

# Güç Kalite Bozukluklarında Örüntü Çıkarımı ve Tanısı için Bir Yaklaşım

## An Approach to Pattern Extraction and Diagnosis of Power Quality Disturbances

Turgay YALÇIN<sup>1</sup>, Muammer ÖZDEMİR<sup>1</sup>

<sup>1</sup>Elektrik - Elektronik Mühendisliği Bölümü

Ondokuz Mayıs Üniversitesi

Samsun, Türkiye

turgay.yalcin@omu.edu.tr, ozdemirm@omu.edu.tr

### Özet

Güç kalitesi sorunlarından, gerilim kırışması, harmonikler ve elektromanyetik girişim sonucunda şebeke güvenilirliği olumsuz yönde etkilenmektedir. Bu nedenle, bu tür bozuklukların kaynaklarının ve nedenlerinin bilinmesi, arızaların görüntülenmesi, tanısı ve öngörüsü, gerekli koruyucu önlemlerin alınmasına ve ileri aşamada sistemin kendi kendisini onarımında büyük ölçüde yarar sağlayacaktır. Çalışmanın işaret işleme aşamasının ilk bölümünde, güç kalite(GK) bozukluklarını sınıflandırmayı amaçlayan özellik çıkarma ve özellik seçiminde İçsel Kip işlevleri; TDKY (Toplu Deneysel (Görgül) Kip Ayırımı tarafından oluşturulmuştur. Özellikler Hilbert Huang Dönüşümü kullanılarak güç işaretlerinden çıkarılmaktadır. Hilbert Dönüşümü (HD) dönüşümünün çıkışları anlık frekanslar (AF) ve anlık genliklerdir (AG). Karakteristik özellikler 1. İçsel Kip İşlevlerinin (1. IMF' lerin) AF ve AG' den elde edilmektedir. Elde edilen 8 özellik ortalama, standart sapma, çarpıklık ve basıklık; AG ve AF eğrilerinden elde edilir. Çalışmanın son bölümünde HHD özellik çıkarımı algoritmasının başarımları; Destek vektör makinası (DVM) ve C4.5 Karar ağaçları sınıflayıcısı için denenmiştir ve karşılaştırılmıştır.

**Anahtar Kelimeler:** Güç Kalite Bozuklukları, Hilbert- Huang Dönüşümü, Destek Vektör Makineleri, C4.5 Karar Ağaç Sınıflayıcısı

### Abstract

When Voltage flicker, harmonics and electromagnetic interference the power quality problems are not overcome, this leads to breakdown of sensitive loads in smart grids, energy loss on transformers and engines. As a result of all these cases, grid reliability are affected negatively and the grid is broken down completely. That's why, knowing the causes and origins of this kind of disturbances, the monitoring, identification and prediction of faults will be considerably beneficial for taking necessary protective measures and self healing of the system in an advanced stage. In the first part of the signal processing side; IMFs are decomposed by EEMD (ensemble empirical mode decomposition) feature extraction and selection aiming classifying power quality disturbances. Features are extracted from the power electrical signals by using Hilbert Huang Transform (HHT). The outputs of HT are instantaneous frequency (IF) and instantaneous amplitude (IA). Characteristic features are obtained from first IMFs', IF and IA. The eight features obtained are mean, standard deviation, skewness and kurtosis of IF and IA. In last part of the study HHT feature extraction algorithms are first tested, then compared with the accuracy of classifiers such as Support Vector Machine (SVM) and C4.5 Decision Tree Classifier.

