



POLİTEKNİK DERGİSİ

*JOURNAL of POLYTECHNIC*

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.gov.tr/politeknik>



# Güç kalitesi bozulmalarının 2 boyutlu ayrık dalgacık dönüşümü ve torbalama karar ağaçları yöntemi ile sınıflandırılması

## *Classification of power quality disturbances with 2D discrete wavelet transform and bagged decision trees method*

Yazar(lar) (Author(s)): Seçkin KARASU<sup>1</sup>, Zehra SARAÇ<sup>2</sup>

ORCID<sup>1</sup>: 0000-0001-5277-5252

ORCID<sup>2</sup>: 0000-0003-3330-5196

**Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article):** Karasu S. ve Saraç Z., “güç kalitesi bozulmalarının 2 boyutlu ayrık dalgacık dönüşümü ve torbalama karar ağaçları yöntemi ile sınıflandırılması”, *Politeknik Dergisi*, 21(4): 849-855, (2018).

**Erişim linki (To link to this article):** <http://dergipark.gov.tr/politeknik/archive>

**DOI:** 10.2339/politeknik.391795

# Güç Kalitesi Bozulmalarının 2 Boyutlu Ayrık Dalgacık Dönüşümü ve Torbalama Karar Ağaçları Yöntemi ile Sınıflandırılması

*Araştırma Makalesi / Research Article*

**Seçkin KARASU, Zehra SARAC\***

Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Zonguldak, Türkiye

(Geliş/Received : 07.07.2017 ; Kabul/Accepted : 11.09.2017)

## ÖZ

Bu çalışmada, Güç Kalitesi (GK) bozulmalarının sınıflandırılması için 2 Boyutlu Ayrık Dalgacık Dönüşümü (2B-ADD) yöntemi ile öznelikler çıkartılmakta ve Destek Vektör Makineleri (DVM), Yapay Sinir Ağları (YSA) ve Torbalama Karar Ağaçları (TKA) yöntemleri ile sınıflandırma işlemi yapılmaktadır. Gürültülü (40 dB, 30 dB ve 20 dB) ve gürültüsüz durumları içeren 11 farklı GK bozulması için toplamda 2200 adet sinyal sentetik olarak üretilmektedir. Sinyaller 2 boyutlu görüntü matrislerine çevrilmekte ve her birine 2B-ADD uygulanmaktadır. Farklı ayrıştırma seviyesi ve istatistiksel özellikler uygulanarak öznelikler oluşturulmaktadır. Özneliklerden en uygun olanları Sıralı İleri Seçim (SİS) ve ReliefF yöntemleri ile seçilmektedir. Benzetim çalışmasına göre 3 farklı sınıflandırıcının başarımı birbirleri ile kıyaslanmaktadır. Sıralı ileri seçim ile seçilen öznelikleri kullanan TKA yönteminin %99.12±0.12 oranı ile en iyi başarımı veren yöntem olduğu görülmektedir.

**Anahtar Kelimeler:** Güç kalitesi, 2 boyutlu ayrık dalgacık dönüşümü, torbalama karar ağaçları sınıflandırıcısı, sıralı ileri seçim, ReliefF.

## Classification of Power Quality Disturbances with 2D Discrete Wavelet Transform and Bagged Decision Trees Method

### ABSTRACT

In this study, to classify Power Quality (PQ) disturbances, attributes are extracted by 2D Discrete Wavelet Transform (2D-DWT) method and Support Vector Machines, Artificial Neural Networks and Bagged Decision Trees (BDT) methods are used for classification stage. 2200 signals are synthetically produced for 11 different PQ disturbances, including noisy (40 dB, 30 dB and 20 dB) and noiseless states. Signals are transformed into 2D image matrices and 2D DWT is applied to each. Attributes are created by applying different level of decomposition and statistical properties. The most appropriate ones are selected with Sequential Forward Selection (SFS) and ReliefF methods. BDT method, which uses selected attributes with SFS, is the method that gives the best performance with a rate of 99.12±0.12%.

**Keywords:** Power quality, 2D discrete wavelet transform, bagged trees classifier, sequential forward selection, ReliefF

### 1. GİRİŞ (INTRODUCTION)

Son zamanlarda elektrik şebekesinde yenilenebilir enerji kaynaklarının, ileri hızlı kontrol donanımlarının ve karmaşık sistem bağlantılarının kullanımının artması, Güç Kalitesi (GK) bozulmalarında artışa sebep olmakta ve bu durum konut, sanayi ve akademik alanlarda kritik bir sorun olarak ortaya çıkmaktadır [1, 2]. GK bozulmaları, elektrik şebekesinin ekonomik işletilmesini olumsuz etkilemektedir [3]. Mevcut şebekelerin akıllı şebekelere dönüşmeye başladığı günümüzde, hem üreticilerin hem de tüketicilerin yüksek GK seviyesine ulaşmalarını sağlamak için otomatik olarak GK'nın izlenmesi, bozulmaların tanınması ve sınıflandırılması önemli olmaktadır [3, 4].

