

The Estimation of Substrate Concentrations in Sequencing Batch Reactor by using Artificial Intelligence Methods

Gulgun Koseoglu¹

¹Sakarya University, Engineering Faculty, Environmental Engineering Department,
54187 Sakarya, Turkey. E-mail: gulgunk@sakarya.edu.tr

Abstract: The aim of the study was the estimation of substrate concentrations at the end of reaction phase (S_e , mg/l) which varying of S_f values (substrate concentrations at the end of filling phase, mg/l) and time (t_r , h) depend on wastewater flow rate (Q , m³/h) in sequencing batch reactor (SBR) by using Neural Network and Adaptive Neuro Fuzzy Inference System (ANFIS) approaches. The main purpose of using these methods was rapidly access to true and certain solutions according to conventional mathematical methods. A performance method was developed to compare the applicable systems performances. Obtained data form each model were analyzed independently and error quantities of systems were calculated by comparing with prior mathematical method results. The error quantities for Neural Network method were %0.7 at test set and %0.02 at training set. In Adaptive Neuro Fuzzy Inference System (ANFIS), the error quantities were %0.9 and %0.03 in respect of test set and training set. Neural Network approach was turned out satisfactory with lower error quantities. But also each method was in practical level because of their low differences between the error quantities. Obtained results were evinced that these two approaches was rapidly accessed to the true and certain results instead of conventional mathematical methods.

Keywords: Sequencing Batch Reactor, Wastewater, Neural Network, Adaptive Neuro Fuzzy Inference System (ANFIS)

Ardisik Kesikli Reaktörde Substrat Konsantrasyonlarının Yapay Zeka Teknikleri Ile Hesaplanması

Özet: Bu çalışma ardisik kesikli bir reaktör prosesindeki atıksu debisine (Q , m³/saat) bağlı olarak değişen S_f değerleri (doldurma fazi sonundaki substrat konsantrasyonu, mg/l) ve zaman (t_r , saat) baz alınarak, yapay sinir ağı ve sinirsel bulanık mantık yaklaşımları ile oluşturulan sistemlerin reaksiyon fazi sonundaki substrat konsantrasyonunu (S_e , mg/l) tahminleri amaçlanmıştır. Bu sistemlerin uygulanmasındaki amaç, doğru ve kesin çözüme, geleneksel matematiksel metotlara nazaran daha hızlı ulaşmaktır. Uygulanan bu iki sistemin performanslarını karşılaştırmak için bir performans metodu geliştirilmiştir. Her iki modelden elde edilen veriler ayrı ayrı incelenmiş ve daha önce matematiksel yöntemle tespit edilmiş sonuçlarla karşılaştırılarak, sistemlerin hata miktarları bulunmuştur. Yapay sinir ağı metodu için hata miktarı, test setinde %0,7, eğitim setinde %0,02 bulunurken, sinirsel bulanık mantık metodunda hata miktarı, test seti için %0,9, eğitim seti için %0,03 olmuştur. Yapay sinir ağı yöntemi daha düşük hata miktarı ile daha iyi sonuç vermiştir. Fakat aradaki hata miktarı farkı çok küçük olduğundan her iki yöntemde uygulanabilecek düzeydedir. Elde edilen sonuçlar bize, bu problemin çözümünde geleneksel matematiksel yöntemlerin yerine, bu iki yaklaşım ile de (yapay sinir ağı ve sinirsel bulanık mantık) doğru ve kesin çözüme ulaşılabilirliğini açıkça göstermiştir.

Anahtar kelimeler: Ardisik Kesikli Reaktör, atık su, yapay sinir ağı, sinirsel bulanık mantık (ANFIS)

Reference to this paper should be made as follows (bu makaleye aşağıdaki şekilde atıfta bulunulmalı):

G. Koseoglu , 'The Estimation Of Substrate Concentrations In Sequencing Batch Reactor By Using Artificial Intelligence Methods', Elec Lett Sci Eng , vol. 1(1), (2005), 42-47

