



Sinüs Kosinüs Algoritması ile Çok Katmanlı Algılayıcı Eğitimi

M. Evren Kıymaç^{1*}, Yasin Kaya²

^{1*} Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Adana, Türkiye, (ORCID: 0000-0003-4008-626X), evren.kiymac@icloud.com

² Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Adana, Türkiye, (ORCID: 0000-0002-9074-0189), ykaya@atu.edu.tr

(İlk Geliş Tarihi 12 Eylül 2021 ve Kabul Tarihi 21 Kasım 2021)

(DOI: 10.31590/ejosat.994406)

ATIF/REFERENCE: Kıymaç, M. E. ve Kaya, Y. (2021). Sinüs kosinüs algoritması ile çok katmanlı algılayıcı eğitimi. *Avrupa Bilim ve Teknoloji Dergisi*, (27), 1113-1117.

Öz

Yapay sinir ağlarının (YSA) eğitilmeleri açısından, meta-sezgisel yöntemlerin geleneksel, eğitim tabanlı yöntemlere göre üstünlükleri, bilimsel yazındaki çok sayıda çalışma ile gösterilmiştir. Bu çalışmanın amacı, bir YSA türü olan Çok Katmanlı Algılayıcı (ÇKA) eğitimindeki başarımlar açısından, bir meta-sezgisel en iyileştirme yöntemi olan Sinüs Kosinüs Algoritması (SKA) ile iki başka yöntemin (parçacık sürü en iyileştirme (PSEİ) ve yaras algoritması (YA)) karşılaştırılmasıdır. Bütün yöntemlerin, Kaliforniya Üniversitesi, Irvine, Yapay Öğrenme Kaynağı üzerinden alınan beş hastalık ile ilgili veri kümesinde (göğüs kanseri, diyabet, karaciğer, omurga ve parkinson) ikili sınıflandırmadaki başarımlar değerlendirilmiştir. Deney sonuçlarında, SKA ile eğitilen ÇKA'lar %97'ye varan yüksek doğruluk oranlarına ulaşmıştır. Yöntem, YA'dan büyük çoğunlukla daha yüksek, PSEİ'den büyük çoğunlukla daha düşük başarımlar göstermiştir. PSEİ yöntemi genel olarak daha yüksek başarımlar gösterse de, SKA yöntemi de bir veri kümesinde en yüksek, kalan veri kümelerinin biri dışında hepsinde ikinci en yüksek eğitim başarımlarını göstermiştir. İncelenen yöntem arama uzaylarında, hem yüksek keşfetme ve yerel en iyiden kaçınma, hem de amaçlanan değerlere yüksek yakınsama hızları göstermektedir. Bu sonuçlar, SKA'nın ÇKA eğitiminde yetkin ve etkili olabildiğini ortaya koymaktadır.

Anahtar Kelimeler: Yapay Sinir Ağları, Çok Katmanlı Algılayıcı, Meta-sezgisel Yöntemler, Sinüs Kosinüs Algoritması.

Multilayer Perceptron Training with Sine Cosine Algorithm

Abstract

The superiority of metaheuristic methods over conventional, gradient-based methods, in terms of training artificial neural networks (ANN), has been shown with numerous studies in the literature. The aim of this study is to compare the Sine Cosine Algorithm (SCA), which is a metaheuristic optimization method, with two other methods (particle swarm optimization (PSO) and bat algorithm (BA)) in terms of the performance in Multilayer Perceptron (MLP) training, which is a type of ANN. Performance evaluations of all methods on binary classification were made on five datasets which are related with diseases (breast cancer, diabetes, liver disorders, vertebral column, and parkinsons) obtained from the University of California, Irvine, Machine Learning Repository. In the results of the experiments, the MLPs which were trained with the SCA have achieved high accuracy rates up to 97%. The method performed mostly higher than the BA and mostly lower than the PSO. Although the PSO method showed higher success in general, the SCA method also showed the highest training performance in one dataset and the second highest in all but one of the remaining datasets. In the search spaces, the investigated method shows both high exploration and avoidance of local optimum, as well as high convergence rates to the aimed values. These results reveal that, the SCA can be competent and effective at training the MLP.