GK bozulmalarını ayırt etmek için her bir bozulmayı temsil edecek özellikler belirlenmelidir [4]. Literatürde sinyal işleme yöntemleri ile ayırt edici öznelikler çıkartılmakta ve bunlar sınıflandırma aşamasında kullanılmaktadır [4, 5]. Ayrık Fourier Dönüşümü (AFD), Kısa Zamanlı Fourier Dönüşümü (KZFD), Dalgacık Dönüşümü (DD), Stockwell Dönüşümü (SD), Hilbert Dönüşümü (HD) ve Gabor Dönüşümü (GD) [4, 5] gibi sinyal işleme yöntemleri GK bozulmalarından özneliklerin çıkartılması için kullanılmaktadır. Sınıflandırma aşamasında oluşturulacak modelin karmaşıklığını azaltmak ve sınıflandırma başarımını yükseltmek amacıyla çıkartılan özneliklerden en uygun olanları seçilmektedir [5, 6]. Makine öğrenmesinde filtreleme ve sarmalama gibi öznelik seçme yaklaşımları mevcuttur [7]. Filtreleme yaklaşımında sınıflandırma yöntemi uygulanmadan önce en uygun öznelikler korelasyon tabanlı belirlenmektedir. Sarmalama yaklaşımında ise sınıflandırma performansı

\*Sorumlu Yazar (Corresponding Author)  
e-posta : zehrasarac@beun.edu.tr

göz önünde bulundurularak en uygun öznelik vektörü belirlenmektedir. Literatürde Bilgi Kazancı, Ki-Kare, ReliefF, F-Skor gibi filtreleme yöntemleri ile Sıralı İleri Seçim (SİS), Sıralı Geri Seçim (SGS), Genetik Algoritma (GA), Parçacık Sürü Optimizasyonu (PSO), Karınca Koloni Optimizasyonu (KKO) gibi sarmalama tabanlı öznelik seçme yöntemleri bulunmaktadır [5-7]. Karar Ağaçları (KA), Naive Bayes (NB), k-En Yakın Komşu (k-EYK), Destek Vektör Makineleri (DVM), Yapay Sinir Ağları (YSA) [18], Hibrid ve Kolektif Öğrenme yaklaşımları gibi sınıflandırma yöntemleri mevcuttur [8, 9].

Literatürde GK bozulmalarını temsil eden özneliklerin çıkartılması aşamasında bir boyutlu sinyal işleme yöntemleri kullanılmaktadır. Bu çalışmanın da temelini oluşturan sinyal işleme yöntemi olarak 2B-ADD [10-12] çalışmaları mevcuttur. Ece ve Gerek yaptıkları çalışmada GK bozulma verisi üzerinde bir periyot boyunca değişim gösteren dalga şekillerini 2 boyutlu görüntü matrisine çevirmişlerdir. Daha sonra 2B-ADD, GK bozukluklarını tespit etmek için kullanmışlardır. Çalışmada önerdikleri yöntemin gerilim yükselmesi, gerilim kesintisi ve harmonikli durumlar gibi sinyalleri ayırt etmede önemli özellikler sergilediğini göstermiş olmalarına rağmen herhangi bir sınıflandırma algoritması ile performans incelemesi yapmamışlardır [10]. Shareef ve arkadaşları, 150 adet 8 çeşit GK bozulma verisini önerdikleri görüntü işleme tabanlı yöntem ile sınıflandırmışlardır. Önce 1 boyutlu veriyi 2 boyutlu gri görüntü verisine çevirmişler daha sonra Ayrık Dalgacı Dönüşümü (ADD) ile Yatay, Dikey ve Diyagonal detay katsayılarını elde etmişlerdir. [10]'daki gibi elde ettikleri öznelik dalga formunun büyüklüğü ve süresine bağlı olarak sınıflandırma yapmışlardır. Bu yöntemin %97.33 oranında başarımlı sağladığını göstermişlerdir. Sonrasında Gama Doğrulaması (Gamma Corection), Kenar Belirleme (Edge Detection), Doruklar ve Vadiler (Peaks and Valleys) tanıma yöntemleri ile özellik çıkartımı yapıp bu morfolojik özelliklere dayalı sınıflandırma yapmışlardır. Sınıflandırıcı başarımlarını [10]'daki yöntemle elde ettikleri ile kıyaslama yaparak, sınıflandırma başarımlarını önerdikleri yöntem ile %99.33 olarak bulmuşlardır [11].

Krishna ve Kaliaperumal yaptıkları çalışmada 1 boyutlu GK bozulma verisini 2 boyutlu veriye çevirip, bu matrisi 2B-ADD yöntemi ile Yaklaşık, Yatay, Dikey ve Diyagonal olmak üzere 4 alt banda ayırmışlardır. Daha sonra 8 çeşit sınıf içeren 2000 veri üzerinde çıkarttıkları özellikleri kullanarak Karar Ağaçları Sınıflandırıcısı ile sınıflandırma işlemini yapmışlardır. Sınıflandırıcı başarımlarını 1 boyutlu ADD (1B-ADD) ile kıyaslamışlardır. Önerdikleri yöntemin %98,98'lik bir başarımlı olduğunu göstermişlerdir (1B-ADD için bu oran %94.3). Daha sonra bozulma türlerinin ikili veya üçlü olacak şekilde gerçekleşmesi durumu içinde bir çalışma yapmışlardır. 16 farklı sınıf içeren 480 veri üzerinde 1B-ADD, 2B-ADD ve 1 Boyutlu Stockwell Dönüşümü (1B-SD) yöntemleri ile sırası ile %81.04, %97.29 ve %97.91'lik sınıflandırıcı başarımlı elde etmişlerdir. Önerdikleri yöntemin 1D-SD sonucuna yakın olduğunu bulmuşlardır. Yüksek örnekleme frekansında

çalışma durumunda, dağıtık bilgisayarlar ve paralel işlemciler veya FPGA ve GPU gibi özelleştirilmiş işlemciler kullanılarak işlem yükünün azaltılabileceğini önermişlerdir [12].

