

# GÖLLERDE ÜÇ BOYUTLU HİDRODİNAMİK MODELLEMEDE POM VE YAPAY SİNİR AĞLARI YÖNTEMLERİNİN KULLANILMASI : GÖKPINAR BARAJ GÖLÜ ÖRNEĞİ

**Mahmut FIRAT, Fatih DİKBAŞ**

Pamukkale Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Kınıklı/Denizli

Geliş Tarihi : 08.04.2005

## ÖZET

Göl ve haznelerdeki akıntı yapısı birçok dış etkene bağlı olarak değişmektedir. Oluşan akıntı yapısını gölün tüm noktalarında yerinde ölçümle belirlemek oldukça masraflı ve zordur. Bu nedenle, hızları ve seviye değişimlerini bilgisayar ortamında belirleyen modeller geliştirilmiştir. Bu modeller kullanılarak, oluşabilecek çevresel sorunların önceden tahmin edilebilmesi ve su kirlilik konsantrasyonlarının belirlenmesi için bir altyapı elde edilmiş olur. Günümüzde göl ve haznelerin modellenmesinde üç boyutlu modellerin kullanımı yaygınlaşmıştır. Bu çalışmada, Denizli’de bulunan Gökpınar Baraj Gölü için Princeton Okyanus Modeli (POM) ile yapılmış olan üç boyutlu hidrodinamik modellemenin sonuçları üzerinde Yapay Sinir Ağları (YSA) modeli uygulanarak göl içindeki bazı kesitler için çeşitli rüzgar yön ve hızları altında oluşan hız ve seviye değişimi değerleri elde edilmiştir. Oluşturulan YSA modeli, aynı kesitlere farklı rüzgar şartları altında tekrar uygulanmış ve sonuçların POM sonuçlarına uyum gösterdiği tespit edilmiştir. Yapılan karşılaştırmalar neticesinde, model oluşturulması ve çözüm aşamalarında her iki yöntemin birbirine üstünlük sağladığı unsurlar tespit edilmiş ve belirtilmiştir.

**Anahtar Kelimeler** : Princeton okyanus modeli, Yapay sinir ağları, Hidrodinamik modelleme

## USE OF POM AND ARTIFICIAL NEURAL NETWORKS IN THE THREE-DIMENSIONAL MODELING OF LAKES : GOKPINAR DAM RESERVOIR AS A CASE STUDY

## ABSTRACT

The circulation pattern in lakes and reservoirs varies according to many external factors. In situ measurement of the occurring flow pattern in every point of the lake is a very costly and hard task. For this reason, models determining the velocities and surface fluctuations are developed by using computers. The use of these models enables the generation of the foundation for the prediction of possible environmental problems and water pollution concentrations. Today, three dimensional models are widely used in the modelling of lakes and reservoirs. In this study, the velocity profiles and surface fluctuation values generated under various wind speed and directions at some sections in Gokpinar Lake in Denizli are obtained by applying artificial neural networks (ANN) on the results of three dimensional hydrodynamic model of the lake made with Princeton Ocean Model (POM). The developed ANN model is applied to the same sections for different wind conditions and it is found that the results are in accordance with the results of POM. As a result of the comparisons of the models, the superiorities of the models on each other at the model generation and solution phases are determined and mentioned.

**Key Words** : Princeton ocean model, Artificial neural networks, Hydrodynamic modeling

## 1. GİRİŞ

Gökpınar baraj gölü Denizli şehir merkezinin kuzebatısında yeralan, Türkiye'nin ilk şehiriçi baraj gölüdür. Gölün üç boyutlu hidrodinamik modellemesi Princeton Okyanus Modeli (POM) kullanılarak yapılmıştır. Bu model özellikle kıyı kesimlerinin ve göllerin modellemesinde yaygın şekilde kullanılmaktadır. Modelin detaylı açıklaması literatürde mevcuttur (Blumberg and Mellor, 1987). Gökpınar baraj gölünün üç boyutlu modelini oluşturmak için göl alanı 100'er metre karelik grid alanlarına bölünmüştür. Sigma koordinat modeline uygun olarak düşey doğrultuda 8 tabaka oluşturulmuş ve böylece 14763 prizmatik sıvı elemandan oluşan göl modeli elde edilmiştir. Elde edilen modele POM uygulanarak çeşitli rüzgar yön ve şiddetleri altında oluşan akıntı dokusu ve seviye değişimleri elde edilmiştir.

