

Asenkron Motorlardan Elde Edilen Titreşim Sinyalleri Kullanılarak Arıza Tespiti

Sefa Bulut

YÜKSEK LİSANS TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Mayıs 2018

Fault Detection Using Vibration Signals Obtained From Induction Motors

Sefa Bulut

MASTER OF SCIENCE THESIS

Department of Electrical and Electronics Engineering

May 2018

Asenkron Motorlardan Elde Edilen Titreşim Sinyalleri Kullanılarak Arıza Tespiti

Sefa Bulut

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliği Uyarınca
Elektrik Elektronik Mühendisliği Anabilim Dalı
Elektrik Makineleri Bilim Dalında
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır

Danışman: Prof. Dr. M. Bilginer Gülmezoğlu

Bu tez ESOGÜ BAP tarafından “2017-1610” no’lu proje çerçevesinde desteklenmiştir.

Mayıs 2018

ONAY

Elektrik Elektronik Mühendisliđi Anabilim Dalı Yüksek Lisans öđrencisi Sefa Bulut'un YÜKSEK LİSANS tezi olarak hazırladıđı "Asenkron Motorlardan Elde Edilen Titreşim Sinyalleri Kullanılarak Arıza Tespiti" başlıklı bu alıřma, jürimizce lisansüstü yönetmeliđin ilgili maddeleri uyarınca deđerlendirilerek oybirliđi ile kabul edilmiřtir.

Danışman : Prof. Dr. M. Bilginer Gülmezođlu

İkinci Danışman : -

Yüksek Lisans Tez Savunma Jürisi:

Üye : Prof. Dr. M. Bilginer Gülmezođlu

Üye : Doç Dr. Semih Ergin

Üye : Dr. Öğr. Üyesi řener Ađalar

Üye : -

Üye : -

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun tarih ve
..... sayılı kararıyla onaylanmıřtır.

Prof. Dr. Hürriyet ERřAHAN
Enstitü Müdürü

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Prof. Dr. M. Bilginer Gülmezođlu danışmanlığında hazırlamış olduđum “Asenkron Motorlardan Elde Edilen Titreşim Sinyalleri Kullanılarak Arıza Tespiti” başlıklı YÜKSEK LİSANS tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; tezimde verdiđim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiđimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduđumu beyan ederim. 24/05/2018

Sefa Bulut

İmza

ÖZET

Asenkron motorlar, verimlilikleri ve düşük maliyetleri sebebiyle endüstriyel uygulamalarda sıklıkla kullanılmaktadır. Ancak, bu motorlarda meydana gelebilecek arızalar, işletmedeki tüm süreci etkileyeceği için bu arızaların erken tespiti büyük önem taşımaktadır. Bu arızaların tespiti için genellikle akım, titreşim ve akustik sinyaller kullanılmaktadır. Bu tez çalışmasında, asenkron motorun rulmanlarından alınan titreşim sinyalleri kullanılarak arıza tespiti yapılmıştır. Hem literatürde sıklıkla kullanılan bir hazır veri seti kullanılarak, hem de laboratuvar ortamında bir veri seti oluşturularak titreşim sinyalleri elde edilmiştir. Elde edilen titreşim sinyallerine 4 farklı öznitelik çıkarma yöntemi uygulanarak öznitelik vektörleri oluşturulmuştur. Elde edilen bu öznitelik vektörlerinden en değerli öznitelikleri elde edebilmek ve boyut indirgemek için Temel Bileşen Analizi (TBA) ve Genetik Algoritma (GA) yöntemleri kullanılmıştır. Hem öznitelik seçimi yapılmadan, hem de öznitelik seçimi yapıldıktan sonra elde edilen öznitelik vektörleri 5 farklı sınıflandırıcıya (k-En Yakın Komşuluk (k-EYK), Ortak Vektör Yaklaşımı (OVY), Destek Vektör Makineleri (DVM), Yapay Sinir Ağları (YSA) ve Fisher'in Doğrusal Ayırtaç Analizi (FDAA)) uygulanmış ve sınıflandırıcıların tanıma performansları test edilmiştir.

Anahtar Kelimeler: Örüntü tanıma, asenkron motor, arıza tespiti, öznitelik çıkarımı, öznitelik seçimi, sınıflandırma

SUMMARY

Induction motors are widely used in industrial applications by the reason of their efficiency and low cost. Since, faults on these motors may influence the whole process in operation, early detection of these faults has great importance. Current, vibration and acoustic signals are generally used for detection of these faults. In this thesis, fault detection is performed using vibration signals collected from ball bearings of induction motor. Vibration signals are obtained both using an open database which has been used in the literature enormously and constructing a database in the laboratory. Feature vectors are constructed by applying 4 different feature extraction method to obtained vibration signals. Principal Component Analysis (PCA) and Genetic Algorithm are used in order to obtain most valuable features and reduce dimension. Both with feature selection and without feature selection, feature vectors are applied to 5 different classifiers (k-Nearest Neighbor (k-NN), Common Vector Approach (CVA), Support Vector Machines (SVM), Artificial Neural Network (ANN) and Fisher's Linear Discriminant Analysis (FLDA)) and recognition performances of classifiers are tested.

Keywords: Pattern recognition, induction motor, fault detection, feature extraction, feature selection, classification

TEŞEKKÜR

Tez konumun belirlenmesinde ve tezimin tamamlanmasında yardımlarını esirgemeyen tez danışmanım Sayın Prof. Dr. M. Bilginer GÜLMEZOĞLU'na, tezimin tüm aşamalarında yardımlarını esirgemeyen Sayın Doç. Dr. Semih ERGİN'e ve 2017-1610 numaralı proje kapsamında gerekli malzeme ve cihaz desteği sağlayan Bilimsel Araştırma Projeleri (BAP) kuruluna teşekkür ederim.

Ayrıca bu süreçte bana destek olan aileme, değerli çalışma arkadaşlarım Sayın Dr. Öğr. Üyesi Burak URAZEL, Sayın Şemsettin ÜRKMEZ ve Sayın Kaya TURGUT'a teşekkür ederim.

İÇİNDEKİLER

Sayfa

| | |
|---|------|
| ÖZET | vi |
| SUMMARY | vii |
| TEŞEKKÜR | viii |
| İÇİNDEKİLER | ix |
| ŞEKİLLER DİZİNİ | xi |
| ÇİZELGELER DİZİNİ | xii |
| SİMGELER VE KISALTMALAR DİZİNİ | xiii |
| 1. GİRİŞ VE AMAÇ | 1 |
| 2. LİTERATÜR ARAŞTIRMASI | 4 |
| 2.1. Akım Sinyalleri Kullanılarak Arıza Tespiti | 4 |
| 2.2. Akustik Sinyaller Kullanılarak Arıza Tespiti | 5 |
| 2.3. Titreşim Sinyalleri Kullanılarak Arıza Tespiti | 5 |
| 3. MATERYAL VE YÖNTEM | 9 |
| 3.1. Veri Seti | 9 |
| 3.1.1. CWRU veri seti | 9 |
| 3.1.2. Laboratuvar veri seti | 11 |
| 3.2. Yöntem | 12 |
| 4. ÖZİNİTELİK ÇIKARIMI | 14 |
| 4.1. Zaman ve Frekans Düzlemi Parametreleri | 14 |
| 4.2. Dalgacık Paket Dönüşümü | 16 |
| 4.3. Ampirik Kip Ayrışımı | 20 |
| 4.4. Otoregresif Model | 22 |
| 5. BOYUT İNDİRGEME VE ÖZİNİTELİK SEÇİMİ | 23 |
| 5.1. Temel Bileşen Analizi | 24 |
| 5.2. Genetik Algoritma | 24 |
| 6. SINIFLANDIRICILAR | 27 |
| 6.1. Fisher' in Doğrusal Ayırtaç Analizi | 27 |
| 6.2. Ortak Vektör Yaklaşımı | 28 |
| 6.3. K-En Yakın Komşuluk | 30 |

İÇİNDEKİLER (devam)

| | <u>Sayfa</u> |
|--|---------------------|
| 6.4. Destek Vektör Makineleri | 31 |
| 6.5. Yapay Sinir Ağları..... | 32 |
| 7. BULGULAR VE TARTIŞMA | 35 |
| 7.1. Öznitelik Vektörlerinin Oluşturulması | 35 |
| 7.1.1. Zaman ve frekans düzlemi öznitelikleri | 36 |
| 7.1.2. Dalgacık Paket Dönüşümü | 36 |
| 7.1.3. Ampirik Kip Ayırışımı | 36 |
| 7.1.4. Ampirik Kip Ayırışımı-Otoregresif Model | 36 |
| 7.1.5. Bütün öznitelikler | 39 |
| 7.2. Boyut İndirgeme ve Öznitelik Seçimi | 39 |
| 7.3. Sınıflandırma | 39 |
| 7.4. Sonuçlar | 40 |
| 8. SONUÇ VE ÖNERİLER | 47 |
| KAYNAKLAR DİZİNİ..... | 49 |

ŞEKİLLER DİZİNİ

| <u>Sekil</u> | <u>Sayfa</u> |
|--|---------------------|
| 1.1. Asenkron motor arızalarının sınıflandırılması..... | 1 |
| 1.2. Asenkron motorlarda meydana gelen arızaların dağılımı | 2 |
| 3.1. CWRU veri seti elde etmek için kurulan test düzeneği..... | 9 |
| 3.2. Laboratuvar ortamında kurulan test düzeneği | 11 |
| 3.3. Arıza tespiti akış diyagramı | 13 |
| 4.1. 3 seviye Ayrık Dalgacık Dönüşümü..... | 17 |
| 4.2. 3 seviye Dalgacık Paket Ayrıştırması..... | 18 |
| 4.3. Db4, db8, db9 ve db10 dalgacık fonksiyonları..... | 19 |
| 4.4. AKA uygulanmış bir sinyal örneği..... | 21 |
| 5.1. GA akış diyagramı..... | 26 |
| 6.1. İki sınıflı bir problem için k-EYK örneği..... | 31 |
| 6.2. Doğrusal DVM örneği..... | 32 |
| 6.3. Çok Katmanlı Algılayıcı örneği | 33 |
| 7.1. Normal duruma ait ilk 4 İKF | 37 |
| 7.2. İç bilezik arızalı duruma ait ilk 4 İKF | 37 |
| 7.3. Dış bilezik arızalı duruma ait ilk 4 İKF | 38 |
| 7.4. Bilye arızalı duruma ait ilk 4 İKF..... | 38 |

ÇİZELGELER DİZİNİ

| <u>Cizelge</u> | <u>Sayfa</u> |
|---|--------------|
| 3.1. CWRU-1 veri setine ait bilgiler..... | 10 |
| 3.2. CWRU-2 veri setine ait bilgiler..... | 10 |
| 3.3. 6205 rulman özellikleri..... | 12 |
| 4.1. Zaman düzlemi istatistiksel parametreleri..... | 15 |
| 7.1. Öznitelik seçimi yapılmadan CWRU-1 veri seti için elde edilen sonuçlar | 41 |
| 7.2. Öznitelik seçimi yapılmadan CWRU-2 veri seti için elde edilen sonuçlar | 41 |
| 7.3. Öznitelik seçimi yapılmadan Lab. veri seti için elde edilen sonuçlar | 41 |
| 7.4. TBA ve GA uygulandıktan sonra CWRU-1 veri seti için elde edilen sonuçlar | 42 |
| 7.5. TBA ve GA uygulandıktan sonra CWRU-2 veri seti için elde edilen sonuçlar | 42 |
| 7.6. TBA ve GA uygulandıktan sonra Lab. veri seti için elde edilen sonuçlar | 43 |
| 7.7. GA ile CWRU-1 veri seti için elde edilen ortalama öznitelik sayıları | 43 |
| 7.8. GA ile CWRU-2 veri seti için elde edilen ortalama öznitelik sayıları | 44 |
| 7.9. GA ile Lab. veri seti için elde edilen ortalama öznitelik sayıları | 44 |

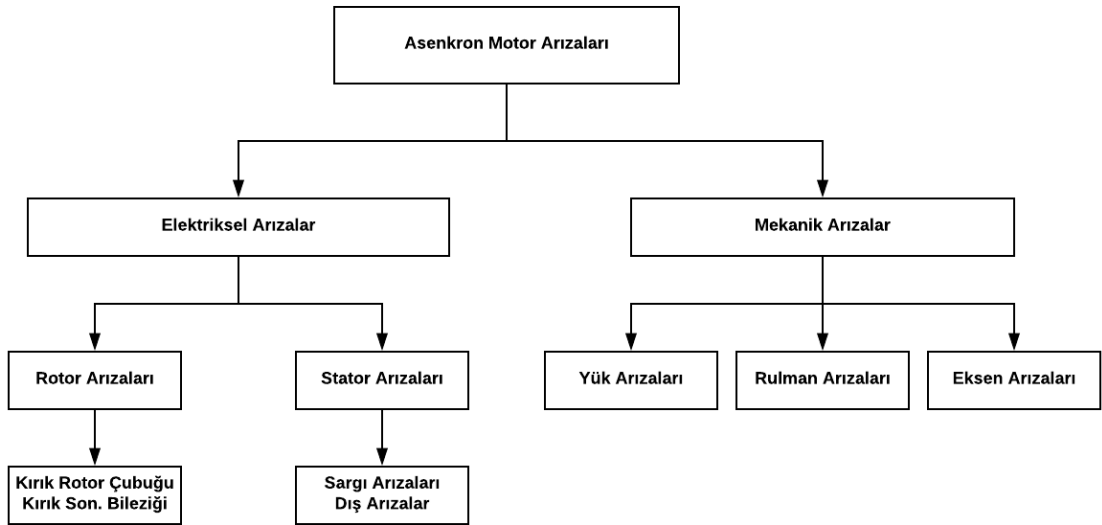
SİMGELER VE KISALTMALAR DİZİNİ**Kısaltmalar****Açıklama**

| | |
|-------|---------------------------------------|
| AKA | Ampirik Kip Ayrışımı |
| ANN | Artificial Neural Network |
| CVA | Common Vector Approach |
| CWRU | Case Western Reserve University |
| DPD | Dalgacık Paket Dönüşümü |
| DVM | Destek Vektör Makineleri |
| EMD | Empirical Mode Decomposition |
| FDA | Fisher' in Doğrusal Ayırtaç Analizi |
| FLDA | Fisher's Linear Discriminant Analysis |
| GA | Genetik Algoritma |
| İKF | İçsel Kip Fonksiyonu |
| k-EYK | k-En Yakın Komşuluk |
| k-NN | k-Nearest Neighbor |
| OM | Otoregresif Model |
| OVY | Ortak Vektör Yaklaşımı |
| PCA | Principal Component Analysis |
| SVM | Support Vector Machines |
| TBA | Temel Bileşen Analizi |
| WPT | Wavelet Packet Transform |
| YSA | Yapay Sinir Ağları |

1. GİRİŞ VE AMAÇ

Asenkron motorlar, sağlam ve basit yapıları, verimli olmaları ve düşük maliyetleri sebebiyle günümüzde sıklıkla kullanılmaktadır. Sağlam yapılarına rağmen, bazen elektrik enerjisini mekanik enerjiye çevirirken arızalar meydana gelebilir. Bu arızaların erken tespiti, motor tamamen bozulmadan gerekli önlemlerin alınmasına katkı sağlar. Arızanın zamanında tespit edilememesi durumunda, motorun değişimi zorunlu hale gelebilir ve bu durum da hem maddi hem de zaman kaybına sebebiyet verebilir.

