

DOĞRUSAL OLMAYAN DİNAMİK SİSTEMLERİN YAPAY SİNİR AĞLARI TARAFINDAN TANINMASI VE DENETİMİ

M. Önder Efe¹, M. Okyay Kaynak²

^{1,2}Mekatronik Uygulama ve Araştırma Merkezi, Boğaziçi Üniversitesi, 80815, Bebek, İstanbul,
TÜRKİYE

e-posta : efemond@boun.edu.tr - kaynak@boun.edu.tr

Özet


Bu çalışmada, bir bioreaktör sisteminin yapay sinir ağları tarafından tanınması ve denetimi ele alınmıştır. Denetim yöntemi olarak, Ters Denetim Yöntemi, Model Dayanaklı Uyarlamalı Denetim, Kendi Kendine Öğrenme ile Denetim ve Dinamik Sinir Ağları ile Denetim yordamları bioreaktör sistemine uygulanmış ve değişik başarı ölçütlerine göre bir karşılaştırma yapılmıştır.

1. Giriş

1980'li yılların başında ortaya atılan Yapay Sinir Ağları (YSA) kavramı, günümüzde birçok alanda kendine bir uygulama alanı bulmuştur. Çok güçlü bir eşleştirme yeteneğine sahip olması ve öğrenmeye dayalı uygulamalarda yüksek başarı ile çalışması, bu yaklaşımı daha da çekici hale getirmiştir. Bu çalışma yapay sinir ağlarının denetim uygulamalarının benzetimini içermektedir. Denetimi yapılmaya çalışılan sistem davranışı aşağıda özetlenmiştir.

Bioreaktör, Şekil 1.1 de gösterildiği gibi, içerisinde su, besinler ve biyolojik hücreler içeren bir tanktır. Besinler ve biyolojik hücreler tank içerisinde karışmış durumdadırlar. Sistemin durum değişkenleri biyolojik hücrelerin sayısı $c_1(t)$ ve besin miktarı $c_2(t)$ ile ifade edilmektedir. Tank içerisindeki hacim, karışıma saf su ilave edip, karışımdan da aynı debide sıvıyı atmak suretiyle sabit tutulmakta ve giriş akımının $(r(t))$ değiştirilmesi ile sistem denetlenmeye çalışılmaktadır. Denetim yordamının amacı, tank içerisindeki biyolojik hücre sayısını istenen bir değerde tutmaktır. Durum değişkenleri 0 ile 1 arasında, denetim değişkeni ise 0 ile 2 arasında değerler alabilmektedir. Sistemin kararlı durumunda $c_1 = 0.1207$, $c_2 = 0.8801$, ve $r = 0.7500$ olmaktadır [1]. Durum değişkenlerinin ilk değerleri yukarıda verilen kararlı durum değerlerinin

$\pm 10\%$ 'u ile tanımlanan aralıktan, düzgün dağılıma sahip oldukları da gözönüne alınarak rastgele seçilmektedir. Sistemin zaman domenindeki davranışı aşağıdaki eşitliklerle belirlenir:



Şekil 1.1 Bioreaktör sistemi besin ve biyolojik hücrelerin bir tank içerisinde karışımından oluşmaktadır

$$\dot{c}_1(t) = -c_1(t)r(t) + c_1(t)(1-c_2(t))e^{\frac{c_2(t)}{\gamma}} \quad (1.1)$$

$$\dot{c}_2(t) = -c_2(t)r(t) + c_1(t)(1-c_2(t))e^{\frac{c_2(t)}{\gamma}} \frac{1+\beta}{1+\beta - c_2(t)} \quad (1.2)$$

Burada $\beta=0.02$ ve $\gamma=0.48$ 'dir. Denetleyici girişleri durum değişkenleri, çıkış büyüklüğü ise $r(t)$ dir. (1.1) ve (1.2) birinci dereceden yaklaşıklıkla $\Delta=0.01$ sn. seçerek ayrıklaştırılmış ve denetim aralığı 50Δ olarak seçilmiştir. Amaç, bir öğrenme süreci boyunca $c_1(t)$ değişkeninin istenen değerlere getirilebilmesini sağlayacak denetleyicinin yapay sinir ağları ile geliştirilmesidir. Ele alınan problem her ne kadar az sayıda değişken ile ifade edilebiliyor olsa da sistemin doğrusal olmayan davranışı ve durum uzayındaki kararsız bölgeler nedeni ile sistem denetiminde önemli güçlükler ortaya çıkar.