Bu çalışmada, POM ile göl için elde edilen sonuçlara yapay sinir ağları (YSA) yöntemi uygulanarak farklı rüzgar şartları altında tekrar modellemeye gerek duymadan yeni ve güvenilir sonuçlar elde edilip edilemeyeceği araştırılmıştır. YSA'nın tercih edilmesinin sebebi POM'a göre uygulamasının çok daha basit olması ve az zaman almasıdır.

İnsan beyninin çalışma prensibinden esinlenerek geliştirilen Yapay Sinir Ağları (YSA) nesne tanıma, sinyal işleme, sistem modelleme ve denetimi gibi çeşitli alanlarda yaygın olarak kullanılmaya başlanmış ve problemlerin çözümüne yeni yaklaşımlar getirmiştir. Genel olarak bir YSA, tek katmanlı ya da çok katmanlı olarak düzenlenebilen ve paralel olarak çalışan çok sayıda doğrusal olmayan yapay hücreden meydana gelen bir sistem ya da matematiksel model olarak tanımlanabilir (Nasr et al., 2003).

Yapay sinir ağları hidroloji ve hidromekanikte yağış-akış modellerinin, günlük ve aylık yağış, akım, sıcaklık ve kar erimesi, askı maddesi miktarı gibi değerlerin tahmininde kullanılmaktadır. Bu çalışmalardan bazıları, maksimum taşkın tahmini (Bodri and Cermak, 2000), akım tahmini (Dibike and Solomatine., 2001; Hsu et al., 1998), yağış ve akış modellemesi (Luket et al., 2001a) ve akış modellemesi (Zhang and Govindaraju, 1998; Nagy et al., 2002) gibi sıralanabilir.

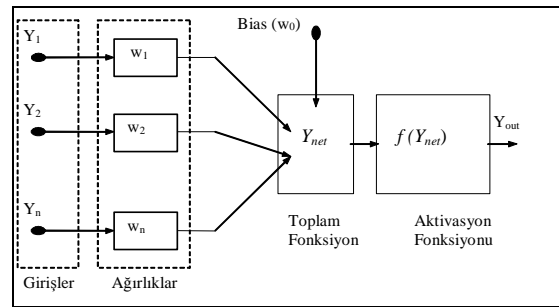
Çalışma sonucunda, POM ile elde edilen doktora tez (Dikbaş, 2002) verileri kullanılarak Gökpınar baraj gölü için seviye değişimi ve hızların tahmininde YSA'nın etkin bir yöntem olarak kullanılabileceği gösterilmiştir.

## 2. YAPAY SİNİR AĞLARI

Yapay Sinir Ağları (YSA), insan biyolojik sinir sistemini temel alarak geliştirilen bir yöntemdir. YSA, birbirine paralel bir şekilde bağlanmış ve lineer olmayan bir yapıya sahip olan nöron olarak adlandırılan bir çok elemandan oluşmaktadır (Jang et al., 1997). Yapay sinir ağları, nesne tanıma, sinyal işleme, sistem modelleme, lineer olmayan ve karmaşık yapıya sahip mühendislik problemlerinin çözümünde kullanılmaktadır.

