



# Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

## Asenkron Motor Eş Zamanlı Çoklu Arızalarının Titreşim Sinyalleri ile Çok Etiketli Sınıflandırılması

 Mustafa ERCİRE <sup>a,\*</sup>,  Abdurrahman ÜNSAL <sup>b</sup>

<sup>a</sup> Bilgisayar Teknolojileri Bölümü, Gediz Meslek Yüksekokulu, Kütahya Dumlupınar Üniversitesi, Kütahya, TÜRKİYE

<sup>b</sup> Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Kütahya Dumlupınar Üniversitesi, Kütahya, TÜRKİYE

\* Sorumlu yazarın e-posta adresi: [mustafa.ercire@dpu.edu.tr](mailto:mustafa.ercire@dpu.edu.tr)  
DOI: 10.29130/dubited.1288799

### ÖZ

Endüstride yaygın olarak kullanılan asenkron motorlarda meydana gelen arızaların tespiti büyük öneme sahiptir. Asenkron motorlarda yaygın olarak meydana gelen arızalar elektriksel ve mekanik arızalardan oluşmaktadır. Arızaların tespiti için çeşitli yöntemler kullanılmaktadır. Yaygın kullanılan arıza tespit yöntemleri stator akımı, besleme gerilimi, titreşim, ısı ve ses gibi verileri kullanılmaktadır. Bu yöntemlerde genel olarak her bir arıza türü için belirli bir yöntem kullanılmaktadır. Birden çok arızanın eş zamanlı olarak meydana geldiği durumlar için ileri seviye arıza tespit yöntemlerinin kullanılması gerekir. Bu çalışmada, asenkron motorlarda meydana gelen rotor kırığı, dış-bilezik rulman arızası, iç-bilezik rulman arızası, eksenal kaçıklık ve stator sargısı kısa-devre arızaları tekil, eş zamanlı-ikili ve eş zamanlı-üçlü olarak incelenmiştir. İncelemede 3-eksen titreşim verileri kullanılmıştır. Titreşim verilerinin istatistiksel değerlerinden öznitelik vektörleri çıkarılmıştır. Öznitelik vektörü çok etiketli sınıflandırma yönteminde girdi olarak kullanılmıştır. Çok etiketli sınıflandırma için İkili Alâka Düzeyi (*Binary Relevance*, BR), Etiket Güç Seti (*Label Powerset*, LP) ve Sınıflandırıcı Zinciri (*Classifier Chain*, CC) problem dönüşüm yöntemleri kullanılmıştır. Temel sınıflandırıcı olarak ise Naive Bayes (NB), K-En Yakın Komşu (*K-Nearest Neighbors*, K-NN), Karar Ağacı (*Decision Tree*, DT) ve Destek Vektör Makinesi (*Support Vector Machine*, SVM) yöntemleri kullanılmıştır. LP yöntemi ile NB sınıflandırıcısının birlikte kullanımında %99,9 doğrulukta, CC yöntemi ile DT sınıflandırıcısının birlikte kullanımında %99,3 doğrulukta ve BR yöntemi ile DT sınıflandırıcısının birlikte kullanımında %97,8 doğrulukta sınıflandırma başarımına ulaşılmıştır. Problem dönüştürme yöntemi olarak LP, sınıflandırıcı olarak ise DT en yüksek başarımları vermektedir.

**Anahtar Kelimeler:** Çok etiketli sınıflandırma, Asenkron motor arızaları, Titreşim analizi, Çoklu arıza

## Multi-Label Classification of Simultaneous Faults of Induction Motors by Vibration Signals

### ABSTRACT

It is important to diagnose the fault of induction motors which are widely used in the industry. The common faults of induction motors consist of mechanical and electrical faults. Various methods are used to detect faults. Commonly used fault detection methods use stator current, supply voltage, vibration, heat, and sound data. In general, a specific method is generally used for each type of fault. Advanced diagnostic methods should be when the simultaneous multiple faults are present. In this study, broken rotor bars, inner-race bearing faults, outer-race bearing faults, short-circuit stator winding faults, and eccentricity faults are investigated individually, in simultaneous two and three groups. Three-axis vibration signals are used in the study. The feature vectors are calculated from the statistical features of vibration signals. The feature vector are used as input in the multi-label

classification method. For the multi-label classification, Binary Relevance (BR), Label Powerset (LP) and Classifier Chain (CC) problem transformation methods are used. Naïve Bayes (NB), K-Nearest Neighbors (K-NN), Decision Tree (DT) and Support Vector Machine (SVM) methods are used as base classifier. When LP method and NB classifier are used together, 99.9% accuracy was achieved. When CC method and DT classifier are used together 99.3% accuracy was achieved. When BR method and DT classifier are used together 97.8% accuracy was achieved. LP as the problem transformation method and DT as the classifier give the best accuracy rate among the other methods.

**Keywords:** Multi label classification, Induction motor faults, Vibration analysis, Multi faults

## **I. GİRİŞ**

Asenkron motorlar üretimlerinin kolay, denetiminin basit ve bakım maliyetlerinin düşük olmasından dolayı diğer elektrik motorlarına göre avantajlıdır. Bundan dolayı, elektrik motorları arasında özellikle sanayide en çok tercih edilen motor çeşididirler. Asenkron motorlarda meydana gelen arızalar üretim süreçlerinde aksamalara neden olmaktadır. Bu aksamalar neticesinde hammadde ve ürün kayıpları, iş gücü ve zaman kayıplarından dolayı ekonomik kayıplar meydana gelebilmektedir. Bundan dolayı asenkron motorların arızalarının tespiti önemlidir.

Asenkron motorlarda meydana gelen arızalar elektriksel ve mekanik arızalar olmak üzere iki kategoriye ayrılabilir. Elektriksel arızalar stator sargı arızaları ve kırık rotor arızalarını kapsamaktadır. Mekanik arızalar ise dış-bilezik rulman arızası, iç-bilezik rulman arızası ve eksenel kaçıklık arızalarını kapsamaktadır [1].

Stator sargı arızaları genel olarak bobin-bobin kısa-devre, sargı-sargı kısa-devre, açık-devre, faz-faz kısa-devre ve bobin-toprak kısa-devre şeklinde meydana gelir. Asenkron motorlarda karşılaşılan yaygın rotor arızaları kısa-devre halkasının çatlaması/kırılması ve rotor çubuklarının çatlaması/kırılması sonucu meydana gelir. Asenkron motorların en önemli parçalarından biri olan rulman, iç-bilezik, dış-bilezik ile bilye ve kafesten meydana gelir. Yaygın rulman arızaları da iç-bilezik, dış-bilezik ile bilye ve kafesin mekanik olarak zarar görmesi (kırılma, çatlama, karıncalanma...) sonucu meydana gelir.

Bunlara ilave olarak asenkron motorlarda eksenel kaçıklık, motor kapağı, motor mili arızaları vb. meydana gelebilir. Bu arızalar birbirinden bağımsız ve tekil olarak meydana geldiği gibi eş zamanlı çoklu arıza şeklinde de meydana gelebilmektedir. Arıza analizinde ağırlıklı olarak stator akımı, besleme gerilimi, titreşim, ısı ve ses gibi veriler kullanılmaktadır. Bu veriler kullanılarak asenkron motorlarda meydana gelen arızaların türü ve seviyesi tespit edilebilmektedir. Eş zamanlı çoklu arızaların meydana geldiği durumlarda geleneksel tekil arıza analizi yöntemleri yerine ileri seviye arıza analiz yöntemlerine ihtiyaç duyulmaktadır.

Son yıllarda, asenkron motor arızalarının sınıflandırılmasında çok etiketli sınıflandırılma yöntemleri de kullanılmaktadır. Dineva ve arkadaşları [2], aynı anda birden fazla arızayı teşhis etmek ve gürültülü koşullar altında arıza şiddetini değerlendirmek için İkili Karar Ağacı (*Binarized DT*), CC ve K-NN yöntemlerini kullanarak titreşim ve akım sinyalleri ile çok etiketli sınıflandırma için yeni bir yöntem önermişlerdir. Juez-Gil ve arkadaşları [3], Asenkron motorda tekil, birleşik ve eş zamanlı arıza koşullarının oluşumunu değerlendirmek için Temel Bileşen Analizi (*Principal Component Analyze*, – PCA) ve karar ağacı kullanarak titreşim, stator akımları, gerilimler ve dönme hızı verilerine dayalı yeni bir akıllı çoklu arıza teşhis yöntemi sunmuştur. Vong ve arkadaşları tarafından yapılan çalışmada [4], eş zamanlı meydana gelen arızaların zaman-frekans özelliklerinin, onu oluşturan tekil arızaların özelliklerine benzer olduğu varsayımı altında, bu sorunun çözümü için öznitelik çıkarımı, ikili olasılıklı çok etiketli sınıflandırma ve karar eşiği optimizasyonunu birleştiren bir yöntem önerilmiştir. Bu yöntem, bir test durumu olarak zamana bağlı ateşleme modellerine dayalı otomotiv motor ateşleme sisteminin arıza teşhisinde uygulanmış ve doğrulanmıştır. Asenkron motorlarda eş zamanlı olarak meydana gelen arızaların geçici durum (*transient*) akım verileri kullanılarak Kısa-Zamanlı Fourier Dönüşümü (*Short-Time Fourier Transform* - STFT) ve Sürekli Dalgacık Dönüşümü (*Continuous Wavelet Transform* –

CWT) yöntemleri ile öznelik çıkarımı yapan bir yöntem Georgoulas ve arkadaşları tarafından sunulmuştur [5]. Çalışmada elde edilen özneliklere BR, LP ve Kalibre Edilmiş Etiket Sıralaması (*Calibrated Label Ranking – CLR*) problem dönüşüm yöntemleri uygulanmıştır. Minimum Mahalanobis Uzaklık Sınıflandırıcısı (*Minimum Mahalanobis Distance Classifier – MMDC*) ve En Yakın Komşu sınıflandırıcısı (*Nearest Neighbor Classifier – NN*) temel sınıflandırıcıları ile karşılaştırmalı olarak kullanılarak çok etiketli sınıflandırma ile etiketleme yapılmış ve umut verici sonuçların elde edildiği belirtilmiştir.

