

Elektriksel Boşalma Sesinden Elektrot Sistemini Tanıma

Suna Bolat Sert¹

Özcan Kalenderli²

^{1,2}Elektrik Mühendisliği Bölümü, İstanbul Teknik Üniversitesi, İstanbul

¹e-posta: bolats@elk.itu.edu.tr

²e-posta: ozcan@elk.itu.edu.tr

Özetçe

Bu çalışmada, elektrot sistemlerinde oluşan elektriksel boşalma sesinden, elektrot sisteminin türünü belirlemeye yani tanıma yönelik bir araştırma sunulmuştur. Bu amaçla, iki farklı elektrot düzeninde, elektrotlara, boşalma (korona) başlangıç gerilimi olarak saptanan 27 kV'un üzerinde 50 Hz frekanslı alternatif gerilimler uygulanarak, oluşan ses örnekleri bilgisayara kaydedilmiştir. Toplanan ses örnekleri, bir Olasılıksal Sinir Ağı – Probabilistic Neural Network (PNN) eğitiminde kullanılmış ve Doğrusal Öngörü – Linear Prediction (LP) kullanılarak çözümlenmiştir. İki farklı elektrot düzeni kullanılan bu çalışma, olasılıksal sinir ağı ile bir sınıflama problemidir. Sonuçlar, kullanılan yöntemin söz konusu problemi çözmek için uygun olduğunu göstermektedir.

1. Giriş

Potansiyel farkı olan iki nokta arasındaki gerilim veya bir iletken çevresindeki elektrik alan şiddeti, aradaki veya çevredeki yalıtkanın delinme geriliminden veya delinme dayanımından büyük olursa bu noktalar arasında, tamamında (delinme) veya belli bölümünde (kısmi boşalma, korona şeklinde) gerçekleşen bir elektriksel boşalma olur [1-3]. Elektriksel boşalma kendini, akım, gerilim darbeleri ve elektromanyetik alan yayılımı dışında, ısı, ışık, koku gibi birçok özelliği ile belli eder. Boşalma ile ilgili elektriksel olmayan bilgilerin en önemlilerinden biri de, boşalmanın sesidir [4-5].

Elektriksel olmayan büyüklüklerden, boşalmanın varlığını ve yerini belirlemek amacıyla yararlanılabilir. Bu amaçla, hem ışıktan hem de sestten yararlanılan çalışmalar yapılmaktadır [6-11]. Günümüzde ışık ve ses algılama ve kaydetme olanakları, bilgisayar donanımları ve işaret işleme yöntemlerinin gelişmesi, bu gibi çalışmaların önemini arttırmaktadır.

Genelde elektriksel boşalma sıcaklık, basınç, nem, malzeme türü, boyutları, geometrisi, homojenliği, uygulanan alanın türü gibi pek çok değişkene bağlı fiziksel bir olay olduğu için, sestten elektriksel büyüklükleri belirlemek güvenilir bir yol olarak görülmemektedir. Ancak gelişen teknoloji, akustik ölçme yöntemlerinin ilgi çekici bir seçenek olarak karşımıza çıkmasını sağlamıştır [6].

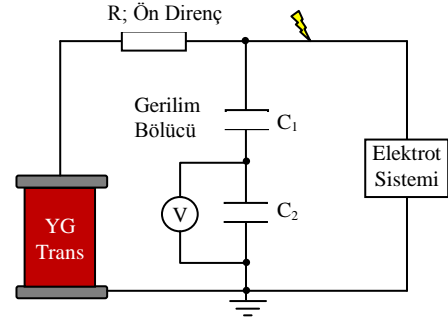
Bu çalışmada farklı elektrot sistemlerinden yayılan elektriksel boşalmaya ilişkin ses kayıtları kullanılarak, bir olasılıksal yapay sinir ağı – Probabilistic Neural Network (PNN) yardımıyla, elektriksel boşalmanın olduğu elektrot sisteminin türü belirlenmiştir. Bu amaçla, farklı elektrot düzenleri kullanılarak kurulan deney düzenekleri ile ses kayıtları yapılmıştır. Elde edilen ses verileri ile eğitilen sinir ağının sınıflama probleminde yüksek başarılı sonuçlar verdiği gözlenmiştir.

2. Deneysel Veri Toplama

Farklı elektrot sistemlerinden yayılan boşalma seslerini elde etmek için çubuk – düzlem ve hat – düzlem olmak üzere, iki

farklı elektrot sistemi oluşturulmuştur. Deney düzeni Şekil 1'de görülmektedir.

