

Güç Kalitesi Bozulmalarının Hilbert-Huang Dönüşümü, Genetik Algoritma Ve Yapay Zeka/Makine Öğrenmesi Yöntemleri İle Sınıflandırılması


Classification of Power Quality Disturbances with Hilbert-Huang Transform, Genetic Algorithm and Artificial Intelligence/Machine Learning Methods

Önemli noktalar (Highlights)

- ❖ Güç Kalitesi (GK) bozulma sinyalleri için Grupsal Ampirik Kip Ayrışımı ve Hilbert Huang (HH) dönüşümü (HD) ile öznelilikler çıkartılmaktadır. / For Power Quality (PQ) disturbances signals, features are extracted by Ensemble Empirical Mode Decomposition (EEMD) and Hilbert Huang transform (HT).
- ❖ Genetik Algoritma (GA) ve K en yakın komşu sınıflandırma (KNN) yaklaşımı ile en uygun öznelilikler belirlenmektedir. / The most suitable features are determined by Genetic Algorithm (GA) and K Nearest Neighbour (KNN) classification approach.
- ❖ Oluşturulan model için GK bozulmaları yüksek başarımla sınıflandırılmaktadır. / PQ disturbances are classified with high performance for the created model.

Grafik Özet (Graphical Abstract)

HH Dönüşümü, GA ve KNN sınıflandırma yöntemleri ile PQ bozulmaları sınıflandırılmaktadır. / PQ disturbances are classified by HH transform, GA and KNN methods.



Şekil. GK bozulmalarını sınıflandırma / Figure. Classification of PQ disturbances

Amaç (Aim)

EEMD + HD + GA + KNN yöntemleri kullanılarak tekli ve çoklu GK bozulmalarının yüksek başarımla sınıflandırılması amaçlanmıştır. / It is aimed to classify single and multiple PQ disturbances with high performance rate by using EEMD + HT + GA + KNN methods.

Tasarım ve Yöntem (Design & Methodology)

EEMD ve HD yöntemleri ile öznelilikler belirlenmektedir. GA + KNN yöntemi ile başarımla yüksek tutacak öznelilikler seçilmektedir. / Features are extracted by EEMD and HT methods. Features that will keep the performance high are selected with GA + KNN method.

Özgünlük (Originality)

Hibrit sınıflandırıcı ile yüksek başarımla sınıflandıran yeni bir model oluşturulmaktadır. / A novel model is created that classifies high performance PQ disturbances with the hybrid classifier.

Bulgular (Findings)

GA + KNN yöntemi kullanılarak EEMD ve HD yöntemleri ile elde edilen özneliliklerden en uygun olanları seçilmektedir. / The most suitable features that extracted with EEMD and HT methods are selected by using GA + KNN method.

Sonuç (Conclusion)

EEMD + HD + GA + KNN yöntemleri kullanılarak GK bozulmalarının sınıflandırılması yüksek başarımla sağlanmaktadır. / Classification of PQ disturbances is achieved with high performance by using the EEMD + HT + GA + KNN methods.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

Güç Kalitesi Bozulmalarının Hilbert-Huang Dönüşümü, Genetik Algoritma ve Yapay Zeka/Makine Öğrenmesi Yöntemleri İle Sınıflandırılması

Araştırma Makalesi / Research Article

Seçkin KARASU^{1*}, Zehra SARAÇ²

¹Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Zonguldak, Türkiye

²İstanbul Medeniyet Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, İstanbul, Türkiye

(Geliş/Received : 05.01.2019 ; Kabul/Accepted : 23.03.2019)

ÖZ

Bu çalışmada Güç Kalitesi (GK) Bozulmalarını sınıflandırmak için Hilbert-Huang Dönüşümü yöntemi ve istatistiksel özellikler ile öznitelikler elde edilmektedir. Elde edilen özniteliklerden uygun olanları Genetik Algoritma (GA) ve k-En Yakın Komşu (KNN) sınıflandırma yaklaşımı ile seçilmektedir. Yapay Zeka ve Makine Öğrenmesi yöntemlerine dayalı modeller oluşturulmakta ve deneysel düzeneğe alınan veriler kullanılarak test işlemi yapılmaktadır. Gürültülü durumlar matematiksel eşitlikler kullanılarak üretilmektedir. Bunun yanında deneysel düzeneğe elde edilen Güç Kalitesi Bozulma verisi de bu çalışmada kullanılmaktadır. Sinyallere öncelikle Ampirik Kip Ayırışımı (EMD) yöntemi uygulanmaktadır. Daha sonra Hilbert dönüşümü (HT) neticesinde istatistiksel özellikler ile gerekli öznitelikler çıkartılmaktadır. Aynı işlem Grupsal Ampirik Kip Ayırışımı (EEMD) yöntemi için tekrarlanmaktadır. Çıkartılan özniteliklerden gerekli olanlarının seçilebilmesi için GA + KNN sarmalama yaklaşımı kullanılmaktadır. Çok katmanlı algılayıcı (MLP) ve KNN yaklaşımları ile GK Bozulmalarını sınıflandıran modeller oluşturulmaktadır. 9 adet tekli, 9 adet çoklu bozulma türü için oluşturulan EEMD + HT + GA + KNN sınıflandırma modelinin başarımları sentetik veriler için %99.15, deneysel veriler için % 99.02 olarak elde edilmektedir. Literatürdeki çalışmalar ile kıyaslandığında elde edilen EEMD + HT + GA + KNN yönteminin, 9 adet çoklu GK bozulmasını ayırt edebilme özelliğine sahip olduğu ve %99.12'lik genel başarımlar oranı ile en iyi başarımlar veren yöntem olduğu sonuçlarına varılmaktadır.

Anahtar Kelimeler: Güç kalitesi, Hilbert-Huang dönüşümü, ampirik mod ayrıştırması, grupsal ampirik mod ayrıştırması, genetik algoritma.

Classification of Power Quality Disturbances with Hilbert-Huang Transform, Genetic Algorithm and Artificial Intelligence/Machine Learning Methods

ABSTRACT

In this study, Hilbert-Huang Transform method and statistical features are obtained to classify Power Quality (PQ) Disturbances. The appropriate features are selected by the Genetic Algorithm (GA) and k-Nearest Neighbor (KNN) classification approach. Models based on Artificial Intelligence and Machine Learning methods are formed and test process is performed by using data from experimental setup. Noisy situations are produced using mathematical equations. In addition, PQ Disturbances data from the experimental setup is also used in this study. Firstly, Empirical Mode Decomposition (EMD) method is applied to the signals. Then, by applying Hilbert transformation (HT), statistical features are extracted. The same procedure is repeated for Ensemble Empirical Mode Decomposition (EEMD). GA + KNN wrapper approach is used to select necessary features from feature subset. PQ Disturbances models are created based on Multilayer Perceptron (MLP) and KNN methods. The performance of EEMD + HT + GA + KNN classification model for 9 single and 9 multiple types of disturbances is 99.15% for synthetic data and 99.02% for experimental data. Compared to the literature, EEMD + HT + GA + KNN method has the ability to distinguish 9 multiple PQ disturbances. The overall performance gives the best performance with a rate of 99.12%.

