

## YAPAY SİNİR AĞLARI İLE BEYŞEHİR GÖLÜ SU SEVİYESİ DEĞİŞİMLERİNİN BELİRLENMESİ

Alpaslan YARAR, Mustafa ONÜÇYILDIZ

Selçuk Üniversitesi Mühendislik Mimarlık Fakültesi İnşaat Mühendisliği Bölümü, KONYA  
[ayarar@selcuk.edu.tr](mailto:ayarar@selcuk.edu.tr), [m13yildiz@selcuk.edu.tr](mailto:m13yildiz@selcuk.edu.tr)

**ÖZET:** Hidrolojik modelleme çalışmalarında, bilindiği halde ölçülemeyen veya hesaba katılmayan bazı değerler mevcuttur. Yapay Sinir Ağları gibi modelleme araçları bu gibi değerlerin yokluğunda oldukça iyi sonuçlar vermektedir. Bu çalışmada Konya Ovası Projesinin ana su kaynağı olan Beyşehir Gölü'nün su seviyesi değişimleri Yapay Sinir Ağları yöntemi ile belirlenmeye çalışılmıştır. DSİ tarafından yapılan, 1962 ile 1990 yılları arasına ait Giren akım-Kayıp akım, Yağış, Buharlaştırma, Çekilen akım ve Seviye ölçümleri kullanılarak Yapay Sinir Ağları yöntemi yardımı ile seviye değerleri elde edilmiş ve elde edilen değerler geleneksel yöntemlerden edinilen sonuçlarla karşılaştırılmıştır. Yapılan uygulamalar ile en iyi sonuç Ölçeklendirilmiş Eşleştirmeli Gradyant modelinde 1 gizli katman, 7 gizli düğüm sayısı ve 500 epoch için en küçük hata 0.056285 ile elde edilmiştir.

Beyşehir Gölü için yapılan bu çalışma ile geleneksel yöntemlerle yapılan seviye ölçümlerinin değerlendirilmesinde karşılaşılan zorluk ve problemlerin ortadan kaldırılması ile sonuca en kısa sürede ulaşılması amaçlanmıştır.

**Anahtar Kelimeler:** *Yapay Sinir Ağları, Beyşehir Gölü, Seviye Değişimleri, Su Dengesi, Su Bütçesi.*

### Determination of Water Level Fluctuations of Beyşehir Lake Using Artificial Neural Networks

**ABSTRACT:** There are some datas, which are known but ignored or cannot be measured, in hydrological modeling studies. Modeling instruments like Artificial Neural Networks, give efficient results in absence these datas. In this study, water level changes of Beyşehir Lake that is the main water resource of Konya Plain Project, was studied with Artificial Neural Networks method. DSİ carried out the determination of level values with Artificial Neural Networks using Inflow – Loss flow, Rainfall, Evaporation, Drawn flow and Level measurements between years 1962 – 1990, and the obtained values were compared with the results of the traditional methods.

The best result was obtained by Scaled Conjugate Gradient model with 0.056285 as lower error, under 1 hidden layer, 7 hidden nodes and 500 epochs, with made application.

With this study, performed for Beyşehir Lake, it was aimed to obtain the results in a very short time by eliminating the difficulties and problems faced during the traditional evaluation of level measurements.

**Keywords:** *Artificial Neural Networks, Beyşehir Lake, Level Changes, Water Equilibrium, Water Budget.*

### GİRİŞ

Hidrolojik problemlerin çözümünde son zamanlarda matematiksel modeller kurularak bu modellerin bilgisayar yardımıyla çözülmesi ile sonuca gidilmeye çalışılmaktadır. Ancak problemlerin çözülmesinde sadece bilgisayarların hızından ve bilgi tutma

kapasitesinden yararlanmak yetersiz kalmaktadır. Mevcut bilgisayarlarla ya da algoritmalarla çözülemeyen veya iyi sonuç alınamayan, hidrolojik olaylara ait karmaşık problemlere çözümler üretmek için, son yıllarda yeni bir bilgi işleme yöntemi olarak Yapay Sinir Ağları kullanılmaktadır.

Hidrolojide zaman serilerinin analizinde mevcut tekniklerin çoğu değişkenler arasında lineer ilişkiler olduğunu kabul etmektedir. Gerçekte ise verilerdeki zamansal değişimler basit ve düzenli olmayıp lineer değildir. Yağış, yağış-akış, yer altı suyu modellemesi ve hazne çalışmaları gibi hidrolojik tahmin çalışmalarında Yapay Sinir Ağları (YSA), geleneksel metotlara alternatif olarak oldukça başarılı sonuçlar üretmektedir (French ve diğ., 1992; Grimes ve diğ., 2003; Luk ve diğ., 2000; Baratti ve diğ., 2003; Chang ve Chen, 2001; Chang ve diğ., 2004; Dawson ve Wilby, 1998; Hsu ve diğ., 1995; Karunanithi ve diğ., 1994; Xu ve Li, 2002; Zhu ve Fujita, 1994; Lallahem ve Mania, 2003; Yang ve diğ., 1997; Hasebe ve Nagayama, 2002; Jain ve diğ., 1999; Raman ve Chandramouli, 1996).

