

Genetik Algoritma Kullanan Yapay Sinir Ağları ile İkili Gaz Karışımlarının Sınıflandırılması

*¹ M. Fatih Adak, Kadriye Canpolat, Nejat Yumusak

*¹ Department of Computer Engineering, Sakarya University, Sakarya, Turkey

Özet

İkili gaz karışımları ile elde edilen solvent yapısındaki gazların sanayi ortamında kullanılması ve farklı oranlardaki bu karışımların insan üzerinde farklı etki oluşturması, yapılacak bir sınıflandırma çalışmasının, insan üzerinde oluşacak etkinin düzeyini de belirlemesi açısından önemlidir. Dolayısıyla bu çalışmada ikili gaz karışımlarının başarılı bir şekilde sınıflandırılması için yapay sinir ağının eğitim aşaması Genetik algoritma yardımıyla optimize edilmiştir. Yedi farklı ağ tasarımı yapılarak yapılan birçok test, yapay sinir ağının genetik algoritma ile eğitilmesinin geleneksel yöntem olan geri yayılım (BP) ile eğitilmesine göre çok daha başarılı sonuçlar verdiği görülmüştür.

Anahtar kelimeler: gas sensörü, YSA, Genetik algoritma, sınıflandırma

Artificial Neural Network Using Genetic Algorithm to Classify Binary Gas Mixtures

Abstract

Binary gas mixtures are used as solvents in a large number of industries. Different gas concentrations within these solvents create different effects on human body. Classification of individual gas components in a solvent is important to determine the level of the effect caused by a specific solvent. In this study, the proposed hybrid algorithm uses an artificial neural network trained by Genetic Algorithm. It is used in order to successfully classify binary gas mixtures. Several tests are conducted using seven different network designs, and it is observed that training by Genetic Algorithm gives much more successful results than the traditional Back Propagation Algorithm.

Key words: gas sensor, ANN, Genetic algorithm, classification

1. Giriş

Sanayi endüstrisinde solvent olarak kullanılan uçucu gazlar, insan üzerinde olumsuz etkiler bıraktığı bilinmektedir [1]. Bu gazların belli oranlardaki ikili karışımlarının sınıflandırılması, olumsuz etkilerin büyüklüğünü tespit açısından önemlidir. Bu gazlardan metanol ve aseton'un kloroform ile belli oranlardaki ikili karışımları yapılmış ve laboratuvar ortamında gaz sensörleri yardımıyla bu karışımların verileri elde edilmiştir. Verilerin sınıflandırılması için, gaz sensörleri çalışmalarında sıklıkla kullanılan yapay sinir ağı kullanılmıştır.

Yapay sinir ağında (YSA), geleneksel yöntem olarak geri yayılım algoritması (BP) kullanılır. Fakat bu yöntemin test performansında ve global minimum erişimde yetersiz olduğu bilinmektedir [2]. Bundan dolayı eğitim aşaması, hybrid algoritmalarda sıklıkla kullanılan Genetic algoritma (GA) yardımıyla gerçekleştirilmiştir. Bu konuda aynı fikirde olan benzer çalışmalar yapılmıştır [3], [4]. Yine benzer, fakat çalışmada farklılıklar bulunan Baklacioglu'nun çalışmasında YSA, BP ile eğitimi sağlanmış, eğitim sonucunda sonlanma kriteri sağlanmadıysa GA çalıştırılıp yeni ağırlık değerleri belirlenmiştir [5]. Gizli katmanda kaç adet nöron bulunması gerektiğini belirlemek için GA kullanılmış, eğitim ve test işleminin süresi geleneksel yöntemle göre iyileştirilmiştir [6]. Yine buna benzer bir çalışmada Zaji ve arkadaşları, çalışmalarında iki gizli katman kullanmışlardır. Gizli katmandaki nöron sayısı ve aktivasyon fonksiyonunu genetic algoritmayı temel alan Genetic programlama ile bulmuşlardır [7]. GA ile YSA'yı ayrı ayrı kullanıp ortak bir model kuran Ghanim ve Abu-Lebdeh, bu modeli gerçek zamanlı trafik işaretleri control sisteminde kullanmışlardır. GA'yı optimum en yakın sinyal zamanını, YSA'yı ise bu optimizasyon değerlerini korumada kullanmışlardır [8]. GA ve YSA'yı ayrı ayrı çalıştıran diğer bir çalışmada da başarılı sonuçlar elde edilmiştir [9]. Bu önerilen çalışmada hata tespit için MSE (Mean Squared Error) kullanılmıştır. Fakat MAPE (Mean Absolute Percentage Error)'nin kullanıldığı ve YSA-GA yaklaşımını içeren çalışmada bulunmaktadır [10]. Kromozomların sadece girdi ve çıktılardan oluşan YSA-GA hibrid çalışmasında başarılı sonuçlar alınmıştır [11]. Gulbag ve arkadaşlarının ikili gaz karışımları üzerine yaptıkları çalışmada probabilistic neural networks (PNNs) ve geleneksel YSA kullanarak sınıflandırma yapılmış test verisi üzerinde PNN'nin 100%'e yakın bir başarı sağladığı görülmüştür [12].