Keywords: Power quality disturbances, Hilbert-Huang transform, emprical mode decompositon mod, ensemble emprical mode decomposition, genetik algorithm.

1. GİRİŞ (INTRODUCTION)

Güç kalitesi, standartlar ile belirlenmiş gerilim akım ve faz değerlerinde elektrik gücünün elektrik şebekesindeki varlığı olarak tanımlanmaktadır [1]. Elektrik şebekesinin

elektirsel dalga formlarının temsili, bir insan kalbinin elektrik fonksiyonuna ve sağlık durumuna ilişkin bilgiler sunan elektrokardiyogramın (EKG) temsil edilmesiyle karşılaştırılabilir [1-2]. Aynı şekilde, bir güç şebekesinden elde edilen sinyallerin değerlendirilmesi bir elektrik mühendisine elektrik sistemindeki olası arızaları tahmin ve teşhis edebilme yeteneği vermektedir.

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

Ancak gün geçtikçe elektrik şebekelerinin karmaşık bir yapı alması, harmonik içeren yüklerin, doğrusal olmayan yüklerin sayısının artması çok çeşitli bozulma tipinin oluşmasına ve bu amaçla insan müdahalesi olmadan güç kalitesi bozulmalarının sınıflandırılması ihtiyacının doğmasına sebep olmaktadır [3]. Güç kalitesi bozulmalarının tanınması problemi bir örüntü tanıma problemi olarak ele alınmaktadır. Bu sebeple, sinyal işleme yöntemi ile özniteliklerin belirlenmesi, yararlı öznitelik grubunun belirlenmesi ve sınıflandırma adımları ile tanıma modelleri oluşturulmaktadır.

Literatürde bu konuda oldukça fazla çalışma yapılmaktadır. Bunlardan mevcut yaklaşım olan Varyasyonel Kip Ayrışımı (VMD), Ağırlıklı Online Ardışıl-Aşırı Öğrenme Makinası yöntemleri ile 7 tekli, 9 ikili bozulma ürünü [4]'de sınıflandırılmaktadır. Nöron Ağacı, Yüksek Dereceden İstatistikler yöntemleri ile de sınıflandırma yapılmaktadır [5]. [6]'da ise KL İraksama ve Destek Vektör Makinası yöntemi ile sınıflandırma işlemi yapılmaktadır. Ayrık Dalgacık Dönüşümü (DWT), Yapar Arı Koloni (ABC) ve Olasılıksal Sinir Ağları (PNN) yöntemleri ile sınıflandırma yöntemi ise [7]'de önerilmektedir. Korelasyonlu Öznitelik Seçme (CFS), Karşılıklı Bilgiye dayalı Öznitelik Seçme (MIFS) ve SVM yöntemleri de kullanılmaktadır [8]. [9]'da WT, Parçacık Sürü Optimizasyonu (PSO) ve Aşırı Öğrenme Makinası (ELM) tabanlı PQ sınıflandırma modeli oluşturulmuştur. Her iki olay için sınıflandırma oranı % 99.00 olmasına rağmen, sekiz tek olay için performans oranı % 97.25'dir. Genel performans % 97.60'dır.

Sinyal işleme yöntemlerinden Hilbert Dönüşümü ve Hilbert-Huang Dönüşümü ile oluşturulan modellerden Ampirik Kip Ayrışımı (EMD), Hilbert Dönüşümü (HT) ve Destek Vektör Makinası (SVM) yöntemleri ile 10 farklı bozulma türünü sınıflandırmaktadırlar [10]. Gerilim düşmesi, gerilim yükselmesi, harmonikli durumlar, gerilimde salınımlı durumlar için İteratif Hilbert Huang dönüşümü ile Güç kalitesi bozulmalarını da [11]'de incelemektedirler. Bu [11]'deki sinyaller üzerinde ayırt edici özellikler barındırdıklarını göstermiş olmalarına rağmen, sınıflandırma yöntemi ile bir model oluşturamamışlardır. [12]'de gerilim düşmesi için EMD ve Hilbert Huang (HH) dönüşümü uygulayarak bir simülasyon çalışması yapmaktadırlar. İlgili çalışmada EMD sonucunda oluşan İçkin Kip Fonksiyonları (IMF)'lerin HH dönüşümü ile bu sinyaller üzerinde ayırt edici özellikler sergilediğini göstermişlerdir ancak sınıflandırma işlemi yapmamışlardır. [13]'de HH Dönüşümü ve Uygunluk Vektör Makinası yöntemi ile 7 çeşit güç kalitesi bozulma verisi için sınıflandırma işlemi yapmaktadırlar. Ayrıca belirtilen çalışmada KNN ve SVM yöntemlerini de test etmişler ve önerdikleri yöntemin diğer yöntemlere göre yüksek olduğunu; %94.57'lik bir başarımla sergilediğini göstermişlerdir. [14]'te Ortogonal Hilbert Huang (OHH) dönüşümü ile gerilimde salınımlı durumları incelenmektedir. EMD ile önce IMF leri elde edip sonra bunu OHH dönüşümünde kullanmaktadırlar. HHT'ye göre OHH ile gerilimde salınımlı durum sinyallerinin tespitinin daha sağlıklı

yapıldığı gösterilmektedir. [15]'de geliştirilmiş HH Dönüşümü ile güç kalitesi bozulmaları üzerinde analiz yapılmaktadır ve sentetik veriler üzerinde çalışmaktadırlar. Maskeleye işlemi ile EMD üzerinde elde edilen IMF'ler geliştirilmiş HH dönüşümüne uygulanmaktadır. Belirtilen çalışmada sınıflandırma işlemi yapılmamış olmasına rağmen güç kalitesi bozulmalarının teşhisinde HH'nin kullanılabileceğini ifade etmektedirler.