Diğer bir sinyal işleme yaklaşımını kullanan Uyar ve arkadaşları yaptıkları çalışmada S-dönüşümü ve yerel ikili örüntüler yöntemi ile 8 farklı güç kalitesi bozulma çeşidini ayırmak için bir çalışma yapmışlardır. Sinyallere SD uygulamışlar, daha sonra ön işlem yaparak gri seviyeli görüntü elde etmişlerdir. Gri görüntülü sinyallerden ikili görüntüye yerel ikili örüntüler yaklaşımı ile geçiş yapmışlardır. Bu dönüşüm ile histogram şeklinde bir öznelik vektörü elde edilmiştir. YSA ile sınıflandırma yapmışlar ve 10-katlamalı çapraz doğrulama ile oluşturdukları modeli test etmişlerdir. Sonuçta 8 sınıf için %98.12'lik bir başarımlı elde etmişlerdir [13].

Bu çalışmada, 2B-ADD yöntemi ve istatistiksel özellikler ile güç kalitesi bozulmalarından gerekli öznelikler çıkartılmaktadır. Öznelik seçiminde SİS ve ReliefF yöntemleri sırasıyla uygulanmaktadır. Sınıflandırma adımı DVM, YSA ve TKA yöntemleri ile en yüksek başarımlı sınıflandırıcı oluşturulmaktadır. 2B-ADD yönteminde 1., 2. ve 3. seviye ayırıştırma için SİS yöntemi ile seçilen öznelikleri kullanan TKA sınıflandırıcısının genel başarımlı %99.12±0.12 olarak elde edilmektedir. 2B-ADD ve TKA yöntemlerine dayalı GK bozulmalarını sınıflandıran bu modelin, literatürdeki görüntü işlemeye dayalı modellerle kıyaslaması yapılmaktadır. Önerilen modelin 11 farklı GK bozulması ile en çok sınıf içeren sınıflandırıcı modeli olmasına rağmen, diğer yöntemlere göre başarımlarının oldukça yüksek olduğu görülmektedir. Çalışmada kullanılan yöntemler II. bölümde açıklanmakta, farklı ayırıştırma seviyelerinin uygulandığı ve en iyi özneliklerin seçilerek farklı sınıflandırma modellerinin başarımları III. bölümde kıyaslanmakta ve IV. bölümde sonuçlar değerlendirilmektedir.

## 2. MODELLER VE YÖNTEMLER (MODELS AND METHODS)

### 2.1. Veri seti (Dataset)

Çalışmada, 11 farklı GK bozulma durumunu içeren 2200 adet sinyal matematiksel eşitliklere dayalı olarak oluşturulmaktadır [9]. Standartlarla belirlenmiş olan GK olayları, normalize genliğe sahip ve 50 Hz şebeke frekansı temel alınarak üretilmektedir. Tek bir sinyal, satır ve sütun sayısı eşit 2 boyutlu bir matris haline dönüştürülebiilen 1600 adet veri noktası içermektedir. Sinyalin örnekleme frekansı 8 kHz olmaktadır. Her bir sinyalde 10 periyot bulunmaktadır. Gürültüsüz ve 40 dB, 30 dB ve 20 dB Gauss gürültü seviyesi içeren sinyaller eşit miktarda üretilmektedir. Sinyal çeşitleri için sınıf etiketleri ve sinyal sayıları Çizelge 1.'deki gibi verilmektedir.

**Çizelge 1.** GK bozulmaları için sınıf etiketleri ve sayıları (Class tags and numbers for PQ disturbances)

Etiket	Sinyal Çeşidi	Sinyal Adedi
S1	Sinüoidal Sinyal	200
S2	Gerilim Düşmesi	200
S3	Gerilim Yükselmesi	200
S4	Gerilim Kesintisi	200
S5	Gerilim Titreşimi	200
S6	Geçici Sahnımlı Durum	200
S7	Harmonikli Durum	200
S8	Gerilimde Çentik	200
S9	Gerilimde Ani Yükseliş	200
S10	Harmonikli Gerilim Düşmesi	200
S11	Harmonikli Gerilim Yükselmesi	200

## 2.2. Veri Önileme (Data pre-processing)

Veri önileme, veri içerisinde gürültü bileşenlerinin, tutsuz, eksik veya kayıp verinin temizlenmesi amacıyla yapılmaktadır [7]. Benzetim çalışmasında GK bozulma sinyallerindeki özellikleri kaybetmeyen ancak gürültü bileşenlerini azaltan Butterworth alçak geçiren filtre uygulanmaktadır.

## 2.3. Öznitelik Çıkartma (Feature Extraction)

### 2.3.1 RMS ve THD Hesabı (Calculation of RMS and THD)

RMS (Kare Ortalamalarının Karekökü) değeri, sinyal üzerinde ( $V_s$ ) N adet noktanın karelerinin toplamının ortalaması karekökü alınarak hesaplanmaktadır. Bu ifade Eşitlik 1 ile verilmektedir.

