

Bulanık yapay sinir ağıyla model referans robot denetimi

Osman CANBERİ*, Ahmet KUZUCU

İTÜ Makine Fakültesi, Makine Mühendisliği Bölümü, Gümüşsuyu, İstanbul

Özet

Çok serbestlik dereceli robotların doğrusal olmayan dinamik modelinin detaylı bir şekilde elde edilmesi ve bu modelin denetim algoritması içinde gerçek zamanda uygulanması zordur. Bu çalışma kapsamında, yaklaşık robot modelini kullanan, uygulamaya yönelik, öğrenebilen ve öz uyarlamalı gelişmiş bir adaptif robot denetim yapısı elde edilmesi amaçlanmıştır. Bu yapıya ulaşabilmek için bulanık mantıkla denetim, yapay sinir ağları ve bunların bileşimi olan yapay sinir ağı temelli bulanık denetleyiciler incelenmiş ve model referans adaptif izleme sistemi yapısında, robot denetimi amaçlı bir bulanık yapay sinir ağı denetleyici (BUYSA) önerilmiştir. Bulanık yapay sinir ağı denetleyicinin temelini oluşturan gerçek zamanda yapı geliştirme ve parametre öğrenme algoritmaları tanıtılmıştır.

Anahtar Kelimeler: Robotik, doğrusal olmayan sistemler, bulanık yapay sinir ağıyla denetim, geriye yayılma, öğrenen manipülatör denetimi, öz yapılanmalı denetleyici.

Model reference robot control using fuzzy neural network

Abstract

Multi degree of freedom robot manipulators have nonlinear and complex dynamic characteristics. The use of computed torque etc. conventional type controllers require detailed manipulator dynamics model. Because of coupling effects between links, external disturbances, variation of payloads, frictions, saturation of actuators etc. obtaining the complicated nonlinear manipulator model and its real time implementation in control algorithm are difficult. In this study, fuzzy logic and artificial neural network have been combined together under model reference adaptive control structure to obtain a self-learning and self-tuning sophisticated adaptive robot controller (BUYSA). To achieve this controller structure, fuzzy logic control, neural networks, neuro-fuzzy control subjects have been investigated and a new neuro-fuzzy controller has been developed under the model reference adaptive system structure. Real time structure development and parameter learning algorithms, forming the basis of BUYSA, have been introduced. In the simulations implemented by proposed BUYSA, membership functions and number of fuzzy rules changed in real time in relation to dynamic characteristics of system, variation of system parameters and external disturbances, saturation of actuators, complexity of motion tasks and expected control quality. If degree of freedom of robot and/or complexity of motion tasks increase then huge calculations caused by necessity of bigger fuzzy neural network with bigger number of neurons have to be avoided. To achieve this, a separated structure that formed by fuzzy neural networks has been proposed.

Keywords: Nonlinear robotic systems, neuro-fuzzy control, back propagation, learning manipulator control, self-structuring controller.


*Yazışmaların yapılacağı yazar: Osman CANBERİ. ocanberi@robotek.com.tr; Tel: (216) 527 15 42.

Bu makale, birinci yazar İTÜ Makine Fakültesi'nde tamamlanmış olan "Bulanık yapay sinir ağıyla model referans robot denetimi" adlı doktora tezinden hazırlanmıştır. Makale metni 14.03.2003 tarihinde dergiye ulaşmış, 16.07.2003 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 30.06.2005 tarihine kadar dergiye gönderilmelidir.

Giriş

Bulanık mantık, denetim ve bilgi süreçlerinin birçoğu için güçlü bir problem çözme yöntemidir ve kesin olmayan bulanık bilgidan dikkate alınacak kadar basit bir şekilde kesin sonuçlar elde edilmesine olanak sağlar (Zadeh, 1965). Yapay sinir ağlarının en önemli özelliği öğrenilme yeteneğidir. Bulanık mantık ve yapay sinir ağlarının birbirlerini tamamlayıcı özelliklerinden faydalanarak birçok uygulama gerçekleştirilmiştir (Wang, 1993; Chen ve Chen, 1994; Buja ve Todesco, 1994). Model referans adaptif denetim yapısı, lineer olmayan özellikleri nedeniyle matematik modeli tam olarak kurulamayan sistemlerin, matematik modeli bilinen bir sistemin davranışını izlemesi esasına dayanır.

Gelenekselleşmiş güvenilir bir teknoloji haline gelen model referans adaptif denetim yapısını, bulanık mantık ve yapay sinir ağları gibi modern teknolojiler olan yapı taşlarıyla inşa etmek, bu üç teknolojinin birbirini tamamlayıcı etkisiyle ve birleşimlerinden ortaya çıkan sinerjiyle robot denetimine yeni bir yaklaşım getirecektir (Şekil 1).



