



ISSN:1306-3111

e-Journal of New World Sciences Academy  
2011, Volume: 6, Number: 1, Article Number: 1A0161

**ENGINEERING SCIENCES**

Received: October 2010

Accepted: January 2011

Series : 1A

ISSN : 1308-7231

© 2010 [www.newwsa.com](http://www.newwsa.com)

**Beytullah Eren**

**Sinan Mehmet Turp**

Sakarya University

beren@sakarya.edu.tr

smturp@sakarya.edu.tr

Sakarya-Turkey

**SIZINTI SUYUNDAN NİKEL (II) İYONLARI GİDERİM VERİMİNİN YAPAY SİNİR AĞLARI İLE TAHMİN EDİLMESİ**

**ÖZET**

Bu çalışmada sızıntı suyundan Nikel (II) iyonlarının giderim verimini (%  $R_e$ ) tahmin edebilen bir Yapay Sinir Ağı (YSA) modeli geliştirilmiştir. Modelin geliştirilmesinde kullanılan 90 adet deneysel veri laboratuvar ölçekli deneylerden elde edilmiştir. YSA modelinin geliştirilmesinde girdi parametresi olarak sızıntı suyu başlangıç Nikel (II) iyonu konsantrasyonu (mg/L), adsorbent miktarı (gr) ve temas süresi (dk) parametreleri, çıkış parametresi olarak Nikel (II) iyonu giderim verimi (%  $R_e$ ) kullanılmıştır. Geliştirilen modelin etkinliği Ortalama Karesel Hata (OKH), Ortalama Mutlak Hata (OMH) ve determinasyon katsayısı ( $R^2$ ) gibi istatistiksel parametreler kullanılarak belirlenmiştir. Geliştirilen tüm modeller arasında %  $R_e$  için en iyi tahmin kabiliyetine sahip olan YSA modelinin tek gizli katmanlı, 10 işlem elemanlı (3-10-1) ve öğrenme algoritması olarak Levenberg-Marquardt geri yayılım algoritmasını (*trainlm*) kullanan ağ mimarisine sahip olduğu belirlenmiştir. Geliştirilen 3-10-1 ağ mimarili YSA modelinden elde edilen tahminlerin ölçüm sonuçları ile istatistiksel açıdan karşılaştırılması ile modelinin çok iyi bir tahmin yeteneğine sahip olduğu ve bu amaçla kullanılabilirliği görülmüştür.

**Anahtar Kelimeler:** Adsorpsiyon, Modelleme, Nikel (II) İyonları, Yapay Sinir Ağları, Zeolit

**PREDICTION OF NICKEL (II) IONS REMOVAL EFFICIENCY FROM LEACHATE USING ARTIFICIAL NEURAL NETWORK**

**ABSTRACT**

This paper presents the development of an artificial neural network (ANN) model for the prediction of the removal efficiency ( $R_e$  %) of Nickel (II) ions from leachate based on 90 experimental data sets obtained in a bench scale experiments. The ANN models developed in this study used three input variables including initial concentration of Ni (II) ions, adsorbent dosage, and contact time for predicting corresponding  $R_e$  %. The performance of the ANN models were assessed through mean square error (MSE), mean absolute error (MAE), and coefficient of determination ( $R^2$ ). The ANN model was able to predict  $R_e$  % of Ni (II) ions with a tangent sigmoid transfer function (*tansig*) in hidden layer with 10 neurons and a linear transfer function (*purelin*) in output layer. The Levenberg-Marquardt algorithm (*trainlm*) was found as the best training algorithm with a minimum MSE of 0,00049. The modeling results indicated that there was an excellent agreement between the experimental data and predicted values.