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N (V_s(n))^2} \quad (1)$$

THD (Toplam Harmonik Bozunum) hesabı, sinyal üzerinde n. harmonik değerinin RMS değerlerinin karesinin toplamının karekökü, temel frekansın RMS değerine ( $V_{temel}$ ) oranlanması ile yapılmaktadır. Bu ifade Eşitlik 2 ile verilmektedir.

$$THD = \sqrt{\frac{\sum_{n=2}^N (V_{rms}(n))^2}{V_{temel}}} \quad (2)$$

### 2.3.2 İki Boyutlu Ayrık Dalgacık Dönüşümü (2D Discrete Wavelet Transform)

2B-ADD kullanarak, iki boyutlu ölçeklendirme fonksiyonu  $\varphi(x,y)$  ve üç adet iki boyutlu dalgacık fonksiyonu  $\psi^H(x,y)$ ,  $\psi^V(x,y)$  ve  $\psi^D(x,y)$  elde edilebilir [14]. Bu fonksiyonlar, her biri tek boyutlu bir ölçekleme fonksiyonuna ( $\varphi$ ) bağlı olan dalgacık fonksiyonlarıdır ( $\psi$ ). Tek boyutlu bu dalgacık fonksiyonları, farklı yönlerdeki etkileri dikkate alınarak ayrılabilir ölçeklendirme parametresine bağlı olarak Eşitlik 3-6 ile ifade edilmektedir [12, 14].

$$\varphi(x,y) = \varphi(x)\varphi(y) \quad (3)$$

$$\psi^H(x,y) = \psi(x)\varphi(y) \quad (4)$$

$$\psi^V(x,y) = \varphi(x)\psi(y) \quad (5)$$

$$\psi^D(x,y) = \varphi(x)\varphi(y) \quad (6)$$

Eşitlik 4-6 ile ifade edilen dalgacıklar iki boyutlu görüntü üzerinde yatay ( $\psi^H$ ), dikey ( $\psi^V$ ), diyagonal ( $\psi^D$ ) değişimleri ortaya koymaktadırlar.

Ayrılabilir iki boyutlu ölçekleme ve frekansa bağlı olan dalgacık fonksiyonları Eşitlik 7-8 ile yazılmaktadır.

$$\varphi_{j,m,n}(x,y) = 2^{j/2} \varphi(2^j x - m, 2^j y - n) \quad (7)$$

$$\psi_{j,m,n}^i(x,y) = 2^{j/2} \psi^i(2^j x - m, 2^j y - n) \quad (8)$$

Eşitlik 8'de i terimi H, V veya D değerlerinden birini ifade etmektedir ( $i=\{H,V,D\}$ ). M ve N boyutlarındaki  $f(x,y)$  fonksiyonunun ADD'si Eşitlik 9-10 ile verilebilir.

$$W_\varphi(j_0, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x,y) \varphi_{j_0,m,n}(x,y) \quad (9)$$

$$W_\psi^i(j, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x,y) \psi_{j,m,n}^i(x,y) \quad (10)$$

Normalde  $j_0 = 0$  olsun,  $j=0,1,2,\dots,J-1$  ve  $m,n=0,1,2,\dots,2^j-1$  olacak şekilde  $m,n=0,1,2,\dots,2^j-1$  seçelim. Bu eşitliklerdeki  $j_0$  ölçek fonksiyonu için keyfi bir başlangıç noktasını,  $W_\varphi(j_0, m, n)$  katsayıları ise  $j_0$  ölçeğinde  $f(x,y)$  fonksiyonu için yaklaşık katsayısını ve  $W_\psi^i(j, m, n)$  yatay, dikey ve diyagonal detay katsayılarını  $j \geq j_0$  koşulu için ifade etmektedir [14].

## 2.4. Öznitelik Seçme Yöntemleri (Feature Selection Methods)

### 2.4.1. Sıralı İleri Seçim (SİS) (Sequential Forward Selection-SFS)

Bu yöntemde, başlangıç öznitelik kümesi boş küme seçilmekte ve sırasıyla öznitelikler eklendikçe kriter değeri hesaplanmaktadır [6]. Bu yöntemde ilk seçilen en önemli öznitelik olmaktadır. Her bir adımda kriter değeri hesaplanmakta ve bu değer sıfır olana kadar iterasyona devam edilmektedir [6]. Koşul sağlandığında en uygun öznitelik kümesi bulunmaktadır.

### 2.4.2. ReliefF Yöntemi (ReliefF Method)

Bu yöntem veri madenciliği uygulamalarında sınıflandırma ve regresyon analizinde özniteliklerin seçilmesinde kullanılmaktadır [6].

ReliefF algoritmasındaki temel amaç, değerleri birbirine yakın örnekler arasında ne kadar iyi ayırt edildiğine göre özniteliklerin kalitesini tahmin etmektir [15, 16]. Rastgele seçilmiş örnek sayısı R olmak üzere, algoritma iki en yakın komşu için arama yapmaktadır. Bunlardan ilki aynı sınıftan en yakın komşuyu ifade eden H ve farklı sınıftan en yakın komşuyu ifade eden M olarak tanımlanır. Aynı ve farklı sınıftan en yakın komşuları hesaplamak için çok boyutlu öklit uzaklığı kullanılmaktadır. R, M ve H değerlerine bağlı A öznitelikleri için tahmin edilen  $W[A]$  ağırlık katsayısı güncellenmekte ve ağırlık katsayılarının bulunması için m kez çalıştırılmak-

tadır [15]. İki ayrı örnek için öznitelik değerleri arasındaki fark diff fonksiyonu ile hesaplanmakta ve  $W[A]$  öznitelik kalitesi Eşitlik 11 ile verilmektedir.

$$W_{yeni}[A] = W_{eski}[A] - \frac{\text{diff}(A, R, H)}{m} + \frac{\text{diff}(A, R, M)}{m} \quad (11)$$

Yöntem Kononenko tarafından, tamamlanmamış, gürültülü verilere toleranslı ve çoklu sınıf içeren problemlerin çözümü için uyarlanmıştır [17].

