

# İletim Hatlarında Radyal Tabanlı Fonksiyon Ağları ile Arıza Tespiti

## Fault Detection on Transmission Lines Using Radial Basis Function Networks

Sami EKİCİ<sup>1</sup>, Selçuk YILDIRIM<sup>1</sup>, Mustafa POYRAZ<sup>2</sup>

<sup>1</sup>Elektrik Eğitimi Bölümü  
Fırat Üniversitesi  
sekici@firat.edu.tr, syildirim@firat.edu.tr

<sup>2</sup>Elektrik-Elektronik Mühendisliği Bölümü  
Fırat Üniversitesi  
mpoyraz@firat.edu.tr

### Özet

Bu çalışmada, radyal tabanlı fonksiyon ağları (RTFA) ve dalgacık dönüşümü (DD) yöntemlerini kullanarak iletim hatlarında meydana gelen arızaların tip ve yerleri belirlenmiştir. Çalışmada yararlanılacak veriler 380 kV'luk bir güç sistemi benzetiminden elde edilmiştir. Arıza benzetimleri için Alternative Transient Program (ATP) ve MATLAB yazılımları kullanılmıştır. 360 km uzunluğundaki iletim hattının farklı noktalarında meydana getirilen faz ve toprak arızalarından elde edilen akım ve gerilim bilgileri bilgisayar ortamında kaydedilmiştir. Her üç faza ait akım ve gerilim sinyalleri DD yöntemi ile analiz edilerek arıza durumlarına ait geçici durum özellik vektörleri elde edilmiştir. Daha sonra arıza durumlarını içeren özellik vektörleri RTFA'ya giriş olarak verilerle meydana gelen arızanın yeri ve tipi belirlenmiştir. Önerilen yöntemin etkinliğini değerlendirmek için elde edilen sonuçlar ile diğer sinir ağ modellerinin sonuçları karşılaştırılmış ve önerilen yöntemin oldukça yüksek bir performansa sahip olduğu görülmüştür.

### Abstract

In this study, the types and locations of the transmission line faults are determined by using radial basis function networks (RBFN) and wavelet transform (WT). The data utilized in this study is obtained from a 380-kV power system simulation. The Alternative Transient Program (ATP) and MATLAB software are used for the fault simulations. The current and voltage information obtained from the phase and earth faults which are occurred different points of the 360-km transmission line are saved on the computer media. The feature vectors of the fault transients are obtained by analyzing the three-phase current and voltage signals using WT. Then, the type and location of the occurred fault are determined by using the feature vectors which contain the fault information as the inputs of RBFN. To evaluate the effectiveness of the proposed method, the obtained results are compared with the other network models and it is show that the proposed method has a higher performance than the others.

### 1. Giriş

Elektrik güç sistemlerinde iyi bir tasarım, uygun işletme şartları ve cihazların bakımlarının düzenli olarak yapılması, oluşabilecek arıza olasılığını azaltmakla birlikte tamamen ortadan kaldırmaz. Bu durumda güç sistemi elemanlarını, oluşabilecek arızalara karşı mümkün olduğu kadar iyi korumak gerekir.

Sayısal teknolojiadaki gelişmelere paralel olarak, bilim adamları mikroişlemci tabanlı röleler üzerinde çalışmaya başlamışlardır. Önerilen ilk dijital röle modelleri çoğunlukla hat empedansının hesaplanması ve yürüyen dalga yöntemlerine dayalıdır [1, 2]. Yürüyen dalganın sönümlü olması ve giderek bozulması, dalganın varış süresinin ve hızının tam olarak belirlenememesine yol açar. Coğrafik etkenler ve hat yapılandırmasının değişmesi bu yöntemlerin doğru sonuç vermemesine neden olur. Kullanılan cihazların maliyetlerinin fazla olması da bu yöntemlerin olumsuz yönleridir.

