



**MUSTAFA KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**YAPAY SINIR AĞLARI YÖNTEMİ İLE
BARAJ HAZNE KOTU TAHMİNİ**

M. MURAT ÇALIM

YÜKSEK LİSANS TEZİ

ANTAKYA

ŞUBAT-2008

MUSTAFA KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SİNİR AĞLARI YÖNTEMİ İLE
BARAJ HAZNE KOTU TAHMİNİ

MEHMET MURAT ÇALIM
YÜKSEK LİSANS TEZİ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

Yrd.Doç.Dr.Fatih ÜNEŞ'in danışmanlığında hazırlanan bu tez 14/02/2008 tarihinde aşağıdaki jüri üyeleri tarafından oybirliği ile kabul edilmiştir.

Yrd.Doç.Dr. Fatih ÜNEŞ
Başkan

Doç.Dr. Ali KOÇ
Üye

Yrd.Doç.Dr. Hasan GÜZEL
Üye

Bu tez Enstitümüz İnşaat Mühendisliği Anabilim Dalında hazırlanmıştır.

Kod No :

Prof. Dr. Necat AĞCA
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

İÇİNDEKİLER

ÖZET	II
ABSTRACT	III
SİMGELER VE KISALTMALAR.....	IV
ÇİZELGE DİZİNİ.....	V
ŞEKİLLER DİZİNİ.....	VI
1. GİRİŞ	1
1.1. Suyun İnsan Hayatındaki Önemi	10
2. ÖNCEKİ ÇALIŞMALAR.....	12
3. MATERYAL VE YÖNTEM	14
3.1. Klasik Yöntemler	14
3.1.1. Çoklu Regresyon Yöntemi (MLR).....	14
3.1.2. Otoregresif Model (AR(p))	16
3.1.2.1. Otoregresif Modeller (Markov Modelleri).....	17
3.2. Yapay Sinir Ağları (YSA) Modeli	17
3.2.1. Y.S.A' nın Biyolojik Temeli	17
3.2.1.1 Bir Nöronun modeli	18
3.2.1.2. Aktivasyon Fonksiyonları Tipleri	20
3.2.1.3. Geri Besleme (Feedback):.....	22
3.2.1.3. YSA'nın Çalışma Ağının Yapısı.....	24
4. ARAŞTIRMA BULGULARI ve TARTIŞMA	33
4.1 Uygulama Alanı ve Tanıtılması	33
4.2. Yarseli Barajı Uygulamaları	39
4.2.1 Rezervuar Seviye Dalgalanmalarının Tahmin Edilmesi	40
5. SONUÇ VE ÖNERİLER	52
KAYNAKLAR	45
TEŞEKKÜR.....	48
ÖZGEÇMİŞ	49
EK.....	50

ÖZET

**YAPAY SİNİR AĞLARI YÖNTEMİ İLE
BARAJ HAZNE KOTU TAHMİNİ**

Baraj hazne kotu deęişim tahminleri baraj yapılarının, işletme, tasarım ve güvenlik deęerlendirmeleri için önemlidir. Bu çalışmada, baraj haznesi seviye deęişim tahminleri, Yapay Sinir Ağları (YSA) metodu kullanılarak araştırılmıştır.

YSA nın baraj hazne seviyesinin belirlenmesinde uygulanabilirliği, günlük hazne seviyesi, toplam günlük göle gelen su hacmi, toplam günlük su sarfiyatı ve baraj havzasına düşen günlük yağış yükseklikleri veri olarak alınarak deęerlendirilmiştir. Bu veriler Türkiyenin Akdeniz bölgesinde yer alan Yarseli Barajı ve havzasında 1796 günlük ölçümlerle elde edilmiştir.

YSA yapısı olarak çok tabakalı algılayıcı kullanılmıştır. Verilerin YSA modelinin eğitilmesinde Bayesian düzenleme teknięi kullanılmıştır. Bu teknik Levenberg-Marquardt optimizasyon yöntemine göre geliştirilerek ağırlık ve bias katsayıları yenilenmiştir.

Elde edilen YSA sonuçları, geçmişte çok kullanılan, çoklu-lineer regresyon (MLR) ve otoregresiv (AR(p)) model sonuçları ile karşılaştırılmıştır. Modeller, grafik ve istatistiksel sonuçlarla analiz edilmiştir. Bu sonuçlar göstermiştir ki; baraj haznesi seviye deęişiminin tahmininde YSA model çözüm sonuçları, geçmişte kullanılan klasik yöntemlerle kıyaslandığında daha iyi bir performans vermiştir.

2008, 60 Sayfa

Anahtar Kelimeler: Yapay Sinir Ağları (YSA), Baraj, Hazne seviyesi, Tahmin, Çok tabakalı algılayıcı, Model,

ABSTRACT

ESTIMATION OF DAM RESERVOIR LEVEL WITH ARTIFICIAL NEURAL NETWORK METHOD

Dam reservoir level predictions are important for operation, design and security evaluation of dam structure. In the present study, prediction and estimation of dam reservoir level are investigated using Artificial Neural Networks (ANN) method. Feasibility of ANN is evaluated using dam reservoir daily data, such as daily precipitation, total required daily released volume, total daily inflow water volume and daily reservoir level. The data were collected on daily basis measurement over 1796 days at the Yarseli Dam in the Mediterranean region of Turkey. A multi layer perceptron (MLP) is used as the ANN structure. Bayesian regularization technique is used in the training of the network. The technique updates the weight and bias values according to Levenberg-Marquardt optimization. ANN results are compared with conventional multi-linear regression (MLR), and autoregressive (AR(p)) model. The models are analysed with statistics and graphs results. The results show that ANN model solution for dam reservoir level fluctuations can provide better performance prediction compared to those of the conventional statistical method.

2008, 60 pages

Key Words: Artificial Neural Networks (ANN), dam, reservoir level, prediction, multi layer perceptron, model,

SİMGELER ve KISALTMALAR LİSTESİ

W_{kj}	= Bağlantı Ağırlık Katsayısı
b_k	= Bias terimi
$\varphi (\cdot)$	= Aktivasyon Fonksiyonu
Y_k	= Çıktı Değeri
X_m	= Girdi Değeri
V_k	= Girdi sinyallerinden dolayı oluşan lineer bileşen çıktısı
H_j	= Gizli tabakadaki girdi değeri
$f(H_j)$	= Çıktı düğüm noktası değeri
η	= Öğrenme Oranı
α	= Momentum katsayısı oranı
MAE	= Toplam Karesel Hata
MSE	= En Düşük Karesel Hata
R	= Korelasyon katsayısı

ÇİZELGELER DİZİNİ

Çizelge 4.1. Yarseli Barajının bütün istatistiksel parametre değişimleri	38
Çizelge 4.2. Yarseli Barajının eğitim ve test verileri istatistiksel parametre değişimleri.....	38
Çizelge 4.3. Yarseli Barajında kullanılan bütün modellerde test verileri için elde edilen MSE, MAE ve R parametrelerinin karşılaştırılması	41
Çizelge Ek.1. Yarseli Barajında Kullanılan Tüm Verilerin Aylık Ortalama Değerleri	50

ŞEKİLLER DİZİNİ

Şekil 3.1. Beyin sinir sistemi çalışma şeması	18
Şekil 3.2. Basit bir YSA Modeli	19
Şekil 3.3. Eşik Fonksiyonu	20
Şekil 3.4. Parçalı Lineer fonksiyon	21
Şekil 3.5. Sigmoid Fonksiyonu	22
Şekil 3.6. Tek döngülü geriye beslemeli sistem için akım sinyal şeması	23
Şekil 3.7. Tek tabakalı ileri beslemeli ağ	24
Şekil 3.8. Tam bağlı ileri beslemeli bir gizli ve çıktı tabakalı hesap ağı	25
Şekil 3.9. İki girdili, tek gizli tabakalı, dört nodlu ve bir çıktılı YSA yapısı	27
Şekil 3.10. Çok tabakalı algılayıcı (perceptron)	29
Şekil 4.1. Yarseli Barajı Genel Görünümü	33
Şekil 4.2. Yarseli Barajı ve Sulaması Genel Vaziyet Planı	34
Şekil 4.3. P0 Pompa İstasyonu Genel Görünüşü	35
Şekil 4.4. 10 Ocak 2002 ile 30 Kasım 2006 tarihleri arası Yarseli Barajı Günlük Göl Kotu Değişimleri	36
Şekil 4.5. Yarseli Barajı günlük yağış yüksekliği değişimleri	36
Şekil 4.6. Yarseli Barajı günlük gelen su miktarı değişimleri	37
Şekil 4.7. Günlük Su Sarfiyatı Değişimleri	37
Şekil 4.8. MLR metodu ile elde edilmiş göl kotu sonuçları ile ölçüm değerlerinin karşılaştırılması	42
Şekil 4.9. MLR günlük göl kotu test sonuçları ile ölçüm değerlerinin karşılaştırılması	43
Şekil 4.10. MLR sonuçları ile ölçüm değerlerinin saçılma diyagramı	43
Şekil 4.11. Yapay sinir ağları modelinde günlük göl kotu eğitim sonuçları ile eğitim ölçüm değerlerinin karşılaştırılması	44
Şekil 4.12. YSA modelinde günlük göl kotu test sonuçları ile ölçüm test değerlerinin karşılaştırılması	44
Şekil 4.13. YSA'da günlük göl kotları ile ölçüm değerlerinin saçılma diyagramı	45
Şekil 4.14. İkinci girdi kombinasyonu ve eğitim verileri için 3 nodlu YSA modeli sonuçları	46
Şekil 4.15. İkinci girdi kombinasyonu ve test verileri için 3 nodlu YSA modeli sonuçları	46

VII

Şekil 4.16. 3 nodlu YSA test sonuçları ve ölçüm verileri sonuçları için saçılma diyagramı	47
Şekil 4.17. İkinci girdi kombinasyonu ve eğitim verileri için 5 nodlu YSA modeli sonuçları	47
Şekil 4.18 İkinci girdi kombinasyonu ve test verileri için 5 nodlu YSA modeli sonuçları	48
Şekil 4.19. 5 nodlu YSA test sonuçları ve ölçüm verileri sonuçları için saçılma diyagramı	48
Şekil 4.20. Otoregresif modelde günlük göl kotlarının AR(3) ile ölçüm değerlerinin karşılaştırılması	50
Şekil 4.21. AR (3) Değerleri İle Ölçüm Değerlerinin Saçılma Diyagramı	50
Şekil 4.22. Otoregresif modelde günlük göl kotlarının AR(6) ile ölçüm değerlerinin karşılaştırılması	51
Şekil 4.23. AR (6) değerleri ile ölçüm değerlerinin saçılma diyagramı	51

1.GİRİŞ

1.1. Suyun İnsan Hayatındaki Önemi

Taze ve tatlı su hayatın devam ettirilmesi için gerekli temel etmenlerden biridir. Nehirler bu önemli taze su kaynaklarından birisidir. Barajlar da, bu akarsuları düzenleyen ve çeşitli amaçlar için kullanılmasını sağlayan yapılardır. Fakat su yapıları ve nehir yakınlarında kurulacak barajlar gibi kaynak geliştirme sistemleri çok maliyetli olduğundan bu yapılar iyi bir şekilde planlanmalı ve hayata geçirilmelidir. Rezervuardaki su hacminin tespiti, hidrolik yapıların dizaynı ve inşası, sanayi ve belediyelere su temin edilmesi, sulama ve drenaj, enerji üretimi için su gücünden faydalanma, sel planlama çalışmaları ve selin verebileceği zararı azaltma, baraj rezervuarının sevk ve idare edilmesi, su kalitesinin ayarlanması ve modellenmesi için büyük önem teşkil etmektedir.

Baraj rezervuarındaki su hacminin kontrolü ise doğru zamanda suyun biriktirilmesi ve dağıtılmasıyla olur. Zamanında alınmayan önlemler ve su kaynaklı problemlerden ötürü (sel, su kaynağı ve susuzluk gibi) can ve mal kaybı olabilmektedir. İşte bu yüzden, düzgün bir baraj rezervuar yönetimi sadece taze su temini açısından değil, aynı zamanda olası zararları önlemek açısından bir gerekliliktir. En etkili şekilde baraj rezervuarının yönetilmesinin temel şartlarından biri de baraj rezervuar su hacmini saptamak ve bu hacimdeki iniş ve çıkışları tahmin edebilmektir. Bundan ötürü, su kaynaklarını etkileyen parametreler net bir şekilde tanımlanmalıdır.

Barajlar da dâhil olmak üzere hidrolik yapıların dizayn edilmesinde gelecekteki olası hidrolojik faaliyet parametrelerinin öngörülmesi çok önem kazanmaktadır. Bir barajdaki su hacmini etkileyen birçok parametre vardır. Drenaj alanı, bitki örtüsü, yağış, sızıntı miktarı, toprak tarafından emilmeyen ve yüzeyde kalan yağmur suları, buharlaşma ve sulama gibi parametreler belirleyici olmaktadır. Baraj rezervuarını idare edebilmek için uzun yıllar boyunca bütün bu parametrelerin sürekli olarak ölçülmesi gerekmektedir. En önemli parametreler rezervuar hacminde meydana gelen iniş-çıkışlar ve biriktirme kapasitesidir.

Barajlara giren nehir akışları mevsimlerle yükselip azalır. Su kaynaklarını ve özellikle baraj rezervuar planlamasını, nehir havzasındaki meteorolojiye bağlı değişkenler (yağmur, buharlaşma, suyun tuzluluk oranı, kar, kar erimesi, albedo ve dolu

olarak düşen yağışlar gibi), topografik özellikler (bölge, şekil, eğim gibi nehir havza özellikleri), ve coğrafi yapı (geçirgenlik, toprağın süzme kapasitesi, yer altı kaynak sularının seviyesi ve toprak nemi gibi) özellikleri etkiler. Bu değişkenler arasındaki ilişki o kadar karmaşıktır ki hala tamamiyle anlaşılabilmiş değildir. Meteorolojik unsurlar, baraj rezervuar hacmini ve faaliyetlerini birebir etkilemektedir. Rezervuar kapasitesini belirleme üzerine yapılan ilk çalışmalar Ripple (1883), Hazen (1914), ve Sudler (1927) tarafından klasik yöntemler kullanılarak yapılmıştır [Usul (2005)]. O çalışmalardan beri, birçok araştırmacı baraj rezervuar çalışmalarında klasik ve geleneksel yöntemleri kullanmaktadır. Bu yöntemlerde, rezervuar hacmi, hidrolik araştırma sistemlerindeki makro ölçekte kütlenin muhafaza edilmesi (süreklilik denklemi) olarak tanımlanmıştır. Göllerdeki su seviyesi ve hacmi üzerine yapılan geçmiş araştırmalarda, kütle-hacim metotları ve istatistik metotları göz önünde bulundurularak, suyun yıllık seviyesinin stabilitesi genellikle kullanılmıştır. Bu metotlara göre, herhangi bir baraj rezervuarı için aşağıdaki ilişki (1.1) kurulabilir:

$$X(t)-Y(t) = V \quad (1.1)$$

Bu denklemde $X(t)$ içeri giren suyun hacmine, $Y(t)$ dışarı çıkan suyun hacmine ve V ise depo hacminin varyasyonlarına denktir. İçeri giren su parametreleri, yağış, yüzey akışı ve alt yüzey akışı hacmi olabilir. Dışarı çıkan su parametreleri buharlaşma hacmi, ihtiyaç duyulan kullanım suyu hacmi ve ayrıca baraj rezervuar havzasından sızan su hacmi olarak alınabilir. İçeri giren ya da dışarı çıkan suyun belirlenmesine ek olarak, yağmurun emilmeyen ve yüzeyde kalan su miktarının ve buharlaşma modellerinin de kullanılması gerekir. Anlaşılabilceği üzere, yukarıda bahsedilen bütün parametreler geçici varyasyon olaylardan etkilenmektedir. Bundan dolayı bu modelleri kullanmak için çözüm bulmak adına birçok parametrenin kaydı gerekmektedir.

Son zamanlarda, Yapay Sinir Ağları (YSA) Su Mühendisliği alanında sıkça kullanılmaya başlanmıştır. Fakat yine de, YSA tarafından yapılmış baraj rezervuar kotu tahminiyle ilgili bir çalışma literatürde mevcut değildir.

Bu araştırmada gerçek baraj rezervuar değişikliklerinden elde edilen veriler üç farklı metotla değerlendirilmiş; Çoklu-Lineer Regresyon (MLR), Otoregresif Model (AR(p)) ve Yapay Sinir Ağı (YSA).

Türkiye'deki Yârseli barajı ve verileri bu modellerde kullanılmıştır.

2.ÖNCEKİ ÇALIŞMALAR

Bugüne kadar YSA birçok farklı disiplinde ve alanlarda kullanılmıştır. YSA su kaynakları yönetimiyle ilgili birçok araştırma konusunda çok başarılı sonuçlar vermiştir (Kişi 2004, Cigizoğlu 2005). Hidrolojistler su kaynaklarının dizaynı ve yönetilmesiyle alakalı ortaya çıkan problemlere mantıklı cevaplar bulmaya çalışırken, diğer bir taraftan birçok hidrolojik işlemler yüksek derecede geçici ve uzaysal değişkenlik gösterir. Bu olayların, fiziksel yapısının nonlinearlığı sebebiyle, olayları temsil eden parametrelerin belirlenmesini sağlayan yeni metotlar oldukça kolaylık sağlamaktadır. Bu yüzden, hidrolojistler yeni metotlardan olan YSA'yi sıklıkla; su seviyesi, kirletici konsantrasyonu, yağış akış ilişkisi vb. nin tahmini ve hesaplanması problemlerine uygularlar.