## 2.5 Sınıflandırma Yöntemleri (Classification Methods)

### 2.5.1. Destek Vektör Makineleri (DVM) (Support Vector Machines-SVM)

DVM son zamanlarda veri sınıflandırma ve regresyon problemleri için kullanılan güçlü bir veri madenciliği aracıdır [5, 7]. 2 farklı DVM sınıflandırıcı kombinasyonu ile çoklu sınıf içeren problemlere çözüm aranmaktadır [5]. DVM, iki grubun üyelerini birbirine en uzak olacak şekilde ayıran sınır çizgisini bulmaya çalışmaktadır [7].

### 2.5.2. Yapay Sinir Ağları (YSA) (Artificial Neural Networks-ANN)

Farklı karmaşık ve gerçek dünya problemini çözmek amacıyla YSA tabanlı yöntemler kullanılmaktadır. Sinir ağı tabanlı sınıflandırma yöntemi, kendi kendini ayarlayabilme, öğrenebilme yeteneğine sahip, veri ilişkilerini bilmesine gerek olmadan farklı modellere uygulanabilme gibi ayırt edici özelliklere sahiptir [4]. Giriş ve çıkış arasında bir gösterimin olmadığı, örüntü tanıma, sınıflandırma [18], regresyon [19, 20] analizlerinde kullanılmaktadır.

### 2.5.3. Torbalama Karar Ağaçları (TKA) (Bagged Decision Trees-BDT)

Kolektif öğrenme yöntemi olan torbalama karar ağacı sınıflandırıcısı, birlikte çalışan sınıflandırma algoritmalarını kullanarak başarıyı arttırmaya yönelik olarak düzenlenmektedir [7]. Tekil öğrenci yerine, temel öğrenciden birden fazla kopya bir karar ağacı oluşturmakta ve sınıflandırıcı çıkışı oylama tekniği ile birleştirilmektedir [7].

## 2.6. K-Katlamalı Çapraz Doğrulama (K-fold Cross Validation)

K katlamalı çapraz doğrulama, X veri kümesi rastgele olmak üzere, K tane eşit büyüklükte parçalara

bölünmekte ve her katta biri doğrulama diğerleri eğitim amaçlı olarak kullanılmaktadır. Oluşturulan K adet sınıflandırma başarımının ortalaması alınarak sistemin genel başarımı hesaplanmaktadır [7].

## 2.7. Başarım Ölçütü (Performance Measure)

Oluşturulan sınıflandırıcının ne kadar başarılı olduğunu Eşitlik 12'deki başarım ölçütü ifadesi ile hesaplamak mümkündür [7]. Bu eşitlikteki TP ve TN sırasıyla doğru pozitif ve doğru negatifleri, FP ve FN ise yanlış pozitifleri ve yanlış negatifleri temsil etmektedir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$

## 3. BENZETİM SONUÇLARI (SIMULATION RESULTS)

Benzetim çalışması için MATLAB programı kullanılmaktadır. Matematiksel eşitlikler ile 2200 adet GK bozulma verisi üretilmektedir. 1. ve 2. öznitelikler sırası ile RMS ve THD değerleri olmaktadır. 2B-ADD'de Db1 (Daubechies-1) ana dalgası kullanılmakta ve 1. 2. ve 3. seviye ayrıştırma için inceleme yapılmaktadır. 2B-ADD sonucunda oluşan Yatay, Dikey, Diyagonal ve Yaklaşık katsayı matrisleri için ağırlıklı, harmonik ve geometrik ortalama, standart sapma, çarpıklık, basıklık gibi istatistiksel özellikler hesaplanmaktadır. Dönüşüm sonucunda oluşan katsayı matrisleri için En Yüksek Satır Vektörü (EYSaV) ve En Yüksek Sütun Vektörü (EYSüV) oluşturulmaktadır. EYSaV ve EYSüV için sırasıyla ağırlıklı ortalama, standart sapma ve norm entropi değerleri hesaplanmaktadır.

Zaman bölgesine dayalı RMS ve THD değerleri ile 2B-ADD analizi sonucu oluşan istatistik tabanlı değerler birlikte düşünüldüğünde, sadece 1. seviye ayrıştırma için 50 adet, 1. seviye ve 2. seviye ayrıştırma için 98 adet ve 1. seviye, 2. seviye, 3.seviye ayrıştırma için toplamda 146 adet öznitelik oluşturulmaktadır. Çizelge 2.'de tüm öznitelikler ve öznitelik indisleri verilmektedir.

Ayrıştırma seviyesinin artırılması ile amaçlanan, seçilen öznitelikler ve oluşturulan farklı sınıflandırıcılar için en yüksek başarıyı veren modeli ortaya çıkartmaktır. Karmaşıklığı azaltmak ve başarıyı yüksek sınıflandırıcı


Çizelge 2. Oluşturulan öznitelikler ve öznitelik indisleri (Created features and their indices)

