

PARÇACIK SÜRÜ OPTİMİZASYONU İLE BULANIK-NÖRAL KONTROLÖR EĞİTİMİ VE BENZETİM ÖRNEKLERİ

Cihan KARAKUZU

Elektronik ve Haberleşme Mühendisliği Bölümü
Mühendislik Fakültesi
Kocaeli Üniversitesi, 41040, İzmit, Kocaeli
e-posta: cihankk@kou.edu.tr

Anahtar sözcükler: Parçacık Sürüsü Optimizasyonu, Bulanık-Nöral Ağ Eğitimi, Kontrol Benzetimi

ABSTRACT

This paper describes the effective utilization of particle swarm optimization (PSO) to train a Fuzzy-Neural controller (FNC) for two samples of high nonlinear systems. First sample system is continuous stirred tank reactor (CSTR) and the second is Van-Der-Pole (VDP) oscillator. FNCs are learned by PSO to hold the selected state variable at fixed set point. While the controller's antecedent parameters are hold at proper fixed value, its rule (consequent) parameters are optimized with PSO. The superiority of this learning technique is not to need the partial derivative for the parameter learning. The results show that fuzzy controllers learned by PSO have exhibited good control performances.

1. GİRİŞ

Son yıllarda, parçacık sürü optimizasyonu (PSO) zor ve karmaşık problemleri çözümünde etkili bir teknik olarak kullanılmaya gelmektedir. Bu teknik ilk kez Eberhart ve Kennedy [1] tarafından önerilmiştir. Türev bilgisi gerektirmeksizin optimizasyon yapması en büyük üstünlüğü olarak görülebilir. Bu teknik, problemin çözümü için önceden belirlenen parametrelere (parçacık) rasgele atanmış aday çözümlerden oluşan bir popülasyonla (sürü) ile başlar. Her bir PSO algoritması iterasyonunda, sürüdeki her bir parçacık arama uzayındaki kendi pozisyonunu o iterasyona kadar bulunmuş en iyi parçacık pozisyonuna dayalı olarak ayarlar.

PSO'nun parçacık pozisyonunu sürüdeki diğer parçacıklarla dinamik bir etkileşim içinde uyarlamalı (adaptif) olarak ayarlama yeteneği Bulanık-Nöral Kontrol (BNK) problemlerinde parametre öğrenmesi için kullanmaya uygundur. Eğer ilgilenilen sistemi kontrol etmek için en uygun parametreler PSO ile belirlenebilirse, BNK tasarım problemi çözülmüş olur. Bu bildirinin ana teması bu noktadır. Bildiri birinci dereceden Sugeno tipi bir bulanık kontrolörün kural parametrelerinin PSO ile nasıl belirleneceğini açıklar,

yüksek eğriselliğe sahip iki sistemin kontrolü için bu yolla eğitilen bulanık kontrolörlerin başarımını irdeler.

Bildiride çalışma şu düzen içinde anlatılmıştır: İkinci bölümde klasik PSO tanımlanmış, üçüncü bölümde çalışılan iki örnek sistemin davranışı sunulmuş, kullanılan bulanık kontrolör yapısı ve bu yapının PSO ile nasıl eğitileceği üzerinde durulmuştur. Dördüncü bölümde önerilen yaklaşımla elde edilen sonuçlar verilmiştir. Beşinci ve son bölümde ise yorumlar ve ileriye dönük çalışmalar üzerinde durulmuştur.

2. PARÇACIK SÜRÜ OPTİMİZASYONU

Parçacık sürü algoritması hayvanlar arasındaki sosyal etkileşimden esinlenen bir optimizasyon tekniğidir. PSO algoritması içinde modellenen sosyal etkileşim arama uzayının en anlamlı bölgesine doğru hareket eden ve parçacıklar olarak adlandırılan bir bireyler popülasyonuna rehberlik etmek için kullanılır.