Son yıllarda arıza tahmini için, insan beyninin çalışmasından esinlenerek geliştirilen yapay zekâ tekniklerini kullanan akıllı sistemler üzerinde çalışılmaktadır [3]. Yapay zeka tekniklerinin en belirgin özellikleri, hızlı öğrenebilme, hata toleransı ve bir sisteme ait kısmi verilerle doğru bir çıkış üretebilmeleridir. Bu özellikleri ile yapay zeka teknikleri, güç sistemleri gibi büyük ve dinamik sistemlerin modellenmesi ve kontrolü için çok uygun yöntemlerdir. Bu yöntemler, arıza olayı gibi birçok değişkene sahip, bu değişkenler arasındaki fonksiyonel ilişkileri tam belirli olmayan veya hesaplanması zor olan problemlere rahatlıkla uygulanabilirler. Güç sistemlerinde meydana gelen kısa devre arızalarının incelenmesinde uzman sistemler, genetik algoritmalar, bulanık mantık, karar ağaçları, en yakın-komşuluklar algoritması ve Yapay Sinir Ağları (YSA) gibi yapay zeka teknikleri kullanılmıştır [4]. Bu yöntemler, arıza analizinde ayrı ayrı ya da birleşik olarak kullanılmışlardır.

Bu çalışmada, arıza tipini ve yerini belirlemek için öncelikle iletim hattının başından alınan akım ve gerilim sinyalleri DD yöntemi ile analiz edilerek bu sinyallere ait ayırt edici özellikler çıkarılmıştır. Bu veriler sayıca çok fazla olduğundan dolayı, veri matrisinin boyutlarının düşürülmesi gerekmektedir. Bu çalışmada veri matrisinin boyutunu indirgemek için sinyalin düzensizlik ölçütü olarak da

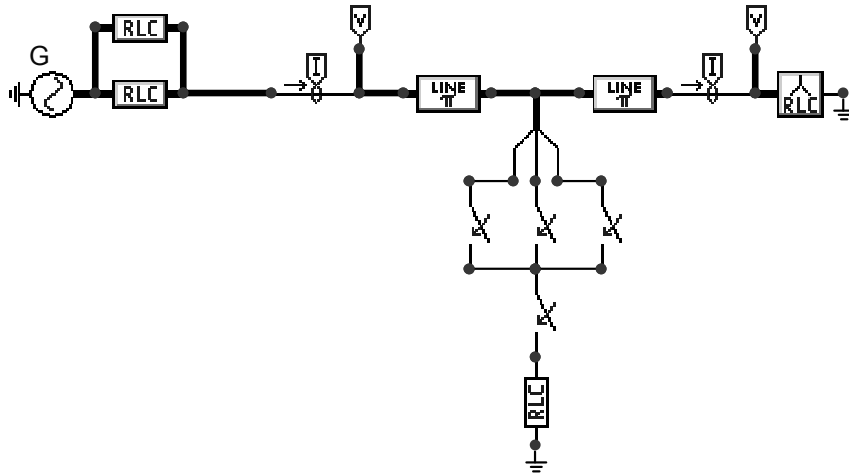
tanımlanan dalgacık entropisi yöntemi kullanılmıştır. Farklı noktalarda meydana gelen faz ve toprak arızalarına ait olan ve boyutları indirgenen bu ayırt edici özellik vektörü elemanlarının bir kısmı RTFA'nın eğitimi için, geriye kalan kısmı ise ağır test edilmesi için kullanılmıştır. RTFA'ya daha önce hiç sunulmamış olan test verileri ile yapılan benzetim sonuçlarına bakıldığında, ağır sınıflandırma ve arıza yerini tahmin etme başarısının oldukça yüksek olduğu görülmüştür.

## 2. Kısa Devre Arızalarının Benzetimi


Son yıllarda, bilgisayar teknolojisindeki gelişmelere paralel olarak sayısal analiz yöntemlerinde de hızlı gelişmeler olmuştur. Güç sistemleri analizinde kullanılan bilgisayar destekli benzetim programları, gözle görülemeyen elektriksel olayların detaylı olarak incelenmesine imkan sağlamıştır. Güç sistemleri analizinde en sık kullanılan analiz programları ATP

ve MATLAB'tır [5, 6]. ATP, Electro Magnetic Transient Program'ın (EMTP) ücretsiz ve eğitim amaçlı olan bir sürümüdür. Kullanış kolaylığı ve benzetimdeki başarısı ATP'yi güç sistemleri analizinde dünya'da en çok kullanılan program haline getirmiştir.