2. Yapay Sinir Ağları ile Sistem Tanıma

Denetleyici tasarımı, denetlenecek sisteme ilişkin temsili bilgi gerektirir. Birçok uygulamada matematiksel model ile gerçek sistem arasında, etkileri hassas bir şekilde model içerisine katılmayan uyumsuzluklar olup bunların da denetleyici başarısına olumsuz etkisi sıkça karşılaşılan bir durumdur. Bu nedenle denetleyici tasarımında kullanılan bilgi, sistemi tatmin

edici ölçüde tanımlayıcı niteliğe sahip olmalıdır. Tanımayı güçleştiren başlıca etkenler sistemin doğrusal olmayan davranışı, doyma, gecikme ve zamanla değişen parametrelerdir. Bu yüzden hem matematiksel olarak işlenebilirliği olan hem de sisteme ilişkin bu davranış özelliklerini içeren bir model bulmak çözümü oldukça güç bir sorundur. Tanınacak sistem T_p ile gösterilsin. T_p kapalı uzay $U \in \mathbf{R}^n$ 'i $Y \in \mathbf{R}^m$ 'e eşleştirir. Amaç T_i ile gösterilen ve T_p yi yeteri derecede iyi bir şekilde temsil eden bir sınıfı bulmaktır. Diğer bir deyişle T_i (2.1) denklemini sağlayacak biçimde oluşturulmalıdır. Şekil 2.1 sistem tanıma yordamını şematik olarak göstermektedir.

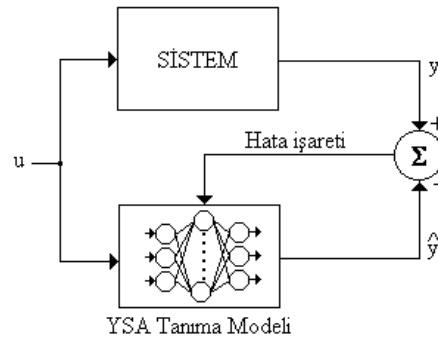


Figure 2.1 Sistem Tanıma Mimarisi

$$\| T_i(u) - T_p(u) \| \leq \varepsilon, u \in U \quad (2.1)$$

Yapay sinir ağları ile sistem tanıma işleminin en önemli yanı uyarlamalı bir değişken güncelleme yordamının belirlenmesidir. Bu yordam, gerçek sistem ile onu taklit edecek modelin çıkışları arasındaki farkın enküçüklenmesini sağlamalı ve bu gerçek sistemden elde edilen gözlem sonuçları ile uyumlu olmalıdır. Yapılan çalışmada bioreaktör, hata geriye yayma yordamı kullanılarak tanınmış ve sinir ağı yapısı olarak 3-25-16-2 yapısı seçilmiştir. Burada eğitim çiftleri sistem davranışını belirleyen sistem girişleri ve durumları ile sistem çıkışları olarak alınmıştır.

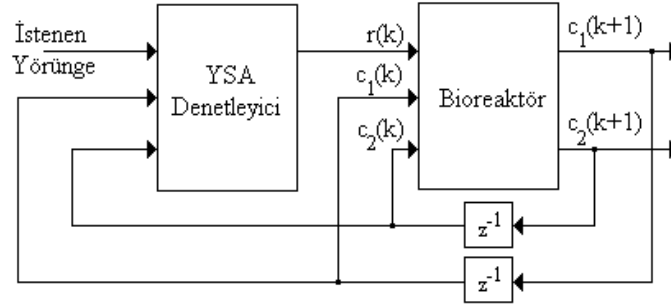
3.Ters Denetim Töntemi (TDY)

Bu yöntemde YSA tabanlı denetleyici, sistem davranışının tersini öğrenir. Bu işlemde denetlenecek sistemden ileri yönde elde edilen giriş/durum/çıkış bilgisi kullanılır. Sistem davranışının (3.1) denklemi ile verildiğini varsayalım;

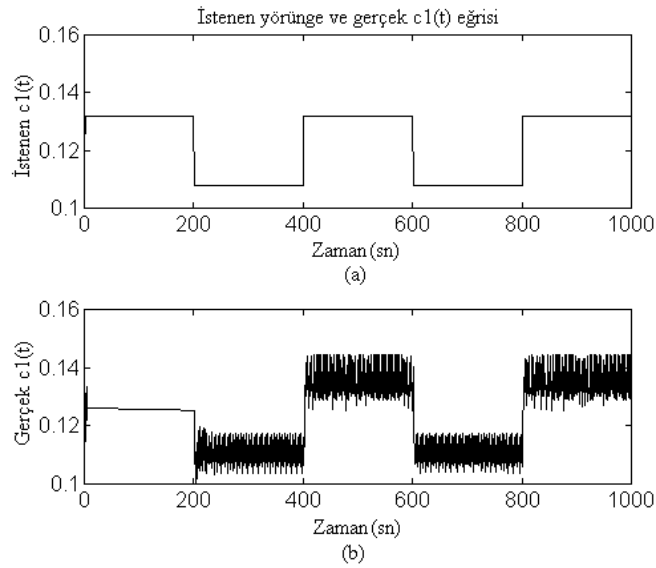
$$x(k+1) = F[x(k), u(k)] \quad (3.1)$$

$$u(k) = G[x(k+1), x(k)] \quad (3.2)$$

Burada $x \in \mathbb{R}^m$ ve $u \in \mathbb{R}^n$ vektörel büyüklüklerdir. Sistem \mathbb{R}^{m+n} uzayından \mathbb{R}^m uzayına doğrusal olmayan bir eşleştirme yapmaktadır. Amaç, bu eşleştirme bilgisinden sistem girişlerini çekmektir. Eğer bir denetleyici durum geçiş bilgisini kullanarak bu geçişe neden olan girdileri hesaplayabilirse, bu denetleyici sistemin tersini gerçekleştirebilir ve sistemi denetleyebilir. Bunun için gerek şart, sistem durumlarının gözlenebilir olmasıdır. Yordam yapay sinir ağları açısından değerlendirilirse, eğitim çiftleri kümesinin, ayrıklaştırılmış sistem denklemlerinden elde edilebileceği ve hata geriye yayma yöntemi ile denetleyicinin eğitilebileceği ortaya çıkmaktadır. Bioreaktör sistemi için denetim mimarisi Şekil 3.1 de, benzetim sonuçları Şekil 3.2 de verilmiştir.