Keywords: Artificial Neural Networks, Multilayer Perceptron, Metaheuristic Methods, Sine Cosine Algorithm.

* Sorumlu Yazar: evren.kiymac@icloud.com

1. Giriş

Yapay sinir ağları (YSA), yapay öğrenme alanındaki en önemli buluşlardan biridir. Bu yöntemde, insan beynindeki sinir hücrelerinin uyarı iletimi sırasındaki işleyişlerinden ve bilgi oluşumu için düzenlenişlerinden esinlenilerek oluşturulan matematiksel yapılar kullanılmaktadır. İlk örnekleri 1940'larda uygulanmıştır (McCulloch ve Pitts, 1943).

Bilimsel yazında, yöntemin birtakım türleri önerilmiştir: İleri beslemeli sinir ağları (Bebis ve Georgiopoulos, 1994), yineleyen sinir ağları, vd. İleri beslemeli sinir ağlarında, giriş katmanından çıkış katmanına doğru ilerleyen tek yönlü bir dizi veri iletimi vardır. Yineleyen sinir ağlarında ise, katmanlar arasında ileri ve geri olarak iki yönlü veri paylaşımı gerçekleşir.

YSA'ların, işleyişlerindeki ayrılıklara karşın, ortak özellikleri öğrenme yetenekleridir. Öğrenme, deneyimlerden bilgi çıkarımı yapabilmeleri anlamındadır. Doğal sinir ağlarına benzer biçimde, YSA'ların kendilerine verilen girdi veri kümesine kendilerini uyarlayan bir işleyişleri bulunmaktadır.

Bir YSA'nın öğrenmesini gerçekleştiren yöntem, bir *eğitici* olarak adlandırılır. Eğitici, YSA'nın daha önce görmediği girdi veri kümeleri karşısında en yüksek başarıyı elde edecek biçimde eğitilmesinden sorumludur. Bir gözetimli öğrenme yöntemi olarak, eğitici önce YSA'ya eğitim örneklerini verir. Sonra, her eğitim adımında YSA'nın başarılarını geliştirmek için yapısal parametrelerini değiştirir. Eğitim aşaması tamamlandıktan sonra, eğitici devreden çıkar ve YSA kullanıma hazır olur.

Bilimsel yazındaki öğrenme yöntemleri, belirlenimci (deterministik) ve rastlanımcı (stokastik) olmak üzere iki türde bulunmaktadır. Geri yayılım ve eğitim tabanlı yöntemler belirlenimci olarak değerlendirilir. Bu türden yöntemlerde, eğitim örnekleri değişmedikçe, ayrı eğitim denemeleri özdeş başarımla sonuçlanır. Buna karşın, rastlanımcı yöntemlerde, özdeş eğitim örnekleri ile yapılan ayrı eğitim denemeleri az çok değişken başarımlarla sonuçlanır (Ozkaya ve Seyfi, 2018).

Belirlenimci yöntemlerin üstünlükleri, yalınlık ve hızdır. Ancak, başlangıç çözümlerine bağımlı bir başarımla elde edilir ve yerel en iyi değerlere takılıp genel en iyi değeri kaçırma olasılıkları daha yüksektir. Oysa rastlanımcı yöntemlerde, başlangıç çözümlerinin seçilmesi ve eğitim süreci rastsal olarak gerçekleştiğinden, yerel en iyi değerlerden kaçınarak genel en iyi değere yaklaşma olasılıkları daha yüksektir.

2. Gereç ve Yöntem

Bu çalışmada, Çok Katmanlı Algılayıcı (ÇKA) eğitimindeki başarımla açısından, bir rastlanımcı öğrenme ve meta-sezgisel en iyileştirme yöntemi olan Sinüs Kosinüs Algoritması (SKA) (Mirjalili, 2016) ile iki başka meta-sezgisel en iyileştirme yönteminin karşılaştırılması amaçlanmıştır.