**Keywords:** Adsorption, Artificial Neural Networks, Modeling, Nickel (II) Ions, Zeolite

## 1. GİRİŞ (INTRODUCTION)

Sızıntı suyu, katı atıkların vahşi ya da düzenli depolanması sonucunda atıkların depolandığı alanda biriken kar, yağmur suları ve katı atıkların bünyesindeki sıvıların, atıkların içinden süzülerek birtakım fiziksel, kimyasal ve biyolojik olaylara maruz kalması sonucu depolama alanının tabanına ulaşan bir atıksu türüdür. Bu tür atıksular depolanan atıkların türüne bağlı olarak çevreye ve canlılara zarar verebilecek yüksek miktarda kirlilik yükü içeren organik maddeleri ve çeşitli toksik maddeleri içerisinde barındırmaktadır [1 ve 2]. Sızıntı suları hiçbir işleme tabi tutulmadan doğrudan alıcı ortamlara verildiğinde, içerisinde bulunan organik kirleticilerden dolayı bu ortamlarda oksijen kıtlığına neden olmaktadır. Ayrıca bu tür atıksular ihtiva ettiği ağır metaller gibi toksik kirleticiler nedeni ile hem alıcı ortamlardaki canlı hayatını olumsuz etkilemekte hem de bu ortamların geri dönüşümü zor olacak şekilde kirlenmesine neden olmaktadır. Bundan dolayı sızıntı sularının içerisindeki çevreye ve canlı yaşamına zarar verecek olan kirleticilerden arındırıldıktan sonra alıcı ortamlara deşarj edilmesi gerekmektedir.

Atıksuyun içinde bulunan kirleticilerin herhangi bir arıtma prosesinde hangi oranda giderildiğinin bilinmesi alıcı ortamlara deşarj edilecek atıksuların belirli standartları sağlanması açısından büyük önem arz etmektedir. Atıksulardan herhangi bir kirleticinin arıtılarak hangi oranda atıksudan uzaklaştırıldığı genellikle deneysel yöntemler kullanılarak belirlenmektedir. Fakat deneysel yöntemler hem çok fazla zaman gerektirmekte hem de deneylerin sürekli yapılmasından dolayı uzun vadede yüksek maliyetlere neden olmaktadır. Bu nedenle deneysel yöntemlere alternatif olarak, daha önceden elde edilmiş verileri kullanarak olaylar hakkında tahmin yapılmasını sağlayan çeşitli istatistiksel yöntemler ve modelleme teknikleri geliştirilmiştir. Bunlardan biri olan Yapay Sinir Ağları (YSA) son yıllarda bilimin diğer alanlarında olduğu gibi Çevre Mühendisliğinin birçok alanında da bir veri modelleme aracı olarak sıklıkla kullanılmaktadır [3, 4, 5 ve 6].

Bu çalışmanın başlıca amacı, katı atık depolama alanlarında elektronik atıkların ve atık pillerin depolanması sonucu sızıntı suyuna karışan Nikel (II) iyonlarının Zeolit adsorbenti ile değişik şartlar altında (Ni (II) iyonu başlangıç konsantrasyonu (mg/L), adsorbent miktarı (gr) ve temas süresi (dk)) sızıntı suyundan hangi oranda giderildiğini tahmin edebilen bir YSA modeli geliştirmektir. Bu amaçla model geliştirilmesi sürecinde MATLAB® yazılımındaki yapay sinir ağları modülü (Neural Network Toolbox) kullanılacaktır.

## 2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

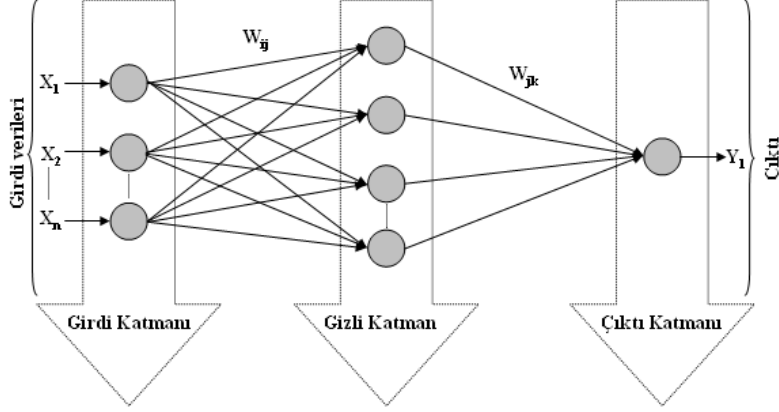
Katı atık depolama alanlarında oluşan sızıntı suları alıcı ortamlara verilmeden önce içerisindeki kirleticilerin miktarının deşarj standartlarında belirtilen değerlere uygun hale getirilmesi gerekmektedir. Bu tür atıksular herhangi bir arıtma işlemine tabi tutulduktan sonra içerisindeki kirleticilerin hangi oranda giderildiği genellikle deneysel yöntemlerle belirlenmektedir. Ancak deneysel yöntemler hem çok zaman gerektirmekte hem de uzun vadede büyük bir maliyeti beraberinde getirmektedir. Bu sebeplerden dolayı son yıllarda deneysel yöntemlere alternatif olarak, Yapay Sinir Ağları (YSA) gibi geçmiş verileri kullanarak tahmin yapabilen yöntem ve metotlar kullanılmaya başlanmıştır. Bu çalışmada sızıntı suyundan Ni(II) iyonlarının giderimini tahmin etmek için kullanılacak bir YSA modeli geliştirilecektir.