Shen ve arkadaşları [6], makine hatalarının akıllı teşhisi için ilişkili özneliklerin öğrenilmesi ve eksik etiket sorununun çözülmesini amaçlayan Çok Etiketli Evrimsel Sinir Ağı (*Multi-Label Convolutional Neural Network - MLCNN*) olarak adlandırdıkları derin çok etiketli bir öğrenme yöntemi önermişlerdir. Sonuçlar, öznelikler arasındaki ilişkilerin MLCNN tarafından öğrenildiğini ve kayıp etiket problemi oluştuğunda MLCNN'nin sınıflandırma doğruluklarının geleneksel yöntemlere göre daha yüksek olduğunu göstermiştir. Han ve arkadaşları tarafından rulmanda arıza olup olmadığına, arıza konumuna, hasar moduna ve hasar derecesine göre etiketleme yapılmış bir veri seti üzerinde çok etiketli sınıflandırma yapan bir çalışma [7]'de sunulmuştur. Çalışmada, CNN ve geçitli tekrarlayan birimi (*gated recurrent unit - GRU*) entegre biçimde kullanılarak elde edilen sonuçların çok sınıflı sınıflandırmadan daha yüksek doğruluk oranına ulaştığı gösterilmiştir. Yu ve arkadaşları [8], titreşim sinyallerinden hata teşhisine duyarlı Zaman-Frekans İmza Matrisi (*Time-Frequency Signature Matrix - T-FSM*) özneliklerini elde ederek Meta-Öğrenme ile Çok Etiketli Evrimsel Sinir Ağına (*Multi-Label Convolutional Neural Network with Meta-Learning - MLCML*) dayalı yeni bir rulman arıza teşhis yöntemi geliştirerek yüksek doğrulukta başarımlar elde etmişlerdir. Li ve arkadaşları [9], çalışmalarında rulman durumunu ve farklı arıza tiplerini bir arada değerlendirmişlerdir. Rulman durumu sağlıklı, bozulma ve kritik olmak üzere üç kategoride, arızalar ise beş farklı türde etiketlenmiş ve istatistiksel öznelikler üzerinden BR yöntemiyle çok etiketli sınıflandırma yapılarak yöntemin üstünlüğü gösterilmiştir.

Literatürde yer alan çalışmalar incelendiğinde, asenkron motor arızalarının çok etiketli sınıflandırılmasına ilişkin yöntemlerde veri seti, öznelik çıkarım süreci ve sınıflandırma yöntemi açısından farklılıklar görülmektedir. Veri seti olarak ağırlıklı akım ve titreşim sinyallerinin kullanıldığı görülmektedir. Öznelik çıkarımı sürecinde de çeşitli sinyal işleme teknikleri ve dönüşüm yöntemleri kullanılmaktadır. Sınıflandırma yöntemi olarak ise makine öğrenmesi tabanlı geleneksel sınıflandırıcıların ve özellikle son dönemlerde kullanımı yaygınlaşan derin öğrenme yöntemlerinin tercih edildiği gözlemlenmektedir.

Ağırlıklı olarak çalışılan arıza türleri rulman arızaları, rotor kırıkları ve sargı arızalarıdır. Çok etiketli sınıflandırma bakımından temel problem dönüşüm yöntemleri ve sıklıkla tercih edilen temel sınıflandırıcı performanslarının rulman, rotor ve stator gibi asenkron motor arızaları üzerinden karşılaştırıldığı çalışmalarda dönüşüm yöntemi ve sınıflandırıcı çeşitlerinin sınırlı olduğu görülmektedir.

Literatürde yayınlanan çalışmalarda, asenkron motorlarda benzetim (*simulation*) yoluyla edilmiş verilerin kullanıldığı ve en fazla iki ya da üç tip arıza çeşidinin çalışıldığı görülmektedir. Asenkron motorlarda meydana gelebilecek olası tüm elektriksel ve mekanik arızaları aynı anda inceleyen çalışmalara rastlanmamıştır. Bu arızaların eş zamanlı olarak incelenmesi ve teşhis edilmesi, arıza sonucu meydana gelebilecek olası hasarların önlenmesi veya asenkron motorların tamamen devre dışı kalmasını önleme açısından önemlidir [10].

Bir elektrik motorunda titreşime sebep olan dinamik kuvvetler, bir arıza meydana geldiğinde, arızanın erken aşamasında dahi motorun titreşim modelini değiştirir. Bundan dolayı son yıllarda elektrik motorlarının izlenmesinde titreşim sinyalleri yaygın olarak kullanılmaktadır [11]. Rotor kırığı arızalarında titreşim sinyalleri güç spektrumu ile incelendiğinde, rotordaki kırık sayısı ve yük arttıkça yan bant frekanslarının genliğinin arttığı görülmektedir [12]. Rulman arızalarının titreşim sinyalleri ile tespitinde, yük seviyesi arttıkça hataya ilişkin öznelikler daha belirgin hale gelmekte ve sınıflandırma doğruluk oranı daha yüksek değerlere ulaşmaktadır [13].

Çalışmada, 3-fazlı, 380 V, 50 Hz şebekeden beslenen ve %100 yük altında çalışan bir asenkron motorda meydana gelen tekil ve eş zamanlı çoklu arızalar incelenmiştir. Veri seti olarak asenkron motordan toplanan 3-eksen titreşim verileri kullanılmıştır. Asenkron motorda meydana gelen tekil ve eş zamanlı çoklu arızaların çok etiketli sınıflandırılmasına odaklanılarak literatüre katkı sağlamak amaçlanmıştır.

Sınıflandırmada 3-eksen titreşim sinyallerinin istatistiksel öznitelikleri çıkarılmıştır. Çıkarılan özniteliklere BR, CC ve LP problem dönüşüm yöntemleri uygulanarak DT, K-NN, SVM ve NB sınıflandırıcıları ile çok etiketli sınıflandırma yapılmıştır. Problem dönüşüm yöntemleri ve temel sınıflandırıcıların birlikte kullanımında çeşitli değerlendirme ölçütleri ile genel başarımlar ve etiket bazında başarımlar oranları karşılaştırılmalı olarak analiz edilmiştir.

Çalışmanın ikinci bölümünde çok etiketli sınıflandırma yöntemi, üçüncü bölümünde veri ön işleme yöntemi verilmektedir. Dördüncü bölümde çok etiketli sınıflandırma yöntemi ile arıza analizi detaylı olarak verilmektedir. Çalışmanın sonuçları beşinci bölümde sunulmaktadır.

## **II. ÇOK ETİKETLİ SINIFLANDIRMA**

Geleneksel tek etiketli sınıflandırma (*single label classification*) birden fazla ve farklı etiketten oluşan bir kümeden ( $L$ ) tek bir etiketin ( $l$ ) öğrenilmesiyle ilgilidir. Öğrenme problemi etiket sayısı 2 ise ikili sınıflandırma (*binary classification*), 2'den fazla ise çok sınıflı sınıflandırma (*multi-class classification*) problemi olarak adlandırılır [14]. Bir etiketin iki ya da daha çok sınıftan sadece birine karşılık gelmesi tek etiketli sınıflandırma problemi, birden fazla sınıfa karşılık gelmesi ise çok etiketli sınıflandırma problemi olarak adlandırılır.

Gerçek dünya verileri, analiz edilen olgular üzerinde her zaman kesin olarak birbirinden ayrılmış sınıflar sunmamaktadır. Örneğin bir elektrik motorunun durumu, motordan elde edilen veriler kullanılarak ikili sınıflandırma ile 'çalışıyor ya da çalışmıyor' biçiminde, çoklu sınıflandırma ile 'rotor veya stator veya rulman veya mil arızası' biçiminde belirlenebilir. Çok etiketli sınıflandırma ile aynı veriler kullanılarak, çalışan bir motorun rotor, stator, rulman ve mil arızalarından hangilerini ve ne düzeyde barındırdığı tespit edilebilir.

Çok etiketli sınıflandırma için kullanılan iki temel yöntem problem dönüştürme (*problem transformation*) ve algoritma uyarlama (*algorithm adaptation*) olarak gruplanabilir. Problem dönüştürme çok etiketli problemin tek etiketli alt problemlere dönüştürülmesidir. Algoritma uyarlama ise çok etiketli verileri işlemek için öğrenme algoritmalarının genişletilmesi sürecidir [14].

Çok etiketli sınıflandırmada eğitim seti  $D$  olarak tanımlanır ve  $E_i = (x_i, Y_i)$ ,  $i = 1..N$  olmak üzere içinde  $N$  adet örnek bulunur. Her  $E_i$  örneği  $x_i = (x_{i1}, x_{i2}, \dots, x_{im})$  ile gösterilen bir öznitelik vektörü ve  $Y_i \subseteq L$  etiketlerinin bir alt kümesiyle ilişkilidir, burada  $L = \{y_j : j = 1..q\}$   $q$  olası etiketlerin kümesidir. Çok etiketli sınıflandırmada temel amaç,  $E = (x, ?)$  şeklinde etiketlenmemiş bir örnek verildiğinde  $Y$  etiketlerinin alt kümesini doğru bir şekilde tahmin edebilen  $H(E) \rightarrow Y$  şeklinde tanımlanan bir  $H$  sınıflandırıcısı oluşturmaktır. Burada  $Y$ ,  $E$  örneğiyle ilişkili etiketlerden oluşur.

### **A. PROBLEM DÖNÜŞÜM YÖNTEMLERİ**

#### **A. 1. Basit Problem Dönüşüm Yöntemleri**

Tek etiketli sınıflandırıcının çok etiketli veri kümesine uygulanabilmesi için çok etiketli veri kümesini tek etiketli veri kümesine dönüştüren ve basit dönüşüm yöntemleri olarak anılan Kopya Dönüşümü (*Copy Transformation*), Seçme Dönüşümü (*Select Transformation*) ve Yok Say Dönüşümü (*Ignore Transformation*) yöntemleri kullanılmaktadır [15], [16]. Tablo 1'de çok etiketli bir veri seti örneği verilmiştir.

