

## Dalgacık Dönüşümü ve Özbağlanım Model Parametreleri Öznitelikleri ile Otomobil Motor Seslerinden Arıza Tespitİ

Göktuğ YILMAZ<sup>a</sup>, Necip Fazıl METE<sup>b</sup>, Umusalama UMUGABEKAZI<sup>c</sup>, Önder AYDEMİR<sup>\*d</sup>

Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 61080, Trabzon

(Alınış / Received: 17.11.2020, Kabul / Accepted: 24.12.2020, Online Yayınlanması / Published Online: 31.12.2020)

### Anahtar Kelimeler

Motor arızası

Ses tanıma

Öznitelik çıkarma

Sınıflandırma

**Özet:** Örütü tanıma ve makine öğrenmesi başarılı sonuçlar sağlasından dolayı popülerliğini giderek artırmaktadır. Bu çalışmada marka ve model farkı gözetmeksizin zamanlama zinciri ve vuruntu arızası ile normal çalışma durumlarına ait otomobil motor sesleri sınıflandırılmıştır. Önerilen yöntem iki saniyelik motor seslerinden sürekli dalgacık dönüşümü ve özbağlanım parametresi özniteliklerin  $k$ -en yakın komşuluk algoritması ile sınıflandırarak %91.8 oranında sınıflandırma doğruluğu elde etmiştir. Elde edilen sonuçlar önerilen yöntemin otomobil motor sesleri kullanılarak araçlarda meydana gelebilecek arızaları büyük oranda tespit edilebileceğini göstermiştir. Böylece, otomobil motorlarındaki arızanın erken tespiti mümkün olmakta, bu da olası kazaların ve büyük arızaların ortaya çıkışının önüne geçmektedir. Ayrıca, önerilen yöntemin araç yetkili servislerine ve motor ustalarına rehberlik etmek ve zaman kazandırmak amaçlı da kullanılabileceği düşünülmektedir.

## Wavelet Transform and Autoregressive Model Parameter Features based Engine Fault Diagnosis System

### Keywords

Motor fault

Sound recognition

Feature extraction

Classification

**Abstract:** Pattern recognition and machine learning are increasing in popularity due to their successful results and are used in many areas. In this study, the timing belt and knock failure and automobile engine sounds belonging to normal operating conditions are classified, regardless of brand and model. The proposed method has achieved a classification accuracy of 91.8% by classifying the features of continuous wavelet transform and autoregressive model parameter from two-second motor sounds with the  $k$ -nearest neighborhood algorithm. The obtained results showed that the proposed method could be used to detect engine faults that may occur in vehicles by using automobile engine sounds. Thus, early detection of engine faults in automobiles is possible, which prevents possible accidents and major breakdowns. In addition, it is thought that the proposed method can be used to guide vehicle authorized services and engine masters and to save time.

## 1. Giriş

Örütü tanıma ve makine öğrenmesi birçok disiplinde önemli bir çalışma sahisi haline gelmiştir. Mühendislikten [1-3] tıbba [4-7], biyolojiden [8] finansa [9], [10] kadar birçok alanda araştırmacıların problemleri çözmek için başvurduğu etkin bir çözüm aracı olarak popülerliği giderek artmaktadır. Yapılan

çalışmalar, örütü tanıma ve makine öğrenmesi tabanlı çözümlerin özellikle tipta erken teşhis veya teşhis destek sistemi olarak oldukça yaygın bir şekilde kullanıldığını göstermektedir [11-16].

Örütü tanıma ve makine öğrenmesi yöntemlerinin tercih edildiği ve bu çalışmanın da içeriğini oluşturan bir diğer konu ise motor arızası tespitidir [17-21]. Özellikle, otomobil motorlarının çıkardıkları sesler,

\*İlgili yazar: onderaydemir@ktu.edu.tr, <sup>d</sup>ORCID: 0000-0002-1177-8518

<sup>a</sup> ORCID: 0000-0002-0901-5992, <sup>b</sup>ORCID: 0000-0003-3819-339X, <sup>c</sup> ORCID: 0000-0001-6031-3576

