleyerek tekrardan derin öğrenmenin gücünü ortaya çıkarmışlardır. Derin öğrenmenin en büyük avantajı imgeden otomatik olarak öznelik çıkarabilmektedir. Derin öğrenme ile bir imgeyi sadece 4, 8 veya 16 öznelik ile göstermek mümkündür.



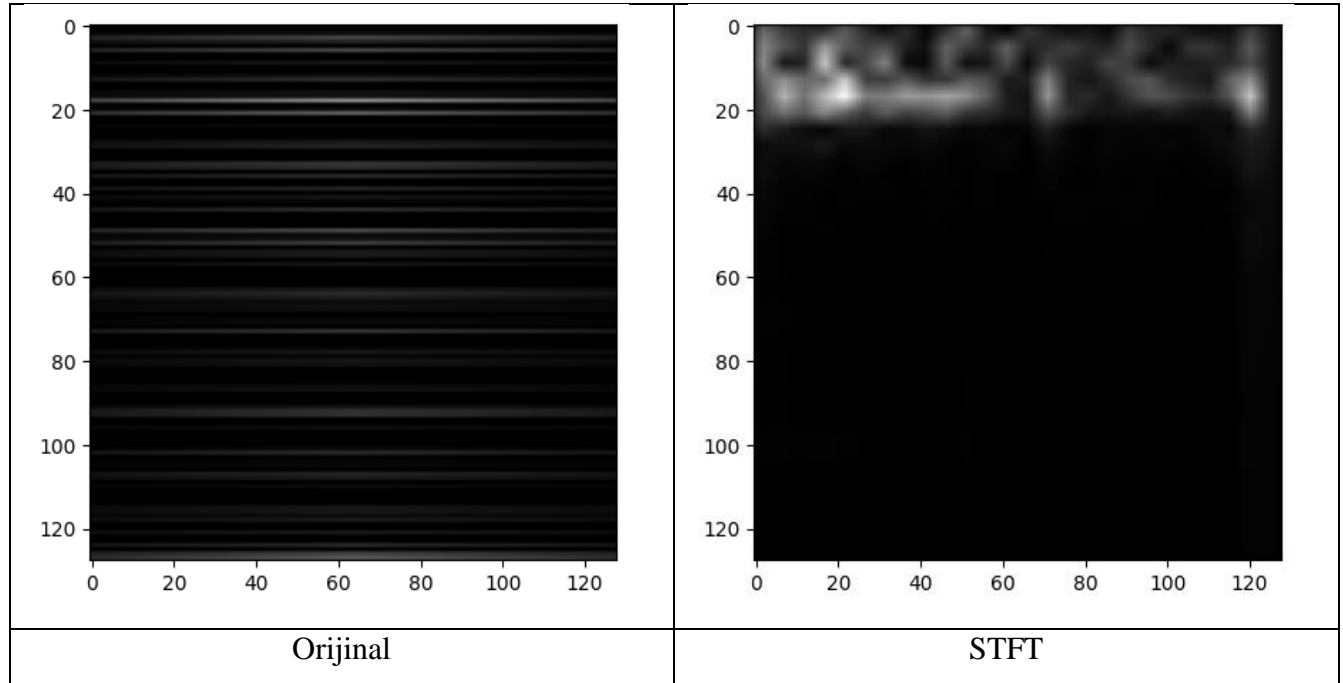
Şekil 2. Derin öğrenme ile sınıflandırmanın gösterimi.

Şekil 2’de derin öğrenme ile hata tanınmanın gösterimi yapılmıştır. Görüldüğü rulan verisi 1B veya 2B şeklinde ele alınabilmektedir. 1B CNN yapısında sinyal verisi vektör şeklinde katmanlara gönderilerek farklı transformasyonlardan geçirilmektedir. Şekilde de görüldüğü gibi CNN katman çıktıları tam bağımlı katmanlara (fully connected layers) gönderilerek sınıflar için ayırt edici öznelikler çıkartılmaktadır. 2B CNN yapılarında ise rulan titreşim verisi resim formatında 2B evrişimsel katmanlara iletilerek kademeli olarak boyut indirgeme yapılmaktadır. Benzer şekilde yine tam bağımlı katmanlar vasıtasıyla daha düşük boyutta ve ayırt ediciliği yüksek öznelikler elde edilmektedir.