Şekil 3.1 Denetim Mimarisi



Şekil 3.2 (a) İstenen işaret (b) Gerçek c_1 işareti

4. Model Dayanaklı Uyarlamalı Denetim (MDUD)

Bu çalışmada ele alınan bir başka yöntem de model dayanaklı uyarlamalı denetim yordamıdır. Yöntem, denetim girişlerini hesaplarken sistem çıkışlarının kararlı bir istenen model gibi davranmasını da sağlamaktadır. Birçok uygulamada sistem parametrelerinin tam olarak bilinmemesi, tasarlanan denetleyicinin yeterli ölçüde başarılı olmasını engeller. Buna karşılık, denetleyicinin değişen şartlar altında kendisini ortama uyarlaması gerekir. Bu noktada, yapay sinir ağları sistem parametrelerinin tahmin edilmesinde ve en uygun girişin hesaplanmasında kullanılabilir. Bu bölümde ele alınan doğrudan uyarlamalı denetim yöntemi, e_c ile gösterilen anlık izleme hatasını kullanarak parametreleri günceller. (1.1) ve (1.2) ile verilen bioreaktör denklemleri düzenlenerek şu şekle getirilebilir:

$$\dot{c}_1 = -c_1 w + f(c_1, c_2) \quad (4.1) \quad \dot{c}_2 = -c_2 w + f(c_1, c_2) g(c_2) \quad (4.2)$$

$$f(c_1, c_2) = c_1 (1 - c_2) e^{\frac{c_2}{\gamma}} \quad (4.3) \quad g(c_2) = \frac{1 + \beta}{1 + \beta - c_2} \quad (4.4)$$

Bioreaktör sistemi için seçtiğimiz dayanak modelin ilk denklemi (4.5) ile ifade edilen kararlı bir modeldir. Bu seçimin $c_{2m}(t)$ parametresine etkisi aşağıdaki şekilde incelenebilir.

$c_{2m}(t)$ serbest durum değişkeni olduğu için $c_{2m}(t)$ 'nin ortaya koyabileceği koşullar etkisizdir ve (4.8) denkleminde ifade edildiği gibi diferansiyel düzeyde $c_{2m}(t)$, $c_{1m}(t)$ 'nin doğrusal bir fonksiyonudur.

$$\dot{c}_{1m}(t) = -c_{1m}(t) + r(t) \quad (4.5)$$

$$c_{2m}(t) = c_{2m}(c_{1m}(t)) \quad (4.6)$$

$$\dot{c}_{2m}(t) = \frac{\partial c_{2m}(t)}{\partial c_{1m}(t)} \dot{c}_{1m}(t) = \frac{\partial c_{2m}(t)}{\partial c_{1m}(t)} (-c_{1m}(t) + r(t)) \quad (4.7)$$

(4.7) denklemi düzenlenirse;

$$\dot{c}_{2m}(t) = - \frac{\partial c_{2m}(t)}{\partial c_{1m}(t)} c_{1m}(t) + \frac{\partial c_{2m}(t)}{\partial c_{1m}(t)} r(t) \quad (4.8)$$

(4.8) denklemindeki ilk terim (4.9) daki gibi, ikinci terim (4.10) daki gibi düşünülebilir: Bu çıkarımın sonucu, $c_{1m}(t)$ için seçilen kararlı model $c_{2m}(t)$ için de kararlı bir modeli kendiliğinden kurmakta ve $c_{1m}(t)$ ile $c_{2m}(t)$ arasında (4.11) denklemi ile verilen ilişki ortaya çıkmaktadır. Sistem çıkışlarının dayanak model çıkışlarını takip ettiği varsayımı altında (4.1) ve (4.12) denklemleri (4.14) ile ifade edilen denetimin uygulanmasını öngörür.

$$-\frac{\partial c_{2m}}{\partial c_{1m}} c_{1m} = -c_{2m} \quad (4.9)$$

$$\frac{\partial c_{2m}}{\partial c_{1m}} r = g(c_{2m}) r \quad (4.10)$$

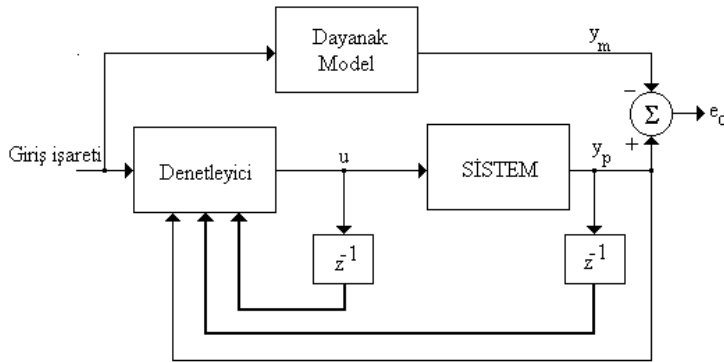
$$g(c_{2m}) = \frac{c_{2m}}{c_{1m}} = \frac{1+\beta}{1+\beta-c_{2m}} \quad (4.11)$$