**Key words:** Power Quality Disturbances, Hilbert - Huang Transform, Support Vector Machines, C4.5 Decision Tree Classifier

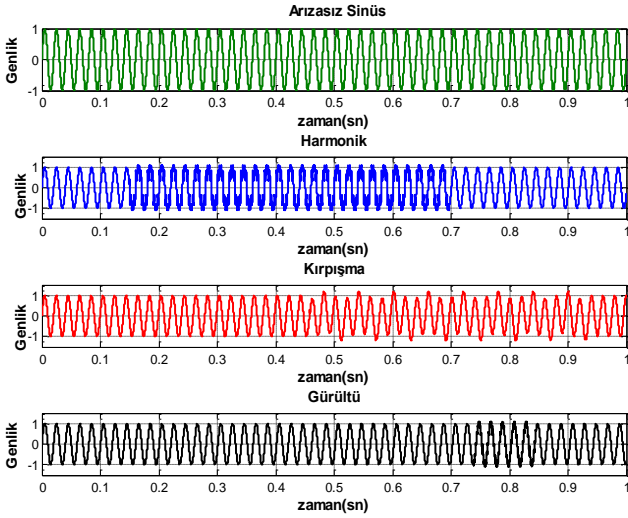
### 1. Giriş

Akıllı Şebekelerde güç kalitesinde harmonik ve kırışma (flicker) ve elektromanyetik girişim (gürültü) gibi sorunlar önemli rol oynar. Güç kalitesini doğrudan etkileyen bu etmenler sistem elemanlarının uyumlu şekilde ve etkin çalışmalarını engeller ayrıca bu bozukluklar üretim kalitesini ve verimi de düşürmektedir. Bu nedenle akıllı şebekelerde arızaların teşhisi, tanısı, önceden kestirim ve sınıflandırılması sorunu çok önemli ve güncel bir sorundur.

Gerçek zaman işaretlerini doğru bir şekilde temsil etmek üzere, akıllı şebekelerde güç kalite bozukluklarını ifade eden sentetik işaretler oluşturmak için kullanılan matematiksel denklemler çizelge 1' de belirtilmiştir. Sentetik işaretler, gerçek zamanlı işaretlerle tüm özellikleri ile eşleşmesi gerekir. Akıllı şebekelerde arıza tanımlama, tanı ve önceden hata sezim tekniklerinin başarımı için gereklidir. AA TECH- AWG1010 Rassal (arbitrary) işaret üretici ve Easywave yazılımıyla akıllı şebeke GK Harmonik ve Kırışma (flicker) bozuklukları işaretleri normalize olarak rastgele ve çizelge 1' deki değişken aralığına göre üretilmiştir. Şekil 1 AWG1010 işaret üretici ile üretilen GK bozukluk işaretlerini göstermektedir [1].

Çizelge 1. Kırışma, Harmonik Bozuklukların Matematiksel Modelleri

Olay	Denklem	Değişken Aralığı
Saf Sinüs	$V(t) = A \sin(\omega t)$	$A = 1 \text{ V p.u}$ frekans = 50 Hz
Harmonikler	$V(t) = \sum A(\alpha_i \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t))$	$0.05 \leq \alpha_3 \leq 0.15,$ $0.05 \leq \alpha_5 \leq 0.15,$ $0.05 \leq \alpha_7 \leq 0.15$
Kırışma (Flicker)	$V(t) = A \sin(\omega t)(1 + a \sin(b\omega t))$	$0.1 \leq a \leq 0.2, 0.1 \leq b \leq 0.4$
Gürültü (EMG)	$V(t) = A \sin(\omega t) + a \text{wgn}(A \sin(\omega t), 25)$	



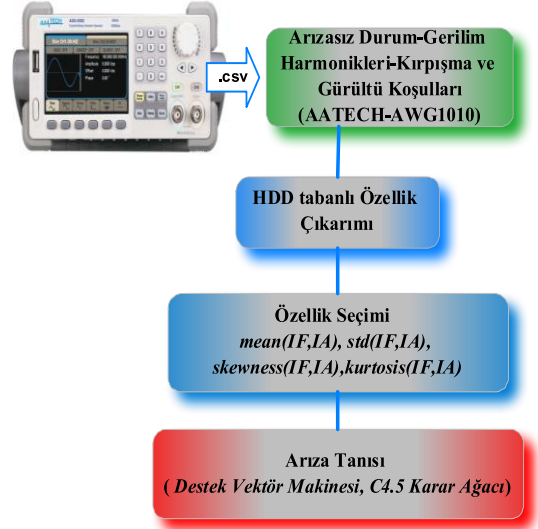
Şekil 1. AWG1010 işaret üretici ile üretilen GK bozukluk işaretleri

