

Determination of The Salt Rejection Efficiency by Nanofiltration Membranes Using Neural Networks

Beytullah Eren^{1*} Recep Ileri¹

¹ Department of Environmental Engineering, Sakarya University, Esentepe Campus, Sakarya, Turkey

Abstract: In this paper, a feedforward neural network (NN) model is used to determination the salt rejection efficiency of a Nanofiltration (NF) experimental setup, which uses a DS5 nanofiltration membrane. Experimental data were collected from literature. Two hundred thirty eight experimental data were used for training and testing the network. The NN was fed with five inputs: the feed pressure, pH, salt concentration, dye concentration and cross flow velocity to determination the salt rejection efficiency. The Scaled Conjugate Gradient Algorithm (SCG) was used as optimization algorithm for training the NN. The best network configuration was set as 5-9-1 with trying and testing. The model will determine the salt rejection efficiency of nanofiltration membranes based on input and output parameters. The network was trained with a hundred seventy eight experimental data and tested with sixty experimental data. The mean absolute percentage error method was used to evaluate performance of NN. The mean absolute percentage error of training and testing results were 4.22 and 3.84 respectively. It is shown that the agreement between NN predictions and experimental data was very good.

Keywords: Salt Rejection Efficiency, Nanofiltration Membranes, Neural Networks

Yapay Sinir Aglarini Kullanarak Nanofiltrasyon Membranlari Ile Tuz Giderim Veriminin Belirlenmesi

Özet: Bu çalışmada DS 5 tipi nanofiltrasyon membran kullanan membran prosesinde tuz giderim verimini belirlemek için ileri beslemeli bir YSA modeli kullanılmıştır. Yapay Sinir Agini (YSA) eğitmek ve test etmek için kullanılacak olan 238 adet deneysel veri literatürden toplanmıştır. Bu deneysel verilerin 178 tanesi YSA'nin eğitim setinde ve 60 tanesi de test setinde kullanılmak üzere rasgele seçilerek iki kısma ayrılmıştır. YSA modeli bes girdi ve bir çıktidan oluşmaktadır. Girdiler basınç, tuz konsantrasyonu, boya konsantrasyonu, yatay akis hizi ve pH iken çıktı yalnızca tuz giderim verimidir. YSA'nin eğitimi için optimizasyon algoritması olarak ölçeklenmiş konjuge gradyent algoritması kullanılmıştır. Test setinde YSA'nin performansını değerlendirmek için ortalama mutlak yüzde hata (OMYH) ve ortalama karesel hata (OKH) metotları kullanılmıştır. Eğitim ve test işlemleri sonucunda en uygun gizli katman ve işlem elemanı sayısı deneysel veriler ile YSA sonuçları arasındaki en düşük OMYH ve OKH performans değerlerine sahip olan tek gizli katmanlı ve 9 işlem elemanı yapı olarak belirlenmiştir. Eğitim ve test sonuçları için ortalama mutlak yüzde hata değerleri sırasıyla 4,22 ve 3,84'dür. Bu değerlere göre deneysel sonuçlar ile YSA sonuçları arasında çok iyi bir uyum olduğu görülmektedir.

Anahtar Kelimeler: Tuz giderim Verimi, Nanofiltrasyon Membranlar, Yapay Sinir Aglari

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

B. Eren , 'Determination Of The Salt Rejection Efficiency By Nanofiltration Membranes Using Neural Networks', Elec Lett Sci Eng , vol. 3(1), (2007), 50-58

* Corresponding author; Tel.: +(90)555 284 62 67, E-mail:beren@sakarya.edu.tr

1.Giris

Tekstil endüstrileri ürettikleri atıksuların hem miktarı hem de kirlilik oranı bakımından tüm endüstri sektörleri arasında en büyük paya sahiptirler. Tekstil endüstri boyahanelerinde, çok miktarda su, boyar madde ve yardımcı kimyasallar kullanılmakta ve sonuçta, yüksek konsantrasyonda çözünmüş madde içeren ve çok renkli atıksular, merkezi arıtma tesisine gönderilmektedir. Bu tür atıksular merkezi atıksu arıtma tesisine gönderilmeden önce arıtılması ve desarj standartlarına uygun hale getirilmelidir. Nanofiltrasyon membranlar bu tip atıksuların arıtılması için uygun olmakla birlikte, NF membranlar ile atıksuyun içerisindeki tuzlar çok düşük giderme veriminde giderilirken, atıksuyun rengi tamamen giderilmekte, böylece su ve tuz geri kazanımı mümkün olmaktadır [1,2].