Bu çalışmada ise GK bozulma sinyallerinin sınıflandırılması için HH dönüşümü ile öznitelikler çıkartılmakta, GA + KNN yaklaşımı ile özniteliklerden en uygun olanları seçilmektedir. IMF'lerin elde edilmesi aşamasında EMD ve Grupsal Ampirik Kip Ayrışımı (EEMD) yaklaşımları uygulanmakta ve Hilbert Analizi yapılmaktadır. Yapay zeka yöntemlerinden Çok Katmanlı Algılayıcı (MLP) ve Makine Öğrenmesi yöntemlerinden k-En Yakın Komşu (KNN) sınıflandırma yöntemi ile modeller oluşturulmaktadır. Sentetik veriler ve deneysel düzenekten alınan veriler kullanılarak sınıflandırma başarımları ölçülmektedir. Farklı gürültülü durumlarda ve tekli, çoklu bozulmalar için de başarımlar değerlendirilmektedir. Buna göre 9 adet tekli, 9 adet çoklu bozulma türü için oluşturulan EEMD + HT + GA + KNN sınıflandırma modelinin başarımları sentetik veriler için %99.15, deneysel veriler için % 99.02 olmakta ve genel başarımlar ise %99.12 olarak elde edilmektedir. Bu yöntemin literatürdeki diğer yöntemlere göre çok farklı çoklu bozulma türlerini sınıflandırma özelliği içerdiği ve deneysel veriler için sınıflandırma başarımlarının yüksek olduğu görülmektedir.

Çalışmada kullanılan yöntemler II. bölümde açıklanmakta ve III. bölümde çalışmada kullanılan yöntemin genel akışı verilmektedir. IV. bölümde sonuçlar irdelenmektedir.

2. MATERYAL VE METOD (MATERIAL and METHOD)

2.1 Hilbert Dönüşümü (Hilbert Transform)

Orijinal bir sinyal $x(t)$ için Hilbert dönüşümü, $-\infty < t < \infty$ aralığında tanımlanan gerçek değerli $\hat{x}(t)$ ile denklem (1)'deki gibi ifade edilmektedir.

$$\hat{x}(t) = H\{x(t)\} = \int_{-\infty}^{\infty} \frac{x(\tau)}{\pi(t - \tau)} dt \quad (1)$$

Bu eşitlikte $H\{\cdot\}$ Hilbert dönüşümünü, τ kaydırma operatörüne karşılık gelmektedir. Bir sinyalin Hilbert dönüşümü, orijinal sinyalden 90° faz kaydırılmış bir ortogonal sinyal üretmektedir [16, 17]. $x(t)$ sinyali için analitik form Picibono tarafından tanımlanmak ve bu ifade denklem (2)'deki gibi verilmektedir [18].

$$z_x(t) = x(t) + j\hat{x}(t) \quad (2)$$

Analitik form kullanılarak Anlık Zarf (AZ) $a_x(t)$, Anlık Faz (AF1) $\phi_x(t)$ ve Anlık Frekans (AF2) $f_x(t)$ denklem (3)-(5) ile ifade edilmektedir.

$$a_x(t) = |z_x(t)| = \sqrt{x(t)^2 + \hat{x}(t)^2} \quad (3)$$

$$\Phi_x(t) = \arctan\left(\frac{\hat{x}(t)}{x(t)}\right) \quad (4)$$

$$f_x(t) = \frac{1}{2\pi} \left[\frac{d\Phi_x(t)}{dt} \bmod(2\pi) \right] \quad (5)$$

2.2 Hilbert-Huang Dönüşümü (Hilbert-Huang Transform)

Hilbert-Huang dönüşümü (HHD), Huang vd. tarafından Ampirik Mod Ayırıştırması (EMD) ve Hilbert Spektral Analizinin (HSA) birleştirilmesi ile ortaya çıkartılan bir yöntemdir [19]. EMD yöntemi, doğrusal olmayan ve durağan süreçlerden elde edilen verileri Hilbert Dönüşümü aracılığı ile anlamlı anlık frekans sağlayan basit salınımlı fonksiyona indirgemek için kullanılmaktadır. HHD, iki aşamadan oluşan bir analiz yöntemidir. İlk olarak EMD ile bir sinyalin, her biri frekans modülasyonu içeren birer işaret olan İMF çıkartılmaktadır. Sinyal boyutuna göre elde edilen her bir İMF'den HHD ile zaman-frekans alanında anlık frekans ve genlik değerleri elde edilmektedir [19].

2.3 Ampirik Kip Ayırışımı (Empirical Mode Decomposition)

EMD algoritması ile orijinal $X(t)$ sinyali denklem (6)'daki gibi ifade edilmektedir [19].

$$X(t) = \sum_{i=1}^n C_i(t) + R_n(t) \quad (6)$$

Burada $\{C_i(t)\}$ serisi İçkin Kip Fonksiyonlarını (Intrinsic Mode Functions-IMF), $\{R_n(t)\}$ residü ifadesini tanımlamaktadır.

EMD algoritması ile IMF ve residü ifadesi aşağıdaki gibi bulunmaktadır.

Adım 1: Öncelikle $X(t)$ 'nin lokal ekstremleri tanımlanır ve yerel maksimum ve yerel minimum olmak üzere iki kısma ayrılır.

Adım 2: Bir kübik eğri çizgi ile üst eğri $X_{üst}(t)$ ve alt eğri $X_{alt}(t)$ tüm lokal noktalar kendi arasında birleştirilerek oluşturulmaktadır.

Adım 3: Üst ve alt eğri ortalaması alınarak ortalama eğrisi $M(t)$ elde edilmektedir.

Adım 4: Mevcut $X(t)$ sinyalinden $M(t)$ sinyali çıkartılarak IMF adayı olan $H(t)$ bulunmaktadır.

Adım 5: $H(t)$ IMF olma koşulu kontrol edilir. Üst ve alt eğrilerin ortalaması '0' ise ve ekstrem sayıları ile sıfır-geçiş sayısı en fazla 1 farklı ise IMF koşulu sağlanmaktadır. Bu şart sağlanmaz ise Adım 1'e geri dönülerek şart sağlanıncaya kadar işlemler tekrarlanır.

2.4 Grupsal Ampirik Kip Ayırışımı (Ensemble Empirical Mode Decomposition)

Geleneksel EMD'de ortaya çıkan mod karıştırma probleminin üstesinden gelebilmek için 2009 yılında Wu ve Huang, Grupsal Ampirik Kip Ayırışımı (EEMD) olarak adlandırılan yeni bir yaklaşım önermişlerdir [20]. Mod karıştırma fenomenini çözüldükten sonra, EEMD durağan olmayan sinyal ayrışmasında iyi bir performansa sahip olduğu gösterilmektedir [20].