Şekil 1. Tamamlayan teknolojiler

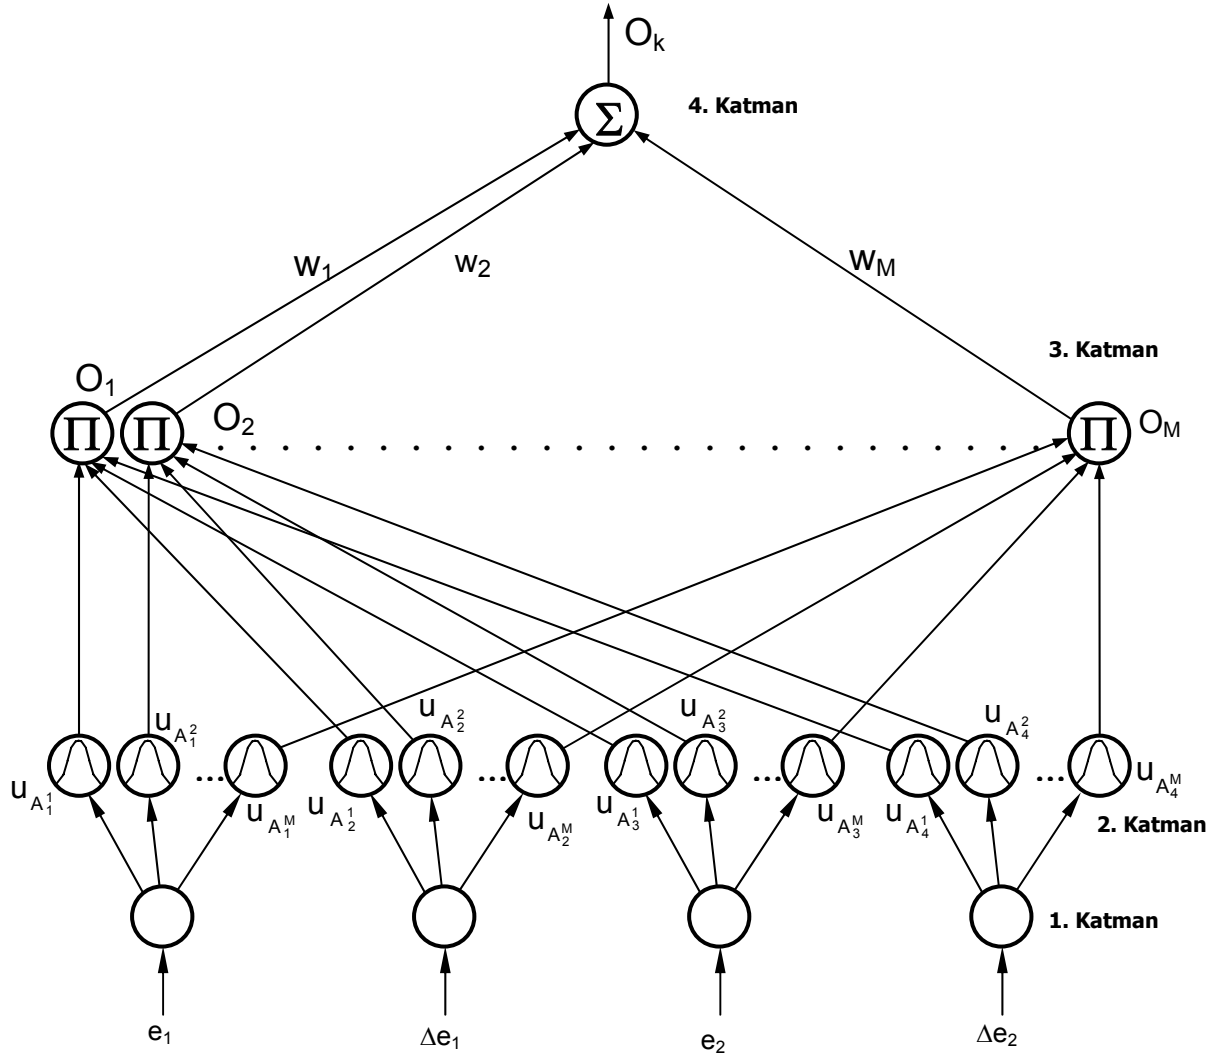
Bulanık yapay sinir ağı (BUYSA) denetleyici tasarımı

Robot dinamiğindeki belirsizliklerin kaynağı sürtünme özellikleri, eylemsizlik momenti gibi zamanla değişen sistem parametreleri, dışarıdan robota etkiyen kuvvetlerin, robotun taşıdığı yükün değiştiği durumlar, modelleme hataları

ve diğer doğrusal olmayan bozucu etkiler olabilir. Sadece robot dinamiğine bağlı bir denetim algoritması kullanarak arzu edilen performansı yakalamak zordur. Öğrenebilen bir denetleyici kullanıldığında, hesaplanmış moment gibi yöntemleri kullanan geleneksel denetleyiciler için gerekli olan “dinamik modelin ve model parametrelerinin hassas bir şekilde elde edilmesi zorunluluğu” önemini kaybeder. Öğrenebilen denetleyiciler robot hareket denetiminde her geçen gün daha yoğun kullanım alanı bulmaktadır (Koo, 2001; Lin ve Lee, 1996; Spooner ve Passino, 1996).

Robot denetiminde iyi sonuçlar veren model referans adaptif denetim sisteminin adaptasyon yeteneğini, dolayısıyla denetim hassasiyetini, hızını ve esnekliğini arttırmak, en önemlisi sisteme öğrenilme yeteneği kazandırmak için, hataya bağlı bir fonksiyonun çıkışlarını eğitim girişi kabul eden ve Şekil 2’deki yapay sinir ağı yapısında olan “çok eksenli bulanık denetleyici” önerilmiştir. Bu çalışmada önerilen bulanık yapay sinir ağı ise gerçek zamanda süreç elemanlarındaki üyelik işlevleri olan Gauss fonksiyonlarının tanım parametrelerini ve üyelik işlevi sayısını değiştirebilmektedir. Önerilen denetleyiciyi oluşturan bulanık yapay sinir ağı (BUYSA) ileri beslemeli ve çok katmanlıdır. BUYSA eş zamanlı olarak yapısal geliştirme ve parametre öğrenmesi yapabilmektedir. Yapay sinir ağının sinir hücreleri arasındaki bağlantı ağırlıklarını ve iletkenlikleri belirlemek için kullanılan gözlemcili veya gözlemcisiz öğrenme algoritmalarının büyük bölümü hassas ve yoğun eğitim veri takımlarını gerektirir (Lee ve Teng, 2000). Gerçek bir uygulamada bu eğitim veri takımlarını elde etmek oldukça zordur. Önerilen sistem, bulanık mantık denetleyicide kullanılan yapay sinir ağının gerçek zamanda öğrenmesi için oldukça kaba veri takımlarını da kullanabilmektedir (Lin, 1995).

BUYSA model referans adaptif denetim stratejisi, yaklaşık model olarak ikinci dereceden doğrusal bir diferansiyel denklem, gerçek zamanda öğrenmeyi sağlayan “delta adaptasyon kuralı” algoritması ve bulanık yapay sinir ağından oluşmaktadır (Şekil 3).