### 2. 1. Ağ Mimarisi

Literatürde farklı yapay sinir ağ yapıları kullanılmaktadır. Bunlar, ileri beslemeli, geri beslemeli ve radyal tabanlı sinir ağlarıdır (Luk et al., 2001b). Yapay sinir ağlarının, lineer olmayan yapıya sahip olması sebebiyle, nonlineer ve karmaşık problemlerin çözümünde oldukça başarılı sonuçlar verdiği gözlenmiştir. Gökpınar Baraj Gölünün hidrodinamik modellemesine yönelik yapılan bu çalışmada ileri beslemeli yapay sinir ağları kullanılmıştır. İleri beslemeli bir yapay sinir, giriş, çıkış ve gizli katman olmak üzere en az üç katmandan oluşmaktadır. Giriş ve çıkış katmanındaki nöron sayıları ele alınan problemin şartlarına göre belirlenir. Gizli tabaka sayısı ve nöron sayısı ise deneme yanılma ile belirlenir. Şekil 1'de bir nöronun matematiksel modeli gösterilmektedir. Bu şekilden de görüleceği gibi, nöron girdileri sinaptik bağıntılar üzerindeki ağırlıklar ile çarpılarak bir toplayıcıya uygulanmakta ve elde edilen toplam, nöronun aktivasyon fonksiyonundan geçirilerek çıkışlar hesaplanmaktadır.



Şekil 1. Nöron matematik modeli

$$Y_{net} = \sum_{i=1}^N Y_i \cdot w_i + w_0 \quad (1)$$

$$Y_{out} = f(Y_{net}) = f\left(\sum_{i=1}^N Y_i \cdot w_i + w_0\right) \quad (2)$$

Burada,  $Y_{out}$ : ağın ürettiği sonuç,  $F(Y_{net})$ : seçilen transfer fonksiyonu,  $Y_{net}$ : toplam fonksiyonu,  $Y_i$ : nöron girdisi,  $w_i$ : her bir nöron girdisine ait ağırlık katsayısı ve  $w_0$ : eşiktir.

## 2. 2. Öğrenme

Yapay sinir ağları biyolojik sinir sisteminden esinlenerek geliştirildiği için insanlar gibi örneklerle eğitilirler. Ele alınan bir problemin çözümünde eldeki mevcut örneklerden başka bilgiye ihtiyaç duymaz. Ancak yapay sinir ağları ile bir problemi çözerken sonuç üzerinde etkili olan giriş verileri iyi seçilmelidir. Öğrenme genel anlamda, denetimli öğrenme ve denetimsiz öğrenme olmak üzere iki şekilde verilebilir. Denetimli öğrenmede, sinir ağına giriş ve çıkış verileri sunulur ve ağdan bu verilere göre ağırlık katsayılarını düzenleyerek problemi çözmesi istenir. Denetimsiz öğrenmede ise, sinir ağına sadece giriş verileri sunulur ve bunlara göre ağırlıkları düzenlemesi istenir (Luk et al., 2001a; Fırat, 2002). Yapılan bu çalışmada, ileri beslemeli sinir ağlarının çözümünde kullanılan denetimli öğrenme tipi seçilmiştir.

Bir ağ mimarisi, aktivasyon fonksiyonu ve öğrenme algoritması ile karakterize edilir. Bu çalışmada, aktivasyon fonksiyonu olarak, sürekli ve diferansiyeli alınabilen problemlerin çözümünde kullanılan ve denklem (3)'te verilen sigmoid tipi aktivasyon fonksiyon kullanılmıştır (Dibike and Solomatine, 2001). Öğrenme algoritması olarak da, hatayı geriye yayma (error backpropagation) algoritması kullanılmıştır (Hjelmfelt and Wang, 1996).

$$Y_{out} = f(Y_{net}) = \frac{1}{1 + e^{-Y_{net}}} \quad (3)$$

Denklem (1) ile hesaplanan toplam fonksiyon, seçilen nonlineer bir aktivasyon (transfer) fonksiyonundan geçirilerek ağın çıkışı elde edilir. Daha sonra ağın ürettiği sonuç ile gerçek sonuç karşılaştırılarak denklem (4) yardımıyla ağ hatası hesaplanır.

$$J_r = \frac{1}{2} \sum_{i=1}^k (Y_{gerçek} - Y_{out})^2 \quad (4)$$


burada,  $J_r$ : Gerçek değer ile ağın ürettiği sonuç arasındaki hata,  $Y_{gerçek}$ : Gerçek çıkış değeridir. Bu hata kabul edilebilir değere ulaşıncaya kadar eğitime devam edilir.

