

**T.C.
KIRKLARELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YALOVA GÖKÇE BARAJININ SU SEVİYESİNİN YAPAY SİNİR AĞLARI İLE
TAHMİN EDİLMESİ**

YÜKSEK LİSANS TEZİ

Yunus DAMLA

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

İNŞAAT MÜHENDİSLİĞİ PROGRAMI

**Tez Danışmanı: Doktor Öğretim Üyesi Erdiñ KESKİN
Eş Danışman : Doktor Öğretim Üyesi Temel TEMİZ**

TEMMUZ 2020

**T.C.
KIRKLARELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YALOVA GÖKÇE BARAJININ SU SEVİYESİNİN YAPAY SİNİR AĞLARI İLE
TAHMİN EDİLMESİ**

YÜKSEK LİSANS TEZİ

**Yunus DAMLA
(1178202110)**

**İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI
İNŞAAT MÜHENDİSLİĞİ PROGRAMI**

**Tez Danışmanı : Doktor Öğretim Üyesi Erdiñ KESKİN
Eş Danışman : Doktor Öğretim Üyesi Temel TEMİZ**

29 Temmuz 2020

ÖNSÖZ VE TEŞEKKÜR

Bu çalışma, bilim ve teknolojinin gelişmesine paralel olarak insan beynini oluşturan sinir sistemini taklit eden algılayıcılar yardımı ile daha önceden öğrenilmiş veya sınıflandırılmış olan bilgileri kullanarak bunlardan yeni bilgiler ve aynı zamanda karar verecek sonuç oluşturabilen yapay sinir ağının kullanılması ile Yalova Gökçe Barajının rezervuarındaki su seviyesinin tahmin edilmesi amacıyla yapılmıştır.

Bana bu konuda çalışma fırsatı veren ve bu çalışmanın bir tez olarak kazanılmasında fikirleri ile destek olan Kırklareli Üniversitesi İnşaat Mühendisliği Bölümü Öğretim Üyesi Sayın Dr. Erdinç KESKİN'e ve eş danışmanım Yalova Üniversitesi İnşaat Mühendisliği Bölümü Öğretim Üyesi Sayın Dr. Temel TEMİZ'e teşekkürü bir borç bilirim. Ayrıca hayatım boyunca benden desteklerini esirgemeyen annem Hanife DAMLA'ya ve babam Adulvehap DAMLA'ya desteklerinden dolayı sonsuz minnetlerimi sunarım.

Temmuz 2020

Yunus DAMLA

İnşaat Mühendisi

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR.....	ii
ŞEKİLLER DİZİNİ	viii
ÖZET.....	xvi
SUMMARY	xviii
1. GİRİŞ	1
1.1 Genel Bilgiler	2
1.2 Çalışmanın Amacı	3
1.3 Çalışmanın Önemi	3
2. LİTERATÜR ÇALIŞMASI	5
3. YAPAY SİNİR AĞLARI (ARTİFİCAL NEURAL NETWORKS).....	11
3.1 Yapay Sinir Ağanın Elemanları	13
3.2 Yapay Sinir Ağlarının Tarihçesi.....	14
3.2.1 1980 Öncesi yapay sinir ağı tarihsel gelişimi	14
3.2.2 1980 Sonrası yapay sinir ağı tarihsel gelişimi	15
3.3 Yapay Sinir Ağlarında Aktivasyon Fonksiyonları	16
3.3.1 Eşik (adım) aktivasyon fonksiyonu	16
3.3.2 Doğrusal aktivasyon fonksiyonu	16
3.3.3 Logaritma sigmoid transfer (lojistik) aktivasyon fonksiyonu.....	17
3.3.4 Hiperbolik tanjant aktivasyon fonksiyonu	17
3.4 Yapay Sinir Ağlarının Sınıflandırılması.....	18
3.4.1 İleri beslemeli (Feed forwad) yapay sinir ağı	18
3.4.2 Geri beslemeli (Feed back) yapay sinir ağı	19
3.5 Öğrenme Algoritmalarına Göre Yapay Sinir Ağları	19
3.5.1 Danışmanlı öğrenme (supervised learning) metodu	20
3.5.2 Danışmansız öğrenme (unsupervised learning) metodu	22
3.5.3 Pekiştirmeli öğrenme (Reinforcement Learning) metodu.....	23
3.6 Çok katmanlı perseptronlar (MLP) ve öğrenme algoritmaları	23
3.7 Yapay Sinir Ağlarının Uygulama Alanları.....	24
4. REGRESYON ANALİZİ	25

4.1 Tek Değişkenli Regresyon Analiz Modeli	26
4.2 Çok Değişkenli Regresyon Analiz Modeli	26
5. ÇALIŞMA ALANI	27
5.1 Gökçe Barajı Yeri ve Gölalanı (Rezervuar) Jeolojisi	28
5.2 Yalova Gökçe Barajı	29
5.2.1 Gökçe barajı tesisleri.....	29
5.3 İklim.....	34
5.4 Yağış.....	35
5.5 Sıcaklık	35
5.6 Buharlaşma	36
5.7 Rüzgâr.....	37
5.8 Gökçe Barajı Su Kaynağı	38
5.9 Gökçe Barajı Su Tahliyesi	39
5.10 Gökçe Barajı Rezervuar Su Değişimi.....	40
6. YÖNTEM.....	45
6.1 Yalova Gökçe Barajının Su Seviyesinin Tahmin Edilmesinde Kullanılan Veriler.....	45
6.1.1 Yağış miktarı.....	45
6.1.2 Buharlaşma miktarı	46
6.1.3 Giren debi miktarı	46
6.1.4 Sızma miktarı	47
6.1.5 Yalova Gökçe Barajından çıkan debiler	47
6.1.6 Yalova Gökçe Baraj rezervuar su seviyesi (kot).....	48
6.2 Yalova Gökçe Barajı su seviyesinin tahmininde kullanılan MATLAB	48
6.2.1 MATLAB programının uygulama alanları	48
6.2.2 MATLAB programının ana kısımları	49
6.2.3 MATLAB programlama dili	49
6.2.4 MATLAB geliştirme ortamı	50
6.2.5 MATLAB programında grafik işlemleri.....	50
6.2.6 MATLAB programının matematiksel fonksiyon kütüphanesi	50
6.2.7 MATLAB uygulama programı ara birimi.....	51
6.2.8 MATLAB programındaki yapay sinir ağı eğitim fonksiyonları	51
6.2.9 MATLAB programında eğitim ve test işlemi	51

6.3 Analiz Verilerinin Normalizasyonu	52
6.4 Tez Analizinde Kullanılan Hata Formülleri	53
6.4.1 Ortalama kare hata (Mean Squared Error (MSE)).....	53
6.4.2 Ortalama mutlak yüzde hata (Mean Absolute Percentage Error (MAPE))	54
6.4.3 Ortalama mutlak hata (Mean Absolute Error (MAE)).....	54
6.5 MATLAB'ta seçilen yapay sinir ağı eğitim fonksiyonları.....	55
7. ANALİZ	55
7.1 Çoklu Regresyon Analizi Veri Çalışması.....	57
7.2 Levenberg-Marquardt (Trainlm) eğitim fonksiyonu analizi veri çalışmaları... 60	
7.2.1 Nöron sayısının belirlenmesi	60
7.2.2 Gizli hücre sayısının belirlenmesi.....	61
7.2.3 Çevrim sayısının belirlenmesi	62
7.2.4 Variant sayısının belirlenmesi	63
7.2.5 Öğrenme kat sayısının belirlenmesi.....	64
7.2.6 Momentum kat sayısının belirlenmesi.....	65
7.2.7 Levenberg-Marquardt (Trainlm) eğitim fonksiyonu analizindeki en yüksek veri sonuçları.....	66
7.3 Gradient Descent With Momentum (Traindm) Eğitim Fonksiyonu Analizi	
Veri Çalışmaları.....	75
7.2.1 Nöron sayısının belirlenmesi	75
7.3.2 Gizli hücre sayısının belirlenmesi.....	76
7.3.3 Çevrim sayısının belirlenmesi	77
7.3.4 Variant sayısının belirlenmesi	78
7.3.5 Öğrenme kat sayısının belirlenmesi.....	79
7.3.6 Momentum kat sayısının belirlenmesi.....	80
7.3.7 Gradient Descent with Momentum (Traindm) eğitim fonksiyonu	
analizindeki en yüksek veri sonuçları.....	81
8. SONUÇ ve ÖNERİLER.....	91
KAYNAKLAR	95
EKLER	99
ÖZGEÇMİŞ	101

ŞEKİLLER DİZİNİ

Şekil 3.1	: Sinir hücresi (Soycan, 2008).	11
Şekil 3.2	: Sinir sistemindeki bilgi akışı (Soycan, 2008).	12
Şekil 3.3	: Yapay sinir ağı örneği (Keskenler, 2017)	13
Şekil 3.4	: Eşik aktivasyon fonksiyonu (Öztemel, 2003).	16
Şekil 3.5	: Doğrusal aktivasyon fonksiyonu (Öztemel, 2003)	16
Şekil 3.6	: Logaritma sigmoid aktivasyon fonksiyonu (Öztemel, 2003).	17
Şekil 3.7	: Hiperbolik tanjant aktivasyon fonksiyonu (Öztemel, 2003).	17
Şekil 3.8	: İleri beslemeli yapı (Öztemel, 2003)	18
Şekil 3.9	: Geri beslemeli yapı (Öztemel, 2003)	19
Şekil 3.10	: Danışmanlı öğrenme yapısı (Öztemel, 2003)	21
Şekil 3.11	: Geri yayılım (MLP) yapısı (Öztemel, 2003)	23
Şekil 5.1	: Çalışma alanının genel görünümü (Google Earth görüntüsü, 2020)	27
Şekil 5.2	: Çalışma alanı genel görünümü (Google Earth görüntüsü, 2020)	27
Şekil 5.3	: Çalışma alanı genel görünümü (Google Earth görüntüsü, 2020)	28
Şekil 5.5	: Gökçe barajı gövde genel görüntüsü	30
Şekil 5.6	: Rezervuar alanı genel görünümü (Google Earth görüntüsü, 2020)	30
Şekil 5.7	: Gökçe barajı hacim satıh grafiği	31
Şekil 5.8	: Gökçe barajı rezervuar (baraj gölü) genel görüntüsü	32
Şekil 5.9	: Gökçe barajı dolu savak genel görüntüsü	32
Şekil 5.10	: Gökçe barajı dolu savak genel görüntüsü	33
Şekil 5.11	: Gökçe barajı dip savak+vana odası genel görüntüsü	33
Şekil 5.12	: Gökçe barajı su alma yapısı genel görüntüsü	34
Şekil 5.13	: 2000-2019 yılları arasındaki aylık toplam yağış miktarı	35
Şekil 5.14	: Yıllık ortalama sıcaklık değişim grafiği	36
Şekil 5.15	: Aylık ortalama sıcaklık değişim grafiği	36
Şekil 5.17	: Aylık ortalama rüzgar hızı grafiği	37
Şekil 5.18	: 2000-2019 yılları arasındaki Sellimadıra deresinin aylık ortalama akış debisi	39
Şekil 5.19	: 2000-2019 yılları arasındaki Gökçe Barajından tahliye (dolu savak tahliye+içme suyu+ dip savak tahliyeleri) olan aylık toplam su miktarı	39
Şekil 5.20	: 2000-2019 yılları arasındaki Gökçe Barajının aylık ortalama rezervuar su kotu	40
Şekil 5.21	: Gökçe Barajı 2019 yılı aylık ortalama göl su kotu (seviye) değişim grafiği	39
Şekil 5.22	: Gökçe barajı yıllık ortalama göl su kotu (seviye) değişim grafiği	39
Şekil 5.23	: Sellimandıra Deresi 2019 yılı aylık toplam debi değişim grafiği	42
Şekil 5.24	: Yıllık yağış+buharlaşma hacmi ve göl su kotu değişim grafiği	43
Şekil 5.25	: Yıllık yağış+buharlaşma hacmi ve sıcaklık değişim grafiği	43
Şekil 5.26	: Yıllık toplam yağış ve buharlaşma hacmi değişim grafiği	44
Şekil 6.1	: 2000-2019 yılları arasındaki Gökçe Barajından sızıntı su miktarı	47
Şekil 6.2	: MATLAB programı ara yüzü penceresi	50
Şekil 6.3	: Saklı katmanlı yapay sinir ağı modelindeki ağırlık ve hata grafiği (Temiz, 2015)	52

Şekil 7.1 : Çoklu regresyon tahmin değerleri ile gerçek değerlerinin saçılım grafiği. (a).....	58
Şekil 7.2 : Çoklu regresyon tahmin değerleri ile gerçek değerlerinin aylara göre saçılım grafiği. (b).....	59
Şekil 7.3 : 23 nolu analizin korelasyon (R) değerleri grafiği.....	66
Şekil 7.4 : 23 nolu analizin performans değeri grafiği.	66
Şekil 7.5 : 23 nolu analizin eğitim grafiği.	67
Şekil 7.6 : 23 nolu analizin gerçek seviye-YSA tahmin değerleri grafiği (a).....	68
Şekil 7.7 : 23 nolu analizin aylık gerçek seviye-YSA tahmin değerleri grafiği (b)	68
Şekil 7.8 : 59 nolu analizin korelasyon (R) değerleri grafiği.....	69
Şekil 7.9 : 59 nolu analizin performans değeri grafiği.	69
Şekil 7.10 : 59 nolu analizin eğitim grafiği.	70
Şekil 7.11 : 59 nolu analizin gerçek seviye-YSA tahmin değerleri grafiği (a).....	71
Şekil 7.12 : 59 nolu analizin aylık gerçek seviye-YSA tahmin değerleri grafiği(b)	71
Şekil 7.13 : 69 nolu analizin korelasyon (R) değerleri grafiği.....	72
Şekil 7.14 : 69 nolu analizin performans değeri grafiği.	72
Şekil 7.15 : 69 nolu analizin eğitim grafiği.	73
Şekil 7.16 : 69 nolu analizin gerçek seviye-YSA tahmin değerleri grafiği (a).....	74
Şekil 7.17 : 69 nolu analizin aylık gerçek seviye-YSA tahmin değerleri grafiği(b)	74
Şekil 7.18 : 32 nolu analizin korelasyon (R) değerleri grafiği.....	81
Şekil 7.19 : 32 nolu analizin performans değeri grafiği.	81
Şekil 7.20 : 32 nolu analizin eğitim grafiği.	82
Şekil 7.21 : 32 nolu analizin gerçek seviye-YSA tahmin değerleri grafiği (a).....	83
Şekil 7.22 : 32 nolu analizin aylık gerçek seviye-YSA tahmin değerleri grafiği (b)	83
Şekil 7.23 : 50 nolu analizin korelasyon (R) değerleri grafiği.....	84
Şekil 7.24 : 50 nolu analizin performans grafiği.	84
Şekil 7.25 : 50 nolu analizin eğitim grafiği.	85
Şekil 7.26 : 50 nolu analizin gerçek seviye-YSA tahmin değerleri grafiği (a).....	86
Şekil 7.27 : 50 nolu analizin aylık gerçek seviye-YSA tahmin değerleri grafiği (b)	86
Şekil 7.28 : 63 nolu analizin korelasyon (R) değerleri grafiği.....	87
Şekil 7.29 : 63 nolu analizin performans grafiği.	87
Şekil 7.30 : 63 nolu analizin eğitim grafiği.	88
Şekil 7.31 : 63 nolu analizin gerçek seviye-YSA tahmin değerleri grafiği (a).....	89
Şekil 7.32 : 63 nolu analizin aylık gerçek seviye-YSA tahmin değerleri grafiği (b)	89

ÇİZELGE DİZİNİ

Çizelge 5.1	: Gökçe barajı gövde karakteristik bilgileri	29
Çizelge 5.2	: Gökçe barajı rezervuarının karakteristik bilgileri.	31
Çizelge 7.1	: Çoklu regresyon analizi sonucu bulunan katsayılar.	57
Çizelge 7.2	: Çoklu regresyon analizi tahmin çizelgesi.....	57
Çizelge 7.3	: Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan nöron sayısı tespiti analiz çizelgesi.....	60
Çizelge 7.4	: Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan gizli hücre sayısı tespiti analiz çizelgesi.....	61
Çizelge 7.5	: Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan çevrim sayısı tespiti analiz çizelgesi.	62
Çizelge 7.6	: Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan çevrim sayısı tespiti analiz çizelgesi.	63
Çizelge 7.7	: Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan öğrenme kat sayısı tespiti analiz çizelgesi.....	64
Çizelge 7.8	: Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan momentum kat sayısı tespiti analiz çizelgesi.....	65
Çizelge 7.9	: 23 nolu analizdeki rezervuarın gerçek seviyesi ile YSA..... tahmin değerleri çizelgesi.	67
Çizelge 7.10	: 59 nolu analizdeki rezervuarın gerçek seviyesi ile YSA tahmin değerleri çizelgesi.....	70
Çizelge 7.11	: 69 nolu analizdeki rezervuarın gerçek seviyesi ile YSA tahmin değerleri çizelgesi.....	73
Çizelge 7.12	: Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan nöron sayısı tespiti analiz çizelgesi.....	75
Çizelge 7.13	: Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan gizli hücre sayısı tespiti analiz çizelgesi.....	76
Çizelge 7.14	: Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan çevrim sayısı tespiti analiz çizelgesi.....	77
Çizelge 7.15	: Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan variant sayısı tespiti analiz çizelgesi.....	78
Çizelge 7.16	: Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan öğrenme kat sayısı tespiti analiz çizelgesi.....	79
Çizelge 7.17	: Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan momentum kat sayısı tespiti analiz çizelgesi.....	80
Çizelge 7.18	: Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan 32 nolu analizinin tespit çizelgesi.....	82
Çizelge 7.19	: Gradient Descent with Momentum (Traindm) eğitim fonksiyon ile yapılan 50 nolu analizinin tespit çizelgesi.....	85
Çizelge 7.20	: Gradient Descent with Momentum (Traindm) eğitim fonksiyon ile yapılan 63 nolu analizinin tespit çizelgesi.....	88
Çizelge 7.21	: Çoklu regresyon analizi ile yapılan sonuç çizelgesi.....	90
Çizelge 7.22	: Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan sonuç çizelgesi.	90

Çizelge 7.23 : Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan sonuç çizelgesi.....	90
---	----

SİMGELER DİZİNİ

A	:m ² cinsinden göl alanı
A _i	:Ortalama kesit alanı
A _t	:Gerçek değer
b	: Bias
c	: Çıkış
C	: Rüzgâr hızı
E	: Buharlaşma miktarı
h	:Yükseklik, su seviyesi
K	:Bir sabit kat sayı değeri
	:Akım hızı
Q	: Debi
Q _{min.}	: Minimum debi
Q _o	:Çekilen debi
P	: Yağış
P _{Çınarcık}	: Çınarcık ilçesi yağış değeri
P _{ort.yağış}	: Ortalama yağış değeri
P _{Yalova}	: Yalova ili yağış değeri
R	: Korelasyon katsayısı
R ²	:Determimasyon katsayısı
S	:Sistemde depolanan su miktarı
T	: Havanın ortalama sıcaklığı
T _a	:Havanın sıcaklığı
T _w	:Suyun sıcaklığı
V	: Hacim
V _i	:Ortalama hızı
<i>max</i>	:Normalize edilecek olan en büyük değer
<i>min</i>	:Normalize edilecek olan en küçük değer
<i>N</i>	:Normalize edilmiş olan verinin değeri
<i>R</i>	:Normalize edilecek olan verinin değeri
w ₁ , w ₂ , w ₃ ..w _n	:Ağırlıklar
x ₁ , x ₂ , ...x _n	:Girdiler
Y _i	:Verinin kendi değeri
Y _i [^]	:Verinin ortalama değeri
y(t)	:Sistemden çevreye çıkan sular
Δ	: Sembolik gecikme süresi
η	: Öğrenme katsayısı
Σ	: Toplama fonksiyonu

KISALTMALAR

AAFNN	:Adaptive Activation Function Neural Network (Uyarlanabilir aktivasyon fonksiyonlu sinir ağı)
ADALİNE	: ADAPtive LInear NEuron (Uyarlanabilen Doğrusal Nöron)
AGİ	:Akım Gözlem İstasyonu
ANFİS	:Adaptive-Network Based Fuzzy Inference Systems (Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri)
ANLR	:Additive-Linear Regression (Genelleştirilmiş Doğrusal Regresyon)
ANN	:Artificial Neural Network (Yapay Sinir Ağı)
ARMA	:Autoregressive Moving Average (Otoresif Hareketli Ortalama)
ARIMA	:Autoregressive Integrated Moving Average (Otoresif Entegre Hareketli Ortalama)
ARMAX	:Autoregressive Moving Average With Exogenous Inputs (Otomatik Regresif Hareketli Ortalama ile Ex - ogenous Girişler)
ART	:Adaptive Resonance Theory (Uyarlanabilir Rezonans Teorisi)
BFG	: BFGS Quasi-Newton (Broyden- Fletcher- Goldfard- Shanno Yarı Newton Algoritması)
DT	:Decision Tree (Karar Ağacı Modeli)
EİE	:Elektrik İdaresi Genel Müdürlüğü
FFBP	:Feed-Forward Back-Bropagation Neural Network (Geri Yayılma Çok Katmanlı Öğrenme Besleme- İleri Sinir Ağı)
FFNNs	:Feed-Forward Neural Networks (Çok Katmanlı Beslemeye Giriş- İleri Sinir Ağları)
GA	:Genetik Algoritma
GR-NN	:Generalized Regression-Neural Network (Genelleştirilmiş Regresyon Sinir Ağı)
IBM	:International Business Machines (Uluslararası İş Makinaları Şirketi)
ICOLD	:International Commission on Large Dam (Uluslararası Barajlar Komisyonu)
LVQ	: Learning Vector Quantization
MAE	:Mean Absolute Error (Ortalama Mutlak Hata)
MASE	:Mean Absolute Scaled Error (Ortalama Mutlak Ölçekli Hata)
MATLAB	:Matrix Laboratory (Matris Laboratuvarı)
MAPE	:Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
ME	:Mean Error (Ortalama Hata)
MNLR	:Multiplicative Non-Linear Regression (Çarpımsal Liner Olmayan Regresyon)

MLP	:Multilayer Perceptron (Çok Katmanlı Yapay Sinir Ağları)
MLR	:Multi-Linear Regression (Çoklu Liner Regresyon)
MSE	:Mean Squared Error (Ortalama Kare Hata)
NN	:Neural Network (Nöron Ağı)
OSS	:One Step Secant (Bir Adım Sekant Algoritması)
RBF-NN	:Radial Basis Function-Neural Network (Radyal Temel Foksiyonlu – Sinir Ağı)
RBF	:Radial Basis Function (Radyal Temelli Fonksiyon)
RBNNs	: Radial Basis Function Neural Networks (Radyal Temel Foksiyonlu – Sinir Ağları)
RMSE	:Root Mean Squared Error (Kök Ortalama Kare Hata)
SCG	: Scaled Conjugate Gradient (Ölçekli Eşlenik Gradyan Algoritması)
SCRR	:Simple Conceptual Rainfall-Runoff(Kavramsal Yağış- Akış Modeli)
sMAPE	:Symmetric Mean Absolute Percentage Error (Simetrik Ortalama Mutlak Yüzde Hata)
SOM	:Self Organizing Map(Kendi Kendini Düzenleyen Harita Algoritması)
SVR	:Support Vector Regression (Destek Vektör Regresyonu)
WANFİS	:Wavelet- Adaptive-Network Based Fuzzy Inference Systems (Dalgalı Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri)
WARMA	:Wavelet-Autoregressive Moving Average (Dalgalı Otoresif Hareketli Ortalama)
WSVR	:Wavelet- Support Vector Regression (Dalgalı Destek Vektör Regresyonu)

YALOVA GÖKÇE BARAJININ SU SEVİYESİNİN YAPAY SINIR AĞLARI İLE TAHMİN EDİLMESİ

ÖZET

Artan dünya nüfusu ve küresel ısınmanın oluşturduğu kuraklığın etkisi ile su gibi ikamesi olmayan bir kaynağın, canlıların ihtiyaçlarını karşılayacak oranda muhafaza edebilmek, dünya kamuoyunun üzerinde durduğu önemli konular arasında yer almaktadır. Akarsulardaki su seviyesinin düşük olduğu dönemlerde gerekli olan su ihtiyaçlarını karşılamak ve akarsuların oluşturmuş olduğu düzensizliği ortadan kaldırılması için biriktirme haznelerinin yapılması gerekmektedir. Bu çalışmada Yalova Gökçe Barajının 2000-2019 yılları arasındaki, barajın su seviyesinin oluşmasında etkili olan Sellimandıra deresinin akış debisi, havzasının yağış ve buharlaşma değerleri, baraj su tahliyeleri, sızıntı suyu miktarı ile barajın su seviyesi ölçümleri kullanılarak, 2019 yılı baraj rezervuardaki su seviyesinin yapay sinir ağı ile tahmin edilmesi amaçlanmıştır.

Bu amaçla yapay sinir ağı analizinde iki farklı çok katmanlı yapay sinir ağı modeli olan Levenberg-Marquardt eğitim fonksiyonu ile Gradient Descent with Momentum eğitim fonksiyonu ve aynı zamanda analiz verilerinin kendi aralarındaki ilişkisinin tespiti içinde çoklu regresyon analizi kullanılmıştır.

Yapay sinir ağı kullanılarak oluşturulmuş olan analiz modellerinde en iyi analiz sonucunun Levenberg-Marquardt eğitim fonksiyonu ile yapılan analizlerde (R^2) determinasyon değeri %94,14 ile aylık tahmin verilerinin aylık gerçek su seviyesine yakın değerlerde olduğu tespit edilmiştir.

Sonuç olarak Levenberg-Marquardt eğitim fonksiyonu ile tahmin edilen 2019 yılı ortalama baraj su seviyesi 73,77 metre iken, barajdaki gerçek ortalama su seviyesi 72,13 metre olarak ölçülmüştür. Bu sonuçlar altında Yalova Gökçe Barajının su seviyesinin tahmininde, Levenberg-Marquardt eğitim fonksiyonu ile yapılan analiz modelinin başarılı sonuçlar verdiği ifade edilebilir.

Anahtar Kelimeler: Yalova Gökçe Barajı, Yapay Sinir Ağları, Baraj Su Yüzey Seviyesi, Buharlaşma, Yağış, Sızıntı, Gelen Akım.