1. Giriş

Ardisik Kesikli Reaktör prosesi; her biri belirli bir periyot boyunca süren proses fazları serisiyle (doldurma, reaksiyon, çökeltme, bosalma ve bekleme) tanımlanır. Bu proses, sürekli akım ve tam karıştırmalı sistemlerin bazı özelliklerine sahip hibrit sistemlerdir fakat kendilerine has

* Corresponding author; Tel.: +(90) XXX YYYYYYY , E-mail:xxx@yyyyyy.yyy.yy

karakteristiklere sahiptirler. Havalandırma ve çökelme fazları için ayrı bir tanka ihtiyaç duymamaları, bu prosesleri klasik aktif çamur proseslerinden ayıran en temel özelliktir. Ardisik Kesikli Reaktör sistemleri, geri devirsiz sistemlerdir [1]. Tekstil endüstrisi atıksuları, renk, sıcaklık, yüksek miktarda ve çeşitlilikte organik, inorganik maddeler ile ağır metal faktörlerini içerir [2, 3, 4]. Özellikle tekstil endüstrisinde başlangıçta kullanılan büyük miktarlardaki suyun sadece az bir kısmının üründe yer alması ve sonuçta üründe kullanılmayan suyun büyük hacimlerde çıktı olarak oluşması, en uygun aritma tipinin belirlenmesini bir zorunluluk haline getirmiştir [4, 5]. tekstil endüstrisi atıksuları Ardisik Kesikli Reaktör ile biyolojik olarak aritilabilir. Fakat Ardisik Kesikli Reaktör'lerin tekstil endüstrisi atıksularının aritimindeki verimi ve etkisi, giriş besin konsantrasyonunun, giriş çamur konsantrasyonunun, reaksiyon süresinin ve çökelme süresinin kontrolü ile sağlanır [2]. Bu parametrelerin matematiksel ifadelerle kontrolleri ve hesaplamaları mümkün fakat zor ve zaman alıcıdır. Günümüzde yapay sinir ağları ve sinirsel bulanık mantık teknolojileri, bu tip dinamik sistemlerin tanımlanmasında ve kontrolünde başarıyla uygulanmaktadır [6]. Bu çalışmada da, atıksu debisi (Q , m³/saat) ile değişim gösteren S_f değerleri (doldurma fazi sonundaki substrat konsantrasyonu, mg/l) ve zaman (t_r , saat) baz alınarak, yapay sinir ağı ve sinirsel bulanık mantık yaklaşımları ile oluşturulan sistemin reaksiyon fazi sonundaki substrat konsantrasyonu (S_e , mg/l) değerlerini tahmini amaçlanmıştır. gerek yapay sinir ağı, gerekse sinirsel bulanık mantık ile matematiksel işlemlere gerek duymadan kesin ve doğru sonuca daha hızlı ulaşılmıştır.

2. Materyal ve Metot

2.1 Geleneksel Matematiksel Yaklaşım

Doldurma fazi sonunda kalan substrat konsantrasyonu, hacmin ve doldurma süresince uzaklaştırılan substratın kinetik ifadesinin değişken bir fonksiyonudur. [1]. Bu fonksiyonu formüle etmek için, doldurma sürecindeki kütle değişiminin eşitliği yazılırsa;

Giren-Çıkan+ Üretilen=Biriken

$$Q S_0 - 0 + r_{sf} V = \frac{d}{dt} (V S) \quad (1)$$

$$\frac{dS}{dt} + \frac{Q}{V} S + k S = \frac{Q}{V} S_0 \quad (2)$$

(2) no.lu diferansiyel denklem çözüldüğü zaman, doldurma sürecinin sonundaki substrat konsantrasyonu (S_f);

