

Konaklama İşletmelerinde Doluluk Oranının Tahmini İçin Yapay Arı Koloni (ABC) Algoritması Kullanılarak ANFIS Eğitimi

Ebubekir KAYA¹Derviş KARABOĞA²

¹Bilgisayar Teknolojileri Bölümü
Meslek Yüksekokulu

Nevşehir Hacı Bektaş Veli Üniversitesi, NEVŞEHİR

²Bilgisayar Mühendisliği Bölümü
Mühendislik Fakültesi
Erciyes Üniversitesi, KAYSERİ

E-mail: ebubekir@nevsehir.edu.tr

karaboga@erciyes.edu.tr

Özet

Bu çalışmada, konaklama işletmelerindeki doluluk oranının tahmini için ABC algoritması kullanılarak, ANFIS eğitimi gerçekleştirilmiştir. 1990 - 2014 yılları arasındaki tesis sayısı, yatak sayısı, konaklayan yabancı ziyaretçi sayısı, geceleme sayısı ve ortalama kalış süresi giriş değişkeni olarak alınarak 5 giriş ve 1 çıkıştan oluşan ANFIS yapısı oluşturulmuştur. Çıkış olarak ise doluluk oranı kullanılmıştır. ANFIS'in yapısında bulunan başlangıç ve sonuç parametrelerinin optimizasyonu, ABC algoritması kullanılarak gerçekleştirilmiştir. Elde edilen sonuçlar regresyon ve ANFIS tabanlı diğer yöntemlerle (ANFIS-PSO, ANFIS-DE) karşılaştırılmıştır. Simülasyon sonuçları konaklama işletmelerindeki doluluk oranının tahmininde önerilen yöntemin etkili olduğunu göstermektedir.

1. Giriş

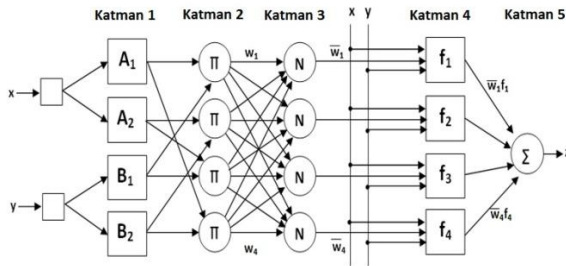
Jang [1] tarafından geliştirilen ANFIS, sinir ağlarının öğrenme yeteneği ile bulanık mantığın çıkarım yapabilme özelliğinin birleşmesinden oluşmaktadır. Bu özelliğinden dolayı son zamanlarda farklı alanlardaki pek çok çalışmada kullanılmıştır [2]. Eğitim [3], medikal sistemler [4], ekonomi[5], görüntü işleme ve özellik çıkarma [6], tahmin çalışmaları [7], sistem modelleme [8], elektrik ve elektronik sistemler [9] ve turizm uygulamaları[10] ANFIS'in kullanıldığı alanlardandır. ANFIS kullanarak bir sistemi modellemek için bir optimizasyon algoritması ile eğitilmesi gerekmektedir. ANFIS eğitiminde kullanılan algoritmalar türev tabanlı olan ve türev tabanlı

olmayanlar şeklinde karşımıza çıkmaktadır. Türev tabanlı algoritmalar ile ANFIS eğitimi gerçekleştirildiğinde, üyelik fonksiyonlarına ait parametrelerin optimizasyonunda lokal minimuma takılmaktadır. Bu yüzden son zamanlarda türev tabanlı olmayan, sezgisel algoritmaların kullanımı yaygınlaşmıştır. Genetik algoritma (GA) [11], parçacık sürü algoritması (PSO) [12], yapay bağışıklık sistemi (AIS) [13], karınca koloni optimizasyonu (ACO) [14], diferansiyel gelişim (DE) [15] algoritması ve ABC [16-17] algoritması ANFIS eğitiminde kullanılan sezgisel algoritmalarındandır.