2.5 Genetik Algoritma (Genetic Algorithm)

John Holland yaptığı çalışmada, evrimsel sürecin bir benzerinin, Genetik Algoritmalar (GA) ile matematiksel problemleri ve mühendislik optimizasyon problemlerini çözmek için nasıl uygulanabileceğini göstermektedir [21]. GA'da bilgi taşıyan en küçük birim olarak kabul edilen genin, birden fazlasının bir araya gelmesi ile kromozomlar oluşmaktadır. Birden fazla kromozomun bir araya gelmesi ile popülasyon meydana gelmektedir. GA ile jenerasyon boyunca, popülasyonda bulunan olası çözümleri içerebilecek olan kromozomlar çaprazlama, mutasyon ve başarılı gen seçimi olmak üzere üç işlem uygulanarak tespit edilmektedir. Bir jenerasyondan diğer jenerasyona geçerken, popülasyon bireyleri (kromozomları) birbirleri ile farklı kromozom parçalarını değiştirerek yeni bireyler oluşturmaktadır. Yeni bireyler probleme özgü belirlenmiş olan bir uygunluk fonksiyonu ile değerlendirmeye tabi tutulmaktadır. Seçme mekanizması gelecek jenerasyona en uygun olabilecek olan bireylerin aktarılmasını sağlamaktadır. GA'da ayrıca mutasyon işlemi, mevcut problemi çözebilecek genetik çeşitlilik sunmaktadır [21].

2.6 Sınıflandırma Yöntemleri (Classification - Methods)

2.6.1 Yapay Sinir Ağları (Artificial Neural Networks)

Yapay Zeka yöntemlerinden çok katmanlı algılayıcılar, insan beyninin öğrenme yeteneğinin makinelerle aktarılması ile, farklı karmaşık ve gerçek dünya problemini çözdürmek amacıyla kullanılmaktadır [22].

2.6.2 K-En Yakın Komşu Sınıflandırma (K-Nearest Neighbor Classification)

Makine öğrenmesi yöntemlerinden K-En Yakın Komşu Sınıflandırma (KNN) yöntemi, en temel ve basit sınıflandırma yöntemlerinden biridir. Verilerin dağılımı hakkında çok az veya hiç bilginin olmadığı durumlarda bir sınıflandırma çalışması için ilk tercihlerden biri olmaktadır [23]. Fix ve Hodges tarafından 1951 yılında, örüntü tanıma için daha sonra KNN olarak adlandırılacak parametrik olmayan bir yaklaşım tanıtılmıştır [23]. KNN, olasılık yoğunluklarının güvenilir parametrik tahminlerinin bilinmediği veya belirlenmesinin zor olduğu durumlarda diskriminant analizi yapma ihtiyacından geliştirilmiştir. Bu yöntemde örnek veri kümesinde bulunan bir veri noktasının, k adet en yakın komşu veri noktasına bakılması ile hangi sınıfa dahil olduğu belirlenmektedir. [22]'de veriler arasındaki uzaklık Euclidian, Manhattan, Minkowski vb. uzaklıklarıyla hesaplanmaktadır.

2.7 Modelin Test Edilmesi ve Başarım Ölçütü (Model Testing and Performance Metric)

Oluşturulan modelin eğitim ve test aşaması k-çapraz doğrulama yöntemi ile yapılmaktadır. Bu yöntemde veri k parçaya ayrılmaktadır. k-1 parça için model eğitimi yapılır ardından kalan 1 parça için test işlemi yapılmaktadır. Başarım değeri hesaplanmaktadır. Ardından daha önce test aşamasında kullanılan kısım eğitim kısmına eklenmektedir. Yeni k-1 parça için model

eğitimi yapılır ve daha önce kullanılmamış olan 1 parça test aşamasında kullanılmaktadır. Bu adım k parça için tekrarlanarak ortalama başarımlar değeri hesaplanmaktadır [22].


3. ÖNERİLEN YÖNTEMİN TEMEL YAPISI (FRAMEWORK OF THE PROPOSED METHOD)

Bu çalışmada sinyal işleme yöntemlerinden HH dönüşümü ile Güç Kalitesi Bozulmalarını temsil eden öznitelik grubu oluşturulmaktadır. Bu aşamada hem

Adım 1. Rastgele parametrelere bağlı matematiksel modelleme ile üretilen veriler ve deneysel düzenden alınan Güç Kalitesi Bozulma (GKB) verisi bu aşamada kullanım için hazırlanmaktadır.

Adım 2. GKB üzerinde Ampirik Kip Ayrışımı (EMD) ve Hilbert Dönüşümü (HT) uygulanmaktadır. Ayrıca EEMD-HT yönteminin de etkisi incelenmektedir. İstatistiksel özellikler ile sinyallerin ayırt edici özellikleri belirlenmektedir.

Adım 3a. Normalizasyon işlemi ile özelliklerin belirli bir küme aralığından değeri alınması sağlanmaktadır.



Şekil 1. Güç kalitesi bozulmalarının sınıflandırılmasında kullanılan yöntemin akış diyagramı (Flow chart of the proposed method used in classification of power quality disturbances)

EMD-HT ve EEMD-HT yöntemleri ile özellikler elde edilmektedir. GA + KNN yaklaşımı ile özellik sayısı en az olacak ancak sınıflandırma başarımları yüksek modeller oluşturulmaktadır. MLP ve KNN yöntemleri ile model çeşitliliği sağlanmaktadır. Önerilen yöntemin temel yapısı Şekil 1'deki gibi verilmektedir.

Genetik Algoritma ve KNN yöntemleri ile en uygun özellikler belirlenmektedir.

Adım 3b. Genetik Algoritma ve KNN yöntemlerinin bir araya getirildiği sarmalama (Wrapper) yaklaşımı, özellikler arasında sınıflandırıcı başarımları yüksek tutanların belirlenmesi amacıyla kullanılmaktadır. KNN başarımlarının yüksek ve seçilen özellik sayısının

az olması gibi uygunluk kriterleri Genetik Algoritma ile göz önünde bulundurulmaktadır.

Adım 4. Seçilen öznelikler kullanılarak KNN ve MLP modelleri oluşturulmaktadır.

Adım 5. Oluşturulan modellerin performansları değerlendirilmektedir.

3.1 Sentetik Veriseti (Synthetic Dataset)

Çalışmada, 18 farklı Güç Kalitesi Bozulma durumu için sentetik veriye dayalı [24-27] olarak veri oluşturulmaktadır. Her bir sınıf için Tablo 1'deki gibi etiket değerleri verilmektedir. 3 farklı gürültü seviyesi içeren (40 dB, 30 dB, 20 dB) 150'şer adet toplamda 2700 veri oluşturulmaktadır. Sinyaller oluşturulurken bilgi kaybını önlemek için Nyquist örnekleme teoremine göre örnekleme frekansı 16 kHz olarak seçilmekte ve her bir sinyal 10 periyot içerecek şekilde toplamda 3200 veri noktası oluşturulmaktadır.