ESTIMATION OF WATER LEVEL OF YALOVA GÖKÇE DAM BY ARTIFICIAL NEURAL NETWORKS

SUMMARY

With the increasing world population and the effect of the drought caused by global warming, being able to preserve a non-substituted resource such as water to meet the needs of living things is among the important issues that the world public opinion emphasizes. During the periods when the water level in the rivers is low, the accumulation chambers need to be built in order to meet the water requirements required and to eliminate the irregularity created by the rivers. In this study, the artificial nerve of the water level in the reservoir of 2019 was used by using the flow rate of Sellimandıra stream, which is effective in the formation of the water level of the dam between the years 2000-2019 of the Yalova Gökçe Dam, the precipitation and evaporation values of the basin, the dam water discharge, the amount of leachate and the water level of the dam. networks are intended to be estimated.

For this purpose, in the analysis of artificial neural networks, two different multi-layer artificial neural network models, Levenberg-Marquardt training function and Gradient Descent with Momentum training function, as well as multiple regression analysis were used to determine the relationship between the analysis data.

In the analysis models created using artificial neural network, the best analysis result was determined by the Levenberg-Marquardt training function (R^2), and the determination value was %94.14, and the monthly prediction data was close to the monthly real water level.

As a result, while the average dam water level estimated by the Levenberg-Marquardt training function in 2019 was 73.77 meters, the actual average water level in the dam was measured as 72.13 meters. Under these results, it can be stated that the analysis model made with Levenberg-Marquardt training function gives successful results in the estimation of the water level of the Yalova Gökçe Dam.

Keywords: Yalova Gökçe Dam, Artificial Neural Networks, Dam Water Surface Level, Evaporation, Precipitation, Leakage, Incoming Flow, Irrigation.

1. GİRİŞ

Su, bütün canlıların yaşamını sürdürmesi için ihtiyaç duyduğu, başka bir madde ile ikame ettirilemeyen ve bundan dolayı hayati önem taşıyan vazgeçilmez bir maddedir. Canlı ve cansız, tüm çevre üzerinde etkisi olan su, yaşamın başlangıcı olarak sayılabilir.

Canlı bir varlık olan insanın suya olan etkisini, kendisine fiziksel, sosyal ve kültürel anlamda fayda sağlamak amacıyla gerçekleştirmiştir. Bu durum ise insanı tarihsel süreçte toplumsal hale getirmiştir. Antik çağlardan itibaren bütün medeniyetler suya yakın yerlerde kurulmuş ve sudan faydalanmayı amaçlamışlardır.

Bir bölgedeki su ihtiyacı; nüfus yoğunluğu, nüfus artışı, yaşam seviyesi, tarım ve endüstride verim artışı ile ekonomik kalkınma gibi faktörlere bağlıdır. Ancak akarsu, göl, yeraltı suyu, pınar, deniz ve yapay yağmur gibi su kaynaklarında kullanılacak su miktarı sınırlıdır. Aynı zamanda doğal hidrolojik çevrim içinde su hareket halinde olduğundan belirli bir yerdeki ve zamandaki miktarı da değişmektedir (Erkek, Ağralıoğlu, 2013).

Bu çalışmamızda, Yalova Gökçe Barajının su seviyesinin tespitinde etkili olan verileri kullanarak, barajdaki mevcut su seviyesinin tahmin edilmesi amaçlanmıştır.

Yalova Gökçe Barajı, Yalova ilinin ile Karamürsel ve Çınarcık ilçelerinin içme, kullanma ve endüstri suyu ihtiyacını karşılayabilmek için Sellimandıra deresi üzerine 1980-1989 yılları arasında inşa edilmiş bir barajdır. Yalova Gökçe Barajının hizmete girmesi ile yeraltı suyunun tarımsal kullanımına bırakılması, aşırı yer altı suyu çekiminin önlenmesi ve aynı zamandan yer altı suyunun tuzlanması olasılığının ortadan kalkması dolayısıyla sanayi tesisleri ve yerleşim yerlerine de sürekli, güvenilir ve arıtmaya tabi tutulmuş daha kaliteli suyun sağlanması hedeflenmiştir.

Son zamanlarda yapay sinir ağları birçok uygulama alanında başarıyla kullanılmaktadır. Yapay sinir ağları; insan beynini oluşturan sinir sisteminin taklit edilerek sinirsel algılayıcılar yardımıyla daha önceden öğrenilmiş veya sınıflandırılmış olan verileri kullanarak bunlardan yeni bilgiler elde ederek, karar verebilecek sonuçlar oluşturabilen bilgisayar programlarıdır.

Bu çalışmamızdaki esas amaç; yapay sinir ağları modellerini kullanılarak, Yalova Gökçe Barajının 2019 yılındaki rezervuarındaki mevcut su seviyesinin tahminini

yapmaktır. Bu amaçla yapay sinir ağıları modellerini oluşturulurken su seviyesinin tespitinde kullanılacak olan verilerin %95'i eğitim verisi %5'i ise test verisi olarak kullanılmıştır. Analiz modellemelerini oluşturan girdi verileri; Yalova Gökçe Barajının 2000-2019 yılları arasındaki barajı besleyen Sellimandıra Deresinin gelen akım değerleri, baraj havzasına düşen yağış miktarı, havzanın buharlaşma miktarı, barajdan sızan sızıntı suyu miktarı, dolu savak tahliye suyu miktarı, sulama ile içme suyu miktarları ve barajın rezervuarındaki su seviyesi ölçümleri veri olarak kullanılmıştır.

Yapılan analizlerde elde edilen tahmin değerleri ise 2019 yılındaki ölçülmüş olan su seviyesi verileri ile karşılaştırılmıştır.

1.1 Genel Bilgiler

Yalova Gökçe Barajı yapılmasının amacı; İstanbul-İzmit sahil şeridinin yerleşim ve sanayi tesisleri ile tamamen dolmuş olmasından yeni gereksinimler için Yalova Karamürsel arasındaki sahil bölgesinin seçilmesi, bu bölgenin gelişmesine önemli bir etken olmaktadır. Adı geçen bölgede oluşan yeni sanayi tesisleri ve yeni yerleşimler bazı sorunlarda yaratmaktadır. Bu sorunların nedenlerinden biri de mevcut su kaynaklarının, içme kullanma ve endüstri suyu ihtiyacını karşılayamaz duruma gelmesidir. Mevcut durumda ise Karamürsel ilçesi ile Yalova- Karamürsel arasındaki sanayi tesisleri ve sahil siteleri, içme kullanma ve endüstri suyu ihtiyaçlarını yeraltı suyundan karşılamaktadır. Adı geçen bölgede Taşköprü ve Altınova ismi ile iki ayrı ova bulunmaktadır. Yeraltı suyu bu ovalardan karşılanmaktadır. Taşköprü ovasının yıllık su rezervi $2,5 \times 10^6$ m³, Altınova'nın yıllık su rezervi $6,5 \times 10^6$ m³ 'dür. Bu ovaların yıllık su rezervleri dolmuş olup yeni kuyuların açılmasına izin verilmemektedir. Yıllık toplam suyu 9×10^6 m³ olan bu iki ova, sulama suyu yanı sıra içme, kullanma ve endüstri suyu ihtiyaçlarına cevap veremez duruma gelmiştir. Altınova ve Taşköprü ovasında, yeraltı su seviyesi özellikle son yıllardaki aşırı su çekimi nedeni ile gittikçe düşmekte ve bu iki ovadaki yer altı suyunda denizin etkisi ile tuzlanma görülmektedir. Yalova ilinin içme, kullanma ve endüstri suyu ihtiyacının önemli bir kısmını Sellimandıra deresinden karşılanmaktadır. Ancak yaz aylarında Sellimandıra deresinin suyunun azalması veya tamamen kurumması, Yalova ili için yeterli suyun teminine engel olmaktadır. Belirtilen bu nedenlerden dolayı Cınarcık, Yalova ve Karamürsel için içme, kullanma ve endüstri suyu ihtiyacını karşılamak üzere yeni kaynak araştırması yapılmış, Sellimandıra deresi üzerine

Gökçe Barajının inşa edilmesi uygun görülmüştür. Gökçe Barajının hizmete girmesi ile yer altı suyu tarımsal kullanıma bırakılacak, aşırı yer altı suyu çekimi önlenmiş olunacak ve dolayısıyla yer altı suyunun tuzlanması olasılığı da ortadan kalkacaktır. Aynı zamanda sanayi tesisleri ve yerleşim birimleri de sürekli, güvenilir ve arıtmaya tabi tutulmuş daha kaliteli suya kavuşmuş olacaktır (Planlama raporu, 1978).
Yalova Gökçe Barajı, Sellimandıra deresi üzerine 1980-1989 yılları arasında inşa edilmiş ve günümüze kadar ilgili bölgelere hala hizmet etmektedir.

1.2 Çalışmanın Amacı

Bu çalışmada yapay sinir ağları modelleri kullanılarak Yalova Gökçe Barajının 2019 yılı su seviyesinin tahmininin yapılması amaçlanmış olup bu verilerin ışığında sonraki senelerin baraj su seviyelerinin tahmininin yapılabileceğini göstermektedir. Baraj işletmesi açısından su seviyelerinin tahmininin yapılabilmesi, baraj rezervuarındaki mevcut suyun daha optimum seviyede kullanılmasını sağlayacaktır.

1.3 Çalışmanın Önemi

Gökçe Barajının su seviyesinin tahmininin yapılabilmesi, barajdaki mevcut suyun hangi dönemlerde ne kadar miktarda suyun muhafazasını veya ne kadar miktardaki suyun uygun şartlarda tahliyesinin yapılması yönünde ön bilgiye sahip olunmasını sağlayacaktır.

Gökçe Barajının aylık su seviyesinin tahmininin yapılabilmesi, ülkemizdeki diğer barajlarında su seviyelerinin tahmininin yapılabileceğini gösterecek olup bu tahmin verileri ile barajlardaki mevcut suyun daha optimum seviyede kullanılabilmesi sağlanacaktır.

2. LİTERATÜR ÇALIŞMASI

Yapay sinir ağları birçok disiplinin araştırmalarına konu olmuştur. Yapay sinir ağları yapılan araştırmalarda istenilen verinin tahmin edilmesinde büyük ölçüde tutarlı sonuçlar oluşturulmasını sağlamıştır.

Holger ve Graeme (1996), Güney Avustralya'daki Murray Nehri'nin tuzluluğunu 14 önceden tahmin etmek amacı ile yapay sinir ağını kullanmıştır. Yaptıkları bu çalışmada dört farklı yıllık veri için 14 günlük yapay sinir ağı tahmini ile ortalama mutlak hata değeri %5,30-%7,00 arasında bulunmuş, bu ara değerlerin tutarlı değerler olduğu sonucuna varmışlardır.

Tokar ve Markus (2000), Yapılan bu araştırma çalışmasında yapay sinir ağı modelleri ile yağış, kar suyu eşdeğeri ve sıcaklığın bir fonksiyonu olarak havza akışını tahmin etmede geleneksel kavramsal modellerle karşılaştırmalar yapılmıştır. Yapay sinir ağı modelleri ile günlük yağış akışı süreci modellenmiş ve eğitim ve test sonuçları, basit bir kavramsal yağış akışı (SCRR) modeliyle karşılaştırılmıştır. Yapay sinir ağının farklı zamanlarda topografya ve iklim modelleri için yağış akışı sürecini modellemede güçlü araçlar olabileceği sonucuna varılmıştır.

Altunkaynak (2007), Van Gölü su seviyesinin yükselmesi ile kıyı kesimlerinin su altında kalmasında dolayı bu çalışmayı yapmıştır. Göl su seviyesinde zamanla oluşan değişimlerin modellenmesinde yapay sinir ağı kullanılmıştır. Bu çalışma ile yapay sinir ağı ile yağış ve göl su seviyesi arasındaki ilişkinin modellenebileceği sonucuna varılmış olup aynı zamanda göl suyu seviyesindeki dinamik değişimler incelenmiştir.

Alp ve Cigizoğlu (2007), bu çalışmada yapay sinir ağı nehirlerde asılı olan tortu yükünün tahmin etmek amacı ile kullanılmıştır. Bu sinir ağı modellemelerinde, gelen yağış akışı ve asılı tortu yük verileri kullanılarak ağın eğitimi yapılmıştır. Bunun için yapay sinir algoritmalarından ileri beslemeli geri yayılım (FFBP) yöntemi ile radyal temel fonksiyonu (RBF) kullanılmıştır.

Çalım (2008), bu çalışmada Türkiye'nin Akdeniz Bölgesinde yer alan Hatay, Antakya Yârseli Barajı ve havzasının 1796 günlük ölçüm verileri yapay sinir ağı yöntemi kullanarak baraj haznesinin seviye değişimi tahmini yapılmıştır. Bu tahminin yapılmasında günlük haznenin seviyesi, günlük baraj gölüne gelen su

hacmi, günlük toplam su sarfiyatı ve baraj hazasına düşen günlük yağış yükseklikleri veri olarak kullanılmıştır. Yapay sinir ağının modellenmesinde Boyesian düzenlenme tekniği kullanılmıştır. Bu ise Levenberg-Marquardt (LM) eğitim algoritması kullanılarak ağırlık ve bias katsayıları yenilenmiştir. Yapılan yapay sinir ağı modellemeleri çalışmasında bulunan tahmin sonuçları geleneksel yöntemle bulunan veriler ile kıyaslandığında iyi performans verdiği tespit edilmiştir.

Sreekanth vd. (2009), yaptıkları bu çalışma ile yapay sinir ağı eğitim modeli olan Levenberg- Marquardt (LM) kullanarak Hindistan, Hyderabad, Maheshwaran havzasının yer altı suyunun tahmini amaçlanmıştır.

Al Aboodi vd. (2009) yaptıkları bu çalışmada Irak'ın güneyindeki Shatt Al-Arab nehrinin havzasının tuzluluk oranının yüksek olması dolayısıyla nehir suyunun sulama ve içme amacıyla kullanılması sorun teşkil etmeye başlamıştır. Bundan dolayı Shatt Al-Arab nehrinin gelecekteki bu tuzluluk oranının tahmin edilmesi amaçlanmıştır.

Yarar ve Onüçyıldız (2009), yapılan bu çalışmada Konya Ovası Projesinin ana su kaynağı olan Beyşehir Gölü'nün su seviyesi değişimlerinin yapay sinir ağı yönteminin kullanılarak belirlenmesidir. DSİ tarafından ölçülen ve 1962 ile 1990 yılları arasındaki Beyşehir Gölü'ne giren akım- kayıp akım, yağış, buharlaşma, çekilen akım ve seviye ölçümleri kullanılarak yapay sinir ağı ile seviye değerleri tahmin edilmiş, elde edilen tahmin değerleri geleneksel yolla elde edilmiş olan sonuçlar ile karşılaştırılmıştır. Bu çalışmada en iyi tahmin sonucu Ölçeklendirilmiş Esleştirmeli Gradyant modelinde 1 gizli katman, 7 gizli düğüm sayısı ve 500 epoch için en küçük hata 0,056285 ile elde edilmiştir. Beyşehir Gölü için yapılmış olan bu çalışma ile geleneksel yöntemlerle yapılan göl su seviye ölçümlerinin değerlendirilmesinde karşılaşılan zorluklar ortadan kaldırılarak en kısa sürede göl su seviyesinin bulunması amaçlanmıştır.

Özaydın (2009), yapılmış olan bu çalışma Eskişehir Porsuk Barajı su haznesi su seviyesinin tahmin edilmesinde yapay sinir ağları ile ARMAX modeli kullanarak öngörülme çalışılmış aynı zamanda bu iki modelin bir biri ile karşılaştırılması yapılmıştır. Belirtilen bu amaç doğrultusunda Ocak 1973- Aralık 2006 yılı Porsuk Barajı su seviyesi, baraja gelen suyun hacmi, su sarfiyatları (taşkın, buharlaşma, diğer sarfiyatları) ve havzaya gelen yağış miktarı verileri kullanılarak analiz çalışması yapılmıştır. Yapılan analizler ile yapay sinir ağı ile oluşturulan modelin ARMAX yöntemi modeline göre gerçeğe yakın daha doğru sonuçlar verdiği tespit

edilmiştir. Bu çalışma ile Porsuk Barajı'nın ileriki zamanlarda bir su sıkıntısının olup olmayacağı ve aynı zamanda taşkınları olup olmayacağı öngörülmüştür.

Mpallas vd. (2011), bu çalışma Yunanistan'nın Selanik şehrinin 100 km kuzeyindeki Kerkini Gölü (Strymonos nehir havzası tarafından beslenen yapay göl) 1932 yılında baraj inşaatı ile baraj gölüne dönmüştür. Kerkini Gölünün su seviye değerleri 1990-2003'e kadar mevcut değildir. Bu değerleri elde etmek için Visual Basic dilinde oluşturulan program kullanılarak bulunmaya çalışılmıştır. Bu çalışmanın girdi verileri; yağış, göl suyu buharlaşması, strymonos havzası buharlaşma insprirasyonu ve Bulgaristan'dan gelen su akış verileri kullanılmıştır. Yapay sinir ağı'nın modellenmesinde ise Levenberg- Marquardt eğitim modelinin daha iyi performans verdiği tespit edilmiştir. Bunun için ise eğiti verisi olarak (1982-1997 yılları arası), test veri seti için (1998-2000 yıllar arası) ve doğrulama için (2001-2003 yılları) kullanılmıştır. Sonuç olarak, yapay sinir ağı yönteminin kullanılması ile tüm parametreler kullanılmadan sonuca ulaşılabildiği ispatlanmıştır.

Tezel vd. (2013), yapılan çalışmada Beyşehir Gölünün aylık su seviyelerinin tahmini yapılmıştır. Bu tahmini yapabilmek için çok katmanlı yapay sinir ağı (MLP) ve uyarlanabilir aktivasyon fonksiyonu sinir ağı (AAFNN) modelleri kullanılmıştır. Veri olarak ise aylık yağış, buharlaşma, göl girdi ve göl çıktı debilerinin ile aylık göl su seviyeleri kullanılmıştır. Modellerin performansları MAE, RMSE ve R² kullanılarak kıyaslamalar yapılmıştır.

Okoye ve Igboanugo (2013), yapmış oldukları çalışmalarında Nijer nehri üzerinde yer alan aynı zamandan Nijerya'nın en büyük hidroelektrik barajı olan Kainji Barajı'nın su seviyesinin tahmini için girdi sayısı farklı olan beş yapay sinir ağı modeli ve Otoregresif Entegre Hareketli Ortalama (ARIMA) modelleri kullanılmıştır. Oluşturulan sinir ağı modelleri için girdi verileri olarak Kainji Barajının 2001 yılında 2010 yılına kadarki on yıllık günlük su verileri alınarak analizle yapılmıştır. Yapılan bu çalışma ile sinir ağı modellerinin su seviyesinin tahmininde doğruluğun artan girdi verileri ile arttığı, ancak sonrasında beş girişli modelleme ile tahmin doğruluğunda azalmalar olduğu görülmüştür. Dört girişli sinir ağı modeli en düşük rölatif hata yüzde 0,062 iken tek girişli yapay sinir ağı modelinde ise rölatif hata oranı yüzde 0,237 en yüksek değeri almıştır. ARIMA modeli ile oluşturulan modelde ise rölatif hata oranı olarak yüzde 0,039 oranı ile en iyi tahmin sonucu alınmıştır. Bu çalışmanın, Nijerya'nın hidroelektrik santrallerinin güç planlamalarında önemli bir kaynak olacağı sonucuna varılmıştır.

Aksoy vd. (2013), yapılan çalışmada, Van Gölü kapalı havzasının 1990 yılında yaklaşık 2 metre yükselmiştir. Bunun nedeni olarak ise hidro meteorolojik verilerin analizinde, su seviyesindeki değişikliğin gölün su bütçesi ile ilişkili olduğunu görülmüştür. Van Gölü'ndeki aylık su seviyesi verilerinin tahmini (modellemesinde) için stokastik modeller tavsiye edilmiştir. Bunun için tekli ve çoklu trend zaman serilerini göz önüne alan iki seri geliştirilmiştir. Bu modellemeler veri kümesindeki eğilimin ve periyodikliğin arındırılmasından sonra türetilmiştir. Van Gölü su seviyesindeki zaman serilerinde tespit edilen trend, tekli ve çoklu trend çizgilerle donatılmıştır. Tekli trend modelinde, zaman seri, göl suyu seviyesinin artan bir trende sahip olduğu hipotezi kurulmuştur. İkinci model ise (çoklu trend olarak adlandırılan) zaman serileri, her biri için ayrı parçalara ayrılabilen bir dizi segmente ayrılmıştır. Bu çalışma ile sentetik göl su seviyesinin çoklu trend modelinin tekli trend modelinde daha uygun olduğu bundan dolayı tekli trend modeline kıyasla çoklu tren modelinin sonuçları doğrultusunda göl kıyı alt yapı projelerinin yapılmasının daha uygun olacağı sonucuna varılmıştır.

Özen vd. (2014), yapılmış olan bu çalışmada, Bursa İznik Gölü'nde minimum göl seviyesi değişimlerinin otoregresif hareketli ortalama (ARMA) teknikleri modelleri ile tahmin doğruluğunun test etmek için kullanılmıştır. Bunun için girdi verileri olarak 1955-2002 yılları arasındaki Bursa İznik Gölü'nün günlük su seviye kayıtları kullanılmıştır. Bu veriler Elektrik İşleri Genel Müdürlüğünden (EİE) alınmıştır. Bu 47 yıllık veriler günlük ölçümler aylık verilere dönüştürülerek 46 yıllık veriler modellerin (AR, MA ve ARMA) eğitimi için son bir yıllık veri ise test ve tahminin doğrulaması için kullanılmıştır. ARMA modeli ile elde edilen analiz sonuçlarının, minimum göl seviyesi tahmininde diğer modellerden daha iyi performans gösterdiği tespit edilmiştir. Yapılan analiz incelendiğinde herhangi bir veri setine ihtiyaç duymadan sadece kendi minimum su seviyesi veri seti ile minimum su seviyesinin tahmin edilebileceği tespit edilmiştir.

Shafaei ve Kisi (2016), yapılan bu çalışmada aylık göl seviyesi değişimlerinin tahmin edilebilmesi için entegre dalgacık ve otomatik regresif hareketli ortalama (ARMA), uyarlanan nöro bulanık çıkarım sistemi (ANFİS) ve destek vektör regresyon (SVR) algoritmaları kullanılmıştır. Analizlerde zamanla değişen göl seviyesi verileri, ayrı dalgacık dönüşümü kullanarak düşük ve yüksek frekanslı verilerin ayrılması sağlanmıştır. Sonrasında ise ARMA, ANFİS ve SVR analiz modelleri kullanılarak her veri için ayrı ayrı tahminde bulunulmuştur. Analizlerde

WANFİS (Wavelet ANFIS), WARMA (Wavelet ARMA) ve WSVR (Wavelet SVR) algoritmaları tek ANFİS, ARMA ile SVR algoritmaları ile kıyaslanmıştır. Sonuç olarak, çoklu (entegre) modellerin göl su seviyesini tahmin etmede tekli modellere göre daha doğru sonuçlar sağladığı tespit edilmiştir. Ayrıca WSUR algoritma modelinin diğer çoklu algoritmalarına kıyasla biraz daha iyi tahmin sonuçları verdiği tespit edilmiştir.

Doğan vd. (2016), yapılan bu çalışmada Van Gölünün günlük su seviyesi tahmini için iki farklı sinir ağı modeli kullanılmıştır. Bu sinir ağları; İleri beslemeli sinir ağları (FFNNs) ve radyal temel fonksiyonlu sinir ağları (RBNNs) modelleridir. Bu sinir ağı algoritmalarının kullanılmasının nedeni daha hızlı yakınsama, daha küçük hatalar ve daha yüksek güvenilirlikten vermesinden dolayı kullanılmıştır. Yapılan analizler ile bulunan tahmin değerleri bunlara karşılık gelen ölçülmüş değerler ile korelasyon gösterdiği tespit edilmiştir. Bulunan analiz sonuçları ortalama kare hata (MES) ve R^2 (determinasyon) katsayısı kullanılarak tahmin sonuçları karşılaştırılmıştır. Bu karşılaştırma ile FFNN algoritma modelinin RBFNN algoritma modelinden daha iyi performans gösterdiği görülmüştür. Yapılan bu çalışma ile elde edilen tahmin sonuçlarına göre gelecekte Van Gölü'nün su seviyesinde düşmelerin olacağı ön görülmektedir. Bu durumda Van Gölü sahil çevresindeki hızlı gelişen ve yoğun yerleşimin olduğu bölgelerde suyun artışı tehdit oluşturmayacağı sonucuna varılmıştır.

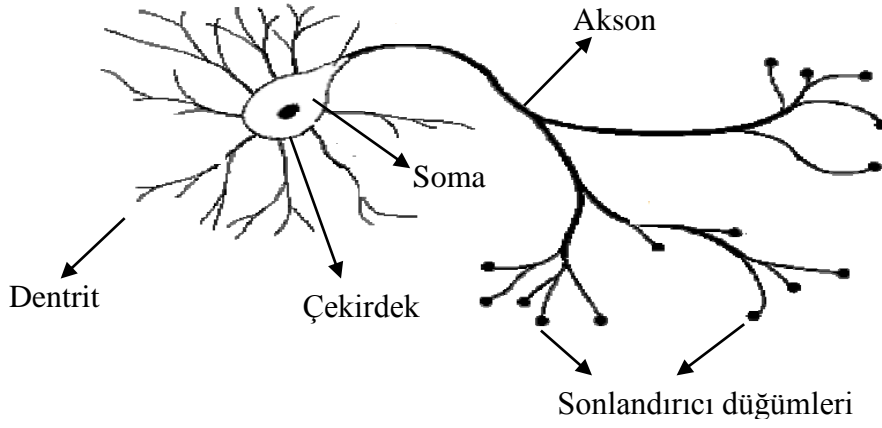
Vaheddoost vd. (2016), Urmia Gölü'ndeki aylık su seviyesi değişimleri tahmin edebilmek için parametrik ve parametrik olmayan modeller kullanılmıştır. Kullanılan parametrik modeller, ileri geri yayılım sinir ağı (FFBP-NN) sırasında çok doğrusal regresyon (MLR), toplamsal ve çarpımsal doğrusal olmayan regresyon (ANLR ve MNLR) ve karar ağacı olarak (DT), parametrik olmayan modeller ise regresyon sinir ağı (GR-NN) ve radyal temel fonksiyon sinir ağı (RBF-NN) kullanılmıştır. Bu çalışmada Urmia Gölü'nün 1966-2010 yılları arasındaki ölçülen aylık su seviyesi verileri kullanılmıştır. Analiz modellerinin karşılaştırılmasında dört kriter kullanılmıştır. Bu kriterler; belirleme katsayısı, Lin'in uyum korelasyon katsayısı, performans indeksi ve kök ortalama kare yüzde hatası kullanılmıştır. İlk iki kriter analiz sonuçlarının başarısı için, diğer son iki kriter ise başarısızlık için düşünülmüştür. Başarı kriterlerine 0 ile 10 arasında notlar verilmiş, başarısızlık kriterleri için ise -10 ile 0 arasında bir not verilmiştir. Bulunan notların toplamı ise her modelin toplam notu olarak kabul edilmiş. Analiz sonuçlarında regresyon

modellerinin ile FFBP-NN'nin aylık göl su seviyesini tahmin etmede GR-NN, RBF-NN ve DT'den daha doğru sonuçlar bulduğu tespit edilmiştir.

