

BİRLEŞİK DALGACIK-SİNİR AĞI MODELİ YAKLAŞIMI İLE ELEKTRİK GÜÇ SİSTEMLERİNDE ARIZA SINIFLAMA

Oben DAĞ¹

Canbolat UÇAK²

^{1,2}Elektrik-Elektronik Mühendisliği Bölümü
Mühendislik-Mimarlık Fakültesi

Yeditepe Üniversitesi, 34755, Erenköy, İstanbul

¹e-posta: obendag@yeditepe.edu.tr

²e-posta: canbolat@yeditepe.edu.tr

ABSTRACT

This paper presents an integrated design of a fault classifier which uses a hybrid Wavelet-Artificial Neural Network (ANN) based approach. The data for the fault classifier is produced by PSCAD/EMTDC simulation program for 34.5 kV Sağmalcılar-Maltepe distribution system in Istanbul, Turkey. It is aimed to design a classifier capable of recognizing ten classes of three-phase distribution system faults. A database of line currents and line-to-ground voltages is built up including system faults at different fault inception angles and fault locations. The characteristic information over six-channel of current and voltage samples is extracted by the wavelet multi-resolution analysis technique. Then, an ANN-based tool was employed for classification task. The main idea of this approach is to solve the complex fault (three-phase short-circuit) classification problem under various system and fault conditions. A self-organizing map, with Kohonen's learning algorithm and type-one learning vector quantization technique is implemented into this study. The performance of the wavelet-neural fault classifier is presented and the results are analyzed in the paper. It is shown that this technique correctly recognizes and discriminates the fault types and faulted phases with a high degree of accuracy in the simulated model distribution system.

Anahtar Kelimeler—Enerji dağıtımı, arıza sınıflama, dalgacık dönüşümü, çoklu-çözünürlük analizi, yapay sinir ağları, kendine-organize özellik haritaları, vektör kuantalamayı öğrenme.

1. GİRİŞ

Kaliteli elektrik enerjisi üretimi ve tüketicilere temin edilmesi günümüzde son derece önemli bir yere sahiptir. Kullanılan yüklerin verimini ve etkinliğini azaltması sebebiyle tüketiciler, güç kalitesindeki bozulmalara ve arızalara artık daha az tolerans göstermektedir. Elektrik enerjisinin kalitesini arttırmak için tüketicilere dağıtılan enerjinin sürekli izlenmesi yoluna gidilmektedir. Güç izleme cihazları kullanılarak bozucu dalga şekilleri izlenmekte ve kayıt

edilmektedir. Bununla birlikte, bu cihazlar, yakalanan sinyallerin verimli ve hızlı bir şekilde ayrıştırılması yeteneğinden çok dalga şekillerinin görsel takibine dayandığından, yüksek miktarda verinin sınıflanması görevi uzman güç kalitesi mühendislerince yapılmaktadır [1].

Güç izleme cihazlarının dalga şekillerini yakalayıp kaydetme özelliklerine ek olarak bu sinyalleri sınıflayabilme becerisine sahip olmaları arzulanan bir özelliktir. Bu özellik, otomasyon sistemlerinde hızlı ve etkin karar verme süreçlerinin sağlanmasına olanak tanıyacaktır. Sonuç olarak güç sistemlerinden optimum verimin alınması ve tüketici memnuniyetsizliklerinin de azaltılması mümkün olabilecektir.

Bu çalışmada, bozucu dalga şekillerinin sınıflanması konusu için önem taşıyabilecek bir yaklaşım sunulmaktadır. Yapılan çalışmanın ana fikri, on adet 3 faz sistem arızalarının tanımlanmasına olanak sağlayacak bir akıllı sistem tasarlanmasıdır. Arıza tipi bulunduktan sonra gerekli mekanizmalar hızlı bir şekilde devreye alınarak elektrik enerjisinin kalitesinin kesintiye uğramasının önüne geçilebilecektir. Bu amaçla, öncelikli olarak 12-baralı 34,5 kV Sağmalcılar-Maltepe dağıtım şebekesi PSCAD/EMTDC ile simule edilerek her arıza tipi için altı kanal akım ve gerilim bilgileri elde edilmiştir. Daha sonra dalgacık dönüşümü ve çoklu çözünürlük analizi kullanılarak her sınıf için ayırt edici öz-nitelik vektörleri elde edilmiştir. Bu veriler elde edildikten sonra yapay sinir ağı (YSA) tabanlı sınıflayıcı modeli kullanılarak girilen sinyallerin birbirinden ayırt edilmesi sağlanmıştır. Elde edilen sonuçlar, bildirinin son bölümünde verilmiştir. Bu bildiri, [2] ve [3] çalışmalarının bir derlemesi niteliğindedir. Daha detaylı bilgi için bu kaynaklara başvurulabilir.