3.2 Deneyisel Veriseti (Experimental Dataset)

Güç Kalitesi Bozulmalarının sınıflandırılması ile ilgili

Çizelge 1. PQ Bozulmaları için sınıf etiketleri (Class labels for PQ disturbances)

Etiket	Sinyal Çeşidi
S1	Sinüsoidal Sinyal
S2	Gerilim Düşmesi
S3	Gerilim Yükselmesi
S4	Gerilim Kesintisi
S5	Gerilim Titreşimi
S6	Geçici Salınlımlı Durum
S7	Harmonikli Durum
S8	Gerilimde Çentik
S9	Gerilimde Ani Yükseliş
S10	Harmonikli Gerilim Düşmesi
S11	Harmonikli Gerilim Yükselmesi
S12	Harmonikli Gerilim Kesintisi
S13	Harmonikli Geçici Salınlımlı Durum
S14	Harmonikli Gerilimde Çentik
S15	Geçici Salınlımlı Durumlu Gerilim Düşmesi
S16	Geçici Salınlımlı Durumlu Gerilim Yükselmesi
S17	Harmonikli, Gerilim Salınlımlı Gerilim Düşmesi
S18	Harmonikli, Gerilim Salınlımlı Gerilim Yükselmesi

literatürdeki yapılan çalışmalar incelendiğinde, model oluşturma aşamasında gerçek veri kullanımının sentetik veri kullanımına kıyasla düşük olduğu görülmektedir [28-29].

Bunun nedenlerinden biri gerçek veriye ulaşmanın önünde güvenlik açısından bir engelin olmasıdır. Bir diğer neden ise verilerin dengesiz örnek sayıları içermesi nedeniyle sentetik veriye dayalı gürbüz model oluşturmada daha cazip olmasıdır. Dezavantajlı durumu ortadan kaldırmak için bu alanda çalışanlar Güç Kalitesi Bozulmalarını elektriksel ekipmanlar kullanarak laboratuvar ortamında oluşturmaktadırlar. Literatürde Güç Kalitesi Bozulma durumlarının laboratuvar ortamında kurulan deneysel düzenek ile elde edilmesi üzerine çeşitli çalışmalar mevcuttur. Bozulma durumları, pratik bir dağıtım sisteminde olduğu gibi doğrusal ve

doğrusal olmayan yüklerin anahtarlanması sonucunda laboratuvar ortamında üretilmektedir. Örnek bir çalışma, ayarlanabilir güç kaynağı, gerilim/akım sensörü (LV-25P/LA-55P), veri toplama ünitesi (NI-cDAQ) ile gerilimde düşme, yükselme, gerilimde çentik gibi sinyallerin üretilmesi ve ölçülen sinyallerin MATLAB ortamına aktarılması ile yapılmaktadır [30].


National Instruments ürünü olan USV-6008 veri toplama cihazı ve bir fonksiyon jeneratörü ile normal sinüs, gerilimde düşme, yükselme ve kesinti gibi sinyallerin üretilmesi [32]'de yapılmaktadır. Doğrusal ve doğrusal olmayan yüklerin kullanılarak gerilimde düşme/yükselme durumlarını incelemek için rüzgar enerji sistemi, güneş enerji sistemi ve bunların bir arada kullanıldığı dağıtım sistemi için bir deney düzeneği [33]'te kullanılmaktadır. [34]'te Fluke 6100A marka sinyal kaynağı, veri toplama kartı ve bir PC kullanılarak gerilimde düşme, fliker, harmonik, kesinti, ve ikili bozulmalardan harmonikli gerilimde düşme ve harmonikli gerilimde yükselme durumları incelenmektedir. Omik yükler, ayarlanabilir alternatif akım oto transformatör ile Güç Kalitesi bozulma sinyalleri oluşturulmakta ve bu sinyaller gerilim/akım sensör kartı, veri toplama kartı (DAQ) ile Labview ortamına aktarılmaktadır [35]. Bir başka çalışmada kapasitör bankası, farklı tipte motorlar, transformatör bankası, motor başlatıcısı, ayarlanabilir motor sürücü gibi çok çeşitli deney düzeneği içermekte ve veri toplama ünitesi toplanan veriler PC'ye aktarılmaktadır [36].

Bu çalışmada, literatürdeki çalışmalar dikkate alınarak, çok çeşitli bozulma olay verilerini deneysel ortamda üretebilmek için Şekil 3.2'deki gibi bir düzenek dikkate alınmaktadır.

Literatürdeki çalışmalara kıyasla, bu projede yüksek örnekleme frekansında çalışabilen PC tabanlı osiloskop kullanılmaktadır. Çeşitli yükler, elektrik panoları röle kartları ile kontrolcü kartları ve PC ile kontrol edilebilmektedir. Bu sayede deney düzeneği ile farklı etkilere sahip anahtarlama işlemlerinin yakın zaman diliminde gerçekleştirilmesi sağlanarak çok çeşitli bozulma sinyalleri oluşturulabilmektedir. Bu çalışmada Tablo 1'deki her bir durum için 50'şer adet olmak üzere toplamda 900 veri toplanmaktadır.

3.3 Özneliklerin Çıkartılması (Feature Extraction)

Bu aşamada EMD-HT ve EEMD-HT yöntemlerinden istatistiksel ve enerji tabanlı eşitlikler yardımı ile öznelikler oluşturulmaktadır. Ortalama Karekök, Toplam harmonik bozulma, enerji, entropi, aritmetik ortalama, geometrik ortalama, harmonik ortalama, standart sapma, çarpıklık, basıklık, en büyük ve en küçük değer gibi çeşitli öznelikler elde edilmektedir. Tablo 2'de öznelikler ve eşitlikleri verilmektedir. EMD ve EEMD yöntemlerinden her birinden ayrı ayrı elde edilen



Şekil 2. Projede kullanılan deney düzeneğinin gösterilmesi (Demonstration of the experimental setup used in the project)

5 adet IMF'ye HT uygulandığında sırasıyla anlık zarf dizisi $a_x(n) = \{a_x(\text{IMF}_1), a_x(\text{IMF}_2), a_x(\text{IMF}_3), a_x(\text{IMF}_4), a_x(\text{IMF}_5)\}$, anlık faz dizisi $\Phi_x = \{\Phi_x(\text{IMF}_1), \Phi_x(\text{IMF}_2), \Phi_x(\text{IMF}_3), \Phi_x(\text{IMF}_4), \Phi_x(\text{IMF}_5)\}$ ve anlık frekans dizisi $f_x = \{f_x(\text{IMF}_1), f_x(\text{IMF}_2), f_x(\text{IMF}_3), f_x(\text{IMF}_4), f_x(\text{IMF}_5)\}$ olacak şekilde elde edilmektedir. Bu işlem sonucunda bir Güç Kalitesi Bozulma verisi toplamda 15 farklı dizi ile

temsil edilmektedir. Toplam dizi $F(n) = \{a_x(n), \Phi_x(n), f_x(n)\}$ olarak ifade edilmektedir. Tablo 2'deki 12 adet öznelilik, çıkartılan bu 15 diziye uygulanarak toplamda 180 adet öznelilik oluşturulmaktadır. Bu sayede boyut indirgeme işlemi yapılmaktadır. Ancak bu özneliliklerden model karmaşıklığını azaltmak ve başarıyı yüksek bir sınıflandırıcı modeli oluşturmak için GA + KNN tabanlı öznelilik seçme yaklaşımı da uygulanmaktadır.