motordaki arızaya dair ciddi ipuçları verebilmektedirler. Böylelikle bu seslerin analiz edilmesi ve sınıflandırılmasıyla, otomobil motorlarındaki arızanın erken tespiti mümkün olmakta, bu da olası kazaların ve büyük arızaların ortaya çıkışının önüne geçmektedir. Dahası, sağladığı erken bilgilendirme ile can ve mal kaybının en aza inmesine katkı sağlamaktadır. Ayrıca, bu sistemler yetkili servislere ve motor ustalarına rehberlik etmek ve zaman kazandırmak amaçlı da kullanılabilmektedirler. Navea ve Sybingco tarafından 2013 yılında yapılan çalışmada [22] motor mars problemleri, tahrik kayışı problemleri ve vana açıklığına bağlı arıza problemleri tespit edilmiştir. Bahsi geçen makalede hedef marka ve modeldeki arızaların yanı sıra başka marka ve modeldeki arızaların da tespiti gerçekleştirılmıştır. Referans ses kayıtları 1996- 2000 model Honda Civic arabalarından alınmış olup, %56 sınıflandırma doğruluğu sağlayan bir model önerilmiştir. Bunun yanında bazı problemler ise %100 doğrulukla tespit edilmiştir. Çalışmada öznitelik olarak Fourier Dönüşümleri ve Spektrum güç yoğunlukları kullanılmıştır. Sınıflandırma işlemi ise bir bulanık mantık çıkarsama sistemi aracılığıyla gerçekleştirılmıştır. Bir başka motor sesi arızası tabanlı çalışmada Siegel ve arkadaşları ise yanlış ateşleme arızasının tespiti üzerine çalışmışlardır [23]. Bu çalışmada farklı ortam koşullarında 35 adet Honda Civic'ten hem sağlıklı hem de arızalı motorlar için ses kaydı alınmış olup, bu seslerden Fourier, Dalgacık Dönüşümü ve Mel-Frekansı Kepstrum Katsayıları öznitelikleri çıkarılmıştır. Sınıflandırma yöntemi olaraksa Destek Vektör Makineleri (DVM) kullanılmış olup, %99 doğruluk oranı elde edilmiştir. Ayrıca herbir kayıt 2.5 saniyelik parçalara ayrılmıştır ve bu şekilde 992 adet 2.5 saniyelik parçadan oluşan bir veri seti elde edilmiştir. Farklı bir çalışmada ise Wang ve arkadaşları Santana 2000 aracı üzerinde motor ses kayıtları almıştır [24].

Çalışma kapsamında öznitelik çıkarmak için Hilbert-Huang dönüşümü kullanılmıştır. Ölçümler motor silindir kapağının 30 cm üzerinden gerçekleştirilmiş olup, arka plan sesleri, arıza sesinden 15 dB düşük olduğundan görmezden gelinmiştir. Ölçüm sırasındaki sinyal uzunluğu 3sn, örneklemme değeri 16.384 Hz'dır. Ölçümler sıcak bir motorda ve 2500 dev/dk'da gerçekleştirılmıştır. Arızaların her biri için 20 araçtan toplamda 140 veri toplanmıştır. DVM yöntemi kullanılarak %96'ya varan oranla hata tespit edilmiştir. Motor sesinden başka insan sesi gibi dış ortamdan gelen farklı sesleri de dikkate alan Kemalkar ve Bairagi ise, yağlama arızası, zincir arızası, krant arızası ve vana arızasına dayalı sesleri 44.1 kHz örneklemme frekansı ile kaydetmişlerdir [25]. Kayıtlar servis istasyonunda alındığından, insan konuşmaları ve farklı ortam sesleri de olduğu gibi kaydedilmiştir. Çalışma, motosiklet motoru üzerinde yapılmış olup Honda Unicorn ve Bajaj Pulsar marka

motosikletler üzerinde çalışılmıştır. Honda'dan 20 saniyelik, Bajaj Pulsar'dan da 15 saniyelik ses kayıtları alınmış olup, doğruluk oranları %50 ile %75 arasında değişmektedir. Öznitelik çıkartmak için kullanılan yöntemse Mel-Frekansı Kepstrum katsayıları algoritmasıdır. Diğer bir çalışmada ise Madain ve arkadaşları 2008 model Audi A4 ve 2005 model Toyota Rav4 motorları üzerinde çalışmış olup, bazı yatak arızaları ve egzoz arızalarını sınıflandırmışlardır [26]. Audi ile yapılan çalışmada doğru teşhis oranı %100 iken Toyota'da bu değer %90 olarak belirtilmiştir. Seslerin sınıflandırılması yapılrken korelasyon katsayıları, normalize edilmiş ortalama karesel hata ve formant freksansları kullanılmıştır.