2.1. Gereç

Bütün yöntemlerin, Kaliforniya Üniversitesi, Irvine, Yapay Öğrenme Kaynağı (University of California, Irvine, Machine Learning Repository, 2021) üzerinden alınan beş hastalıkla ilgili veri kümesinde, ikili sınıflandırmadaki başarımla değerlendirmeleri yapılmıştır. Sınıflandırılan veri kümelerinde, örneklerin değerlerine en düşük - en yüksek normalleştirilmesi uygulanmış ve örnekler %66 eğitim %34 sınıflama alt kümelerine ayrılmıştır.

Sınıflandırılan veri kümeleri ile öznelik ve örnek sayıları Tablo 1'de verilmiştir:

Tablo 1. Sınıflandırılan veri kümeleri

Veri kümesi	Öznelik sayısı	Örnek sayısı
Göğüs Kanseri (<i>Breast Cancer</i>)	8	599
Diyabet (<i>Diabetes</i>)	8	768
Karaciğer (<i>Liver Disorders</i>)	6	345
Omurga (<i>Vertebral Column</i>)	6	310
Parkinson (<i>Parkinsons</i>)	22	195

Deneyler için, dört çekirdekli 3.2 GHz işlemci ve 8 GB bellekli bir bilgisayarda, Python dilinde yazılmış açık kaynaklı bir çerçeve (Faris vd., 2020; Faris vd., 2016) kullanılmıştır.

2.2. Yöntem

Her veri kümesi için 10 deney gerçekleştirilmiş; alınan sonuçların ortalaması alınarak değerlendirme yapılmıştır. Deneylerde, topluluk büyüklükleri 50, yineleme sayıları 250 olarak seçilmiştir. Kullanılan eğitici yöntemler ile başlangıç değerleri Tablo 2'de verilmiştir:

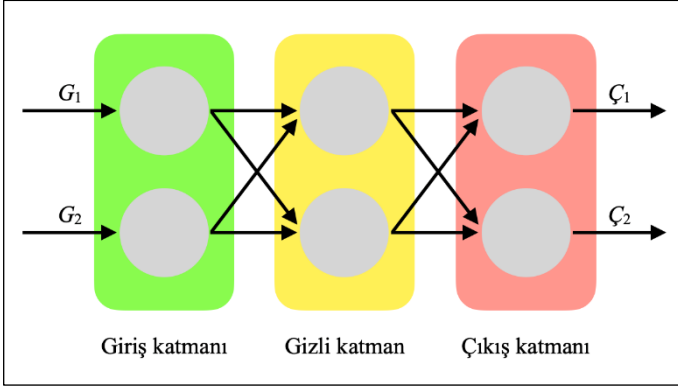
Tablo 2. Kullanılan eğitici yöntemler

Yöntem	Başlangıç değeri
Sinüs Kosinüs Algoritması (<i>Sine Cosine Algorithm</i>)	a değişmezi: 2
Parçacık Sürü En İyileştirmesi (PSEİ) (<i>Particle Swarm Optimization</i>) (Kennedy ve Eberhart, 1995)	ivme değişmezleri: [2.1, 2.1] eylemsizlik ağırlıkları: [0.9, 0.6]
Yarasa Algoritması (YA) (<i>Bat Algorithm</i>) (Yang, 2010)	ses yüksekliği: 0.5 titreşim oranı: 0.5 en düşük titreşim sıklığı: 0 en yüksek titreşim sıklığı: 1

2.2.1. Çok Katmanlı Algılayıcı

İleri beslemeli sinir ağları, veri iletiminin tek ve ileri yönlü gerçekleştiği sinir ağlarıdır. Bu ağlarda, düğümler sıralı katmanlar biçiminde düzenlenir (Bebis ve Georgiopoulos, 1994). İlk katman *giriş katmanı*, son katman ise *çıkış katmanı* olarak adlandırılır. Bu iki katmanın arasındaki katmanlara *gizli katman* denir. Bu yapıda, bir katmandaki her bir düğüm sonraki katmandaki her bir düğüm ile bağlantılıdır.