YSA'nin çekici özelliğinden biri, işlemlerin arkasındaki olayın fiziği olmaksızın giriş ve çıkış değerleri arasındaki ilişkiyi çıkarabilme kabiliyetidir (ASCE,2000 a-b). Birçok araştırmacı YSA modellerinin konvansiyonel modellere göre çok daha iyi performansı olduğunu göstermiştir, çünkü su kaynaklarındaki değişik uygulamalar kompleks ve yüksek derecede nonlinearlığa sahiptir.

YSA modelleri birçok araştırmacı tarafından rezervuarlardaki yağış akış ilişkisini çalışmak için uygulanmıştır (Hallf vd., 1993; Smith ve Eli, 1995; Hsu vd., 1995; Minns ve Hall, 1996; Fernando ve Jayawardena, 1998; Shamseldin, 1997; Dawson ve Wilby, 1998; Tokar ve Johnson, 1999; Kumar vd., 2002; Wilby vd., 2003; Solomatine ve Dulal, 2003; Rajurakr vd., 2004).

Karuhunanithi v.d. (1994), Dawson ve Wilby (1998), Campolo v.d (1999), Zealand v.d (1999) ve Imrie v.d (2000) tarafından yapılmış önceki araştırmalar YSA'nın nehir akışı tahminlerinde kullanılabileceğini göstermiştir. Bu araştırmalarda kullanılan YSA'lar geleneksel modellerden çok daha iyi sonuç verdiği tespit edilmiştir. Yağış-akış sürecini modellemek amacıyla YSA ilk defa Halff v.d. (2000) tarafından kullanılmıştır. Halff, bu çalışmasında hidrogafların tahmin edilmesi için üç katmanlı bir ileri bildirim kullanmıştı. Bu ilk çalışmadan itibaren YSA kullanarak yağış-akış sürecinin modellenmesi bağlamında birçok çalışma yapıldı. Hsu v.d.(1995) bir YSA'nin eğitilmesi için lineer en küçük kareler simpleksi adı verilen (LLSSIM) yeni bir algoritma ortaya koydu. Bu algoritma, lineer en küçük kareler ile çoklu-başlangıçlı

simpleks optimizasyonun kombinasyonunu kullanmıştır. Bu algoritma, birçok araştırmacının yaygın olarak kullandığı geriye yayılım algoritmasından (EBP) daha efektif ve verimli bulunmuştur. Smith ve Eli (1995) sentetik bir havzadan simule edilmiş dataları baz alıp, akışın tamamen boşalmasını ve doruğa ulaşma zamanını tahmin etmek için geriye beslemeli yapay sinir ağlarını kullanmıştır.

Minns ve Hall (1996) tarafından yapılmış olan çalışmada, verinin standardizasyonunun önemine dikkat çekilmiştir. Shamseldin (1997) farklı iklimlere sahip altı havzadan elde ettiği verileri kullanarak ağı eğitmek için Conjugate Gradyen metodunu kullanmıştır. Compolo v.d. (1999), havza çıkış noktalarındaki su seviyelerini tahmin etmek amacıyla farklı yağış-ölçme merkezlerinden elde edilmiş ve sınıflandırılmış yağış verilerinden faydalanmıştır. Compolo v.d. (1999) ve Minns ve Hall'un (1996) ortaya koyduğu model sonuçları, girdi olarak sadece yağış gözlemleri kullanıldığında oldukça yetersiz sonuçlar vermiştir. Modellerin doğruluk payı, yakın geçmişte gözlemlenmiş su seviyeleri de ayrıca kullanıldığında gelişme göstermiştir. Sajkumar ve Thandaveswara (1999) geçici geriye yayılım sinir ağlarını (TBP-NN) nadir bulunan veri koşullarında aylık yağış-akış modellemesi için kullanmıştır. Tokar ve Johnson (1999) ve Tokar ve Markus (2000) akış tahminlerinin doğruluk payında eğitim datalarının seleksiyonun güçlü etkisini ortaya koymuştur. Zhang ve Govindaraju (2000) modüler sinir ağını havza akım tahmini için kullanmış ve eğitim algoritmasını araştırmada Bayes konseptinden faydalanmıştır. Xiong v.d. (2001) Karst bir havzadaki akış tahmini için YSA kullanırken, bir diğer taraftan Shamseldin v.d. (1997) ise yağış-akış sürecinin kavramsal modellerinin ve farklı kara kutu sonuçlarının simülasyonunun bir araya getirilmesinde YSA' den faydalanarak taşkın tahminlerinin doğruluk oranını geliştirebilmiştir.

Son yıllarda YSA'nın fiziğini içeren çalışmalar yayınlanmıştır. Jain et al.(2004) YSA'nın korelasyon ağırlıkların içine yerleştirilen fiziğini soruşturmuşlardır. Sudheer ve Jain (2004), nehir akış modelleri ile yapay sinir ağının içsel davranışını açıklamaya çalışmışlardır. Sudheer (2004, 2005) nehir modellerini eğitilmiş sinir ağlarından çıkarılmış bilgilerle oluşturmaya çalışmıştır. Üneş (2006), Üneş ve Kunduz (2006)'da Tahtaköprü Barajı hazne seviye değişimlerini YSA ile belirlemeye çalışmışlardır.

3. MATERYAL VE YÖNTEM

Bu çalışmada baraj hazne kot seviyesinin belirlenmesinde klasik (Çoklu Regresyon Yöntemi, Otoregresif (AR) Model) ve yeni yöntem olarak adlandırılan yapay sinir ağları (YSA) yöntemi kullanılmaktadır. Aşağıda bu yöntemler ile ilgili olarak temel bilgiler verilmektedir.

3.1. Klasik Yöntemler

3.1.1. Çoklu Regresyon Yöntemi (MLR)

Mühendislik problemlerinde iki veya daha çok rastgele değişkenin aynı gözlem sırasında aldıkları değerlerin birbirinden istatistik bakımdan bağımsız olmadığını, dolayısıyla bu değişkenler arasında bir ilişki bulunduğunu görürüz. İki değişken arasında bir ilişki bulunması bunlardan birinin diğerinden etkilenmesi, ya da her iki değişkenin başka değişkenlerden birlikte etkilenmelerinden kaynaklanır. Örneğin bir akarsu havzasındaki akıyla yağış arasındaki ilişki, akışın yağışın etkisiyle ortaya çıkmasından doğar. Komşu iki havzadaki akışlar arasındaki ilişki ise her ikisinin de o bölgedeki yağıştan etkilenmelerine bağlıdır. (Bayazit ve Oğuz (2005))

Ancak söz konusu ilişkiler deterministik (fonksiyonel) nitelikte değildir. Yani değişkenlerden biri, belli bir değer aldığı anda, diğerinin her zaman aynı değeri alacağı söylenemez. Söz konusu ilişkide dikkate almadığımız diğer değişkenlerin etkisiyle bu değer çeşitli gözlemlerde az çok farklı olabilir. Örneğin yanyana iki havzanın birinde akım belli bir değeri aldığı anda diğerindeki akım her zaman aynı değerde olmaz. Yine de değişkenler arasındaki fonksiyonel olmayan bağıntının varlığının ortaya çıkarılması ve biçiminin belirlenmesi pratikte büyük önem taşır. Zira bu bağıntıyı kullanarak bir değişkenin alacağı değeri, diğer bir (ya da birden fazla) değişkenin bilinen değerlerine bağlı olarak tahmin etmek mümkün olur. Bu tahmin söz konusu değişkenin alacağı gerçek değeri kesin olarak vermemekle birlikte bu değere yakın en iyi tahmin olur. Tahmin edilen değer gerçeğe değerden olan farkının (hatanın) da belli bir olasılıkla hangi sınırlar içinde kalacağı söylenebilir.

Yukarıda sözü edilen tipten bir bağıntıyı gösteren matematik ifadeye regresyon denklemi denir. Regresyon analizinin amacı göz önüne alınan değişkenler arasında

anlamli bir iliřki bulunup bulunmadığını belirlemek, böyle bir iliřki varsa, bu iliřkiyi ifade eden regresyon denklemini elde etmek ve bu denklemi kullanarak yapılacak tahminlerin güven aralıklarını hesaplamaktır.

Regresyon analizinin inřaat mühendisliğinde kullanımına bir örnek olarak iki komřu havzada aynı yılda ölçülen akımlar arasındaki iliřkiyi gösterebiliriz. Her iki akım da o yıl içinde bölgeye düşen yağıştan etkilendikleri için aralarında fonksiyonel olmayan bir iliřki vardır. Bu iliřkiyi gösteren regresyon denklemi elde edilebilirse bu denklemi kullanarak geçmişte havzalardan birinde ölçülmemiş olan eksik akım verilerini diđer havzada aynı yıllarda ölçülmüş olan akımlara bađlı olarak tahmin edebiliriz. Tahmin edilen deđerler gerçekte görülmüş olan deđgerlere eşit olmamakla birlikte yapılabilecek en iyi tahminler olurlar. Gerçek deđerin tahmin edilen deđerden farkının belli bir olasılıkla hangi aralıkta kalacağını da hesaplayabiliriz.

Diđer bir örnek olarak betonun 28 gün sonra elde edeceđi basınç direncinin daha kısa bir süre içinde elde edeceđi dirence dayanarak tahmin edilmesi gösterilebilir. Bu iki direnç arasındaki istatistik iliřkiyi ifade eden regresyon denklemi elde edilebilirse ölçülen kısa süreli bir dirence dayanarak 28 günlük direnç için bir tahmin yapılabilir.

Regresyon analizine başlarken aralarında bir iliřki aranacak olan iki (ya da daha fazla sayıda) deđişkenin hangileri olduğuna karar vermek, sonra da bu deđişkenler arasındaki iliřkiyi gösteren denklemin biçimi için bir kabul yapmak gerekir. Buna göre regresyon analizi řu şekilde sınıflandırılabilir:

Basit doğrusal regresyon analizi: En çok kullanılan bu en basit analizde iki deđişken arasında doğrusal bir iliřki bulunduğu kabul edilir.

Çok deđişkenli doğrusal regresyon analizi: İki den daha fazla sayıda deđişken arasında doğrusal bir iliřki bulunduğu kabul edilir.

Dođrusal olmayan (nonlinear) regresyon analizi: Burada iki ya da daha fazla sayıda deđişken arasında doğrusal olmayan ve biçimi önceden seçilen bir denklemle ifade edilen bir iliřkinin varlığı kabul edilir. (Bayazit ve Ođuz (2005))

Çok deđişkenli regresyon iliřkisi Y bađımlı deđişkeninin X_1, X_2, \dots, X_m gibi m bađımsız deđişkenden etkilendiđi kabul edilir ve aralarındaki iliřki için doğrusal bir denklem seçilirse Y için regresyon denklemi řu şekilde yazılabilir:

$$y = a + b_1x_1 + b_2x_2 + \dots + b_mx_m \quad (3.1)$$

Bu denklemde y , bağımsız değişkenler $X_1=x_1, X_2=x_2, \dots, X_m=x_m$ değerlerini aldığında Y değişkeninin beklenen değerini göstermektedir.

A, b_1, b_2, \dots, b_m regresyon katsayıları basit regresyondakine benzer şekilde, gözlem noktalarının regresyon denkleminin gösterdiği düzlemde olan e_{yi} uzaklıklarının karelerinin toplamı olan,

$$\sum_{i=1}^N e_{yi}^2 = \sum_{i=1}^N \underbrace{(y_i - a - b_1 x_{1i} - b_2 x_{2i} - \dots - b_m x_{mi})}_y^2 \quad (3.2.)$$

İfadesini minimum yapacak şekilde hesaplanır. (Bayazıt ve Oğuz (2005))

Y nin X_1, X_2 ve X_3 gibi üç bağımsız değişkene göre regresyon denkleminin en basit hali olarak şu şekli alır:

$$y = a + b_1 x_1 + b_2 x_2 + b_3 x_3 \quad (3.3)$$

3.1.2. Otoregresif Model (AR(p))

Bir rasgele değişkenin aldığı değerlerin zaman içinde belli aralıklarla (Δt) izlenmesi halinde bir zaman serisi ($X_1, X_2, \dots, X_i, \dots$) elde edilir. Ardışık anlardaki X_i ve X_{i+1} değerleri arasında istatistik anlamda bir bağımlılık bulunması halinde X_i bir stokastik süreç oluşturur.

Zaman serilerine İnşaat Mühendisliğinde özellikle hidrolojik uygulamalarda rastlanır. Bir akarsu kesitinde Δt aralıklarıyla ölçülen akımlar (ya da Δt aralığındaki toplam akım hacmi) bir zaman serisi oluşturur. Diğer bir uygulama alanı hava trafiğinin zaman içinde değişimidir. Bu bölümde akım serilerinin istatistik analizinde kullanılan metotlar tanıtılacaktır (Bayazıt, 1996).

Yıllık akım serilerinin (trend ya da sıçrama bileşeni bulunmadığı takdirde) stasyonier oldukları kabul edilebilir. Buna karşılık zaman aralığının daha küçük alınması halinde (mevsim, ay, hafta, gün) yıl periyod olmak üzere bir periyodik bileşen bulunacağından akım serileri stasyonier olmayacaktır. Stasyonier olmayan serilerin

incelenmesi güç olduğundan ileride görüleceği gibi bunların uygun bir dönüşümle stasyonere hale getirilmesine çalışılır.

Akarsu havzasının depolama özellikleri akım serilerindeki ardışık değerler arasında bağımlılık (iç bağımlılık) bulunmasına neden olur. Zaman aralığı kısaldıkça iç bağımlılık kuvvetlenir. Yıllık akımlar için en çok kullanılan modeller ARMA (autoregressive-moving average) sınıfı modellerdir. Bu sınıfta Markov modelleri olarak da bilinen lineer otoregresif modeller, hareketli ortalama modeller ve bu ikisinin karışımı şeklinde olan modeller bulunur. (Model kurarken işlemleri basitleştirmek için veriler normalize edilerek kullanılır. Bu çalışmada sadece AR(p) modelleri kullanılacaktır.

3.1.2.1. Otoregresif Modeller (Markov Modelleri)

p-inci mertebeli Markov modelinde (AR(p) modeli) i-inci yılın y_i akımı için şöyle bir ifade kabul edilir:

$$y_i = \sum_{j=1}^p \phi_j y_{i-j} + \epsilon_i$$

$$= \phi_1 y_{i-1} + \phi_2 y_{i-2} + \dots + \phi_p y_{i-p} + \epsilon_i \quad (3.4.)$$

Burada i-inci yılın akımının bundan önceki p yılın akımlarıyla doğrudan doğruya bağımlı olduğu görülmektedir. Modelde, ϕ_i regresyon katsayıları, ϵ_i bağımsız değişkendir. Bu çalışmada verilere 6. mertebeli otoregresif model uygulanmıştır.

3.2. Yapay Sinir Ağları (YSA) Modeli


YSA modeli, elimizde var olan tüm problemlere uygulayabileceğimiz bir yöntemdir. Bu yöntem çalışmalardan bağımsız ve oldukça derindir. Her olayda kullanılabilir. Bu sebeple, yapay sinir ağları yöntemi, inşaat, makine ve tıptan mikro elektriğe kadar birçok farklı ve geniş disiplin dallarına uygulanmaktadır.

3.2.1. Y.S.A' nın Biyolojik Temeli

Yapay sinir ağları işlemleri büyük ölçüde beyinde bulunan biyolojik yapıya paralel olarak türetilmiştir. Kısmen basit otomatik hareketler, bir bardak su almak ve

telefon numarası çevirmek gibi otomatik hareketler için bedensel koordinasyon, öğrenme ve hafızanın birçok parçası aynı zaman sürecinde işlev yapmaktadır. Bizim her zaman düşünmeksizin yaptığımız bu tip basit hareketlerin karışıklığı, bu hareketleri öğrenme robotlarına uygulamak istediğimizde daha açık bir şekilde görülmektedir.

İnsan sinir sisteminin merkezi beyindir ve sürekli olarak bilgiyi alır, onları kavrayarak, uygun kararlar verir. Bu sistem, sinir ağları (neural net) olarak da tanımlanır. Sinir sistemlerinin, temel yapı bloğu sinirlerdir. Bir siniri oluşturan temel elemanlar; ana hücre yapısı, dentristler ve aksonlardır. İnsan beyni çok fazla sayıda nörona (işlemci elemanı) sahiptir. Bu ortalama olarak 10~500 milyar arasında değişir. Aşağıdaki şekilde sinir sistemini ifade eden bir diyagram verilmiştir.



Şekil 3.1. Beyin sinir sistemi çalışma şeması

Yukarıdaki şekilde 2 yönde ok vardır. Bunlar sıra ile sistemde ileriye ve geriye doğru besleme (taşınım) göstermektedir. Aynı şekilde sinirlerde algılayıcılar insan vücudundan uyarı şeklinde aldıkları elektrik etkilerini uyarılara dönüştürürler. Sonuçlandırıcılar ise sinir ağı tarafından oluşturulan elektrik etkilerini dönüştürür ve sistemin sonuç çıktısı olarak verir. Roman Y. Cayal (1911) beynin yapısal bileşenleri olarak sinirlerin planını (bilgiyi taşınmasını) ilk tanımlayanlardandır.