Bu çalışmada rulan titreşim verilerinden kusur tespiti için genelde tercih edilen WDCNN mimarisi modifiye eklemeler yapılarak kullanılmıştır. WDCNN yönteminin temel hipotezi şu şekildedir. VGG16 yapısında imgeler 3x3 filtrelerden geçirilerek sınıflandırma yapılmaktadır. Bu şekildeki bir uygulamanın doğru olduğunu vurgulamaktadır. Fakat 2048x1 boyunda bir sinyali 3x1 filtre ile konvolüsyon yapıldığında sinyaldeki gerçek bilginin uzun katmanlı CNN mimarisinde saklanamayacağı

hipotezini savunmaktadır. Bunun için “İlk Katmanda Büyük Çekirdek” (First Layer with Wide Kernel) uygulamanın daha iyi gerçekçi ve daha iyi öznetelik seti oluşturacağını söylemektedir.

Bu çalışmanın deney süreçlerinde WDCNN yönteminin benzeri bir mimari geliştirilerek deneyler yapılmıştır. Eğer girdi verisi 2B ise 2B WDCNN yöntemi kullanılmıştır. Diğer türlü ise 1B WDCNN yöntemi devreye konulmuştur. Girdi verisi boyutu WDCNN için 128x128x3 iken 1B WDCNN için 1x784 olarak belirlenmiştir. Tüm yöntemlerde benzer şekilde eğitim yapılmıştır. Şekil 3’te 2B verinin görselleştirilmesi mevcuttur.



Şekil 3. Orijinal ve STFT veriye ait 2B görüntüleme.

3.Bulgular ve Tartışma

Bu çalışmada dengesiz veri seti (imbalanced dataset) durumu gözlenmektedir. Tüm sınıfların örnek sayısı incelendiğinde 7_OR sınıfının örnek sayısı çok fazladır. Bu durum dengesiz veri seti gerçeğini göstermiştir. Bundan dolayı denklem (1)’de görüldüğü tek doğruluk metriği kullanmak yerine denklem (6)’da AUC skor, denklem (5)’de Cohen’s Kappa skor, denklem (4)’de F1 skor gibi dengesiz veri seti problemini gözetken metrikler tercih edilmiştir. Ayrıca yöntemlerin denklem (2)’de görüldüğü gibi kesinlik (precision) ve denklem (3)’de görüldüğü gibi hassasiyet (recall) değerleri de hesaplanmıştır. Doğru Pozitif (TP) ve Doğru Negatif (TN) modelin doğru olarak tahminlediği, Yanlış Pozitif (FP) ve Yanlış Negatif (FN) ise modelin yanlış olarak tahminlediği alanlardır.

$$\text{Doğruluk (Accuracy)} = (TP + TN) / (TP + TN + FP + FN) \quad (1)$$

$$\text{Kesinlik (Precision)} = (TP) / (TP + FP) \quad (2)$$

$$\text{Duyarlılık (Recall)} = (TP) / (TP + FN) \quad (3)$$

$$\text{F1 Skorlama (F1 Score)} = 2 * (\text{Recall} * \text{Precision}) / (\text{Recall} + \text{Precision}) \quad (4)$$

$$Po = (TP + TN) / (TP + TN + FP + FN)$$

$$Pe = ((TP + FN) * (TP + FP) + (FP + FN) * (FN + TN)) / ((TP + FN + FP + FN))^2$$

$$\text{Cohen'in Kappa Testi (Cohen's Kappa)} = (Po - Pe) / (1 - Pe) \quad (5)$$

$$\text{Doğru Pozitif Oranı (True Positive Rate) (TPR)} = (TP) / (TP + FN)$$

$$\text{Yanlış Pozitif Oranı (False Positive Rate) (FPR)} = (FP) / (FP + TN) \quad (6)$$


3.1. 1 Boyutlu Özelliklerin Değerlendirilmesi

Bu çalışmada makine öğrenmesi ve derin öğrenmenin rulman titreşim verilerinden hata tespiti için kapasitesi analiz edilmiştir. Kullanılan yöntemlerin karşılaştırmalı olarak performansını ortaya çıkarmak için en bilindik metrikler kullanılmıştır. Makine öğrenmesi yöntemleri olarak KNN ve SVM tercih edilmiştir. Derin öğrenme yöntemi olarak 1D WDCNN yapısı önerilmiştir.

Tablo 2. 1B Verilerden elde edilen performans sonuçları.

Data	Method	Size	ACC	AUC	Cohen's	F1	Precision	Recall
Original	KNN	784	69%	0.9052	0.6424	0.6808	0.7443	0.6769
	SVM	784	78%	0.9814	0.7444	0.7429	0.7988	0.7530
	WDCNN	784	99%	0.9999	0.9923	0.9938	0.9937	0.9939
STFT Applied	KNN	784	95%	0.9891	0.9386	0.9418	0.9421	0.9418
	SVM	784	100%	0.9998	0.9945	0.9954	0.9947	0.9961
	WDCNN	784	99%	0.9999	0.9940	0.9944	0.9946	0.9943

Tablo 2’te verilen performans metrikleri incelendiğinde bütün metrikler arasında doğrusal bir ilişki vardır. Bir modelin accuracy (doğruluk) değeri yüksek ise diğer metrik skorlarında yüksek olduğu tespit edilmiştir. Orijinal rulman titreşim verisetinden en yüksek skorlar 1B WDCNN ile 99%, 0.9999, 0.9923 ve 0.9938 oranında ACC, AUC, Cohen’s ve F1 performansları verdiği gözlenmiştir. Yine ilginç olarak STFT geçirilmiş veride tüm yöntemler yüksek skor vermiştir. STFT verilerinden elde edilen istatistiksel özellikler kullanılıncaya performans büyük oranda düşmüştür.