## 2. Güç Kalite Bozukluk Tanısı

GK bozukluklarında özellik çıkarımı ve seçimi, arıza tanısında ön işlem olarak da bilinir. Çıkarılan özellikler, GK olaylarının tanısında ve sınıflandırılmasında kullanılır (Şekil 2.). Ön işlem sonunda, tanılayıcı ve sınıflandırıcı algoritmaları kullanılarak son işlem birimi yoluyla kesin karar alınır [2]. GK olaylarının uygun özelliklerinin seçilmesi, tanı ve sınıflandırma açısından son derece önemlidir. Özellikler, doğrudan dönüşüme uğramış bazı alanlardan elde edilen orijinal ölçümlerden veya sinyal modelleri parametrelerinden çıkarılabilir [3]. Bu özellik çıkarım teknikleri ile ilgili son gelişmeler ışığında elde edilen sentetik veriler yardımıyla oluşturulan uygulamalar aşağıdaki bölümlerde ele alınmış ve sonuçları karşılaştırılmıştır [4].

### 2.1. Hilbert Huang Dönüşümü (HHD) Tabanlı Yöntemler

Hilbert Huang dönüşümü (HHD), 1998 yılında Dr. Huang tarafından önerilen ve iki ayrımlı süreçten oluşan yeni bir sinyal işleme algoritmasıdır [5]. Analiz edilecek sinyal, deneysel kip ayrıştırma (DKA) sürecinden geçirilerek; anlamlı anlık frekans ve genlik değerlerine sahip özgün tip işlevi (IMF) gerçekleşir. DKA sürecinde sinyal IMF'lere çözünür; bu süreçte IMF'ler, en yüksek frekanstan en düşük frekansa doğru sıralanır. Sinyal, IMF'lere ayrıştırıldığı zaman her IMF'ye Hilbert dönüşümü uygulanarak, anlık genlik (AG) ve anlık frekans (AF) ile karşılaştırmalı zaman eğrisi elde edilir. DKA süreci ve Hilbert dönüşümünün bu birleşimi, Hilbert-Huang Dönüşümü (HHD) olarak bilinmektedir [5]. Güç kalitesi olaylarının değerlendirilmesinde DKA ve Hilbert dönüşüm birleştirilmesiyle oluşan bir yöntem geliştirilmiştir [6]. Bununla birlikte, güç kalitesi sorunlarının, HHD ve Bağlantı Vektör Makinesi (BVM) kullanılarak sınıflandırılmasına yönelik bir yaklaşım, sunulmuştur [7]. HHD algoritması çoklu arıza, karmaşık güç kalite işareti üzerinde başarımlı gerçekleşmiştir. Doğrusal olmayan ve durağan olmayan işaretlerin çözümlemesinde HHD yerine Dikgen (ortogonal) Hilbert Huang Dönüşümü (DHHD) kullanılarak gerilim kırpışması analizi yapılmıştır [8].