## 3. MATERYAL ve METOD (MATERIAL AND METHODS)

### • Yapay Sinir Ağları (YSA):

Yapay Sinir Ağları (YSA), insan beyninin çalışma prensibinden esinlenilerek beyindeki sinir hücrelerinin yapay olarak taklit edilmesi ve karmaşık problemleri çözmek amacıyla bilgisayar sistemlerine uygulanması

sonucu ortaya çıkmış bir veri işleme tekniğidir. YSA insan beyinde olduğu gibi örneklerden öğrenmekte ve genellikle veriler arasındaki ilişkilerin çok karmaşık ve doğrusal olmadığı durumlarda kullanılmaktadır [7 ve 8]. En basit YSA yapısı Şekil 1'de gösterildiği gibi girdi katmanı, gizli katman ve çıktı katmanı olmak üzere 3 farklı katman ve her bir katmanda nöron ya da işlem elemanı olarak adlandırılan bir ya da daha fazla sayıda basit yapay sinir hücresinden oluşmaktadır.



Şekil 1. Temel üç katmanlı yapay sinir ağı (YSA) mimarisi  
(Figure 1. Basic architecture of three-layer artificial neural network  
(ANN))

YSA yöntemi ile herhangi bir problemin modellenmesindeki en önemli nokta, probleme en iyi çözümü sağlayacak en uygun ağ mimarisini, yani gizli katman sayısını ve gizli katman(lar)daki işlem elemanı sayısının belirlenmesidir. Girdi ve çıktı katmanındaki işlem elemanı sayısı modellemeye kullanılacak olan parametre sayısına eşitken, gizli katman sayısı ve her bir gizli katmandaki işlem elemanı sayısı modellenecek problemin zorluğuna göre değişiklik göstermektedir. Modellenmek istenen problemdeki veriler arasındaki ilişki karmaşıklaştıkça oluşturulacak olan ağ mimarisindeki gizli katman sayısı ve her bir katmandaki işlem elemanı sayısı genel olarak artmaktadır.

YSA ile herhangi bir problemin modellenmesi kısaca şu şekilde gerçekleşmektedir: Öncelikle YSA'nın girdi katmanında dış dünyadan alınan veriler ağa tanıtılır. Gizli katman(lar) ve çıktı katmanında ise kendisinden önceki katmandan gelen veriler işlem elemanları arasındaki

ağırlıklar ( $w$ ) ile çarpılarak toplama fonksiyonu ( $y = \sum_{i=1}^m w_i * x_i$ ) yardımıyla

ağırlıklı ortalamaları alındıktan sonra transfer fonksiyonu aracılığı ile uygun çıktılara dönüştürülür. Gizli katman sayısı ve bu katman(lar)daki işlem elemanı sayısının deneme yanılma yoluyla değiştirilmesi ile oluşturulan YSA yapılarından probleme en iyi çözümü veren yapı, YSA tahminleri ile geçek değerlerin karşılaştırılması sonucu en uygun YSA mimarisi olarak belirlenir.

En yaygın olarak kullanılan transfer fonksiyonları logaritma sigmoid (*logsig*), tanjant sigmoid (*tansig*) ve lineer (*pureline*) transfer fonksiyonlarıdır ve sırasıyla denklem 1, 2 ve 3'de gösterilmiştir.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (1)$$

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

$$f(x) = x \quad (3)$$

- **Model Performans Kriterleri:**

Bu çalışmada oluşturulan YSA modellerinin performansları üç farklı ölçüt kullanılarak karşılaştırılmıştır. Bu ölçütler, Ortalama Karesel Hata (OKH), Ortalama Mutlak Hata ve determinasyon katsayısı ( $R^2$ ) gibi istatistiksel parametrelerdir.

