

**KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**NAMAZGÂH BARAJINDA METEOROLOJİK VERİLER
KULLANILARAK YAPAY SINIR AĞLARI İLE AKIŞIN
TAHMİN EDİLMESİ**

AHMET RAŞİT AKGÜN

KOCAELİ 2019

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI

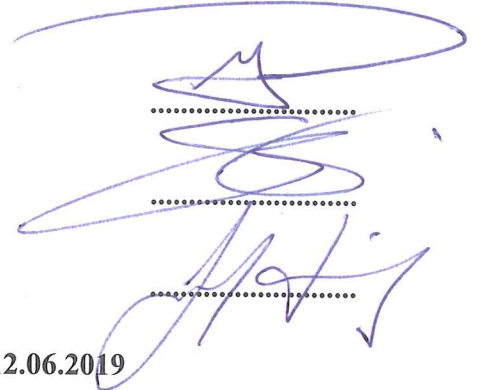
YÜKSEK LİSANS TEZİ

NAMAZGAH BARAJINDA METEOROLOJİK VERİLER
KULLANILARAK YAPAY SİNİR AĞLARI İLE AKIŞIN
TAHMİN EDİLMESİ

AHMET RAŞİT AKGÜN

Prof. Dr. Mücahit OPAN
Danışman, Kocaeli Üniversitesi
Prof. Dr. Safa Bozkurt COŞKUN
Jüri Üyesi, Kocaeli Üniversitesi
Dr. Öğr. Üyesi Temel TEMİZ
Jüri Üyesi, Yalova Üniversitesi

Tezin Savunulduğu Tarih: 12.06.2019



ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışması meteorolojik veriler kullanılarak Namazgâh Barajına ait akışın Yapay Sinir Ağı yöntemiyle tahmin edilmesi üzerinedir. Çalışmada Radyal Temelli ağ modeli ile dinamik programlama tabanlı seriye bağlı doğrusal olmayan otoregresif bir ağ modeliyle probleme çözüm aranmıştır. Modellemelerden yaklaşık sonuçlar elde edilmiştir. Hatayı minimize etmekte YSA'nın çok iyi performans sergilediği ortaya konulmuştur.

Amaç hidrometeorolojik verilerden faydalanıp Namazgâh Barajına ait akışın tahmini için basit bir YSA modeli tasarlamaktır.

Çalışmalarında bana her zaman destek olan ve tecrübelerini benden esirgemeyen danışmanım Prof. Dr. Mücahit OPAN'a ve tez çalışmamda bana yardımcı olan İnş. Yük. Müh. Ayşe DOĞAN'a teşekkürlerimi sunarım.

Hayatım boyunca beni destekleyen babam, annem ve kardeşlerim ile tüm arkadaşlarıma sonsuz teşekkürlerimi sunarım.

Mayıs – 2019

Ahmet Raşit AKGÜN

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iv
TABLolar DİZİNİ	v
SİMGELER VE KISALTMALAR DİZİNİ	vi
ÖZET.....	viii
ABSTRACT.....	ix
GİRİŞ	1
1. TAHMİN YÖNTEMLERİ.....	2
1.1. Sebep- Sonuç İlişkisine Bağlı Tahmin Modelleri	2
1.2. Zaman Serisi Analizine Dayanan Tahmin Yöntemleri	2
2. LİTERATÜR TARAMASI.....	3
2.1. Yapay Sinir Ağları	3
3. MATERYAL VE YÖNTEM	8
3.1. Yapay Sinir Ağları	8
3.1.1. Biyolojik sinir hücresi	9
3.1.2. Yapay sinir hücresi.....	9
3.1.3. Toplama fonksiyonları	11
3.1.4. Aktivasyon fonksiyonları	13
3.1.4.1. Step fonksiyonu.....	13
3.1.4.2. Doğrusal (Lineer) fonksiyon	13
3.1.4.3. Sigmoid fonksiyonu	14
3.1.4.4. Sinüs fonksiyonu	15
3.1.4.5. Hiperbolik tanjant fonksiyonu.....	16
3.1.4.6. Logaritmik aktivasyon fonksiyonu	16
3.2. Yapay Sinir Ağı Yapısı	18
3.3. Yapay Sinir Ağlarında Öğrenme.....	20
3.3.1. Danışmanlı öğrenme	22
3.3.2. Danışmansız öğrenme	22
3.3.3. Destekleyici öğrenme.....	23
3.4. Çok Katmanlı Yapay Sinir Ağlarında Öğrenme Algoritması	23
3.4.1. Geri yayılım algoritması	23
3.4.2. Çıktı katmanında ağırlık güncellemesi	24
3.4.3. Öğrenme hızı ve momentum katsayısı	28
3.4.4. Çalışmada kullanılan öğrenme algoritması.....	28
3.5. Yapay Sinir Ağı Mimarileri	29
3.5.1. Geri beslemeli yapay sinir ağı (GBYSA)	29
3.5.2. İleri beslemeli yapay sinir ağı	29
3.5.3. Radyal tabanlı yapay sinir ağı (RTYSA)	30
3.6. Zaman Serileri	31
3.6.1. Yapay sinir ağlarında zaman serileri.....	31
3.6.2. Doğrusal olmayan otoregresif (Nonlinear Autoregressive).....	31
3.6.3. Doğrusal olmayan otoregresif eksojen (Nonlinear autoregressive exogenous)	32

4. ÇALIŞMA ALANI VE YERİ.....	34
4.1. Kocaeli İli Kandıra İlçesinde Bulunan Namazgâh Barajı	34
4.2. Çalışma Alanına Ait Veriler.....	34
4.3. YSA Tahmin Senaryoları	35
4.3.1. Giriş değişkenlerinin belirlenmesi	36
4.3.2. Eldeki verilerin değerlendirilmesi.....	36
4.3.3. Veri gruplarının oluşturulması	36
4.3.4. Verilerin programa uygun hale getirilmesi	37
4.3.5. Modelin belirlenmesi	39
4.3.6. Kurulan YSA'nın eğitimi, test edilmesi ve simule edilmesi.....	40
4.3.7. Akış tahmini için kurulan yapay sinir ağı modelleri.....	41
5. SONUÇLAR VE ÖNERİLER	47
KAYNAKLAR	49
KİŞİSEL YAYIN VE ESERLER	52
ÖZGEÇMİŞ	53



ŞEKİLLER DİZİNİ

Şekil 3.1.	Gerçek nöron hücresinin yapısı.....	9
Şekil 3.2.	Yapay sinir hücresinin yapısı	10
Şekil 3.3.	Step fonksiyonunun yapısı	13
Şekil 3.4.	Doğrusal fonksiyonun grafiği.....	14
Şekil 3.5.	Sigmoid fonksiyonunun grafiği.....	15
Şekil 3.6.	Sinüs fonksiyonunun grafiği	15
Şekil 3.7.	Hiperbolik tanjant fonksiyonu grafiği	16
Şekil 3.8.	Logaritmik aktivasyon fonksiyonu grafiği.....	17
Şekil 3.9.	Yapay sinir ağının yapısı.....	18
Şekil 3.10.	Tek katmanlı yapay sinir ağının yapısı	19
Şekil 3.11.	Çok katmanlı yapay sinir ağının yapısı	20
Şekil 3.12.	Geri beslemeli yapay sinir ağının yapısı	20
Şekil 3.13.	Geri beslemeli ağ modeli örneği	29
Şekil 3.14.	İleri beslemeli yapay sinir ağının yapısı.....	30
Şekil 3.15.	Radyal tabanlı yapay sinir ağı yapısı.....	30
Şekil 3.16.	Seriye bağlı NARX modeli mimarisi	32
Şekil 3.17.	Dışsal girişli NARX modeli mimarisi.....	33
Şekil 4.1.	Namazgâh Barajı'nın uydu görüntüsü.....	34
Şekil 4.2.	Tahminde kullanılan girdi veri gruplarının boyutsuz hali.....	39
Şekil 4.3.	Tahminde kullanılan çıktı veri grubunun boyutsuz hali.....	39
Şekil 4.4.	Akış tahmini için en iyi performansı veren modelin mimarisi.....	44
Şekil 4.5.	Akış tahmini için en iyi performansı veren modelin çıktısı ve hedef değer grafiği	44
Şekil 4.6.	Akış tahmini için en iyi performansı veren modelin deneysel hata grafiği	44
Şekil 4.7.	Radyal Tabanlı Ağ Modelinin Mimarisi.....	46
Şekil 4.8.	NARX ve Radyal Tabanlı Ağ modelinin MSE değeri karşılaştırma grafiği.....	47
Şekil 4.9.	Radyal Tabanlı Ağ modelinin deneysel hata grafiği	47

TABLULAR DİZİNİ

Tablo 3.1. Toplama fonksiyonları	12
Tablo 3.2. Aktivasyon fonksiyonu örnekleri	17
Tablo 4.1. Tahminde kullanılacak Kocaeli Meteoroloji Müdürlüğü AGİ verilerinin yapısı.....	35
Tablo 4.2. Tahminde kullanılacak akış verilerinin yapısı	35
Tablo 4.3. Bayesian Regularization öğrenme algoritmasıyla elde edilen sonuçlar	42
Tablo 4.4. Scaled Conjugate Gradient öğrenme algoritmasıyla elde edilen sonuçlar	42
Tablo 4.5. Levenberg- Marquardt öğrenme algoritmasıyla elde edilen sonuçları.....	42
Tablo 4.6. YSA tahmin modellerinden alınan sonuçlar	43
Tablo 4.7. Akış tahmini için Radyal Tabanlı Ağ Modeli MSE Hata Değerleri.....	46

