Eleco'2002 Symposium on Electrical-Electronics and Computer Engineering, Bursa, pp. 154-158, December 18-22, 2002

YÜKSEK GERİLİM İZOLATÖRLERİNİN DARBE ATLAMA GERİLİMLERİNİN YAPAY SİNİR AĞI İLE BELİRLENMESİ

Suna BOLAT[1] Özcan KALENDERLİ[2] Emel ÖNAL[3] Ahmet MEREV[4]

[1, 2, 3]İstanbul Teknik Üniversitesi
Elektrik-Elektronik Fakültesi, Elektrik Mühendisliği Bölümü
80626, Maslak, İstanbul
[4]TUBİTAK - Ulusal Metroloji Enstitüsü (UME)
PK 54, 41470, Gebze, Kocaeli
[1]e-posta: bolats@elk.itu.edu.tr [2]e-posta: ozcan@elk.itu.edu.tr
[3]e-posta: onal@elk.itu.edu.tr [4]e-posta: ahmetm@ume.tubitak.gov.tr

Anahtar sözcükler: Yüksek Gerilim, İzolatör, Darbe Gerilimi, Atlama Gerilimi, Yapay Sinir Ağı

ABSTRACT

This paper presents determination of impulse flashover voltages of high voltage post-insulators using by artificial neural network (ANN) algorithm. Data used in ANN is obtained an experimental study of impulse flashover characteristics of cast resin support insulators under low pressure in dry air. Experimental data obtained for different pressure, temperature, relative humidity and type of insulator is used to train the ANN. ANN can give results with mean absolute error of 0.9% when compared with experimentally obtained results. The results from the present study show that the trained ANN can give flashover voltage very efficiently and accurately.

1. GİRİŞ

Yüksek gerilim tekniğinde, iletim sistemlerinde, transformatör ve yüksek gerilim bağlama cihazlarında kullanılan izolatörler, iletkenlerin birbirine ve toprağa karşı yalıtımını sağlarlar. İzolatörler elektriksel bakımdan yalıtım sağlamanın yanında, mekanik bakımdan da bağlantıların yapılmasını sağlayan elemanlar oldukları için, elektrik sistemlerinde önemli bir yer tutar. İzolatörün yapısal özellikleri, etkisi altında bulunduğu sıcaklık, nem, basınç, kirlenme gibi ortam koşulları, yükselti, gerilim türü gibi çalışma koşulları ve mekanik etkiler, izolatörlerin güvenilirliğini etkiler. Bu etkenlerin izolatörler üzerindeki etkisini incelemek, tasarımları geliştirmek, davranışlarını belirlemek ve olayları anlamak bakımından çok önemlidir. Bu amaçla pek çok araştırma yapılmaktadır [1-5]. Bu araştırmalardan biri de, farklı basınçlarda, negatif ve pozitif darbe gerilimi altında, değişik özellikli izolatörlerde, yüzeysel boşalma (atlama) olayıdır.

İzolatörler, uygulamada bulundukları yerin ortam koşullarına ve yükseltisine göre, farklı basınçlar altında bulunabilirler. Farklı basınçlarda izolatörlerin davranışlarının belirlenmesi ve açıklanması yönündeki çalışmalar devam etmektedir [2, 5]. İzolatörlerin normal atmosfer basıncı için verilmiş olan atlama verilerinden, bu basınç yakınındaki diğer basınçlar için, standartlarda verilen düzeltme katsayıları kullanılarak belirlenir. Ancak normal atmosfer basıncına yakın olmayan basınçlarda, bu belirlemenin nasıl yapılacağı konusu, çalışmaya açıktır.