İstatistiksel Özellikler	$I_1^V$	$I_1^H$	$I_1^D$	$I_1^A$	$I_2^V$	$I_2^H$	$I_2^D$	$I_2^A$	$I_3^V$	$I_3^H$	$I_3^D$	$I_3^A$
Ağırlıklı Ortalama	3	15	27	39	51	63	75	87	99	111	123	135
Harmonik Ortalama	4	16	28	40	52	64	76	88	100	112	124	136
Geometrik Ortalama	5	17	29	41	53	65	77	89	101	113	125	137
Standart Sapma	6	18	30	42	54	66	78	90	102	114	126	138
Çarpıklık	7	19	31	43	55	67	79	91	103	115	127	139
Basıklık	8	20	32	44	56	68	80	92	104	116	128	140
EYSaV Ağırlıklı Ortalama	9	21	33	45	57	69	81	93	105	117	129	141
EYSaV Standart Sapma	10	22	34	46	58	70	82	94	106	118	130	142
EYSaV Norm Enerji	11	23	35	47	59	71	83	95	107	119	131	143
EYSüV Ağırlıklı Ortalama	12	24	36	48	60	72	84	96	108	120	132	144
EYSüV Standart Sapma	13	25	37	49	61	73	85	97	109	121	133	145
EYSüV Norm Entropi	14	26	38	50	62	74	86	98	110	122	134	146


(1;RMS, 2:THD)

modeli oluşturmak için SİS ve ReliefF yöntemleri ile en iyi öznelikler seçilmektedir. DVM, YSA ve TKA yöntemleri ile her bir durumda seçilen öznelikler için modeller oluşturulmakta ve 10-katlamalı çapraz doğrulama ile sınıflandırıcı başarımları ölçülmektedir.

Şekil 1. ve Şekil 3.'te sırasıyla SİS ve ReliefF yöntemlerinin, her bir iterasyon sonucu kriter değeri değişiminin 2B-ADD analizinde farklı ayırıştırma seviyesi durumlarındaki değişimi verilmektedir. SİS yöntemi için genel olarak iterasyon sayısının artırılması ve 3. seviye ayırıştırmanın da dahil edilmesi ile kriter değerinin azaldığı ve en düşük kaldığı görülmektedir.



**Şekil 1.** SİS yöntemi için her bir iterasyondaki kriter değeri değişimi (Change of the criterion value in each iteration for SFS method)




**Şekil 2.** SİS yöntemi için ağırlık değerlerine göre sıralanmış öznelikler (Features ordered by weights for SFS method)

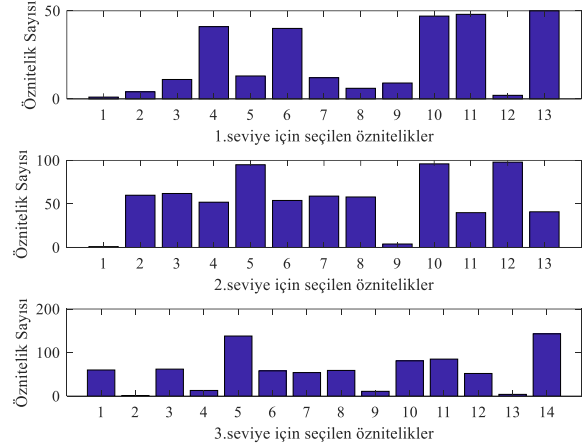
ReliefF yöntemi için iterasyon sayısının artırılması ile kriter değeri azalmakta ancak 1. seviye için kriter değeri en düşük kalmaktadır. Her bir iterasyonda sırasıyla seçilen özneliklerin indisleri SİS ve ReliefF yöntemleri için sırasıyla Şekil 2. ve Şekil 4.'te verilmektedir.

DVM için çekirdek fonksiyonu Polinom ve çoklu sınıf modeli Bire Bir (One vs One) olarak seçilmektedir. YSA için giriş katmanı nöron sayısı 1 ile 14 arasında, gizli katman nöron sayısı 1 ile 60 arasında değiştirilmekte ve çıkış katmanı nöron sayısı 11 olmaktadır. Aktivasyon

fonksiyonları Tan-Sigmoid, Soft-Max olarak seçilmektedir. Eğitim aşamasında Momentumlu Gradyan azalan algoritması kullanılmakta ve Epoch sayısı 1000 olarak alınmaktadır. Kolektif öğrenme yöntemi Torbalama (Bagging) yöntemi ve temel öğrenicisi Karar Ağaçları sınıflandırıcı olan TKA için 30 adet öğrenici kopyası oluşturulmaktadır. İki farklı yöntemle seçilen öznelikler ve farklı ayırıştırma seviyeleri için DVM, YSA ve TKA yöntemleri ile sınıflandırma başarımları sonuçları Çizelge 3.'teki gibi verilmektedir.



**Şekil 3.** ReliefF yöntemi için her bir iterasyondaki kriter değeri değişimi (Change of the criterion value in each iteration for ReliefF method)



**Şekil 4.** ReliefF yöntemi için ağırlık değerlerine göre sıralanmış öznelikler (Features ordered by weights for ReliefF method)

**Çizelge 3.** Sınıflandırma yöntemlerinin başarımları (Performances of classification methods)

2B ADD Analizi	Öznelik Seçme Yöntemleri	Sınıflandırma Yöntemleri		
		DVM	TKA	YSA
1-seviye	SİS	97.94±0.11	98.54±0.13	98.23±0.11
	ReliefF	97.90±0.14	98.17±0.21	98.09±0.15
1 ve 2-seviye	SİS	98.62±0.10	98.75±0.14	98.53±0.08
	ReliefF	94.21±0.22	93.63±0.34	92.07±0.46
1, 2, 3-seviye	SİS	98.41±0.11	99.12±0.12	98.60±0.05
	ReliefF	97.28±0.19	97.75±0.22	97.10±0.07