Yapılan deneylerde, elektrotlara 0,220/100 kV, 5 kVA'lık bir yüksek gerilim trafosundan, elektrot sistemi çevresinde çıplak kulakla duyulabilir boşalma (korona) başlangıç gerilimi olarak saptanan 27 kV'un üzerinde 50 Hz frekanslı, sırasıyla 40 kV, 45 kV, 50 kV, 55 kV, 65 kV ve 70 kV etkin değerli alternatif gerilimler uygulanmıştır. Deneyler, 758 mmHg hava basıncı ve 24 °C ortam sıcaklığında, elektromanyetik ekranlı bir yüksek gerilim laboratuvarında, sessiz ortam koşullarında gerçekleştirilmiştir.




Şekil 1: Deney Düzenegi.

2.1. Çubuk – Düzlem Elektrot Sistemi

Çubuk – düzlem elektrot sistemini oluşturmak için tepe açısı 120° olan, konik uçlu, 10 mm çaplı, 50 mm uzunluğunda krom kaplı çubuk elektrot ile kenar eğrilik yarıçapı 3 mm olan, 15 mm kalınlığında, 75 mm çapında, disk şeklinde düzlem elektrot kullanılmıştır. Kullanılan çubuk-düzlem elektrot sisteminin biçimi ve boyutları Şekil 2'de görülmektedir.


Elektrot sistemine uygulanan her gerilim basamağında, elektrot sisteminden yatayda 1 m uzağa yerleştirilen bir bilgisayar çoğul ortam mikrofonu yardımıyla bir dizüstü bilgisayarda, elektrot sisteminden gelen elektriksel boşalma (korona) sesleri kaydedilmiştir.



Şekil 2: Çubuk – Düzlem Elektrot Sistemi. Ölçüler mm cinsindedir.

2.2. Hat – Düzlem Elektrot Sistemi

Hat – Düzlem elektrot sistemini oluşturmak için, Şekil 3'te görülen deney düzeninde iki izolatör arasında yerden 220 cm yükseklikte, 5 m uzunluğunda, 2,5 mm² dairesel kesitli, 1,8 mm çaplı, pürüzsüz, temiz, kuru, çıplak bir bakır tel gerilmiştir.



Şekil 3: Hat – Düzlem Elektrot Sistemi.
Ölçüler mm cinsindedir.

Hatta uygulanan her gerilim basamağında, yerden 1 m yükseklikte, hattan yatayda 1 m uzağa yerleştirilen bir bilgisayar çoğul ortam mikrofonu üzerinden bir dizüstü bilgisayarda, hattaki koronadan yayılan elektriksel boşalma (korona) sesleri kaydedilmiştir.

3. Doğrusal Öngörü Analizi

Kaydedilen ses verilerini yapay sinir ağı ile eğitmek için, ses verileri bir ön işlemden geçirilir. Bu amaçla, ses spektrumunu elde etmenin yollarından biri olan ve genellikle konuşma işareti analizinde kullanışlı bir yöntem olarak bilinen doğrusal öngörü (LP) analizinden yararlanılmıştır. Doğrusal öngörü, güçlü ve genel bir spektral zarf kestirim yöntemidir. Doğrusal öngörü ile amaçlanan, frekans yanıtı elde edilmek istenen işaretin spektrumuna mümkün olduğunca benzeyen bir süzgeç tasarlamaktır. Daha sonra bu süzgeç, beyaz gürültü gibi geniş bir spektruma sahip işaretlerle sürülerek istenen işaret elde edilmeye çalışılır. Daha iyi bir sonuç elde etmek için süzgeç genelde zamanla değişen yapıdadır. Kısa süreli spektrum yöntemlerinden farklı olarak, doğrusal öngörü giriş işaretinin spektrumunun zarfının tümünü ele alır.

Doğrusal öngörü (LP) kodlaması tüm-kutup sinyal modelleme yöntemlerinden biridir. Bu yöntemde spektrum bir tüm-kutup süzgeç ile modellenir. Bu kutuplar, spektral tepelerde odaklanmıştır. İnsan kulağının süzgecin sınırlarına neredeyse duyarız olduğu bilinmektedir [12]. Bu nedenle, tüm-kutup bir süzgeç, ses işleme uygulamaları için yeterlidir.