PSO çok boyutlu bir arama uzayında sürü parçacıklarının arama davranışına dayalı iteratif bir yöntemdir. Her bir iterasyonda, tüm parçacıkların hızları ve pozisyonları güncellenir. PSO'da her parçacık problem için bir çözüm adayı olarak değerlendirilebilir. Algoritmada bu çözüm adayı (i. parçacık) aşağıdaki eşitlikte verilen bir vektör olarak tanımlanır.

$$\vec{p}_i = (p_{i1}, p_{i2}, p_{i3}, \dots, p_{iN}) \quad (1)$$

Her parçacık arama uzayında iki önemli etkene bağlı olarak uçuşur: o iterasyona kadar kendisinin en iyi pozisyonu (yerel en iyi, p_{yei}) ve tüm popülasyon içinde en iyi (küresel en iyi, p_{kei}) pozisyona sahip parçacığın pozisyonu.

$$\vec{p}_{yei} = (p_{yei1}, p_{yei2}, p_{yei3}, \dots, p_{yeiN}) \quad (2)$$

$$\vec{p}_{kei} = (p_{kei1}, p_{kei2}, p_{kei3}, \dots, p_{keiN}) \quad (3)$$

i. parçacığın pozisyonundaki değişim hızı parçacık hızı (v_i) olarak adlandırılır ve eşitlik (4)'de verilen bir vector olarak tanımlanır.

$$\vec{v}_i = (v_{i1}, v_{i2}, v_{i3}, \dots, v_{iN}) \quad (4)$$

Parçacıkların hızı bir sonraki adımda kullanılacak parçacıkları belirlemek için eşitlik (5) ile güncellenir. i. Parçacığın yeni değeri de eşitlik (6) ile belirlenir [2].

$$v_i(n) = \chi(v_i(n-1) + \varphi_1 r_1 (p_{\text{yei},i} - p_i(n-1)) + \varphi_2 r_2 (p_{\text{kei},i} - p_i(n-1))) \quad (5)$$

$$p_i(n) = p_i(n-1) + v_i(n) \quad (6)$$

$$\chi = \frac{2}{|2 - \varphi - \sqrt{\varphi^2 - 4\varphi}|}, \quad \varphi = \varphi_1 + \varphi_2, \quad \varphi > 4 \quad (7)$$

Şekil 1'de algoritmanın genel işleyiş yapısı verilmiştir. Şekilde verilen akıştan da anlaşılacağı üzere algoritma problemin çözümü için aday parçacık popülasyonunun (sürünün) rasgele oluşturulması ile başlar. Sürüdeki her bir parçacığın belirlediği çözüm için aday parametrelerle sistem çözümü yapılır. Elde edilen çözümden problemin yapısına göre önceden belirlenen bir ölçüt ile parçacığın uygunluğu sayısal olarak belirlenir. Bu işlem sürüdeki tüm parçacıklar için tekrarlanır ve içlerindeki en iyi uygunluk değerine sahip olan parçacık küresel en iyi olarak etiketlenir. İkinci iterasyon için yeni parçacık değerleri belirlenir. İkinci ve sonraki adımlarda her parçacık için yerel en iyi parçacık, önceki adımlardaki en iyi uygunluk değerini alan aynı indisli parçacık olarak belirlenirken, küresel en iyi parçacık ise o iterasyona kadarki tüm parçacıklar içinden en iyi uygunluk değerini veren parçacık olarak etiketlenir ve bunlara göre güncellenir.

Rasgele başlangıç sürüsünü oluştur. (P adet parçacık) tekrarla
i=1'den P'ye kadar yap
p_i parçacığı ile sistemi çözümler
eğer uygunluk(p_i) < uygunluk($p_{\text{yei},i}$) **ise** $p_{\text{yei},i} = p_i$
eğer uygunluk(p_i) < uygunluk($p_{\text{kei},i}$) **ise** $p_{\text{kei},i} = p_i$
i. parçacığın hızını Eşitlik (5) ile hesapla;
i. parçacığı Eşitlik (6) ile güncelle;
son
sonlandırma kriteri sağlanıncaya kadar

Fig. 1. PSO algoritmasının genel işleyiş yapısı

3. ÖRNEK SİSTEMLER VE BULANIK KONTROLÖR YAPISI

Bu bölümde önerilen yöntemin etkinliğinin gösterilmesi amacıyla kullanılan iki adet sistem ve bunların davranışı ve bu sistemleri kontrol etmek üzere PSO ile eğitilecek bulanık kontrolörün yapısı açıklanacaktır.


