



MUSTAFA KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

**YAPAY SİNİR AĞLARI YAKLAŞIMI İLE
TAHTAKÖPRÜ BARAJINDAKİ AYLIK
BUHARLAŞMA MİKTARININ TAHMİNİ**

KAZIM KADİR DİNDAR

YÜKSEK LİSANS TEZİ

Antakya/HATAY

ŞUBAT-2010



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

**YAPAY SİNİR AĞLARI YAKLAŞIMI İLE
TAHTAKÖPRÜ BARAJINDAKİ AYLIK
BUHARLAŞMA MİKTARININ TAHMİNİ**

KAZIM KADİR DİNDAR

YÜKSEK LİSANS TEZİ

Antakya/HATAY

ŞUBAT-2010

MUSTAFA KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SİNİR AĞLARI YAKLAŞIMI İLE
TAHTAKÖPRÜ BARAJINDAKİ AYLIK
BUHARLAŞMA MİKTARININ TAHMİNİ

KAZIM KADİR DİNDAR
YÜKSEK LİSANS TEZİ

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

Yrd.Doç.Dr.Fatih ÜNEŞ'in danışmanlığında hazırlanan bu tez 05/02/2010 tarihinde aşağıdaki jüri üyeleri tarafından oybirliği ile kabul edilmiştir.

Yrd.Doç.Dr. Fatih ÜNEŞ
Başkan

Doç.Dr. Ali KOÇ
Üye

Yrd.Doç.Dr. Selahattin KOCAMAN
Üye

Bu tez Enstitümüz İnşaat Mühendisliği Anabilim Dalında hazırlanmıştır.

Kod No :

Doç. Dr. Erdal YILMAZ
Enstitü Müdür V.

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

	Sayfa
ÖZET.....	II
ABSTRACT.....	III
SİMGELER VE KISALTMALAR DİZİNİ.....	IV
ÇİZELGELER DİZİNİ.....	V
ŞEKİLLER DİZİNİ.....	VI
1.GİRİŞ.....	1
2.ÖNCEKİ ÇALIŞMALAR.....	3
3. MATERYAL VE YÖNTEM.....	5
3.1. Materyal.....	5
3.1.1. Klasik Yöntemler.....	5
3.1.1.1. Çok Değişkenli Doğrusal Regresyon Analizi.....	6
3.1.1.1.1. Altı Bağımsız Değişkenli Doğrusal Regresyon Analizi.....	8
3.1.1.1.2. Determinasyon Katsayısı.....	8
3.1.1.2. Oto regresif Model(AR(p)).....	8
3.2. Yöntem.....	10
3.2.1. Yapay Sinir Ağları (YSA) Modeli.....	10
3.2.1.1. Biyolojik Sinir Ağları.....	11
3.2.1.1.1 Biyolojik ve Yapay Sinir Ağlarının Temel Farkları.....	16
3.2.1.2. Yapay Sinir Ağları ve İstatistiksel Yöntemler.....	17
4. ARAŞTIRMA BULGULARI VE TARTIŞMA.....	20
4.1. Uygulama Alanı ve Tanıtılması.....	20
4.2. Tahtaköprü Barajı Uygulamaları.....	22
4.2.1. Aylık Buharlaştırma Miktarının Tahmin Edilmesi.....	23
5. SONUÇ VE ÖNERİLER.....	33
KAYNAKLAR.....	34
TEŞEKKÜR.....	37
ÖZGEÇMİŞ.....	38
EKLER.....	39
EK 1. Tahtaköprü barajında kullanılan tüm verilerin aylık ortalama değerleri.....	39

ÖZET

**YAPAY SİNİR AĞLARI YAKLAŞIMI İLE
TAHTAKÖPRÜ BARAJINDAKİ AYLIK
BUHARLAŞMA MİKTARININ TAHMİNİ**

Buharlaşma miktarı, içme, sulama ve kullanma suyunun baraj rezervuarından karşılanması bakımından önem arz etmektedir. Barajlar su tutan yapılar olduğu için buharlaşma barajdaki su miktarının belirlenmesinde etkili olmaktadır. Baraj gölünde meydana gelen buharlaşma miktarı; mevcut enerjiye, kütle ve enerji transfer mekanizmasına, barajın derinliğine ve göl yüzey alanına bağlıdır. Buharlaşma baraj haznesinde büyük ölçüde su kayıplarına neden olmaktadır. Barajlardan içme, sulama ve kullanma suyu ihtiyaçlarının karşılandığı düşünüldüğünde, buharlaşma miktarının doğru belirlenebilmesi oldukça önem arz etmektedir. Bu çalışmada, Tahtaköprü barajındaki aylık buharlaşma miktarının tahmini, Yapay Sinir Ağları (YSA) metodu kullanılarak araştırılmıştır.

YSA'nın, baraj aylık buharlaşma miktarının belirlenmesinde uygulanabilmesi için, geçmiş yıllarda Tahtaköprü barajında meydana gelen aylık buharlaşma miktarları veri olarak değerlendirilmiştir.

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

Elde edilen YSA sonuçları, geçmişte çok kullanılan, çoklu-lineer regresyon (MLR) ve otoregresif (AR(p)) model sonuçları ile karşılaştırılmıştır. Modeller, grafik ve istatistiksel sonuçlarla analiz edilmiştir. Bu sonuçlara göre; baraj haznesi aylık buharlaşma miktarının tahmininde YSA model çözüm sonuçları, geçmişte kullanılan klasik yöntemlerle kıyaslandığında daha iyi bir yaklaşım göstermiştir.

2010, 42 sayfa

Anahtar Kelimeler: Yapay Sinir Ağları (YSA), Aylık Buharlaşma, Çoklu-Lineer Regresyon (MLR), Otoregresif Model (AR(p)), Tahtaköprü Barajı

ABSTRACT

PREDICTION OF MONTHLY EVAPORATION AMOUNT IN TAHTAKÖPRÜ DAM USING ARTIFICIAL NEURAL NETWORK

Evaporation is significant in terms of providing water for drinking, irrigation and other purposes. Since the dams are the structures that impounds water, evaporation is an effective parameter in determining the water level in the reservoir. The amount of evaporation in the reservoir depends on the available energy, mass and energy transfer mechanism, depth and surface area of the reservoir. Evaporation causes large amount of water loss from the reservoir. Since the water demand for drinking, irrigation and other purposes are provided from the dams, estimating the rate of evaporation correctly becomes important. In this study, the prediction of monthly evaporation amount in Tahtaköprü dam is investigated using Artificial Neural Network (ANN) method.

To apply ANN in obtaining the monthly evaporation amount, the past records of monthly evaporation amount in Tahtaköprü dam were used as input data. A multi-layer sensor was used as ANN structure. Bayesian arrangement technique was used to train the ANN model. This technique was developed according to the Lenenberg-Marquardt optimisation method to renew the weight and bias coefficients.

The ANN results obtained were compared with the results of the multi-linear regression (MLR) and autoregressive (AR(p)) models. The models were analyzed using graphical and statistical results. Based on these results, ANN model solutions gave better proximity in estimating monthly evaporation amount in the dam reservoir compared to classical methods used in the past.

2010, 42 pages

Key Words: Artificial Neural Network (ANN), Monthly evaporation, Multi-Linear Regression, Autoregressive Models (AR(p)), Tahtaköprü Dam

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
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

	Sayfa
Çizelge 4.1. Tahtaköprü barajının eğitim ve test verileri istatistiksel parametre değişimleri.....	22
Çizelge 4.2. Tahtaköprü Barajında kullanılan bütün modellerde test verileri için elde edilen MSE, MAE ve R parametrelerinin karşılaştırılması	24

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1. Sinir hücrelerinin bağlantılarının basitleştirilmiş şematik yapısı.....	11
Şekil 3.2. Yapay sinir hücresi modeli.....	13
Şekil 3.3. Üç tabakalı Yapay Sinir Ağları modeli.....	14
Şekil 4.1. Tahtaköprü Barajı genel görünümü.....	20
Şekil 4.2. Haziran 1976 – Haziran 2005 tarihleri arasın Tahtaköprü Barajı aylık buharlaşma miktarları	21
Şekil 4.3. MLR metodu ile eğitimde elde edilmiş buharlaşma miktarı sonuçları ve ölçüm değerlerinin karşılaştırılması.....	26
Şekil 4.4. MLR metodu ile test de elde edilmiş buharlaşma miktarı sonuçları ve ölçüm değerlerinin karşılaştırılması.....	26
Şekil 4.5. MLR sonuçları ile ölçüm değerlerinin saçılma diyagramı.....	27
Şekil 4.6. Otoregresif modelde aylık buharlaşma miktarlarının AR (3) ile ölçüm değerlerinin karşılaştırılması	28
Şekil 4.7. AR(3) sonuçları ile ölçüm değerlerinin saçılma diyagramı	29
Şekil 4.8. Otoregresif modelde aylık buharlaşma miktarlarının AR(6) ile ölçüm değerlerinin karşılaştırılması.....	29
Şekil 4.9. AR(6) sonuçları ile ölçüm değerlerinin saçılma diyagramı	30
Şekil 4.10. YSA modelinde aylık buharlaşma miktarı eğitim sonuçları ile ölçüm değerlerinin karşılaştırılması.....	31
Şekil 4.11. YSA eğitim sonuçları ve ölçüm verileri sonuçları için saçılma diyagramı..	31
Şekil 4.12. YSA modelinde aylık buharlaşma miktarı test sonuçları ile ölçüm değerlerinin karşılaştırılması.....	32
Şekil 4.13. YSA test sonuçları ve ölçüm verileri sonuçları için saçılma diyagramı.....	32

1. GİRİŞ

Yeryüzünde canlıların yaşaması için suyu kullanmak ve kontrol altına almak insanlığın önemli ilgi alanlarından biri olmuştur. Suyun özelliklerini tanımaya, hareketini yöneten kanunları belirlemeye, yaratabileceği tehlikeleri önlemeye ve sudan en iyi şekilde yararlanmaya çalışılmıştır.

Yerküresinde (yeryüzünde, yer altında ve atmosferde) suyun çevrimini, dağılımını, fiziksel ve kimyasal özelliklerini, çevreyle ve canlılarla karşılıklı ilişkilerini incelemek Hidrolojinin konusu olmuştur. Suyun kullanılması ile ilgili çalışmalarda İnşaat Mühendisleri , Hidroloji bilimi ile birlikte hareket etmek suretiyle sulama ve hidroelektrik barajlar inşa etmişlerdir.

Barajlar, bir akarsu vadisini kapatan ve arkasında su biriktiren; enerji üretimi, içme suyu temini, sulama suyu temini ve akarsuların düzenlenmesi gibi pek çok gayeye hizmet eden ekonomik faydası olmasının yanı sıra , büyük yatırım gerektiren yapılardır. Günümüzde birkaç yüz metre yükseklikte ve kilometrelerce uzunlukta inşa edilmiş hacmi milyonlarca metreküp kapasiteye ulaşmış barajlar mevcuttur.

Baraj haznesindeki suyun miktarının belirlenmesini ve işletilmesini etkileyen en önemli faktörlerden biri olan buharlaşma, göldeki su seviyesinde azalmaya neden olmaktadır. Barajda meydana gelen buharlaşma miktarı, mevcut enerjiye, kütle ve enerji transfer mekanizmasına, barajın derinliğine ve yüzey alanına bağlıdır. Bunun yanında buharlaşmanın, güneş radyasyonunun, sıcaklığın, rüzgar hızının, rölatif nemin, atmosfer basıncının ve çevresel koşulların bir fonksiyonudur. Buharlaşma miktarı, içme, sulama ve kullanma suyunun baraj rezervuarından karşılanması bakımından önem arz etmektedir. Serbest su yüzeyinde meydana gelen buharlaşmanın tahmini için kullanılan metotlar, direkt ve indirekt metotlar olmak üzere iki grupta sınıflandırılabilir. Buharlaşma, doğasından kaynaklanan doğrusal olmayan karmaşık ilişkiler sebebiyle, literatürdeki birçok buharlaşma miktarı tahmin denklemleri ampirik olarak geliştirilmişlerdir. Genellikle bu formüller kendi aralarında da çelişmektedir ve bu nedenle en iyi çözümü veren denklemi belirlemek oldukça güç olmaktadır. Problemin karmaşıklığı ve belirsizliği klasik yöntemlere rahat modelleme imkanı vermez.