Çizelge 2. Öznelilikler ve eşitlikleri (Features and equations)


No	Öznelilik	Eşitlikler
1	Rms	$Rms = \sqrt{\frac{1}{N} \sum_{n=1}^N (F(n))^2}$
2	Thd	$Thd = \sqrt{\frac{\sum_{n=2}^N (F_{rms}(n))^2}{F_{temel}}}$
3	Enerji	$Eng = \sum_{n=1}^N (F(n))^2$
4	Entropi	$Ent = \sum_{n=1}^N F(n) \log F(n) $
5	En büyük	$Eb = \max \{F(n)\}$
6	En küçük	$Ek = \min \{F(n)\}$
7	Aritmetik Ortalama	$Aort = \frac{1}{N} \sum_{n=1}^N F(n) $
8	Geometrik Ortalama	$Gort = \sqrt[N]{\prod_{n=1}^N F(n) }$
9	Harmonik Ortalama	$Hort = \frac{N}{\sum_{n=1}^N \frac{1}{ F(n) }}$
10	Std. Sapma	$Std = \sqrt{(F(n) - Aort)^2}$
11	Çarpıklık	$\zeta_{ar} = \frac{1}{N} \sum_{n=1}^N \left(\frac{ F(n) - Aort}{Std} \right)^3$
12	Basıklık	$Bas = \frac{1}{N} \sum_{n=1}^N \left(\frac{ F(n) - Aort}{Std} \right)^4$

GA + KNN yöntemi sonucunda EMD + HT için toplamda 10 adet öznelilik seçilmektedir. Bunlar sırasıyla IMF1 genlik dizisinin entropi değeri, maksimum değeri, çarpıklık değeri, basıklık değeri, IMF1 faz dizisinin entropi değeri, maksimum değeri, çarpıklık değeri, IMF1 frekans dizisinin RMS değeri, en küçük değeri, geometrik ortalama değeri olmaktadır. Algoritmanın seçim aşamasında jenerasyon boyunca başarımlar ve öznelilik değişimleri Şekil 3-4'de verilmektedir.


GA + KNN yöntemi sonucunda EEMD + HT için toplamda 9 adet öznelilik seçilmektedir. Bunlar ise sırasıyla IMF1 genlik dizisinin entropi değeri, standart sapma değeri, basıklık değeri, IMF1 faz dizisinin entropi değeri, minimum değeri, geometrik ortalama değeri, IMF1 frekans dizisinin RMS değeri, en büyük değeri, geometrik ortalama değeri olmaktadır. Algoritmanın seçim aşamasında jenerasyon boyunca başarımlar ve öznelilik değişimleri Şekil 5-6'da verilmektedir.

3.4 Kullanılan yöntemler için başarımların Kıyaslanması (Comparison of Performances for Applied Methods)

EMD-HT ve EEMD-HT tabanlı çıkartılan öznelilikler yardımı ile oluşturulan modellerin başarımları kıyaslanmaktadır. Modeller için hem sentetik hem de gerçek veriler kullanılmaktadır. Sentetik veriler için 40 dB, 30 dB, 20 dB gürültülü durumlardaki ayrı ayrı başarımların ne olduğu incelenmektedir. Sınıflandırma aşamasında KNN ve MLP yaklaşımlarının da başarımlar üzerindeki etkisi incelenmektedir. KNN modeli için k sayısı 1, 3, 5, 7, 9 için denlenmektedir. k=1 için en iyi model sonucu bulunmaktadır. MLP için gizli katman nöron sayısı 3 ile 50 arasında değişmektedir. Gizli



Şekil 3. EMD + HT öz nitelikleri için, GA + KNN yaklaşımında her bir jenerasyondaki en iyi çözüm için başarımın değişimi (Change of performance for the best solution in each generation in the GA + KNN approach for EMD + HT features)




Şekil 4. EMD + HT öz nitelikleri için, GA + KNN yaklaşımında her bir jenerasyondaki en iyi çözümün içerdiği (The best solution in each generation is included for the EMD + HT features in the GA + KNN approach.)

katman nöron sayısı 40 için en iyi sonuç elde edilmektedir. Tablo 3'te çalışma boyunca oluşturulan modellerin başarımları verilmektedir. EEMD-HT tabanlı yöntem ile ayırt edici öz niteliklerin elde edilerek başarımları yüksek model elde edilmektedir.


Tablo 4'ten görülebileceği gibi EEMD HT + GA + KNN yöntemi S1, S3, S5, S6, S7, S8, S9, S10, S11, S13, S14, S15, S16, S18 olmak üzere 14 adet sinyal tipi için %99 üzerinde bir sınıflandırma başarımına sahiptir. S2, S4,

S12, S17 sınıfları %98-%99 arasında sınıflandırılmaktadır. Birbirleri ile en çok karışan sınıflar Gerilim Düşmesi ve Gerilim Kesintisi arasında olmaktadır.

Tablo 5'te bu çalışmada elde edilen EEMD + HT + GA + KNN modeline dayalı PQ sınıflandırma modelinin, literatürdeki diğer yöntemler ile karşılaştırılması yapılmaktadır. Deneysel verinin kullanılmadığı [4-8],[10] çalışmalarına göre elde edilen başarımların



Şekil 5. EEMD + HT öznitelikleri için, GA + KNN yaklaşımında her bir jenerasyondaki en iyi çözüm için başarımın değişimi (Change of performance for the best solution in each generation in the GA + KNN approach for EMD + HT features)



Şekil 6. EEMD + HT öznitelikleri için, GA + KNN yaklaşımında her bir jenerasyondaki en iyi çözümün içerdiği (The best solution in each generation is included for the EMD + HT features in the GA + KNN approach.)

tekli ve çoklu bozulma türleri içi yüksek olduğu görülmektedir. Deneysel verilerin kullanıldığı [31-33],[37] çalışmalarına kıyasla oluşturulan modelin çok çeşitli bozulma türlerini sınıflandırma özelliğine sahip olduğu söylenebilir. Özellikle üçlü bozulmaların %99.03 (S17 ve S18 sınıflarının başarımlarının ortalama değeri) oranı ile sınıflandırıldığı Tablo 4'ten çıkartılmaktadır.