Ülkemizin en büyük tatlı su gölü olma özelliğini taşıyan, Konya ve Isparta illerinin bir kısmının su temininde en önemli su kaynağı olan Beyşehir Gölü su kaynaklarına ilişkin koruma ve kullanım çalışmaları açısından büyük önem arz etmektedir.


Beyşehir Gölü'ne ait işletme kotları göl su seviyesinin geçmiş yıllardaki değişimleri, yörede arazilerinin sulanmasını bekleyen üreticilerin sosyo-ekonomik durumları, taşkın sorunu ve Çevre Bakanlığının önerileri de dikkate alınarak belirlenmiştir. Beyşehir Gölü, Suğla Gölü, Apa Barajı kanallarla birbirine bağlanarak suyun fazla olduğu bölgeden az olan bölgeye aktarımı söz konusudur. Göl seviyesi ve gölden çekilen su miktarı birbiri ile direkt ilişkili olarak yıldan yıla değişim göstermektedir. Çekilen su miktarı göl çevresi belediyeleri ile diğer belediyeler arasında anlaşmazlıklara sebep olmaktadır. Son yıllarda

kullanımı hızla artan, yeni bir bilgi işleme yöntemi olan Yapay Sinir Ağları metodu kullanılarak seviyenin belirlenmesi zaman ve gerçeklik açısından önemlidir.

## MODEL

Yapay sinir ağlarının oluşturulmasında biyolojik sinir ağlarının yapısından esinlenilmiştir. Bu sebeple sinir sisteminin en basit yapısı olan bir nöronun analizi önem arzeder. Nöron, sinir ağlarının en temel elemanlarından birisi olup sinir sistemi içerisindeki fonksiyon ve görevlerine göre değişik şekil ve büyüklükte olabilir. Bütün nöronların ortak bazı özellikleri bulunmaktadır (Şekil 1.)

Nöron, soma adı verilen hücre gövdesi, bir ucunda bir grup liflere benzer "dentrit" adı verilen ve hücreye diğer hücrelerden veya dış dünyadan bilgiler (sinyaller) getiren bağlantı elemanları, diğer ucunda ise tek bir life benzer "akson" adı verilen ve hücrelerden diğerlerine veya dış dünyaya bilgiler taşıyan bağlantı elemanından müteşekkildir. Bu akson daha sonra diğer hücrelerle birleşme esnasında dağınık dallara ayrılmaktadır. Bu iki uçtaki bağlantı noktalarının elektrofizyolojik olarak hücrelerdeki bilgileri işlemede önemli yeri vardır. Dentrit tarafından alınan sinyaller hücrede birleştirilerek bir çıkış darbesi üretilip üretilmeyeceğine karar verilir. Eğer bir iş yapılacaksa üretilen çıkış darbesi aksonlar tarafından taşınarak diğer nöronlarla olan bağlantılara veya terminal organlara iletilir.



Şekil 1. Biyolojik nöron/sinir hücresinin şematik yapısı.

Hızlı hesaplama yönelik YSA çalışmaları 1950'li yıllarda başlamıştır. Basit nöron modellerine dayalı bir hesaplama modeli, Rosenblatt (1959) tarafından önerilmiş ve ardından perceptron diye bilinen tek katmanlı ilk YSA modeli ortaya çıkmıştır. Widrow ve Hoff (1960), bu basit nöron modelini kullanarak öğrenebilen ilk adaptif sistemler üzerinde çalışmış ve delta kuralı diye bilinen; gerçek çıkış ile istenen çıkış arasındaki farka eşit bir hata terimi kullanarak bağ ağırlıklarının değiştirildiği bir öğrenme kuralını ortaya koymuşlardır.


Bilgisayar ortamında, beynin yaptığı işlemleri yapmaya çalışan, karar verebilen, sonuç çıkarabilen, yetersiz veri durumunda var olan mevcut verilerden yola çıkarak sonuca ulaşabilen, sürekli yeni veri girişini kabul eden, öğrenen, hatırlayan bir algoritma "Yapay Sinir Ağları" (YSA) olarak adlandırılır (Kaltakçı ve Dere 1997).

