

Classification of Alcohol and Carbon Monoxide using Gas Sensors by Heuristic Algorithm based Neural Network

*¹M. Fatih ADAK and ¹Nejat YUMUSAK

*¹Faculty of Computer and Information Sciences, Department of Computer Engineering, Sakarya University, Turkey

Abstract

The classification of electronic noses data and odors is an issue that needs to be taken to a higher level in industry, science and health. Because of Industry 4.0 and the Internet of Things is today's popular subject, it reinforces this proposal. In this study, the classification of alcohol and carbon monoxide gases which can be used frequently in industry and health fields has been classified. In order for the classification to be successful, neural networks were trained by the help of heuristic algorithms and more successful results than traditional methods have gained. Neural networks, especially trained with the Ant Colony algorithm, have achieved the best classification success in both training and test data. These results show that neural networks trained with Ant Colony algorithm will give successful results in classification of gases such as alcohol and carbon monoxide.

Key words: heuristic algorithms, neural networks, odor classification, gas sensors

Gaz Sensörlerinden Elde Edilen Alkol ve Karbon monoksit Verisinin Sezgisel Algoritmalar Tabanlı Sinirsel Ağlar ile Sınıflandırılması

Özet

Elektronik burun verisi ve kokuların sınıflandırılması sanayi, bilim ve sağlık alanlarında ihtiyaç duyulan ve daha ileri seviyeye götürülmesi gereken bir konudur. Endüstri 4.0 ve nesnelerin interneti günümüzün popüler konusu olması bu öneriyi güçlendirmektedir. Bu çalışmada sanayi ve sağlık alanlarında sıklıkla kullanılabilen alkol ve karbonmonoksit gazlarının sınıflandırılması yapılmıştır. Sınıflandırmanın başarılı olabilmesi için sinirsel ağlar, sezgisel algoritmalar yardımıyla eğitilmiş ve geleneksel yöntemlere göre daha başarılı sonuçlar elde edilmiştir. Özellikle Karınca Koloni algoritması ile eğitim yapılan sinirsel ağlar hem eğitim hem de test verisinde en iyi sınıflandırma başarısını sağlamıştır. Elde edilen bu sonuçlar alkol ve karbonmonoksit gibi gazların sınıflandırılmasında Karınca Koloni algoritması ile eğitilen sinirsel ağların başarılı sonuçlar vereceğini göstermiştir.

Anahtar kelimeler: sezgisel algoritmalar, sinirsel ağlar, koku sınıflandırması, gaz sensörleri

1. Giriş

Nesnelerin interneti alanında son zamanlarda yaşanan büyük gelişmeler, hayatı kolaylaştırma anlamında büyük faydalar sağlamıştır. Burada her alanda kullanılan çeşitli birçok sensörün katkısı göz ardı edilemez.


*Corresponding author: Address: Faculty of Computer and Information Sciences, Department of Computer Engineering, Sakarya University, 54187, Sakarya TURKEY. E-mail address: fatihadak@sakarya.edu.tr