Ortalama Karesel Hata (OKH), ölçüm değerleri ile model tahminleri arasındaki hata oranını belirlemek amacıyla kullanılmakta ve OKH değerinin sıfıra yaklaşması modelin tahmin kabiliyetinin artması anlamına gelmektedir. OKH aşağıdaki şekilde hesaplanmaktadır [8].

$$OKH = \frac{\sum_{i=1}^n (y_{model,i} - y_{göz,i})^2}{n} \quad (4)$$

Burada,

$y_{model,i}$  ve  $y_{göz,i}$  sırasıyla model tahminlerini ve ölçüm değerlerini,  $n$  ise gözlem sayısını göstermektedir.

Ortalama Mutlak Hata (OMH), ölçüm değerleri ile model tahminleri arasındaki mutlak hatayı belirleme amacıyla kullanılmaktadır. OMH değeri sıfıra ne kadar yakın olursa modelinin tahmin yeteneği o kadar iyi demektir. OMH aşağıdaki denklem kullanılarak hesaplanmaktadır [9].

$$OMH = \frac{1}{n} \sum_{i=1}^n |y_{göz,i} - y_{model,i}| \quad (5)$$

Determinasyon katsayısı ( $R^2$ ), ölçüm değerleri ile model tahminleri arasında doğrusal bir ilişki olup olmadığını belirlemek amacıyla kullanılır.  $R^2$  değeri 0 ile 1 arasında değişmekte ve bu değer 1'e yaklaşması model tahminleri ile ölçüm değerleri arasındaki bağımlılığın kuvvetli olduğu anlamına gelmektedir.  $R^2$  korelasyon katsayısının karesi olup aşağıdaki şekilde hesaplanmaktadır [4].

$$R^2 = \left[ \frac{n \sum_{i=1}^n y_{göz,i} y_{model,i} - (\sum_{i=1}^n y_{göz,i})(\sum_{i=1}^n y_{model,i})}{\sqrt{\left[ n \sum_{i=1}^n y_{göz,i}^2 - (\sum_{i=1}^n y_{göz,i})^2 \right] \times \left[ n \sum_{i=1}^n y_{model,i}^2 - (\sum_{i=1}^n y_{model,i})^2 \right]}} \right]^2 \quad (6)$$

#### 4. BULGULAR (FINDINGS)

- **Veri Seti:**

Bu çalışmada, Ni (II) iyonlarının sızıntı suyundan giderimine etki eden 3 farklı parametre (Ni (II) iyonu başlangıç konsantrasyonu (mg/L), adsorbent miktarı (gr) ve temas süresi (dk)) YSA modelinin geliştirilmesinde girdi parametresi olarak, Ni (II) iyonu giderim verimi (%  $R_e$ ) ise çıktı parametresi olarak kullanılmıştır. Deneysel veriler, değişik Ni (II) iyonu başlangıç konsantrasyonu (mg/L), temas süresi (dk) ve zeolit adsorbenti miktarı (gr) kullanılarak yapılan laboratuvar çalışmalarından elde edilmiştir. Deneysel verilerle ilgili istatistiksel bilgiler Tablo 1'de özetlenmiştir.

Tablo 1. YSA modelinde kullanılan deneysel verilerin istatistik analizi  
(Table 1. Statistical analyses of experimental data used in ANN model)

Değişkenler	İstatistikler			
	Minim um	Maksim um	Ortala ma	Standart Sapma
Girdi Katmanı				
Ni (II) İyonu Başlangıç Konsantrasyonu (mg/L)	1	50	18,3	15,2
Adsorbent Miktarı (gr)	0,1	2	0,85	0,65
Temas Süresi (dk)	5	50	21,2	14,7
Çıktı Katmanı				
Giderim Verimi (%)	0,42	81,6	45,2	25,3

YSA modelinin geliştirilmesinde kullanılacak olan ham veriler ağına eğitime başlamadan önce öğrenme süreci ve hataların önlenmesi açısından normalize edilmesi gerekmektedir. Bu nedenle ağına eğitime başlamadan önce girdi ve çıktı verileri denklem 7 kullanılarak normalize edilmiştir.

$$x_i = 0.8 \frac{(x - x_{\min})}{(x_{\max} - x_{\min})} + 0.1 \quad (7)$$

Burada,

$x_{\max}$  ve  $x_{\min}$  veri setindeki parametrelerin maksimum ve minimum değerleri,  $x_i$  ise  $x$  verisinin normalize edilmiş halidir. Normalize edilmiş verilerin %75'i ağına eğitmek, geri kalan %25'i ise eğitilmiş ağına test etmek için kullanılmak üzere rastgele olarak iki kısma ayrılmıştır.