3.2.1.1 Bir Nöronun modeli

Nöron, bir yapay sinir ağının temelini oluşturan bilgi işleme birimidir. YS ağı modelinin 3 temel elemanı vardır. Snopsis (bağlantı elemanları): Bunların her biri kendi etkinlik veya ağırlık derecesiyle tanımlanır. Özellikle bir k nöronuna bağlanan (j) snopsisinin girdi kümesindeki bir X_j elemanı, W_{kj} bağlantı ağırlık katsayısı (snoptik weight) ile çarpılır.

Nöronların ağırlıklı çarpımları ve nöronların bağlantılarının ağırlık etkisiyle bağlı değişen bias (dış etkileri yansıtan) terimi ile toplanır. Bu işlem lineer

Çıktı değeri ise;

$$Y_K = \varphi(V_K + b_K) \quad (3.6.)$$

olarak belirlenir. Burada bias terimi (dış etken parametresi, veya aktivasyon fonksiyonunun girdilerinin artması ya da azalmasının etkisini katmak amacıyla kullanılan bir sabittir), b_K bu çalışmada 1 olarak alınmış ve;

$$Y_K = \varphi(V_K) \quad (3.7.)$$


elde edilmiştir.

Tipik olarak aktivasyon fonksiyonu sonucunda bir nöronun çıktısının normalize edilmiş genlik alanı, kapalı bir birim aralığı olarak [0-1] veya [-1, 1] arasında alınabilir Ciğizoğlu (2004).

3.2.1.2. Aktivasyon Fonksiyonları Tipleri

Bir nöronun çıktılarının genliğini sınırlamak için bir çok tip aktivasyon fonksiyonu, “ $\varphi(V)$ ”, vardır. Bunlar arasında, en çok kullanılan aktivasyon fonksiyonları; **Eşik fonksiyonu (Threshold function):**

Bu tip aktivasyon fonksiyonu şekli aşağıdaki gibidir.



Şekil 3.3. Eşik Fonksiyonu

$$\text{Eğer } V \geq 0 \Rightarrow \varphi(V) = 1 \quad (3.8a)$$

$$\text{Eğer } V < 0 \Rightarrow \varphi(V) = 0 \quad (3.8b)$$

olarak belirlenir.

Mühendislik literatüründe bir eşik fonksiyonunun bu şekline artı-azalan (Heaviside) adı verilir. Bu eşik fonksiyonundaki gibi çalışan bir K nöronun çıktısı aşağıdaki gibi açıklanabilir.

$$\text{Eğer } V_K \geq 0 \Rightarrow Y_K = 1 \quad (3.9a)$$


$$\text{Eğer } V_K < 0 \Rightarrow Y_K = 0 \quad (3.9b)$$

V_K ; nöronun oluşan sınırlandırılmış alanıdır ve denklem (3.5) benzer şekilde şöyle ifade edilir;

$$V_K = \sum_{J=1}^M w_{KJ} \cdot x_J + b_K \quad (3.10)$$

Parçalı Lineer fonksiyonu (Piecewise-Linear Function)

Parçalı Lineer fonksiyon aşağıdaki şekilde ifade edilebilir.



Şekil 3.4 Parçalı Lineer fonksiyon

Parçalı Lineer fonksiyon değişim aralığı şekilde olduğu gibi aşağıda verilmiştir.


$$\varphi(V) = \begin{cases} 1 \Rightarrow V \geq \frac{1}{2} \text{ için} \\ V + \frac{1}{2} \Rightarrow -\frac{1}{2} \leq V \leq +\frac{1}{2} \text{ için} \\ 0 \Rightarrow V \leq -\frac{1}{2} \text{ için} \end{cases} \quad (3.11)$$

Bu fonksiyonda işlemin lineer bölge içinde olması durumunda arttırma faktörü (1) olarak kabul edilir. Aktivasyon fonksiyonunun bu formu bir nonlineer artırım yaklaşımıdır.

Sigmoid Fonksiyonu:

Bu fonksiyon (S) şekline sahiptir ve yapay sinir ağlarının uygulamasında en yaygın kullanılan aktivasyon fonksiyonudur. Bu fonksiyon tam olarak bir artan fonksiyondur, lineer ve nonlineer davranış arasında bir dengeyi gösterir.

Sigmoid fonksiyonunun bir örneği de Logistic fonksiyonudur ve $\varphi(V) = \frac{1}{1 + \exp(-ON)}$ ile temsil edilir. Sigmoid fonksiyonu genel şekli aşağıda verildiği gibidir.




Şekil 3.5. Sigmoid Fonksiyonu

Burada a; Sigmoid fonksiyonu eğri parametresidir.

3.2.1.3. Geri Besleme (Feedback):

Sistemin bir parçasının (kısımının) çıktısı, girdi (input) olarak alınan, belirli bir bölümü ile etkileşiyorsa, geri beslemeli bir dinamik sistem olduğu kabul edilir. Böylelikle sistem içerisindeki sinyallerin iletilmesi için bir veya daha fazla kapalı yol ortaya çıkmaktadır (Üneş (2006), Çiğizoğlu (2006)).

Aşağıdaki şekilde tek döngülü geri beslemeli sistem için akım sinyal şeması verilmektedir.



Şekil 3.6 Tek döngülü geriye beslemeli sistem için akım sinyal şeması

Burada girdi sinyalleri ($X_j(n)$); ilk sinyaller $X'_j(n)$ ve çıktı sinyaller $Y_k(n)$ olmak üzere, ayrıklaştırma (nümerikleştirme) zaman değişkeni (n)'nin fonksiyonu olarak verilmiştir. Bu sistem operatörleri ileriye ve geriye besleme oluşumunu tanımlamaktadır. Özellikle ileriye beslemekteki çıktılar kısmen geri besleme yolu ile kendi çıktılarından belirlenir.

Yukarıdaki şekilden görüldüğü gibi girdi ve çıktı arasındaki ilişki kolayca belirlenebilmektedir.

$$Y_k(n) = A[X_j(n)] \quad (3.12.)$$

$$X'_j(n) = X_j(n) + B[Y_k(n)] \quad (3.13.)$$

Denklemler yeniden incelendiğinde $Y_k(n)$ çıktıları istenen aralıkta elde edilene kadar $X'_j(n)$ iç sinyallerinden etkilenmektedir, yani $X_j(n)$ girdileri lineer fonksiyon çıktıktan sonra istenilen aralıkta belirlenememişse $B[Y_k(n)]$ döngüsüne girmekte (geri besleme yapılmakta) ve $X'_j(n)$ iç sinyalleri olarak yeniden döngüye sokulmaktadır. Tabii ki bu döngünün girdileri $Y_k(n)$ kümesinin çıktıları olacaktır. Burada (A) ve (B) döngü operatörü olarak davranmaktadır (Üneş (2005)).

Yukarıdaki (3.12, 3.13) denklemlerinden $X'_j(n)$ çıkarılırsa aşağıdaki denklik elde edilir.

$$Y_k(n) = \frac{A}{1 - AB} [X_j(n)] \quad (3.14.)$$

Bu ifade sistemin kapalı döngü operatörü olarak tanımlanır. Genelde açık döngü operatöründe $BA \neq AB$ yoludur, yani açık döngü operatörü iletişimsizdir (Bağımsızdır).

Yukarıdaki denklem açılırsa

$$Y_K(n) = A[X_J(n) + B(Y_K(n))] \quad (3.15)$$

$$= A X_J(n) + AB(Y_K(n))$$

$$Y_K(n) = \frac{A}{1-AB} [X_J(n)] \quad (3.16.)$$


elde edilir .

3.2.1.3. YSA'nın Çalışma Ağının Yapısı:

YSA'nın nöronlarının yapılanmasındaki yol özellikle ağı eğitmek için kullanılan öğrenme (Eğitme) algoritması ile ilgilidir. Bu yapılanma aşağıdaki gibi sınıflandırır.

Tek Tabakalı İleri Beslemeli Ağ:

Tek tabakalı yapay sinir ağlarında nöronlar tabaka şekline göre düzenlenir. Tabakalı ağın en basit formunda kaynak (girdi noktalarının) bir girdi tabakası ve nöronların (hesap noktaları), bir çıktı tabakası vardır. Bu tip tek tabakalı ağ YSA modellerinde pek alışılmış ve kullanılmış değildir. Diğer bir deyişle de bu tip ağ tamamen ileriye beslemeli (feed forward) bir tiptir.




Şekil 3.7. Tek tabakalı ileri beslemeli ağ

Çok Tabakalı İleri Beslemeli Ağ

İleri beslemeli bir sinir ağının, bu 2. sınıf formu, bir veya daha fazla gizli tabakaların oluşturulması ile kendi kendiliğinden ayırt edilebilir bir forma girmektedir. Bu gizli tabakaların hesaplanan noktaları şekilleri ile uyumlu olarak gizli nöronlar (hiddenlayers) veya gizli birimler olarak tanımlanır (hidden units).

Bu gizli tabakaların sinirlerinin fonksiyonu, hesaplarda faydalanılmak amacı ile, dış girdiler (veriler =inputlayer) ve hesap ağı çıktıları arasında yer alır. Bir veya daha fazla gizli tabaka eklenerekte daha hassas dereceli istatistiksel sonuçlar elde etmek mümkündür.



Şekil 3.8. Tam bağlı ileri beslemeli bir gizli ve çıktı tabakalı hesap ağı

Çalışma ağının giriş verileri tabakasındaki girdi (input) verileri sırası ile girdi vektörlerinin elemanlarını oluşturur. Bunlar 2 tabakadaki nöronlara uygulanan giriş verisi sinyallerinden oluşur.

Eğer YSA modelimiz birden fazla ara tabaka içeriyorsa ikinci tabakanın çıkış sinyalleri, 3. tabakanın girdi verileri olarak kullanılır ve çalışma ağının tümü için bu şekilde uygulanabilir. Su kaynakları mühendisliğinde yapılan uygulamalar için bize tek tabaka yeterli olacaktır.

Çalışma ağının çıktı tabakalarındaki (output) nöronların çıktı sinyallerinin kümesi, girdi (input) tabakasındaki verilerden elde edilen girdi vektörlerine YSA modelinin yanıtı olarak elde edilir.

Şekil 3.9'da ileri beslemeli sinir ağı 2-4-1 hesap ağı olarak tanımlanır. Sebebi de bu hesap ağı 2 adet girdi noktası (source nodes), 4 adet gizli nöron (hidden neurons) ve 1 adet çıktı nöronuna (output neurons) sahip olmasıdır.

Bunun yanı sıra bu şekildeki nöron çalışma ağın tam bağlantılı (Fully connected) YSA modeli olarak isimlendirilir. Çünkü çalışma ağının her bir tabakasındaki her bir düğüm, önündeki komşu tabakalardaki her bir düğüm ile bağlanmıştır. Ancak eğer bu iletme bağlantılarının (synaptic connections) bazıları eksik ise bu tip çalışma modeline kısmi bağlantılı YSA modeli denir.


YSA Algılama, Öğrenme Şeması (Perceptron)

Perceptron (algılama); bir lineer ayrıştırılabilen YSA modelinin en basit şekline verilen addır. Bir perceptron temel olarak, düzeltilebilir bağlantı ağırlıkları ile bir nöron ve bias eğilim teriminden oluşur.

Bu algoritma ilk olarak Rossen Blatt (1958–1962)'in beyin algılama (öğrenme modeli) için geliştirdiği bir öğrenme prosedüründe görünen bir sinir ağının bağımsız parametrelerini düzenlemede kullanılmıştır.

Rossen Blatt, girdi verileri lineer olarak ayrılabilen iki farklı sınıftan alınan perceptronları eğitmek için kullanıldığında perceptron algoritmasının yakınsak sonuçlar verdiğini göstermiştir.. Bu algoritmanın yakınsamasının ispatı perceptron yakınsama teoremi olarak bilinir. Birden fazla nöronu içermesi için perceptronun çıktı tabakası genişletilerek daha fazla uygun sınıflamada yapılabilir.

Aşağıda Şekil 3.9.'da iki girdili, tek gizli tabakalı, dört nodlu ve bir çıktılı YSA şeması verilmiştir. Şekilde, sinir ağı 1 girdi (input) tabakası ve 2 nod gizli tabakaya (hidden layer) ve anod çıktı (output) ve tek nod tabakasına sahiptir. Her bir tabaka birkaç düğüm ağından (nodes) oluşturulur ve tabakalar ağırlık değerleriyle bağlanmıştır.



Şekil 3.9. İki girdili, tek gizli tabakalı, dört nodlu ve bir çıktılı YSA yapısı

Hatayı Geriye Yayararak Eğitime: (Training by error backpropagation)

Her bir tabakadaki nöronların sayısı ve bağlantı şekli belirli şartlar içerisinde değişebilir. Bir tabaka içerisindeki düğüm noktaları arasında (iletişim) bağlantı kurulmasına izin verilmez. Ancak her bir tabakadaki düğüm noktası değerleri, ardışık yani ondan sonraki tabakaya önceki tabaka çıktısı veya bulunduğu tabakanın girdisi olarak işlem yapabilir.

Düğüm noktalarına verilen veriler, hem başlangıçlardaki girdilerden (yani ilk girdi dosyalarından) hem de sonraki tabaka çıktılarından geri beslemelerinden ileri gelebilir. Bu geri besleme 2 safha içerir: Girdi düğümlerindeki dışardan girilen verilerin bir ileri besleme safhası ile çıktı tabakasındaki çıktı bilgilerini hesaplayarak ileriye doğru yayılması. Çıktı gözlemlenen değerler ve hesaplananlar arasındaki farka (hataya) dayanarak bağlantı ağırlıklarını (w ; ağırlık-etkinlik katsayılarını) değiştirme-geri besleme fazında yapılır.

Eğitim işleminin başlangıcında, bağlantı eğitim algoritması, eğitime işlemini başarıyla tamamlayana kadar her bir iterasyonda düzeltilerek değiştirilir. Ağırlıkları rasgele değerler olarak alınarak başlanır.

Bu iterasyon işlemi (geriye doğru hataların yayılmasıyla yapılan) yakınsadığı zaman, bir ileri beslemeli hesap ağındaki YSA modeli ile elde edilen çıktı sonuçları değerlendirilerek o modelin sonucunda ağırlık katsayıları belirlenir.

Bir YSA modelinde N tane (girdi parametre verisi) girdi verisi vardır. Bu verilerin her biri girdi değerlerinin bir kümesine sahiptir. Buna X_i dersek; $X_i = (i=1,2,3,\dots,k)$ kadar ve çıktı düğümlerinde J_n , ($n= 1, 2, 3,\dots, m$) kadar çıktı değeri vardır. Bu girdi değerleri gizli tabakalardaki W_{ij} ($j=1,2,3,\dots,h$) ile çarpılır ve çıkan değerler düzenlenerek gizli tabakaların girdi değerleri olarak kullanılır.

$$H_j = \sum_{i=1}^k W_{ij} \cdot X_i \quad (j = 1,2,3,\dots,h) \quad (3.17)$$

H_j : (j)inci gizli tabakadaki girdi değerleridir.

W_{ij} : (i)inci nöronun (j) inci nörona bağlantı, ağırlık katsayılarıdır.

Her bir gizli tabaka bir gizli tabaka, çıktısı üretmek için sigmoid fonksiyonu (veya diğer fonksiyon) ile dönüştürülür veya işleme tabii tutulur. H_{Oj} olarak gösterilen çıktılar elde edilir.

$$H_{Oj} = f(H_j) = \frac{1}{1 + \exp[-(H_j + \theta_j)]} \quad (3.18.)$$

H_j : Düğüm noktalarındaki girdi değerleri

$f(H_j)$: Çıktı düğüm noktası değeri

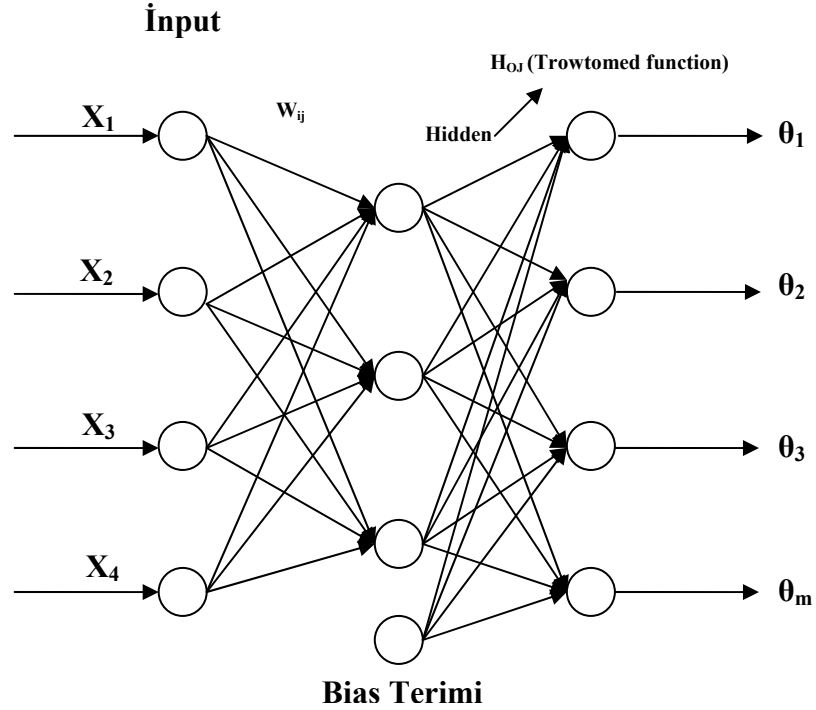
θ_j : Bir başlangıç veya Bias terimi olarak alınabilir.