Grossberg (1986), Uyarlanabilir Rezonans Teorisi (Adaptive Resonance Theory, ART) adında bir YSA yapısını geliştirmiştir. ART çok gelişmiş bir YSA modeli olmakla beraber henüz çok fazla probleme uygulanmamıştır. Aynı zamanda Kohonen (1984)'de "kendi kendini düzenleyen nitelik haritası" (self-organizing maps) geliştirmiştir. Bu YSA modeli, nümerik aerodinamik akış hesaplamaları için çoğu algoritmik yöntemden daha etkili olmuştur.

Rumelhart ve diğ. (1986) "Paralel Distributed Processing" (paralel dağılımlı

işleme) adlı kitaplarında, ileri beslemeli (feed-forward) ağlarda yeni öğrenme modeli olan hatanın geriye yayılması algoritmasını (backpropagation algorithm) geliştirerek, daha önce bu konuda Minsky ve arkadaşları tarafından iddia edilen aksaklıkların aşılabileceğini göstermişlerdir. Bugün endüstride birçok YSA uygulamasında bu öğrenme yöntemi ile bunun değişik varyasyonları kullanılmaktadır. Back-propagation algoritması, kullanımı çok yaygın olan ve öğrenilmesi kolay bir ağıdır. Ayrıca biyolojik işaretlerin sınıflamalarında tercih edilen bir ağ yapısıdır. İç içe girmiş konveks yapıdaki kümelerin sınıflamasını rahatlıkla yapmaktadır.

YSA temel olarak, Şekil 2.'te görüldüğü gibi, basit yapıda ve yönlü bir şebeke/ağ biçimindedir. Her bir düğüm, hücre denilen  $n$ . Dereceden lineer olmayan bir devredir. Düğümler işlem elemanı olarak tanımlanır. Düğümler arasında bağlantılar vardır. Her bağlantı tek yönlü işaret iletim yolu olarak görev yapar. Her işlem elemanı istenildiği sayıda giriş bağlantısı ve tek bir çıkış bağlantısı alabilir. Fakat bu bağlantı kopya edilebilir. Yani bu tek çıkış, birçok hücreyi besleyebilir. Ağdaki tek gecikme, çıkışları ileten bağlantı yollarındaki iletim gecikmeleridir. İşlem elemanının çıkışı isteğe bağlı olarak sürekli/reel veya iki tabanlı bir değeri olan herhangi bir matematiksel tipte olabilir.



Şekil 2. Üç katmanlı basit bir YSA örneği.

Kısmen sürekli çalışma konumunda "aktif" halde eleman bir çıkış işareti üretir. Giriş işaretleri YSA ya bilgi taşır. Sonuç ise çıkış işaretlerinden alınabilir.

Hatanın geriye yayılması eğitime algoritması, çok katmanlı,ileri yayımlı bir perceptrondan elde edilen çıkışlar ile eldeki hedef çıkışlar arasındaki hataların karesinin ortalamasını minimum yapmak için geliştirilmiş iteratif bir gradyan algoritmadır (Şekil 3).

Şekil 3'de şeması gösterilen algoritma, ana hatlarıyla şöyledir: Ağ mimarisi tanımlanır ve ağırlıklar bazı rastgele küçük sayılar ile başlatılarak, ağa giriş sunulur. Burada m-boyutlu giriş örüntüleri girildiğinde;  $x_i = [x_1, x_2, \dots, x_m]^T$ 'dir. Benzer şekilde istenilen n-boyutlu çıkış örüntülerini ise;  $d_k = [d_1, d_2, \dots, d_n]^T$  belirtir.  $x_i$  değerleri i katmanındaki nöronların çıkış değerleri ise, j katmanındaki bir nörona gelecek olan toplam giriş,

$$\text{net}_j = \sum_{i=1}^m w_{ji} \cdot x_i \quad (\text{i.düğümünden j. düğümüne}) \quad (1)$$

şeklinde olur. Gizli katmandaki j nöronunun çıkışı;

$$y_j = f_j(\text{net}_j), \quad j=1,2,\dots,j \quad (2)$$

şeklinde gösterilebilir. Burada  $f_j$  transfer fonksiyonudur. Çıkış katmanındaki k nöronuna gelecek olan toplam giriş ise;