Şekil 4. 1B original test verisinin karışıklık-matrisi

Genel olarak karışıklık-matrisi gösteriminde hangi sınıfların birbirine çok benzediğini tespit edebiliriz. Bunun için düşük performanslı modelin sonuçlarına odaklanabiliriz. Şekil 4'te verilen orijinal veriden elde edilen öznelikler kullanıldığında 1B WDCNN yöntemi 88% ile düşük performans verdiği gözlenmektedir. En çok hata yapılarak sınıflandırılan sınıf çiftleri; 14_BA ve 14_OR, 7_BA ve 14_IR, 7_OR ve 21_IR olarak görülmektedir. İlginç bir çıkarım olarak Normal (N) sınıfın 7 örneği 14_BA sınıfına atanmıştır. Genel dağılıma bakıldığında 7_OR tüm diğer sınıflarla çok benzer olduğu görülmekte ve yüksek hata skorun oluşmasına sebep olmuştur. Bir diğer çıkarım olarak 21_BA sınıfı diğerlerinden kolayca ayrılabilirdiği not edilmiştir.

3.1.2 Boyutlu Özelliklerin Değerlendirilmesi

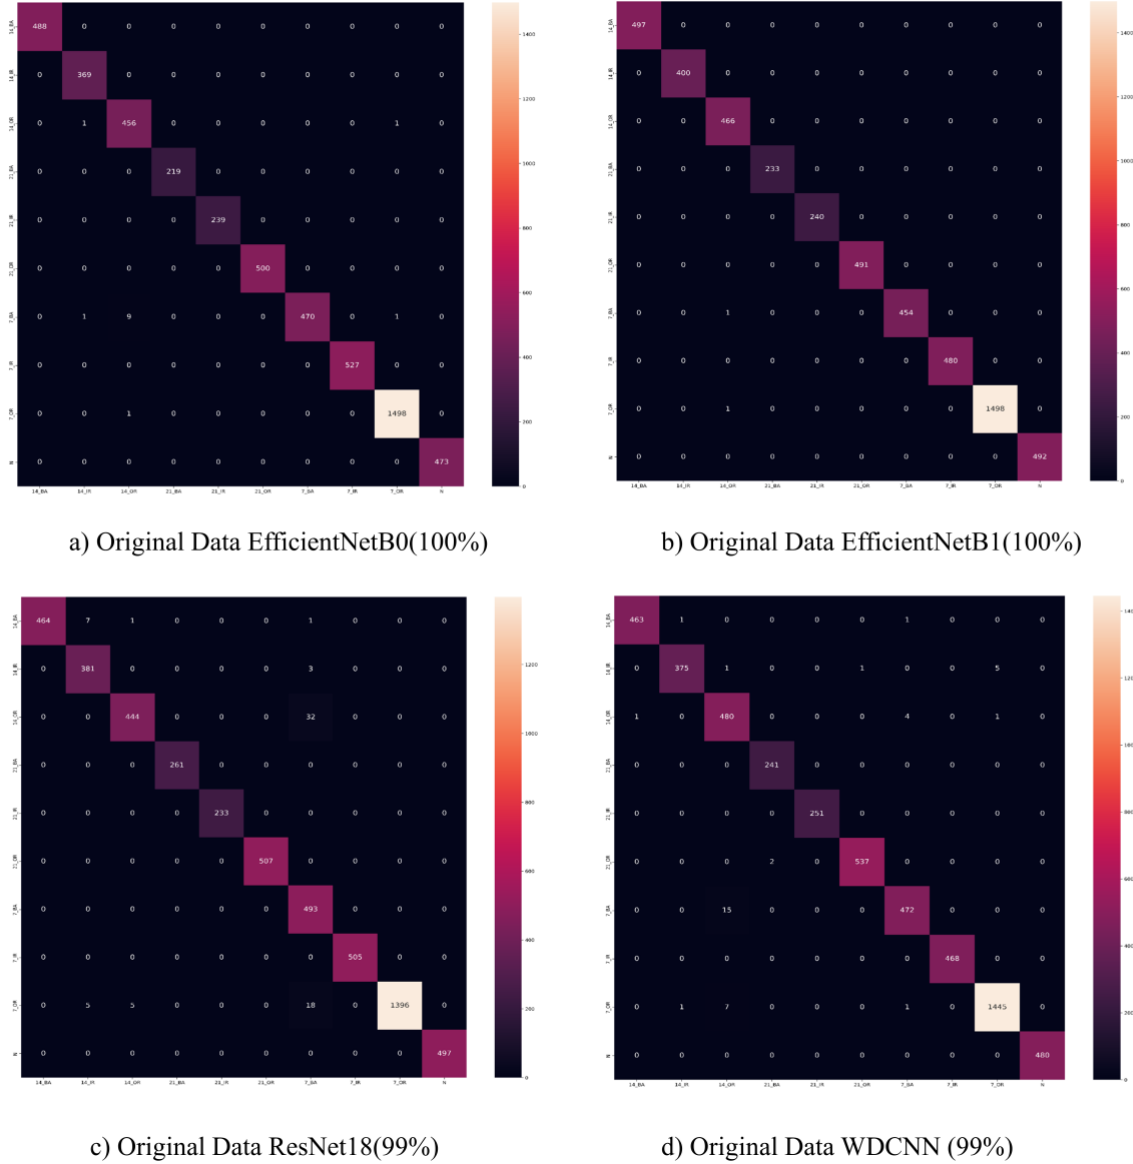
Bu bölümde veriler 2 boyutlu olarak ele alınarak imge formatı şeklinde (H, W, 3) şeklinde CNN modellerine gönderilerek performans ölçümü yapılmıştır. Tablo 3'te EfficientNetB0, EfficientNetB1, ResNet18 ve 2B WDCNN şeklinde dört farklı model ile performans ölçümü yapılmıştır. Vektörleri imge formatına dönüştürmek için 1x784 boyutu yeniden şekillendirilerek 28x28 formatına dönüştürülmüştür. EfficientNet ve ResNet18 yapıları için minimum imge boyutunu sağlamak için 28x28 matrisleri 128x128