Abu Salam (2018), bu çalışma Irak Kerkük'ün Kuzeybatısında bulunan Dibis Barajının su seviyesinin tahmin edilmesi için yapılmıştır. Yapay sinir ağının girdi verileri olarak 10 yıllık veriler kullanılmıştır. Bu veriler baraja giren akım değerleri, barajdan çıkan akım değerleri, yağış ve başlangıç su seviyesi ölçümleridir. Bu verilerin %80'ni eğitim verisi kalan %20 'sini ise test verisi olarak kullanmıştır. Yapay sinir ağı modellemesinde bütün modeller ileri beslemeli geri yayılım öğrenme algoritması kullanılmıştır. Analizlerde dört farklı analiz modeli oluşturulmuştur. Bu analiz modelleri; yağışlı / yağışsız, başlangıç su seviyeli/ başlangıç su seviyesiz şeklinde oluşturulmuştur. Bu çalışmada başlangıç su seviyesinin önemli bir veri olduğu sonucuna varılmıştır.

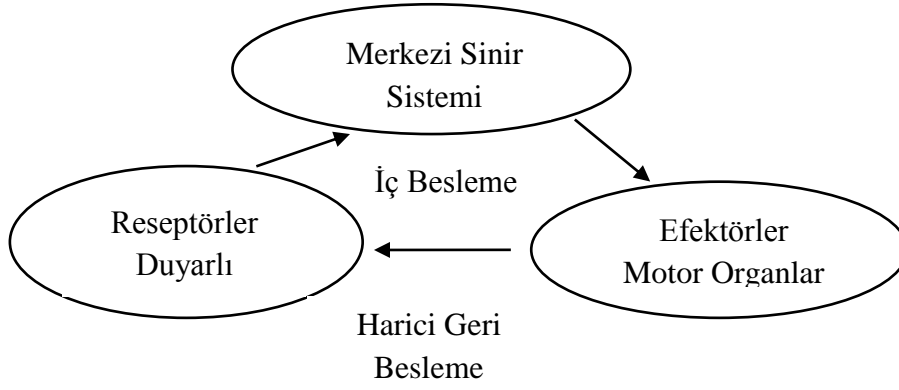
3. YAPAY SİNİR AĞLARI (ARTİFİCAL NEURAL NETWORKS)

Biyolojik sinir sisteminin temelini oluşturan sinir hücrelerine nöron denir. **Şekil 3.1**'de de görüleceği üzere sinir hücresi üç ana bölümde oluşur. Bunlar; hücre gövdesi (soma), akson ve dentritlerdir.



Şekil 3.1 : Sinir hücresi (Soycan, 2008).

Dentritler, nöronun gövdesinden (somadan) çıkan ağaç dalları şeklinde olup sinir hücresine sinyallerin girişini sağlar ve sonrasında somaya taşınmasına yardımcı olur. Nöronlardaki sinyalin taşınmasını sağlayan uzun sinirsel bağlantı olan akson, somada işlenen sinyalleri çıkışa taşır. Akson ve dentritler arasındaki bağlantıya “synapse” denir. Synapse sinir hücreleri arasındaki elektrokimyasal bağlantıyı oluşturmaktadır. İnsan beynini oluşturan nöron ve synapse bağlantıları verimli bir yapıda olup son derece kompleks, doğrusal olmayan ve paralel bir bilgisayar şeklindedir. Beyni oluşturan nöronların organize etme yeteneği ile kesin hesapları gerçekleştirme sayesinde görüntü tanıma, algılama vb. günümüzün en hızlı sayısal bilgisayarlarından daha hızlıdır. İnsan beyninin öğrenme, birleştirme uyarılma ve genelleştirme yetenekleri sayesinde oldukça karmaşık, doğrusal olmayan ve paralel dağıtılmış bir işletim sistemi olarak ifade edilir (Soycan, 2008)

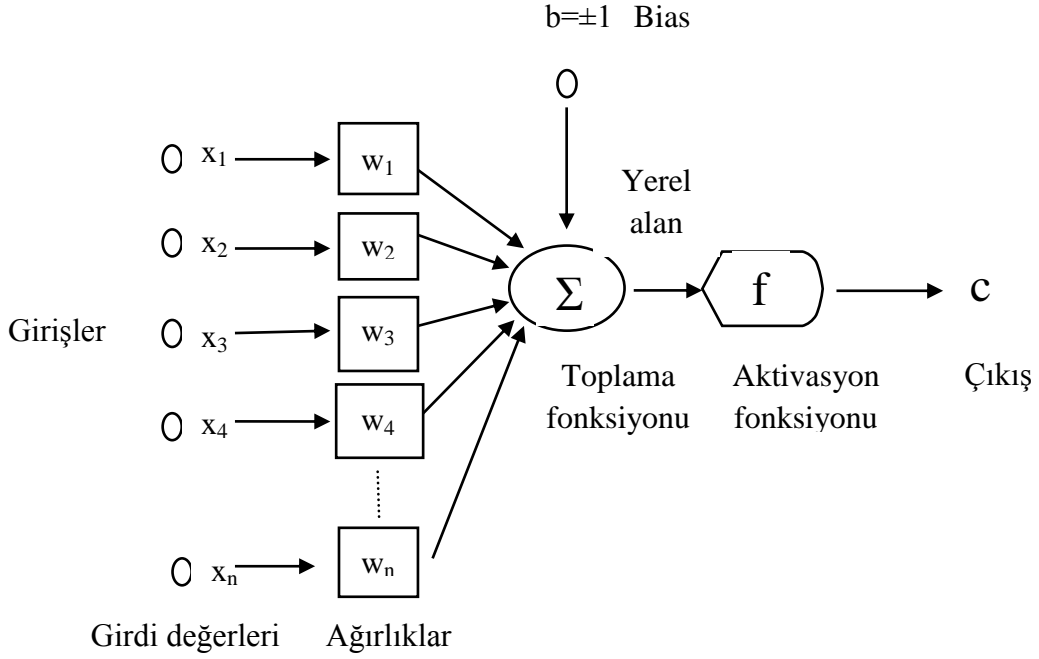


Şekil 3.2 : Sinir sistemindeki bilgi akışı (Soycan, 2008).

Sinirsel ağa girişler duyarlı algılayıcılarla (reseptörler) sağlanır. Bu reseptörler sinyalleri (uyarıları) gövdeye ileterek akış sağlanmış olur. Bunun sonucunda çeşitli eylemlerin cevabı oluşur. Gerek görüldüğünde komutlar merkezi sinir sisteminde üretilir ve ilgili motor organlarına iletir. Bu motor organlarda uyarıları doğrulayan geri beslemeli bağlantılar ile merkezi sinir sistemini yönetir ve denetler (Soycan, 2008).

Yapay sinir ağları, insan beynini oluşturan sinir sisteminin taklit edilerek sinirsel algılayıcılar yardımıyla daha önceden öğrenilmiş veya sınıflandırılmış olan verileri kullanarak bunlardan yeni bilgiler oluşturabilen ve karar vererek sonuç oluşturabilen bilgisayar programlarıdır. Örüntü tanıma, sistem tanımlama, robotik, sinyal işleme, nonlineer denetim alanları gibi birçok alanda kullanılmaktadır (Keskenler, 2017).

Yapay sinir ağı, dış ortamdan ya da diğer nöronlardan alınan veriler **Şekil 3.3**'te belirtildiği gibi çıktı üretilmektedir.



Şekil 3.3 : Yapay sinir ağı örneği (Keskenler, 2017)

Şekil 3.3'te belirtilen sonucun oluşabilmesi için ağ belirli verilerle (örneklerle) önceden eğitilir, daha sonra ağa verilen bu verilerle genelleme ve karar verebilecek bir düzeye ulaşır ve sonrasında kazanılan bu yetenekle veri çıktıları oluşur ve buda denklem 3.1 ile ifade edilmiş olur.

$$c = \sum_{i=1}^n w_{ij}x_i + b \quad (3.1)$$

Denklem 3.1'de; c, çıkışı, w, ağırlıklar matrislerini, x, girişler matrisini, n, giriş sayısı, b, bias değeri ve f, aktivasyon fonksiyonudur (Soycan, 2008).

Yapay sinir ağları paralel dağıtılmış ağlar, bağlantılı ağlar, nöromorfik ağlar gibi adlarla da anılmaktadır (Keskenler, 2017).

3.1 Yapay Sinir Ağının Elemanları

Girdiler, yapay sinir ağına dış ortamdan veya diğer hücrelerden ulaşan bilgilerdir. Ağırlıklar, sinir hücreleri arasındaki bağlantıların sayısal değerini tanımlamakta olup bir hücreye gelen bilgilerin değerlerini ve hücreler üzerindeki etkisini gösterir. Toplama fonksiyonu hücreye gelen ağırlıklarını çarpıp toplayarak hücrenin net girdilerinin hesaplanmasına yardım eder. Aktivasyon fonksiyonu, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üretebileceği çıktının belirlenmesini sağlar. Çıktılar, aktivasyon fonksiyonu tarafından belirlenmiş olan çıktı değerleridir.

Sonuç alınan çıktı değeri ya dış dünyaya, başka bir hücreye ya da kendisine girdi olarak gönderilebilir.

3.2 Yapay Sinir Ağlarının Tarihçesi

Bilgisayar biliminin 1980 yılından sonra gelişmeler gösterdiği düşünülürse yapay sinir ağlarının tarihsel gelişimi incelenirken 1980 öncesi ve sonrası diye ayırmak gerekir.

3.2.1 1980 Öncesi yapay sinir ağı tarihsel gelişimi

Yapay sinir ağları ile ilgili 1930 yılından önce mühendislik değeri olmayan bazı araştırmalar yapılmıştır. Yapay sinir ağında yapılan ilk modelleme çalışması McCulloch ve Walter Pitts tarafından yapılmış (McCulloch ve Pitts, 1933) ve bunun temellerini atmış olup elektrik devrelerini kullanarak insan beyninin hesaplama ve analiz yeteneğini dikkate alarak bir yapay sinir hücresi geliştirmişlerdir. Bu yapay sinir hücreleri ile her türlü mantıksal ifadenin formüle edilmesini göstermişlerdir. Sonrasında daha fazla yapay sinir hücrelerini birlikte çalışmasının sağlayarak paralel çalıştırma tekniği ile öğrenme kurallarının belirlenmesine yardımcı olmuşlardır. 1939'da Donald Hebb'in Organization of Behavior kitabında "Hebbian Öğrenme" teorisini buldu. Bu teori ile sinir ağının bağlantı sayısı ile öğrenme ve uyum sağlayabilmenin ilişkili olduğunu bulmuştur. 1950 ve 1951 yıllarında Hebb teorisine yapay sinir ağları ile ilgili simülasyon çalışmaları IBM laboratuvarlarında yapılmış, 1951 yılında ilk nuro- bilgisayar üretilmiştir. 1953 yılında Farely ve Clark tarafından rassal ağlar ve adaptif tepki üretme terimleri bulunmuş. 1957 yılında Frank Rosentblatt tarafından bulunan "Perceptron (tek katmanlı eğitilebilen ve tek çıkışlı yapay sinir ağı) ile yapay sinir ağındaki gelişmeler hız kazanmıştır. 1958 ve 1961 yıllarında Rosentblatt ile Caianiello tarafından rassal ağlarla adaptif tepki üretmede çalışmalar yapmışlardır. John Von Neuman telgraf röleleri ve vakum tüpleri ile ilkel sinir sisteminin taklit edilmesini önermiş, Frank Rosentblatt kavrama ve anlam verme ile çalışmalar yapmış, kavrama düğümünü ortaya çıkarmıştır. (Kavrama düğümü günümüzde kullanılan en eski yapay sinir ağıdır.) 1959 yılında Bernad Widrow ile Marcian Hoff, Stanford üniversitesinde ADALİNE (ADAPtive LInear NEuron) ve MADALİNE yapay sinir ağı modelleri geliştirmişlerdir. Bulunan bu modeller yapay sinir ağının mühendislikteki uygulama alanlarına yönelik olan ilk çalışmalardır. 1956 yılında yapay zekâ kavramının ortaya atılması ile yapay sinir


ağları ile birlikte incelenmiş dolayısıyla bu dönemde yapılmış olan araştırmalar yüzünü yapay zekâya çevirmiştir. 1965 yılında Nilssons tarafından yazılan “ Öğrenen Makineler” kitabı ile bütün yapay sinir ağı çalışmaları bir araya toplanmıştır. 1960 yılının sonlarında Pappert ve Misnk tarafından yazılmış olan “Algılayıcılar” kitabı ile yapay sinir ağı çalışmaları duraklamıştır. Bunun nedeni ise yazarlar kitaplarında yapay sinir ağının bilimsel açıdan bir değerinin olmadığı ve lineer olmayan problemlerine yönelik çözümler üretemediğini ispatlamaya çalışmışlardır. Bu tezlerini ispatlamak için ise bilgisayar biliminde bilinen XOR probleminin çözümünü örnek gösterdiler. Bu da birçok bilim adamının yapay sinir ağı alanında çalışma yapmasını durdurmuştur. Bu sıkıntılı süreç ancak XOR probleminin çözülmesi ile tekrar başlamıştır. 1969 yılına kadar devam etmiş olan bu süreç Amari, Cooper, Kohonen, Grossberg, Fukushima, Hopfield ve Anderson gibi araştırmacılar ile yapay sinir ağı çalışmaları devam etmiş, 1980 yılına kadarki 10 yıllık süreç yapılan araştırmalar neticesinde yapay sinir ağı araştırmaları duraklama dönemi sona ermiş ve gelişmeler hızlanmıştır (Keskenler, 2017).

3.2.2 1980 Sonrası yapay sinir ağı tarihsel gelişimi

1982 yılında Kohonen tarafında yapılmış “Kendi kendine öğrenme nitelik haritaları” çalışması yayınlanmış, aynı yılda Hopfield tarafından önemli ağ sınıflarının matematik modelleri oluşturulmuştur. Yapay sinir ağları içi devrim niteliğinde olan çok katmanlı algılayıcıların bulunmasında önemli bir adım olan Rumelthart’ın paralel programlama çalışmalarını bulunduran ve 2 çilt (McClelland ve Rumelthart,1986 ve Rumelhart ve McClelland, 1986,1988) eseleri bu çalışmaların temelini oluşturmuştur. Bu buluşla yapay sinir ağlarının popüleritesi yeniden yükselişe geçmiştir. 1983yılında Kohonen tarafından danışmasız öğrenme ağları geliştirilmiştir. 1988 yılında Broomhead ve Lowe tarafından “Radyal tabanlı fonksiyonlar” modeli geliştirilmiştir. 1988 yılında Specht tarafından “Probalistik Ağları” ve 1991 yılında çok katmanlı algılayıcıların alternatifi ve gelişmiş olan “Genel Regresyon Ağları” modellerini geliştirmiştir. 1990 yılından günümüze kadarki süreçte yapay sinir ağı modelleri ilk dönemlerindeki aksine teorik ve laboratuvar araştırmaları olmaktan ziyade günlük hatta kullanılabilen sistemlerde kullanılarak pratik anlamda yararlı olmaya başlamıştır (Keskenler, 2017).

3.3 Yapay Sinir Ağlarında Aktivasyon Fonksiyonları


3.3.1 Eşik (adım) aktivasyon fonksiyonu



Şekil 3.4 : Eşik aktivasyon fonksiyonu (Öztemel, 2003).

Şekil 3.4'te görüleceği üzere eşik (adım) aktivasyon fonksiyonu, şayet net değer sıfırdan küçükse çıkışında -1 , sıfırdan(0) daha büyükse net çıkışında +1 alır. Şayet eşik aktivasyon fonksiyonun -1 ile +1 arasında değişeni ise signum aktivasyon fonksiyonu oluşur. Signum aktivasyonu, net giriş değeri sıfırdan büyükse +1, sıfırdan küçükse -1, sıfıra eşitse sıfır değerini alır (Soycan, 2008).


3.3.2 Doğrusal aktivasyon fonksiyonu



Şekil 3.5 : Doğrusal aktivasyon fonksiyonu (Öztemel, 2003).

Şekil 3.5'te de görüleceği üzere doğrusal (linear) aktivasyon fonksiyonunda çıkışı, girişine eşittir. Sürekli çıkışlarda, çıkış katmanındaki aktivasyon fonksiyonu linear aktivasyon fonksiyonu olur (Soycan, 2008).


3.3.3 Logaritma sigmoid transfer (lojistik) aktivasyon fonksiyonu



Şekil 3.6 : Logaritma sigmoid aktivasyon fonksiyonu (Öztemel, 2003).

Şekli 3.6'da görüleceği üzere fonksiyon linear olmaması nedeniyle türevi alınabilmekte dolayısıyla geri yayınlımlı ağlarda kullanılabilmektedir (Soycan, 2008).

3.3.4 Hiperbolik tanjant aktivasyon fonksiyonu



Şekil 3.7 : Hiperbolik tanjant aktivasyon fonksiyonu (Öztemel, 2003).

Şekil 3.7'de de görüleceği üzere hiperbolik tanjant aktivasyon fonksiyonu lineer olmayan bir fonksiyon olmasından dolayı türevi alınabilir. +1 ile -1 arasında çıkış değerleri üretir (Soycan, 2008).


3.4 Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağlarını yapılarına ve öğrenme algoritmalarına göre sınıflandırmak mümkündür (Ataseven, 2013).

Yapay sinir ağları yapılarına göre ileri beslemeli yapay sinir ağı ve geri beslemeli yapay sinir ağı olmak üzere iki gruba ayrılmaktadır.

3.4.1 İleri beslemeli (Feed forward) yapay sinir ağı

Bu modelde gecikme olmadan, işlemler girişten çıkışa doğru düzenli katmanlar şeklinde ilerler.




Şekil 3.8 : İleri beslemeli yapı (Öztemel, 2003).

Şekil 3.8'de görüleceği üzere ağa gelen veriler giriş katmanına daha sonrasında sırasıyla gizli katmanlar ve çıkış katmanlarda veriler işlenerek geçer ve sonrasında dış dünyaya çıkar. İleri beslemeli ağda sistemin işlemci elemanları bir katmandan diğer bir katmana bağlantılarını kurarken aynı katmanda bağlantıları bulunmaz. Bu ağa örnek olarak Çok Katmanlı Perseptron (Multi Layer Perseptron-MLP) ve Öğrenme Vektör Nicelendirmesi (Learning Vector Quantization-LVQ) verilebilir (Soycan, 2008).

3.4.2 Geri beslemeli (Feed back) yapay sinir ağı

Geri beslemeli yapay sinir ağları, kontrol sistemli uygulamalarda olduğu gibi gecikmeler oluşur.



Şekil 3.9 : Geri beslemeli yapı (Öztemel, 2003).

Şekil 3.9 'da görüleceği üzere bir hücrenin çıktısı sadece kendinden sonra gelen katmana girdi oluşturmuyorlar. Kendinden önceki katmandan veya kendindeki herhangi bir hücreye girdi oluşturabilir.

Geri beslemeli bu modelde girişlere bağlı olarak ileri beslemeli bir ağdan elde edilir. Bu ağ, t anındaki çıkış $O(t)$, $t+\Delta$ anındaki çıkışı ise $O(t+\Delta)$ 'dir. Δ simgesi sembolik gecikme süresidir. İleri beslemeli yapay sinir ağı kullanıldığında $O(t+\Delta)$ denklem 3.2 yazılabilir.

$$O(t + \Delta) = f[w O(t)] \quad (3.2)$$

Denklem 3.2 'de dikkat edilmesi gereken husus $x(t)$ başlangıç anına ihtiyaç duyulması olup bu başlangıç anı $O(0) = x(0)$ 'dır.

Geri belemeli ağ mimarisi, danışmansız öğrenme kurallarının uygulama alanı bulunduğu ağ sistemleridir. Geri besleme, bir katmandaki hücreler arasında oluşabileceği gibi katmanlar arasındaki hücreler arasında da olabilir. Bu yapıları nedeni ile doğrusal olmayan dinamik davranış göstermektedir. Bu ağa örnek olarak Hopfield, Elman ve Jardon ağları verilebilir (Ataseven, 2013).

3.5 Öğrenme Algoritmalarına Göre Yapay Sinir Ağları


Yapay sinir ağ sistemlerinin en ayırt edici özelliklerinden birisi ise öğrenme yeteneğine sahip olmasıdır. Öğrenme; giriş, işlem, bellek, çıkış aşamalarına sahiptir. Öğrenme; tekrar ya da yaşantı yoluyla organizmanın davranışlarında meydana gelen kalıcı ya da izli değişikliklerdir (Aydın, 1999).

İnsan beyni doğumdan sonra çevresindeki süreçleri ve değişimleri duyu organları ile algılar, algıladığı bu davranışları öğrenir, yorumlar ve daha sonra öğrenilmiş olunan bu bilgileri kendi davranış süreçlerinde kullanır. Beyin öğrenilmiş olan bilgilerle gelişir ve tecrübe kazanır. Dolayısıyla karşılaşılan olaylarda nasıl bir tepki gösterebileceğini bilmektedir. Fakat daha önce hiç karşılaşılmayan etkiler karşısında tecrübesiz kalabilir. Yapay sinir ağları da öğrenme sürecinde aynen dış ortamı gözlerle veya vücudun diğer organları ile uyarıları benzer şekilde dış ortamdan girişler (uyarılar) alınır, daha sonra bu girişler beyne iletilerek buradan da değerlendirilerek bir tepki oluşturması gibi yapay sinir ağındaki aktivasyon fonksiyonundan geçirilerek bir tepki çıkışı oluşturulur. Bu çıkış öğrenilmiş olan etkiler (tecrübe) karşılaştırılarak hata bulunmuş olur. Yapay sinir ağlarında öğrenilmiş olan aktivasyonlar, daha önce verilmemiş olan girişler verilip sinir ağının çıkışıyla gerçek çıkışın yaklaşımı karşılaştırılır. Şayet verilmiş olan yeni örnekler doğru olan sonuca yaklaşıyorsa sinir ağı bu aktivasyonu öğrenmiş demektir. Eğer sinir ağı verilmiş olan örnekler optimum değerden fazla ise sinir ağı bu aktivasyonu öğrenmemiş bu ezberlemiştir (Soycan, 2008).

Yapay sinir ağlarında kullanılan öğrenme metotları; danışmalı öğrenme (supervised learning), danışmansız öğrenme (unsupervised learning), takviyeli öğrenme (reinforcement learning) olarak üç temel gruba ayrılmaktadır.

3.5.1 Danışmanlı öğrenme (supervised learning) metodu

Yapay sinir ağlarında en fazla kullanılan bir öğrenme metodudur. Bu ağ kullanılmaya başlamadan önce eğitilir. Bu ağın eğitiminde hem girdi değerleri hem de o girdi değerleri için istenen çıktı değerleri sisteme verilerek istenen sonuç değeri ağın sonuç olarak verdiği değer ile karşılaştırılarak hata hesabı yapılır ve ağırlıklar güncellenir. Bu ağ metodunda başlangıcında rassal olarak verilen değer, ağ tarafından hatası minimize edilene kadar döngüler halinde değiştirilir (Ataseven, 2013).



Şekil 3.10 : Danışmanlı öğrenme yapısı (Öztemel, 2003).

Danışmanlı öğrenme kuralları; Algılayıcı öğrenme kuralı, delta öğrenme kuralı, genişletilmiş delta öğrenme kuralı, geri yayılım öğrenme kurallarından oluşur (Şen, 2003).

Yapay sinir ağlarında istenilen giriş- çıkış verilerinin ne kadar sağlandığının bir değeri olarak denklem 3.3'te belirtilen bir uygunluk fonksiyonu tanımlanmıştır.

$$e_i = d_i - y_i(k) \quad (3.3)$$

Uygunluk fonksiyonu ise denklem 3.4 ifade edilmiştir.

$$E = \frac{1}{2} \sum_i e_i^2 = \frac{1}{2} \sum_i (d_i - y_i(k))^2 \quad (3.4)$$

Denklem 3.4'te sistemin k'inci iterasyonunda yapay sinir ağının çıkış katmanındaki i'ninci çıkış değeri y_i , bu sinirin vermesi istenilen sonuç değeri d_i ile gösterilirse, e_i sinirinin hata sinyalidir (Ataseven, 2013).

Uygunluk fonksiyonu yapay sinir ağının ağırlık değerlerine bağlı olup bu ağırlık denklem 3.5'te belirtilen değerlerinin en uygun şekilde değişmesi işlemlerinden oluşmaktadır.

$$\Delta W_{ij} = -\eta \frac{\partial E(w)}{\partial w_{ij}} \quad (3.5)$$

Denklem 3.5'teki η , öğrenme katsayısıdır.

Yapay sinir ağında çıkışlarda oluşan hatalardan yola çıkarak devredeki ağırlıkların yeniden düzenlenmesi yapılmaktadır. Yapay sinir ağındaki her ağırlık değişimi denklem 3.6 ile ifade edilmektedir.

$$\Delta W_{ij} = \eta \delta_j y_i \quad (3.6)$$

δ_j çıkış katmanı sinirleri ağırları için denklem 3.7 ifade edilmektedir.

$$\delta_j = e_j(k) f_j' \quad (3.7)$$

Gizli katmanlardaki sinir ağırları için denklem 3.8 ifade edilmektedir.

$$\delta_j = f_j' \sum_m \delta_m w_{mj} \quad (3.8)$$

f_j, j sinir ağıının aktivasyon fonksiyonlarıdır.