Bu durumlarda daha uygun olarak kullanılabilir başka yöntemlerde mevcut olup halen bu konuda çalışmalar devam etmektedir. Bu çalışmalar doğrultusunda son zamanlarda Yapay Sinir Ağları (Y.S.A) modelleri doğal olayların modellenmesinde sıkça kullanılmaktadır. Günümüzde Y.S.A birçok bilim alanına uygulanmaktadır. Bu yaklaşım diğer bilim dallarında olduğu gibi hidrolik ve hidroloji bilim dallarında da iyi sonuçlar elde etmek için kullanılmaktadır. Su kaynakları sistemleri doğrusal olmayan ve pek çok değişkene sahip karmaşık ilişkilerden oluşmaktadır. Bu tür problemler Y.S.A kullanılarak etkili bir şekilde çözülebilmektedir. Buda Y.S.A'nın probleme kolayca uyum sağlayabilmesinden kaynaklanmaktadır. Hidroloji alanındaki çalışmalarda en yaygın olarak kullanılan Y.S.A mimarisi çok katmanlı geri yayılım algoritmaları ileri beslemeli ağ modeli olduğu araştırmalardan görülmüştür.

Bu çalışmada, Türkiye'nin güneydoğu bölgesinde bulunan Tahtaköprü barajı için metodolojinin uygulanması sunulmuştur. Bu barajdaki aylık verilere YSA model uygulanmıştır. Muhtemel gelecekteki su seviyeleri geleneksel istatistiksel metot ve YSA metoduyla ortaya çıkarılmıştır. Baraj rezervuar seviyesindeki dalgalanmalar üç farklı metotla belirlenmiştir. Bunlar; Multi Lineer Regresion modeli (MLR) , Otoregresiv ((AR) modeli ve Yapay Sinir Ağları (YSA) dır. Modelde ortalama karesel hata (MSE), ortalama mutlak hata (MAE) ve model tahminleri ve gözlenmiş rezervuar seviyeleri arasındaki belirlilik katsayısı (R^2) ile incelenmiştir.

2. ÖNCEKİ ÇALIŞMALAR

Günümüze kadar YSA çok farklı alanlarda kullanılmıştır. Hidrolik ve Hidroloji gibi su kaynaklarına yönelik disiplinlerde bu yöntemle çok başarılı sonuçlar alındığı görülmüştür. Hidrolojik olayları tam olarak laboratuvar koşullarına indirgemek mümkün olmadığından; olayları temsil eden parametrelerin belirlenmesini sağlayan YSA metodu oldukça kolaylık sağlamaktadır.

Geçmişte ülkemizde ve yurtdışında, YSA modelleri birçok araştırmacı tarafından hidrolojik araştırmalarda buharlaşma miktarının tespitinde kullanılmıştır. Bu çalışmalardan bazıları aşağıda özetlenmiştir.

Doğan ve arkadaşları (2007) yaptıkları çalışmada ileri beslemeli geri yayınlı (İBGY-YSA) ve radyal temelli yapay sinir ağı (RT-YSA) modeli kullanarak Sapanca Gölü için günlük buharlaşma tahmini yapmışlardır. Sonuçlar Penman-Monteith (PM) modeli ile karşılaştırılmıştır. Minimum ve maksimum sıcaklığa, rüzgar hızına, göreceli neme, gerçek güneşlenme süresine ve maksimum güneşlenme müddetine bağlı olan günlük buharlaşma miktarının tahmini için İBGY-YSA ve RT-YSA modelleri uygulanmıştır. İBGY-YSA, RT-YSA ve PM modellerinin performansları sonucunda İBGY-YSA yöntemi, ölçülen günlük buharlaşma miktarına en yakın sonucu vermiştir.

Keskin ve Taylan 2007 yılındaki çalışmalarında Orta Akdeniz Havzasındaki Dim Çayı, Manavgat Çayı ve Köprüçay' a ait aylık akımların tahmini için stokastik modeller geliştirilmiştir. Seçilen modeller kullanılarak her bir akım serisi ile aynı uzunlukta sentetik seriler üretilmiştir. Üretilen serilerin, ölçülmüş akım serileri ile uyum içerisinde olduğu görülmüştür. Aynı zamanda, seçilen istasyonlara ait akımlar için Yapay Sinir Ağları modelleri kurulmuştur.

Yine Terzi, Keskin (2005) çalışmalarında buharlaşma tahminine alternatif bir yaklaşım olarak, Eğirdir Gölü'nden meteorolojik parametrelerle günlük tava buharlaşmasını tahmin etmek için (YSA) metodu kullanmışlardır. YSA modelinin ve Penman metodunun sonuçları tava buharlaşma değerleri ile kıyaslanmış ve YSA modelinin, tava buharlaşma değerleri ile uyum içerisinde olduğu görülmüştür.

Çalım (2008) yapmış olduğu Yüksek Lisans Tez çalışmasında baraj haznesi seviye değişim tahminlerinde (YSA) metodunu kullanmıştır. 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 sonuçlara göre; baraj haznesi seviye değişiminin tahmininde (YSA) model çözüm sonuçları, geçmişte kullanılan klasik yöntemlerle kıyaslandığında daha iyi bir performans göstermiştir.

YSA' lar su kaynakları mühendisliğinde ve birçok farklı disiplin ve alanlarda kullanılmaya başlanmıştır. YSA lar su kaynakları yönetimi ile ilgili birçok araştırma konusunda pratik olarak kabul edilebilir sonuçlar vermektedir. YSA modelleri pek çok araştırmacı tarafından yağış-akarsu ilişkisine uygulanmıştır. (Halff ve ark., 1993; Smith and Eli, 1995; Hsu ve ark., 1995; Minns and Hall, 1996; Fernando and Jayawardena, 1998; Shamseldin, 1997; Dawson and Wilby, 1998; Tokar and Johnson, 1999; Kumar ve ark., 2002; Solomatine and Dulal, 2003; Rajurakr ve ark., 2004).

Akarsularda, yağış-akarsu ilişkisi birçok araştırmacı tarafından YSA ile modellenmiştir. (Karunanithi ve ark., 1994; Cigizoglu, 2003 (a-b); Ramirez ve ark., 2005).

Kayda değer sayıda araştırmacı sediment (sürüntü maddesi) çalışmalarında YSA modellerini kullanmıştır (Cigizoglu, 2004a-b; Kişi, 2004,a-b; Kişi, 2005; Cigizoglu and Kişi, 2005; Cigizoglu and Kişi, 2006). Rezervuar giriş tahmini ve su kalitesi modellerinde YSA birçok araştırmacı tarafından kullanılmıştır (Jain ve ark., 1999-2004). Ayrıca su kaynaklarında YSA model uygulamaları ASCE çalışma komitesi tarafından özetlenmiştir (2000a-b). İlave olarak, Jain ve ark. (2004) YSA'nın korelasyon ağırlıklarında gizli fiziki bilgileri araştırmıştır. Sudheer ve Jain (2004) yapay sinir ağı yaklaşımı ile ırmak akış modellerinin içsel davranışını açıklamaya çalışmışlardır. Sudheer (2005), eğitilmiş YSA ile akarsu akış modellerinden yağış – akış bilgilerini araştırmıştır. Kişi ve ark. (2004), YSA modellerini kullanarak Van Gölü seviyesindeki dalgalanmaları çalışmışlardır. YSA modelleri Üneş (2006), Kunduz ve Üneş (2006) tarafından rezervuar hacmi ve seviye dalgalanmalarının belirlenmesinde kullanılmıştır.

3. MATERYAL VE YÖNTEM

Bu çalışmada, barajdaki aylık buharlaşma miktarının 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. Materyal

3.1.1. Klasik Yöntemler

Geçmişte günümüze değişkenler arasındaki ilişkiyi incelemek bilimin uğraşlarından birisi olmuştur. Gerek günlük hayatımızda gerekse bilimsel araştırmalarda karşılaştığımız sorunların çoğunluğu iki (veya daha çok) değişken arasında bir ilişki olup olmadığının saptanması ile ilgilidir. İki değişken arasında bir ilişki bulunup bulunmadığı, eğer varsa bu ilişkinin derecesinin saptanması da istatistiksel çözümlenelerde sık sık karşılaşılan bir sorundur. Değişkenler arasındaki ilişkinin incelenmesinde regresyon ilk akla gelen tekniktir.

İstatistiksel anlamda iki değişken arasındaki ilişki, bunların değerlerinin karşılıklı değişimleri arasında bir bağıllık şeklinde anlaşılır. Gerçekten x değişkeninin değerleri değişirken, buna bağlı olarak y değişkeninin değerleri de değişiyor ise, bu iki değişken arasında bir ilişki bulunduğu söylenebilir.

Regresyonda değişkenlerin bağımlı değişken ve bağımsız değişken(ler) olarak iki gruba ayrılması bir gerekliliktir. Bağımlı değişken, bağımsız değişken(ler) tarafından açıklanmaya çalışılan değişkendir. Genelde regresyonda bağımlı değişken y ve bağımsız değişken(ler) de x ile ifade edilir.

Regresyonda, amaçlardan biri bağımlı değişkenle bağımsız değişken(ler) arasındaki ilişkilerin ortaya çıkarılmasıdır. Örneğin y ile x arasında $y_i = a + bx_i$ ($i=1,2,3,\dots$) gibi doğrusal bir ilişki öngörülüyorsa ilk adım modelin bilinmeyen a ve b parametrelerinin tahmin edilmesidir. Modelin bilinmeyen parametreleri tahmin edildiğinde bağımsız değişken(ler)'in farklı değerleri için bağımlı değişkenin alacağı değeri tahmin etmek regresyonda bir diğer amaçtır. Bağımsız değişken(ler)'in aldığı her farklı değer(ler)'i için bağımlı değişkenin aldığı değer sabit ise ortada araştırılacak bir problem yoktur.

Hem regresyonda hem de varyans çözümlemesinde bağımlı deęişken en az eşit aralıklı düzeyde ölçülür. Regresyonda, bazı özel durumlar dışında, bağımsız deęişken(ler) de en az eşit aralıklı düzeyde ölçülmelidir. Varyans çözümlemesinde ise bağımlı deęişken yine en az eşit aralıklı düzeyde ölçülürken bağımsız deęişken(ler) sınıflama ya da sıralama ölçme düzeyinde ölçülür. Bu nedenle regresyon ve varyans çözümlemesinde amaç aynı olmakla beraber hangisinin kullanılacağı bağımsız deęişken(ler)in ölçme düzeyine bağlıdır.

Doğrusal regresyon analizi, bağımsız deęişken sayısına göre aşağıda gösterildięi gibi iki kısımda incelenmektedir:

1. Basit regresyon analizi (Tek bağımsız deęişken)
2. Çok deęişkenli doğrusal regresyon analizi (Birden çok bağımsız deęişken)

3.1.1.1. Çok Deęişkenli Doğrusal Regresyon Analizi

İkiden daha fazla sayıda deęişken arasında doğrusal bir ilişki bulunduğu kabul edilir. Çok deęişkenli regresyon ilişkisi Y bağımlı deęişkeninin X_1, X_2, \dots, X_m gibi m bağımsız deęişkendenden etkilendięi kabul edilir ve aralarındaki ilişki için doğrusal bir denklem seçilirse Y için regresyon denklemi şu şekilde yazılabilir:

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

Bu denklemde y, bağımsız deęişkenler $X_1=x_1, X_2=x_2, \dots, X_m=x_m$ deęerlerini aldığımda Y deęişkeninin beklenen deęerini göstermektedir.

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

$$\sum_{i=1}^N e_{yi}^2 = \sum_{i=1}^N \underbrace{(y_i - a - b_1x_{1i} - b_2x_{2i} - \dots - b_mx_{mi})^2}_y \quad (3.2)$$

ifadesini minimum yapacak şekilde hesaplanır (Bayazit ve Oğuz, 2005).