formatına dönüştürülmüştür. Sonra 3 kere birleştirme yapılarak 128x128 formatı elde edilmiştir. Bunun nedeni matrisleri bir araya getirerek 3 boyutlu imge oluşturmaktır.

Tablo 3. 2B Verilerden elde edilen performans sonuçları.

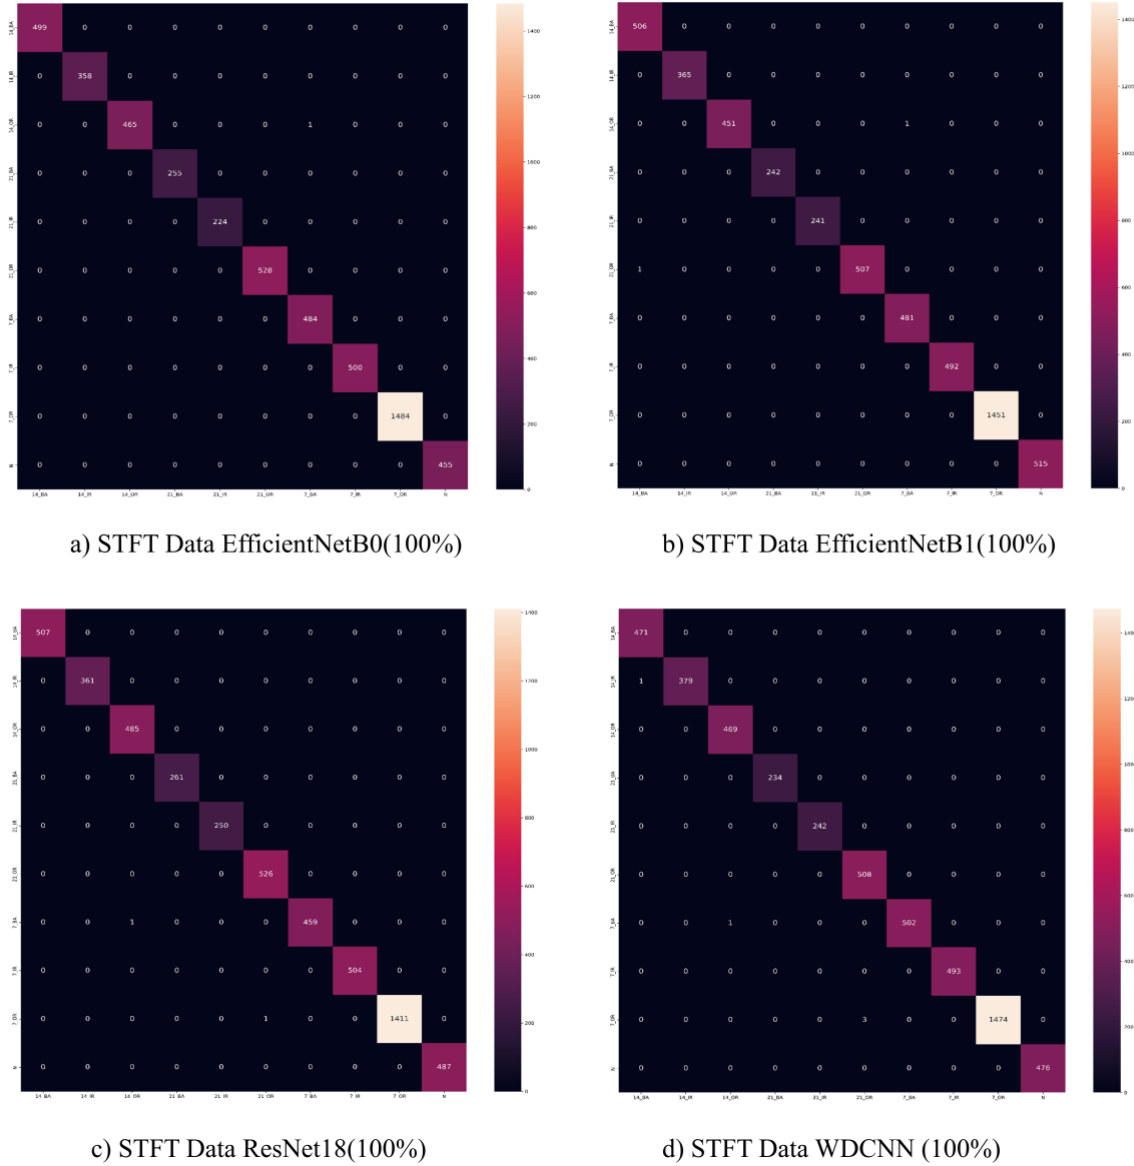
Data	Method	Size	ACC	AUC	Cohen's	F1	Precision	Recall
Original	EfficientNetB0	128X128	100%	1.0000	0.9969	0.9972	0.9972	0.9972
	EfficientNetB1	128X128	100%	1.0000	0.9996	0.9996	0.9996	0.9997
	ResNet18	128X128	99%	1.0000	0.9842	0.9868	0.9857	0.9886
	WDCNN-2D	128X128	99%	0.9999	0.9909	0.9922	0.9920	0.9924
STFT	EfficientNetB0	128X128	100%	1.0000	0.9998	0.9998	0.9998	0.9998
	EfficientNetB1	128X128	100%	1.0000	0.9996	0.9996	0.9996	0.9996
	ResNet18	128X128	100%	1.0000	0.9996	0.9997	0.9996	0.9996
	WDCNN-2D	128X128	100%	1.0000	0.9989	0.9992	0.9990	0.9993

Tablo 3'te 2B şeklinde veriyi ele aldığımızda performans değerlerini göstermektedir. Tabloda verilen sonuçlar referans alındığında, en yüksek tanıma performansının EfficientNetB0 ile STFT verisi için sergilemiştir. Cohen's Kappa metriği temel alındığında EfficientNetB0 ve