$$\dot{c}_{1m}(t) = -c_{1m}(t) + r(t) \quad (4.12)$$

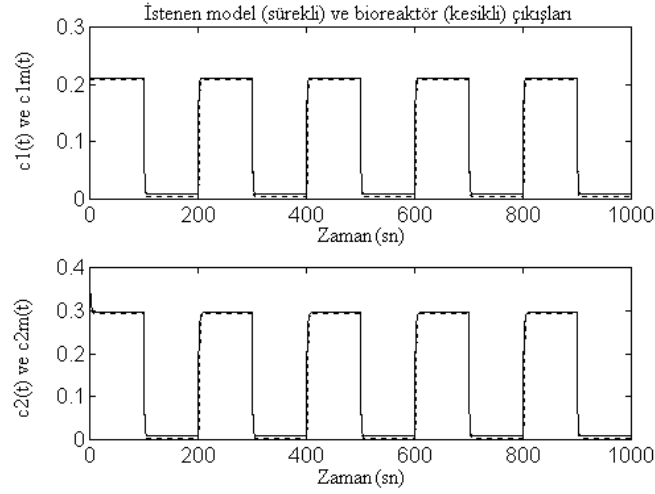
$$\dot{c}_{2m}(t) = -c_{2m}(t) + g(c_{2m}(t))r(t) \quad (4.13)$$

$$w(c_1(t), c_2(t), r(t)) = \frac{f(c_1(t), c_2(t)) + c_1(t) - r(t)}{c_1(t)} \quad (4.14)$$

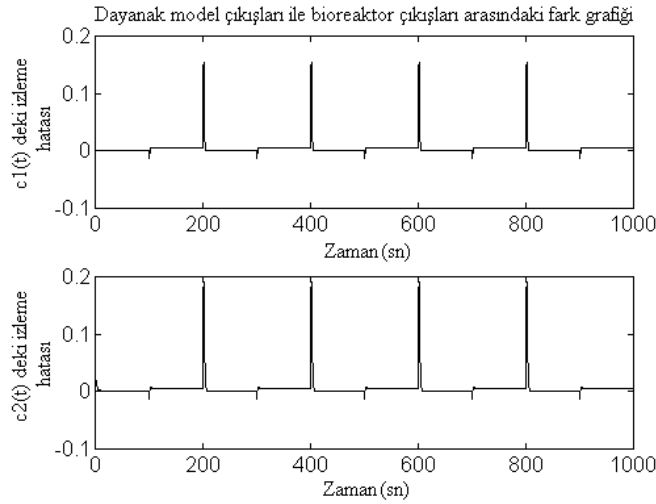
(4.14) denklemleri ile verilen denetime göre $c_{1m}(t) = c_1(t)$ sonucu çıkar. Eğer $f(c_1, c_2)$ fonksiyonu bir yapay sinir ağı tarafından gerçekleştirirse istenen model ile bioreaktör çıkışları arasındaki farkın zaman içerisinde sifira yakınsayacağı görülür. Bu sonucun pratikteki en önemli gerek şartı $f(c_1, c_2)$ fonksiyonunun yapay sinir ağı tarafından yeterli hassasiyetle gerçekleştirilebilmesidir. Benzetim sonuçları Şekil (4.2) de verilmiştir.



Şekil 4.1 Doğrudan Uyarlamalı Denetim Mimarisi



Şekil 4.2(a) Bioreaktör ve istenen modelin $r(t) = 0.11 + 0.1\text{sgn}(\sin(2\pi t/200))$ işaretine verdikleri c_1 ve c_2 çıkışları



Şekil 4.2(b) $r(t) = 0.11 + 0.1\text{sgn}(\sin(2\pi t/200))$ girişi için oluşan izleme hataları

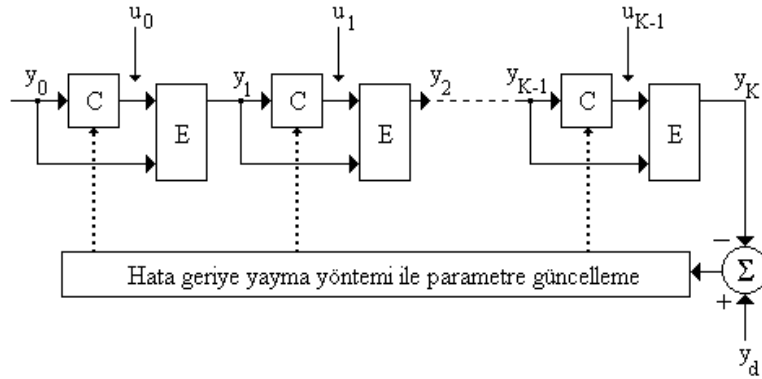
5. Kendi Kendine Öğrenme İle Denetim (KKÖD)

Nguyen ve Widrow [3] tarafından önerilen bu yöntem dışarıdan referans işareti almaz. Denetleyici, önceden tanımlanan sürekli hal çıkışlarına ulaşmayı sağlayacak biçimde eğitilir. Denetleyici eğitimi hata geriye yayma yöntemi ile yapılır.