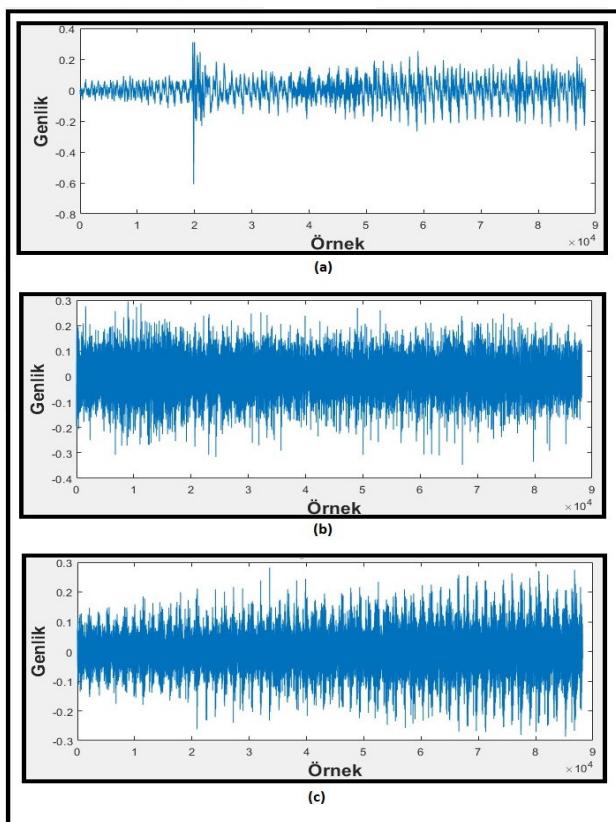
Literatürde motor sesine dayalı arıza tespitinde çok farklı araçlar ve farklı arıza durumlarında çalışıldığı ve genel bir yöntem önerilmediği söylenebilir. Bu çalışmada model farkı gözetilmeksiz zamanlama zinciri ve vuruntu arızaları ile sağlıklı motor durumlarına ait sesler sınıflandırılmıştır. Zamanlama zinciri veya kayışı, motorun krant mili ile kam mili arasındaki hareketi düzenler. Motordaki bu önemli parça, kimi araçlarda zincir kimi araçlarda ise kayış şeklindedir. Bu parçanın kopması, piston ve subap hareketinin zamanlamasını bozarak motora ciddi zararlar verebilir. Kimi zaman aniden kopan bu zincir, kimi zamansa dışlerindeki bozulmalardan ötürü problemi işaret eden sesler çıkarır. Bu ses tespit edildiği zaman, zincirin değiştirilmesi gerekmektedir. İncelenen bir diğer arıza ise sık rastlanan bir sorun olan, vuruntu problemidir. İçten yanmalı motorlarda hava ve benzin karışımı, silindir içerisindeki üst ölü noktaya ulaştıktan sonra bujilerin alev almasıyla yanmaktadır. Ancak bazen, yüksek basınç ve sıcaklık değerlerinde, yakıt hava karışımı üst ölü noktaya ulaşmadan yanar ve bu olay vurunu olarak adlandırılır. Bu durumda motor titreşimli ve darbeli çalışmaya başlar ve kendini belli eden bir ses oluşturur. Motorun zarar görmesine sebep olan bu arızanın erken tespiti, hasar daha ciddi boyutlara ulaşmadan yapılmalıdır. Çalışma kapsamında bu arızaların teşhisinde, sürekli dalgacık dönüşümü ve özbağlanım modeli parametreleri öznitelikleri ve k-en yakın komşuluk (k-EYK) sınıflandırıcısı kullanılmış olup k=1 değeri için %91.8 doğruluk oranı elde edilmiştir. Çalışma kapsamında herhangi bir çapraz doğrulama yöntemi kullanılmamıştır.

## 2. Materyal ve Metot

### 2.1. Veri Seti Tanıtımı

Bu çalışmada internetten bulunan zamanlama zinciri ve vuruntu arızaları ile sağlıklı motor durumlarına ait sesler sınıflandırılmıştır. Arıza tespitleri alanında uzman motor ustaları tarafından yapılmıştır. Motor