EfficientNetB1 yarışı içinde olduğu görülmektedir. Diğer yandan ResNet18 yönteminin orijinal verisetinde F1 skorunun göreceli olarak biraz düşük olduğu not edilmiştir. STFT verisi için tüm yöntemler 100% tanıma oranı vermiştir.



Şekil 5. 1B verisetlerinden 1B WDCNN ile edilen özneliklerin PC1 ve PC2 analizi.

Şekil 5'te 2B şeklinde veriyi ele aldığımızda performans değerlerini göstermektedir. Tabloda verilen karışıklık matrisleri detaylı bir şekilde incelendiğinde orijinal veride EfficientNetB0 yönteminin 7_OR, 14_OR ve 14_IR sınıfları için bir elin parmakları kadar örnekler hatalı sınıflandırılmıştır. En fazla hatanın ResNet18 modeli 7_BA sınıfı için verdiği görülmektedir. WDCNN modelinin ise 14_OR sınıfını tanımada biraz zayıf yetenekte olduğu vurgulanabilir. En güzel sonuçları ortaya çıkaran EfficientNetB1 yönteminin sadece 14_OR sınıfına ait 2 örneği yanlış sınıflandırdığı söylenebilir. 7_OR sınıfının test örneğinin sayısının fazla olmasından kaynaklı hataların oluştuğu sonucuna varılabilir.



Şekil 6. 2B STFT test verisi için 2B CNN yöntemlerine ait karışıklık-matrisleri.