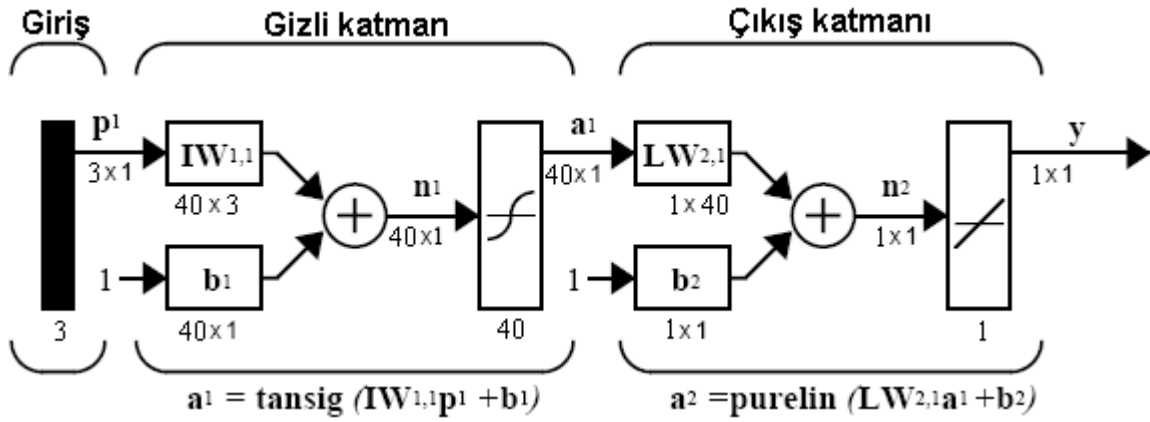
$$S_f = \frac{S_0 Q}{k V_B} + \left(\frac{V_I}{V_B} S_e - \frac{Q S_0}{V_B k} \right) e^{-k \left(\frac{V_{AB}}{Q} \right)} \quad (3)$$

elde edilmiştir. Reaksiyon sürecinin sonundaki substrat konsantrasyonu (S_e) aşağıdaki denklem ile ifade edilmiştir.

$$S_e = S_f e^{-k t_r} \quad (4)$$


2.2 Yapay Sinir Ağı Modeli

Bu çalışmada yapay sinir ağını eğitmek için Matlab'ın Neural Network Toolbox'i kullanılmıştır.



Sekil-1 Uygulanan 3 giriş, 40 gizli katman, 1 çıkışlı, tansig/purelin yapay sinir ağı [7]

Bu yapay sinir ağı, genel fonksiyon yaklaşıtrici olarak kullanılabilir. Bu ağı, herhangi bir fonksiyonu, sonlu sayıda devamsız fonksiyonlara yaklaşıtrir. İsteğe bağlı olarak gizli katmana yeterli miktarda sinir verilebilir [7]. Bu çalışmada da, 3 girişli, 1 çıkışlı, Levenberg-Marquardt prensibine göre bir sistem oluşturuldu (Sekil-1). Girişlere (Q , S_f , t_r) P değeri, çıkışa (S_e) T değeri atandı. Sistem ilk olarak verilerin 0, 1 aralığına çekilmesi ile optimize edildi, böylelikle öğrenme daha başarılı, test de oldukça hızlı oldu. Daha sonra net yapısı ayarlandı, maksimum ve minimum giriş limitleri, 40 adet gizli katman ve 1 çıkış belirtilerek, sistem tansig transfer fonksiyonuna göre ayarlandı. Ayarlama, yeni ileri beslemeli backpropagation yapay sinir ağına göre yapıldı. Yapıda maksimum 2000 iterasyonda eğitim yapıldı ve 25 kez öğrettikten sonra yapının öğrenmesi sağlandı. Hata payı 10^{-6} olarak belirlendi ve bu yapıya göre yapay sinir ağına eğitimi gerçekleşti. Sisteme, veri girilip test edildikten sonra değerler 0-1 aralığından tekrar normal aralığına getirildi. Oluşturulan yapının eğitim dosyasındaki verileri iyi bir şekilde öğrenmesi sağlandı. Eğitim 160 iterasyonda tamamlanmıştır. Yapay sinir ağına test setinde hesaplanan değerlerle, gerçek değerlerin karşılaştırılması Sekil 2'de verilmiştir.