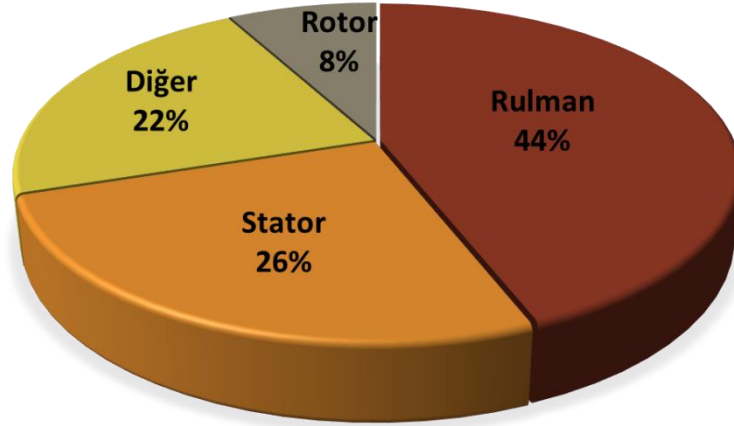
Asenkron motorlarda, arızalar elektriksel ve mekanik arızalar olarak 2 gruba ayrılabilir (Siddiqui vd., 2014). Bu arızalar Şekil 1.1.'de gösterilmektedir (Siddiqui vd., 2014).



Şekil 1.1. Asenkron motor arızalarının sınıflandırılması (Siddiqui vd., 2014)

Mekanik arızalar içinde en sık karşılaşılan arızalar rulmanlardan kaynaklanmaktadır (Yang vd., 2003). Bu sebeple, rulman arızalarının erken tespiti önem arz etmektedir. Asenkron motorlarda meydana gelen arızaların dağılımı Şekil 1.2.'de gösterilmektedir (IEEE Motor Reliability Working Group, 1986).

Bu çalışmada, asenkron motorun rulmanından elde edilen titreşim sinyallerinin yardımıyla arıza tespiti amaçlanmıştır. Arıza tespiti işlemi hem hazır veri seti için, hem de laboratuvar ortamında oluşturulan bir deney düzeneği yardımıyla elde edilen veri seti için gerçekleştirilmiştir. Her iki veri seti de normal, iç bilezik arızalı, dış bilezik arızalı ve bilye arızalı olmak üzere 4 farklı durum içeren titreşim sinyallerinden oluşmaktadır. Bu sinyallerden, zaman ve frekans düzleminde elde edilen istatistiksel özellikler, Dalgacık Paket Dönüşümü (DPD), Ampirik Kip Ayırışımı (AKA) ve Otoregresif Model (OM) kullanılarak öznitelikler çıkartılmıştır. Elde edilen bu öznitelikler, OVY, FDAA, YSA, DVM ve k-EYK sınıflandırıcılarına uygulanarak arıza tespiti yapılmıştır. Öznitelikler, hem herhangi bir seçim veya boyut indirgeme işlemi yapılmadan sınıflandırıcılara uygulanmış, hem de TBA ile boyut indirgeme ve GA ile öznitelik seçim işlemi yapılarak sınıflandırıcılara ayrı ayrı uygulanmıştır. Yapılan deneysel çalışmalarda, zaman ve frekans düzleminde elde edilen öznitelikler, DPD uygulanarak elde edilen öznitelikler ve AKA ve OM beraber kullanılarak oluşturulan öznitelikler için hem öznitelik seçimi veya boyut indirgeme işlemi yapılmadan, hem de öznitelik seçimi veya boyut indirgeme işlemi yapılarak yüksek tanıma oranlarının elde edildiği görülmüştür.



Şekil 1.2. Asenkron motorlarda meydana gelen arızaların dağılımı (IEEE Motor Reliability Working Group'tan, 1986)

Tezin ikinci bölümünde, daha önce yapılan çalışmaların anlatıldığı literatür araştırmasına yer verilmiştir. Arıza tespiti için kullanılan veri seti ile tezde kullanılan

öznitelik çıkarımı ve sınıflandırma yöntemleri ile ilgili bilgiler üçüncü bölümde anlatılmıştır. Dördüncü bölümde öznitelik çıkarımı için kullanılan yöntemler detaylandırılmıştır. Beşinci bölümde, boyut indirgeme ve öznitelik seçimi için kullanılan yöntemlere, altıncı bölümde ise sınıflandırıcılara verilmiştir. Yedinci bölümde yapılan deneysel çalışmalar anlatılmıştır. Sekizinci bölümde ise sonuç ve öneriler verilmiştir.



2. LİTERATÜR ARAŞTIRMASI

Asenkron motorlarda durum izleme ve arıza tespiti konusu endüstriyel süreçlerde gün geçtikçe önem kazanmaktadır. Asenkron motorlarda meydana gelen arızaların büyük bir kısmı rulmanlardan kaynaklandığı için rulman arızalarının erken tespiti önemlidir (Yang vd., 2003). Rulman arızalarının tespitinde genellikle titreşim (Li vd., 2000; McInerny ve Dai, 2003; Saidi vd., 2015; Golbaghi vd., 2017), akım (Schoen vd., 1995; Jung vd., 2006; Haddad vd., 2015; Leite vd., 2017) ve akustik (Tandon vd., 2007; Delgado-Arredondo vd., 2017) sinyaller kullanılmaktadır.

2.1. Akım Sinyalleri Kullanılarak Arıza Tespiti

Asenkron motorlarda rulman arızalarının tespitinde kullanılan sinyallerden biri akım sinyalleridir. Literatürde akım sinyalleri yardımıyla arıza tespiti konusunda birçok çalışma bulunmaktadır.

Zarei ve Poshtan (2007), iç bilezik ve dış bilezik kusurlarının bulunduğu arızaları tespit edebilmek için stator akımı sinyallerini kullanmıştır. 1.2 kW gücündeki bir motordan elde edilen akım sinyallerinden, DPD yardımıyla dalgacık paket katsayılarını elde etmiş ve bu katsayıların enerjilerini hesaplayarak arıza tespitinde bulunmuşlardır.

Yapılan bir başka çalışmada normal durum, iç bilezik ve dış bilezik arızası olmak üzere iki rulman arızası, stator arızası, kırık rotor çubuğu arızası ve açık devre sargıları arızası olmak üzere 6 sınıf içeren bir veri seti için stator akımı kullanılarak arıza tespiti yapılmıştır (Ergin vd., 2012). Elde edilen akım sinyallerine Ayrık Dalgacık Dönüşümü uygulanarak öznitelik vektörleri oluşturulmuş ve OVY uygulanarak arıza tespiti yapılmıştır.

Haddad vd. (2015), 1.1 kW gücündeki 3 fazlı bir asenkron motorda yüksüz, %50 yüklü durumda ve %100 yüklü durumda olmak üzere farklı yük durumları için dış bilezik arızası ve arıza şiddeti tespiti yapmışlardır. Elde edilen akım sinyallerine Kısa Zamanlı

Fourier Dönüşümü ile analiz edilmiş ve Doğrusal Ayırtaç Analizi yardımıyla sınıflandırılarak dış bilezik arızası ve şiddeti tespit edilmiştir.

2.2. Akustik Sinyaller Kullanılarak Arıza Tespiti

Son yıllarda, asenkron motorlarda rulman arızalarının tespitinde akustik sinyaller popüler olmaya başlamıştır.

Delgado-Arredondo vd. (2017) yaptıkları çalışmada dış bilezik arızası, kırık rotor çubuğu arızası ve dengesizlik (unbalance) arızası için hem titreşim hem de ses sinyallerini kullanarak arıza tespiti yapmışlardır. Her iki sinyal tipi için de Tam Birleşik Ampirik Kip Ayırımı (Complete Ensemble Empirical Mode Decomposition) yardımıyla arıza tespiti yapmışlardır.

Glowacz vd. (2018) yaptıkları çalışmada, tek fazlı bir asenkron motor için normal durum, rulman arızalı durum ve rulman arızası ile yardımcı sargı arızasının beraber olduğu durumu içeren 3 sınıflı bir problem üzerinde çalışmışlardır. Frekans Genliklerinin Seçimi Yöntemi (Method of Selection of Amplitudes of Frequency-Multiexpanded) ile öznelik vektörleri oluşturmuşlardır. Oluşturdukları öznelik vektörlerini, En Yakın Komşuluk, En Yakın Ortalama Sınıflandırıcısı ve Gauss Karışım Modeli'ne uygulanmış ve arıza tespiti yapmışlardır.

2.3. Titreşim Sinyalleri Kullanılarak Arıza Tespiti

Rulman arızalarının erken tespitinde titreşim sinyalleri iyi sonuç vermektedir (Gülmezoğlu ve Ergin, 2007). Bu nedenle, asenkron motorlarda rulman arızalarının tespitinde en sık kullanılan sinyal tiplerinden biri titreşim sinyalidir.

Asenkron motorların arıza tespitinde, öznelik çıkarımı ve sınıflandırıcı büyük önem arz etmektedir. Gülmezoğlu ve Ergin (2007), asenkron motordan alınan her bir sınıfa ait titreşim sinyallerini öncelikle 480 sete ayırmış ve her bir seti ön-vurgulama (pre-emphasized) işlemine tabii tutmuşlardır. Bunun ardından her bir seti %25 örtüşmeli

“Hamming” pencere yardımıyla 8 dilime ayırmışlardır. Her bir dilim için 33 “root-melcep” parametresi hesaplamış ve öznitelik vektörlerini oluşturmuşlardır. Bu öznitelik vektörleri, OVY yardımıyla sınıflandırılmışlardır.

Saidi vd. (2015), yaptıkları çalışmada dört sınıflı problem için her bir sınıfa ait sinyalden “bi-spektrum” (üçüncü seviye spektrum) analizi yardımıyla öznitelikler türetmişlerdir. Ardından, öznitelik vektörü boyutunu indirgemek için TBA yöntemini kullanmışlardır. TBA uygulandıktan sonra elde edilen daha düşük boyutlu öznitelik vektörünü DVM sınıflandırıcısına uygulamış ve arıza tespiti yapmışlardır.

Asenkron motorun rulman arıza tespitinde öznitelik çıkarımı için zaman düzleminde elde edilen parametreler sıklıkla kullanılmaktadır. Sreejith vd. (2008), zaman düzleminde tepe değeri, “rms” değeri, standart sapma, basıklık, krest faktör (crest factor), biçim faktörü (shape factor), açıklık faktörü (clearance factor), negatif logaritmik olasılık ve normal olasılık değerlerini hesaplamışlar ve öznitelik vektörlerini oluşturmuşlardır. Oluşturulan bu öznitelik vektörleri normalize edildikten sonra, geri yayılım öğrenme algoritmasına sahip ileri beslemeli sinir ağına uygulanarak arıza tespiti yapılmış. İleri beslemeli sinir ağının gizli katman sayısı bir olarak seçilmiştir. Gizli katmandaki nöron sayısı tüm özniteliklerin kullanıldığı durum için 11 olarak seçilmiştir. Ayrıca, öğrenme algoritmalarının arıza teşhisi üzerine etkisini de araştırmış ve dört farklı öğrenme algoritması üzerinde deneysel çalışma gerçekleştirmişlerdir. Bu algoritmalar “Levenberg-Marquardt” , “Resilient Propagation” , “Scaled Conjugate Gradient” , “Powell-Beale Conjugate Gradient” olarak seçilmiştir. Yapılan testler sonucunda Levenberg-Marquardt algoritmasının bu algoritmalar arasında en uygun çözümü ürettiğini belirtmişlerdir.

Zaman düzleminde üretilen öznitelikler arıza teşhisinde tek başına yeterli olmayabilir (Lei vd., 2008). Lei vd. (2008) titreşim sinyalinden, zaman düzleminde 11, frekans düzleminde 13 parametre hesaplamışlardır. Ayrıca, titreşim sinyalini demodüle etmek için Hilbert Dönüşümü (Hilbert Transform) uygulanmış, ardından demodülasyon spektrumları 13 frekans düzlemi parametresi daha elde etmek için işlenmiştir. Son olarak sinyale AKA uygulanmış ve elde edilen 6 İçsel Kip Fonksiyonu (İKF) için enerji entropileri hesaplanmıştır. Böylece toplamda 43 adet öznitelik elde edilmiştir. Öznitelik vektörleri

oluşturulduktan sonra, geliştirilmiş uzaklık değerlendirme tekniği uygulanarak öznitelik seçimi yapılmış ve Adaptif Bulanık-Sinir Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System) yardımıyla arıza tespiti yapılmıştır.

Rulmanlardan elde edilen titreşim sinyalleri kullanılarak yapılan arıza tespitlerinde zaman ve frekans düzleminde yapılan analizlerin yanında zaman-frekans düzleminde yapılan analizler de literatürde sıklıkla yer almaktadır. Su vd. (2015), titreşim sinyallerini AKA kullanarak İKF'lere ayırmışlardır. Oluşturulan İKF'ler için istatistiksel değerler, otoregresif model parametreleri ve "shannon" entropi değerleri hesaplanmıştır. Bu öznitelikler, hem boyut indirgeme yapılmadan, hem de Dikey Öğrenmeli Doğrusal Yerel Teğet Uzay Hizalaması (Orthogonal Supervised Linear Local Tangent Space Alignment) yöntemi ile öznitelik seçimi yapılarak En Küçük Kareler Destek Vektör Makineleri (Least Squares Support Vector Machines) vasıtasıyla sınıflandırılmıştır.

Zaman-frekans düzlemi analizi için kullanılan yöntemlerden biri de Ayrık Dalgacık Dönüşümü'dür. Golbaghi vd. (2017), titreşim sinyaline Ayrık Dalgacık Dönüşümü uygulayarak alt bantlara ayırmışlardır. Bu alt bantlar için de, istatistiksel özellikler hesaplanmış ve YSA yardımıyla arıza tespiti yapmışlardır. Ayrıca Parçacık Küme Optimizasyonu (Particle Swarm Optimization), GA ve Cuckoo Optimizasyon Algoritması (Cuckoo Optimization Algorithm) yardımıyla YSA parametreleri optimize edilmiştir.

Ayrık Dalgacık Dönüşümü'nün dışında, DPD de rulman arızalarının tespitinde sıklıkla kullanılan zaman-frekans düzlemi analiz yöntemlerinden biridir. Rauber vd. (2015), yaptıkları çalışmada, asenkron motorun sürücü-uç ve fan-uç rulmanlarından, farklı yük ve arıza şiddeti altında toplanan titreşim sinyalleri için zaman ve frekans düzlemi özniteliklerini hesaplamalarının yanında, Kompleks Zarf Analizi (Complex Envelope Analysis) ve DPD ile de öznitelik çıkarımı yapmışlardır. Farklı rulmanlardan elde edilen titreşim sinyallerine 4 seviye Ayrık Dalgacık Dönüşümü uygulamış ve 4. seviye katsayılar için enerji hesaplayarak öznitelik vektörü oluşturmuşlardır. Oluşturdukları bu üç öznitelik vektörü grubunu hem ayrı ayrı hem de tüm öznitelik gruplarını birleştirerek tek bir havuz oluşturarak sınıflandırıcılara uygulamışlardır. Sınıflandırma işlemi için 1 EYK, DVM ve Çok Katmanlı Algılayıcılar'ı tercih etmişlerdir. En yüksek tanıma oranlarını tüm sınıflandırıcılar için tüm öznitelik

vektörlerinin beraber olarak sınıflandırıcılara uygulandığı durum için elde etmişlerdir. Ayrıca, TBA, Ardışık İleri Yönlü Seçim, Ardışık İleri Yönlü Kayan Seçim, Ardışık Geri Yönlü Seçim ve Ardışık Geri Yönlü Kayan Seçim yardımıyla boyut indirgeme ve öznelik seçimi işlemi gerçekleştirerek öznelik seçim yöntemlerini karşılaştırmışlardır.