Sensör verileri üzerinde GA uygulanıp başarılı sonuçlar alındığı birçok çalışmada bulunmaktadır. Örneğin Kim ve arkadaşları, buzdolabındaki yiyeceklerin çürüme derecesinin tespiti için sekiz gaz sensörü kullanarak elde ettikleri veri üzerinde genetic yapay sinir ağını (GANN) çalıştırarak başarılı sonuçlar elde etmişlerdir [13]. Yine gaz sensörleri üzerinde yapılan çalışmada yapay sinir ağının ağırlıkları GA tarafından optimize edilerek belirlenmiş ve BP'ye göre çok düşük hata oranı elde edilmiştir [14], [15]. GA elektronik burun yardımıyla çaydan elde edilen sensor verisi üzerinde de başarılı olduğu görülmüştür [16]. GA'nın YSA ile değil de Parallel Coordinate Descent (PCD) ile kullanılmış ve çok iyi MSE grafiği elde edilmiştir [17].

İncelenen bu çalışmalardan anlaşıldığı üzere Yapay sinir ağı veya Genetik algoritma tek başına sensor verisi üzerinde çok başarılı sonuçlar verememekle birlikte zayıf yönleri bulunmaktadır [2]. Bu çalışmada gaz sensörlerinden elde edilen ikili gaz karışımlarından en üst düzeyde performans alabilmek için yapay sinir ağı genetic algoritma ile eğitilmiştir. Çalışmanın geri kalan kısmı şu şekilde organize edilmiştir. YSA ve GA çalışma şekli ve YSA'nın GA ile nasıl eğitildiği II. bölümde, gaz sensor verisinin nasıl modellendiği III. bölümde, yapılan senaryolar ve alınan sonuçlar IV. bölümde açıklanmış ve çalışmanın sonuçları V. bölümde verilmiştir.

2. Metot

2.1. Yapay Sinir Ağları (YSA)

Beynin çalışmasını örnek alan ve birçok sınıflandırma ve kümeleme yöntemlerinde kullanılan yapay sinir ağları, katmanlar, katmanları oluşturan nöronlar ve nöronların birbirine ağırlıklar ile ifade edilen bağlarla bağlanması ile oluşur. Öğrenme aşamasında geleneksel yöntem olarak geri

yayılım (BP) algoritması kullanılır [18]. Bu algoritma ağda ileri besleme ile oluşan mse hata değerini, ağda geri hareket ederek bütün nöronlara iletir ve hata oranına göre ağırlıklar güncellenir. Bu şekilde çalışma ile belli bir epoch sayısından sonra hata minimize edilmiş olur. Bu çalışmada aktivasyon fonksiyonu olarak Sigmoid kullanıldığı için girdi değerlerinin [0,1] arasında olması gerekmektedir. Bundan dolayı veri setine min-max normalizasyonu uygulanmıştır (Denklem 1).

$$y_{i0-1} = \frac{y_i - y_{\min}}{y_{\max} - y_{\min}} \quad (1)$$

2.2. Genetik Algoritma (GA)

Genetik algoritma, gerçek hayattaki doğal seçim mekanizması ve gen yapılarını örnek alan çaprazlama ve mutasyon içeren sezgisel arama algoritmasıdır [19]. Her bir iterasyonda çaprazlama sonucu oluşan yeni güçlü bireyler bir sonraki nesillere aktarılır. Bu çalışmada çaprazlama tekniği olarak tek noktalı çaprazlama kullanılmıştır. Populasyonda bulunan kromozomlardan en iyi bir veya iki tanesi (elitist seçim) hiç çaprazlamaya girmeden bir sonraki nesle aktarılır. Diğer kromozomlar çaprazlamaya girerek yeni bireyleri oluşturur. Bütün bireyler arasından, populasyon sayısı kadar en iyi kromozomlar seçilip bir sonraki nesle aktarılır.