Şekil 1'de ATP ile benzetimi yapılan 380 kV'luk güç sistemi modeli gösterilmiştir. Benzetim süresi 0,5 saniye olup, örnekleme periyodu  $20 \mu s$ 'dir. Örnekleme frekansının yüksek olması, arıza anında oluşan yüksek frekanslı bozulmaların daha iyi gözlemlenebilmesine imkan sağlar. Bu durumda, gürültü ve harmonik gibi diğer yüksek frekans bileşenlerinin arıza geçici durumlarından ayırt edilmesi gerekir. Şekil 2'de, iletim hattının başında meydana gelen tek faz-toprak arızasına (1FTA) ait ATP benzetiminden elde edilen gerilim ve akım sinyalleri gösterilmiştir.



Şekil 1: Prototip güç sisteminin ATP modeli.



Şekil 2: Hat başında meydana gelen 1FTA için ATP benzetiminden elde edilen gerilim ve akımların değişimi.

### 3. DD ile Geçici Durum Analizi

Son yıllarda güç sistemleri analizinde yaygın olarak kullanılan DD yönteminin FD'ye göre önemli avantajları vardır. DD yöntemi, sinyali ayarlanabilir bir pencereleme tekniği kullanarak analiz etmektedir. Durağan olmayan sinyal, farklı ölçeklerde ayarlanabilir bir pencereleme yöntemi ile parça parça analiz edilerek zamana karşılık gelen frekans spektrumları hesaplanır. Bu işlem defalarca tekrarlandıktan sonra sinyalin zaman-frekans cevabı elde edilir. DD yüksek frekanslar için kısa pencereleme, alçak frekanslar için uzun pencereleme kullanır [7].

Sürekli Dalgacık Dönüşümü (SDD), FD'ye benzer bir yapıya sahiptir. SDD'yi FD'den ayıran fark, FD incelenen sinyalin farklı frekanslardaki sinüs ve kosinüs bileşenlerini toplarken, SDD sinyalin farklı ölçeklemelere sahip ötelenmiş dalgacıklardan oluştuğunu kabul etmesidir [8]. SDD matematiksel olarak,

$$SDD(s, \tau) = \int f(t) \psi_{s, \tau}^*(t) d(t) \quad (1)$$

biçiminde ifade edilir. Buradaki  $\psi_{s, \tau}(t)$  ana dalgacık (AD) olarak adlandırılır [8]. Ana dalgacığın alt indisi olarak gösterilen  $\tau$  ifadesi ise öteleme parametresidir. Dolayısıyla SDD,  $s$  ve  $\tau$ 'nin bir fonksiyonudur. AD formülasyonu,

$$\psi_{s, \tau}(t) = \frac{1}{\sqrt{s}} \psi \frac{t - \tau}{s} \quad (2)$$


gibi yazılır. Buradaki  $s$ , ölçekleme katsayısı olarak adlandırılır. Ölçekleme faktörünün küçük olması dalgacığın daha fazla sıkıştırılmış olduğu anlamına gelir. SDD'de karşılaşılan problem, hesaplama zorluğu olmasa bile sonsuz sayıda dalgacığın olmasıdır. SDD'nin bu olumsuzlukları ayırık dalgacıklar kullanılarak giderilmiştir. Ayırık dönüşüm denk. (2)'yi aşağıdaki gibi ayırıklaştırarak sağlanır:

$$\psi_{j, k}(t) = \frac{1}{\sqrt{s_0^j}} \psi \left( \frac{t - k\tau_0 s_0^j}{s_0^j} \right) \quad (3)$$

Buradaki  $j$  ve  $k$  birer tamsayı,  $s_0 > 0$  genleşme katsayısı ve  $\tau_0$  genleşme katsayısına bağlı öteleme faktörüdür [9]. ADD, frekans spektrumlarını ayırıştırarak sinyale ait detay ve yaklaşık katsayılarını elde eden bir süzgeç grubu gibi davranır. ADD ile analiz yapılırken, ilk olarak orijinal sinyal bir yüksek ve alçak geçiren süzgeçten geçirilir. Daha sonra her iki süzgecin çıkışları ayırıştırılarak, birinci seviyedeki yaklaşık (A1) ve detay (D1) katsayıları elde edilir. Yaklaşık katsayıları, bir önceki işlemin tekrarı için ikinci adıma gönderilir. Bu işlemler tekrarlanarak, istenilen seviyeye kadar ayırışma devam edilir.