Yapılan çalışmalar dikkate alındığında, asenkron motorların endüstride sıklıkla kullanılmaları, bu motorlarda meydana gelen arızaların işletmeler için çok ciddi zaman ve maddi kayıplara sebebiyet vermesi nedeniyle, bu motorlarda meydana gelen arızaların erken ve etkili bir şekilde tespiti hala önemini korumaktadır.



3. MATERYAL VE YÖNTEM

3.1. Veri Seti

Bu tez çalışmasında, asenkron motor rulmanından elde edilen titreşim sinyali yardımıyla arıza tespiti yapılmıştır. Çalışmada iki farklı veri seti kullanılmıştır. İlk veri seti, “Case Western Reserve University (CWRU)” tarafından sağlanan veri setidir (Loparo, 2018). İkinci veri seti ise laboratuvar ortamında elde edilen veri setidir. İki veri seti ile ilgili bilgiler ilerleyen bölümde verilmiştir.

3.1.1. CWRU veri seti

Bu veri seti, asenkron motorun sürücü-uç (drive-end) rulmanlarından elde edilen titreşim sinyallerini içermektedir. Bu titreşim sinyalleri, normal durum ile iç bilezik, dış bilezik ve bilye arızalarını içeren üç farklı arızalı durum için toplanmıştır. Arızalı durumların her birisi kendi içerisinde, 0,18 mm, 0,36 mm ve 0,53 mm çapa sahip olmak üzere 3 farklı kusuru içermektedir. Veriler hem normal, hem de arızalı durumlar için 0, 1, 2 ve 3 beygir gücü olmak üzere 4 farklı yük altında toplanmıştır. Belirtilen yük durumları için motorun hız değerleri sırasıyla 1797 dev/dak, 1772 dev/dak, 1750 dev/dak ve 1730 dev/dak olarak ölçülmüştür. Kullanılan veri setinin elde edildiği test düzeneği Şekil 3.1.’de gösterilmiştir.



Şekil 3.1. CWRU veri seti elde etmek için kurulan test düzeneği (Loparo’dan, 2018)

Bu çalışmada, CWRU veri seti de kendi içerisinde iki alt veri setine ayrılmıştır. İlk veri grubu, arıza çaplarından ve yükten bağımsız olarak oluşturulmuştur. Normal durum, iç bilezik arızası, dış bilezik arızası ve bilye arızası olmak üzere 4 sınıflı bir problem oluşturulmuştur. Her bir sınıf için farklı yük ve arıza çapları altında toplanan titreşim sinyalleri kullanılarak 60 örnek set oluşturulmuştur. Örneğin, normal durumda, her bir yük durumu için 15 adet örnek set oluşturularak toplam 60 örnek seti elde edilmiştir. Arızalı durumlarda da her bir sınıfta, her bir yük ve arıza çapı için 5 adet örnek set oluşturularak toplam 60 adet örnek seti elde edilmiştir. Örneğin iç bilezik arızası için, her bir yük için 5 adet 0,18 mm, 5 adet 0,36 mm ve 5 adet 0,53 mm arıza çapı içeren örnek seti oluşturulmuştur. Böylece 4 farklı yük için toplamda 60 örnek seti elde edilmiştir. Bu veri grubu, CWRU-1 veri seti olarak isimlendirilmiştir.

İkinci veri grubu, arızalı durumların sadece 0.36 mm çapa sahip olduğu ve verilerin tüm sınıflarda yüksüz durum için toplandığı durumdur. Bu veri grubu, CWRU-2 veri seti olarak isimlendirilmiştir.

CWRU-1 ve CWRU-2 veri setinin içerdiği bilgiler Çizelge 3.1. ve Çizelge 3.2.'de verilmiştir.

Çizelge 3.1. CWRU-1 veri setine ait bilgiler

| Yük | Normal | İç Bilezik | Dış Bilezik | Bilye |
|------------|---------------|-------------------|--------------------|--------------|
| 0 BG. | 15 | 15 | 15 | 15 |
| 1 BG. | 15 | 15 | 15 | 15 |
| 2 BG. | 15 | 15 | 15 | 15 |
| 3 BG. | 15 | 15 | 15 | 15 |
| Toplam | 60 | 60 | 60 | 60 |


Çizelge 3.2. CWRU-2 veri setine ait bilgiler

| Yük | Normal | İç Bilezik | Dış Bilezik | Bilye |
|------------|---------------|-------------------|--------------------|--------------|
| 0 BG. | 60 | 60 | 60 | 60 |
| Toplam | 60 | 60 | 60 | 60 |

3.1.2. Laboratuvar veri seti

Kullanılan hazır veri setlerinin yanında bir de laboratuvar ortamında oluşturulan veri seti üzerinde sınıflandırma işlemi gerçekleştirilmiştir. Bu veri seti de Laboratuvar veri seti (Lab. veri seti) olarak isimlendirilmiştir.

Veri setinin oluşturulmasında, 3 faz 1.1 kW gücünde 4 kutuplu Gamak Asenkron Motor, 100 mV/g hassasiyete sahip bir ivmeölçer, National Instruments Veri Elde Etme Sistemi ve dizüstü bilgisayar kullanılmıştır. Kurulan test düzeneği Şekil 3.2.'de gösterilmiştir. Yapılan testlerde, asenkron motorun hızı yaklaşık olarak 1495 dev/dak olarak ölçülmüştür.



Şekil 3.2. Laboratuvar ortamında kurulan test düzeneği

Hem CWRU veri setinde, hem de laboratuvar ortamında elde edilen veri setinde, sürücü-uç rulmanı olarak 6205 tipinde bilyeli rulman kullanılmıştır. Laboratuvar ortamında oluşturulan veri seti için hata çapları 2 mm olarak seçilmiştir. Söz konusu rulmanlara ait teknik özellikler Çizelge 3.3. de verilmiştir. Her iki veri seti için de örnekleme frekansı 12 kHz olarak seçilmiştir.

Her iki veri seti için de özniteliklerin elde edilmesi, seçimi ve sınıflandırılması için Matlab programı kullanılmıştır. Laboratuvar ortamında veri elde etme işlemi için Labview

programı kullanılmıştır. Yapılan işlemler için Intel Core i7-6700 HQ 2.7 GHz işlemci ve 16 GB bellek kapasitesine sahip bir dizüstü bilgisayar kullanılmıştır.

Çizelge 3.3. 6205 rulman özellikleri

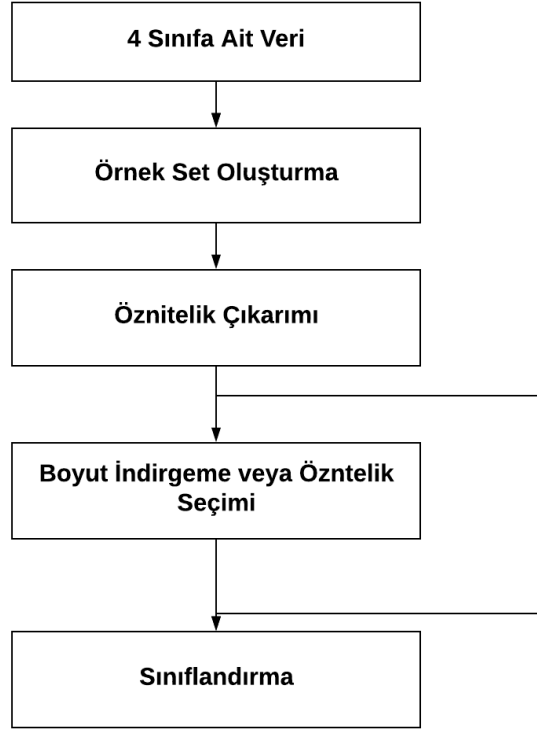
| | |
|-----------------|---------|
| Dış Çap | 52 mm |
| İç Bilezik Çapı | 25 mm |
| Bilye Çapı | 7,94 mm |
| Bilye Sayısı | 9 adet |

3.2. Yöntem

Bu tez çalışmasında kullanılan her veri seti örtüşmesiz olarak her biri 1024 örnek içerecek şekilde 60 eşit örnek setine ayrılmıştır. Daha sonra bu örnek setleri için farklı öznitelik çıkarma yöntemleri kullanılarak öznitelik vektörleri oluşturulmuştur.

Bu öznitelik vektörlerini sınıflandırmak için DVM, OVY, YSA, FDAA ve k-EYK yöntemleri kullanılmıştır.

Oluşturulan öznitelik vektörlerinin direkt olarak sınıflandırıcılara uygulanmasının yanında, bir de TBA ve GA yardımıyla boyut indirgeme ve öznitelik seçimi işlemi yapılarak sınıflandırma işlemi gerçekleştirilmiştir. Arıza tespiti akış diyagramı Şekil 3.3.'te verilmiştir.



Şekil 3.3. Arıza tespiti akış diyagramı

4. ÖZNETELİK ÇIKARIMI

Asenkron motorlarda arıza tespitinde başarı oranını etkileyen en önemli unsurlardan biri öznitelik çıkarımıdır. Bu tez çalışmasında, asenkron motor rulmanından elde edilen sinyallerden zaman ve frekans düzleminde elde edilen parametreler, DPD, AKA ve OM yardımıyla öznitelik çıkarımı yapılmıştır.

4.1. Zaman ve Frekans Düzlemi Parametreleri

Titreşim sinyallerden öznitelik çıkarımında zaman düzlemindeki istatistiksel parametreler sıklıkla kullanılmaktadır (Rauber vd., 2015). Her bir sınıfa ait titreşim sinyalinden Çizelge 4.1.'de yer alan 10 adet zaman düzlemi parametresi hesaplanmıştır.

Zaman düzleminde elde edilen parametreler, doğru teşhis için yeterli olmayabilir. Bu sebeple elde edilen 10 zaman düzlemi istatistiksel parametresinin yanında, frekans düzleminde ortalama frekans değeri öznitelik olarak hesaplanmıştır .

Çizelge 4.1. Zaman düzlemi istatistiksel parametreleri

| Öznitelik Adı | Matematiksel İfadesi |
|----------------------|--|
| Ortalama Değer | $\mu = \frac{1}{N} \sum_{i=1}^N x_i$ |
| RMS Değeri | $\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$ |
| Varyans | $\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2$ |
| Standart Sapma | $\sqrt{\text{varyans}}$ |
| Çarpıklık | $\frac{1}{N} \sum_{i=1}^N \frac{(x_i - \mu)^3}{\sigma^3}$ |
| Biçim Faktörü | $\frac{\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}}{\frac{1}{N} \sum_{i=1}^N x_i }$ |
| Krest Faktör | $\frac{\text{maks } x_i }{\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}}$ |
| Dürtü Faktörü | $\frac{\text{maks } x_i }{\frac{1}{N} \sum_{i=1}^N x_i }$ |
| Basıklık | $\frac{1}{N} \sum_{i=1}^N \frac{(x_i - \mu)^4}{\sigma^4}$ |
| Tepeden Tepeye Değer | $\text{maks } x_i - \text{min } x_i$ |

4.2. Dalgacık Paket Dönüşümü

Titreşim sinyallerinin sınıflandırılmasında, zaman ve frekans düzlemi analizinin yanında, zaman-frekans düzlemi analizi de sıklıkla kullanılmaktadır. En sık kullanılan zaman-frekans düzlemi analizi yöntemleri; Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform), Dalgacık Dönüşümü ve Ampirik Kip Ayırımı (Empirical Mode Decomposition-EMD) olarak söylenilebilir.

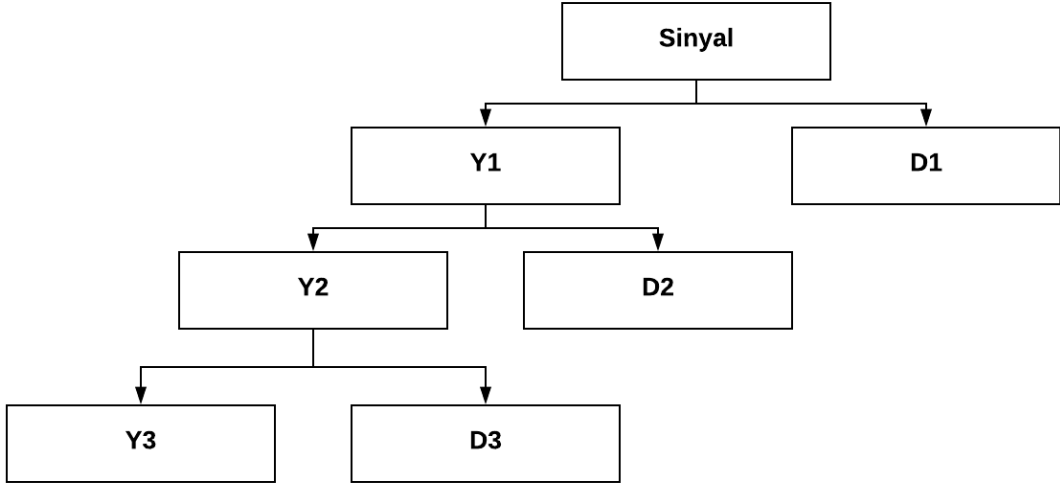
Dalgacık Dönüşümü, sürekli veya ayrık zamanlı olabilir (Chebil vd., 2009). Sürekli Dalgacık Dönüşümü'ne ait matematiksel ifade aşağıda verilmiştir.

$$CWT = \int_{-\infty}^{\infty} f(x) \frac{1}{\sqrt{a}} \psi^* \left(\frac{t-b}{a} \right) dt \quad (4.1)$$

Burada ψ ana dalgacı, a ölçekleme parametresini, b ise zamanda kaydırma parametresini ifade eder. Parametre a , sıfırdan büyük bir pozitif sayıyı temsil etmektedir.

Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform), Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)'ne göre daha fazla detay barındırmasına rağmen, çok fazla işlem yükü gerektirir (Chebil vd., 2009). Bu sebeple birçok uygulamada daha az işlem yüküne sahip Ayrık Dalgacık Dönüşümü tercih edilmektedir (Chebil vd., 2009).

Mallat (1989), Ayrık Dalgacık Dönüşümünü etkin bir şekilde uygulamak için bir yol geliştirmiştir. Giriş sinyalin bir alçak geçiren ve bir yüksek geçiren filtre yardımıyla, alçak frekanslı yaklaşım katsayılarına ve yüksek frekanslı detay katsayılarına ayrıştırılabileceğini ortaya koymuştur. 3 seviye Ayrık Dalgacık Dönüşümü örneği Şekil 4.1.'de verilmiştir. Şekil 4.1.'de yer alan "Y" harfi yaklaşım katsayılarını, "D" harfi detay katsayılarını ifade etmektedir (Yan vd., 2014).



Şekil 4.1. 3 seviye Ayrık Dalgacık Dönüşümü

Ayrık Dalgacık Dönüşümü'nde detay katsayıları yeniden ayrıştırma işlemine tutulmazlar. Sadece elde edilen yaklaşım katsayılarına yeniden Ayrık Dalgacık Dönüşümü uygulanır. Bu durum da, alçak frekanslı bileşenlerin daha iyi bir çözünürlükte incelenirken, yüksek frekanslı bileşenlerin daha kötü bir çözünürlükte incelenmesine sebebiyet verir (Zarei ve Poshtan, 2007). Ayrık Dalgacık Dönüşümü'nün genişletilmiş versiyonu olan Dalgacık Paket Dönüşümü (Wavelet Packet Transform – WPT) ile bu durumun önüne geçilebilir.