Filtrasyon akışkan içerisinde çözünmeyen partikül boyutundaki bileşiklerin büyüklüklerine ve şekline bağlı olarak sivilardan veya gazlardan ayrılması işlemidir. Membran filtrasyon prosesleri ise bunu bir adım daha ileri götürerek çözünmüş maddelerinde sivilardan ve gazlardan ayrılmasını mümkün hale getirmektedir [1,6]. Bu yüzden membran prosesler son yıllarda su ve atıksu arıtımında kullanılan en popüler teknolojilerden biri olmuştur. Çözelti içerisinde bulunan çözünmüş maddeler yarı geçirgen membrandan sürücü kuvvet olarak basınç kullanılarak geçirilmekte, çözünmüş maddeler molekül büyüklüğüne ve şekline bağlı olarak ayrılmaktadır. Su ve atıksu arıtımında kullanılan en etkili basınç sürüslü membran prosesler Mikrofiltrasyon(MF), Ultrafiltrasyon(UF), Nanofiltrasyon(NF) ve Ters Osmoz(TO)'dur [4,5]. Nanofiltrasyon (NF) membranlar Ultrafiltrasyon ve Ters Osmoz arasında bulunan yeni bir membran sınıfıdır. Nanofiltrasyon, Ters Osmoz ve Ultrafiltrasyon proseslerinin uygun bir çözüm olmadığı proseslerde kullanılmaktadır. Nanofiltrasyonda arıtılmış su, yalnızca tek değerlikli iyonlar ve düşük molekül ağırlıklı organik maddeler içerir [3]. Tekstil endüstrisinde NF membranların kullanılmasının nedeni atıksu içerisindeki çift değerlikli iyonlar (boyar madde) membran tarafından tutulurken, tek değerlikli iyonlar (tuz) ve su membrandan geçmekte böylece tuz ve su geri kazanımı mümkün olmaktadır.[1,2] Ters Osmoz prosesinde membrandan yalnızca su geçtiği için NF membranlar bu atıksuların arıtılması için TO'a göre daha ekonomiktir [13,14].

NF membranların performansının belirlenmesi membran proseslerinin optimizasyonu ve dizaynı için çok önemlidir [5].

2. Yapay Sinir Ağları (YSA)

Yapay sinir ağları insan beyninin ve sinir sisteminin varsayılan çalışma prensibini taklit etmeye çalışan paralel ve dağıtılmış bir bilgi işleme aracıdır [7,8]. Yapay sinir ağları hesaplama ve bilgi işleme gücünü, paralel dağıtılmış yapısından, öğrenbilme ve genelleme yeteneğinden almaktadır. Genelleme, eğitim ya da öğrenme sürecinde ağı daha önceden gösterilmeyen girişler için YSA'ların uygun tepkileri üretmesi olarak tanımlanır. Bu üstün özellikleri, YSA'ların karmaşık problemleri çözebilme yeteneğini gösterir [9].

YSA mimarileri, bir giriş katmanı, bir veya birden çok gizli katman ve bir çıkış katmanından oluşmaktadır. Bir katmandaki her bir işlem elemanı, bir sonraki katmanın bütün işlem elemanları ile değiştirilebilir ağırlıklı bağlantılar aracılığı ile bağlanmıştır. YSA'da bilgi bu bağlantılarda saklıdır. Çok katmanlı İleri beslemeli ağlar için en çok kullanılan eğitim algoritması geri yayılım algoritmasıdır [8]. Geri yayılım algoritması temel olarak iki safhadan oluşmaktadır. Birincisi girişlerin çıkışlara dağıtıldığı ileriye doğru safhası, ikincisi ise bağlantı ağırlıklarını yeniden

ayarlamak için, çıktı katmanında arzu edilen çıktılar ile ağın ürettiği çıktılar arasındaki hatanın geriye doğru dağıtıldığı safhadır.[8,15]

Geri yayılım algoritmasının birinci safhasında, her bir işlem elemanının net girdi değeri bir önceki katmandaki işlem elemanlarının çıkışlarının ilgili bağlantı ağırlıkları ile çarpılarak toplanması ile hesaplanır.

$$net_j = \sum_{i=1}^k w_{ij}x_i + bias_j \quad (1)$$

Burada net_j j. işlem elemanı için k işlem elemanlı bir önceki katmandaki çıkış değerlerinin ağırlıklı toplamıdır. w_{ij} j. işlem elemanı ile bir önceki katmandaki i. işlem elemanı arasındaki bağlantının ağırlığını, x_i bir önceki katmandaki i. işlem elemanının çıkış değerini, $bias_j$ bir işlem elemanına gelen net girdiyi artıran +1 değerli ya da azaltan -1 değerli bir eşik değerini temsil etmektedir [10].