• **Ağ mimarisinin oluşturulması:**

Herhangi bir problemin Yapay Sinir Ağları (YSA) ile modellenmesi probleme en iyi çözümü verecek en uygun ağ mimarisinin belirlenmesi ile sağlanmaktadır. Ağ mimarisini belirleyici unsurlardan en önemlileri probleme uygun öğrenme algoritmasının seçilmesi ve gizli katman sayısı ile her bir gizli katmandaki işlem elemanı sayısının belirlenmesidir. Öğrenme algoritmaları, girdi ve çıktı verileri arasındaki en uygun ilişkiyi sağlayacak olan bağlantı ağırlıklarının bulunmasını sağlamaktadır. Bu amaçla, bu çalışmada öncelikle en sık kullanılan öğrenme algoritmaları kullanılarak oluşturulan modeller karşılaştırılarak probleme en uygun öğrenme algoritması belirlenmiştir. Tüm öğrenme algoritmaları için tek gizli katmanlı ve 15 işlem elemanlı bir ağ mimarisi kullanılmıştır. Tablo 2'de çeşitli öğrenme algoritmaları kullanılarak oluşturulan modellerin performansları sunulmuştur. Tablo 2'deki sonuçlara göre, en küçük Ortalama Kare Hata (OKH) ve en büyük determinasyon katsayısına ( $R^2$ ) sahip olan Levenberg-Marquardt geri yayılım algoritması (*trainlm*) probleme en iyi çözümü sağlayan öğrenme algoritması olarak seçilmiştir.

Tablo 2. Tek gizli katmanlı ve 15 işlem elemanı YSA mimarisi için farklı öğrenme algoritmalarının performanslarının karşılaştırılması  
(Table 2. The comparison of model performances for different training algorithms in a network with 15 hidden neuron)

Öğrenme algoritması	Fonksiyon	OKH	R <sup>2</sup>
Ölçeklenmiş konjuge granyant geri yayılım algoritması	trainscg	0,00229	0,961
Powell-Beale konjuge gradyant geri yayılım algoritması	traincgb	0,01433	0,724
Fletcher-Reeves konjuge gradyant geri yayılım algoritması	traincgf	0,00110	0,980
Polak-Ribiere konjuge gradyant geri yayılım algoritması	traincgp	0,01223	0,793
Momentumlu granyant düşürme algoritması	traingdm	0,01208	0,846
Değişken öğrenme oranlı granyant düşürme algoritması	traingdx	0,00291	0,945
Levenberg-Marquardt geri yayılım algoritması	trainlm	0,00049	0,996
Esnek geri yayılım algoritması	trainrp	0,00080	0,985
BFGS quasi-Newton geri yayılım algoritması	trainbfg	0,00114	0,990
Tek adım algoritması	trainoss	0,00266	0,951
OKH, Ortalama karesel hata; R <sup>2</sup> , Determinasyon katsayısı			

Probleme en uygun öğrenme algoritması belirlendikten sonra ağ mimarisinin tamamlanması için gizli katman sayısı ve gizli katmanlardaki işlem elemanı sayısının belirlenmesi gerekmektedir. Bu çalışmada, problemin çözümü için tek gizli katmanın yeterli olduğu görüldüğünden dolayı, tek gizli katmanlı en iyi ağ mimarisi için gizli katmandaki işlem elemanı sayısı deneme yanılma metodu kullanılarak belirlenmiştir. Şekil 2’de tek gizli katmanlı YSA mimarisi için gizli katmandaki işlem elemanı sayısının YSA modelinin performansına etkisi gösterilmiştir. Şekil 2’den de görüldüğü gibi işlem elemanı sayısındaki değişime YSA modelinin performansında değişimlere neden olmuş ve 3,10 ve 14 işlem elemanı için lokal minimum Ortalama Karesel Hata (OKH) değerleri elde edilmiştir. Fakat 10 işlem elemanında en küçük OKH değeri elde edildiğinden dolayı tek gizli katmanlı ve 10 işlem elemanlı ağ mimarisinin problemin çözümü için en iyi durum olduğuna karar verilmiştir.



