

Kırık Rotor Çubuğu Sayısının Ampirik Mod Ayrışımı ve Makine Öğrenmesi Yaklaşımları İle Belirlenmesi

Fırat DİŞLİ^{1*}, Mehmet GEDİKPİNAR², Abdulkadir ŞENGÜR³

^{1,2,3} Elektrik-Elektronik Mühendisliği, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

^{*1} dislifirat@gmail.com, ² mgedikpinar@gmail.com, ³ ksengur@gmail.com

(Geliş/Received: 02/05/2023;

Kabul/Accepted:12/08/2023)

Öz: Endüstriyel sürücü sistemlerinde verimlilikleri, sağlamlıkları, güç ve boyut çeşitlilikleri nedeniyle asenkron motorlar sıklıkla kullanılmaktadır. Asenkron motorlarda meydana gelen kırık rotor çubuğu arızaları, sistemin verimliliğini doğrudan etkilediğinden arıza teşhisi gittikçe önem kazanmaktadır. Kırık rotor çubuğu arızalarının teşhisi için hem stator akım sinyali hem de motor titreşim sinyali kullanılmaktadır. Son zamanlarda bu konuda yapılan çalışmalarda bazı sinyal işleme teknikleri ile birlikte makine öğrenmesi yöntemleri kullanılmaktadır. Bu çalışmada, ampirik mod ayrışımı (AMA) ve makine öğrenmesi yöntemleri kullanılarak kırık rotor çubuğu sayısının sınıflandırılması gerçekleştirilmiştir. İlk olarak arızalı motor veri setinden alınan bir faz akımı ve motor titreşim sinyali filtrelenip zarflanmıştır. İkinci adımda bu sinyaller AMA yöntemiyle 5 adet içsel mod fonksiyonuna (İMF) ayrıştırılıp spektral entropi ve anlık frekans öznitelikleri elde edilmiştir. Üçüncü adımda bu öznitelikler uç uca eklenip yeni öznitelik vektörü oluşturulmuştur. Dördüncü adımda, öznitelik vektörleri destek vektör makinesi (DVM), k en yakın komşu (KEK) ve karar ağacı (KA) makine öğrenmesi yöntemleriyle sınıflandırılmıştır. Başarı parametresi olarak sınıflandırma doğruluğu kullanılmış ve en yüksek başarı %93,9 ile DVM sınıflandırma yönteminden elde edilmiştir. Çalışmanın sonunda literatürde aynı veri seti için yapılan çalışmalar ile performans karşılaştırılması yapılmış ve bunların sonucunda kırık rotor çubuğu sayısının sınıflandırılmasının AMA ve DVM ile yapılabileceği görülmüştür.

Anahtar kelimeler: Ampirik mod ayrışımı, Asenkron motor, Kırık rotor çubuğu, Makine öğrenmesi.

Determination of The Number of Broken Rotor Bars by Empirical Mode Decomposition and Machine Learning Approaches

Abstract: Induction motors are frequently used in the industrial drive systems due to their efficiency, robustness, power and size diversity. Diagnosis is becoming increasingly important as broken rotor bar failures in induction motors directly affect the efficiency of the system. Both the stator current signal and the motor vibration signal are used to diagnose broken rotor bar faults. In recent studies on this subject, machine-learning methods are used together with some signal processing techniques. In this study, determination of the number of broken rotor bars was performed using empirical mode decomposition (EMD) and machine learning methods. Firstly, a phase current and vibration signal taken from the faulty motor data set are filtered and enveloped. In the second step, these signals were decomposed into five intrinsic mode functions (IMF) using by the EMD method, and their spectral entropy and instantaneous frequency features were obtained. In the third step, these features are added end-to-end and a new feature vector is created. In the last step, feature vectors are classified by support vector machine (SVM), k nearest neighbor (KNN) and decision tree (DT) machine learning methods. Classification accuracy was used as the success parameter and the highest success in classification was obtained with SVM, with a classification accuracy of 93.9%. Final of the study, performance comparisons were made with the studies conducted for the same data set in the literature. As a result, it has been seen that the classification of the number of broken rotor bars can be done successfully with EMD and SVM.

Key words: Broken rotor bar, Induction motor, Empirical mode decomposition, Instantaneous frequency, Machine learning.

1. Giriş

Asenkron motorlar endüstriyel sistemler, elektrikli araçlar ve ev aletleri gibi birçok alanda kullanılmaktadır. Asenkron motorlarda dönme hareketinin oluşturulması ve tork üretilmesi için gerekli olan önemli bir bileşen rotor elemanıdır. Besleme kayağındaki dengesizlikler, yükteki dengesizlikler gibi çalışma koşulları motorlarda bazı problemleri meydana getirmektedir. Bu problemler rotor elemanlarında genellikle rotor çubuğu kırılması arızasına neden olmaktadır. Bu arıza ile torkta dalgalanma, motorda aşırı ısınma, akımda dalgalanmalar ve ortalama torkta azalma oluşarak motor verimini düşürmektedir. Endüstriyel uygulamalardaki bu tür kayıpların azaltılması ve arızanın teşhisi için bilgi teknolojilerinin gelişmesiyle sinyal işleme temelli yöntemler yaygınlaşmıştır. Arıza teşhis

* Sorumlu yazar: dislifirat@gmail.com. Yazarların ORCID Numarası: ¹ 0000-0003-0016-3558, ² 0000-0002-1045-7384, ³ 0000-0003-1614-2639

yöntemleri genellikle vibrasyon sinyali ve motor akım sinyali üzerine temellenir. Bu veriler gürültülü olsa da, sinyal işleme teknikleri arıza özelliklerini doğru biçimde çıkarabilir. Sinyal işleme teknikleri ile birlikte yapay sinir ağı modellerinin kullanılmasıyla birlikte arıza teşhisinin hesaplama hızı ve genelleme performansı artabilmektedir [1,2].

İletim yolu ve ortam gürültüsünden dolayı vibrasyon sinyalinin arıza teşhisine yönelik karakteristik bilgisi zayıflarken kırık rotor çubuğu arızasının stator akımına özellikli etki yapması, stator akımı ile arıza teşhisini kolaylaştırmaktadır. Bu nedenlerle arıza teşhisi için vibrasyon ve akım sinyalinin birlikte kullanılması teşhis başarısını arttırmaktadır [3,4].


Asenkron motorlarda kırık rotor çubuğu arızası için, genellikle frekans analizine dayalı sinyal işleme teknikleri kullanılmaktadır. Motor akımı kullanılarak yapılan bu yöntemler motor akım imza analizi olarak adlandırılmaktadır. Motorun arıza özelliklerini elde etmek için akım sinyali bazı sinyal işleme teknikleri ile bileşenlerine ayrılır veya bazı istatistiksel değerler elde edilir. Elde edilen bu değerler ve bileşenler analiz edilerek arıza teşhisi yapılabilmektedir. Sinyal işleme uygulamalarında sıklıkla kullanılan hızlı Fourier dönüşümü (HFD) tekniği, durağan olmayan sinyallerde ve düşük hızlarda arıza teşhisi konusunda zayıf kalmaktadır. Bu dezavantajından dolayı son zamanlarda AMA sürekli dalgacık dönüşümü (SDD), kısa zamanlı Fourier dönüşümü (KZFD) gibi gelişmiş teknikler kullanılmaya başlamıştır. Bu teknikler hem akım sinyali hem de vibrasyon sinyalinden arıza özellikleri çıkarılması konusunda başarılı sonuçlar vermektedirler [5-7].

Sinyal işleme teknikleri ile çıkarılan arıza özellikleri, hem istatistiksel analizler hem de yapay sinir ağı (YSA) modelleri ile sınıflandırılmaktadır. Problemin çözümde DVM, KA, KEK gibi makine öğrenmesi metodlarının yanında evrişimli sinir ağları (ESA), uzun kısa süreli bellek (UKSB) gibi derin öğrenme metodları da kullanılmaktadır. Makine öğrenmesi metodlarında arıza özelliklerinin çıkarılması ve seçilmesi araştırmacı tarafından yapılırken, derin öğrenme modellerinde özellik çıkarılması adımı modelin kendisi tarafından yapılmaktadır. Makine öğrenmesi yöntemleri sınırlı veri kümelerinde başarılı sonuçlar üretirken, derin öğrenme modelleri daha büyük veri kümelerinde başarılı sonuçlar üretmektedir. Ayrıca önceden başka problemlerde eğitilmiş ağların transfer öğrenme yöntemiyle yeni problemler için kullanılabilmesinden dolayı son zamanlarda derin öğrenme yaklaşımları arıza teşhisi konusunda ön plana çıkmaktadır [8-15].