SİMGELER VE KISALTMALAR DİZİNİ

Δ_w	: Mevcut ağırlık değişimi miktarı
$E_{\text{düğüm}}$: Bütün düğümlerin toplam hatası
E_k	: k düğümü için hesaplanan hata değeri
f_i	: İstenen çıktı
f_k^{\ominus}	: f_k^{\ominus} fonksiyonunun türevi
g_k	: k vektörü için gerçek çıktı değerini
g_{ki}	: İlgili düğümün gerçek çıktısı
t_k	: k düğümü için tahmin edilen çıktı değeri
t_{ki}	: İlgili düğümün ağ tahmini
W_{eski}	: Eski ağırlık
W_{ij}	: j. nöronu i. nörona bağlayan ağırlık değerleri
W_{ij}^h	: j. düğümün i. girdi katman düğümü ile olan gizli katman bağlantı ağırlığını
W_{ji}	: j. nöronu i. nörona bağlayan ağırlık katsayısı
W_{kj}^{\ominus}	: Çıktı katman düğümlerinden olan k ve j düğümleri arasındaki bağlantı ağırlığı
W_{yeni}	: Güncel ağırlık
\bar{X}	: Normalleştirilecek verilerin ortalaması
X_0	: Gerçek veri değeri
X_i	: Girdi vektörü
X_i	: Giriş değerleri
X_{ki}	: k. vektörün i. eğitim elemanı
X_{maks}	: Normalleştirilecek verinin maksimum değeri
X_{min}	: Normalleştirilecek verinin minimum değeri
X_n	: Normalleştirilmiş veri
$\delta_{\text{düğüm}}$: Tek bir çıktı düğümü hatası
δ_i	: İlgili düğümün hatası
δ_{nk}^{\ominus}	: Çıktı katmanı toplam hatası
ε_k	: Gerçek değer – tahmin edilen değer
θ_i	: i. nörona bağlı aktivasyon fonksiyonu eşik değeri.
θ_j^h	: Gizli katman eğim değeri
θ_k^{\ominus}	: Eğim değerini
∂	: Eşik değeri
A	: Ağırlıklar
E	: Hata değeri
$f_{(\text{net})}$: Aktivasyon fonksiyonu işlevi
G	: Girdiler
$h_{\text{gizli katman}}$: Gizli katman
N	: Toplam girdi sayısı(sinir hücresi sayısı)
Net	: Toplama fonksiyonu

R^2	: Belirlilik katsayısı
S	: Normalizasyon verilerinin standart sapması
W	: Herhangi bir ağırlık
W	: Ağırlık matrisi
X	: Girişler
x_n	: Girdi vektörü
$Y_{(t)}$: NARX modelde çıkış sinyali
$Y_{(t+1)}$: NARX modelde bir sonraki çıkış sinyali
η	: Öğrenme oranı
η	: Öğrenme hızı
Θ	: Çıktı katmanı
Θ	: Çıktı
θ	: Eşik değeri
μ	: Pozitif sabit bir sayı
μ	: Momentum katsayısı
φ	: Çıkış değeri
$\varphi(\infty)$: Aktivasyon fonksiyonu işlevi

Kısaltmalar

AGİ	: Araştırma Gözlem İstasyonu
ANFIS	: Bulanık Mantık Yapay Sinir Ağı
ANN	: Artificial Neural Network (Yapay Sinir Ağı)
DVR	: Destek Vektör Regresyonu
ET	: Evapotransporasyon
GBYSA	: Geri Beslemeli Yapay Sinir Ağı
İBGYYSA	: İleri Beslemeli Geri Yayınımlı Yapay Sinir Ağı
İSU	: Kocaeli Su ve Kanalizasyon İdaresi
LM	: Levenberg Marquardt
MLP	: Multi-Layer Perceptron (Çok Katmanlı Ağ)
MSE	: Mean Square Error (Hata Kareler Ortalaması)
NAR	: Nonlinear Autoregressive (Doğrusal Olmayan Otoregresif)
NARX	: Nonlinear Autoregressive Exogenous (Doğrusal Olmayan Otoregresif Eksojen)
PM	: Penman Yöntemleriyle
RTYSA	: Radyal Temelli Yapay Sinir ağı
YSA	: Yapay Sinir Ağı
YSH	: Yapay Sinir Hücresi

NAMAZGÂH BARAJINDA METEOROLOJİK VERİLER KULLANILARAK YAPAY SİNİR AĞI İLE AKIŞIN TAHMİN EDİLMESİ

ÖZET

Gelecekte barajda meydana gelecek olan akıma dair tahminde bulunmak güç olduğu kadar önem de arz etmektedir. Özellikle projelendirme çalışmaları, taşkın kontrolü ve taşkın kontrollü hazne işletmeciliği ve su ihtiyacı gibi pek çok durum değerlendirmesi açısından önemlidir. Akış, temelde yağış, sıcaklık, nem başta olmak üzere çeşitli meteorolojik parametrelerin bileşkesinden oluşmaktadır. Parametreler arası doğrusal olmayan bir ilişki söz konusu olduğu için, yağış-akış arasındaki ilişkiyi modellemek taşkın hidrolojisinde büyük önem taşımaktadır. Bu çalışma, Kocaeli İli, Kandıra İlçesinde bulunan Namazgâh Barajında meteorolojik veriler kullanılarak Yapay Sinir Ağları ile akışın tahmin edilmesi üzerinedir. Modellemede giriş verisi olarak minimum sıcaklık, ortalama sıcaklık, buhar basıncı ve yağış kullanılırken çıkış verisi ise akış olarak ele alınmıştır. Öncelikle veriler normalizasyon işlemi ile programa uygun hale getirilmiştir. Sırasıyla Levenberg-Marquardt(LM), Bayesian Regularization, Scaled Conjugate Gradient öğrenme algoritmalarından problem karşısında en iyi performansı Levenberg-Marquardt öğrenme algoritmasının diğer algoritmalara oranla daha iyi performans sergilediği tespit edilmiştir. LM öğrenme algoritması kullanılarak NARX modeli ve Radyal Temelli YSA modeli probleme uyarlanmıştır. İki modellemede hesaplanan Ortalama Karesel Hata (MSE) değerleri yaklaşık sonuçlar verse de Radyal Temelli YSA daha fazla nöron kullanılmakla birlikte daha fazla iterasyon yapmaya gerek duymuştur. Bu yüzden daha az iterasyon ve daha az nöronla problemi çözen NARX modelinin daha güçlü olduğu sonucuna ulaşılmıştır. Eğitim verileri için öğrenme de %96'lık başarı sağlanarak test verilerine ise %90 doğru cevap alınmıştır. Hata kareler ortalamasının da sıfıra yakın olduğu sonucuna ulaşılmıştır. Geri besleme gecikmesine sahip dinamik ağ tabanlı NARX modelinin akış tahmini olumlu sonuçlar üretebileceği kanısına varılmıştır. En iyi performans belirlenirken ise MSE ve Belirlilik (R^2) dikkate alınmıştır. Hidrolojik problemlerin çözümü için YSA modellemelerinin rahatlıkla kullanılabileceği kanısına varılmıştır.

Anahtar Kelimeler: Akış, Meteorolojik Veriler, Namazgâh Barajı, Yağış, Yapay Sinir Ağları.

ESTIMATION OF THE FLOW WITH ARTIFICIAL NEURAL NETWORK USING METEOROLOGICAL DATA IN NAMAZGÂH RESERVOIR

ABSTRACT

In the future, estimation of the current flow will be as important as it is. In particular, project planning studies, flood control and flood-controlled reservoir management and water needs are important in terms of many situations such as assessment. The flow consists mainly of precipitation, temperature, humidity and various meteorological parameters. Since there is a nonlinear relationship between the parameters, it is of great importance in flood hydrology to model the relationship between precipitation and flow. This study is based on the estimation of flow by Artificial Neural Networks using meteorological data in Namazgâh Reservoir located in Kandira District of Kocaeli Province. In the modeling, the minimum temperature, average temperature, vapor pressure and precipitation are used as input data and the output data is considered as flow. First of all, the data has been adapted to the program by normalization process. Levenberg-Marquardt (LM), Bayesian Regularization, Scaled Conjugate Gradient learning algorithms were found to perform better than other algorithms. Using the LM learning algorithm, the NARX model and Radial Based ANN model are adapted to the problem. Although the mean squared error (MSE) values calculated in both models were approximate, Radial Based ANN was more neuron use but needed more iterations. Therefore, it was concluded that the NARX model, which solves the problem with less iterations and less neurons, is stronger. For learning data, 96% success was achieved in learning and 90% correct answer to test data. The mean error squares were also close to zero. It has been concluded that the dynamic network based NARX model with feedback delay can produce positive predictions of flow. MSE and Specificity (R2) were taken into consideration when determining the best performance. It is concluded that ANN modeling can be used to solve the hydrological problems.

Keywords: Flow, Meteorological Data, Namazgah Reservoir, Precipitation, Artificial Neural Networks.

GİRİŞ

Barajlarda meydana gelecek akışa dair tahminde bulunmak akıştan kaynaklı gerçekleşebilecek problemlerin analizi açısından büyük önem arz etmektedir. Yapay zekâ öngörü modellemesi olan YSA hidrolojik pek çok problem çözümünde kullanıldığı gibi son zamanlarda akış tahmini için de kullanılmıştır. YSA'nın son zamanlarda sıkça tercih edilmesinin en temel sebebi ise analiz için bir ön bilgiye gereksiniminin olmamasıdır. Veri örnek uzayından elde ettiği bilgilerle ilişkiye çözüp hiç görmediği örnek uzayı hakkında yorum yapabilme kapasitesine sahip olması alternatif yöntem kabul edilmesinin en temel sebeplerinden biridir. YSA'nın problem çözümedeki temel mantığı öğrenme algoritmalarına dayanır. Yapay öğrenme olarak tabir edilen YSA insan beyninin işleyiş mekanizmasından esinlenmiştir. İnsan beynini taklit ettiğinden dolayı yapısında bulunan nöronlar vasıtasıyla katmanlar arası bilgi iletimiyle çıktı üretebilmektedir. Bu çalışmada ise meteorolojik birtakım veriler giriş verisi olarak kullanılıp akış ise çıkış verisi olarak verilir, ilişki NARX bir modelle farklı öğrenme algoritmaları kullanılarak ele alınmaya çalışılmıştır. Bu modelden elde edilen hata değeri ile Radyal Tabanlı ağ modelinden elde edilen hata değerleri karşılaştırılmıştır. Hesaplanan hata değerleri yaklaşık olmasına rağmen Radyal Tabanlı YSA problemi çözmek için daha fazla iterasyon yapmakla birlikte daha fazla nörona ihtiyaç duymuştur. NARX modelinin daha kısa sürede çözümlenmesiyle daha güçlü olduğu kanısına varılmıştır. Hidrolojik pek çok problem için de kullanılabilir. YSA'nın meteorolojik verilerle akış ilişkisi için tahmin gerektiren çözümlene yaklaşımını iyi şekilde temsil ettiği görülmüştür.