Basınç, nem, sıcaklık gibi koşullara bağlı olarak atlama gerilimi hesaplanmasında genellikle deneye dayalı olarak yazılmış (amprik) bağıntılar kullanılır. Gazlarda Townsend teorisinin geçerli olduğu durumlarda Paschen bağıntısı, düzgün olmayan alanda kanal teorisi bağıntısı kullanılır. Yüzeysel boşalma için genelde parametrelere göre tek tek deney yapılarak, elde edilen verilere uyan bağıntılar çıkarılır. Bu amaçla yapılan çalışmalarda, genel bir bağıntı bulmak zordur. Literatürü araştırıp duruma uyan veya yakın olan bağıntılardan yararlanılır veya onlarda değişiklik yapılarak kullanılabilir. Ancak deney yapmak zaman alan pahalı bir yöntem olduğu için, daha çok sayısal yöntemler tercih edilmektedir. Bu çalışmalardan birisi de, sınırlı sayıdaki atlama verilerinden yararlanarak, bir Yapay Sinir Ağı (YSA) algoritması kullanmaktır. Böyle bir amaçla yapay sinir ağlarının kullanılması, deneysel çalışmaların zorluklarını, zaman alıcılığını ve pahalılığını gidermesi yanında hesaplamada hem daha kolay ve hızlı, hem de daha genel sonuç alınmasını sağlar.

Son yıllarda pekçok alanda, Yapay Sinir Ağlarının kullanımı ve geliştirilmesi için çok çeşitli çalışmalar yapılmaktadır [6 - 9]. Bunun sonucu olarak da, yapay sinir ağları literatürü oldukça hızlı bir şekilde gelişmiştir. Yapay sinir ağları, çok geniş uygulama alanına sahiptir. Elektrik enerji sistemlerinde YSAlar, yük tahmininde, güvenlik değerlendirilmesinde, kapasite kontrolünde, alarm değerlendirilmesinde çok etkin olarak kullanılmaktadır. Yüksek gerilim sistemlerinde ise YSA uygulamaları, başta kısmi

boşalma örüntülerinin tanınması olmak üzere her türlü boşalma olayının modellenmesinde ve elektrot optimizasyonunda kullanılmaktadır [6 - 8].

Bu çalışmada, farklı basınç ve ortam koşulları altında, izolatörlerin darbe atlama gerilimlerinin hesaplanmasında yeni bir yaklaşım açıklanmıştır. Yapay sinir ağları kullanılarak, darbe atlama geriliminin hesaplanmasında, bir çok katmanlı, ileri beslemeli ağ kullanılmıştır. Yapay sinir ağının ağırlıklarının hesaplanması için, eğitim sürecinde, geriye yayılım (back-propagation) algoritmasından yararlanılmıştır.

2. YAPAY SİNİR AĞLARI

Yapay sinir ağları, insan beyninin öğrenme şeklinin uygulanmaya çalışıldığı bir yöntemdir. Bir yapay sinir ağı, nöron adı verilen, bilgi işleme elemanlarından oluşmaktadır. Nöronlar, bağlantı hatları üzerinden işaret göndererek birbirlerini etkilerler. Bu bağlantı hatlarının herbirinin kendine özgü bir ağırlığı vardır. Uyarlamalı hesaplanabilen bu ağırlıklar, bilgi simgesini, doğru olarak bildirir. Genellikle, bilgi ağ boyunca dağıldığı için, bağlantı ağırlıklarını önceden belirlemek mümkün değildir. Bu sebeple, ağırlıkların değiştirileceği bir öğrenme işlemi gereklidir.

Öğrenme işlemi üç tiptir: eğiticili öğrenme, eğiticisiz öğrenme ve özdenetimli öğrenme. Bu öğrenme şekilleri, ağdaki ağırlıkları eğitmek için hata işareti kullanılarak tanımlanır. Eğiticili öğrenmede, ortamın dışından bir eğitici, her çıkış nöronu için hata üretir. Eğiticisiz öğrenmede, hata işareti üretilmez, bunun yerine, ağırlıkları değiştirmek için kullanılmak üzere, nöronlar arasındaki hatalar üretilir. Özdenetimli öğrenmede ise sistem, girişlerin istatistiksel düzenini belirledikten sonra, sınıflamayı başaracak beceriyi oluşturur.

Eğiticili öğrenmede, nöronları birleştiren ağırlıklar, eğitici tarafından ayrıntılı hata bilgileri ağa uygulanacak şekilde yerleştirilirler. Pek çok durumda ağ, giriş-çıkış çiftleri kullanılarak eğitilir. Bu öğrenme işleminin performansı, eğitim kümesi kullanılarak istenen sonuca ulaşılabilmesi ve eğitilen ağın genelleştirilebilmesiyle ölçülür.