sesleri herhangi bir marka ve model ayrimı gözetilmemiş olup, aracın odaklanılan motor arızasına sahip olması yeterli görülmüştür. Kayıtlar Honda, Ford, Mercedes ve Audi marka araçlardan alınmıştır. Bu kayıtlar, internetten rastgele indirildikleri için ortam koşulları değişkenlik göstermektedir. Ayrıca kayıtların arıza sesi içermeyen bölümleri kesilmiştir. Her bir arıza için 20 adet video kaydı indirilmiş olup, indirilen bu dosyalara video düzenleme programı ile gürültü eklenerek yeni kayıtlar türetilmiş ve arıza başına 40 adet ses dosyası videolardan elde edilmiştir. Gürültüler olarak kullanılmak üzere tren, yıldırım, rüzgar, yağmur, kahkaha ve konuşma sesleri gibi çeşitli ortam sesleri tercih edilmiştir. Gürültüler sinyal-gürültü oranı yaklaşık 44 olacak şekilde eklenmiştir. Sağlıklı motor sesinden ise 20 adet indirilmiş olmakla beraber, kayıtlara gürültü eklenmemiş ve yeni kayıtlar türetilmemiştir. Sonuç olarak, her bir arıza için 40 adet, sağlıklı motor sesi içinse 20 adet olmak üzere, toplam 100 adet kayıttan yararlanılmıştır. Ses dosyaları 2'ser saniyelik parçalara ayrılmış ve 44.1 kHz örnekleme frekansıyla her bir parçadan 88200 örnek alınmıştır. Herbir ses sınıfının yarısı eğitim yarısı da test olarak gruplandırılmıştır. Veri setinin tüm özelliklerini Tablo 1'de verilmiştir. Ayrıca arızalı ve sağlıklı motor seslerine ait ikişer saniye uzunluğundaki ses sinyali örnekleri Şekil 1'de verilmiştir.



**Şekil 1.** Motor seslerine ait örnek işaretler,  
a) Zamanlama zinciri arızası, b) Vuruntu arızası ve  
c) normal çalışma durumu

**Tablo 1.** Veri seti özelliklerı

	Zamanlama Zinciri		Vuruntu		Sağlıklı	
	Var	Yok	Var	Yok	Var	Yok
Kayıt Sayısı	20	20	20	20	0	20
Toplam Kayıt Sayısı	40		40		20	
Toplam Kayıt Süresi	1964 saniye		2270 saniye		874 saniye	
Toplam Deneme Sayısı	982		1135		437	
Bir Denemenin Süresi	2 saniye		2 saniye		2 saniye	

## 2.2. Yöntem

Ham ses işaretin tek başına ayırt edici bir özellik taşımayabilir. Bunun için örüntü tanıma algoritmaları ses işaretlerinden öznitelikler hesaplayarak verilerde bulunan gizli bilgileri ortaya çıkartmak için kullanılır. Bu aşamanın örüntü tanıma ve makine öğrenmesi problemleri için en kritik aşama olduğu söylenebilir. Çünkü öznitelikler direkt olarak sınıflandırma yönteminin performansını etkilemektedir. Bu çalışmada ses işaretleri sürekli dalgacık dönüşümü (SDD) katsayıları ve özbağlanım parametreleri (ÖBP) temelli öznitelikler ile sınıflandırılmıştır. Sınıflandırma aşamasında ise basit olmasına rağmen literatürde örüntü tanıma ve makine öğrenmesi alanında çalışan araştırmacılar tarafından sıkılıkla kullanılan ve başarılı sonuçlar elde edilen k-en yakın komşuluk yöntemi kullanılmıştır. Tüm hesaplamalar MATLAB R2018a ortamında yapılmıştır. Aşağıda verilen alt başlıklarda öznitelik çıkarma ve sınıflandırma adımlarının hesaplama yöntemleri detaylı bir şekilde verilmiştir.

### 2.2.1 Öznitelik Çıkarma

Dalgacık dönüşümü, bir işaretin zaman-frekans analizi için ölçek ve kaydırma parametreleri ile kullanılan önemli bir yöntemdir. Ortalaması sıfır olan ve ölçek parametresi ile ön plana çıkaracağı frekans bölgesi ayarlanabilen dalgacık, kaydırma parametresi ile analize edilecek  $f(x)$  işaretü üzerinde gezdirilir ve her bir adımda dalgacık ile işaret Eşitlik 1'de gösterildiği gibi konvolüsyona tabi tutulur. Eşitlik 2'de ise dalgacığın matematiksel ifadesi verilmiştir [27], [28].

$$SDD_f(a, b) = \int_{-\infty}^{\infty} f(x)\psi_{a,b}^*(x) dx \quad (1)$$

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}}\psi\left(\frac{x-b}{a}\right) \quad (2)$$

Bu eşitliklerde  $SDD_f(a, b)$  SDD dönüşümü katsayılarını,  $\psi_{a,b}(x)$  ana dalgacığı,  $b$  öteleme parametresini ve  $a$  ise ölçek parametresini ifade

etmektedir. Bu çalışmada SDD katsayılarının standart sapması ve ortalaması her bir 2 saniyelik ses işaretini temsil etmek için öznitelik olarak sırasıyla Eşitlik 3 ve Eşitlik 4'te verildiği gibi hesaplanmıştır.

$$SDD\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |SDD_i - SDD\mu|^2} \quad (3)$$

$$SDD\mu = \frac{1}{N} \sum_{i=1}^N SDD_i \quad (4)$$

Bu eşitliklerde  $SDD\sigma$  SDD katsayılarının standart sapmasını,  $SDD\mu$  SDD katsayılarının ortalamasını,  $N$  örnek sayısını ve  $SDD_i$   $i=1, 2, 3, \dots, N$  olmak üzere  $i$ 'inci SDD katsayısını ifade etmektedir.