Şekil 6’da STFT transformundan geçirilen verinin 2B sınıflandırması ile edilen karışıklık matrislerini göstermektedir. Şekilde verilen karışıklık matrislerine göre STFT verisinde EfficientNetB0 yönteminin sadece 7_BA sınıfındaki bir örneği 14_OR sınıfına hatalı olarak atadığı görülmektedir. Benzer sınıflandırmayı EfficientNetB1 için gözlenmiştir. WDCNN yönteminin 14_OR’deki 1 örneği 7_BA sınıfına, 21_OR’deki 3 örneği 7_OR sınıfına ve 14_BA’deki 1 örneği 14_IR sınıfına hatalı olarak atadığı not edilmiştir. En az hata veren modellerden biri olan ResNet18 modeli 14_OR’deki 1 örneği 7_BA sınıfına, 21_OR’deki 1 örneği 7_OR sınıfına atadığı dikkate alınabilir.

3.3. Gauss Deney Değerlendirilmesi

Farklı bir deney olarak orijinal veriye gürültü eklendikten sonra STFT uygulandığında performans değişimi not edilmiştir. STFT uygulayınca elde edilen spectrogramın çok etkili olmadığı ve bunun nedeni Fourier dönüşümün bozulan sinyalin trendini yakalayamamasıdır. Doğruluk değerlerine bakılınca SNR +5 db ile 89% STFT uygulanmasından elde edildiği görülmektedir. Ayrıca yüksek gürültü (-5 db) ile sinyalin bozulması durumunda ise 57% sınıflandırma performansı sergilemiştir.

Tablo 4. Gauss gürültüsü eklenince WDCNN performans sonuçları.

Data	SNR	Size	ACC	AUC	Cohen's	F1	Precision	Recall
Original	+5	128x128	95%	0.9971	0.9407	0.9482	0.9519	0.9467
	-5	128x128	75%	0.9675	0.7121	0.7491	0.7512	0.7493
STFT	+5	128x128	89%	0.9906	0.8733	0.8814	0.8841	0.8812
	-5	128x128	57%	0.9002	0.4999	0.5450	0.5426	0.5486

Gauss gürültüsü eklenince elde ettiğimiz performans değerler orijinal ve STFT verileri için karşılaştırılmalı olarak Tablo 4'te gösterilmiştir. Bu deneyde hipotez olarak gürültü eklemenin derin öğrenmenin performansını ne ölçüde düşüreceği sorusuna cevap aranmaktadır. Performans metrikleri olarak Accuracy(ACC), AUC, Cohen's Kappa, F1, Precision, Recall kullanılmıştır. Deney için SNR -5 ve SNR 5 bozulmanın sonuçları üzerinde yorumlama yapılmıştır.

Tablo 4'teki sonuçları karşılaştırdığımızda tüm yöntemlerin Accuracy değerleri düşmüştür. Verilen doğruluk oranları analiz edildiğinde WDCNN yöntemi; orijinal ve STFT verisi için 95%, 75%, 89% ve 57% şeklinde performans verebilmiştir. Detaylı inceleme yapıldığında ise AUC skorların 0.9'un üzerinde olmasının olumlu olduğu vurgulanabilir. Performans metriklerinden Cohen's Kappa değerleri ile F1 skoru değerleri arasında doğrudan bağlantı olduğu gerçeği gözlenmiştir. Gerçeğe yakın olan +5 db SNR bozulması durumunda bile derin öğrenme yüksek tanıma vermiştir.

3.4. Literatür karşılaştırılması

Önerdiğimiz yöntemlerin performansı son zamanlardan önerilen yaklaşımlarla karşılaştırılmıştır. Tablo 5'te tüm yöntemlerin doğruluk performansı, ele aldığı sınıf sayısı ve uygulanan derin öğrenme/makine öğrenimi hakkında bilgi verilmiştir. 2D CNN yöntemlerin 1D CNN yöntemlerinden daha başarılı olduğu açıkça görülmektedir. Bunun nedeni 2B düzlemde konvolüsyon yapıldığında uzaysal bilgi korunmaktadır. 1B uzayda komşuluk bilgisi ihmal edilmekte ve düşük performans ile

sonuçlanmaktadır. Ayrıca daha önce denenmemiş olan EfficientNetB0 ve EfficientNetB1 yöntemlerin performansı da CWRU very seti üzerinden analiz edilmiştir.

Tablo 5. Önerilen yöntemin literatürdeki çalışmalarla karşılaştırılması.