Threshold (başlangıç) fonksiyonu, (θ_j) ağırlık katsayılarının eğitilmesine bir değer (genelde 1 alınır) olarak etkitilebilir. H_{Oj} çıktı değerleri ardışık tabakalarda girdi olarak da görev yapabilir. Birden fazla gizli tabaka alınması durumunda bu işlem çıktı tabakasına varıncaya kadar devam eder. Yani kaç tane ara tabaka var ise her ara tabakanın çıktısı sonrakinin girdisi (inputu) olarak alınır ve bu işlem çıktı tabakasına kadar devam eder. Bu işlemin tümüne ileri doğru hareket akışı denir. Eğer n tane çıktı düğümü için girdi olarak I_{On} alınırsa aşağıdaki gibi ifade edebiliriz.

$$I_{On} = \sum_{j=1}^h W_{jn} \cdot H_{jn} \quad (n = 1,2,3,\dots, m) \quad (3.19.)$$

Bütün girdi değerleri aktivasyon fonksiyonu ile yeniden tanımlanarak (O_n) sinir ağının çıktı değerleri belirlenir. Şekil 3.10'da çok tabakalı algılayıcının genel formu verilmiştir.

Yakınsak çözüm için ardışık olarak iterasyonlar boyunca ağırlıkların değiştirilmesi (hataların geriye yayılması) veya eğitme işlemlerinin geriye yayılması öğrenme algoritması ile başarılmaktadır. Çıktı tabakasındaki (O_n) değerleri hedeflenen değerler ile (elimizdeki bulmayı amaçladığımız ölçüm veya model sonuçları) aynı olmayacaktır. Belirli bir miktar hata içerecektir.



Şekil 3.10. Çok tabakalı algılayıcı (perceptron)

θ_j Burada başlangıç fonksiyonu olarak alınır, bu terim yerine bias terimi genellikle kullanımlarda (1) olarak alınıp işlem yapılır. H_{Oj} çıktısı ise sigmoid fonksiyonu kullanılarak çıktı değerlerini ardışık gizli tabakalar boyunca input değerleri olarak almış ve output değerlerine kadar devam etmiştir.

Bu input değerleri yapay sinir ağından elde edilecek (O_n) çıktı değerlerini vermesi için YSA modeli boyunca sürdürülüp yine eğitime işlemi ardışık ağırlık düzeltme işlemi ve geriye beslemeli eğitim algoritması ile başarılmaktadır.

YSA uygulanarak elde edilen çıktıya (O_n) bulunması istenen ölçüm değerlerine (T_n) denirse her bir girdi verisi için (e_p) p'inci girdi verisinin çıktı sonucu oluşan hatası toplam karesel hataya göre yazılırsa (sum of squares of error) ;

$$e_p = \sum_{l=1}^m (T_n - O_n)^2 \text{ dir.} \quad (3.20)$$

ve “MSE” (mean square veya average system error) ortalama karesel hataya göre hesaplanmak istendiğinde, tüm girdi verileri için toplam miktarı olarak ;

$$E = \frac{1}{2N} \sum_{p=1}^N \sum_{n=1}^m (Tp_n - Op_n)^2 \quad (3.21)$$

burada, N; bütün Girdi veriler, Tp_n : Gerçek veriler (bulunması istenen hedef değer), Op_n ; (YSA) yapay sinir ağları çıktı değerleridir.

Geri beslemeli algoritmanın amacı iteratif olarak ortalama karesel hataların minimize edilmesidir. Bu işlem çıktı tabakasındaki her bir bağ noktası için δ_n hesaplanan değişim miktarını verir.

$$\delta_j = O_n(1 - O_n)(T_n - O_n) \quad (3.22.)$$

burada δ_j hatanın değişimidir ve bir önceki tabakadaki hesaplanan hataların ağırlıklı toplamları tarafından ara tabakalar için yenilenerek her bir iterasyon için belirlenir.

$$\delta_j = H_{Oj}(1 - H_{Oj}) \sum_{n=1}^m \delta_n \cdot W_{jn} \quad (3.23.)$$

olarak yazılabilir. Burada, H_{Oj} ; girdi ve çıktı (input ve output) arasındaki ağırlık fonksiyonu ile verilen ilişkiden yola çıkarak, H_j , gizli tabaka girdisi ile O_j , çıktı değerine geçişi veren sigmoid fonksiyonu dönüşümüdür.

$$H_j = \sum_{i=1} W_{ij} \cdot X_i \quad (3.24.)$$

ve

$$H_{Oj} = f(H_j) = \frac{1}{1 + \exp(-H_j - O_j)} \quad (3.25.)$$

Hata değerinin miktarı hesap ağının ağırlık değerlerini güncelleştirmede kullanılır.

$$\Delta W_{ij} = \eta \cdot \delta_j \cdot X_i \quad (3.26.)$$

şeklinde yazılarak ağırlık değeri hataya göre yenilenir.

$$W_{ij}(r+1) = W_{ij}(r) + \Delta W_{ij} \quad (3.27.)$$

Genellikle hızlı bir yakınsama sağlamak için eskalasyon (değerler arasındaki fark-salınım) yol açmamak için geniş adım aralığı kullanılır. (r) inci data girildikten sonra ağırlıklardaki değişim ise;

$$\Delta W_{ij}(r) = \eta \cdot \delta_j \cdot X_i + \alpha \Delta W_{ij}(r-1) \quad (3.28.)$$

burada, α ; Yakınsamayı hızlandırmak için kullanılan bir momentum oranı ifadesini, η ; hatanın değişiminde ve yayılımındaki adım aralığını belirleyen öğrenme oranı, r; iterasyon sayısı, δ_j ; hata miktarını göstermektedir.

Öğrenme Oranı (Learning Rate $0 \leq \eta \leq 1$)

Öğrenme oranı $\{0-1\}$ arasında belirlenir. Küçük bir öğrenme oranı “ η ” için, bir iterasyondan diğerine çalışma ağındaki iletişim ağırlık çarpanının (W_{ij}) değişimi daha küçük olacaktır.

Yani daha küçük “ η ” deęeriyle daha yavař bir öğrenmenin oluşmasına sebep olacaktır. Dięer taraftan çok yüksek bir “ η ” deęeri seçildiğinde YSA modeliyle oluşan çalışma aęı yakınsak bir sonuç vermeyebilir (unstable).

Momentum Oranı katsayısı “ α ” (Momentum Rate $0 \leq \alpha \leq 1$)

Momentum katsayısı olaya dahil edilerek yakınsak (stable) ve doęru sonuca daha yakın bir deęer elde edebiliriz. Momentum oranı, grafiklerin veya verilerin dönüm noktalarındaki hata yüzeylerinde modelin öğrenme işlemini sonlandırmasını önleyebilir. Yani momentum oranı Lokal minumumlarda YSA’nın iterasyona son vermesini önler.

Bir sonraki iterasyonda yayılacak hata miktarı ařağıdaki gibi verilmiştir.

$$\Delta W_{ji}(r) = \eta \cdot \delta_i \cdot X_i + \alpha \Delta W_{ji}(r-1) \quad (3.29.)$$

Bu çalışmada Levenberg-Marquardt geriye beslemeli algoritma kullanılmıştır. Bu algoritma, doęru çözüme yaklaşımı hızlandırmak amacı ile en çok kullanılan algoritmalardan biridir (Kisi, 2004). YSA modelinin uygulanması amacı ile istenilen girdi, çıktı ve eğitim sınırlarına göre MATLAB yazılım dilinde bir alt program yazılarak baraj haznesindeki seviye salınımları belirlenmiştir.

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

4.1 Uygulama Alanı ve Tanıtılması


Baraj haznesindeki seviye salınımının belirlenmesi için uygulama barajı olarak Hatay ili Altınözü ilçesi Beyazçay deresi üzerine sulama amacıyla inşa edilen Yarseli barajı seçilmiştir. Yarseli barajı Mayıs 1992’de işletmeye açılmış olup Sulama sahası brüt 6398 net 5758 ha’dır.

224 km² drenaj alanına sahip Yarseli Barajı zonlu toprak tipinde olup yıllık ortalama akımı 52.64 hm³/yıl dır. Barajın maksimum hazne kotu 134.50 m’dir. Minimum su seviyesinde göl hacmi 4.90 hm³ minimum hazne kotu 114.40 m.dir. Barajın ölü hacmi 2.80 hm³ olup aktif hacmi 51.70 hm³ tür. Baraj dolgusunun kret kotu 137.00 m. olup, kret uzunluğu 960 m., gövde dolgusu 3.000.000 m³ tür. Barajın talveg kotu 102.00 m., temel kotu 95.00 m. dir. Barajın temelden yüksekliği 42.00 m. talveg’den yüksekliği 35.00 m.dir.

Barajın dolu savağı sol sahilde karşıdan alışlı ve radyal kapaklı olup deşarj kapasitesi 888 m³/sn.dir. Dolusavak eşik kotu 128.00 m.dir. Barajın Dipsavağının deşarj kapasitesi 15 m³/sn.dir. Dipsavak sulama suyu alımında kullanılmaktadır. Şekil 4.1- 4.2 de bu baraja ait genel görünüm ve vaziyet planı verilmiştir. Bu çalışmada Yarseli Barajının 1 Ocak 2002-30 Kasım 2006 tarihleri arasındaki günlük ölçüm değerleri kullanılmıştır. Yarseli Barajına yağışın az olduğu yıllarda Asi Nehrinde bulunan PO pompa istasyonundan (Şekil 4.3) su takviyesi yapılmaktadır.



Şekil 4.1. Yarseli Barajı Genel Görünümü

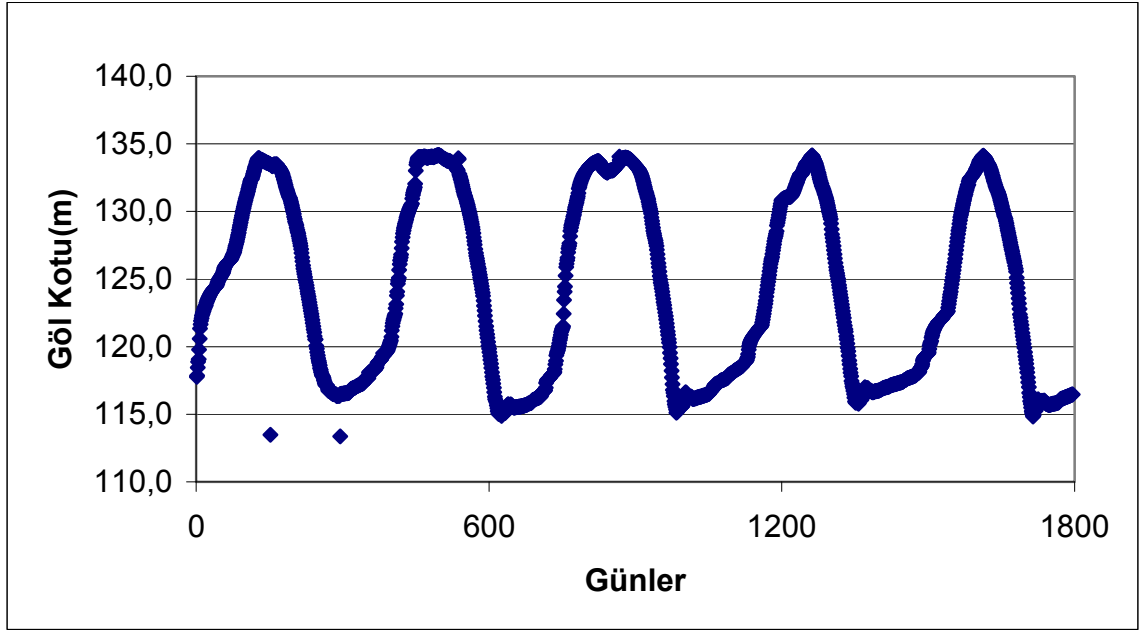


Şekil 4.2 Yarseli Barajı ve Sulaması Genel Vaziyet Planı

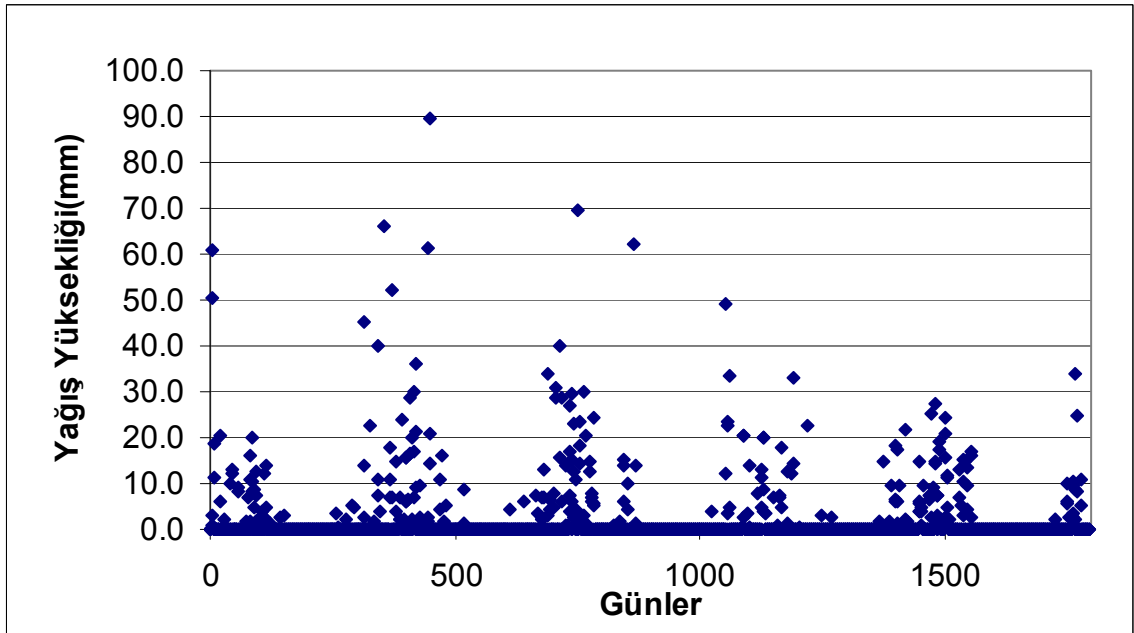


Şekil 4.3. P0 Pompa İstasyonu Genel Görünüşü

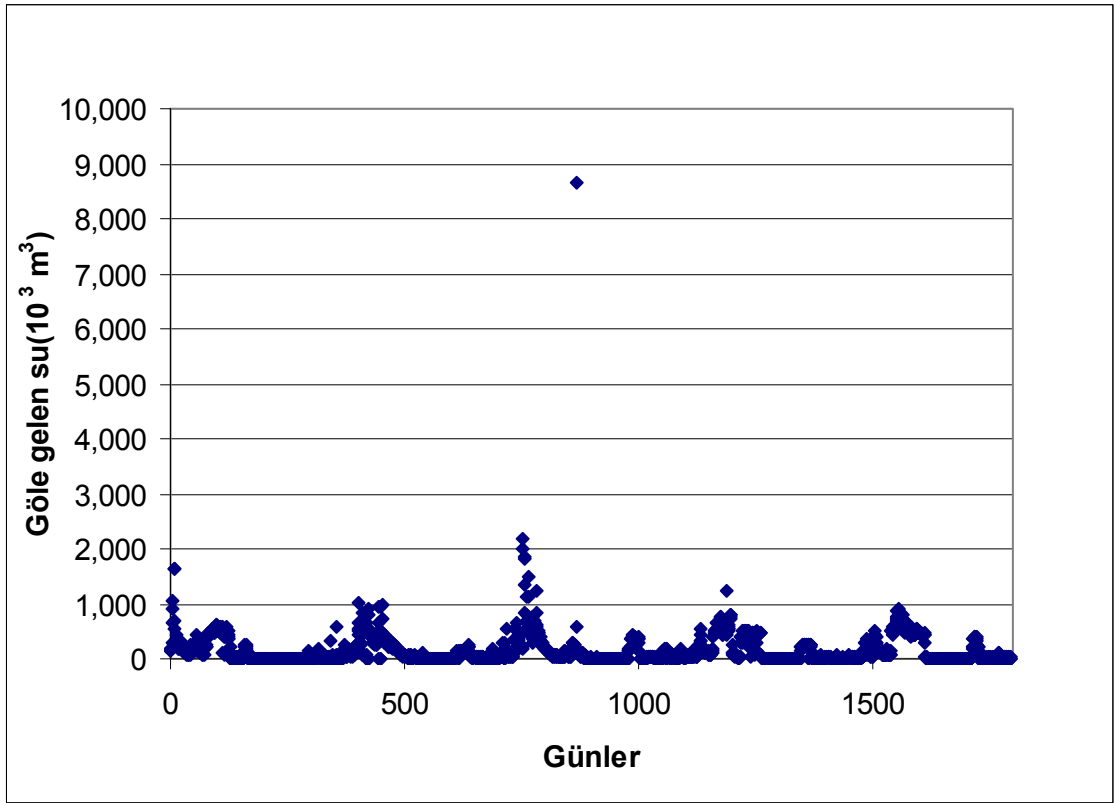
YSA ve diğer klasik modeller için kullanılan veriler aşağıdaki gibidir: Yarseli barajına ait günlük yağış yüksekliği, günlük su sarfiyatı, günlük göle gelen su, günlük göl kotu ölçüm bilgileri. Bu veriler Devlet Su İşleri (DSİ) Genel Müdürlüğü'nden elde edilmiştir. Günlük yağış yüksekliği, buharlaşma ile ilgili veriler DSİ'nin Yarseli Barajındaki ölçüm istasyonundan alınmıştır. Günlük su sarfiyatı olarak ölçülmüş buharlaşma, sulama suyu ve savaklanan su değerlerinin toplamı kullanılmıştır. Günlük göle gelen su verilerinde dereden gelen ve pompayla takviye edilen günlük su toplamı alınmıştır. Bu veri setleri her iki metoda uygulanmış ve karşılaştırmalar yapılmıştır. Bu zaman periyodu içindeki aylık baraj rezervuar seviye değişimleri Şekil 4.4.'de gösterilmektedir. Bu bölge bahar başlangıcı ve sonunda yüksek miktarlarda yağış alan bir bölgedir. Ama bir diğer taraftan, yaz mevsimi kurak geçmektedir. Sonuç olarak meydana gelen su seviyesindeki dalgalanmaların büyük ölçüde drenaj alanını etkileyen meteorolojik koşullara bağlı olduğu gözlemlenmiştir. Şekil 4.4'de de görülebileceği üzere, dikey eksen baraj rezervuarındaki istasyon ölçümlerini göstermektedir ve dalgalanmalar 20,8 metre kadardır. Bu çalışmada kullanılan diğer verilerin günlere göre değişimleri Şekil 4.5.-4.6.-4.7.'de verilmiştir.