Şekil 2. Gizli katmandaki işlem elemanı sayısının YSA performansına etkisi  
(Figure 2. The effect of the number of neuron in hidden layer)

• **En iyi ağ mimarisi için elde edilen sonuçlar:**

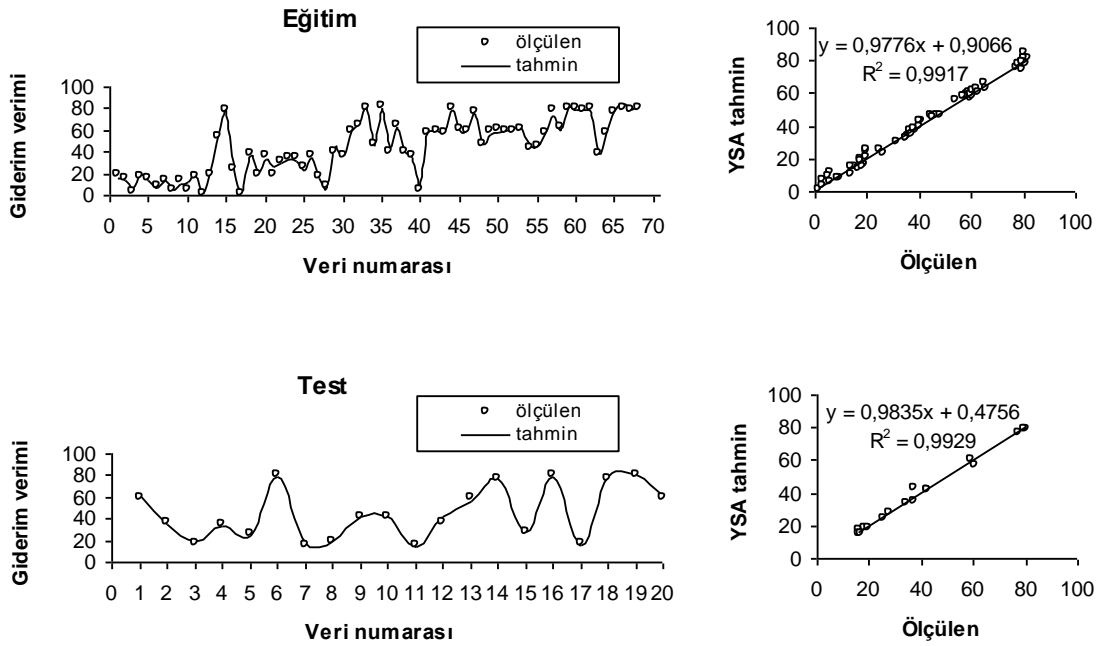
Sızıntı suyundan Zeolit adsorbenti ile Ni (II) iyonları giderim verimini en iyi tahmin eden ağ mimarisi (3-10-1) olarak belirlenmiştir. Seçilen bu ağ mimarisi için elde edilen performans değerleri Tablo 3’de özetlenmiştir.

Tablo 3. En iyi YSA mimarisi ile elde edilen sonuçlar  
(Table 3. Results for the best ANN architecture)

Optimum Yapı	Transfer fonksiyonu	İstatistiksel değerler					
		Eğitim			Test		
3-10-1	<i>tansig</i> (Gizli katman) ve <i>purelin</i> (Çıktı katmanı)	OKH	OMH	R <sup>2</sup>	OKH	OMH	R <sup>2</sup>
		0,00052	0,0174	0,9917	0,00032	0,0151	0,9929

OKH, Ortalama karesel hata; OMH, Ortalama Mutlak Hata; R<sup>2</sup>, Determinasyon katsayısı

Şekil 3'de eğitim ve test setlerinin her biri için YSA'dan elde edilen tahmin değerleri ile ölçüm değerleri karşılaştırılmıştır. Şekil 3'den de açık bir şekilde görüldüğü gibi geliştirilen YSA modeli sızıntı suyundan Ni (II) iyonları giderim verimini çok iyi bir şekilde tahmin etmiştir.



Şekil 3. Eğitim ve test setleri için tahmin ve ölçüm sonuçlarının karşılaştırılması

(Figure 3. The comparison of measured and predicted results for train and test sets)