Yalnızca bir gizli katmanı bulunan ileri beslemeli sinir ağları, *çok katmanlı algılayıcı* olarak tanımlanır. Şekil 1'de, her katmanında ikişer düğüm bulunan bir ÇKA örneği verilmiştir:



Şekil 1. Bir gizli katmanı bulunan ÇKA

Bir ÇKA için, girdi verileri ile düğümler arası ağırlık ve eşik değerleri sağlandıktan sonra, çıktı verileri aşağıdaki denklemler (1)–(4) ile elde edilir:

1. Girdilerin ağırlıklı toplamları alınıp etkinleştirme işlevinden geçirilerek, gizli katmandaki çıktılar (H_j) bulunur:

$$h_j = \sum_i (G_i \cdot A_{ij}) - E_j \quad (1)$$

$$H_j = \text{sigmoid}(h_j) = \frac{1}{1 + \exp(-h_j)} \quad (2)$$

G_i , giriş katmanındaki i . düğümün değerini; A_{ij} , giriş katmanındaki i . düğümünden, gizli katmandaki j . düğüme ağırlık değerini; E_j , gizli katmandaki j . düğümün eşik değerini gösterir.

2. Gizli katmandaki düğümlerin çıktılarına benzer işlemler uygulanarak, sistem çıktıları (ζ_k) bulunur:

$$\zeta_k = \sum_j (H_j \cdot A_{jk}) - E_k \quad (3)$$

$$\zeta_k = \text{sigmoid}(\zeta_k) = \frac{1}{1 + \exp(-\zeta_k)} \quad (4)$$

H_j , gizli katmandaki j . düğümün çıktısını; A_{jk} , gizli katmandaki j . düğümünden, çıkış katmanındaki k . düğüme ağırlık değerini; E_k , çıkış katmanındaki k . düğümün eşik değerini gösterir.

Bir ÇKA'nın eğitilmesi işlemi, yukarıdaki denklemlerden de anlaşılacağı üzere, girdiler ve çıktılar arasında istenen ilişkiyi elde etmek için, en uygun ağırlık ve eşik değerlerinin bulunmasıdır (Mirjalili, 2015). Bu çalışmada, gizli katmandaki düğüm sayısı, veri kümelerindeki öznitelik sayısının iki katının bir fazlası ($2 \times [\text{öznitelik sayısı}] + 1$) olarak belirlenmiştir.

2.2.2. Sinüs Kosinüs Algoritması

SKA, topluluk tabanlı bir meta-sezgisel en iyileştirme algoritmasıdır ve 2016 yılında önerilmiştir.

Bu yöntemde, bir rastgele aday çözümler kümesi oluşturulması ile başlanır ve bu aday çözümler üzerinde, sonlandırma ölçütleri karşılanana kadar, yinelemeli olarak iyileştirmeler gerçekleştirilir. Yöntemin sözde kodu, aşağıda verilen Şekil 2'deki gibidir:

Bir rastgele çözümler kümesi oluştur
Sonlandırma ölçütleri sağlanmadıkça:

Her çözüm için:

Amaç işlevi ile çözümü değerlendir

Eğer çözüm hedef çözümden daha iyiyse

Hedef çözümü güncelle

r_1, r_2, r_3, r_4 rastgele değişkenlerini güncelle


Çözümü denklem (5)'e göre güncelle

Şekil 2. SKA'nın sözde kodu

Yeni aday çözümleri arama işlemi, aşağıda verilen denklem (5) ile gerçekleştirilir:


$$A_i^{t+1} = \begin{cases} A_i^t + r_1 \sin(r_2) |r_3 H_i^t - A_i^t| & r_4 < 0.5 \\ A_i^t + r_1 \cos(r_2) |r_3 H_i^t - A_i^t| & r_4 \geq 0.5 \end{cases} \quad (5)$$

A_i^t , t . yinelemedeki i . aday çözümü; H_i^t , t . yinelemedeki i . hedef çözümü gösterir. r_1 , sinüs ve kosinüs işlevlerinin aralık büyüklüklerini; r_2 , hedefe yaklaşan veya hedeften uzaklaşan bir adımı belirleyen, sinüs ve kosinüs işlevlerinin etki alanlarını (bk. Şekil 3) belirtir. r_3 , hedef çözümün yeni çözümün belirlenmesindeki katkı oranını; r_4 , sinüs ve kosinüs işlevleri arasındaki eşit olasılıklı geçişi belirler.