İleri yönlü doğrusal öngöründe amaç, doğrusal ayrık zamanlı bir sistemin bir sonraki çıkış örneği $\hat{y}(n)$ 'i daha önceki p adet çıkışın doğrusal bir birleşimi ile elde etmektir:

$$\hat{y}(n) = \sum_{i=1}^p a_i y(n-i) \quad (1)$$

Buradaki a_i katsayıları LP katsayıları olarak adlandırılır. LP katsayıları tarafından tanımlanan tüm-kutup LP süzgecinin transfer fonksiyonu aşağıdaki gibidir.

$$H(z) = \frac{1}{A(z)} = \frac{1}{1 - \sum_{i=1}^p a_i z^{-i}} \quad (2)$$

LP'de amaçlanan, kısa süreli ortalama karesel hata e' 'yi en küçük yapacak öngörü katsayılarını bulmaktır.

$$e = E \left\{ \left| y(n) - \sum_{i=1}^p a_i y(n-i) \right|^2 \right\} \approx \sum_{n=-\infty}^{\infty} \left| y(n) - \sum_{i=1}^p a_i y(n-i) \right|^2 \quad (3)$$

Burada $E\{\cdot\}$, beklenen değer operatörüdür. Ortalama karesel hatayı en küçük yapan çeşitli algoritmalar mevcuttur. Burada, Rabiner tarafından geliştirilen özilişki yöntemine yer verilecektir [13]. (3) denklemini minimize eden a_i değerlerini bulabilmek için e' 'nin a_i 'lere göre kısmi türevlerinin alınıp sıfıra eşitlenmesi gerekir:

$$\frac{\partial e}{\partial a_i} = 0, i = 1, 2, \dots, p \quad (4)$$

Böylelikle normal denklemler elde edilir:

$$\sum_n y(n)y(n-k) - \sum_{i=1}^p a_i \sum_n y(n-i)y(n-k) = 0, k = 0, 1, \dots, p-1 \quad (5)$$

$y(n)$ durağan ve reel bir dizi ise,

$$R(k) = \sum_{m=-\infty}^{\infty} y(m)y(m+k) \quad (6)$$

özilişki fonksiyonu olmak üzere, (7) eşitliği şu şekilde düzenlenebilir:

$$\begin{bmatrix} R(0) & R(1) & \dots & R(p-1) \\ R(1) & R(0) & \dots & R(p-2) \\ \dots & \dots & \dots & \dots \\ R(p-1) & R(p-2) & \dots & R(0) \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \dots \\ a_p \end{bmatrix} = \begin{bmatrix} R(1) \\ R(2) \\ \dots \\ R(p) \end{bmatrix} \Leftrightarrow \mathbf{R}\mathbf{a} = \mathbf{r} \quad (7)$$

Bu denklem takımı, Yule-Walker eşitliği olarak bilinir. \mathbf{R} matrisinin çeşitli özelliklerinden yararlanarak (simetrik Toeplitz bir matris olması gibi) bu denklem takımı etkin bir şekilde çözülebilir. En etkin yöntemlerden biri, Durbin'in yinelemesidir. Durbin'in yinelemesi şu şekilde işler:

$$E^{(0)} = R(0) \quad (8)$$

$$k_i = \frac{R(i) - \sum_{j=1}^{i-1} a_j^{(i-1)} R(i-j)}{E^{(i-1)}}, 1 \leq i \leq p \quad (9)$$

$$a_i^{(i)} = k_i \quad (10)$$

$$a_j^{(i)} = a_j^{(i-1)} - k_i a_{i-j}^{(i-1)}, 1 \leq j \leq i-1 \quad (11)$$

$$E^{(i)} = (1 - k_i^2) E^{(i-1)} \quad (12)$$

Bu denklemlerin $i = 1, 2, \dots, p$ için yinelemeli çözümü ile p. adımda elde edilen $a_j = a_j^{(p)}$ katsayıları, aranan LP katsayılarıdır. Aynı şekilde, k_j 'ler de yansıtma katsayılarıdır.