Bu çalışmada, konaklama işletmelerindeki doluluk oranının tahmini için ABC algoritması kullanılarak ANFIS'in eğitimi gerçekleştirilmiştir. Elde edilen sonuçlar regresyon ve ANFIS tabanlı farklı yöntemlerle karşılaştırılmıştır. ABC algoritmasının geliştirilmesinden bu yana; elektrik mühendisliği, elektronik mühendisliği, inşaat mühendisliği, yazılım mühendisliği, kontrol mühendisliği, endüstri mühendisliği ve mekanik mühendisliği ile veri madenciliği, algılayıcı ağlar, görüntü işleme, nümerik problemlerin çözümü ve protein yapı optimizasyonu alanlarında bir çok gerçek dünya probleminin çözümünde kullanılmış ve başarılı sonuçlar elde edilmiştir [18-21]. Bu yüzden, ANFIS'in eğitimi için ABC algoritması kullanılmıştır. Çalışmanın ilerleyen bölümleri şu şekilde devam etmektedir: İkinci bölümde ANFIS'in temel yapısı ve üçüncü bölümde ABC algoritması anlatılmıştır. Dördüncü bölümde simülasyon sonuçları, beşinci bölümde ise sonuçlar verilmiştir.

2. Adaptif ağ tabanlı bulanık mantık çıkarım sistemi (ANFIS)

ANFIS, sinir ağlarının öğrenme yeteneği ile bulanık mantığın çıkarım yapabilme özelliğinin birleşmesinden oluşmaktadır [1]. Yapısında bulunan sinir ağlarına uzman gibi karar verme imkânı sağladığı için tahmin problemlerinde sıkça kullanılmaktadır. ANFIS başlangıç ve sonuç olmak üzere iki bölümden oluşmaktadır. ANFIS'in eğitimi sırasında bu bölümlerde bulunan parametreler kullanılmaktadır. ANFIS beş katmandan oluşmakla birlikte iki giriş ve bir çıkıştan oluşan örnek ANFIS yapısı Şekil 1'de verilmiştir.



Şekil 1. İki giriş ve bir çıkıştan oluşan ANFIS yapısı.

Birinci katman bulanıklaştırma katmanı olarak anılmaktadır. Bu katmanda girişlerden bulanık kümeler elde etmek için üyelik fonksiyonları kullanılmaktadır. Bu şekilde μ_x ve μ_y üyelik değerleri elde edilmektedir (1)(2).

$$\mu_{A_i}(x) = gbellmf(x; a, b, c) = \frac{1}{1 + \left| \frac{x - c}{a} \right|^{2b}} \quad (1)$$

$$O_i^1 = \mu_{A_i}(x) \quad (2)$$

İkinci katman ise kural katmanı olarak adlandırılmaktadır. Bu katmanda, bulanıklaştırma katmanında elde edilen üyelik değerleri kullanılarak her kuralın ateşleme seviyesi (w) bulunmaktadır (3).

$$O_i^2 = w_i = \mu_{A_i}(x) * \mu_{B_i}(x) \quad (3)$$

Üçüncü katman normalizasyon katmanı olarak adlandırılmaktadır. Bu katmanda, kural katmanında elde edilen ateşleme değerleri kullanılarak (w), her kural için normalize edilmiş ateşleme değerleri hesaplanmaktadır (4).

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad (4)$$

Dördüncü katman durulaştırma katmanı olarak anılmaktadır. Bu katmanda, normalizasyon katmanında elde edilen normalize edilmiş ateşleme değerleri ile birinci dereceden polinomun çarpılmasıyla her kuralın çıkışı bulunmaktadır (5).

$$O_i^4 = \bar{w}_i f_i = w_i (p_i x + q_i y + r_i) \quad (5)$$

Beşinci katman çıkış katmanı olarak adlandırılmaktadır. Durulaştırma katmanında her kural için elde edilen çıkışlar toplanarak ANFIS'in çıkışı elde edilmektedir (6).

$$O_i^5 = \sum_i \bar{w}_i f_i \quad (6)$$

3. Yapay arı koloni (ABC) algoritması

ABC algoritması, bal arılarının yiyecek arama davranışlarını modelleyen Karaboğa tarafından 2005 yılında geliştirilmiştir [22-23]. ABC algoritmasında, her bir koloni de görevli arılar, gözcü arılar ve kâşif arılar olmak üzere üç grup arı bulunmaktadır. ABC algoritmanın temel versiyonunda her bir kaynakta sadece bir tane görevli arının bulunduğu kabul edilmektedir. Bu yüzden görevli arıların sayısı yiyecek kaynağı sayısına eşittir. Bununla birlikte görevli arıların sayısı da gözcü arıların sayısına eşittir. Yiyecek kaynaklarının pozisyonu optimizasyon problemleri için olası bir çözümü temsil etmektedir. Yiyecek kaynaklarının nektar miktarı ise çözümün kalitesine karşılık gelmektedir. ABC algoritmasında koloni büyüklüğü, limit ve maksimum çevrim sayısı olmak üzere üç kontrol parametresi bulunmaktadır. ABC algoritmasının temel adımları şu şekildedir:

-Başlangıç yiyecek kaynaklarını üret ve kontrol parametrelerine değerlerini ata.

repeat

-Görevli arıları yiyecek kaynağı bölgelerine yeni kaynakları belirlemeleri için gönder.

-Görevli arılardan gelen bilgilere göre kaynakların seçilme olasılık değerini hesapla.

-Hesaplanan olasılık değerlerine göre, gözcü arıları yeni kaynakları belirlemek için yiyecek kaynaklarına gönder.

-Terk edilecek kaynağı belirle ve onun görevli arısını kâşif arıya dönüştür.

until Çevrim sayısı = Maksimum çevrim sayısı

ABC algoritması, rastgele üretilen başlangıç yiyecek kaynağı pozisyonları ile çalışmaya başlamaktadır. Bu yüzden Eşitlik 7 kullanılarak belirlenen alt ve üst sınırlar arasından rastgele değerler üretilmektedir. Burada, $i = 1, 2, \dots, SN$ ve $j = 1, 2, \dots, PN$ olmak üzere SN yiyecek kaynağı sayısını ve PN optimize edilecek parametre sayısını göstermektedir. Görevli arı, görevli olduğu yiyecek kaynağının komşuluğunda Eşitlik 8'i kullanarak yeni bir yiyecek kaynağı belirler ve bu kaynağın kalitesini değerlendirir. Burada σ_{ij} , [-1,1] arasında rastgele bir sayıyı göstermektedir.

$$x_{ij} = x_j^{\min} + rand(0,1)(x_j^{\max} - x_j^{\min}) \quad (7)$$

$$v_{ij} = x_{ij} + \sigma_{ij}(x_{ij} - x_{kj}) \quad (8)$$

ABC algoritmasında olasılık tabanlı seçme işlemi, kaynaklardaki nektar miktarını ifade eden uygunluk değeri kullanılarak, Eşitlik 9'da verildiği gibi hesaplanmaktadır. Burada, fit_i kaynağının kalitesini ve SN yiyecek kaynağı sayısını göstermektedir.

$$p_i = \frac{fit_i}{\sum_{j=1}^{SN} fit_j} \quad (9)$$

4. Simülasyon sonuçları

Bu bölümde, konaklama işletmelerindeki doluluk oranının tahmini için ABC algoritması kullanılarak, ANFIS'in eğitimi gerçekleştirilmiştir. 5 giriş ve 1 çıkıştan oluşan, blok şeması Şekil 2'de verilen ANFIS yapısı kullanılmıştır. Giriş ve çıkışların belirlenmesinde [24]'de yapılan çalışmadan yararlanılmıştır. Buna göre ANFIS'in girişleri;

- TS : Türkiye'deki bakanlık belgeli tesislerin yıllık olarak sayısı,
- YS : Türkiye'deki bakanlık belgeli konaklama tesislerinin yıllık olarak sahip olduğu yatak sayısı,
- YTS : Türkiye'deki bakanlık belgeli konaklama işletmelerinde konaklayan yabancı turistlerin yıllık olarak toplam sayısı,
- GS : Türkiye'deki bakanlık belgeli konaklama işletmelerinde konaklayan yabancı turistlerin yıllık olarak toplam geceleme sayısı,
- KS : Türkiye'deki bakanlık belgeli konaklama işletmelerinde konaklayan

yabancı turistlerin yıllık olarak ortalama kalış süresi

olarak belirlenmiştir. ANFIS'in çıkışı ise;

- DO : Türkiye'deki bakanlık belgeli konaklama işletmelerinde konaklayan yabancı turistlerin oluşturduğu yıllık doluluk oranı

alınmıştır. 1990 - 2014 yılları arasındaki yıllık verilerden yararlanılmıştır. Verilerin %80'i eğitim ve %20'si test için kullanılmıştır. Üyelik fonksiyonu olarak genelleştirilmiş bell fonksiyonu seçilmiştir. Her giriş için 2 üyelik fonksiyonu kullanılmış ve 32 kural elde edilmiştir. ABC algoritmasının kontrol parametreleri; koloni büyüklüğü, limit ve maksimum çevrim sayısı sırasıyla 20, 250 ve 5000 alınmıştır.