Bu sensörlerden gaz sensörleri ve özellikle elektronik burunların kullanımı oldukça yaygındır [1]. Örneğin sağlık alanında, yiyecek kalitesinin belirlenmesinde, çevresel çalışmalarda ve savunma sanayinde uygulamalarını görmek mümkündür [2], [3]. Bu çalışmada birbirine benzer özellikler içeren ve sınıflandırma aşamasında zorluklar yaşanabilecek iki farklı gaz, alkol ve karbon monoksit sınıflandırılmıştır. Buna benzer çalışmalara literatürde rastlamak mümkündür. Örneğin kemometrik bir yaklaşım kullanan Versari, şarap kalitesini analiz etmiştir [4]. Diğer bir çalışmada biranın sınıflandırılması veri madenciliği kullanılarak yapılmıştır [5]. Yine Murugan ve ark. çalışmasında alkol karakteristiğinin analizinde elektronik burun kullanıldığı görülmektedir [6]. Polipirol tabanlı elektronik burun, karbon monoksit ve benzeri gazların sınıflandırılmasında kullanılmıştır [7]. Gaz sınıflandırılmasında yapay sinir ağlarının (YSA) sıklıkla ve başarıyla kullanıldığı literatürden görülmektedir [8]–[13]. Fakat geleneksel YSA'nın test performansının düşük olduğu bundan dolayı Hibrit yaklaşımların kullanıldığı bilinmektedir [14]. Örneğin Sunny ve ark. Aseton ve 2-propanol'dan oluşan ikili gaz karışımlarını YSA ve destek vektör makinesi (SVM) kullanarak 94.7%'lik bir performans ile sınıflandırmışlardır [15]. İkili gaz karışımlarının istatistiksel yöntemlerle de başarı ile yoğunluk tespiti yapılabilmektedir [16]–[20]. Saraoglu ve ark. Radyal temelli ANN ile kandaki glikoz miktarını ölçmüşlerdir [13]. Benzer çalışmalara ikili gaz karışımlarının sınıflandırılmasında da rastlanmıştır [21]. Yine gaz sensörleri alanında Yapay arı koloni algoritması (ABC)'nin, YSA ile başarılı bir şekilde kullanıldığı görülmektedir [1], [22]. Genetik algoritmanın, gaz sınıflandırılmasında YSA ile birlikte kullanıldığı çalışmalar bulunmaktadır. Örneğin Kim ve ark. çalışmasında seçici koku tespitinde sinirsel genetik sınıflandırma algoritması kullanılmış ve 95%'e varan bir başarı elde edilmiştir [23]. Röggar gazı bileşenlerinin tespiti için sinirsel ağları karınca koloni algoritması (ACO) ile birlikte kullanmışlar ve başarılı sonuçlar elde etmişlerdir [24]. Kapalı alan hava kalitesinin belirlenmesinde Chaos based sinirsel ağlar ile parçacık sürü optimizasyon (PSO) karşılaştırılmış ve Chaos tabanlı sinirsel ağların daha başarılı olduğu görülmüştür [25]. Bu çalışmalar ışığında, alkol ve karbon monoksit gazları YSA'nın, GA, ABC, ACO ve PSO algoritmalarının her biri ile ayrı ayrı Hibrit kullanılarak sınıflandırma yapılmış ve performansları karşılaştırılmıştır. Bu çalışma şu şekilde organize edilmiştir; Bölüm 2'de gaz ölçüm sistemi anlatılmış gaz verisinin nasıl elde edildiğinde bahsedilmiştir. Bölüm 3'te tasarlanan metot ve materyallerden bahsedilmiştir. Bölüm 4'te elde edilen bulgular ve hangi algoritmanın nerede daha başarılı olduğu belirtilmiştir. Çalışmanın sonuçları son bölümde verilmiştir.

2. Gaz Ölçüm Sistemi

Bu çalışmada Karbon monoksit ve Alkol verisinden gaz ensörleri yardımıyla elde edilen veri bir veri seti oluşturulmuş ve Hibrit algoritmalar ile sınıflandırma yapılmıştır. İki farklı gas sensörü bir sensör dizisi olarak kullanılmıştır. Kullanılan gaz sensörleri MQ-9 karbon monoksit ve yanıcı gaz sensörü ile MQ-3 alkol ethanol gas sensörü, Raspberry pi yardımıyla devre kurulmuş ve ölçüm işlemi gerçekleştirilmiştir. Kurulan devre Şekil 1.'de verilmiştir.


Her ölçüm işlemi 10 kez tekrarlanmış olup, ölçümün gerçekleştirilme şekli, bir dakika örnek gazı sensörlere vererek, beş dakika ise sensörlerin temizlenmesi için sade hava vererek olmuştur. Gaz sensörlerinin alkol ve karbon monoksit örneklerine verdikleri tepki Şekil 2.'de verilmiştir.



Şekil 1. Gas ölçümü için kurulan devre

3. Materyal ve Metot

ANN'nin eğitim kısmı sezgisel bir algoritma ile optimize edildiğinde daha iyi sonuçlar verdiği bilinmektedir. Bu literatür taramasının yapıldığı giriş bölümünde de açıkça görülmektedir.