## 3. GÖKPINAR BARAJ GÖLÜNÜN HİDRODİNAMİK MODELLEMESİNDE YAPAY SINIR AĞLARININ KULLANILMASI

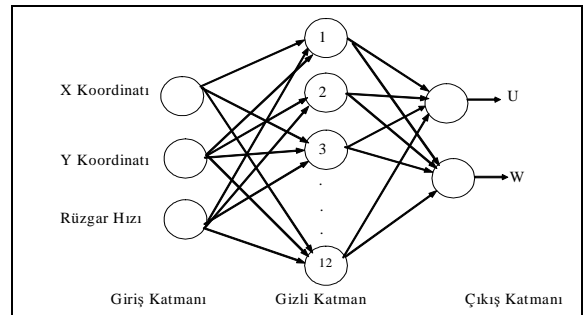
### 3. 1. Giriş Verilerinin Yapısı

Yapay sinir ağları insanlar gibi örnekler ile eğitildikleri için eğitim sırasında yeterli sayıda veri grubunun kullanılması gerekir. Bu çalışmada, eğitim ve test işlemlerinde, Dikbaş (2002) doktora tez çalışması verileri kullanılmıştır. Yapay sinir ağları kullanılarak Gökpınar baraj gölünün hidrodinamik modellemesinde, farklı rüzgar açıları ve hızlarında, seviye değişimleri ve hızlar hesaplanmıştır.

Seviye değişimi tahmin edilirken gölün  $Y=3000$  m.'deki enkesiti için  $0$  ve  $180$  derece rüzgar açıları ile esen farklı rüzgar hızları altında oluşan iki farklı veri seti kullanılmıştır. Giriş verisi olarak  $X$  koordinatı ve rüzgar hızı, çıkış olarak da seviye değişimi kullanılmıştır (Şekil 2). Hız değişimlerinin tahmin edilmesinde aynı şekilde  $0$  ve  $180$  derece rüzgar yönleri için iki farklı veri seti kullanılmıştır.  $X$  ve  $Y$  yönündeki hız değişimlerini tahmin etmek için giriş verisi olarak koordinat ve rüzgar hızı kullanılmıştır (Şekil 3).



Şekil 2. Seviye değişiminin tahmini için kullanılan ağ yapısı



Şekil 3. Hız tahmini için kullanılan ağ yapısı

### 3. 2. Ağın Eğitilmesi ve Test Edilmesi

Şekil 2 ve 3'te veri girişleri belirtilen modellerin eğitiminde aktivasyon fonksiyonu olarak (3) numaralı bağıntıda tanımlanan sigmoid tipi aktivasyon fonksiyonu kullanılmıştır. Kullanılan aktivasyon fonksiyonun özelliğinden dolayı, veri setleri ağa verilmeden önce her bir giriş ve çıkış değerleri [0~1] arasında normalize edilmiştir. Buna bağlı olarak yapay sinir ağlarının üreteceği sonuç

değerleri de [0~1] arasında elde edilmiştir. Orijinal verilere dönmek için normalize işlemleri tersine çevrilerek çıkış değerleri bulunmuştur. Her bir veri seti için eğitim yapılırken gizli katman sayısı, gizli katmandaki nöron sayısı, öğrenme derecesi, momentum katsayısı ve iterasyon sayısı deneme yanılma yoluyla belirlenmiştir. Farklı rüzgar yönleri için seviye değişiminin ve U ve W hızlarının tahmini için eğitimde seçilen parametreler Tablo 1 ve 2'de verilmiştir.