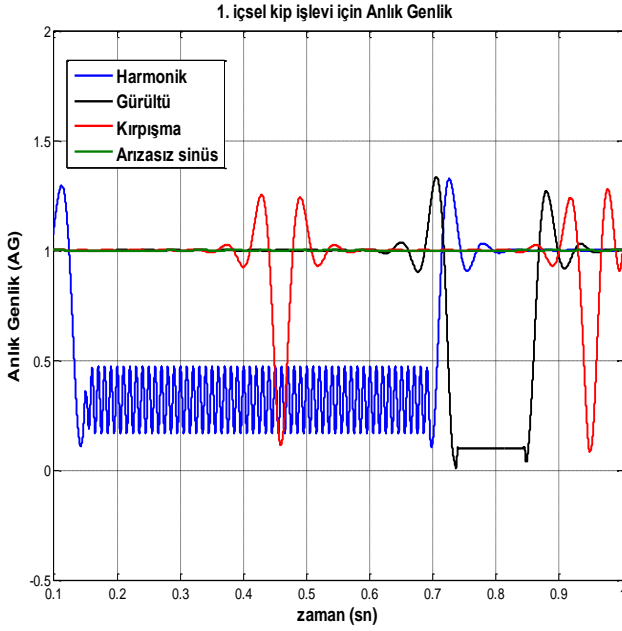


Şekil 2. Arıza tanısında işaret işleme teknikleri (HHD)

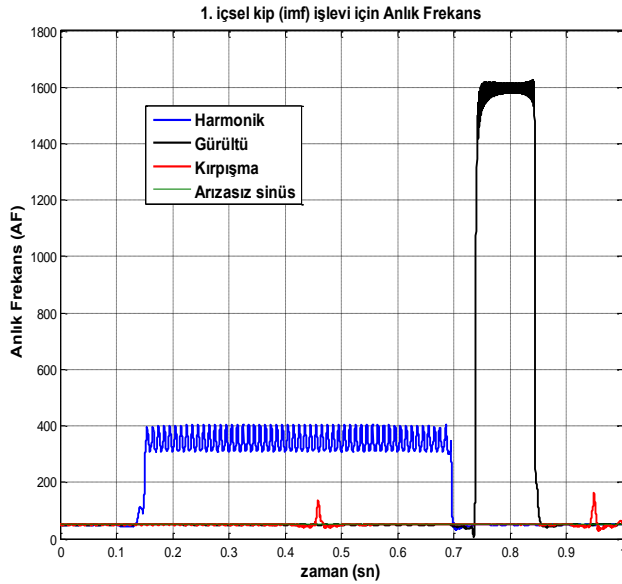
Çizelge 2. GK bozukluklarında işaret işleme tabanlı özellik çıkarım yöntemlerinin karşılaştırılması [4]

	DD	SD	HHD
<b>Avantajları</b>	Hem zaman, hem frekans boyutunda yerel tespit olanağı sağlar. Bu nedenle, iyi zaman-sıklık dengesi gereken hallerde uygundur.	Zaman alanından 2 boyutlu frekans dönüşümüne ve ardından Fourier frekans bölgesine tam dönüşümüne olanağı sağlar.	Bozulan dalga formunda özellik ayıklamasında yararlıdır; ürettiği sinyaller (imf'ler) sayesinde anlık genlik ve faz, kolaylıkla değerlendirilebilir.
<b>Dezavantajları</b>	Sinyalde bulunan gürültünün yüksek etkisi altındadır; spektral kaçaklar ve sınır duvar etkilerinden olumsuz etkilenir.	Blok işlemlere dayalı olup, gerçek zamanlı gereksinimleri karşılayamaz; frekans aralığı genişliğine bağlı olduğundan harmonikler hatalı ölçülür.	Sadece dar bant koşullarıyla sınırlıdır.

Şekil 3. arızasız sinus, gerilim harmonikleri, kırpışma ve gürültü durumlarında Anlık genlik (AG) durumlarını; şekil 4. arızasız ve gerilim bozuklukları durumlarında Anlık frekans (AF) durumları göstermektedir. Anlık genlik ve anlık frekans izgeleri sınıflandırıcı için bozuklukları ayırt etmede özellik çıkarımı için kullanılmıştır.