1. TAHMİN YÖNTEMLERİ

Geçmiş dönem gözlemlerine dayanarak olaylar hakkında tahminleme yapmak mümkündür. Kişinin yaptığı tahminlerde farklılık görülebilir fakat geleneksel matematiksel yöntemlere dayanan tahminlerde bu durum değişmektedir. Geçmiş dönem sayısal verilerine dayanan tahminlerde geleceğe yönelik de aynı durumun gerçekleşebileceği kabulü söz konusudur. Geçmiş dönem verilerine ait veri kümesi arası ilişkiler çözümlenir ve bu süreç hakkında çeşitli yorumlar yapılabilir. Bu tür yorumların tutarlı olabilmesi için geliştirilen yaklaşımlar sırasıyla iki temel başlık altında toplanabilir. Bunlar;

1-) Sebep- Sonuç İlişisine Bağlı Tahmin Modelleri

2-) Zaman Serisi Analizine Dayanan Tahmin Yöntemleri

1.1. Sebep- Sonuç İlişisine Bağlı Tahmin Modelleri

Açıklayan ve açıklanan olmak üzere iki temel kavrama dayanan modellemelerdir. Ki bu da regresyon tekniğini anımsatmaktadır. Çünkü Regresyon tekniğinde bağımlı ve bağımsız değişken arasındaki ilişki çözümlenmeye çalışılmaktadır. Bu teknik sebep sonuç ilişkisine dayanan tahminlerin matematiksel modeline örnek kabul edilebilir. Bu tahminler geleceğe dair çeşitli yorumlar yapmamızı sağlasa da yeterli düzeye sahip değildir. Çünkü bağımsız değişkenlerin gelecekteki değerlerinin bilinmesi söz konusudur. Zaman serisiyle bu olayı çözüme kavuşturmak daha da kolay olabilmektedir [1].

1.2. Zaman Serisi Analizine Dayanan Tahmin Yöntemleri

Zaman serisi analiziyle pek çok problem çözümlenebilmektedir. Zaman serisine ait problemin çözümü için model seçimi ve modelde kullanılacak doğru parametre tercihi veriler arası ilişkinin çözümlenmesi açısından büyük önem arz etmektedir. İstatistiki yöntemlere göre daha esnek olabilen yöntemler bulmaya yönelik çalışmalar günümüzde de devam etmektedir. Bulunan yöntemler arasında ilk sıralarda YSA yerini almaktadır [1]. Bu çalışmada da YSA'nın esnekliğinden faydalanılarak akış tahmini için model kurulmaya çalışılmıştır.

2. LİTERATÜR TARAMASI

2.1. Yapay Sinir Ağları

Çalışmada tek katmanlı ağlara oranla veriler arası ilişkiyi çözmeye daha iyi sonuç verdiği için dolayı çok katmanlı bir ağ modeli tercih edilmiştir. Dolayısıyla John Hopfield'in çalışması ve çok katmanlı ağlar üzerine yaptığı çalışmalar Geri Yayılım Öğrenme Algoritmalarını kapsamaktadır. Bu öğrenme algoritmaları hem veriler arası ilişkiyi çözümlenmeye de hem de hatayı minimize etmekte oldukça iyi performans sergilemektedirler.

Hopfield, National Academy of Science'a sunduğu çalışmasının temelini matematiksel analizi temel alan sinir ağları oluşturmaktadır [2].

Rumelhart ve arkadaşları da YSA'yı Hopfield'a benzer şekilde analizleri ile kullanmıştır [3].

YSA konusunda pek çok araştırmacı öğrenme algoritmaları geliştirmiştir. Bunlardan en önemlilerinden birisi de Rumelhart ve McClelland çok katmanlı ağlar üzerinde geliştirdikleri geri yayılım algoritmalarıdır [3].

Broomhead ve Lowe, Radyal Tabanlı Fonksiyon Ağları kullanarak sayısal analizleri sinir ağları ile bağdaştırmıştır. Bu konudaki bilgi alma süreci ise onlar tarafından aşağıdaki varsayımlara göre sinir hücrelerinde bulunan nöronlar vasıtasıyla başlatılmaktadır [4].

- Bilgi işlevini başlatan nöronlar ağırlıklarla birbirine bağlıdır.
- Nöronları bağlayan ağırlıklar birbirinden farklıdır.
- Gruplandırılmış sinir hücreleri birbiriyle bağlantılı olan katmanları meydana getirmektedir. Aynı katmanda bulunan nöronların işlevleri benzerdir.
- Nörona ait çıktı tanımlanan aktivasyon fonksiyonundan geçirilerek çıktı üretilmektedir.

YSA konusunda 1980'den bugüne kadar pek çok farklı çalışma ortaya konulmuştur ve bu konudaki çalışmalar günlük yaşamın her alanına uygulanmaya devam etmektedir. Bu alanlardan biri de su kaynakları mühendislik problemleridir.

Alp ve Cıgızcıođlu çalışmalarında, ileri beslemeli geriye yayılım metodu (İBGY) ile genelleştirilmiş regresyon sinir ađı (GRSA) yöntemini karşılaştırmışlardır. İBGY ile farklı YSA mimarileri ile en iyi sonucu elde edene kadar denemeler yapmışlardır. En iyi İBGY simülasyonunun diğer model tahminlerine göre daha iyi sonuç verdiği kanısına varmışlardır [5].

Yerdelen, yaptığı çalışmada hidrolojik veriler kullanarak Dođu Anadolu'daki Karasu-Kırkgöze havzası için kar erimesini analiz etmek için YSA ile tahmin modeli geliştirmiştir [6].

Öcal, yaptığı tez çalışmasında Büyük Menderes Nehri üzerinde bulunan Yukarı Büyük Menderes Alt Havzası ve Banaz Çayı Alt Havzası katı madde miktarının tahmini için çeşitli YSA modelleri kullanmıştır. Bu YSA modellemelerinde yağış ve akış ilişkisi önemli bir faktör olmuştur. Elde ettiği sonuçlara göre Yapay Sinir Ağları yönteminin yağış, akış ve katı madde tahminleri için başarılı bir şekilde uygulanabileceğini kanısına varmıştır [7].

Özdemir, çalışmasında yağış-akış modeli olarak USDA (United States Department of Agriculture) tarafından geliştirilen SCS (Soil Conservation Service) Curve Number metodu kullanmıştır. Çalışmada Edremit ve Burhaniye meteoroloji istasyonlarından elde edilen günlük yağış verileri kullanılmıştır. Modellemeler sonucunda elde edilen akım verileriyle yağış değerleri ve havzadaki tek akım ölçüm istasyonuna ait akım verileri karşılaştırılmış ve veriler arasında yüksek korelasyonlar gözlemlenmiştir [8].

Yurdusev ve diđ. çalışmalarında tahmin uygulamalarında sıkça kullanılan YSA yöntemi kullanılarak Akarçay kapalı havzasındaki aylık akımların, yağış ve akım gözlemlerinden tahmin edilmesini ele almışlardır. Havzada bulunan yağış gözlem istasyonlarının konumları, gözlem aralığı gibi parametrelere bađlı olarak 4 ayrı kategoride modellenmiştir. Elde edilen sonuçlar çok deđişkenli regresyon analizi ile kıyaslanarak YSA'nın, akış tahmini problemlerine uygulanabileceđi ve güvenli tahminler üretebileceđi kanısına varılmıştır [9].

Partal ve diğ. hazırlamış olduđu çalışmaları YSA yönteminin tahmindeki başarısını arttırmak için dalgacık dönüşümü yöntemini kullanarak günlük yağış tahmini yapmışlardır. Çalışmada Türkiye'ye ait 3 istasyonun günlük meteorolojik verileri kullanılmıştır. YSA yönteminin literatürde en çok kullanılan algoritmalarından, İleri Beslemeli Geriye Yayılmalı Yapay Sinir Ağları (İBGYSA) ve Radyal Tabanlı Yapay Sinir Ağları (RTYSA) yöntemleri yağış tahmini amacıyla kullanılmıştır. Farklı girdi kombinasyonları denenerek İBGYSA ve RTYSA modellerini karşılaştırmışlardır ve İBGYSA'nın en iyi performansı sergilediği sonucuna ulaşmışlardır. Dalgacık dönüşümü-YSA yönteminin tahmin sonuçları çoklu lineer regresyon yönteminin sonuçları ile kıyaslanmış ve performans kriterlerine göre daha iyi olduğu sonucuna ulaşmışlardır [10].

Dahamsheh ve Aksoy, çalışmalarında aylık toplam yağışın tahmini için Markov zincirleri eklenmiş koşullu İBGYSA yöntemi kullanmışlardır. Uygulama için Ürdün'ün dağlık bölgesinden Amman meteoroloji istasyonu seçilmiştir. Deneme-yanılma yöntemi ile çok sayıda model seçeneği üretilmiştir. Denenen her bir modelin performansı Ortalama Karesel Hata (OKH) ve belirlilik katsayısı (R^2) ile ölçülmüştür. Markov zincirleri ile birleştirilmiş koşullu İBGYSA modelinin kuru ayların belirlenmesinde, en yüksek yağış ve yağış tahmininde büyük başarı gösterdiği anlaşılmıştır [11].