2.3. YSA'nın GA Tabanlı Eğitilmesi

Sezgisel algoritmalar, yapay sinir ağının eğitilmesi (local minimum takılma) gibi kompleks optimizasyon problemlerin çözümünde oldukça başarılıdır [20]. Bu çalışmada yapay sinir ağının, ağırlık ve eşik değerleri, genetic algoritmada kromozomları oluşturmuş ve yapılan çaprazlama ve mutasyon işlemlerinden sonra optimum ağırlık ve eşik değerleri bulunmuştur. GA'nın aktivasyon fonksiyonunda her bir kromozomun gen değerleri ağ üzerine yerleştirilerek, ağda ileri besleme yapılır (Denklem 2).

$$y_i = f\left(\sum w_{ji}x_j\right) \quad (2)$$

İleri beslemenin sonucunda oluşan hata (MSE) aktivasyon fonksiyonunun döndürdüğü değer olacaktır (Denklem 3 ve 4). Buradaki amaç her iterasyonda MSE değerini aşağı çekerek sifıra yaklaştırmaktır.


$$E = \frac{1}{2} \sum (y_{d_j} - y_j)^2 \quad (3)$$

$$MSE = \frac{E}{Train Data Set} \quad (4)$$

3. Model

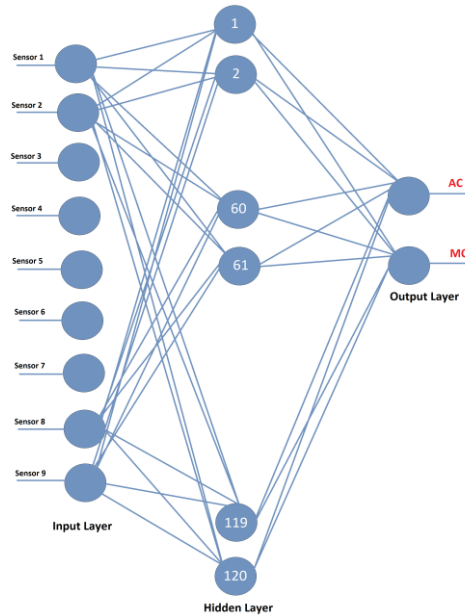
Solvent yapımında sıklıkla kullanılan metanol, aseton ve kloroform gazlarının ikili karışım verileri gaz sensörleri yardımıyla elde edilmiştir. İkili gaz karışım oranlarında kloroform sabit tutularak

acetone ve methanol belli oranlarda arttırılmıştır. Karışım oranları Şekil 1’de gösterildiği gibi, kloroform sabit tutularak her ölçümde diğer iki gazdan (aseton, metanol) biri 1000 ppm’den başlayarak 6000 ppm’e kadar 1000’er ppm arttırılmıştır. Cam tüpün içinde -15 C dercede konulan ikili gaz karışımları, herbir karışım oranında ölçüm 200 saniye sürmüştür. 100 saniyelik sürede gaz karışımı sensörlere verilirken, diğer 100 saniyelik sürede saf hava ile sensörler temizlenmiştir.