Çizelge 3.'ten, genel olarak SİS ile seçilen özneliklerin Relief yöntemi ile seçilenlere göre yüksek başarımlı sağladığı görülmektedir. DVM yönteminin en yüksek başarımlı, 1. ve 2. seviye ayrıştırma için SİS ile seçilen özneliklerin kullanıldığı durumda %98.62±0.10 olarak bulunmaktadır. YSA yönteminde ise en yüksek başarımlı, 1., 2. ve 3. seviye ayrıştırma için SİS ile seçilen özneliklerin kullanıldığı durumda %98.60±0.05 olarak ortaya çıkmaktadır. YSA yönteminin DVM'ye göre ayrıştırma seviyesi arttırıldığında başarımlı olarak yakaladığı görülmektedir. 1., 2. ve 3. seviye ayrıştırma için üretilen ve SİS ile seçilen öznelikler için TKA yöntemi, %99.12±0.12 oranı ile en yüksek sınıflandırıcı başarımlı yakalamaktadır. Çizelge 4.'te en iyi modelin giriş olarak aldığı özneliklerin hangi ayrıştırma seviyelerinden geldiği görülmektedir. Zaman

bölgesinden 2 adet ve ADD analizinde 1. seviye ayrıştırmadan 6, 2. seviyeden 4 ve 3. seviyeden 2 adet olmak üzere toplamda 14 adet öznelik SİS yöntemi ile seçilmektedir. Çizelge 5.'te ise en iyi model olan TKA yöntemi için sınıflandırma başarımlı karışıklık matrisi ile sunulmaktadır. Bu yöntem, S2 sınıfını %97.5 oranı ile en düşük oranda, S1, S7 ile S8 sınıflarını ise %100 oranında sınıflandırmaktadır.

Çizelge 6.'da çalışmada ortaya çıkan sınıflandırıcının başarımlının, iki boyutlu görüntü işlemeye dayalı olarak önerilen diğer yöntemlerle kıyaslanması yapılmaktadır.

Literatürdeki sonuçlara göre oluşturulan model, 11 farklı GK bozulması ile en çok sınıf içeren sınıflandırıcı modeli olmasına rağmen, diğer yöntemlere göre başarımlının oldukça yüksek olduğu görülmektedir.

**Çizelge 4.** 2B-ADD analizinde 1., 2. ve 3. seviye ayrıştırma seviyeleri için SİS yöntemi ile seçilen öznelikler (Selected features by SFS method for 1st, 2nd and 3rd level decompositions in 2D-DWT analysis)

İstatistiksel Özellikler	I <sub>1</sub> <sup>V</sup>	I <sub>1</sub> <sup>H</sup>	I <sub>1</sub> <sup>D</sup>	I <sub>1</sub> <sup>A</sup>	I <sub>2</sub> <sup>V</sup>	I <sub>2</sub> <sup>H</sup>	I <sub>2</sub> <sup>D</sup>	I <sub>2</sub> <sup>A</sup>	I <sub>3</sub> <sup>V</sup>	I <sub>3</sub> <sup>H</sup>	I <sub>3</sub> <sup>D</sup>	I <sub>3</sub> <sup>A</sup>
Ağırlıklı Ortalama	3	15	27	39	51	63	75	87	99	111	123	135
Harmonik Ortalama	4	16	28	40	52	64	76	88	100	112	124	136
Geometrik Ortalama	5	17	29	41	53	65	77	89	101	113	125	137
Standart Sapma	6	18	30	42	54	66	78	90	102	114	126	138
Çarpıklık	7	19	31	43	55	67	79	91	103	115	127	139
Baskılık	8	20	32	44	56	68	80	92	104	116	128	140
EYsAv Ağırlıklı Ortalama	9	21	33	45	57	69	81	93	105	117	129	141
EYsAv Standart Sapma	10	22	34	46	58	70	82	94	106	118	130	142
EYsAv Norm Enerji	11	23	35	47	59	71	83	95	107	119	131	143
EYSüV Ağırlıklı Ortalama	12	24	36	48	60	72	84	96	108	120	132	144
EYSüV Standart Sapma	13	25	37	49	61	73	85	97	109	121	133	145
EYSüV Norm Entropi	14	26	38	50	62	74	86	98	110	122	134	146
Seçilen	2	2	2		3			1	1	1		

(1:RMS, 2:THD)

**Çizelge 5.** En iyi model olan TKA için karışıklık matrisi (Confusion matrix for the best model BDT)

S1	200											100
S2		195		4								97.5
S3	1		196		3							98
S4				199							1	99.5
S5					200							100
S6	4					196						98
S7							200					100
S8								200				100
S9	1		1						198			99
S10		2								198		99
S11			1								199	99.5
												99.14
	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	

Tahmin Edilen Sınıf

**Çizelge 6.** Önerilen yöntemin literatürdeki çalışmalar ile kıyaslanması (Comparison of the proposed method with the studies in the literature)

Çalışmalar	Sınıf	Sinyal İşleme Yöntemi	Sınıflandırma Başarımlı
[10]	4 adet	2B-ADD	-
[11]	8 adet	Gama Doğrulaması, Kenar Belirleme, Doruklar Vadiler	%99.33
[12]	7 adet	2B-ADD	%98.98
[13]	8 adet	1D S-Dönüşümü, Yerel İkili Örüntüler	%98.12
<b>Bu çalışma</b>	11 adet	2B-ADD	%99.12±0.12