Tablo 1. Seviye Değişimi Tahmini için Eğitimde Seçilen Parametreler

Rüzgar Açısı	Eğitim Veri Sayısı	Test Veri Sayısı	Ağ Yapısı	Öğrenme Derecesi	Momentum Katsayısı	İterasyon Sayısı
0	87	21	2 - 14 - 1	0.01	0.8	15000
180	87	21	2 - 16 - 1	0.01	0.6	20000

Tablo 2. U ve W Hızlarının Tahmini için Eğitimde Seçilen Parametreler

Rüzgar Açısı	Eğitim Veri Sayısı	Test Veri Sayısı	Ağ Yapısı	Öğrenme Derecesi	Momentum Katsayısı	İterasyon Sayısı
0	360	128	3 - 18 - 2	0.01	0.7	25000
180	360	120	3 - 20 - 2	0.04	0.8	30000


Tablo 3. Seviye Değişimi (DH) Sonuçlarının Karşılaştırılması

Rüzgar Hızı	Rüzgar Açısı 0 DH (m)		(POM-YSA) Farkı		Rüzgar Açısı 180 DH (m)		(POM-YSA) Farkı	
	POM	YSA	%	M	POM	YSA	%	m
V <sub>r</sub> =1 m/s	0.0000	0.0487	0.0487	-	0.00000	0.02629	0.0263	-
	0.5075	0.5661	0.0587	0.1156	0.54760	0.48681	0.0608	0.1110
	0.5986	0.6524	0.0538	0.0899	0.61404	0.57409	0.0399	0.0651
	0.6112	0.6163	0.0051	0.0084	0.61372	0.53947	0.0742	0.1210
	0.6084	0.5948	0.0137	0.0225	0.60306	0.68599	0.0829	0.1375
	0.6105	0.5489	0.0616	0.1009	0.59820	0.54537	0.0528	0.0883
	0.0000	0.0574	0.0574	-	0.00000	0.00806	0.0081	-
V <sub>r</sub> =3 m/s	0.0000	0.0292	0.0292	-	0.00000	0.03680	0.0368	-
	0.3329	0.2920	0.0409	0.1228	0.69683	0.62650	0.0703	0.1009
	0.5269	0.5469	0.0200	0.0380	0.67290	0.64058	0.0323	0.0480
	0.6035	0.5639	0.0396	0.0656	0.62809	0.58078	0.0473	0.0753
	0.6391	0.6958	0.0567	0.0887	0.59054	0.53684	0.0537	0.0909
	0.6621	0.6658	0.0036	0.0055	0.54967	0.49448	0.0552	0.1004
	0.0000	0.0388	0.0388	-	0.00000	0.00431	0.0043	-
V <sub>r</sub> =5 m/s	0.0000	0.1075	0.1075	-	0.00000	0.00259	0.0026	-
	0.0328	0.0351	0.0023	0.0699	1.24441	1.13470	0.1097	0.0882
	0.3790	0.3877	0.0087	0.0229	0.98952	0.85884	0.1307	0.1321
	0.5791	0.5719	0.0071	0.0123	0.84976	0.75261	0.0971	0.1143
	0.7048	0.6294	0.0754	0.1070	0.75265	0.68135	0.0713	0.0947
	0.7663	0.6651	0.1012	0.1321	0.64375	0.59442	0.0493	0.0766
	0.0000	0.0388	0.0388	-	0.00000	0.00237	0.0024	-


Şekil 4'te Gökpınar baraj gölünün taban topografyası görülmektedir. Eşyüksekti eğrileri 1'er metre aralıklarla çizilmiştir. Gölün en derin noktası yüzeyden 32 metre aşağıdadır. Göl için POM çözümünde kullanmak için oluşturulan model Şekil 5'te verilmiştir. Modelde grid boyutları 100'er metredir. Yani gölün genişliği yaklaşık 3.5 km. ve boyu 6 km'dir. Her grid noktasındaki su derinliği 8

eşit parçaya bölünerek modellemede kullanılacak olan üç boyutlu sigma koordinat modeli elde edilmiştir. Modelleme ile ilgili ayrıntılar bir başka makalede sunulacaktır. POM ile çeşitli rüzgar şartları altında her grid noktasında oluşan su hızları elde edilmiştir. Yapay sinir ağları hesaplamalarının uygulandığı y = 3000 m'deki endkesit Şekil 5'te gösterilmiştir. POM ile YSA yöntemlerinin

karşılaştırmalarının yapıldığı tüm grafikler bu kesite aittir. Modellemede x eksenini yönünde, doğu ve batı yönünde esen 1, 3 ve 5 m/s'lik rüzgar değerleri kullanılmıştır.