Literatürde kırık rotor çubuğu arızası teşhisi için yapılan çalışmalar incelendiğinde genelde çözüm için dört temel adım uygulandığı görülmektedir. Birinci adım, deney setinin oluşturulması ve verilerin toplanması, ikinci adım sinyal ve veri ön işleme işleme, üçüncü adım özellik çıkarma ve özellik seçme, dördüncü adım ise arıza sınıflandırma ve ya özellik analizi yapılması şeklinde ilerlemektedir. Reddy ve arkadaşları, 4 farklı seviyede rulman arızası deney seti oluşturup, motordan alınan vibrasyon sinyallerini AMA ile bileşenlerine ayırarak arıza özellikleri çıkarmışlardır. Entropi temelli özellik seçme yöntemini kullanıp farklı makine öğrenmesi teknikleri ile sınıflandırma yapmışlardır [8]. Benzer bir çalışmada Sbaa ve arkadaşları, sağlıklı ve 1 kırık rotor çubuklu motor seti oluşturup, yüksüz ve %75 yükte testler yapmışlardır. Elde ettikleri stator akımlarından HFD, ayırık dalgacık dönüşümü (ADD) ve AMA yöntemleri kullanarak özellikler çıkarmışlardır. Bu özellikleri istatistiksel yöntemlerle analiz edip, ADD ve AMA yöntemleri ile daha başarılı teşhis yapılacağı sonucuna varmışlardır [5]. Bir başka çalışmada Shao ve arkadaşları, stator sargılarında kısa devre arızası, rulman arızası, eksenel kaçıklık arızası, rotor bent arızası ve kırık rotor çubuk arızası teşhisleri için çoklu sinyal kullanan çok kanallı CNN modeli önermişlerdir. Yaptıkları çalışmada stator akımı ve vibrasyon sinyalini SDD ile zaman-frekans özellikleri çıkarılmış. Bu özellikler çok kanallı bir ESA ile sınıflandırılmış ve çoklu sinyal kullanılarak oluşturulan yöntemin daha başarılı sınıflandırma yaptığı sonucuna varmışlardır [4]. Faiz ve arkadaşları ise, farklı sayıda ve farklı rotor lokasyonlarında kırık çubuğa sahip inverter beslemeli asenkron motor arızası teşhisi için AMA temelli analiz yapmışlardır. Elektrik motorları genellikle inverter ile sürüldüğünden deneylerini inverter kullanarak yapmışlardır. İnverter besleme ile arızanın hız üzerindeki etkisi kompoze edilip farklı hızlarda yaptıkları testlerde kırık rotor çubuklarının bitişik konumda olması arızanın daha belirgin olduğu sonucuna varmışlardır [9]. Motor arıza teşhisi konusunda yapılan bir başka çalışmada Valles-Novo ve arkadaşları, farklı sayıda kırık rotor çubuğu arızasını hem farklı yüklerde hem de motorun geçici ve kalıcı durumda test etmişlerdir. AMA kullanarak stator akımını bileşenlerine ayırıp standart sapma değeri üzerinden alanda programlanabilir kapı dizisi (APKD) kullanarak sınıflandırma yapmışlardır. Yaptıkları çalışma ile hem motorun geçici durumunda hem de kalıcı durumunda arıza teşhisini yapmışlardır [10].

Literatürdeki çalışmalar incelendiğinde, motor akım sinyali ve vibrasyon sinyalinin birlikte kullanılıp, AMA ile özelliklerine ayrıştırıldıktan sonra birçok alanda kullanılan makine öğrenmesi yöntemleri ile asenkron motor arıza teşhisinin sınıflandırılması başarılı sonuç vereceği öngörülmektedir. Bu bağlamda, yapılan çalışmada ilk olarak 1'er saniyelik akım ve gerilim sinyalleri filtrelenmiş ve zarflanmıştır. İkinci adımda AMA yöntemi ile 5 adet içsel mod fonksiyonu (IMF) elde edilmiş ardından bu fonksiyonlardan anlık frekans ve spektral entropi özellikleri çıkarılmıştır. Çıkarılan özellikler bir sonraki adımda uç uca eklenerek birleştirilip ilk 10000 özellik

seçilmiştir. Seçilen özellikler için son adımda karar ağacı, k en yakın komşu ve destek vektör makinesi yöntemleri ile sınıflandırma yapılmıştır. Çalışmada kullanılan yöntemle ait akış şeması Şekil 1’de verilmiştir. Çalışmanın sonucunda elde edilen sonuçlar karışıklık matrisleriyle gösterilmiş ve bu sonuçlar aynı veri seti üzerinde yapılan diğer çalışmalar ile karşılaştırılmıştır. Literatürdeki benzer çalışmalar incelendiğinde genellikle kullanılan motorun yüksüz ve tam yük olmak üzere iki yük koşulunda çalıştığı ve arıza çeşitliliğinin olmadığı görülmektedir. Bu çalışmada sekiz farklı yük koşulunda arıza teşhisinin yapılması ile asenkron motor arıza teşhisi literatürüne katkı sağlayacağı düşünülmektedir [15-18].



Şekil 1. Kırık rotor çubuğu arızası teşhisi için önerilen metod

2. Teorik Arkaplan

2.1. Ampirik mod ayrışımı

Ampirik mod ayrıştırma, Huang ve arkadaşları tarafından geliştirilmiş olup bir sinyali bir dizi içsel mod işlevine ayıran sinyal işleme tekniğidir. Geliştirildiği günden bu yana sinyal işleme, medikal işaret işleme, yapay sinir ağları ve finans gibi bir çok alanda yaygın olarak kullanılmaktadır. AMA yöntemi bir sinyali içsel mod fonksiyonundan (İMF) oluşan bir diziye dönüştürür. Sinyaldeki tüm yerel maksimum ve yerel minimum değerleri tanımlanarak ve kübik çizgiler kullanılarak aralarında interpolasyon yapıp İMF’ler çıkarılır. İnterplasyonlu uç değerler, İMF’nin üst ve alt zarflarını oluşturur ve bunlar daha sonra ilk İMF’yi elde etmek için sinyalden çıkarılır. İşlem daha sonra bir durdurma kriteri karşılanana kadar artık sinyal üzerinde tekrarlanır [11]. Zamana bağlı bir $x(t)$ sinyalini ele alalım, AMA algoritması şu şekilde çalışır:

- Sinyaldeki $x(t)$ tüm yerel maksimumları ve minimumları tanımlanır. Bunlar sırasıyla $min = \{n_1, n_2, \dots, n_N\}$ ve $max = \{m_1, m_2, \dots, m_N\}$ olarak gösterilsin. Burada n yerel minimum noktalarını, m yerel maksimum noktalarını temsil etmektedir.
- Sırasıyla üst ve alt zarfları elde etmek için kübik çizgileri kullanarak maksimum ve minimum arasında interpolasyon yapılır. Burada $u(t)$ üst zarfı, $l(t)$ alt zarfı temsil etmektedir.
 - $u(t) = interpolasyon(max)$
 - $l(t) = interpolasyon(min)$
- Zarfların ortalaması olan $m(t)$ fonksiyonu hesaplanır.
 - $m(t) = (u(t) + l(t)) / 2$
- İlk İMF’nin elde edilmesi için ortalama zarf orijinal sinyalden çıkarılır.

$$IMF1(t) = x(t) - m(t) \quad (1)$$

- Durdurma kriteri karşılanana kadar (örneğin, önceden belirlenmiş sayıda İMF çıkarılmaya veya kalıntı monoton bir fonksiyon haline gelene kadar) kalıntı sinyali ($IMF1(t)$) üzerinde i-iv adımları tekrarlanır.
- İMF’lerine ayrıştırılmış sinyalin son hali $x(t)$ şu şekilde verilebilir.

$$x(t) = IMF1(t) + IMF2(t) + \dots + IMFk(t) + R(t) \quad (2)$$

Burada k , çıkarılan toplam İMF sayısını ve $R(t)$ kalıntı sinyalini temsil etmektedir. AMA algoritması, her bir İMF için iki kriteri karşılar:

- İMF, iyi tanımlanmış bir anlık frekansa sahip tek bileşenli bir sinyaldir.
- Ekstremim sayısı ile sıfır geçiş sayısı arasındaki fark en fazla birdir.

AMA algoritması yinelemelidir ve sinyalin karmaşıklığı arttıkça çıkarılan İMF’lerin sayısı artabilmektedir. Çıkarılan İMF’ler, trend analizi veya gürültü azaltma gibi daha ileri analizler için kullanılabilir. Bununla birlikte, AMA algoritmasının mod karıştırma olasılığı ve gürültüye duyarlılık gibi bazı sınırlamaları olabilmektedir [11].