3.1 Kontrol edilecek örnek sistemler ve davranışları

Bu çalışmada kullanılan birinci örnek sistem sürekli karıştırmalı tank reaktör (SKTR) sistemidir. Sistem


denklem (8)'deki matematiksel model ile verilir. İkinci örnek sistem ise denklem (9)'daki matematiksel model ile verilen Van-Der-Pol (VDP) osilatör sistemidir [3, 4].

$$\begin{aligned} \frac{dx_1}{dt} &= -x_1 + Da(1-x_1) \exp\left[\frac{x_2}{1+x_2/\gamma}\right] \\ \frac{dx_2}{dt} &= -x_2 + BDa(1-x_1) \exp\left[\frac{x_2}{1+x_2/\gamma}\right] - \beta(x_2 - x_{2c}) + d + \beta u \end{aligned} \quad (8)$$

x_1, x_2 boyutsuz tepken (reaktant) değişimi ve sıcaklık durum değişkenleri; Da , Damköhler sayısı ve d ve u sırasıyla besleme sıcaklığındaki sapma bozucusu ve reaktör sıcaklığı kontrol değişkenidir. Benzetimlerde $Da=0.135$, $B=11$, $\beta=1.5$ ve $\gamma=20$ alınmıştır. Sistemin kontrolsüz ($u=0$) davranışı Şekil 2'de, $u=0.1$ için davranışı da Şekil 3'de verilmiştir. Görüleceği üzere sistem yüksek eğriselliğe sahiptir.



Şekil 2. SKTR sisteminin kontrolsüz davranışı




Şekil 3. SKTR sisteminin $u=0.1$ için davranışı

$$\begin{aligned} \frac{dx_1}{dt} &= x_2 \\ \frac{dx_2}{dt} &= -x_1 + a(1-x_1^2) + u \end{aligned} \quad (9)$$

VDP sisteminin benzetimlerinde $a=1$ alınmıştır. x_1, x_2 boyutsuz durum değişkenleri ve u ise kontrol değişkenidir. Sistemin $x(0)=[0 \ 0.1 \ 0.1]^T$ başlangıç

koşulları için kontrolsüz davranışı Şekil 4'de verilmiştir. Görüleceği üzere sistem kaotik davranış göstermektedir.



Şekil 4. VDP sisteminin kontrolsüz davranışı

3.2 Bulanık kontrolör yapısı ve PSO ile eğitim alt yapısı

Bu çalışmanın amacı yukarıda tanımlanan sistemlerde kontrol edilecek değişkeni istenen ön ayar (set) değerinde tutacak bulanık kontrolörün parametrelerinin PSO ile belirlemektir. Bu amaçla SKTR için sıcaklık değişkeni (x_2) kontrol edilecek değişkendir. Diğer durum değişkeni serbesttir. Benzer şekilde VDP için ise x_1 kontrol edilecek değişkendir.

Bu sistemleri kontrol etmek için Şekil 5'deki gibi iki girişli standart birinci dereceden Sugeno bulanık modeli kullanılmıştır. Cebirsel çarpım T-norm, gauss üyelik fonksiyonlu ve ağırlıklı ortalama durulandırılmalı bir Sugeno modeli matematiksel olarak eşitlik (10)'daki gibi ifade edilebilir.

$$f(x, y) = \frac{\sum_{i=1}^R (p_i x + q_i y + r_i) \exp\left(-\frac{1}{2} \left(\frac{x - c_{xi}}{\sigma_{xi}}\right)^2\right) \exp\left(-\frac{1}{2} \left(\frac{y - c_{yi}}{\sigma_{yi}}\right)^2\right)}{\sum_{i=1}^R \exp\left(-\frac{1}{2} \left(\frac{x - c_{xi}}{\sigma_{xi}}\right)^2\right) \exp\left(-\frac{1}{2} \left(\frac{y - c_{yi}}{\sigma_{yi}}\right)^2\right)} \quad (10)$$

Eşitlikteki R bulanık kural sayısını; c_i ve σ_i sırasıyla i. kurala giriş teşkil eden gauss üyelik fonksiyonlarının merkezi ve varyansını; p_i , q_i ve r_i i. kurala ait parametrelerdir.

Bu çalışmada bulanık sistemin girişleri ön ayar (set) değer ile sistem çıkışı arasındaki hata (e) ve hatanın değişimi (de) dir. e girişi için 5, de girişi için ise 3 gaus biçimli üyelik fonksiyonu (ÜF) kullanılmıştır (R=15). ÜF'lerin merkezleri ilgili değişkenin değişim aralığında düzgün dağıtılmıştır. ÜF'lerin varyansları için uygun değerler atanmıştır. Bu parametreler bu değerlerde sabit tutulmuşlardır. Kural parametreleri ise PSO ile belirlenmiştir. Şu halde PSO'da sürü (11) nolu eşitlikte verilen türden parçacıklardan oluşur.