Bu çalışmada, kısa devre arıza tiplerinin ve arızanın meydana geldiği noktanın belirlenmesi için ATP'de benzetimleri yapılan tek faz-toprak (1FTA), iki-faz (2FA), iki faz-toprak (2FTA) ve üç fazlı simetrik arıza (3FSA) durumlarına ait akım ve gerilim sinyallerine ADD yöntemi uygulanarak, sınıflandırmada kullanılacak ayırıcı özellikler elde edilmiştir. ADD analizinde kullanılacak sinyaller, ayırışmadan önce [-1, 1] aralığında normalize edilmiştir. ADD analizinde arıza analizlerinde yaygın olarak kullanılan Daubechies (db4) dalgacık ailesi kullanılmıştır [10].

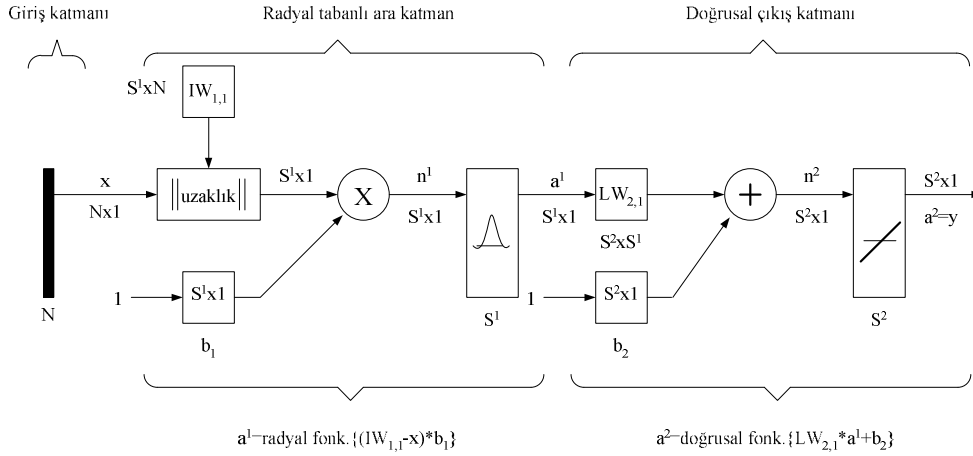
Sinyaller ADD ile analiz edilirken 6 seviyeli bir ayırışım yapılmıştır. ADD ile 6 seviyeli bir ayırışım yapılması, kullanılan veri sayısı ve buna bağlı olarak örnekleme frekansı ile ilişkilidir. ADD ayırışımından elde edilen yaklaşık katsayıları alçak frekans bileşenlerini içerdikleri için, arıza durumlarına ait yüksek frekanslı geçici durum bilgilerini içermezler. Bu yüzden yaklaşık katsayıları, sınıflandırma ve tahmin uygulamalarında kullanılmamıştır. Şekil 3'te, Şekil 2'de gösterilen her üç fazın bir periyotluk sinyallerine ait, yeniden oluşturulmuş detay ve yaklaşık katsayıları görülmektedir.



Şekil 3: Tek-faz toprak arızasında arızalı A fazının ADD analizi, (a) gerilim sinyali, (b) akım sinyali.

#### 4. Radyal Tabanlı Fonksiyon Ağları

Birçok YSA uygulamasında çoğunlukla geri yayımlı, ileri beslemeli çok katmanlı algılayıcı ağları kullanılmasına rağmen bu tip ağlar eğitim sürelerinin uzun olması, yerel optimuma takılma, kaç ara katman kullanılacağı ve bu ara katmanlardaki nöron sayısının belli olmaması gibi dezavantajlara sahiptir [11]. RTFA giriş katmanı, ara katman ve çıkış katmanı olmak üzere üç katmandan oluşan ileri beslemeli bir ağ yapısıdır.



Şekil 4: Radyal tabanlı fonksiyon ağ yapısı.