4. SONUÇLAR (RESULTS)

Bu çalışmada, %25'i deneysel düzenekten alınan, her bir sınıftan 200 adet olmak üzere 18 adet sınıf içeren 3600 adetlik veri için EMD-HT ve EEMD-HT tabanlı sinyal işleme yöntemleri ile istatistiksel öznitelikler elde edilmektedir. Özniteliklerden sınıflandırma başarımını yüksek tutabilecek olanları GA + KNN yöntemi ile seçilmektedir. MLP ve KNN yöntemleri ile sınıflandırma yapılmaktadır. EEMD yöntemi ile elde edilen model

Çizelge 3. Kullanılan yöntemlerin birbirleri ile kıyaslanması (Comparison of used features)

Yöntemler	Sentetik Veri			Deneyisel Veri	Genel Başarım
	40 dB	30 dB	20 dB		
EMD + HT + GA + KNN	99,55	99,19	98,00	98,75	98,87
EMD + HT + GA + MLP	99,35	99,27	97,28	98,50	98,60
EEMD + HT + GA + KNN	99,50	99,35	98,60	99,02	99,12
EEMD + HT + GA + MLP	99,42	99,27	96,74	98,35	98,44

Çizelge 4. Önerilen yöntemin sınıflara ve veri tipine göre başarımlar (Performance of the proposed method according to classes and data type)

Etiket	Sinyal Çeşidi	Sentetik Veri			Deneyisel Veri	Ortalama
		40 dB	30 dB	20 dB		
S1	Sinüsoidal Sinyal	99,75	97,50	99,25	99,50	99,00
S2	Gerilim Düşmesi	99,50	99,00	97,50	98,00	98,50
S3	Gerilim Yükselmesi	99,75	99,55	99,25	99,00	99,39
S4	Gerilim Kesintisi	99,00	98,25	97,80	98,50	98,39
S5	Gerilim Titreşimi	99,50	99,60	98,75	99,35	99,30
S6	Geçici Salınlı Durum	99,60	99,75	98,75	99,50	99,40
S7	Harmonikli Durum	99,35	99,25	98,50	99,15	99,06
S8	Gerilimde Çentik	99,50	99,90	98,25	99,00	99,16
S9	Gerilimde Ani Yükseliş	99,50	99,90	99,15	98,80	99,34
S10	Harmonikli Gerilim Düşmesi	99,75	99,90	98,10	99,75	99,38
S11	Harmonikli Gerilim Yükselmesi	99,00	99,80	98,60	99,50	99,23
S12	Harmonikli Gerilim Kesintisi	99,25	99,00	98,50	99,00	98,94
S13	Harmonikli Geçici Salınlı Durum	99,75	99,80	98,50	98,75	99,20
S14	Harmonikli Gerilimde Çentik	99,75	99,90	99,00	98,70	99,34
S15	Geçici Salınlı Durumlu Gerilim Düşmesi	99,50	99,44	99,10	99,25	99,32
S16	Geçici Salınlı Durumlu Gerilim Yükselmesi	99,60	99,25	98,50	99,00	99,09
S17	Harmonikli, Gerilim Salınlı Gerilim Düşmesi	99,40	99,25	98,50	98,75	98,98
S18	Harmonikli, Gerilim Salınlı Gerilim Yükselmesi	99,50	99,20	98,75	98,85	99,08
Ortalama Genel Başarım:		99,50	99,35	98,60	99,02	99,12

Çizelge 5. Önerilen yöntemin literatürdeki çalışmalar ile kıyaslanması (Comparison of the proposed method with the studies in the literature)

No	Yöntemler	Tekli Sınıf No.	Tekli Sınıflar İçin Model Performansı (%)	Çoklu Sınıf No.	Çoklu Sınıflar İçin Model Performansı (%)	Deneyisel Veri için Model Performans	Tüm Model Performansı
[4]	VMD+WOSLM	7	96.57	9	-	-	98.12
[5]	NT+HOS	4	99.79	16	97.43	-	97.80
[6]	KLD+SVM	6	-	5	-	-	94.02
[8]	CFS+MIFS+SVM	5	99.83	2	99.16	-	98.40
[10]	EMD+HT+SVM	10	95.33	-	-	-	95.33
[31]	ADMN-OSLA	6	84.92	-	-	84.92	84.92
[32]	WT+MLP	7	89.13	2	86.00	88.84	88.84
[33]	LS-SVM	6	95.16	-	-	98.33	96.21
[37]	ST+DT	6	96.66	7	97.09	96.90	98.80
Bu Çalışma	EEMD + HT + GA + KNN	9	99.06	9	99.17	99.02	99.12

başarım değerleri EMD yöntemine göre olanlardan daha iyi olduğu görülmektedir. Ayrıca KNN yöntemi ile elde edilen başarımlar MLP ile elde edilenlerden yüksek olduğu görülmektedir. EEMD + HT + GA + KNN sınıflandırma modelinin başarımlar sentetik veriler için %99.15, deneysel veriler için % 99.02 olarak elde

edilmektedir. Oluşturulan deney düzeneğinden elde edilen Güç Kalitesi Bozulma verileri için model başarımları, sentetik verilerden elde edilenlere yakın çıkmaktadır. Literatürdeki çalışmalardan farklı olarak bu model ile 18 farklı sınıfın %99.12 gibi yüksek bir oranla sınıflandırılması sağlanmaktadır.

TEŞEKKÜR (ACKNOWLEDGEMENT)

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

**ETİK STANDARTLARIN BEYANI
(DECLARATION OF ETHICAL STANDARDS)**

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

KAYNAKLAR (REFERENCES)