Şekil 2. Gaz sensörlerinin alkol ve karbonmonoksit'e verdikleri tepki

Gaz sensörlerinden elde edilen verinin sınıflandırılmasında hangisinin daha iyi bir performans sergileyeceğini gözlemlemek adına ABC, ACO, PSO ve GA algoritmaları ANN ile birlikte Hibrit kullanılmış ve sınıflandırma sonuçları elde edilmiştir. Bu algoritmaların seçilme sebebi literatürde ANN ile birlikte Hibrit kullanılan, sıklıkla başvurulan algoritma olmalarından kaynaklanmaktadır.

3.1. Yapay Arı Koloni Algoritması (ABC)

Derviş Karaboğa tarafından geliştirilen ve arıların nektar arayışından yola çıkarak global

minimumuna erişmeye çalışan bir sezgisel algoritma olan ABC algoritması birçok çalışmada başarılı sonuçlar vermiştir [26]. Algoritmanın temelinde 3 farklı arı türü içerir, bunlar; işçi, kaşif ve gözlemci arıdır. Bir yerdeki zengin nektar tükendiğinde scout arıya dönüşür. Zengin nektar çevresine yakın yeni nektar bölgeleri aranır.

3.2. Karınca Koloni Algoritması (ACO)

ACO algoritması karıncaların iki nokta arasındaki en kısa yolu bulmalarını sağlayan feromon mekanizmasını kullanan ve nihayetinde global minimuma erişmeyi sağlayacak olan algoritmadır [27].

3.3. Parçacık Sürü Optimizasyonu (PSO)

Stochastic optimizasyon tekniği olan PSO 1995 yılında Eberhart ve Kennedy tarafından tanıtılmıştır [28]. Algoritma temelde kuş sürülerinin bir hedefi aradıklarında sergiledikleri davranışları örnek alan konum ve hız bilgilerini kullanan bir algoritmadır.

3.4. Genetik Algoritma (GA)

Bir arama algoritması olan genetik algoritma iyi genlerin yeni nesillere aktarılarak daha güçlü bir nesil elde etme şeklini örnek olarak Goldberg tarafından 1989 yılında tanıtılmıştır. Mutasyon ve çaprazlama içeren GA bu şekilde bilgi aktarımını sağlar. ANN ile birlikte çok fazla kullanım örneği bulunmaktadır.

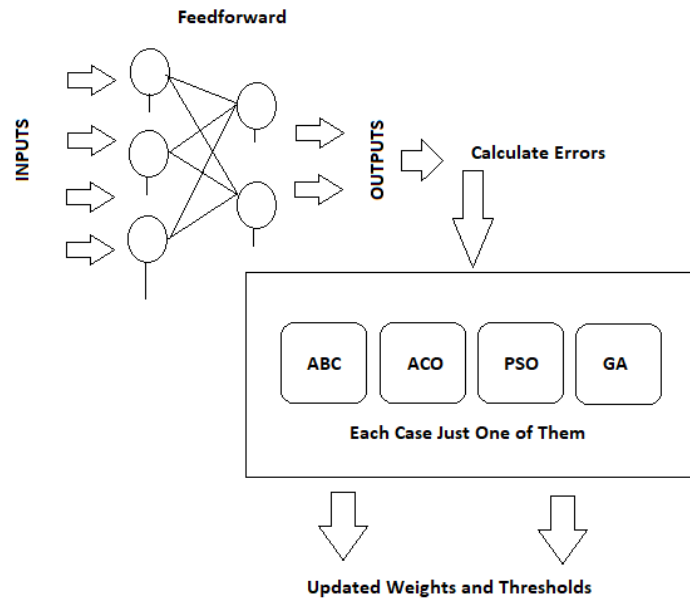
3.5. Sezgisel Algoritma Tabanlı Sinirsel Ağ

Tasarlanan ANN'nin eğitim kısmı dört farklı algoritma ile ayrı ayrı gerçekleştirilmiştir. Bu aşamada kullanılan parametreler Tablo 1.'de verilmiştir.