4. Olasılıksal Sinir Ağı

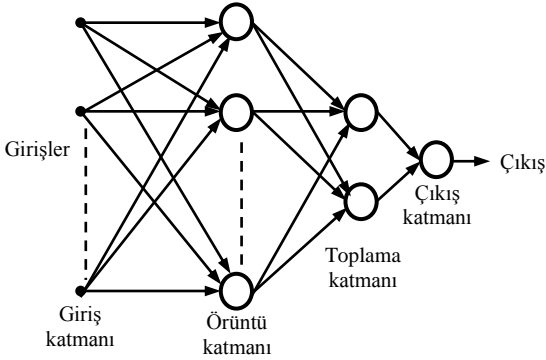
Olasılıksal Sinir Ağı (Probabilistic Neural Network - PNN) Bayes-Parzen kestiriciler olarak da bilinir. K1 ve K2 sınıflarından birine ait, m-boyutlu bir x vektörü olsun. K1 ve K2 sınıflarına ait olasılık yoğunluk fonksiyonları $F_1(x)$ ve $F_2(x)$ olsun. Bayes Teoremi'ne göre x vektörü,

$$\frac{F_1(x)}{F_2(x)} > \frac{L_1 P_2}{L_2 P_1} \quad (13)$$

eşitsizliği doğru ise K1, eşitsizliğin tersi doğru ise K2 sınıfına aittir. Burada P_1 ve P_2 , K1 ve K2 sınıflarının görülme olasılığıdır. L_1 , x vektörünün K1 sınıfına ait iken K2 olarak yanlış sınıflama oranı; L_2 ise x vektörünün K2 sınıfına ait iken K1 olarak yanlış sınıflama oranıdır ve maliyet fonksiyonu olarak adlandırılır. Buradan görüleceği gibi, $F_1(x)$, $F_2(x)$, L_1 ve L_2 'nin bilinmesi durumunda x vektörünün en yüksek olasılıkla hangi sınıfa ait olduğu tespit edilebilir [14]. Uygulamada genellikle maliyet fonksiyonları eşit alındığından, sınıflara ait olasılık yoğunluk fonksiyonlarının hesaplanması yeterlidir. Sınıflara ait yoğunluk fonksiyonları Parzen pencereleri [12] kullanılarak aşağıdaki şekilde bulunur:

$$F(x) = \frac{1}{(2\pi)^{m/2} \sigma^m n} \sum_{i=1}^n \exp \left[-\frac{(x - x_i)^T (x - x_i)}{2\sigma^2} \right] \quad (14)$$

Burada n eğitim verisi sayısı, m giriş uzayının boyutu, i örüntü numarası ve σ ise ayarlanabilir bir yumuşatma terimidir.



Şekil 4: Olasılıksal Sinir Ağı'nın Basit Yapısı

Şekil 4'te bir olasılıksal sinir ağı'nın basit yapısı görülmektedir. Ağın ilk katmanı, m tane giriş değişkenini temsil eden (x_1, x_2, \dots, x_m) giriş katmanıdır. Giriş nöronları, bütün x değişkenlerini ikinci katmandaki bütün nöronlara dağıtır. Örüntü katmanı, eğitim kümesindeki her örüntü için bir nöron ile birinci katmana tamamen bağlıdır. Bu katmandaki nöronların ağırlık değerleri, farklı eğitim örüntülerine eşittir. Eşitlik (14)'teki eksponansiyel terimin toplama işlemi, toplama katmanı tarafından gerçekleştirilir. Her kategori için bir toplama nöronu bulunmaktadır. Toplama katmanındaki her nöron, örüntü katmanı nöronlarının çıkışlarını toplar. Çıkış katmanı nöronu, en yüksek olasılık yoğunluk fonksiyonuna karşılık gelen, ikili bir çıkış oluşturur. Bu, söz konusu örüntü için en iyi sınıflamayı belirtir.

Bu durum, ikili karar verme problemidir. Bu nedenle, çıkış katmanında yalnız bir nöron bulunurken, toplama katmanında iki nöron bulunmaktadır [15-17].

5. Uygulama

5.1. Ses Verileri

Çalışmada kullanılan ses örnekleri, farklı iki elektrot sistemi için, elektrotlara uygulanan her gerilim basamağında 60 s'lik süreli kayıtlar sonucunda elde edilen elektriksel boşalma (korona) sesi örnekleridir. Ses örnekleri 22050 Hz örnekleme frekansında ve 8 bit çözünürlükle kaydedilmiştir.