$$\text{net}_k = \sum_{j=1}^j w_{kj} \cdot y_j \quad (3)$$

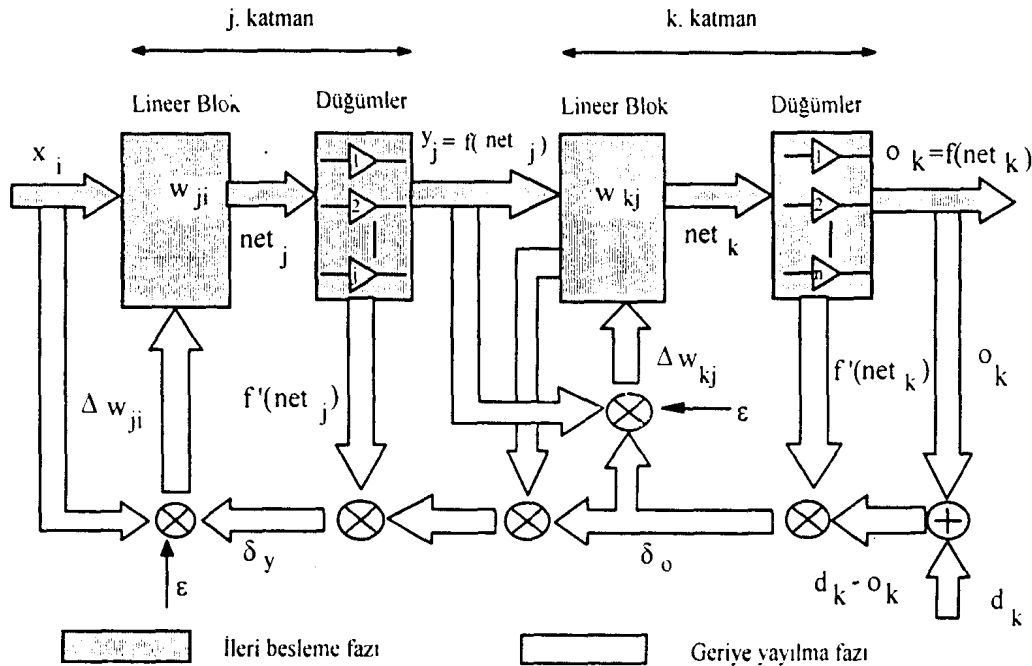
şeklinde. Yine çıkış katmanındaki bir k nöronunun lineer olmayan çıkışı;

$$o_k = f_k(\text{net}_k), \quad k=1,2,\dots,n \text{ olur.} \quad (4)$$

Ağdan elde edilen çıkış, asıl çıkış ile karşılaştırılır ve  $e_k$  hatası;

$$e_k = (d_k - o_k) \quad (5)$$

formülü ile hesaplanır. Burada  $d_k$  ve  $o_k$  sırasıyla çıkış katmanındaki herhangi bir k nöronunun hedef (istenilen) ve ağdan elde edilen (asıl) çıkışlardır. Dikkat edilmesi gereken husus, böyle bir karşılaştırmanın sadece ağın çıkış katmanı için mümkün olmasıdır. Böylece çıkış katmanıyla olan bağlar için ağırlık ayarlaması öncelikle göz önüne alınır.



Şekil 3. Hatanın geriye yayılması algoritmasının blok diyagramı.

## MODEL DENEYLERİ

Bilindiği gibi hidroloji'nin temel denklemlerinden olan su dengesi denklemi  $X - Y = \Delta S$  gereğince bir hidrolojik sisteme giren su ile çıkan suların farkı o hidrolojik sistemdeki su miktarının değişimini verir. Yağış, yüzeysel akış, yeraltı akışı gibi parametreler giren suyu (X), buharlaşma, yüzeysel akış, yeraltı akışı ve sızma gibi parametreler çıkan suyu (Y), seviye değişimi, nem değişimi gibi değerler de değişen su miktarını ( $\Delta S$ ) verir. Bu çalışmada DSİ 4. Bölge Müdürlüğü tarafından belirlenen 1962 ile 1990 yılları arasındaki Giren akım-Kayıp akım (G-K), Yağış (Y), Buharlaşma (B) Çekilen akım (Ç) ve Seviye (S) değerleri kullanılarak seviye değişimleri YSA metodu ile hesaplanarak, hesaplanan değerlerin ölçülen ve değerlendirilerek düzeltilen değerlere olan yakınlığı araştırılmıştır.

### Yapay Sinir Ağları Modellerinin Eğitilmesi

Literatürde çok sayıda öğrenme algoritması mevcuttur. Bunlar YSA yapılarına göre değişmektedir. Bu çalışmada kullanımının ve uygulamalarının yaygın olması sebebiyle geriye yayımlı çok katmanlı YSA modeli esas alınmış ve 3 farklı algoritma kullanılmıştır. Bunlar Levenberg-Marquardt, Tek Adım Sekant ve Ölçeklendirilmiş Eşleştirmeli Gradyent algoritmalarıdır.