- [1] Abdoos, A. A., Mianaei, P. K., & Ghadikolaei, M. R. (2016). Combined VMD-SVM based feature selection method for classification of power quality events. *Applied Soft Computing*, 38: 637-646.
- [2] Ribeiro, P. F., Duque, C. A., Ribeiro, P. M., & Cerqueira, A. S. (2013). Power systems signal processing for smart grids. *John Wiley & Sons*.
- [3] Lee, Ian WC, and Pradipta K. Dash. "S-transform-based intelligent system for classification of power quality disturbance signals." *IEEE Transactions on Industrial Electronics* 50(4): 800-805, 2003.
- [4] Sahani, M., & Dash, P. K. (2018). Variational Mode Decomposition and Weighted Online Sequential Extreme Learning Machine for Power Quality Event Patterns Recognition. *Neurocomputing*.
- [5] Ribeiro, E. G., Mendes, T. M., Dias, G. L., Faria, E. R., Viana, F. M., Barbosa, B. H., & Ferreira, D. D. Real-time system for automatic detection and classification of single and multiple power quality disturbances. *Measurement*, 128: 276-283, 2018.
- [6] Kapoor, R., Gupta, R., Jha, S., & Kumar, R. Boosting performance of power quality event identification with KL Divergence measure and standard deviation. *Measurement*, 126: 134-142, 2018..
- [7] Khokhar, S., Zin, A. A. M., Memon, A. P., & Mokhtar, A. S. A new optimal feature selection algorithm for classification of power quality disturbances using discrete wavelet transform and probabilistic neural network. *Measurement*, 95: 246-259, 2017.
- [8] Moravej, Z., Banihashemi, S. A., & Velayati, M. H. Power quality events classification and recognition using a novel support vector algorithm. *Energy Conversion And Management*, 50(12): 3071-3077, 2009.
- [9] Ahila, R., Sadasivam, V., & Manimala, K. An integrated PSO for parameter determination and feature selection of ELM and its application in classification of power system disturbances. *Applied Soft Computing*, 32, 23-37, 2015.
- [10] Babu, N. R., & Mohan, B. J., Fault classification in power systems using EMD and SVM. *Ain Shams Engineering Journal*, 8(2): 103-111, 2017.
- [11] Drummond, C. F., & Sutanto, D., Classification of power quality disturbances using the iterative Hilbert Huang transform, 2010.
- [12] Yang, L., Yu, J., & Lai, Y. Disturbance source identification of voltage sags based on Hilbert-Huang transform. In *Power and Energy Engineering Conference Asia-Pacific*, 1-4, 2010.
- [13] Hafiz, F., Chowdhury, A. H., & Shahnaz, C., An approach for classification of power quality disturbances based on Hilbert Huang transform and Relevance vector machine. *7th International Conference In Electrical & Computer Engineering*, 201-204, 2012.
- [14] Önal, Y., & Turhal, Ü. Ç. The orthogonal Hilbert-Huang transform application in voltage flicker analysis. *Fourth International Conference on Power Engineering, Energy and Electrical Drives (POWERENG)*, 700-704, 2013.
- [15] Senroy, N., Suryanarayanan, S., & Ribeiro, P. F., An improved Hilbert-Huang method for analysis of time-varying waveforms in power quality. *IEEE Transactions on Power Systems*, 22(4): 1843-1850, 2007.
- [16] Manjula, M., Mishra, S., & Sarma, A. V. R. S., Empirical mode decomposition with Hilbert transform for classification of voltage sag causes using probabilistic neural network. *International Journal Of Electrical Power & Energy Systems*, 44(1): 597-603, 2013.
- [17] Ktonas, P. Y., & Papp, N., Instantaneous envelope and phase extraction from real signals: theory, implementation, and an application to EEG analysis. *Signal Processing*, 2(4): 373-385, 1980.
- [18] Picinbono, B. On instantaneous amplitude and phase of signals. *IEEE Transactions On Signal Processing*, 45(3): 552-560, 1997.
- [19] Huang, et al. "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis." *Proc. R. Soc. Lond. A* 454: 903-995, 1998.
- [20] Wu, Z., & Huang, N. E. Ensemble empirical mode decomposition: a noise-assisted data analysis method. *Advances in adaptive data analysis*, 1(01): 1-41, 2009.
- [21] Holland, J. H., Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence. *MIT Press*, 1992.
- [22] P. N. Tan, V. Kumar, and M. Steinbach, "Introduction to Data Mining", *Pearson*, 2005.
- [23] Fix E, Hodges JL, Jr., Discriminatory analysis, nonparametric discrimination. USAF School of Aviation Medicine, Randolph Field, Tex., Project 21-49-004, *Rept. 4*, Contract AF41(128)-31, February 1951.
- [24] Karasu, S., & Saraç, Z., Investigation of power quality disturbances by using 2D discrete orthonormal S-transform, machine learning and multi-objective evolutionary algorithms. *Swarm And Evolutionary Computation*, 2018.
- [25] Karasu, S., & Saraç, Z. Classification of Power Quality Disturbances with 2D Discrete Wavelet Transform and Bagged Decision Trees Method. *Journal Of Polytechnic-Politeknik Dergisi*, 21(4): 849-855, 2018.
- [26] Karasu, S., & Saraç, Z., Classification of power quality events signals with pattern recognition methods by using Hilbert transform and genetic algorithms. In *2018 26th Signal Processing and Communications Applications Conference*, 1-4, 2018.
- [27] Karasu, S., & Saraç, Z. Classification of power quality disturbances with S-transform and artificial neural

- networks method. In *Signal Processing and Communications Applications Conference*, 1-4, 2017.
- [28] Mahela, Om Prakash, Abdul Gafoor Shaik, and Neeraj Gupta. "A critical review of detection and classification of power quality events." *Renewable and Sustainable Energy Reviews* 41: 95-505, 2015.
- [29] Saini, M. K., & Kapoor, R. Classification of power quality events—a review. *International Journal of Electrical Power & Energy Systems*, 43(1): 11-19, 2012.
- [30] Kumar, R., Singh, B., Shahani, D. T., Chandra, A., & Al-Haddad, K. Recognition of power-quality disturbances using S-transform-based ANN classifier and rule-based decision tree. *IEEE Transactions on Industry Applications*, 51(2): 1249-1258, 2015.
- [31] Wang, M., Zhou, H., Yang, S., Jin, L., & Jiao, L., Robust compressive features based power quality events classification with Analog-Digital Mixing Network (ADMN). *Neurocomputing*, 171: 685-692, 2016.
- [32] Sebastian, P., & DŚa, P. A., Implementation of a Power Quality signal classification system using wavelet based energy distribution and neural network. *International Conference In Power and Advanced Control Engineering (ICPACE)* 157-161, 2015.
- [33] Ray, P. K., Mohanty, S. R., & Kishor, N. Classification of power quality disturbances due to environmental characteristics in distributed generation system. *IEEE Transactions on sustainable energy*, 4(2): 302-313, 2013.
- [34] He, S., Li, K., & Zhang, M., A real-time power quality disturbances classification using hybrid method based on S-transform and dynamics. *IEEE transactions on instrumentation and measurement*, 62(9): 2465-2475, 2013.
- [35] Khadse, C. B., Chaudhari, M. A., & Borghate, V. B. Conjugate gradient back-propagation based artificial neural network for real time power quality assessment. *International Journal of Electrical Power & Energy Systems*, 82: 197-206, 2016.
- [36] Camarena-Martinez, D., Valtierra-Rodriguez, M., Perez-Ramirez, C. A., Amezcua-Sanchez, J. P., de Jesus Romero-Troncoso, R., & Garcia-Perez, A., Novel downsampling empirical mode decomposition approach for power quality analysis. *IEEE Transactions on Industrial Electronics*, 63(4): 2369-2378, 2016.
- [37] Biswal, M., & Dash, P. K., Detection and characterization of multiple power quality disturbances with a fast S-transform and decision tree based classifier. *Digital Signal Processing*, 23(4): 1071-1083, 2013