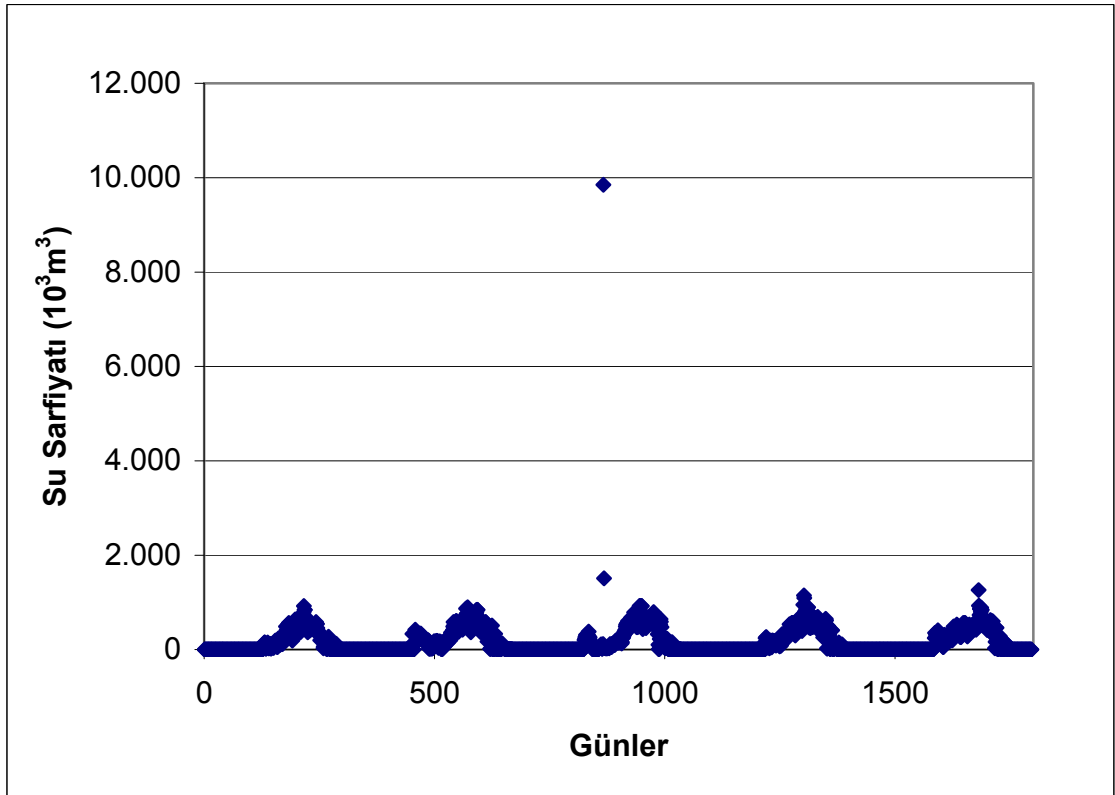
Şekil 4.4. 10 Ocak 2002 ile 30 Kasım 2006 tarihleri arası Yarseli Barajı Günlük Göl Kotu Değişimleri



Şekil 4.5. Yarseli Barajı günlük yağış yüksekliği değişimleri



Şekil 4.6. Yarseli Barajı günlük gelen su miktarı değişimleri



Şekil 4.7. Günlük Su Sarfiyatı Değişimleri

Bu veriler göz önünde bulundurularak hem model gelişimi hem de doğruluğu sergilenecektir. Bu yüzden model doğruluğunun kontrolü için ilk 1004 günlük veriler eğitimde kullanıldı. Geriye kalan 792 günlük veriler de geliştirilmiş modelin geçerliliğini doğrulamak amacıyla test aşamasında kullanılmıştır. Gözlemlenmiş ortak verilerin istatistiksel özetleri, eğitim verisi ve test verisi olarak, istatistiksel moment metodları kullanılarak hesaplanmış ve bu özetler Çizelge 4.1'de gösterilmiştir. Çizelge 4.1'de x_{max} , x_{min} , ve x_{avg} sırasıyla bütün verilerin maksimum, minimum ve parametrelerin ortalama değerlerini temsil etmektedir. s_x ve c_{sx} değerleri sırasıyla standart sapmayı ve çarpıklık katsayısını temsil etmektedir. Çizelge 4.2.'de de eğitim verileri ve test verilerinin istatistiksel parametre değişimleri ayrı ayrı verilmiştir.

Çizelge 4.1. Yarseli Barajının bütün istatistiksel parametre değişimleri

Veri Grubu	Veri Tipi	Parametreler				
		x_{max}	x_{min}	x_{ort}	s_x	c_{sx}
Tüm Veriler	G.Y.Y(mm)	89,5	0,0	1,9	6,7	6,0
	G.G.G.S(*10 ³ m ³)	11883,0	0,0	156,7	362,5	19,6
	G.S.S(*10 ³ m ³)	9853,0	0,0	166,7	328,5	14,8
	G.G.K(m)	134,2	113,4	124,2	6,9	0,2

G.Y.Y :Günlük yağış yüksekliği; G.G.G.S:Günlük göle gelen su; G.S.S :Günlük su sarfıyatı ; G.G.K :Günlük göl kotu

Çizelge 4.2. Yarseli Barajının eğitim ve test verileri istatistiksel parametre değişimleri

Veri Grubu	Veri Tipi	Parametreler				
		x_{max}	x_{min}	x_{ort}	s_x	c_{sx}
Eğitim Verileri	G.Y.Y(mm)	89,5	0,0	2,1	7,6	5,9
	G.G.G.S(*10 ³ m ³)	11883,0	0,0	162,0	444,3	18,9
	G.S.S(*10 ³ m ³)	9853,0	0,0	178,8	387,0	15,9
	G.G.K(m)	134,2	113,4	125,4	7,0	-0,1
Test Verileri	G.Y.Y(mm)	49,0	0,0	1,5	4,9	4,5
	G.G.G.S(*10 ³ m ³)	1232,0	0,0	150,1	218,7	1,5
	G.S.S(*10 ³ m ³)	1260,0	0,0	151,3	233,4	1,5
	G.G.K(m)	134,2	114,8	122,6	6,5	0,6

G.Y.Y :Günlük yağış yüksekliği; G.G.G.S:Günlük göle gelen su; G.S.S :Günlük su sarfıyatı ; G.G.K :Günlük göl kotu

Girdi ve çıktı veri değişkenlerinin büyüklüğü farklı olduğundan, bütün değişkenleri içeren girdi ve çıktı verileri denklem 4.1 'i kullanarak eğitim ve test aşamalarında 0.1 ve 0.9 arasında normalize edilmiştir.

$$x = 0.1 + 0.8 \left(\frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \right) \quad (4.1)$$

4.2. Yarseli Barajı Uygulamaları

Bu çalışmada, YSA'da rezervuar hacim problemini tanımlarken bir gizli katmanlı MLP (Çok tabakalı algılayıcı) seçilmiştir. MLP'nin en yaygın öğrenim yöntemi olan geriye yayılım algoritması (BPA), girdi ve çıktı veri seti için kullanıldı. İleri beslemeli Bayes regülarizasyon yayılım algoritması, Marquardt Levenberg Metodu uygulandı ve MATLAB koduyla yazıldı. YSA modelinde, iterasyon sayısı, öğrenme ve momentum hızı oranı sırası ile 1000, 0.65, 0.65 olarak alınmıştır.

YSA'nın baraj rezervuar hacim verisine uygulanması iki adımdan oluştu. İlk adım sinir ağlarının eğitimidir. Bu adımda, günlük yağış yüksekliği, günlük su sarfiyatı, günlük göle gelen su gibi parametreler girdi olarak, çıktı olarakta günlük göl kotu verilerini, ağdaki aylık rezervuar seviye dalgalanmalarını ve birbirine bağlı değerleri elde etmek gerekiyordu. Baraj rezervuar modellerinin geliştirilmesi amacıyla YSA, ilk veri setinin bir başka deyişle ilk 1004 günlük gözlemlerden oluşan eğitim verisinin kullanımıyla eğitildi. Eğitim aşaması tamamlandıktan sonra MLP'ler son 792 günlük gözlemlerden oluşan test verilerine uygulandı. Belirli bir problem için uygun bir ağ yapısını saptamak, ağ topolojisi, hesap karmaşıklığını ve genelleme yapabilme yetisini bire bir ilgilendirdiğinden önemli bir konudur (Ciğizoğlu, 2003-b). İşte bu yüzden, yaygın olarak kullanılan test ve hata metotlarından yola çıkılarak gizli katman nodlarına ve gizli katman sayısına karar verilir. Farklı MLP yapıları denendikten sonra bu çalışmada 5 katmanlı ve tek gizli tabakalı MLP yapısı seçilmiştir. Her bir model için en düşük karesel hata (MSE), toplam karesel hata (MAE) ve model tahminleri ve gözlemlenmiş değerler arasındaki korelasyon katsayıları hesaplanır. Sonuçları da model tahmini ve gözlem verilerinin performanslarını karşılaştırmak için kullanılır. MSE ve MAE aşağıdaki gibi belirlenmiştir.

$$MSE = \frac{1}{N} \left(\sum_{i=1}^N Y_{i_{observed}} - Y_{i_{forecast}} \right)^2 \quad (4.2)$$

ve

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_{i_{observed}} - Y_{i_{forecast}}| \quad (4.3)$$

Burada N data set sayılarını ve Y_i rezervuar seviye verilerini göstermektedir. Ayrıca stokastik model teknikleri de rezervuar hacim varyasyonlarını tanımlamak için kullanılabilir. Hidrolojik verilerin Stokastik modelleri regresyon, zaman dizimi ve olasılık modelleri kullanarak da elde edilebilir. Bu teknikler değişkenler arasında lineer ilişkinin olduğunu varsaymaktadır (Çiğizoğlu ve Kişi, 2006). Her ne kadar rezervuar seviye varyasyonu probleminin çözümü non-lineer bir yaklaşım gerektirse de, YSA ile stokastik modelleme yöntemlerini karşılaştırabilmek için bu çalışmada otoregresif ve çoklu lineer değişkenli regresyon modelleri kullanılmıştır. Farklı sayıda girdi kombinasyonları ve gizli tabaka sayısı, MLP'den en iyi sonucu almak amacıyla denendi ve bu modeller AR(p) ve MLR modelleriyle karşılaştırıldı.

4.2.1 Rezervuar Seviye Dalgalanmalarının Tahmin Edilmesi

Bu çalışmada MLR, AR(p), YSA modellerinin uygulama sonuçları aşağıda Çizelge 4.3' de verilmiştir. Görüldüğü gibi YSA modelleri ilk olarak normal verilere (G.Y.Y, G.G.G.S, G.S.S.) uygulanmış çok düşük korelasyon katsayısı ve yüksek hata değerleri elde edilmiştir. Bundan dolayı bu çalışmada YSA uygulanırken yukarıdaki verilerin içerisine AR(1) (zaman aralığı bir ötelenmiş) verileri ek veri olarak eklenmiş ve aşağıdaki sonuçlar elde edilmiştir

Çizelge 4.3. Yarseli Barajında kullanılan bütün modellerde test verileri için elde edilen MSE, MAE ve R parametrelerinin karşılaştırılması

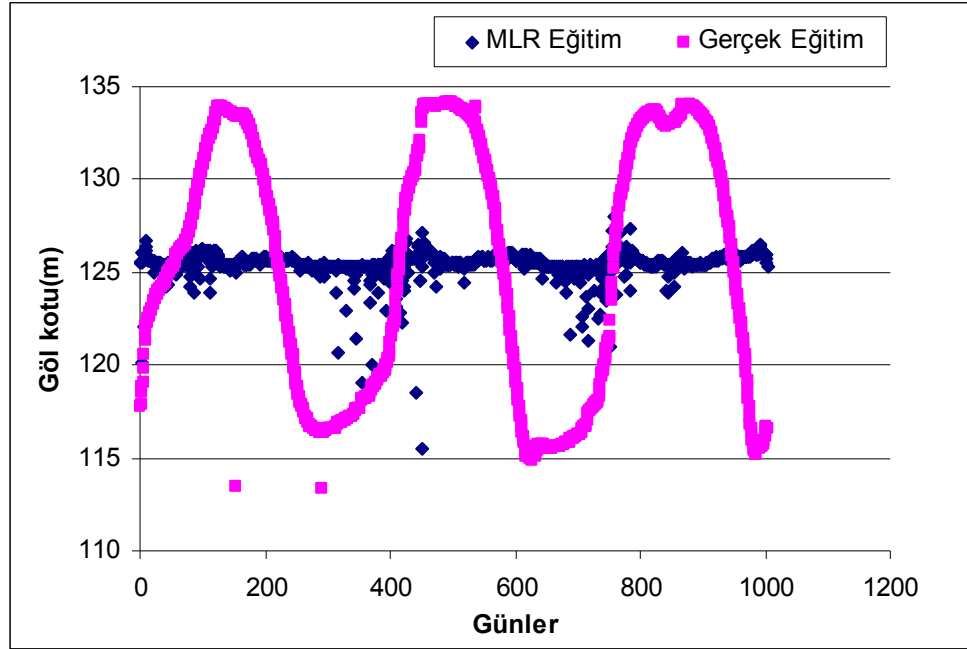
Modeller	Giriş Kombinasyonları	MSE	MAE	R
MLR	G.Y.Y, G.G.G.S, G.S.S.	61,278	6,970	0,599
YSA	G.Y.Y, G.G.G.S, G.S.S.	87,934	3,603	0,666
YSA-AR(1)	G.Y.Y, G.G.G.S, G.S.S ve G.G.K-1	0,135	0,115	0,991
AR(3)	G.G.K-3	0,002	0,393	0,997
AR(6)	G.G.K-6	0,002	0,391	0,997

MSE :Ortalama karesel hata; MAE:Mutlak Ortalama hata R; Korelasyon katsayısı

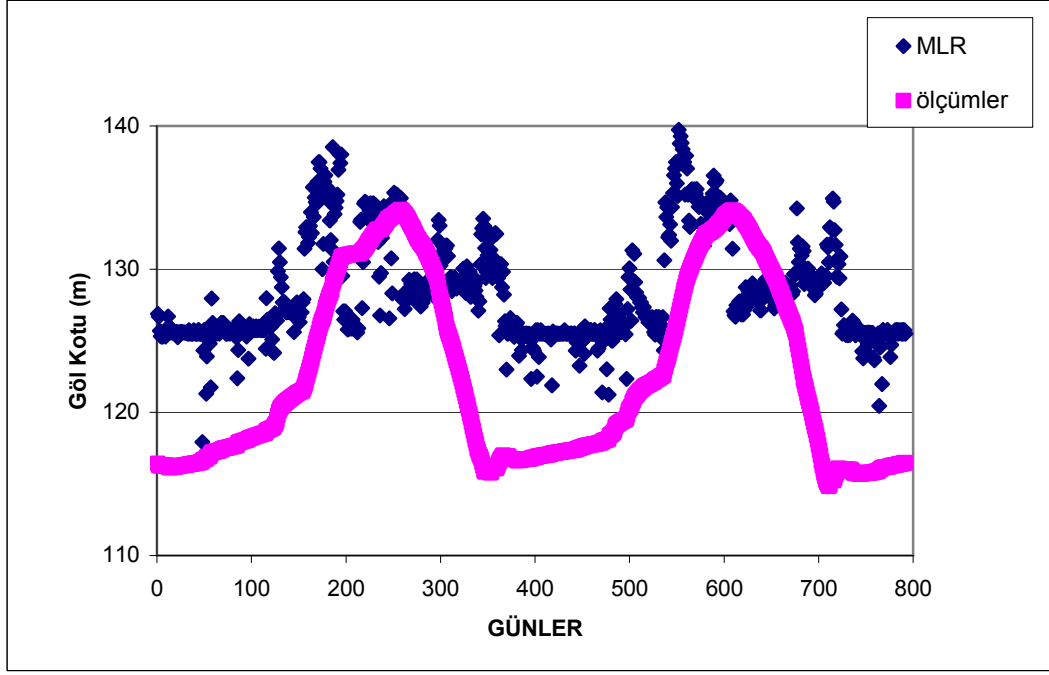
Eğitim ve test aşamaları boyunca süren MLP model simülasyonlarının hepsinde, farklı MLP yapıları denendikten sonra, ağ yapısı 5 nodu, bir gizli tabakası ve bir çıktı nöronu olan gizli bir katmanla beraber alınır. Farklı sayıda girdi kombinasyonları modellerin ne kadar işe yaradığını tespit etmek üzere gerçek gözleme dayanan veri setleri için kullanılmıştır. İşte bu yüzden, ilk önce ham veriler (girdi verileri: ortalama aylık yağış, aylık rezervuar seviye değişiklikleri, aylık gereken tahliye hacmi, Çıktı verileri: aylık rezervuar seviyesi) YSA ve MLR modelleri olarak bu çalışmada denenmiştir. Bu ham verilerin sonuçları iyi bir performans göstermemiştir. Bu sonuç girdi öğeleri arasındaki uygun olmayan olasılık dağılımıyla açıklanabilir. Çizelge 4.3 , test sürecini ve her bir kombinasyonu MSE, MAE ve Korelasyon katsayısı (R) ilişkisi açısından gösterilmiştir. Çizelge 4.3.'den görülebileceği üzere, ilk girdi kombinasyonu için MLR ve YSA modelinde en yüksek MSE (87.93-61.28 m), MAE (3.60-6.97m) ve en küçük R (0.67-0.60) elde edilmiştir.