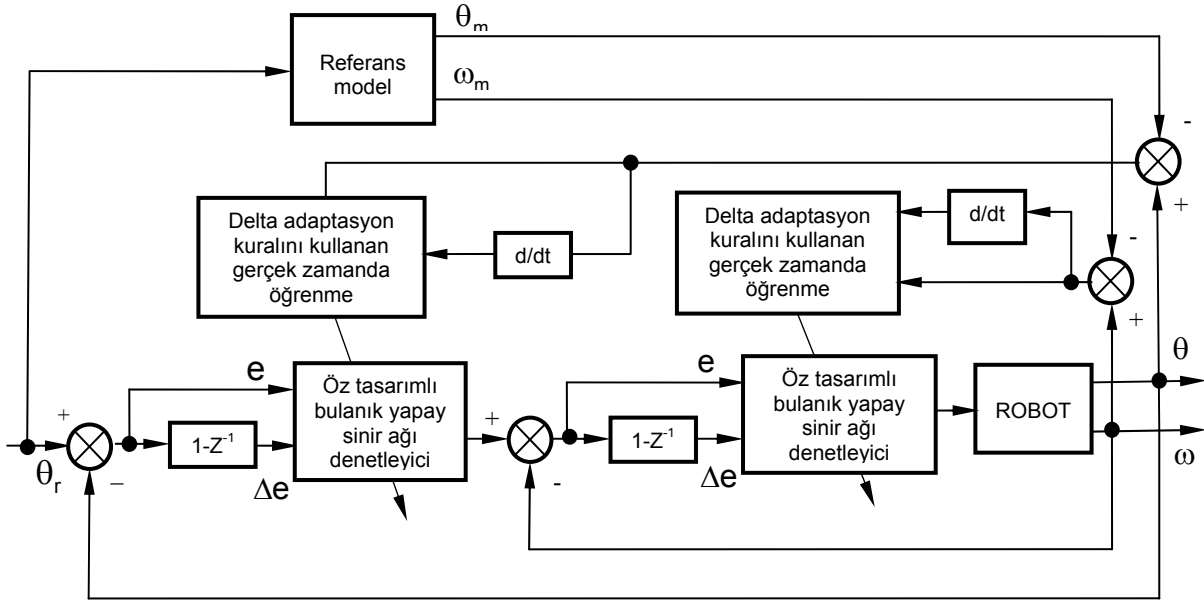


Şekil 2. İki serbestlik dereceli bir robotun konum ve hız denetimi için önerilen bulanık yapay sinir ağı denetleyicinin (BUYSA) şematik diyagramı

Ayrık bulanık yapay sinir ağı model referans adaptif denetleyici

Önerilen denetleyiciyle yapılan robot benzetimlerinde sürtünme özellikleri ve eylemsizlik momenti gibi zamanla değişen sistem parametreleriyle, dışarıdan robota etkiyen kuvvetlerin, robotun taşıdığı yükün değiştiği durumlarda oldukça iyi sonuçlar elde edilmiştir. Bununla birlikte robotun serbestlik derecesi ve hareket ödevlerinin nitelikleri arttıkça, istenilen kalitede bir denetimin yapılabilmesi için bulanık denetim sisteminin üyelik işlevi sayısının, dolayısıyla kural sayısının artması gereği ortaya çıkmıştır. Bu da yapay sinir ağının süreç elemanı sayısının artması

anlamına gelir. Süreç elemanı sayısının artması iterasyon sayısının dolayısıyla hesap yükünün artması yani gerekli olan kontrol çevrim zamanının uzaması sonucunu doğurur. Oysa robotlar gibi çok eksenli dinamik sistemlerin hareket ödevlerini istenilen kalitede yerine getirebilmeleri için, 1ms gibi oldukça kısa kontrol çevrim zamanına ihtiyaç duyulur. Bu çevrim zamanının uygulamaya bağlı olarak daha da kısa olması istenebilir. Denetleyicinin, çok eksenli robotlarda da istenilen performansı verebilmesi için, Şekil 3'te blok diyagramı verilen ve nispeten işlem yükü ve karmaşıklığı daha az olan "ayrık bulanık yapay sinir ağı" yapısı önerilmiştir.



Şekil 3. Ayrık BUYSA'lı hareket denetleyici

Bu sistemde robotun her bir serbestlik derecesi için model referans adaptif denetleyici yapısı altında iki adet bulanık yapay sinir ağı bulunur. Yapay sinir ağlarından ilki konum denetleyicisi rolünde olup ikincisi hız denetleyicisi işlevini görür.

Bulanık yapay sinir ağı yapısı

Bir yapay sinir ağı yapısını kullanarak bulanık çıkarımı gerçekleyebilmek için Şekil 2'deki bulanık yapay sinir ağı tasarlanmıştır. Bulanık çıkarım parametreleri yapay sinir ağının bağlantı ağırlıkları ile ve süreç elemanı işlevleri ile tanımlanır. Bulanık mantık sisteminin yapay sinir ağı kullanılarak ifade edilmesi, yapay sinir ağının öğrenme yeteneği sayesinde bulanık mantık parametrelerinin otomatik olarak ayarlanması avantajını sağlar. Robot denetimi amacı ile önerilen bulanık yapay sinir ağı sisteminin girişi, örneklenmiş bir hareketin konum ve hız yörüngeleridir.

Önerilen BUYSA katmanlarındaki süreç elemanlarının üyelik işlevleri izleyen maddelerde tanımlanmıştır.

1. *Katman*-Bu katman giriş katmanıdır ve girişler herhangi bir hesaplama yapılmadan ikinci katmana iletilirler. Şekil 2'de görüldüğü gibi bulanık yapay sinir ağının girişinde, robotun her

bir serbestlik derecesi için konum hatası "e" ve konum hatasının değişimi "Δe" olmak üzere toplam dört tane düğüm mevcuttur.

2. *Katman*-Bu katman giriş üyelik işlevlerini kapsar, katmandaki her bir düğüm 1. katmandaki giriş değişkenlerinden birinin dilsel etiketi olarak davranır ve hangi giriş değerinin hangi bulanık kümeye ne oranda ait olduğunu belirler. Her bir düğümde üyelik işlevi olarak Gauss fonksiyonu seçilmiştir.

$$u_{A_i} = \exp\left[-\frac{(x_i - m_{ji})^2}{\sigma_{ji}^2}\right] \quad (1)$$

m_{ji} : i'ninci giriş değişkeni x_i ile ilgili olan j'ninci terimin Gauss fonksiyonunun merkezi, σ_{ji} : i'ninci giriş değişkeni x_i ile ilgili olan j'ninci terimin Gauss fonksiyonunun genişliğidir.

m_{ji} ve σ_{ji} terimleri değiştirilerek aynı keskin nokta için değişik üyelik işlevleri elde edilebilir.