Şekil 4. Göl topografyası ( $\Delta h=1m.$ )




Şekil 5. Göl modeli

Şekil 6-11'de görüldüğü gibi rüzgarın esme doğrultusuna göre su yüzü profili değişmektedir.


Rüzgar sağ sahilden eserken sol sahilde seviye yükselmektedir. Benzer şekilde rüzgar yönü tersine döndüğünde birikme sağ sahilde olmaktadır. POM ile elde edilen sonuçlar ve su yüzü profili çok küçük farklarla YSA ile de elde edilmiştir. Elde edilen sonuçlar yapay sinir ağı modelinin farklı rüzgar hızları altında gölde oluşacak su yüzü profilinin belirlenmesinde kullanılabileceğini göstermektedir. Gölün modellenmesinde esas önem taşıyan unsur, gölde oluşan su hızları ve yönleri, yani ortamdaki akıntı paternidir. Çünkü göl özellikle sulama amaçlı olarak kullanılacak ve göldeki suyun kirlilik konsantrasyonu büyük önem taşıyacaktır. Bilindiği gibi gölde su hareketi ne kadar fazla ve gölün tamamında etkin olursa kirlilik konsantrasyonu o kadar azalacak ve oksijen oranı yükselecektir. Bu nedenle göl ortamında oluşan akıntı paterninin incelenmesine daha fazla ağırlık verilmiştir.




Şekil 6. Yüzey Seviye Değişimi (Rüzgar Açısı:0°, H




Şekil 7. Yüzey Seviye Değişimi (Rüzgar Açısı: 180°, Hızı 1m/s)




Şekil 8. Yüzey Seviye Değişimi (Rüzgar Açısı:0°, Hızı 3m/s)



Şekil 9. Yüzey seviye değişimi (Rüzgar Açısı : 180°, Hızı 3m/s)




Şekil 10. Yüzey seviye değişimi (Rüzgar Açısı : 0°, Hızı 5m/s)




Şekil 11. Yüzey seviye değişimi (Rüzgar Açısı:180°, Hızı 5m/s)

Göl için farklı rüzgar şartları altında POM ve YSA ile elde edilen su hızlarının grafiksel karşılaştırmaları aşağıda verilmiştir. Bu grafikler, oluşturulan göl modelinin  $y = 3000$  m'deki enkesitinde,  $x = 600, 1000, 1400, 1800$  ve  $2200$  m'de, düşey kesitlerde oluşan yatay su hızı bileşenlerini göstermektedir. Gösterilen tüm noktalarda, düşey yöndeki su hızı bileşenleri de aynı şekilde elde edilmiş fakat grafiğe dönüştürülmemiştir çünkü düşey hız bileşenleri yatay hız bileşenlerine göre oldukça düşük mertebededir. Elde edilen hız bileşenleri, incelenen rüzgar şartları altında gölde tek tabakalı bir çevrintinin oluştuğunu göstermektedir ancak bu makalenin kapsamı dışında olduğu için bu konuda ayrıntılı bilgi verilmeyecektir. Rüzgar yönü değiştiğinde göldeki akıntının yönü de değişmektedir. Rüzgarın şiddeti değiştirilmeden, yönünün 180 derece değiştirilmesiyle elde edilen