Yapay sinir ağında önemli konulardan biri sistemin eğitiminin ne kadar süreceğidir. Sistemin eğitiminde belli bir miktarda hata toleransını dikkate almak ve o hata değerinden daha düşük hata değerine ulaşmaya kadar sistemin eğitimi sürdürülmeli ve hata toleransı uygun sınırlarda olmalıdır (Ataseven, 2013).

Danışmanlı öğrenmeye Widrow-Hoff tarafından geliştirilen delta kuralı ile Rumelhart ve McClelland tarafından geliştirilmiş olan deltan ile geri besleme algoritmaları örnek verilebilir (Öztemel, 2003).

3.5.2 Danışmansız öğrenme (unsupervised learning) metodu

Bu model sistemin öğrenimine yardımcı olan herhangi bir danışman yoktur. Sistem yalnızca girdiler (veriler) verilir, örneklerdeki parametrelerde bulunan ilişkilerden sistemin kendi kendine öğrenmesi beklenir, istenilen çıkış değerinin bilinmesine gerek yoktur. Bu metot araştırılan ve gelişen bir öğrenme metottur. Bu yöntemde bilgisayarların insan etkisi olmadan öğrenebileceklerinin bir göstergesidir. Ancak sınırlı bir kullanım alanı olan ve araştırma aşamasındadır (Anderson ve McNeill, 1992).

Bu öğrenme yönteminde sistemin öğrenmesi için yalnızca giriş bilgileri verilir. Bu öğrenmeye örnek olarak Grossberg'in geliştirmiş olduğu ART (Adaptive Resonance Theory) ve Kohonen tarafından geliştirilen SOM (Self Organizing Map) verilir (Öztemel, 2003).

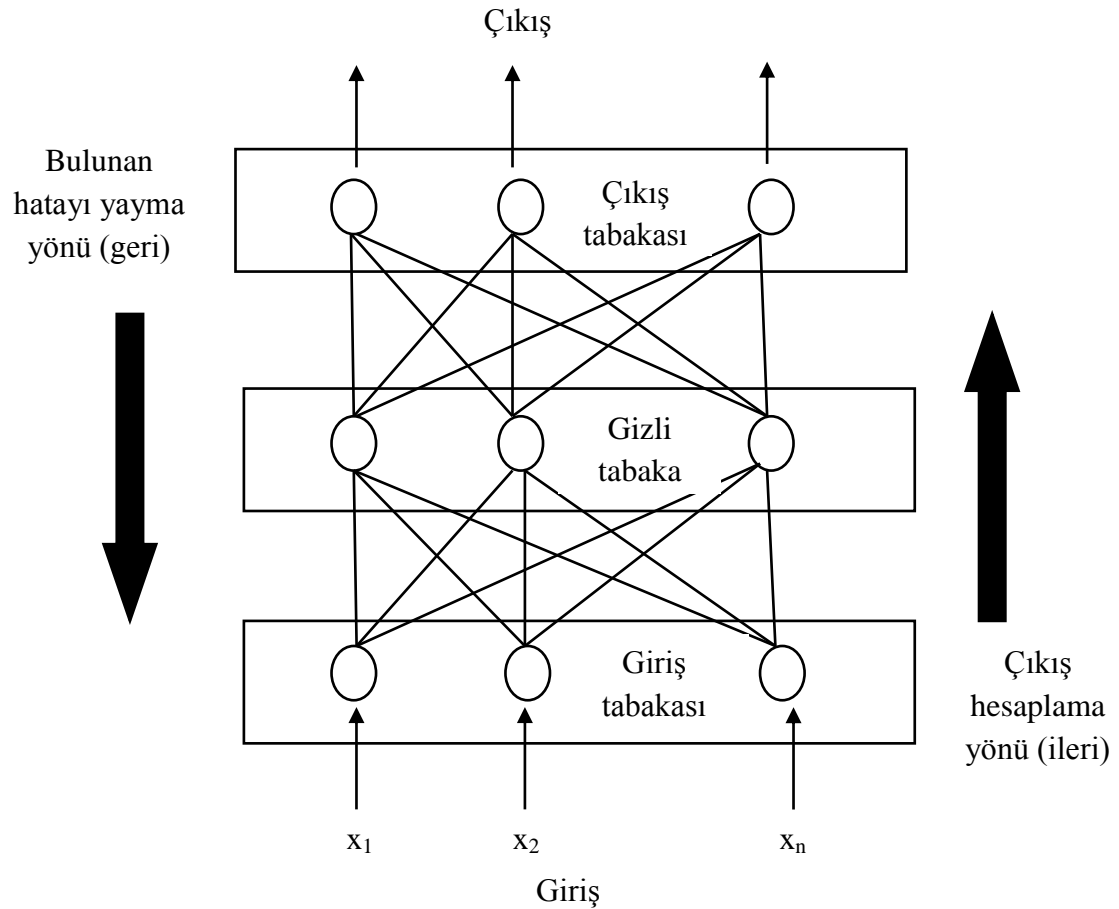
3.5.3 Pekiştirmeli öğrenme (Reinforcement Learning) metodu

Bu öğrenme metodunda, giriş verileri ağa uygulanır ve sonucunda danışman tarafından değerlendirilmesi istenir. Ödüllendirme ve cezalandırma yöntemiyle ağın ağırlıkları güncellenir.

Danışmanlı öğrenmeye yakın bir metottur. Hinton ve Sejnowski'nin geliştirmiş olduğu Boltzmann kuralı ve GA takviyeli öğrenmeye örnek verilebilir (Öztemel, 2003).

3.6 Çok katmanlı perseptronlar (MLP) ve öğrenme algoritmaları

Bu yöntem daha çok mühendislik uygulamalarında kullanılan sinir ağı metodudur. Bu modelin yaygın olarak kullanılmasında öğrenme algoritmalarının çoğunun bu ağı kullanabilmesidir. MLP yönteminde bir giriş, bir veya daha fazla ara segment ve bir çıkış katmanından meydana gelir. Bir segmentteki işlem elemanları bir üst segmentteki bütün işlem elemanlarına bağlıdır. Sistemde akış ileri yönlü olup geri besleme yapısı yoktur. Bundan dolayı ileri beslemeli ağ modeli olarak da tanımlanır.



Şekil 3.11 : Geri yayılım (MLP) yapısı (Öztemel, 2003).

MLP model ađ sisteminde ađa bir rnek bildirilir, bu rneđin neticesinde nasıl bir sonu reteceđi đretilir. (Danıřmanlı đrenme) Sisteme verilen rnek giriř katmanına bildiriliri, ara segmentlerde iřlenir ve sonrasında ıkıř segmentinde de ıkıřlar elde edilir. Sisteme đretimi sađlayan bu eđitme algoritmasına gre ađın ıkıřı ile istenilen ıkıř arasında olan hata tekrar geriye dođru yayılarak hata en az seviyeye dřnceye kadar ađın ađırlık deđerleri deđeritirilir (Soycan, 2003).

3.7 Yapay Sinir Ađlarının Uygulama Alanları

Yapay sinir ađları birok alanda ve uygulamalarda kullanılmaktadır. Bu uygulama alanları; kana analizlerinin sınıflandırılması, parmak izi tanıma, ses tanıma, robotik aralar iin optimum rota belirleme, meteorolojik verilerin yorumlanması, otomatik araların denetimi, toprak sıcaklıđının tahmini, binalarda ısı tahmini ve enerji ihtiyacının belirlenmesi, agregaların sınıflandırmasında, spor sonularını tahmini, betonarme yapılarda donatı ve kesit hesaplanmasında, deprem hasarlarının hızlı tespitinde vs. alanlarında kullanılabilirlerdir.

4. REGRESYON ANALİZİ

Regresyon ilk kez 19. yüzyılda Sir Francis Galton tarafından ortaya atılmıştır. Galton tarafında yapılan çalışmada; anne, baba ve bunların çocuklarının boy uzunlukları arasındaki ilişkiyi araştırılmıştır. Yaptığı bu çalışmanın sonucunda, boyları çok uzun veya çok kısa olan ailelerin çocuklarının boy uzunluklarının grup ortalamasına doğru eğilim gösterdiğini ileri sürmüştür ve buna regresyon demiştir. (Günaşdı, 2014).

İki değişken arasında bir ilişki bulunup bulunmadığı ve şayet varsa bu ilişkinin derecesinin belirlenmesi istatistiksel çözümlenelerde en çok karşılaşılan problemlerden biridir. Değişkenler arasındaki ilişkinin tespitinde regresyon analizi kullanılan bir yöntemdir. İstatistiksel anlamda iki değişken arasındaki ilişkinin varlığı, bunların değerlerinin karşılıklı değişimleri aralarındaki bir bağıllık şeklinde anlaşılabilir. Şayet X değişkeninin değerleri değişirken buna bağlı olarak Y değişkeninin değerleri de değişiyorsa, bu iki veri arasında bir ilişki bulunduğu söylenebilir. Regresyon analizinde veriler, bağımlı değişken veya bağımsız değişken(ler) olarak iki gruba ayrılmaktadır. Bağımlı değişken; bağımsız değişken (ler) tarafından açıklanmaya çalışılan değişkendir. Regresyon analizinde bağımlı değişkenler Y ile ifade edilirken, bağımsız değişken (ler) de X ile ifade edilir (Karaca ve Karacan, 2016).

Regresyon analizinde esas amaç; bağımlı değişken ile bir ya da daha çok bağımsız değişken arasındaki ilişkiyi incelemektir. Regresyon analiz, bilinen verilerden, bilinmeyen verilerin türetilmesine yardımcı olur. Regresyon, bağımlı veya bağımsız değişkenler arasındaki ilişkiyi ve doğrusal eğri kavramını kullanarak, bir tahmin değeri oluşturur. Değişkenler arasındaki ilişki bulunduktan sonra, bağımsız değişkenlerin değeri bilindiğinde bağımlı değişkenin değeri tahmin edilebilir (Can, 2012).

Regresyon analizi aşağıda belirtildiği şekilde sınıflandırılır.

Regresyon analizi, değişken sayısına göre;

- Tek değişkenli regresyon analizi,
- Çok değişkenli regresyon analizi,

Verilerin dağılımına göre;

- Doğrusal regresyon analizi,
- Doğrusal olmayan regresyon analizi,

Verilerin kaynağına göre;

- Ana kütle verileriyle regresyon analizi,
- Örnek verileri ile regresyon analizi,
- Zaman serilerinde regresyon analizi şeklinde gruplandırılır (Karaca ve Karacan, 2016).

4.1 Tek Değişkenli Regresyon Analiz Modeli

Bağımlı değişken verisi ile bağımsız değişken verisi arasındaki doğrusal ilişkiyi tanımlayan tek değişkenli regresyon modeli aşağıda denklem 4.1'de belirtildiği gibidir;

$$Y = a + bx \quad (4.1)$$

Denklem 4.1'te belirtilen Y, bağımlı değişkenin değeri; a regresyon doğrusunun kesişim değeri; b, regresyon doğrusunun eğimi ve x, bağımsız değişken değerini ifade etmektedir (Can, 2012).

4.2 Çok Değişkenli Regresyon Analiz Modeli

Çoklu doğrusal regresyon analizinde bir bağımlı ve birden fazla bağımsız değişken arasındaki fonksiyonel ilişkiyi incelenmektedir. Çoklu doğrusal regresyondaki esas amaç; bağımlı değişkeni etkilediği belirlenen değişkenler aracılığı ile bağımlı değişkenin değerini tahmin etmek ile bağımlı değişkeni etkilediği düşünülen bağımsız değişkenlerden hangisinin veya hangilerinin bağımlı değişkeni daha çok etkilediğini bulmak ve aralarındaki ilişkiyi belirleyebilmektir (Günaşdı, 2014).

Y bağımlı değişkeni ile p sayıda bağımsız değişken arasındaki ilişki doğrusal ise ve şayet Y ile X'lere ait n tane gözlem değeri varsa çoklu doğrusal regresyon modeli aşağıda denklem 4.2 ile gösterilmiştir.

$$Y = b_0 + b_1X_{i1} + b_2X_{i2} + \dots + b_pX_{ip} + e_i \quad (i = 1,2 \dots n) \quad (4.2)$$


Denklem 4.2'de $b_0, b_1 \dots b_p$ değerleri regresyon katsayılarını; Y, bağımlı değişkeni; X, Y bağımlı değişkenine bağlı olan değişkenlerdir (Günaşdı, 2014)

5. ÇALIŞMA ALANI


Çalışma alanı; 28° 45' ve 29° 35' Doğu boylamları ile 40° 28' ve 40° 45' Kuzey enlemleri arasında bulunan ve literatürde Gökçe Barajı bölgesidir. Gökçe Barajı, Yalova ilinin güney batısında olup Yalova Termal yolu üzerindedir. Baraj aksının Yalova'ya uzaklığı 8 km, Termal ilçesine uzaklığı 3 km'dir. Şekil 5.1, Şekil 5.2 ve Şekil 5.3'de çalışma alanı gösterilmektedir.



Şekil 5.1 : Çalışma alanının genel görünümü (Google Earth görüntüsü, 2020).



Şekil 5.2 : Çalışma alanı genel görünümü(Google Earth görüntüsü, 2020).



Şekil 5.3 : Çalışma alanı genel görünümü (Google Earth görüntüsü, 2020).


5.1 Gökçe Barajı Yeri ve Göl Alanı (Rezervuar) Jeolojisi

Baraj yeri ve göl alanında magmatik kayaç olarak andezitler bulunmaktadır. Bu andezitler muhtemelen oligosen yaşlıdır. Andezitlerin üzerinde uyumsuz pliosenin karasal fosiesli depozitleri gelmektedir. Bunlardan başka birimlere rastlanmamıştır. Baraj yerindeki andezitler, baraj yerinin her iki yakasının ve göl alanının temel kayacıdır. Andezit volkanik bir kayadır. Bu andezitler gerek katılma esnasında gerekse katılma sonrasında tektonik olaylar neticesinde içlerinde yer yer çatlak / kırık sistemleri oluşmuştur. Bundan dolayı baraj ekseninde belli seviyelere kadar çimento ile perde enjeksiyonu yapılarak geçirimsizliği sağlanacaktır. Karasal fosiesli depozitler, andezitlerin üzerinde yer almakta olup göl alanının büyük bir kısmını kaplar. Killi, kumlu ve çok miktarda irili ufaklı beyaz kuvars çakıllarından oluşmaktadır. Muhtemel yaşları pliosen – neojen yaşındadır. Baraj yerinin her iki yakasında ve göl alanında yamaç molozlarına rastlanmakta olup kalınlıkları 5-10 cm'den 5-6 m kalınlığa kadar değişmektedir. Bu yamaç molozlarının yapısında çeşitli boyutlarda andezit, kuvars çakılları ile killi kumlu birikimler oluşturmaktadır. Baraj yerinin sol sahilinde 10 metre, sağ sahilinde 50 metre kadar genişlikte alüvyon sahaları mevcuttur. Alüvyonda ise killi, kumlu kısımlar ile irili ufaklı andezit, kum taşı, granit, tuf çakıl ve blokları oluşturur. Baraj yerinin aks yerinde kalınlığı 11,50 metre olup geçirimlidir. Göl alanında alüvyon, iyi derecelenmiş kum ve çakıl ile killi kum ve orta derecede plastik killi sahalar şeklindedir. Akış yukarı doğru alüvyon sahaları daralır (DSİ planlama raporu, 1978).



Şekil 5.5 : Gökçe barajı gövde genel görüntüsü.

5.2.1.2 Gökçe barajı rezervuarının (gölü) karakteristik özellikleri




Şekil 5.6 : Rezervuar alanı genel görünümü(Google Earth görüntüsü, 2020).

Baraj kesitinden geçen yıllık ortalama su (1969-1678 yılları verileri için) $77,04 \text{ hm}^3$ 'dür. Bu barajdan yılda $36,6 \text{ hm}^3$ su; içme, kullanma ve endüstri suyu olarak temin edilecek. Ayrıca $6,22 \text{ hm}^3$ su ise tarımsal sulama için ayrılmıştır. Gökçe barajı karakteristik bilgileri **Çizelge 5.2** ve rezervuardaki su seviyesine göre su hacim satıh grafiği **Şekil 5.7**'de gösterilmiştir.

Çizelge 5.2 Gökçe barajı rezervuarının karakteristik bilgileri.

Minimum su seviyesinde (m)	43
Minimum su hacmi (hm ³)	1.480
Minimum rezervuar alanı (km ²)	0.225
Normal su seviyesinde (m)	79.50
Normal su hacmi (hm ³)	21.791
Normal rezervuar alanı (km ²)	1.207
Maksimum su seviyesinde (m)	80
Maksimum su hacmi (hm ³)	22.306
Maksimum rezervuar alanı (km ²)	1.237
Yağış alanı (km ²)	86.5



Şekil 5.7 : Gökçe barajı hacim satıh grafiği.



Şekil 5.8 : Gökçe barajı rezervuar (baraj gölü) genel görüntüsü.

5.2.1.3 Gökçe barajı dolu savak karakteristik bilgileri

Gökçe barajının normal su seviyesinin 79,50 metre, maksimum su seviyesi 80,00 metre olması neden ile dolu savağın kapaklı olarak yapılmasını zorunlu kılmaktadır. Dolu savak kadastrol feyzan piki $Q=496,00 \text{ m}^3 / \text{sn}$ geçirecek şekilde sol sahilde 5,50x8,00 metre boyutlarında 2 adet radyel kapak düşünülmüştür. Dolu savak yapısı her ne kadar baraj gövdesini ikiye ayırıyorsa da sağlam zemine oturmaktadır. Dolu savak **Şekil 5.9** ve **Şekil 5.10** gösterilmiştir (DSİ planlama raporu, 1978).



Şekil 5.9 : Gökçe barajı dolu savak genel görüntüsü.



Şekil 5.10 : Gökçe barajı dolu savak genel görüntüsü.

5.2.1.4 Gökçe barajı dip savak karakteristik bilgileri

Barajdan içme suyu, sulama suyunu ve dereye tahliye sağlamak için 1200mm çapında ve uzunluğu 243,25 m cebri boru yapılarak sağlanmıştır. Maksimum ihtiyaçta dip savaktan çekilecek su debisi $2.10 \text{ m}^3 / \text{sn}$, minimum su kotunda çekilecek su debisi $5.05 \text{ m}^3 / \text{sn}$, normal işletme kotunda $11.40 \text{ m}^3 / \text{sn}$ ve tam kapasite ile çalışması sonucunda ise $15.08 \text{ m}^3 / \text{sn}$ su verilmektedir. Dip savağın boyutlandırılmasında çekilecek maksimum su ihtiyacının yanı sıra bir arıza anında baraj gölünün yaklaşık bir ay içerisinde boşaltılması da dikkate alınarak tasarımı yapılmıştır (DSİ planlama raporu, 1978).



Şekil 5.11 : Gökçe barajı dip savak+vana odası genel görüntüsü.

5.2.1.5 Gökçe barajı eğik su alma yapısı karakteristik bilgileri

Gökçe barajının içme suyu barajı olması, su alma yapısının kademeli su almaya imkân verecek şekilde boyutlandırılmasını zorunlu kılmıştır. Gökçe barajının birinci derecede deprem bölgesinde bulunması kademeli su alabilmek için 38-40 metre yüksekliğinde bir kule yapısının yapılmasını olanak vermemektedir. Bundan dolayı sağlam zemin üzerine açılmış bir kanal ve kanalın üzerine raylar vasıtası ile kayabilen kapaklardan oluşmaktadır. Baraj gölünde su seviyesinin değişmesine paralel olarak kapakların çekilmesi veya yerine konması ile sistem çalışmaktadır (DSİ planlama raporu, 1978).




Şekil 5.12 : Gökçe barajı su alma yapısı genel görüntüsü.

5.3 İklim

Gökçe Barajının rezervuar alanı, yazları kurak ve sıcak kışları ılık ve yağışlı Akdeniz iklimi ile her mevsim yağışlı Karadeniz iklim bölgesi arasında geçiş olan Marmara iklim özelliklerine sahiptir. 1962-1975 yılı verilerine göre yıllık ortalama yağışı 900mm olup Yalova meteoroloji istasyonu gözlemlerine göre en çok yıllık toplam yağış 1011mm, en az yağış yıllık toplam 464mm olarak ölçülmüştür (DSİ planlama raporu, 1978).

5.4 Yağış

Tez çalışmasında rezervuar alanındaki Çınarcık ve Yalova meteoroloji istasyonlarına göre alınan ve **Şekil 4.13**'te görüleceği üzere 2000-2019 yılı veri aralıklarına göre Yalova Gökçe Barajı havzasına düşen aylık toplam ortalama yağış miktarı 2011 yılında 357,95 mm Eylül ayında iken en düşük yağış değerini ise 2015 yılında 0,90 mm değeri ile Ağustos ayında almıştır. Mevsimsel etiler ile sonbahar ve kış aylarında yağış miktarı artmakta, yaz aylarında ise azalmaktadır.




Şekil 5.13 : 2000-2019 yılları arasındaki aylık toplam yağış miktarı.

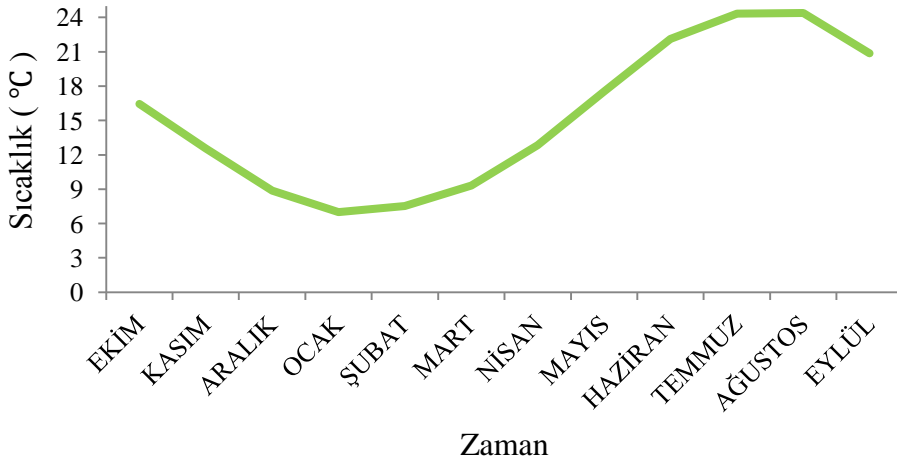
5.5 Sıcaklık

Proje sahasında gözlemlenen sıcaklık, yıllık ortalama sıcaklık 14.2°C olup gözlem süresince gözlemlenmiş en düşük sıcaklık -9.7°C, en yüksek sıcaklık ise 40.2°C'dir (DSİ planlama raporu, 1978).

Tez çalışmasında rezervuar alanındaki Çınarcık ve Yalova meteoroloji istasyonlarına göre ve **Şekil 5.14**'te görüleceği üzere 2000-2019 yılı veri aralıklarına göre ise iki istasyonu ortalama verileri olarak yıllık en düşük ortalama sıcaklık 14.28 °C, en büyük toplam ortalama sıcaklık 16.52 °C, ve ortalama sıcaklık ise 14.28 °C olarak tespit edilmiştir. Ayrıca aylık ortalama en düşük sıcaklık değeri Ocak ayında 7.00 °C iken en yüksek sıcaklık değeri Ağustos ayında 24.39 °C 'dir. Ölçülen günlük en düşük sıcaklık -2.8°C olup günlük en yüksek ise 32.6°C olarak tespit edilmiştir.



Şekil 5.14 : Yıllık ortalama sıcaklık değişim grafiği.




Şekil 5.15 : Aylık ortalama sıcaklık değişim grafiği.

5.6 Buharlaşma

Serbest su yüzü buharlaşması, Penman yöntemine göre DSİ Etüt Plan Dairesi Proje Hidrolojik Fen Heyeti Müdürlüğünce bilgisayar ortamında hesaplanan Yalova meteoroloji verileri alınmıştır. Bu verilere buharlaşmanın toplamda en fazla olduğu ay Temmuz ayı 155mm, en az olduğu ay Aralık ayı 15mm olarak tespit edilmiştir (DSİ planlama raporu, 1978).

Tez çalışmasında rezervuar alanındaki Yalova meteoroloji istasyonuna göre alınan ve **Şekil 5.16**'da görüleceği üzere 2000-2019 yılı veri aralıklarında, Yalova Gökçe Barajı havzasındaki toplam aylık buharlaşma miktarı 189,9 mm ile 2007 yılı Temmuz ayında görülmüş iken en düşük buharlaşma değerleri ise mevsimsel şartlar

dolayısıyla buharlaşma ölçümlerinin yapılamadığı Aralık, Ocak, Şubat ve Mart aylarında görülmektedir.




Şekil 5.16 : 2000-2019 yılları arasındaki aylık toplam ortalama buharlaşma miktarı.

5.7 Rüzgâr

Proje sahasında en hızlı rüzgâr hızı yönü ve şiddeti (kuzey batı) NW 31.8m/sn'dir (DSİ planlama raporu, 1978).

Tez çalışmasında rezervuar alanındaki Yalova meteoroloji istasyonu verilerine göre Şekil 5.17'de görüleceği üzere 2000-2016 yılı arasındaki aylık ortalama en yüksek ortalama rüzgar hızı 13.9 m/sn olarak tespit edilmiştir.



Şekil 5.17 : Aylık ortalama rüzgar hızı grafiği.