Y' nin X_1 ve X_2 gibi iki bağımsız deęişkene göre regresyon denkleminin en basit hali olarak şu şekli alır:

$$y = a + b_1x_1 + b_2x_2 \quad (3.3)$$

(3.2)denklemini için (3.3) denklemini minimum yapan regresyon katsayıları aşağıdaki denklem takımını çözerek bulunur:

$$Na + b_1 \sum_{i=1}^N x_{1i} + b_2 \sum_{i=1}^N x_{2i} = \sum_{i=1}^N y_i \quad (3.4)$$

$$a \sum_{i=1}^N x_{1i} + b_1 \sum_{i=1}^N x_{1i}^2 + b_2 \sum_{i=1}^N x_{1i}x_{2i} = \sum_{i=1}^N x_{1i}y_i \quad (3.5)$$

$$a \sum_{i=1}^N x_{2i} + b_1 \sum_{i=1}^N x_{1i}x_{2i} + b_2 \sum_{i=1}^N x_{2i}^2 = \sum_{i=1}^N x_{2i}y_i \quad (3.6)$$

Bu denklem takımının çözümüyle regresyon katsayıları için şu ifadeler elde edilir:

$$b_1 = \frac{\left[\sum_{i=1}^N (x_{2i} - \bar{x}_2)^2 \right] \left[\sum_{i=1}^N (x_{1i} - \bar{x}_1)(y_i - \bar{y}) \right] - \left[\sum_{i=1}^N (x_{1i} - \bar{x}_1)(x_{2i} - \bar{x}_2) \right] \left[\sum_{i=1}^N (x_{2i} - \bar{x}_2)(y_i - \bar{y}) \right]}{D} \quad (3.7)$$

$$b_2 = \frac{\left[\sum_{i=1}^N (x_{1i} - \bar{x}_1)^2 \right] \left[\sum_{i=1}^N (x_{2i} - \bar{x}_2)(y_i - \bar{y}) \right] - \left[\sum_{i=1}^N (x_{1i} - \bar{x}_1)(x_{2i} - \bar{x}_2) \right] \left[\sum_{i=1}^N (x_{1i} - \bar{x}_1)(y_i - \bar{y}) \right]}{D} \quad (3.8)$$

$$a = \bar{y} - b_1x_1 - b_2x_2 \quad (3.9)$$

Burada:

$$D = \left[\sum_{i=1}^N (x_{1i} - \bar{x}_1)^2 \right] \left[\sum_{i=1}^N (x_{2i} - \bar{x}_2)^2 \right] - \left[\sum_{i=1}^N (x_{1i} - \bar{x}_1)(x_{2i} - \bar{x}_2) \right]^2 \quad (3.10)$$

(3.10) denklemlerinin sonucundan görüleceği gibi regresyon denklemi daima (x_1, x_2, y) noktasından geçer. Regresyon denklemindeki a katsayısı $x_1=x_2=.....=x_m=0$ için y nin beklenen değerini, b_1 katsayısı x_1 değişkeni dışındaki bütün bağımsız değişkenler sabit kalmak üzere x_1 değişkenindeki birim değişikliğe karşılık y de beklenen değişikliği gösterir. Bu nedenle b_1 katsayılarına kısmi korelasyon katsayıları gözüyle bakılabilir (Bayazıt ve Oğuz, 2005).

3.1.1.1.1. Altı Bağımsız Değişkenli Doğrusal Regresyon Analizi

Bir bağımsız değişkenli, bir bağımlı değişkenli doğrusal regresyon çok sayıda bağımsız değişkenler için genişletilebilir. Bu çalışmada y değişkeninin x_1, x_2, x_3, x_4, x_5 ve x_6 bağımsız değişkenlerinin fonksiyonu olduğu kabul edilmiş ve denklem aşağıdaki şekilde ifade edilebilir.

$$y = a + b_1x_1 + b_2x_2 + b_3x_3 + b_4x_4 + b_5x_5 + b_6x_6 \quad (3.11)$$

Bu çalışmada yukarıdaki denklem çalışılan konuya uyarlanmış ve regresyon katsayıları Excel yardımı ile belirlenmiştir.

3.1.1.1.2. Determinasyon Katsayısı

Bu çalışmanın kalibrasyon ve değerlendirmesinde kullanılan diğer bir parametrede determinasyon katsayısıdır. Çoklu belirlilik katsayısı, bağımsız değişkenlerin bağımlı değişkeni açıklama oranı olarak tanımlanarak aşağıdaki gibi hesaplanır.

$$R^2 = \frac{\sum \hat{y}_i'^2}{\sum y_i'^2} = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2} \quad (3.12)$$

$$R^2 = 1 - \frac{\sum e_i^2}{\sum y_i'^2} \quad (3.13)$$

$$R^2 = \frac{b_1 \sum y_i'x_{1i}' + b_2 \sum y_i'x_{2i}'}{\sum y_i'^2} \quad (3.14)$$

3.1.1.2. Otoregresif Modeller (AR(p))

Bir rastgele 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 inşaat mühendisliğinde özellikle hidrolojik uygulamalarda rastlanır. Bir akarsu kesitinde Δt aralıklarıyla ölçülen akımlar (ya da Δt aralığındaki toplam akım hacmi) bir zaman serisi oluşturur (Bayazıt, 1996).

Yıllık akım serilerinin (trend ya da sıçrama bileşeni bulunmadığı takdirde) stasyoner 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 stasyoner olmayacaktır. Stasyoner olmayan serilerin incelenmesi güç olduğundan bunların uygun bir dönüşümle stasyoner hale getirilmesine çalışılır.

Akarsu havzasının depolama özellikleri akım serilerindeki ardışık değerler arasında bağımlılık (iç bağımlılık) bulunmasına neden olur. Zaman aralığı kısaltıldıkça 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 ve stabilizasyon hatalarından kaçınmak için veriler normalize edilerek kullanılır. Bu çalışmada sadece AR(p) modelleri kullanılacaktır.

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

$$y_i = \sum_{j=1}^p \phi_j y_{i-j} + \epsilon_i = \phi_1 y_{i-1} + \phi_2 y_{i-2} + \dots + \phi_p y_{i-p} + \epsilon_i \quad (3.15)$$

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 8. mertebeye kadar AR(p) modeli uygulanmış fakat 3. ve 6. mertebeden otoregresif model sonuçları verilmiştir (Beyazıt, 1996).

3.2. Yöntem

3.2.1. Yapay Sinir Ağları (YSA) Modeli


YSA insan beyninin çalışma mekanizmasını taklit ederek beynin öğrenme, hatırlama, genelleme yapma yolu ile yeni bilgiler türetebilme gibi temel işlevlerini gerçekleştirmek üzere geliştirilen mantıksal yazılımlardır. Aslında YSA'nın tarihçesi modern bilgisayarlardan daha eskidir ve bu konudaki çalışmalar sinir hücrelerinin bilgi işleyiş mekanizmasının modellenmesi ile başlamıştır. İlk olarak 1943'te nörofizyolog McCulloch ve mantıkçı Pitts ilk sinir ağı modelini geliştirerek birkaç ara bağlantı kurmaya çalıştılar. 1950'li yıllarda hızlı bir gelişim gösteren bilgisayar teknolojisi üzerine çalışan uzmanlar, sinirbilimcilerle temasa geçerek bu konuda çalışmalar yaptılar. Ancak 1969 yılında Minsky ve Papert yazdıkları bir kitapta bu çalışmaların verimsiz olduğunu söyleyince, araştırmacılar uzun yıllar maddi kaynak bulmakta zorlandılar ve bu konudaki çalışmalar durma noktasına geldi. Sınırlı imkanlara rağmen hala bu konuda çalışan az sayıda bilim adamının gayreti ile düzenlenen konferanslar ve bazı endüstriyel ve finansal kuruluşlarda başarılı ticari uygulamalar sayesinde 1980'lerin başlarından itibaren YSA çalışmaları yeniden ivme kazandı. Günümüzde verilerden yola çıkarak tahminde bulunmayı gerektiren finans ve satış sektöründen, çeşitli mühendislik sektörlerine kadar birçok alanda çalışma alanları bulan YSA'nın, tıp alanında da uygulama çalışmaları devam etmektedir. Şu anda tıp alanındaki uygulamalar daha çok insan vücut parçalarının modellenmesi ve taramalardan elde edilen sonuçlardan (ultrason taraması, kardiyogram vb.) hastalıkların tanısının konmasına yöneliktir. Hastalığa nasıl tanı koyduğuna dair özgün bir algoritmaya ihtiyaç duymayan YSA'lar veri örneklerinden öğrenme yoluyla tanı koymaya çalışır. YSA'nın biyokimyasal analizlerde, genetik alanında yapılan çalışmalarda, kardiyoloji, gastroenteroloji, onkoloji, nöroloji, jinekoloji ve patolojide tahmin ve teşhis amaçlı kullanımı giderek yaygınlaşmaktadır. Üstün özellikleriyle çeşitli avantajlar sunan ve sürekli gelişmekte olan bu teknoloji ile istatistiksel yöntemler arasında önemli ilişkiler söz konusudur. Bu çalışmada YSA'nın genel yapısı ele alınarak istatistiksel yöntemlerle ilişkileri araştırılmıştır.

3.2.1.1. Biyolojik Sinir Ağları

İnsan beyninin nasıl çalıştığı henüz tam olarak anlaşılabilmiş değildir. Ancak bu konuda beyni oluşturan milyarlarca sinir hücresinin önemli rol oynadıkları bilinmektedir. Beynin çalışması genel olarak üç aşamadan oluşur:

1. Bilgi girişi,
2. Sentezleme ve karşılaştırma,
3. Bilgi çıkışı ve eylem.

Beynin bu işlevlerini yerine getirebilmesini sağlayan ise temel yapı elemanı olan sinir hücreleri yani nöronlardır. Sinir hücreleri birbirleri ile ilişki halindedirler. Bu sıkı ilişki, sinirsel işlevin temelini oluşturan bilgi akışını sağlar. Biyolojik sinir ağını oluşturan insan beynindeki nöronlar Şekil 3.1.'de görüldüğü gibi üç temel bölgeden oluşur:



Şekil 3.1. Sinir hücrelerinin bağlantılarının basitleştirilmiş şematik yapısı

a) Çekirdek ve Soma (Hücre gövdesi)

Hücresinin gövde kısmında bulunan çekirdek, hücrenin temel işlevlerini belirleyen ve DNA molekülü üzerinde kodlanmış halde bulunan genetik bilgiyi içerir. DNA üzerindeki bilgi, hücrenin bulunduğu ortama, ortamdaki değişimlere ve hücrenin iç çevresine bağlı olarak deşifre edilerek, hücre içi olayların meydana gelmesini sağlar. Hücre etkinliklerine ilişkin yapım/yıkım (metabolizma) faaliyetlerinin büyük bir çoğunluğu ise hücre gövdesinde yürütülür. Hücre gövdesi, jel kıvamındaki hücre plazması (sitoplazma) içinde, mitokondri, golgi aygıtı, endoplazmik retikulum gibi birçok hücre organelini de içeren bölümdür (www.mcatürk.com/Sinir-Sistemimiz_244.htm).

b) Dendritler ve Akson

Hücre gövdesinden çıkan uzantılardır. Kısa, ağaç dalları biçiminde ve genellikle çok sayıda olan yapılar dendrit adını alır. Diğer hücrelerin aksonlarıyla gelen sinir sinyallerini alarak ait oldukları hücre gövdesine taşırlar. Akson ise uzun ve tek olup, uç kısımlarından genellikle dallanmalar gösterir. Hücre gövdesinde üretilen sinyalleri diğer nöronların dendritlerine taşımakla yükümlüdür.

c) Sinapslar

Akson ve dendritlerin veri iletişimi amacıyla bir araya geldikleri birleşim yerlerine sinaps adı verilir. Sinapslar, bir hücrede üretilen sinyalleri, yapısına ve biyofiziksel özelliklerine bağlı olarak sonraki hücreye iletirler. Genel olarak bir sinir hücresi, gövde ve dendritleri aracılığıyla sinyalleri alır. Bu sinyaller akson vasıtasıyla, hücre içindeki genel duruma ve gelen tüm sinyallerin toplam etkisine göre diğer bir hücreye aktarılır.

Şekil 3.1'de görüldüğü gibi nöronlar kendi aralarında bağlantılar kurarak, elektrik devrelerine benzer yollarla iletişim sağlayıp, beyin işlevlerinin ortaya çıkmasını sağlayan ana elemanlardır. Bu sistem bir bütün olarak, bir sinir bilimci-nin bile hayal edebileceğinin çok ötesinde bir karmaşıklığa sahiptir.

