

## Tiroid Hastalığının Teşhisinde Parçacık Sürü Optimizasyonu ile Yapay Sinir Ağının Hibrit Kullanımı

\*<sup>1</sup> M. Fatih Adak, Nejat Yumusak

\*<sup>1</sup> Department of Computer Engineering, Sakarya University, Sakarya, Turkey

### Özet

Ülkemizde neredeyse her üç kişiden birinde görülen hastalık olan tiroidin erken teşhiste yaşam kalitesini arttırdığı bilinmektedir. Tiroid şüphesi olan kişilerden alınabilecek bazı ölçümler ve nitelikler Tiroid ile ilgili ipuçları verebilmektedir. Bundan dolayı bu çalışmada deneklerden alınarak elde edilen bilgilerden oluşturulmuş veri seti, eleme ve normalizasyondan geçirilerek yeni veri seti oluşturulmuştur. Yeni veri seti üzerinde, parçacık sürü optimizasyonu kullanan yapay sinir ağı (YSA-PSO) ile başarılı sınıflandırma sonuçları elde edilmiştir. Bu çalışma, Tiroid ve benzeri hastalıkların teşhisinde PSO ile optimize edilmiş YSA'nın başarılı sonuçlar verebileceğini göstermiştir.

**Anahtar kelimeler:** YSA, PSO, optimizasyon, tiroid teşhisi

## Diagnosis of Thyroid by Hybrid Particle Swarm Optimization with Artificial Neural Network

### Abstract

It is known that the thyroid disease seen almost one in every three people and in early diagnosis of it improves the life quality. Some tips about thyroid disease can be gathered by taking some measurements from suspicion people. Therefore a dataset that is formed by data which taken from the subjects is created by elimination and normalization techniques. Artificial neural network using particle swarm optimization (ANN-PSO) is applied to this resulting dataset and successful classification results are obtained. This shows, using ANN optimized by PSO, could give successful results in diagnosis of thyroid and similar diseases.

**Key words:** YSA, PSO, optimization, Diagnosis of Thyroid

### 1. Giriş

Hastalıkların erken teşhisi, yaşama sürecini uzatma ve hayat kalitesini artırma anlamında büyük önem arz etmektedir. Erken teşhis olarak literatürde öğrenme teknikleri ve optimizasyon sıklıkla kullanılmıştır [1]. Yine üzerinde çok çalışma yapılan Tiroid hastalığının ülkemizde rastlanma oranı oldukça yüksektir. Tiroid hastalığını erken teşhisi yaşam kalitesini artırma açısından çok önemlidir. Hastalık şüphesi olanlara yapılacak bazı ölçümler ve anket soruları Tiroid hastalığı teşhisi açısından önemli bilgiler verecektir. Tiroid hastalığının bir tehlikeli yönü, Tiroid hastalarının, kendilerinde bu hastalık olup olmadığını anlayamamalarıdır [2].

Bu çalışmada Tiroid şüphesi veya hastası olan kişilerden elde edilmiş ölçüm ve anket bilgisi barındıran ve UCI veri setleri sitesinde yayınlanmış olan Tiroid veri seti kullanılmıştır [3]. Tiroid hastalığının teşhisinde yapılan çalışmalara bakıldığında, destek vektör makineleri ile özellik seçme algoritmaları birlikte kullanılarak 144 nitelikten sadece 20'si seçilip başarılı sonuçlar elde edilmiştir [4]. Yine destek vektör makineleri kullanıp Tiroid hastalığının teşhisinde başarılı sonuçların elde edildiği diğer bir çalışmada %99'a yakın bir sınıflandırma başarısı elde edilmiştir [5]. Bu sınıflandırma başarısına yakın başarı elde etmiş diğer bir çalışmada bulanık k-en yakın komşuluk algoritması kullanılmıştır [6].