Bu safhada her bir işlem elemanının çıktısı ise aktivasyon fonksiyonu kullanılarak hesaplanır. Burada j. işlem elemanının çıktısı (out_j) sigmoid aktivasyon fonksiyonu kullanılarak aşağıdaki şekilde hesaplanır.

$$out_j = f(net_j) = \frac{1}{1 + e^{-(net_j)}} \quad (2)$$

Birinci safhada ağı ilk çıktıları ürettikten sonra ağı ürettiği çıktılar ile istenilen çıktılar arasındaki hatayı belirlemek için toplam karesel hata (SSE) performans indeksi kullanılarak ağın hatası belirlenir. Bundan sonra ikinci safhaya geçilerek hatanın geriye doğru dağıtılması ve bağlantı ağırlıklarının yeniden ayarlanması işlemi yapılır. Toplam karesel hata (SSE) aşağıdaki şekilde hesaplanır.[16,17]

$$SSE = \sum_{i=1}^n (y_{i,exp} - y_{i,out})^2 \quad (3)$$

Burada $y_{i,exp}$ istenilen çıktılar, $y_{i,out}$ ağı ürettiği çıktılar, n veri setindeki örnek sayısıdır.

Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanıldığında eğitim işlemine başlamadan önce eğitim ve test setlerinde bulunan veriler normalize edilmelidir. Normalizasyon işlemi aşağıdaki şekilde yapılmaktadır.[8]

$$X_n = (b - a) \left(\frac{X - X_{min}}{X_{max} - X_{min}} \right) + a \quad (4)$$

X_n : Normalize edilmiş değer

X_{min} : Maksimum değer

X_{max} : Minimum değer

a,b : Sıra ile normalizasyonun minimum ve maksimum değerleri

Ağı eğitim işleminin başarı ile tamamlanması için eğitim ve test setinde problemi temsil edecek yeterli sayıda veri olmalıdır. Eğitim işlemine, arzu edilen çıktılar ile ağı ürettiği çıktılar arasındaki toplam karesel hata değeri istenilen düzeye ulaşmaya kadar devam edilir. Eğitim

islemi sonunda arzu edilen çiktılar ile ađın çiktıları arasındaki ortalama mutlak yüzde hata (MAPE), ve regresyon katsayısı (R^2) ařadadaki şekilde belirlenir.

$$MAPE = \frac{1}{n} \left(\sum_{i=1}^n \left| \frac{y_{i,exp} - y_{i,out}}{y_{i,exp}} \right| \right) * 100 \quad (5)$$

$$R^2 = \frac{\sum_i (y_{i,exp} - \overline{y_{i,exp}}) * (y_{i,out} - \overline{y_{i,out}})}{\sqrt{\sum_i (y_{i,exp} - \overline{y_{i,exp}})^2 * \sum_i (y_{i,out} - \overline{y_{i,out}})^2}} \quad (6)$$

3. Yapay Sinir Ađının Eđitiminde Kullanılacak Model

Belirli bir ađ, sahip olduđu birleřtirme fonksiyonu, transfer fonksiyonu, ađın mimarisi (topolojisi), kullanılan öđrenme kuralı ve öđrenme stratejisi ile karakterize edilir[11]. Bu çalıřmada önerilen YSA modeli geri yayılım (Back Propagation) ađı modelini kullanmaktadır. Bu modelde ađın ürettiđi çiktılar ile istenen çiktılar arasındaki hata bulunarak ađda geriye dođru dađıtılır ve ađ bađlantıları arasındaki ađırlıklar yeniden ayarlanır. Ađın probleme ait dođru çiktıları üretmesini sađlayacak optimum ađırlık deđerlerini buluncaya kadar bu isleme devam edilir. NF prosesi veriminin belirlenmesi dođrusal olmayan bir problem olduđundan, ölçeklenmiş konjuge gradyant algoritması diđer algoritmalara göre daha hızla sonuç vermesinden dolayı hatayı geriye yayma algoritması olarak ölçeklenmiş konjuge gradyant algoritması kullanılmıřtır [8].