Şekil 4.8'de eğitim sürecinde sonuç tahminleri ile ölçüm değerleri karşılaştırması görülmektedir. Şekil 4.9'da test süreci için MLR göl kotu tahminleri ve ölçüm değerleri karşılaştırılmış, Şekil 4.10'da bu ilişki saçılma diyagramı formatında verilmiştir. Şekil 4.11'de eğitim sürecinde sonuç tahminleriyle ölçüm değerleri karşılaştırması görülmektedir. Şekil 4.12'de test süreci için YSA göl kotu tahminleri ve ölçüm değerleri karşılaştırılmıştır. Şekil 4.13'de ise YSA sonuçları saçılma diyagramı formatında verilmiştir. Şekillerden de anlaşılabilceği üzere ilk girdi kombinasyonu için


hem YSA hem de MLR'nin performansının uyum göstermediği korelasyon katsayılarında açıkça görülmektedir. Diğer sonuçlardan da görülebileceği üzere model tahminleri daha dağınık ve bu da yüksek MSE, MAE ve daha düşük R değerleri vermiştir. Bu yüzden, şekillerdeki saçılma diyagramı günlük göl kotunun tahmin edilmesinde fazlasıyla bir sapmaya neden olmaktadır. Ham veriler kullanılarak oluşturulan YSA modeli rezervuar seviyesi ve diğer parametreler için zayıf bir ilişki kurabilmektedir. Fakat bir diğer taraftan, gerçekte baraj rezervuar seviyesini etkileyen parametreler arasında iyi bir korelasyon bulunmamasına rağmen, yine de yapay sinir ağı model sonuçları ham verilerde daha başarılı olmuştur ($R=0.67$).



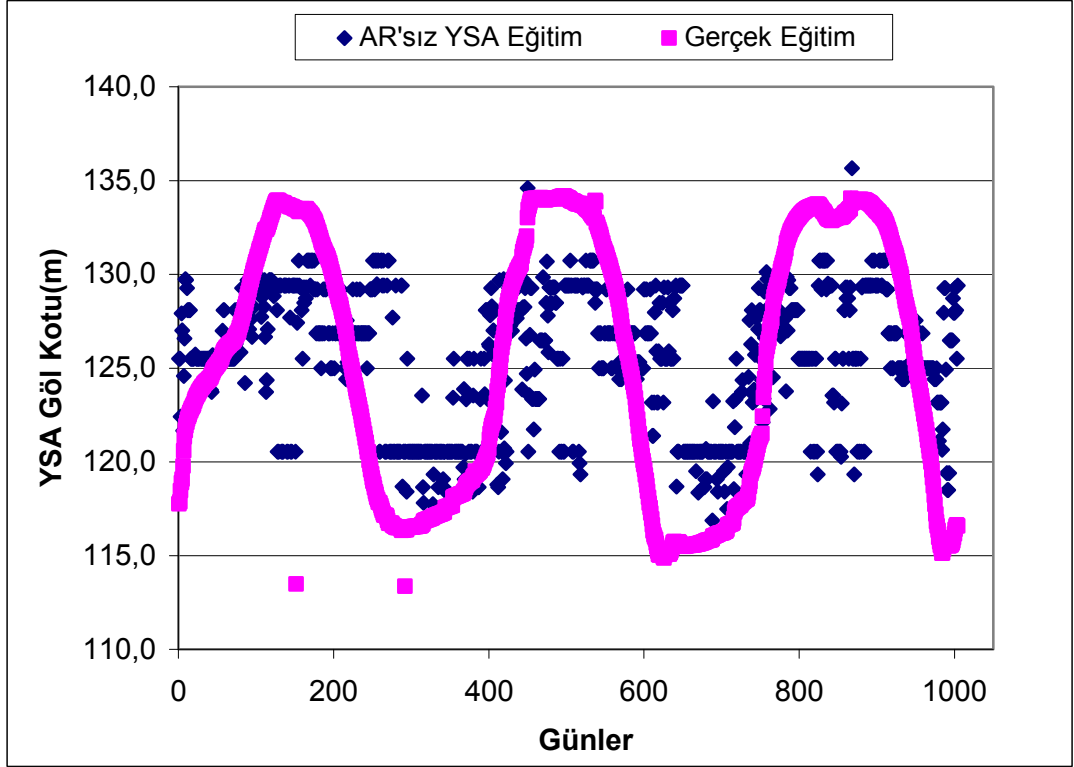
Şekil 4.8. MLR metodu ile elde edilmiş göl kotu sonuçları ile ölçüm değerlerinin karşılaştırılması



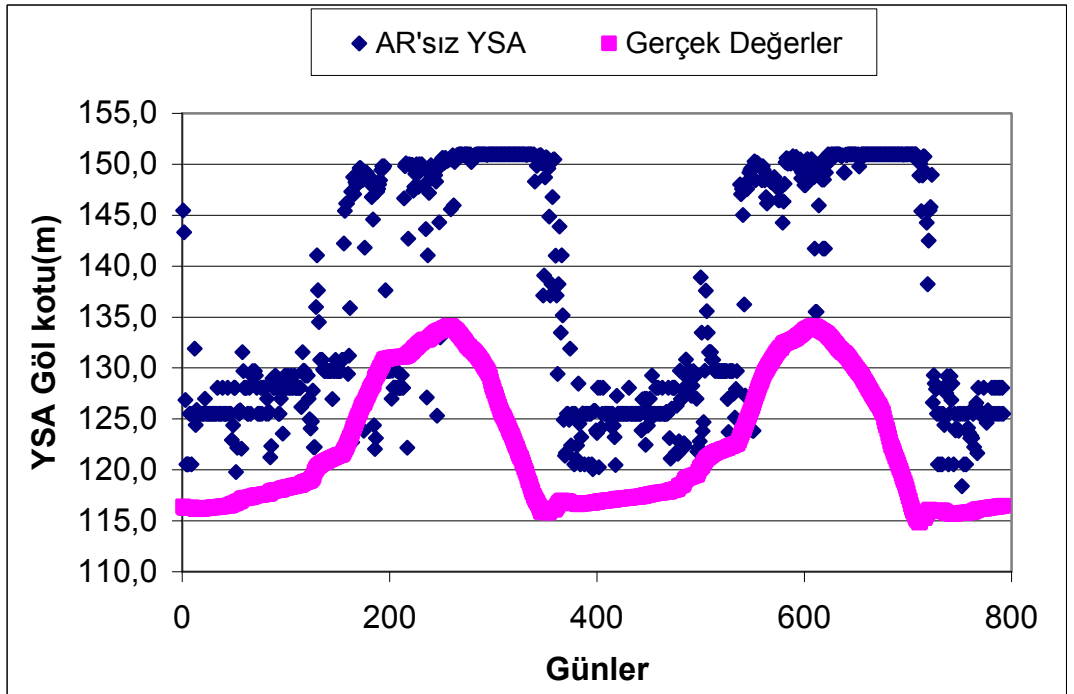
Şekil 4.9. MLR günlük göl kotu test sonuçları ile ölçüm değerlerinin karşılaştırılması



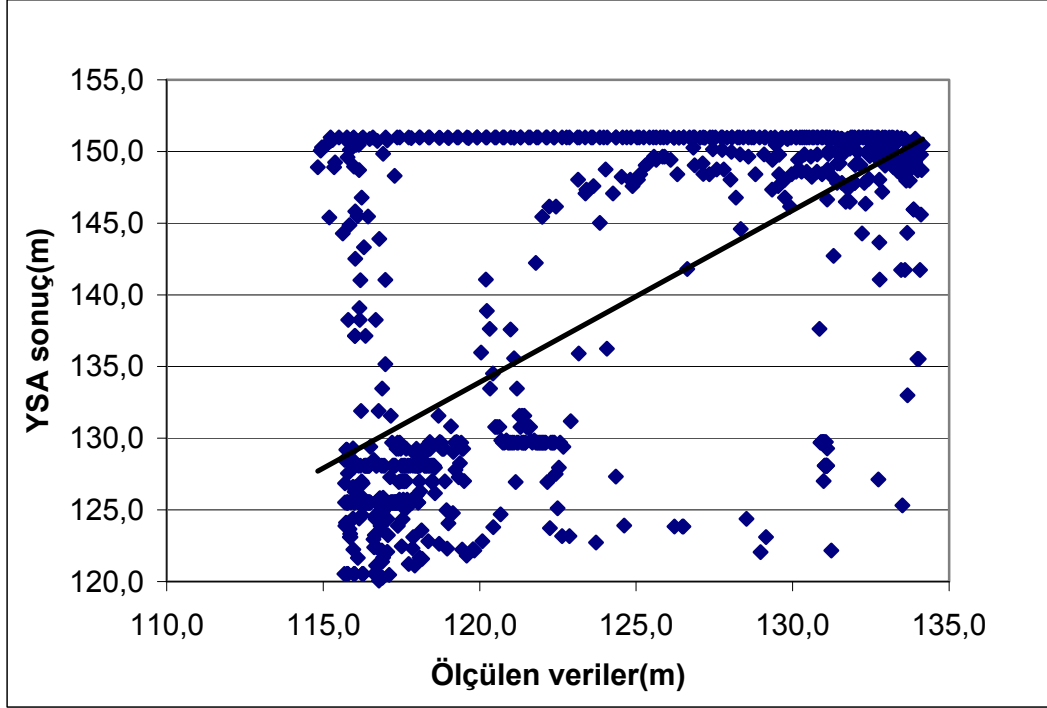
Şekil 4.10. MLR sonuçları ile ölçüm değerlerinin saçılma diyagramı



Şekil 4.11. Yapay sinir ağları modelinde günlük göl kotu eğitim sonuçları ile eğitim ölçüm değerlerinin karşılaştırılması.

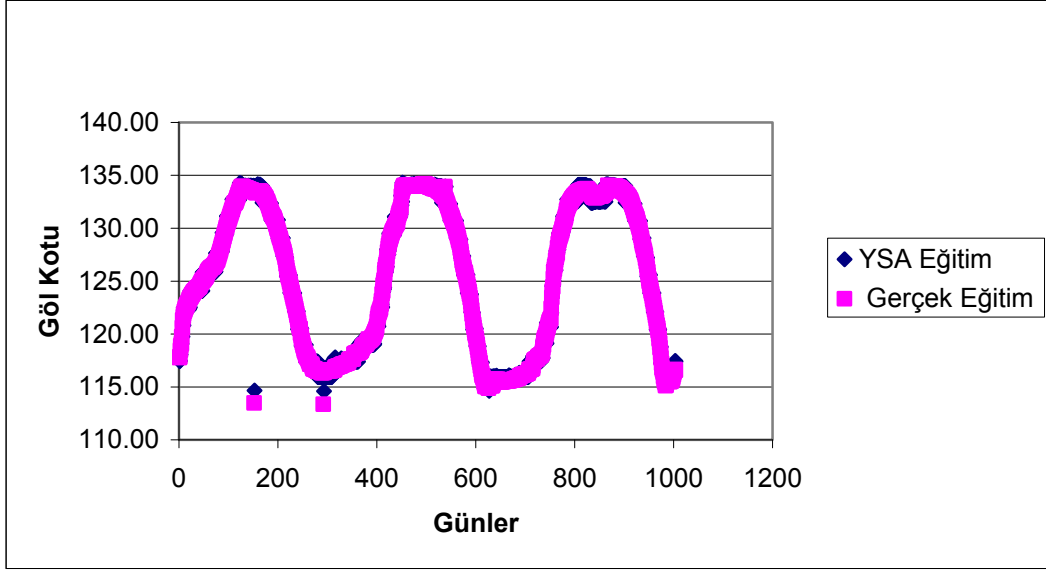


Şekil 4.12. YSA modelinde günlük göl kotu test sonuçları ile ölçüm test değerlerinin karşılaştırılması




Şekil 4.13. YSA’da günlük göl kotları ile ölçüm değerlerinin saçılma diyagramı

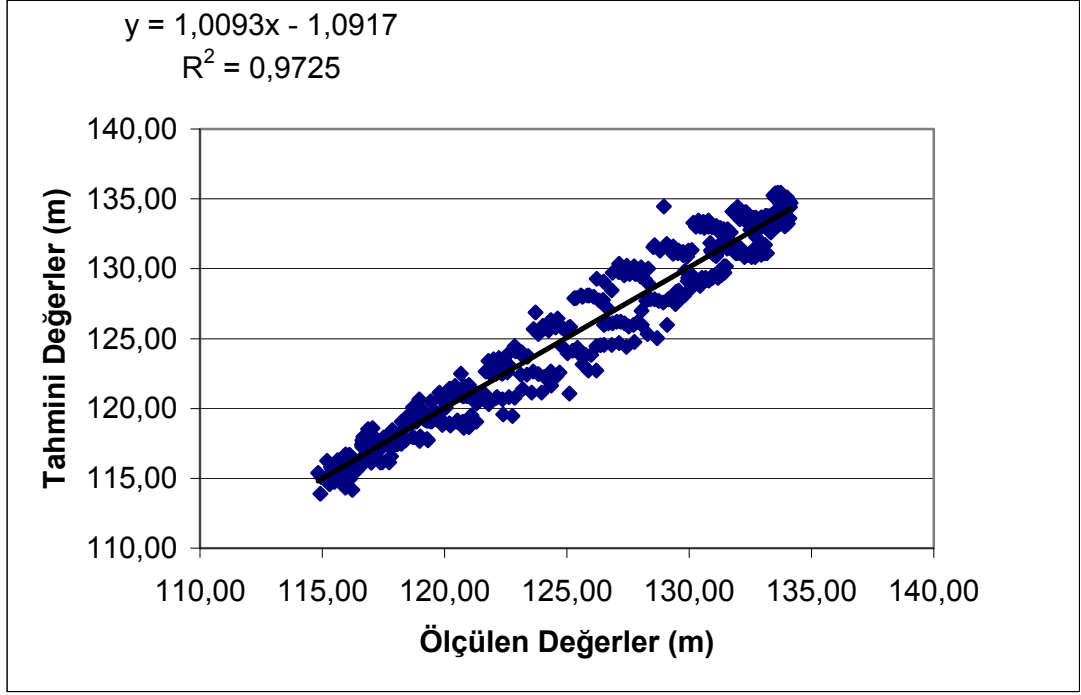
İkinci girdi kombinasyonu olarak gözlemlenmiş ham veriler ve geçmiş baraj rezervuar seviyesi (zaman, t-1) alınmıştır. İkinci girdi kombinasyonu Çizelge 4.3’de G.Y.Y :Günlük yağış yüksekliği, G.G.G.S:Günlük göle gelen su, G.S.S :Günlük su sarfiyatı , G.G.K-1 :Günlük göl kotu olarak gösterilmiştir. Yine aynı biçimde eğitim ve test aşamalarındaki simulasyonlar, dört girdili, bir gizli tabakalı ve bir çıktılı olan bir gizli katmanlı ağ yapısının iyi bir tahmin modeli olarak YSA modelinde kullanılabileceğini göstermiştir. YSA tahminleri test süreci için tanımlanmakta ve seviye eğilimi ve saçılma diyagramı formatında gözlemlenmiş baraj rezervuar seviyesiyle karşılaştırılmaktadır. Bu sonuçlar, Şekil 4.14, 4.15, 4.16, 4.17, 4.18, 4.19 ve Çizelge 4.3.’de gösterilmiştir. Şekillerden ve Çizelge 4.3.’den anlaşılabilceği üzere her iki metodun sonuçları ve saçılma diyagramı belirlenmiş ve tahmini baraj rezervuar seviyesi arasında uyumluluk tespit edilmiştir. İkinci girdi kombinasyonunda YSA metodu için, MSE (0.135) ve MAE (0.115) R (0.991) iyi sonuç vermiştir. Aşağıdaki şekillerde görüldüğü gibi, YSA model sonuçları gözlemlenmiş seviye dalgalanmalarıyla olan uyumu iyi şekilde ortaya koymuştur ($R^2=0.982$, MSE=0.135 ve MAE=0.115).