#### 4. SONUÇ (CONCLUSION)

Bu çalışmada, farklı parametrelere dayalı matematiksel eşitlikler yardımı ile rastgele üretilmiş 2200 adet GK bozulmasının 2B-ADD ile ayırt edici özellikleri oluşturulmakta, SİS ve Relief yöntemleri ile oluşturulan özneliklerden en uygun olanları seçilmekte ve DVM, YSA ve TKA yöntemleri ile sınıflandırılması yapılmaktadır. Sinyallerden doğrudan alınan RMS ve THD değerleri de özneliklere eklenmekle birlikte, ADD analizinde 1., 2. ve 3. seviye ayırıştırma ile sırasıyla 50, 98 ve 146 adet öznelik istatistiksel özelliklere dayalı olarak oluşturulmaktadır. Her bir adımda SİS ve Relief yöntemleri oluşturulan özneliklere uygulanarak sınıflandırma başarımını yüksek tutabilecek olanları seçilmektedir. Zaman bölgesinden 2 adet ve ADD analizinde 1. seviye ayırıştırılmadan 6, 2. seviyeden 4 ve 3. seviyeden 2 adet olmak üzere toplamda 14 adet öznelik SİS yöntemi ile seçilmektedir. Bu öznelikler için sınıflandırma aşamasında TKA yönteminin %99.12±0.12 oranı ile en iyi başarıyı veren yöntem olduğu görülmektedir.

#### TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma Bülent Ecevit Üniversitesi tarafından desteklenmiştir (BAP Projesi No: 2017-75737790-03). Yazarlar Bülent Ecevit Üniversitesi'ne desteklerinden ötürü teşekkür ederler.

#### KAYNAKLAR (REFERENCES)

- [1] Thirumala K., Jain T. and Umarikar A.C., "Visualizing time-varying power quality indices using generalized empirical wavelet transform", *Electric Power Systems Research*, 143: 99-109, (2017).
- [2] Nashad N.R., Islam M.J., Alam S., Rahat R.M., Begum M.T. and Alam M.R., "A simplistic mathematical approach for detection and classification of power quality events", *Electrical, Computer and Communication Engineering (ECCE), International Conference on IEEE*, 698-703, (2017).
- [3] Granados-Lieberman D., Romero-Troncoso R.J., Osornio-Rios R.A., Garcia-Perez A. and Cabal-Yepez E., "Techniques and methodologies for power quality analysis and disturbances classification in power systems: a review", *IET Generation, Transmission & Distribution*, 5(4): 519-529, (2011).
- [4] Saini M.K. and Kapoor R., "Classification of power quality events—a review", *International Journal of Electrical Power & Energy Systems*, 43(1): 11-19, (2012).
- [5] Khokhar S., Zin A.M., Mokhtar A.S., Ismail N.M. and Zareen N., "Automatic classification of power quality disturbances: A review", *Research and Development (SCORED), IEEE Student Conference on IEEE*, 427-432, (2013).
- [6] Stańczyk U. and Jain L.C., "Feature selection for data and pattern recognition", *New York: Springer*, (2015).
- [7] Tan P.N., Kumar V. and Steinbach M., "Introduction to Data Mining", *Pearson*, (2005).
- [8] Montoya F.G., García-Cruz A., Montoya M.G. and Manzano-Agugliaro F., "Power quality techniques research worldwide: A review" *Renewable and Sustainable Energy Reviews*, 54: 846-856, (2016).
- [9] Karasu S. and Başkan S. "Classification of power quality disturbances by using ensemble technique", *24th Signal Processing and Communication Application Conference (SIU), IEEE*, 529-532, (2016)
- [10] Ece D.G. and Gerek O.N., "Power quality event detection using joint 2-D-wavelet subspaces", *IEEE Transactions on Instrumentation and Measurement*, 53(4): 1040-1046, (2004).
- [11] Shareef H., Mohamed A. And Ibrahim A.A., "An image processing based method for power quality event identification", *International Journal of Electrical Power & Energy Systems*, 46: 184-197, (2013).
- [12] Krishna B.V. and Kaliaperumal B., "Image pattern recognition technique for the classification of multiple power quality disturbances", *Turkish Journal of Electrical Engineering and Computer Science*, 21(3): 656-678, (2013).
- [13] Uyar M., Kaya Y. and Ataş M., "Classification of power quality disturbances based on S-transform and image processing techniques", *21st Signal Processing and Communications Applications Conference (SIU), IEEE*, 1-4, (2013).
- [14] Gonzalez R.C. and Woods R.E., "Digital Image Processing", *Prentice Hall*, 2002.
- [15] Robnik-Šikonja M. and Kononenko I., "An adaptation of Relief for attribute estimation in regression", *Machine Learning: Proceedings of the Fourteenth International Conference (ICML)*, 296-304, (1997).
- [16] Kira K. and Rendell L.A., "A practical approach to feature selection", *Machine Learning Proceedings*, 249-256, (1992).
- [17] Kononenko I., "Estimating attributes: analysis and extensions of RELIEF", *European conference on machine learning, Springer*, 171-182, (1994).
- [18] Karasu S. and Saraç Z., "Classification of power quality disturbances with S-transform and artificial neural networks method", *25th Signal Processing and Communications Applications Conference (SIU), IEEE*, 1-4, (2017).
- [19] Karasu S., Altan A., Saraç Z. and Hacıoğlu R., "Prediction of wind speed with non-linear autoregressive (NAR) neural networks", *25th Signal Processing and Communications Applications Conference (SIU), IEEE*, 1-4, (2017).
- [20] Karasu S., Altan A., Saraç Z. and Hacıoğlu R., "Estimation of fast varied wind speed based on NARX neural network by using curve fitting", *International Journal of Energy Applications and Technologies*, 4(3): 137-146, (2017).