Tablo 1. Algoritmalarda kullanılan parametreler

| Parameters | ABC | ACO | PSO | GA |
|-------------------|-----|------|-----|-------|
| Colony Size | 50 | 20 | 50 | 1000 |
| Food Source | 250 | - | - | - |
| Lower Bound | -10 | -1 | -1 | -10 |
| Upper Bound | 10 | 1 | 1 | 10 |
| Evaoperation Rate | - | 0.85 | - | - |
| Mutasyon Oranı | - | - | - | 0.001 |
| Çaprazlama Oranı | - | - | - | 0.85 |

ANN'nin eğitim kısmının sezgisel bir algoritma ile optimize edilmesi Şekil 3'te verilmiştir. Veri setinden okunan girdiler ile ağda ileri besleme yapılır. Daha sonra hesaplanan hata ilgili sezgisel algoritmaya gönderilerek algoritmanın ağdaki ağırlık ve eşik değerlerini bu hata değerine göre yeniden hesaplaması beklenir. Bu şekilde istenilen hata düzeyine erişilince eğitim durur.




Şekil 3. ANN’de eğitimin optimize edilmesi

Alkol ve Karbonmonoksit sınıflandırılmasında her algoritma ayrı olarak 100, 500, 1000, 1500 ve 2000 iterasyon olacak şekilde ayrı ayrı çalıştırılmıştır.

4. Bulgular

Gaz verileri üzerinde yapılan farklı çalışmalar en iyi sınıflandırmanın Karınca koloni ve Parçacık Sürü optimizasyon algoritmaları tarafından yapıldığını göstermiştir. Bu algoritmalara en yakın performansı Yapay arı koloni algoritması daha sonrasında Genetik algoritma en düşük performansı da geleneksel geri yayılım algoritmasının gösterdiği görülmüştür. Eğitim sürecinde algoritmaların verdikleri hata grafiği Şekil 4.’te verilmiştir. Eğitim verisinde en iyi performansı Karınca koloni algoritması göstermiştir. Test verisi üzerinde elde edilen sonuçlar Tablo 2’de verilmiştir. Tablo 2’den de görüldüğü üzere Karınca koloni ve Parçacık Sürü optimizasyon algoritmaları test verisini sınıflandırma performansları %100’dür.



Şekil 4. ANN’de eğitimin optimize edilmesi

Tablo 2. Algoritmaların sınıflandırma performansı

| Geri Yayılım Algoritması | | | | | | Yapay Arı Koloni Algoritması | | | | |
|-----------------------------|----------|----------|-----------------|-----------------|-----------------|------------------------------|-----------------|-----------------|----------|----------|
| İterasyon | 100 | 500 | 1000 | 1500 | 2000 | 100 | 500 | 1000 | 1500 | 2000 |
| Alkol | 8,82E-05 | 6,02E-06 | 1,33E-05 | 1,43E-06 | 9,94E-07 | 3,88E-09 | 2,35E-21 | 2,62E-17 | 1,49E-17 | 5,48E-18 |
| Karbon | 8,41E-05 | 6,27E-06 | 1,38E-05 | 1,49E-06 | 1,28E-06 | 1,45E-08 | 2,11E-17 | 1,16E-17 | 2,39E-17 | 5,4E-19 |
| Genetik Algoritma | | | | | | Karınca Koloni Algoritması | | | | |
| İterasyon | 100 | 500 | 1000 | 1500 | 2000 | 100 | 500 | 1000 | 1500 | 2000 |
| Alkol | 4,67E-10 | 3,81E-07 | 2,62E-10 | 8,48E-09 | 1,2E-06 | 0 | 0 | 0 | 0 | 0 |
| Karbon | 5,08E-07 | 1,49E-07 | 1,09E-08 | 4,13E-09 | 1,53E-07 | 0 | 1,3E-277 | 0 | 0 | 0 |
| Parçacık Sürü Optimizasyonu | | | | | | | | | | |
| İterasyon | 100 | 500 | 1000 | 1500 | 2000 | | | | | |
| Alkol | 0 | 0 | 0 | 0 | 0 | | | | | |
| Karbon | 0 | 0 | 0 | 0 | 0 | | | | | |

Her ne kadar test verisinde Karınca koloni ve parçacık süre optimizasyonu aynı performansları gösterse de eğitimdeki Karınca koloni algoritmasının başarısı bu çalışmada ve bu tür verilerde en iyi sınıflandırmanın Karınca koloni tabanlı sinirsel ağlar tarafından yapılacağını göstermektedir.