Şekil 2. Kullanılan ANFIS yapısının giriş ve çıkışlarını gösteren blok şema.


Uygulamalarda hata değeri olarak ortalama mutlak yüzdelik hata (MAPE) kullanılmıştır. ABC algoritması kullanılarak gerçekleştirilen ANFIS eğitimi rastgele seçilen başlangıç popülasyonu ile başlamış ve 30 kere sonuç alınmıştır. Elde edilen sonuçların ortalaması alınarak MAPE değeri hesaplanmıştır.

Tablo 1. Elde edilen sonuçların farklı yöntemlerle karşılaştırılması.

Algoritma	Eğitim (MAPE)	Test (MAPE)
Regresyon	5.96	11.01
ANFIS-PSO	4.86	10.99
ANFIS-DE	3.54	9.26
ANFIS-ABC (Önerilen)	2.82	8.16

Tablo 1'de, önerilen yöntem kullanılarak elde edilen sonuçlar; regresyon, ANFIS-PSO ve ANFIS-DE gibi farklı yöntemlerle karşılaştırılmıştır. Regresyon, ANFIS-PSO, ANFIS-DE ve önerilen yöntem ile sırasıyla 5.96, 4.86, 3.54 ve 2.82 eğitim hata değerleri elde edilmiştir. Test için ise sırasıyla 11.01, 10.99,

9.26 ve 8.16 hata değerleri bulunmuştur. Görüldüğü gibi, eğitim için 2.82 ve test için 8.16 hata değerleri ile, en iyi sonuç önerilen yöntem kullanılarak elde edilmiştir. Şekil 3'de ise önerilen yöntem için "Gerçek Doluluk Oranı - Bulunan Doluluk Oranı" grafiği verilmiştir. Eğitim aşamasında bulunan hata değerinin düşük olmasından dolayı, grafik üzerinde başarılı bir eşleşmenin olduğu görülmektedir.



Resim 3. Eğitim işlemi için "Gerçek Doluluk Oranı - Bulunan Doluluk Oranı" grafiği.

5. Sonuçlar

Bu çalışmada, konaklama işletmelerindeki doluluk oranının tahmini için ABC algoritması kullanılarak, ANFIS eğitimi gerçekleştirilmiştir. Önerilen yöntem ile elde edilen hata değerlerinin %10'un altında olduğu görülmektedir. Literatürde yapılan çalışmalarda MAPE cinsinden hata değerinin %10'un altında olması durumunda elde edilen sonuçların çok iyi olduğu vurgulanmıştır. Bu durum, konaklama işletmelerindeki doluluk oranının tahmini için ABC algoritması kullanılarak gerçekleştirilen ANFIS eğitiminin etkili bir yöntem olduğunu göstermektedir.

6. Kaynaklar

- [1] J.S.R. Jang, "ANFIS: Adaptive-network-based fuzzy inference system", IEEE T Syst Man Cyb, 1993; 23: 665-685.
- [2] S. Kar, S. Das and P.K. Ghosh, "Applications of neuro fuzzy systems: A brief review and future outline", Applied Soft Computing, 2014; 15: 243-259.