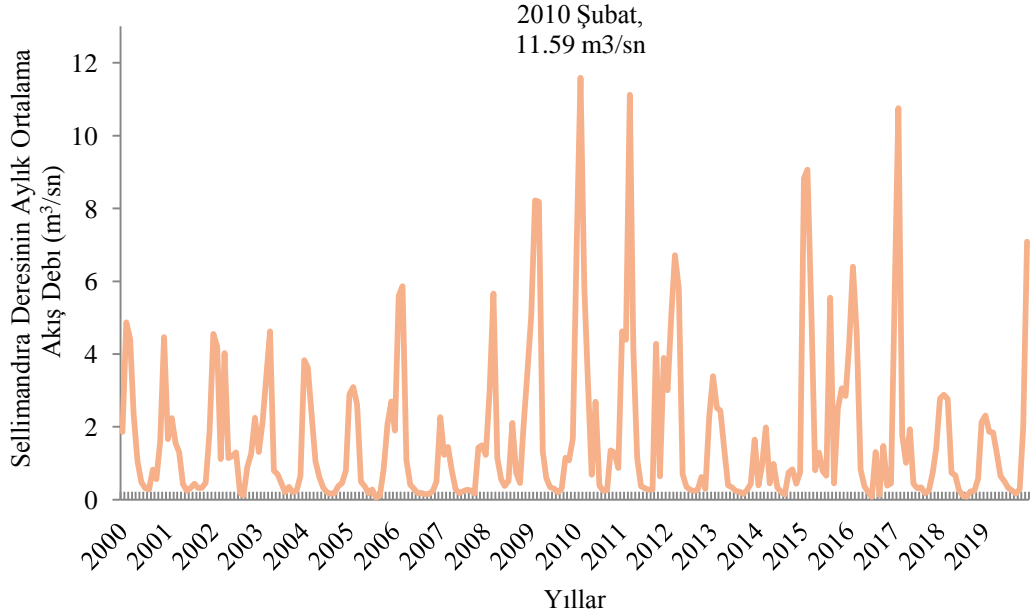
5.8 Gökçe Barajı Su Kaynağı

Barajın su kaynağını Sellimandıra deresi oluşturmaktadır. Gökçe barajının 1969-1978 yılları arasındaki su temini değerlerine göre yıllık ortalama su $77.04 \times 10^6 \text{ m}^3$ 'tür. Gökçe barajının yağış alanının 86.5 km^2 olması, akışa geçen suyun $77.04 \times 10^6 \text{ m}^3$ olduğu rasatlarda tespit edilmesi nedeni ile akışa geçen suyun miktarı 890 mm olması gerekmektedir. ($77,04 \times 10^6 \text{ m}^3 / 86.5 \times 10^6 \text{ m}^2 = 0,890 \text{ m} = 890 \text{ mm}$) Proje alanında yıllık ortalama yağış 900 mm olduğuna göre 900 mm 'lik yağışın 890 mm 'sinin akışa geçmesi mümkün değildir. Bu durum baraj alanında bulunan kaynakların varlığı ile izah edilebilir. Gökçe barajının yüzeysel yağışın akışa geçen miktarı ortalama 250 mm olarak kabul edersek yüzeysel yağıştan gelecek olan su ($86.5 \times 10^6 \text{ m}^2 \times 0.250 = 21.625 \times 10^6 \text{ m}^3$) olacaktır. Bu durumda kaynaklardan gelecek su ise $77.04 \times 10^6 \text{ m}^3 - 21.62 \times 10^6 \text{ m}^3 = 55.42 \times 10^6 \text{ m}^3$ 'tür. Barajın aktif hacim boyutlandırılmasında temel olan su temininin (1969-1978) değerleri bölgenin kurak bir periyodunun içinde olması nedeni ile kritik bir periyot olacağı saptanmıştır. Bu nedenle verilerin kısa süreli olmasından dolayı baraj aktif hacminin boyutlandırılmasında büyük bir hataya düşülmüş olmayacaktır.

Sellimandıra deresinden (Termalden gelen sular karışmadan önce) Yalova ilçesinin (Planlama raporunun hazırlandığı tarihte Yalova'nın, İstanbul'un ilçesi konumunda idi.) mevcut durumundaki içme, kullanma ve endüstri suyu ihtiyaçlarını karşılamaktadır. Sellimandıra deresinden alınan akış suyu hiçbir arıtmaya tabi tutulmadan yalnızca klorlanarak Yalova'ya verilmektedir. Gökçe barajı yağış alanının tamamının ormanla kaplı olması ve yıllık ortalama $77.04 \times 10^6 \text{ m}^3$ 'lük suyun $40-50 \times 10^6 \text{ m}^3$ 'nün kaynak suyu olması Sellimandıra deresinin arıtmaya tabi tutulmadan içilebilme özelliğine oldukça yaklaşmaktadır. Termalden gelen ve Sellimandıra deresine karışan sular; Termal kaplıcalarından 14 lt/sn sıcak su, 1319 nüfuslu Gökçedere köyü ve 442 nüfuslu Üvezpınar köylerinin kanalizasyon sularından oluşmaktadır. Gökçe barajı yapıldığından Termalden gelen kanalizasyon sularının baraj rezervuarına girmeden barajın mansabına akıtılması belirtilmiştir (DSİ planlama raporu, 1978).

Tez çalışmasında kullanılan Sellimandıra Deresi akımları D02A125 nolu AGİ istasyonunca ölçülmektedir. Bu istasyon 1996 yılında devreye alınmıştır. Bu istasyonun yeri Gökçe Barajının membasındaki Üvezpınar Mahallesi'nin güneyindedir. $29^{\circ} 10' 45''$ Doğu boylamı ile $40^{\circ} 35' 28''$ Kuzey enlemlindedir.


Yaklaşık kotu 91 metredir. **Şekil 5.18**'de görüleceği üzere gözlem süresince Sellimandıra deresinde en yüksek aylık ortalama akış debi mevsimsel yağışların etkisi etkile ile 2010 Şubat ayında $11,59 \text{ m}^3/\text{sn}$ iken en düşük akış debisi ise Ağustos ve Eylül aylarında görünmektedir.



Şekil 5.18:2000-2019 yılları arasındaki Sellimandıra deresinin aylık ortalama akış debisi.

5.9 Gökçe Barajı Su Tahliyesi


Şekil 5.19'da görüleceği üzere Yalova Gökçe Barajından mevsimsel yağışların oluşturduğu yüzeysel akışlar ve Sellimandıra deresinden gelen akış suları nedeni ile maksimum su seviyesine ulaşan baraj hacmi dolu savağında tahliye yapılarak, barajdaki taşkın suları kontrollü olarak tahliye edilmektedir. Gökçe Barajından toplamda aylık ortalama en yüksek tahliye değeri $31,754 \times 10^6 \text{ m}^3$ değeri ile 2002 Aralık ayında olmuştur. Barajın içme suyu barajı olması nedeni ile sürekli olarak içme ve kullanma suyuna ihtiyaç duyulmaktadır. Bundan dolayı içme suyuna en çok ihtiyaç duyulan aylar ortalama $3,5 \times 10^6 \text{ m}^3$ değeri ile Temmuz ve Ağustos aylarında olmaktadır.




Şekil 5.19:2000-2019 yılları arasındaki Gökçe Barajından tahliye (dolu savak tahliye+içme suyu+ dip savak tahliyeleri) olan aylık toplam su miktarı.

5.10 Gökçe Barajı Rezervuar Su Değişimi


Sekil 5.20'de görüleceği üzere 2000-2019 yılları arasında Yalova Gökçe Barajında mevsimsel yağışlar ve Sellimandıra deresinde gelen akışlar nedeni ile aylık ortalama rezervuardaki su seviyesi en yüksek değerini 2015 yılı Mayıs ayı 79,51 metre değeri hesaplanmış olup buharlaşma ve su tahliyeleri etkisi ile en düşük su seviyesi 2014 yılı Eylül ayı 46,72 metre değeri olarak hesaplanmıştır. Gökçe Barajı 2000-2019 yılları arasında 2014 yılı hariç dolu savak eşik üst kotunun 72,00 metre olması nedeni ile kış mevsimi şartları dolayısıyla dolu savaktan su tahliyesi yapılmıştır.




Şekil 5.20:2000-2019 yılları arasındaki Gökçe Barajının aylık ortalama rezervuar su kotu.




Şekil 5.21:Gökçe Barajı 2019 yılı aylık ortalama göl su kotu (seviye) değişim grafiği.




Şekil 5.22:Gökçe barajı yıllık ortalama göl su kotu (seviye) değişim grafiği.




Şekil 5.23 : Sellimandıra Deresi 2019 yılı aylık toplam debi değişim grafiği.



Şekil 5.24 :Yıllık yağış+buharlaşma hacmi ve göl su kotu değişim grafiği.



Şekil 5.25 :Yıllık yağış+buharlaşma hacim ve sıcaklık değişim grafiği.



Şekil 5.26: Yıllık toplam yağış ve buharlaşma hacim değişim grafiği.

6. YÖNTEM

Bu tez çalışması kapsamında daha önceki bölümlerde ayrıntılı olarak Yalova Gökçe Barajının yapılış amacını ve bu tez çalışmasının önemi ile literatür çalışması hakkında bilgiler verilmiştir.

Baraj su seviyesinin (kotu) tahmini için kullanılacak olan yapay zekâ ve yapay sinir ağı tanımlanmış, sinir ağının yapı elemanlarının ne olduğu, tarihsel gelişimi, aktivasyon fonksiyonları, yapay zekânın sınıflandırması, öğrenme yöntemleri ve en sonda uygulama alanları hakkında bilgiler verilmiştir.

Bu tez çalışmasının su kaynağını teşkil eden Yalova Gökçe Barajının konumlandığı yerin ve havzasının jeolojik yapısı, baraj tesislerinin karakteristik bilgileri ve özellikleri hakkında bilgiler incelenmiştir. Gökçe Barajının havzasının iklimsel özellikleri, yağış miktarı, sıcaklık değişimleri, buharlaşma miktarı, rüzgâr ve barajın su kaynağının teşkil eden Sellimandıra deresinin debi değişimleri hakkında bilgiler verilmiş ve bunların yıllara ve aylara göre değişim grafikleri incelenmiştir.

6.1 Yalova Gökçe Barajının Su Seviyesinin Tahmin Edilmesinde Kullanılan Veriler

Bu tez çalışmasının amacı 2019 yılı Yalova Gökçe Barajının su seviyesi değişimlerini, yapay sinir ağı yöntemini kullanarak tahmin edilmesini sağlamaktır. Bu tahmin değerleri, barajdaki mevcut suyun daha optimum kullanılmasına neden olacaktır.

6.1.1 Yağış miktarı

17658 Nolu Yalova Çınarçık ilçesi ve 17119 Nolu Yalova meteoroloji istasyonlarının verileri alınmıştır. Yalova Gökçe Barajı havzasındaki iki yağış verisinin ortalamasını almak, barajı besleyen havzasının bütün her yerinde gelen yağış ile daha gerçekçi bir değer alınacağından dolayı ortalama yağış verisi alınmıştır.

$$P_{\text{ort.yağış}} = \frac{P_{\text{Çınarcık}} + P_{\text{Yalova}}}{2} \quad (6.1)$$

Denklem 6.1 'de $P_{\text{ort.yağış}}$, ortalama yağış değerini, $P_{\text{Çınarcık}}$, Çınarcık meteoroloji istasyonu ölçülen yağış değerini, P_{Yalova} , Yalova meteoroloji istasyonunun ölçülen yağış değerini ifade etmektedir.

Baraj yüzey alanına düşen yağış miktarı, denklem 6.2 ifade edildiği gibi hesaplanmıştır.

$$P_{\text{yağış}} = P_{\text{ort.yağış}} \times A \quad (6.2)$$

Denklem 6.2'de $P_{\text{yağış}}$, baraj yüzeyine düşen toplam yağışı, $P_{\text{ort. yağış}}$, baraj yüzeyine düşen ortalama yağışı, A, barajın göl suyu yüzey alanını ifade etmektedir. Denklem 6.1 ve 6.2 ile Yalova Gökçe Barajı göl suyuna düşen yağış miktarının hacmi hesaplanmıştır.

6.1.2 Buharlaşma miktarı

Yalnızca 17119 Nolu Yalova meteoroloji istasyonu verisi kullanılmıştır. Çünkü 17658 Nolu Yalova Çınarcık ilçesi meteoroloji istasyonu için buharlaşma değeri bulunmamıştır.

Gökçe barajı yüzey alanındaki buharlaşma miktarını hesaplanmasında denklem 6.3 kullanılmıştır.

$$E = k_p \times E_i \times A \quad (6.3)$$

Denklem 6.3'te E, yüzeydeki toplam buharlaşan miktar, k_p , düzeltme kat sayısı (0.3-1.0 arasında değişmekte olup bu değer DSİ 113.Yalova Şubesinde alınan Gökçe Barajı bilgi föylerinde 0.78 alınmış olması dolayısıyla 0.78 değeri alınmıştır.), E_i , meteoroloji istasyonu ile ölçülen buharlaşma miktarı, A barajın göl suyu yüzey alanını ifade etmektedir.

6.1.3 Giren debi miktarı


Gökçe barajının ana su kaynağını teşkil eden Sellimandıra deresinin günlük ölçülen debi değerleri kullanarak denklem 6.4 ile baraja giren suyun hacmi hesaplanmıştır.

$$Q_{\text{Giren}} = 24 \times 60 \times 60 \times Q_d \quad (6.4)$$

Denklem 6.4'te Q_{giren} , Bir gün boyunca dereden baraja giren suyun hacmini, Q_d , Sellimandıra deresinde geçen suyun debisini ifade etmektedir.

6.1.4 Sızma miktarı

Gökçe barajında belli dönemlerde ölçülerek tespit edilen, sızan suyun miktarıdır.



Şekil 6.1. 2000-2019 yılları arasındaki Gökçe Barajından sızıntı su miktarı.

Şekil 6.1'de görüleceği üzere Yalova Gökçe Barajından 2000-2003 yılları içerisinde ölçülen aylık ortalama sızıntı suyu miktarı $1 \times 10^3 \text{ m}^3$ iken 2004-2019 yılları içerisinde aylık ortalama sızıntı suyu miktarı $2 \times 10^3 \text{ m}^3$ 'tür. Bu durum baraj sızıntı suyunda bir miktar artış gözlemlenmiş daha sonra ise sızıntı suyu miktarının sabit değerde kaldığı görülmüştür.

6.1.5 Yalova Gökçe Barajından çıkan debiler

6.1.5.1 Sulama suyu

Gökçe barajının vana odasından sulama amaçlı sulama suyuna giden miktar alınarak, hesaplama yapılmıştır. Fakat her zaman sulama amaçlı sulama suyu verilmemiştir.

6.1.5.2 İçme suyu

Yalova ilinin temel içme suyu kaynağı olan Yalova Gökçe Barajında içme suyunu temin etmek için içme suyu arıtma tesisine, vana odasından pompa istasyonuna verilen suyun miktarı alınmıştır.

6.1.5.3 Dolu savak tahliye

Dolu savak tahliye suyu mevsimsel yağışlar nedeni ile baraj su hacminin normal su seviyesinin üstüne çıkması dolayısıyla maksimum su seviyesine ulaşan suyun dolu

savak radyal kapaklarının belli miktarda açılması sonucu rezervuar gölündeki tahliye edilen su hacmidir.

6.1.6 Yalova Gökçe Baraj rezervuar su seviyesi (kot)

Yalova Gökçe Barajına toplamda giren ve çıkan suyun miktarı sonrasında oluşan farkı sonucunda barajda ölçülen su seviyesidir. Baraj rezervuarındaki su seviyesi, günlük olarak eşeller ile ölçülmüş olan değerlerdir.

6.2 Yalova Gökçe Barajı su seviyesinin tahmininde kullanılan MATLAB programı

MATLAB programı isminden de anlaşılacağı üzere (MATrix LABoratory) kelimelerin anlamlarına gelen çok paradigmalı sayısal hesaplama yazılımlı ve dördüncü nesil programlama dilidir. Bu program kullanıcıya matris işleme, fonksiyon ve veri çizme, algoritma uygulamalarını ile kullanıcı ara yüzü oluşturma, C, C++, Java ile Fortran benzeri diğer dillerde yazılmış programlara ara bağlanma imkânı sağlar.

MATLAB programı bilinen matematiksel rakamlar ve işaretler ile ifade edilen problemleri kolay bir şekilde hesaplama, görüntülemesini sağlayarak programlama işlemlerini bütünleştirmiştir.

MATLAB programı ile yapılabilen matematiksel işlemler; doğrusal cebir, veri çözümlenme, işaret işleme, polinom ve ara değer işlemleri, sayısal integral alma ile diferansiyel denklem çözme işlemlerini yapabilmektedir. Aynı zamanda matematiksel işlemlerin sonuçlarını ve bu işlemlerin sonucunda ortaya çıkan iki veya üç boyutlu grafiklere ulaşılmasını sağlayarak bu grafiklerde istenilen renk, ışıklandırma ve animasyon özelliklerini yapılabilmektedir.

6.2.1 MATLAB programının uygulama alanları

- Matematik ve hesaplama işlemleri,
- Algoritma geliştirme,
- Programın analizini sağlayacak verileri bir araya getirme, bu verileri modelleme, benzetim ve bunları prototiplenme,
- Bilimsel ve mühendislik uygulama alanlarındaki grafik işlemlerini yapma ve bu grafikleri geliştirme şeklinde sıralanabilir.

6.2.2 MATLAB programının ana kısımları

MATLAB programı aşağıda belirtilmiş olan beş ana kısımdan oluşmaktadır.


- MATLAB programlama dili,
- Geliştirme ortamı,
- Grafik işlemleri,
- MATLAB matematiksel fonksiyon kütüphanesi,
- MATLAB uygulama programı ara birimi,

6.2.3 MATLAB programlama dili

MATLAB programlama dili; şartlı deyimler, fonksiyonlar, veri yapıları, giriş- çıkış ve nesneye yönelik özellikler içeren yüksek seviyeli matris/dizim dilidir (Temiz, 2015).

MATLAB programında C programlama dili ya da Fortran'daki fonksiyonlar çağırılabilir ve alt programları yazılabilir. Çevirici bir fonksiyon olan MATLAB'ta veri tipleri geçişli ve devamlı olarak oluşturabilir. Bu şekilde derlenen fonksiyonlar tarafından oluşturulan dinamiksel yüklenebilir nesne dosyaları, "MEX-files" (MATLAB executable) olarak adlandırılır. Java, Active X ya da .NET ile yazılan kütüphaneler, direkt olarak MATLAB 'tan çağırılabilir ve birçok MATLAB kütüphanesi (örneğin XML ya da SQL desteği), Java veya Active X kütüphaneleri çerçevesinde wrapper olarak uygulanabilir. MATLAB 'ta, Java'dan çağrışım yapmak çok karmaşıktır, fakat bu durum MATLAB ile genişletilebilir (URL-1).

6.2.4 MATLAB geliştirme ortamı



Şekil 6.2 MATLAB programı ara yüzü penceresi

Şekil 6.2 'de görüleceği üzere MATLAB programı ilgili fonksiyonları ve dosyalarının kullanılmasında yardımcı olan araç ve gereçler dizininden oluşmaktadır. Bu araç ve gereçler ise komut tarihsel günlüğü, yazı düzenleyicisi, yanlış ayıklayıcısı, yardım, çalışma ortamı, dosyalar ve arama yolu için gerekli olan tarayıcılardan oluşmuştur (Temiz, 2015).

6.2.5 MATLAB programında grafik işlemleri

MATLAB, geliştirme uygulamalarıyla beraber grafiksel kullanıcı ara yüzü özelliklerini de destekler. Ayrıca graph-plotting özellikleri entegre edilmiştir. MATLAB'de en sık kullanılan temel grafik çizimi plot fonksiyonudur.

MATLAB programında grafik araçları iki ve üç boyutlu veri görüntülemesi, görüntü işleme, canlandırma ve grafikleri temsil etmekte kullanılan yüksek seviye fonksiyonlarından oluşmuştur. MATLAB analiz çalışmalarında tam bir grafiksel kullanıcı ara yüzünü yapılandırmak kadar grafiklerin görünüşünü istenilen hale sokulmasına olanak sağlayan düşük seviye fonksiyonları da bulunmaktadır (Temiz, 2015).

6.2.6 MATLAB programının matematiksel fonksiyon kütüphanesi

MATLAB matematiksel fonksiyon kütüphanesinde; sum, log, exp, abs, sin, cos, tan, cot vs. elemanal fonksiyonlardan ve karmaşık aritmetikten, matrisin boyutu, matrisin tersi, matris öz değerleri, matrisin determinantı, Bessel fonksiyonları ve hızlı Fourier dönüşümlerine kadar değişen çok geniş kapsamlı hesaplama algoritmalarında oluşur.

6.2.7 MATLAB uygulama programı ara birimi

MATLAB programı ile etkileşimli çalışan C ve Fortran programları yazılmasına olanak sağlayan bir kütüphaneye sahiptir. MATLAB programında rutinleri çağırma, bir hesaplama motoru gibi kullanma ve MAT-dosyalarını yazma ile okuma için gerekli gereçlerden meydana gelmiştir (Temiz, 2015).

6.2.8 MATLAB programındaki yapay sinir ağı eğitim fonksiyonları

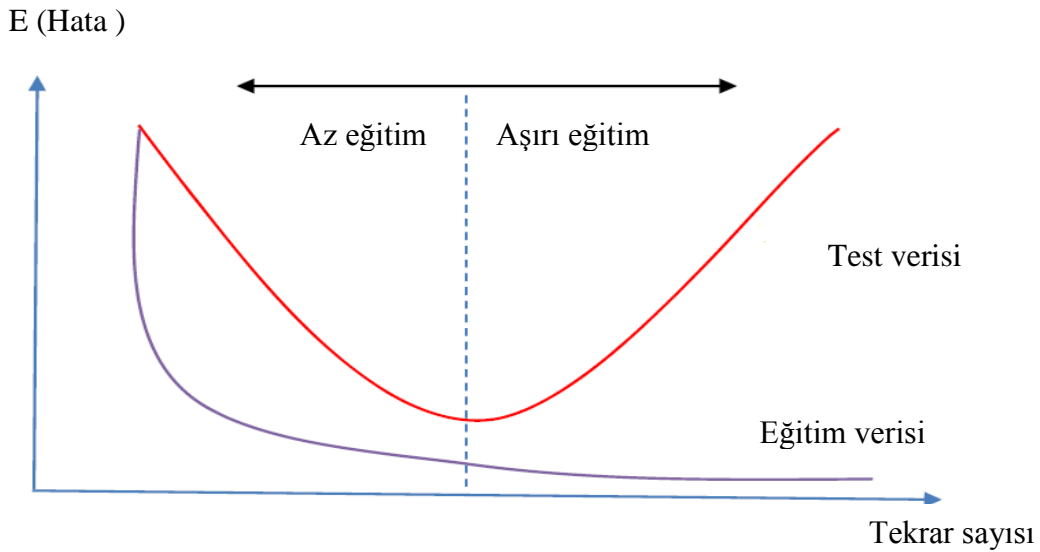
Bu tez çalışmasında yapılan analizlerde iki farklı çok katmanlı yapay sinir ağı eğitim fonksiyonu kullanılmıştır. Bunlar sırasıyla Trainlm (Levenberg-Marquardt) ve Traindm (Gradient Descent with Momentum) eğitim fonksiyonlarıdır. Bu fonksiyonlar yapıları ve sonuca ulaşma süreleri bakımından birbirlerinden farklılık göstermektedir. Bu tez çalışmasında iki farklı yapay sinir ağı modeli için elde edilen sonuçları incelendiğinde, en uygun yapının Trainlm (Levenberg-Marquardt) olduğu görülmüştür.

6.2.9 MATLAB programında eğitim ve test işlemi

MATLAB programında analiz için verilmiş olan veriler eğitim ve test verisi, girdi verisi olarak tanımlanır. Yapay sinir ağlarında performans fonksiyonlarının kullanılması ile ağırlık kat sayılarında yapılacak düzenlemelerle ortaya çıkan sonuç verilerinin belli bir tolerans aralığında olması istenir. MATLAB programında yapılan bu işlen yapay sinir ağının veriler ile eğitilmesi olarak tanımlanır. Yapay sinir ağlarında bulunmak istenen tahmin değerleri için sinir ağının eğilmesi aşamasında yeterli miktarda verinin olması gerekmektedir. Ağa verilen veriler ile eğitimi sona erdikten sonra test işlemine tabi tutulması gerekmektedir. Sinir ağının test edilmesi amacı ile ayrılmış olan girdi verileri, sinir ağının eğitilmesi ile oluşmuş olan sinir ağı modeline indirgenmesi ile çıktı verileri üretilmiş olunur. Sonrasında performans fonksiyonlarını kullanmak sureti ile yapay sinir ağının tahmin etkinliği tespit edilmiş olunur. Sinir ağının eğitimin başlangıcında kullanılan ağırlık kat sayıları ağın kendisi tarafından belirlenir. Ağın eğitimi anında hatalara bağlı olarak bu ağırlık kat sayıları değişime uğrar. Ağırlık kat sayılarındaki bu değişim, hatanın düzeyini belirlenen değere ulaştırana ağırlık matrisinin bulunmasına kadar tekrar edilir. Sinir ağının eğitiminin fazla yapılması ile olumsuz sonuçlar oluşabilir. Sinir ağındaki ağırlık kat sayı matris değerleri yapılan eğitimlere bağlı olması nedeni ile fazla yapılan eğitimle genelleştirme yeteneğinde azalmalar meydana gelir. Bu durumda ise eğitim verisi grubundaki muhtemel hatalı değerleri, sistemin kendisi tarafından sanki mutlak

dođru imiş gibi algılanabileceğinden dolayı eğitimin kalitesi düşük olmuş olur. Bu durum analizli yapay sinir ağı modellerinde eğitim verisinde hiç hata oluşmaz iken test grubunda yapılan ezberlemeler dolayısıyla çok büyük hatalar meydana gelmiş olur. Böylelikle bu gibi durumların oluşmaması için eğitim aşamasında gereğinden fazla eğitim (ezber) yapılmadan sonlandırılmalıdır. Yapay sinir ağı modelindeki eğitim ile test grubu hata değerlerinin birbirine benzer olması, o yapay sinir ağı modelinin iyi tasarlanmış model olduğu anlamına gelir.

Sonuç olarak; yapay sinir ağı modelinin optimum eğitim düzeyine ulaşması sonrasında, eğitim grubu hatalarında düşüş görülürken test grubu hatalarda artma başlar. Bu durumun nedeni yapay sinir ağı modelinde aşırı eğitim ya da ezberlemenin başlamasıdır. Şayet böyle bir durum oluştu ise iyi bir yapay sinir ağı modelinin oluşması için yapılan eğitimin durdurulması gerekmektedir. Eğer mevcut veriler çok az sayıda ise ortalama karesel hata kullanılabilir. Ulaşılmış olunan bu durum hata değerlerini sabit tutacağından, eğitimi durdurmak oluşacak olan aşırı eğitimi engelleyecektir. **Şekil 6.3** 'te eğitim ve test değerleri hatalarının tekrar sayısına göre değişim grafiğı verilmiştir (Temiz, 2015).