2.2. Anlık frekans ve spektral entropi

Anlık frekans (AF), belirli bir zaman noktasındaki bir sinyalin frekansının bir ölçüsüdür. Sinyalin zamanla değişen fazından aşağıdaki gibi hesaplanabilir:

- $x(t)$ reel bileşen, j sanal bileşen olduğunda, sinyalin karmaşık analitik temsili $z(t) = x(t) + j * y(t)$ şeklinde olur.
- Bu sinyal $z(t) = A(t) * e^{(j\varphi(t))}$ şeklinde kutupsal olarak yazılabilir, burada $A(t)$ anlık genlik ve $\varphi(t)$ sinyalin anlık fazıdır.
- Sinyalin anlık frekansı, fazın zaman türevi ile verilir: $AF(t) = \frac{\partial \varphi(t)}{\partial t}$

Spektral entropi (SE), bir sinyalin frekans spektrumunun karmaşıklığının bir ölçüsüdür. Spektral entropi, frekans alanındaki güç dağılımının bir ölçüsüdür ve sinyalin zamansal dinamikleri hakkında herhangi bir bilgi sağlamaz. Zamansal dinamikleri yakalamak için, kayan pencere yaklaşımı kullanılarak kısa zaman aralıklarında spektral entropi hesaplanabilir. Bu durumda, spektral entropi her pencere için hesaplanarak frekans spektrumunun karmaşıklığının zamanla değişen bir ölçüsü elde edilir [8]. Sinyalin güç spektral yoğunluğunun (GSY) entropisiyle ilişkilidir ve şu şekilde verilir:

- Fourier dönüşümü $X(f)$ olan bir $x(t)$ sinyalinin GSY'si $P(f) = |X(f)|^2$ şeklinde verilebilir.
- Spektral entropi $H(f)$ ise şu şekilde tanımlanır: $H(f) = -1 \int P(f) * \log_2(P(f)) df$


burada integral ilgili frekans aralığı üzerinden alınır. SE, 0 ile $\log_2(N)$ arasında değişir, burada N , GSY'deki frekans bölmesi sayısıdır. 0 değeri tamamen düz bir spektrumu gösterirken, $\log_2(N)$ değeri, tüm frekans bölmelerine eşit enerji dağıtılmış maksimum derecede karmaşık bir spektrumu gösterir [12].

2.3. Destek vektör makinesi

Destek Vektör Makinesi (DVM) sınıflandırıcısı, istatistiksel yöntemleri kullanan güçlü bir lineer olmayan sınıflandırıcıdır. Hem özellik çıkarma hem de sınıflandırma uygulamalarında kullanımının kolay olması nedeniyle sıklıkla kullanılmaktadır. DVM'nin temel işlevi, iki boyutlu uzayda doğrusal olarak sınıflandırılabilen iki örnek grubunu, düz bir çizgi ile ayırmaktır. Çok boyutlu uzaydaki örnekler, bir düz çizgi tarafından ayrılabilir. Yine de örneklerin bir düz çizgi tarafından ayrılmadığı problemlerde düşük boyutlu uzaydaki verileri yüksek boyutlu uzaya eşleme yöntemiyle DVM'ler örnek kümeyi doğrusal olarak ayrılabilir hale getirebilir ve bu işlemi gerçekleştirmek için bir çekirdek fonksiyonu kullanılır. Ek olarak, DVM'nin yumuşak marjlı olması genelleme performansını güçlendirir. DVM'ler, regresyonların yanı sıra çeşitli türdeki sorunları sınıflandırmak için kullanılabilen farklı hibritlere sahiptir. x_i bir giriş vektörü, y_i karşılık gelen çıkışlar olsun. Böylece eğitim seti $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ olur, burada n eğitim setindeki toplam örnek sayısıdır. DVM'nin amacı, eğitim setini iki farklı kümeye ayıran Υ ($\Upsilon = 1, \Upsilon = -1$) değerlerine sahip düz çizgi bulmaktır. Bura Υ hiper-düzlem ile kümeler arasındaki mesafeyi temsil etmektedir. Hiper-düzlem eşitliği denklem 3'de verildiği gibi doğrusal düzlem olarak kabul edilebilir [16,17].

$$f(x) = w * x + b \quad (3)$$

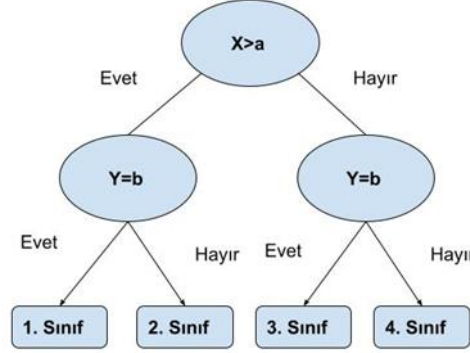
Burada w , x ile aynı boyuta sahip bir giriş vektörü ve b ise bias değeridir. Optimum sınıflandırma için, optimum bir hiper-düzlem bulunmalıdır. Optimum hiper-düzlem, Şekil 2'de gösterildiği gibi iki farklı küme arasındaki en büyük geometri mesafesini Υ almasıyla meydana gelmektedir.



Şekil 2. Eğitim setinde geometrik uzaklık

2.4. Karar ağacı


Karar ağaçları, hızları ve verimlilikleri nedeniyle sınıflandırmada ve regresyon problemlerinde sıklıkla kullanılan denetimli makine öğrenmesi yöntemlerinden biridir. Karar ağaçları, ağaç mimarisinin oluşturulması ve bu ağaçtan kuralların elde edilmesi olarak iki aşamada oluşturulurlar. Kök düğüm, dal ve yaprak düğümler karar ağaçlarının temel bileşenleri olup, karar verme süreci kök düğümlerden yaprak düğümlere doğru ilerler. Kök düğümler özellik kümelerini temsil ederken dallar kuralları temsil etmektedir. Dallardaki kurallar takip edilerek ulaşılan yaprak düğümler ise ağacın çıkışı olan bir kararı ifade etmektedir. Temel bir karar ağacı yapısı Şekil 3'de verilmiştir [18].



Şekil 3. Temel bir karar ağacı

2.5. K en yakın komşu

KEK, sınıflandırma ve kümeleme problemlerinde sıklıkla kullanılan denetimli makine öğrenmesi yöntemidir. Bu algoritmada, sınıflandırılmış mevcut veriler saklanır, önceki veriler ile yeni gelen veriler arasında hesaplanan uzaklıklara göre sınıflandırma yapılır. Bu yöntemde “k” tane komşu için yeni gelen verinin mevcut verilere uzaklığı hesaplanır. Her bir yinelemede yeni gelen verinin mevcut verilere uzaklıkları hesaplanıp “k” yakın komşuluğu kontrol edilir. Veriler, k tane komşu için yakın hesaplanan komşusunun sınıfına dâhil edilir. Yeni gelen verinin komşularına olan mesafesi hesaplanırken Öklid, Manhattan ve Minkowski fonksiyonları kullanılır. Şekil 4’de örnek bir KNN çizimi verilmiştir. Buna göre üçgen ve karelerden oluşan kümeler ek bir elips ile ifade edilen veri geldiğinde bu verinin komşularına olan uzaklığı ölçülür. K değeri 3 olduğunda yeni gelen elips kare sınıfına dâhil edilirken, k=7 olduğunda üçgen sınıfına dâhil edilir. KNN algoritması güçlü bir sınıflandırıcı olmasına rağmen, her yeni veri geldiğinde tüm işlemleri tekrar yaptığından, büyük veri kümelerinde hesaplama zamanı artmaktadır. Bu nedenle küçük veri kümelerinde daha etkili kullanılabilir [19,20].