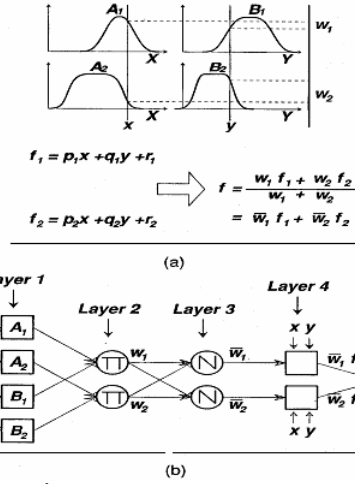


Fig. 5. a) İki-girişli birinci dereceden Sugeno bulanık çıkarımı; b) Eşdeğer ANFIS mimarisi [5].

$$\vec{p}_i = (p_i, q_i, r_i, p_2, q_2, r_2, \dots, p_R, q_R, r_R) \quad (11)$$


Eşitlik (11)'den de anlaşılacağı üzere optimum çözümü 3R boyutlu uzayda arayacaktır. Parçacıkların uygunluk ölçümü (12) eşitliği ile hesaplanmıştır. Bu çalışmada bulanık modelin bir kontrolör olarak çalışması istendiği ve uygunluk ölçütü olarak sistemin zaman kursu boyunca bir adım çalıştırılması sonucunda elde edilen hataların ortalaması uygunluk ölçütü olarak tanımlandığı için, en küçük uygunluk ölçütünü sağlayan parçacık en iyi parçacıktır. Bu sebeple PSO işletilirken bu ölçütün sürekli azalır seyir izlemesi beklenir.

$$J_i = \frac{1}{N} \sum_{i=1}^N e_i^2 \quad (12)$$


4. PSO İLE EĞİTİLEN BULANIK KONTROLÖRÜN BAŞARIMI

Önceki bölümde tanımlanan sistemleri önceden belirlenen set değerinde kontrol edecek birer bulanık kontrolörün ÜF parametreleri sabit tutulurken, kural parametreleri PSO ile Şekil 1'de verilen yapıda çalışan bir program aracılığıyla belirlenmiştir. PSO 10 adet parçacıktan oluşan sürü ile işletilmiştir. Algoritma en fazla 100 adım çalıştırılmıştır.

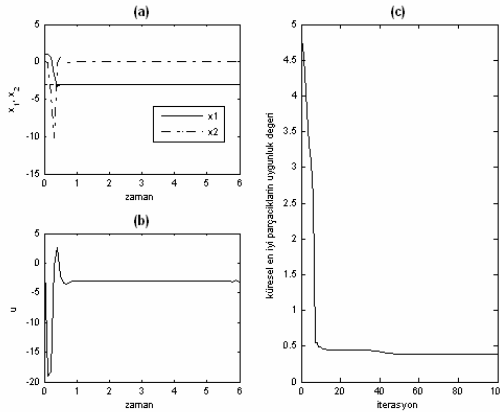
Şekil 6'da $d=0.1$ bozuculu SKTR'yi bu sistem için optimum değer olan 1.13 set değerinde tutmak için PSO ile eğitilen bulanık kontrolörün başarımı verilmiştir. Şekilden de görüleceği üzere sistemde bozucu var iken bile oldukça iyi başarımla elde edilmiştir. Şekil 7'de de $x_{2set}=0$ için eğitilen kontrolörün başarımı verilmiştir. Şekilden de görüleceği üzere diğerinden farklı olarak SKTR'nin başlangıç koşulları $x(0)=[0 \ 1]^T$ alınmıştır. Şekil 8'de ve Şekil 9'da sırasıyla DVP'yi $x_{1set}=-3$ ve $x_{1set}=4$ set değerinde tutmak için PSO ile eğitilen bulanık kontrolörün başarımı verilmiştir. Şekil 10 ve 11'de ise $x_{1set}=4$ için eğitime başlarken ve eğitim sonunda kontrolörün gerçeklediği yüzeyler verilmiştir. Görüleceği üzere PSO kontrolörü ilgili uzayda bambaşka bir konuma getirmiştir. Benzetimlerde başlangıç koşulları $x(0)=[1 \ 0]^T$ alınmıştır.



Şekil 6. SKTR'ı 1.13 set değerinde tutmak için eğitilen bulanık kontrolörün başarımı (a), ürettiği çıkış (b) ve eğitim boyunca küresel en iyi parçacıklara ilişkin uygunluk değerinin eğitim boyunca değişimi (c).