Okkan ve Mollamahmutoğlu, çalışmalarında Çoruh Nehrine ait günlük akımları kullanarak bir YSA modeli tasarlamışlardır. Bu YSA modeli içsel bağımlı stokastik AR modeliyle karşılaştırılmıştır. Modellerin yaklaşık sonuçlar verdiği tespit edilmiş fakat YSA'nın daha iyi sonuç vermiştir. YSA modelinin Çoruh Nehri günlük akımlarını başarıyla temsil ettiği; böylece geliştirilen model yapısının diğer akarsu havzalarının günlük akımlarının tahmininde de başarıyla kullanılabileceği kanısına varılmıştır [12].

Yarar, yaptığı çalışmada Susurluk Havzası'na ait 7 farklı Akım Gözlem İstasyonunun aylık ortalama akım verileri YSA ve Bulanık Mantık yöntemleri ile modellemiş ve Zaman Serileri modeli olan Bulanık Mantık modeli ile karşılaştırmıştır. Modellerin kıyaslamasının yapılabilmesi için her bir modelin tahmin değerleri ile ölçüm değerleri grafikleri çizilmiş ayrıca Ortalama Karesel Hata değerleri ve R^2 değerleri hesaplanarak

hata performanslarına bakılmıştır. Elde edilen sonuçlara göre yapay sinir ağıları ve bulanık mantık modelleri, R^2 düşük değeri olan iki akım gözlem istasyonu dışında kabul edilebilir sonuçlar üretebildiği görülmüştür [13].

Saplıoğlu, bu çalışmada YSA yöntemi kullanarak yağış tahmini için bir model oluşturmuştur. Bu yöntem, Amerika Birleşik Devletlerinin Portland bölgesinde bulunan 4 adet yağış gözlem istasyonlarından ölçülmüş günlük yağış verilerine uygulanmıştır. Her bir istasyondan alınan 3170 adet günlük yağış verisi işleme konulmuştur. YSA'dan elde edilen sonuçlar literatürde mevcut olan ağırlıklı ve harmonik ortalama metotlarından elde edilen sonuçlar ile karşılaştırılmıştır. Hesaplamalarda YSA'nın tahminde diğer yöntemlere göre daha iyi olduğu sonucuna varılmıştır [14].

Can, akım değerlerini elde etmek için YSA yöntemini kullanmıştır. YSA'yı çoklu regresyon yöntemleriyle karşılaştırmıştır. Çalışmasında YSA'nın bu alanda başarılı diğer yöntemlere oranla daha başarılı olduğu tespit edilmiştir [15].

Gümüş ve diğ. yağış gözlem istasyonuna ait aylık toplam yağış verileri arasındaki ilişki yapay sinir ağıları metotlarından İleri Beslemeli Geri Yayınım Sinir Ağı (İBGYSA), Genelleştirilmiş Regresyon Yapay Sinir Ağı (GRYSA) ve Radyal Tabanlı Yapay Sinir Ağı (RTYSA) ile araştırılmıştır. Elde edilen sonuçlar daha klasik bir yöntem olan Çoklu Doğrusal Regresyon (ÇDR) yöntemi ile karşılaştırılmıştır. Akım ve yağış verilerinin girdi olarak kullanıldığı bu çalışmada yeni akım değerleri tahmin edilmeye çalışılmıştır. Çalışma sonunda kullanılan tüm yapay sinir ağı yöntemlerinin ÇDR yöntemine göre daha iyi sonuç verdiği görülmüştür. RTYSA yöntemiyle tahmin edilen akım değerlerinin, kullanılan diğer yapay sinir ağı yöntemleriyle tahmin edilen değerlere kıyasla gözlenen akım değerlerine daha iyi yakınsadığı belirlenmiştir [16].

Yüksek ve diğ. çalışmalarında günlük ortalama yağış ve akış değerlerini kullanarak 5 girdili bir model tasarlamışlardır. Oluşturulan yağış-akış modellemelerinde tüm YSA yapıları iyi sonuçlar üretmiş ve en iyi yapı olarak YSA-QN olduğu sonucuna ulaşılmıştır [17].

Doğan ve Opan, yapmış oldukları çalışmada Namazgâh Barajına ait eksik su kalite değerlerinin tahmin edilmesinde YSA yöntemini kullanmışlardır. Çalışmada İBGYSA

olan çok katmanlı bir ađ tercih etmişlerdir. Deneme yanılma yolu ile farklı nöron sayıları kullanılarak tasarladıkları modellemelerde YSA'nın tahminleme yaparken hatayı minimize etmede oldukça iyi performans sergilediđini ortaya koymuşlardır [18].

Dođan ve Opan'ın yapmış olduđu bir diđer çalıřma Namazgâh Barajına ait buharlaşma miktarını YSA ile tahmin edilmesi üzerinedir. Bu çalıřmada Meteorolojik veriler giriş verisi olarak kullanılarak buharlaşma çıkış verisi olarak deđerlendirilmiştir. Çalıřmanın birinci aşaması eksik verilerin tamamlanması için İBGYYSA modeli tasarlamak, ikinci aşaması ise NARX modeli ile buharlaşma tahminidir. Sonuç olarak zaman serisi analiziyle buharlaşma miktarı tahmini için Levenberg-Marquardt öğrenme algoritması kullanarak NARX modeliyle probleme çözümler bulmuşlardır. Benzer çalıřmalar için NARX modelinin rahatlıkla kullanılabileceđini önermişlerdir [19].

Bu çalıřmada ise Kocaeli ili Kandıra ilçesine ait, Tarım ve Orman Bakanlığı Kocaeli Meteoroloji Genel Müdürlüğü, araştırma gözlem istasyonlarından alınan günlük meteorolojik veriler giriş verisi olarak kullanılmıştır. Giriş verileri Minimum Sıcaklık, Ortalama Sıcaklık, Su Buharı Basıncı ve Yađış, çıkış verisi ise akıřtır. Radyal Tabanlı YSA ve dinamik programlama tabanlı zaman serisine dayanan NARX modelinin yaklaşık sonuçlar verdiđi tespit edilmiştir. NARX modeli için 3 farklı öğrenme algoritması denenerek LM'nin daha iyi sonuç verdiđi görülmüştür.

3. MATERYAL VE YÖNTEM

İnsan beyninin çalışma mekanizmasından faydalanıp beynin işleyişini yazılım ortamına aktaran bütün sistemler Yapay Zekâ başlığı altında toplanabilir. YSA ise yapay zekânın öngörü modelleri sınıfına girmektedir.

İnsan beyni gözlem ve tecrübelerden yola çıkarak öğrenmeye açık olmanın yanında öğrendiklerini birleştirip farklı olaylara da çözüm üretebilme yeteneğine sahiptir. Bu işleyişi öğrenme algoritmaları vasıtası ile makinelere kazandıran sistem yapay öğrenme olarak adlandırılmaktadır.


Böylece yapay öğrenme ile insan beyninin çalışma mekanizmasından esinlenerek problemlere çözüm bulmak amacıyla makinelerin aktif kullanılmasına ortam hazırlanmıştır. Yaşanan bu gelişmeler sayesinde günlük yaşamın her alanında karşılaşılan problemlere yapay öğrenme tekniği uyarlanmıştır. Yapay öğrenme tekniklerinden birisi de YSA'dır. Bu çalışmada ise YSA yöntemiyle probleme çözüm bulunmak istenmiştir.

3.1. Yapay Sinir Ağları

Matematiksel modellemede insan beynini çalışma prensibini referans alarak geliştirilen sisteme YSA denilebilir. Aynı işlevi gören yapay sinir hücrelerinin gruplaşması ve ağırlıklarla birleşmesiyle YSA oluşmaktadır. YSA'nın en büyük avantajlarından biri eş zamanlı çalışan işlemci birimlere sahip olmasıdır. Bu yüzden karmaşık olan pek çok probleme kısa sürede çözüm üretebilmektedir. Bu işlemin yerine getirilebilmesi için geçmiş dönem gözlemlerine dayanan veri setinin var olması önemli bir faktördür. YSA eldeki bu verilerden yola çıkarak veriler arası ilişkiyi çözümleyebilir, bunlara dair çıkarımlar yapabilir ve hiç görmediği örneklerle çözüm üretebilmektedir.

3.1.1. Biyolojik sinir hücresi

İnsan beyni sinir hücrelerinin işlevi dendrit, çekirdek, bağlantı blokları ve akson' un bilgi iletimini gerçekleştirmesine dayanır. Şekil 3.1'de insana ait nöron hücresinin gösterilmiştir.



Şekil 3.1. Gerçek nöron hücresinin yapısı [20]

İnsan nöron sisteminde bulunan dentritler aracılığı ile alınan bilgiler çekirdekte birleştirilerek bağlantı blokları vasıtasıyla akson uçlarına iletilir. Akson uçlarında yer alan sinapsların bulunduğu bölgede insan nöron sisteminde öğrenme olayı gerçekleşmektedir.