YSA'da insanlar gibi örnekleređen öđrendiđi için ađın eđitimi için çok sayıda verinin kullanılması ile çok iyi sonuçlar elde edilebilir. Bu çalıřmada ađın eđitilmesi için kullanılacak olan 238 adet deneysel veri literatürden toplanmıřtır. Bu veriler denklem 1'de verilen metotla [0.01 1] arasinda normalize edildikten sonra verilerin 178 tanesi eđitim ve 60 tanesi de test setinde kullanılmak üzere rasgele sečilerek iki kisma ayrılmıřtır. Modeli oluřtururken girdi ve çıktı katmanları arasinda bulunan gizli katman sayısı ve bu katmandaki işlem elemanı sayısı deneme yanılma yoluyla belirlenmiştir. Tablo 1'den de görüldüđu gibi modeldeki gizli katman sayısı ve bu katmandaki işlem elemanı sayısı, eđitim ve test işlemleri sonucunda en az hatayı veren tek katman ve 9 işlem elemanının en uygun olduđuna karar verilmiştir.

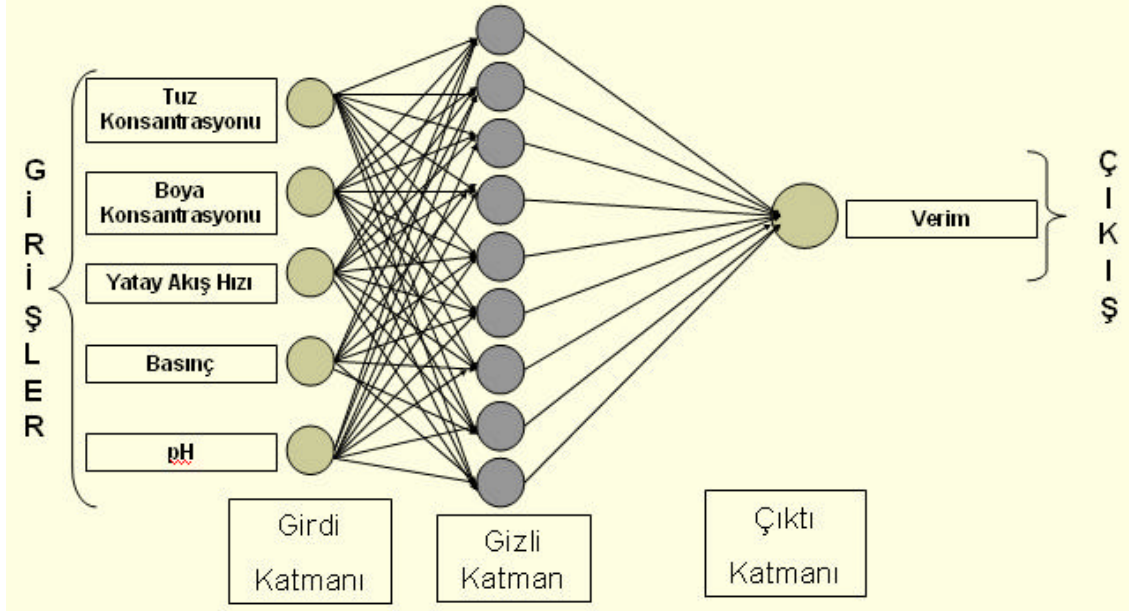
Tablo 1. Veritabanındaki parametrelerin minimum ve maksimum deđerleri

Deđiskenler	Minimum	Maksimum
Tuz Konsantrasyonu (Csb, (g/lt))	1	80
Boya Konsantrasyonu (Cdb, (g/lt))	0	50
Yatay akis hızı (?, (m/sn))	0.11	1.11
pH	4	10
Basınç (P, (bar))	8	28
Verim (%)	3.30	83.70

Tablo 2. YSA modellerinin eğitim ve test seti performansları (Not: *en iyi sonuçları, MAPE: ortalama mutlak yüzde hata, MSE: ortalama karesel hata, R^2 : regresyon katsayısı, göstermektedir.)