2. ÖZ-NİTELİK ÇIKARILMASI

Bu çalışmada sunulan arıza saptama ve sınıflama yaklaşımı şu üç genel adımdan oluşmaktadır: hat akımı ve hat-toprak gerilimlerinin üretilmesi, bu sinyal kümeleri kullanılarak YSA'nın eğitilmesi ve sistemin test edilmesi. Eğitim kümeleri

elektromanyetik geçici bileşen benzetim programı kullanılarak elde edilmiştir. Sınıflama performansını **arttırmak** amacıyla, üretilen sinyaller bir ön işlemde geçirilmiştir. Bu ön-işleyici modülünün görevi dalga şekillerinin belirli karakteristiklerini çıkartmak ve buna ek olarak bu sinyallerden oluşan veri yığını boyutlarını azaltarak YSA ağının yükünü azaltmaktır. Öz-nitelik çıkartma işleminin hedefleri; (i) kategorilerin tipik karakteristiklerinin elde edilmesi, ve (ii) kategoriler arası ayırt edici niteliklerin çıkartılmasıdır. Bu bildiriye sunulan özellik çıkartım yöntemi dalgacık dönüşümü (DD) ve çoklu-çözünürlük analizi (ÇÇA) tekniklerine dayanmaktadır. ÇÇA, ayrık dalgacık dönüşümü (ADD) kullanarak zamanla değişen sinyallerin frekans bileşenleri olarak ifade edilmesini sağlamaktadır [4]. ÇÇA, zaman uzayındaki tek boyutlu bir işaretin zaman ve ölçek uzayında iki boyutlu bir fonksiyona dönüştürülmesine olanak sağlar. DD, işaretlerin farklı ölçek ve pozisyonlarda basit bloklar (dalgacıklar) halinde ifade edilmesini sağlar. Asıl amaç, karmaşık bir $f(t)$ işaretini ortonormal baz fonksiyonları (ölçekleme ve dalgacık fonksiyonları) biçiminde ifade edebilmektir. Ölçekleme ve dalgacık fonksiyonları, farklı pozisyonlarda ve ölçeklerde dalgacıklar elde edilmesi amacıyla dönüştürülmekte ve ölçeklendirilmektedir. Dalgacık fonksiyonları verilen işaretin detaylarına karşılık gelen yüksek frekans bileşenlerini, ölçekleme fonksiyonu ise sinyalin alçak frekans bileşenlerini göstermektedir. Bu iki fonksiyon kullanılarak $f(t)$ işareti yeniden oluşturulabilir. Bu ise çoklu çözünürlük işaret oluşturma (MSD) yöntemi olarak adlandırılmaktadır. ADD ve MSD tekniklerinin detaylı tanımlaması [5] makalesinde bulunabilir.

3. UYARLAMALI ÖRÜNTÜ SINIFLAYICI

Arıza sınıflama çalışmalarında kullanılan YSA modellerinin birçoğu, çok katmanlı ileri-beslemeli ağ mimarisine sahiptir. Geleneksel eğitici geriye yayılım (GY) algoritmasında giriş-çıkış kümelerinden oluşan örnekler YSA'ya verilmekte ve YSA'nın giriş-çıkış verileri arasındaki ilişkiyi öğrenmesi beklenmektedir. Bununla birlikte, GY ağının eğitim süreci zaman alma, yüksek miktarda eğitim kümesi gerektirme ve kolay bir şekilde yerel minimum noktasında çakılı kalabilme zaaflarına sahiptir. Bundan başka, YSA'nın yeni eğitim kümeleri ile eğitimi de zor olabilmektedir. Sonuç olarak bu yöntem arıza sınıflama için yeterli olmayabilir. Bir başka yaklaşım ise kendine-organize ağ tasarımı kullanarak eğitici öğrenme algoritması ile sınıflama yapmaktır. Burada sınıflayıcı ağının görevi arıza sınıflarını kümelemektir; bu ise bir örüntü tanımlama problemi olarak nitelendirilebilir. Kendine-organizasyon, dışardan eğitici örnekleri verilmeksizin öğrenme işlemi olarak nitelenebilir. Burada giriş örnekleri sisteme verildiğinde, kendine-organize ağı oluşturan birbirine komşu işlem birimleri (nöronlar) bu örneklerin öz-niteliklerini yakalayıcı dedektörler niteliği kazanmaktadır. Bu şekilde herbir yerel nöron