Şekil 6.3:Saklı katmanlı yapay sinir ağı modelindeki ağırlık ve hata grafiğı

(Temiz, 2015).

6.3 Analiz Verilerinin Normalizasyonu

Excel programında regresyon analizi ile MATLAB programında yapay sinir ağı analizleri yapılmadan önce veriler mutlaka normalize işleminden geçirilmesi gerekmektedir. Normali edilmesindeki amaç; analizi yapılacak verilerin arasındaki

büyük farklılıkların azaltılması ve verileri bir sayı aralığında sınırlandırmaktır. Literatürde çeşitli normalizasyon formülleri mevcut olup en yaygın olarak kullanılan normalizasyon D_min_max'tır (minimum–maksimum normalizasyonu). Bu normalizasyonda analiz edilecek verilerin hepsi sıfırdan büyük bir değer almaktadır. Aşağıdaki denklem 7.1 'de kullanılan normalizasyon denklemi belirtilmiştir.

$$\vartheta_N = 0.8 \times \left[\frac{\vartheta_R - \vartheta_{\min}}{\vartheta_{\max} - \vartheta_{\min}} \right] + 0.1 \quad (6.5)$$

Denklem 7.1'de ϑ_N , normalize edilmiş olan verinin değerinin sonucu, ϑ_R , normalize edilecek olan veri, ϑ_{\min} , normalize edilecek en küçük değerdeki veri, ϑ_{\max} , normalize edilecek en büyük değerdeki verileri ifade etmektedir.

Yapılan analiz sonucunda bulunan veriler, 6.5 denkleminin ters çevrilmesi ile oluşan denklem 6.6 kullanarak normal değerlere dönüştürülmüş olunur.

$$\vartheta_R = \left(\frac{\vartheta_N - 0,1}{0,8} \right) \times (\vartheta_{\max} - \vartheta_{\min}) + \vartheta_{\min} \quad (6.6)$$

6.4 Tez Analizinde Kullanılan Hata Formülleri

6.4.1 Ortalama kare hata (Mean Squared Error (MSE))

Ortalama kare hata, bir regresyon eğrisinin bir dizi noktaya ne kadar yakın olduğunu söyler. MSE, bir makine öğrenmesi modelinin, tahminleyecinin performansını ölçer, her zaman pozitif değerlidir ve aynı zaman MSE değeri sıfıra yakın olan tahminleyicilerin daha iyi bir performans gösterdiği söylenebilir. MSE formülü denklem 6.7'de gösterilmiştir.

$$MSE = \frac{1}{n} \times \sum_{i=1}^n (Y_i - Y_i^{\wedge})^2 \quad (6.7)$$

Denklem 6.7'de verilen n, verilerin sayısını Y_i , verinin kendisi, Y_i^{\wedge} , verinin ortalamasını ifade eder.

6.4.2 Ortalama mutlak yüzde hata (Mean Absolute Percentage Error (MAPE))

Ortalama mutlak yüzde hata, regresyon ve zaman serileri modellerinde tahminlerin doğruluğunu ölçmek için ortalama mutlak yüzde hata sıkça kullanılmaktadır. Gerçek değerler arasında sıfır içerenler varsa, sıfır ile bölünme olacağı için MAPE hesaplanamaz. Çok düşük tahmin değerleri için yüzde hatası %100'ü geçemez; ancak çok yüksek tahmin değerleri olduğunda yüzde hatasının üst sınırı yoktur. MAPE, tahminleyicilerin doğruluğunu karşılaştırmak için kullanıldığında, tahminleri çok düşük olan bir yöntemi sistematik seçmesi nedeniyle önyargılıdır. Bu ufak ama ciddi problemin, tahmin değerlerin gerçek değerlerine oranını bulan bir doğruluk ölçütü ile üstesinden gelinebilir. Bu yaklaşım geometrik ortalama açısından yorumlanabilen tahminlere yol açar. MAPE formülü denklem 6.8'de gösterilmiştir.

$$MAPE = \frac{100\%}{n} \times \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (6.8)$$

Denklem 6.8 'te n, verilerin sayısını, A_t , gerçek değeri, F_t , tahmin değerini ifade eder.

6.4.3 Ortalama mutlak hata (Mean Absolute Error (MAE))

Ortalama mutlak hata, iki sürekli değişken arasındaki farkın ölçüsüdür. MAE, her gerçek değer ile veriye en iyi uyan çizgi arasındaki ortalama dikey mesafedir. MAE aynı zamanda her veri noktası ile en iyi uyan çizgi arasındaki ortalama yatay mesafedir. MAE değeri kolay yorumlanabilir olduğu için regresyon ve zaman serisi problemlerinde sıkça kullanılmaktadır. MAE, yönlerini dikkate almadan bir dizi tahmindeki hataların ortalama büyüklüğünü ölçen, tüm tekil hataların ortalama eşit olarak ağırlıklandırıldığı doğrusal bir skordur. MAE değeri 0'dan ∞ 'a kadar değişebilir. Negatif yönelimli puanlar yani daha düşük değerlere sahip tahminleyiciler daha iyi performans gösterir. MAE formülü denklem 6.9'da gösterilmiştir.

$$MAE = \frac{1}{n} \times \sum_{i=1}^n |y_i - x_i| = \frac{1}{n} \times \sum_{i=1}^n |e_i| \quad (6.9)$$

Denklem 6.9 'te n , verilerin sayısını, x_i , gerçek değeri, y_i , tahmin değerini ifade eder.

6.5 MATLAB'ta seçilen yapay sinir ağı eğitim fonksiyonları

Yapılan tez çalışmasında, iki farklı çok katmanlı yapay sinir ağı eğitim fonksiyonları olan Levenberg-Marquardt (Trainlm) ve Gradient Descent with Momentum (Traindm)' ile analizler yapılmıştır. Yapılacak olan analizler için 2000-2019 yılı arasındaki verilerin; 2000 yılında 2018 yılına kadar olan verilerden 1368 adet (%95) verinin 1140 adet olan verisi ağın eğitim input verisi, 228 adet veri ise target verisi olarak, 2019 yılının verisi olan 72 adet (%5) verinin 60 âdeti test girdi, geriye kalan 12 adet veri ise sinir ağının test edilmesi için kullanılmıştır. Analizlerde oluşturulan yapay sinir ağının performansını etkileyebilecek hususlardan olan nöron sayıları, gizli hücre sayıları, çevrim sayısı, variant katsayısı, öğrenme ve momentum katsayılarında değişiklikler yapılarak en iyi analiz sonucuna ulaşılmaya çalışılmıştır. Bu analizlerin performans kriterleri ise korelasyon kat sayısı, determinasyon katsayısı, ortalama kare hata (MSE), ortalama mutlak yüzde hata (MAPE) ve ortalama mutlak hata (MAE) değerleri seçilmiştir.

7. ANALİZ

7.1 Çoklu Regresyon Analizi Veri Çalışması

Regresyon analizi, aralarında sebep-sonuç ilişkisi bulunan iki veya daha fazla değişken arasındaki ilişkiyi belirlemek, bu ilişkiyi kullanarak o konu ile ilgili tahminler ya da kestirimler yapabilmek amacıyla yapılır.

Çizelge 7.1: Çoklu regresyon analizi sonucu bulunan katsayılar.

	Katsayılar
Kesişim (b_0)	0,33747416
b_1 Değişkeni 1	0,26486926
b_2 Değişkeni 2	0,42364794
b_3 Değişkeni 3	0,13892231
b_4 Değişkeni 4	0,53278775
b_5 Değişkeni 5	-0,0060191


Çoklu regresyon analizi ile istenilen tahmin verisi denklem 7.1'de gösterilmiştir

$$Y = 0,3374 + 0,2648X_1 + 0,4236X_2 + 0,1389X_3 + 0,5327X_4 - 0,0060X_5 \quad (7.1)$$

Denklem 7.1'de belirtilen katsayıların gerçek ölçülen değerler ile çarpılması sonucunda oluşan tahmin değerleri **Çizelge 7.2'**de gösterilmiştir.


Çizelge 7.2: Çoklu regresyon analizi tahmin çizelgesi.

Aylar	Normalize Geçek Kot Değerleri	Çoklu Regresyon Analizinin Tahmin Ettiği Normalize Değerler	Rezervuardaki Gerçek Su Seviyesi Değerleri (m)	Çoklu Regresyon Analizinin Tahmin Ettiği Değerler (m)
Ocak	0,66938	1,39211	73,32	91,87
Şubat	0,79820	1,03626	76,63	82,74
Mart	0,86689	0,98958	78,39	81,54
Nisan	0,89604	0,80566	79,14	76,82
Mayıs	0,90000	0,86113	79,24	78,24
Haziran	0,83561	0,96757	77,59	80,97
Temmuz	0,74598	1,05453	75,29	83,21
Ağustos	0,63153	1,05537	72,35	83,23
Eylül	0,49612	0,69773	68,88	74,05
Ekim	0,34698	0,73180	65,05	74,92
Kasım	0,18650	0,57124	60,93	70,80
Aralık	0,10000	0,70328278	58,71	74,19



Şekil 7.1 :Çoklu regresyon tahmin değerleri ile gerçek değerlerinin saçılım grafiği. (a)

Şekil 7.1 saçılım grafiğinde çoklu regrasyon tahmin değerlerinin lineer bir saçılım yaptığı, fakat yerinde ölçülen gerçek değerlerin ise dağınık bir saçılımda olduğu görülmektedir.



Şekil 7.2 :Çoklu regresyon tahmin değerleri ile gerçek değerlerinin aylara göre saçılım grafiği. (b)

Şekil 7.2’de Çoklu regresyon analizi sonucunda Mayıs ayındaki değerin yerinde ölçülen değerlere yakın olduğu, diğer ayların tahmin değerlerinin ise yerinde ölçülen grafikteki değerlerine uzak olduğu görünmektedir.

7.2 Levenberg-Marquardt (Trainlm) eğitim fonksiyonu analizi veri çalışmaları

7.2.1 Nöron sayısının belirlenmesi

Aşağıdaki Çizelge 7.3'te Levenberg-Marquardt (Trainlm) eğitim fonksiyonunda nöron sayısının değişiminin performansa etkisi görülmektedir. En iyi performans kriterine göre en yüksek korelasyon (R) % 85,51 değeri nöron sayısı 5 iken ve korelasyon (R) % 86,68 değeri ile nöron sayısı 6 iken almıştır.

Çizelge 7.3 : Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan nöron sayısı tespiti analiz çizelgesi.

Nöron Sayısının Belirlenmesi							
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)						
Eğitim Fonksiyonu	Trainlm (Levenberg-Marquardt)						
Öğrenme Fonksiyonu	Learnlstm						
Aktivasyon Fonksiyonu	Tansig						
Nöron Sayısı Belirlenmesi	1 ile 16 arasında						
Gizli Hücre Sayısı	3						
Çevrim Kat Sayısı	1000						
Variant Katsayısı	10000						
Gizli Katman Sayısı	1						
Öğrenme Katsayısı	0,8						
Momentum Katsayısı	0,7						
Deneme No	Nöron Sayısı	Tahmin Değerinin Toplamı	Gerçek Değerinin Toplamı	All R(%)	MSE	MAE	MAPE %
1	1	9,14	7,47	78,79	0,07467	0,196	92,49
2	2	9,27	7,47	80,50	0,07244	0,194	92,76
3	3	9,01	7,47	81,79	0,06721	0,166	87,36
4	4	8,66	7,47	82,91	0,05015	0,171	68,87
5	5	8,62	7,47	85,51	0,06717	0,164	79,48
6	6	8,69	7,47	86,68	0,09094	0,192	91,44
7	7	7,66	7,47	85,26	0,10339	0,221	77,15
8	8	8,13	7,47	84,36	0,01064	0,233	91,28
9	9	7,52	7,47	80,88	0,08429	0,211	84,82
10	10	9,37	7,47	85,46	0,08321	0,188	86,17
11	11	7,14	7,47	86,19	0,12238	0,242	97,66
12	12	8,22	7,47	87,21	0,01777	0,313	97,72
13	13	8,64	7,47	82,23	0,04586	0,166	59,86
14	14	8,74	7,47	85,42	0,09606	0,195	94,28
15	15	8,68	7,47	80,74	0,06243	0,187	80,86
16	16	9,36	7,47	80,53	0,05294	0,188	68,46

7.2.2 Gizli hücre sayısının belirlenmesi

Aşağıdaki Çizelge 7.4'te Levenberg-Marquardt (Trainlm) eğitim fonksiyonunda gizli hücre sayısının değişiminin performansa etkisi görülmektedir. En iyi performans kriterine göre en yüksek korelasyon (R) % 86,85 değeri ile gizli hücre sayısı 6 iken ve korelasyon (R) % 83,69 değeri ile gizli hücre sayısı 9 iken almıştır.

Çizelge 7.4 :Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan gizli hücre sayısı tespiti analiz çizelgesi.

Gizli Hücre Sayısının Belirlenmesi								
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)							
Eğitim Fonksiyonu	Trainglm (Levenberg-Marquardt)							
Öğrenme Fonksiyonu	Learnqdm							
Aktivasyon Fonksiyonu	Tansig							
Nöron Sayısı	5 ve 6							
Gizli Hücre Sayısı	3 ile 10 arasında							
Gizli Katman Sayısı	1							
Öğrenme Katsayısı	0,8							
Çevrim Katsayısı	1000							
Variant Kat Sayısı	10000							
Momentum Katsayısı	0,7							
Deneme No	Gizli Hücre Sayısı	Nöron Sayısı	Tahmin Değerinin Toplamı	Gerçek Değerinin Toplamı	All R(%)	MSE	MAE	MAPE %
17	3	5	9,32	7,47	82,50	0,08872	0,208	99,31
18	4	5	7,28	7,47	85,80	0,05014	0,14	28,79
19	5	5	8,54	7,47	84,24	0,08699	0,215	85,56
20	6	5	8,94	7,47	86,85	0,10678	0,221	105,1
21	7	5	8,92	7,47	85,79	0,09639	0,227	97,29
22	8	5	8,61	7,47	83,97	0,07583	0,167	85,84
23	9	5	8,90	7,47	83,69	0,02981	0,144	39,21
24	10	5	8,06	7,47	86,89	0,10837	0,242	95,70
25	3	5	7,90	7,47	83,69	0,05901	0,183	49,90
26	4	6	8,58	7,47	83,3	0,05281	0,148	75,68
27	5	6	8,12	7,47	82,5	0,05636	0,177	47,19
28	6	6	9,39	7,47	81,21	0,06289	0,195	79,44
29	7	6	9,35	7,47	83,5	0,07605	0,194	94,60
30	8	6	5,27	7,47	82,65	0,19974	0,337	49,11
31	9	6	8,04	7,47	84,47	0,13209	0,277	98,73
32	10	6	8,33	7,47	81,39	0,11219	0,248	103,9

7.2.3 Çevrim sayısının belirlenmesi

Aşağıdaki Çizelge 7.5'te Levenberg-Marquardt (Trainlm) eğitim fonksiyonunda çevrim sayısı değişiminin performansa etkisi görülmektedir. En iyi performans kriterine göre en yüksek korelasyon (R) % 84,94 değeri ile çevrim sayısı 750 iken almıştır.

Çizelge 7.5 : Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan çevrim sayısı tespiti analiz çizelgesi.

Çevrim Sayısının Belirlenmesi									
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)								
Eğitim Fonksiyonu	Trainglm (Levenberg-Marquardt)								
Öğrenme Fonksiyonu	Learnlm								
Aktivasyon Fonksiyonu	Tansig								
Nöron Sayısı	6								
Variant Katsayısı	10000								
Gizli Katman Sayısı	1								
Öğrenme Katsayısı	0,8								
Momentum Katsayısı	0,7								
Deneme No	Çevrim Sayısı	Gizli Hücre Sayısı	Tahmin Değerinin Toplamı	Gerçek Değerinin Toplamı	All R(%)	MSE	MAE	MAPE %	
33	250	6	9,54	7,47	85,34	0,0756	0,175	92,39	
34	500	6	7,80	7,47	85,21	0,05488	0,162	54,45	
35	750	6	9,64	7,47	84,94	0,07159	0,186	87,51	
36	1000	6	8,17	7,47	82,78	0,08444	0,197	85,16	
37	1250	6	7,04	7,47	84,55	0,0865	0,188	73,96	
38	1500	6	8,30	7,47	84,76	0,99061	0,219	99,45	
39	1750	6	8,82	7,47	83,10	0,09993	0,206	91,36	
40	2000	6	8,82	7,47	83,10	0,09959	0,206	91,09	
41	2250	6	9,18	7,47	82,59	0,04295	0,15	41,68	
42	2500	6	9,41	7,47	80,32	0,06132	0,188	73,27	
43	2750	6	9,28	7,47	87,16	0,10318	0,212	110,9	
44	3000	6	9,37	7,47	79,84	0,09906	0,222	102,3	
45	250	9	9,47	7,47	88,25	0,09009	0,194	100,9	
46	500	9	8,98	7,47	82,14	0,07107	0,169	87,74	
47	750	9	8,32	7,47	85,68	0,02025	0,11	31,89	
48	1000	9	9,66	7,47	85,16	0,09582	0,208	99,14	
49	1250	9	7,98	7,47	83,99	0,03891	0,165	56,44	
50	1500	9	8,74	7,47	84,62	0,91648	0,192	95,45	
51	1750	9	9,69	7,47	83,41	0,08525	0,209	99,03	
52	2000	9	9,44	7,47	82,64	0,07686	0,171	87,46	
53	2250	9	9,12	7,47	85,75	0,07868	0,17	87,93	
54	2500	9	9,63	7,47	80,99	0,08547	0,212	96,18	
55	2750	9	8,28	7,47	83,85	0,05688	0,196	69,99	
56	3000	9	9,72	7,47	83,88	0,08864	0,197	97,08	

7.2.4 Variant sayısının belirlenmesi

Aşağıdaki Çizelge 7.6’da Levenberg-Marquardt (Trainlm) eğitim fonksiyonunda çevrim sayısı değişiminin performansa etkisi görülmektedir. En iyi performans kriterine göre en yüksek korelasyon (R) % 83,88 değeri ile çevrim sayısı 1500 iken ve korelasyon (R) % 82,80 değeri ile çevrim sayısı 6500 iken almıştır.

Çizelge 7.6 : Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan çevrim sayısı tespiti analiz çizelgesi.

Variant Sayısının Belirlenmesi	
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)
Eğitim Fonksiyonu	Trainlm (Levenberg-Marquardt)
Öğrenme Fonksiyonu	Learngdm
Aktivasyon Fonksiyonu	Tansig
Nöron Sayısı	6
Çevrim Sayısı	750
Gizli Katman Sayısı	1
Variant Katsayısının Belirlenmesi	500 ile 10000 arasında
Gizli Hücre Sayısı	9
Öğrenme Katsayısı	0,8
Momentum Katsayısı	0,7

Deneme No	Variant Kat Sayısı	Tahmin Değerinin Toplamı	Gerçek Değerinin Toplamı	All R(%)	MSE	MAE	MAPE %
57	500	8,71	7,47	85,82	0,12784	0,273	109,1
58	1000	8,01	7,47	85,49	0,1444	0,263	104,4
59	1500	8,24	7,47	83,88	0,01263	0,089	29,62
60	2000	9,51	7,47	84,68	0,08389	0,177	91,45
61	2500	8,56	7,47	86,83	0,08981	0,207	100,03
62	3000	8,46	7,47	86,01	0,08741	0,252	78,32
63	3500	9,39	7,47	84,81	0,05326	0,178	68,32
64	4000	9,44	7,47	81,82	0,07075	0,185	88,16
65	4500	9,09	7,47	83,30	0,07523	0,184	88,45
66	5000	9,14	7,47	80,49	0,04315	0,162	45,99
67	5500	9,25	7,47	85,07	0,06261	0,173	75,41
68	6000	9,21	7,47	86,67	0,08521	0,179	91,32
69	6500	8,57	7,47	82,80	0,01685	0,101	31,92
70	7000	5,85	7,47	86,06	0,10479	0,225	39,72
71	7500	9,25	7,47	84,80	0,06362	0,181	75,93
72	8000	9,47	7,47	84,80	0,07448	0,176	89,03
73	8500	9,06	7,47	85,70	0,07342	0,169	85,78
74	9000	9,55	7,47	86,15	0,08046	0,178	94,01
75	9500	6,06	7,47	83,68	0,11527	0,233	33,46
76	10000	9,4	7,47	88,14	0,07322	0,181	87,83

7.2.5 Öğrenme kat sayısının belirlenmesi

Aşağıdaki Çizelge 7.7’de Levenberg-Marquardt (Trainlm) eğitim fonksiyonunda öğrenme kat sayısı değişiminin performansa etkisi görülmektedir. En iyi performans kriterine göre en yüksek korelasyon (R) % 85,64 değeri ile öğrenme kat sayısı 0,50 iken ve korelasyon (R) % 89,21 değeri ile öğrenme kat sayısı 0,70 iken almıştır.

Çizelge 7.7 : Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan öğrenme kat sayısı tespiti analiz çizelgesi.

Öğrenme Sayısının Belirlenmesi									
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)								
Eğitim Fonksiyonu	Trainglm (Levenberg-Marquardt)								
Öğrenme Fonksiyonu	Learnqdm								
Aktivasyon Fonksiyonu	Tansig								
Nöron Sayısı	6								
Çevrim Sayısı	750								
Gizli Katman Sayısı	1								
Gizli Hücre Sayısı	9								
Öğrenme Katsayısının Belirlenmesi	0,1-0,9								
Momentum Katsayısı	0,7								
Deneme No	Variant Kat Sayısı	Öğrenme Kat Sayısı	Tahmin Değerinin Toplamı	Gerçek Değerinin Toplamı	All R(%)	MSE	MAE	MAPE %	
77	1500	0,10	8,84	7,47	86,21	0,06283	0,133	80,49	
78	1500	0,20	9,35	7,47	81,03	0,07319	0,206	86,39	
79	1500	0,30	9,47	7,47	86,47	0,09064	0,196	94,82	
80	1500	0,40	9,46	7,47	86,15	0,09064	0,196	94,82	
81	1500	0,50	8,47	7,47	85,64	0,03062	0,126	24,75	
82	1500	0,60	9,48	7,47	85,06	0,07815	0,169	90,92	
83	1500	0,70	9,42	7,47	89,21	0,06771	0,193	86,61	
84	1500	0,80	8,65	7,47	86,82	0,06243	0,16	73,32	
85	1500	0,90	8,01	7,47	85,34	0,07225	0,195	72,03	
86	6500	0,10	8,12	7,47	84,55	0,07114	0,176	62,1	
87	6500	0,20	8,61	7,47	88,59	0,12691	0,255	93,27	
88	6500	0,30	9,35	7,47	87,35	0,06387	0,161	78,59	
89	6500	0,40	7,32	7,47	84,50	0,07495	0,221	61,16	
90	6500	0,50	9,52	7,47	87,07	0,09757	0,187	108,4	
91	6500	0,60	8,77	7,47	84,58	0,04248	0,172	56,66	
92	6500	0,70	8,82	7,47	85,87	0,10117	0,194	97,47	
93	6500	0,80	8,21	7,47	82,95	0,04521	0,152	29,05	
94	6500	0,90	5,98	7,47	87,45	0,10037	0,218	38,66	

7.2.6 Momentum kat sayısının belirlenmesi

Aşağıdaki Çizelge 7.8'de Levenberg-Marquardt (Trainlm) eğitim fonksiyonunda öğrenme kat sayısı değişiminin performansa etkisi görülmektedir. En iyi performans kriterine göre en yüksek korelasyon (R) % 82,60 değeri ile momentum kat sayısı 0,30 iken almıştır.

Çizelge 7.8 : Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan momentum kat sayısı tespiti analiz çizelgesi.


Momentum Sayısının Belirlenmesi	
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)
Eğitim Fonksiyonu	Trainlm (Levenberg-Marquardt)
Öğrenme Fonksiyonu	Learngdm
Aktivasyon Fonksiyonu	Tansig
Nöron Sayısı	6
Çevrim Sayısı	750
Gizli Katman Sayısı	1
Gizli Hücre Sayısı	9
Variat Katsayısı	1500
Momentum Katsayısı Tespiti	0,1 ile 0,9 arasında

Deneme No	Öğrenme Katsayısı	Momentum Kat Sayısı	Tahmin Değerinin Toplamı	Gerçek Değerinin Toplamı	All R(%)	MSE	MAE	MAPE %
95	0,5	0,10	6,99	7,47	83,67	0,06978	0,198	37,30
96	0,5	0,20	8,35	7,47	84,66	0,04217	0,151	57,98
97	0,5	0,30	9,16	7,47	82,60	0,04688	0,165	65,36
98	0,5	0,40	9,32	7,47	86,58	0,07533	0,159	87,87
99	0,5	0,50	8,69	7,47	84,83	0,06739	0,185	81,31
100	0,5	0,60	9,44	7,47	85,53	0,08005	0,166	91,90
101	0,5	0,70	7,68	7,47	84,02	0,10516	0,212	89,52
102	0,5	0,80	9,41	7,47	81,95	0,08129	0,204	96,39
103	0,5	0,90	9,29	7,47	83,87	0,0943	0,239	101,8
104	0,7	0,10	7,89	7,47	83,69	0,05582	0,167	48,56
105	0,7	0,20	9,21	7,47	84,83	0,07803	0,187	92,42
106	0,7	0,30	9,25	7,47	84,06	0,06096	0,175	83,17
107	0,7	0,40	6,64	7,47	81,07	0,11674	0,254	93,38
108	0,7	0,50	8,80	7,47	87,47	0,10671	0,255	102,24
109	0,7	0,60	9,24	7,47	88,36	0,08171	0,183	87,14
110	0,7	0,70	7,49	7,47	85,39	0,12188	0,230	94,44
111	0,7	0,80	7,99	7,47	85,97	0,08148	0,187	38,99
112	0,7	0,90	9,34	7,47	86,85	0,10076	0,223	99,44


7.2.7 Levenberg-Marquardt (Trainlm) eğitim fonksiyonu analizindeki en yüksek veri sonuçları

Levenberg-Marquardt eğitim fonksiyonu ile yapılan 112 adet yapay sinir ağı analizinde, en iyi performans kriterine sahip ve korelasyon (R) değeri yüksek olan üç analiz verileri alınmış olup bunlarla ilgili sonuçlar aşağıda verilmiştir.