**Tablo 1.** Çok etiketli bir örnek veri seti.

Örnek	Öznitelikler	Etiketler	İlişkili Etiket Seti
E <sub>1</sub>	x <sub>11</sub> , x <sub>12</sub> , ..., x <sub>1m</sub>	L <sub>1</sub> , L <sub>2</sub> , L <sub>5</sub>	Y <sub>1</sub>
E <sub>2</sub>	x <sub>21</sub> , x <sub>22</sub> , ..., x <sub>2m</sub>	L <sub>3</sub> , L <sub>5</sub>	Y <sub>2</sub>
E <sub>3</sub>	x <sub>31</sub> , x <sub>32</sub> , ..., x <sub>3m</sub>	L <sub>1</sub> , L <sub>4</sub> , L <sub>5</sub>	Y <sub>3</sub>
E <sub>4</sub>	x <sub>41</sub> , x <sub>42</sub> , ..., x <sub>4m</sub>	L <sub>2</sub>	Y <sub>4</sub>
E <sub>5</sub>	x <sub>51</sub> , x <sub>52</sub> , ..., x <sub>5m</sub>	L <sub>1</sub> , L <sub>5</sub>	Y <sub>5</sub>

Kopya dönüşümünde her çok etiketli örnek (*instance*) ilişkili etiket sayısına kopyalanır ve her kopyaya etiketlerden birisi atanır. Bu yöntemin düzeltilmiş ağırlıklı kopya (*dubbed copy-weight*) olarak adlandırılan bir türünde ise kopyalanarak üretilen her bir örnek için 0 ile 1 arasında bir ağırlık değeri belirlenir. Kopya dönüşümü yönteminde örneklerin sayısı artar ancak bilgi kaybı yoktur. Seçme dönüşümünde her çok etiketli örnek için ilişkili etiketlerden yalnızca biri seçilir. Seçim yöntemi olarak en yüksek sıklık (*select-max*), en düşük sıklık (*select-min*) ve rastgele (*select-random*) yaklaşımları kullanılır. Seçme dönüşümü yönteminde örneklerin sayısı aynı kalır ancak bilgi kaybı vardır. Yok say dönüşümünde çok etiketli örnekler yok sayılarak yalnızca tek etiketli örnekler alınır. Yok say dönüşümü yönteminde örneklerin sayısı azalır ancak yüksek bilgi kaybı vardır. Tablo 2’de basit dönüşüm yöntemlerinin Tablo 1’de verilen örnek veri setine uygulanmasından elde edilen sonuçlar gösterilmiştir.

**Tablo 2.** Basit dönüşüm yöntemlerinin örnek veri setine uygulanması: (a) Kopya dönüşümü, (b) Ağırlıklı kopya dönüşümü, (c) Seçme dönüşümü (en yüksek sıklık), (d) Seçme dönüşümü (en düşük sıklık), (e) Seçme dönüşümü (rastgele), (f) Yok say dönüşümü.

Örnek Etiket	Örnek Etiket Ağırlık	Örnek Etiket	Örnek Etiket	Örnek Etiket	Örnek Etiket
1a L <sub>1</sub>	1a L <sub>1</sub> 0,33	1 L <sub>5</sub>	1 L <sub>2</sub>	1 L <sub>1</sub>	1 L <sub>2</sub>
1b L <sub>2</sub>	1b L <sub>2</sub> 0,50	2 L <sub>5</sub>	2 L <sub>3</sub>	2 L <sub>5</sub>	
1c L <sub>5</sub>	1c L <sub>5</sub> 0,25	3 L <sub>5</sub>	3 L <sub>4</sub>	3 L <sub>1</sub>	
2a L <sub>3</sub>	2a L <sub>3</sub> 1,00	4 L <sub>2</sub>	4 L <sub>2</sub>	4 L <sub>2</sub>	
2b L <sub>5</sub>	2b L <sub>5</sub> 0,25	5 L <sub>5</sub>	5 L <sub>1</sub>	5 L <sub>5</sub>	
3a L <sub>1</sub>	3a L <sub>1</sub> 0,33				
3b L <sub>4</sub>	3b L <sub>4</sub> 1,00				
3c L <sub>5</sub>	3c L <sub>5</sub> 0,25				
4 L <sub>2</sub>	4 L <sub>2</sub> 0,50				
5a L <sub>1</sub>	5a L <sub>1</sub> 0,33				
5b L <sub>5</sub>	5b L <sub>5</sub> 0,25				
(a)	(b)	(c)	(d)	(e)	(f)

## A. 2. İkili Alâka Düzeyi (*Binary Relevance - BR*)

İkili Alâka Düzeyi, etiket kümesindeki her farklı etiket için bir tane olmak üzere ikili sınıflandırıcıları öğrenen bir problem dönüştürme yöntemidir. Bu yöntemde orijinal veri seti farklı etiket sayısı kadar alt veri setlerine dönüştürülür. Tüm örnekler için her alt veri setinde ilgili etiketi içeriyorsa pozitif (+) içermiyorsa negatif (-) şeklinde bir atama yapılır [17].

**Tablo 3.** İkili Alâka Düzeyi dönüşümünün örnek veri setine uygulanması.

Örnek	Y	Örnek	Y	Örnek	Y	Örnek	Y	Örnek	Y
E <sub>1</sub>	y <sub>1</sub>	E <sub>1</sub>	y <sub>2</sub>	E <sub>1</sub>	¬y <sub>3</sub>	E <sub>1</sub>	¬y <sub>4</sub>	E <sub>1</sub>	y <sub>5</sub>
E <sub>2</sub>	¬y <sub>1</sub>	E <sub>2</sub>	¬y <sub>2</sub>	E <sub>2</sub>	y <sub>3</sub>	E <sub>2</sub>	¬y <sub>4</sub>	E <sub>2</sub>	y <sub>5</sub>
E <sub>3</sub>	y <sub>1</sub>	E <sub>3</sub>	¬y <sub>2</sub>	E <sub>3</sub>	¬y <sub>3</sub>	E <sub>3</sub>	y <sub>4</sub>	E <sub>3</sub>	y <sub>5</sub>
E <sub>4</sub>	¬y <sub>1</sub>	E <sub>4</sub>	y <sub>2</sub>	E <sub>4</sub>	¬y <sub>3</sub>	E <sub>4</sub>	¬y <sub>4</sub>	E <sub>4</sub>	¬y <sub>5</sub>
E <sub>5</sub>	y <sub>1</sub>	E <sub>5</sub>	¬y <sub>2</sub>	E <sub>5</sub>	¬y <sub>3</sub>	E <sub>5</sub>	¬y <sub>4</sub>	E <sub>5</sub>	y <sub>5</sub>

Tablo 1’de verilen örnek veri setine BR dönüşümünün uygulanması ile oluşan yeni veri setinin örnek bir görünümü Tablo 3’te verilmiştir. Bu dönüşüm ile orijinal veri setinde yer alan özniteliklerde bir

değişim meydana gelmemektedir. Dönüşüm etiketler üzerinden gerçekleşmektedir. Dönüşüm sonucunda elde edilen yeni gösterimde her farklı etiket için ilgili örneğin etiketi içerip içermediğini gösteren alt veri setleri oluşmaktadır [18].

### A. 3. Etiket Güç Seti (*Label Powerset - LP*)

Etiket Güç Seti, çok etiketli bir eğitim kümesinde bulunan her benzersiz etiket kümesini yeni bir tek etiketli sınıflandırma işlemi olarak değerlendirmeye alır. Bu yaklaşım basit ama etkili bir problem dönüştürme yöntemidir [17]. LP dönüşümünün tek etiketli sınıflandırıcısı yeni bir örnek verildiğinde aslında bir etiket kümesi olan en olası sınıfı sonuç olarak verir [19].

**Tablo 4.** Etiket Güç Seti dönüşümünün örnek veri setine uygulanması.

Örnek	Y	Örnek	Y
E <sub>1</sub>	Y <sub>1</sub> ={y <sub>1</sub> ,y <sub>2</sub> ,y <sub>5</sub> }	E <sub>1</sub>	y <sub>1,2,5</sub>
E <sub>2</sub>	Y <sub>2</sub> ={y <sub>3</sub> , y <sub>5</sub> }	E <sub>2</sub>	y <sub>3,5</sub>
E <sub>3</sub>	Y <sub>3</sub> ={y <sub>1</sub> ,y <sub>4</sub> ,y <sub>5</sub> }	E <sub>3</sub>	y <sub>1,4,5</sub>
E <sub>4</sub>	Y <sub>4</sub> ={y <sub>2</sub> }	E <sub>4</sub>	y <sub>2</sub>
E <sub>5</sub>	Y <sub>5</sub> ={y <sub>1</sub> ,y <sub>5</sub> }	E <sub>5</sub>	y <sub>1,5</sub>

Tablo 1’de verilen örnek veri setine LP dönüşümünün uygulanması ile oluşan yeni veri setinin örnek bir görünümü Tablo 4’te verilmiştir. Bu dönüşüm ile orijinal veri setinde yer alan özniteliklerde bir değişim meydana gelmemektedir. Dönüşüm etiketler üzerinden gerçekleşmektedir. Dönüşüm sonucunda elde edilen yeni gösterimde etiketi temsil eden  $y_{i,j,\dots,k}$  gösterimi dönüştürülen örneğin sırasıyla  $y_i \wedge y_j, \dots, y_k$  etiketlerinin birleşiminden oluştuğunu ifade etmektedir [17].

### A. 4. Sınıflandırıcı Zincir (*Classifier Chain - CC*)

Sınıflandırıcı Zincir modeli, BR dönüşümünde olduğu gibi her etiket için bir tane olmak üzere ikili dönüşümler içerir. Model BR dönüşümünden farklı olarak her ikili model için öznitelik alanını önceki tüm sınıflandırıcıların 0/1 etiket alâkalarıyla genişletir ve böylece bir sınıflandırıcı zinciri oluşturur [20]. Sınıflandırıcı Zincir dönüşümünün Tablo 1’de verilen örnek veri setine uygulanmasıyla elde edilen sonuçlar Tablo 5’te verilmiştir.

**Tablo 5.** Sınıflandırıcı Zincir dönüşümünün örnek veri setine uygulaması.

Örnek	Y <sub>1</sub>	Örnek	Y <sub>1</sub>	Y <sub>2</sub>	Örnek	Y <sub>1</sub>	Y <sub>2</sub>	Y <sub>3</sub>	Y <sub>4</sub>	Örnek	Y <sub>1</sub>	Y <sub>2</sub>	Y <sub>3</sub>	Y <sub>4</sub>	Y <sub>5</sub>
E <sub>1</sub>	1	E <sub>1</sub>	1	1	E <sub>1</sub>	1	1	0		E <sub>1</sub>	1	1	0	0	1
E <sub>2</sub>	0	E <sub>2</sub>	0	0	E <sub>2</sub>	0	0	1		E <sub>2</sub>	0	0	1	0	1
E <sub>3</sub>	1	E <sub>3</sub>	1	0	E <sub>3</sub>	1	0	0		E <sub>3</sub>	1	0	0	1	1
E <sub>4</sub>	0	E <sub>4</sub>	0	1	E <sub>4</sub>	0	1	0		E <sub>4</sub>	0	1	0	0	0
E <sub>5</sub>	1	E <sub>5</sub>	1	1	E <sub>5</sub>	1	1	0		E <sub>5</sub>	1	1	0	0	1

## B. ALGORİTMA UYARLAMA YÖNTEMLERİ

Bu yaklaşımda, tek etiketli sınıflandırıcıların çok etiketli problemlerde kullanımlarını mümkün kılmak amacıyla içyapıları uyarlanarak tek etiketli sınıflandırıcıların uzantıları geliştirilmiştir [21]. Çok etiketli sınıflandırma problemleri için geliştirilen belirli bir algoritmanın, algoritmadan bağımsız yaklaşıma dayalı yöntemlerden daha iyi bir performansa sahip olabileceği iddia edilmektedir [22]. Literatürde DT, lojistik regresyon (*logistic regression*), K-NN, olasılıksal (*probabilistic*) yöntemler, sinir ağları (*neural networks*), SVM, rastgele orman (*random forest*), tembel (*lazy*), ilişkisel (*associative*) yöntemler ve artırma (*boosting*) gibi farklı algoritmalara dayalı çeşitli algoritma uyarlama yöntemleri önerilmiştir [23], [24].