grubu girişte verilen örnekler için kodlayıcı vazifesi görmektedir [6]. Eğitici öğrenme metodu ile öğrenme aşamasından sonra YSA sınıflama görevi için hazır hale gelmektedir; böylece giriş verilerinden alınan öz-nitelikler sınıflara atanmaktadır. Bir kendine-organize haritası tekil olarak sınıflayıcı rolü alabilmesine rağmen, literatürde [7] ve [8], en iyi performans için kendine-organize haritasının (KOH) bir eğitici öğrenme modeli ile birleştirilmesi önerilmiştir. Burada kendine-organize haritasının işlevi, bir uyarlamalı örüntü sınıflama probleminin ilk safhası olarak nitelenebilir. İkinci aşamada vektör kuantalamayı öğrenme (LVQ) tekniği ile özellik haritasının iyileştirilmesi sağlanmaktadır. Kendine-organize harita ile eğitici öğrenme yapılarının birleşimi hibrit uyarlamalı örüntü sınıflayıcısını oluşturmaktadır [6].

Bu çalışmada, Kohonen algoritmasını kullanarak KOH ve LVQ teknikleri uygulanmıştır [7]. KOH, karmaşık doğrusal olmayan yüksek boyutlu veri içindeki gizli bilginin elde edilmesini ve bunun düşük boyutlu basit geometrik bir yapı şeklinde gösterilmesini sağlamaktadır.

KOH eğitim prosedürü iteratiftir; her eğitim adımında giriş veri kümesi içinden örnek bir x vektörü rasgele seçilerek, bu vektör ile diğer prototip vektörleri arasındaki mesafe hesaplanır. b ile gösterilen en iyi uyan birim (BMU) x vektörüne en yakın prototip vektörünü içeren harita elemanı (nöron) olmak üzere şu şekilde ifade edilir;

$$\|x - m_b\| = \min_i \{\|x - m_i\|\} \quad (1)$$

Daha sonraki aşamada prototip vektörleri güncellenir. BMU ve onun topolojik komşuları giriş uzayında başlangıçta girilmiş olan giriş vektörüne yaklaştırılır. Bir i elemanındaki prototip vektörünün güncellenmesi

$$m_i(t+1) = m_i(t) + \eta(t)h_{bi}(t)[x - m_i(t)] \quad (2)$$

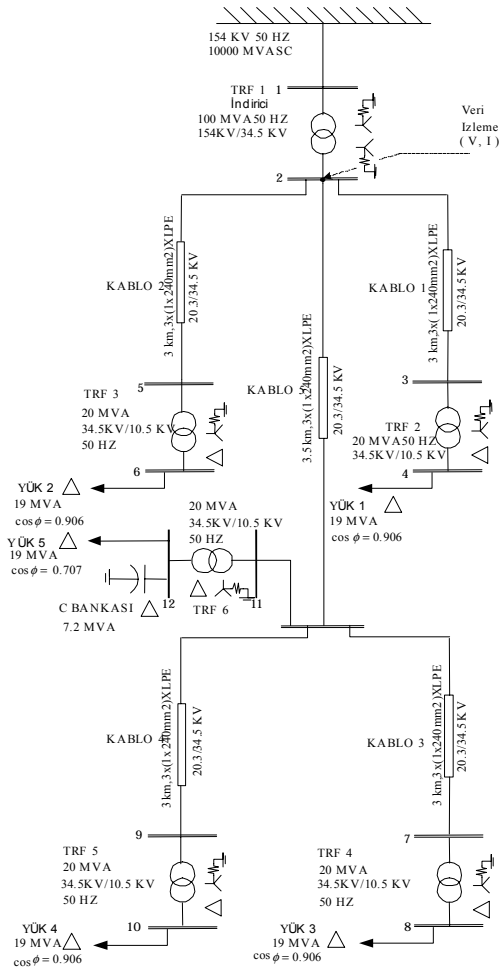
kuralına [6] göre yapılır. Burada t ayrık zaman, $0 < \eta(t) < 1$ zamana bağlı öğrenme oranı, $h_{bi}(t)$ kazanan eleman için komşuluk fonksiyonudur.