Bu çalışmada ele alınan atlama geriliminin bulunması probleminde, farklı izolatör tipleri (silindirsel, etekli, eteksiz izolatör, mekik izolatör) ve yalnızca atlama aralığı, ortam koşulları (bağıl nem, sıcaklık ve basınç) değerlerine karşılık, negatif ve pozitif darbe atlama gerilim değerleri bilinmektedir. Problemde giriş-çıkış eğitim kümesi bilindiğine göre, eğiticili öğrenmeli bir yapay sinir ağı kullanılması uygundur.

3. ÇOK KATMANLI İLERİ BESLEMELİ AĞ

Eğiticili öğrenmeli en basit ağ yapısı, bir giriş ve bir çıkış katmanı bulunan, iki katmanlı, ileri beslemeli ağdır. Çıkış katmanındaki herbir nöron, düzeltilebilen ağırlıklar yoluyla, bütün giriş nöronlarından işaret alır. Ancak iki katmanlı ileri beslemeli yapay sinir ağları, sadece lineer ayrıştırılabilir fonksiyonları hesaplayabilir. Bununla birlikte, birden fazla adaptif ağırlıklı katmana sahip olan bir ileri beslemeli ağ, çok kompleks fonksiyonları hesaplayabilir.

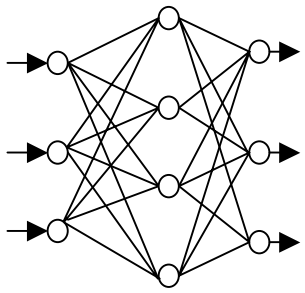

Şekil 1. Şematik çok katmanlı ileri beslemeli ağ.

Şekil 1'de bir çok katmanlı ileri beslemeli ağın şematik yapısı görülmektedir. Ağda giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç katman bulunur. Burada dikkat edilmesi gereken nokta, bir ileri beslemeli ağda, işaretlerin girişten çıkışa bir veya daha fazla gizli katman üzerinden yayılmasıdır.

Yapay sinir ağları, giriş vektörünü bir kez tanımladıktan sonra, ağırlıkları öğrenme işlemine göre ayarlar. Bu çalışmada, Widrow-Hoff öğrenme kuralının genelleştirilmiş hali olan geriye yayılım (back-propagation) algoritması kullanılmıştır.

3.1. GERİYE YAYILIM ALGORİTMASI

Geriye yayılım algoritması, yapay sinir ağlarında en çok kullanılan algoritmadır [9]. Geriye yayılım öğrenmesi sırasında ağ, her giriş örüntüsünü, çıkış nöronlarında sonuç üretmek üzere gizli katmanlardaki nöronlardan geçirir. Daha sonra çıkış katmanındaki hataları bulabilmek için, beklenen sonuçla, elde edilen sonuç karşılaştırılır. Bundan sonra, çıkış hatalarının türevi çıkış katmanından geriye doğru gizli katmanlara geçirilir. Hata değerleri bulunduktan sonra, nöronlar kendi hatalarını azaltmak için ağırlıklarını ayarlar. Ağırlık değiştirme denklemleri, ağdaki ortalama hata karesini en küçük yapacak şekilde düzenlenir. Öğrenme algoritması aşağıda notasyonuyla birlikte açıklanmıştır.

n. iterasyonda, j. nöronun çıkışındaki hata işareti, j. nöron çıkış katmanındaysa;

$$e_j(n) = d_j(n) - y_j(n) \tag{1}$$

şeklinde tanımlanır. Ağın öğrenme sırasındaki hatası geriye yayılım algoritmasıyla en küçük değere indirilir. Hata fonksiyonu, N eğitim kümesindeki tüm örüntü sayısı olmak üzere, (2) denklemiyle bulunur:

$$E_{ort} = \frac{1}{n}\sum_{n=1}^{N} E(n) \tag{2}$$

$$E(n) = \frac{1}{2}\sum_{j \in C} e_j^2(n) \qquad (3)$$

(3) denklemindeki C kümesi, ağın çıkış katmanındaki bütün nöronları içerir.