Burada N giriş elemanı sayısı, x giriş,  $S^1$  birinci katmandaki nöron sayısı,  $S^2$  ikinci katmandaki nöron sayısı,  $a^1$  ara katman çıktısı,  $a^2$  çıkış katmanı çıktısı,  $b_1$ ,  $b_2$  ara katman ve doğrusal çıkış katmanı için eşik değerleridir. Şekil 4'te görüldüğü gibi, ara katman çıktısı  $a^1$ , ara katman ile çıkış katmanı arasındaki ağırlıklar ile çarpılmakta, bu çarpıma  $b_2$  eşik değeri ilave edilmekte ve çıkan sonuç doğrusal transfer fonksiyonundan geçirildikten sonra  $a^2$  ağ çıktıları elde edilmektedir. RTFA eğitiminin her döngüsünde ağıra bir nöron ilave edilir. Bu işlem, önceden belirlenen nöron sayısına ulaşıncaya veya hata değeri belirli bir sınıra altına düşünceye kadar devam eder.

#### 5. Kısa Devre Arıza Tiplerinin Belirlenmesi

Bu bölümde, ATP benzetiminden elde edilen kısa devre arıza verileri kullanılarak arıza tipi sınıflandırması yapılacaktır. Sınıflandırma işleminden önce, arıza sinyallerinin arıza meydana gelmeden önceki yarım periyodu ve arıza anından sonraki yarım periyodu ele alınarak [-1, 1] aralığında normalize edilmiştir. Sinyallere ait karakteristik özelliklerin elde edilebilmesi için ADD yöntemi kullanılmıştır. Veri sayısını uygun bir değere düşürmek için, ADD detay katsayılarının entropileri hesaplanmıştır. Entropi, bir sistemin düzenliliğini ölçmek için yararlanılan ve işaret işleme ilk olarak Shannon tarafından kullanılmış bir terimdir [14]. Entropi hesaplama tekniği, durağan olmayan bir işaretin düzensizlik derecesini ölçmek ve işaretin içerdiği bilginin ortalama miktarını ölçmek için uygun bir yöntemdir [8, 14]. Normalizasyon ve entropi işlemlerinden sonra elde edilen verilerin bir bölümü RTFA sınıflandırıcısının eğitimi, geriye kalan bölümü ise testi için kullanılmıştır. Bu çalışmada RTFA yönteminin tercih edilme nedeni, yüksek doğruluk oranı ve eğitim hızıdır. Sınıflandırma işlemindeki doğruluk oranlarının karşılaştırılması için çok katmanlı algılayıcı ağları (ÇKA), k-En Yakın Komşuluklar (k-EYK) algoritması, Elman ağları ve Bayes sınıflandırıcılarının (BS) eğitim ve test sonuçları

Bu tip ağlarda ara katmandaki işlemci elemanı, girişlerin ağırlıklandırılmış şeklini kullanmaz [12]. Sadece ara katman işlemci elemanı çıktıları ağırlıklandırılarak çıkış katmanına iletilir. RTFA'nın en önemli özelliği, ara katmanda transfer fonksiyonu olarak doğrusal olmayan radyal tabanlı bir fonksiyon kullanmasıdır. RTFA ara katmanındaki işlemci elemanlarının çıkışı, YSA girişleri ile temel fonksiyonun merkezi arasındaki uzaklığa göre belirlenmektedir [12]. Şekil 4'te RTFA'nın genel yapısı görülmektedir [13].

kullanılmıştır. Tablo 1'de RTFA ve diğer sınıflandırıcıların başarı oranları görülmektedir.

Tablo 1: RTFA sınıflandırıcısının diğer sınıflandırıcılar ile karşılaştırılması.


| Sınıflandırıcı | Eğitim Süresi (s) | % Başarı |
|----------------|-------------------|----------|
| RTFA           | 0.2500            | 99       |
| Bayes          | 0.1400            | 45       |
| k-EYK          | -                 | 96       |
| Elman          | 327.77            | 85       |
| ÇKA            | 105.13            | 99       |

Tablo 1'den görüldüğü gibi farklı arıza tiplerini belirlemede başarıları en yüksek olan sınıflandırıcılar RTFA ve ÇKA yapılarıdır. Sınıflandırma başarıları en düşük olan yöntem ise % 45 doğruluk oranına sahip olan Bayes sınıflandırıcısıdır. Tablo 1'e bakıldığında, Bayes sınıflandırıcısı dışındaki tüm sınıflandırıcıların başarı performansı oldukça iyidir. Başarı performansı yanında sınıflandırıcı seçiminde dikkat edilmesi gereken diğer önemli bir husus, ağırlıklandırılması, eğitim ve testi için harcanan zamandır. Tablo 1'den de görüldüğü gibi, %99'luk başarı oranı ile bu çalışmada da kullanılan RTFA sınıflandırıcısının arıza tiplerini belirlemek için harcadığı zaman sadece 0.25 saniyedir.