Method	#Class	Accuracy	Reference
1D WDCNN	10	99.00%	(Zhang ve ark., 2017).
1D CNN + MLP	4	93.88%	(Eren ve ark., 2019).
Naive Bayes	6	98.21%	(Zhang ve ark., 2018)
1D CNN Ensemble	10	96.42%	(Han ve ark., 2020)
2D CapsuleNetwork +LSTM	10	99.00%	(Zhang ve ark., 2022).
2D CNN	10	98.50%	(Magar ve ark., 2021)
1D CNN + LSTM	6	99.77%	(Khorram ve ark., 2021).
1D WDCNN+ ND	4	91.00%	(Miettinen ve ark., 2022).
1D WDCNN + org. data	10	99%	Önerdiğimiz
1D SVM + STFT	10	100%	Önerdiğimiz
2D EfficientNetB0 + org. data	10	100%	Önerdiğimiz
2D EfficientNetB0 + STFT	10	100%	Önerdiğimiz
2D EfficientNetB1+ org. data	10	100%	Önerdiğimiz

4. Sonuçlar ve Öneriler

Rulmanlar dönen makinenin önemli bir parçasıdır. Rulmanın arızalı olası durumunda insana ve çevreye önemli zararlar verebilmektedir. Bundan dolayı rulman arızalarından kaynaklı makine hatasını mümkün olan en kısa sürede tespit etmek önemlidir. Bu çalışmada makine öğrenimi ve derin öğrenme, hata tespiti için potansiyel olarak bir araç olarak görülmüş ve elde edilen titreşim sinyallerinin daha hızlı ve etkili bir şekilde işlenebildiği görülmüştür. CWRU veriseti üzerinden ham (raw) ve frekans alanında 1B ve 2B şeklinde sınıflandırma yapılmıştır. 1B veri hazırlanma sürecinde belirlenen sabit pencere boyutu belirlenerek ele alınmıştır. Ayrıca 1B veriye STFT uygulanarak veri frekans alanında işlenmiştir. Boyut indirgeme için veriden istatistiksel öznitelikler elde edilerek performans değerlendirmesi yapılmıştır. 2B veriyi oluşturmak için 1x784 boyutundaki vektör yeniden şekillendirilerek 28x28 boyutunu dönüştürülerek matris formatına dönüştürülmüştür. Daha sonra 28x28 matris 128x128x3 üst-örnekleme yapılarak spektrogram alanında sınıflandırma yapılmıştır.

Elde edilen bulgular, istatistiksel metriklerden Accuracy, AUC, Cohen's Kappa, F1, Precision ve Recall üzerinden değerlendirme yapılmıştır. Elde edilen sonuçlar, 1-B orijinal veri üzerinde uygulanınca en yüksek başarı sonucun WDCNN ile 99% olduğu görülmektedir. İlginç bir bulgu olarak STFT uygulanan veride SVM ile 100% doğruluk elde edilmiştir. Öznitelik çıkarılarak yapılan deneylerde ise daha düşük başarı elde edilmiştir. Ayrıca 2-B spektrogram üzerinde yapılan deneylerde derin öğrenme

yöntemlerinden EfficientNetB0, EfficientNetB1, ResNet18 ve WDCNN mimariler ile 100% doğruluk oranı verdiği gözlenmektedir.

Yazarların Katısı

Tüm yazarlar çalışmaya eşit katkıda bulunmuştur.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Anagün, Y., Işık, Ş., ve Çakır, F. H. (2023). Surface roughness classification of electro discharge machinedvsurfaces with deep ensemble learning. *Measurement*, 215, 112855.
- Aydın, İ., Aydın, E., Akın, E., Kaner, S. (2024). Derin Evrışimsel Sinir Ağ Mimarisi ve Zaman Frekans Gösterimini Kullanılarak Büyük Güçlü Motor Arızalarının Tespiti. *EMO Bilimsel Dergi*, 14(1), 51-59.
- Berghian-Grosan, C., Isik, S., Porav, A. S., Dag, I., Ay, K. O., ve Vithoukas, G. (2024). Ultra-high dilutions analysis: Exploring the effects of potentization by electron microscopy, Raman spectroscopy and deep learning. *Journal of Molecular Liquids*, 401, 124537.
- Caesarendra, W., ve 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*, 5(4), 1-28. <https://doi.org/10.3390/machines5040021>
- Carvalho, T. P., Soares, F. A., Vita, R., Francisco, R. d., Basto, J. P., ve Alcalá, S. G. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137. <https://doi.org/10.1016/j.cie.2019.106024>
- Ertarğın, M., Yıldırım, Ö., ve Orhan, A. (2023). Motor Yataklarında Meydana Gelen Arızaları Tespit Etmek için Yeni Bir Tek Boyutlu Konvolüsyonel Sinir Ağı Modeli. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 35(2), 669-678. <https://doi.org/10.35234/fumbd.1292390>
- Eren, L., Ince, T., ve Kiranyaz, S. (2019). A Generic Intelligent Bearing Fault Diagnosis System Using Compact Adaptive 1D CNN Classifier. *Journal of Signal Processing Systems*, 91, 179–189. doi:s11265-018-1378-3
- Fawaz, H. I., Forestier, G., Weber, J., Idoumghar, L., ve Muller, P.-A. (2019). Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery*, 33, Lhassane Idoumghar & Pierre-Alain Muller. doi:10.1007/s10618-019-00619-1
- Han, S., ve Jeong, J. (2020). An Weighted CNN Ensemble Model with Small Amount of Data for Bearing Fault Diagnosis. *Procedia Computer Science*, 175, 88-95. doi:j.procs.2020.07.015
- Hendrickx, K., Meert, W., Mollet, Y., Gyselinck, J., Cornelis, B., Gryllias, K., ve Davis, J. (2020). A general anomaly detection framework for fleet-based condition monitoring of machines. *Mechanical Systems and Signal Processing*, 139, 1-21. doi:j.ymsp.2019.106585