DPD aşağıda verildiği şekliyle hesaplanabilir (Yan vd, 2014).

$$u_{2n}(t) = \sqrt{2} \sum_k h(k) u_n(2t - k) \quad (4.2)$$

$$u_{2n+1}(t) = \sqrt{2} \sum_k g(k) u_n(2t - k) \quad (4.3)$$

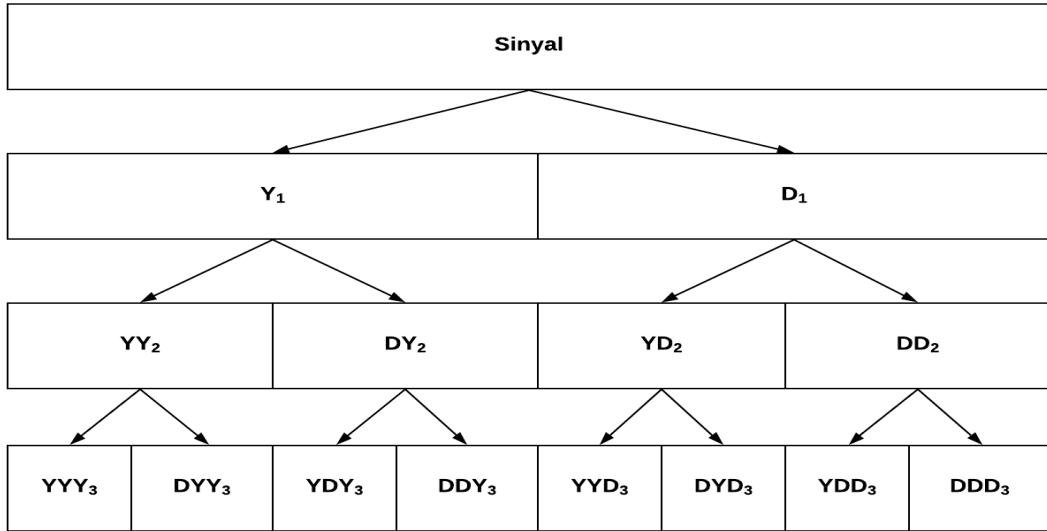
Burada $u_0(t)=\varphi(t)$ ve $u_1(t)=\psi(t)$ olacak şekilde ifade edilebilir(Yan vd, 2014).

Son durumda dalgacık katsayıları aşağıda verilen ifadeler kullanılarak hesaplanabilir (Coifman ve Wickerhauser,1992; Yan vd., 2014).

$$d_{j+1,2n} = \sum_m h(m - 2k)d_{j,n} \quad (4.4)$$

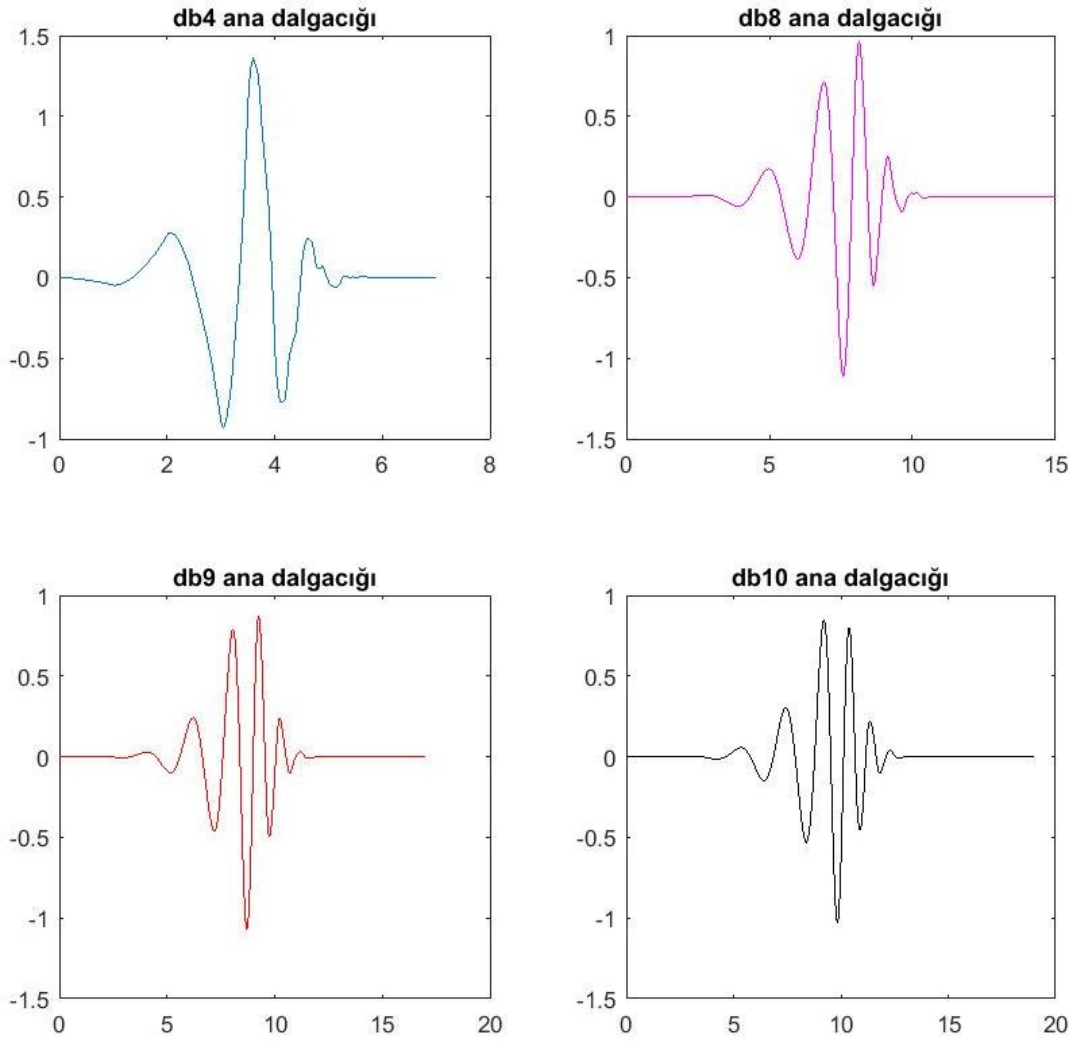
$$d_{j+1,2n+1} = \sum_m g(m - 2k)d_{j,n} \quad (4.5)$$

Burada $d_{j,n}$, j seviyedeki dalgacık katsayılarını; m dalgacık katsayısının sayısını; $d_{j+1,2n}$ ve $d_{j+1,2n+1}$, $j + 1$ seviyedeki dalgacık katsayılarını; n , alt bandları ifade etmektedir (Coifman ve Wickerhauser,1992; Yan vd., 2014). 3 seviye Dalgacık Paket Ayırıştırması Şekil 4.2.'de gösterilmiştir.



Şekil 4.2. 3 seviye Dalgacık Paket Ayırıştırması

DPD'de kullanılan ana dalgacığın önemi büyüktür. Titreşim sinyallerinden arıza tespitinde 'db4' (Rauber vd., 2015; Golbaghi vd., 2017; Chebil vd., 2009), 'db8' (He, 2013), 'db9' (Shen vd., 2013), 'db10' (Wang vd., 2015) ana dalgacıkları literatürde birçok kez kullanılmıştır. Bu ana dalgacıklar Şekil 4.3.'te gösterilmektedir.



Şekil 4.3. Db4, db8, db9 ve db10 dalgacık fonksiyonları

DPD’de ana dalgacık seçiminin yanı sıra hangi seviyeye kadar ayrıştırma işleminin yapılacağına seçiminin yapılması da önemlidir. Yapılan ‘j’ seviye bir ayrıştırma işlemi için, o seviyede 2^j kadar alt band (sub band) elde edilir. Örneğin; 3 seviye DPD için 3. Seviyede 8 adet alt band elde edilir. Elde edilen bu alt bandlar için enerji (Rauber vd., 2015) , basıklık, çarpıklık, rms değeri, standart sapma, varyans gibi istatistiksel özellikler (Rajeswari vd., 2014) hesaplanarak da öznelilikler elde edilebilir.

4.3. Ampirik Kip Ayrışımı

Ampirik Kip Ayrışımı (Huang vd., 1998) , titreşim sinyalleri gibi durağan olmayan sinyaller için etkili bir zaman-frekans analizi yöntemidir (Bin vd., 2012) . AKA'da orijinal sinyal $(x(t))$, İKF denilen alt fonksiyonlara ve kalan (residue) sinyale ayrılır. AKA uygulanan orijinal sinyal, İKF ve kalan sinyalin toplamı olarak yeniden oluşturulabilir. Bu durumu gösteren eşitlik aşağıda verilmiştir.

$$x(t) = \sum_{i=1}^n c_i(t) + r_n \quad (4.6)$$

Eşitlik (4.6)'da; $x(t)$, AKA uygulanan orijinal sinyali; n , oluşturulan toplam İKF sayısını; $c_i(t)$, i . İKF'yi; r_n ise kalan sinyali temsil etmektedir.

AKA'da oluşturulan her bir İKF aşağıda verilen iki durumu sağlamalıdır (Huang vd., 1998) .

- i-) Tüm veri içerisindeki uç (extrema) noktaların sayısı ile sıfır geçiş (zero crossing) noktalarının sayısı birbirine eşit olmalı veya aralarında en fazla bir fark olmalıdır.
- ii-) Herhangi bir noktada üst zarf ve alt zarfın yerel ortalaması sıfır olmalıdır.


AKA algoritmasının aşamaları aşağıda verilmiştir (Lei vd., 2013).

- 1) $r_0 = x(t)$ ve $i = 1$ olarak oluştur
- 2) Aşağıda verilen işlemler takip edilerek "i." İKF'yi oluştur.
 - a) $h_{i(k-1)} = r_{i-1}$ ve $k=1$ olarak başlat.
 - b) $h_{i(k-1)}$ e ait yerel maksimum ve minimum uç noktalarını bul.
 - c) $h_{i(k-1)}$ ' in alt ve üst zarflarını oluşturabilmek için yerel maksimum ve minimum noktaları ara değerlendirme işlemine tabi tut.
 - d) $h_{i(k-1)}$ ' in alt ve üst zarflarının ortalamasını $m_{i(k-1)}$ hesapla.
 - e) $h_{ik} = h_{i(k-1)} - m_{i(k-1)}$ olarak hesapla.
 - f) Eğer h_{ik} bir İKF ise $c_i = h_{ik}$ olarak oluştur. Değilse k 'yı bir arttır ve adım b' ye geri dön.
- 3) Kalan sinyali $r_{i+1} = r_i - c_i$ olarak tanımla.

- 4) Eğer r_{i+1} , en az 2 uç nokta içeriyorsa adım 2' ye geri dön. Eğer içermiyorsa işlemi sonlandır ve kalan sinyali r_{i+1} olarak tanımla.

Elde edilen İKF ile sinyale ait öznitelik hesaplaması yapılabilir. Literatürde, her bir İKF için enerji entropisi (Yu ve Junsheng, 2006), istatistiksel parametreler (Pandya vd. 2013; Su vd., 2015; Gupta vd., 2016; Hassan ve Bhuiyan, 2016) hesaplanarak öznitelik vektörleri oluşturulmuştur.

AKA uygulanmış bir sinyal örneği Şekil 4.4'te verilmiştir. Dönüşüm uygulanan sinyal için 4 adet İKF elde edilmiştir. AKA uygulaması için Rilling vd. tarafından geliştirilen “emd.m” fonksiyonu kullanılmıştır (Rilling vd., 2003).



Şekil 4.4. AKA uygulanmış bir sinyal örneği

4.4. Otoregresif Model

Otoregresif Model, sinyalin önceki değerlerini ve hata terimini kullanarak sinyali modelleyen parametrik bir yöntemdir (Ayaz, 2012). Lineer OM, eşitlik (4.7)' de verilmiştir (Box vd., 2015).

$$x(t) = a_1 \cdot x(t-1) + \dots + a_p \cdot x(t-p) + e(t) = \sum_{k=1}^p a_k \cdot x(t-k) + e(t) \quad (4.7)$$

Eşitlik (4.7)'de yer alan a_k model katsayılarını; p , model seviyesini; $e(t)$, ise modelin hata terimini ifade etmektedir. OM için model seviyesinin belirlenmesi çok önemlidir. Model seviyesi tahmini için Akaike'nin Bilgi Kriteri (Akaike's Information Criteria) ve Son Tahmin Hatası (Final Prediction Error) literatürde sıklıkla kullanılmaktadır (Ayaz, 2012; Al-Bugharbee ve Trendafilova,2015). Uygun model seviyesi belirlendikten sonra elde edilen p adet katsayı öznitelik olarak kullanılabilir.

OM titreşim sinyallerinden arıza tespiti için iyi bir öznitelik çıkarım yöntemidir. Ancak OM durağan sinyallere uygulanabilmektedir ve rulmanlardan elde edilen titreşim sinyalleri durağan olmadığından OM uygulamadan önce bir ön işleme tabi tutulması gerekir (Junsheng vd., 2006). Bu nedenle, bu tez çalışmasında titreşim sinyalleri öncelikle AKA uygulanarak İKF'lere ayrılmış, daha sonra bu İKF'ler için OM parametreleri hesaplanmış ve öznitelik vektörleri oluşturulmuştur.

5. BOYUT İNDİRGEME VE ÖZNETELİK SEÇİMİ

Örüntü tanımada öznitelik çıkarımı ve sınıflandırma işleminin yanında öznitelik seçimi de önemli bir yer kaplamaktadır. Çok yüksek boyutlu öznitelik vektörlerinin sınıflandırma süresinde artışa sebep olması, çıkartılan öznitelikler arasında sınıflandırma doğruluğunun düşmesine sebep olanların bulunması gibi problemler sebebiyle boyut indirgeme işlemi ve öznitelik seçimi, örüntü tanıma için önemlidir.

Öznitelik seçimi yöntemleri; Filtreleme, Sarmalama ve Gömülü yöntemler olmak üzere 3 ana başlığa ayrılabilir (Kumbhar ve Mali, 2016) .

Filtreleme yönteminde, sınıflandırıcıdan bağımsız olarak öznitelik seçimi yapılır. Veri kendi içerisinde istatistiksel özelliklerden yararlanarak analiz edilir ve öznitelik seçimi yapılır. Filtreleme yönteminin, hesaplama sürecinin kısa olması, sınıflandırıcıdan bağımsız olarak uygulanabilmesi, aşırı uyumdan (overfitting) kaçınması avantajları olarak gösterilirken, özniteliklerin birbirleri ile olan bağılıklarını dikkate almaması dezavantajı olarak gösterilebilir (Saeys vd., 2007).

Sarmalama yöntemlerinde, filtreleme yöntemlerinden farklı olarak seçilen öznitelikler sınıflandırıcıya girdi olarak uygulanır. Sarmalama yöntemlerinin sınıflandırıcı algoritmayla etkileşim içerisinde olması ve öznitelikler arasındaki bağılılığı modellemesi avantajları olarak gösterilirken, işlem süresinin fazla olması ve aşırı uyum probleminin meydana gelebilmesi dezavantajları olarak gösterilebilir (Saeys vd., 2007).