3. *Katman*-Bulanık kuralların işlediği bu katmanda, her bir düğüm bir bulanık mantık kuralının ön koşul kısmını temsil eder ve girişlerine gelen işaretlerini çarpıp çarpım sonucunu çıkarırlar. u_j , j'ninci kural düğümünün çıkışı göstermek üzere kuralın ateşleme gücü aşağıdaki

şekilde ifade edilir. Bu katmandaki kural sayısı hataya ve sistemden beklenen performansa göre gerçek zamanda artar.

$$O_j = \prod_i u_{A_j}(x_i) \quad (2)$$

4. Katman-Bulanık yapay sinir ağının ürettiği kumanda işareti bu katmandan çıkar. Katmanın işlevi “durulama”dır ve katmanda bulunan tek düğüme gelen işaretler toplanarak kumanda işareti oluşturulur. İfadede bağlantı ağırlığı ω_j , j’nci kuralın çıkış etki gücüdür. O_k ise bulanık yapay sinir ağının çıkışıdır.

$$O_k = \sum_{j=1}^M \omega_j O_j \quad (3)$$

Gerçek zamanda yapısal geliştirme ve parametre öğrenme algoritması

Önerilen sistemde yapısal geliştirme ve parametre öğrenmesi olmak üzere iki tip öğrenme algoritması kullanılmaktadır. Kumanda kalitesi ikinci katmandaki üyelik işlevlerinin geometrileriyle ilgili olduğu kadar sayılarıyla da ilgilidir. İkinci katmandaki her bir üyelik işlevine karşılık üçüncü katmanda kurallar bulunduğu için, üyelik işlevi sayısının artması, yanında kural sayısının da artmasını getirir. Birbirine çok benzemeyen üyelik işlevlerinin, dolayısıyla kural sayısının bir değere kadar artması üretilen kumanda işaretinin hassasiyetini de artırır. Fakat bu aynı zamanda işlem yükünün de artması anlamına gelir. İşlem yükünü sınırlayabilmek için kullanılan donanımın hızına ve sistemden beklenen denetim kalitesine göre kural sayısının artışı sınırlayacak ölçütler geliştirilmiştir. Bir başka deyişle yapısal geliştirme, uygun giriş uzayı bulanık bölüntüleri bulmak ve üretilen kuralların sayısı ile her bir giriş değişkeninin söylem evreni üzerindeki bulanık kümelerin sayısını en aza indiren bulanık mantık kurallarını ortaya koymak için kullanılır.

Gauss fonksiyonunun, sırasıyla merkezini ve genişliğini belirleyen m_{ji} ve σ_{ji} değişkenlerinin ayarlanması işi “parametre öğrenme” olarak adlandırılır. Parametre öğrenmesi gözlemcili bir

öğrenmedir. m_{ji} ve σ_{ji} terimleri değiştirilerek aynı keskin noktada değişik üyelik işlevleri elde edilebilir. Sonuç kısmındaki bağlantı ağırlıkları ve üyelik işlevlerinin parametreleri, verilen enerji fonksiyonunu minimize eden geriye yayılma algoritması ile kaynaklarda verilen yöntemlere benzer şekilde ayarlanmıştır (Jang, 1992; Nauck ve Kruse, 1993). Bulanık yapay sinir ağı, başlangıçta her bir giriş için birer üyelik işlevi, sadece bir kural düğümü, bunların yanında giriş ve çıkış düğümlerini içerir. Üyelik işlevi ve kural düğümleri, model hata ifadesinin sonucu olarak geri beslenen işaretlere göre, yapısal geliştirme ve parametre öğrenme süreçleri sırasında denetleyicinin kendisi tarafından gerçek zamanda üretilirler.

Yapısal geliştirme evresi

Yapısal geliştirmenin gerekliliği, model hatasının öngörülen kabul edilebilir bir hatadan daha büyük olduğu durumlarda ortaya çıkar ve bu her kontrol çevrim zamanında denetlenir.

“Eğer $e_{\min} \leq KEH$ veya $\Delta e_{\min} \leq \Delta KEH$ ise yapıyı geliştir.”

e_{\min} :En küçük model hatası, Δe_{\min} :En küçük model hatasının değişimi, KEH:Öngörülmuş kabul edilebilir hatanın büyüklüğü, ΔKEH : Öngörülmuş kabul edilebilir hata değişiminin büyüklüğüdür.

Yapısal geliştirme yapılacak ise, bir sonraki aşamada 2. katmana yeni düğüm yani üyelik işlevi ve 3. katmana ilgili bulanık mantık kuralı eklenip eklenmeyeceğine karar verilir. Bunun için herhangi bir anda mevcut olan 3. katman çıkışlarının en etkili, yani ateşleme gücü en büyük olanının değeri, üyelik işlevi ve kural sayısının artışı sınırlamak amacıyla daha önceden belirlenmiş bir eşik değeriyle kıyaslanır. Eğer 3. katmanın nöronlarından ateşleme gücü en yüksek olanının çıkışı eşik değerinden düşük ise yeni bir üyelik işlevi ve buna bağlı kural üretilir.

$$EBAG = \max_{1 \leq j \leq M} O_j \quad (4)$$

“Eğer $EBAG \leq ED$ ise yeni üyelik işlevi üret”

M:Herhangi bir anda mevcut olan kuralların sayısı, ED:Üyelik işlevi ve kural sayısının artışıını sınırlamak amacıyla daha önceden belirlenmiş 0 ile 1 arasındaki eşik değeri, EBAG:Üçüncü katman çıkışları olan O_j 'lerin en büyük ateşleme gücüdür.

Bu aşama da geçilirse yeni üretilen üyelik işlevi adayına ilk değerleri atanır. Yani bulanık yapay sinir ağına yeni eklenmesi düşünülen Gauss fonksiyonun sırasıyla merkezi ve genişliğine ilk değerleri verilir.

$$m_i^{(aday)} = x_i \quad (5)$$

$$\sigma_i^{(aday)} = \sigma_i \quad (6)$$

x_i :Yeni gelen veri, σ_i :Önceden belirlenmiş sabittir.

$m_i^{(aday)} = x_i$ ifadesinin kullanımında üyelik işlevi adayının ateşleme gücünün en büyük değeri olan 1 başlangıç değeri olarak alınabilir.

Aday üyelik işlevi, mevcut olanlara belirli bir orandan daha fazla benzer ise, denetleyici performansına fazla bir katkısı olamamasının yanında işlem yükünün gereksiz yere artmasına ve denetim sisteminin yavaşlamasına hatta şişerek (overflow) tıkanmasına neden olabilir. Yeni üretilen aday üyelik işlevinin mevcut olanlara belirli bir orandan daha çok benzemesini önlemek için aralarındaki benzerlik denetlenmelidir. Bunun için Şekil 4'te gösterilen basit yaklaşım kullanılabilir.