Oldukça başarılı bir optimizasyon metodu olan Levenberg-Marquardt (LM) Öğrenme Algoritması, öğrenmede kullanılan geri yayımlı algoritmasının farklı öğrenme tekniklerinden biridir. Çok sayıda komşuluk fikri üzerine dayanan LM algoritması, en küçük kareler yaklaşımı (least square estimation) metodudur (Levenberg, 1944; Marquardt, 1963). Levenberg-Marquardt algoritmasının en önemli avantajlarından biri, hızlı yakınsama özelliğidir.

Bazı yöntemlerin her bir iterasyonda ihtiyaç duyduğu hafıza ve işlem zamanını azaltmak için bir sekant yaklaşımına ihtiyacı vardır. Tek Adım Sekant Öğrenme Yöntemi bu alandaki yöntemler arasındaki eksikliklere cevap vermek amacıyla geliştirilen bir algoritmadır.

Ölçeklendirilmiş Eşleştirmeli Gradyent algoritması, Moller tarafından doğrudan arama süresinde kazanç sağlamak amacıyla

geliştirilmiş son derece kompleks bir algoritmadır (Moller 1993). Temel yaklaşımı, güvenilir bölgelerin birleştirilmesine dayanır ve Levenberg-Marquardt algoritmasında da kullanılan model-doğru alan yaklaşımına erişmektedir.

Eğitime işlemi için 1962 ile 1985 yılları arasındaki 276 aylık veri kullanılmıştır. Giriş katmanında Giren akım-Kayıp akım, Yağış, Buharlaşma Çekilen akım değerleri, çıkış katmanında ise Seviye Değişimi değerleri bulunmaktadır. Burada seviye değerleri kot olarak verildiği için her ayın seviye değişimi değerleri bir önceki ayla olan kot farkları alınarak hesaplanmıştır.

Eğitime işlemi farklı yapılarda yapılmıştır. Bu yapılar gizli katman ve gizli düğüm sayılarına göre değişmiştir. Bu yapılar 5-1, 6-1, 7-1, 8-1, 9-1, 9-9-1 olarak alınmıştır. İlk beş yapıda bir gizli katman ve bir çıkış katmanı mevcuttur. Yapılardaki ilk değerler gizli katmandaki düğüm sayılarını, son değerler ise çıkış katmanını göstermektedir. Son yapıda ise iki gizli katman vardır. Yine ilk iki değer gizli katmandaki düğüm sayılarını son değer ise çıkış katmanını göstermektedir. Ayrıca her yapı için epoch sayıları artırılarak denenmiş ve en iyi sonuçlar elde edilmeye çalışılmıştır. Epoch sayısı iterasyon sayısının farklı bir yapısıdır. 1 epoch, eğitimdeki set sayısı kadar iterasyon sayısına eşittir. Yani 1 epoch = 276 iterasyon'dur. Böylece her yapıda 100, 250, 500, 750 ve 1000 epoch'ta eğitim işlemi yapılmıştır. Eğitim işlemi sonucunda öğrenilen seviye değişim değerlerine bağlı olarak elde edilen kotlarla ölçülen gerçek kotlar arasındaki farkların mutlak değerlerinin aritmetik ortalaması hesaplanarak ortalama hatalar bulunmuştur. Oluşan eğitim hataları Tablo 1.'de verilmiştir.

### YSA Modellerinin Test Edilmesi

Test işlemi için 1985 ile 1990 arasındaki 72 aylık değerler kullanılmıştır. Bu aşamada sadece giriş katmanı olan Giren akım- Kayıp akım, Yağış, Buharlaşma ve Çekilen akım değerleri hacim cinsinden verilerek Seviye Değişimi değerleri elde edilmiştir. Bu işlem eğitimde kullanılan her yapı ve her epoch sayısında yapılmıştır. Test işlemi sonucunda bulunan aylık

seviye değişimi değerleri eğitime setinin son ayındaki kot değerinden başlanarak ardışık olarak eklenmiş, böylece YSA sonuçlarının kotları elde edilmiştir.

Test işlemi sonucunda elde edilen seviye değişim değerlerine bağlı olarak hesaplanan kotlarla ölçülen gerçek kotlar arasındaki farkların mutlak değerlerinin aritmetik ortalaması hesaplanarak ortalama hatalar bulunmuştur. Oluşan test hataları Tablo 2.'de verilmiştir.

Tablo 2.'deki ortalama hatalardan da görüldüğü gibi LM algoritması için bir gizli katmanlı yapılar, iki gizli katmanlı yapıya göre daha iyi sonuç vermektedir. Çünkü hata oranları

arttıkça istenilen kot değerlerinden uzaklaşmaktadır. Diğer iki algoritmada hata oranları bir ve iki gizli katmanlı yapılarda belirgin farklılıklar göstermese de en küçük hatalar, dolayısıyla da en iyi performanslar bir gizli katmanlı yapılarda elde edilmiştir. LM için 7-1 yapısı ve 100 epoch sayısında, ÖEG için 7-1 yapısı ve 500 epoch sayısında, TAS için ise 5-1 yapısı ve 1000 epoch sayısında en iyi sonuçlar edilmiştir.