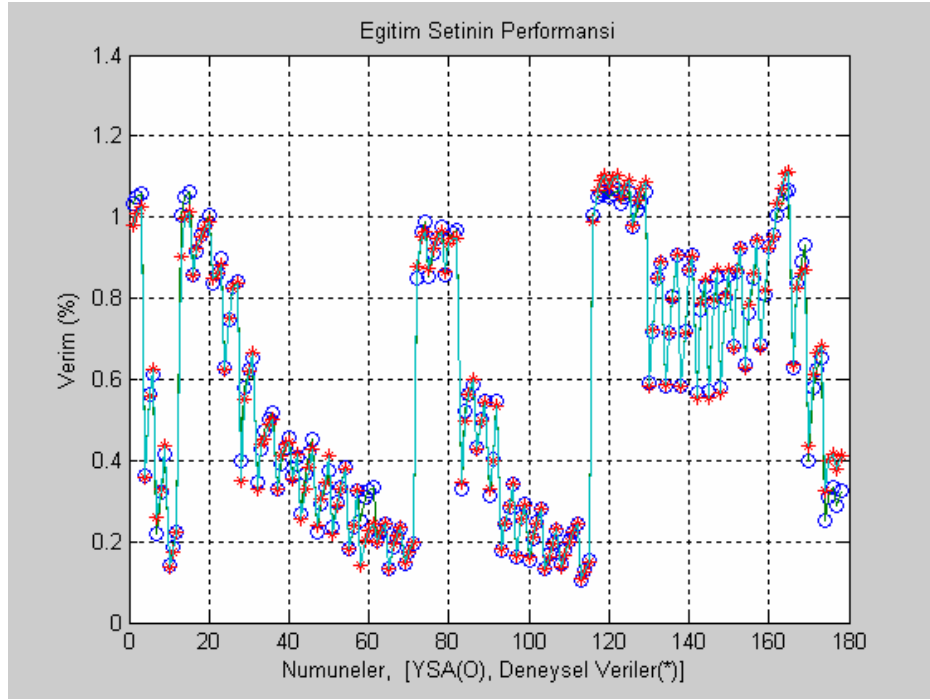
GK İşlem Elemanı Sayısı	EGITIM			TEST		
	MAPE	MSE	R^2	MAPE	MSE	R^2
1	13.8588	0.0041	0.9592	14.7314	0.0047	0.9540
3	7.8952	0.0023	0.9766	8.1877	0.0024	0.9758
5	6.9029	0.0014	0.9859	7.6881	0.0013	0.9867
7	6.4362	0.0014	0.9864	7.5126	0.0013	0.9868
9	4.2232*	0.0008*	0.9917*	3.8422*	0.0008*	0.9919*
10	5.4926	0.0011	0.9890	6.7968	0.0013	0.9872
11	5.4217	0.0011	0.9888	6.4562	0.0013	0.9874
13	5.1424	0.0010	0.9896	7.1130	0.0012	0.9887
15	4.6073	0.0010	0.9903	6.9981	0.0014	0.9866
17	4.7832	0.0010	0.9900	6.1404	0.0012	0.9887
19	4.8639	0.0011	0.9892	6.5107	0.0012	0.9881
21	4.7014	0.0010	0.9902	6.8423	0.0012	0.9882
25	4.4984	0.0010	0.9904	8.1263	0.0016	0.9859
29	4.3283	0.0009	0.9907	7.6799	0.0014	0.9862

Sekil 1’de bu çalışmada kullanılan bir girdi katmanı, bir gizli katman ve bir çıktı katmanından oluşan YSA mimarisi gösterilmektedir.