Gömülü yöntemlerde, öznitelik seti arama işlemi, sınıflandırmanın eğitim aşamasının içerisine entegre edilir ve bu yüzden, gömülü yöntemler de sarmal yöntemler gibi sınıflandırıcıya bağımlı sistemlerdir (Günel, 2012).

Bu çalışmada boyut indirgeme için TBA, öznitelik seçimi için ise sarmalama yöntemleri olan GA kullanılmıştır. Kullanılan yöntemler ilerleyen bölümlerde anlatılmaktadır.

5.1. Temel Bileşen Analizi

Sınıflandırma işlemlerinde yüksek veri boyutları ile çalışmak, sınıflandırma için harcanan sürenin fazla olmasına sebebiyet vermektedir. Bu problemin önüne geçebilmek için boyut indirgeme yöntemleri kullanılmaktadır. TBA de bu lineer boyut indirgeme yöntemlerinden biridir (Gülmezoğlu vd., 2001). TBA’da temel amaç n boyutlu bir uzayı, daha küçük k boyutlu bir uzay üzerine proje etmektir. Temel Bileşen Analizi kısaca aşağıda verilmiştir.

TBA kullanılarak m adet örneğe sahip n boyutlu bir veriyi $\mathbf{x}_i (i = 1, 2, \dots, m)$ k boyutuna indirgemek için öncelikle kovaryans matrisi eşitlik 5.1’ de verildiği gibi hesaplanır.

$$\Phi = \frac{1}{m} \sum_{i=1}^m (\mathbf{x}_i - \mathbf{x}_{ort})(\mathbf{x}_i - \mathbf{x}_{ort})^T \quad (5.1)$$

Eşitlik (5.1)’de yer alan \mathbf{x}_{ort} , öznitelik vektörlerinin ortalamasını, m ise toplam öznitelik vektörü sayısını ifade etmektedir.

Kovaryans matrisi hesaplandıktan sonra, hesaplanan kovaryans matrisine özdeğer ve özvektör ayrıştırması uygulanır. Özdeğerler ve bu özdeğerlere karşılık gelen özvektörler elde edilir. Elde edilen bu özdeğerlerden en büyük k adedi seçilir ve bu k adet öznitelige karşı gelen özvektörler kullanılarak $k \times n$ boyutuna sahip bir projeksiyon matrisi oluşturulur. Bu projeksiyon matrisi yardımıyla, $n \times m$ boyutuna sahip orijinal öznitelik vektörü, $k \times m$ boyutuna indirgenir.

5.2. Genetik Algoritma

Genetik algoritma, evrimden ilham alınarak geliştirilmiş, genellikle optimizasyon problemlerini çözmek için kullanılan bir yöntemdir (Ahmad vd., 2014; Harrag, 2015). GA’da, öncelikle her birine kromozom adı verilen çözüm kümelerinin oluşturduğu bir başlangıç popülasyonu oluşturulur. Bu başlangıç popülasyonu rastgele oluşturulabilir. Ardından bu başlangıç popülasyonunda bulunan tüm kromozomlar için uygunluk (fitness)

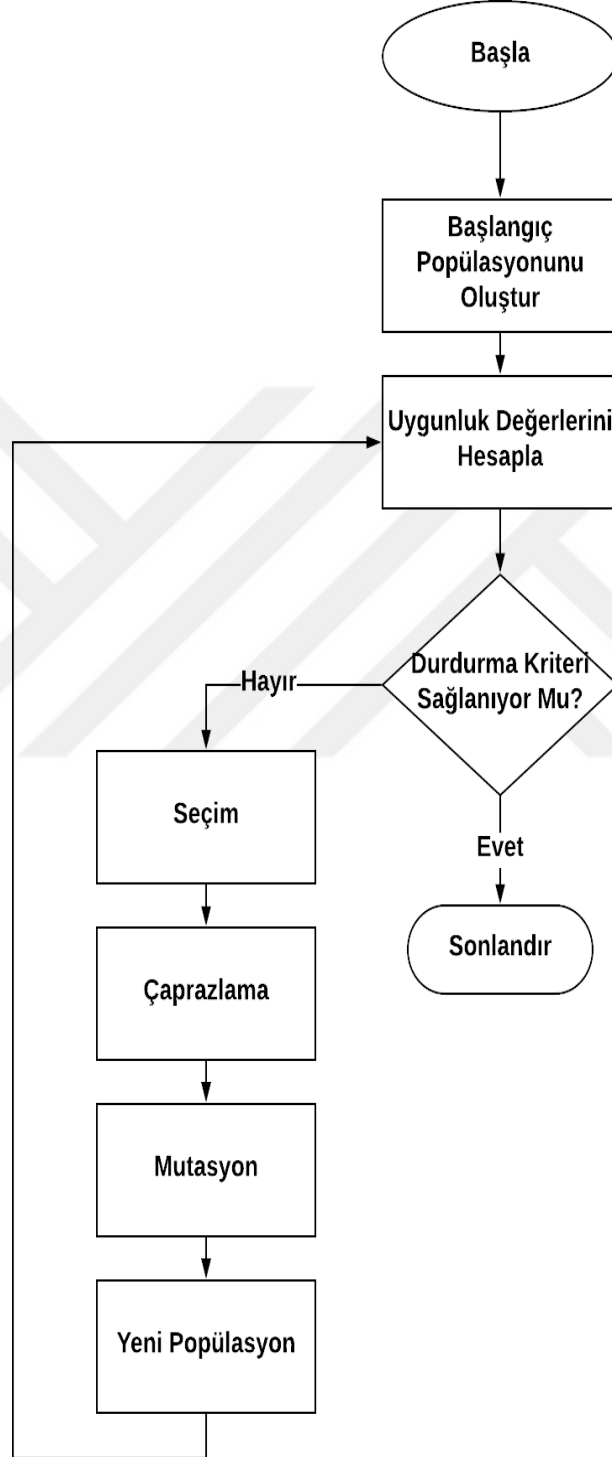
değerleri hesaplanır. Bu uygunluk değerleri hesaplandıktan sonra genetik algoritma parametreleri olan seçim, çaprazlama ve mutasyon işlemleri uygulanarak mevcut popülasyon güncellenir. İstenilen durdurma kriterine ulaşılan kadar bu işlem devam ettirilir (Harrag, 2015).

GA'da başlangıç popülasyonunun oluşturulması için öncelikle kromozom tipine karar verilmelidir. Kromozomlar "bit string" veya farklı tiplerde (Örn. reel sayı) oluşturulabilir (Haupt vd., 1998) . "Bit string" yönteminde, her bir kromozom içerisinde bulunan bit değerleri 0 ve 1'lerden oluşmaktadır. Eğer bir kromozom içerisindeki bit değeri, 1 ise, o özneliğin seçildiğini, 0 ise o özneliğin seçilmediğini ifade eder (Ahmad vd., 2014). Bu tez çalışmasında bit string yöntemi ile kromozomlar ifade edilmiştir.

GA' da kromozom tipine karar verildikten sonra başlangıç popülasyonu oluşturabilir. Başlangıç popülasyonu, elle veya birçok uygulamada yer aldığı gibi rastgele olarak oluşturulabilir. Bu çalışmada, başlangıç popülasyonları (her bir öznelik çıkarma ve sınıflandırma algoritması için) rastgele olarak oluşturulmuştur. Başlangıç popülasyonu boyutu ise 50 olarak belirlenmiştir.

Başlangıç popülasyonu oluşturulduktan sonra, başlangıç popülasyonundaki her bir kromozom için amaç fonksiyonu yardımıyla uygunluk değeri hesaplanır. Bu çalışmada uygunluk değeri olarak sınıflandırma doğrulukları kullanılmıştır. Her bir kromozom için uygunluk değeri hesaplandıktan sonra seçim, çaprazlama ve mutasyon operatörleri yardımıyla yeni nesillerin oluşturulması gerekir. Bu çalışmada, seçim işlemi için Rulet Tekerleği (Roulette Wheel), çaprazlama için Tek Noktalı Çaprazlama (Single Point Crossover) kullanılmıştır. Mutasyon oranı ise 0.05 olarak seçilmiştir.

Bu çalışmada, GA için iki adet durdurma kriteri belirlenmiştir. İlki, uygunluk değerinin 100%' e ulaşmasıdır. Diğer durdurma kriteri ise, maksimum nesil sayısına ulaşılmasıdır. Bu iki kriterden biri sağlandığında, GA işlemi duracaktır. GA aşamalarını gösteren akış diyagramı Şekil 5.1'de verilmiştir.



Şekil 5.1. GA akış diyagramı

6. SINIFLANDIRICILAR

Titreşim sinyallerinden; Bölüm 3.2' de verilen 4 farklı öznitelik çıkarım yöntemi kullanılarak elde edilen öznitelik vektörleri, 5 farklı sınıflandırıcıya girdi olarak uygulanmıştır. Bu sınıflandırıcılar Fisher' in Doğrusal Ayırtaç Analizi (Fisher's Linear Discriminant Analysis), Ortak Vektör Yaklaşımı (Common Vector Approach) , Destek Vektör Makineleri (Support Vector Machines) , k-En Yakın Komşuluk (k-Nearest Neighbor) ve Yapay Sinir Ağlarıdır (Artificial Neural Network).

6.1. Fisher' in Doğrusal Ayırtaç Analizi

Fisher' in Doğrusal Ayırtaç Analizi hem boyut indirgeme hem de sınıflandırma için kullanılan bir altuzay tabanlı yöntemdir (Sugiyama, 2007 ; Isikli Esener vd., 2017). FDAA, sınıf içi dağılım matrisini minimize ederken, sınıflar arası dağılım matrisini maksimize edecek bir projeksiyon matrisi bulmayı amaçlar (Fisher, 1936). Projeksiyon matrisini bulabilmek için öncelikle sınıf içi (S_i) ve sınıflar arası (S_a) dağılım matrisleri bulunur.

$$S_i = \sum_{k=1}^C \sum_{i=1}^{N_k} (\mathbf{x}_i^k - \mathbf{x}_{ort}^k)(\mathbf{x}_i^k - \mathbf{x}_{ort}^k)^T \quad (6.1)$$

$$S_a = \sum_{k=1}^C N_k (\mathbf{x}_{ort}^k - \mathbf{x}_{ort})(\mathbf{x}_{ort}^k - \mathbf{x}_{ort})^T \quad (6.2)$$

Eşitlik (6.1) ve (6.2)'de C , sınıf sayısını; N_k , k . sınıftaki öznitelik vektör sayısını; \mathbf{x}_{ort}^k , k . sınıfın ortalamasını; \mathbf{x}_i^k , k . sınıfa ait i . öznitelik vektörünü; \mathbf{x}_{ort} ise tüm sınıfların ortalamasını temsil etmektedir.

Sınıf içi ve sınıflar arası dağılım matrisi hesaplandıktan sonra optimum projeksiyon matrisini elde etmek için Fisher Kriteri'ni ($J(W)$) maksimize edecek W matrisi bulunur.

$$J(W) = \arg \max \frac{|W^T S_a W|}{|W^T S_i W|} \quad (6.3)$$

Fisher Kriterini maksimize eden projeksiyon matrisi $S_i^{-1}S_a$ denkleminin en büyük m adet özdeğerine karşılık gelen özvektör alınarak çözülebilir. Burada m değeri en fazla sınıf sayısından bir eksik olabilir.

6.2. Ortak Vektör Yaklaşımı

OVY, altuzay tabanlı bir örüntü tanıma algoritmasıdır (Gülmezoğlu ve Ergin, 2007). OVY, motor arıza tanısı (Gülmezoğlu ve Ergin, 2007; Ergin vd., 2011), bitki sınıflandırması (Aytaç vd., 2016), konuşmacı tanıma (Sadıç ve Gülmezoğlu, 2011) gibi birçok farklı alanda sınıflandırma algoritması olarak kullanılmaktadır.

OVY, özellikle eğitim setindeki öznitelik vektörlerinin sayısının (m), öznitelik vektörlerinin boyutundan (n) daha az veya eşit olduğu durum için oldukça kullanışlıdır (Gülmezoğlu vd., 2001). Bu durum yetersiz veri durumu (insufficient data case) olarak adlandırılır. Eğitim setindeki öznitelik vektörlerinin sayısının, öznitelik vektörlerinin boyutundan büyük olduğu durum ise yeterli veri durumu (sufficient data case) olarak adlandırılır.

Her bir sınıfa ait öznitelik vektörleri oluşturulduktan sonra; OVY'de ilk olarak her bir sınıfa ait kovaryans (covariance) matrisi hesaplanır. Kovaryans matrisine ait denklem aşağıda verilmiştir.

$$\Phi^c = \sum_{i=1}^m (\mathbf{a}_i^c - \mathbf{a}_{\text{ort}}^c)(\mathbf{a}_i^c - \mathbf{a}_{\text{ort}}^c)^T \quad (6.4)$$

Burada c , kovaryans matrisi hesaplanan sınıfın indisini; m , öznitelik vektörlerinin sayısını; \mathbf{a}_i^c , c . sınıfa ait i . öznitelik vektörü; $\mathbf{a}_{\text{ort}}^c$, ise c . sınıfa ait öznitelik vektörlerinin ortalamasını temsil etmektedir.

Her bir sınıfa ait kovaryans matrisi elde edildikten sonra, bu kovaryans matrislerine özdeğer-özvektör ayrıştırma işlemi uygulanarak, özdeğerler (λ_j^c) ve bu özdeğerlere karşılık gelen özvektörler \mathbf{u}_j^c elde edilir. Bu özdeğerler azalan bir düzende sıralanır. Elde edilen tüm

özvektörler tarafından kapsanan öznitelik uzayı $(k - 1)$ boyutuna sahip farklılık alt uzayına (difference subspace), ve $(n - k + 1)$ boyutlu farksızlık alt uzayına (indifference subspace) ayrılabilir. Farklılık alt uzayı \mathbf{B} ile, ona dik olan farksızlık alt uzayı ise \mathbf{B}^\perp ile sembolize edilebilir. Azalan düzende sıralanan ilk $(k - 1)$ özdeğerlere karşılık özvektörler farklılık alt uzayını kapsarken, sonraki $(n - k + 1)$ özdeğere karşılık gelen özvektörler farksızlık altuzayını kapsar ve kapsanan bu iki alt uzayın toplamı da tüm öznitelik uzayını verir (Gülmezoğlu vd., 2001).

Yetersiz veri durumu ($m \leq n$) için, $(n - m + 1)$ adet özdeğer sıfır olarak elde edilir ve ortak vektör bu özdeğerlere karşılık gelen özvektörlerin lineer kombinasyonu olarak yazılabilir (Gülmezoğlu vd., 2001). Ancak, yeterli veri durumu ($m > n$) için, herhangi bir özdeğer sıfır olmayacaktır. Bu durumda seçilecek özdeğer sayısı eşitlik (6.5)'te verilen kriter yardımıyla seçilebilir. Eşitlik (6.5)'te verildiği gibi, en düşük $(n - k + 1)$ adet özdeğerin toplamının, tüm özdeğerlerin toplamına oranının; daha önce belirlenmiş bir L değerinden düşük olduğu durumu sağlayan bir k değeri seçilebilir (Oja, 1983).

$$\frac{\sum_{j=k}^n \lambda_j^c}{\sum_{j=1}^n \lambda_j^c} < L \quad (6.5)$$

Bu kriter dışında, azalan düzende sıralanmış tüm özdeğerler çizdirilip, özdeğerlerin değişiminin yavaşladığı nokta tespit edilerek te k değerine karar verilebilir (Gülmezoğlu vd., 2001).