Şekil 3. Sinüs ve Kosinüs işlevlerinin etki alanlarının gösterimi (Mirjalili vd., 2020)

r_1 değişkeni, yöntemin keşfetmesini azaltmak ve bir noktaya yakınsamasını sağlamak için, doğrusal olarak, $r_1 = a(1 - t/T)$ denklemine göre azalır (bk. Şekil 4). a , bir değişmez sayıyı; t , şimdiki yineleme sayısını; T , toplam yineleme sayısını gösterir. r_2 $[0, 2\pi]$ aralığında, r_3 $[0, 2]$ aralığında ve r_4 ise $[0, 1]$ aralığında birer rastgele sayıdır.



Şekil 4. Azalan r_1 değişkeninin, Sinüs ve Kosinüs işlevlerinin aralık büyüklüklerine etkisi (Mirjalili vd., 2020)

3. Bulgular ve Tartışma

3.1. Bulgular

Karşılaştırılan bütün yöntemler ile veri kümeleri üzerinde gerçekleştirilen deneylerin sonuçlarına göre, yöntemlerin eğittikleri ÇKA'ların ortalama sınıflandırma doğruluk oranları, her veri kümesi için en yüksek değer kalın yazıyla gösterilerek, Tablo 3'te verilmiştir.

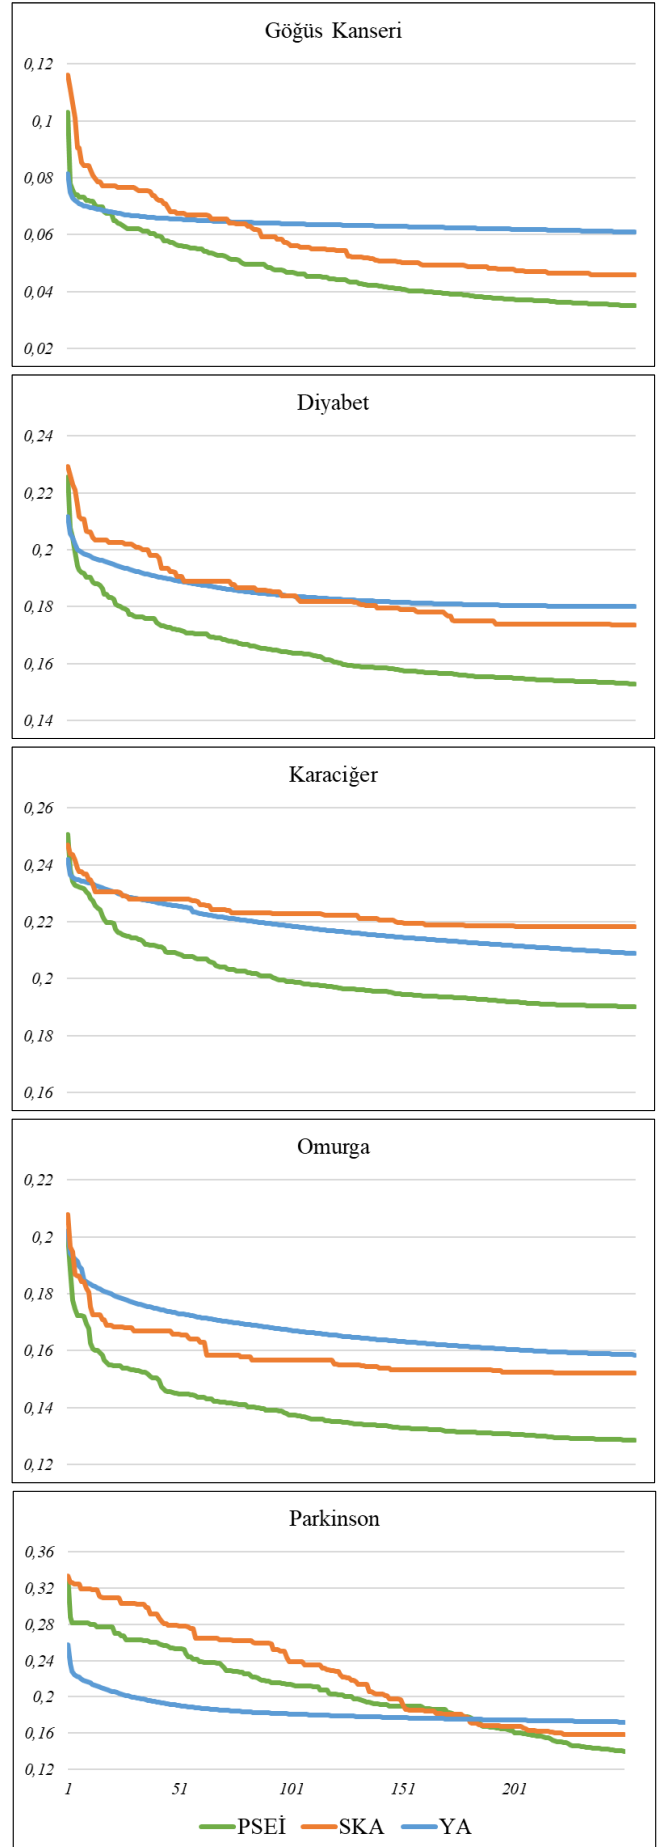
Buna göre, Parçacık Sürü En İyileştirmesi (PSEİ) yöntemi, beş veri kümesinin dördünde en yüksek doğruluk oranını, kalan bir veri kümesinde (Parkinson) ise ikinci en yüksek doğruluk oranını vermiştir.