Şekil 4. K en yakın komşu algoritması grafiği

3. Veriseti

Çalışmamızda açık erişim olan kırık rotor çubuğu arızalarına sahip asenkron motorun veri seti kullanılmıştır. Üç fazlı asenkron motor üzerinde yapılan testlerden elde edilen elektriksel ve mekanik sinyaller veri setinde bulunmaktadır. Veri setinde kullanılan asenkron motor 3 faz, 1 hp güç, 220/380V besleme gerilimi, 4 kutup ve


1785 rpm nominal hıza sahiptir. Veri setinde 1, 2, 3 ve 4 kırık çubuğa sahip dört hata sınıfı ve de bir sağlıklı sınıf bulunmaktadır. Tüm sınıflar için veri seti, yük koşulu olarak 0.5, 1.0, 1.5, 2.0, 2.5, 3.0, 3.5 ve 4.0 Nm tork olarak 8 yük koşulundan oluşturulmuştur. Veri kümesi oluşturma için sağlıklı ve yükleme koşullarının her bir kombinasyonu için on deney yapılmıştır [21]. Bu çalışmada, sağlıklı ve yükleme koşullarının her bir kombinasyonu için sürülen taraftaki radyal mekanik titreşim sinyali ve bir faz akım sinyali kullanılmıştır. Radyal mekanik titreşim sinyali veri setinde Vib_acpi olarak, bir faz akım sinyali Ia olarak temsil edildiğinden, yapılan çalışmada bu temsilleri kullanılmıştır. Titreşim sinyallerinin örnekleme frekansı 7600 Hz ve elektriksel sinyallerinin örnekleme frekansı 50 kHz'dir. Çalışmada, 8 yük koşulu ve 5 arıza sınıfı için 1 sn lik sinyaller her bir deney için 40, toplamda 5 sn ve 10 deney göz önüne alındığında toplam sinyal sayısı 2000 adet oluşturulmuştur. Şekil 5'te arızalı asenkron motor veri seti elde etmek için kurulan deney seti görseli verilmiştir.



Şekil 5. Veri seti için kurulan deney seti


4. Deneysel Çalışmalar ve Bulgular

Deneysel çalışmalarda i7 İntel mikro işlemcisi 64 GB RAM'ı olan bir bilgisayar kullanılmıştır. Ayrıca makina öğrenme uygulamaları için de 8 GB RAM'a sahip Nvidia M4000 GPU kullanılmıştır. Tüm kodlamalar MATLAB ortamında gerçekleştirilmiştir. Titreşim sinyali Vib_acpi ve akım işareti Ia'nın güç spektrumlarında [900 1300] Hz bandında ilgilenilen frekans bileşenleri bulunmaktadır. Bu nedenle, Vib_acpi ve Ia sinyallerini bu bant aralığında filtrelemek için bir bant geçiren süzgeç kullanılmıştır. Bant geçiren filtrelemeden sonra sinyallerin zarfları hesaplanmış ve bu zarflar bir sonraki adımda kullanılmıştır. Veri setindeki sinyallerin uzunluğu 18 saniye olup, Vib_acpi ve Ia sinyallerinin zarflarının örnekleme için 11-15 saniye aralığında, 1 saniye uzunluğunda örtüşmeyen pencereler kullanılmıştır. Böylece her bir Vib_acpi ve Ia sinyali için toplam 2000 sinyal örneği oluşturulmuş ve deneysel çalışmalarda kullanılmıştır. 1 saniye uzunluğundaki Ia sinyali, filtrelenmiş durumu ve filtrelenmiş durumunun zarf spektrumu Şekil 6'da verilmiştir.



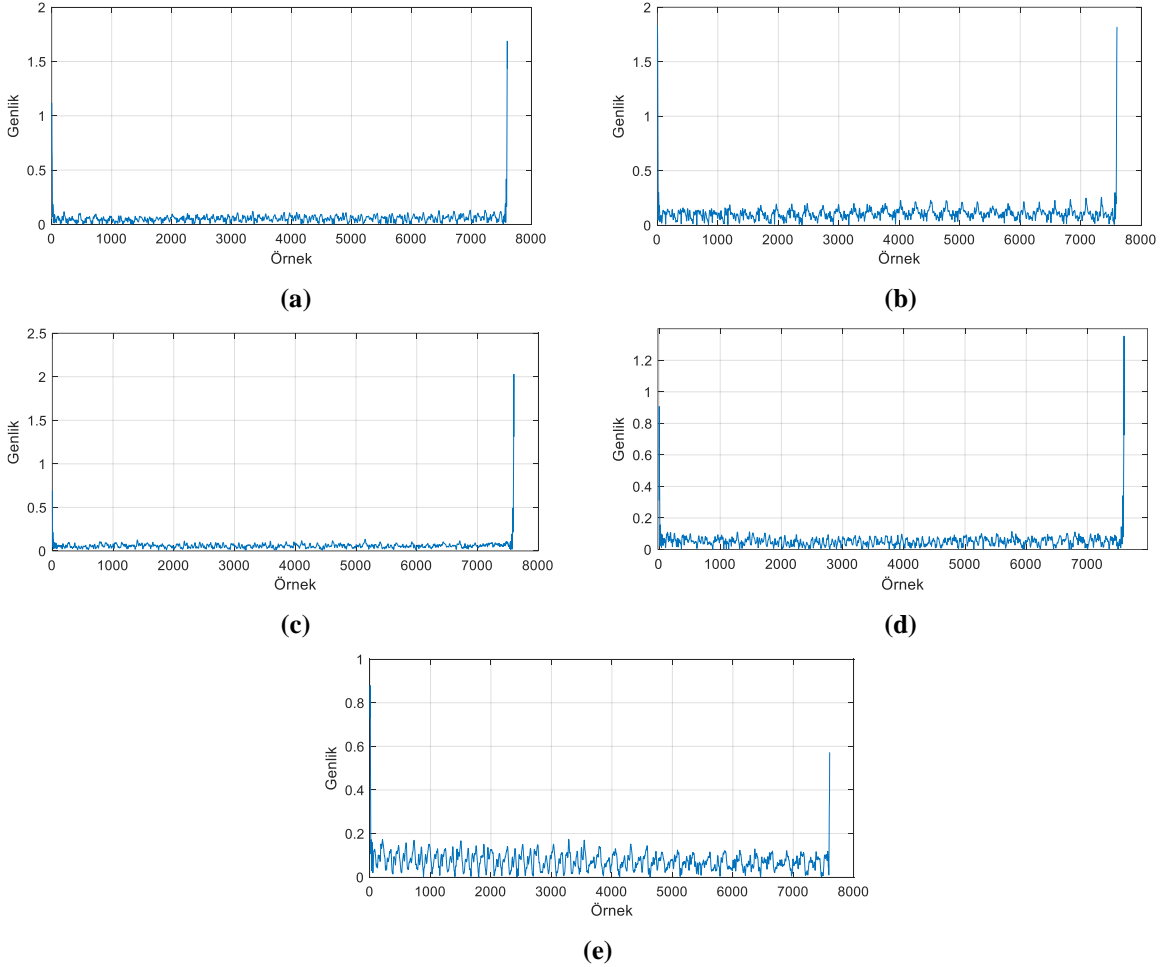
Şekil 6. 1 sn uzunluğunda Ia sinyali, filtrelenmiş hali ve zarf spektrumu

Zarf spektrumu analizi özellikle dönen makinelerin arıza teşhisinde sıklıkla kullanılan bir yöntemdir. Arızalı sinyal ile sağlıklı sinyal zarf spektrumu arasındaki farklılık, bazı istatistiksel yöntemler ve HFD gibi sinyal işleme teknikleri ile belirlenebilmektedir. Zarf spektrumu ile arıza analizi üç adıma ayrılabilir, İlk olarak sinyal filtrelenir, ikinci olarak üst zarfı ve bu zarfından Hilbert dönüşümü ile zarf spektrumları elde edilir. Son olarak AMA yöntemi gibi sinyal işleme teknikleri ile arıza özellikleri elde edilir [22].