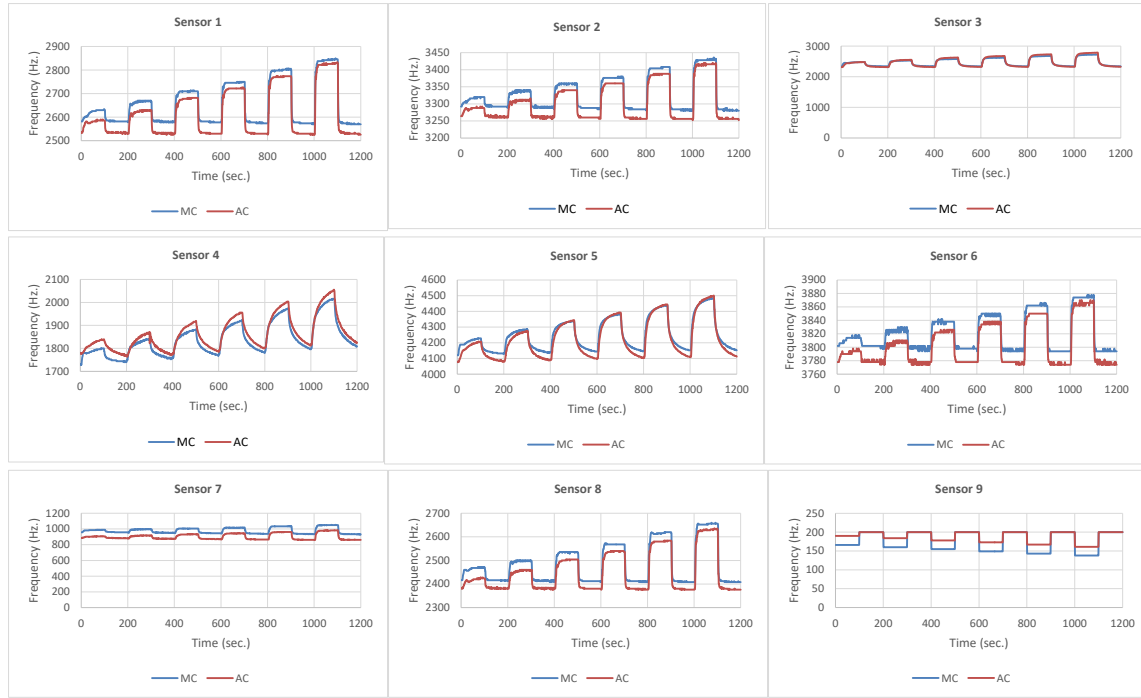


Şekil 1. İkili gazların karışım oranları

Kullanılan sensör dizisi 9 adet QCM sensörden oluşmaktadır. Sensörlerden, dördüncü sensörün kaplama frekansı 23 KHz, diğer sensörler 22 KHz’dir. Altı farklı karışım oranı kullanıldığı için toplam ölçüm alma süresi 1200 saniye sürmüştür. 9 adet sensörün karışımlara verdikleri tepki Şekil 3’te verilmiştir.



Şekil 2. Çalışmada kullanılan YSA’nın yapısı



Şekil 3. Sensörlerin MC ve AC ikili gaz karışımlarına verdikleri tepki

Chloroform'un sabit tutulup, acetone'nun arttırıldığı ikili gaz karışımından elde edilen verinin sınıf adına AC, Chloroform'un sabit tutulup, methanol'un arttırıldığı ikili gaz karışımından elde edilen verinin sınıf adına ise MC denilmiştir. Dokuz adet sensör bulunduğu için tasarlanan yapay sinir ağında dokuz adet girdi bulunmaktadır. Yedi farklı YSA yapısı tasarlanmış olup en iyi sonucun alındığı yapı Şekil 2'de verilmiştir. Bu yapıda bir girdi, bir gizli bir de çıktı katmanı bulunmaktadır. Gizli katmanda 120 adet nöron vardır. Çıktı katmanında iki adet sınıf (AC, MC) olduğundan iki adet çıktı bulunmaktadır. Gelen verinin hangi sınıftan olduğu ilgili çıktının 1, diğer çıktının 0 değerini alması ile belirlenir.