7.2.7.1 23 Nolu analiz sonuçları



Şekil 7.3 : 23 nolu analiz korelasyon (R) değerleri grafiği.



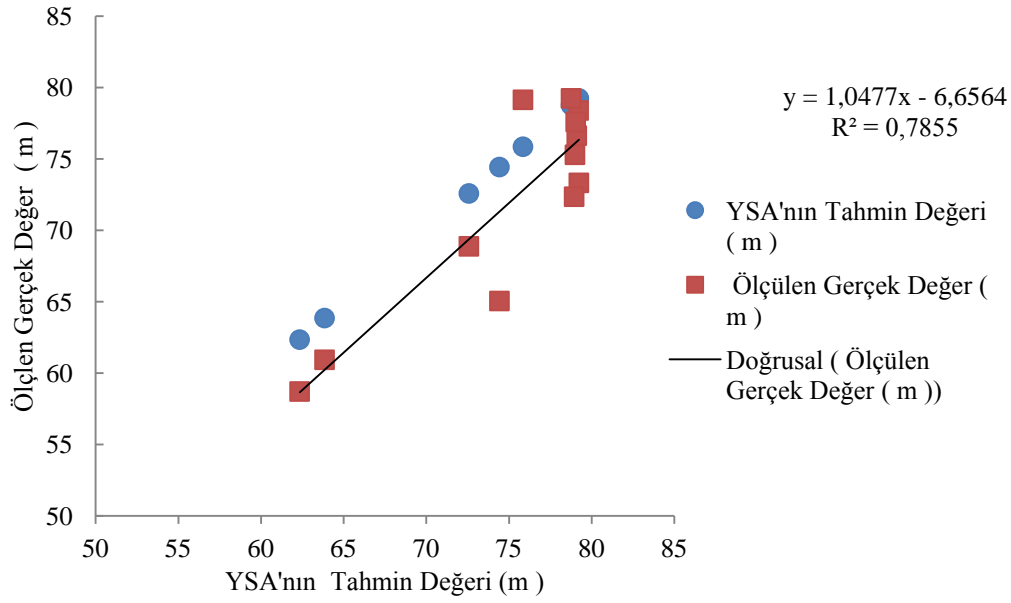
Şekil 7.4 : 23 nolu analiz performans değeri grafiği.




Şekil 7.5: 23 nolu analizin eğitim grafiği.

Çizelge 7.9: 23 nolu analizdeki rezervuarın gerçek seviyesi ile YSA'nın tahmin değerleri çizelgesi.

Analiz No	All R (%) Değeri	Aylar	Normalize Geçek Kot Değerleri	YSA'nın Tahmin Ettiği		Gerçek Seviye Değeri (m)	YSA'nın Tahmin Ettiği Değerleri (m)
				Normalize Değerler	Değerler		
23	83,69	Ocak	0,66938	0,89966579		73,32	79,23
		Şubat	0,79820	0,8947446		76,63	79,11
		Mart	0,86689	0,89911562		78,39	79,22
		Nisan	0,89604	0,76793576		79,14	75,85
		Mayıs	0,90000	0,88124684		79,24	78,76
		Haziran	0,83561	0,89221719		77,59	79,04
		Temmuz	0,74598	0,89047025		75,29	79,00
		Ağustos	0,63153	0,88853572		72,35	78,95
		Eylül	0,49612	0,64046982		68,88	72,58
		Ekim	0,34698	0,71248697		65,05	74,43
		Kasım	0,18650	0,3003616		60,93	63,85
		Aralık	0,10000	0,24158948		58,71	62,34




Şekil 7.6 : 23 nolu analiz için gerçek seviye-YSA tahmin değerleri grafiği (a).




Şekil 7.7: 23 nolu analiz için aylık gerçek seviye-YSA tahmin değerleri grafiği (b).

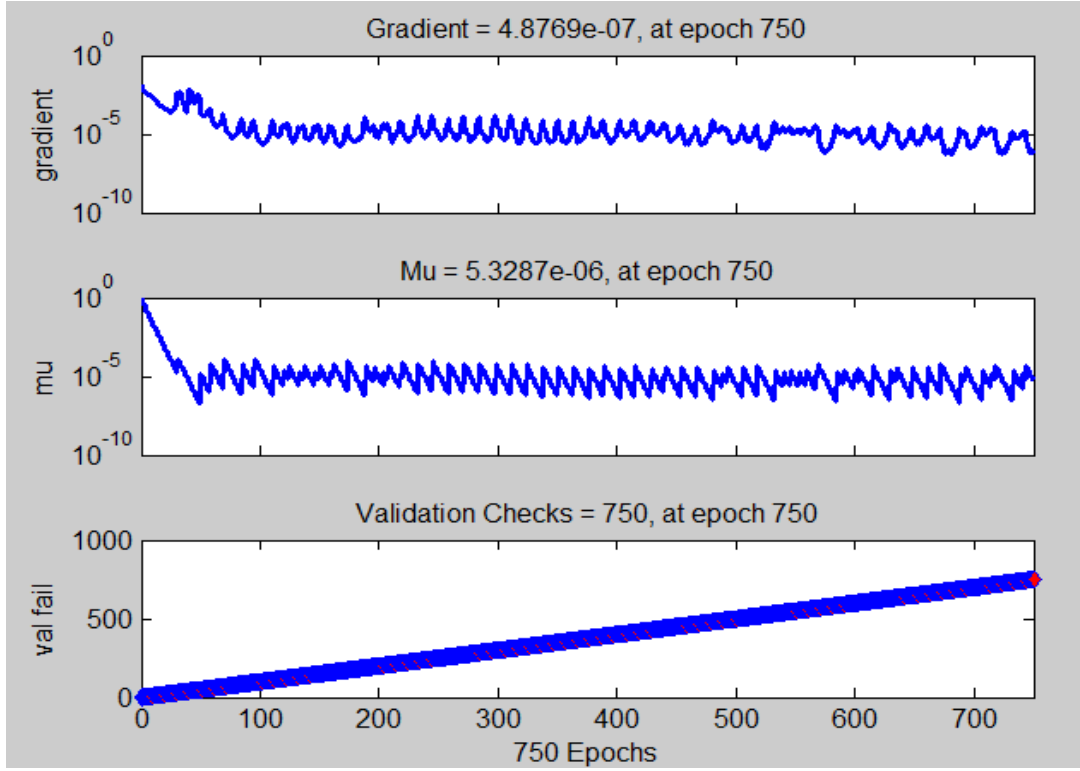
7.2.7.2 59 Nolu analiz sonuları



Şekil 7.8 : 59 nolu analiz korelasyon (R) değeri grafiđi.




Şekil 7.9 : 59 nolu analiz performans değeri grafiđi.




Şekil 7.10 : 59 nolu analiz için eğitimin grafiği.

Çizelge 7.10 :59 nolu analizdeki rezervuarın gerçek seviyesi ile YSA tahmin değerleri çizelgesi.

Analiz No	All R(%) Değeri	Aylar	Normalize Geçek Kot Değerleri	YSA'nın Tahmin Ettiği Normalize Değerler	Gerçek Seviye Değeri (m)	YSA'nın Tahmin Ettiği Değerleri (m)
59	83,89	Ocak	0,66938	0,89999999	73,32	79,24
		Şubat	0,79820	0,89999999	76,63	79,24
		Mart	0,86689	0,90000000	78,39	79,24
		Nisan	0,89604	0,89920352	79,14	79,22
		Mayıs	0,90000	0,89999954	79,24	79,24
		Haziran	0,83561	0,85321620	77,59	78,04
		Temmuz	0,74598	0,66655259	75,29	73,25
		Ağustos	0,63153	0,74961977	72,35	75,38
		Eylül	0,49612	0,42490221	68,88	67,05
		Ekim	0,34698	0,44798081	65,05	67,64
		Kasım	0,18650	0,37596152	60,93	65,79
		Aralık	0,10000	0,22328499	58,71	61,87




Şekil 7.11 : 59 nolu analiz için gerçek seviye-YSA tahmin değerleri grafiği (a).




Şekil 7.12:59 nolu analiz için aylık gerçek seviye-YSA'nın tahmin değerleri grafiği(b).


7.2.7.3 69 Nolu analiz sonuları



Şekil 7.13 : 69 nolu analiz korelasyon (R) deęerleri grafięi.




Şekil 7.14 : 69 nolu analiz performans deęeri grafięi.




Şekil 7.15 : 69 nolu analizin eğitim grafiği.

Çizelge 7.11 : 69 nolu analizdeki rezervuarın gerçek seviyesi ile YSA'nın tahmin değerleri çizelgesi.

Analiz No	All R (%) Değeri	Aylar	Normalize Geçek Kot Değerleri	YSA'nın Tahmin Ettiği Normalize Değerler	Gerçek Seviye Değeri (m)	YSA'nın Tahmin Ettiği Değerleri (m)
69	82,80	Ocak	0,66938	0,89998225	73,32	79,24
		Şubat	0,79820	0,80715163	76,63	76,86
		Mart	0,86689	0,89999341	78,39	79,24
		Nisan	0,89604	0,89902504	79,14	79,21
		Mayıs	0,90000	0,8796457	79,24	78,72
		Haziran	0,83561	0,79982536	77,59	76,67
		Temmuz	0,74598	0,80633806	75,29	76,84
		Ağustos	0,63153	0,84337761	72,35	77,79
		Eylül	0,49612	0,62672571	68,88	72,23
		Ekim	0,34698	0,56262568	65,05	70,58
		Kasım	0,18650	0,29912712	60,93	63,82
		Aralık	0,10000	0,24632508	58,71	62,47



Şekil 7.16 :69 nolu analiz için gerçek seviye-YSA'nın tahmin değerleri grafiği (a).



Şekil 7.17 :69 nolu analiz için aylık gerçek seviye-YSA tahmin değerleri grafiği (b).

7.3 Gradient Descent With Momentum (Traindm) Eğitim Fonksiyonu Analizi Veri Çalışmaları

7.2.1 Nöron sayısının belirlenmesi

Aşağıdaki Çizelge 7.12’de Gradient Descent with Momentum (Traindm) eğitim fonksiyonunda nöron sayısının değişiminin performansa etkisi görülmektedir. En iyi performans kriterine göre en yüksek korelasyon (R) % 79,26 değeri ile nöron sayısı 3 iken almıştır.

Çizelge 7.12 : Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan nöron sayısı tespiti analiz çizelgesi

Nöron Sayısının Belirlenmesi	
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)
Eğitim Fonksiyonu	Trainngdm (Gradient Descent with Momentum)
Öğrenme Fonksiyonu	Learngdm
Aktivasyon Fonksiyonu	Tansig
Gizli Hücre Sayısı	3
Variant Katsayı	10000
Çevrim Katsayısı	1000
Gizli Katman Sayısı	1
Öğrenme Katsayısının Belirlenmesi	0,8
Momentum Katsayısı	0,7

Deneme No	Nöron Sayısı	Tahmin Değerinin Toplamı	Gerçek Değerinin Toplamı	All R(%)	MSE	MAE	MAPE %
1	1	9,70	7,47	74,70	0,07172	0,207	89,09
2	2	9,23	7,47	76,18	0,06286	0,187	84,15
3	3	9,43	7,47	79,26	0,05792	0,188	78,07
4	4	9,45	7,47	76,06	0,07355	0,207	93,12
5	5	9,44	7,47	77,79	0,07137	0,201	91,01
6	6	9,53	7,47	79,24	0,07988	0,197	96,21
7	7	9,17	7,47	78,54	0,07726	0,208	90,19
8	8	9,31	7,47	76,82	0,0688	0,185	86,82
9	9	9,49	7,47	77,29	0,07717	0,199	93,60
10	10	9,49	7,47	80,16	0,06804	0,195	89,19
11	11	9,34	7,47	77,97	0,06285	0,182	86,88
12	12	9,38	7,47	76,23	0,07895	0,204	93,92
13	13	9,84	7,47	79,33	0,08675	0,212	100,40
14	14	9,39	7,47	79,1	0,06872	0,191	89,79
15	15	9,46	7,47	80,25	0,08484	0,202	98,92
16	20	9,47	7,47	78,61	0,08084	0,184	94,97

7.3.2 Gizli hücre sayısının belirlenmesi

Aşağıdaki Çizelge 7.13'te Gradient Descent with Momentum (Traindm) eğitim fonksiyonunda gizli hücre sayısının değişiminin performansa etkisi görülmektedir. En iyi performans kriterine göre en yüksek korelasyon (R) değerini % 76,01 değeri ile gizli hücre sayısı 3 iken almıştır.

Çizelge 7.13 : Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan gizli hücre sayısı tespiti analiz çizelgesi.

Gizli Hücre Sayısının Belirlenmesi	
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)
Eğitim Fonksiyonu	Traingdm (Gradient Descent with Momentum)
Öğrenme Fonksiyonu	Learngdm
Aktivasyon Fonksiyonu	Tansig
Nöron Sayısı	3
Gizli Hücre Sayısının Tespiti	3 ile 10 arasında
Gizli Katman Sayısı	1
Öğrenme Kat Sayısı	0,8
Çevrim Katsayısı	1000
Variant Kat Sayısı	10000
Momentum Katsayısı	0,7

Deneme No	Gizli Hücre Sayısı	Tahmin Değerinin Toplamı	Gerçek Değerinin Toplamı	All R(%)	MSE	MAE	MAPE %
17	3	9,23	7,47	76,01	0,05957	0,184	84,24
18	4	8,82	7,47	76,41	0,05708	0,167	80,32
19	5	8,30	7,47	76,60	0,06133	0,185	85,07
20	6	9,48	7,47	76,47	0,07599	0,212	91,34
21	7	9,54	7,47	75,71	0,06749	0,201	86,44
22	8	9,46	7,47	76,09	0,07051	0,201	89,04
23	9	9,35	7,47	77,74	0,07158	0,206	85,5
24	10	75,52	7,47	75,52	0,06576	0,197	84,65

7.3.3 Çevrim sayısının belirlenmesi

Aşağıdaki Çizelge 7.14'te Gradient Descent with Momentum (Traindm) eğitim fonksiyonunda çevrim sayısının değişiminin performansa etkisi görülmektedir. En iyi performans kriterine göre en yüksek korelasyon (R) değerini % 79,62 değeri ile çevrim sayısı 2000 iken almıştır.

Çizelge 7.14 : Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan çevrim sayısı tespiti analiz çizelgesi.

Çevrim Sayısının Belirlenmesi	
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)
Eğitim Fonksiyonu	Traingdm (Gradient Descent with Momentum)(Momentum Terimli Geri Yayılım Algoritması)
Öğrenme Fonksiyonu	Learngdm
Aktivasyon Fonksiyonu	Tansig
Nöron Sayısı	3
Çevrim Sayısının Belirlenmesi	250-3000 arasında
Variant Kat Sayısı	10000
Gizli Katman Sayısı	1
Gizli Hücre Sayısı	3
Öğrenme Katsayısı	0,8
Momentum Katsayısı	0,7

Deneme No	Çevrim Sayısı	Tahmin Değerinin Toplamı	Gerçek Değerinin Toplamı	R(%)	MSE	MAE	MAPE %
25	250	9,48	7,47	75,36	0,06673	0,198	85,01
26	500	9,51	7,47	75,47	0,06827	0,199	86,37
27	750	9,50	7,47	75,47	0,06729	0,199	85,71
28	1000	9,52	7,47	75,51	0,07100	0,200	88,98
29	1250	9,54	7,47	75,56	0,07280	0,201	90,17
30	1500	9,28	7,47	78,57	0,06187	0,190	80,43
31	1750	9,25	7,47	77,28	0,05802	0,189	79,86
32	2000	9,14	7,47	79,62	0,0484	0,176	67,68
33	2250	9,58	7,47	75,82	0,07421	0,199	92,86
34	2500	9,47	7,47	79,52	0,06832	0,185	82,44
35	2750	9,30	7,47	76,74	0,06845	0,196	88,15
36	3000	9,38	7,47	76,64	0,06536	0,186	85,54

7.3.4 Variant sayısının belirlenmesi

Aşağıdaki Çizelge 7.15'te Gradient Descent with Momentum (Traindm) eğitim fonksiyonunda variant sayısının değişiminin performansa etkisi görülmektedir. En iyi performans kriterine göre en yüksek korelasyon (R) değerini %77,14 değeri ile variant sayısı 7.000 iken almıştır.

Çizelge 7.15 : Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan variant sayısı tespiti analiz çizelgesi.

Variant Sayısının Belirlenmesi							
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)						
Eğitim Fonksiyonu	Traingdm (Gradient Descent with Momentum)						
Öğrenme Fonksiyonu	Learngdm						
Aktivasyon Fonksiyonu	Tansig						
Nöron Sayısı	3						
Çevrim Sayısı	2000						
Gizli Katman Sayısı	1						
Çevrim Sayısı	2000						
Gizli Hücre Sayısı	3						
Öğrenme Katsayısı	0,80						
Momentum Katsayısı	0,7						
Deneme No	Variant Kat Sayısı	Tahmin Değerinin Toplamı	Gerçek Değerinin Toplamı	All R(%)	MSE	MAE	MAPE %
37	500	9,40	7,47	77,07	0,68530	0,189	88,74
38	1000	9,51	7,47	75,89	0,07080	0,204	89,79
39	1500	9,38	7,47	76,99	0,06310	0,184	82,94
40	2000	9,36	7,47	75,59	0,05961	0,192	80,36
41	2500	9,35	7,47	77,59	0,06213	0,195	83,49
42	3000	9,49	7,47	79,21	0,06117	0,19	80,66
43	3500	9,43	7,47	78,08	0,06685	0,192	87,30
44	4000	9,45	7,47	77,12	0,06450	0,192	83,96
45	4500	9,47	7,47	76,49	0,07134	0,201	89,02
46	5000	9,31	7,47	77,12	0,07169	0,200	91,26
47	5500	9,32	7,47	77,44	0,06411	0,196	81,39
48	6000	9,4	7,47	76,11	0,06789	0,193	87,53
49	6500	9,44	7,47	79,15	0,06445	0,187	80,84
50	7000	8,96	7,47	77,14	0,04839	0,176	71,55
51	7500	9,44	7,47	74,71	0,07185	0,198	90,58
52	8000	9,08	7,47	76,43	0,05197	0,19	74,74
53	8500	9,32	7,47	75,44	0,05842	0,192	75,44
54	9000	9,16	7,47	76,62	0,06139	0,189	82,88
55	9500	9,41	7,47	79,66	0,05994	0,191	80,17
56	10000	9,35	7,47	76,91	0,06743	0,194	88,39

7.3.5 Öğrenme kat sayısının belirlenmesi

Aşağıdaki Çizelge 7.16’da Gradient Descent with Momentum (Traindm) eğitim fonksiyonunda öğrenme katsayısının değişiminin performansa etkisi görülmektedir. En iyi performans kriterine göre en yüksek korelasyon (R) değerini % 78,92 değeri ile öğrenme kat sayısı 0,70 iken almıştır.

Çizelge 7.16 : Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan öğrenme kat sayısı tespiti analiz çizelgesi.

Öğrenme Sayısının Belirlenmesi	
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)
Eğitim Fonksiyonu	Trainngdm (Gradient Descent with Momentum)
Öğrenme Fonksiyonu	Learngdm
Aktivasyon Fonksiyonu	Tansig
Nöron Sayısı	3
Çevrim Sayısı	2000
Gizli Katman Sayısı	1
Çevrim Sayısı	2000
Variant Katsayısı	7000
Gizli Hücre Sayısı	3
Öğrenme Katsayısının Belirlenmesi	0,1 ile 0,9 arasında
Momentum Katsayısı	0,7

Deneme No	Öğrenme Kat Sayısı	Tahmin Değerinin Toplamı	Gerçek Değerinin Toplamı	All R(%)	MSE	MAE	MAPE %
57	0,10	9,54	7,47	72,64	0,06511	0,201	84,84
58	0,20	9,36	7,47	76,68	0,06196	0,185	83,89
59	0,30	9,13	7,47	74,96	0,05781	0,196	72,86
60	0,40	9,31	7,47	76,02	0,06831	0,184	87,67
61	0,50	9,42	7,47	76,06	0,06688	0,201	87,21
62	0,60	9,33	7,47	74,94	0,06012	0,195	81,3
63	0,70	9,15	7,47	78,92	0,05081	0,166	75,56
64	0,80	9,46	7,47	78,06	0,06852	0,192	85,31
65	0,90	9,48	7,47	75,21	0,07408	0,199	94,11

7.3.6 Momentum kat sayısının belirlenmesi

Aşağıdaki Çizelge 7.17’de Gradient Descent with Momentum (Traindm) eğitim fonksiyonunda momentum sayısının değişiminin performansa etkisi görülmektedir. En iyi performans kriterine göre en yüksek korelasyon (R) değerini % 79,12 değeri ile momentum kat sayısı 0,10 iken almıştır.

Çizelge 7.17: Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan momentum kat sayısı tespiti analiz çizelgesi.


Momentum Sayısının Belirlenmesi	
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)
Eğitim Fonksiyonu	Trainngdm (Gradient Descent with Momentum)
Öğrenme Fonksiyonu	Learngdm
Aktivasyon Fonksiyonu	Tansig
Nöron Sayısı	3
Çevrim Sayısı	2000
Gizli Hücre Sayısı	3
Gizli Katman Sayısı	1
Variant Kaysayısı	7000
Öğrenme Katsayısı	0,7
Momentum Katsayısı	0,1 ile 0,9 arasında
Tespiti	

Deneme No	Momentum Kat Sayısı	Tahmin Değerinin Toplamı	Gerçek Değerinin Toplamı	All R(%)	MSE	MAE	MAPE %
66	0,10	9,32	7,47	79,12	0,05446	0,191	73,87
67	0,20	9,63	7,47	76,70	0,07667	0,212	94,56
68	0,30	9,34	7,47	76,69	0,06634	0,192	85,26
69	0,40	9,32	7,47	76,10	0,0746	0,189	92,61
70	0,50	9,74	7,47	77,47	0,07855	0,209	93,88
71	0,60	9,36	7,47	76,51	0,07269	0,205	90,33
72	0,70	9,32	7,47	77,12	0,06996	0,195	91,03
73	0,80	9,47	7,47	79,59	0,06454	0,189	82,25
74	0,90	9,39	7,47	76,02	0,06503	0,191	84,69


7.3.7 Gradient Descent with Momentum (Traindm) eğitim fonksiyonu analizindeki en yüksek veri sonuçları

Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan 74 adet yapay sinir ağı analizinde, en iyi performans kriterine sahip ve korelasyon (R) değeri yüksek olan üç analiz verileri alınmış olup bunlarla ilgili sonuçlar aşağıda verilmiştir.


7.3.7.1 32 nolu analiz sonuları



Şekil 7.18 : 32 nolu analiz korelasyon (R) değeri grafiđi.




Şekil 7.19:32 nolu analiz performans değeri grafiđi.




Şekil 7.20:32 nolu analiznin eğitim grafiği.

Çizelge 7.18 :Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan 32 nolu analiznin tespit çizelgesi.

Analiz No	All R (%) Değeri	Aylar	Normalize Geçek Kot Değerleri	YSA'nın	Gerçek Seviye Değeri (m)	YSA'nın
				Tahmin Ettiği Normalize Değerler		Tahmin Değerleri (m)
32	79,62	Ocak	0,66938	0,89939120	73,32	79,22
		Şubat	0,79820	0,83334026	76,63	77,53
		Mart	0,86689	0,89568850	78,39	79,13
		Nisan	0,89604	0,79174825	79,14	76,46
		Mayıs	0,90000	0,81422105	79,24	77,04
		Haziran	0,83561	0,79805680	77,59	76,62
		Temmuz	0,74598	0,82258808	75,29	77,25
		Ağustos	0,63153	0,88592368	72,35	78,88
		Eylül	0,49612	0,78315359	68,88	76,24
		Ekim	0,34698	0,71163205	65,05	74,41
		Kasım	0,18650	0,37614315	60,93	65,80
		Aralık	0,10000	0,52931113	58,71	69,73




Şekil 7.21 : 32 nolu analiz için gerçek seviye-YSA tahmin değerleri grafiği (a).




Şekil 7.22: 32 nolu analiz için aylık gerçek seviye-YSA tahmin değerleri grafiği (b).

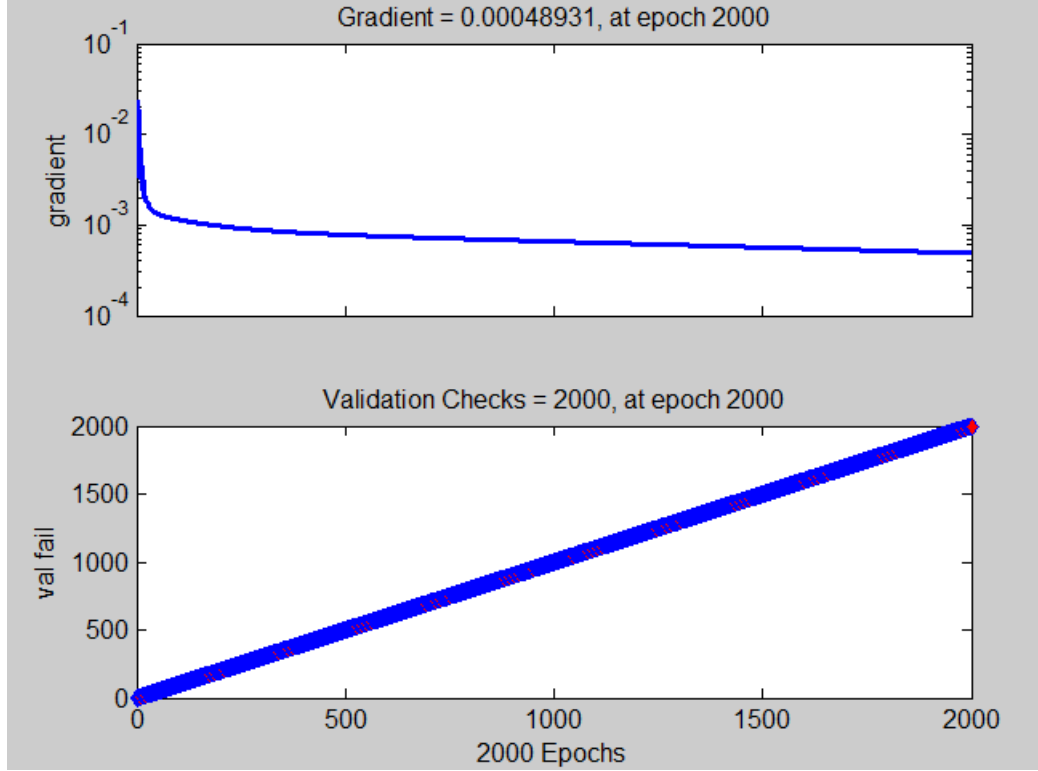
7.3.7.2 50 nolu analiz sonuları



Şekil 7.23 : 50 nolu analiz korelasyon (R) deęerleri grafięi.