Hatayı en küçük değere indirmek için en uygun ağırlık seçimi şu şekilde gerçekleştirilir:

1. $\delta E/\delta w$ hesaplanır.
2. Ağırlıklar w(n)'den w(n+1)'e güncellenir.

$$w(n+1) = w(n) + \Delta w(n) \qquad (4)$$

$$\Delta w_{ji}(n+1) = \eta\, \delta_j(n)\, y_i(n) + \alpha\, \Delta w_{ji}(n) \qquad (5)$$

(5) denklemi ile yazılan kurala delta kuralı denilmektedir. Ağ ağırlıklarını güncellemek için kullanılan bu eşitlikte, η öğrenme hızı, α momentum katsayısı, $\alpha\Delta w_{ji}$ ise momentum terimidir. Yerel gradyen denilen δ_{ji}, j. nöronun çıkış katmanında veya gizli katmanda olmasına göre farklı hesaplanır. φ aktivasyon fonksiyonunu belirtmek üzere, eğer j. nöron çıkış katmanında ise;

$$\delta_{ji} = e_j(n)\varphi_j'(v_j(n)) \qquad (6)$$

bağıntısından, eğer j. nöron gizli katmanda ise;

$$\delta_{ji} = \varphi_j'(v_j(n))\sum_k \delta_k(n) w_{kj}(n) \qquad (7)$$

bağıntısından hesaplanır.

Bu çalışmada, yerel gradyenlerin hesabında φ aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır. Söz konusu YSA algoritması çalışmaları, Matlab 5.0 Neural Network Toolbox kullanılarak gerçekleştirilmiştir.

4. GİRİŞ ÇIKIŞ VERİLERİNİN NORMALİZASYONU

Giriş çıkış verilerinin normalizasyonu, yakınsama ve öğrenme işlemi açısından oldukça önemlidir. Sigmoid fonksiyonunun özelliğinden dolayı, ağın çıkışı 0-1 arasında olmalıdır. Bununla birlikte, giriş değişkenleri, sigmoid fonksiyonunun doymaya girmemesi için yeterince küçük tutulmalıdır. Bu sebeple, giriş çıkış verilerinin, ağ eğitilmeden önce normalize edilmesi gerekir. Bu çalışmada, giriş çıkış verileri 0 ve 1 arasında kalacak şekilde normalize edilmiştir. Giriş ve çıkış nöronları tek tek, o nörondaki en büyük değere bölünür. Normalizasyon işlemi sonunda, giriş ve çıkış vektörleri 0-1 arasında değer alır.

5. GİRİŞ ÇIKIŞ VERİLERİNİN ELDE EDİLMESİ

Yüksek gerilim izolatörlerinin alçak basınçta darbe atlama geriliminin sayısal belirlenmesinde veri olarak kullanılan gerilim değerleri, deneysel çalışma ile elde edilmiştir. Deneylerde düz ve mekik biçimi, bina içi türden epoksi reçineden yapılmış iki tür izolatör kullanılmıştır.

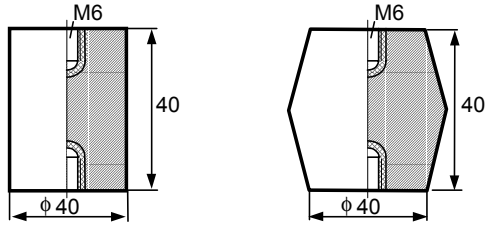

(a) Düz izolatör (b) Mekik İzolatör

Şekil 2. Denenen izolatörler

Her biri 40 mm boyunda olan izolatörler, biri gerilim kaynağına bağlı diğeri topraklanmış düzlem – düzlem elektrotlar arasına konmuş, bu düzen de pleksiglastan yapılmış 10^{-3} bar'lık bir basınç kabına yerleştirilmiştir. Kabın basıncı bir vakum pompası ile ayarlanmış ve kap içindeki basınç, kap üzerindeki manometreden okunmuştur.

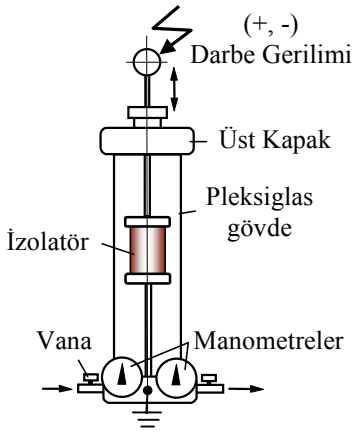

Şekil 3. Deney düzeni.