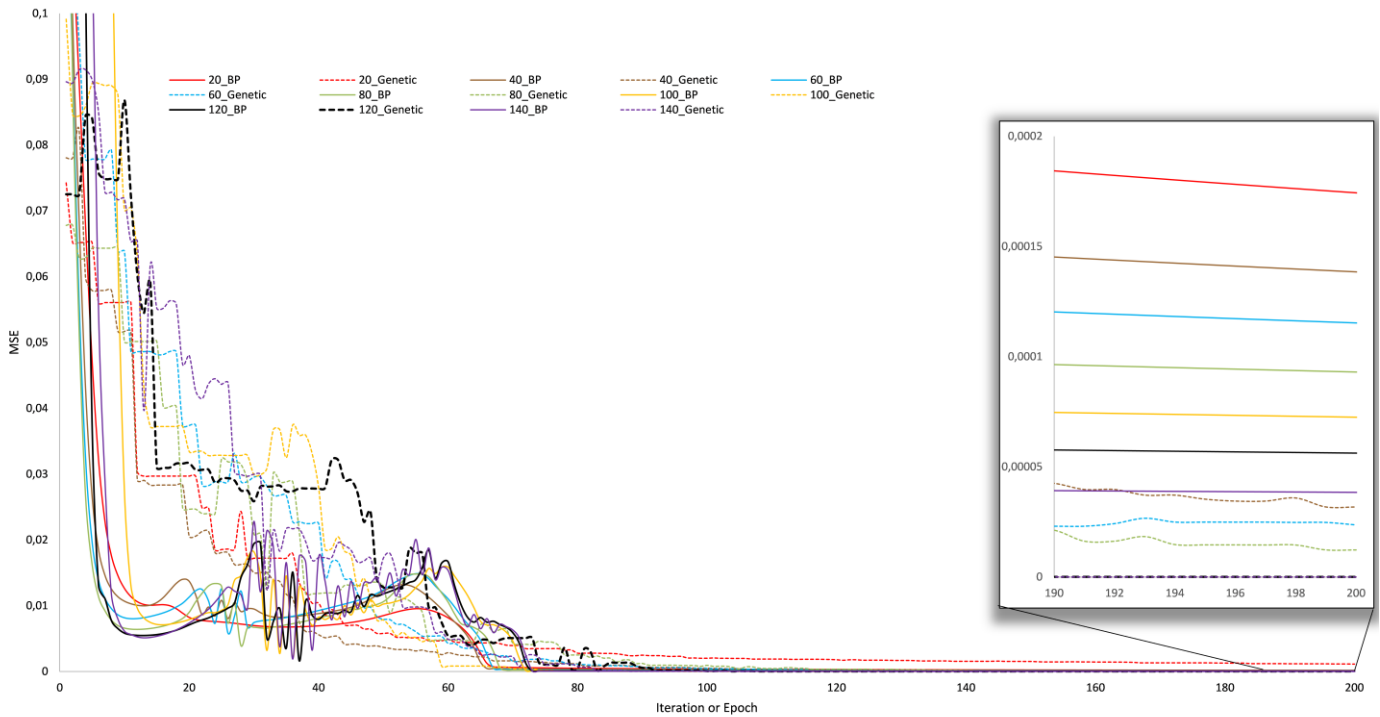
4. Senaryo ve Bulgular

İkili gaz karışımlarından elde edilen veri seti %75 eğitim, %25 test olmak üzere ikiye bölünmüştür. Aynı eğitim veri setleri kullanılarak YSA-BP ve YSA-Genetic ağları kendi yöntemleri ile eğitilmiş ve test sonuçları elde edilmiştir. YSA-BP ve YSA-Genetic'te kullanılan parametreler Tablo 1'de verilmiştir.

Tablo 1. YSA ve Genetik algoritmalarının parametreleri

YSA		Genetic	
Learning rate	0.2	Mutate rate	0.001
Momentum	0.8	Crossover rate	0.85
Epoch	500	Gen range	[-10,10]
Weight range	[-1,1]	Population size	1000
Thres. range	[-1,1]	Iteration	200

Yapılan çalışmada yedi farklı ağ yapısı test edilmiş, Ağ yapılarında gizli katmandaki nöron sayısı 20'den başlayarak, 140'a kadar 20'şer arttırılarak testler uygulanmıştır. YSA-BP 500 epoch çalıştırılmış, YSA-Genetic'te ise 200 iterasyon uygulanmıştır. Tablo 2'den de görüldüğü üzere 140'tan sonra MSE değerleri artmaya başlamıştır. Bundan dolayı 140'tan sonra yeni bir ağ yapısı denenmemiştir. BP için en iyi test sonucu 20 ve 100 nöron sayılı ağlarda elde edilmiştir. Genetik ile eğitilen YSA'da en iyi sonuç 120 nörona sahip gizli katmanlı ağda elde edilmiştir. YSA-Genetic için 120 nöronda elde edilen test sonucu MSE değeri YSA-BP'nin hiçbir senaryosunda erişilememiştir. Yedi farklı senaryonun eğitim aşamasında verdikleri MSE değerleri Şekil 5'te verilmiştir. En iyi senaryo olan 120 nörona sahip gizli katmanlı ağ yapısı koyu siyah çizgili bir şekilde gösterilmiş ve ulaşılan min MSE değeri $2,25E-09$ olmuştur. Bu başarıyı test verisinde de gösterip AC için $2,91E-09$ ve MC için $2,46E-08$ MSE değerleri elde edilmiştir.