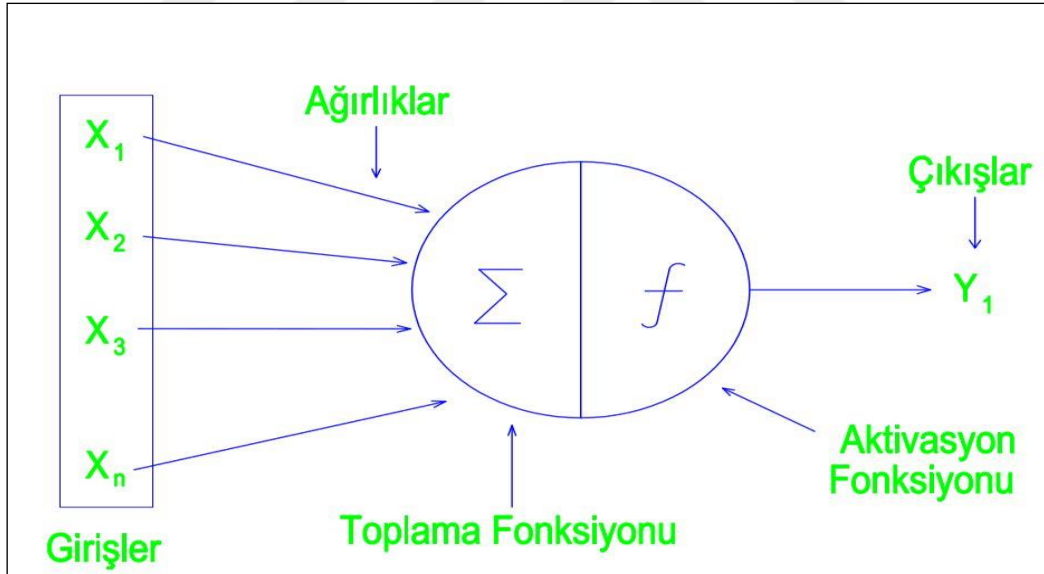
3.1.2. Yapay sinir hücresi

İnsan beyni öğrendiklerini uzun süreli hafızaya alma kapasitesine sahiptir. Bu işlevi sinir hücreleri vasıtasıyla yapmaktadır. Bunu yaparken olayın gerçekleşme sıklığı önem arz etmektedir. Tekrarlanan olaylar güçlü bağlantıların kurulmasına sebep olmaktadır. Bundan dolayı hafızada uzun süreli tutulması mümkün iken tekrar edilmeyen olaylar ise zayıf bağlantılara sahip olduğundan yeterli düzeyde öğrenme gerçekleşmemekle birlikte bilgi kaybına sebep olabilmektedir.

Aynı durum yapay sinir ağlarında da geçerlidir. Yapay sinir hücresi adı verilen temel yapı taşlarından meydana gelen ağda, öğrenmenin gerçekleşmesi ağırlık adı verilen

bağlantılar vasıtasıyla gerçekleştirilmektedir. Ağırlıklar hangi verinin ne kadar öneme sahip olduğunu belirleyen katsayı olarak tanımlanabilir. Girişlerin ağ içerisindeki önemi diye de ifade edilebilir. Bu bağlantı ağırlıkları başlangıçta rastgele belirlenirken daha sonra hesaplanan hataya düzeyine göre yeniden ağ tarafından güncellenmektedir. En uygun ağırlıkların belirlenmesi, ağ için öğrenmenin gerçekleştiği anlamını taşımaktadır. Ağırlıkların öneminin yanında ağda kullanılması gereken nöron sayısı ve problemin çözümü için gerekli katman sayısı da bir o kadar önem taşımaktadır. İBGYYSA' da hesaplama yönü ileri doğru iken, hatayı yayma yönü geriye doğrudur. Bu işlem katmanların geriye dönük belirlenen yeni ağırlıklarla beslenmesi vasıtası ile gerçekleştirilir. Uygun ağırlıklar bulunana kadar besleme işlemi devam ettirilir ve minimum hata düzeyi yakalandığında öğrenme işlemi ağ tarafından durdurulur.

Şekil 3.2'de bağlantı ağırlıklarının gösterildiği bir yapay sinir hücresi mevcuttur. Ayrıca Denklem (3.1)'de çıkış değeri ve çıkış değerinin matematiksel ifadesine ait eşitlik verilmiştir.



Şekil 3.2. Yapay sinir hücresinin yapısı

X_i = Giriş değerleri

W_{ij} = j. nöronu i. nörona bağlayan ağırlık değerleri

θ = Esik değeri

Net=Toplama fonksiyonu

$f(\text{net})$ = Aktivasyon fonksiyonu işlevi

φ = çıkış değeri ve çıkış değerinin matematiksel ifadesi

$$\varphi = f(w \times x + \theta) \quad (3.1)$$

Ağırlıklandırılmış girdiler toplama fonksiyonu ile birleştirilir. θ_i ; i. nörona ait aktivasyon fonksiyonunun eşik değeri, toplama fonksiyonunda gerçekleşen işlemin denkleminin matematiksel olarak gösterimi Denklem (3.2)'deki gibidir;

$$\text{net} = \sum_{j=0}^p X_j * W_{ij} - \theta_i \quad (3.2)$$

Toplama fonksiyonu ile elde edilen değer bir aktivasyon fonksiyonundan geçirilerek çıktı üretilir, bu işlemin denklemi matematiksel olarak Denklem(3.3)'te verildiği şekilde olur;

$$f(\text{net}) = f\left(\sum_{j=0}^p X_j * W_{ij} - \theta_i\right) \quad (3.3)$$

W_{ij} ; i'nci nöronu j'nci nörona bağlayan ağırlık katsayısı θ_i , i'nci nörona bağlı aktivasyon fonksiyonu eşik değeri.

Kullanılacak aktivasyon fonksiyonu geri yayımlı ağlar için çok büyük öneme sahiptir. Çünkü hatayı geri doğru minimize ederken, aktivasyon fonksiyonunun türevine ihtiyaç duymaktadır. Toplama fonksiyonundan elde edilen değer için aktivasyon işlemi $f(x)$ uygulanır. Aktivasyon işleminden sonra nöron çıktısı bir diğer katman için girdi görevi görebilmektedir. Doğrusal olmayan ilişkileri çözümlenmede kullanılacak aktivasyon fonksiyonu en önemli rolü üstlenmektedir. Doğrusal olmayan anlamlı özelliklerin ağ tarafından anlaşılabilmesi için aktivasyon fonksiyonu aktive edilmektedir.

Çalışma prensiplerine göre aktivasyon fonksiyonları değişkenlik arz edebilir. Yapay Sinir ağlarında kullanılan temel toplama ve aktivasyon fonksiyonları aşağıdaki gibidir:

3.1.3. Toplama fonksiyonları

Aktivasyon fonksiyonuna aktarılacak net girdi toplama fonksiyonu tarafından belirlenir. Ağırlıklı toplamı ifade eden toplama fonksiyonu en çok tercih edilenler sıralamasında yer almakla birlikte ağırlıklı toplamı bulan fonksiyon olarak adlandırılmaktadır. Girdiler ilişkili olduğu ağırlık değeri ile çarpılarak toplam girdi

elde edilir. Bu fonksiyonun denkleminin matematiksel ifadesi Denklem (3.4)'teki gibi olur;

$$\text{net} = \sum_1^n G_i \times A_i \quad (3.4)$$

G: Girdiler

A: Ağırlıklar

n: Toplam girdi sayısı (sinir hücresi sayısı)

Kullanılan fonksiyona göre girdi değeri ya da girdi sayısı önemli olabilmektedir.

Bu farklılıktan dolayı toplama fonksiyonları örnekleri aşağıdaki tabloda gösterilmiştir. Bazı toplama fonksiyonları örnekleri aşağıda Tablo 3.1 ile verilmiştir [21].

Tablo 3.1. Toplama fonksiyonları

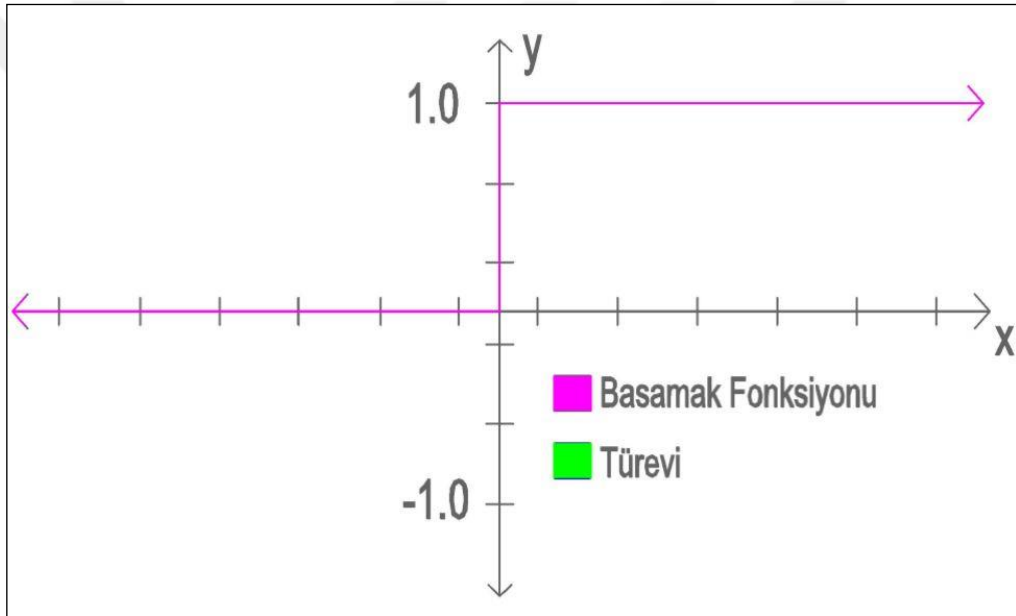
Net Giriş	Açıklama
Çarpım Net Girdi = $\prod_i G_i A_i$	Ağırlıklandırılmış girdilerin birbiriyle çarpımı sonucu net girdi hesaplanmaktadır.
Maksimum Net Girdi = $\text{Max}(G_i A_i), i=1 \dots N$	N adet ağırlıklandırılmış girdinin en büyüğü yapay sinir ağı hücresinin girdisi olarak kabul edilir.
Minimum Net Girdi = $\text{Min}(G_i A_i), i=1 \dots N$	N adet ağırlıklandırılmış girdinin en küçüğü yapay sinir ağı hücresinin girdisi olarak kabul edilir.
Çoğunluk Net Girdi = $\sum_i \text{sgn}(G_i A_i)$	N adet ağırlıklandırılmış girdi pozitif ve negatif olarak sayıları bulunduktan sonra büyük olan sayı hücrenin sahip olduğu net girdi olarak dikkate alınır.
Kümülatif Toplam Net Girdi = $\text{net}(\text{eski}) + \sum_i \text{sgn}(G_i A_i)$	Ağırlıklandırılmış girdiler daha önceki NET bilgiye eklenir. Net girdi elde edilir.