Sekil-2 Yapay sinir ağına test setinde hesaplanan değerlerle, gerçek değerlerin karşılaştırılması

Geri Besleme Algoritması

Çok çeşitli geri besleme algoritmaları mevcuttur. En basit geri besleme uygulaması, ağıdaki ağırlık, biaslar ve komutlar doğrultusunda güncel bilgileri öğrenir, bu sırada negatif eğitim ile performans fonksiyonu da hızla azalır. Bu algoritmanın bir iterasyonu şöyle yazılabilir [7].

$$X_{k+1} = X_k - a_k g_k \quad (5)$$

Burada, X_k ; mevcut ağırlıkların ve biasların vektörü, g_k ; mevcut eğim ve a_k ; öğrenme oranıdır. Eğim ini algoritmasını tamamlayan iki farklı yol vardır: artis modu ve küme modu. Artis modunda, eğim hesaplanır ve her giriş ağına uygulandığında ağırlıklar güncelleştirilir. Küme modunda ise, ağırlıklar güncelleştirilmeden önce bütün girişler ağına uygulanır [7].

Levenberg-Marquardt

Quasi-Newton metodunda olduğu gibi, Levenberg-Marquardt algoritmasında, Hessian matrisini hesaplamadan, ikinci-sıra eğitim hizına yaklaşmak için dizayn edilmiştir. Performans fonksiyonu, kareler toplamı formunu aldığı anda, Hessian matrisi suna yaklaşıp [7];

$$H = J^T J \quad (6)$$

ve eğim şöyle hesaplanır;

$$g = J^T e \quad (7)$$

Burada J; Jacobian matrisidir, bu ağırlıklara ve biaslara uyarak yapay sinir ağı hatalarının ilk türevlerini içerir, e ise ağına hata vektörüdür. Jacobian matrisi, standart geri besleme tekniği ile hesaplanabilir. Bu hesaplama Hessian matris hesaplamasına nazaran daha az karmaşıktır. Levenberg-Marquardt algoritması şu yaklaşımı kullanır [7];

$$X_{k+1} = X_k - [J^T J + \mu I]^{-1} J^T e \quad (8)$$

Newton metoduna göre, scalar μ sıfır olduğunda, klasik olarak Hessian matrisi kullanılır. μ geniş olduğunda, eğim ini, küçük basamak ölçüsüne sahip olur. Newton metodu daha hızlıdır ve hatayı minimuma indirerek doğruya yaklaşıp. Bu nedenle, her başarılı adımdan sonra μ azalır, sadece deneme niteliğindeki adımlarda artar buda performans fonksiyonunu artırır. Bu sayede de algoritmanın her iterasyonunda, performans fonksiyonu ile ölçülen değer daima azalır, böylelikle performans artar [7].

2.3 Sinirsel bulanik mantik modeli

Sugeno tipindeki bulanik sonuç çıkarma mekanizması

İlk kez 1985’de ortaya atılan Sugeno bulanik sonuç çıkarma işleminin ilk iki bölümü, girişlerin bulaniklaştırılması ve bulanik operatörün uygulanması, Mamdani’deki gibidir [8]. Mamdani ile Sugeno arasındaki temel fark, Sugeno çıkış üyelik fonksiyonunun ya lineer yada sabit olmasıdır. Tipik bir Sugeno bulanik model formu şöyledir [9];

$$\text{If Input1}=x \text{ and Input2}=y, \text{ then output } z=ax+by+c \quad (9)$$


Sıfır-sıra Sugeno modeli için, çıkış değeri z sabittir ($a=b=0$). Her kuralın çıkış değeri w_i kuralına dönüştürülerek, çıkış değerlerinin büyüklükleri artırılır. Örneğin AND kuralı için Input1=x and Input2=y, o zaman firing strength aşağıdaki gibidir [9];

$$w_i = \text{AndMethod}(F_1(x), F_2(y)) \quad (10)$$

Burada; $F_{1,2}(\cdot)$, Input1 ve 2'nin üyelik fonksiyonlarıdır. Sistemin son çıkışları, bütün çıkış kurallarının ağırlık ortalamasıdır ve şöyle hesaplanır [9];


$$\text{Sonuç Çıkışı} = \frac{\sum_{i=1}^N w_i z_i}{\sum_{i=1}^N w_i} \quad (11)$$

Sugeno kuralı aşağıdaki diyagrama (Şekil-3) göre çalışır [9];



Şekil-3 Sugeno kuralına ait diyagram [9]

Bu çalışmada oluşturulan sistemdeki girişler ve sonuçlar data matrisinde bir araya getirildi. Yapıda, 20 iterasyonda eğitim yapıldı. Yapı, Adaptive Neuro Fuzzy Inference System (ANFIS), Sugeno tipindeki bulanık sonuç çıkarma mekanizmasına göre oluşturuldu. Oluşturulan yapıda 3 adet girişin her biri 4 gruba ayrıldı ve bunlar için üçgen fonksiyon kullanıldı. Sistem eğitildi ve eğitim 20 iterasyonda tamamlandı. Sinirsel bulanık mantık test setinde hesaplanan değerlerle, gerçek değerlerin karşılaştırılması Şekil 4'de verilmektedir.