Özbağlanım modelinde ise zaman uzayında bulunan işareti girdi olarak alarak bir tahmin işlemi gerçekleştirilir. İşaretin geçmişteki davranışını referans olarak alınarak gelecekteki davranışını tahmin etmeye dayalı bir işleyişe sahiptir [29]. Bir özbağlanım modeli için  $n$ 'inci dereceden tahmin eşitliği Eşitlik 5'te verilmiştir.

$$f(x) = p_1 f_{t-1} + p_2 f_{t-2} \dots p_n f_{t-n} + e(t) \quad (5)$$

Bu eşitlikte  $f(x)$  ham ses işaretini,  $p_1, p_2, \dots, p_n$   $n$ 'inci derece ÖBP katsayılarını ve  $e(t)$  önceki değerlerden bağımsız olan beyaz gürültüyü temsil etmektedir. Bu çalışmada  $p$  katsayıları ÖBP öznitelikleri olarak kullanılmıştır.

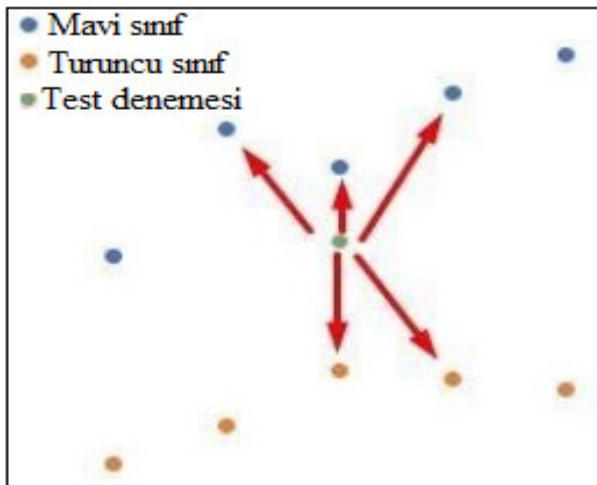
### 2.2.2. Sınıflandırma

Bu çalışmada literatürde sıkılıkla kullanılan ve başarılı sonuçlara verebilen  $k$ -EYK sınıflandırıcısı kullanılmıştır. Bu yöntemde sınıflandırma, öznitelik uzayındaki verilerin birbirine olan uzaklıklarına yapılmaktadır. Şekil 2'de gösterildiği gibi sınıflandırılması gereken test denemesinin, eğitim öznitelik uzayındaki denemelere olan uzaklıklarını öncelikle hesaplanır. Bu uzaklıklardan en küçük  $k$  tanesi dikkate alınarak oylama yöntemi ile test denemesinin ait olduğu sınıf belirlenir.  $k$ -EYK sınıflandırıcısında hem  $k$  parametresinin değeri hem de denemeler arasındaki uzaklıkların hesaplan yöntemi sınıflandırma sonucuna etki eden faktörlerdir. Bu çalışmada  $k$  parametresi 10 kat çapraz doğrulama yöntemi ile, uzaklık hesaplaması ise Eşitlik 6'da verildiği gibi Öklit ölçütı ile hesaplanmıştır [30].

$$U = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (6)$$

Bu eşitlikte  $x_1$  ve  $y_1$  iki boyutlu bir öznitelik uzayında bir denemenin koordinatlarını,  $x_2$  ve  $y_2$  de aynı uzayda diğer bir denemenin koordinatlarını

göstermektedir.  $U$  ise bu iki denemenin Öklit ölçütüne göre uzaklığıdır.