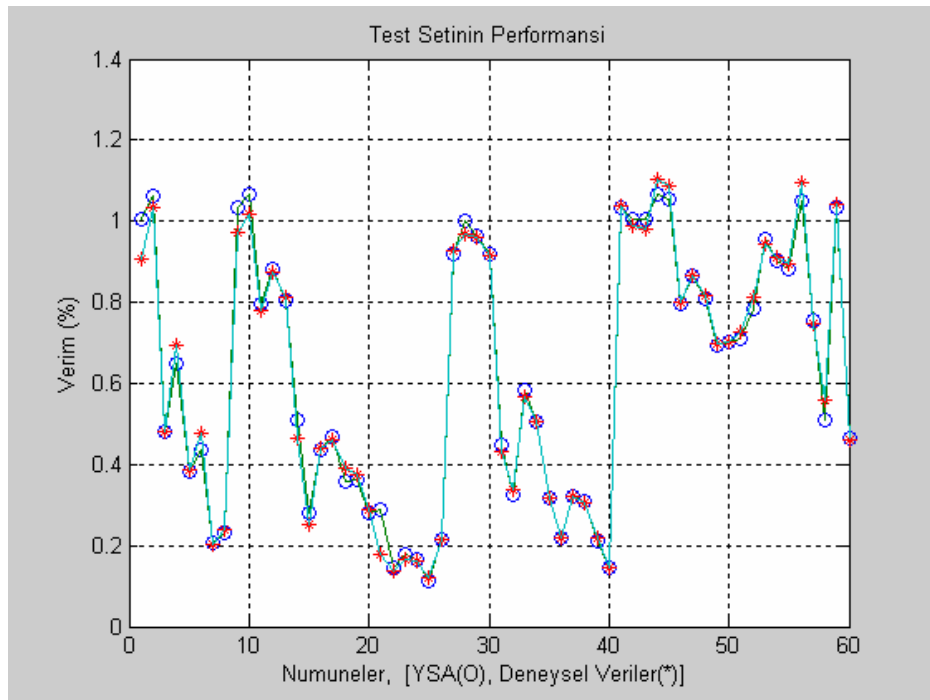


Sekil 1. Bu çalışmada kullanılan YSA'nın mimarisi


Aşağıda YSA'nın eğitim ve test işlemleri sonucunda YSA'dan elde edilen veriler ile istenilen sonuçlar arasındaki ilişkiler gösterilmiştir.