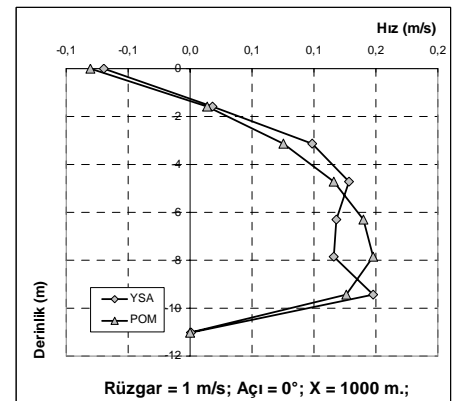
akıntı profilleri şekillerden de görüleceği gibi simetrik değildir. Bu durum beklenen bir durumdur çünkü göl simetrik bir geometriye sahip değildir. Buradan farklı rüzgar yön ve şiddetleri altında gölde tamamen farklı yapıda akıntı paternleri oluşacağı anlaşılmaktadır. Şekil 12 ile 21 arasında, 1m/s hızı sahip rüzgar altında düşey yönde oluşan akıntı profilleri için POM ve YSA ile elde edilen sonuçlar karşılaştırmalı olarak sunulmuştur. 3 ve 5 m/s rüzgar için her iki yöntemle hesaplanan hız değerleri daha yüksektir ancak hız profilleri aynı eğilimdedir. Yer sıkıntısı nedeniyle bu grafikler verilmemiştir.




Şekil 12. Hız profili




Şekil 13. Hız profili



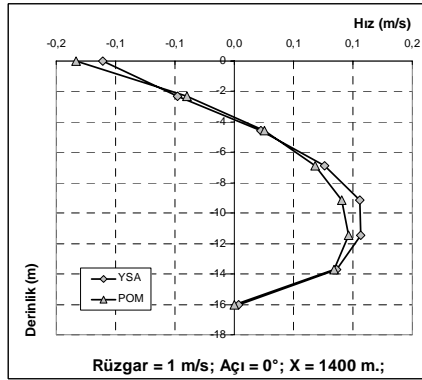
Şekil 14. Hız profili




Şekil 15. Hız profili



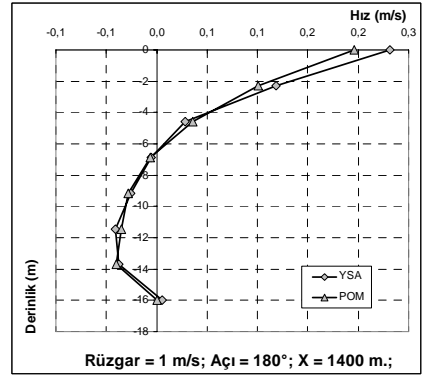
Şekil 19. Hız profili



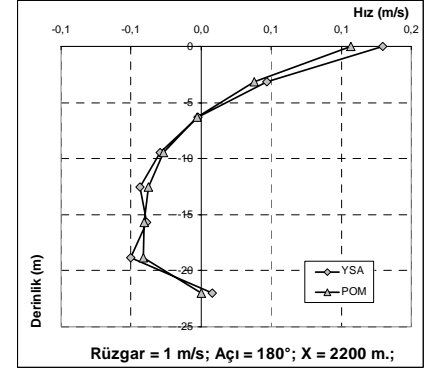
Şekil 16. Hız profili




Şekil 20. Hız profili



Şekil 17. Hız profili



Şekil 21. Hız profili



Şekil 18. Hız profili

## 4. SONUÇLAR

Princeton Okyanus Modeli (POM) ve Yapay Sinir Ağları (YSA) ile elde edilen sonuçlar karşılaştırıldığında her iki yöntemin de akıntı dokularını başarılı şekilde modelleyebildiği görülmüştür. Her iki modelin de birbirine göre üstünlükleri ve dezavantajları tespit edilmiştir. YSA ile modellemede daha önceden elde edilmiş hesap veya gözlem sonuçları gerekirken, POM bunu gerektirmemektedir. YSA sonuçlara POM'dan çok