Deneyler standart yıldırım darbe gerilimi ile yapılmıştır. Darbe gerilimleri, 280 kV, 200 J'luk bir darbe üretecinden elde edilmiştir. Elde edilen gerilimler, devrenin çıkışına bağlı bir kapasitif gerilim bölücü ve bir darbe tepe değer voltmetresi ile ölçülmüş ve dalga şekli bir osiloskoptan izlenmiştir. Deneyler hem pozitif hem de negatif kutuplu darbe gerilimleri ile yapılmıştır. Her durum için deneysel olarak %50 atlama gerilimi saptanmış ve bu değer atlama gerilimi olarak alınmıştır.

Deneyler atmosfer basıncından 100 mbar aralıklarla 100 mbar'a kadar yapılmıştır. Her basınç basamağında kararlı basınç elde edildikten sonra pozitif ve negatif darbe atlama gerilimi deneysel olarak saptanmıştır. Benzer çalışma, elektrotlar arasında izolatör yokken 40 mm elektrot açıklığı için yinelenmiştir. Bu durum YSA incelemesinde (1) durumu olarak, mekik izolatörün bulunduğu durum (2) durumu olarak ve düz izolatörün bulunduğu durum da (3) durumu olarak

kodlanmıştır. Bu kodlama, izolatör türünün ve varlığının değişken parametre olarak ele alınmasını kolaylaştırmıştır. Deney, değişik alçak basınçlar yanında farklı sıcaklık ve nem koşullarında gerçekleştirilmiştir. YSA için eğitim kümesi olarak kullanılan deney verileri Tablo 1'de verilmiştir.

Tablo 1. Eğitim kümesi

Giriş verileri				Çıkış verileri	
Kod	t (^oC)	Nem (%)	(1 – p) (bar)	+ U_a (kVtepe)	- U_a (kVtepe)
2	26,0	66,9	0,9	13,00	13,30
2	26,0	66,9	0,4	67,85	68,14
2	26,0	66,9	0,0	101,20	110,00
3	27,4	74,0	0,8	30,17	31,12
3	27,4	74,0	0,3	72,07	78,54
3	27,4	74,0	0,1	95,64	99,59
1	26,0	66,9	0,6	72,17	58,28
1	26,0	66,9	0,5	76,27	61,31
1	26,0	66,9	0,2	87,11	82,24
1	23,0	38,0	0,7	53,41	39,62
1	23,0	38,0	0,6	67,20	50,31
1	23,0	38,0	0,5	69,14	60,66
1	23,0	38,0	0,0	101,80	119,54

6. ALGORİTMANIN UYGULANMASI

Ağın eğitimi için gerekli deney verilerinin elde edilmesinden sonra oluşturulan eğitim kümesinde, izolatör tipi, basınç, sıcaklık ve bağıl nem, giriş vektörünü; pozitif ve negatif darbe atlama gerilimi değerleri ise, çıkış vektörünü oluşturmaktadır. Görüldüğü gibi, yapay sinir ağı, 4 giriş nöronu ve 2 çıkış nöronundan meydana gelmektedir.

Eğitimin tamamlanmasından sonra, ağın güvenilirliğini sınamak amacıyla, eğitim kümesinden bir örüntü kullanılarak bir test kümesi oluşturulmuş ve gerçek çıkış ile yapay sinir ağının hesaplamış olduğu çıkış karşılaştırılarak, hata bulunmuştur.

Test kümesi, arada izolatör yokken (1) 23°C sıcaklıkta, 300 mbar basınçta (0,7) ölçülen atlama gerilimi değerlerinden oluşmaktadır. Bu durumda test kümesinin giriş vektörü [1 23 38 0,7], ve istenen çıkış vektörü ise [53,41 39,62] olacaktır.

Hesaplamalar, 10 nöronlu tek katmanlı bir ağ için yapılmış ve ağ için en uygun parametreleri bulmak amacıyla, öğrenme hızı (η) ve momentum katsayısı (α), 0,1'den 0,9'a kadar değiştirilerek denemeler yapılmıştır. Bulunan uygun η ve α değerleri kullanılarak yapılan denemelerde, gizli katmandaki nöron sayısı 5'ten 15'e kadar değiştirilmiş ve en iyi sonuç aranmıştır.