Her bir gerilim basamağı için elde edilen ses örnekleri, 1 s'lik parçalara bölünerek doğrusal öngörü kodlamasıyla öznelikleri çıkarılmıştır. LP katsayıları 1 s'lik ses kaydı boyunca 20 ms uzunluklu çerçeveler için hesaplanmıştır. Çerçeveler arasında örtüşme yoktur. Her çerçeve için LP katsayıları hesaplanmış, tüm çerçeveler için hesaplanan katsayıların ortalamaları alınarak, her ses kaydının bir s'si bu ortalama değerler ile temsil edilmiştir. Ses kayıtları için 20. dereceden LP katsayıları hesaplanmıştır. Böylece 60 s uzunluğundaki her bir ses kaydı için 20 adet öznelik elde edilir. Her gerilim basamağındaki ses kaydı için 60×20 veri elde edilmiştir. 7 farklı gerilim basamağı için, iki elektrot sistemi kullanılarak elde edilen $420 \times 2 = 840$ veri ile eğitim ve test kümeleri oluşturulmuştur. LP katsayılarının uzunluğu değiştirilerek, uzunluğun sonuca etkisi de incelenebilir.

5.2. Sınıflama

Ses kayıtlarından çıkarılan öz nitelikler, başka bir deyişle hesaplanan LP katsayıları olasılıksal sinir ağı'nın giriş vektörünü oluşturmaktadır. Sinir ağı'nın çıkış vektörü ise, sesi oluşturan kaynağın yani elektrodun türüdür. Farklı elektrot sistemleri, olasılıksal sinir ağı'nda farklı sınıflar olarak ele alınır. Bu çalışmada, elektriksel boşalma sesini oluşturan kaynaklardan çubuk – düzlem elektrot sistemi 1 ve hat – düzlem elektrot sistemi 2 numaralı sınıf ile ifade edilmiştir.

Olasılıksal sinir ağı'nda değiştirilebilen tek parametre, σ yumuşatma terimidir. Bu çalışmada, σ 'nın optimum değeri, deneme yanılma yöntemiyle belirlenmiştir. σ , olasılıksal sinir ağı'nda kullanılan radyal tabanlı fonksiyonların bant genişliğidir.

Olasılıksal sinir ağı'nın güvenilirliğini sınamak için, veri kümesi, tek sayılı veriler ve çift sayılı veriler olmak üzere, iki alt kümeye bölünmüştür. İki alt kümeden hangisinin bütün veri kümesini daha iyi temsil ettiğini incelemek için de 2 – katlamalı çapraz geçerlilik yöntemi kullanılmıştır. Birinci durumda, ilk alt küme eğitim kümesi olarak, ikinci alt küme ise test kümesi olarak kullanılmıştır. İkinci durumda ise, eğitim ve test kümelerinin yerleri değiştirilerek olasılıksal sinir ağına uygulanmıştır. Bu çalışmayla, ağı genelme yeteneği incelenir. Eğitim ve test kümeleri için hatalı sınıflama sayıları ve yüzdeleri Tablo 1'de ve Tablo 2'de görülmektedir.

Tablo 1: Birinci durumda hatalı sınıflama.

	σ	Eğitim kümesi için hatalı sınıflama		Test kümesi için hatalı sınıflama	
		Sayı	[%]	Sayı	[%]
1. durum	3,50	37	8,809	37	8,809
	3,00	27	6,428	29	6,905
	2,50	5	1,190	4	0,952
	2,00	3	0,714	3	0,714
	1,50	1	0,238	2	0,476
	0,50	0	0	0	0

Tablo 2: İkinci durumda hatalı sınıflama

	σ	Eğitim kümesi için hatalı sınıflama		Test kümesi için hatalı sınıflama	
		Sayı	[%]	Sayı	[%]
2. durum	3,50	36	8,571	37	8,809
	3,00	25	5,952	29	6,905
	2,50	4	0,952	3	0,714
	2,00	3	0,714	3	0,714
	1,50	1	0,238	3	0,714
	1,00	0	0	2	0,476

Sonuçlar, olasılıksal sinir ağının 1. durumda hatasız sınıflama yaptığı, 2. Durumda ise yüksek başarımlı sınıflama yaptığını göstermektedir. Sonuçlar, problem için kullanılan yöntemin uygunluğunu göstermektedir.