Bu çalışmada, Kohonen'in LVQ1 algoritması [7] eğitici sınıflayıcı olarak modele eklenmiştir. LVQ1 algoritması, sınıf bilgisini kullanarak KOH üzerindeki Voronoi vektörlerinin yavaşça hareket ettirilerek, sınıflayıcının karar bölgelerindeki ayırtedebilme becerisinin artırılmasını sağlamaktadır.

4. BENZETİM SONUÇLARI

Bu çalışmadaki arıza sınıflama problemi, on adet kısa-devre sistem arızalarının ayırt edilebilmesi çalışmasını kapsamaktadır. Bu sınıflar AG , BG , CG , AB , AC , BC , ABG , ACG , BCC , ve $ABCG$ olarak adlandırılmaktadır. A , B , C ve G harfleri sırasıyla faz A, faz B, faz C ve

toprak olarak tanımlanmıştır.



Şekil 1. 34.5 kV Sagmalcılar-Maltepe Dağıtım Şebekesinin Tek-Hat Diyagramı.

Çalışmada, İstanbul'daki bir dağıtım şebekesinin PSCAD/EMTDC programı ile benzetimi yapılmıştır. Test sisteminin ağ parametreleri Şekil 1 üzerinde gösterilmiştir. 12-baralı sistemin baz gerilimi 34.5 kV, baz gücü ise 100 MVA dir. Tüm test verisi Şekil 1 de düğüm 2 olarak gösterilen ana indirici trafonun (TRF1) sekonder barası üzerinden alınmıştır. Amaç, sadece 34.5 kV baradan alınan akım ve gerilim bilgisini kullanarak şebekenin herhangi bir noktasında oluşan arızanın tanımlanabilmesidir. Herbir örnek kümesi, bir saha izleme cihazının tipik olarak yakalayacağı ve işlenmek üzere hafıza ünitesinde saklayabileceği üç kanal hat akımı ve üç kanal hat-toprak gerilimi sinyallerinden oluşmaktadır.

A. PSCAD/EMTDC ile sinyal üretilmesi

PSCAD/EMTDC yazılımı ile test sisteminin çeşitli noktalarında ve farklı oluşum anlarında tek faz toprak, iki faz, iki faz toprak, ve üç faz toprak olarak dört tip arıza senaryolarını içeren benzetimler yapılmış ve altı kanal işaret bilgilerini içeren bir veritabanı oluşturulmuştur.

Daha sonra, altı kanal dalga şekillerinden meydana gelen veri kümeleri oluşturularak sınıflama modelinin

ikinci aşamasını oluşturan işaret ön-işleyiciye girilecek hale getirilmiştir. Bu veri kümesinde, herbir kanal 5 kHz örnekleme frekansında (50 Hz temel frekans), 200 [msn] lik 10 periyod şeklinde üretilmiştir. Böylece, (1001,6) matris boyutlarında altı-kanal veri kümeleri oluşturulmuştur.

B. ÇRA ile öz-nitelik çıkarılması

Öz-nitelik seçimi işleminde kullanılan kriter, herbir sınıfı diğerlerinden ayırt etmeyi sağlayan önemli karakteristiklerin elde edilmesidir. Dalgacık çoklu çözünürlük analiz tekniği bir ön-işleyici şeklinde kullanılarak, her sınıf daha küçük boyutlarda veri kümeleri biçimine dönüştürülmüştür. Öz-niteliklerin elde edilmesi sürecinde dalgacık dönüşümü tekniğinin kullanılmasındaki ana fikir, herbir işaret tipi için elde edilen dalgacık dönüşümü katsayılarının özgün ve tek olmasıdır. Dalgacık dönüşümü tekniğine ek olarak tanımlayıcı istatistik analiz tekniği de kullanılarak veri kümesinin en belirleyici özelliklerden oluşan yapılar biçimine indirgenmesi amaçlanmıştır.