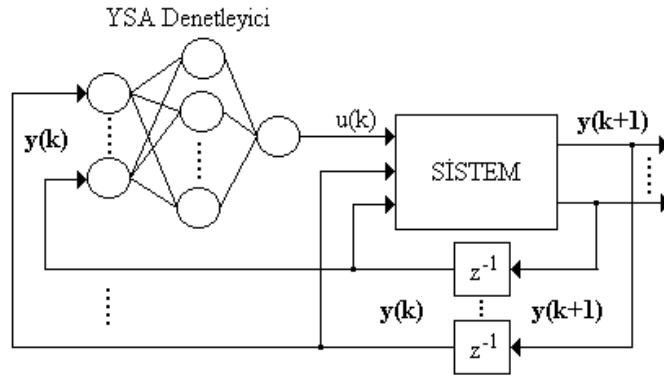
Benzetimin ilk aşaması bioreaktörün bir yapay sinir ağı tarafından tanınmasıdır. Şekil 5.1 de E kutuları bioreaktöre ait yapay sinir ağı modelleridir. Denetim mimarisi K adımıda sistem

çıkışlarının başlangıç değerinden (y_0) istenen son değerine (y_d) getirilebilmesini sağlamaktadır. Adım sayısı tasarımcı tarafından belirlenmektedir. Eğitim için başarı ölçütü (5.1) ile verilmiştir.

$$J = E\left(\|y_d - y_K\|^2\right) \quad (5.1)$$



Şekil 5.1 Kendi kendine öğrenme mimarisi ile denetleyicinin eğitilmesi



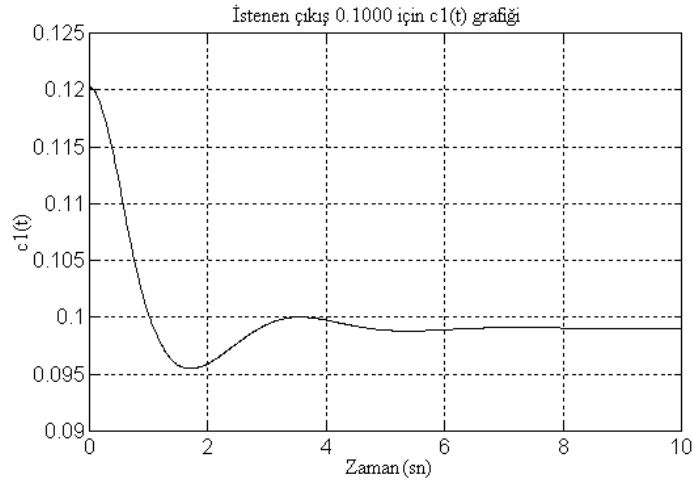
Şekil 5.2 Denetim mimarisi

Enküçükleme işlemi K . adımda çıkış hatasının hesaplanıp hata geriye yayma yöntemi ile ilk adıma kadar getirilmesi ve bu işlem sırasında ağırlıkların güncellenmesine dayanmaktadır. Şekil 5.1 de gösterildiği biçimde K . aşamada yapılan parametre güncellemesi ($K-1$). aşamada yapılacak parametre güncellemesini etkilemektedir. Bu, değişimlerin K adım boyunca hesaplanarak biriktirilmesini ve elde edilen değişim vektörünün kullanılmasını gerektirmektedir. Uygulamada her adımda parametrelerin güncellenmesinin de başarı ölçütünü etkilemediği görülmüştür [3].Eğitilen YSA denetleyici Şekil 5.2 de görüldüğü gibi sisteme yerleştirilmektedir.

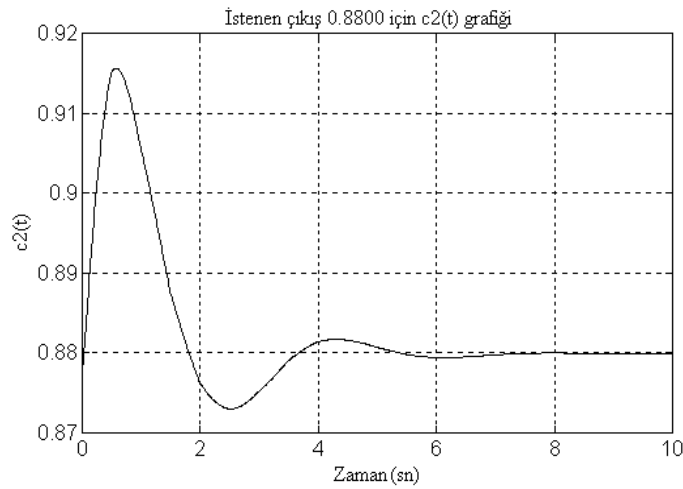
Benzetim sonuçları Şekil 5.3 te görülmektedir. Bu benzetimde aşağıdaki YSA yapısı kullanılmıştır.