## C. TEMEL SINIFLANDIRICILAR

Problem Dönüştürme yöntemleri ile ikili ya da çok sınıflı sınıflandırma problemine uygun hale getirilen çok etiketli veri setine geleneksel sınıflandırıcılar uygulanmaktadır. Bu çalışmada kullanılan 4 farklı sınıflandırıcı yöntemi aşağıda açıklanmaktadır.

### C. 1. Naive Bayes

Naive Bayes sınıflandırıcısı, özniteliklerin verilen sınıftan bağımsız olduğunu varsayarak öğrenme sürecini büyük ölçüde basitleştirir. Bağımsızlık genellikle zayıf bir varsayım olsa da uygulamada çoğu zaman daha gelişmiş sınıflandırıcılarla iyi rekabet eder [25]. Bayes teoremi, eğitim veri setindeki örneklerden faydalanarak daha önce görmediği bir örneğin sınıfını en iyi şekilde tahmin etmeyle ilgilidir. Seçilen sınıf  $P(C_i | E) = (P(C_i)P(E | C_i))/P(E)$  değerini en büyük yapan olmalıdır. Burada  $C_i$   $i$ 'nci sınıf,  $E$  test edilen örnek,  $P(Y | X)$  verilen  $X$  için  $Y$ 'nin koşullu olasılığıdır ve olasılıklar eğitim örneğinden tahmin edilir. Bir örnek  $a$  adet öznitelikten oluşan bir vektör olsun. Eğer öznitelikler verilen sınıftan bağımsız ise  $P(E | C_i)$  ifadesi  $P(v_1 | C_i) \dots P(v_a | C_i)$  şeklinde ayrıştırılabilir. Burada  $v_j$ ,  $E$  örneğinin  $j$ 'inci özneliğinin değeridir [26].

### C. 2. Karar Ağacı (J48)

J48 isimlendirmesi C4.5 karar ağacı algoritmasının WEKA (*Waikato Environment for Knowledge Analysis*) [27] uygulaması içindeki kullanımı olup J harfi Java programlama dilini temsil etmektedir. Çok sayıda karar ağacı algoritması içerisinde bilinirliği en fazla olan C4.5 algoritmasıdır. C4.5 algoritması ID3 algoritmasının geliştirilmesiyle ortaya çıkmıştır. C4.5 algoritması karar ağacını oluştururken “böl ve yönet” (*divide and conquer*) stratejisini kullanır. Ağaçtaki her düğüm bir dizi durumla ilişkilidir. Ayrıca, bilinmeyen öznitelik değerlerini hesaba katmak için örneklere ağırlıklar atanır. Başlangıçta, yalnızca kök mevcut olup tüm eğitim veri seti ile ilişkilidir ve tüm durum ağırlıkları 1'e eşittir [28].

### C. 3. K-En Yakın Komşu

K-En Yakın Komşu, gözetimli öğrenme ile sade ve etkin biçimde öğrenme ve sınıflandırma yapabilen bir algoritmaya sahiptir. Aynı zamanda parametrik değildir ve temel veri kümesi üzerinde herhangi bir varsayımda bulunmadan çalışır. Etiketlenmemiş verilerin sınıfının tahmin edilebilmesi için veri noktalarının çeşitli sınıflara ayrıldığı etiketli bir eğitim veri kümesi sağlanır. Belirli bir bölgedeki en yakın veya komşu eğitim örneklerine dayalı olarak verileri sınıflandırmak için kullanılır [29]. En Yakın Komşu sınıflandırmasının altında yatan sezgi oldukça basittir: Örnekler en yakın komşularının sınıfına göre sınıflandırılır. Bu yaklaşımda birden fazla komşuyu dikkate almak genellikle yararlıdır. Bu nedenle sınıfın belirlenmesinde yaygın olarak  $k$  adet en yakın komşunun kullanıldığı K-NN sınıflandırması olarak adlandırılır. Sınıflandırma, doğrudan eğitim örneklerine dayandığından, Örnek Tabanlı Sınıflandırma veya Vaka Tabanlı Sınıflandırma olarak da adlandırılır [30].

### C. 4. Destek Vektör Makinesi

Destek Vektör Makinesi bir taraftan verilere aşırı uyumdan kaçınırken diğer taraftan tahmin doğruluğunu en üst düzeye çıkarmak için makine öğrenimi teorisini kullanan gözetimli bir sınıflandırma ve regresyon tahmini aracıdır [31]. Vektör uzayında bir dizi  $p$ -boyutlu vektör verildiğinde vektör uzayını vektörlerin alt kümesine bölen ayırıcı hiperdüzlemi bulur. Ayrılmış her alt küme bir sınıfa atanır. Bu ayırıcı hiper düzlem için iki alt küme arasındaki marjı en büyükleme koşulu aranır [32].

## D. DEĞERLENDİRME ÖLÇÜTLERİ (EVALUATION METRICS)

Değerlendirme ölçütleri üç farklı kategoride incelenebilir. Örnek tabanlı (*example-based*) değerlendirmede önce etiketlerdeki her bir örnek için hesaplama yapıp ardından tüm örneklerdeki

ortalama alınır. Etiket tabanlı (*label-based*) değerlendirmede önce örneklerdeki her bir etiket için hesaplama yapıp ardından tüm etiketlerdeki ortalama alınır. Sıralama tabanlı (*ranking-based*) değerlendirmede her etiketin tahminine güven duymaya dayalı olarak etiketler sıralanır [33].

Örnek tabanlı ölçütlerden Hamming Puanı (*Hamming Score*), Hamming kaybına (*Hamming Loss*) dayanılarak  $1 - \text{Hamming Kaybı}$  şeklinde hesaplanır. Hamming kaybı, yanlış sınıflandırılmış örnek-etiket çiftlerinin oranıdır [34]. Doğruluk (*Accuracy*), tahmin edilen ve gerçek etiket setlerinin benzerliğini ve farklılığını karşılaştırır [35]. Alt Küme Doğruluğu (*Subset Accuracy*), ya da tam eşleşme (*exact match*) tüm etiketleri doğru olarak sınıflandırılmış örneklerin yüzdesini gösterir [36]. Etiket tabanlı ölçütler makro-ortalama ve mikro-ortalama olmak üzere 2 kategoriye ayrılır. Bu ölçütler çok etiketli sınıflandırmada kesinlik (*precision*), duyarlılık (*recall*) ve F1 ölçüsü (*F1 measure*) için makro-ortalama ve mikro-ortalama türünde kullanılmaktadır [37].

Sıralama tabanlı ölçütlerden Tek Hata (*OneError*), sıralamada en üstte olan etiketin örneğe uygun etiket kümesinde kaç kez bulunmadığını, Sıralama Kaybı (*Ranking Loss*) ise her örnek için ters sıralı etiket çiftlerinin ortalama oranını verir [34]. Ortalama Kesinlik (*Average Precision*), belirli bir  $y_i \in Y$  etiketinin üzerinde sıralanan ve gerçekte  $Y$ 'de bulunan etiketlerin ortalama oranını verir [34]. Ayrıca sınıflandırma performansından bağımsız olarak veri setine ilişkin değerlendirme ölçütleri de kullanılmaktadır. Etiket Önem Düzeyi (*Label Cardinality*), veri seti içerisindeki örneklerin etiketlerinin sayısının ortalamasıdır. Etiket Yoğunluğu (*Label Density*), veri setinin etiket önem düzeyinin veri setinin etiket sayısına oranıdır [14]. Çok etiketli sınıflandırmada sıklıkla kullanılan değerlendirme ölçütleri Tablo 6'da verilmiştir.

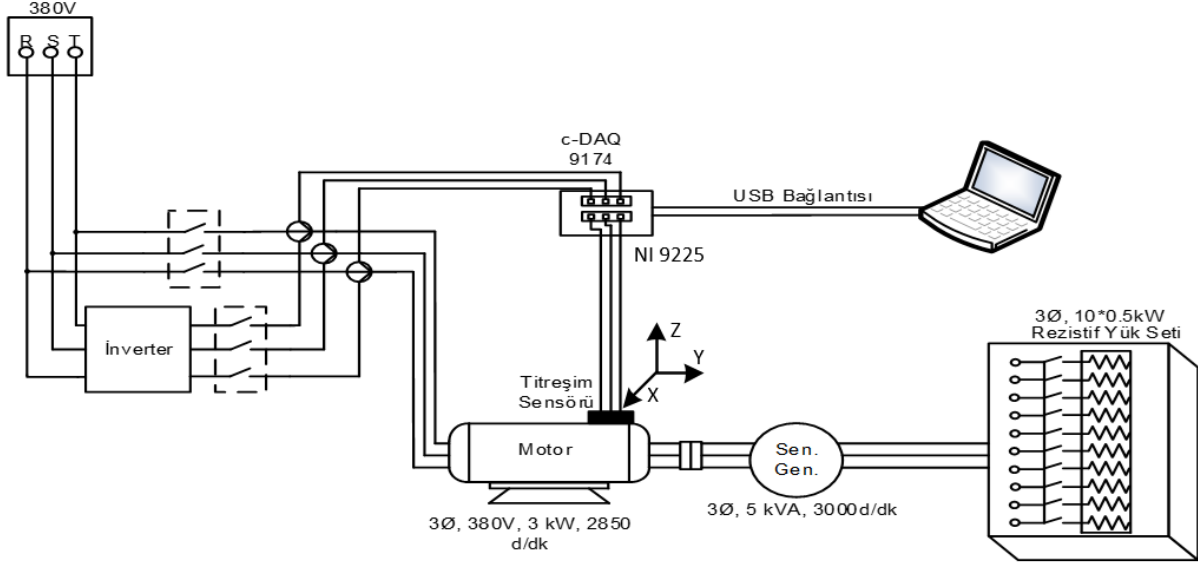
**Tablo 6.** Çok etiketli sınıflandırma için değerlendirme ölçütleri.