#### 6. RTF ile Arıza Yerinin Belirlenmesi

YSA benzetimleri, MATLAB Neural Network Toolbox kullanılarak gerçekleştirilmiştir [13]. Sunulan yöntem bir önceki bölümde belirlenen arıza tiplerine bağlı olarak çalışmaktadır. Tüm arıza tipleri için arıza yerini bulan tek bir YSA kullanılması, elde edilen sonuçların doğruluğunu olumsuz etkileyeceğinden, bu çalışmada her bir arıza tipi için

1 YSA olmak üzere toplam 4 ayrı ağ kullanılmıştır (RTF-1, RTF-2, RTF-3, RTF-4). RTFA'nın eğitimini etkileyen ve kullanıcı tarafından belirlenen Gauss fonksiyonu genişliğinin en doğru sonucu verecek biçimde ayarlanması için farklı değerler kullanılmıştır. Şekil 5'te en uygun genişlik değerinin belirlenmesi için [0, 2] aralığında değişen farklı değerler ile yeniden eğitilen RTFA'nın benzetim sonuçları verilmiştir.



Şekil 5: En uygun Gauss parametresinin belirlenmesi.

Farklı değerler kullanılarak eğitilen ağ başarımının en yüksek olduğu parametre değeri, 1.3 olarak bulunmuştur. Kullanıcı tarafından belirlenen ve Gauss fonksiyonunun genişliğini ifade eden bu değer, giriş vektörü ile ağırlıklar arasındaki en küçük uzaklık değerinden büyük, en büyük uzaklık değerinden ise küçük olması gerekir [12]. Bu değer çok küçük olması durumunda ağın genelleme kabiliyeti azalır. Genişlik değerinin çok büyük olması durumunda ise ağın eğitim süresi artar [13]. RTFA'nın eğitiminin durdurulması için kullanılan amaca yakınlık değeri ise 0,001 olarak seçilmiştir. Ağ eğitimi, RTFA'nın çıkışı ile beklenen çıkışlar arasındaki farka bağlı olarak hesaplanan ortalama karesel hata değeri kullanıcı tarafından belirlenen amaca yakınlık değerine eşit ya da daha düşük oluncaya kadar devam eder.

RTFA'nın eğitimini sonlandırmak için kullanılan diğer bir parametre, ağa dahil edilen nöron sayısının belirlenmesidir. Hesaplanan ortalama karesel hata değeri, amaca yakınlık değerinin altına düşünce ya da önceden belirlenen eklenecek nöron sayısına ulaşıncaya ağ eğitimi durdurulur. Bu çalışmada ağa ilave edilecek maksimum nöron sayısı 25 olarak seçilmiştir. Her bir arıza tipi için 50 farklı arıza yerinden elde edilen 18x25 veri YSA'nın eğitimi için, geriye kalan 18x25 veri ise ağın test edilmesi için kullanılmıştır. Tablo 2'de sırasıyla 1FTA, 2FA, 2FTA ve 3FSA için eğitilen RTF-1, RTF-2, RTF-3 ve RTF-4 ağlarının test sonuçlarının ÇKA ve Elman ağlarının test sonuçlarıyla karşılaştırılması gösterilmiştir. Sonuçlar incelendiğinde, RTFA yapısının ÇKA ve Elman ağlarına göre çok daha iyi sonuçlar verdiği görülmektedir.