YSA tabanlı sistem modeli : 3-25-16-2 Hata : 88e-6
Denetleyici : 2-8-4-1 Hata : 1e-6

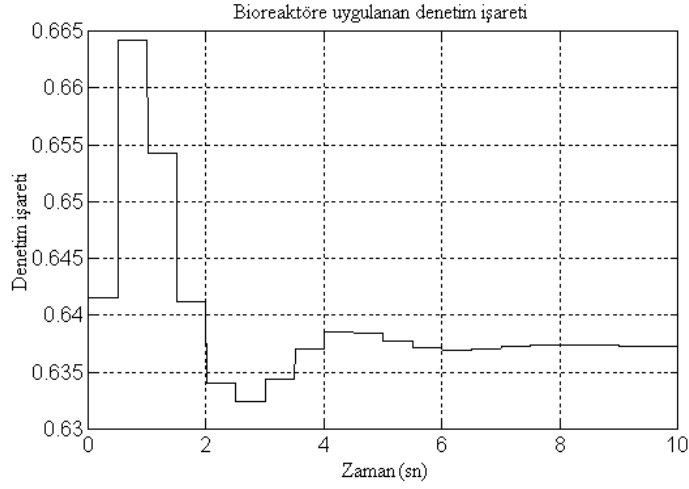
Özetle c_1 ve c_2 parametrelerinin istenen değerleri önceden belirlenmiş ve bioreaktörün YSA tabanlı bir modeli oluşturularak denetleyici $K=20$ adım için eğitilmiş ve Şekil 5.2 de görüldüğü şekilde sisteme yerleştirilerek benzetim sonuçları elde edilmiştir.



Şekil 5.3(a) İstenen değer 0.1000 için c_1 'in zamana göre değişimi



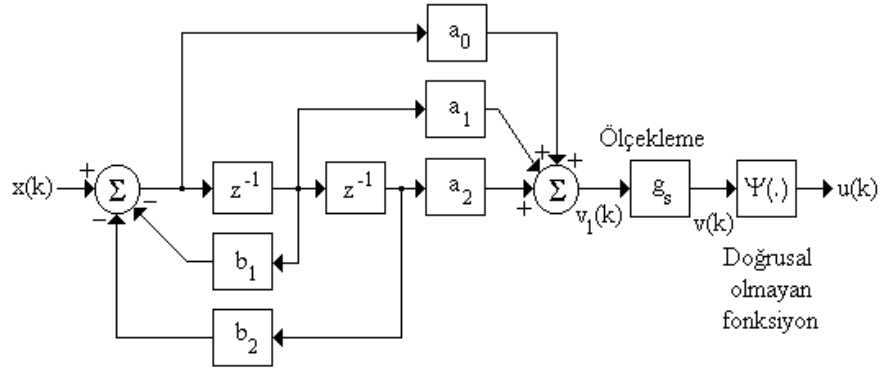
Şekil 5.3(b) İstenen değer 0.8800 için c_2 'nin zamana göre değişimi



Şekil 5.3(c) Denetleyici tarafından üretilen denetim işareti

6. Dinamik Sınır Ağları İle Doğrusal Olmayan Dinamik Sistemlerin Denetimi

Bu bölümde yeni bir nöron modeli ele alınmış ve bu model ile kurulan ağların denetim uygulamaları araştırılmıştır. Modelin yapısı Şekil 6.1 de görülmektedir. Nöron tek girişlidir, giriş katında ikinci dereceden bir sistem yer almakta ve bu sistemin cevabı ölçeklenerek doğrusal olmayan bir fonksiyondan geçirilmek suretiyle çıkış elde edilmektedir.



Şekil 6.1 Dinamik Nöron Yapısı

Dinamik nöronun doğrusal kısmının davranışı (6.1) ile verilen bir fark denklemdir, bu fonksiyon z-domeninde (6.2) denklemindeki gibi ifade edilebilir.

$$v_1(k) = -b_1v_1(k-1) - b_2v_1(k-2) + a_0x(k) + a_1x(k-1) + a_2x(k-2) \quad (6.1)$$

$$T(z) = \frac{a_0 + a_1z^{-1} + a_2z^{-2}}{1 + b_1z^{-1} + b_2z^{-2}} \quad (6.2)$$

Dinamik nöronun çıkışı (6.4) denklemi ile hesaplanır.

$$v(k) = g_s v_1(k) \quad (6.3)$$

$$u(k) = \Psi(v(k)) = \tanh(g_s v_1(k)) \quad (6.4)$$

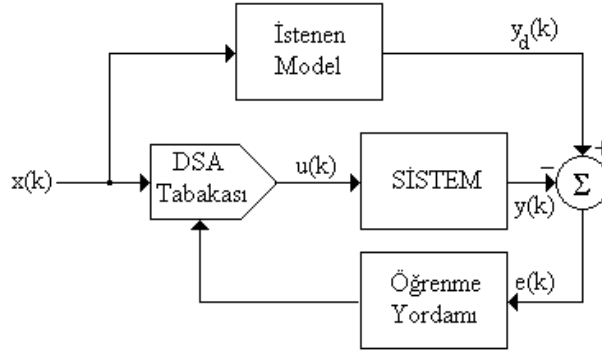


Figure 6.2 Dinamik nöronlar ile kurulan denetim mimarisi

Yöntem, çıkışta oluşan izleme hatasının ortalama değerinin enküçüklenmesine dayanmaktadır. Bu işlem için nöron parametreleri w ile gösterilirse, parametre güncellenmesi (6.5) denkleminde ifade edildiği gibi eğim düşümü yordamının uygulanması şeklinde dönüşmektedir.