Yeterli veri durumunda, kovaryans matrislerine özdeğer-özvektör ayrıştırma işlemi uygulanıp n adet özdeğer ve bu özdeğerlere karşılık gelen özvektörler elde edildikten ve k değeri seçildikten sonra ortak vektör, ortalama vektörün farksızlık altuzayına izdüşümü alınarak elde edilir.

$$\mathbf{a}_{\text{ortak}}^c = \sum_{j=k}^n [(\mathbf{a}_{\text{ort}}^c)^T \mathbf{u}_j^c] \mathbf{u}_j^c \quad (6.6)$$

Ortak vektör oluşturulduktan sonra, karar kriteri yardımıyla sınıflandırma işlemi gerçekleştirilebilir. Karar kriteri aşağıdaki eşitlikte verilmiştir. Eşitlikte yer alan \mathbf{a}_{test} , test vektörünü; c , ilgili sınıfın indisini; S , toplam sınıf sayısını ifade etmektedir.

$$K = \operatorname{argmin}_{1 \leq c \leq S} \left\| \sum_{j=k}^n \{ [(\mathbf{a}_{\text{test}} - \mathbf{a}_{\text{ort}}^c)^T \mathbf{u}_j^c] \mathbf{u}_j^c \} \right\|^2 \quad (6.7)$$

Yetersiz veri durumunda ise ortak vektör, herhangi bir öznitelik vektörünün, farklılık alt uzayına proje edilmesiyle bulunur.

$$\mathbf{a}_{\text{ortak}}^c = \sum_{j=m}^n [(\mathbf{a}_i^c)^T \mathbf{u}_j^c] \mathbf{u}_j^c \quad (6.8)$$

Yetersiz veri durumu için karar kriteri de aşağıda verildiği gibi yazılabilir.

$$K = \operatorname{argmin}_{1 \leq c \leq S} \left\| \sum_{j=m}^n \{ [(\mathbf{a}_{\text{test}} - \mathbf{a}_i^c)^T \mathbf{u}_j^c] \mathbf{u}_j^c \} \right\|^2 \quad (6.9)$$

K değeri, her bir sınıf indisi için hesaplandıktan sonra, en küçük K değerini veren sınıf indisine bakılır ve gelen test vektörünün o sınıfa ait olduğu söylenir.

6.3. K-En Yakın Komşuluk


K-En Yakın Komşuluk algoritması, tembel öğrenmeli ve parametrik olmayan bir sınıflandırma algoritmasıdır (Cunningham ve Delany, 2007). Basit yapısına rağmen birçok uygulama için etkili sonuçlar verebilmektedir.

K-EYK algoritması, gelen test verisini, eğitim seti içerisindeki en yakın k nokta ile karşılaştırır ve test verisinin, eğitim setindeki verilerle benzerlik veya benzemezlik değerlerini karşılaştırarak doğru sınıfı bulmayı amaçlar. Gelen test verisiyle, en yakın k adet komşuluk arasındaki uzaklık hesaplanır. Bu uzaklıklar artan düzende sıralanır. En düşük

uzaklığa sahip k adet eğitim verisinin çoğunluğunun oluşturduğu sınıf indisi bulunarak gelen test verisinin o sınıfa ait olduğu belirlenir.

Seçilecek k değeri ve uzaklık ölçüm yöntemi sistemin başarısı için önemlidir. Uzaklık ölçümünde en sık kullanılan yöntemlerden biri Öklid (Euclidean) uzaklığıdır. Seçilecek k değeri, pozitif bir tamsayıdır.

Şekil 6.1.'de, 2 sınıflı bir problem için, bir k - En Yakın Komşuluk algoritması örneği verilmiştir. Şekilde "x" ile belirtilen veriler 1. sınıfa, "o" ile belirtilen veriler ise 2. sınıfa ait veriler olsun. Test verisi ise "+" ile gösterilsin. Seçilen k sayısının 3 olduğunu varsayalım. Bu durumda test verisinin en yakın olduğu 3 komşuluğa bakılması gerekmektedir. Görülebileceği gibi test verisinin en yakın olduğu 3 komşusundan, 2 komşusunun indisi 1. sınıfa ait iken, 1 komşusunun indisi 2. sınıfa aittir. Böylece, bu test verisi 1. sınıfa ait olarak sınıflandırılır.

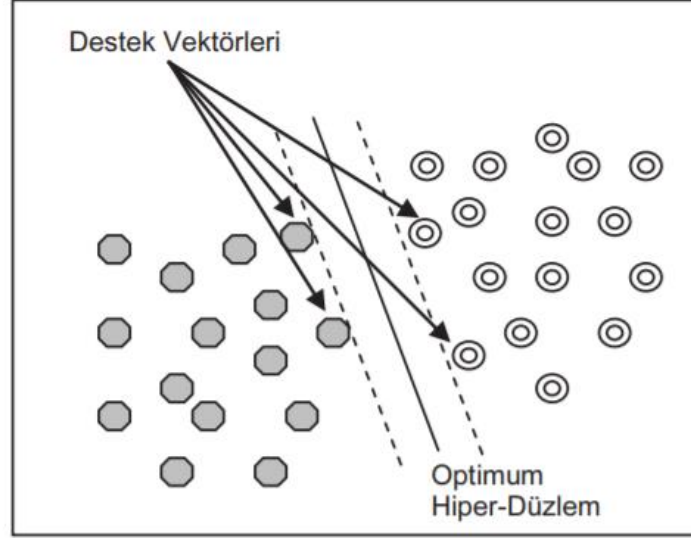


Şekil 6.1. İki sınıflı bir problem için k -EYK örneği

6.4. Destek Vektör Makineleri

Destek Vektör Makineleri, örüntü tanımda sıklıkla kullanılan, Vapnik tarafından geliştirilmiş, ikili (binary) bir sınıflandırma algoritmasıdır (Vapnik, 1998). DVM algoritması temelde, her bir sınıfın hiper düzleme olan uzaklığını maksimum yapacak bir hiper düzlem

bulmayı amaçlar (Guo vd., 2000). Şekil 6.2.’de doğrusal olarak ayrılabilen bir veri kümesi için DVM örneği verilmiştir.



Şekil 6.2. Doğrusal DVM örneği (Kavzoğlu ve Çölkesen’den, 2010)

Bazı durumlarda veriler, doğrusal olarak birbirinden ayıramayabilir. Bu durumda, sınıflandırma işlemini gerçekleştirmek için “kernel” fonksiyonlar kullanılabilir. Bu çalışmada, polinom “kernel” fonksiyonu kullanılmıştır.


DVM orijinalinde, ikili (binary) sınıflandırıcı algoritma olarak önerilmiştir. Çok sınıflı veriler için işlem yapmak için bire karşı bir (one against one) , bire karşı diğerleri (one against all) gibi stratejiler uygulanmaktadır (Hsu ve Lin, 2002). Bu çalışmada bire karşı diğerleri stratejisi kullanılarak çok sınıflı sınıflandırma işlemi gerçekleştirilmiştir.

6.5. Yapay Sinir Ağları

YSA, insan beyninin bilgiyi işleyişinden ilham almış bir bilgi işleme örneğidir (Saxena ve Saad, 2007). YSA; öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda kullanılmaktadır (Öztemel, 2003). Bu tez çalışmasında, YSA algoritması sınıflandırma için kullanılmıştır.

YSA'nın Kendi Kendini Organize Eden Model (Self Organizing Map), Öğrenmeli Vektör Nicemleme (Learning Vector Quantization), Çok Katmanlı Algılayıcılar (Multi-Layer Perceptrons) gibi birçok tipi bulunmaktadır. Bu çalışmada Çok Katmanlı Algılayıcılar kullanılmıştır.

Çok Katmanlı Algılayıcılar bir giriş katmanı (input layer), bir veya birden fazla gizli katman (hidden layer) ve bir çıkış katmanından (output layer) oluşur. Seçilecek gizli katman sayısı ve gizli katmanlardaki nöron sayısı ağın yeteneğini oldukça etkilemektedir. Az sayıda seçilecek gizli katman ve gizli katmandaki nöron sayısı performansın yetersiz olmasına sebebiyet verebilirken, çok sayıda seçilecek gizli katman ve nöron sayısı aşırı uyuma (overfitting) sebebiyet verebilir (Samanta, 2004). Bir giriş, bir gizli katman ve bir çıkış katmanına sahip bir Çok Katmanlı Algılayıcı örneği Şekil 6.3.'te gösterilmiştir.



Şekil 6.3. Çok Katmanlı Algılayıcı örneği

Bu çalışmada, bir giriş katmanı, bir çıkış katmanı ve bir gizli katman içeren İleri Beslemeli (Feed Forward) Çok Katmanlı Algılayıcı kullanılmıştır. Sınıflandırma için Matlab Neural Network Toolbox kullanılmıştır. Öğrenme algoritması için “Levenberg Marquardt” algoritması tercih edilmiştir. Gizli katmandaki nöron sayısına yapılan deneysel çalışmalar sonucunda karar verilmiştir.



7. BULGULAR VE TARTIŞMA

Bu bölümde, hem CWRU veri seti, hem de laboratuvar ortamında oluşturulan veri seti için elde edilen sınıflandırma sonuçlarına yer verilmiştir.

CWRU veri seti farklı arıza tipleri için farklı yarıçaplarda kusurlar içermektedir. Bu tez çalışmasında, CWRU veri seti iki farklı veri grubuna ayrılmıştır. İlk veri grubu, arıza çaplarından ve yükten bağımsız olarak oluşturulmuştur. Örneğin farklı yükler altındaki 0,18 mm, 0,36 mm ve 0,53 mm çapa sahip arızalar tek bir sınıf olarak ele alınmıştır. Bu veri grubu, CWRU-1 veri seti olarak isimlendirilmiştir.

İkinci veri grubu, arızalı durumların sadece 0.36 mm çapa sahip olduğu ve yüksüz durum için toplandığı durumdur. Bu veri grubu, CWRU-2 veri seti olarak isimlendirilmiştir.

Kullanılan hazır veri setlerinin yanında bir de laboratuvar ortamında oluşturulan veri seti üzerinde sınıflandırma işlemi gerçekleştirilmiştir. Bu veri seti de Laboratuvar veri seti (Lab. veri seti) olarak isimlendirilmiştir.

Sınıflandırma işlemi yapılmadan bu üç farklı veri seti için 5 farklı öznitelik grubu oluşturulmuştur. Elde edilen özniteliklerden, iki farklı yöntem ile boyut indirgeme ve öznitelik seçimi yapılmış ve beş sınıflandırıcı kullanılmıştır. Öznitelik vektörlerinin oluşturulması Bölüm 7.1' de anlatılmıştır.

7.1. Öznitelik Vektörlerinin Oluşturulması

Üç veri seti için de her bir sınıfa ait sinyaller (normal durum, iç bilezik arızalı durum, dış bilezik arızalı durum ve bilye arızalı durum), 60 adet örnek setine ayrıştırılmıştır. CWRU-1, CWRU-2 ve Laboratuvar veri seti için her bir örnek seti 1024 örnek içermektedir. Her bir örnek seti için toplam 5 farklı öznitelik grubu oluşturulmuştur.

7.1.1. Zaman ve frekans düzlemi öznitelikleri

İlk öznitelik grubu, zaman ve frekans düzlemindeki istatistiksel parametreler hesaplanarak oluşturulmuştur. Her bir örnek seti için Bölüm 4.1.'de yer alan 10 zaman düzlemi ve 1 adet frekans düzlemi parametresi hesaplanarak öznitelik vektörleri oluşturulmuştur. Böylece 1x11 boyutlu öznitelik vektörleri oluşturulmuştur.

7.1.2. Dalgacık Paket Dönüşümü

İkinci öznitelik grubu her bir örnek setinde bulunan sinyale 3 seviye DPD uygulanarak elde edilmiştir. Uygulanan 3 seviye DPD sonrasında 3. seviyede toplam 8 adet katsayı elde edilmiştir. Bu katsayıların her biri için ortalama, varyans, basıklık ve çarpıklık değerleri hesaplanmıştır. Böylece 1x32 boyutlu öznitelik vektörleri elde edilmiştir. DPD için “db4” ana dalgacığı seçilmiştir.


7.1.3. Ampirik Kip Ayrışımı

Üçüncü öznitelik grubu için her bir örnek setindeki sinyale AKA uygulanmış ve İKF'ler elde edilmiştir. Elde edilen İKF'lerden ilk 4 tanesi seçilmiş ve seçilen bu İKF'ler için ortalama, varyans, basıklık ve çarpıklık değerleri hesaplanmıştır. Böylece toplam 1x16 boyutlu öznitelik vektörleri oluşturulmuştur. CWRU veri seti içerisinde yer alan sağlıklı durum, iç bilezik arızalı durum, dış bilezik arızalı durum ve bilye arızalı durumlara ait sinyaller için oluşturulan ilk 4 İKF sırasıyla Şekil 7.1., Şekil 7.2., Şekil 7.3. ve Şekil 7.4'te verilmiştir.


7.1.4. Ampirik Kip Ayrışımı-Otoregresif Model

Dördüncü öznitelik grubu, AKA ve OM beraber kullanılarak oluşturulmuştur. AKA kullanılarak elde edilen içsel kip fonksiyonları için OM parametreleri hesaplanarak öznitelik vektörleri oluşturulmuştur. İlk 4 İKF ve bu 4 İKF için toplamda 45 adet OM parametresi


hesaplanarak 1×45 boyutunda öznitelik vektörleri oluşturulmuştur. İlk İKF için 15, diğer İKF'ler için 10'ar adet otoregresif model parametresi hesaplanmıştır.




Şekil 7.1. Normal duruma ait ilk 4 İKF



Şekil 7.2. İç bilezik arızalı duruma ait ilk 4 İKF



Şekil 7.3. Dış bilezik arızalı duruma ait ilk 4 İKF



Şekil 7.4. Bilye arızalı duruma ait ilk 4 İKF

7.1.5. Bütün öznitelikler

Son öznitelik grubu, daha önce oluşturulan 4 farklı öznitelik grubundan elde edilen özniteliklerin birleştirilmesiyle elde edilmiştir. Böylece 1x104 boyutlu öznitelik vektörleri oluşturulmuştur.

7.2. Boyut İndirgeme ve Öznitelik Seçimi

Bu tez çalışmasında boyut indirgeme ve öznitelik seçimi işlemleri için TBA ve GA kullanılmıştır.

TBA ile, toplam varyansın %97'sine karşılık gelen özvektörler kullanılarak boyut indirgeme işlemi gerçekleştirilmiştir.

GA için uygunluk (fitness) fonksiyonu, doğruluk (accuracy) değeri olarak belirlenmiştir. Popülasyon boyutu 50, nesil sayısı 75, mutasyon oranı ise 0.05 olarak seçilmiştir. Seçim işlemi için "Rulet Tekerleği" yöntemi ve çaprazlama için tek noktalı çaprazlama fonksiyonu kullanılmıştır. Popülasyon tipi için "bit string" tercih edilmiştir. GA ile öznitelik seçimi işlemi, DVM ve k-EYK sınıflandırıcıları için gerçekleştirilmiştir. GA, her "fold" için uygulanmıştır. Her bir "fold" içerisinde yer alan eğitim verisi, kendi içerisinde 36 eğitim, 12 doğrulama verisi olacak şekilde bölünmüştür. Öznitelik seçimi esnasında uygunluk fonksiyonunun değeri bu doğrulama verileri kullanılarak gerçekleştirilmiştir. Daha sonra elde edilen öznitelikler için test verileri sınıflandırıcılara uygulanmış ve sınıflandırma işlemi gerçekleştirilmiştir.