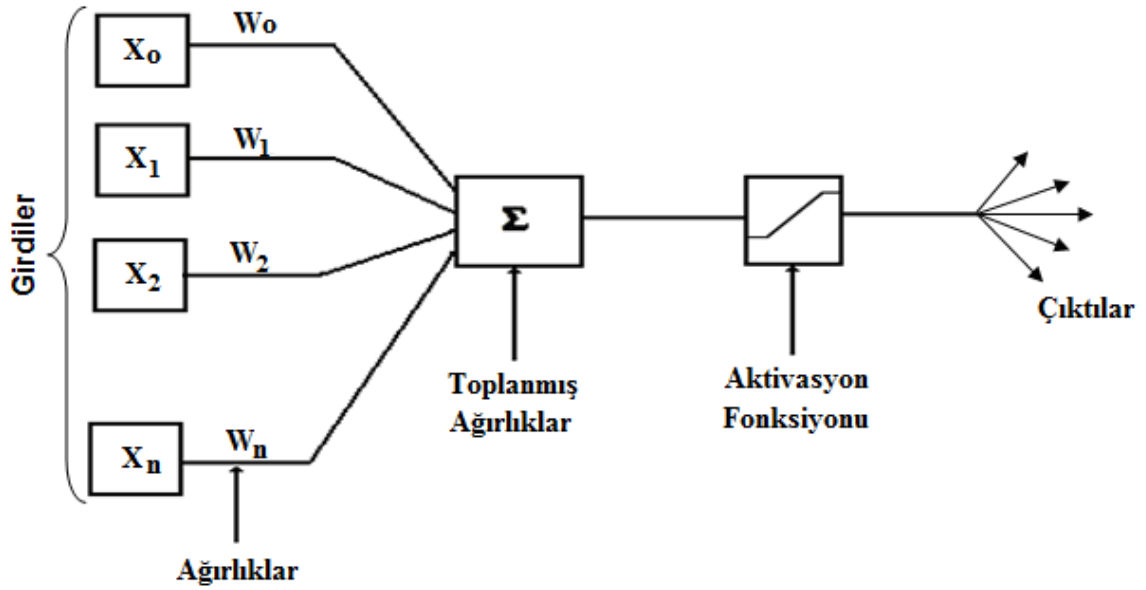
Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik bağlantılar ile olur. İnsan beyni doğumdan itibaren sürekli bir öğrenme süreci içindedir. Beyin sürekli bir gelişme gösterir. Bu gelişim sadece yeni beyin hücrelerinin oluşumuyla değil, özellikle nöronlar arasındaki bağlantı ya da diğer bir ifadeyle sinaps sayısının artmasıyla meydana gelir.

Aksonların yeni dalları oluşur ve bu dallar yeni dendritlerle bağlantı kurar. Böylece öğrenme gerçekleşir. Nöronlar arasındaki bağlantılar arttıkça, beyin daha ayrıntılı işlemler yapabilir ve daha çok öğrenmiş olur.

YSA algoritmaları, canlı organizmada bulunan biyolojik sinir yapısı modellenerek oluşturulmuşlardır. Taklit edilen yapay sinir hücreleri birbirleriyle çeşitli şekillerde bağlanarak YSA'yı oluştururlar ve genellikle katmanlar şeklinde düzenlenirler. Bu ağlar öğrenme, hafızaya alma, hatırlama, sonuç çıkarma yeteneğine sahiptirler. YSA hesaplamalarının gücü, toplam işlem yükünü paylaşan

işlem elemanlarının yani nöronların birbirleri arasındaki yoğun bağlantıdan kaynaklanmaktadır.

Matematiksel olarak modellenmiş bir biyolojik nöron Şekil 3.2.'de görülmektedir. Bu nöronlar Mc Culloch-Pits nöronu olarak bilinirler. Birbirleriyle bağlanarak ağı oluştururlar. Bir nöron diğer nörondan sinyalleri alır, bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkartır. Her bir nöron şiddetine göre gelen sinyali ya sönümlendirir ya da iletir. Giriş değerlerinin her biri bir bağlantı ağırlığıyla çarpılır. Nöronlar giriş bilgilerini ağırlıklandırdıktan sonra, doğrusal olarak toplar ve eşik bu bilgiyi doğrusal veya doğrusal olmayan bir fonksiyonda işleyerek çıktı bilgisine dönüştürür. Bu çıktıyı hücreye bağlantısı olan diğer nöronlar giriş bilgileri olarak alırlar. YSA'da en uygun ağırlık setinin belirlenmesi için yapılan ağ hesaplamaları iki aşamadan oluşur:



Şekil 3.2. Yapay sinir hücresi modeli; X_i , giriş değerleri; W_i , bağlantı ağırlığıdır.

Öğrenme:

Ağlar örneklerle eğitilirler. İki öğrenme stratejisi söz konusudur:

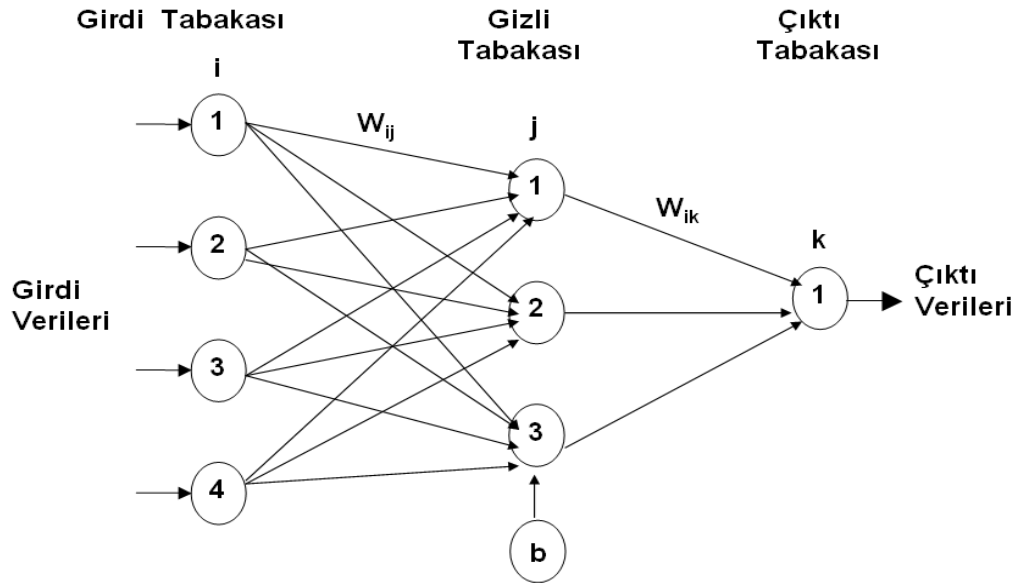
a- Danışmanlı öğrenme: Ağa giriş-çıkış vektörleri şeklinde ayrıntılı eğitim örnekleri verilmektedir. Örneğe ait hem giriş hem de çıkış değerleri ağa sunulur ve her iterasyonda örneğe ait çıkış değerleri ile ağın çıkış değerleri karşılaştırılarak

ağın hatası hesaplanır. Bu hata minimum olana kadar ağ, nöronlar arasındaki bağlantı ağırlıkları düzelterek iterasyona devam eder. YSA'da en yaygın öğrenme biçimidir.

b- Danışmansız öğrenme: Ağa sadece giriş veri grubu sunulur ve bu veri grubuna uyumlu bir çıkış değeri üretecek şekilde ağın kendisinin uygun bağlantı ağırlıkları düzenlenmesi istenir.

Hatırlama (Test etme):

Ağın öğrenmesi sonucu elde edilen bağlantı ağırlık grubu kullanılarak ağa benzer bir probleme ait giriş değerleri verilir ve bu probleme çözüm getirmesi istenir. YSA, ağın kullanıldığı veri setine göre sınıflandırılabilir. Temel olarak veriler kategorik ve sayısal olmak üzere iki ana gruba ayrılır. Kategorik veriler ile çalışan ağlar ister danışmanlı ister danışmansız öğrenme kullansın, sınıflandırma ağları olarak bilinirler. Kantitatif veriler kullanan, danışmanlı eğitim almış YSA ise genellikle regresyon analizi amaçlıdır.



Şekil 3.3. Üç tabakalı YSA şeması.

Şekil 3.2'de W_{ij} ve W_{jk} bağlantı ağırlıkları, bir önceki girdi verilerinin işlem yapılan eleman üzerindeki etkisini ifade eden katsayı değerleridir. Başlangıçta rastgele ağırlık değerleri alan bu katsayılar, eğitim sürecinde tahmin edilen çıktılarla gerçek çıktı değerleri karşılaştırılarak devamlı değişmekte ve hataları minimum yapan bağlantı ağırlık değerleri ayarlanıncaya kadar hatalar geriye doğru yayılmaktadır. Şekil 3.2. ve

3.3' deki gizli ve çıktı tabakalarındaki her bir hücre, önceki tabakadan gelen verilerin toplam fonksiyonu (net)'e girmesini sağlar. Bu fonksiyon hücreye gelen net girdiyi hesaplayarak aşağıdaki eşitliği belirlemektedir.

$$net_{pj} = \sum_{i=1}^N W_{ij} X_{pi} + b_j \quad (3.16)$$

3.16 denkleminde; N girdi vektörünün boyutu, b_j , bias (tarafılık, eşik) sabiti, W_{ij} , i ve j tabakaları arasındaki ağırlıklar kümesi, X_{pi} , p örneği için i tabakasının girdi kümesidir.

Bu çalışmada da, en çok kullanılan aktivasyon fonksiyonu (tanımlama) olan Sigmoid fonksiyonu kullanılmıştır. Bu fonksiyon ve k tabakalarındaki her bir hücrede, net değerini doğrusal olmayan bir tanımlama fonksiyonundan geçirerek $f(net)$ çıktısını üretmekte ve 3.17. denklemindeki gibi ifade edilmektedir.

$$f(net) = \frac{1}{1 + e^{-net}} \quad (3.17)$$

YSA, yapısal olarak da sınıflandırılabilir. Yapısal olarak YSA, bilginin akış yönüne bağlı olarak, nöronlar arasındaki bağlantıların yapısı bakımından ileri beslemeli ve geri beslemeli olmak üzere iki ana grupta toplanır.

1) İleri Beslemeli Ağlar: Ara sinirlerden geçerek giriş katından çıkış katına doğru bilgi akışının yalnız bir yönde ilerlediği ağlardır. Giriş tabakası, gizli tabaka ve çıkış tabakası olmak üzere 3 tabakadan oluşurlar. Ağ üzerinde bilgi akışı giriş tabakasından çıkış tabakasına doğru ilerler. Yani nöronlar arka arkaya beslenirler.

2) Geri Beslemeli YSA: Herhangi bir sinirin çıkışından girişine doğru bilgi akışının ilerlediği ağlardır. Bu tür ağ yapısında geri besleme bağlantıları söz konusudur.

Ayrıca hem ileri besleme hem de geri yayılma olarak tanımlanabilecek ağ yapıları da mevcuttur. Tüm YSA modelleri içinde en çok kullanılan ağlar geri yayılma ile eğitilen çok tabakalı ileri beslemeli ağlar (Back Propagation Network), radial tabanlı ağlar, Hopfield ve Kohonen sayılabilir. Geri yayılmalı YSA hem kullanışlı hem de güvenilir olmasından dolayı en çok kullanılan ağ türüdür. En önemli özelliği kestirim (prediction) ve sınıflandırma işlemleri için oldukça uygun olması ve doğrusal olmayan yapı içeren modellerde oldukça kullanışlı olmasıdır. Bu tip

ağların kullanıldığı birkaç çalışma şöyle özetlenebilir. Acil servise başvuran hasta sayısı üzerine atmosferik değişimlerin etkisi araştırılmak istenmiş ve etkiler ileri beslemeli geri yayımlı YSA algoritması ile incelenmiştir. Elde edilen sonuçlar değerlendirildiğinde YSA'nın başarısı %80 olarak bulunmuştur. Bir başka çalışmada ise ratlarda 3 uyku-uyanıklık döngüsüne ait elektrofizyolojik kayıtlar yardımıyla bu evrelerin sınıflandırması yapılmış ve kullanılan ağın başarı oranı yaklaşık %95 bulunmuştur. Yine EEG dalga kayıtlarının girdi verisi olarak kullanıldığı bir diğer çalışmada ileri beslemeli geri yayımlı YSA modeli kullanılmış ve EEG paternine göre denekler uyanık-tetikte, uykulu-uyuşuk ve uykuda olarak sınıflandırılmıştır. Sınıflama başarısı %94-%96 aralarında bulunmuştur.