Değerlendirme Ölçütü	Denklem	En İyi Değer	
Örnek Tabanlı	Hamming Puanı	$1 - \left( \frac{1}{p} \sum_{i=1}^p \frac{1}{q}  h(x_i) \Delta Y_i  \right)$	1
	Doğruluk	$\frac{1}{p} \sum_{i=1}^p \frac{ h(x_i) \cap Y_i }{ h(x_i) \cup Y_i }$	1
	Alt Küme Doğruluğu	$\sum_{i=1}^p \mathbb{I}[h(x_i) = Y_i]$	1
Etiket Tabanlı	$B_{\text{Makro-Ortalama}}$ (B Kesinlik, Duyarlılık, F1 ölçüsü yerine kullanılır)	$\frac{1}{q} \sum_{j=1}^q B(TP_j, FP_j, FN_j)$	1
	$B_{\text{Mikro-Ortalama}}$ (B Kesinlik, Duyarlılık, F1 ölçüsü yerine kullanılır)	$B \left( \sum_{j=1}^q TP_j, \sum_{j=1}^q FP_j, \sum_{j=1}^q FN_j \right)$	1
Sıralama Tabanlı	Tek Hata	$\frac{1}{p} \sum_{i=1}^p \mathbb{I} \left[ \left[ \arg \max_{y \in Y} f(x_i, y) \right] \notin Y_i \right]$	0
	Sıralama Kaybı	$\frac{1}{p} \sum_{i=1}^p \frac{1}{ Y_i   \bar{Y}_i }  \{(y', y'') : f(x_i, y') \leq f(x_i, y''), (y', y'') \in Y_i \times \bar{Y}_i\} $	0
	Ortalama Kesinlik	$\frac{1}{p} \sum_{i=1}^p \frac{1}{ Y_i } \sum_{y \in Y_i} \frac{ \{y' : \text{rank}_f(x_i, y') \leq \text{rank}_f(x_i, y), y' \in Y_i\} }{\text{rank}_f(x_i, y)}$	1
Veri Seti	Etiket Önem Düzeyi	$\frac{1}{p} \sum_{i=1}^p  Y_i $	Yok
	Etiket Yoğunluğu	$\frac{1}{pq} \sum_{i=1}^q  Y_i $	Yok




### III. VERİ ÖN İŞLEME

Bu çalışmada “116E302” numaralı “Asenkron Motorlar Arızalarının Tespiti ve Entropi Analizi ile Arıza Şiddetinin Belirlenmesi” başlıklı TÜBİTAK projesi kapsamında elde edilen titreşim verileri kullanılmıştır [38]. Titreşim verileri, PCB356A31 ivme sensörü ve NI cDAQ-9174 CompactDAQ sistemi (NI 9225 modülü ile birlikte) kullanılarak 25 kHz’lik bir örnekleme frekansı ile kaydedilmiştir. Veriler, 380V, 50 Hz, 3-fazlı, 3 kW, 2 kutuplu bir asenkron motor şebekeden beslenerek ve %100 oranında yüklenerek kaydedilmiştir. Veri toplama deney düzeneği Şekil 1’de gösterilmiştir.




Şekil 1. Veri toplama deney düzeneği [38].


Şekil 2 - Şekil 6’da asenkron motorun farklı durumlarında elde edilen 3-eksen titreşim sinyallerinden örnekler soldan sağa x, y ve z eksenı sırasıyla verilmektedir. Şekil 2’de asenkron motorun sağlam durumu, Şekil 3’te 3-Kırıklı rotor durumu, Şekil 4’te Dış-Bilezik rulman arızası durumu, Şekil 5’te Eksenel Kaçıklık durumu ve Şekil 6’da 3-Kırıklı rotor + Dış-Bilezik rulman arızası + Eksenel kaçıklık (3’lü eş zamanlı arıza) durumu için 3-eksen titreşim sinyalleri gösterilmiştir.




Şekil 2. Sağlam motor durumu için 3-eksen titreşim sinyalleri.




Şekil 3. Üç-Kırıklı rotor durumu için 3-eksen titreşim sinyalleri.



Şekil 4. Dış-Bilezik rulman arızası durumu için 3-eksen titreşim sinyalleri.

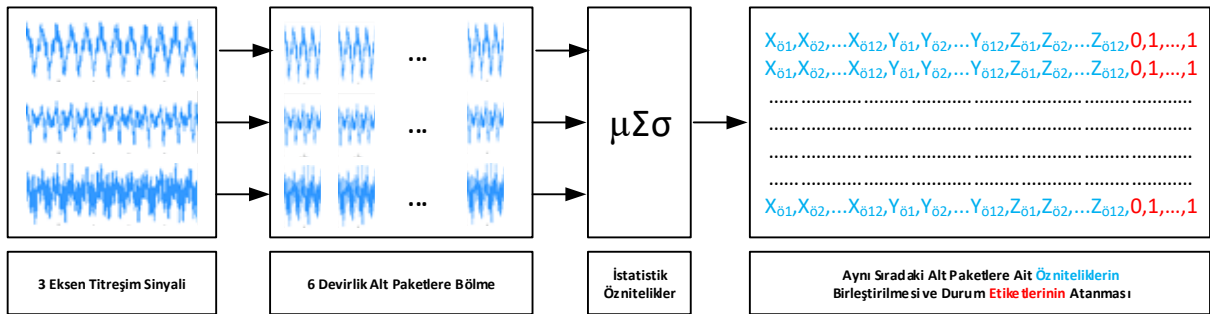


Şekil 5. Eksenel kaçıklık durumu için 3-eksen titreşim sinyalleri.



Şekil 6. Üç-Kırıklı rotor + Dış-Bilezik rulman arızası + Eksenel kaçıklık (3'lü eş zamanlı arıza) durumu için 3-eksen titreşim sinyalleri.

Her bir tekil ve eş zamanlı çoklu arıza ile sağlam motor durumu için toplamda 21 adet 3-eksen titreşim sinyali ham veri olarak bulunmaktadır. Verilerin elde edildiği test motoru %100 yük altında ve 2850 dev/dak ile çalıştırılmıştır. Öznitelik çıkarımında veriler eşit uzunlukta küçük parçalara ayrılarak kullanılmıştır. Bu doğrultuda her bir titreşim eksenini için veriler 6 devirlik alt veri paketlerine bölünmüştür. Her alt veri paketinden her bir eksen için 12 adet olmak üzere toplam 36 adet istatistiksel öznitelik elde edilmiştir. Veri ön işleme sürecinin bir parçası olan öznitelik çıkarım süreci Şekil 7'de görsel olarak verilmiştir.



Şekil 7. Veri ön işleme süreci.

Çalışmada, aritmetik ortalama (*mean*), ortanca (*median*), tepe noktası (*mod*), toplam (*sum*), RMS, standart sapma (*standard deviation*), varyans (*variance*), çarpıklık (*skewness*), basıklık (*kurtosis*), en büyük (*maximum*), en küçük (*minimum*) ve değer aralığı (*range*) öznitelikleri kullanılmıştır. Bu özniteliklerin denklemleri/yöntemleri Tablo 7'de verilmiştir.

**Tablo 7.** İstatistiksel değerlerin elde edilmesinde kullanılan denklemler/yöntemler.

İstatistiksel Değer	Denklemler/Yöntem
Aritmetik Ortalama	$\mu = \frac{1}{n} \sum_{i=0}^{n-1} x_i$
Ortanca	n tek ise $\rightarrow \text{median}(x) = x_{(n+1)/2}$ n çift ise $\rightarrow \text{median}(x) = \frac{x_{(n/2)} + x_{(n/2)+1}}{2}$
Tepe Noktası	Bir sayısal veri serisi içinde en çok tekrar eden sayıdır.
Toplam	$\text{sum} = \sum_{i=1}^n x_i$
RMS	$\text{RMS} = \sqrt{\frac{1}{n}(x_1^2 + x_2^2 + \dots + x_n^2)}$
Standart Sapma	$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n}}$
Varyans	$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \mu)^2}{n}$
Çarpıklık	$\text{skewness} = E \left[ \left( \frac{X - \mu}{\sigma} \right)^3 \right]$
Basıklık	$\text{kurtosis} = E \left[ \left( \frac{X - \mu}{\sigma} \right)^4 \right]$
En Büyük	Bir sayısal veri serisi içinde en büyük sayıdır.
En Küçük	Bir sayısal veri serisi içinde en küçük sayıdır.
Değer Aralığı	Range = En Büyük – En Küçük

Çok etiketli sınıflandırma yapılabilmesi için ihtiyaç duyulan etiket kümesi veri setinde yer alan farklı arıza tipleri ve sağlam motor durumunu da içerecek şekilde oluşturularak Tablo 8’de verilmiştir. Farklı arıza tipleri 8 adet olmak üzere sağlam motor durumu ile birlikte toplam 9 adet etiket bulunmaktadır. Her bir etiket için etiketin işaret ettiği durumun/sınıfın var olup olmadığını ikili olarak 0 veya 1 ile temsil eden bir etiket vektörü oluşturulur. Etiket vektörünün eleman sayısı etiket sayısına eşittir.

**Tablo 8.** Etiket kümesi ve etiket vektörleri.

Etiket	Etiket Açıklaması	Etiket Vektörü
L1	1-Kırıklı Rotor	1,0,0,0,0,0,0,0,0
L2	2-Kırıklı Rotor	0,1,0,0,0,0,0,0,0
L3	3-Kırıklı Rotor	0,0,1,0,0,0,0,0,0
L4	Dış-Bilezik Rulman Arızası	0,0,0,1,0,0,0,0,0
L5	İç-Bilezik Rulman Arızası	0,0,0,0,1,0,0,0,0
L6	Eksenel Kaçıklık	0,0,0,0,0,1,0,0,0
L7	%3 Sargı Kısa-Devre	0,0,0,0,0,0,1,0,0
L8	%5 Sargı Kısa-Devre	0,0,0,0,0,0,0,1,0
L9	Sağlam Motor	0,0,0,0,0,0,0,0,1

Çok etiketli sınıflandırma yapılması ihtiyacını ortaya çıkaran birden fazla arızanın eş zamanlı var olması olasılığıdır. Tablo 9’da tekil ve eş zamanlı çoklu arıza durumları ve atanan etiket vektörleri gösterilmektedir. İlgili sınıfta arıza tipi var ise 1 atanır aksi halde 0 atanmıştır. Çok etiketli veri setinin etiket önem düzeyi 1,859 olarak hesaplanmıştır. Etiket yoğunluğu ise 0,207 olarak hesaplanmıştır.

