

YAPAY SİNİR AĞI İLE GAZ KARIŞIMINDA ELEKTROT AÇIKLIĞINA VE KARIŞIM YÜZDELERİNE BAĞLI OLARAK DELİNME GERİLİMLERİNİN BELİRLENMESİ

Suna BOLAT¹ Özcan KALENDERLİ² Emel ÖNAL³

^{1, 2, 3}Elektrik Mühendisliği Bölümü

Elektrik-Elektronik Fakültesi

İstanbul Teknik Üniversitesi, Maslak, İstanbul

E-posta: bolats@elk.itu.edu.tr

ozcan@elk.itu.edu.tr

onal@elk.itu.edu.tr

Özet

Gazlar, elektrik mühendisliğinde yaygın kullanılan yalıtkanlardır. Yalıtımları delinme gerilimleri ile sınırlıdır. Ekonomik ve teknik gereksinimler, gazların karıştırılarak kullanımına zorlamaktadır. Gaz karışımlarında, karışımı oluşturan gazların oranına ve kullanılacağı sistemlerdeki elektrot açıklıklarına göre delinme gerilimleri farklılıklar gösterir. Bu farklılık genelde pahalı ve zaman alıcı deneysel çalışmalarla belirlenir. Bu çalışmada bu zorluğu yenmek amacıyla elde edilen deneysel bilgiyi değerlendirip yeni bir yaklaşım olarak yapay sinir ağı ile delinme gerilimlerini bulma yöntemi ve örneği sunulmuştur.

1. Giriş

Gazlar, konuldukları hacme kolay uyum sağlamaları ve istenen teknik özellikleri ağırlık sorunu yaratmadan karşılamaları açısından yalıtkanlar içinde ayrı bir yere sahiptir. Yüksek gerilim aygıtlarının boyutlandırılması ve davranışı bakımından yalıtım ortamı sağlayan gazların delinme karakteristiklerinin bilinmesi önemlidir. Bu amaçla gazlarla ilgili pek çok araştırma ve yayın yapılmaktadır [1-11].

Gazlar üzerinde bugüne kadar yapılan çalışmalar, gazların elektriksel dayanımının gaz basıncı, elektrot şekli, ortam koşulları, gaz özellikleri, gerilim türü ve kutbiyeti gibi pek çok etkene bağlı olduğunu göstermiştir [1-5]. Gaz yalıtkanlar içinde üstün yalıtkanlık özellikleri nedeni ile SF₆ (kükürt heksaflorür) gazının ayrı bir yeri vardır. Çok kullanılan fakat pahalı bir gaz olan SF₆'nın bu durumu diğer gazlarla karışımı yoluyla yeni ekonomik ve teknik çözümler aramaya yöneltmiştir. N₂, CO₂ ve hava gibi yalıtım amaçlı kullanılan gazların delinme gerilimleri az oranda SF₆ katılarak yükseltilebilmekte ve saf SF₆'nın olumsuz özellikleri giderilmektedir [6, 7].

Bu çalışmada, 50 Hz frekanslı alternatif gerilimde ve düzgün olmayan alanda 1 bar'lık gaz basıncında, farklı SF₆ gazı oranları ve farklı elektrot açıklıkları için delinme gerilimleri Yapay Sinir

Ağı (YSA) ile belirlenmiştir. Deneysel olarak elde edilen veriler, YSA'nın eğitimi için kullanılmıştır. Çalışmada YSA için hem Çok Katmanlı İleri Beslemeli Ağ hem de Genelleştirilmiş Regresyon Ağı kullanılmış ve bunlarla elde edilen sonuçlar ağ başarımını sınamak için karşılaştırmalı olarak verilmiştir. Bu çalışmalardan amaç, her koşul için deneysel çalışma yapmanın zor ve pahalı olduğu ve uzun zaman aldığı durumlarda, veri üretmek için YSA'nın kullanılabilirliğini incelemek, uygulamalı olarak uygun YSA yapısını aramak ve elde edilen sonuçları değerlendirip paylaşmaktır.