- [3] O. Taylan, B. Karagozolu, "An adaptive neuro-fuzzy model for prediction of student's academic performance", Computers & Industrial Engineering, 2009; 57 (3): 732-741.
- [4] N.B. Khameneh, H. Arabalibeik, P. Salehian and S. Setayeshi, "Abnormal red blood cells detection using adaptive neuro-fuzzy system", Studies in Health Technology and Informatics, 2012; 173: 30-34.
- [5] G.S. Atsalakis and K.P. Valavanis, "Forecasting stock market short-term trends using a neuro-fuzzy based methodology", Expert Systems with Applications, 2009; 36: 10696-10707.
- [6] Y. Chakrapani and K. Soundararajan, "Adaptive neuro-fuzzy inference system based fractal image compression", International Journal of Recent Trends in Engineering, 2009; 2 (1): 47-51.
- [7] H. Galavi and L.T. Shui, "Neuro-fuzzy modeling and forecasting in water resources", Scientific Research and Essays, 2012; 7 (24): 2112-2121.
- [8] S.M. Seyedhoseini, J. Jassbi and N. Pilevari, "Application of adaptive neuro fuzzy inference system in measurement of supply chain agility: real case study of a manufacturing company", African Journal of Business Management, 2010; 4 (1): 083-096.
- [9] B. Allaoua, A. Laoufi and B. Gasbaoui, "A. Abderrahmani, Neuro-fuzzy DC motor speed control using particle swarm optimization", Leonardo Electronic Journal of Practices and Technologies, 2009; 15: 1-18.
- [10] M.S. Chen, L.C. Ying and M.C. Pan, "Forecasting tourist arrivals by using the adaptive network-based fuzzy inference system. Expert Systems with Applications, 2010; 37(2); 1185-1191.
- [11] W.H. Ho, J.X. Chen, I. Lee and H.C. Su, "An ANFIS-based model for predicting adequacy of vancomycin regimen using improved genetic algorithm", Expert Syst Appl, 2011; 38: 13050-13056.
- [12] M.Y. Chen, "A hybrid ANFIS model for business failure prediction utilizing particle swarm optimization and subtractive clustering", Inform Sciences 2013; 220: 180-195.
- [13] S. Suja Priyadharsini, S. Edward Rajan and S. Femilin Sheniha, "A novel approach for the elimination of artefacts from EEG signals employing an improved artificial immune system algorithm", J Exp Theor Artif In, 2016; 28: 239-259.

- [14] M. Jalali-Heravi and M. Asadollahi-Baboli, "Quantitative structure-activity relationship study of serotonin (5-HT₇) receptor inhibitors using modified ant colony algorithm and adaptive neuro-fuzzy inference system (ANFIS)", *Eur J Med Chem*, 2009; 44: 1463-1470.
- [15] S.M. Khazraee, A.H. Jahanmiri and S.A. Ghorayshi, "Model reduction and optimization of reactive batch distillation based on the adaptive neuro-fuzzy inference system and differential evolution", *Neural Comput Appl*, 2011; 20: 239-248.
- [16] D. Karaboga and E. Kaya, "Training ANFIS using artificial bee colony algorithm", In: 2013 IEEE International Symposium on Innovations in Intelligent Systems and Applications (INISTA), 19-21 June 2013; Albena, Bulgaria: IEEE. pp. 1-5.
- [17] D. Karaboga and E. Kaya, "Training ANFIS using artificial bee colony algorithm for nonlinear dynamic systems identification", In: IEEE Signal Processing and Communications Applications Conference (SIU); 23-25 April 2014; Trabzon, Turkey: IEEE. pp. 493-496.
- [18] S. Kockanat and N. Karaboga, "The design approaches of two-dimensional digital filters based on metaheuristic optimization algorithms: a review of the literature", *Artif Intell Rev*, 2015; 44: 265-287.
- [19] S. Kockanat and N. Karaboga, "A novel 2D-ABC adaptive filter algorithm: a comparative study", *Digit Signal Process*, 2015; 40: 140-153.
- [20] B. Akay and D. Karaboga, "A survey on the applications of artificial bee colony in signal, image, and video processing", *SIViP*, 2015; 9: 967-990.
- [21] D. Karaboga, B. Gorkemli, C. Ozturk and N. Karaboga, "A comprehensive survey: artificial bee colony (ABC) algorithm and applications", *Artif Intell Rev*, 2014; 42: 21-57.
- [22] D. Karaboga, "An idea based on honey bee swarm for numerical optimization", Technical Report-TR06, Erciyes University, Engineering Faculty, Computer Engineering Department, 2005.
- [23] Karaboga D, Basturk B. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm. *J Global Optim* 2007; 39: 459-471.
- [24] M. Çuhadar and C. Kayacan, "Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme", *Anatolia Turizm Araştırmaları Dergisi*, 2005; 16(1): 121-126.