Şekil 3. GK bozuklukları için Anlık genlik (AG) değişimi



Şekil 12. GK bozuklukları için Anlık genlik (AF) değişimi

### 3. GK Bozukluk Tanısında Özellik Seçimi

GK arıza türlerinin tanısı ve sınıflandırılması için, önerilen işaret işleme yöntemleri (HHD, SD) aracılığıyla üretilen özellik vektörü seçiminde, Ortalama (Mean), Standart Sapma (Standard Deviation), Çarpıklık (Skewness), Basıklık (Kurtosis) istatistiksel işlevler kullanılmıştır. Çıkarılan özellik vektörleri aşağıda sırasıyla verilmektedir:

### 3.1. HHD Tabanlı Tanılayıcı ve Sınıflayıcılar

HHD sonucu elde edilen; Anlık genlik (AG) değerleri için:

#### F1- Ortalama-mean (Anlık Genlik(AG))

$$x = \frac{1}{N} \sum_{i=1}^N x_i \quad (1)$$

#### F2- Standart sapma-std (Anlık Genlik(AG))

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - x)^2} \quad (2)$$

#### F3- Çarpıklık - Skewness (AG)

$$\sigma_{skew} = \frac{1}{(N-1)\sigma^3} \sum_{i=1}^N (x_i - x)^3 \quad (3)$$

#### F4- Basıklık - Kurtosis (AG)

$$\sigma_{kurt} = \frac{1}{(N-1)\sigma^4} \sum_{i=1}^N (x_i - x)^4 \quad (4)$$

HHD sonucu elde edilen; Anlık frekans (AF) değerleri için:

#### F5- Ortalama-mean (Anlık Frekans(AF))

#### F6- Standart sapma-std (Anlık Frekans(AF))

#### F7- Skewness (Anlık Frekans(AF))

#### F8- Kurtosis (Anlık Frekans(AF))

8 tür özellik vektörü çıkarılmıştır.

## 4. GK Bozukluklarının Tanısı Algoritmaları

Bu bölümde GK bozuklukları tanı ve sınıflandırılmasında kullanılan başarımlı yüksek sınıflandırıcı [9], C4.5 Karar Ağaç Algoritması hakkında bilgi verilmektedir.

### 4.1. Karar Ağaçları

Karar ağaçları, tümevarımla öğrenme biçimi olarak böl-yönet izlemi kullanılan araçlardır. Bunun başlıca kazanımı; derli toplu ve ayrıntılı olarak okunabilen ve sonuçların da kolaylıkla anlaşıldığı yapılar oluşturulmasıdır. Bu amaçla kullanılan ağaç sunumu; bir dizi birleşik düğüm halinde hiyerarşik olarak yapılandırılmış veri kümeleri halinde örüntü sınıflandırmasına yardımcı olur. Bunların iç düğümleri kullanılarak bir girdi niteliği/özelligi ve bir karar sabiti elde edilir ve bu şekilde aşağıya doğru bir sonraki düğümde ne olacağı saptanır. Bu bağlamda yapraklar şeklinde düşünülen düğümler, kullanıma sunulan etikete göre kendilerine ulaşan olayları sınıflandırır. Dolayısıyla bir karar ağacındaki her bilgi bir düğüm ile temsil edilir ve sürekli

bir düğüm arayışı ile bir yaprak düğümüne dek bu döngü sürer [10, 11]. Bir ağacın tümevarım süreci, manuel olarak gerçekleştirilebilir. Ancak çok sayıda veri bulunması durumunda bu süreç kapsamlı ve ayrıntılı hale geleceğinden, normal koşullarda denetimli öğrenimde uygulanan bir otomatik tümevarım yaklaşımı benimsenebilir [11, 12]. Bu şekilde devam eden algoritma sonucunda, bir dizi eğitim verisi ve bundan beklenen çıktı değerlerinden yola çıkılarak ağacın düğüm ve yaprakları saptanır. Bu proje çalışmasında, karar ağaçlarının otomatik tümevarım süreci için C4.5 algoritmasını kullanılmıştır. C4.5 algoritması çerçevesinde; bir eğitim seti yardımıyla ağaç oluşturulması ve her düğümde kullanılacak değer/özellik seçimi için bilgi edinme ölçütünden yararlanılması öngörülmektedir.