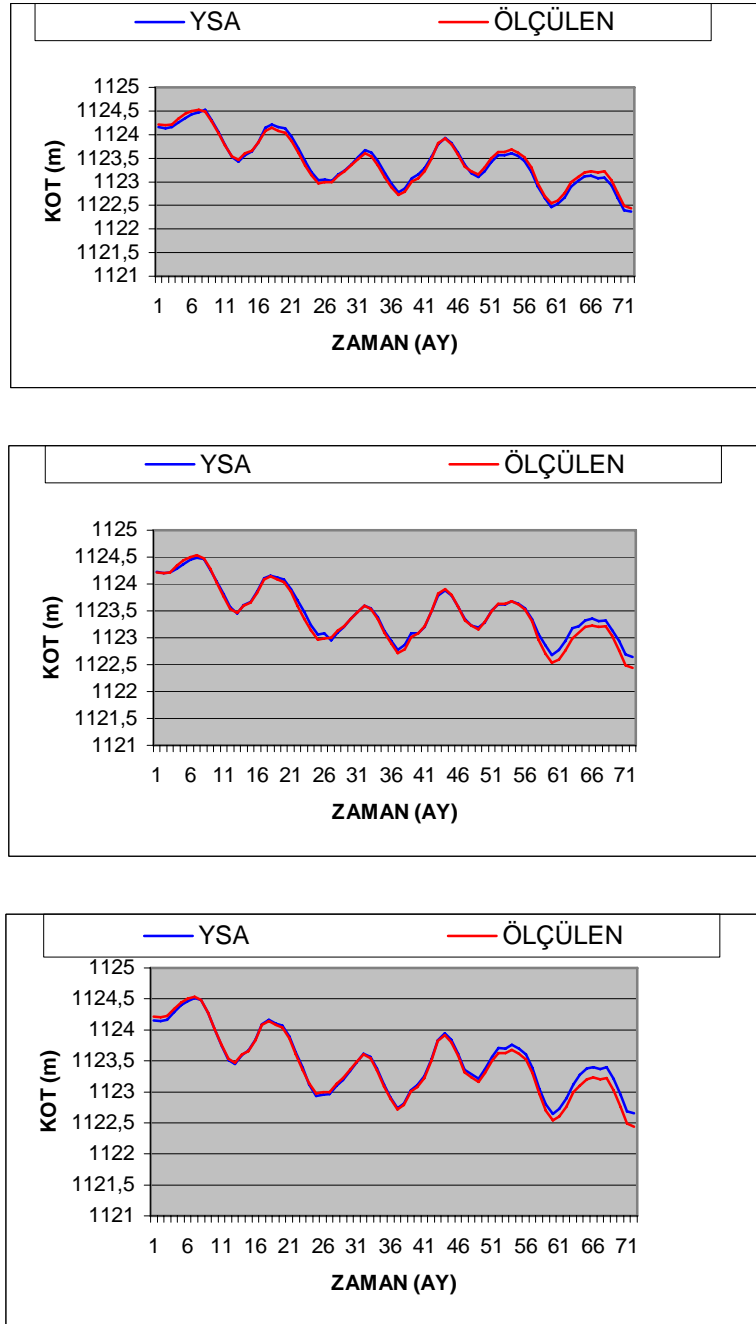
Bu sonuçlara göre elde edilen kotlarla ölçülen gerçek kotlar arasındaki ilişki Şekil 4'de verilmiştir. Şekillerden de anlaşılacağı üzere her üç algoritmanın da en iyi sonuçları birbiri ile uyum içinde olup yakınlık göstermektedir.