Elektrik mühendisliğinde de YSA, pek çok alanda kullanılmakta ve geliştirilmektedir. Örneğin, elektrik enerji sistemlerinde YSA, yük tahmininde, güvenilirlik analizinde, kapasite kontrolünde ve alarm değerlendirilmesinde etkin olarak kullanılmaktadır. Yüksek gerilim tekniğindeki YSA uygulamalarından bazıları ise kısmi boşalma örüntülerinin tanınması, her türlü boşalma olayının modellenmesi [12, 13], yıldırım tahmini, elektrot ve yalıtkan biçim optimizasyonudur [14].


2. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin öğrenme şeklinin modellenmeye 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, bilgiyi, doğru olarak bildirir. Genellikle, bağlantı ağırlıkları bir öğrenme işlemi ile belirlenir. Değişik öğrenme işlemi ile belirlenebilen ağırlıkları da kullanarak sonuç bilgilerine ulaşılır [11].

3. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı

En basit ağ yapısı, bir giriş ve bir çıkış katmanı bulunan, iki katmanlı, ileri beslemeli ağıdır. Çıkış katmanındaki herbir nöron, ağırlıklar yoluyla, bütün giriş nöronlarından işaret alır. Genelde karşılaşılan karmaşık yapıdaki fonksiyonları

hesaplamak için basit ağırlar yerine arada gizli katmanların bulunduğu çok katmanlı YSA'lar kullanılır.



Şekil 1. Çok katmanlı ileri beslemeli bir ağ örneği.

Şekil 1'de çok katmanlı ileri beslemeli bir ağı basitçe yapısı görülmektedir. Ağda giriş, gizli ve çıkış katmanı olmak üzere üç katman bulunur. Bir ileri beslemeli ağda, işaretler girişten çıkışa bir veya daha fazla gizli katman üzerinden yayılır.

YSA, giriş vektörünü bir kez tanımladıktan sonra, ağırlıkları öğrenme işlemine göre ayarlar. Bu çalışmada, öğrenme kuralı olarak geriye yayılım algoritması kullanılmıştır.

4. Geriye Yayılım Algoritması

Bu, YSA'da en çok kullanılan algoritmadır [12-14]. 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 bulunduğundan sonra, nöronlar kendi hatalarını azaltmak için ağırlıklarını ayarlar. Ağırlık değiştiren denklemler, ağdaki ortalama hata karesini en küçük yapacak şekilde düzenlenir. Bu öğrenme algoritmasına göre n. iterasyonda, j. nöronun çıkışındaki hata işareti, j. nöron çıkış katmanındaysa;

$$e_j(n) = d_j(n) - y_j(n) \quad (1)$$

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

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

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

Burada C kümesi, ağı çıkış katmanındaki bütün nöronları içeren bir kümedir. Hatayı en küçük değere indirmek için:

1. $\delta E / \delta w$ hesaplanır.

2. Ağırlıklar $w(n)$ 'den $w(n+1)$ 'e güncellenir.

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

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

Ağ ağırlıklarını güncellemek için (5) denklemi ile yazılan kurala delta kuralı denilmektedir. Bu eşitlikte, α momentum katsayısı, η ise öğrenme hızıdır. Yerel gradyen denilen δ_{ji} , j. nöronun çıkış katmanında veya gizli katmanda olmasına göre farklı hesaplanır. ϕ aktivasyon işlevini belirtmek üzere, eğer j. nöron çıkış katmanında ise;

$$\delta_{ji} = e_j(n) \phi'_j(v_j(n)) \quad (6)$$

bağıntısından, eğer j. nöron gizli katmanda ise;

$$\delta_{ji} = \phi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (7)$$

bağıntısından hesaplanır.

5. Genelleştirilmiş Regresyon Ağı

Genelleştirilmiş regresyon ağları (Generalized Regression Network - GRN), radyal tabanlı işlev ağlarının özel bir durumudur. Ağ yapısı bir radyal tabanlı katman ile özel bir doğrusal katmandan oluşmaktadır. Radyal tabanlı YSA'larda temel fikir, bir grup radyal tabanlı işlevi istenen işleve yaklaşacak şekilde ağırlıklandırarak toplamaktır. Genelleştirilmiş regresyon ağlarında ise radyal tabanlı işlev ağlarının merkez ve bant genişliklerinin eğitime verisinin deterministik işlevleri olarak belirlenir ve bu tip ağlarda eğitim için yinelemeli (iteratif) yöntemler kullanılmaz.