Yapay sinir ağı (YSA) ve Hibrit algoritmalar kullanılarak ta Tiroid hastalığının teşhisinde başarılı sonuçlar elde edilmiştir. Örneğin Prasad ve Rao, Tiroid hastalığını teşhisinde makine öğrenme algoritması, karar destek sistemleri ile Hibrit kullanılmış ve %93'lük bir başarı elde edilmiştir [7]. Karar destek sistemlerinin Tiroid hastalığının teşhisinde kullanıldığı diğer bir çalışmada %95'lik bir sınıflandırma başarısı elde edilmiştir [8]. Yine YSA'nın sürü optimizasyonu teknikleri ile Hibrit kullanımı ile Tiroid hastalığının teşhisinde, YSA'nın ölçekli eşlenik gradyan algoritması ile Hibrit kullanıldığında ortalamada %99'luk başarı elde edilmiştir [9]. Bilgisayar destekli medikal teşhislerin karşılaştırıldığı bir çalışmada çeşitli kanserlerin yanında, Tiroid hastalığının teşhisi %83 başarı ile YSA'nın geleneksel eğitim modeli olan geri yayılım algoritması (BP) ve Hibrit olarak kullanılan uyaran örnekleme yöntemiyle elde edilmiştir [10].

Yapay sinir ağlarının birçok algoritma ile optimize edildiği ve başarılı sonuçlar alındığı bilinmektedir. Bu çalışmada YSA'nın eğitim kısmı, parçacık sürü optimizasyonu (PSO) ile optimize edilmiştir. Bu yöntemi kullanan farklı çalışmalara bakıldığında, Epilepsi hastalığının teşhisinde YSA ve PSO Hibrit bir şekilde kullanılmış ve başarılı sonuçlar elde edilmiştir [11]. Khan ve Sahai, YSA'nın eğitiminde farklı algoritmalar kullanmış ve bunu uzaktan öğrenme üzerine uygulamışlardır. BA ve PSO algoritmaları benzer performans değerleri göstermişlerdir [12]. Bu sonuçlara bakıldığında PSO algoritması YSA'nın eğitiminde kullanmak için uygun bir algoritma olduğu görülmektedir [13].

Bu bilgiler ışığında, bu çalışmada Tiroid veri seti üzerinde, eğitimin PSO ile optimize edildiği YSA uygulanmış ve modelin hiç görmediği test verisi üzerinde performans analizleri yapılmıştır. Çalışma şu şekilde organize edilmiştir. Bölüm 2'de kullanılan metotlar anlatılmış, Bölüm 3'te tasarlanan model verilmiş, Bölüm 4'te Tiroid veri setine uygulanan modelden elde edilen sonuç ve performanslar gösterilmiş ve son bölümde çalışmanın sonuçlarından bahsedilmiştir.

## 2. Metot

### 2.1. Yapay Sinir Ağları (YSA)

YSA, insan beyninin öğrenme modelini örnek alan, nöronlar içeren ve bu nöronların ağırlıklarla birbirine bağlanması ile farklı katmanlardan oluşan bir yapıdır. Sınıflandırma veya kümeleme çalışmalarında kullanılmaktadır. Öğrenme modeli olarak geri yayılım (BP) algoritması kullanılır [14]. BP algoritması veri seti girdilerinin nöronlara ağırlıklar yardımıyla iletilmesi ve çarpılması ile ağda yapılan ileri hareket sonucunda oluşan MSE hata değerini, çıktı katmanından, girdi katmanına hareket ettirerek bu MSE değeri bütün nöronlara iletilir. Bu iletim sırasında bütün

ağırlıklar ve eşik değerleri güncellenecektir. Belirlenmiş epoch sayısından sonra hata kabul edilebilir bir seviyeye indirilmesi beklenmektedir. Eğitim modelinde 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. Parçacık Sürü Optimizasyonu (PSO)

Stokastik optimizasyon tekniklerinden olan PSO, Kennedy ve Eberhart tarafından 1995 yılında tanıtılmıştır [15], [16]. Göçmen kuşların, göç akınları sırasında hedef aramada kullandıkları yöntemden esinlenmiştir. Bu algorithmada popülasyon sürü (swarm) olarak, sürüdeki her birey ise parçacık olarak ifade edilmektedir. Bu parçacıklar çok boyutlu uzay içerisinde akış halinde kabul edilirler. Bir parçacığın konumu, hız  $v_i(t+1)$  hesaba katılarak Denklem 2'deki gibi hesaplanır.