$$w_{k+1} = w_k - \mu \frac{\partial J}{\partial w} \quad (6.5)$$

$$J = \frac{1}{2} E(e^2(k)) \quad (6.6)$$

$$e(k) = y_d(k) - u(k) \quad (6.7)$$

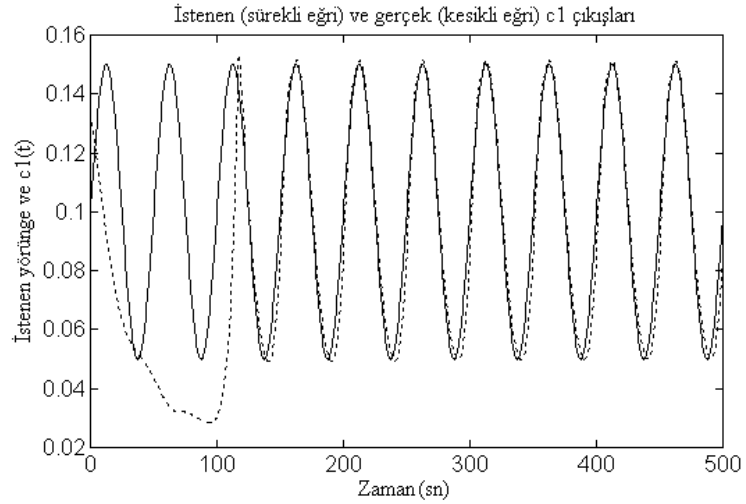
Daha açık biçimiyle parametre güncelleme kuralı (6.8),(6.9) ve (6.10) denklemleri ile verilebilir ($i=0,1,2$ ve $j=1,2$)

$$\Delta a_i(k+1) = \mu_{a_i} E\left(e(k) g_s^2(k) \operatorname{sech}^2[v_1(k)] x(k-i)\right) \quad (6.8)$$

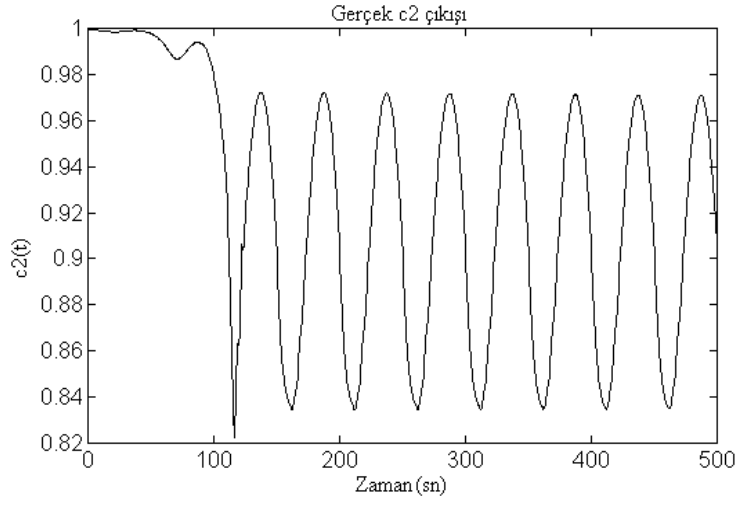
$$\Delta b_j(k+1) = -\mu_{b_j} E\left(e(k) g_s^2(k) \operatorname{sech}^2[v_1(k)] v_1(k-j)\right) \quad (6.9)$$

$$\Delta g_s(k+1) = g_s(k) \mu_{g_s} E\left(e(k) \operatorname{sech}^2[v_1(k)] v_1(k)\right) \quad (6.10)$$

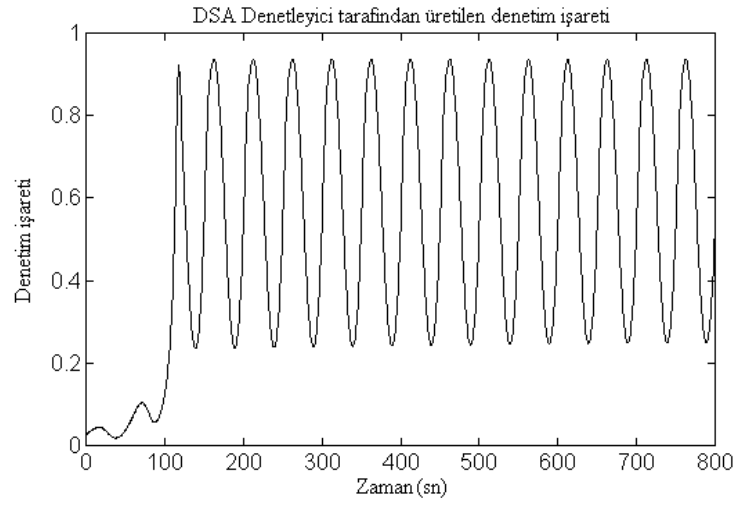
Benzetimde μ_{a_i}, μ_{b_j} ve μ_{g_s} adım büyüklüğünü belirleyen ve (0,1) aralığından seçilen sayılardır. Denetim mimarisi oluşturulurken aynı tabakada olan nöronlar aynı girişi alırlar ve tabaka çıkışı, her bir nöronun cevabının toplanması ile bulunur. Denetleyici eğitimi benzetimin işleyişi esnasında gerçekleşmektedir. Bioreaktör benzetimi aşamasında $r(t) = 0.1 + 0.05\sin(2\pi t/50)$ seçilmiş ve elde edilen sonuçlar Şekil 6.3 te sunulmuştur.