Birinci katman, normal bir radyal tabanlı YSA gibi işler. Her nöronun ağırlıklı girişi, giriş vektörü ile bu girişin ağırlık vektörü arasındaki uzaklıktır. Her nöronun net girişi, o nöronun ağırlıklı girişi ile biasının çarpımıyla belirlenir. Her nöronun çıkışı, o nöronun net girişinin radyal tabanlı katmandan geçirilmesiyle hesaplanır.

Genel regresyon ağlarında bir x_j girişi, ağdaki Gauss çekirdeklerinden birinin merkezi olarak atanır. Herhangi bir giriş vektörü x için i. radyal tabanlı biriminin çıkışı

$$\beta_i = \exp \left[- \frac{(x - x_i)^T (x - x_i)}{2\sigma^2} \right] \quad (8)$$

şeklinde hesaplanır. Burada σ kullanıcı tarafından belirlenen yumuşatma parametresidir. Herhangi bir x girişi için ağı çıkışı y

$$y = \sum_{i=1}^K \alpha_i y_i \quad (9)$$


şeklinde. Eşitlik (9)'da kullanılan α katsayıları aşağıda görüldüğü gibi hesaplanır:

$$\alpha_i = \frac{\beta_i}{\sum_{i=1}^K \beta_i} \quad (10)$$

Eğer giriş vektörü x , herhangi bir x_i eğitim vektörüne yakın ise x_i 'ye ilişkin α_i en büyük olacak ve istenen çıkış y , x_i 'ye ilişkin y_i çıkışına yaklaşacaktır.

6. Giriş Çıkış Verilerinin Elde Edilmesi

Bu çalışmada kullanılan gerilim verileri, uzun süren, zahmetli, özel donanım gerektiren deneysel çalışma ile elde edilmiştir [5]. Deneylerde, Şekil 2'de gösterilen 1 mm yarıçaplı yarı küresel uçlu çubuk elektrot ile 75 mm çapında disk şeklinde bir düzlem elektrottan oluşan bir elektrot sistemi kullanılmıştır. Deneyler, 5, 10, 15, 20 ve 25 mm elektrot açıklıklarında yapılmıştır. Elektrotlar, basınca dayanıklı, saydam bir deney kabına yerleştirilmiştir. Çubuk elektrot yüksek gerilim kaynağına bağlanmış, düzlem elektrot topraklanmıştır.



Şekil 2. Deney düzeni.


Deney kabı, deney yapılacak gaz doldurulmadan önce vakumlanmış ve daha sonra deney yapılacak basınca kadar gaz ile doldurulmuştur. Bu işlemten sonra ortamdaki gazın kararlı duruma gelmesi için beklenmiştir. 1 bar sabit basınç altında yapılan deneylerde SF_6+N_2 gaz karışımında SF_6 gazının %0; %0,125; %0,5; %1; %4; %10; %20 ve %100'lük oranlarında delinme gerilimi değerleri ölçülmüştür. 50 Hz frekanslı yüksek alternatif gerilim, 100 kV'luk bir deney transformatöründen elde edilmiştir. Delinme gerilimleri, bir kapasitif gerilim bölücü ve bir yüksek gerilim voltmetresi yardımıyla kVef cinsinden ölçülmüştür. Her bir delinme gerilimi değeri, 10 ölçmenin aritmetik ortalamasından belirlenmiştir. 8 farklı oranda SF_6 gazı kullanılarak, 5 farklı elektrot açıklığı için 10 hafta süren deneyler sonunda 40 adet veri elde edilebilmiştir. Deney verisini arttırmak uzun, yorucu ve pahalı bir çalışmayı gerektirmiştir.

7. Uygulama

Deneysel veri elde etmenin zorluğu nedeni ile, elde edilen sınırlı sayıdaki deney verisinden yararlanarak yapılmayan diğer durumlar için YSA ile veri üretilmesi düşünülmüştür.. Ağın eğitimi için oluşturulan eğitim kümesinde, elektrot açıklığı ve gaz karışımındaki SF_6 oranı giriş vektörünü; bu değerlerde ölçülen delinme gerilimi değerleri de çıkış vektörünü oluşturmaktadır. Bu şekilde, yapay sinir ağı, 4 giriş nöronu ve 2 çıkış nöronundan meydana gelmektedir.