7.3 Sınıflandırma

Oluşturulan 5 farklı öznitelik grubu hem öznitelik seçimi uygulanmadan hem de öznitelik seçimi uygulanarak sınıflandırıcılara girdi olarak verilmiş ve sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemleri için daha önce de bahsedildiği gibi OVY, DVM, k-EYK, YSA ve FDDA kullanılmıştır.

OVY’de yeterli veri durumunda, ortak vektörü hesaplamak için seçilecek özdeğerlerin sayısı; tüm özdeğerler çizdirildikten sonra özdeğerlerdeki değişimin yavaşladığı yer tespit edilerek seçilmiştir.

K-EYK algoritması için optimum k değeri, her bir öznitelik vektör grubu için deneysel sonuçlar neticesinde elde edilmiştir.

DVM ile sınıflandırma için bire karşı diğerleri tekniği uygulanmış ve “kernel” fonksiyonu olarak “polynomial” kullanılmıştır.

YSA için tek gizli katmana sahip bir İleri Beslemeli YSA modeli Matlab Neural Network Toolbox kullanılarak oluşturulmuştur. Gizli katmandaki nöron sayılarına deneysel sonuçlar neticesinde karar verilmiştir. Başlangıç ağırlıkları rastgele oluşturulmuştur. Sınıflandırma işlemi 5 kez tekrarlanmış ve en iyi sonuç alınmıştır.

Tüm sınıflandırıcılar için, sınıflandırma aşamasında 5 katlı çapraz doğrulama (5 fold cross validation) yöntemi kullanılmıştır.

7.4 Sonuçlar

Öncelikle herhangi bir boyut indirgeme veya öznitelik seçimi işlemi yapılmadan her üç veri grubu için sınıflandırma işlemi gerçekleştirilmiştir. Çizelge 7.1, 7.2 ve 7.3’ te sırasıyla CWRU-1, CWRU-2 ve Laboratuvar veri seti için öznitelik seçimi uygulanmadan elde edilen sınıflandırma başarıları verilmiştir. K-EYK için seçilen ‘k’ değeri ve DVM için seçilen polinom derecesi ‘d’ ilgili çizelgelerde tanıma oranlarının yanında parantez içerisinde verilmiştir. Boyut indirgeme ve öznitelik seçimi yapılırken de bu değerler kullanılmıştır. Zaman ve frekans düzlemi öznitelikleri, çizelgelerde “ZFDÖ” ile ifade edilmiştir.

Çizelge 7.1. Öznitelik seçimi yapılmadan CWRU-1 veri seti için elde edilen sonuçlar

| Öznitelik Grubu | FDA | OVY | DVM | YSA | k-EYK |
|---------------------|-------|-------|-------------|-------|-------------|
| ZFDÖ | 85,83 | 85,83 | 93,75 (d=2) | 97,5 | 93,75 (k=5) |
| DPD | 81,25 | 81,67 | 90 (d=1) | 90,83 | 76,25 (k=1) |
| AKA | 72,08 | 73,75 | 76,25 (d=2) | 88,33 | 75,42 (k=1) |
| AKA-OM | 93,33 | 87,5 | 89,17 (d=1) | 93,33 | 80,42 (k=1) |
| BÜTÜN ÖZİNİTELİKLER | 91,25 | 97,08 | 95,83 (d=1) | 96,25 | 92,08 (k=9) |

Çizelge 7.2. Öznitelik seçimi yapılmadan CWRU-2 veri seti için elde edilen sonuçlar

| Öznitelik Grubu | FDA | OVY | DVM | YSA | k-EYK |
|---------------------|-------|-------|-------------|-------|-------------|
| ZFDÖ | 99,17 | 96,25 | 100 (d=1) | 100 | 99,58 (k=3) |
| DPD | 96,67 | 98,75 | 100 (d=1) | 99,58 | 97,08 (k=3) |
| AKA | 86,25 | 85,42 | 92,92 (d=1) | 96,25 | 85,83 (k=5) |
| AKA-OM | 98,33 | 94,17 | 97,92 (d=1) | 99,58 | 94,58 (k=1) |
| BÜTÜN ÖZİNİTELİKLER | 100 | 99,58 | 100 (d=1) | 100 | 98,75 (k=3) |

Çizelge 7.3. Öznitelik seçimi yapılmadan Lab. veri seti için elde edilen sonuçlar

| Öznitelik Grubu | FDA | OVY | DVM | YSA | k-EYK |
|---------------------|-------|-------|-------------|-------|-------------|
| ZFDÖ | 79,58 | 87,08 | 86,67 (d=3) | 92,5 | 90 (k=3) |
| DPD | 92,5 | 90,42 | 96,67 (d=1) | 99,58 | 85,83 (k=1) |
| AKA | 85,42 | 85 | 93,75 (d=1) | 94,58 | 83,75 (k=9) |
| AKA-OM | 95,83 | 90,42 | 96,67 (d=1) | 97,92 | 90 (k=7) |
| BÜTÜN ÖZİNİTELİKLER | 93,33 | 97,5 | 99,17 (d=1) | 98,75 | 95 (k=7) |

Her üç veri seti için de, daha sonra TBA yöntemi kullanılarak boyut indirgeme ve GA ile öznitelik seçimi işlemi ayrı ayrı gerçekleştirilmiştir. Çizelge 7.4, 7.5 ve 7.6' da

sırasıyla CWRU-1, CWRU-2 ve Laboratuvar veri seti için TBA ile boyut indirgeme ve GA ile öznitelik seçimi uygulanarak elde edilen sınıflandırma başarıları verilmiştir.

Çizelge 7.4. TBA ve GA uygulandıktan sonra CWRU-1 veri seti için elde edilen sonuçlar

| Öznitelik Grubu | TBA | | | | | GA | |
|-----------------------|-------|-------|-------|-------|-------|-------|-------|
| | FDAА | OVY | DVM | YSA | k-EYK | DVM | k-EYK |
| ZFDÖ | 79,58 | 79,17 | 93,75 | 87,92 | 93,75 | 95,42 | 94,58 |
| DPD | 76,25 | 79,58 | 88,75 | 67,08 | 76,25 | 87,08 | 88,75 |
| AKA | 70 | 63,75 | 68,75 | 71,67 | 75,42 | 86,25 | 76,67 |
| AKA-OM | 85,83 | 86,25 | 87,5 | 88,33 | 79,58 | 96,25 | 95 |
| BÜTÜN ÖZNİTELİKLER | 92,5 | 90 | 94,17 | 80,83 | 91,25 | 96,67 | 93,33 |

Çizelge 7.5. TBA ve GA uygulandıktan sonra CWRU-2 veri seti için elde edilen sonuçlar

| Öznitelik Grubu | TBA | | | | | GA | |
|-----------------------|-------|-------|------|-------|-------|-------|-------|
| | FDAА | OVY | DVM | YSA | k-EYK | DVM | k-EYK |
| ZFDÖ | 99,58 | 97,92 | 100 | 100 | 100 | 99,17 | 99,58 |
| DPD | 97,92 | 97,5 | 100 | 87,08 | 97,92 | 97,92 | 99,17 |
| AKA | 78,75 | 82,5 | 85 | 87,5 | 81,67 | 92,08 | 87,5 |
| AKA-OM | 97,92 | 93,33 | 97,5 | 96,25 | 94,17 | 97,5 | 96,25 |
| BÜTÜN ÖZNİTELİKLER | 100 | 96,67 | 100 | 91,67 | 98,33 | 100 | 97,92 |

Çizelge 7.6. TBA ve GA uygulandıktan sonra Lab. veri seti için elde edilen sonuçlar

| Öznitelik Grubu | TBA | | | | | GA | |
|------------------------|-------|-------|-------|-------|-------|-------|-------|
| | FDA | OVY | DVM | YSA | k-EYK | DVM | k-EYK |
| ZFDÖ | 83,75 | 84,58 | 86,67 | 76,25 | 87,92 | 93,33 | 90,42 |
| DPD | 89,17 | 85,42 | 95 | 78,75 | 85,42 | 95,83 | 87,08 |
| AKA | 81,67 | 80,42 | 88,75 | 87,92 | 82,92 | 92,92 | 80,42 |
| AKA-OM | 87,92 | 85,42 | 93,33 | 95 | 89,58 | 97,08 | 89,58 |
| BÜTÜN ÖZİNİTELİKLER | 96,67 | 87,5 | 97,5 | 86,25 | 94,58 | 96,25 | 94,58 |

GA daha önce bahsedildiği gibi her “fold” için uygulanmıştır. Her bir “fold” içerisinde bulunan her bir sınıftaki 48 eğitim vektörü, kendi içerisinde 36 eğitim 12 doğrulama vektörü olarak ayrılmıştır. Uygunluk fonksiyonu değeri de bu doğrulama vektörleri kullanılarak hesaplanmış ve değerli öznitelikler elde edilmiştir. Ardından elde edilen bu değerli öznitelikler için, ilgili fold için başlangıç aşamasında ayrılan test vektörleri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir.

Çizelge 7.7, 7.8. ve 7.9.’da GA sonucunda elde edilen ortalama öznitelik sayıları verilmiştir.

Çizelge 7.7. GA ile CWRU-1 veri seti için elde edilen ortalama öznitelik sayıları

| Öznitelik Grubu | DVM | k-EYK |
|---------------------|------|-------|
| ZFDÖ | 6,4 | 4,6 |
| DPD | 17,4 | 14,8 |
| AKA | 7 | 8,2 |
| AKA-OM | 21,6 | 22,2 |
| BÜTÜN ÖZİNİTELİKLER | 53 | 50 |

Çizelge 7.8. GA ile CWRU-2 veri seti için elde edilen ortalama öznitelik sayıları

| Öznitelik Grubu | DVM | k-EYK |
|---------------------|------|-------|
| ZFDÖ | 7,2 | 8 |
| DPD | 16,6 | 17,4 |
| AKA | 9 | 7,6 |
| AKA-OM | 23,2 | 23,2 |
| BÜTÜN ÖZİNİTELİKLER | 55 | 53,4 |

Çizelge 7.9. GA ile Lab. veri seti için elde edilen ortalama öznitelik sayıları

| Öznitelik Grubu | DVM | k-EYK |
|---------------------|------|-------|
| ZFDÖ | 6,2 | 3,6 |
| DPD | 17 | 14,2 |
| AKA | 9 | 7,8 |
| AKA-OM | 23,8 | 20,4 |
| BÜTÜN ÖZİNİTELİKLER | 51,4 | 52,8 |

Sonuçlar değerlendirildiğinde, boyut indirgeme veya öznitelik seçimi uygulanmadan;

CWRU-1 veri seti için, en yüksek tanıma oranının, zaman ve frekans düzlemi özniteliklerinin, YSA sınıflandırıcısına uygulandığında elde edildiği görülmüştür. AKA uygulanan sinyalden elde edilen özniteliklerin, tüm sınıflandırıcılar için en kötü sonucu verdiği görülmektedir.

CWRU-2 veri setinde, tüm öznitelik çıkarım yöntemleri için yüksek tanıma oranları elde edilmiştir. Zaman ve frekans düzlemi öznitelikleri ile hem DVM hem de YSA için %100 tanıma oranı elde edilmiştir. Ayrıca DPD ile elde edilen öznitelikler, DVM sınıflandırıcısına uygulandığında yine %100 tanıma oranı elde edilmiştir. Tüm sınıflandırıcılar için, AKA kullanılarak elde edilen öznitelikler en kötü tanıma oranlarını

vermiştir. Bütün özneliklerin birleştirilerek kullanıldığı durumda, 3 sınıflandırıcının tüm test vektörlerini hatasız sınıflandırdığı gözlemlenmiştir.

Lab. veri seti için, AKA ve OM birlikte kullanılarak elde edilen öznelik vektörleri ve DPD kullanılarak elde edilen öznelik vektörleri en yüksek tanıma oranlarını vermiştir. Bütün özneliklerin birleştirilmesiyle oluşturulan öznelik grubunda ise, tüm sınıflandırıcılar için %90'ın üzerinde başarı sağlanmıştır.

TBA ile boyut indirgeme işlemi uygulandığında;

CWRU-1 veri seti için, birçok öznelik çıkarımı yöntemi ve sınıflandırıcı için tanıma oranlarının düştüğü gözlemlenmiştir. Boyut indirgeme işleminden sonra özellikle YSA için tanıma oranlarında ciddi düşüşler gerçekleşmiştir.

CWRU-2 veri seti için, boyut indirgeme gerçekleştirildiğinde zaman ve frekans düzleminde elde edilen öznelikler için, üç sınıflandırıcıda %100 tanıma oranı elde edilmiştir. Ayrıca DPD ile elde edilen öznelikler de TBA ile boyut indirgemesi işlemi gerçekleştirildikten sonra DVM sınıflandırıcısına uygulandığında, %100 tanıma oranı vermiştir. AKA ile elde edilen özneliklere TBA uygulandığında oranların oldukça düştüğü gözlemlenmiştir. Bütün özneliklerin kullanıldığı öznelik grubunda ise, boyut indirgeme uygulandığında FDAA ve DVM için %100 tanıma oranı elde edildiği görülmüştür.

Lab. veri seti için de, TBA ile boyut indirgeme uygulandığında, DPD, AKA ve bütün özneliklerin kullanıldığı durum için en yüksek tanıma oranları DVM sınıflandırıcısı ile elde edilirken, AKA-OM beraber kullanılarak elde edilen öznelik vektörleri için en yüksek tanıma oranı YSA için elde edilmiştir. Zaman ve frekans düzlemi öznelikleri için en yüksek tanıma oranı ise k-EYK sınıflandırıcısı kullanıldığında elde edilmiştir.

GA ile öznelik seçimi uygulandığında;

Genelde k-EYK algoritması için tanıma oranları artarken, DVM için bir düşüş olduğu gözlemlenmiştir. Genetik algoritma uygulanırken, DVM için her bir “fold” da

dođrulama (validation) vektörlerinin tanıma oranları çok yüksek gelmesine rağmen, test vektörleri için aynı başarı sağlanamamıştır.

Üç veri seti kendi içerisinde değerlendirildiğinde, aynı yük ve arıza çaplarında veri toplanan CWRU-2 veri seti ve Laboratuvar veri seti kullanılarak elde edilen tanıma oranlarının, farklı yük ve arıza çapları altında toplanan verilerin birleştirilmesiyle elde edilen CWRU-1 veri seti kullanılarak elde edilen tanıma oranlarından birçok durumda fazla olduğu görülmüştür.



8. SONUÇ VE ÖNERİLER

Asenkron motorlar, endüstride sıklıkla kullanıldıkları için, bu motorların arızalarının tespiti için literatürde birçok çalışma yapılmıştır. Yapılan çalışmalarda, asenkron motorlarda meydana gelen arızalarının büyük bir kısmının rulman arızaları olduğu görülmektedir. Bu durum da rulman arızalarının tespitinin önemini ortaya koymaktadır.

Rulman arızalarının tespitinde genellikle akım, titreşim ve akustik emisyon sinyalleri kullanılmaktadır. Bunlar arasında en sık tercih edileni titreşim sinyalleridir. Yapılan çalışmalar gösteriyor ki, titreşim sinyalleri rulman arızalarının tespitinde büyük başarı göstermektedir. Bu tez çalışmasında da rulman arızalarının tespiti için titreşim sinyallerinden yararlanılmıştır. Çalışma kapsamında hem hazır bir veri seti kullanılmış, hem de laboratuvar ortamında bir titreşim veri seti oluşturulmuştur.