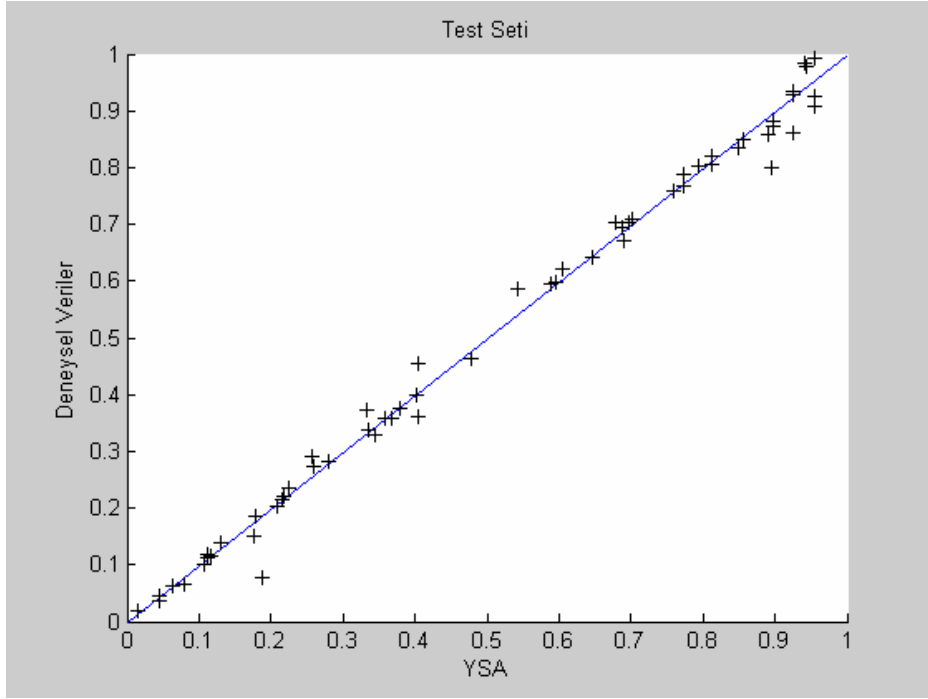
Sekil 2. YSA egitim setinin performansi



Sekil 3. YSA test setinin performansi



Sekil 4. YSA-istenen sonuların eğitim seti için $x=y$ grafiđi üzerinde gösterimi



Sekil 5. YSA-istenen sonuların test seti için $x=y$ grafiđi üzerinde gösterimi

4. Sonular

Bu alısmada nanofiltrasyon membran prosesinin veriminin belirlenmesinde yapay sinir ađı kullanılmıstır. YSA'dan elde edilen sonularla deneysel sonular karsılaştırıldığında, ortalama mutlak yüzde hata deđerleri (MAPE), eğitim seti iin 4.22 ve test set iinde 3.84 olarak bulunmuştur. Bu performans deđerlerine gre deneysel sonular ile YSA sonuları arasında ok iyi bir uyum olduđu grlmektedir. Bylelikle verime etki eden parametrelerin bilinmesiyle (YSA girdi parametreleri), yeni ve daha fazla deneysel alısmaya yapmadan, eğitilmiş ve test edilmiş YSA modelini kullanarak yeni teorik verim deđerleri retilenmektedir. Membran proseslerin veriminin bilinmesi aritma sistemlerinin optimizasyonu ve tasarımı aisinden nemlidir. Sonu olarak; Yapay Sinir Ađları, nanofiltrasyon membran proses veriminin belirlenmesinde kullanılabilir etkin bir yntemdir. Deneysel alısmaya yapmanın hem maliyetli, hem de zaman alıcı olmasından dolayı, bu model (YSA) sayesinde membran proseslerin tasarımı ve optimizasyonunda kullanılabilir, ekonomik ve faydalı bir yntem elde edilmiş olur.

References (Referanslar)

1. I.Koyuncu, "Nanofiltrasyon Membranları ile Tuz Gideriminde Organik İyon Etkisi", Doktora Tezi, (2001)
2. Koyuncu, I. and Topacık, D., Effects of operating conditions on the salt rejection of nanofiltration membranes in reactive dye/salt mixtures, Separation and Purification Technology , 33 (3), (2003), 283-294.
3. <http://www.tolemaritma.com/nanofiltrasyon.htm> ,(Aralık, 2006)
4. Coskun, A., Demir, I, and Yildiz, E., Modeling of flux decline in crossflow microfiltration using neural networks: the case of phosphate removal Journal of Membrane Science, Volume 248, Issues 1-2, 15 February 2005, Pages 53-62
5. W. Richard Bowen, Meirion G. Jones, Julian S. Welfoot and Haitham N. S. Yousef, Predicting salt rejections at nanofiltration membranes using artificial neural networks Desalination, Volume 129, Issue 2, 10 July 2000, Pages 147-162
6. <http://en.wikipedia.org/wiki/Filtration> (Aralık,2006)
7. Fausett, Laurene V., Fundamentals of Neural Networks : Architectures, Algorithms, and Applications, Prentice-Hall, Englewood Cliffs, (1994), NJ.
8. etin E., Yapay Sinir Ađları, Sekin Yayınevi, Ankara, 2003.

9. Çetin M. ,Ugur A. , Bayzan S., Ileri Beslemeli Yapay Sinir Aglarinda Backpropagation (Geriye Yayilim) Algoritmasinin Sezgisel Yaklasimi, (2006)
10. Firat M., Güngör M., Aski Madde Konsantrasyonu Ve Miktarinin Yapay Sinir Aglari Ile Belirlenmesi, Imo Teknik Dergi, 2004 3267-3282, Yazı 219
11. Karna, K. N ve Breen D. M, 'An Artificial Neural Networks Tutorial: Part 1 Basics', Neural Networks, 1, (1989), 4-23
12. MATLAB® Documentation (2002) Neural Network Toolbox Help, Version 6.5, Release 13, The MathWorks, Inc.,
13. K. Ranganathan, K. Karunagaran and D.C. Sharma, Recycling of wastewaters of textile dyeing industries using advanced treatment technology and cost analysis—Case studies Conservation and Recycling, In Press, Corrected Proof, Available online 26 July 2006
14. In-Chul Kim and Kew-Ho Lee, Dyeing process wastewater treatment using fouling resistant nanofiltration and reverse osmosis membranes, Desalination, Volume 192, Issues 1-3, 10 May 2006, Pages 246-251
15. Zoltan Kalman Nagy, Model based control of a yeast fermentation bioreactor using optimally designed artificial neural networks Chemical Engineering Journal, In Press, 9 November 2006
16. Grishma R. Shetty, Heidar Malki and Shankararaman Chellam, Predicting contaminant removal during municipal drinking water nanofiltration using artificial neural networks Journal of Membrane Science, Volume 212, Issues 1-2, 15 February 2003, Pages 99-112
17. Murat Pala and Naci Caglar, A parametric study for distortional buckling stress on cold-formed steel using a neural network Journal of Constructional Steel Research, Volume 63, Issue 5, May 2007, Pages 686-691