**Tablo 1.**Eğitime hataları.

	EPOCH SAYISI	YAPI					
		5--1	6--1	7--1	8--1	9--1	9--9--1
LM	100	0.205568	0.220397	0.145880	0.196989	0.134527	0.251385
	250	0.216015	0.221383	0.146103	0.143776	0.112717	0.091425
	500	0.215773	0.218280	0.151070	0.159230	0.115611	0.092500
	750	0.215752	0.214080	0.151237	0.165215	0.117996	0.056449
	1000	0.215737	0.211549	0.151274	0.173000	0.120005	0.024190
ÖEG	100	0.128414	0.604470	0.299943	0.908245	0.311924	0.300904
	250	0.199841	0.288666	0.457898	0.366374	0.316663	0.266050
	500	0.226416	0.112317	0.208757	0.267513	0.208928	0.204089
	750	0.225264	0.188524	0.078286	0.268874	0.207797	0.192543
	1000	0.234346	0.240756	0.094430	0.263499	0.202718	0.242567
TAS	100	0.327929	1.227667	0.574385	0.730468	1.000523	0.409476
	250	0.314609	1.214601	0.485196	0.835740	1.052680	0.294022
	500	0.306748	1.226666	0.435004	0.269912	1.050364	0.404519
	750	0.308267	1.225727	0.382212	0.172830	1.027969	0.524171
	1000	0.178169	1.189757	0.142730	0.142730	1.016410	0.526437

**Tablo 2.** Test hataları.

	EPOCH SAYISI	YAPI					
		5--1	6--1	7--1	8--1	9--1	9--9--1
LM	100	1.375006	0.119029	<b>0.063949</b>	0.149528	0.304044	0.252168
	250	0.094464	0.100926	0.065175	0.211908	0.148510	0.383051
	500	0.094354	0.101485	0.072347	0.277537	0.105144	3.185457
	750	0.094261	0.102086	0.072486	0.274193	0.128569	8.252882
	1000	0.094233	0.106947	0.072526	0.271172	0.128465	9.462793
ÖEG	100	0.153465	0.986554	0.157626	0.663174	0.175336	0.201990
	250	0.064732	1.214164	0.193728	0.560286	0.166942	0.460701
	500	0.226954	0.224781	<b>0.056285</b>	0.547072	0.186011	0.600475
	750	0.112469	0.231796	0.057628	0.552168	0.434408	0.436408
	1000	0.195450	0.615686	0.122629	0.473457	0.405593	0.267644
TAS	100	0.589719	1.605911	0.080026	0.301369	1.768126	0.287822
	250	0.547899	1.599697	0.139540	0.271869	1.551262	0.354399
	500	0.379615	1.591197	0.177692	0.587204	1.251176	1.005040
	750	0.113810	1.590078	0.157421	0.611999	1.214997	1.408050
	1000	<b>0.059022</b>	1.400633	0.121201	0.623237	1.212063	1.297351



Şekil 4. Elde edilen kotlarla ölçülen gerçek kotlar arasındaki ilişki.

## SONUÇLAR

Bu çalışmada göl su seviyelerinin modellenmesi için Yapay Sinir Ağları'nın kullanım potansiyeli araştırılmıştır. Bu amaçla Konya Beyşehir Gölü'ne ait 1962-1990 yılları arasındaki aylık veriler kullanılarak, Giren Akım-Kayıp Akım, Yağış, Buharlaşma, Çekilen Akım değerleri girdi, göl Su Seviyesi Değişimi değerleri de çıktı olarak alınmış ve Çok Katmanlı Geri Yayılımlı Yapay Sinir Ağları'nda 3 farklı

model oluşturulmuştur. Öğrenme ve tahmin aşamalarında modellerden elde edilen seviye verileri ile gözlenmiş seviye verileri arasındaki ilişki belirlenmiştir.

Oluşturulan 3 farklı modelden Ölçeklendirilmiş Eşleştirmeli Gradyant modelinde 1 gizli katman, 7 gizli düğüm sayısı ve 500 epoch için en küçük hata 0.056285 elde edilmiştir.

Çalışma sonucunda çok karmaşık ve lineer olmayan Beyşehir Gölü su seviyesi değişiminin

Su Dengesi denkleminin Yapay Sinir Ağları metoduna uyarlanmasıyla kolayca modellenebileceği gösterilmiştir.

Çalışma sonucunda Beyşehir Gölü'ne giren ve çıkan yeraltı suyunun belirlenmesi için yeterince gözlem yapılmadığı kanaatinden hareketle göl çevresinde yeraltı suyu gözlem kuyularının faaliyete geçirilerek gerekli gözlemlerin yapılması önerilmektedir. Ayrıca 1992'de başlayan ve devam eden çalışmalarla

göle giren ve çıkan akımların tam olarak belirlenmesiyle göl tabanından olduğu ileri sürülen kayıpların da YSA metoduyla kolayca hesaplanabileceği açıktır.

### TEŞEKKÜR

Bu yayın Alpaslan YARAR'ın Yüksek Lisans Tez çalışmasından olup Selçuk Üniversitesi Fen Bilimleri Enstitüsüne teşekkür ederiz.