Hem hazır veri seti için, hem de laboratuvar ortamında elde edilen veri seti için çeşitli öznitelik çıkarım, seçim yöntemleri ve sınıflandırıcıların başarıları incelenmiş ve hangi öznitelik çıkarım yöntemlerinin hangi sınıflandırıcı ile beraber kullanıldığında daha başarılı sonuçlar verdiği irdelenmiştir.

Bu sonuçlar ışığında, öznitelik seçimi ve boyut indirgemesi uygulanmayan durum için, tüm veri setlerinde, bütün özniteliklerin kullanıldığı durumda, yüksek tanıma oranlarının elde edildiği gözlemlenmiştir. Tek öznitelik çıkarım yöntemi kullanılan durumlar değerlendirildiğinde ise, AKA ve OM beraber kullanılarak oluşturulan özniteliklerinin, Lab. veri seti için en iyi sonuçları verirken, zaman ve frekans düzleminde elde edilen özniteliklerin, CWRU-1 ve CWRU-2 veri setleri için en iyi sonuçları verdiği gözlenmiştir.

Sınıflandırıcılar değerlendirildiğinde ise birçok öznitelik çıkarım yöntemi için YSA ve DVM'nin en iyi sonuçları verdiği gözlemlenmiştir. YSA ve DVM, CWRU-2 veri setinde öznitelik seçimi veya boyut indirgeme uygulanmadan zaman ve frekans düzlemi öznitelikleri için %100 başarı sağlamıştır.

CWRU-1 ve CWRU-2 veri setleri için zaman ve frekans düzlemi öznitelikleri çok yüksek başarı gösterirken, Lab. veri seti için bu öznitelik grubunun daha düşük başarı sağladığı gözlemlenmiştir. Bu durumun, CWRU veri setleri elde edilirken kullanılan ivmeölçerin, Lab. veri seti elde edilirken kullanılan ivmeölçerden çok daha iyi hassasiyete sahip olmasından kaynaklandığı düşünülmektedir.

İleride yapılacak çalışmalar için, farklı öznitelik çıkarım yöntemlerini, farklı sınıflandırıcılar ile beraber kullanarak daha iyi sonuçlar elde edilmesi planlanmaktadır. Ayrıca daha iyi performans veren öznitelik seçim yöntemleri ile tanıma oranlarının artırılması planlanmaktadır.



KAYNAKLAR DİZİNİ

- Ahmad, I., Hussain, M., Alghamdi, A., Alelaiwi, A., 2014, Enhancing SVM performance in intrusion detection using optimal feature subset selection based on genetic principal components. *Neural computing and applications*, 24(7-8), 1671-1682.
- Al-Bugharbee, H., Trendafilova, I., 2015, Autoregressive modelling for rolling element bearing fault diagnosis. In *Journal of Physics: Conference Series* (Vol. 628, No. 1, p. 012088). IOP Publishing.
- Ayaz, E., 2012, Autoregressive modeling based bearing fault detection in induction motors. In *IX Symposium Industrial Electronics INDEL*, Banja Luka.
- Aytaç, Z., Gülmezoğlu, N., Gülmezoğlu, M. B., 2016, Application of the common vector approach on identification of winter rapeseed (*Brassica napus* L.) cultivars and their yield characters. *International Journal of Sustainable Agricultural Management and Informatics*, 2(1), 66-78.
- Bin, G. F., Gao, J. J., Li, X. J., Dhillon, B. S., 2012, Early fault diagnosis of rotating machinery based on wavelet packets—Empirical mode decomposition feature extraction and neural network. *Mechanical Systems and Signal Processing*, 27, 696-711.
- Box, G. E., Jenkins, G. M., Reinsel, G. C., Ljung, G. M., 2015, *Time series analysis: forecasting and control*. John Wiley & Sons.
- Chebil, J., Noel, G., Mesbah, M., Deriche, M., 2009, Wavelet decomposition for the detection and diagnosis of faults in rolling element bearings. *Jordan Journal of Mechanical and Industrial Engineering*, 3(4), 260-267.
- Coifman, R. R., Wickerhauser, M. V., 1992, Entropy-based algorithms for best basis selection. *IEEE Transactions on information theory*, 38(2), 713-718.
- Cunningham, P., Delany, S. J., 2007, k-Nearest neighbour classifiers. *Multiple Classifier Systems*, 34, 1-17.
- Delgado-Arredondo, P. A., Morinigo-Sotelo, D., Osornio-Rios, R. A., Avina-Cervantes, J. G., Rostro-Gonzalez vd., 2017, Methodology for fault detection in induction motors via sound and vibration signals. *Mechanical Systems and Signal Processing*, 83, 568-589.
- Ergin, S., Tezel, S., Gulmezoglu, M. B., 2011, DWT-based fault diagnosis in induction motors by using CVA. In *Innovations in Intelligent Systems and Applications (INISTA)*, 2011 International Symposium on (pp. 129-132). IEEE.

KAYNAKLAR DİZİNİ (devam)

- Ergin, S., Uzuntas, A., Gulmezoglu, M. B., 2012, Detection of stator, bearing and rotor faults in induction motors. *Procedia Engineering*, 30, 1103-1109.
- Fisher, R. A., 1936, The use of multiple measurements in taxonomic problems. *Annals of human genetics*, 7(2), 179-188.
- Glowacz, A., Glowacz, W., Glowacz, Z., Kozik, J., 2018, Early fault diagnosis of bearing and stator faults of the single-phase induction motor using acoustic signals. *Measurement*, 113, 1-9.
- Golbaghi, V. K., Shahbazian, M., Moslemi, B., Rashed, G., 2017, Rolling Element Bearing Condition Monitoring Based on Vibration Analysis Using Statistical Parameters of Discrete Wavelet Coefficients and Neural Networks. *International Journal of Automation and Smart Technology*, 7(2), 61-69.
- Guo, G., Li, S. Z., Chan, K., 2000, Face recognition by support vector machines. In *Automatic Face and Gesture Recognition, 2000. Proceedings. Fourth IEEE International Conference on* (pp. 196-201). IEEE.
- Gupta, A., Kumar, D., Chakraborti, A., Sharma, K., 2016, Performance Evaluation of Empirical Mode Decomposition Algorithms for Mental Task Classification. *bioRxiv*, 076646.
- Gülmezoglu, M. B., Dzhafarov, V., Barkana, A., 2001, The common vector approach and its relation to principal component analysis. *IEEE Transactions on Speech and Audio Processing*, 9(6), 655-662.
- Gülmezoglu, M. B., Ergin, S., 2007, An approach for bearing fault detection in electrical motors. *International Transactions on Electrical Energy Systems*, 17(6), 628-641.
- Günel, S., 2012, Hybrid feature selection for text classification. *Turkish Journal of Electrical Engineering & Computer Sciences*, 20(Sup. 2), 1296-1311.
- Haddad, R. Z., Lopez, C. A., Pons-Llinares, J., Antonino-Daviu, J., Strangas, E. G., 2015, Outer race bearing fault detection in induction machines using stator current signals. In *Industrial Informatics (INDIN), 2015 IEEE 13th International Conference on* (pp. 801-808). IEEE.
- Harrag, A., 2015, Nature-inspired feature subset selection application to arabic speaker recognition system. *International Journal of Speech Technology*, 18(2), 245-255.
- Hassan, A. R., Bhuiyan, M. I. H., 2016, Automatic sleep scoring using statistical features in the EMD domain and ensemble methods. *Biocybernetics and Biomedical Engineering*, 36(1), 248-255.

KAYNAKLAR DİZİNİ (devam)

- Haupt, R. L., Haupt, S. E., Haupt, S. E., 1998, Practical genetic algorithms (Vol. 2). New York: Wiley.
- He, Q., 2013, Vibration signal classification by wavelet packet energy flow manifold learning. *Journal of Sound and Vibration*, 332(7), 1881-1894.
- Hsu, C. W., Lin, C. J., 2002, A comparison of methods for multiclass support vector machines. *IEEE transactions on Neural Networks*, 13(2), 415-425.
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H. vd., 1998, The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. In *Proceedings of the Royal Society of London A: mathematical, physical and engineering sciences* (Vol. 454, No. 1971, pp. 903-995). The Royal Society.
- IEEE Motor Reliability Working Group, 1986, Report of large motor reliability survey of industrial and commercial installations. *IEEE Trans. Ind. Appl.*, vol. IA-21, no. 4, pp. 853-872, Jul. .
- Isikli Esener, I., Ergin, S., Yuksel, T., 2017, A New Feature Ensemble with a Multistage Classification Scheme for Breast Cancer Diagnosis. *Journal of healthcare engineering*, 2017.
- Jung, J. H., Lee, J. J., Kwon, B. H., 2006, Online diagnosis of induction motors using MCSA. *IEEE Transactions on Industrial Electronics*, 53(6), 1842-1852.
- Junsheng, C., Dejie, Y., Yu, Y., 2006, A fault diagnosis approach for roller bearings based on EMD method and AR model. *Mechanical Systems and Signal Processing*, 20(2), 350-362.
- Kavzoğlu, T., Çölkesen, İ., 2010, Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 144(7), 73-82.
- Kumbhar, P., Mali, M., 2016, A survey on feature selection techniques and classification algorithms for efficient text classification. *International Journal of Science and Research*, 5(5), 9.
- Lei, Y., He, Z., Zi, Y., 2008, A new approach to intelligent fault diagnosis of rotating machinery. *Expert Systems with applications*, 35(4), 1593-1600.
- Lei, Y., Lin, J., He, Z., Zuo, M. J., 2013, A review on empirical mode decomposition in fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*, 35(1-2), 108-126.

KAYNAKLAR DİZİNİ (devam)

- Leite, V. C. M. N., da Silva, J. G. B., Torres, G. L., Veloso, G. F. C., da Silva vd., 2017, Bearing Fault Detection in Induction Machine Using Squared Envelope Analysis of Stator Current. In Bearing Technology. InTech.
- Li, B., Chow, M. Y., Tipsuwan, Y., Hung, J. C., 2000, Neural-network-based motor rolling bearing fault diagnosis. IEEE transactions on industrial electronics, 47(5), 1060-1069.
- Loparo, K. A., 2018, CWRU veriseti, <http://csegroups.case.edu/bearingdatacenter>, erişim tarihi: 15.05.2018
- Mallat, S. G., 1989, A theory for multiresolution signal decomposition: the wavelet representation. IEEE transactions on pattern analysis and machine intelligence, 11(7), 674-693.
- McInerny, S. A., Dai, Y., 2003, Basic vibration signal processing for bearing fault detection. IEEE Transactions on education, 46(1), 149-156.
- Oja E., 1983, Subspace methods of pattern recognition. John Wiley and Sons, Inc.: New York.
- Öztemel, E., 2003, Yapay Sinir Ağları. PapatyaYayincilik, İstanbul.
- Pandya, D. H., Upadhyay, S. H., Harsha, S. P., 2013, Fault diagnosis of rolling element bearing with intrinsic mode function of acoustic emission data using APF-KNN. Expert Systems with Applications, 40(10), 4137-4145.
- Rajeswari, C., Sathiyabhama, B., Devendiran, S., Manivannan, K., 2014, Bearing fault diagnosis using wavelet packet transform, hybrid PSO and support vector machine. Procedia Engineering, 97, 1772-1783.
- Rauber, T. W., de Assis Boldt, F., Varejão, F. M., 2015, Heterogeneous feature models and feature selection applied to bearing fault diagnosis. IEEE Transactions on Industrial Electronics, 62(1), 637-646.
- Rilling, G., Flandrin, P., Goncalves, P., 2003, On empirical mode decomposition and its algorithms. In IEEE-EURASIP workshop on nonlinear signal and image processing (Vol. 3, pp. 8-11). NSIP-03, Grado (I).
- Sadıç, S., Gülmezoğlu, M. B., 2011, Common vector approach and its combination with GMM for text-independent speaker recognition. Expert Systems with Applications, 38(9), 11394-11400.
- Saeys, Y., Inza, I., Larrañaga, P., 2007, A review of feature selection techniques in bioinformatics. bioinformatics, 23(19), 2507-2517.

KAYNAKLAR DİZİNİ (devam)

- Saidi, L., Ali, J. B., Fnaiech, F., 2015, Application of higher order spectral features and support vector machines for bearing faults classification. *ISA transactions*, 54, 193-206.
- Samanta, B., 2004, Gear fault detection using artificial neural networks and support vector machines with genetic algorithms. *Mechanical Systems and Signal Processing*, 18(3), 625-644.
- Saxena, A., Saad, A., 2007, Evolving an artificial neural network classifier for condition monitoring of rotating mechanical systems. *Applied Soft Computing*, 7(1), 441-454.
- Schoen, R. R., Habetler, T. G., Kamran, F., Bartfield, R. G., 1995, Motor bearing damage detection using stator current monitoring. *IEEE transactions on industry applications*, 31(6), 1274-1279.
- Shen, C., Wang, D., Kong, F., Peter, W. T., 2013, Fault diagnosis of rotating machinery based on the statistical parameters of wavelet packet paving and a generic support vector regressive classifier. *Measurement*, 46(4), 1551-1564.
- Siddiqui, K. M., Sahay, K., Giri, V. K., 2014, Health monitoring and fault diagnosis in induction motor-a review. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 3(1), 6549-6565.
- Sreejith, B., Verma, A. K., Srividya, A., 2008, Fault diagnosis of rolling element bearing using time-domain features and neural networks. In *Industrial and Information Systems, 2008. ICIIS 2008. IEEE Region 10 and the Third international Conference on* (pp. 1-6). IEEE.
- Su, Z., Tang, B., Liu, Z., Qin, Y., 2015, Multi-fault diagnosis for rotating machinery based on orthogonal supervised linear local tangent space alignment and least square support vector machine. *Neurocomputing*, 157, 208-222.
- Sugiyama, M., 2007, Dimensionality reduction of multimodal labeled data by local fisher discriminant analysis. *Journal of machine learning research*, 8(May), 1027-1061.
- Tandon, N., Yadava, G. S., Ramakrishna, K. M., 2007, A comparison of some condition monitoring techniques for the detection of defect in induction motor ball bearings. *Mechanical systems and signal processing*, 21(1), 244-256.
- Vapnik, V., 1998, *Statistical learning theory*. New York: John Wiley & Sons.
- Wang, Y., Xu, G., Liang, L., Jiang, K., 2015, Detection of weak transient signals based on wavelet packet transform and manifold learning for rolling element bearing fault diagnosis. *Mechanical Systems and Signal Processing*, 54, 259-276.

KAYNAKLAR DİZİNİ (devam)

- Yan, R., Gao, R. X., Chen, X., 2014, Wavelets for fault diagnosis of rotary machines: A review with applications. *Signal processing*, 96, 1-15.
- Yang, D. M., Stronach, A. F., MacConnell, P., 2003, The application of advanced signal processing techniques to induction motor bearing condition diagnosis. *Meccanica*, 38(2), 297-308.
- Yu, Y., Junsheng, C., 2006, A roller bearing fault diagnosis method based on EMD energy entropy and ANN. *Journal of sound and vibration*, 294(1-2), 269-277.
- Zarei, J., Poshtan, J., 2007, Bearing fault detection using wavelet packet transform of induction motor stator current. *Tribology International*, 40(5), 763-769.