Şekil 5. Sensörlerin MC ve AC ikili gaz karışımlarına verdikleri tepki


Hangi çizginin hangi senaryoya ait olduğu gizli katmandaki nöron sayısını ifade eden başındaki sayı ile verilmiştir. Şekil 5'te eğitim aşamasındaki MSE değerleri incelendiğinde diğer hiçbir MSE değerinin en iyi senaryoyu geçemediği görülmüştür. Şekil 5'te x ekseninde gösterilen değerler BP için epoch iken, Genetik için iterasyon olmaktadır. BP'de epoch sayısı 500 olmasına rağmen 200'e kadar gösterilmesinin sebebi asıl önemli karşılaştırma bölgesinin bu kısım olmasıdır. Geri kalan kısımda neredeyse değişmeyen bir grafik görülmektedir. Şekil 5'te zoom yapılan yerde 190-200 arası gösterilmiş en düşük MSE değerinin 120 nörona sahip olan ve GA ile eğitilen ağa ait olduğu vurgulanmıştır.

Herbir test verisine karşılık YSA-BP'nin ve YSA-Genetic'in üretmiş oldukları çıktı Şekil 6'da AC ve MC için ayrı bir şekilde verilmiştir. Mavi renk ile gösterilen gerçek çıktı olup, yeşil ile ifade edilen YSA-Genetic, kırmızı ile ifade edilen YSA-BP'dir. YSA-Genetic'in ürettikleri çıktı

neredeysse gerçek çıktı ile %100'e varan bir oranda örtüşmektedir.

Tablo 2. Test verisi hata performans değerleri

Modeller	MSE YSA-BP		MSE YSA-Genetic	
	AC	MC	AC	MC
Nöron Sayıları				
20	6,26E-05	5,87E-05	1,66E-02	2,68E-03
40	7,87E-05	7,84E-05	3,81E-02	4,33E-03
60	1,15E-04	9,69E-05	2,92E-04	2,80E-02
80	7,81E-05	7,67E-05	6,74E-06	1,22E-03
100	6,14E-05	9,33E-05	1,03E-05	2,94E-05
120	7,61E-05	6,17E-05	2,91E-09	2,46E-08
140	6,27E-05	5,95E-05	1,01E-07	7,80E-06



Şekil 6. Test sonuçlarının karşılaştırılması

Sonuçlar

Çalışmada 9 adet QCM gaz sensöründen oluşan sensör dizisine, AC ve MC ikili gaz karışımları verilmiş ve veriler toplanıp veri seti oluşturulmuştur. Bu veri seti eğitim ve test veri seti olarak rastgele ayrılmıştır. Eğitim veri seti BP ile eğitilen ve GA ile eğitilen ağlara verilerek ağların eğitimi sağlanmıştır. Bu ağlara daha önceden hiç görmedikleri test verisi verilerek test performansları ölçülmüştür. Yedi farklı senaryo ile tekrarlanan eğitim ve testler GA ile eğitilen YSA'ların BP ile eğitilen YSA'lara göre çok daha başarılı olduğu görülmüştür. Alınan bu başarılı sonuçlar solvent yapımında kullanılan bu tehlikeli gazların farklı ikili karışım oranlarının gaz sensörü ve YSA-Genetic kullanarak başarılı bir şekilde sınıflandırabileceğini ve tehlike düzeyi hakkında faydalı bilgi verebileceğini göstermiştir.

Teşekkür

TÜBİTAK'ta yapılan gaz ölçümlerinde yardımlarını esirgemeyen Dr. Cihat Taştaltın'a teşekkür ederiz.