daha kısa sürede ulaşabilmektedir. YSA ile gölün herhangi bir kesiti için hız ve seviye değişimi değerleri tüm göl hacmi için modelleme yapmadan elde edilebilmekte ancak POM'da tüm kesitler için eş zamanlı çözüm gerekmektedir. Hız profillerini gösteren grafiklerden de anlaşılacağı gibi, POM ile elde edilen hız değerleri daha düzenli hız profilleri oluştururken YSA'nın elde ettiği hızlar daha düzensiz dağılım göstermekte; ancak aralarındaki fark gözardı edilebilecek derecede düşük olmaktadır. Bu farkın daha da azaltılması için düşey çözünürlüğün artırılması ve daha fazla noktada hesap yapılması gereklidir. Bu çalışmada buna gerek kalmamıştır. İlerdeki araştırmalarda YSA ile tüm göl hacminde su hızlarını hesaplamaya yönelik çalışmalar yapılması önerilebilir ancak bunun da çok fazla sayıda veri ile uğraşmayı gerektireceği görülmektedir ve klasik nümerik modelleme yöntemleri işlem hacmi ve hesap süresi yönünden daha avantajlı olacaktır. Belirli kesitlerde çok sayıda ayrıntılı hesap yapılması gereken durumlarda yapay sinir ağları yönteminin kullanılması sonuç olarak önerilebilir.

## 5. KAYNAKLAR

Blumberg, A. F. and Mellor, G. L. 1987. Description of a three dimensional coastal ocean circulation model, Heaps, N. S. Ed., Three Dimensional Coastal Models, American Geophysical Union, Washington DC.

Bodri, L. and Cermak, V. 2000. Prediction of Extreme Precipitation Using a Neural Network: Application to Summer Flood in Moravia, *Advances in Engineering*, 31, 311-321.

Dibike, Y. B. and Solomatine, D. P. 2001. River Flow forecasting Using Artificial Neural Networks, *Phys. Chem. Earth (B)*, 26 (1), 1-7.

Dikbaş, F. 2002. Göl ve Haznelerdeki Akımların Üç Boyutlu Matematik Modellemesi ve Gökpınar Baraj Gölü İçin Bir Uygulama, 136 s. Doktora Tezi,

Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.

Fırat, M. 2002. Doğrusal ve Kıvrımlı Akarsulara Yerleştirilen Köprü Ayakları Etrafında Meydana Gelen Oyuşma Derinliğinin Yapay Sinir Ağları ile Belirlenmesi, Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.

Hjelmfelt, A. T. and Wang. M. 1996. Predicting Runoff Using Artificial Neural Networks, *Surface Water Hydrology*, 233-244.

Hsu, K., Gupta, H. V. and Sorooshian. S. 1998. "Streamflow Forecasting Using Artificial Neural Networks", **ASCE Water Resources Engineering Conference '98**, 967-972.

Jang, J. S. R., Sun. C. T. and Mizutani. E. 1997 Neuro-Fuzzy and Soft Computing, PrenticeHall, ISBN 0-13-261066-3, 607 p., United States of America.

Luk, C. K., Ball, J.E. and Sharma, A. 2001. A Study of Optimal Model Lag and Spatial to Artificial Neural Network for Precipitation Forecasting, *Journal of Hydrology*, 227, 56-65.

Luk, C. K., Ball, J.E. and Sharma, A. 2001. An Application of Artificial Neural Networks for Precipitation Forecasting, *Mathematical and Computer Modeling*, 33, 683-693.

Nagy, H. M., Watanabe, K. and Hirano, M. 2002. Prediction of Sediment Load Concentration in Rivers using Artificial Neural Network Model, *Journal of Hydraulics Engineering, ASCE*, 128, 588-595.

Nasr, G. E., Badr, E. A. and Joun, C. 2003. Back Propagation Neural Networks For Modeling Gasoline Consumption, Energy Conversion and Management, 44, 893-905.

Zhang, B. and Govindaraju, R. S. 1998. "Using Modular Neural Networks to Predict Watershed Runoff", **ASCE Water Resources Engineering Conference'98**, 897-902.