## 5. Deneysel Çalışmalar

AA TECH- AWG1010 rassal işaret üreticisiyle Easywave yazılımıyla elde edilen Harmonik, Kırpışma (flicker) ve Elektromanyetik Girişim (Gürültü) GK bozukluk işaretleri normalize olarak rastgele üretilmiştir. Üreticinin arayüz yazılımında veriler.csv, excel çalışma kitabı hazırlanmıştır. Önerilen çalışmada işaretin işleme kısmı ve arıza tanısı ve sınıflandırılması MATLAB araç kutusu yardımıyla gerçekleştirilmiştir. Önerilen tanı algoritmasının başarımlarını sınamak ve karşılaştırmak için HHD sonucu elde edilen; Anlık genlik (AG) ve anlık frekans (AF) değerleri için istatistik işlevler (ortalama, standart sapma, çarpıklık, basıklık) kullanılarak arıza türlerini sınıflandırmak için 160 (8x20) özellik vektörü çıkarılmıştır. 20 eğitim veri kümesi, 6 test veri kümesi olmak üzere toplamda 26 arızasız ve güç kalite bozukluğu veri kümesi kullanılmıştır.

Veri Kümesi 3 tür durağan olmayan bozukluktan oluşmuştur.

- VF (voltage flicker) – gerilim kırpışması
- VH (voltage harmonics) – harmonikler
- VEM (EMI) – elektromanyetik girişim

**Çizelge 3.** Hilbert – Huang Dönüşümü Tabanlı, Bire-karşı diğerleri (OAA) çoklu DVM sınıflandırıcıları performans tablosu

20 Eğitim verisi / 6 Test verisi	VF	VH	VEM (EMI)
VF	2	0	0
VH	0	2	0
VEM (EMI)	0	0	2

Çizelge 3.' de Hilbert – Huang Dönüşümü Tabanlı Bire-karşı diğerleri (OAA) çoklu DVM sınıflandırıcıları performans tablosu gösterilmiştir. Çizelge 3.' ün köşegenlerindeki elemanlar doğru tahminleri; dışındaki elemanlar ise sınıflandırma hatasını göstermektedir. 6 test kümesi Bire- karşı- diğerleri (OAA) yöntemi % 100 doğrulukla sınıflandırılmıştır.

**Çizelge 4.** Hilbert - Huang Dönüşümü Tabanlı - Farklı türdeki sınıflandırıcıların başarımlar tablosu

Sınıflayıcı (Classifier)	(Hata) Error	Doğruluk (Precision)	CPU zamanı (sn)
DVM-Doğrusal	0.0000s	1.000	4.640
DVM-Polinom kernel $d=2$	0.0000	1.000	4.810
DVM-RTİ $\sigma = 0.01$	0.0000	1.000	4.960
DVM-RTİ $\sigma = 1$	0.0000	1.000	4.940
<b>C4.5 – Karar Ağacı</b>	<b>0.0000</b>	<b>1.000</b>	<b>2.250</b>

Çizelge 4. Hilbert - Huang Dönüşümü Tabanlı - Farklı türdeki sınıflandırıcıların başarımlar tablosunu göstermektedir. DVM için çekirdek (kernel) işlevinin türü de sınıflayıcının başarımlarını CPU süresi yönüyle etkilemektedir. Çizelge 4.' e bakıldığında radyal tabanlı çekirdek işlevi (RTİ) kullanan DVM en başarılı sınıflayıcı olmakla birlikte sigma (0.01 - 1) değerinin değişimiyle daha kısa sürede arızayı tanıladığı gözlenir. Gerçek zamanlı sınıflandırma problemi için CPU zamanı da sınıflayıcı seçiminde önemli bir etkidir. Başarımı en yüksek sınıflayıcı C4.5 Karar ağacı (Decision Tree) tanı algoritmasıdır. Özellik çıkarımı yapılan arıza türlerinin gözetimsiz öğrenmeli (unsupervised learning), k - Ortalamalar, k - en yakın komşu kümeleme algoritmaları vb. başarımlarını sınanacaktır.