Referanslar

- [1] M. H. Ho, G. G. Guilbault, and B. Rietz, "Continuous detection of toluene in ambient air with a coated piezoelectric crystal," *Anal. Chem.*, vol. 52, no. 9, pp. 1489–1492, Aug. 1980.
- [2] C. M. Bishop, *Pattern Recognition and Machine Learning*, 1st ed. Singapore: Springer India, 2006.
- [3] R. Mahajan and G. Kaur, "Neural Networks using Genetic Algorithms," *Int. J. Comput. Appl.*, vol. 77, no. 14, pp. 6–11, Sep. 2013.
- [4] D. Chen, R. Lu, F. Zou, and S. Li, "Teaching-learning-based optimization with variable-population scheme and its application for ANN and global optimization," *Neurocomputing*, vol. 173, pp. 1096–1111, Jan. 2016.
- [5] T. Baklacioglu, "Modeling the fuel flow-rate of transport aircraft during flight phases using genetic algorithm-optimized neural networks," *Aerosp. Sci. Technol.*, vol. 49, pp. 52–62, Feb. 2016.
- [6] K. S. Sajan, B. Tyagi, and V. Kumar, "Genetic algorithm based artificial neural network model for voltage stability monitoring," in *18th National Power Systems Conference, NPSC, 2014*, pp. 1–5.
- [7] A. H. Zaji and H. Bonakdari, "Application of artificial neural network and genetic programming models for estimating the longitudinal velocity field in open channel junctions," *Flow Meas. Instrum.*, vol. 41, pp. 81–89, Mar. 2015.
- [8] M. S. Ghanim and G. Abu-Lebdeh, "Real-Time Dynamic Transit Signal Priority Optimization for Coordinated Traffic Networks Using Genetic Algorithms and Artificial Neural Networks," *J. Intell. Transp. Syst.*, vol. 19, no. 4, pp. 327–338, Oct. 2015.
- [9] A. Mellit, "ANN-based GA for generating the sizing curve of stand-alone photovoltaic systems," *Adv. Eng. Softw.*, vol. 41, no. 5, pp. 687–693, May 2010.
- [10] A. Azadeh, H. S. Mianaei, S. M. Asadzadeh, M. Saberi, and M. Sheikhalishahi, "A flexible ANN-GA-multivariate algorithm for assessment and optimization of machinery productivity in complex production units," *J. Manuf. Syst.*, vol. 35, pp. 46–75, Apr. 2015.
- [11] Jin Ma, Bing-Shu Wang, and Yong-Guang Ma, "ANN-based real-time parameter optimization via GA for superheater model in power plant simulator," in *2008 International Conference on Machine Learning and Cybernetics, 2008*, pp. 2269–2273.
- [12] A. Gulbag, F. Temurtas, and I. Yusubov, "Quantitative discrimination of the binary gas mixtures using a combinational structure of the probabilistic and multilayer neural networks," *Sensors Actuators B Chem.*, vol. 131, no. 1, pp. 196–204, Apr. 2008.

- [13] E. Kim, J. H. Lee, B. J. Shin, S. Lee, Y. T. Byun, J. H. Kim, H. S. Kim, and T. Lee, "An Odor Monitoring System Based on Differentiated Pattern Recognition Implemented a Semiconductor Gas Sensor Array," *Adv. Sci. Lett.*, vol. 19, no. 10, pp. 2901–2904, Oct. 2013.
- [14] H. Li, D. Wang, and Y. Zhang, "Knowledge-based genetic algorithms data fusion and its application in mine mixed-gas detection," *J. Softw.*, vol. 7, no. 2, pp. 303–307, Feb. 2012.
- [15] A. Nezhadali and S. Sadeghzadeh, "Optimization of stripping voltammetric sensor by mixture design-artificial neural network-genetic algorithm for determination of trace copper(II) based on iodoquinol-carbon nanotube modified carbon paste electrode," *Sensors Actuators B Chem.*, vol. 224, pp. 134–142, Mar. 2016.
- [16] B. Shi, L. Zhao, R. Zhi, and X. Xi, "Optimization of electronic nose sensor array by genetic algorithms in Xihu-Longjing Tea quality analysis," *Math. Comput. Model.*, vol. 58, no. 3–4, pp. 752–758, Aug. 2013.
- [17] S. U. Khan, I. M. Qureshi, A. Naveed, B. Shoaib, and A. Basit, "Detection of Defective Sensors in Phased Array Using Compressed Sensing and Hybrid Genetic Algorithm," *J. Sensors*, vol. 2016, pp. 1–8, 2016.
- [18] S. Haykin, *Neural Networks: A Comprehensive Foundation*, 2nd ed. Prentice Hall PTR, 1999.
- [19] D. E. Goldberg and J. H. Holland, "Genetic Algorithms and Machine Learning," *Mach. Learn.*, vol. 3, no. 2/3, pp. 95–99, 1988.
- [20] E. Alba and R. Marti, *Metaheuristic Procedures for Training Neural Networks*, 1st ed., vol. 36. Boston, MA: Springer US, 2006.