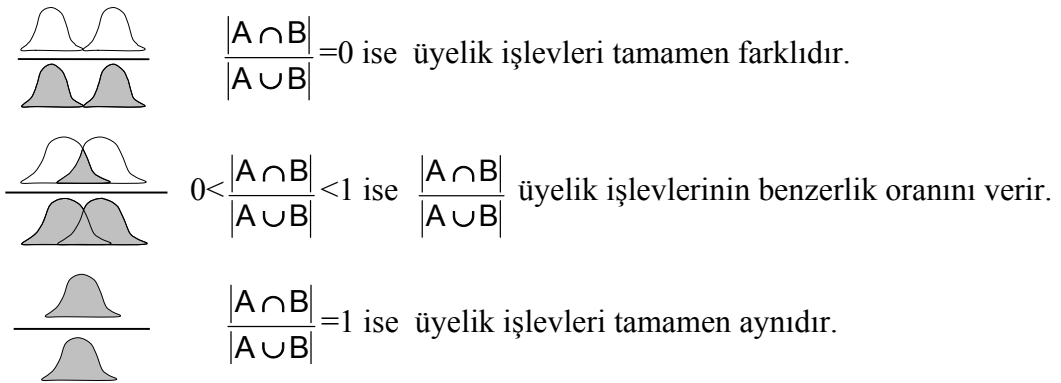
Benzerlik denetimi bütün x_i giriş değişkenleri için yapılır. Aday üyelik işlevi ile mevcut olan tüm üyelik işlevlerinin arasındaki benzerlik oranları hesaplanır, en büyük değer yani aday üyelik işlevinin en çok benzediği mevcut üyelik işlevi seçilir ve aralarındaki benzerlik oranı, denetim sisteminin hesaplama hızı ve sistemden beklenen hassasiyete göre önceden belirlenmiş olan "kabul edilebilir en büyük benzerlik oranı" kıyaslanır. Aday üyelik işleviyle mevcut en benzer üyelik işlevi arasındaki benzerlik oranı yukarıdaki kıstaslarla önceden belirlenmiş olan kabul edilebilir en büyük değerden daha küçük ise, aday üyelik işlevi yeni üyelik işlevi olarak bağlı olduğu yeni kuralla birlikte bulanık yapay sinir ağına eklenir ve kontrol çevrimine devam edilir. Eğer en büyük benzerlik oranı, önceden belirlenmiş kabul edilebilecek değerden daha büyükse aday üyelik işlevi ve buna bağlı olan bulanık kural iptal edilerek kontrol çevrimine devam edilir.

Benzerlik denetimi amacı ile üyelik işlevleri $u_A(x) = e^{-(x-m_1)^2/\sigma_1^2}$ ve $u_B(x) = e^{-(x-m_2)^2/\sigma_2^2}$ olan A ve B bulanık kümelerini varsayalım, $m_1 \geq m_2$ ise benzerlik oranı (7) numaralı ifade ile hesaplanır.

$$\frac{|A \cap B|}{|A \cup B|} = \frac{|A \cap B|}{\sigma_1 \sqrt{\pi} + \sigma_2 \sqrt{\pi} - |A \cap B|} \quad (7)$$

Bu oranın hesaplanmasından sonra

$m_{j1}, \sigma_{j1} \in B_j$ ve $m_i^{(aday)}, \sigma_i^{(aday)} \in A$ iken,



Şekil 4. Üyelik işlevi benzerliğinin araştırılması

$$\max_{1 \leq j \leq M(t)} \left(\frac{|A \cap B_j|}{|A \cup B_j|} \right) \leq \text{KBO ise} \quad (8)$$

$$\begin{cases} m_i^{(\text{aday})} = m_i^{(\text{yeni})} = x_i \\ \sigma_i^{(\text{aday})} = \sigma_i^{(\text{yeni})} = \sigma_i \\ M(t+1) = M(t) + 1 \end{cases} \text{ olur.}$$

A:Aday üyelik işlevi, B_j:Mevcut üyelik işlevleri, M:O anda mevcut olan düğüm sayısı, KBO:0 ile 1 arasında tanımlı kabul edilebilir benzerlik oranıdır.

Bir üyelik işlevinin üretimi yeni bir bulanık kuralın üretimine karşılık geleceğinden, yeni bulanık kuralla ilgili bağlantı ağırlığı $\omega^{(\text{yeni})}$ belirlenmelidir. Genellikle bağlantı ağırlığı $\omega^{(\text{yeni})}$ gelişigüzel seçilmiş veya önceden belirlenmiş bir sabit olabilir.

Parametre öğrenme evresi

Bulanık yapay sinir ağında parametre öğrenme algoritması, verilen giriş/çıkış çiftleri kümesini temel alan ağ parametrelerini ayarlayabilmek için oluşturulmuş adaptif kurallara dayanır. Eğer ağ parametreleri bir parametre vektörünün elemanları olarak kabul edilirse, öğrenme süreci, verilen bir ölçütü minimize edecek vektörün belirlenmesini içerir. Vektöre göre ölçüt fonksiyonelinin gradiyenti hesaplanır ve vektör negatif gradiyent boyunca ayarlanır. Yapay sinir ağında her katmandaki işlem ağırlık katsayıları çıkış başarımına bağlı olarak giriş katmanlarına doğru güncelleştirildiği için bu yöntem geriye yayılma (Back propagation) öğrenme kuralı olarak adlandırılır. Gözlemcili gradiyent eksiltme (Supervised Gradient Descent) kuralını kullanarak bulanık yapay sinir ağının gerçek zamanda parametre öğrenme algoritmasını elde etmek için önce ölçüt fonksiyoneli tanımlanır, daha sonra geriye yayılma yöntemini temel alan parametre öğrenme algoritması gerçekleştirilir. Bir ölçüt fonksiyoneli (9) ifadesindeki gibi tanımlanabilir.

$$E = \frac{1}{2}(\theta_m - \theta)^2 = \frac{1}{2}e_m^2 \quad (9)$$

4. Katman-Bu katmanın δ^4 hata terimi hesaplanarak geriye yayılacaktır. Hata hesabı aşağıdaki ifadeyle yapılır.

$$\delta^4 = -\frac{\partial E}{\partial O_k} = -\frac{\partial E}{\partial e_m} \frac{\partial e_m}{\partial O_k} = -\frac{\partial E}{\partial e_m} \frac{\partial e_m}{\partial \theta} \frac{\partial \theta}{\partial O_k} \quad (10)$$

bağlantı ağırlıkları izleyen ifadeyle güncellenir.

$$\omega(t+1) = \omega(t) - \eta_\omega \delta^4 O_j \quad (11)$$

η_ω : Bağlantı ağırlığının öğrenme oranı faktörüdür.