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (2)$$

Bu konumlar referans alınarak, her parçacığın hızı Denklem 3'teki gibi hesaplanır.

$$v_{ij}(t+1) = v_{ij}(t) + c_1 r_{1j}(t)[y_{ij}(t) - x_{ij}(t)] + c_2 r_{2j}(t)[\bar{y}_j(t) - x_{ij}(t)] \quad (3)$$

## 2.3. YSA'nın PSO Tabanlı Eğitilmesi

Sezgisel algoritmalar, yapay sinir ağının eğitilmesi (local minimum takılma) gibi kompleks optimizasyon problemlerin çözümünde oldukça başarılıdırlar [17]. Bu çalışmada yapay sinir ağının, ağırlık ve eşik değerleri, PSO ile belirlenerek eğitim sağlanmıştır. Her bir parçacığın hız ve konumu bulunmaktadır ve uygunluk değeri konumdaki değerlerin ağ üzerine yerleştirilmesi ile, ağda ileri besleme yapılarak bulunur (Denklem 4).

$$y_i = f\left(\sum w_{ji} x_i\right) \quad (4)$$

İleri beslemenin sonucunda oluşan hata (MSE) aktivasyon fonksiyonunun döndürdüğü değer olacaktır (Denklem 5 ve 6). Buradaki amaç her iterasyonda MSE değerini aşağı çekerek sıfıra yaklaştırmaktır.

$$E = \frac{1}{2} \sum (y_{dj} - y_j)^2 \quad (5)$$

$$MSE = \frac{E}{Train Data Set} \quad (6)$$

### 3. Model

#### 3.1. Veri Setinin Hazırlanması

YSA'da eğitim yapılacak veri setinin oluşturulması için bazı sayısal olmayan ve içerisinde fazlaca ölçümü alınmamış veriler barındıran nitelikler veri setinden çıkarılmıştır. Tiroid veri setinde 21 adet bulunan nitelik sayısı 7 adede indirilmiştir. Yine 7200 adet veri içeren veri seti Tiroid Var veya Yok şeklinde dengeli ayarlayabilmek adına 212 örneğe indirilmiştir. Bu 212 örnek içerisinde hiçbir şekilde ölçümü bulunmayan bir nitelik bulunmamaktadır. Seçilen 6 adet girdi niteliği ve 1 adet sonuç niteliği Tablo 1'de verilmiştir.

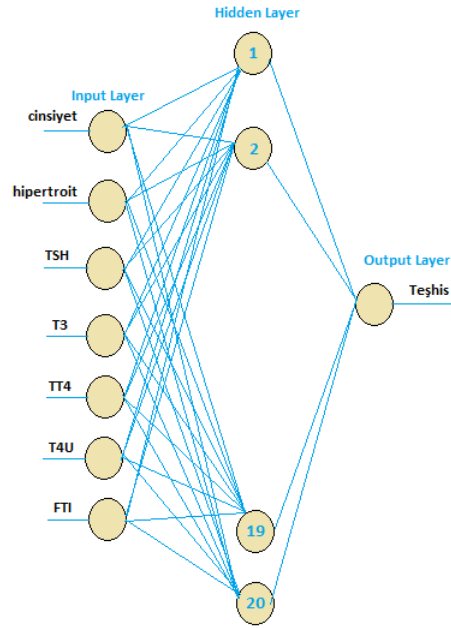
**Tablo 1.** YSA ve Genetik algoritmalarının parametreleri