3.2.1.1.1. Biyolojik ve YSA'nın Temel Farkları

YSA, temel olarak biyolojik sinir sistemini örnek alsa da canlı sistemin ileri düzeyde karmaşıklığı, canlıdaki etkinlik ve kapasitede bir sinir ağı tasarımına şu anda izin vermemektedir. Canlı sistemlerde hücreler, hücre uzantıları ve bunlar arasındaki bağlantılar çok dinamik ve değişken bir yapılanma gösterirler. Canlı bir hücrenin hem yapısal hem de biyokimyasal olarak geçirdiği değişiklikleri hesaplayabilmek oldukça karmaşık bir işlem dizisi gerektirir. Ayrıca biyolojik sinir ağları her öğrenmeden sonra hem yapısal hem de kimyasal birtakım değişiklikler göstererek adapte olma özelliğine sahiptirler. Bunun yanı sıra, veri iletişim noktaları olan sinapsların ileri düzeyde uyarlanabilir yapılar olması, bir tek sinapsın bile veri iletişimini modellemeyi güçleştirmektedir. Sinapslar, geçirdikleri verinin tipi ve karşı hücrede uyandırdıkları yanıtı göre bir dizi düzenleme işlevini de gerçekleştirirler.

Tüm bunlarla birlikte, canlılardaki sinir sistemi sadece nöronlardan kurulmamıştır; sinir sisteminde sinir hücrelerinin yaklaşık 50 katı kadar sayıya ulaşabilen ara hücreler (glia hücreleri) de bulunur ve bunların sinir sisteminin bilgi-işlem süreçlerindeki rolleri halen tartışmalıdır. Tüm bu koşullar göz önüne alındığında en gelişmiş sinir ağları bile canlılardaki sinir sisteminin, sadece bilimsel olarak bilinen kısmına dair kaba bir model/benzetim olarak kabul edilebilir.

3.2.1.2. YSA ve İstatistiksel Yöntemler

YSA uygulamalarında istatistiksel bağlantıların büyük önemi vardır. İstatistikte doğrusal olmayan modeller için kullanılan yöntemler bazı YSA algoritmalarını eğitmek için kullanılmaktadır. YSA terminolojisinde istatistiksel çıkarımın anlamı, ham veriden genelleme yapmayı öğrenmektir. YSA ve istatistiksel yöntemler arasında önemli bir kesişim kümesi vardır. Örneğin en küçük kareler yöntemi YSA modellerinde de sıklıkla kullanılmaktadır. Bununla beraber model geliştirmede YSA ile istatistikte kullanılan yaklaşımlar tamamen farklı olabilir. Değişik eğitime kriterleri, değişik istatistiksel özelliklere sahip farklı tahmin yöntemleridir. Örneğin aritmetik ortalama, basit bir geri yayılma ağ ile kolayca hesaplanabilir. Bunun için, aritmetik ortalama formülünün ağ içinde kullanılması yeterlidir. Sonuçta hesaplanma şekli ne olursa olsun çıktı olarak aritmetik ortalama elde edilir. YSA'nın klasik ve modern istatistiksel yöntemlere ek olarak kullanımı gittikçe yaygınlaşmaktadır.

Geri beslemeli YSA, daha çok optimizasyon problemlerinde kullanılırlar. En popüler geri beslemeli ağ tiplerinden biri Kohonen ağlarıdır. Kullanımı zor ancak çok güçlüdür. Uyarlamalı vektör ölçümü için Kohonen ağları, k ortalamalı kümeleme analizine çok benzemektedir. Kohonen kendi kendini organize edebilen haritaları, temel eğriler ve yüzeyle ayrı bir yaklaşımdır.

Geri yayılma YSA, özellikle zaman serileri analizinde yaygın bir biçimde kullanılmaktadır. Geri yayılım algoritmasının yeni olmadığı, aslında bilinen bir istatistiksel yöntem olan stokastik yaklaşım olduğu ileri sürülmektedir.

Genel olarak danışmanlı öğrenme ile eğitilen YSA regresyon analizi ve ayırma analizi amacıyla kullanılmaktadır. Danışmansız öğrenme ile eğitilen YSA, sınıflama (cluster) analizi ve veri indirgemedede kullanılmaktadırlar.

YSA ile klasik istatistiksel yöntemler arasındaki en temel farklılık istatistiksel yöntemlerin, modele alınacak değişkenlerin yapısı hakkında bilgiye gereksinim duyması ve birtakım varsayımları göz önüne almasıdır. YSA ise değişkenlerin yapısı hakkında bilgi istemez ve önşart gerektirmez. Yani istatistiksel yaklaşımlar, varsayılan bir modele dayanır ancak YSA veriye dayanır.

İstatistiksel Analiz Yöntemi Olarak YSA'nın Avantajları:

YSA doğrusal değildir. Bu özelliği nedeniyle her alana uygulanabilir. Herhangi bir sürekli fonksiyona ve türevlerine de yakınsama yeteneğine sahiptir ve bu yönüyle evrensel fonksiyon yakınsayıcı yöntem olarak tanımlanmaktadır. YSA'nın özellikle doğrusal olmayan zaman serilerinde gösterdiği başarı, bir tahmin aracı olarak tercih edilmesini sağlamıştır.

1. Öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlarda genelleme yapabilmektedir. Yani hatalı veya kayıp veriler için çözüm üretebilmektedir. Eksik bilgileri de işleyerek sonuca varabilir.

2. Sınırsız sayıda değişken ve parametre ile kolaylıkla çalışılabilmektedir. YSA, doğrusal olmayan, çok boyutlu, hatalı veya eksik gözlem içeren, grup içi varyansın büyük olduğu ve özellikle problemin çözümünde kesin bir matematiksel mo-delin veya algoritmanın bulunmadığı verilerin analizinde önemli bir araç haline gelmiştir.

3. YSA, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağın sahip olduğu bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağın doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle hatayı tolere etme yetenekleri son derece yüksektir.

4. Değişken uzayı karmaşık ve verinin dağılımı bilinen istatistiksel dağılımlardan farklıysa, istatistiksel sınıflama yöntemlerinden daha güvenilir sonuçlar verirler. Mesela klasik parametrik istatistiksel sınıflandırma yöntemleri öklit, 'maximum likelihood' ve 'mahalanobis' uzaklığı sınıflandırıcılarını kullanırlar. Bu yaklaşımlar, sınıflandırılmış veriler için çok değişkenli normal dağılım varsayımına gerek duyarlar. Değişken uzayındaki her bir özelliğin çok değişkenli normal dağılım gösterdiği varsayılır. Ancak veriler bu varsayımı sağlamıyor olabilir. Bu durumda dağılımdan bağımsız YSA'nın kullanımı önerilir. Sınıflama amacıyla kullanılan, danışmanlı öğrenme ile eğitilen YSA, yine sınıflama amacıyla kullanılan k tane en yakın komşu algoritmasına benzer ancak YSA'dan elde edilen sonuçların daha güvenilir olduğu görülmüştür.

İstatistiksel Analiz Yöntemi Olarak YSA'nın Dezavantajları:

1. Sinir ağlarının eğitilmesine ve test edilebilmesine yetecek genişlikte veri setine ihtiyaç duyulmaktadır.

2. Uygun ağ yapısının belirlenmesi genellikle deneme yanılma yöntemiyle gerçekleştirilmektedir.

3. Gizli katmandaki nöron sayısı, bir tanıma işleminin doğruluğunu ve eğitim hızını etkilemektedir. Örneğin karmaşık ilişkiler gizli tabakada nöron sayısı az olduğunda bulunamamaktadır ancak sayının çok büyük olması da hesaplama yükünü çok fazla arttırmaktadır.

4. Basit olarak görülebilecek modelleme yapılarına rağmen zaman zaman uygulaması zor ve karmaşık olabilmektedir.

5. Diğer birçok tahmin yöntemi gibi bir model oluşturmaz ve parametre tahminlerini vermez.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA


4.1. Uygulama Alanı ve Tanıtılması

Bu çalışmada; Tahtaköprü barajındaki aylık buharlaşma miktarının tahmini için Yapay Sinir Ağları modeli kullanılmıştır. Bu amaçla benzer konularda (YSA) uygulamaları incelenmiş ve sonuçlar değerlendirilmiştir. Tahtaköprü Barajı (Şekil 4.1), Hatay ilinde, Karasu Çayı üzerinde, sulama amacı ile 1967-1975 yılları arasında inşa edilmiş bir barajdır. Toprak gövde dolgu tipi olan barajın gövde hacmi 2.142.000 m³, akarsu yatağından yüksekliği 50,00 m, normal su kotunda göl hacmi 200,00 hm³, normal su kotunda göl alanı 23,40 km² dir. 11.575 hektarlık bir alana sulama hizmeti vermektedir. Hesaplarda kullanılmak üzere aylık toplam buharlaşan su miktarı D.S.İ. Hatay İl Müdürlüğünden elde edilmiş ve düzenlenmiştir.



Şekil 4.1. Tahtaköprü Barajı Genel Görünümü

YSA ve diğer klasik modeller için kullanılan veriler aşağıdaki gibidir: Tahtaköprü barajına ait aylık buharlaşma miktarı verileri DSİ Müdürlüğü'nden alınmış buharlaşma verileri düzenleme sonrasında kaydırılarak altı adet veri haline getirilmiş, adı geçen yöntemlere uygulanmış ve sonuçlar karşılaştırılmıştır. Barajın konumlandığı bölge bahar başlangıcı ve sonunda yüksek miktarlarda yağış alan bir bölge olup, yaz mevsimi kurak geçmektedir. Bu çalışmada kullanılan buharlaşma verilerinin aylara göre değişimleri Şekil 4.1'de verilmiştir.



Şekil 4.2. Haziran 1976 ile Haziran 2005 tarihleri arası Tahtaköprü barajı aylık buharlaşma miktarları

Bu veriler göz önünde bulundurularak hem model gelişimi (eğitimi) hem de doğruluğu (test) sergilenecektir. Bu yüzden model doğruluğunun kontrolü için ilk 240 aylık veri eğitimde kullanılmıştır. Geriye kalan 103 aylık veri geliştirilmiş modelin geçerliliğini doğrulamak amacıyla test aşamasında kullanılmıştır. Gözlemlenmiş ortak verilerin istatistiksel özetleri, eğitim verisi ve test verisi olarak, istatistiksel metotlar kullanılarak hesaplanmış ve bu özetler Çizelge 4.1'de gösterilmiştir. Çizelge 4.1'de eğitim verileri ve test verilerinin istatistiksel parametre değişimleri ayrı ayrı verilmiştir.

Çizelge 4.1. Tahtaköprü barajının eğitim ve test verileri istatistiksel parametre değişimleri

Veri Grubu	Veri Tipi	Parametreler		
		x_{\max}	x_{\min}	x_{ort}
Eğitim Verileri	A.T.B.S.M (10^3 m^3)	6340,0	0,0	1331.70
Test Verileri	A.T.B.S.M (10^3 m^3)	5187,0	0,0	1059.40

A.T.B.S.M :Aylık toplam buharlaşan su miktarı

Girdi ve çıktı veri değişkenlerinin hacimsel ve büyük değerlerden oluşması nedeniyle, bütün değişkenleri içeren girdi ve çıktı verileri denklem 4.1' i kullanarak eğitim ve test aşamalarında 0.1 ve 0.9 arasında normalize edilmiştir. Böylece iterasyon aşamasında x_{\min} buharlaşma değerlerinin olduğu zamanların eğitim ve test aşamasına etkisi azaltılmış olacaktır.

$$x = 0.1 + 0.9 \left(\frac{x_i}{x_{\max}} \right) \quad (4.1)$$

4.2. Tahtaköprü Barajı Uygulamaları

Bu çalışmada, YSA'da rezervuar buharlaşma problemini tanımlarken bir gizli katmanlı çok tabakalı algılayıcı seçilmiştir. Çok tabakalı algılayıcının en yaygın öğrenim yöntemi olan geriye yayılım algoritması (BPA), girdi ve çıktı veri seti için kullanılmıştır. İleri beslemeli Bayes regülarizasyon yayılım algoritması, Marquardt Levenberg Metodu uygulanarak ve MATLAB koduyla yazılmıştır. MATLAB da oluşturulan YSA modelinde, çok sayıda deneme yapılarak, iterasyon sayısı, öğrenme ve momentum oranı için sırası ile 1000, 0.1, 0.95 değerleri alınmıştır.