3. Katman-Bu katmanda sadece hata terimleri hesaplanır ve yayılır.

$$\delta_j^3 = -\frac{\partial E}{\partial O_j} = \left(-\frac{\partial E}{\partial O_k} \right) \left(\frac{\partial O_k}{\partial O_j} \right) = \delta^4 \omega_j \quad (12)$$

2. Katman-Bu katmandaki hata terimleri aşağıda gösterildiği gibi hesaplanır,

$$\delta_{ji}^2 = -\frac{\partial E}{\partial u_{A_i}} = \left(\frac{\partial E}{\partial O_k} \frac{\partial O_k}{\partial O_j} \right) \left(\frac{\partial O_j}{\partial u_{A_i}} \right) = \delta_j^3 \quad (13)$$

Üyelik işlevinin sırasıyla merkezini ve genişliğini belirleyen m_{ji} ve σ_{ji} parametreleri aşağıdaki ifadelerle güncellenir:

$$m_{ji}(t+1) = m_{ji}(t) + \eta_m \delta_{ji}^2 \frac{2(x_i^2 - m_{ji})}{(\sigma_{ji})^2} \quad (14)$$

$$\sigma_{ji}(t+1) = \sigma_{ji}(t) + \eta_\sigma \delta_{ji}^2 \frac{2(x_i^2 - m_{ji})^2}{(\sigma_{ji})^3} \quad (15)$$

η_ω :Üyelik işlevinin merkezini belirleyen m_{ji} parametreleri öğrenme oranı faktörü, η_σ :Üyelik işlevinin genişliğini belirleyen σ_{ji} parametreleri öğrenme oranı faktörüdür.

Dördüncü katmandaki δ^4 hata teriminin hesaplanabilmesi için (10) numaralı ifadedeki $\partial E / \partial O_k$ 'nin dolayısıyla da sistem jakobyeni olan $\partial \theta / \partial O_k$ 'nin kesin hesabı gereklidir. Fakat,

sistem parametrelerinin değişimi, sistem dinamiğinin doğrusal olmayışı ve hesabının zorluğu, dış ortamın sistem üzerindeki bozucu etkilerinin tam olarak ifade edilememesi nedeniyle sistem jakobyeninin tam olarak hesabı oldukça karmaşıktır. Bu sorunun üstesinden gelmek amacıyla delta adaptasyon kuralı önerilmiştir (Jang, 1992; Keller ve Tahani, 1992; Horikava vd., 1992). Bu çalışmada hatanın, jakobyeni hesaplamak yerine (16) numaralı ifadeden üretilmesi önerilmiştir.

$$\delta^4 = Ae_m + B \frac{\partial e_m}{\partial t} \quad (16)$$

A, B:Kazanç katsayıları, $e_m = \theta_m - \theta$:Model hatasıdır.

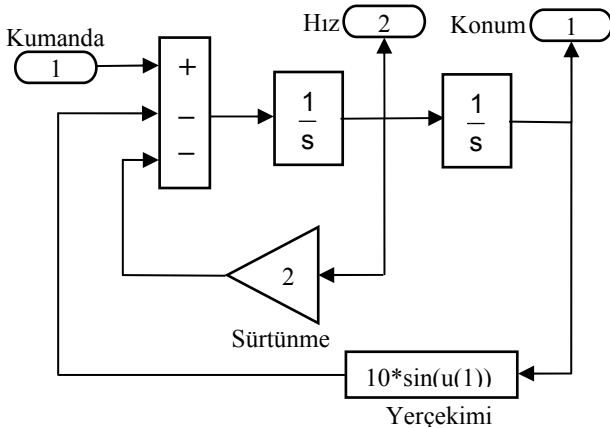
Ayrık BUYSA'lı denetleyicinin bozucu moment etkisinde sinüs izleme senaryosuyla benzetimi

Referans model


Dubowsky ve DesForges (1979) yaklaşımından yola çıkılarak, uç eleman yükünün kolun son parçasıyla birleştiği ve uç elemanın diğer parçalara göre çok daha kısa olduğu varsayılmış ve referans model olarak ikinci dereceden zamanla değişmeyen bir doğrusal diferansiyel denklem kullanılmıştır.

Tek serbestlik dereceli robot modeli

Önerilen denetleyicinin performansını göstermek amacıyla yapılan tek serbestlik dereceli robot denetimi benzetimlerinde Şekil 5'te blok diyagramı verilen robot modeli kullanılmıştır.




Şekil 5. Tek eksenli robot




Şekil 6. İkinci dereceden bir referans model

İlk benzetimde denetleyiciye sinüs girişi verilmiş ve robot eksenine 5. saniyeden itibaren 100 milisaniye süresince 20 Nm bozucu moment uygulanmıştır. Bozucu momentin konum-zaman grafiğinde gözle görülür bir etkisi yoktur. Bozucu momentin robot hareketine olan etkisi Şekil 7'deki hız zaman grafiğinden görülebilir. Hızda meydana gelen küçük bir zıplama çok kısa sürede dengelenmiştir.




Şekil 7. Sinüs izlemede açısal hız


Şekil 8 hız denetleyicisinin ürettiği kumandayı ve Şekil 9 konum denetleyicisinin ürettiği kumandayı göstermektedir. İlk sinüs işaretinde hız denetleyicisinin kumandasında bazı zıplamalar olmakla birlikte daha sonra bu zıplamalar kaybolmaktadır. 5. saniyede uygulanan bozucu momentini dengelemek amacıyla hız denetleyicisinin ürettiği kumanda Şekil 8'de işaretlenen bölgeden görülebileceği gibi büyük genlikli ve hızlıdır, buna rağmen kumanda çok kısa bir sürede kararlı hale dönmüştür.