İsim	Tür
Cinsiyet	İkili Sayı
Hipertiroit	İkili Sayı
TSH	Sayısal
T3	Sayısal
TT4	Sayısal
T4U	Sayısal
FTI	Sayısal
<b>Sonuç</b>	<b>İkili</b>

Eğitim modelinde Sigmoid fonksiyonu kullanıldığı için sayısal değerler [0 1] aralığına normalize edilmiştir. Hazırlanan bu veri seti modele okutulurken %75 Eğitim ve %25 Test verisi olacak şekilde rastgele seçilmiştir.

#### 3.1. Tasarlanan Sinir Ağı

Çalıştırılan senaryolardan en iyi test performansını gösteren YSA yapısı Şekil 1'de verilmiştir. Bu yapıda 3 katman bulunmaktadır. Girdi katmanında çalışmada bulunan 7 adet girdi görünmektedir. Gizli katmanda 20 adet nöron bulunmaktadır. Çıktı katmanından tek bir çıktı bulunmaktadır. Bu çıktı YSA'ya verilen girdi bilgisine karşılık tiroit teşhisi var mı? Yok mu? Kontrol etmektedir.



Şekil 1. Çalışmada kullanılan YSA'nın yapısı

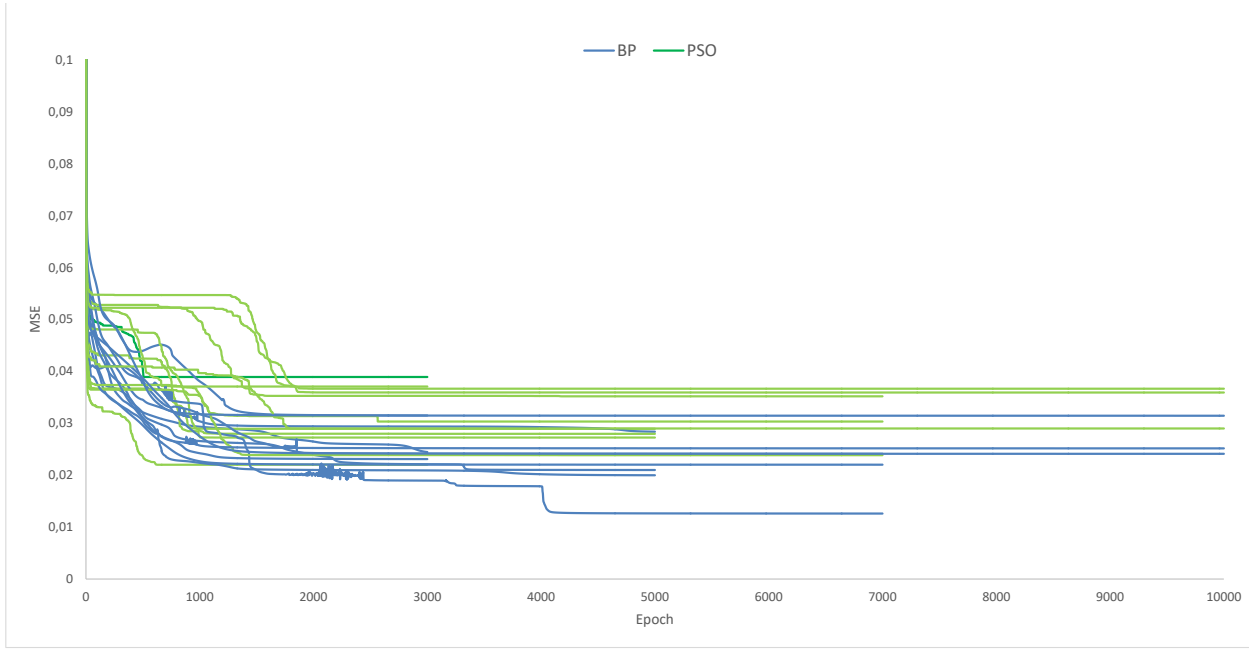
#### 4. Senaryo ve Bulgular

Çalışmada aynı eğitim veri setleri kullanılarak YSA-BP ve YSA-PSO ağları kendi yöntemleri ile eğitilmiş ve test sonuçları elde edilmiştir. YSA-BP ve YSA-PSO'da kullanılan parametreler Tablo 2'de verilmiştir.