**Tablo 9.** Tekil ve eş zamanlı çoklu arıza durumları ve etiket vektörleri.

Tekil ve Eş Zamanlı Çoklu Arıza Durumları	Etiket Vektörü								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
1-Kırıklı Rotor	1	0	0	0	0	0	0	0	0
2-Kırıklı Rotor	0	1	0	0	0	0	0	0	0
3-Kırıklı Rotor	0	0	1	0	0	0	0	0	0
Dış-Bilezik Rulman Arızası	0	0	0	1	0	0	0	0	0
İç-Bilezik Rulman Arızası	0	0	0	0	1	0	0	0	0
Eksenel Kaçıklık	0	0	0	0	0	1	0	0	0
%3 Sargı Kısa-Devre	0	0	0	0	0	0	1	0	0
%5 Sargı Kısa-Devre	0	0	0	0	0	0	0	1	0
Eksenel Kaçıklık + 3-Kırıklı Rotor + Dış-Bilezik Rulman Arızası	0	0	1	1	0	1	0	0	0
Eksenel Kaçıklık + 3-Kırıklı Rotor + İç-Bilezik Rulman Arızası	0	0	1	0	1	1	0	0	0
%3 Sargı Kısa-Devre + Dış-Bilezik Rulman Arızası	0	0	0	1	0	0	1	0	0
%3 Sargı Kısa-Devre + İç-Bilezik Rulman Arızası	0	0	0	0	1	0	1	0	0
%3 Sargı Kısa-Devre + 3-Kırıklı Rotor Arızası	0	0	1	0	0	0	1	0	0
%3 Sargı Kısa-Devre + 3-Kırıklı Rotor + Dış-Bilezik Rulman Arızası	0	0	1	1	0	0	1	0	0
%3 Sargı Kısa-Devre + 3-Kırıklı Rotor + İç-Bilezik Rulman Arızası	0	0	1	0	1	0	1	0	0
%5 Sargı Kısa-Devre + Dış-Bilezik Rulman Arızası	0	0	0	1	0	0	0	1	0
%5 Sargı Kısa-Devre + İç-Bilezik Rulman Arızası	0	0	0	0	1	0	0	1	0
%5 Sargı Kısa-Devre + 3-Kırıklı Rotor Arızası	0	0	1	0	0	0	0	1	0
%5 Sargı Kısa-Devre + 3-Kırıklı Rotor + Dış-Bilezik Rulman Arızası	0	0	1	1	0	0	0	1	0
%5 Sargı Kısa-Devre + 3-Kırıklı Rotor + İç-Bilezik Rulman Arızası	0	0	1	0	1	0	0	1	0
Sağlam Motor	0	0	0	0	0	0	0	0	1

## IV. ARIZA ANALİZİ

Çok etiketli sınıflandırma işlemi MEKA (*A Multi-label/Multi-target Extension to WEKA*) yazılımı ile gerçekleştirilmiştir. MEKA yazılımı çok etiketli sınıflandırma problemlerinin üzerinde çalışılabilmesi amacıyla WEKA üzerinde geliştirilmiştir. WEKA geleneksel tek etiketli sınıflandırıcıları içeren bir yapıya sahiptir. MEKA çok sayıda çok etiketli sınıflandırıcıyı, değerlendirme ölçütlerini ve ilgili araçları içeren çok etiketli sınıflandırıcı deneyimini ve gelişimini sağlayan bir ortam sunmaktadır [39].

**Tablo 10.** Sınıflandırma veri setinin eğitim (2/3) ve test (1/3) olarak ayrılması ile elde edilen sonuçlar.

Değerlendirme Ölçütü	BR				LP				CC				
	NB	DT	K-NN	SVM	NB	DT	K-NN	SVM	NB	DT	K-NN	SVM	
Örnek Tabanlı	Doğruluk	0,5528	<b>0,9780</b>	0,9695	0,7863	<b>0,9998</b>	0,9971	0,9711	0,9714	0,5478	<b>0,9939</b>	0,9711	0,8114
	Hamming Puanı	0,8745	<b>0,9934</b>	0,9916	0,9533	<b>0,9999</b>	0,9990	0,9920	0,9926	0,8795	<b>0,9983</b>	0,9920	0,9466
	Alt Küme Doğruluğu	0,3056	0,9440	<b>0,9550</b>	0,6456	<b>0,9998</b>	0,9965	0,9648	0,9667	0,3228	<b>0,9894</b>	0,9646	0,7203
Etiket Tabanlı	Makro Kesinlik	0,7896	<b>0,9825</b>	0,9827	0,9339	<b>0,9999</b>	0,9976	0,9863	0,9874	0,8052	<b>0,9974</b>	0,9863	0,8742
	Makro Duyarlılık	0,8027	<b>0,9952</b>	0,9891	0,9272	<b>0,9999</b>	0,9981	0,9861	0,9871	0,7719	<b>0,9951</b>	0,9860	0,9274
	Makro F1	0,7800	<b>0,9882</b>	0,9858	0,9300	<b>0,9999</b>	0,9979	0,9862	0,9871	0,7732	<b>0,9963</b>	0,9861	0,8897
	Mikro Kesinlik	0,6925	0,9737	<b>0,9747</b>	0,8942	<b>0,9999</b>	0,9977	0,9804	0,9820	0,7280	<b>0,9970</b>	0,9803	0,8650
	Mikro Duyarlılık	0,6984	<b>0,9949</b>	0,9848	0,8762	<b>0,9998</b>	0,9976	0,9807	0,9820	0,6595	<b>0,9949</b>	0,9806	0,8765
	Mikro F1	0,6954	<b>0,9841</b>	0,9797	0,8851	<b>0,9999</b>	0,9976	0,9805	0,9820	0,6920	<b>0,9959</b>	0,9804	0,8707
Sıralama Tabanlı	Tek Hata	0,2333	<b>0,0027</b>	0,0168	0,1966	<b>0,0001</b>	0,0022	0,0194	0,0194	0,3445	<b>0,0036</b>	0,0194	0,1844
	Sıralama Kaybı	0,0888	<b>0,0022</b>	0,0035	0,0789	<b>0,0001</b>	0,0018	0,0212	0,0207	0,2029	<b>0,0031</b>	0,0213	0,0865
	Ortalama Kesinlik	0,8153	<b>0,9965</b>	0,9885	0,8098	<b>0,9999</b>	0,9975	0,9737	0,9739	0,6105	<b>0,9947</b>	0,9736	0,8336

Çalışmada BR, LP ve CC olmak üzere üç temel problem dönüşüm yöntemi kullanılmıştır. Her bir dönüşüm yöntemi ile NB, DT, K-NN ve SVM olmak üzere 4 farklı sınıflandırıcı çalışılmıştır. Problem dönüşüm yöntemleri ve sınıflandırıcıların birlikte kullanımlarında elde edilen sonuçlar Tablo 10 ve Tablo 11’de verilmiştir.

**Tablo 11.** Sınıflandırma veri setinden 10 kat çapraz doğrulama ile elde edilen sonuçlar.

Değerlendirme Ölçütü	BR				LP				CC				
	NB	DT	K-NN	SVM	NB	DT	K-NN	SVM	NB	DT	K-NN	SVM	
Örnek Tabanlı	Doğruluk	0,5602	<b>0,9821</b>	0,9667	0,8025	<b>0,9998</b>	0,9975	0,9737	0,9804	0,5517	<b>0,9953</b>	0,9737	0,8169
	Hamming Puanı	0,8767	<b>0,9945</b>	0,9922	0,9567	<b>0,9999</b>	0,9992	0,9927	0,9946	0,8805	<b>0,9988</b>	0,9927	0,9478
	Alt Küme Doğruluğu	0,3145	0,9525	<b>0,9538</b>	0,6721	<b>0,9998</b>	0,9971	0,9683	0,9758	0,3242	<b>0,9917</b>	0,9680	0,7344
Etiket Tabanlı	Makro Kesinlik	0,7964	<b>0,9871</b>	0,9865	0,9375	<b>0,9999</b>	0,9983	0,9875	0,9908	0,8064	<b>0,9980</b>	0,9875	0,8776
	Makro Duyarlılık	0,8050	<b>0,9942</b>	0,9870	0,9351	<b>0,9999</b>	0,9978	0,9873	0,9905	0,7759	<b>0,9959</b>	0,9873	0,9288
	Makro F1	0,7855	<b>0,9903</b>	0,9866	0,9357	<b>0,9999</b>	0,9980	0,9874	0,9906	0,7763	<b>0,9969</b>	0,9874	0,8916
	Mikro Kesinlik	0,7014	<b>0,9806</b>	0,9803	0,9003	<b>0,9999</b>	0,9980	0,9821	0,9870	0,7317	<b>0,9977</b>	0,9821	0,8690
	Mikro Duyarlılık	0,7010	<b>0,9932</b>	0,9821	0,8883	<b>0,9999</b>	0,9980	0,9826	0,9870	0,6645	<b>0,9964</b>	0,9825	0,8797
	Mikro F1	0,7011	<b>0,9867</b>	0,9811	0,8943	<b>0,9999</b>	0,9980	0,9823	0,9870	0,6965	<b>0,9970</b>	0,9823	0,8743
Sıralama Tabanlı	Tek Hata	0,2391	<b>0,0023</b>	0,0156	0,1824	<b>0,0000</b>	0,0019	0,0182	0,0105	0,3423	<b>0,0033</b>	0,0182	0,1802
	Sıralama Kaybı	0,0892	<b>0,0017</b>	0,0032	0,0710	<b>0,0001</b>	0,0016	0,0195	0,0137	0,2000	<b>0,0020</b>	0,0195	0,0859
	Ortalama Kesinlik	0,8125	<b>0,9970</b>	0,9894	0,8235	<b>0,9999</b>	0,9978	0,9760	0,9819	0,6137	<b>0,9959</b>	0,9760	0,8387

Tablo 10’da verilen sonuçlar öznitelik vektörlerini içeren verilerin 2/3’ünün eğitim ve kalan 1/3’ünün test verisi olarak ayrıldığı durumda 5 kez tekrarlanıp ortalamaları alınarak elde edilmiştir. Tablo 11’de ise k-katlı çapraz doğrulama (*k-fold cross validation*) ile elde edilen sonuçlar verilmiştir. Çapraz doğrulamada k sayısı 10 olarak belirlenmiş ve işlem 5 kez tekrarlanıp ortalamaları alınarak sonuçlar elde edilmiştir. Her iki yaklaşımda da aynı sürecin tekrarlanarak ortalamalarının alınmasında eğitim ve test veri setlerinin seçimindeki rastgeleliğin etkisini en aza indirmek amaçlanmıştır. Tablolar incelendiğinde benzer sonuçların ortaya çıktığı görülmektedir. Bu tablolarda koyu yazı biçimi ile vurgulanan değerler BR, LP ve CC dönüşüm yöntemleri için ilgili satırda belirtilen değerlendirme ölçütüne göre en başarılı sınıflandırıcıyı göstermektedir. Benzer şekilde altı çizili yazı biçimi ile vurgulanan değer tüm dönüşüm yöntemleri ve sınıflandırıcıların birlikte kullanımında, ilgili satırda belirtilen değerlendirme ölçütü için en başarılı sınıflandırıcıyı göstermektedir.