## 5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada sızıntı suyundan Zeolit adsorbenti ile Ni (II) iyonları giderim verimini (% R<sub>e</sub>) tahmin etmek için bir Yapay Sinir Ağı (YSA) modeli geliştirilmiştir. Bu amaçla, üç farklı ortam şartı altında gerçekleştirilen laboratuvar deneylerinden elde edilen 90 adet veri YSA modelinin geliştirilmesinde kullanılmıştır. Probleme en uygun olan öğrenme algoritmasını belirlemek için 10 farklı öğrenme algoritması tek gizli katmanlı ve 15 işlem elemanlı bir ağ mimarisine sahip YSA için ayrı ayrı denenmiş ve her bir öğrenme algoritmasının kullanıldığı YSA modellerinin performansları karşılaştırılmıştır. Karşılaştırma sonucunda Levenberg-Marquardt geri yayılım algoritmasının (*trainlm*) probleme en uygun öğrenme algoritması olduğu tespit edilmiştir. Ayrıca sızıntı suyundan Ni (II) iyonlarının giderim verimini en iyi tahmin eden ağ mimarisinin (gizli katman ve gizli katman(lar)daki işlem elemanı sayısı) 3-10-1 yapısı olduğu deneme yanılma metodu kullanılarak belirlenmiştir. Sızıntı suyundan Ni (II)

iyonları giderim verimini en iyi tahmin eden 3-10-1 ağ mimarisinden elde edilen tahmin sonuçları ile ölçüm sonuçlarının istatistiksel açıdan karşılaştırılması sonucunda geliştirilen YSA modelinin tahmin kabiliyetinin çok iyi olduğu ve sızıntı suyunda Ni(II) iyonlarının giderim verimini tahmin etmede etki olarak kullanılabilceği görülmüştür.

#### **TEŞEKKÜR (THANK)**

Birinci yazar Türkiye Bilimsel ve Teknolojik Araştırma Kurumu(TÜBİTAK), Bilim İnsanı Destekleme Daire Başkanlığı (BİDEB)'na doktora eğitimi süresince vermiş oldukları desteklerden dolayı teşekkür eder.

#### **NOT (NOTICE)**

Bu çalışma, 14-16 Ekim 2010 tarihinde Dicle Üniversitesinde tamamlanan Bilimde Modern Yöntemler Sempozyumunda (BUMAT2010) sözlü sunumu yapılmış ve NWSA yazım esaslarına göre yeniden düzenlenmiştir.

#### **KAYNAKLAR (REFERENCES)**

1. Shouliang, H., Beidou, X., Haichan, Y., Liansheng, H., Shilei, F., and Hongliang, L., (2008). Characteristics of dissolved organic matter (DOM) in leachate with different landfill ages. *Journal of Environmental Sciences*, Volume:20, Number:4 ,pp:492-498.
2. Justin, M.Z. and Zupancic, M., (2009). Combined purification and reuse of landfill leachate by constructed wetland and irrigation of grass and willows. *Desalination*, Volume:246, Number:1-3 ,pp:157-168.
3. Bowen, W.R., Jones, M.G., Welfoot, J.S., and Yousef, H.N.S., (2000). Predicting salt rejections at nanofiltration membranes using artificial neural networks. *Desalination*, Volume:129, Number:2 ,pp:147-162.
4. Doğan, E., Ateş, A., Yılmaz, E.C., and Eren, B., (2008). Application of Artificial Neural Networks to Estimate Wastewater Treatment Plant Inlet Biochemical Oxygen Demand. *Environmental Progress*, Volume:27, Number:4 ,pp:439-446.
5. Sadrzadeh, M., Mohammadi, T., Ivakpour, J., and Kasiri, N., (2009). Neural network modeling of  $P^{b2+}$  removal from wastewater using electrodialysis. *Chemical Engineering and Processing: Process Intensification*, Volume:48, Number:8 ,pp:1371-1381.
6. Eyupoglu, V., Eren, B., and Dogan, E., (2010). Prediction of Ionic Cr (VI) Extraction Efficiency in Flat Sheet Supported Liquid Membrane Using Artificial Neural Networks (ANNs). *Int. J. Environ. Res.*, Volume:4, Number:3 ,pp:463-470.
7. Kashaninejad, M., Dehghani, A.A., and Kashiri, M., (2009). Modeling of wheat soaking using two artificial neural networks (MLP and RBF). *Journal of Food Engineering*, Volume:91, Number:4, pp:602-607.
8. Singh, K.P., Basant, A., Malik, A., and Jain, G., (2009). Artificial neural network modeling of the river water quality-A case study. *Ecological Modelling*, Volume:220, Number:6 ,pp:888-895.
9. Kaveh, N.S., Ashrafizadeh, S.N., and Mohammadi, F., (2008). Development of an artificial neural network model for prediction of cell voltage and current efficiency in a chlor-alkali membrane cell. *Chemical Engineering Research and Design*, Volume:86, Number:5 ,pp:461-472.