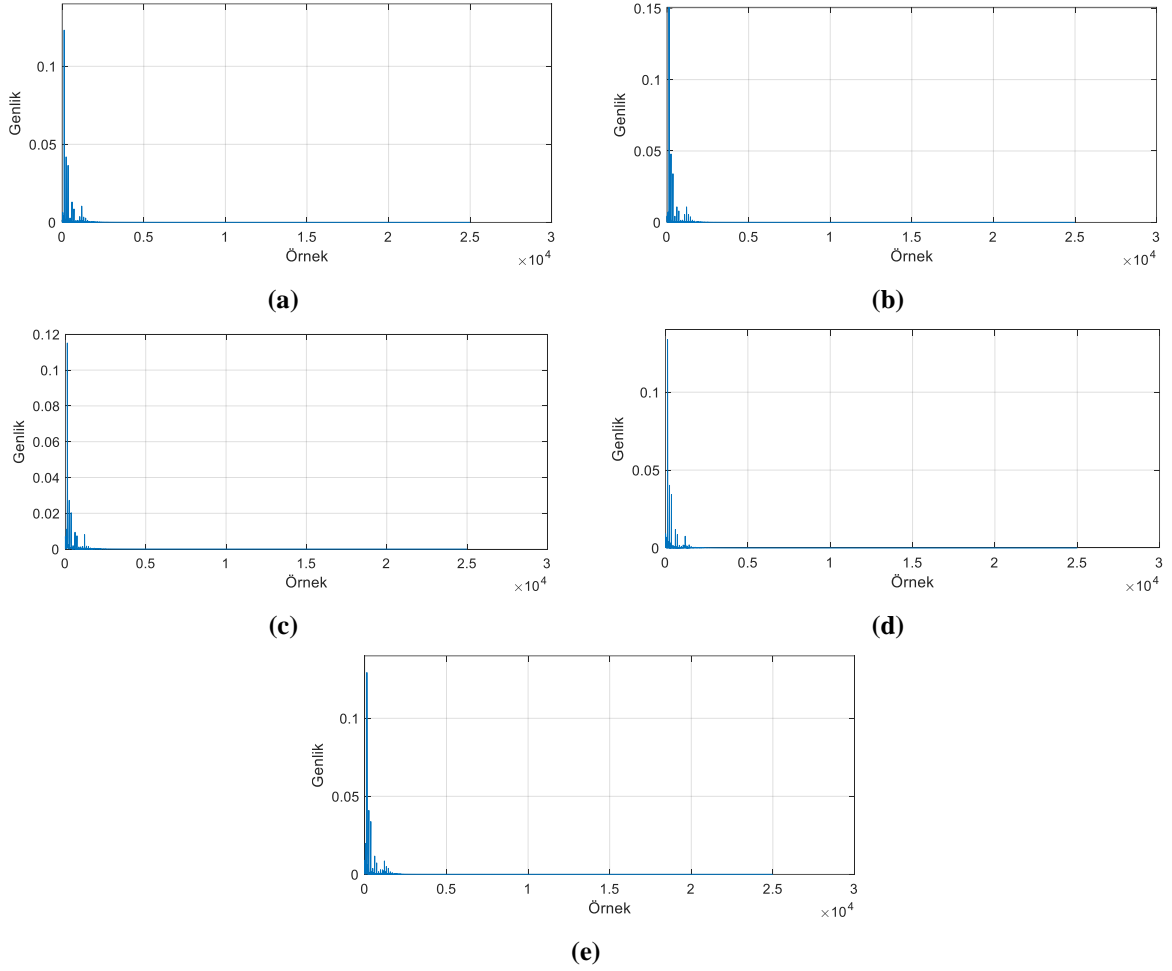


Şekil 7. 1 sn uzunluğunda Vib_acpi sinyali, filtrelenmiş hali ve zarflanmış durumu

Çalışmada kullanılan titreşim sinyali Vib_acpi sinyali, bu sinyalin filtrelenmiş durumu ile filtrelenip zarflanmış hali Şekil 7'de gösterilmiştir. Kırık rotor çubuğu olan arızalı bir asenkron motorun akım ve titreşim sinyallerindeki dalgalanmalar ve bu dalgalanmalara bağlı olarak zarfları ve zarf spektrumlarındaki farklılıkların iki temel değişkene bağlıdır. Bunlar motorun yük durumu ve kırık rotor çubuğu sayısıdır. Hem motorun yükündeki artış hem de kırık rotor çubuğu sayısındaki artış akım ve titreşim sinyallerinin spektrumlarındaki harmonik sayısında artışa ve bu harmoniklerin genliklerinin artmasına neden olmaktadır. Bu çalışmada sekiz farklı yük koşulu kullanılmış ama sınıflandırma işlemi sadece kırık çubuk sayısı için yapılmıştır. Sekiz farklı yük koşulunda ait sinyallerin kullanılması sınıflandırma zorluğunu arttırabilmektedir. Şekil 8'de, tüm arıza sınıfları için Vib_acpi sinyallerinin zarfları göstermektedir. Ayrıca Şekil 9'da tüm arıza sınıfları için la akım sinyalinin zarf spektrumunu verilmiştir.



Şekil 8. 0.5 Nm yük koşulu için Vib_acpi'nin zarf sinyali a) Sağlıklı, b) Bir kırık çubuk, c) İki kırık Çubuk, d) Üç kırık Çubuk, e) Dört kırık çubuk