Sinüs Kosinüs Algoritması (SKA) yöntemi ise, bir veri kümesinde (Parkinson) en yüksek, bir veri kümesinde (Karaciğer) en düşük, kalan üç veri kümesinde ise ikinci en yüksek doğruluk oranını vermiştir.

Son olarak, Yarasa Algoritması (YA) yöntemi, bir veri kümesinde (Karaciğer) ikinci en yüksek, kalan dört veri kümesinde en düşük başarıyı sergileyerek, tüm yöntemler arasında genel olarak son sırada yer almıştır.

Tablo 3. Yöntemlerin ortalama sınıflandırma doğruluk oranları

Yöntem	Veri kümesi				
	Göğüs Kanseri	Diyabet	Karaciğer	Omurga	Parkinson
PSEİ	0.9748	0.7511	0.7542	0.8774	0.7642
SKA	0.9693	0.7168	0.6737	0.7991	0.7776
YA	0.7870	0.4669	0.6780	0.7208	0.6716



Şekil 5. Yöntemlerin ortalama yakınsama grafikleri (eksenler: yineleme sayısı, ortalama kare hata)

3.2. Tartışma

Bu çalışmada elde edilen bulgulara göre, sınıflandırma doğruluk oranı açısından karşılaştırılan üç meta-sezgisel en iyileştirme algoritması arasında, incelemenin odağındaki SKA yönteminin, ÇKA eğitimi için önemli oranda başarılı olabildiği gözlenmiştir.

YA yöntemi ile karşılaştırıldığında, neredeyse incelenen her veri kümesinde büyük ölçüde daha yüksek başarımlar elde etmiştir. YA, sürü tabanlı yöntemler sınıfında bulunmaktadır ve bu sınıftaki yöntemlerin işleyişlerinde, evrimsel yöntemlerin tersine, belirgin olarak anlık ve büyük adımlarla arama uzayında gezinme davranışı bulunmamaktadır. Bu özellikleri, bulgulardaki başarımların düşüklüğünün gerekçesi olarak düşünülebilir. PSEİ yöntemi ise, neredeyse incelenen her veri kümesinde kalan iki yöntemden daha başarılı olmuştur. Bu tutarlılık, yöntemin yüksek etkinliğini ortaya koymaktadır.

Elde edilen bulguların ışığında, incelemenin odağındaki SKA yönteminin amaçlanan değerlere yakınsama hızının da oldukça yüksek olduğu ve sınıflandırma doğruluk oranı ile benzer bir karşılaştırma durumu içerisinde bulunduğu görülmektedir (bk. Şekil 5). Yöntemin, bilimsel yazında tanınır ve geçerli iki başka en iyileştirme yöntemi ile karşılaştırılmasının ortaya koyduğu üzere, başarı beklentisinin kayda değer derecede yüksek olduğu aşığı çıkmaktadır.