Deney verileri ile eğitimin tamamlanmasından sonra, ağın güvenilirliğini sınamak amacıyla, eğitim kümesinden bir örüntü kullanılarak bir sınama kümesi oluşturulmuş ve gerçek çıkış ile yapay sinir ağının hesaplamış olduğu çıkış karşılaştırılarak, yöntemin hatası bulunmuştur. Çalışmada eğitim için toplam karesel hata (sum squared error, sse) ve ortalama karesel hata (mean squared error, mse), sınama için ise ortalama mutlak hata (mean absolute error, mae) kullanılmıştır.

Bu çalışmada eğitim için iki farklı algoritma kullanılarak elde edilen sonuçlar karşılaştırılmıştır. Geriye yayılım algoritmasıyla eğitilen ağ için gizli katmanında 30 nöron bulunan, bir gizli katmanlı, geriye yayılım algoritması kullanılan bir YSA tasarlanmıştır. Birinci katmanda sigmoid, ikinci katmanda doğrusal fonksiyon kullanılmıştır. 1000 iterasyon için yapılan çalışmalarda en uygun öğrenme hızı 0,1; momentum katsayısı 0,4 ve gizli katmandaki nöron sayısı 25 olarak belirlenmiştir. En uygun parametrelerle, eğitim hatası (ortalama karesel hata-mean squared error) % 0,2'den küçük olana kadar eğitime devam edilmiş ve öngörülen hataya 680 iterasyonda ulaşılmıştır (Şekil 3).



Şekil 3. Geriye yayılım algoritmasında hatanın iterasyon sayısı ile değişimi

Eğitim kümesinin dışından bir sınama kümesi ağı uygulandığında, test hatasının (ortalama mutlak hata-mean absolute error) % 0,25 olduğu görülmüştür.

Benzer çalışma genelleştirilmiş regresyon ağı için de gerçekleştirilmiştir. Bu algoritmada kullanılan σ yumuşatma parametresi için denemeler

yapılarak, en uygun sonuç 0,1285 değerinde elde edilmiştir. Bu ağ yapısı, eğitimde iterasyon kullanmadığı için sonuca çok daha hızlı şekilde ulaşmıştır. Aynı eğitim kümesiyle eğitilen ağ için, eğitim sonrasında uygulanan sınaama kümesinin hatası % 0,040 olarak hesaplanmıştır. Çok katmanlı YSA ile genelleştirilmiş regresyon YSA hataları arasındaki fark Tablo 1’de görülmektedir.

Tablo 1. Çok katmanlı YSA ile Genelleştirilmiş Regresyon Ağının sonuçlarının karşılaştırılması

YSA yapısı	Gerçek Değerler	YSA değerleri	SSE (%)	MAE (%)
Çok Katmanlı	8,7500	8,7285	7,800	0,200
Genel Regresyon	8,7500	8,7535	9,760	0,040

Bu bölümde açıklanan sonuçlardan görüleceği gibi, bu çalışmada delinme gerilimi YSA ile % 0,2’den küçük hatayla, oldukça hızlı şekilde belirlenebilmektedir.

Bu çalışmadaki YSA hesaplamaları, Matlab 6.5 Neural Network Toolbox kullanılarak yapılmıştır.

8. Sonuç

Bu çalışmada, farklı elektrot açıklıklarında, SF₆+N₂ gaz karışımında SF₆ gazının farklı oranlarında delinme gerilimleri, YSA ile belirlenmiştir. Burada 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. YSA, problemi hızlı çözüme ulaştırarak deneysel çalışmaların zaman alıcılığını gidermektedir.

Bu çalışmada iki farklı YSA yapısı tasarlanmıştır. Çok katmanlı ve genelleştirilmiş regresyon ağları yapıları, aynı eğitim kümesine uygulanarak, aralarındaki farklar gözlenmiştir. Geriye yayılım algoritmasının eğitim hatası, iteratif yapısından dolayı genelleştirilmiş regresyon ağlarından daha küçük olarak bulunmuştur. Sonuçlar, genelleştirilmiş regresyon ağlarının, geriye yayılım algoritmasındaki gibi iteratif bir sürece bağlı olmaması sebebiyle çok daha hızlı yanıt verdiğini göstermektedir. Bununla birlikte, geriye yayılım algoritması ilk koşullara ve eğitim parametrelerine çok duyarlı olduğu için, her probleme tutarlı sonuç vermeyebilir. Genelleştirilmiş regresyon ağları ise, pek çok probleme kolayca uygulanabilen bir ağ yapısıdır. Uygulanan problem için bu ağ yapısı, test hatası çok küçük olacak şekilde çok hızlı sonuç vermiştir.