- Hoang, D.-T., ve Kang, H.-J. (2019). A survey on Deep Learning based bearing fault diagnosis. *Neurocomputing*, 335, 327-335. doi:j.neucom.2018.06.078
- Khorrarn, A., Khalooei, M., ve Rezghi, M. (2021). End-to-end CNN + LSTM deep learning approach for bearing fault diagnosis. *Applied Intelligence*, 51, 736–751. doi:s10489-020-01859-1
- Kumar, P., ve Hati, A. S. (2020). Review on Machine Learning Algorithm Based Fault Detection in Induction Motors. *Archives of Computational Methods in Engineering*, 28, 1929–1940. doi:s11831-020-09446-w
- Långkvist, M., Karlsson, L., ve Loutfi, A. (2014). A review of unsupervised feature learning and deep learning for time-series modeling. *Pattern Recognition Letters*, 42, 11-24. doi:j.patrec.2014.01.008
- Lecun, Y., Member, Ieee, Bottou, L., Bengio, Y., ve Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86, 2278 - 2324. doi:10.1109/5.726791
- Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N., ve Nandi, A. K. (2020). Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mechanical Systems and Signal Processing*, 138, 1-39. doi:106587
- Magar, R., Ghule, L., Li, J., Zhao, Y., ve Farimani, A. B. (2021). FaultNet: A Deep Convolutional Neural Network for Bearing Fault Classification. *IEEE Access*, 9, 25189-25199. doi:10.1109/ACCESS.2021.3056944
- Miettinen, J., Nikula, R.-P., Keski-Rahkonen, J., Fagerholm, F., Tiainen, T., Sierla, S., ve Viitala, R. (2022). Whitening CNN-Based Rotor System Fault Diagnosis. *Applied Sciences*, 12(9), 1-22. doi:10.3390/app12094411
- Minsky, M. L., ve Papert, S. A. (1969). *Perceptron: an introduction to computational geometry*. ISBN.
- Ran, Y., Zhou, X., Lin, P., Wen, Y., ve Deng, R. (2019). A Survey of Predictive Maintenance: Systems, Purposes and Approaches. *arXiv preprint arXiv:1912.07383*, XX(XX), 1-36.
- Oğuzay, E. (2013). Veri madenciliği ile geliştirilen bir akıllı buzdolabı ve market sepet analizi sistemi. Doktora Tezi, Trakya Üniversitesi, Fen Bilimleri Enstitüsü, Edirne.
- Yoo, Y.-J. (2019). Fault Detection of Induction Motor Using Fast Fourier Transform with Feature Selection via Principal Component Analysis. *International Journal of Precision Engineering and Manufacturing*, 20, 1543–1552. doi:10.1007/s12541-019-00176-z
- Yoo Y, Jo H ve Ban S-W. (2023). Lite Efficient Deep Learning Model for Bearing Fault Diagnosis Using the CWRU Dataset. *Sensors*. 2023; 23(6):3157. <https://doi.org/10.3390/s23063157>
- Zhang, N., Wu, L., Yang, J., ve Guan, Y. (2018). Naive Bayes Bearing Fault Diagnosis Based on Enhanced Independence of Data. *sensors*, 18(2), 1-17. doi:10.3390/s18020463
- Zhang, W., Peng, G., Li, C., Chen, Y., ve Zhang, Z. (2017). A New Deep Learning Model for Fault Diagnosis with Good Anti-Noise and Domain Adaptation Ability on Raw Vibration Signals. *sensors*, 17(2), 1-21. doi:10.3390/s17020425
- Zhang, X., Kong, J., Zhao, Y., Qian, W., ve Xu, X. (2022). A deep-learning model with improved capsule networks and LSTM filters for bearing fault diagnosis. *Signal, Image and Video Processing*, 17, 1325–1333. doi:10.1007/s11760-022-02340-x