Burada on-katsayılı Daubechies filtresi ile diydik-ortonormal dalgacık dönüşümü kullanılarak beş-seviyeli MSD analizi uygulanmıştır. Böylece, hem yüksek hem de alçak frekanslardaki tüm bozucu özelliklerin yakalanması sağlanmıştır.

C. Öz-nitelik Vektörü

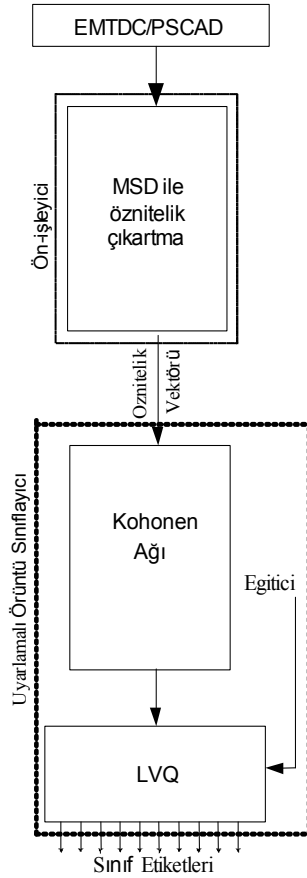
Altı kanal akım ve gerilim örneklerindeki karakteristik bilgi, Şekil 2'de görülen ön-işleyici ile çıkartılmıştır. Herbir altı kanal veri kümesi, 27 parametreden oluşan öz-nitelik vektörlerine dönüştürülmüştür. Buna göre, bir öz-nitelik vektörü parametreleri şunlardır:

- i. Arıza oluşumundan önce herbir akım işaretinin genliği.
- ii. Arıza oluşum anında herbir akım işaretinin genliği.
- iii. Herbir akım işareti kanalının 0.078-0.156 kHz bandında enerjisi.
- iv. Herbir akım işareti kanalının 0.156-0.312 kHz bandında enerjisi.
- v. Herbir akım işareti kanalının 0.312-0.625 kHz bandında enerjisi.
- vi. Herbir akım işareti kanalının 0.625-1.259 kHz bandında enerjisi.
- vii. Herbir akım işareti kanalının 1.250-2.500 kHz bandında enerjisi.
- viii. Herbir gerilim işareti kanalındaki güç bileşeni.
- ix. Herbir gerilim işareti kanalındaki enerji bileşeni.

Yukarıda verilen parametrelerin tanımı şu şekilde yapılabilir: Akım işaretlerinin enerji bileşeni, Parsevals Teoremi ([8], [9]) kullanılarak farklı çözünürlük seviyelerinde elde edilmiştir. Beş-seviye MSD'nin farklı çözünürlük seviyelerindeki ADD katsayılarının standart sapması, akım işaretlerinin enerji bileşeni olarak kullanılmaktadır. Her akım

kanalı için beş-seviye detay katsayılarının standart sapmaları hesaplanarak onbeş parametre elde edilmiştir. Sınıflayıcı verimine yardımcı olması amacıyla akım işaretlerinin genliklerindeki değişme bilgisi de öz-nitelik olarak kullanılmıştır ve altı adet parametre elde edilmiştir. Yavaş bir değişim gösteren (gerilim sarkmaları ve şişmeleri gibi) olayların saptanması için gerilim işareti güç bileşeni (ortalama karesel değeri) kullanılmıştır [10]. Üç adet gerilim işareti için hesaplanan güç bileşenleri de öz-nitelik vektörü için üç bileşen oluşturmuştur. Bunlardan başka, sınıflayıcının verimini iyileştirmek için gerilim işaretlerinin standart sapması da hesaplanarak öz-nitelik vektörünün diğer üç parametresi elde edilmiştir.

Elde edilen öz-nitelik vektörü, daha sonraki aşamada, YSA'ya giriş verisi olarak uygulanmaktadır.



Şekil 2. Uyarlamalı örüntü sınıflayıcı mimarisi.