Kaynaklar

- [1] L. G. Christophorou and R. J. Van Brunt, "SF₆/N₂ mixtures: Basic and HV insulation properties", IEEE Trans. on Dielectrics and Electr. Insulation, Vol. 2, pp. 952-995, 1995.
- [2] Qiu, Y., Xiao, D. M., "Dielectric strength of the SF₆+CO₂ gas mixture in different electric fields", Ninth Int. Symp on High Voltage Engineering, Graz, Paper 2255, 1995.
- [3] Chalmers, L. D., Qiu, X. Q., Coventry, P., "The Study of SF₆ Mixtures with Buffer Gases", Gaseous Dielectrics VIII, pp. 189-195, 1998.
- [4] Farsadi, M., Kalenderli, Ö., "Breakdown and corona inception voltages in non-uniform fields with compressed SF₆, N₂ and SF₆+N₂ gas mixtures", MedPower'02, Mediterranean Conf. on Power Sys., Athens, Paper MED02/111, 2002.
- [5] Önal, E., Kalenderli, Ö., Mardikyan, K., "Breakdown characteristics of CO₂ and N₂ containing SF₆ at different gap spacings", IEEE PowerTech'99 Conference, Budapest, pp. 203-206, Aug. 1999.
- [6] Önal, E., Kalenderli, Ö., Mardikyan, K., "Breakdown characteristics of CO₂ containing 0.125% of SF₆", Int. Symp. on High Voltage Engineering (ISH), London, Vol. 3, pp. 301-304, Aug. 1999.
- [7] Önal, E., Kalenderli, Ö., Mardikyan, K., "Breakdown characteristics of air containing 0.125% of SF₆ at different gap spacings", GD 2000, Int. Conf. on Gas Discharges and Their Appl., Glasgow, pp. 367-369, 2000.
- [8] H. Saitoh, K. Morita, T. Kikkawa, N. Hayakawa and H. Okubo, "Impulse partial discharge and breakdown characteristics of rod-plane gaps in N₂/SF₆ gas mixtures", IEEE Trans. on Dielectrics and Electr. Insul., Vol. 9, No.4, pp. 544-550, 2002.
- [9] N. Hayakawa, J. Deng and H. Okubo, "Impulse partial discharge and breakdown characteristics under non-uniform electric field in CO₂ and N₂/CO₂ gas mixtures", Int. Symp. on High Voltage Eng. (ISH'03), Delft, Aug. 2003.
- [10] Farsadi, M., Kalenderli, Ö., "Effect of macroscopic electrode surface roughness on breakdown and corona inception voltages in SF₆+N₂ gas mixtures", Eleco 2003 Int. Conf. on Electrical and Electronics Eng., Bursa, pp. 222-225, Dec. 2003.
- [11] Haykin, S., "Neural Networks a Comprehensive Foundation", Prentice Hall, N. J., 1999.
- [12] Önal, E., Kalenderli, Ö., Şeker, S., Ayaz, E., "A study on breakdown voltage estimation of CO₂+SF₆ mixture using feedforward neural network approach", Eleco '99 Int. Conf. on Electr. and Electro. Eng., Bursa, pp. 131-134, Dec. 1999.
- [13] Önal, E., Şeker, S., Kalenderli, Ö., Mardikyan, K., "The breakdown voltage estimation of SF₆+N₂ mixture using neural network approach", IEE Int. Conf. on Dielectric Materials, Measurements and Appl., Edinburg, pp. 166-169, 2000.
- [14] Bolat, S., Kalenderli, Ö., "Electrode optimization by artificial neural network based on Levenberg-Marquardt algorithm", TAINN'03, Int. Twelfth Turkish Symp. on Artificial Intelligence and Neural Networks, Çanakkale, July 2003.