Şekil 2.  $k$ -en yakın komşuluk sınıflandırıcı

### 3. Sonuçlar

Bu çalışmada model farkı gözetilmeksiz zamanlama zinciri ve vuruntu arızaları ile normal çalışma durumlarına ait otomobil motor sesleri  $k$ -EYK ile sınıflandırılmıştır. Sınıflandırma işleminde  $k$  değeri 1'den 20'ye kadar değiştirilmiş olup, en yüksek sonucu veren  $k$  değeri belirlenmiştir. İki saniyelik motor sesleri her bir deneme parçasını oluşturmak üzere bu ses işaretlerinden SDD ve ÖBP öznitelikleri çıkarılmıştır. Bu özniteliklerle elde edilen sınıflandırma doğrulukları sırasıyla Tablo 2 ve Tablo 3'te verilmiştir. Burada verilen sınıflandırma doğruluklarının tamamı, test kümesinden elde edilen doğruluklardır. SDD öznitelikleri 10 farklı dalgacık için çıkarılmış ve her biri için sınıflandırma doğrulukları hesaplanmıştır. En yüksek sınıflandırma doğruluğu Morlet ile %56.5 olarak elde edilirken, en düşük sonuç ReverseBior 3.5 ile %52.0 olarak hesaplanmıştır.

Tablo 2. SDD özniteliklerine ait sınıflandırma doğrulukları

Dalgacık Türü	Sınıflandırma Doğruluğu (%)
Daubechies 6	54.1
Daubechies 10	54.8
Coiflets 4	53.5
BiorSplines 1.1	52.2
ReverseBior 3.5	52
Meyer	55.2
Dmeyer	53.3
Gaussian 6	53.5
Symlets 6	53.5
Morlet	56.5

ÖBP öznitelikleri ise farklı ÖBP derecelerine göre elde edilerek en uygun ÖBP derecesi belirlenmiştir. Elde edilen sonuçlara göre en yüksek sınıflandırma doğruluğu 5. derece ile %90.7 olarak hesaplanırken, en düşük sonuç 13. derece ile %79.8 olarak hesaplanmıştır.

**Tablo 3.** ÖBP özniteliklerine ait sınıflandırma doğrulukları

ÖBP Derecesi	Sınıflandırma Doğruluğu (%)
5	90.7
6	90.2
7	87.5
8	89.7
9	86.8
10	84.7
11	84.2
12	83.2
13	79.8
14	82.6
15	81.2

SDD ve ÖBP özniteliklerinin birlikte kullanımlarından başka literatürde sıkılıkla kullanılan toplam band gücü (TBG), Hilbert Dönüşümü (HT), entropi (E) ve istatistiksel ( $\bar{I}$ ) özniteliklerin sınıflandırma performansına olan katkıları da ayrıca hesaplanmıştır. Burada istatistiksel öznitelikler ses işaretlerinin ortalaması, standart sapması, işaretin türevinin standart sapması ve basıklık değerleridir. Bu özniteliklerin birlikte kullanımına ait sınıflandırma doğruluğu sonuçları Tablo 4'te verilmiştir. Herbir doğruluk değerine karşılık, hangi özniteliklerinin kullanıldığı yeşil tik işaretiley gösterilmiştir. Bu sonuçlara göre SDD ve ÖBP'nin birlikte kullanımı en yüksek sınıflandırma doğruluğunu  $k=1$  değeri için %91.8 olarak sağlamıştır.

**Tablo 4.** Özniteliklerin hibrit kullanım sonuçları

ÖBP	✓	✓	✓	✓	✓	✓	✓
SDD	✓	✓	✓	✓	✓	✓	✓
TBG	✓	✓	✓	✓	✗	✗	✗
HD	✓	✓	✓	✗	✓	✗	✗
E	✓	✓	✗	✗	✗	✓	✗
$\bar{I}$	✓	✗	✗	✗	✗	✗	✗
Doğruluk (%)	80.6	37.8	91.3	90.9	91.5	37.8	91.8

#### 4. Bulgular

Çalışma kapsamında otomobil motor sesleri sınıflandırılarak araçlarda meydana gelebilecek arızaların örtülü tanıma ve makine öğrenmesi algoritmaları ile belirlenebileceği gösterilmiştir. Önerilen yöntem oluşturulan veri seti üzerine başarılı bir şekilde uygulanmış, SDD ve ÖBP öznitelikleri ve  $k$ -EYK sınıflandırıcısı ile %92 oranında sınıflandırma doğruluğu test verilerinde sağlamıştır. Özniteliklerin kolay hesaplanabilmesi ve literatürde daha önce dikkate alınmayan zamanlama zinciri ve vuruntu arızaları ile normal çalışma durumuna ait seslerin sınıflandırılması, çalışmayı benzerlerinden ayırmaktır ve literatüre katkı sağlamaktadır. Çalışmanın bir diğer önemli özelliği ise sadece 2 saniyelik motor sesinden sınıflandırma işlemini yapabilmesidir.