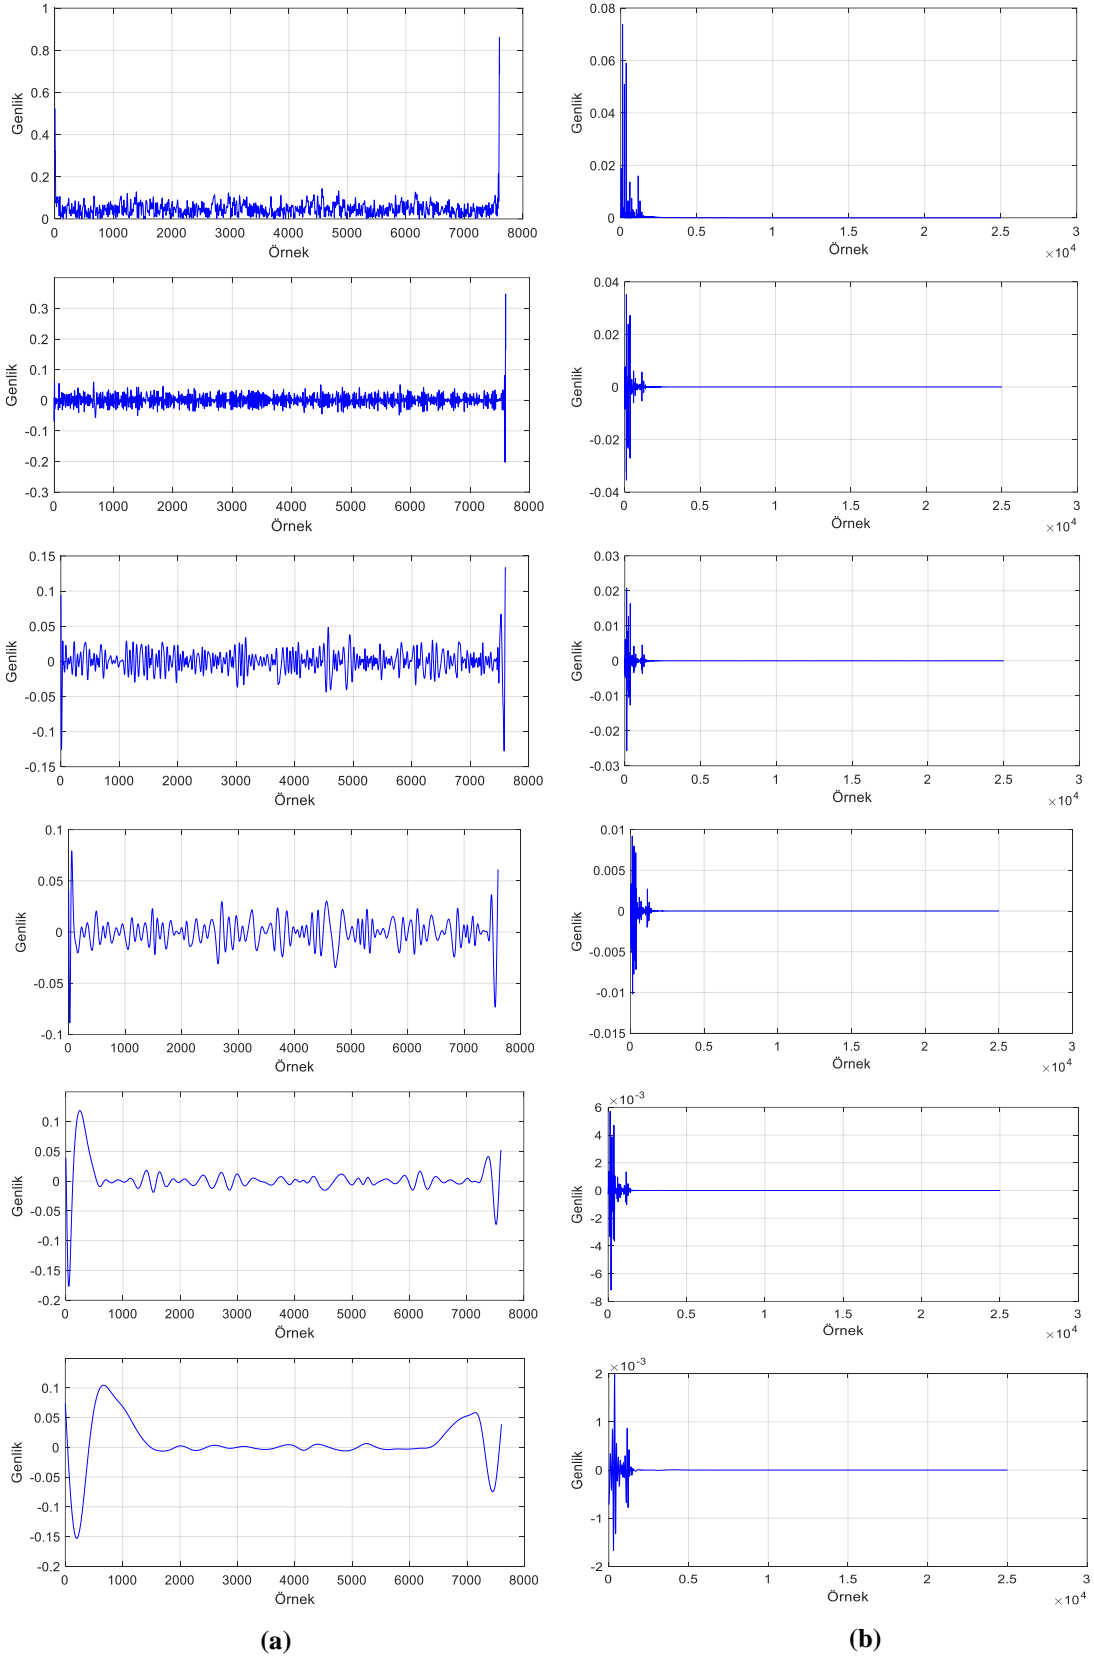


Şekil 9. 0.5 Nm yük koşulu için Ia'nın zarf spektrumu sinyali a) Sağlıklı, b) Bir kırık çubuk, c) İki kırık Çubuk, d) Üç kırık Çubuk, e) Dört kırık çubuk

Asenkron motorda kırık rotor çubuğu arızası teşhisi için, Ia ve Vib_acpi sinyalleri filtrelenip zarfları ve zarf spektrumları elde edildikten sonra AMA yöntemi ile 5 adet İMF'ye ayrıştırılmıştır. Şekil 10'da Vib_acpi ve Ia'nın İMF'leri verilmiştir. Bu şekillerden de anlaşılacağı gibi, İMF sayısı arttıkça ilgili İMF bileşenin genliğindeki değişim azalmaya başlamaktadır ve bu durumda ayrıştırma işlemi bitirilebilir. Son İMF bileşeni artık sinyal olarak adlandırılmaktadır. Artık sinyal üzerinde arıza bilgisi zayıf olmaktadır. Çalışma için kullanılan sinyallerin 5. İMF seviyesinde genlik değişimi azaldığında İMF sayısı bu çalışmada 5 olarak belirlenmiştir.

Arıza sınıflandırılması yapılmadan önce, İMF'lerine ayrıştırılmış sinyallerin anlık frekans ve spektral entropi öznitelikleri elde edilmiştir. Bu öznitelikler motorun arıza durumunda farklılık gösterdiğinden arıza sınıflandırması için kullanılabilirler. Elde edilen bu öznitelikler uç uca ekleme yöntemiyle birleştirilmiş ve yeni arıza öznitelik vektörü oluşturulmuştur. Ayrıca hem akım hem de titreşim sinyallerinden elde edilen bu özellik vektörleri de birleştirilmiştir. Doğal olarak arızanın hem akım sinyali üzerindeki etkisi hem de titreşim sinyali üzerindeki etkisi özellik vektöründe bulunmaktadır. Bu adımdan sonra, Relief öznitelik seçim algoritması ile en etkili 10000 öznitelik seçilmiş ve sınıflandırıcılara verilmiştir.

Bu çalışmada üç farklı makine öğrenmesi yöntemiyle sınıflandırma yapılmıştır. Bunlar karar ağacı (KA), destek vektör makinesi (DVM) ve k en yakın komşu (KEK) yöntemleridir. Sınıflandırmaların başarı parametresi olarak sınıflandırma doğruluğu seçilmiştir. KA kullanılarak yapılan sınıflandırmada Matlab yazılımında "fine tree" özelliği kullanılmış ve %67,6 sınıflandırma doğruluğu elde edilmiştir. DVM yöntemi için "Quadratic SVM" kullanılmış ve %93,3 sınıflandırma doğruluğu elde edilmiştir. Son olarak KEK yönteminde en yakın komşu sayısı 5 parametresi ile sınıflandırma yapılmış ve %88,1 doğruluk elde edilmiştir.

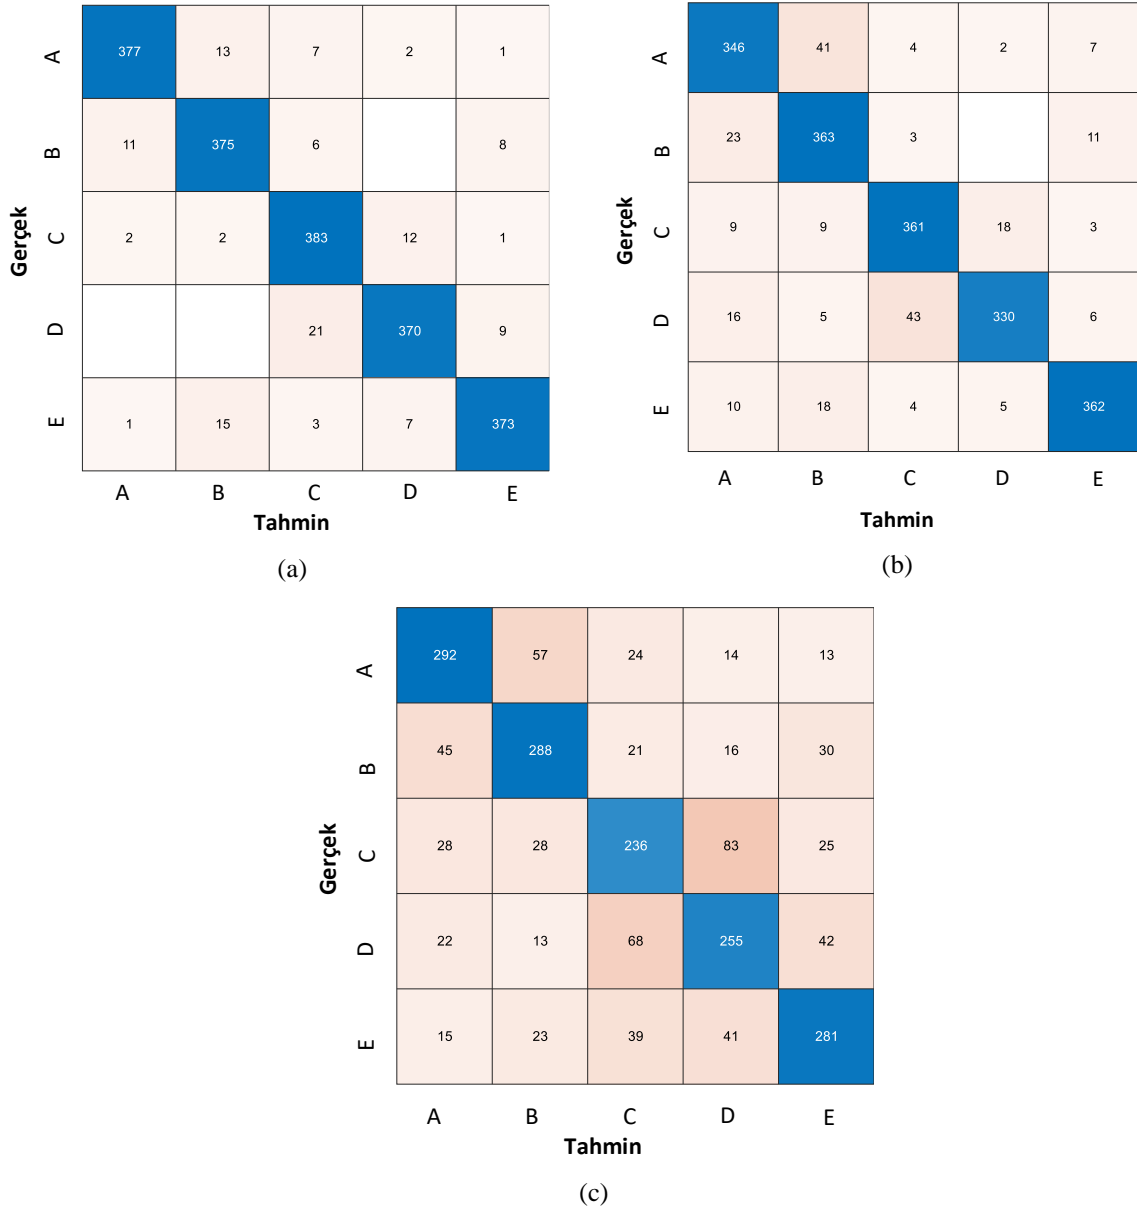


Şekil 10. 4Nm yük durumu ve sağlam motor için a) Vib_acpi ve 5 İMF seviyesi, b) Ia ve 5 İMF seviyesi

Tablo 1. Sınıflandırma Sonuçları

Sınıflandırıcı	Doğruluk
DVM	%93.9
KEK	%88.1
KA	%67.6

Yapılan sınıflandırmalara ait doğruluk değerleri Tablo 1’de verilmiştir. Ayrıca, kullanılan sınıflandırıcıların başarımları karışıklık (karmaşıklık ve ya karışıklık) matrisleri ile de incelenmiştir. Şekil 11’de kullanılan sınıflandırıcılar için elde edilen karışıklık matrisleri gösterilmiştir. Karışıklık matrisinde her arıza sınıfı için 400 adet tahmin sonucu bulunmaktadır. Karışıklık matrislerinde bir kırık çubuk için A, iki kırık çubuk için B, üç kırık çubuk için C, dört kırık çubuk için D ve sağlıklı motor için E kullanılmıştır.