Sonuçlar

Gazların sınıflandırılması, gaz karışımlarının yorumlanması günümüzde sık başvurulan ve birçok alanda başarıyla kullanılan işlemlerdir. Bu çalışmada önerilen sistem sayesinde alkol ve karbonmonoksit gazları %100'lük bir performans ile sınıflandırılabilir. Sınıflandırma performansı hibrit algoritma ile sağlanmıştır ve bu hibrit algoritmalarının geleneksel algoritmalara göre başarılı olduğunu ve özellikle gazların sınıflandırılmasında bu başarı elde edildiği söylenebilir. Sınıflandırma zaman performansı da iyi olduğu için avuç içi cihazlarda, nesnelerin interneti gibi alanlarda performanslı kullanılabilirler. Sinirsel ağların eğitiminde kullanılan sezgisel algoritmalarından gazların sınıflandırılmasında en başarılı algoritma parçacık sürü optimizasyonu ve Karınca koloni algoritması olmuştur. Her ne kadar test verisinde sonuç böyle iken eğitim verisinde Karınca koloni algoritması en iyi performansı göstermiştir.

Referanslar

- [1] M. F. Adak and N. Yumusak, "Classification of E-Nose Aroma Data of Four Fruit Types by ABC-Based Neural Network," *Sensors*, vol. 16, no. 3, p. 304, Feb. 2016.
- [2] M. Baietto and A. Wilson, "Electronic-Nose Applications for Fruit Identification, Ripeness and Quality Grading," *Sensors*, vol. 15, no. 1, pp. 899–931, Jan. 2015.
- [3] A. Wilson, "Diverse Applications of Electronic-Nose Technologies in Agriculture and Forestry," *Sensors*, vol. 13, no. 2, pp. 2295–2348, Feb. 2013.
- [4] A. Versari, V. F. Laurie, A. Ricci, L. Laghi, and G. P. Parpinello, "Progress in authentication, typification and traceability of grapes and wines by chemometric approaches," *Food Res. Int.*, vol. 60, pp. 2–18, Jun. 2014.
- [5] H. Men, Y. Shi, Y. Jiao, F. Gong, and J. Liu, "Electronic nose sensors data feature mining:

- a synergetic strategy for the classification of beer,” *Anal. Methods*, vol. 10, no. 17, pp. 2016–2025, 2018.
- [6] S. Murugan and N. Gala, “ELENA: A low-cost portable electronic nose for alcohol characterization,” in *2017 IEEE SENSORS*, 2017, pp. 1–3.
- [7] Q. Ameer and S. B. Adeloju, “Polypyrrole-based electronic noses for environmental and industrial analysis,” *Sensors Actuators B Chem.*, vol. 106, no. 2, pp. 541–552, May 2005.
- [8] C. Cevoli, L. Cerretani, A. Gori, M. F. Caboni, T. Gallina Toschi, and A. Fabbri, “Classification of Pecorino cheeses using electronic nose combined with artificial neural network and comparison with GC–MS analysis of volatile compounds,” *Food Chem.*, vol. 129, no. 3, pp. 1315–1319, Dec. 2011.
- [9] P. Hanafizadeh, A. Zare Ravasan, and H. R. Khaki, “An expert system for perfume selection using artificial neural network,” *Expert Syst. Appl.*, vol. 37, no. 12, pp. 8879–8887, Dec. 2010.
- [10] Y. Al-Bastaki, “An Artificial Neural Networks-Based on-Line Monitoring Odor Sensing System,” *J. Comput. Sci.*, vol. 5, no. 11, pp. 878–882, Nov. 2009.
- [11] C. Li, P. Heinemann, and R. Sherry, “Neural network and Bayesian network fusion models to fuse electronic nose and surface acoustic wave sensor data for apple defect detection,” *Sensors Actuators, B Chem.*, vol. 125, pp. 301–310, 2007.
- [12] A. K. Pavlou, N. Magan, J. M. Jones, J. Brown, P. Klatser, and A. P. F. Turner, “Detection of Mycobacterium tuberculosis (TB) in vitro and in situ using an electronic nose in combination with a neural network system,” *Biosens. Bioelectron.*, vol. 20, no. 3, pp. 538–44, Oct. 2004.
- [13] H. M. Saraoglu and B. Edin, “E-Nose System for Anesthetic Dose Level Detection using Artificial Neural Network,” *J. Med. Syst.*, vol. 31, no. 6, pp. 475–482, Aug. 2007.
- [14] C. M. Bishop, *Pattern Recognition and Machine Learning*, 1st ed. Singapore: Springer India, 2006.
- [15] Sunny, V. Kumar, V. N. Mishra, R. Dwivedi, and R. R. Das, “Classification and Quantification of Binary Mixtures of Gases/Odors Using Thick-Film Gas Sensor Array Responses,” *IEEE Sens. J.*, vol. 15, no. 2, pp. 1252–1260, Feb. 2015.
- [16] M. F. Adak, M. Akpinar, and N. Yumusak, “Determination of the Gas Density in Binary Gas Mixtures Using Multivariate Data Analysis,” *IEEE Sens. J.*, vol. 17, no. 11, pp. 3288–3297, Jun. 2017.
- [17] S.-I. Choi, T. Eom, and G.-M. Jeong, “Gas Classification Using Combined Features Based on a Discriminant Analysis for an Electronic Nose,” *J. Sensors*, vol. 2016, pp. 1–9, 2016.
- [18] H. Singh, V. B. Raj, J. Kumar, U. Mittal, M. Mishra, A. T. Nimal, M. U. Sharma, and V. Gupta, “Metal oxide SAW E-nose employing PCA and ANN for the identification of binary mixture of DMMP and methanol,” *Sensors Actuators B Chem.*, vol. 200, pp. 147–156, Sep. 2014.
- [19] A. Ziyatdinov, S. Marco, A. Chaudry, K. Persaud, P. Caminal, and A. Perera, “Drift compensation of gas sensor array data by common principal component analysis,” *Sensors Actuators B Chem.*, vol. 146, no. 2, pp. 460–465, Apr. 2010.
- [20] T. Artursson, T. Eklov, I. Lundstrom, P. Martensson, M. Sjostrom, and M. Holmberg, “Drift correction for gas sensors using multivariate methods,” *J. Chemom.*, vol. 14, no. 5–6, pp. 711–723, Sep. 2000.
- [21] 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.
- [22] M. F. Adak and N. Yumusak, “Development of smart gas sensor system to classify binary gas mixtures,” in *17th IEEE International Conference on Smart Technologies, EUROCON 2017 - Conference Proceedings*, 2017.
- [23] E. Kim, S. Lee, J. Kim, C. Kim, Y. Byun, H. Kim, and T. Lee, “Pattern Recognition for Selective Odor Detection with Gas Sensor Arrays,” *Sensors*, vol. 12, no. 12, pp. 16262–16273, Nov. 2012.
- [24] V. K. Ojha, P. Dutta, A. Chaudhuri, and H. Saha, “Understating continuous ant colony optimization for neural network training: A case study on intelligent sensing of manhole gas components,” *Int. J. Hybrid Intell. Syst.*, vol. 12, no. 4, pp. 185–202, Mar. 2016.
- [25] L. Zhang, F. Tian, S. Liu, J. Guo, B. Hu, Q. Ye, L. Dang, X. Peng, C. Kadri, and J. Feng, “Chaos based neural network optimization for concentration estimation of indoor air contaminants by an electronic nose,” *Sensors Actuators A Phys.*, vol. 189, pp. 161–167, Jan. 2013.
- [26] D. Karaboga, B. Gorkemli, C. Ozturk, and N. Karaboga, “A comprehensive survey: artificial bee colony (ABC) algorithm and applications,” *Artificial Intelligence Review*, vol. 42, no. 1, pp. 21–57, 11-Mar-2012.
- [27] M. Dorigo, V. Maniezzo, and A. Coloni, “Ant system: optimization by a colony of cooperating agents,” *IEEE Trans. Syst. Man Cybern. Part B*, vol. 26, no. 1, pp. 29–41, 1996.
- [28] R. Eberhart and J. Kennedy, “A new optimizer using particle swarm theory,” in *MHS’95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science*, pp. 39–43.