YSA'nın baraj rezervuar buharlaşma verisine uygulanması iki adımdan oluşmuştur. İlk adım sinir ağlarının eğitimidir. Bu adımda, aylık buharlaşma miktarları girdi olarak kullanılmıştır. Baraj rezervuar aylık buharlaşma modellerinin geliştirilmesi amacıyla YSA, ilk veri setinin bir başka deyişle ilk 240 aylık gözlemlerden oluşan eğitim verisinin kullanımıyla eğitilmiştir. Eğitim aşaması tamamlandıktan sonra çok

tabakalı algılayıcılar son 103 aylık gözlemlerden oluşan test verilerine uygulanmıştır. Belirli bir problem için uygun bir ağ yapımı saptamak, ağ topolojisi, hesap karmaşıklığını ve genelleme yapabilme yetisini bire bir ilgilendirdiğinden önemli bir konudur (Ciğizoğlu, 2003-b). Bu yüzden, yaygın olarak kullanılan test ve hata metotlarından yola çıkılarak gizli katman nodlarına ve gizli katman sayısına karar verilir. Farklı çok tabakalı algılayıcı yapıları denendikten sonra bu çalışmada 6 katmanlı ve tek gizli tabakalı çok tabakalı algılayıcı yapısı seçilmiştir. Her bir model için en düşük karesel hata (MSE), toplam karesel hata (MAE) ve model tahminleri ve gözlemlenen değerler arasındaki korelasyon katsayıları hesaplanmıştır. Sonuçları da model tahmini ve gözlem verilerinin performanslarını karşılaştırmak için kullanılmıştır'. MSE ve MAE aşağıdaki gibi belirlenmiştir.

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

ve

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

Burada N data set sayılarını ve Y_i rezervuar aylık buharlaşma verilerini göstermektedir. Hidrolojik verilerin Stokastik modelleri regresyon, zaman dizimi ve olasılık modelleri kullanarak da elde edilebilir. Bu teknikler değişkenler arasında lineer ilişkinin olduğunu varsaymaktadır (Ciğizoğlu ve Kişi, 2006). Her ne kadar rezervuar buharlaşma miktarı varyasyonu probleminin çözümü lineer olmayan bir yaklaşım gerektirse de, YSA ile stokastik modelleme yöntemlerini karşılaştırabilmek için bu çalışmada otheregresif ve çoklu lineer değişkenli regresyon modelleri kullanılmıştır. Farklı sayıda girdi kombinasyonları ve gizli tabaka sayısı, çok tabakalı algılayıcıdan en iyi sonucu almak amacıyla denenmiş ve bu modeller AR(p) ve MLR modelleriyle karşılaştırılmıştır.

4.2.1. Aylık Buharlaşma Miktarının Tahmin Edilmesi

Yapılan çalışmada YSA, MLR ve AR(p) model uygulamalarında DSİ den elde edilen ve düzenlenen veriler $(t-1), (t-2), \dots, (t-6)$ zaman aralığına kadar ötelenmiş ve modellemede kullanılan girdi ve çıktı veri dosyaları oluşturulmuştur. Yapılan

çalışmada, YSA modeli ile hazne buharlaşma miktarının belirlenmesi problemi çözümlenirken, 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 kullanılmıştır.

Baraj haznesindeki ölçülen buharlaşma verilerine YSA modelinin uygulanması iki adımdan oluşmaktadır. İlk adım sinir ağlarının eğitimi, ikinci adım test aşamasıdır. Eğitim aşamasında 240 aylık hazne üzerinde ölçülen buharlaşma miktarları kullanılmıştır. Eğitim aşaması tamamlandıktan sonra MLP'ler diğer 103 aylık gözlemlerden oluşan test verilerine uygulanmıştır. Benzer şekilde MLR ve AR (1) ve AR(6) modelleri için aynı eğitim ve test verileri kullanılmıştır. Bu çalışmalar sonucunda elde edilen sonuçlar aşağıda Çizelge 4.2'de verilmiştir. Bu tip çalışmalarda unutulmaması gereken şeylerden birisi, YSA için uygun bir ağ yapısı belirlemektir. Bu konu hesap karmaşıklığını ve genelleme yapabilme yetisini bire bir ilgilendirdiğinden önemli bir konu olduğu Cığizoğlu (2003-b) tarafından bir çok makalede bildirilmektedir. Bu nedenle, eğitim aşamasında çok sayıda deneme sonrasında MLP yapısı belirlenmiştir. Bu çalışma için, en verimli MLP yapısı olarak 6 nodlu, bir gizli tabakalı ve bir çıktı nöronu olan YSA modeli seçilmiştir.

Çizelge 4.2. Tahtaköprü Barajında kullanılan bütün modellerde test verileri için elde edilen MSE, MAE ve R parametrelerinin karşılaştırılması

Modeller	Giriş Kombinasyonları	MSE (m ³) ²	MAE (m ³)	R
MLR	A.T.B.S.M	542069	626	0.87
AR(3)	A.T.B.S.M	791191	542	0.81
AR(6)	A.T.B.S.M	693907	517	0.74
YSA	A.T.B.S.M	0,002	0,393	0,94

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

Bu uygulamalar sonucunda modellerin performansını göstermek amacıyla Çizelge 4.2 verilmiştir. Çizelge 4.2 incelendiğinde, test verileri için en uygun modelin,

YSA modeli olduğu ve en yüksek korelasyon ($R=0,94$) ve en düşük MSE (0,002) ve MAE (0,393) hatası verdiği açıkça görülmektedir. Bunun yanı sıra yine aynı test verileri için MLR modelinin $R=0,87$ korelasyon ve yüksek hata değerleri verdiği, fakat yinede AR(3) ve Ar(6) modeli ile kıyaslandığında ($R(3)=0,81$ ve $R(6)=0,74$) daha gerçeğe uygun sonuçlar verdiği gözlenmiştir.

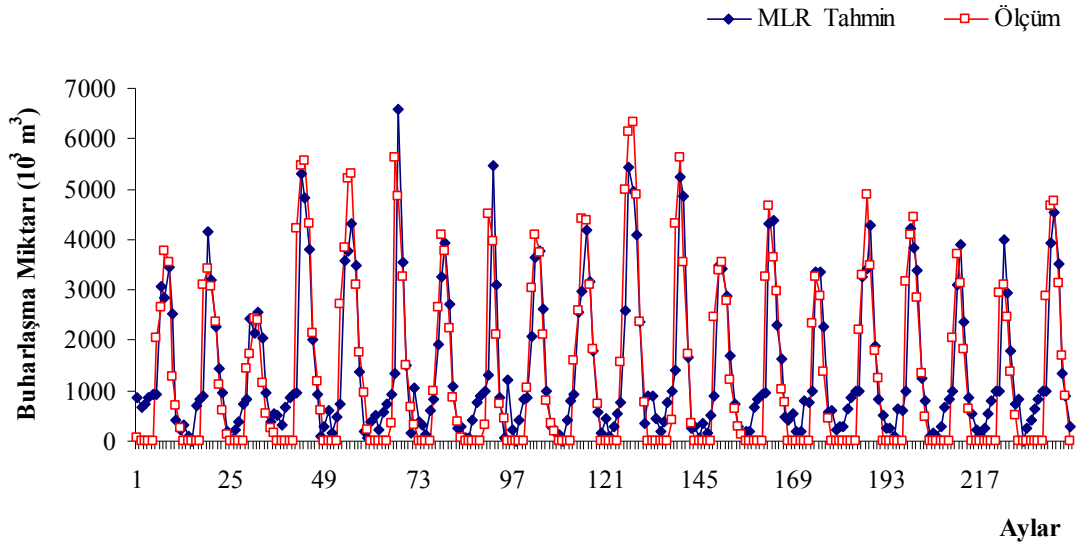
Şekillerden de anlaşılabilceği üzere ilk girdi kombinasyonu için hem YSA hem de MLR'nin performansının uyum göstermediği korelasyon katsayılarında açıkça görülmektedir. Diğer sonuçlardan da görülebileceği üzere model tahminlerinin daha dağınık olduğu ve bunun da yüksek MSE, MAE ve daha düşük R değerleri verdiği gözlenmiştir. 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 diğer bir 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 4.3'de MLR eğitim sürecinde sonuç tahminleri ile ölçüm değerleri karşılaştırması görülmektedir. Şekil 4.4'de test süreci için MLR aylık buharlaşma miktarı tahminleri ve ölçüm değerleri karşılaştırılmış, Şekil 4.5'de bu ilişki saçılma diyagramı formatında verilmiştir.

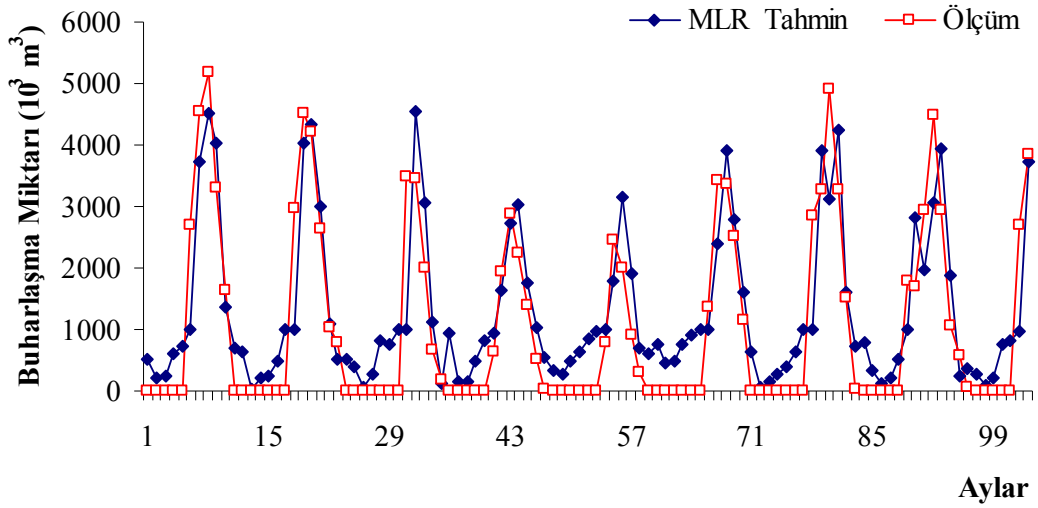
MLR model ile eğitim verileri kullanılarak oluşturulan aşağıdaki denklem test verilerine uygulanmıştır.

$$y = 0.216 + 1.019x_1 - 0.419x_2 - 0.132x_3 - 0.079x_4 + 0.167x_5 - 0.311x_6 \quad (4.4)$$


Eğitimde de elde edilen ve test içinde kullanılan bu denklemin sonucunda Çizelge 4.2' de görüldüğü gibi $R=0.87$ ile iyi sayılabilecek bir sonuç vermiştir.



Şekil 4.3. MLR metodu ile eğitimde elde edilmiş buharlaşma miktarı sonuçları ve ölçüm değerlerinin karşılaştırılması



Şekil 4.4. MLR metodu ile test de elde edilmiş buharlaşma miktarı sonuçları ve ölçüm değerlerinin karşılaştırılması



Şekil 4.5. MLR sonuçları ile ölçüm değerlerinin 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 modelleri ve bunların tahmin performansları göl kotu değişiminin zaman serileri için uygulanmıştır. Böylece YSA modelinde kullanılan aylık buharlaşma miktarı data setleri stokastik AR(p) modeline uygulanmıştır. Girdi katmanı nodları önceki geçmiş aylık buharlaşma miktarı data setleri olarak alınmıştır. Girdi verisi olarak geriye doğru önceki altı aylık buharlaşma miktarı zaman serisi (.t-1,t-2,...,t-6 katı) alınmıştır. Çıktı veya karşılaştırma verisi olarak ise t anına karşılık gelen aylık buharlaşma miktarı alınmıştır. Bu çalışmada, 6 tane, AR(1-6), AR modeli oluşturulmuş. Fakat karşılaştırmada AR(3) ve AR(6) kullanılmıştır. Diğer modellere kıyasla, kullanılan modeller arasında AR(3 ve 6) modelinin test aşaması için en yüksek MSE ve MAE değerini ve en düşük R katsayılarını (0,74-0,81) verdiği görülmüştür.