3.1.4. Aktivasyon fonksiyonları

3.1.4.1. Step fonksiyonu

Türevi alındığında ağı için önem arz etmediğinden dolayı bu fonksiyon çok katmanlı ağlar için tercih edilmemektedir. Fakat tek katmanlı ağlar için çıkış katmanında değerlendirilebilir. Şekil 3.3'te step fonksiyonunun grafiği yer almaktadır. Bu fonksiyonun denkleminin matematiksel gösterimi Denklem (3.5)'te verildiği şekildedir;

$$g(x)=x \quad (3.5)$$




Şekil 3.3. Step fonksiyonunun yapısı

3.1.4.2. Doğrusal (Lineer) fonksiyon

Çok katmanlı ağlarda hata geriye yayılım algoritması vasıtası ile minimize edilir. Dolayısıyla doğrusal fonksiyonumuz $g(x)=x$ olduğu için türevi alındığında sabit bir sayıya ulaşıldığı görülmektedir. Verdiğimiz girdi değerleri çıktı olarak alınmaktadır.

Çok katmanlı ağlarda çıktı katmanı için kullanılabilen bir fonksiyondur. Fakat gizli katmanı işlevsiz bıraktığından dolayı gizli katman için farklı bir fonksiyon tercih edilerek problemler çözüme kavuşturulabilir. Doğrusal fonksiyonun grafiği Şekil 3.4'te verilmiştir.



Şekil 3.4. Doğrusal fonksiyonun grafiği


3.1.4.3. Sigmoid fonksiyonu

Sigmoid fonksiyonu türevi alınabildiğinden ve süreklilik arz ettiğinden dolayı çok katmanlı ağlarda sıklıkla tercih edilir. Ürettiği değerler [0-1] arasında değerler olmaktadır. Türevlenebildiği ve ayrıca ürettiği değerler sıfır ve bir arasında değerler aldığı ve süreklilik arz ettiği için geri yayımlımlı ağlarda sıkça tercih edilmektedir. Geri yayımlımlı ağlar için bu fonksiyon oldukça kullanışlıdır. Sigmoid fonksiyonunun matematiksel ifadesinin denklemi Denklem (3.6)'da verildiği gibidir;

$$g(x) = \frac{1}{1+e^{-x}} \quad (3.6)$$

Aşağıda Şekil 3.5'te sigmoid fonksiyonunun grafiği yer almaktadır.

Grafik incelendiğinde x değerindeki değişim belirli bir noktadan sonra y üzerinde çok fazla değişime sebep olmamaktadır. Bu da belirli aralıklarda iyi bir sınıflandırıcı olarak değerlendirilirken bir noktadan sonra ağın takılmasına sebebiyet verebilmektedir. Çünkü bu noktalarda ağ düşük eğime sahip olur. En büyük avantajlarından biri yüksek öğrenme hızına sahip olmasıdır.




Şekil 3.5. Sigmoid fonksiyonunun grafiği [22]

3.1.4.4. Sinüs fonksiyonu

Sinüs fonksiyonu pozitif ve negatif değerler üreten trigonometrik bir fonksiyondur. Sinüs dalgalarına paralel olarak sunan bir fonksiyondur. Sinüs fonksiyonunun grafiği Şekil 3.6 ile gösterilmiştir. Sinüs fonksiyonunun matematiksel ifadesinin denklemi Denklem (3.7)'de verildiği şekildedir;

$$g(x) = \sin(x) \quad (3.7)$$




Şekil 3.6. Sinüs fonksiyonunun grafiği [23]

3.1.4.5. Hiperbolik tanjant fonksiyonu

Pozitif ve negatif deęerler üretebilme kabiliyetine sahiptir ve türevlenebilen fonksiyondur. Bu yüzden geri yayılımlı ağlarda çokça tercih edilir. Hiperbolik tanjant fonksiyonu ise Şekil 3.7 ile gösterilmiştir. Hiperbolik tanjant fonksiyonunun Matematiksel gösteriminin denklemi ise Denklem (3.8)'de gösterilmiştir;

$$g(x) = \frac{e^{2x-1}}{e^{2x+1}} \quad (3.8)$$




Şekil 3.7. Hiperbolik tanjant fonksiyonu grafięi [22]

3.1.4.6. Logaritmik aktivasyon fonksiyonu

Çalışma mantığı Hiperbolik Tanjant Fonksiyonuna benzeyen pozitif ve negatif çıktı üreten türevi alınabilen fonksiyondur. Bu yüzden çok katmanlı ağlarda tercih edilmektedir. Logaritmik aktivasyon fonksiyonu Şekil 3.8 ile ifade edilmektedir. Logaritmik aktivasyon fonksiyonunun matematiksel gösteriminin denklemi Denklem (3.10)'da gösterilmiştir;

$$g(x) = (\log(1-x) \quad x < 0 ; \log(x+1) \quad x \geq 0) \quad (3.10)$$



Şekil 3.8. Logaritmik aktivasyon fonksiyonu grafiği

Kullanılan aktivasyon fonksiyonları için de en çok sigmoid ve hiperbolik tanjant en çok tercih edilir. Geniş bir sınıflandırıcıya ihtiyaç olduğunda Hiperbolik Tanjant kullanılırken, öğrenme hızı açısından Sigmoid fonksiyonu kullanılabilir. Bazı aktivasyon fonksiyonlarının çizelgesi aşağıda Tablo 3.2 ile verilmiştir [1].

Tablo 3.2. Aktivasyon fonksiyonu örnekleri

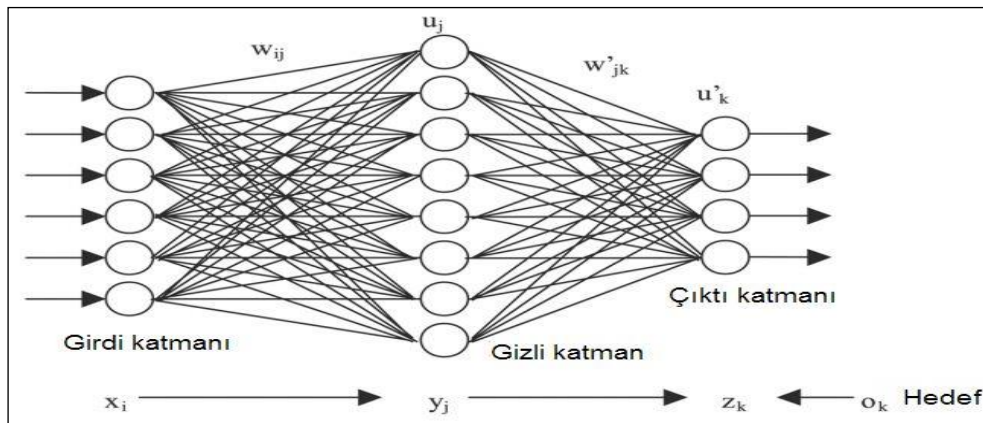
Aktivasyon Fonksiyonu	Açıklama
Lineer fonksiyon $F(\text{NET})=\text{NET}$	Girdinin çıktıya eşit olduğu durumdur.
Step Fonksiyonu $F(\text{NET}) = \begin{cases} 1 & \text{if NET} > \text{eşik değeri} \\ 0 & \text{if NET} < \text{eşik değeri} \end{cases}$	Hesaplanan NET girdinin eşik değerinin altında ya da üzerinde olma durumuna göre hareket edilerek çıktı dış dünyaya 1 veya 0 olarak verilmektedir.
Sinüs Fonksiyonu $F(\text{NET})=\text{Sin}(\text{NET})$	Problem verileri sinüs fonksiyonuna uygun dağılım gösterdiği durumda tercih edilmesi gereken fonksiyondur.

Tablo 3.2. (Devam) Aktivasyon fonksiyonu örnekleri

Aktivasyon Fonksiyonu	Açıklama
<p>Eşik Değer Fonksiyonu</p> $F(\text{NET}) = \begin{cases} 0 & \text{if } \text{NET} \leq 0 \\ \text{NET} & \text{if } 0 < \text{NET} < 1 \\ 1 & \text{if } \text{NET} \geq 1 \end{cases}$	Girdi verilerinin 0 ya da 1 den büyük olma veya küçük olma durumlarına göre hareket edilir. 0 ve 1 dışında değer almaz.
<p>Hiperbolik Tanjant Fonksiyonu</p> $F(\text{NET}) = \frac{(e^{\text{net}} + e^{-\text{net}})}{(e^{\text{net}} - e^{-\text{net}})}$	Hesaplanan net girdinin ilgili fonksiyondan geçirilmesi ile çıktı üretilir.
$F(\text{NET}) = \frac{1}{1 + e^{-\text{NET}}}$	NET proses elemanına gelen NET girdinin ilgili aktivasyon fonksiyonundan geçirilmesi ile çıktı elde edilir.

3.2. Yapay Sinir Ağı Yapısı

YSA yapay sinir hücrelerinden oluşmaktadır. Aynı görevi üstlenen yapay sinir hücrelerinin bulunduğu yer katman olarak tanımlanmaktadır. Bu yüzden YSA' da tek katmanlı ve çok katmanlı ağlar kavramı ortaya çıkmıştır. Çalışmada veriler arası doğrusal olmayan ilişkinin mevcudiyetinden dolayı çok katmanlı ağ tercih edilmiştir. Çok katmanlı ağlar giriş, gizli ve çıktı katmanı olmak üzere en az 3 katmandan oluşmaktadır. Gizli katman sayısı probleme göre farklılık arz etmektedir. Yapay sinir ağının genel yapısı, Şekil 3.9'da gösterilmiştir



Şekil 3.9. Yapay sinir ağının yapısı [23]

Girdi katmanında alınan veriler herhangi bir işleme tabi tutulmaz başka bir deyişle ağ için taşıyıcılık vazifesi görmektedir. Katmanlar arası bilgi iletişimi nöronlar vasıtası

ile gerçekleşir. Herhangi bir nöronda gerçekleşecek bozulma verinin kaybolmasına sebebiyet vermemektedir.