### KAYNAKLAR

- Baratti, R., Cannas, B., Fanni, A., Pintus, M., Sechi, G.M., Toreno, N., 2003. River flow forecast for reservoir management through neural networks. *Neurocomputing*, 55 (3-4), 421-37.
- Chang, F.J., Chen, Y.C., 2001. A counterpropagation fuzzy-neural network modeling approach to real time stream flow prediction. *J Hydrol*, 245, 153-64.
- Chang, L.C., Chang, F.J., Chiang, Y.M., 2004. A two-step-ahead recurrent neural network for stream-flow forecasting. *Hydrol Process*, 18 (1), 81-92.
- Dawson, C.W., Wilby, R.L., 1998. An artificial neural network approach to rainfall-runoff modeling. *Hydrol Sci*, 43 (1), 47-67.
- French, M.N., Krajewski, W.F., Cuykendall, R.R., 1992. Rainfall forecasting in space and time using a neural network. *J Hydrol*, 137, 1-31.
- Grimes, D.I.F., Coppola, E., Verdecchia, M., Visconti, G., 2003. A neural network approach to real-time rainfall estimation for Africa using satellite data. *J Hydrometeorol*, 4, 1119-33.
- Grossberg, S. 1986. *The Adaptive Brain I: Cognition, Learning, Reinforcement, and Rhythm, and The Adaptive Brain II: Visions, Speech, Language, and Motor Control*, Elsevier/North-Holland, Amsterdam.
- Hasebe, M., Nagayama, Y., 2002. Reservoir operation using the neural network and fuzzy systems for dam control and operation support. *Adv Eng Software*, 33 (5), 245-60.
- Hsu, K.L., Gupta, H.V., Sorooshian, S., 1995. Artificial neural network modeling of the rainfall-runoff process. *Water Resour Res*, 31 (10), 2517-30.
- Jain, S.K., Das, A., Srivastava, D.K., 1999. Application of ANN for reservoir inflow prediction and operation. *J Water Resour Plan Manage*, 125 (5), 263-71.
- Kaltakçı M.Y., Dere Y. 1997, "Yapay Sinir Ağları Uygulamalarının İnşaat Mühendisliğinde Kullanımı", Prof. Dr. Rifat Yarar Sempozyumu, Editör: Semih S. Tezcan, İTÜ İnşaat Fakültesi Dekanlığı, Maslak-İstanbul, 10 Aralık, 411-420.
- Karunanithi, N., Grenney, W.J., Whitley, D., 1994. Neural network for river flow prediction. *J Comput Civil Eng*, 8, 201-20.
- Kohonen, T. 1984. *Self-Organization and Associative Memory*, Springer-Verlag, Berlin.
- Lallahem, S., Mania, J., 2003. Evaluation and forecasting of daily groundwater outflow in a small chalky watershed. *Hydrol Process*, 17 (8), 1561-77.
- Levenberg K. 1944. A "Method For the Solution of Certain Nonlinear Problems in Least" Squares, *Quart. Appl. Math.*, 2: 164-168.
- Luk, K.C., Ball, J.E., Sharma, A., 2000. A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting. *J Hydrol*, 227, 56-65.
- Marquardt D. W. 1963. "An Algorithm For Least-Squares Estimation Of Nonlinear Parameters," *J. Soc. Ind. Appl. Math.*, 11: 431-441.



- Moller M. F. 1993 A "Scaled Conjugate Gradient Algorithm for Fast Supervised Learning, Neural Networks", 6: 525-533.
- Raman, H., Chandramouli, V., 1996. Deriving a general operating policy for reservoirs using neural network. J Water Resour Plan Manage. 122 (5), 342-7.
- Rosenblatt, F. 1959. Principles of Neurodynamics, Spartan Books, New York.
- Rumelhart, D.E., McClelland, J.L., PDP Research Group 1986. Paralel Distributed Processing: Explorations in the Microstructure of Cognition, v. I: Foundations, MIT Pres, Cambridge, MA.
- Widrow, B., Hoff, M. 1960, "Adaptive switching circuits", IRE WESCON Convention Record 4: 96-104.
- Xu, Z.X., Li, J.Y., 2002. Short-term inflow forecasting using an artificial neural network model. Hydrol Process. 16, 2433-9.
- Yang, C.C., Prasher, S.O., Lacroix, R., Sreekanth, S., Patni, N.K., Masse, L., 1997. Artificial neural network model for subsurfacedrained farmland. J Irrigat Drainage Eng. 123, 285-92.
- Yarar, A., 2004. Beyşehir Gölü Su Seviyesi Değişimlerinin Yapay Sinir Ağları İle Belirlenmesi, Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü.
- Zhu, M.L., Fujita, M., 1994. Comparisons between fuzzy reasoning and neural network methods to forecast runoff discharge. J Hydrosoci Hydraul Eng. 12 (2), 131-41.