## 6. Sonuçlar

Bu çalışma sonucunda akıllı şebekelerde güç kalite bozuklukları (Harmonikler, kırpışma ve gürültü ) etkili bir şekilde gerçek zamanlı çalışmalar için sınıflandırılmaları amacıyla güncel işaret işleyici Hilbert - Huang dönüşümü kullanılarak özellik vektörleri çıkarılmıştır. Çoklu tanı ve sınıflandırma problemini çözmek için ise destek vektör makineleri ve C4.5 Karar ağacı sınıflayıcısı gibi yüksek performanslı sınıflayıcılarla sınanmıştır. Yüksek başarımlı sonuçlar elde edilmiştir. 5. bölümde sonuçlar çizelgeler kullanılarak karşılaştırılmıştır başarımlar düşük tanı algoritmalarının performansını artırmak için çalışmalar devam etmektedir. Gelecek çalışmalarda tek fazlı yük türleri (D sınıfı yük türleri PC, Monitör), kullanıcı sayısı, hata türü ve kaynak gerilimi arasındaki doğrusal olmayan problem ilişkisi incelenecektir.

## Teşekkür

Bu çalışma TÜBİTAK tarafından 114E919 numaralı proje kapsamında desteklenmiştir.

## 7. Kaynaklar

- [1] Yalcin T., Ozdemir M., “Akıllı Şebekelerde Güç Kalitesi Bozukluklarının İşaret İşleme Yöntemleriyle Tanısı”, 3rd International Istanbul Smart Grid Congress and Fair (ICSG 2015), 29-30 April, Istanbul, Turkey, 2015.
- [2] Saxena D., Verma KS., Singh SN. “Power quality event classification: an overview and key issues”. *Int J Eng Sci Technol* 2010; 2(3):186–99.
- [3] Ji TY, Wu QH, Jiang L, Tang WH. “Disturbance detection, location and classification in phase space.”, *IET Gener Transm Distrib* 2011;5(2):257–65.
- [4] Mishra S., Nagwani T., “A Review on Detection and Classification Methods for Power Quality Disturbances” , *IJESC Volume 6 Issue No. 3*, 2016.
- [5] Inigo M., Carlos L., Jorge R., Antonio G., Antonio ., Juan M. C. , “Classification of electrical disturbances in real time using neural networks.”, *IEEE Trans Power Deliv* 2007;22(7):1288–96.
- [6] Ozgonenel O., Yalcin T., Guney I., Kurt U., “A New Classification for Power Quality Events in Distribution System”, *Electric Power System Research (EPSR)*, 95, 192-199,2013.
- [7] Julio B., Julio D. I., Matilde De A.. “Applications of wavelets in electric power quality: voltage events.”, *Electr Power Syst Res* 2012;88:130–6.
- [8] Ming Z., Kaicheng L., Yisheng H.. “A real-time classification method of power quality disturbances.” *Electr Power Syst Res* 2011;81:660–6.
- [9] Wu X., Kumar V., Quinlan J.R., Ghosh J., Yang Q., Motoda H., McLachlan G. J., Ng A., Liu B., Yu P. S., Zhou Z.-H., Steinbach M., Hand D. J., Steinberg D., “Top 10 algorithms in data mining,” *Knowledge and Information Systems*, 2008,14:1-37.
- [10] Witten I. H. and Frank E., *Data Mining: PraticalMachine Learning Tools and Techniques*. San Mateo, CA, USA: Morgan Kaufmann, 2005.
- [11] Quinlan R. J., *C4.5: Programs for Machine Learning*, vol. 1. San Mateo, CA, USA: Morgan Kaufmann, 1993.
- [12] Borges F. A. S., Fernandes R. A. S., Silva I. N., Silva C. B. S., “Feature Extraction and Power Quality Disturbances Classification Using Smart Meters Signals” *IEEE TRANSACTIONS ON INDUSTRIAL INFORMATICS*, VOL. 12, NO. 2, 2016.