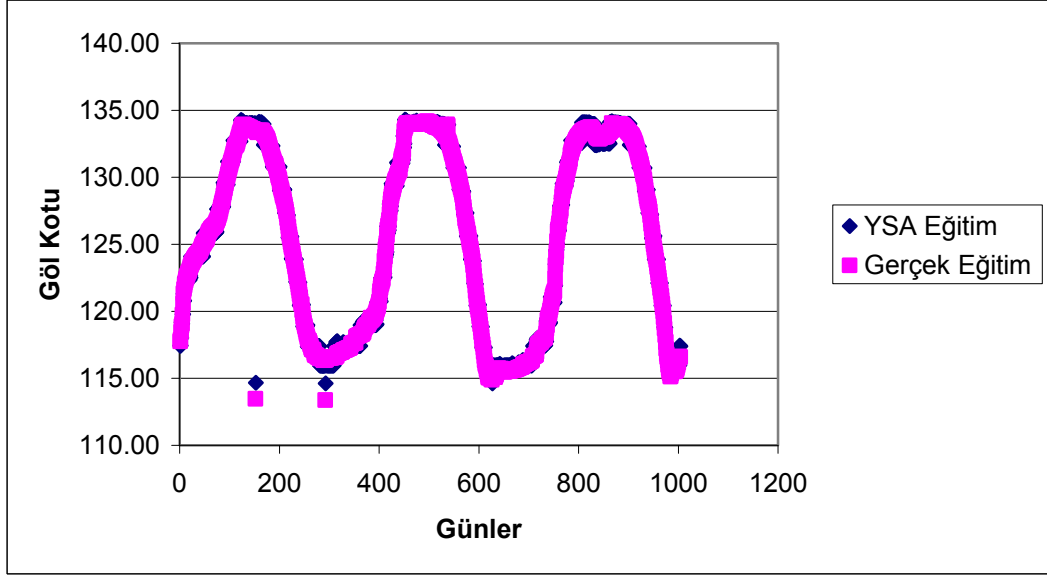
Şekil 4.14. İkinci girdi kombinasyonu ve eğitim verileri için 3 nodlu YSA modeli sonuçları.




Şekil 4.15 İkinci girdi kombinasyonu ve test verileri için 3 nodlu YSA modeli sonuçları



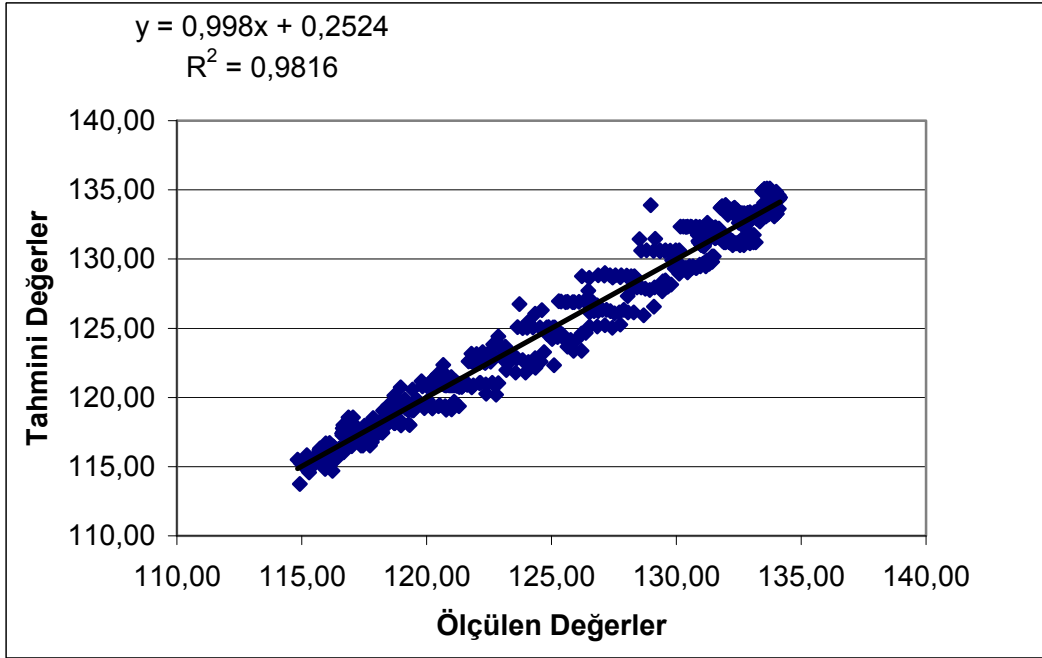
Şekil 4.16. 3 nodlu YSA test sonuçları ve ölçüm verileri sonuçları için saçılma diyagramı



Şekil 4.17. İkinci girdi kombinasyonu ve eğitim verileri için 5 nodlu YSA modeli sonuçları.



Şekil 4.18 İkinci girdi kombinasyonu ve test verileri için 5 nodlu YSA modeli sonuçları

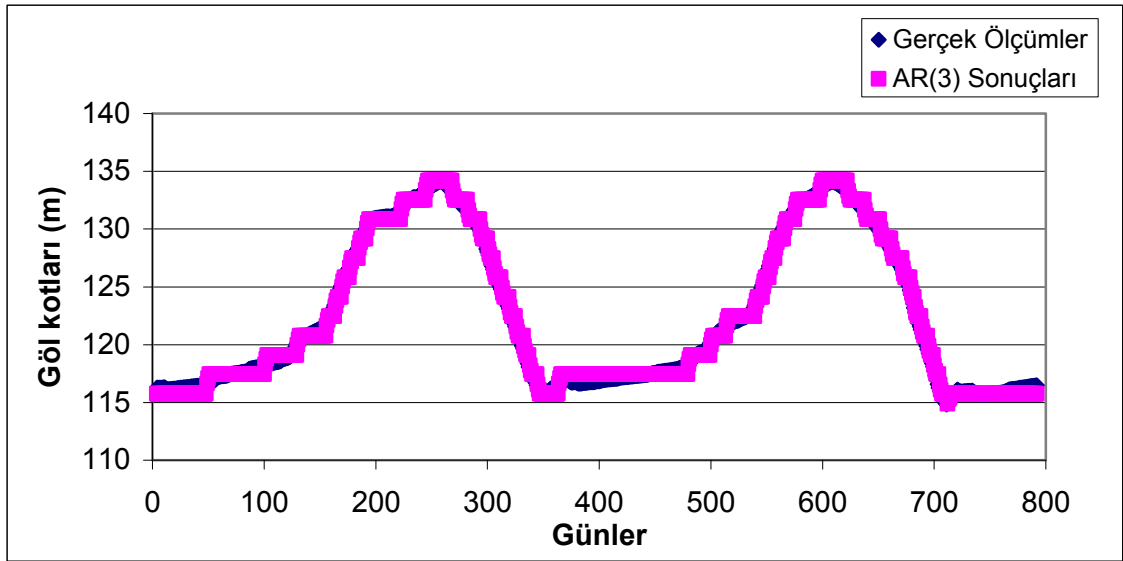


Şekil 4.19. 5 nodlu YSA test sonuçları ve ölçüm verileri sonuçları için saçılma diyagramı

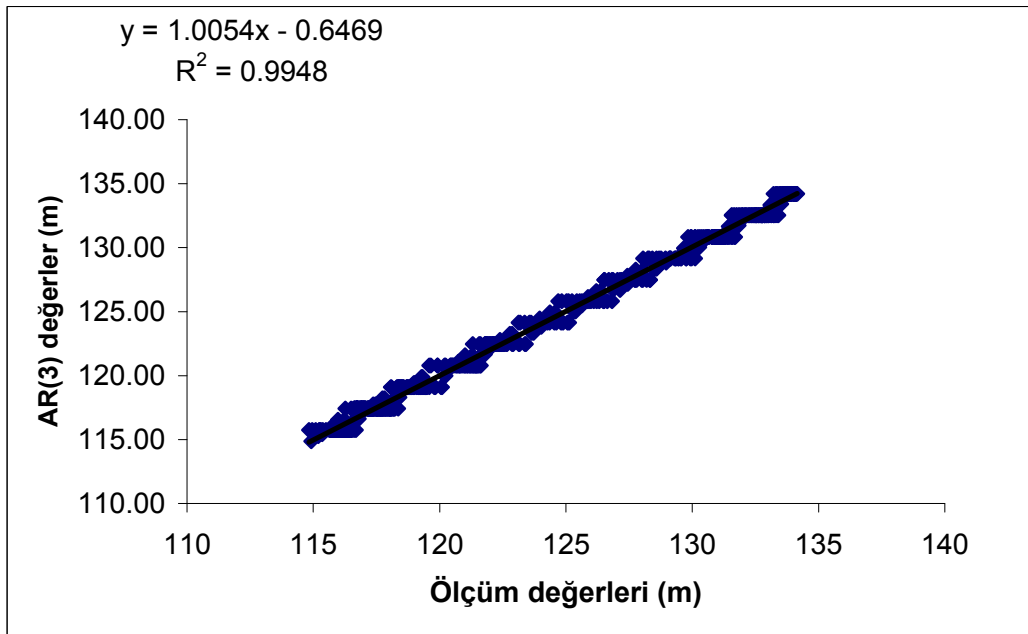
MLR ve YSA modellerine ilaveten stokastik modeller uygulanarak bu çalışmanın kapsamı genişletilmiştir. Bu çalışmada kullanılan diğer bir model ise AR(p), AR(1), AR(2) ... ve AR(6) otoregresif modelleridir ve bunların tahmin performansları göl kotu değişiminin zaman serileri için uygulanmıştır. Böylece YSA modelinde kullanılan rezervuar seviye data setleri stokastik AR(p) modeline uygulanmıştır. Girdi katmanı nodları önceki geçmiş günlük rezervuar seviyesi olarak alınmıştır. Giriş tabaka nodları olarak geriye doğru önceki altı zaman rezervuar seviye serisi ($t-1, t-2, \dots, t-6$ katı) ve t anına karşılık gelen aylık rezervuar seviye salınımda çıkış tabaka nodu veya karşılaştırma verisi olarak alınmıştır.

Bu çalışmada, böylece 6 tane, AR(1-6), AR modeli oluşturulmuş. Kullanılan modeller arasında AR(6) modelinin test aşaması için en düşük MSE (0.002), MAE (0.391m) ve en yüksek R katsayısını (0.997) verdiği görülmüştür. Bu yüzden, AR(3) ve AR(6) otoregresif modelleri bu çalışmada verilmiştir. Test aşaması için otoregresif model sonuç tahminleri, seviye eğilimi ve saçılma diyagramı formatındaki gözlemlenmiş rezervuar seviyesi ile karşılaştırılmıştır.

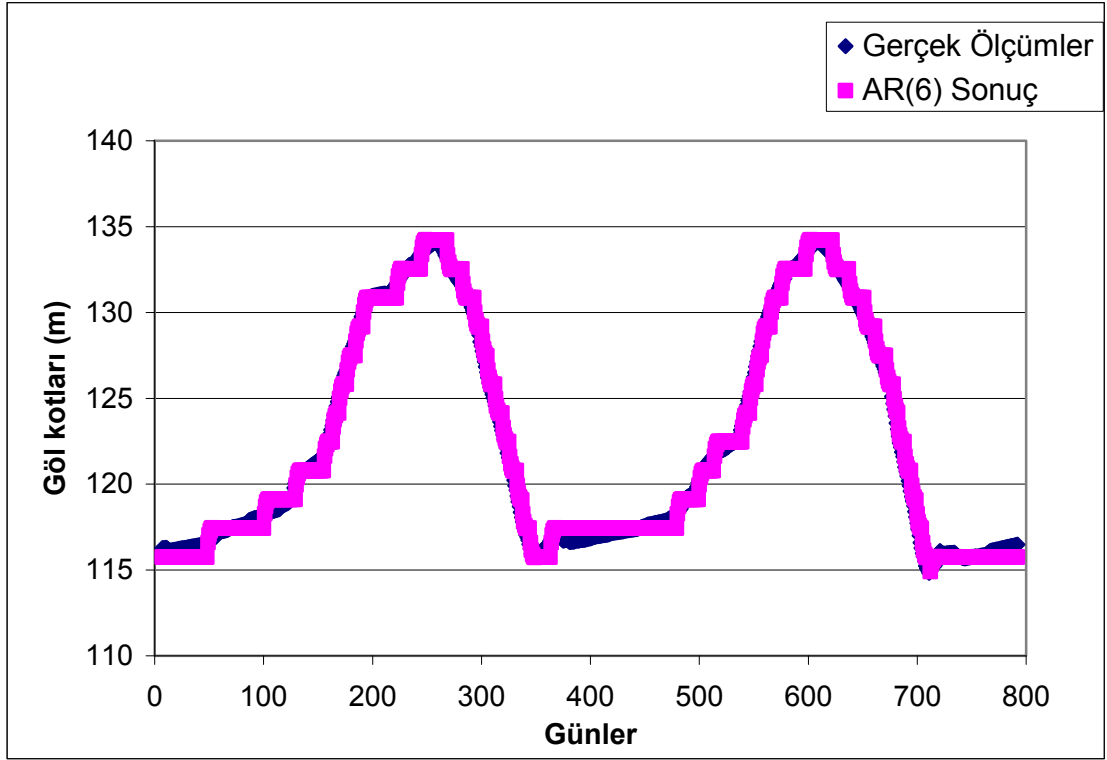
AR(3) ve AR(6) modellerinin performansları Şekil 4.20, 4.21, 4.22 ve 4.23'te gösterilmiştir. Bu şekillerden görülebileceği üzere otoregresif modellerin saçılma diyagramı, gözlemlenmiş ve tahmini baraj rezervuar seviyesi arasında uyumluluk göstermiştir. Bütün veriler ve olayın fiziği dikkate alındığında, YSA modeli güzel ve uyumlu sonuçlar vermektedir. Fakat sadece hazne seviye salınımları dikkate alındığında otoregresif modellerin YSA modelinden çok azda olsa daha iyi sonuç verdiği görülmüştür. Fakat burada dikkat edilmesi gereken önemli husus, YSA modelinin çok değişkenli bir yapıya sahip olmasına rağmen çok iyi sonuçlar elde edilmesidir.



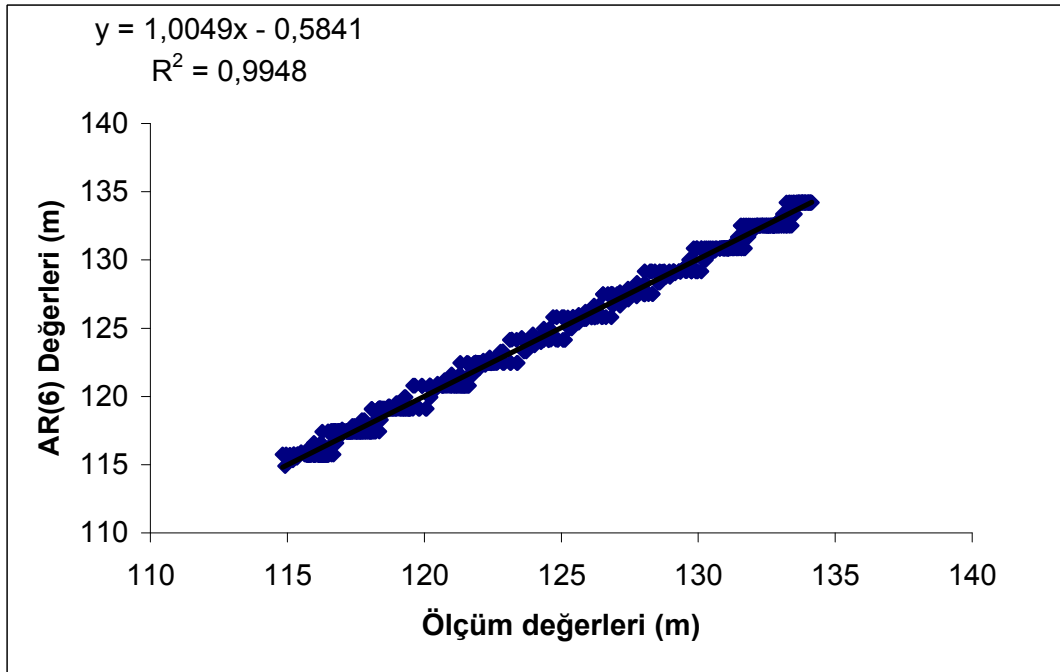
Şekil 4.20. Otoresif modelde günlük göl kotlarının AR(3) ile ölçüm değerlerinin karşılaştırılması



Şekil 4.21. AR (3) Değerleri ile ölçüm değerlerinin saçılma diyagramı



Şekil 4.22. Otoresif modelde günlük göl kotlarının AR(6) ile ölçüm değerlerinin karşılaştırılması



Şekil 4.23. AR (6) değerleri ile ölçüm değerlerinin saçılma diyagramı

5. SONUÇ VE ÖNERİLER

Bu çalışmada Yarseli barajı rezervuar seviyesindeki dalgalanmalar Yapay Sinir Ağları (YSA) ile tahmin edilmektedir. Çok katmanlı YSA modeli tahminleri, baraj rezervuar seviyesinin ham ölçümleri ve geleneksel istatistiksel ve stokastik modeller ile karşılaştırılmıştır. Bu sonuçlara dayanarak, bu çalışmanın su kaynakları literatürüne getirdiği yenilikler aşağıdaki gibidir:

Bu çalışma, ortalama aylık yağış, rezervuar seviye değişiklikleri, ağa girilen aylık tahliye toplam hacmi gibi bir çok parametre kullanarak baraj rezervuar seviye dalgalanmalarının tahmin edilmesi için su kaynakları literatüründeki ilk YSA çalışmasıdır. Bütün bu uygulamalar sunulan YSA modeli, geleneksel modellerle karşılaştırıldığında doğru tahminlerde bulunmuştur.