Kurulan otoregresif modellerden AR(3) ve AR(6)'nın denklemleri bu çalışmada verilmiştir.

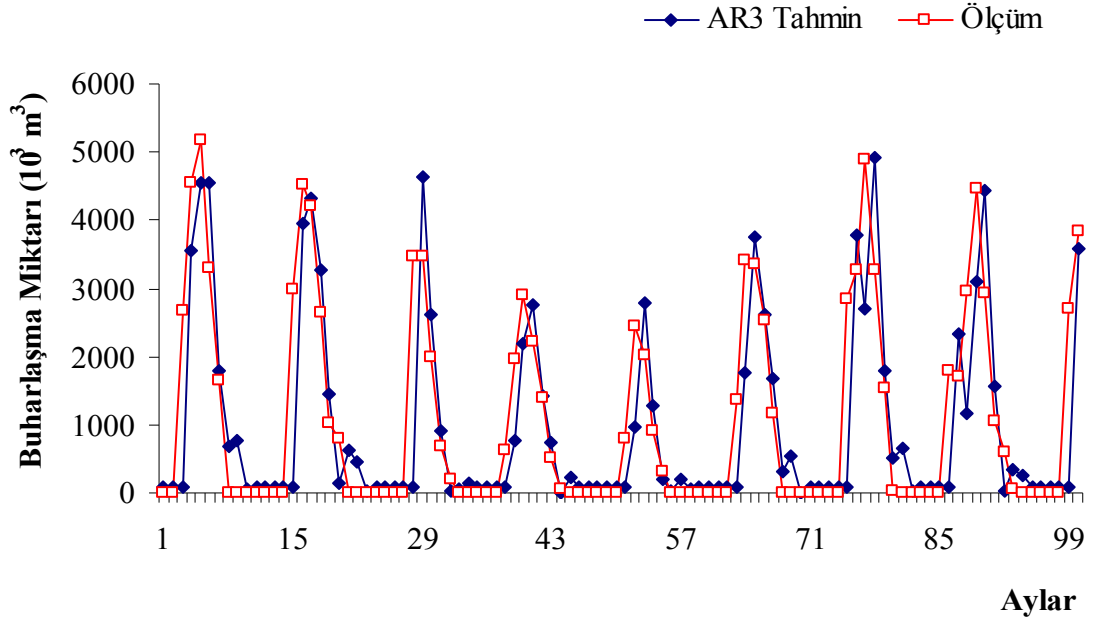
AR(3) denklemi

$$y = 1 - 1.363(t - 1) + 0.583(t - 2) - 0.088(t - 3) \quad (4.5)$$


AR(6) denklemi

$$y = 1 - 1.328(t - 1) + 0.484(t - 2) + 0.052(t - 3) - 0.002(t - 4) - 0.099(t - 5) - 0.004(t - 6) \quad (4.6)$$


AR(3) ve AR(6) modellerinin performansları sırasıyla Şekil 4.6, 4.7, 4.8 ve 4.9'da gösterilmiştir. Çizelge 4.2'de görüldüğü gibi AR(3) ve AR(6)'da sırasıyla $R=0.81$ ve $R=0,74$ 'lük bir korelasyon elde edilmiştir. Bu şekillerden görülebileceği üzere AR(3)'ün performansının AR(6)'ya göre daha iyi sonuç verdiği gözlemlenmiştir.




Şekil 4.6. Otoresif modelde aylık buharlaşma miktarlarının AR(3) ile ölçüm değerlerinin karşılaştırılması



Şekil 4.7. AR(3) sonuçları ile ölçüm değerlerinin saçılma diyagramı



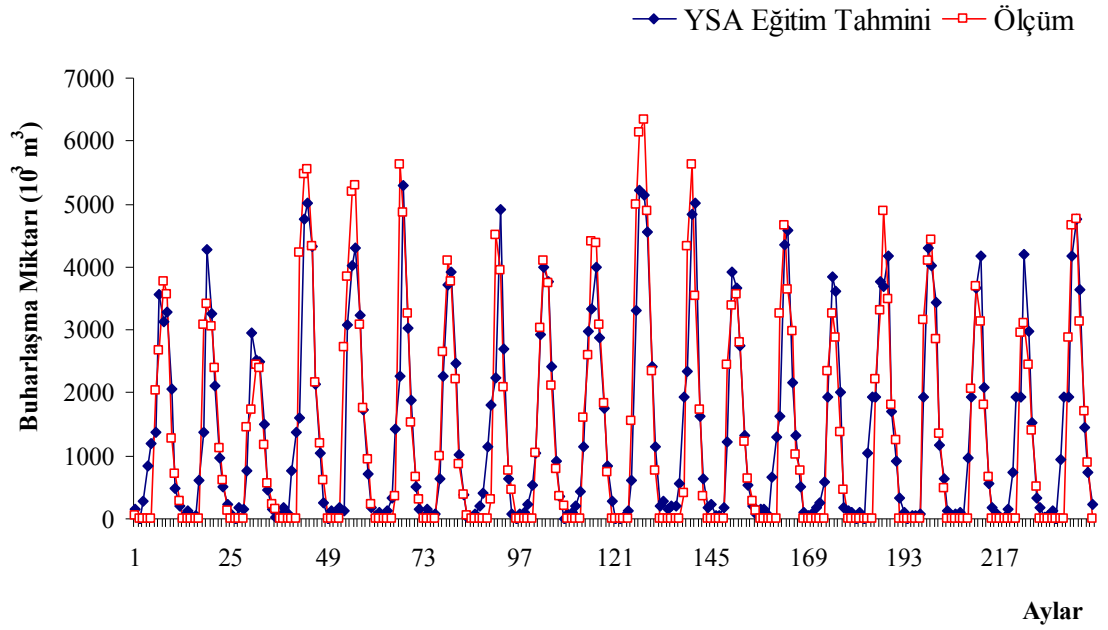
Şekil 4.8. Otoregresif modelde aylık buharlaşma miktarlarının AR(6) ile ölçüm değerlerinin karşılaştırılması




Şekil 4.9. AR(6) sonuçları ile ölçüm değerlerinin saçılma diyagramı

Bu çalışma için kurulan YSA modelinde eğitim ve test verileri için ayrı ayrı tahmin sonuçları ve gözlemlenen buharlaşma miktarları sırasıyla Şekil 4.10, 4.11, 4.12, 4.13' de verilmiştir. Çizelge 4.2' de görüldüğü gibi YSA modelinin test verileri için % 94' lük bir korelasyonla gerçek değerlere yaklaştığı belirlenmiştir.

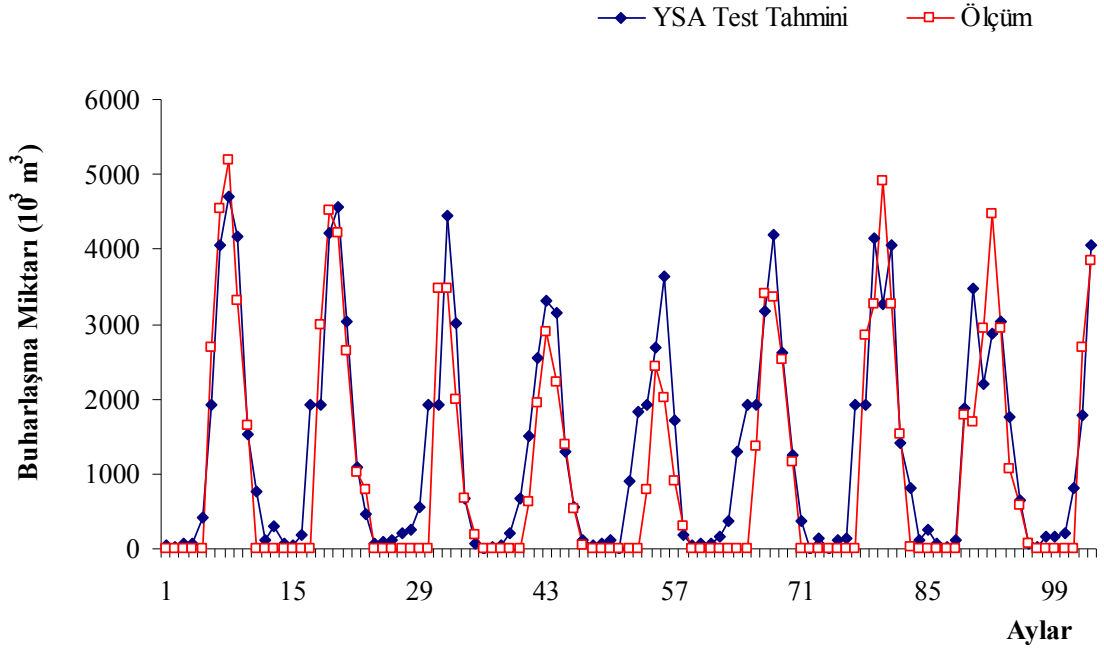
Bütün veriler ve olayın fiziği dikkate alındığında, YSA modelinin diğer iki klasik metoda göre daha iyi sonuç verdiği görülmektedir. Burada dikkat edilmesi gereken önemli husus, YSA modelinin çok değişkenli bir yapıya sahip olmasına rağmen çok iyi sonuçlar elde edilmesidir.




Şekil 4.10. YSA modelinde aylık buharlaşma miktarı eğitim sonuçları ile ölçüm değerlerinin karşılaştırılması



Şekil 4.11. YSA eğitim sonuçları ve ölçüm verileri sonuçları için saçılma diyagramı



Şekil 4.12. YSA modelinde aylık buharlaşma miktarı test sonuçları ile ölçüm değerlerinin karşılaştırılması



Şekil 4.13. YSA test sonuçları ve ölçüm verileri sonuçları için saçılma diyagramı

5. SONUÇ VE ÖNERİLER

Bu çalışmada; Tahtaköprü barajındaki aylık buharlaşma miktarları Yapay Sinir Ağları (YSA) ile tahmin edilmiştir. Çok katmanlı YSA modeli tahminleri, baraj aylık buharlaşma miktarları arazi ölçümleri ve geleneksel istatistiksel ve stokastik modeller ile karşılaştırılmıştır. Bu sonuçlara dayanarak, bu çalışmanın su kaynakları literatürüne getirdiği katkılar aşağıdaki gibi sıralanabilir.

Bu çalışmada, ortalama aylık buharlaşma miktarı parametre olarak kullanılmıştır. Bu uygulamada sunulan YSA modeli, geleneksel modellerle karşılaştırıldığında daha 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 iyi sayılabilecek korelasyon değerleri sağlayabilmiştir. Yine de, YSA'nın gösterdiği performans MLR modeline göre daha iyi sonuç vermiştir.

Fakat burada dikkat edilmesi gereken önemli husus, YSA modelinin çok değişkenli bir yapıya sahip olmasına rağmen çok iyi sonuçlar elde edilebilmesidir. Bütün veriler ve olayın gerçekleştiği fiziki ortam dikkate alındığında YSA modeli doğadaki fiziksel olayları modellemek için daha uygundur.