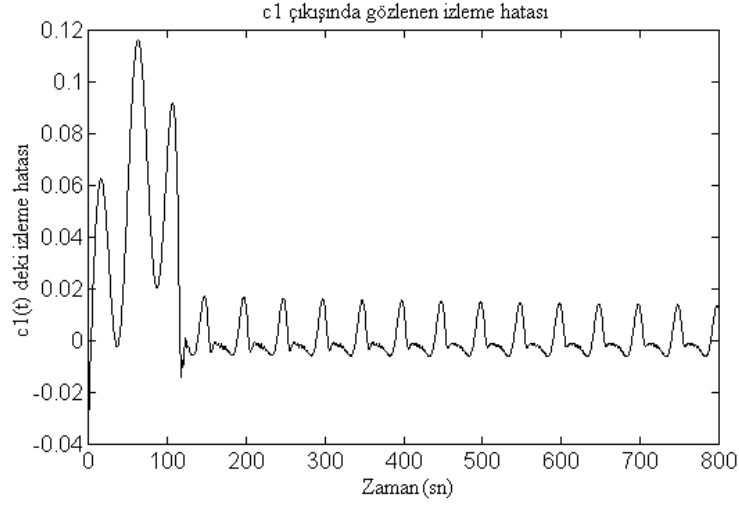
Şekil 6.3(a) $c_1(t)$ çıkışının davranışı



Şekil 6.3(c) $c_2(t)$ çıkışının davranışı



Şekil 6.3(d) Bioreaktöre uygulanan denetim işareti



Şekil 6.3(b) c (t) de oluşan izleme hatası

7. Sonuçlar

Bu çalışma kapsamında ele aldığımız yöntemler için farklı açılardan başarımlar karşılaştırmaları Tablo 1. de sunulmuştur. Buna göre dinamik sinir ağları yaklaşımının genel başarımlarının en iyi olduğu görülmektedir.

TABLO 1. İncelenen denetim Yordamlarının Karşılaştırılması

	TDY	MDUD	KKÖD	DSA
İzleme başarımları	DÜŞÜK	YÜKSEK	YÜKSEK	YÜKSEK
Farklı sistemlere uygulanabilirlik	DÜŞÜK	ORTA	YÜKSEK	YÜKSEK
Ortamdaki değişimlere karşı uyarlanabilirlik	DÜŞÜK	YÜKSEK	YÜKSEK	YÜKSEK
Kararlılık analizinin uygulanabilirliği	YOK	YOK	YOK	VAR
Gürültü yokedebilme başarımları	-	-	-	YÜKSEK
Normal çalışmada aksaklık giderebilme	-	-	ORTA	YÜKSEK

8. Teşekkür

Bu çalışmanın yürütülmesi esnasındaki katkılarından ötürü Boğaziçi Üniversitesi Mekatronik Uygulama ve Araştırma Merkezi'ne teşekkür ederiz.

9. Kaynaklar

- [1]. Ungar, L. H., "A Bioreactor Benchmark for Adaptive-Network Based Process Control," W. T. Miller, R. S. Sutton, P. J. Werbos, *Neural Networks for Control*, MIT Press, 1991
- [2]. Narendra, K. S., Parthasarathy, K., "Identification and Control of Dynamical Systems Using Neural Networks," *IEEE Transactions on Neural Networks*, Vol. 1, No. 1, pp. 4-27, March 1990.
- [3]. Nguyen, D. H., Widrow, B., "Neural Networks for Self-Learning Control Systems," *IEEE Control Systems Magazine*, pp. 18-23, April 1990.
- [4]. Gupta, M. M., Rao, D. H., "Dynamical Neural Units with Applications to the Control of Unknown Nonlinear Systems", *Journal of Intelligent and Fuzzy Systems*, Vol.1, No.1, pp. 73-92, 1993.
- [5]. Hagan, M. T., Menhaj, M. B., "Training Feedforward Networks with the Marquardt Algorithm," *IEEE Transactions on Neural Networks*, Vol. 5, No. 6, pp. 989-993, November 1994.
- [6]. Efe, Mehmet Önder, "Identification and Control of Nonlinear Dynamical Systems Using Neural Networks," Yüksek Lisans Tezi, Boğaziçi Üniversitesi, 1996