Şekil 7.24:50 nolu analiz performans grafięi.




Şekil 7.25 : 50 nolu analiznin eğitim grafiği.

Çizelge 7.19 : Gradient Descent with Momentum (Traindm) eğitim fonksiyon ile yapılan 50 nolu analiznin tespit çizelgesi.

Deneme Testi No	All R (%) Değeri	Aylar	Normalize Geçek Kot Değerleri	YSA'nın Tahmin Ettiği Normalize Değerler	Gerçek Seviye Değeri (m)	YSA'nın Tahmin Değerleri (m)
50	77,14	Ocak	0,66938	0,74701911	73,32	75,31
		Şubat	0,79820	0,84891973	76,63	77,93
		Mart	0,86689	0,78638680	78,39	76,32
		Nisan	0,89604	0,81123851	79,14	76,96
		Mayıs	0,90000	0,75418449	79,24	75,50
		Haziran	0,83561	0,87710260	77,59	78,65
		Temmuz	0,74598	0,83447074	75,29	77,56
		Ağustos	0,63153	0,83801267	72,35	77,65
		Eylül	0,49612	0,71657871	68,88	74,53
		Ekim	0,34698	0,74700672	65,05	75,31
		Kasım	0,18650	0,44564051	60,93	67,58
		Aralık	0,10000	0,55747866	58,71	70,45




Şekil 7.26 : 50 nolu analiz için gerçek seviye-YSA tahmin değerleri grafiği (a).




Şekil 7.27 :50 nolu analiz için aylık gerçek seviye-YSA tahmin değerleri grafiği (b).

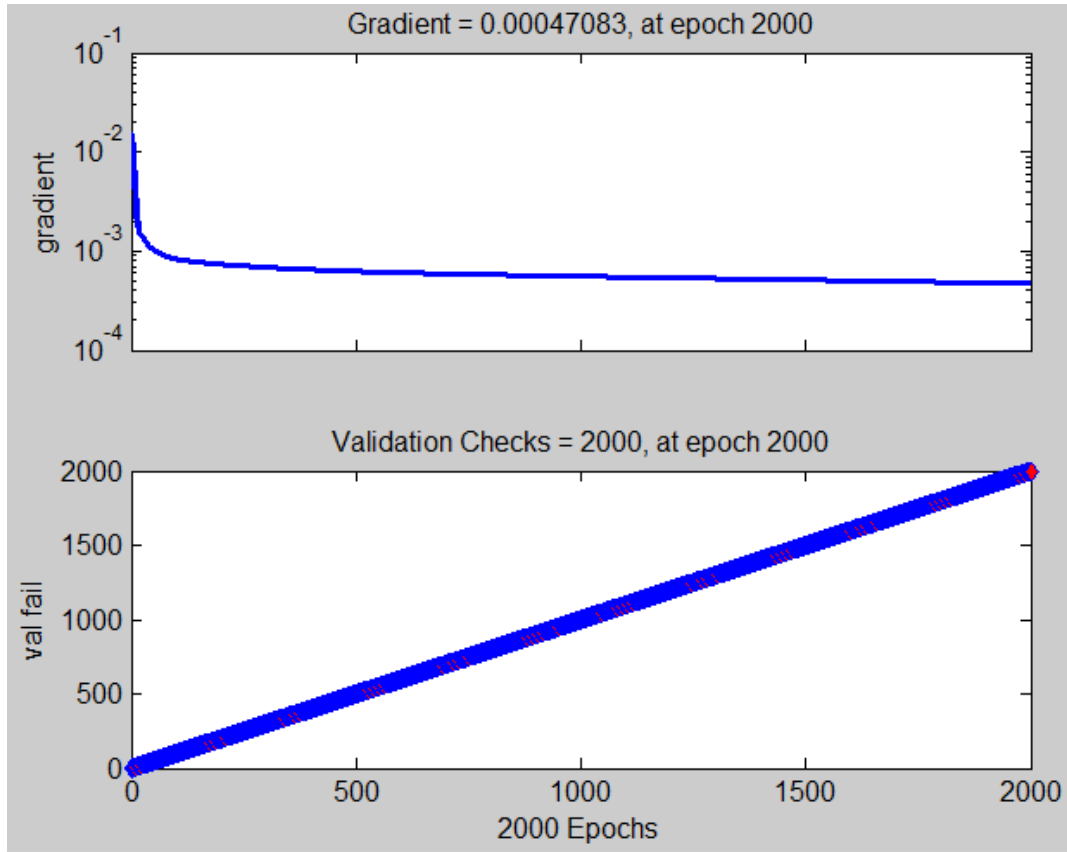
7.3.7.3 63 Nolu analiz sonuları



Şekil 7.28 : 63 nolu analiz korelasyon (R) deęerleri grafięi.



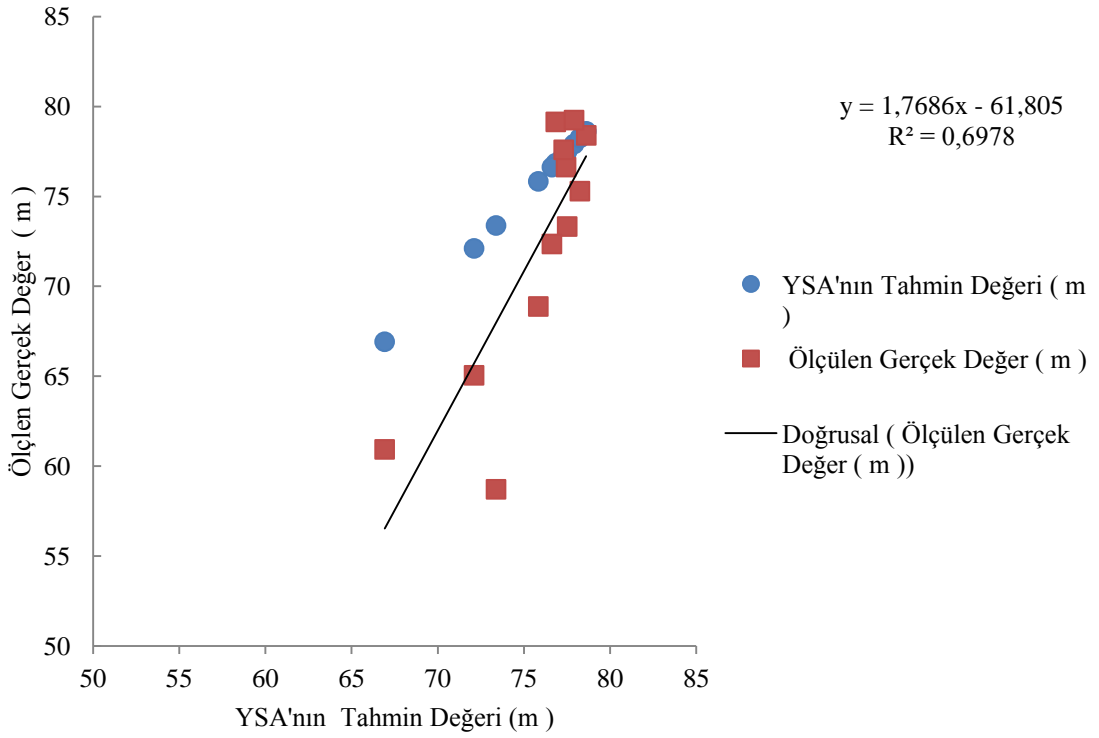
Şekil 7.29:63 nolu analiz performans grafięi.




Şekil 7.30 : 63 nolu analiznin eğitim grafiği.

Çizelge 7.20: Gradient Descent with Momentum (Traindm) eğitim fonksiyon ile yapılan 63 nolu analiznin tespit çizelgesi.

Deneme Testi No	All R (%) Değeri	Aylar	Normalize Geçek Kot Değerleri	YSA'nın Tahmin Ettiği Normalize Değerler	Gerçek Seviye Değeri (m)	YSA'nın Tahmin Değerleri (m)
63	78,92	Ocak	0,66938	0,83255503	73,32	77,51
		Şubat	0,79820	0,82994910	76,63	77,44
		Mart	0,86689	0,87565957	78,39	78,62
		Nisan	0,89604	0,80674028	79,14	76,85
		Mayıs	0,90000	0,84807748	79,24	77,91
		Haziran	0,83561	0,82464383	77,59	77,31
		Temmuz	0,74598	0,86125073	75,29	78,25
		Ağustos	0,63153	0,79798345	72,35	76,62
		Eylül	0,49612	0,76719938	68,88	75,83
		Ekim	0,34698	0,62196541	65,05	72,10
		Kasım	0,18650	0,41972637	60,93	66,91
		Aralık	0,10000	0,67161721	58,71	73,38



Şekil 7.31: 63 nolu analiz için gerçek seviye-YSA tahmin değerleri grafiği (a).



Şekil 7.32:63 nolu analiz için aylık gerçek seviye-YSA tahmin değerleri grafiği (b).

Yapılan bu tez çalışmasında Yalova Gökçe Barajının rezervuarında bulunan su seviyesindeki değişimlerin çoklu regresyon analizi ve yapay sinir ağı ile tahmin edilmesi ile bulunması istenen su seviyesi ölçümleri için yapılan analizlerin tahmin performans kriterleri verileri karşılaştırılmış olup bu çalışmanın sonuçlarına dayanarak aşağıdaki **Çizelge 7.21**, **Çizelge 7.22** ve **Çizelge 7.23**'te belirtilen hususlar tespit edilmiştir.

Çizelge 7.21: Çoklu regresyon analizi ile yapılan sonuç çizelgesi.

MSE	MAE	MAPE (%)	All R	R ² (a)	R ² (b)
0,133	0,3043	104,32	63,51	58,08	31,51

Çizelge 7.22:Levenberg-Marquardt (Trainlm) eğitim fonksiyonu ile yapılan sonuç çizelgesi.

Analiz No	MSE	MAE	MAPE (%)	R	R ² (a)	R ² (b)
23	0,02981	0,144	39,21	83,69	78,75	85,28
59	0,01263	0,089	29,62	83,88	88,25	94,14
69	0,01685	0,101	31,92	82,80	89,48	93,96

Çizelge 7.23:Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan sonuç çizelgesi

Analiz No	MSE	MAE	MAPE(%)	R	R ² (a)	R ² (b)
32	0,04840	0,176	67,68	79,62	65,57	70,70
50	0,4839	0,176	71,55	77,14	67,68	71,58
63	0,05081	0,166	75,56	78,92	69,78	66,01

8. SONUÇ ve ÖNERİLER

Yalova İli Gökçe Barajının rezervuarında bulunan su seviyesindeki değişimlerin regresyon analizi ve yapay sinir ağları ile tahmin edilmesinden bu çalışmanın sonuçlarına dayanarak aşağıda belirtilen hususlar tespit edilmiştir.

Çoklu regresyon analizi sonucunda bulunan %58,08 determinasyon (R^2_a) değeri tahmin verisinin doğruluğu için kabul edilebilir bir değer değildir. Bu durum ise aynı zamanda analizleri oluşturan girdi verilerinin, çıktı verileri ile arasındaki ilişkinin iyi olmadığını göstermektedir.

Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan 74 adet analiz sonucunda en iyi tahmin sonucu, korelasyon katsayısı (R) %77,14 ve determinasyon katsayısı ($R^2_{(b)}$) % 71,58'dir. Bulunan bu determinasyon oranı tahmin değerlerinin doğruluğunda kabul edilebilir bir değer değildir. Dolayısıyla Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan analiz sonuçlarının, su seviyesi tahmininde kullanılması uygun değildir.

Levenberg-Marquardt eğitim fonksiyonu ile yapılan 112 adet analiz sonucunda en iyi tahmin sonucunun, korelasyon katsayısı (R) % 83,88 ve determinasyon katsayısı ($R^2_{(b)}$) % 94,14'tür. Bulunan bu determinasyon oranı ise tahmin değerlerinin doğruluğunda kabul edilebilir bir değerdir. Dolayısıyla Levenberg-Marquardt eğitim fonksiyonu ile yapılan bu tahmin verilerinde Mart, Nisan, Mayıs ile Eylül aylarındaki değerlerinin yerinde ölçülen değerlere yakın değerlere sahip olduğu, Temmuz ve Eylül ayı tahmin değerlerinin ise yerinde ölçülen değerlerden daha küçük olduğu, ayrıca diğer tahmin değerlerinin genel olarak ölçülen değerlerden yüksek olduğu görülmektedir.

Çoklu regresyon analizinin tahmin ettiği 2019 yılı ortalama baraj su seviyesi 79,38metre, Gradient Descent with Momentum (Traindm) eğitim fonksiyonu ile yapılan analizin tahmin değeri 75,31 metre ve Levenberg-Marquardt eğitim fonksiyonu ile yapılan tahmin değeri 73,77 metre iken, barajdaki gerçek ortalama su seviyesi ise 72,13metre olarak ölçülmüştür. Bu durumda gerçek değere en yakın değer Levenberg-Marquardt eğitim fonksiyonu ile yapılan analiz tahmin değerlerinin olduğu görülmektedir.

Bu çalışmada Levenberg-Marquardt (LM) ve Gradient Descent with Momentum (GDM) eğitim fonksiyonları kullanılmış olup BFGS Quasi-Newton (BFG), Scaled Conjugate Gradient (SCG), One Step Secant (OSS) gibi farklı algoritmalar kullanılarak da değişik tahmin sonuçları araştırılabilir.

Ayrıca bu çalışmanın veri araştırması yapılırken 1997 ve 2019 yılları arasındaki günlük yağış miktarı, buharlaşma değerleri, baraj su seviyesi değerleri, baraj haznesine giren debi değerleri aylık işletme tablosunda bulunmuş, fakat 1997 ve 2000 yılları arasındaki toplam su tahliyesi ile ilgili değerler aylık işletme tablosunda bulunamamıştır. Yani bu durumda yapay sinir ağları kullanılarak 1997-2000 yılları arasındaki toplam tahliye suyu miktarı araştırılabilir.

Gökçe Barajının su seviyesinin tahminlerinin elde edilmesinde kullanılan performans seçim kriterinin tespit etmek için korelasyon kat sayısı, determinasyon katsayısı, ortalama kare hata (MES), ortalama mutlak hata (MAE) ve ortalama mutlak yüzde hata (MAPE) değerlerinin en az ikisinin en optimum değerlerde olanlar seçilmiştir. Ancak bu seçim kriterlerinin yanında ortalama hata (ME), kök ortalama kare hata (RMSE), simetrik ortalama mutlak yüzde hata (SMAPE), ortalama mutlak ölçekli hata (MASE) vb. hata kriterlerini kullanılarak farklı seçim modelleri oluşturulabilir.

Yalova Gökçe Barajında 2000-2003 yılları içerisinde ölçülen aylık ortalama sızıntı suyu miktarı $1 \times 10^3 \text{ m}^3$ iken 2004-2019 yılları içerisinde aylık ortalama sızıntı suyu miktarı $2 \times 10^3 \text{ m}^3$ 'tür. Bu durum baraj sızıntı suyunda bir miktar artış gözlemlenmiş daha sonra ise sızıntı suyu miktarının sabit değerde kaldığı tespit edilmiştir. Bu durum 2004 yılında itibaren baraj sızma değerlerinde büyük değişiklikler olmaması ve kurak dönemlerde de aynı sızma değerinin bulunması, ölçümlerinin tutarlılığı açısından değerlendirildiğinde tutarsızlık gösterdiği dolayısıyla bu sızma ölçümlerinin daha dikkatli yapılması uygun olacaktır.

Ayrıca Yalova Gökçe Barajındaki toplam su tahliye değerleri düştüğünde, dolu savak eşiği üst kotu ile aynı değerde rezervuarın uygun bir yerinde iletim kanalı yapılarak, tahliye edilecek olan sular bu iletim kanalında geçirilerek başka bir amaç için su kaynağı olarak kullanılabilir.

Yapılan analizler ile bulunan su seviyeleri tahmin değerleri, Yalova Gökçe Barajının rezervuarındaki su seviyesinde ilerde su miktarında sıkıntı yaşanıp yaşanmayacağı veya dolu savaktan su tahliyesinin olup olmayacağına bir göstergesi olabilir. Bu tahmin değerleri ile Yalova Gökçe Barajının su seviyesinde bir önceki gerçekleşen

değerlere göre artışlar olacağı tespit edilmiştir. Bu durum bir yıllık tahmin verisi ile su sıkıntısının yaşanıp yaşanmayacağı söylenebilir, ancak yalnızca bir ön bilgi olabilecektir.

Sonuç olarak, bu çalışmada elde edilen sonuçlar ışığında Yalova Gökçe Barajının su seviyesinin tahmininde yapay sinir ağının kullanılması baraj işletmesi çalışmalarında bir ön bilgi sağlayacaktır.

KAYNAKLAR

- Abu Salam, Z.,K.,A.,** (2018)., Yapay Sinir Ağları İle Dibi Barajının Seviye Tahmini, Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Ana Bilim Dalı, Isparta, S., 1-45.
- Al Aboodi, A., Dawood, A., Abbas, S.,** (2009)., Prediction of Tigris River Stage in Qurna, South of Iraq, Using Artificial Neural Networks. Engineering and Technology Journal, 27(13), 2448-2450.
- Albayrak, G., A.,** (2017)., İklim Değişikliğinin Su Kaynakları Yönetimine Etkisi, Ankara Örneği, Uzmanlık Tezi, İller Bankası Anonim Şirketi.
- Alp, M., Cigizoğlu, H.,** (2007)., Suspended Sediment Load Simulation By Two Artificial Neural Network Methods Using Hydrometeorological Data. Environmental Modelling and Software, 22, 2-13.
- Altunkaynak, A.,** (2007)., Forecasting Surface Water Level Fluctuations Of Lake Van By Artificial Neural Network. Water Resour Manage (21), 399-408.
- Aksoy, H., Unal, N., Eris, E., Yuce, M.,** (2013)., Stochastic Modeling Of Lake Van Water Level Time Series With Jumps And Multiple Trends. Hydrology and Earth System Sciences, 17, 2297–2303.
- Anderson, D., ve McNeill, G.,** (1992)., Artificial Neural Networks Technology., Kaman Sciences Corporation 258 Genesee Street Utica, New York, USA. (http://andrei.clubicisco.ro/cursuri/f/fsym/5master/aacnnga/AI_neural_nets.pdf 29.5.2020)
- Aydın, A.,** (1999)., Gelişim ve Öğrenme Psikolojisi, Anı Yayıncılık, Ankara.
- Ataseven, B.,** (2013)., Yapay sinir ağları ile öngörü modellemesi, İstanbul Kültür Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, S.101-107.
- Bayazıt, M.,** (2013)., Hidroloji, Birsen Yayınevi, Davutpaşa Cad. Davutpaşa Emintaş Sitesi 103/430, Topkapı, İstanbul
- Can, M.,** (2012)., Yapay Sinir Ağları İle Akım Tahmini;Mahmudiye Göleti Örneği, Yüksek Lisans Tezi, İstanbul Kültür Üniversitesi, Fen Bilimleri Enstitüsü, S:8-10., İstanbul.
- Çalım, M.M.,** (2008)., Yapay Sinir Ağları Yöntemi ile Baraj Hazne Kotu Tahmini., Yüksek Lisans Tezi, Mustafa Kemal Üniversitesi, Fen Bilimleri Enstitüsü , Hatay.

- Doğan, E., Kocamaz, U., Utkucu, M., Yıldırım, E.,** (2016)., Modelling Daily water level fluctuations of Lake Van (Eastern Turkey) using Artificial Neural Networks. *Fundam. Appl. Limnol.*, 187(3), 177–189.
- Erkek, C., Ağralıoğlu, N.,** (2013)., Su Kaynakları Mühendisliği, 7. Baskı, Beta Basım A.Ş., İkitelli Çevre Sanayi Sitesi 8. Blok No:38-40-42-44, Başakşehir, İstanbul.
- Holger, R., Graeme, C.,** (1996)., The Use of Artificial Neural Networks for the Prediction of Water Quality Parameters. *Water Resources Research*, 32(4),1013- 1022.
- Günaşdı, N., E.,** (2014)., Çok Değişkenli Çoklu Doğrusal Regresyon Analizinin İncelenmesi, Yüksek Lisans Tezi, Zootečni Anabilim Dalı, Biyometri ve Genetik Bilim Dalı, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, S:1-2., Erzurum.
- Karaca, Ç., Karacan, H.,** (2016)., Çoklu Regresyon Metoduyla Elektrik Tüketim Talebini Etkileyen Faktörlerin İncelenmesi, Selçuk Üniversitesi, Mühendislik Fakültesi, ISSN:2147-9364 (Elektronik), S:185-188, Konya.
- Keskenler, M., F.,¹ ve Keskenler, E., F.,²** (2017)., Geçmişten günümüze yapay sinir ağları ve tarihçesi, ¹Atatürk Üniversitesi, Erzurum, ²Recep Tayyip Erdoğan Üniversitesi, Rize, Takvim-i Vekayi, ISSN:2148-0087, Çilt 5, No:2, Sf:8-18.
- McCulloch, W.S., ve Pitts, W.A.,** (1943)., A logical calculus of ideas immanent in nervous activity. *Buttetin of mathematics and biophysics*, 5,115-133.
- Mpallas, L., Tzimopoulos, C., Evangelides, C.,** (2011)., Comparison between Neural Networks and Adaptive Neuro-fuzzy Inference System in Modeling Lake Kerkini Water Level Fluctuation Lake Management using Artificial Intelligence. *Journal of Environmental Science and Technology*, 4(4), 366-376.
- Okoye, C., Igboanugo, A.,** (2013)., Predicting Water Levels At Kainji Dam Using Artificial Neural Networks. *Nigerian Journal of Technology*, 32, 129-136.
- Özaydın, Ö.,** (2009)., ARMAX Modelleri ve Porsuk Barajı Su Seviyesinin Öngörüsü. Doktora Tezi, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Anabilim Dalı, Eskişehir.
- Özen, A., Ediş, S., Göl, C.,** (2014)., İznik Gölü Minimum Su Seviyelerinin Zaman Serisi Yöntemleri İle Modellenmesi. *Journal of Biodiversity and Environmental Sciences*, 8(24), 125-132.
- Öztemel, E.,** (2003)., Yapay Sinir Ağları, Papatya Yayıncılık.

Shafaei, M., Kisi, O., (2016)., Lake Level Forecasting Using Wavelet – Svr, Wavelet–Anfis and Wavelet – Arma Conjunction Models. Water Resour Manage, 30, 79-97.

Soycan, Y., T., (2008)., Yapay sinir ađları yaklaşımı ile kompaksiyon parametrelerinin tahmini, Niđde Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliđi Ana Bilim Dalı, Sf.23

Şen, Z., (2004)., Yapay sinir ađları ilkeleri, İstanbul, Su Vakfı Yayınları.

Temiz, T., (2015)., Sapanca Gölü Havzasını Besleyen Derelerde Taşınan Askıda Katı Madde Miktarının Tahmin Edilmesi, Doktora Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliđi Ana Bilim Dalı, Kocaeli.

Tezel, G., Büyükyıldız, M., Kahramanlı, H., (2013)., Lake Level Prediction Using Artificial Neural Network With Adaptive Activation Function. Recent Advances in Civil and Mining Engineering. Antalya, Turkey.

Tokar, A., Markus, M., (2000)., Precipitation-runoff Modeling Using Artificial Neural Networks and Conceptual Models. Journal of Hydrologic Engineering, 5(2), 156-161.

Vaheddoost, B., Aksoy, H., Abghari, H., (2016)., Prediction of Water Level using Monthly Lagged Data in Lake Urmia, Iran. Water Resources Management, 30(13), 4951–4967.

Yarar, A., Onüçyıldız, M., (2009)., Yapay Sinir Ađları ile Beyşehir Gölü Su Seviyesi Deđişimlerinin Belirlenmesi., Selçuk Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 24(2), 21-30.

URL-1: <https://tr.wikipedia.org/wiki/MATLAB> (Erişim tarihi:01.05.2020)

EKLER

Belirtilen Eklerin kapsamı dolayısıyla CD içerisinde sunulacak

Ek A: DSİ Gökçe Barajı Planlama Rapor, 1978.

Ek B: Yapay Sinir Ağı Analiz Girdi Verileri Tablosu ve Grafikleri.

Ek C: Yapay Sinir Ağı Analiz Sonuçları ve Grafikleri.

ÖZGEÇMİŞ



Adı Soyadı : Yunus DAMLA
Doğum Yeri ve Tarihi : BATMAN, 1987
E-Posta :yunusdamla72@gmail.com

ÖĞRENİM DURUMU:

- **Lisans** :2010, Selçuk Üniversitesi, Mühendislik Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü
- **Yüksek Lisans** :2020, Kırklareli Üniversitesi, İnşaat Mühendisliği Bölümü

MESLEKİ DENEYİM:

- 20/08/2010-05/10/2011 Etik Yapı Denetim (Yardımcı Kontrol Elemanı + Şantiye Şefi)
- 06/10/2011-16/06/2012 Erk Yapı Proje Müh. İnş. San. ve Tic. Ltd. (Kaba İşler Şantiye Şefi)
- 29/07/2013-15/08/2019 DSİ 11.Bölge Müdürlüğü/ Çokal Barajı Kontrol Başmühendisliği / Keşan / Edirne (Tatbikat Kontrol Mühendisi)
- 15/08/2019- DSİ 1.Bölge Müdürlüğü/Proje ve İnşaat Şube Müdürlüğü /Bursa(Proje Kontrol Mühendisi)