D. YSA sınıflayıcısı ve benzetim sonuçları

PSCAD/EMTDC kullanılarak 350 farklı durumdan oluşan bir veritabanı oluşturulmuştur. Herbir arıza durumu için veri kümeleri Şekil 2'de gösterilen ön-işleyici kullanılarak işlenmiş ve 27 parametreden oluşan 350 adet giriş vektörü elde edilmiştir. Giriş

vektörü veri kümelerinden oluşan veritabanı biri YSA'nın eğitim fazı, diğeri ise YSA'nın test fazı için olmak üzere iki parçaya ayrılmıştır. Eğitim kümesi 250 adet örnekten (her sınıf için 25 adet örnek) oluşmaktadır. Test kümesi ise 100 adet (her sınıf için 25 örnek) örnekten oluşmaktadır.


Şekil 2'de gösterilen hibrid örüntü sınıflayıcı üzerinde birçok parametre değişimi yapılarak (kendine-organize harita boyutu, harita yapısı gibi) farklı benzetimlerle en iyi performansın elde edilmesini sağlayacak sistem elde edilmiştir. Optimum performans; lineer, dikdörtgen yapıda, (8,10) boyutunda harita ile elde edilmiştir. Sınıflama oranı eğitim kümesi için % 99.0 ve sisteme daha önce hiç girilmemiş test kümesi için % 92.0 olarak elde edilmiştir. Benzetim sonuçları hakkında detaylı bilgi [2] ve [3]'de bulunabilir.

KOH'un LVQ1 ile eğitilmesinden sonraki durumu Şekil 3'de gösterilmiştir. Bu gösterim biçimi hit-histogramları olarak nitelenen [11]; bir veri kümesinin alınıp, herbir örnek için BMU'nun elde edilmesi ve harita elemanındaki sayıcının her yeni BMU oluşunda artırılması yöntemi ile oluşturulmaktadır. Hit-histogramlarının boyutu, o bölgedeki harita elemanının (nöron) kaç kez BMU seçildiğini ifade etmektedir. Bu gösterim biçimi, veri kümesinin kendine-organize harita üzerindeki dağılımını göstermektedir.

Şekil 3'de aynı anda birden fazla hit-histogramı kullanılarak test veri kümesinin dağılımı gözlemlenmiştir. Burada, 10 adet veri kümesinin hit-histogramları şu tanımlamaya göre gösterilmiştir: AG arıza sınıfı "1" ile, BG arıza sınıfı "2" ile, CG arıza sınıfı "3" ile, AB arıza sınıfı "4" ile, BC arıza sınıfı "5" ile, AC arıza sınıfı "6" ile, ABG arıza sınıfı "7" ile, BCG arıza sınıfı "8" ile, ACG arıza sınıfı "9" ile, ve son olarak ABCG arıza sınıfı ise "0" ile etiketlenmiştir.

Şekil 3'ün arka fonundaki görüntü ise KOH'un birleştirilmiş mesafe matrisidir (U-mat). (U-mat, burada enterpole edilmiş renk gölgeleme tekniğini kullanılmaktadır). U-mat, KOH'un kümeleme yapısını analiz etmeye olanak sağlayan bir görüntüleme tekniğidir. Komşu harita elemanlarının prototip vektörleri arasındaki mesafeleri ve KOH'un kümeleme yapısını göstermektedir. Koyu renkler komşu harita elemanları arasındaki uzak mesafeyi (küme sınırlarını) ifade etmektedir. Kümeler ise açık renkli bölgeler ile temsil edilir.

Şekil 3'deki U-mat görsel olarak incelenerek bile 10 farklı sınıfın ayırt edilebileceği görülmektedir. Fakat bu sınıflamanın daha rahat anlaşılması amacıyla hit-histogramları kullanılmıştır.



Şekil 3. Test verisinin U-mat üzerindeki hit-histogramları gösterimi.

5. SONUÇ

Enerji dağıtım sistemleri için bir birleşik dalgacık-YSA tabanlı arıza sınıflayıcı modeli araştırılmıştır. Bu amaç için on adet arıza tipi belirlenmiş ve kullanılmıştır. Kullanılan sınıflayıcı modelinin yüksek doğruluk oranı ile sınıflama yapabileceği gösterilmiştir.