Tanımlanan nöron sayısı ya da gizli katman sayısı olması gereken değerden fazla tanımlanması bu ağın salınımlar yapmasına neden olurken, olması gereken değerden küçük tanımlanması da olayı öğrenme de ağın yetersizliğine sebep olmaktadır. Tanımlanacak olan bu iki değer için deneme yanına yolundan farklı bir yol henüz bulunamamıştır.

YSA' da çıktı katmanında hesaplanan hata giriş katmanına doğru azaltılıp minimum hata düzeyi yakalandığında öğrenme ağ tarafından durdurulmaktadır. Bu da geleneksel yöntemlere oranla daha iyi bir çalışma mekanizmasına sahip olduğunu göstermektedir.

YSA, yapısına göre ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olmak üzere iki başlık altında incelenebilmektedir.


İleri beslemeli ağlarda, bağlantılar aracılığı ile katmanlar sadece ileri doğru beslenirken, geri beslemeli ağlarda katmanlar geriye doğru da güncellenen ağırlıklar vasıtası ile yeniden beslenmektedir.

İleri beslemeli ağları ise, tek ve çok katmanlı ağlar olarak incelemek mümkündür. Tek katmanlı ağlarda ara nöronlar bulunmamaktadır. Besleme yönü ise giriş katmanından çıkış katmanına doğrudur. Başka bir deyişle ileriye dönüktür. Tek katmanlı yapay sinir ağının yapısı Şekil 3.10'da gösterilmiştir.




Şekil 3.10. Tek katmanlı yapay sinir ağının yapısı

Çok katmanlı ağlarda tek katmanlı ağlardan farklı olarak gizli katman bulunmaktadır. Gizli katman sayesinde karmaşık olan veriler arası ilişki daha kolay çözüme kavuşturulur ve probleme çözüm sunulur. Şekil 3.11 çok katmanlı bir ağın yapısını göstermektedir.



Şekil 3.11. Çok katmanlı yapay sinir ağının yapısı

Geri beslemeli ağlarda ağırlıklar vasıtasıyla katmanlar hem ileri doğru beslenir hem de geriye doğru beslenmektedir. Geri beslemeli ağlarda temel şart en az bir tane nöronun çıktısı kendinden önce gelen nöronun girdisi olmalıdır. Geri beslemeli bir yapay sinir ağı yapısı Şekil 3.12’de gösterilmiştir.



Şekil 3.12. Geri beslemeli yapay sinir ağının yapısı

3.3. Yapay Sinir Ağlarında Öğrenme

YSA eldeki verilere dayanarak olaylar arası ilişkiyi çözümlene çözümlendiği örneklerden yola çıkıp farklı örnekler için çıktı üretme yeteneğine sahiptir. Nöronlar

arası ağırlıklar başlangıçta rastlantısal olarak belirlenmektedir. Üretilen çıktı hedef değere yaklaşıncaya kadar ağırlık değişimine devam edilir. En uygun ağırlık ağ tarafından bulunana kadar işlemler bu şekilde devam eder. Uygun ağırlıkların belirlenmesiyle eğitim tamamlanır ve bu öğrenme süreci ağırlık öğrenmesi olarak tanımlanır. Öğrenme sürecinde ağırlık değişimi matematiksel olarak Denklem (3.11)'de görüldüğü şekildedir;

$$W_{\text{yeni}} = W_{\text{eski}} + \Delta w (\eta \times (f_i - \text{net girdi}) \times X_i) \quad (3.11)$$

W: Herhangi bir ağırlık

Δw : Mevcut ağırlık miktarı değişimi

W yeni: Güncel ağırlık

W eski: Eski Ağırlık

η : öğrenme oranı

f_i : İstenen çıktı

x_i : girdi vektörü

net girdi: $w \times x_i + \partial$

∂ : eşik terimi

Ağırlık değişimleri sonucu üretilen çıktının yani nöronu harekete geçiren çıktının matematiksel gösterimi ise aşağıdaki verilen Denklem (3.12) numaralı denklemdeki gibidir;

$$\Theta = f(w \times x + \partial) \quad (3.12)$$

Θ : Çıktı

∂ : Eşik Terimi

W: Ağırlık matrisi

X: Girişler

Toplama fonksiyonu işlevi Denklem (3.13)'te verilmiştir;

$$\alpha = \sum_{j=0}^n w_{ji} \times x_{ji} - \partial_i \quad (3.13)$$

Çıktı değerinin matematiksel ifadesi Denklem (3.14) ve (3.15) numaralı denklemlerle ifade edilmiştir;

$$C_i = \varphi(\sum_{j=0}^n w_{ij} \times x_j - \partial_i) \quad (3.14)$$

$$C_i = \varphi(\alpha) \quad (3.15)$$

X_i =giriş değerleri

w_{ij} =j. nöronuna i.nörona bağlayan ağırlık değeri

∂ =eşik değeri

$\varphi(\alpha)$ =aktivasyon fonksiyonu işlevi

Hata fonksiyonunun minimizasyonunun matematiksel ifadesi Denklem (3.16) numaralı denklemde verilmiştir;

$$E = \frac{1}{2} \sum (gerçek \text{ çıktı değeri} - tahmin \text{ edilen çıktı değeri})^2 \quad (3.16)$$

E: Hata değeri

YSA' da öğrenme tek mekanizma üzerinden gerçekleşmez. Çıktının olup olmaması öğrenme için ayırt edici bir kavramdır. YSA öğrenmeleri sırasıyla danışmanlı, danışmansız ve destekleyici öğrenme olmak üzere ayrılmaktadır.

3.3.1. Danışmanlı öğrenme

Hem çıktının hem de girdinin ağa verildiği öğrenme türüdür. Öğrenme algoritmalarını kullanarak ağa sunulan çıktı ile kendi çıktısını karşılaştırıp hedef değere ulaşana kadar ağırlık güncellemesi yapan öğrenme türüdür. Ağırlık matrisindeki değişim hatanın kabul edilebilir düzeye ulaşması ile değerlendirilir. Geri yayılım ağları örnek verilebilir. Bu çalışmada da danışmanlı öğrenmeden faydalanılarak modelleme yapılmıştır.

3.3.2. Danışmansız öğrenme

Sadece girdi ağa sunuluyorsa danışmansız öğrenme türüdür. Girdi ağ için aynı zamanda çıktı vazifesi görmektedir. Girdiler ağ için çıktı vazifesi görmektedir. Bu öğrenme türünde önemli olan veriler arası istatistiksel ilişkiyi analiz edip ortaya çıkarmaktır. Hopfield ve Kohonen Ağları bu grupta yer almaktadır.

3.3.3. Destekleyici öğrenme

Çıktının sisteme verilmediği sadece olumlu ya da olumsuz sinyalin gönderildiği öğrenme türüdür. Ağırlıkların güncellenme işlemi bu sinyal değerlendirmesine göre yapılmaktadır.

3.4. Çok Katmanlı Yapay Sinir Ağlarında Öğrenme Algoritması

3.4.1. Geri yayılım algoritması

Çok katmanlı ağlar saklı katman sayısı probleme göre değişkenlik göstermekle birlikte girdi katmanı, saklı katman, çıktı katmanı olmak üzere en az üç katmandan oluşan ağlardır.

Giriş katmanında nöronlar vasıtasıyla alınan bilgi çıkış katmanına kadar yine nöronlar aracılığı ile gerçekleştirilmektedir. Çıktı katmanında hesaplanan hata gerçek değer ile ağın çıktısı arasındaki farktır. Hesaplanan hata katmanlara dağıtılır. Minimum hata düzeyi yakalanana kadar işleme devam edilir. Belirlenen bu hata değeri ağın iterasyonlar sonucu daha da azaltılamıyorsa öğrenme ağ tarafından durdurulur. Doğru ağırlıkların belirlenmesi eğitimin gerçekleştiği anlamını taşımaktadır. Kısaca hesaplanan hata düzeyine göre katmanlar geriye doğru güncel ağırlıklarla beslendiğinden dolayı algoritma bu şekilde isimlendirilir. $x_n=(X_{n1}, X_{n2}, X_{n3}, X_{n4}, \dots, X_{nn})^t$ şeklinde ifade edilen bir vektöre dair bilgi girdi katmanı ile alınıp ara katmanda işleme tabi tutulur ve çıktı katmanı ile dış dünyaya iletilir.

Gizli katman h, W_{ij}^h j. düğümün i. girdi katman düğümü ile olan bağlantı ağırlığını, θ_j^h eğim değeri ifade eder. Gizli katmandaki j düğümünün net girdi değeri Denklem (3.17)'de verildiği şekildedir;

$$net_{nj}^h = \sum_{i=1}^N W_{ij}^h \times x_{ni} + \theta_j^h \quad (3.17)$$

İlgili bu düğümün çıktı değeri ise Denklem (3.18)'deki şekilde ifade edilir;

$$i_{nj} = f_j^h(net_{nj}^h) \quad (3.18)$$

Θ çıktı katmanı, W_{kj}^{\ominus} gizli katman düğümlerinden olan k ve j düğümleri arasındaki bağlantı ağırlığı, θ_k^{\ominus} eğim değerini göstermektedir. Çıktı katmanı için k. Düğümün net girdi ve çıktı değerleri Denklem (3.19) ve (3.20)'de verilmiştir;

$$\text{net}_{nk}^{\ominus} = \sum_{j=1}^K W_{kj}^{\ominus} \times X_{pj}^{\ominus} + \theta_k^{\ominus} \quad (3.19)$$

$$a_{nk} = f_k^{\ominus}(\text{net}_{nk}^{\ominus}) \quad (3.20)$$

Hesaplama işlemi yukardaki işlemlere göre yapılmaktadır. Ağın öğrenmesinde kullanılan kurallar aşağıda verilmiştir.