**Tablo 12.** BR dönüşüm yöntemi ile NB sınıflandırıcısı için etiket bazında değerlendirme ölçütleri.

Ölçüt	Etiketler								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
Doğruluk	1,000	1,000	0,621	0,948	0,904	0,887	0,774	0,712	1,000
Harmonik	1,000	1,000	0,475	0,910	0,925	0,815	0,569	0,746	1,000
Kesinlik	1,000	1,000	0,603	0,967	0,757	0,598	0,682	0,492	1,000
Duyarlılık	1,000	1,000	0,331	0,842	0,987	0,736	0,412	0,885	1,000

**Tablo 13.** BR dönüşüm yöntemi ile DT sınıflandırıcısı için etiket bazında değerlendirme ölçütleri.

Ölçüt	Etiketler								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
Doğruluk	1,000	1,000	0,993	0,999	0,998	0,996	0,995	0,992	1,000
Harmonik	1,000	0,996	0,993	0,998	0,998	0,995	0,992	0,992	1,000
Kesinlik	0,993	1,000	0,990	1,000	0,996	0,982	0,995	0,979	1,000
Duyarlılık	1,000	0,992	0,994	0,996	0,996	0,993	0,986	0,993	1,000

**Tablo 14.** BR dönüşüm yöntemi ile K-NN sınıflandırıcısı için etiket bazında değerlendirme ölçütleri.

Ölçüt	Etiketler								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
Doğruluk	1,000	1,000	0,994	1,000	1,000	1,000	0,963	0,962	1,000
Harmonik	1,000	1,000	0,994	1,000	1,000	0,999	0,954	0,954	1,000
Kesinlik	1,000	1,000	0,992	1,000	1,000	1,000	0,938	0,925	1,000
Duyarlılık	1,000	1,000	0,994	1,000	1,000	0,998	0,934	0,939	1,000

**Tablo 15.** BR dönüşüm yöntemi ile SVM sınıflandırıcısı için etiket bazında değerlendirme ölçütleri.

Ölçüt	Etiketler								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
Doğruluk	1,000	1,000	0,800	0,998	0,984	1,000	0,910	0,896	1,000
Harmonik	1,000	0,996	0,782	0,997	0,977	1,000	0,903	0,877	1,000
Kesinlik	1,000	1,000	0,795	0,996	0,985	1,000	0,820	0,798	1,000
Duyarlılık	1,000	0,992	0,716	0,996	0,960	1,000	0,885	0,839	1,000

BR problem dönüştürme yöntemi ile 4 farklı sınıflandırıcı için etiket bazında elde edilen sonuçlar Tablo 12, 13, 14 ve 15’te verilmiştir. Sonuçlar incelendiğinde NB sınıflandırıcısında L1, L2 ve L9; DT sınıflandırıcısında L9; K-NN sınıflandırıcısında L1, L2, L4, L5 ve L9; SVM sınıflandırıcısında L1, L6 ve L9 etiketlerinin tam doğrulukta sınıflandırıldığı görülmektedir. En düşük başarımları NB sınıflandırıcısı ile L3 etiketinde görülmektedir.

**Tablo 16.** LP dönüşüm yöntemi ile NB sınıflandırıcısı için etiket bazında değerlendirme ölçütleri.

Ölçüt	Etiketler								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
Doğruluk	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
Harmonik	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
Kesinlik	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
Duyarlılık	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000

**Tablo 17.** LP dönüşüm yöntemi ile DT sınıflandırıcısı için etiket bazında değerlendirme ölçütleri.

Ölçüt	Etiketler								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
Doğruluk	1,000	0,999	0,999	1,000	1,000	1,000	0,997	0,997	1,000
Harmonik	1,000	1,000	0,999	1,000	1,000	0,999	0,998	0,995	1,000
Kesinlik	1,000	0,984	1,000	1,000	0,999	1,000	0,992	0,998	1,000
Duyarlılık	1,000	1,000	0,998	1,000	1,000	0,998	0,999	0,991	1,000

**Tablo 18.** LP dönüşüm yöntemi ile K-NN sınıflandırıcısı için etiket bazında değerlendirme ölçütleri.

Ölçüt	Etiketler								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
Doğruluk	1,000	1,000	0,994	1,000	1,000	1,000	0,962	0,962	1,000
Harmonik	1,000	1,000	0,994	1,000	1,000	0,999	0,952	0,954	1,000
Kesinlik	1,000	1,000	0,992	1,000	1,000	1,000	0,938	0,927	1,000
Duyarlılık	1,000	1,000	0,994	1,000	1,000	0,998	0,930	0,936	1,000

**Tablo 19.** LP dönüşüm yöntemi ile SVM sınıflandırıcısı için etiket bazında değerlendirme ölçütleri.

Ölçüt	Etiketler								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
Doğruluk	1,000	1,000	1,000	1,000	1,000	1,000	0,972	0,972	1,000
Harmonik	1,000	1,000	1,000	1,000	1,000	1,000	0,970	0,960	1,000
Kesinlik	1,000	1,000	1,000	1,000	1,000	1,000	0,938	0,965	1,000
Duyarlılık	1,000	1,000	1,000	1,000	1,000	1,000	0,967	0,934	1,000

LP problem dönüştürme yöntemi ile 4 farklı sınıflandırıcı için etiket bazında elde edilen sonuçlar Tablo 16, 17, 18 ve 19’da verilmiştir. Sonuçlar incelendiğinde NB sınıflandırıcısında tüm etiketlerin; DT sınıflandırıcısında L1, L4 ve L9; K-NN sınıflandırıcısında L1, L2, L4, L5 ve L9; SVM sınıflandırıcısında L1, L2, L3, L4, L5, L6 ve L9 etiketlerinin tam doğrulukta sınıflandırıldığı görülmektedir. En düşük başarımlar K-NN sınıflandırıcısı ile L7 ve L8 etiketinde görülmektedir.

**Tablo 20.** CC dönüştürme yöntemi ile NB sınıflandırıcısı için etiket bazında değerlendirme ölçütleri.

Ölçüt	Etiketler								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
Doğruluk	1,000	1,000	0,621	0,949	0,907	0,905	0,745	0,743	1,000
Harmonik	1,000	1,000	0,474	0,910	0,926	0,769	0,458	0,765	1,000
Kesinlik	1,000	1,000	0,604	0,969	0,764	0,696	0,625	0,526	1,000
Duyarlılık	1,000	1,000	0,331	0,842	0,982	0,646	0,304	0,833	1,000

**Tablo 21.** CC dönüştürme yöntemi ile DT sınıflandırıcısı için etiket bazında değerlendirme ölçütleri.

Ölçüt	Etiketler								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
Doğruluk	1,000	1,000	0,995	0,999	0,998	0,999	0,994	0,994	1,000
Harmonik	1,000	0,996	0,994	0,998	0,998	0,995	0,991	0,994	1,000
Kesinlik	0,993	1,000	0,997	1,000	0,996	1,000	0,993	0,987	1,000
Duyarlılık	1,000	0,992	0,991	0,996	0,996	0,991	0,986	0,993	1,000

**Tablo 22.** CC dönüştürme yöntemi ile K-NN sınıflandırıcısı için etiket bazında değerlendirme ölçütleri.


Ölçüt	Etiketler								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
Doğruluk	1,000	1,000	0,994	1,000	1,000	1,000	0,962	0,962	1,000
Harmonik	1,000	1,000	0,994	1,000	1,000	0,999	0,952	0,954	1,000
Kesinlik	1,000	1,000	0,992	1,000	1,000	1,000	0,938	0,927	1,000
Duyarlılık	1,000	1,000	0,994	1,000	1,000	0,998	0,930	0,936	1,000

**Tablo 23.** CC dönüştürme yöntemi ile SVM sınıflandırıcısı için etiket bazında değerlendirme ölçütleri.

Ölçüt	Etiketler								
	L1	L2	L3	L4	L5	L6	L7	L8	L9
Doğruluk	1,000	1,000	0,800	0,971	0,999	1,000	0,902	0,902	0,954
Harmonik	1,000	0,996	0,783	0,979	0,998	1,000	0,905	0,837	0,975
Kesinlik	1,000	1,000	0,795	0,906	0,998	1,000	0,784	0,892	0,496
Duyarlılık	1,000	0,992	0,717	0,999	0,998	1,000	0,912	0,739	1,000

CC problem dönüştürme yöntemi ile 4 farklı sınıflandırıcı için etiket bazında elde edilen sonuçlar Tablo 20, 21, 22 ve 23’te verilmiştir. Sonuçlar incelendiğinde NB sınıflandırıcısında L1, L2 ve L9; DT sınıflandırıcısında L1; K-NN sınıflandırıcısında L1, L2, L4, L5 ve L9; SVM sınıflandırıcısında L1 ve L6 etiketlerinin tam doğrulukta sınıflandırıldığı görülmektedir. En düşük başarımlar NB sınıflandırıcısı ile L3 etiketinde görülmektedir.

Etiket bazında elde edilen sonuçlar tüm problem dönüştürme yöntemleri ve tüm sınıflandırıcılarla birlikte Şekil 8’de gösterilmiştir. Şekil 8’de daire şekline yakınsayan çokgenin her bir köşesi bir problem dönüştürme yöntemi ile bir sınıflandırıcının birlikte kullanımı ile elde edilen doğruluk oranını göstermektedir. Çokgen biçiminden çokgenin merkezine doğru olan köşegen sapmaları ilgili etiket için doğruluk oranının azaldığını göstermektedir. Aynı zamanda problem dönüştürme yöntemlerinin performansı da Şekil 8’de verilen doğruluk oranı grafikleri kullanılarak karşılaştırılabilir.



Şekil 8. Etiket bazında sınıflandırma doğruluğunun grafiksel gösterimi.

## V. SONUÇLAR

Bu çalışmada 3-fazlı, 380 V, 50 Hz şebekeden beslenen ve %100 yük altında çalışan bir asenkron motorda meydana gelen tekil ve eş zamanlı çoklu arızaların çok etiketli sınıflandırılmasına odaklanılmıştır. LP yöntemi ile NB sınıflandırıcısının birlikte kullanımında %99,9 oranında, CC yöntemi ile DT sınıflandırıcısının birlikte kullanımında %99,3 oranında ve BR yöntemi ile DT sınıflandırıcısının birlikte kullanımında %97,8 oranında doğrulukla sınıflandırma başarımına ulaşılmıştır.

Etiket bazında sonuçlar değerlendirildiğinde L1, L2 ve L9 etiketleri için yüksek doğrulukta; L3, L7 ve L8 etiketleri için ise diğerlerine nazaran daha düşük doğrulukta sonuçlar elde edildiği görülmektedir. Benzer şekilde CC problem dönüştürme yöntemi ile NB sınıflandırıcısı birlikte kullanıldığında da en düşük doğruluk oranının elde edildiği Şekil 8’de görülmektedir.