Önerilen yöntem otomobil marka ve modeli gözetmeksiz elde edilen motor seslerine uygulanmış olup, verilerin %40'ı yapay olarak oluşturulmuştur. Elde edilen sonuçlar, motor seslerinin sınıflandırılması için izlenmesi gereken yöntem konusunda fikir vermekte birlikte, yöntemin üretilen yapay seslerden arındırılması ve farklı sınıflandırma yöntemlerinin de işin içine dahil edilmesiyle tekrarlanması planlanmaktadır.

Gelecek çalışmalarda farklı arızalara ait sesler de veri setine eklenerek sınıf sayısı artırılacak ve hiçbir yapay ses oluşturulmadan önerilen yöntem test edilecektir. Bu şekilde sınıf sayısı artırılmış veri seti için Katz fraktal katsayıları ve Mel Kepstrum katsayıları öznitelikleri de eklenerek ileri öznitelik seçme algoritması ile etkin öznitelikler belirlenerek yüksek sınıflandırma doğruluğu elde edilecektir.

#### Teşekkür

Bu çalışma TÜBİTAK 2209-B programı kapsamında 1139B411901576 numaralı proje ile desteklenmiştir. Yazarlar, sanayi danışmanlığından ötürü Yılmaz Bilişim Ar-Ge Danışmanlık Yazılım Mühendislik ve Servis Hizmetleri Ticaret Limited Şirketi'ne teşekkür ederler.

#### Kaynakça

- [1] Kim, GB., Kim, WJ., Kim, HU. & Lee, SY. "Machine Learning Applications in Systems Metabolic Engineering", Current Opinion in Biotechnology, Vol. 64. August 2020, pp.1-9.
- [2] H. Liu, Z. Fu, K. Yang, X. Xu, M. Bauchy. "Machine Learning for Glass Science and Engineering: A review", Journal of Non-Crystalline Solids, 2019.
- [3] S. Amershi et al., "Software Engineering for Machine Learning: A Case Study," 2019 IEEE/ACM 41st International Conference on Software Engineering: Software Engineering in