4. Sonuç

YSA'ların eğitilmeleri açısından, meta-sezgisel yöntemlerin geleneksel, eğitim tabanlı yöntemlere göre üstünlükleri, bilimsel yazındaki çok sayıda çalışma ile gösterilmiştir. Bu çalışmada, ÇKA'nın ikili sınıflandırma eğitimindeki başarımları açısından, SKA yöntemi ile iki başka meta-sezgisel en iyileştirme yöntemi (PSEİ ve YA) için bir karşılaştırma gerçekleştirilmiştir. Karşılaştırma için, Kaliforniya Üniversitesi, Irvine, Yapay Öğrenme Kaynağı üzerinden alınan, beş hastalık ile ilgili veri kümeleri kullanılmıştır.

PSEİ yöntemi genel olarak daha yüksek başarımlar gösterse de, SKA yöntemi de bir veri kümesinde en yüksek, kalan veri kümelerinin biri dışında hepsinde ikinci en yüksek eğitim başarımlarını göstermiştir. İncelenen yöntem arama uzaylarında, hem yüksek keşfetme ve yerel en iyiden kaçınma, hem de amaçlanan değerlere yüksek yakınsama hızları göstermektedir. Bu sonuçlar, SKA yönteminin ÇKA eğitimi açısından önemli derecede yetkin ve etkili olabildiğini ortaya koymaktadır.

Ayrıca, gelecek çalışmalarda, gizli katman düğüm sayısının en uygun değerinin saptanmasında ve ÇKA'dan başka yapıdaki YSA'lar üzerinde de bu yöntemin katkısının incelenmesi oldukça yararlı olacaktır.

Kaynakça

- Bebis, G. ve Georgiopoulos, M. (1994). Feed-forward neural networks. *IEEE Potentials*, 13(4), 27–31. <https://doi.org/10.1109/45.329294>
- Faris, H., Aljarah, I. ve Fouad, M. M. (2020). *EvoPy-NN*. GitHub. <https://github.com/7ossam81/EvoPy-NN/>
- Faris, H., Aljarah, I., Mirjalili, S., Castillo, P. A. ve Merelo, J. J. (2016). EvoPy: An open-source nature-inspired optimization framework in Python. *Proceedings of the 8th*

International Joint Conference on Computational Intelligence - IJCCI 2016, 1, 171–177. <https://doi.org/10.5220/0006048201710177>

Kennedy, J. ve Eberhart, R. (1995). Particle swarm optimization. *Proceedings of the International Conference on Neural Networks - ICNN 1995*, 4, 1942–1948. <https://doi.org/10.1109/ICNN.1995.488968>

McCulloch, W. S. ve Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics* 1943, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>

Mirjalili, S. (2015). How effective is the grey wolf optimizer in training multi-layer perceptrons. *Applied Intelligence*, 43(1), 150–161. <https://doi.org/10.1007/s10489-014-0645-7>

Mirjalili, S. (2016). SCA: A sine cosine algorithm for solving optimization problems. *Knowledge-Based Systems*, 96, 120–133. <https://doi.org/10.1016/j.knsys.2015.12.022>

Mirjalili, S. M., Mirjalili, S. Z., Saremi, S. ve Mirjalili, S. (2020). Sine cosine algorithm: Theory, literature review, and application in designing bend photonic crystal waveguides. *Studies in Computational Intelligence*, 811, 201–217. https://doi.org/10.1007/978-3-030-12127-3_12

Ozkaya, U. ve Seyfi, L. (2018). A comparative study on parameters of leaf-shaped patch antenna using hybrid artificial intelligence network models. *Neural Computing and Applications*, 29(8), 35–45. <https://doi.org/10.1007/s00521-016-2620-1>

University of California, Irvine, Machine Learning Repository (2021). *Data Sets*. <http://archive.ics.uci.edu/ml/datasets.php>

Yang, X.-S. (2010). A new metaheuristic bat-inspired algorithm. *Studies in Computational Intelligence*, 284, 65–74. https://doi.org/10.1007/978-3-642-12538-6_6