Problem dönüştürme yöntemleri, çok etiketli sınıflandırma sonuçları üzerinden genel olarak değerlendirildiğinde en yüksek başarımları LP ile elde edilmiştir. Diğer yöntemlerden CC ve BR’nin DT ve K-NN sınıflandırıcıları ile birlikte kullanımında başarılı sonuçlar elde edildiği görülmektedir.

Sınıflandırıcılar karşılaştırıldığında, DT sınıflandırıcısı ile tüm problem dönüştürme yöntemlerinde en yüksek başarımları elde edildiği görülmektedir. Diğer sınıflandırıcılar başarımlarına göre yüksekten



düşüğe doğru K-NN, SVM ve NB şeklinde sıralanmaktadır. En yüksek başarımlı oranı LP ile NB birlikteliğinden elde edilmiştir.

Yapılan çalışma, çok etiketli sınıflandırma yönteminin elektrik makinalarının eş zamanlı çoklu arızalarının sınıflandırılmasında etkin bir şekilde kullanılabileceğini göstermektedir.

**TEŞEKKÜR:** Bu çalışmada “116E302” numaralı “Asenkron Motorlar Arızalarının Tespiti ve Entropi Analizi ile Arıza Şiddetinin Belirlenmesi” başlıklı TÜBİTAK projesi verileri kullanılmıştır. TÜBİTAK Başkanlığına teşekkür ederiz.

## **VI. KAYNAKLAR**

- [1] Y. B. Koca ve A. Ünsal, “Asenkron motor arızalarının değerlendirilmesi,” *Teknik Bilimler Dergisi*, c. 7, s. 2, ss. 37-46, 2017.
- [2] A. Dineva, A. Mosavi, M. Gyimesi, I. Vajda, N. Nabipour, and T. Rabczuk, “Fault Diagnosis of Rotating Electrical Machines Using Multi-Label Classification,” *Applied Sciences*, vol. 9, no. 23, p. 5086, 2019, doi: 10.3390/app9235086.
- [3] M. Juez-Gil, J. J. Saucedo-Dorantes, Á. Arnaiz-González, C. López-Nozal, C. García-Osorio, and D. Lowe, “Early and extremely early multi-label fault diagnosis in induction motors,” *ISA transactions*, vol. 106, pp. 367-381, 2020
- [4] C. M. Vong, P. K. Wong, and W. F. Ip, “A New Framework of Simultaneous-Fault Diagnosis Using Pairwise Probabilistic Multi-Label Classification for Time-Dependent Patterns,” *IEEE Transactions on Industrial Electronics*, vol. 60, no. 8, pp. 3372-3385, 2013
- [5] G. Georgoulas, V. Climente-Alarcon, J. A. Antonino-Daviu, I. P. Tsoumas, C. D. Stylios, A. Arkkio, and G. Nikolakopoulos, “The use of a multilabel classification framework for the detection of broken bars and mixed eccentricity faults based on the start-up transient,” *IEEE Transactions on Industrial Informatics*, vol. 13, no. 2, pp. 625-634, 2016
- [6] J. Shen, S. Li, F. Jia, H. Zuo, and J. Ma, “A deep multi-label learning framework for the intelligent fault diagnosis of machines,” *IEEE Access*, vol. 8, pp 113557-113566, 2020
- [7] S. Han, S. Zhang, Y. Li, and L. Chen, “The multilabel fault diagnosis model of bearing based on integrated convolutional neural network and gated recurrent unit,” *International Journal of Intelligent Computing and Cybernetics*, vol. 15, no. 3, pp 401-413, 2021
- [8] C. Yu, Y. Ning, Y. Qin, W. Su, and X. Zhao, “Multi-label fault diagnosis of rolling bearing based on meta-learning,” *Neural Computing and Applications*, vol. 33, no. 10, pp. 5393-5407. 2021
- [9] F. Li, X. Ma, and Y. Wang, “A multi-label method of state partition and fault diagnosis based on binary relevance algorithm,” in *2020 IEEE 9th Data Driven Control and Learning Systems Conference (DDCLS)*, Liuzhou, China, 2020, pp. 567-572
- [10] P. Gangsar, and R. Tiwari, “Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review,” *Mechanical Systems and Signal Processing*, vol. 144, 106908, 2020

- [11] J. J. Saucedo-Dorantes, M. Delgado-Prieto, J. A. Ortega-Redondo, R. A. Osornio-Rios, and R. D. J. Romero-Troncoso, "Multiple-fault detection methodology based on vibration and current analysis applied to bearings in induction motors and gearboxes on the kinematic chain," *Shock and Vibration*, vol. 2016, no. Special Issue, pp. 1–13, 2016
- [12] A. Alwodai, F. Gu, and A. D. Ball, "A comparison of different techniques for induction motor rotor fault diagnosis," *Journal of Physics: Conference Series*, vol. 364, no. 1, p. 012066, 2012
- [13] M. K. Saini, and A. Aggarwal, "Detection and diagnosis of induction motor bearing faults using multiwavelet transform and naive Bayes classifier," *International Transactions on Electrical Energy Systems*, vol. 28, no. 8, e2577, 2018
- [14] G. Tsoumakas, and I. Katakis, "Multi-label classification: An overview," *International Journal of Data Warehousing and Mining (IJDWM)*, vol. 3, no. 3, pp. 1-13, 2007
- [15] H. Modi, and M. Panchal, "Experimental comparison of different problem transformation methods for multi-label classification using MEKA," *International Journal of Computer Applications*, vol. 59, no. 15, pp. 10-15, 2012
- [16] J. M. Nareshpalsingh, and H. N. Modi, "Multi-label classification methods: A comparative study," *International Research Journal of Engineering and Technology (IRJET)*, vol. 4, no. 12, pp. 263-270, 2017.
- [17] G. Tsoumakas, I. Katakis, and I. Vlahavas, "Mining multi-label data" in *Data mining and knowledge discovery handbook*, 2nd ed., Boston, USA : Springer, 2009, pp. 667-685.
- [18] E. A. Cherman, M. C. Monard, and J. Metz, "Multi-label problem transformation methods: a case study," *CLEI Electronic Journal*, vol. 14, no. 1, pp. 1-10, 2011.
- [19] S. Vogrinčić, and Z. Bosnić, "Ontology-based multi-label classification of economic articles," *Computer Science and Information Systems*, vol. 8, no. 1, pp. 101-119, 2011
- [20] J. Read, "Scalable multi-label classification," Ph.D. dissertation, Department of Computer Science, University of Waikato, Hamilton, New Zealand, 2010.
- [21] A. Santos, A. Canuto, and A. F. Neto, "A comparative analysis of classification methods to multi-label tasks in different application domains," *International Journal of Computer Information Systems and Industrial Management Applications*, vol. 3, pp. 218-227, 2011.
- [22] R. Cerri, R. R. da Silva, and A. C. P. L. F. de Carvalho, "Comparing methods for multilabel classification of proteins using machine learning techniques", *Brazilian Symposium on Bioinformatics (BSB)*, Porto Alegre, Brazil, 2009, pp. 109-120
- [23] D. Ganda, and R. Buch, "A survey on multi label classification," *Recent Trends in Programming Languages*, vol. 5, no. 1, pp. 19-23, 2018.
- [24] N. Endut, W. A. F. W. Hamzah, I. Ismail, M. K. Yusof, Y. A. Baker, and H. Yusoff, "A Systematic Literature Review on Multi-Label Classification based on Machine Learning Algorithms," *TEM Journal*, vol. 11, no. 2, pp. 658-666, 2022
- [25] I. Rish, "An empirical study of the naive Bayes classifier," *IJCAI 2001 workshop on empirical methods in artificial intelligence*, vol. 3, no. 22, pp. 41-46, 2001.

- [26] P. Domingos, and M. Pazzani, "Beyond independence: Conditions for the optimality of the simple bayesian classifier," *13th International Conference Machine Learning (ICML)*, Bari, Italy, 1996, pp. 105-112.
- [27] WEKA, *Bilgisayar Programı*, Versiyon 3.8.6, Hamilton – New Zealand: The University of Waikato, 2022.
- [28] S. Ruggieri, "Efficient C4. 5 [classification algorithm]," *IEEE transactions on knowledge and data engineering*, vol. 14 no. 2, pp. 438-444, 2002
- [29] K. Taunk, S. De, S. Verma, and A. Swetapadma, "A Brief Review of Nearest Neighbor Algorithm for Learning and Classification," *2019 International Conference on Intelligent Computing and Control Systems (ICCS)*, Madurai, India, 2019, pp. 1255-1260
- [30] P. Cunningham, and S. J. Delany, "k-Nearest Neighbour Classifiers - A Tutorial," *ACM Computing Surveys (CSUR)*, vol. 54, no. 6, pp. 1-25, 2021
- [31] V. Jakkula, "Tutorial on support vector machine (SVM)," *School of EECS - Washington State University*, vol. 37, no. 2.5, pp. 1-13, 2006.
- [32] L. Nguyen, "Tutorial on support vector machine," *Applied and Computational Mathematics*, vol. 6, no. 4-1, pp. 1-15, 2017
- [33] E. K. Yapp, X. Li, W. F. Lu, and P. S. Tan, "Comparison of base classifiers for multi-label learning," *Neurocomputing*, vol. 394, pp. 51-60, 2020
- [34] R. E. Schapire, and Y. Singer, "BoosTexter: A boosting-based system for text categorization," *Machine Learning*, vol. 39, pp. 135-168, 2000
- [35] S. Godbole, and S. Sarawagi, "Discriminative methods for multi-labeled classification," in *Pacific-Asia conference on knowledge discovery and data mining*, Berlin, Heidelberg, 2004, pp. 22-30
- [36] N. Ghamrawi, and A. McCallum, "Collective multi-label classification," in *Proceedings of the 14th ACM international conference on Information and knowledge management*, Shanghal, China, 2005, pp. 195-200
- [37] Y. Yang, "An evaluation of statistical approaches to text categorization," *Information retrieval*, vol. 1, no. 1-2, pp. 69-90, 1999
- [38] A. Ünsal, "Asenkron Motorlar Arızalarının Tespiti ve Entropi Analizi ile Arıza Şiddetinin Belirlenmesi," Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK), Türkiye, Rap. 116E302, 2019.
- [39] J. Read, P. Reutemann, B. Pfahringer, and G. Holmes, "Meka: A Multi-label/Multi-target Extension to WEKA," *Journal of Machine Learning Research*, vol. 17, pp. 1-5, 2016.