Tablo 2: Farklı ağ yapılarının arıza yeri belirlemedeki yüzdelik başarı oranları.

|       | RTF-1    | RTF-2    | RTF-3    | RTF-4    |
|-------|----------|----------|----------|----------|
| RTFA  | 0,898564 | 0,219902 | 0,436177 | 1,141538 |
| ÇKA   | 4,110241 | 1,299177 | 1,36472  | 12,21788 |
| Elman | 9,308896 | 5,701545 | 5,555056 | 5,306956 |

## 7. Sonuçlar

Bu çalışmada dalgacık dönüşümü yöntemi ve radyal tabanlı fonksiyon ağları kullanılarak iletim hatlarında meydana gelen arızaların tipleri ve yeri belirlenmiştir. Çalışmada, arıza durumlarına ait üç faz akım ve gerilim sinyalleri kullanılmıştır. Bu akım ve gerilim sinyallerini birbirinden ayırt edecek karakteristik özelliklerin elde edilebilmesi için ayrık dalgacık dönüşümü yöntemi kullanılmıştır. Elde edilen özellik vektörünün boyutunu indirmek için dalgacık entropi yöntemi kullanılmıştır. Elde edilen yeni özellik vektörünün bir kısmı sinir ağ modelinin eğitimi için geriye kalan kısmı ise test işlemi için kullanılmıştır. Sınıflandırma işlemi sonucunda farklı noktalarda meydana gelen kısa arızaların %99'nun doğru olarak tanımlandığı görülmüştür. Arıza yerlerinin belirlenmesi için ise 4 ayrı RTFA kullanılmış ve 50 farklı arıza noktası için hata değerinin çoğunlukla %1'in altında olduğu görülmüştür.

## 8. Kaynaklar

- [1] Hanninen, S., *Single Phase Earth Faults In High Impedance Grounded Networks, Characteristics, Indication and Location*, Technical Research Centre of Finland, VTT Publications, 2001.
- [2] Crossley, P.A. and McLaren, P.G., "Distance Protection Based on Travelling Waves", *IEEE Trans. on Power Apparatus and Systems*, PAS-102, 9, 2971-2983, 1983.
- [3] Cichocki, A. and Lobos, T., "Artificial Neural Networks for Real-Time Estimation of Basic Waveforms of Voltages and Currents", *IEEE Trans. on Power Systems*, 9, 2, 612-618, 1994.
- [4] Perez, L.G., Flechsiz, A.J., Meador, J.L. and Obradovic, A., "Training an Artificial Neural Network to Discriminate Between Magnetizing Inrush and Internal Faults", *IEEE Trans. on Power Delivery*, 9, 1, 434-441, 1994.
- [5] Palo Alto, C.A., *Electromagnetic Transient Program (EMTP) - Rule Book*, EPRI EL 6421-1, Electric Power Research Institute, 1989.
- [6] Natick, M.A., *Using MATLAB, Version 6*, The MathWorks Inc, 2002.
- [7] Michalik, M., Okraszewski, T., Application of The Wavelet Transform to Backup Protection of Mv Networks - Wavelet Phase Comparison Method, *2003 IEEE Bologna PowerTech Proceedings*, 2003, 23-26.
- [8] Misiti, M., Misiti, Y., Oppenheim, G. and Poggi, J.M., *Wavelet Toolbox, For Use with MATLAB*, 2003.
- [9] Daubechies, I., *Ten Lectures on Wavelets, 2nd ed.* Philadelphia: SIAM, CBMS-NSF Regional Conference Series in Applied Mathematics, 1992.
- [10] Lee, C.H., Wang, Y.J. and Hang, W.L., "A Literature Survey of Wavelets in Power Engineering Applications", *Proc. of National Science Council*, 24, 4, 249-258, 2000.
- [11] Mahanty, R.N. and Gupta, P.B.D., "Application of RBF Neural Network to Fault Classification and Location in Transmission Lines", *IEE Proceedings of Gener. Transm. Distrib.*, 151, 2, 201-212, 2004.
- [12] Sağıroğlu, Ş., Beşdok, E. ve Erler, M., *Mühendislikte Yapay Zeka Uygulamaları-1: Yapay Sinir Ağları*, Ufuk Kitap Kırtasiye-Yayıncılık Tic. Ltd. Şti., 2003.
- [13] Demuth, H., Beale, M. and Hagan, M., *Neural Network Toolbox User's Guide for Use with MATLAB*. The MathWorks Inc., 2006.
- [14] Türkoğlu, İ., Durağan Olmayan İşaretler İçin Zaman-Frekans Entropilerine Dayalı Akıllı Örüntü Tanıma, Doktora Tezi, Fırat Üniv. Fen Bilimleri Enstitüsü, 2002.