Şekil 8. Sinüs izlemede hız denetleyici çıkışı



Şekil 10. Sinüs izlemede konum denetleyici kural sayısı



Şekil 9. Sinüs izlemede konum denetleyici çıkışı




Şekil 11. Sinüs izlemede hız denetleyici kural sayısı

Şekil 10 ve 11 sırasıyla konum ve hız BUYSA'larının kural sayılarındaki değişimleri göstermektedir. Sinüs öğrenilene kadar, yani hata ve hata değişimi kabul edilebilir bir değere inene kadar kural sayıları artmakta daha sonra değişmemektedir. 5. saniyede uygulanan bozucu moment kural sayısında bir artışa neden olmamıştır. Bu, mevcut kural sayısının ön görülen kabul edilebilir hatayı ve hata değişimini sağladığı anlamına gelir.

Ayrık BUYSA'lı denetleyicinin bozucu moment etkisinde basamak girişi senaryosuyla benzetimi

İkinci benzetimde, konumunu koruyan denetleyiciye 1. saniyede, konum referans değerine basamak değişimi uygulanmış ve robotun yeni referans değerine ulaşmasından sonra 5. saniyede 100 milisaniye süresince 20 Nm bozucu moment uygulanmıştır. Bu benzetimde de bozucu momentin konum-zaman grafiğinde gözle görülür bir etkisi yoktur. Şekil 12'de referans modelin

açısal hızı ile robotun açısal hızı çakışiktır. Bozucu momentin robot hareketine olan etkisi açısal hız-zaman grafiğindeki işaretli bölgede görülebilir. Gerçek hızda meydana gelen zıplama çok kısa sürede dengelenmiştir. Yer çekimine karşı tutma momentiyle konumunu korumaya çalışan ve basamak girişinden sonra hızla kararlı duruma gelen robotun konum-zaman grafiğinde gözlemlenemeyen düzensizlikler, hız-zaman grafiğinde görülebilmektedir.



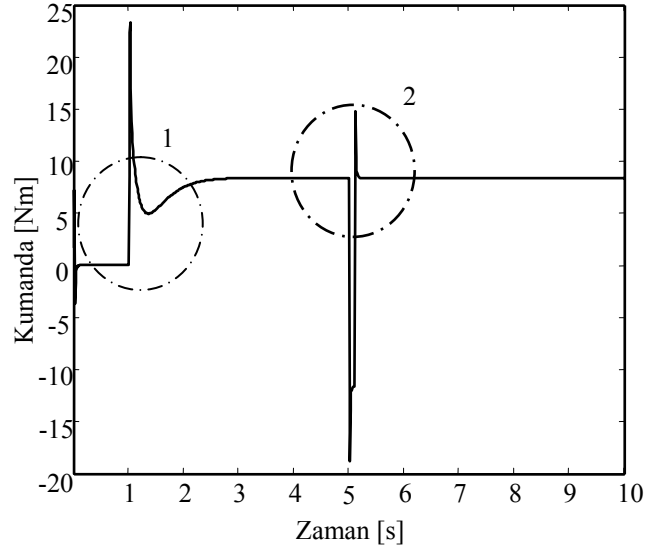
Şekil 12. Basamak girişine karşılık hız değişimi

Şekil 13 ve Şekil 14'te sırasıyla hız ve konum denetleyicilerinin ürettiği kumandalar görülmektedir. Hız denetleyicisinin basamak girişine ve bozucu momente karşı ürettiği kumanda cevapları ve bu kumandaların kısa sürede, salınım yapmadan kararlı hale dönüşü


Şekil 13'teki 1 ve 2 numaralı bölgelerden görülebilir.

Şekil 15 ve 16 sırasıyla konum ve hız BUYSA'larının kural sayılarındaki değişimleri göstermektedir. Şekil 16'daki 1 numaralı bölgeden görülebileceği gibi hız BUYSA denetleyicisinin kural sayısı yer çekimine karşı tutma momentini ayarlayabilmek için artmıştır. Şekil 15'teki işaretli bölgeden ve Şekil 16'daki 2 numaralı bölgeden görüleceği gibi basamak girişine karşılık her iki denetleyici de kural sayılarını arttırmıştır. 5. saniyede uygulanan

bozucu moment kural sayısında bir artışa neden olmamıştır.




Şekil 13. Hız denetleyici kumanda çıkışı




Şekil 14. Konum denetleyici kumanda çıkışı

Sonuçlar

Bu çalışma kapsamında öz uyarlamalı gelişmiş bir robot denetim yapısı elde edilmesi amaçlanmıştır. Bu yapıya ulaşabilmek için bulanık mantıkla denetim, yapay sinir ağları ve bunların bileşimi olan yapay sinir ağı temelli bulanık denetleyiciler incelenmiş ve model referans adaptif izleme sistemi yapısında, robot denetimi amaçlı bir bulanık yapay sinir ağı denetleyici (BUYSA) önerilmiştir.



Şekil 15. Basamak giriş için konum denetleyici kural sayısı değişimi



Şekil 16. Basamak girişi için hız denetleyici kural sayısı değişimi

Geliştirilen “bulanık yapay sinir ağıyla model referans adaptif denetim” yönteminin temelini oluşturan, “gerçek zamanda yapı geliştirme ve parametre öğrenme” algoritmaları tanıtılmıştır. Önerilen BUYSA ile yapılan benzetimlerde başlangıç olarak sadece giriş çıkış düğümleri, her giriş için birer süreç elemanı ve her süreç elemanına karşılık gelen birer kural bulunurken, denetleyici parametrelerinin ve bulanık kural sayısının gerçek zamanda değiştiği gözlenmiştir. Bu çalışma kapsamında, yukarıdaki değişimlerin denetlenen sistemin dinamik karakteristiklerine, sistem parametrelerinin değişimine,

dış ortamdaki sisteme olan etkilerin değişimine, tahrik sisteminin kapasite sınırlarına ulaşılması sonucu ortaya çıkan doymaya, hareket ödevlerinin niteliklerine ve sistemden beklenen performansın kalitesine bağlı olarak gerçekleştiği görülmüştür.