**Şekil 11.** Kümülatif karışıklık matrisleri a) DVM b)KEK c)KA

DVM sınıflandırıcısı için elde edilen karışıklık matrisi incelendiğinde, DVM'nin en iyi sınıflandırma başarımını, 383 adet doğru 17 yanlış tahminle 3 kırık çubuk arıza sınıfı için elde ettiği görülmüştür. Ayrıca, DVM ile en düşük sınıflandırma doğruluğu, 370 doğru ve 30 yanlış tahminle 4 kırık çubuk arıza sınıfı için elde edilmiştir. Ayrıca 1 kırık çubuk sınıfı için 377 doğru 23 yanlış tahmin, 2 kırık çubuk için 375 doğru 25 yanlış tahmin, sağlıklı sınıf için 373 doğru 27 yanlış tahmin elde edilmiştir. KEK ile yapılan sınıflandırma başarısı %88,3 olmuş ve en yüksek başarı 363 doğru 37 yanlış tahmin ile 2 kırık çubuk arızası sınıfında elde edilirken en düşük başarı 330 doğru 70 yanlış tahminle 4 kırık çubuk sınıfında elde edilmiştir. Ayrıca bu sınıflandırma algoritmasında sırasıyla, 1 kırık çubuk için 346 doğru 54 yanlış tahmin, 3 kırık çubuk için 361 doğru 39 yanlış tahmin, sağlıklı rotor sınıfı için 362 doğru 38 yanlış tahmin sonucu elde edilmiştir. Bu çalışmada yapılan son sınıflandırma yönteminde KA kullanılmış ve toplamda %67,6 sınıflandırma başarısı elde edilmiştir. Bu sınıflandırma yönteminde 292 doğru 108 yanlış tahminle 1 kırık çubuk arızası sınıfında en yüksek başarı elde edilirken, 236 doğru 164 yanlış tahminle 3 kırık çubuk arızası sınıfında en düşük başarı elde edilmiştir. Bu sınıflandırma yönteminde diğer sonuçlar sırasıyla, 288 doğru 112 yanlış tahmin ile 2 kırık çubuk, 255 doğru 145 yanlış tahminle 4 kırık çubuk ve 281 doğru 119 yanlış tahminle sağlıklı rotor sınıflarının sınıflandırması şeklinde olmuştur.

Genel olarak karışıklık matrisleri incelendiğinde, sınıflandırmada yanlış tahminlerin komşu sınıflar arasında yoğunlaştığı görülmektedir. Örneğin, DVM ile sınıflandırılmada en çok sayıda yanlış tahmin 4 kırık çubuk arızasının 3 kırık çubuk olarak tahmin edilmesi olmuştur. Benzer şekilde KEK ile sınıflandırılmada en kötü tahmin 43 adet ile 4 kırık çubuğun 3 kırık çubuk olarak, 41 adet ile 1 kırık çubuğun 2 kırık çubuk olarak tahmin edilmesi olmuştur. Aynı durum KA ile sınıflandırmada da görülmektedir. Bu sınıflandırmada 83 adet ile 3 kırık çubuğun 4 kırık çubuk olarak sınıflandırılması, yine 68 adet ile 4 kırık çubuğun 3 kırık çubuk olarak sınıflandırılması, ayrıca 57 adet ile 1 kırık çubuğun 2 kırık çubuk olarak sınıflandırılması yanlış tahminlerin komşu sınıflar arasında yoğunlaştığını pekiştirmektedir. Bu duruma, çalışma için 8 farklı yük ile çalıştırılmış motor sinyallerinin kullanılmasının neden olduğu düşünülmektedir.

Makine öğrenmesi modellerinin performanslarını değerlendirmede doğruluk değerinin yanında kesinlik (precision), duyarlılık (recall) ve bunların harmonik ortalaması olan f1 değerleri kullanılabilir. Öneri robotu gibi uygulamalarda sınıf bazlı f1 değeri kullanılabilir de bu parametreler özellikle dengesiz veri setlerinde ve ikili sınıflandırma problemlerinde performans değerlendirmesi olarak etkili olmaktadır. Tablo 2'de bu çalışmada uygulanan yöntemler için bu performans değerleri verilmiştir. Çalışma için kullanılan veri kümesi, dengeli yani içerisinde her sınıf için eşit sayıda örnek bulunduğu için, ortalama f1 değeri doğruluk değeri ile aynı olmaktadır. Yine de bu parametreler ile diğerlerinden olumsuz olarak ayrılan sınıf belirlenebilmektedir ve bu çalışmada tüm sınıfların f1 değeri doğruluk değerleri ile paralellik göstermektedir. Bu nedenle bu çalışma için yapılan değerlendirme karşılaştırmasında doğruluk değeri kullanılmıştır [23-25].

Tablo 2. Yapılan sınıflandırmaların performans değerleri

Sınıflandırıcı	Durum	Kesinlik	Duyarlılık	f1	Ortalama f1	Doğruluk
DVM	A	0.9641	0.9425	0.9532	0.939	0.939
	B	0.9259	0.9375	0.9316		
	C	0.9119	0.9575	0.9341		
	D	0.9462	0.9250	0.9355		
	E	0.9515	0.9348	0.9431		
KEK	A	0.8564	0.8650	0.8606	0.881	0.881
	B	0.8325	0.9075	0.8684		
	C	0.8698	0.9025	0.8858		
	D	0.9295	0.8250	0.8741		
	E	0.9305	0.9072	0.9187		
KA	A	0.7263	0.7300	0.7281	0.676	0.676
	B	0.7041	0.7200	0.7119		
	C	0.6082	0.5900	0.5989		
	D	0.6234	0.6375	0.6304		
	E	0.7186	0.7042	0.7113		

Tablo 3. Kullanılan veri seti için uygulanan yöntemlerin karşılaştırılması

Referans	Kullanılan Özellik	Sınıflandırıcı	Doğruluk (%)
[16]	Vib_acpi'in ResNet18 ile elde edilen özellikleri	KEK	99.5
[16]	Ia'nın ResNet18 ile elde edilen özellikleri	ESA	95.0
[16]	Derin transfer öğrenme ile Vib_acpi'den elde edilen özellikler	DVM	99.0
[16]	Derin transfer öğrenme ile Ia'dan elde edilen özellikler	DVM	94.5
[16]	Derin transfer öğrenme ile Ia ve Vib_acpi'nin birleştirilmiş özellikleri	DVM	100.0
[26]	Ia ve Vib_acpi'in frekans temelli ve istatistiksel özellikleri	KA	93.8
[26]	Ia ve Vib_acpi'in frekans temelli ve istatistiksel özellikleri	KEK	98.8
[27]	Vibrasyon sinyallerinin zaman bölgesi özellikleri	KEK	77.37
[27]	Vibrasyon sinyallerinin zaman bölgesi özellikleri	KA	83.80
Bu çalışma	Vib_acpi ve Ia dan AMA yöntemi ile çıkarılan spektral entropi ve anlık frekans özellikleri	KA	67.6
Bu çalışma	Vib_acpi ve Ia dan AMA yöntemi ile çıkarılan spektral entropi ve anlık frekans özellikleri	KEK	88.1
Bu çalışma	Vib_acpi ve Ia dan AMA yöntemi ile çıkarılan spektral entropi ve anlık frekans özellikleri	DVM	93.9

Bu çalışmada elde edilen sonuçlar ile literatürde aynı veri seti üzerinde yapılan çalışmaların sonuçları Tablo 3'de verilmiştir. Literatürde kullanılan veri seti üzerinde yapılan çalışmalar sınırlı olduğundan sadece üç farklı çalışma için yapılan uygulamalar ile karşılaştırma yapılabilmektedir. Bu çalışmalara bakıldığında, sürekli dalgacık dönüşümü ile sinyallerin frekans temelli özellikleri iyi temsil edilebildiğinden ve evrişimli sinir ağları ile görüntüler yüksek başarı ile sınıflandırabildiğinden [16] nolu çalışmada daha yüksek başarı elde edilmiştir. Ayrıca AMA yöntemi durağan olmayan sinyallerde daha başarılı sonuç verebilirken, akım sinyali gibi durağan olan sinyallerde ise aynı başarıyı mümkün olmamıştır. Evrişimli sinir ağı ve sürekli dalgacık dönüşümü kullanılarak daha yüksek başarı elde edilebilirken, daha hızlı sınıflandırma söz konusu olduğunda bu çalışmada kullanılan DVM temelli yaklaşım tercih edilebilir.