**Tablo 2.** YSA ve Genetik algoritmalarının parametreleri

YSA		PSO	
Öğrenme katsayısı	0.2	Hata Toleransı	0
Momentum	0.8	Parçacık sayısı	100
Epoch	Değişken	Değer aralığı	[-1 1]
Ağırlıklar aralık	[-1,1]	C1 ve C2 değerleri	2
Eşik değerleri aralık	[-1,1]	İterasyon	Değişken

Yapılan çalışmada 12 farklı ağ yapısı test edilmiş, Ağ yapılarında gizli katmandaki nöron sayısı 5'ten başlayarak, 20'ye kadar artırılarak testler uygulanmıştır. Eğitimde elde edilen MSE grafikleri Şekil 2'de verilmiştir. Mavi olanlar BP ile eğitilen ağların, yeşil olanlar PSO ile eğitilen ağların eğitim grafiklerini göstermektedir. Bariz bir şekilde görülmektedir ki BP ile eğitilen ağlar daha düşük hata seviyelerine ulaşmışlardır. Fakat aynı şekilde Tablo 2'ye bakıldığında ağların hiç görmediği test verisine karşı verdikleri tepkide PSO çok daha iyi sonuç vermiştir. Buradan şu ifade edilebilir. ANN-BP eğitim veri setini ezberlemiş ve dolayısıyla hiç görmediği veride düşük test performansı sergilemiştir.



Şekil 2. Sensörlerin MC ve AC ikili gaz karışımlarına verdikleri tepki

Tablo 2'ye bakıldığında açık bir şekilde görülmektedir ki, PSO BP'den hemen hemen bütün senaryolarda daha iyi test performansı sergilemiştir. PSO ile en düşük erişilen test performansı 3000 epoch çalıştırılan ve gizli katmanında 20 nöron olan senaryo olmuştur. Erişilen MSE değeri  $8,87E-02$  olmuştur.

**Tablo 2.** Test verisi hata performans değerleri

Nöron S.	3000		5000		7000		10000	
	BP	PSO	BP	PSO	BP	PSO	BP	PSO
5	2,35E-01	2,18E-01	1,31E-01	1,05E-01	4,37E-01	4,19E-01	3,67E-01	3,27E-01
10	4,63E-01	4,41E-01	3,23E-01	2,74E-01	4,76E-01	4,77E-01	3,41E-01	3,41E-01
20	1,11E-01	<b>8,87E-02</b>	1,71E-01	1,49E-01	2,60E-01	2,50E-01	3,75E-01	3,46E-01

## Sonuçlar

Tiroid hastalığı şüphesi olanlardan toplanan veri ile oluşturulmuş veri seti, eleme ve normalizasyon yapıldıktan sonra YSA-BP ve YSA-PSO eğitim modellerine ayrı ayrı okutulmuş ve eğitim sağlanmıştır. Eğitimde elde edilen en düşük hata değeri her ne kadar YSA-BP'de olsa da, test verisi performansı olarak YSA-PSO daha başarılı sonuçlar vermiştir. Bu sonuçlar YSA-BP'nin eğitim veri setini ezberlediğini göstermektedir. YSA-PSO eğitim modelinde test performansı olarak erişilen en düşük hata değeri  $8,87E-02$  iken YSA-BP'de bu değer  $1,05E-01$  olmuştur. Bu sonuçlar, YSA-PSO eğitim modelinin Tiroid hastalığının teşhisinde başarılı bir model olduğunu göstermiştir.