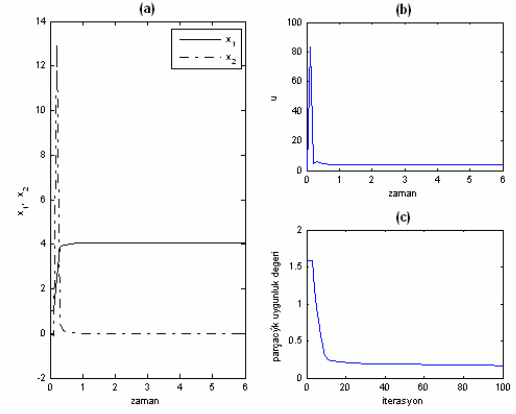


Şekil 7. SKTR'ı $x_{2set}=0$ değerinde tutmak için eğitilen bulanık kontrolörün başarımı (a), ürettiği çıkış (b) ve eğitim boyunca küresel en iyi parçacıklara ilişkin uygunluk değerinin eğitim boyunca değişimi (c).




Şekil 8. VDP'yi $x_{1set}=-3$ değerinde tutmak için eğitilen bulanık kontrolörün başarımı (a), ürettiği çıkış (b) ve eğitim boyunca küresel en iyi parçacıklara ilişkin uygunluk değerinin eğitim boyunca değişimi (c).


Şekil 9'da başarımı verilen bulanık kontrolörün eğitimine rasgele atanmış Tablo 1'de verilen değerlerle başlanmış olup, eğitim sonunda Tablo 2'de verilen kural parametreleri bulunmuştur. Verilen tablolardaki parametre değerlerinden ve bu parametrelerle elde edilen kontrol yüzeylerinden de görüleceği üzere; parçalıklar arama uzayında uygun



Şekil 9. VDP'yi $x_{1set}=4$ değerinde tutmak için eğitilen bulanık kontrolörün başarımı (a), ürettiği çıkış (b) ve eğitim boyunca küresel en iyi parçacıklara ilişkin uygunluk değerinin eğitim boyunca değişimi (c).




Şekil 10. VDP'yi $x_{1set}=4$ değerinde tutmak için eğitilecek bulanık kontrolörün eğitim öncesi başlangıç yüzeyi



Şekil 11. VDP'yi $x_{1set}=4$ değerinde tutmak için eğitilen bulanık kontrolörün eğitim sonrası kontrol yüzeyi

pozisyonlara yönlendirilmiştir. PSO algoritması işletilirken $\varphi_1=\varphi_2=2.05$ alınmıştır. r_1 ve r_2 rasgele her iterasyonda (0,1) aralığında rasgele üretilmiştir. Parçacık hızları ise sezgisel olarak belirlenmiş $[v_{min}, v_{max}]$ değerleri ile sınırlandırılmıştır. Şekil 12'de, Şekil 9'da sonuçları verilen eğitim boyunca sürüdeki 10ncu parçacığın 45nci elemanı yani

bulanık kontrolörün 15nci kuranlının r parametresinin değişimi eğitim seyri hakkında fikir sahibi olunması amacıyla verilmiştir.



Şekil 12. Sürüdeki bir parçacığın bir elemanının eğitim boyunca r parametresinin değişim seyri

Tablo 1. VDP'yi $x_{iset}=4$ değerinde tutmak için eğitilen bulanık kontrolörün eğitim öncesi kural parametreleri

R. N	p	q	r
1	1,265	-1,0045	1,3328
2	0,20179	-0,91684	-0,22171
3	0,3461	-1,3704	0,39182
4	0,3461	-1,3704	0,39182
5	0,40558	0,15567	-0,5574
6	-0,80563	-0,32598	-0,42617
7	1,3458	-0,67665	-0,20328
8	-0,28758	0,15013	0,10559
9	-0,72326	0,39312	-0,015576
10	-1,9889	1,5778	0,2968
11	-0,90291	-0,24542	-0,96783
12	0,018962	-1,4907	-0,79458
13	0,31861	-0,57399	0,66151
14	-0,95957	-0,49456	-0,43508
15	0,11941	0,0349	-1,104

Tablo 2. VDP'yi $x_{iset}=4$ değerinde tutmak için eğitilen bulanık kontrolörün eğitim sonrası kural parametreleri