Bu çalışmada eğitim için toplam karesel hata (sum squared error, sse) ve karesel ortalama hata (root mean square, rms), test için ise ortalama mutlak hata (mean absolute error, mae) kullanılmıştır.

Tablo 2 Öğrenme hızının ve momentum katsayısının hatalara etkisi (sse: sum squared error; mae: mean absolute error)

Gizli katman nöron sayısı = 10 İterasyon sayısı = 5000		
η = 0,1		
α	sse	mae (%)
0,9	0,0638	2,22
0,8	0,0674	2,22
0,7	0,0680	1,60
0,6	0,0679	2,38
0,5	0,0700	1,65
0,4	0,0657	1,53
0,3	0,0774	2,31
0,2	0,0665	1,65
0,1	0,0669	1,96
α = 0,9		
η	sse	mae (%)
0,1	0,0638	2,22
0,2	0,6590	2,03
0,3	0,0491	3,68
0,4	0,5100	1,88
0,5	0,0364	2,48
0,6	0,0372	4,55
0,7	1,1914	6,31

Bu çalışmada her denemede öğrenme hızı ve momentum katsayısı sabit tutulmuştur.

$$sse = \sum_{j=1}^{N} e_j^2(n) \tag{8}$$

$$rms = \sqrt{\frac{1}{N\, n_o} \sum_{j=1}^{N} \sum_{k=1}^{n_o} (d_{jk} - y_{jk})^2} \tag{9}$$

$$mae = \frac{1}{n_t\, n_o} \sum_{j=1}^{n_t} \sum_{k=1}^{n_o} \left[\frac{|d_{jk} - y_{jk}|}{d_{jk}} \right] 100 \tag{10}$$

Burada N eğitim kümesindeki tüm örüntü sayısını, n_o çıkış katmanındaki nöron sayısını, n_t ise test kümesindeki örüntü sayısını göstermektedir.

Tablo 3 Gizli katman nöron sayısının hatalara etkisi

İterasyon sayısı = 5000		
Gizli katman nöron sayısı	sse	mae (%)
4	0,0347	4,56
5	0,0373	3,70
7	0,0303	1,66
8	0,0360	2,86
10	0,0364	2,48
15	0,0496	3,72

Çalışmalar, öğrenme hızının ve momentum katsayısının farklı değerleri için yapılmış ve sonuçlar Tablo 2'de verilmiştir. Tablo 2'den en uygun seçimin $\eta = 0,5$ ve $\alpha = 0,9$ değerleri olduğu görülmektedir.

4'ten 15'e kadar değiştirilen gizli katmandaki nöron sayısı için, 7 nöronun en uygun eğitim ve test sonucu verdiği görülmüştür (Tablo 3). Bu çalışmalar 5000 iterasyon için yapılmıştır.

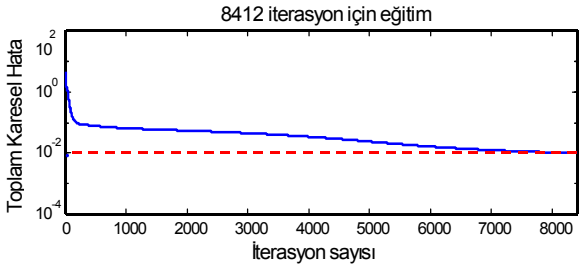

Şekil 4. Hatanın iterasyon sayısına göre değişimi

En uygun öğrenme hızı, momentum katsayısı ve gizli katmandaki nöron sayısı bulunduktan sonra eğitim, toplam karesel hata 0,01'den küçük olana kadar sürdürülmüştür (Şekil 4). Öngörülen toplam karesel hataya 8412 iterasyonda ulaşmış ve bu iterasyon sonunda karesel ortalama hata 0,0196, ve ortalama mutlak hata %0,93 olarak bulunmuştur (Tablo 4).

Tablo 4. YSA sonuçları ile gerçek değerlerin karşılaştırılmasına bir örnek

Gizli katman nöron sayısı = 7; $\alpha = 0,9$; $\eta = 0,5$ İterasyon sayısı = 8412		
Atlama gerilimi (kVtepe)	Gerçek değerler	YSA değerleri
Pozitif darbe	53,41	53,30
Negatif darbe	39,62	40,19

Bu bölümde açıklanan sonuçlardan görüleceği gibi, darbe atlama geriliminin bulunması probleminin yapay sinir ağı ile çözümü oldukça etkin, kesin ve genel bir çözüm vermektedir. Yapay sinir ağı kullanılarak herhangi sıcaklık ve basınç değerleri için farklı izolatörlerde, pozitif ve negatif darbe atlama gerilimi, yaklaşık %1 hatayla bulunabilir.