YSA, baraj hazne planlanmasında ortaya çıkan ve yapılması gereken değişikliklere ve koşullara daha kolay ve doğru bir şekilde adapte olabilmektedir. YSA'nın geleneksel metotlardan daha avantajlı olmasının sebebi YSA yapısının problemin lineer olmayan dinamiklerini ve tüm veri 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'nın 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.
- Çiğizoğlu, H.K., 2004. **İTÜ ders notları**
- Çalım, M.M., 2006. **Yapay Sinir Ağları Yöntemi İle Baraj Hazne Kotu Tahmini**. MKÜ Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü,
- Dawson, C. W., and Wilby, R., 1998. **An artificial neural network approach to rainfall-runoff modeling**. Hydrological Sci., 43(1), 47–66.
- Doğan, E., Işık, S. ve Sandalcı, M., 2007. **Günlük Buharlaşmanın Yapay Sinir Ağları Kullanarak Tahmin Edilmesi**. İMO Teknik Dergi, 4119-4131, Yazı 271.
- Elmas, Ç., Seçkin Y., 2003, **Yapay Sinir Ağları**.
- 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. 55
- 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.
- Keskin, M.E., Taylan, E. D., 2007. **Orta Akdeniz Havzasındaki Akımların Stokastik Modellemesi**. *İMO Teknik Dergi*, 4271-4291, Yazı 282.
- 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.
- McCullough, W. and Pitts, W., 1943. **A Logical Calculus of Ideas Immanent in Nervous Activity**. *Bul. Math. Biophys.* 5, 115-133.
- Minns, A. W., and Hall, M. J., 1996. **Artificial neural networks as rainfall-runoff models**. *Hydrologic Sci.*, 41(3), 1996.
- Minsky, M. and Papert, S., 1969, *Perceptron*, MIT Press, Cambridge.
- 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., Kothiyari, 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 processing, Vol. 1, MIT Press, Cambridge, Mass., 318–362. 56
- 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.
- Terzi, Ö. ve Keskin, M.E., 2007. **Yapay Sinir Ağları Yaklaşımı Kullanılarak Günlük Tava Buharlaşması Tahmini**. İMO Teknik Dergi, 3683-3693, Yazı 243.
- Tokar, A. S., and Johnson, P. A., 1999. **Rainfall-runoff modeling using artificial neural networks**. J. Hydrologic Engrg., ASCE, 4(3), 232– 239.
- 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.
- www.mcatürk.com/Sinir-Sistemimiz_244.htm

TEŐEKKÜR

Tez alıřmamın her ařamasında, dűőüncelerinden ve bilgilerinden istifade ettiđim bunun yanında ilgi ve yardımlarını aldıđım, danıřman hocam Sayın Yrd. Do. Dr. Fatih ÜNEŐ' e en iten teőekkürlerimi sunarım.

Bu yüksek lisans alıřmasının ders ve tez ařamasında, deđerli görűő, katkı ve bilgilerini esirgemeyen, tüm M.K.Ü. İnőaat Műhendisliđi bölűmű öğretim üyelerine en iten teőekkürlerimi sunarım. Tez ařamasında bana destek olan Do. Dr. Ali KO ve İnő. Yük. Műh. Hakan VARİN ile İskenderun Meslek Yüksekokulu öğretim görevlilerine en iten teőekkürlerimi sunarım.

Ayrıca alıřmalarım sırasında sabırla bana destek veren aileme sonsuz teőekkürler ederim.

ÖZGEÇMİŞ

1967 yılında HATAY' ın İskenderun ilçesinde doğdu. İlkokulu Kılıç Ali Paşa ilkokulunda bitirdi. Ortaokulu Atatürk Ortaokulunda okudu. Lise öğrenimini 1984 yılında İskenderun Lisesinde tamamladı. 1986 yılında Süleyman Demirel Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği bölümünü kazandı. 1994 Şubat döneminde İnşaat Mühendisi olarak mezun oldu. 1998 yılında Hatay Mustafa Kemal Üniversitesi İskenderun Meslek Yüksekokulu İnşaat programında öğretim görevlisi olarak çalışmaya başladı. Hatay Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalında yüksek lisans eğitimime devam etmektedir.

Çizelge Ek.1. Tahtaköprü barajında kullanılan tüm verilerin aylık ortalama değerleri

Yıl	Sıra	Aylar	Aylık Toplam Buharlaşan Su (x103m3)	Yıl	Sıra	Aylar	Aylık Toplam Buharlaşan Su (x103m3)	
1976	1	HAZİRAN	1024	1980	44	OCAK	0	
	2	TEMMUZ	1089		45	ŞUBAT	0	
	3	AĞUSTOS	824,8		46	MART	0	
	4	EYLÜL	437,141		47	NİSAN	0	
	5	EKİM	289,508		48	MAYIS	4217,1	
	6	KASIM	255,958		49	HAZİRAN	5479,6	
	7	ARALIK	51,90		50	TEMMUZ	5546,9	
1977	8	OCAK	0		51	AĞUSTOS	4323,3	
	9	ŞUBAT	0		52	EYLÜL	2156,7	
	10	MART	0		53	EKİM	1198,6	
	11	NİSAN	0		54	KASIM	603,7	
	12	MAYIS	2037		55	ARALIK	0	
	13	HAZİRAN	2664,975		1981	56	OCAK	0
	14	TEMMUZ	3757,644			57	ŞUBAT	0
	15	AĞUSTOS	3559,144			58	MART	0
	16	EYLÜL	1264,305	59		NİSAN	2711,4	
	17	EKİM	704,199	60		MAYIS	3849,8	
18	KASIM	270,86	61	HAZİRAN		5195,2		
19	ARALIK	0	62	TEMMUZ		5298,4		
1978	20	OCAK	0	63		AĞUSTOS	3086	
	21	ŞUBAT	0	64		EYLÜL	1766,5	
	22	MART	0	65		EKİM	951,4	
	23	NİSAN	0	66	KASIM	235		
	24	MAYIS	3085,3	67	ARALIK	0		
	25	HAZİRAN	3419	1982	68	OCAK	0	
	26	TEMMUZ	3065,3		69	ŞUBAT	0	
	27	AĞUSTOS	2381,038		70	MART	0	
	28	EYLÜL	1114,4		71	NİSAN	0	
	29	EKİM	607,8		72	MAYIS	344,517	
	30	KASIM	130,9		73	HAZİRAN	5625	
	31	ARALIK	0		74	TEMMUZ	4864	
1979	32	OCAK	0		75	AĞUSTOS	3251,9	
	33	ŞUBAT	0		76	EYLÜL	1517,8	
	34	MART	0		77	EKİM	674	
	35	NİSAN	1444,2		78	KASIM	307,8	
	36	MAYIS	1724,8		79	ARALIK	0	
	37	HAZİRAN	2439,3					
	38	TEMMUZ	2382,3					
	39	AĞUSTOS	1163,2					
	40	EYLÜL	549,6					
	41	EKİM	241,1					
	42	KASIM	146,8					
	43	ARALIK	0					

Yıl	Sıra	Aylar	Aylık Toplam Buharlaşan Su (x103m3)	Yıl	Sıra	Aylar	Aylık Toplam Buharlaşan Su (x103m3)
1983	80	OCAK	0	1986	116	OCAK	0
	81	ŞUBAT	0		117	ŞUBAT	0
	82	MART	0		118	MART	0
	83	NİSAN	995,5		119	NİSAN	1599
	84	MAYIS	2641,5		120	MAYIS	2589,7
	85	HAZİRAN	4092		121	HAZİRAN	4399,9
	86	TEMMUZ	3778		122	TEMMUZ	4387
	87	AĞUSTOS	2227		123	AĞUSTOS	3092
	88	EYLÜL	864		124	EYLÜL	1824
	89	EKİM	375		125	EKİM	740,2
	90	KASIM	48,6		126	KASIM	0
91	ARALIK	0	127	ARALIK	0		
1984	92	OCAK	0	1987	128	OCAK	0
	93	ŞUBAT	0		129	ŞUBAT	0
	94	MART	0		130	MART	0
	95	NİSAN	0		131	NİSAN	1557,9
	96	MAYIS	306		132	MAYIS	4990
	97	HAZİRAN	4517,4		133	HAZİRAN	6131
	98	TEMMUZ	3955		134	TEMMUZ	6340
	99	AĞUSTOS	2097		135	AĞUSTOS	4882
	100	EYLÜL	751		136	EYLÜL	2350
	101	EKİM	450		137	EKİM	774
	102	KASIM	0		138	KASIM	0
103	ARALIK	0	139	ARALIK	0		
1985	104	OCAK	0	1988	140	OCAK	0
	105	ŞUBAT	0		141	ŞUBAT	0
	106	MART	0		142	MART	0
	107	NİSAN	1048		143	NİSAN	0
	108	MAYIS	3036		144	MAYIS	414,5
	109	HAZİRAN	4101		145	HAZİRAN	4322,8
	110	TEMMUZ	3746		146	TEMMUZ	5618
	111	AĞUSTOS	2125		147	AĞUSTOS	3548
	112	EYLÜL	797		148	EYLÜL	1719
	113	EKİM	350		149	EKİM	344,5
	114	KASIM	193		150	KASIM	0
115	ARALIK	0	151	ARALIK	0		

Yıl	Sıra	Aylar	Aylık Toplam Buharlaşan Su (x103m3)	Yıl	Sıra	Aylar	Aylık Toplam Buharlaşan Su (x103m3)
1989	152	OCAK	0	1992	188	OCAK	0
	153	ŞUBAT	0		189	ŞUBAT	0
	154	MART	0		190	MART	0
	155	NİSAN	2445,8		191	NİSAN	0
	156	MAYIS	3387,5		192	MAYIS	2218
	157	HAZİRAN	3556,2		193	HAZİRAN	3300
	158	TEMMUZ	2789		194	TEMMUZ	4878
	159	AĞUSTOS	1218,4		195	AĞUSTOS	3479
	160	EYLÜL	628,9		196	EYLÜL	1795
	161	EKİM	278,3		197	EKİM	1239
	162	KASIM	136		198	KASIM	0
	163	ARALIK	0		199	ARALIK	0
1990	164	OCAK	0	1993	200	OCAK	0
	165	ŞUBAT	0		201	ŞUBAT	0
	166	MART	0		202	MART	0
	167	NİSAN	0		203	NİSAN	0
	168	MAYIS	3266		204	MAYIS	3158
	169	HAZİRAN	4661		205	HAZİRAN	4094
	170	TEMMUZ	3629		206	TEMMUZ	4428
	171	AĞUSTOS	2969		207	AĞUSTOS	2844
	172	EYLÜL	1016		208	EYLÜL	1344
	173	EKİM	756		209	EKİM	489
	174	KASIM	0		210	KASIM	0
	175	ARALIK	0		211	ARALIK	0
1991	176	OCAK	0	1994	212	OCAK	0
	177	ŞUBAT	0		213	ŞUBAT	0
	178	MART	0		214	MART	0
	179	NİSAN	0		215	NİSAN	0
	180	MAYIS	2332		216	MAYIS	2057
	181	HAZİRAN	3268		217	HAZİRAN	3695
	182	TEMMUZ	2882		218	TEMMUZ	3132
	183	AĞUSTOS	1377		219	AĞUSTOS	1806
	184	EYLÜL	446		220	EYLÜL	651
	185	EKİM	0		221	EKİM	0
	186	KASIM	0		222	KASIM	0
	187	ARALIK	0		223	ARALIK	0

Yıl	Sıra	Aylar	Aylık Toplam Buharlaşan Su (x103m3)	Yıl	Sıra	Aylar	Aylık Toplam Buharlaşan Su (x103m3)
2001	296	OCAK	0	2004	332	OCAK	0
	297	ŞUBAT	0		333	ŞUBAT	0
	298	MART	0		334	MART	0
	299	NİSAN	0		335	NİSAN	1782
	300	MAYIS	783		336	MAYIS	1696
	301	HAZİRAN	2440		337	HAZİRAN	2948
	302	TEMMUZ	2008		338	TEMMUZ	4470
	303	AĞUSTOS	906		339	AĞUSTOS	2940
	304	EYLÜL	304		340	EYLÜL	1064
	305	EKİM	0		341	EKİM	589
	306	KASIM	0		342	KASIM	62
	307	ARALIK	0		343	ARALIK	0
	2002	308	OCAK		0	2005	344
309		ŞUBAT	0	345	ŞUBAT		0
310		MART	0	346	MART		0
311		NİSAN	0	347	NİSAN		0
312		MAYIS	1364	348	MAYIS		2690
313		HAZİRAN	3411	349	HAZİRAN		3837
314		TEMMUZ	3350				
315		AĞUSTOS	2517				
316		EYLÜL	1156				
317		EKİM	0				
318		KASIM	0				
319	ARALIK	0					
2003	320	OCAK	0				
	321	ŞUBAT	0				
	322	MART	0				
	323	NİSAN	0				
	324	MAYIS	2853				
	325	HAZİRAN	3270				
	326	TEMMUZ	4900				
	327	AĞUSTOS	3276				
	328	EYLÜL	1522				
	329	EKİM	22				
	330	KASIM	0				
331	ARALIK	0					