- Practice (ICSE-SEIP), Montreal, QC, Canada, 2019, pp. 291-300.
- [4] T. Karatekin et al., "Interpretable Machine Learning in Healthcare through Generalized Additive Model with Pairwise Interactions (GA2M): Predicting Severe Retinopathy of Prematurity," 2019 International Conference on Deep Learning and Machine Learning in Emerging Applications (Deep-ML), Istanbul, Turkey, 2019, pp. 61-66.
- [5] F. Ahamed and F. Farid, "Applying Internet of Things and Machine-Learning for Personalized Healthcare: Issues and Challenges," 2018 International Conference on Machine Learning and Data Engineering (iCMLDE), Sydney, Australia, 2018, pp. 19-21.
- [6] J. Yoo, "On-chip epilepsy detection: Where machine learning meets patient-specific healthcare," 2017 International SoC Design Conference (ISOCC), Seoul, 2017, pp. 146-147.
- [7] A. Mir and S. N. Dhage, "Diabetes Disease Prediction Using Machine Learning on Big Data of Healthcare," 2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA), Pune, India, 2018, pp. 1-6.
- [8] S. Mirzaei, T. Sidi, C. Keasar and S. Crivelli, "Purely Structural Protein Scoring Functions Using Support Vector Machine and Ensemble Learning," in IEEE/ACM Transactions on Computational Biology and Bioinformatics, vol. 16, no. 5, pp. 1515-1523, 1 Sept.-Oct. 2019.
- [9] A. Hasan, O. Kalipsiz and S. Akyokuş, "Predicting financial market in big data: Deep learning," 2017 International Conference on Computer Science and Engineering (UBMK), Antalya, 2017, pp. 510-515.
- [10] R. Xu and M. He, "Application of Deep Learning Neural Network in Online Supply Chain Financial Credit Risk Assessment," 2020 International Conference on Computer Information and Big Data Applications (CIBDA), Guiyang, China, 2020, pp. 224-232,
- [11] E. A. Bayrak, P. Kirci and T. Ensari, "Comparison of Machine Learning Methods for Breast Cancer Diagnosis," 2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT), Istanbul, Turkey, 2019, pp. 1-3.
- [12] M. H. Memon, J. Li, A. U. Haq and M. Hunain Memon, "Early Stage Alzheimer's Disease Diagnosis Method," 2019 16th International Computer Conference on Wavelet Active Media Technology and Information Processing, Chengdu, China, 2019, pp. 222-225.
- [13] Z.K. Senturk, "Early Diagnosis of Parkinson's Disease Using Machine Learning Algorithms", Medical Hypotheses, Volume 138, May 2020, Article 109603.
- [14] M. I. Faisal, S. Bashir, Z. S. Khan and F. Hassan Khan, "An Evaluation of Machine Learning Classifiers and Ensembles for Early Stage Prediction of Lung Cancer," 2018 3rd International Conference on Emerging Trends in Engineering, Sciences and Technology (ICEEST), Karachi, Pakistan, 2018, pp. 1-4.
- [15] M. Nakhshi, A. Toffy, P. V. Achuth, L. Palanichamy and C. M. Vikas, "Early Prediction of Sepsis: Using State-of-the-art Machine Learning Techniques on Vital Sign Inputs," 2019 Computing in Cardiology (CinC), Singapore, Singapore, 2019, pp. Page 1-Page 4.
- [16] Kaya, U., Yılmaz, A. & Dikmen, Y. (2019). Sağlık Alanında Kullanılan Derin Öğrenme Yöntemleri. Avrupa Bilim ve Teknoloji Dergisi, (16), 792-808.
- [17] H. Yu, C. Liu and J. Liu, "Research on Intelligent Engine Fault Detection Method Based on Machine Learning," 2018 4th Annual International Conference on Network and Information Systems for Computers (ICNISC), Wuhan, China, 2018, pp. 419-423.
- [18] Z. Dongzhu, Z. Hua, D. Shiqiang and S. Yafei, "Aero-engine Bearing Fault Diagnosis Based on Deep Neural Networks," 2020 11th International Conference on Mechanical and Aerospace Engineering (ICMAE), Athens, Greece, 2020, pp. 145-149.
- [19] N. K. P. S. G. J. R. S. R and S. K. D, "Vibration Based IC Engine Fault Diagnosis Using Tree Family Classifiers - A Machine Learning Approach," 2019 IEEE International Symposium on Smart Electronic Systems (iSES) (Formerly iNiS), Rourkela, India, 2019, pp. 225-228.
- [20] J. Xu, X. Liu, B. Wang and J. Lin, "Deep Belief Network-Based Gas Path Fault Diagnosis for Turbofan Engines," in IEEE Access, vol. 7, pp. 170333-170342, 2019.
- [21] G. Zhong, H. Wang, K. Zhang and B. Jia, "Fault diagnosis of Marine diesel engine based on deep belief network," 2019 Chinese Automation Congress (CAC), Hangzhou, China, 2019, pp. 3415-3419.
- [22] R.F. Navea, E. Sybingco, "Design and Implementation of an Acoustic-Based Car Engine Fault Diagnostic System in the Android Platform", International Research Conference in Higher Education 2013, Oct, 2013.
- [23] J. Siegel, S. Kumar, I. Ehrenberg, E.S. Sarma, "Engine Misfire Detection With Pervasive Mobile Audio", Machine Learning and Knowledge Discovery in Databases: European Conference, Sept 19-23, 2016, Riva del Garda, Italy.
- [24] Y. Wang, Q.H. Ma, Q. Zhu, X.T. Liu, L.H. Zhao, "An intelligent approach for engine fault diagnosis based on Hilbert-Huang transform and support vector machine", Applied Acoustics, Vol. 75, Jan 2014, pp.1-9

- [25] A.K. Kemalkar, V.K. Bairagi, "Engine fault diagnosis using sound analysis", 2016 International Conference on Automatic Control and Dynamic Optimization Techniques (ICACDOT), Sept 9-10, 2016, Pune India, pp. 943-946.
- [26] M. Madain, A. Al-Mosaiden, M. Al-khassaweneh, "Fault diagnosis in vehicle engines using sound recognition techniques", 2010 IEEE International Conference on Electro/Information Technology, May 20-22, 2010, Normal, IL, USA.
- [27] L. Türkan, "Sürekli Dalgacık Dönüşümü ile Yüzey Ölçümü", Yüksek Lisans, Namık Kemal Üniversitesi Fen Bilimleri Enstitüsü, 2015, Tekirdağ, Türkiye, pp. 15-18.
- [28] H. Alp, T. Ç. Akıncı, M. Albora, "Jeofizik uygulamalarında fourier ve dalgacık dönüşümlerinin karşılaştırılması", Jurnal Of Engineering Sciences, Volume 14(1), 2008, pp. 67-76.
- [29] Feigelson Eric D., Babu G. Jogesh, Caceres Gabriel A., "Autoregressive Times Series Methods for Time Domain Astronomy", Frontiers in Physics, Volume 6(80), 2018, pp.2-3.
- [30] Saedsayad, "K Nearest Neighbors - Classification", website. [Online]. ([https://www.saedsayad.com/k\\_nearest\\_neighbors.htm](https://www.saedsayad.com/k_nearest_neighbors.htm)), Available as of November 15, 2020.