Şekil-4 Sinirsel bulanık mantık test setinde hesaplanan değerlerle, gerçek değerlerin karşılaştırılması

2.4 Performans Metodu

Hata miktarını bulmak için su formülü kullanıldı.

$$\frac{\sum |X - X_{nn}| / X}{n} \quad (12)$$

3. Sonular ve Tartisma

Eldeki mevcut 200 adet verinin 180 adeti ile ‘egitim dosyasi’, 20 verinin bu 200 veriden ıkarılması ile de ‘test dosyasi’ olusturuldu. Yapılan alısmada hem yapay sinir ađları hem de sinirsel bulanik mantik kullanılarak özüm üretilmeye alıstıldı. Her iki modelden elde edilen veriler ayrı ayrı incelenmiş ve daha önce matematiksel yöntemle tespit edilmiş sonularla karsilastırılarak, olusturulan sistemlerin hata miktarları bulunmuştur. Sistemdeki hata miktarları asagıdaki tabloda verilmistir.

Tablo-1 Yapay sinir ađı ve sinirsel bulanik mantik yaklasımlarındaki hata miktarları

	Test Seti	Eđitim Seti
YSA	% 0,7	% 0,02
ANFIS	% 0,9	% 0,03

Tablo 1’den de görüldüğü gibi yaptığımız alısmayı yapay sinir ađı yaklasımı ile daha iyi sonu vermistir. Fakat aralarındaki hata miktarı ok küçük olduğundan dolayı her iki yöntemde kullanılabilecek düzeydedir. İki yaklasım arasındaki hata miktarı farkı önemsenebilecek kadar küçüktür. Sonu olarak bu alısmaya bize, bu problemin özümünde geleneksel matematiksel yöntemlerin yerine yapay sinir ađlarının ve sinirsel bulanik mantıklarının farklı bir yöntem olarak da rahatlıkla kullanılabileceğini ve bu yöntemlerle de dođru ve kesin özümüne ulaşılabileceğini açıka göstermistir.

References (Referanslar)

- [1] Droste, R.L. Theory and Practice of Water and Wastewater Treatment, John Wiley&Sons, Inc., New York, USA, (1997)
- [2] Jamrah, I.A., Abu-Ghunmi, N.L., Biological treatment of textile wastewater using sequencing batch reactor technology. Wat. Sci. Tech. Vol. 44, (2001), 85-92
- [3] O’ Neill, C., Hawkes, F., Esteves, S., Hawkes, D. and Wilcox, S.J., Anaerobic and anerobic treatment of a simulated textile effluent. J. Chem. Technol. Vol. 74, (1999), 993-999
- [4] Wilderer, A.P., Irvine, L.R., Goronszy, C.M., Sequencing batch reactor technology, Scientific and Technical Report, IWA, (2001)
- [5] Metcalf and Eddy. Inc., (1991), Wastewater engineering, NY; McGraw-Hill
- [6] Narendra, K.S., Parthasarathy, K., Identification and control of dynamical systems. IEEE Transactions on Neural Network 1 vol. 1, (1990), 4–27
- [7] MATLAB® Documentation (2002) Neural Network Toolbox Help, Version 4, Release 13, The MathWorks, Inc.
- [8] Roubos, J.A., Mollov, S., Babuska, R., Verbruggen, H. B., Fuzzy model-based predictive control using Takagi-Sugeno models. International Journal of Approximate Reasoning, 22 (1999) 3-30
- [9] MATLAB® Documentation (2002) Fuzzy Logic Toolbox Help, Version 2, Release 13, The MathWorks, Inc.