R. N	p	q	r
1	25,05	-3,268	23,094
2	-4,2505	-10,588	3,7138
3	26,041	-22,198	10,188
4	6,1115	-24,625	20,138
5	1,5182	1,4497	-19,032
6	-1,5179	-27,532	-12,47
7	17,496	7,6003	23,841
8	-1,8161	18,999	2,3205
9	8,7998	17,336	-13,957
10	24,138	-5,1733	23,72
11	10,483	3,1608	33,32
12	30,206	-29,01	-4,9674
13	3,4865	-3,3897	-3,4648
14	9,5319	-0,42672	15,585
15	-17,99	10,699	-22,281

5. SONUÇLAR ve ÖNERİLER

Bu çalışma bulanık-nöral ağ kontrolörün PSO ile eğitimi ve elde edilen sonuçları sunmuştur. Önerilen yöntemde, kontrolörün ÜF parametreleri önceden belirlenen değerlerde sabit tutulurken kural parametrelerinin belirlenmesi PSO ile yapılmaktadır. Verilen sonuçlardan da anlaşılacağı üzere, çalışmada bulanık-nöral ağ kontrolör sabit set değerler için eğitilmiştir. Bu set değerler için eğitimin gerçekleştirildiği verilen sonuç şekillerinde görülmektedir. Kullanılan yöntemin en büyük üstünlüğü klasik optimizasyon algoritmalarından farklı olarak türev bilgisine ağır matematiksel

hesaplamaya ihtiyaç duymamasıdır. Bu üstünlük eğer çalışılan sistemin modelinin bilinmediği durumlarda çok belirgin olarak ortaya çıkar ve kıymet kazanır.

Şekil 6-9'da verilen sonuçlardan da görüleceği üzere; eğitimin başarısı oldukça iyidir. Fakat set değerinin sürekli değiştiği (örneğin sinüs biçiminde) durumlarda çok tatmin edici sonuçlara varılamamıştır. Bu problem küresel en iyi kontrolör elde edememe ile sonuçlanır.

Bu çalışmada verilen bulanık-nöral ağ kontrolör eğitimi yaklaşımı ağıdaki tüm parametreleri kapsayacak şekilde geliştirilebilir. Fakat bu geliştirme yüksek boyutlu parçacıklar ile karmaşık işlemlerin işletilmesinin getirdiği işlem karmaşıklığı ve yüküne sebep olabilir. Bu sorun ÜF parametreleri için ayrı, kural parametreleri için de ayrı parçacıkların kıyaslamalı çaprazlanması ile aşılabılır. Kısaca yukarıda değinilen iki problem yazarın gelecek çalışmalarına yön verecektir.

KAYNAKLAR

- [1] J. Kennedy and R. C. Eberhart, "Particle swarm optimization," in Proc.IEEE Int. Conf. Neural Netw. IV, 1995, pp. 1942–9148.
- [2] Daniel Parrott and Xiaodong Li, "Locating and Tracking Multiple Dynamic Optima by a Particle Swarm Model Using Speciation", IEEE Transaction on Evolutionary Computation, Vol. 10, NO. 4, August 2006, pp. 440-458.
- [3] Y. Oysal, Y. Becerikli, A. F. Konar, "Generalized modeling principles of a nonlinear system with a dynamic fuzzy network", Computers and Chemical Engineering 27 (2003), pp. 1657-1664.
- [4] Y. Becerikli, Nöro-Optimal Kontrol, Doktora Tezi, Fen Bilimleri Enstitüsü, Sakarya Üniversitesi,
- [5] J.-S.R. Jang, C.-T. Sun, E. Mizutani, Neuro-Fuzzy and Soft Computing, Prentice Hall, Upper Saddle River NJ, 1997.

Dr. Cihan Karakuzu, Lisans eğitimini 1993'de Yıldız Teknik Üniversitesi Kocaeli Mühendislik Fakültesi Elektronik ve Hab. Mühendisliği Bölümünde tamamladı. Yüksek Lisans ve Doktorasını sırasıyla 1998 ve 2003 yıllarında Kocaeli Üniversitesi Fen Bilimleri Enstitüsünden aldı. Halen Kocaeli Üniv., Müh. Fak., Elektronik ve Hab. Müh. Bölümü öğretim üyesidir. Çalışma alanları yapay sinir ağları, bulanık mantık, bulanık-nöral sistem modelleme ve kontrol, akıllı denetim, rasgele arama algoritmalarıyla parametre optimizasyonu olarak özetlenebilir. Bu alanlarda yayımlanmış ulusal ve uluslar arası bir çok makale ve bildirisi vardır.