5. Sonuç

Bu çalışmada, asenkron motorlarda meydana gelen kırık rotor çubuğu sayısının belirlenmesi için AMA yöntemi ve makine öğrenmesi yöntemlerinin bazılarını temel alan bir yaklaşım önerilmiştir. Önerilen yaklaşımlarla kırık rotor çubuğu sayısı başarılı bir şekilde tespit edilmiştir. Literatürde bu konuda yapılan çalışmalarda genellikle sinyal işleme tabanlı istatistiksel yöntemler kullanılmış olup, çalışmaların büyük çoğunluğunda yük koşulu ve arıza çeşitliliğinin düşük olduğu görülmektedir. Yük koşulu ve arıza çeşitliliğinin artması arıza teşhisini zorlaştırmasına rağmen, bu çalışmada sekiz farklı yük koşulunda ve beş arıza sınıfında arıza teşhisinin başarılı bir şekilde yapılmasıyla yük ve arıza çeşitliliğinin oluşturduğu zorluğunun üstesinden gelinmiştir. Elde edilen sonuçlar göz önüne alındığında yük çeşitliliğine rağmen, AF ve SE özelliklerinin AMA yöntemiyle çıkarılıp DVM ile sınıflandırılma yapılarak kırık rotor çubuğu sayısının başarılı bir şekilde yapılabileceği görülmektedir. Gelecekteki çalışmalarda asenkron motorlarda aynı anda meydana gelebilecek birden fazla arızanın teşhisi, önerilen yöntem ile yapılabileceği düşünülmektedir. Elektrik motorların hayatın her alanına girdiği günümüzde, farklı elektrik motorlarının arıza teşhisinde de çalışmada uygulanan yaklaşımın kullanılabileceği düşünülebilir.

Kaynaklar

- [1] Garcia M, Antonino-Daviu J. Efficiency assessment of induction motors operating under different fault conditions. *Proceedings of the IEEE International Conference on Industrial Technology*, 2018-Şubat, 1837-42.
- [2] Halder S, Bhat S, Zychma D, Sowa P. Broken Rotor Bar Fault Diagnosis Techniques Based on Motor Current Signature Analysis for Induction Motor—A Review. *Energies*, 2022, 15, 1-20.
- [3] Mohammed A, Melecio JI, Djurovic S. Stator winding fault thermal signature monitoring and analysis by in Situ FBG sensors. *IEEE Transactions on Industrial Electronics*, 2019, 66, 8082-92.
- [4] Shao S, Yan R, Lu Y, Wang P, Gao RX. DCNN-Based multi-signal induction motor fault diagnosis. *IEEE Transactions*

- on *Instrumentation and Measurement*, IEEE. 2020, 69, 2658–69.
- [5] Sbaa S, Bessous N, Pusca R, Romary R. A comparative study dedicated to rotor failure detection in induction motors using MCSA, DWT, and EMD techniques. *2020 International Conference on Electrical Engineering, ICEE 2020*.
- [6] Agoston K. Fault Detection of the Electrical Motors Based on Vibration Analysis. *Procedia Technology*, 2015, 19, 547–53.
- [7] Fourati A, Feki N, Bourdon A, Rémond D, Chaari F, Haddar M. Electrical modeling for faults detection based on motor current signal analysis and angular approach. *Applied Condition Monitoring*, 2016, p. 15–25.
- [8] Reddy MSP, Reddy DM, Devendiran S, Mathew AT. Bearing Fault Diagnosis Using Empirical Mode Decomposition, Entropy Based Features and Data Mining Techniques. *Materials Today: Proceedings*, Elsevier Ltd. 2018, 5, 11460–75.
- [9] Faiz J, Ghorbanian V, Ebrahimi BM. EMD-Based analysis of industrial induction motors with broken rotor bars for identification of operating point at different supply modes. *IEEE Transactions on Industrial Informatics*, IEEE. 2014, 10, 957–66.
- [10] Valles-Novo R, De Jesus Rangel-Magdaleno J, Ramirez-Cortes JM, Peregrina-Barreto H, Morales-Caporal R. Empirical mode decomposition analysis for broken-bar detection on squirrel cage induction motors. *IEEE Transactions on Instrumentation and Measurement*, IEEE. 2015, 64, 1118–28.
- [11] Huang NE, Shen, Z, Long SR, Wu MC, Snin HH, Zheng Q. The empirical mode decomposition and the Hubert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 1998, 454, 903–95.
- [12] Deniz E, Sobahi N, Omar N, Sengur A, Acharya UR. Automated robust human emotion classification system using hybrid EEG features with ICBrainDB dataset. *Health Information Science and Systems*, 2022, 10.
- [13] Demir F, Sengur A, Ari A, Siddique K, Alswaiti M. Feature Mapping and Deep Long Short Term Memory Network-Based Efficient Approach for Parkinson's Disease Diagnosis. *IEEE Access*, IEEE. 2021, 9, 149456–64.
- [14] Aslan M, Akbulut Y, Şengür A, İnce MC. Skeleton based efficient fall detection. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 2017, 32, 1025–34.
- [15] Ucar, F., Alcin, O.F., Dandil, B. and Ata, F. Machine learning based power quality event classification using wavelet - Entropy and basic statistical features. *2016 21st International Conference on Methods and Models in Automation and Robotics, MMAR 2016*, 414–9.
- [16] Dişli, F., Gedikpinar, M. ve Şengür, A. Deep Transfer Learning-Based Broken Rotor Fault Diagnosis For Induction Motors Asenkron Motor Kırık Rotor Çubuğu Arızasının Derin Transfer Öğrenme Tabanlı Teşhisi. *Turkish Journal of Science & Technology*, 2023, 18, 275–90.
- [17] Şengür, D. Investigation of the relationships of the students' academic level and gender with Covid-19 based anxiety and protective behaviors : A data mining approach. *Turkish Journal of Science & Technology*, 2020, 15, 93–9.
- [18] Samantaray SR, Kamwa I, Joos G. Decision tree based fault detection and classification in distance relaying. *Engineering Intelligent Systems*, 2011, 19, 139–47.
- [19] Kilincer IF, Ertam F, Sengur A. Machine learning methods for cyber security intrusion detection: Datasets and comparative study. *Computer Networks*, Elsevier B.V. 2021, 188, 107840.
- [20] Şengür D, Turhan M. Prediction Of The Action Identification Levels Of Teachers Based On Organizational Commitment And Job Satisfaction By Using K-Nearest Neighbors Method. *Firat University Turkish Journal of Science and Technology*, 2018, 13, 61–8.
- [21] Aline ET, Rogério AF, Marcelo S, Narco ARM. Experimental database for detecting and diagnosing rotor broken bar in a three-phase induction motor, IEEE Dataport 2020. <https://doi.org/https://dx.doi.org/10.21227/fimnm-bn95>
- [22] Chauhan DS, Dubey J. Envelope Spectrum Analysis for Rolling Element Bearing Faults Diagnosis by Using Kurtogram and Spectral Kurtosis for Band Selection. *International Journal of Scientific Research and Engineering Development*, 2021, 4, 794–801.
- [23] Amazon Machine Learning: Developer Guide. <https://docs.aws.amazon.com/machine-learning/latest/dg/multiclass-model-insights.html>
- [24] Powers, D.M.W. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation, 2020.
- [25] Gonzalez-Ramirez A, Lopez J, TereesRoman D, Yanez-Vargas I. Analysis Analysis of multi-class classification performance metrics for remote sensing imagery imbalanced datasets. *Journal of Quantitative and Statistical Analysis*, 2021, 8, 11–7.
- [26] Matworks. <https://www.mathworks.com/help/predmaint/ug/broken-rotor-fault-detection-in-ac-induction-motors-using-vibration-and-electrical-signals.html>.
- [27] Misra S, Kumar S, Sayyad S, Bongale A, Jadhav P, Kotecha K. Fault Detection in Induction Motor Using Time Domain and Spectral Imaging-Based Transfer Learning Approach on Vibration Data. *Sensors*, 2022, 22, 1–17.