Ampirik bağları anlatmak için sıklıkla kullanılan çok değişkenli lineerli regresyon modeli problemin çözümünde oldukça doğru sonuçlar vermiştir. Bu metod, bazı veri kombinasyonlarında sağlıklı tahminler ve rezervuar seviye eğilimleri için küçük MSE, MAE değerleri sağlayabilmiştir. Yine de, YSA'nin gösterdiği performans MLR modelinden daha iyi sonuç vermiştir.

Otoregresif AR(p), ikinci girdi kombinasyonu için YSA model sonuçları ile karşılaştırıldığında birbirleri ile uyumlu sonuçlar vermiştir. AR(6) modeli en düşük MSE ve en yüksek R katsayısını sağlamıştır. Fakat sadece hazne seviye salınımları dikkate alındığında AR(6) modelinin YSA modelinden çok azda olsa daha iyi sonuç verdiği görülmüştür. Fakat burada dikkat edilmesi gereken önemli husus, YSA modelinin çok değişkenli bir yapıya sahip olmasına rağmen çok iyi sonuçlar elde edilmesidir. Bütün veriler ve olayın fiziği dikkate alındığında YSA modeli gerçeğe daha uygundur.

YSA, baraj rezervuarında meydana gelen ihtiyaç duyulan su planlanmasındaki değişiklikler gibi değişen girdi koşullarına doğru bir şekilde adapte olmaktadır. Rezervuar seviyelerinin öngörülmesi konusunda YSA'nin geleneksel metotlardan daha avantajlı olmasının sebebi YSA yapısının problemin non-lineer dinamiklerini ve tüm data setlerini dahil etmesi olarak açıklanabilir. Bu oldukça önemlidir, çünkü rezervuar işletim yönetimi çalışmalarıyla zaman dizisindeki benzer ani değişiklikler gözlemlenebilir.

Belirli bir bölge için bir YSA modeli geliştirildikten sonra, bu model su kaynakları yönetimi çalışmalarında oldukça faydalı olabilir. Aylık rezervuar seviye tahminleri periyodik su kaynakları stratejilerinin belirlenmesinde, hidroelektrik enerji ölçümlerinde ve taşkın yönetimi araştırmalarında oldukça bilgilendirici olabilir. Sonuç olarak, elde edilen sonuçlar YSA' nin baraj rezervuar seviyesi tahminlerinde ve dolayısı ile ham işletme çalışmalarında daha doğru bilgiler sağlayabilecek faydalı bir alternatif model olduğunu göstermektedir.

KAYNAKLAR

- ASCE Task Committee, 2000a. **Artificial neural networks in Hydrology I.** Journal of Hydrologic Engineering, ASCE 5 (2), 115–123.
- ASCE Task Committee, 2000b. **Artificial neural networks in hydrology II.** Journal of Hydrologic Engineering, ASCE 5 (2), 124–132.
- Bayazıt, M., İTÜ, 1996. **İnşaat Mühendisliğinde Olasılık Yöntemleri.**
- Bayazıt, M., and Oğuz, B., 2005. **Mühendisler için istatistik.**
- Campolo, M., Andreussi, P., Soldati, A., 1999. **River flood forecasting with a neural network model.** Water Resour. Res. 35(4), 1191-1197.
- Cigizoglu, H.K., 2003a. **Incorporation of ARMA models into flow forecasting by artificial neural networks.** Environmetrics 14 (4), 417–427.
- Cigizoglu, H.K., 2003b. **Estimation, forecasting and extrapolation of flow data by artificial neural networks.** Hydrological Sciences Journal 48 (3), 349–361.
- Cigizoglu, H.K., 2004a. **Estimation and forecasting of daily suspended sediment data by multi layer perceptrons.** Advances in Water Resources 27, 185–195.
- Cigizoglu, H.K., 2004b. **Discussion of performance of neural networks in daily streamflow forecasting.** In: Brikundavyi, S., Labib, R., Trung, H.T., Rousselle, J. (Eds.), ASCE Journal of Hydrologic Engineering, 9, pp. 556–557.
- Cigizoglu, H.K., and Alp, M., 2004. **Rainfall-runoff modelling using three neural network methods, artificial intelligence and soft computing-** ICAISC 2004. Lecture Notes in Artificial Intelligence 3070, 166–171.
- Cigizoglu, H.K., and Kisi, O., 2005. **Flow prediction by three back propagation techniques using k-fold partitioning of neural network training data.** Nordic Hydrology. 36(1) 1–16.
- Cigizoglu, H.K., and Kisi, O., 2006. **Methods to improve the neural network performance in suspended sediment estimation.** Journal of Hydrology 317 (2006) 221–238.
- Ciğizoğlu, H.K., 2004. **İTÜ ders notları**
- Dawson, C. W., and Wilby, R., 1998. **An artificial neural network approach to rainfall-runoff modeling.** Hydrological Sci., 43(1), 47–66.
- Fernando, D. A. K., and Jayawardena, A. W., 1998. **Runoff forecasting using RBF networks with OLS algorithm.** J. Hydrologic Engrg., ASCE, 3(3), 203–209.
- Halff, A. H., Halff, H. M., and Azmoodeh, M., 1993. **Predicting runoff from rainfall using neural networks.** Proc., Engrg. Hydrol., ASCE, New York, 760–765.
- Hsu, K., Gupta, H. V., and Sorooshian, S., 1995. **Artificial neural network modeling of the rainfall-runoff process.** Water Resour. Res., 31(10), 2517–2530.
- Imrie, C.E., Durucan, S., Kore, A., 2000. **River flow prediction using artificial neural networks: generalization beyond the calibration range.** J. Hydrol. 233, 138-153.

- Jain, S. K., Das, D., and Srivastava, D. K., 1999, **Application of YSA for reservoir inflow prediction and operation**. *J. Water Resour. Plan. Manage.* ASCE 125(5), 263–271.
- Jain A., Sudheer K.P., and Srinivasulu S., 2004. **Identification of physical processes inherent in artificial neural network rainfall runoff models**. *Hydrological Processes* 18 (3): 571-581.
- Karunanithi, N., Grenney, W. J., Whitley, D., and Bovee, K., 1994. **Neural networks for river flow prediction**. *J. Comp. in Civ. Engrg.*, ASCE, 8(2), 201–220.
- Kisi, Ö., Cengiz, M. T., and Üneş, F., 2004. **Artificial Neural networks for Lake Level Modeling. Conference on Water Observation and Information System for Decision Support (BALWOIS)**, 25-29 May, p.270, Ohrid, Macedonia.
- Kisi, O., 2004. **River flow modeling using artificial neural networks**. *ASCE Journal of Hydrologic Engineering* 9 (1), 60–63.
- Kisi, O., 2004, **Multi-layer perceptrons with Levenberg-Marquardt training algorithm for suspended sediment concentration prediction and estimation**. *Hydrological Sciences–Journal–des Sciences Hydrologiques*, 49(6).
- Kisi, O., 2005, **Suspended sediment estimation using neuro-fuzzy and neural network approaches**. *Hydrological Sciences–Journal–des Sciences Hydrologiques*, 50(4) .
- Kumar, M., Raghuwanshi, N. S., Singh, R., Wallender, W. W., Pruitt W. O., 2002, **Estimating Evapotranspiration using Artificial Neural Network**. *Journal of Irrigation and Drainage Engineering*, 224.
- Kunduz, B., and Üneş, F., 2006. **Reservoir Level Prediction for Yarseli Dam Using Artificial Neural Networks Model**. *National Clean Energy Symposium*, 25-27 May, p.614, Isparta, Turkey.
- MacKay, D. J. C., **Bayesian interpolation**, *Neural Computation*, vol. 4, no. 3, pp. 415-447, 1992.
- Minns, A. W., and Hall, M. J., 1996. **Artificial neural networks as rainfall-runoff models**. *Hydrologic Sci.*, 41(3), 1996.
- Ramirez, M.C.V., Velho, H.F.C, and Ferreira, N.J., 2005, **Artificial Neural Network Technique for Rainfall Forecasting Applied to the Sao Paulo Region**, *Journal Of Hydrology*, 301, 146-162.
- Rajurkar, M.P., Kothyari, U.C, and Chaube, U.J., 2004, **Modeling Daily Rainfall-Runoff Relationship with Artificial Neural Network**, *Journal Of Hydrology*, 285, 96-113.
- Ripple, W. , 1883, **The Capacity of Storage for water supply**, *Proc., Institution of Civil Engineers*, 71, 270.
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J., 1986. **Learning internal representations by error propagation**. *Parallel distributed procesing*, Vol. 1, MIT Press, Cambridge, Mass., 318–362.

- Solomatine, D. P., and Dulal, K. N., 2003. **Model trees as an alternative to neural networks in rainfall–runoff modeling**, *Hydrol. Sci. J.* 48(3), 399–411.
- Shamseldin, A. Y., 1997. **Application of a neural network technique to rainfall–runoff modeling**. *J. Hydrol.*, Amsterdam, 199, 272–294.
- Smith, J., and Eli, R. N., 1995. **Neural-network models of rainfall-runoff process**. *J. Water Resour. Plng. and Mgmt.*, ASCE, 121(6), 499–508.
- Sudheer K.P., 2005. **Knowledge extraction from trained neural network river flow models**, *Journal of Hydrologic Engineering* 10 (4): 264-269.
- Sudheer, K.P., and Jain A., 2004. **Explaining the internal behaviour of artificial neural network river flow models**. *Hydrological Processes* 18 (4): 833-844.
- Sudler, C. E., 1927, **Storage Required for Regulation of Streamflow**, *Trans.*, ASCE, 91, No. 622.
- Xiong, L., O' Connor, K.M., Goswami, M., 2001. **Application of the artificial neural network in flood forecasting on a Karstic catchment**. *Proc. XXIX IAHR Congr.*, China, 29-35
- Zealand, C., Burn, D.H., Simonovic, S.P., 1999. **Short term streamflow forecasting using artificial neural Networks**. *J. Hydrol.* 214, 32-48.
- Zhang, B., Govindaraju, R.S., 2000. **Prediction of watershed runoff using Bayesian concepts and modular neural Networks**. *Water Resour. Res.* 36 (3), 753-762.
- Tokar, A. S., and Johnson, P. A., 1999. **Rainfall-runoff modeling using artificial neural networks**. *J. Hydrologic Engrg.*, ASCE, 4(3), 232– 239.
- Usul, N., 2005 **Engineering Hydrology**, METU pres, Turkey.
- Üneş, F., 2006. **Precipitation and Reservoir Volume Relationship Prediction with Artificial Neural Networks Model**. *National Clean Energy Symposium*, 25-27 May, p.622, Isparta, Turkey.
- Wilby, R. L., Abrahart, R. J., and Dawson, C. W., 2003. **Detection of conceptual model rainfall–runoff processes inside an artificial neural network**. *Hydrol. Sci. J.* 48(2), 163–181.

TEŞEKKÜR

Tez çalışmamın her aşamasında, düşüncelerinden ve bilgilerinden istifade ettiğim bunun yanında ilgi ve yardımlarını aldığım, danışman hocam Sayın Yrd. Doç. Dr. Fatih ÜNEŞ' e en içten teşekkürlerimi sunarım.

Bu yüksek lisans çalışmasının ders ve tez aşamasında, değerli görüş, katkı ve bilgilerini esirgemeyen Doç. Dr. A. Osman ATAHAN, Yrd. Doç. Dr. U. Korkut SEVİM, Yrd. Doç. Dr. Murat BİKÇE' ye ve tüm inşaat mühendisliği bölümü öğretim üyelerine en içten teşekkürlerimi sunarım. Tez aşamasında bana destek olan İnş. Yük. Müh. Bora KUNDUZ, İnş. Müh. Hakan VARÇİN ve Şengül KÖR'e yardım ve katkılarından dolayı teşekkür ederim.

Ayrıca çalışmalarım sırasında sabırla bana destek veren aileme sonsuz teşekkürler ederim.

ÖZGEÇMİŞ

1970 yılında Antakya / HATAY’ da doğdum. İlkokulu İnönü ilkokulunda, ortaokulu Merkez Lisesinde Antakya’da okudum ve lise öğrenimini Adana Erkek Lisesinde 1987 yılında tamamladım. 1987–1991 yılları arasında İstanbul Teknik Üniversitesi İnşaat Fakültesi İnşaat Mühendisliği bölümünde okudum. 1991 yılının yaz döneminde iyi derece ile mezun oldum. 1991 yılında Devlet Su İşleri VI. Bölge Müdürlüğü 67. Şube emrinde mühendis olarak çalışmaya başladım. 1993–1995 yıllarında VI. Bölge Müdürlüğü Proje İnşaat Şube Müdürlüğü bünyesinde çalıştım. 1995–1996 DSİ 24.Bölge Müdürlüğü Proje İnşaat Şube Müdürlüğünde görev yaptım. 1997 yılından itibaren halen DSİ VI. Bölge Müdürlüğü bünyesinde inşaat mühendisi olarak göreve devam etmekteyim. Aynı zamanda 2005 yılının güz döneminde Hatay Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalında yüksek lisansa başladım.

Çizelge Ek.1. Yarseli Barajında Kullanılan Tüm Verilerin Aylık Ortalama Değerleri

Yıl	Ay	Aylık Ortalama Göl Kotu (m)	Aylık Ortalama Yağış Yüksekliği (mm)	Aylık Ortalama Göle Gelen Su ($\times 10^3 \text{ m}^3$)	Aylık Ortalama Su Sarfıyatı ($\times 10^3 \text{ m}^3$)
2002	Ocak	122,07	5,45	395,32	0,00
	Şubat	124,88	1,88	164,04	0,00
	Mart	127,05	2,73	277,29	0,00
	Nisan	131,35	2,30	491,57	0,00
	Mayıs	133,70	0,12	101,39	60,13
	Haziran	132,52	0,11	53,83	211,77
	Temmuz	130,13	0,00	0,00	469,81
	Ağustos	124,15	0,00	0,00	548,74
	Eylül	118,14	0,13	0,00	222,87
	Ekim	116,40	0,40	9,32	17,65
	Kasım	116,84	2,84	31,40	0,00
	Aralık	117,73	4,19	55,42	0,00
2003	Ocak	119,19	4,90	93,58	0,00
	Şubat	123,88	8,56	406,39	0,00
	Mart	130,89	6,67	437,83	14,84
	Nisan	134,03	1,32	262,83	259,50
	Mayıs	134,00	0,00	61,39	95,32
	Haziran	133,19	0,32	24,20	269,13
	Temmuz	129,27	0,00	0,00	571,52
	Ağustos	121,93	0,00	1,52	571,61
	Eylül	115,51	0,14	132,47	226,73
	Ekim	115,59	0,44	28,61	33,03
	Kasım	115,88	2,78	29,40	0,00
	Aralık	117,03	5,74	86,32	0,00
2004	Ocak	121,28	10,06	590,71	0,00
	Şubat	130,04	4,80	641,03	0,00
	Mart	133,26	0,01	157,68	0,00
	Nisan	133,22	1,27	55,57	137,10
	Mayıs	133,60	2,97	520,74	409,04
	Haziran	133,48	0,00	11,90	167,02
	Temmuz	130,30	0,00	0,00	559,35
	Ağustos	122,93	0,00	0,00	658,28
	Eylül	115,97	0,00	264,17	347,50
	Ekim	116,25	0,12	14,84	28,97
	Kasım	116,65	4,96	46,63	0,00
	Aralık	117,61	1,05	38,23	0,00

Çizelge A.1. Yarseli Barajında Kullanılan Tüm Verilerin Aylık Ortalama Değerleri (devam)

Yıl	Ay	Aylık Ortalama Göl Kotu (m)	Aylık Ortalama Yağış Yüksekliği (mm)	Aylık Ortalama Göle Gelen Su ($\times 10^3 \text{ m}^3$)	Aylık Ortalama Su Sarfiyatı ($\times 10^3 \text{ m}^3$)
2005	Ocak	118,44	1,33	45,13	0,00
	Şubat	120,61	2,93	164,31	0,00
	Mart	124,73	1,67	538,26	0,00
	Nisan	130,38	2,01	308,53	0,47
	Mayıs	132,26	0,73	427,16	141,00
	Haziran	133,56	0,21	199,00	324,33
	Temmuz	130,06	0,00	0,00	606,65
	Ağustos	122,50	0,00	0,00	565,61
	Eylül	116,49	0,06	192,30	271,73
	Ekim	116,76	2,54	20,68	30,29
	Kasım	117,03	2,25	21,27	0,00
	Aralık	117,44	1,73	24,03	0,00
2006	Ocak	118,21	5,50	76,00	0,00
	Şubat	120,60	3,53	181,36	0,00
	Mart	123,01	3,12	278,68	0,00
	Nisan	129,51	1,19	674,73	0,00
	Mayıs	133,18	0,00	456,84	213,06
	Haziran	132,89	0,00	5,17	342,30
	Temmuz	129,15	0,00	0,00	471,52
	Ağustos	122,06	0,00	0,00	630,90
	Eylül	115,78	1,03	157,10	257,33
	Ekim	115,80	1,96	14,23	20,13
	Kasım	116,23	3,05	30,40	0,00