Arıza sınıflama modelinin verimi literatürdeki benzer modellere yakındır. Örneğin, [12]'de Mladen Kezunovic ve Igor Rikalo YSA tabanlı eğitici-eğitici hibrid sistemi ile bir iletim hattındaki oniki sınıftan oluşan sınıflama probleminin % 95.93 oranı ile sınıflanabileceğini belirtmişlerdir. Bundan başka, [10]'da bir dalgacık YSA-bulanık mantık yaklaşımı kullanılarak güç kalitesi bozucu işaretleri eğitim kümesi için % 95 ve test kümesi için de % 92 başarımla sınıflanabilmiştir.

Şekil 3'de gösterilen arıza sınıflayıcısı 250 farklı arıza örneği ile eğitilmiş ve 100 farklı test datası ile de test edilmiştir. Kullanılan modelin verimi test verileri için % 85 ile % 92 arasında elde edilmiştir. Test sonuçları KOH tabanlı modelin, arıza sınıflama problemi için uygun olduğunu göstermektedir.

Bu çalışma, birleşik dalgacık-YSA tekniğinin güç sistemlerinde kısa devre arızalarının tanımlanması amacıyla kullanılabileceği gösterilmektedir. Bu aşamadan sonra karar verme sürecinde bir uzman sistem modeli kullanılarak hızlı ve etkin bir otomasyon modeli oluşturulabilir.

KAYNAKLAR

- [1] S. Santoso, E. J. Powers, W. M. Grady, A. J. Parsons, Power Quality Disturbance Waveform Recognition Using Wavelet-Based Neural Classifier-Part 1: Theoretical Foundation, IEEE TRANS. POWER DELIVERY, 15/1, 222-228, Ocak. 2000.
- [2] O. Dağ, Yüksek Lisans Tezi, İSTANBUL TEKNİK ÜNİVERSİTESİ, Combined Wavelet Neural Classifier for Power Distribution Systems, Mayıs 2002.
- [3] O. Dag, C. Ucak, Combined Wavelet-Neural Classifier for Power Distribution Systems, ARI, İSTANBUL TEKNİK ÜNİVERSİTESİ BÜLTENİ, 53/1, 82-97, Mayıs 2003.
- [4] M. Vetterli, C. Herley, Wavelets and Filter Banks: Theory and Design, IEEE TRANSACTIONS ON SIGNAL PROCESSING, 40/9, 2207-2232, 1992.
- [5] S. Mallat, A Wavelet Tour of Signal Processing, Academic Press, Cambridge, 1999.
- [6] S. Haykin, Neural Networks: A Comprehensive Foundation, Prentice Hall International. Inc., New Jersey, 1999.
- [7] J. A. Kangas, T. Kohonen, J. T. Laaksonen, Variants of Self-Organizing Maps, IEEE TRANSACTIONS ON NEURAL NETWORKS, 1/1, 93-99, Mart. 1990.
- [8] A. M. Gaouda, E. F. El-Saadany, M. M. A. Salama, V. K. Sood, ve A. Y. Chikhani, Monitoring HVDC Systems Using Wavelet Multi-Resolution Analysis, IEEE TRANSACTIONS ON POWER SYSTEMS, 16/4, 662-670, Kasım. 2001.
- [9] A. M. Gaouda, M. M. A. Salama, M. R. Sultan, ve A. Y. Chikhani, Power Quality Detection and Classification Using Wavelet-Multiresolution Signal Decomposition, IEEE TRANSACTIONS ON POWER DELIVERY, 14/4, 16-25, Eylül. 1999.
- [10] A. Elmitwally, S. Farghal, M. Kandil, S. Abdelkader, ve M. Elkateb, Proposed Wavelet-neurofuzzy Combined System for Power Quality Violations Detection and Diagnosis, IEEE PROC. GENER. TRANSM. DISTRIB., 148/1, 662-670, Ocak. 2001.
- [11] J. Vesanto, J. Himberg, E. Alhoniemi, ve J. Parkankangas, SOM Toolbox for Matlab 5, Helsinki University of Technology, URL: <http://www.cis.hut.fi/projects/somtoolbox/>.
- [12] M. Kezunovic, L. Rikalo, Detect and Classify Faults Using Neural Nets, IEEE COMPUTER APPLICATIONS IN POWER, 43-47, Eylül. 1996.