## Referanslar

- [1] D. Demner-Fushman, W. W. Chapman, and C. J. McDonald, "What can natural language processing do for clinical decision support?," *J. Biomed. Inform.*, vol. 42, no. 5, pp. 760–772, Oct. 2009.
- [2] G. (Peter) Zhang and V. L. Berardi, "An investigation of neural networks in thyroid function diagnosis," *Health Care Manag. Sci.*, vol. 1, no. 1, pp. 29–37, 1998.
- [3] R. Quinlan, "UCI Machine Learning Repository [<http://archive.ics.uci.edu/ml>]," 1987. .
- [4] M. Galli, I. Zoppis, G. De Sio, C. Chinello, F. Pagni, F. Magni, and G. Mauri, "A Support Vector Machine Classification of Thyroid Bioptic Specimens Using MALDI-MSI Data," *Adv. Bioinformatics*, vol. 2016, pp. 1–7, 2016.
- [5] K. Geetha and S. Santhosh Baboo, "Efficient thyroid disease classification using differential evolution with SVM," *J. Theor. Appl. Inf. Technol.*, vol. 88, no. 3, pp. 410–420, Jun. 2016.
- [6] D. Y. Liu, H. L. Chen, B. Yang, X. E. Lv, L. N. Li, and J. Liu, "Design of an enhanced Fuzzy k-nearest neighbor classifier based computer aided diagnostic system for thyroid disease," *J. Med. Syst.*, vol. 36, no. 5, pp. 3243–3254, Oct. 2012.
- [7] V. Prasad, T. S. Rao, and M. S. P. Babu, "Thyroid disease diagnosis via hybrid architecture composing rough data sets theory and machine learning algorithms," *Soft Comput.*, vol. 20, no. 3, pp. 1179–1189, Mar. 2016.
- [8] A. Keleş and A. Keleş, "ESTDD: Expert system for thyroid diseases diagnosis," *Expert Syst. Appl.*, vol. 34, no. 1, pp. 242–246, Jan. 2008.
- [9] H. Makas and N. Yumusak, "A comprehensive study on thyroid diagnosis by neural networks and swarm intelligence," in *2013 International Conference on Electronics, Computer and Computation (ICECCO)*, 2013, pp. 180–183.
- [10] F. Gorunescu and S. Belciug, "Boosting backpropagation algorithm by stimulus-sampling: Application in computer-aided medical diagnosis," *J. Biomed. Inform.*, vol. 63, pp. 74–81, Oct. 2016.
- [11] N. YALÇIN, G. TEZEL, and C. KARAKUZU, "Epilepsy diagnosis using artificial neural network learned by PSO," *TURKISH J. Electr. Eng. Comput. Sci.*, vol. 23, pp. 421–432, 2015.
- [12] K. Khan and A. Sahai, "A Comparison of BA, GA, PSO, BP and LM for Training Feed forward Neural Networks in e-Learning Context," *Int. J. Intell. Syst. Appl.*, vol. 4, no. 7, pp. 23–29, Jun. 2012.
- [13] N. Haridas and N. Devi.M, "PSO learning on artificial neural networks," in *Proceedings of the 1st Amrita ACM-W Celebration on Women in Computing in India - A2CWic '10*, 2010, pp. 1–6.
- [14] S. Haykin, *Neural Networks: A Comprehensive Foundation*, 2nd ed. Prentice Hall PTR, 1999.
- [15] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proceedings of ICNN'95 -*

*International Conference on Neural Networks*, vol. 4, pp. 1942–1948.

- [16] 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.
- [17] E. Alba and R. Marti, *Metaheuristic Procedures for Training Neural Networks*, 1st ed., vol. 36. Boston, MA: Springer US, 2006.