6. Tartışma

Bu çalışmada, elektriksel boşalmanın olduğu elektrot sisteminin tipinin belirlenmesi için duyulabilir boşalma sesi kullanılmıştır. Bu amaçla, farklı elektrot düzenlerine 50 Hz alternatif gerilimler uygulanmış ve meydana gelen korona sesi kaydedilmiştir. Kaydedilen ses verilerinin öz nitelikleri, doğrusal öngörü analizinden yararlanılarak elde edilmiştir. Çözümlenen ses verileri, bir olasılıksal sinir ağına uygulamıştır. Sonuç olarak kaydedilen ses verileri kullanılarak boşalmanın hangi kaynaktan yani elektrot sisteminden geldiğini belirlenmiştir.

Sonuçlar, farklı boşalma kaynaklarından meydana gelen boşalma sesinin hatasız olarak ayırt edilebildiğini göstermektedir. Yapılan çalışma, kullanılan elektrot sistemlerinin artırılmasıyla, veri kümesinin genişletilmesiyle zenginleştirilebilir. Birden fazla elektrot sisteminde aynı anda korona oluşturularak kaydedilen ses verilerinin hangi kaynaktan geldiğini belirlemek, ileriye yönelik çalışmalardan biri olarak düşünülebilir.

Yapılan çalışma, işaret işleme tekniklerini kullanarak ses verisinden boşalma kaynağını tanımak için bir adımdır. Özellikle yüksek gerilimde, yüksek gerilim hatlarına bağlantı yapmadan bir arızada ortaya çıkan boşalma sesinden arızaya neden olan boşalmanın kaynağı ve/veya yeri hakkında bilgi edinme veya elektrik sistemlerinde gözleme ve izleme sistemlerinde uygulamaya dönük çalışmalar için bir uygulamadır.

7. Kaynakça

[1] Ö. Kalenderli, C. Kocatepe, O. Arıkan, *Çözümlü Problemlerle Yüksek Gerilim Tekniği*, Cilt 1, Birsen Yayınevi, İstanbul, 2005.

[2] L. I. Sirotnski, (Çeviren: M. Özkaya), *Yüksek Gerilim Tekniği, Gazlarda Deşarj Olayları*, İ.T.Ü. Kütüphanesi Sayı: 594, İstanbul, 1964.

[3] M. S. Naidu, V. Kamaraju, *High Voltage Engineering*, Tata McGraw-Hill, New Delhi, Third Ed. 2004.

[4] ASTM Publ. 669, *Engineering Dielectrics Vol. I: Corona Measurement and Interpretation*, Chapter 10, Philadelphia, 1979.

[5] S. Ray, *An Introduction to High Voltage Engineering*, Prentice Hall of India, New Delhi, 2004.

[6] E. Gulski, *Computer-Aided Recognition of Partial Discharges Using Statistical Tools*, Delft Univ. Press, Delft, 1991.

[7] F. H. Kreuger, *Partial Discharge Detection in High Voltage Equipment*, Butterworths, London, 1989.

[8] F. H. Kreuger, *Discharge Detection in High Voltage Equipment*, Temple Press Books, London, 1964.

[9] P. S. Maruvada, *Corona Performance of High-Voltage Transmission Lines*, Research Studies Press, Hertfordshire, England, 2000.

[10] Ö. Kalenderli, B. Bolat, and S. Bolat, "Determination of Voltage Level from Electrical Discharge Sound by Probabilistic Neural Network", *SIU 2006 14th IEEE Signal Processing and Communications Applications Conference*, Antalya, April 17-19, 2006.

[11] S. Bolat Sert, and Ö. Kalenderli, "Determination of Source Voltage from Audible Corona Noise by Neural Networks" *IEEE Transactions on Dielectrics and Electrical Insulation*, Vol. 16, No. 1, pp. 224-231, February 2009.

[12] A. Eronen, *Automatic Musical Instrument Recognition*, Yüksek Lisans Tezi, Tampere University of Technology, 2001.

[13] L. Rabiner, B. Juang, *Fundamentals of Speech Recognition*, Prentice Hall, New York, 1993.

[14] S. Haykin, *Adaptive Filter Theory*, Prentice Hall, NY, 1991.

[15] R. Senani, "New Current-Mode Biquad Filter", *International Journal of Electronics*, Vol. 73, No. 4, pp. 735-742, 1992.

[16] R. Bozzo, L. Scituro, and R. Zunino, "BP Networks for Partial Discharge Analysis and Dielectric Classification", *International Conference on Neural Networks*, Vol. 1, pp. 37 – 42, June 9-12, 1997.

[17] M. H. Hayes, *Statistical Digital Signal Processing and Modelling*, John Wiley & Sons, NY, 1996.