7. SONUÇ

Bu çalışmada, yüksek gerilim izolatörlerinin darbe atlama gerilimleri, farklı bir yaklaşım olarak yapay sinir ağı algoritması ile belirlenmiştir. Değişik ortam koşulları altında, izolatörlerin darbe atlama gerilimlerinin hesaplanmasında geriye yayılım algoritması kullanan bir ileri beslemeli çok katmanlı bir yapay sinir ağı tasarlanmıştır. Öğrenme hızı, momentum katsayısı ve gizli katmandaki nöron sayısı gibi ağ parametrelerinin doğru sonuç verecek en uygun değerlerini belirlemek için detaylı çalışmalar yapılmıştır. Karar verilen parametrelerin uyumu sonuçlarda kendini göstermiştir. Yapılanın çalışmalardan görüldüğü gibi, pozitif ve negatif darbe gerilimlerinin deneysel sonuçları ile YSA çıkışları arasındaki ortalama mutlak hata değerleri, denemelerin çoğunda % 3'ten küçüktür.

Darbe atlama geriliminin bulunması problemi için yapay sinir ağı kullanılması gerçekten oldukça etkin ve kesin sonuçlar vermektedir. Bu problemde YSA kullanılmasının üstünlüğü, sadece sınırlı sayıda deney yapılarak genel bir çözüme ulaşmaktır. Böyle bir problem için deneysel yöntemleri kullanmak, pahalı olmasının yanında, çok fazla zaman almaktadır. Yapay sinir ağlarının kullanılması ise 13 örüntüsü bulunan bu yapıda, günümüz bilgisayarlarında yaklaşık 150-200 saniyede sonuç vererek, işlemin zaman alıcılığını ve pahalılığını giderir.

KAYNAKLAR

[1] Kalenderli Ö., Aydınay Ş., Alçak Basınçta Havanın Delinme Dayanımı, ELECO'2000, Elektrik Elektronik Bilgisayar Mühendisliği Sempozyumu, Bursa, s. 141-145, 2000.

[2] Kalenderli Ö., Aydınay Ş., Alçak Basınçta Reçine İzolatörlerde Atlama, ELECO'2000, Elektrik Elektronik Bilgisayar Mühendisliği Sempozyumu, Bursa, s. 146-149, 2000

[3] Türk L., Vakum Teknolojisi ve Vakum Kesicilerin Akım Kesme Özellikleri, Elektrik Mühendisliği 3. Ulusal Kongresi, İstanbul, s. 236-239, 1989.

[4] Öztaş H., Yılmaz G., Kalenderli Ö., Darbe Geriliminde Kabloların Dielektrik Özelliklerine Sıcaklığın Etkisi, Elektrik Mühendisliği 6. Ulusal Kongresi, Bursa, s. 286-289, 1995.

[5] İsmailoğlu H., Kalenderli Ö., Özkaya M., Gönenç İ., Darbe geriliminde havanın delinme dayanımı, Elektrik Mühendisliği 6. Ulusal Kongresi, Bursa, s. 257-260, 1995.

[6] Bhattacharya K., Chakravorti S., Mukherjee P. K., Insulator Contour Optimization by a Neural Network, IEEE Transactions on Dielectrics and Electrical Insulation Vol. 8, No. 2, pp. 157-161, 1994.

[7] Chakravorti S., Mukherjee P. K., Application of Artificial Neural Networks for Optimization of Electrode Contour, IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 1, No. 2, pp. 254- 263, 1994.

[8] Salama M. M. A., Bartnikas R., Determination of Neural Network Topology for Partial Discharge Pulse Pattern Recognition, IEEE Transactions on Neural Networks, Vol. 13, No. 2, pp. 446- 456, 2002.

[9] Haykin S., *Neural Networks: a Comprehensive Foundations*, Upper Saddle River, N.J., Prentice Hall, 1999.