Robotun serbestlik derecesi ve hareket ödevlerinin nitelikleri arttıkça, istenilen kalitede bir denetimin yapılabilmesi için BUYSA'nın üyelik işlevi sayısının, dolayısıyla kural sayısının artması gerekliliği ortaya çıkmıştır. Bu da yapay sinir ağının süreç elemanı sayısının artması anlamına gelir. Süreç elemanı sayısının artması iterasyon sayısının, dolayısıyla hesap yükünün artması yani gerekli olan kontrol çevrim zamanının uzaması sonucunu doğurmuştur. Oysa, robotlar gibi çok eksenli dinamik sistemlerin hareket ödevlerini istenilen kalitede yerine getirebilmeleri için, olabildiğince kısa kontrol çevrim zamanına ihtiyaç duyulmaktadır. Bu amaçla denetleyicinin çok eksenli robotlarda istenilen performansı verebilmesi ve karmaşık hareket ödevlerini yerine getirebilmesi için, geleneksel model referans adaptif denetleyicilerde de kullanılan kaskat yapıdaki konum ve hız denetleyicisinden oluşan ayrık BUYSA'lı model referans adaptif denetleyici önerilmiştir. Bu denetleyici kullanılarak tek serbestlik dereceli robotla farklı senaryolar altında benzetimler yapılmış, sinüs girişine, basamak girişine ve bu girişlerle birlikte bozucu momentlere karşı denetleyicinin oldukça iyi bir model izleme performansı verdiği gözlenmiştir. Bu çalışma kapsamında denetleyici performansı iki serbestlik dereceli düzlemsel robot için de sınanmıştır. Denetleyiciye, ters kinematik modülüyle dairesel ve doğrusal interpolasyon modülleri eklenerek, bir doğru ve bir daireden oluşan yörünge robotu izletilmiştir. Robot uzuvlarının birbirlerine olan dinamik etkilerine, yerçekimine ve motor sürücülerin doyma akım değerlerine ulaşmalarına rağmen oldukça iyi bir yörünge izleme performansı gözlenmiştir.

Bu çalışmada, gelenekselleşmiş güvenilir bir teknoloji haline gelen model referans adaptif denetim yapısını, bulanık mantık ve yapay sinir ağları gibi modern teknolojiler olan yapı taşı-

rıyla inşa etmek yoluyla özgün bir denetleyici yapısı önerilmiştir. Mevcut olan üç teknolojinin birbirini tamamlayıcı etkisiyle ve sentezlerinden ortaya çıkan sinerjiyle başarılı sonuçlar elde edilmiştir. Çalışma kapsamında yapılan robot denetim benzetimleri, bu birleşik teknolojiye dayalı model referans adaptif izleme sistemi yapısındaki bulanık yapay sinir ağı denetleyicinin, oldukça iyi bir performans ortaya koyduğunu göstermiştir.

Önerilen denetleyici, çevrim içi öğrenme yeteneği ile kural sayısını ve denetleyici parametrelerini çalışma sırasında değiştirebilmektedir. Uyarılma mekanizması çalışma koşullarındaki herhangi bir değişim ile tetiklenerek hızlı ve başarımı yüksek bir kontrol etkisine yol açmaktadır. Hız ve konum denetleyicilerinin kaskat yapısı güvenilir bir yörünge kontrolünü sağlamaktadır. Önerilen denetleyici bu özellikleri ile gerçek uygulamalar için çekici bir çözüm oluşturmaktadır.

Kaynaklar

- Buja, G. S. ve Todesco, F., (1994). Neural network implementation of a fuzzy logic controller, *IEEE Transactions on Industrial Electronics*, **41**, 6, 663-667.
- Chen, C. ve Chen W., (1994). Fuzzy controller design by using neural network techniques, *IEEE Transactions on Fuzzy Systems*, **2**, 3, 235-244.
- Dubowsky, S. ve DesForges, D. T., (1979). The applications of model referenced adaptive control to robotic manipulators, *ASME Journal of Dynamic Systems Measurement and Control*, **101**, 193-200.
- Horikawa, S., Furahashi, T. ve Uchikava, Y., (1992). On fuzzy modelling using fuzzy neural networks with the backpropagation algorithm, *IEEE Transactions on Neural Networks*, **3**, 5, 801-806.
- Jang, J. R., (1992). Self-learning fuzzy controllers based on temporal back propagation, *IEEE Transactions on Neural Networks*, **3**, 5, 714-723.
- Jang, T. S. R. ve Sun, C. T., (1995). Neural fuzzy modelling and control, *Proceedings IEEE*, **83**, 378-405.
- Keller, J. M. ve Tahani, H., (1992). Backpropagation neural networks for fuzzy logic, *Information Science*, **62**, 205-221.
- Koo, T. J., (2001). Stable model reference adaptive fuzzy control of a class of nonlinear systems, *IEEE Transactions on Fuzzy Systems*, **9**, 4.
- Lee, C. H., ve Teng, C. C., (2000). Identification and control of dynamic systems using recurrent fuzzy neural networks, *IEEE Transactions on Fuzzy Systems*, **8**, 4, 349.
- Lin, C., (1995). A neural fuzzy system with linguistic teaching signals, *IEEE Transactions on Fuzzy Systems*, **3**, 2, 169-189.
- Lin, C. T. ve Lee, C. S. G., (1996). *Neural fuzzy systems: A neural-fuzzy synergism to intelligent systems*. Englewood Cliffs, NJ: Prentice-Hall.
- Nauck, D. ve Kruse, R., (1993). A fuzzy neural network learning fuzzy control rules and membership functions by fuzzy error backpropagation, *IEEE International Conference on Neural Networks*, San Francisco, CA, Mar., 1022-1027.
- Spooner, J. T. ve Passino, K. M., (1996). Stable adaptive control using fuzzy systems and neural networks, *IEEE Transactions on Fuzzy Systems*, **4**, 339-359.
- Wai, R. J., Lin, F. C., Duan, R. Y., Hsieh, K. Y., Lee, J. D., (2002). Motor drive via backstepping design technique, *IEEE Transactions on Fuzzy Systems*, **10**, 1.
- Wang, L. X., (1993). Stable adaptive fuzzy control of nonlinear systems, *IEEE Transactions on Fuzzy Systems*, **1**, 2, 146-155.
- Chang, Y. C. ve Chen B., (2000). Robust tracking designs for both holonomic and nonholonomic constrained mechanical systems: adaptive fuzzy approach, *IEEE Transactions on Fuzzy Systems*, **8**, 1, 46-66.
- Zadeh, L. A., (1965). Fuzzy sets, information control, **1**, 8, 338-353.