En küçük kareler öğrenme kuralı Denklem (3.21)'de verilmiştir [24];

$$W(t+1)_i = W(t)_i + 2 \times \mu \times \varepsilon_k \times X_{ki} \quad (3.21)$$

X_{ki} =k. vektörün i. eğitim elemanı

ε_k =gerçek değer-tahmin edilen değer

μ =pozitif sabit bir sayı

3.4.2. Çıktı katmanında ağırlık güncellemesi

Girdi vektörlerinden k. vektörü için, g_k gerçek çıktı değerini, t_k tahmin edilen çıktı değerini ifade etmektedir. Hata değeri aşağıda verilen Denklem (3.22) formül üzerinden hesaplanır;

$$E_k = g_k - t_k \quad (3.22)$$

Çok katmanlı ağlar için bu formül yeterli değildir. Hesaplama tek düğüm çıktısı üzerinden yapılır. Tek bir çıktı düğümü hatası $\delta_{\text{düğüm}}$, bütün düğümlerin toplam hatası ise $E_{\text{düğüm}}$ olarak gösterilirse tek düğüm hatası Denklem (3.23)'de verilmektedir;

$$\delta_i = g_{ki} - t_{ki} \quad (3.23)$$

g_{ki} = İlgili düğümün gerçek çıktısı

t_{ki} = İlgili düğümün ağ tahmini

δ_i = İlgili düğümün hatası

Bütün düğümlerde hesaplanan hata değerinin matematiksel ifadesi Denklem (3.24)'de verildiği şekilde olur;

$$E_{\text{düğüm}} = \frac{1}{2} \times \sum_{k=1}^M (\delta_{\text{düğüm}})^2 \quad (3.24)$$

Ağırlıkların değişim yönünü belirleyebilmek için E_n değerinin negatif gradyeni hesaplanmalı ve hesaplama kolaylığı bakımından ∇E_n değeri ağırlık uzayı düzlemi olarak düşünülebilir. İlgili bağıntılar Denklem (3.25) ve (3.26) ile verilmiştir;

$$E_n = \frac{1}{2} \times \sum_k (g_{nk} - t_{nk})^2 \quad (3.25)$$

$$\frac{\partial E_p}{\partial W_{kj}^{\Theta}} = -(g_{nk} - t_{nk}) \frac{\partial f_k}{\partial \text{net}_{nk}^{\Theta}} \frac{\partial \text{net}_{nk}^{\Theta}}{\partial W_{kj}^{\Theta}} \quad (3.26)$$

Θ_{pk} çıktı değeri için hata hesabıyla birlikte kısmi türev uygulanmıştır. f_k^{Θ} türevin, $f_k^{\Theta'}$ (net_{nk}^{Θ}) işleme kısaltılmış haliyle verilmiştir. Son olarak negatif gradyene ulaşmak için Denklem (3.26)'dan Denklem (3.27)'deki formül elde edilir;

$$\frac{\partial \text{net}_{nk}^{\Theta}}{\partial W_{kj}^{\Theta}} = \frac{\partial}{\partial W_{kj}^{\Theta}} \sum_{j=1}^K W_{kj}^{\Theta} i_{nj} + \theta_k^{\Theta} = i_{nj} \quad (3.27)$$

η =öğrenme hızı

$$-\frac{\partial E_p}{\partial W_{kj}^{\Theta}} = (g_{nk} - t_{nk}) f_k^{\Theta'}(\text{net}_{nk}^{\Theta}) i_{nj} \quad (3.28)$$

$f_k^{\Theta'} = f_k^{\Theta}$ fonksiyonunun türevi

Denklem (3.26) ve (3.27)'deki denklemler birlikte çözülerek Denklem (3.28)'deki denkleme ulaşmak mümkündür. Negatif gradyen ağırlık değişim miktarı bu şekilde hesaplamaya alınır. Çıktı katman ağırlıklarının matematiksel hesabı aşağıda Denklem (3.29) ve (3.30) denklemleri kullanılarak elde edilir;

$$\Delta_n W_{kj}^{\Theta}(t) = \eta \times (g_{nk} - t_{nk}) f_k^{\Theta'}(\text{net}_{nk}^{\Theta}) i_{nj} \quad (3.29)$$

$$W_{kj}^{\Theta}(t+1) = W_{kj}^{\Theta}(t) + \Delta_n W_{kj}^{\Theta}(t) \quad (3.30)$$

Yukarıdaki denklemlerden yola çıkılarak, çıktı değerleri için iki fonksiyona ulaşmak mümkündür ve bu iki fonksiyon ise Denklem (3.31) ve (3.32) ile verilmiştir;

$$f_k^{\Theta}(\text{net}_{jk}^{\Theta}) = \text{net}_{jk}^{\Theta} \quad (3.31)$$

$$f_k^{\Theta}(\text{net}_{jk}^{\Theta}) = (1 + e^{-\text{net}_{jk}^{\Theta}})^{-1} \quad (3.32)$$

Sırasıyla bu iki fonksiyonun birincisi doğrusal fonksiyon iken iki numaralı fonksiyon sigmoid fonksiyonudur. Problemin çözümüne uygun olarak çıktı fonksiyonu doğrusal ya da sigmoid olarak tercih edilebilir, ancak doğrusal fonksiyon gizli katmanı işlevsiz bıraktığı için gizli katmanda farklı fonksiyon tanımlanmalıdır. İlgili bağıntılar Denklem (3.33) ve (3.34) ile verilmiştir;

$$f_k^{\Theta'} = 1 \quad (3.33)$$

$$f_k^{\Theta'} = f_k^{\Theta} (1 - f_k^{\Theta}) = \Theta_{nk} (1 - \Theta_{nk}) \quad (3.34)$$

Denklemden gerekli düzenlemeler yapılmış doğrusal çıktı için Denklem (3.35) kullanılır;

$$W_{kj}^{\Theta}(t+1) = W_{kj}^{\Theta}(t) + \eta \times (g_{nk} - t_{nk}) i_{nj} \quad (3.35)$$

Doğrusal olmayan çıktılar için de Denklem (3.36) kullanılmaktadır;

$$W_{kj}^{\Theta}(t+1) = W_{kj}^{\Theta}(t) + \eta \times (g_{nk} - t_{nk}) \Theta_{nk} (1 - \Theta_{nk}) i_{nj} \quad (3.36)$$

Ağırlık güncellemesinde kullanılacak denklemler Denklem (3.37) ve Denklem (3.38) ile verilmiştir. Denklem (3.37) gerekli işlemler yapılarak Denklem (3.38)'deki gibi son hali elde edilir;

$$\delta_{nk}^{\Theta} = (g_{nk} - t_{nk}) f_k^{\Theta'} \text{net}_{jk}^{\Theta} \quad (3.37)$$

$$= \delta_{nk} f_k^{\Theta'} \text{net}_{jk}^{\Theta} \quad (3.38)$$

Ağırlık güncellemeleri için kullanılacak temel eşitlik, Denklem (3.39) ile verilir;

$$W_{kj}^{\Theta}(t+1) = W_{kj}^{\Theta}(t) + \eta \times (\delta_{nk}^{\Theta}) i_{nj} \quad (3.39)$$

Gizli katman ağırlık güncellemesi;

$$E_n = \frac{1}{2} \sum_k (g_{nk} - f_k^\Theta(\text{net}_{nk}^\Theta))^2 \quad (3.40)$$

$$E_n = \frac{1}{2} \sum_k (g_{nk} - (\sum_k w_{kj}^\Theta i_{nj} + \theta_k^\Theta))^2 \quad (3.41)$$

Gizli katman hatası hesaplanırken Denklem (3.40) ve (3.41) numaralı denklemler kullanılır. i_{nj} değeri gizli katmandaki ağırlık değişimine bağlı olduğundan gizli katman ağırlık değerlerinin toplam hatası olan E_n 'nin gradyeni hesaplanır. Denklem (3.42) ve (3.43) bağıntıları kullanılır;

$$\frac{\partial \varepsilon}{\partial w_{ji}^g} = \frac{1}{2} \sum_k \frac{\partial}{\partial \text{net}_{nj}^g} (g_{nk} - \Theta_{nk})^2 \quad (3.42)$$

$$= - \sum_k (g_{nk} - \Theta_{nk}) \frac{\partial \Theta_{nk}}{\partial (\text{net}_{nk}^\Theta)} \frac{\partial (\text{net}_{nk}^\Theta)}{\partial \Theta_{nk}} \frac{\partial i_{nj}}{\partial \text{net}_{nj}^g} \frac{\partial \text{net}_{nj}^g}{\partial w_{ji}^g} \quad (3.43)$$

Gerekli işlemler uygulandığında bulunacak formül Denklem (3.44)'teki gibidir;

$$\frac{\partial \varepsilon}{\partial w_{ji}^g} = \sum_k (g_{nk} - t_{nk}) f_k^{\Theta'} (\text{net}_{nk}^\Theta) w_{kj}^{\Theta 2} f_j^{g'} (\text{net}_{nj}^g) i_{ni} \quad (3.44)$$

Denklem (3.44)'ü kullanılarak Denklem (3.45) elde edilir. Gizli katman ağırlık değerlerinin hesabı için Denklem (3.45)'e ulaşılır.

$$\nabla_n w_{ji}^g = \eta f_j^{g'} \text{net}_{nj}^g x_{ni} \sum_k (g_{nk} - \Theta_{nk}) f_k^{\Theta'} (\text{net}_{nk}^\Theta) w_{kj}^\Theta \quad (3.45)$$

Çıktı katmanı için hesaplanan hata eşitlikte yerine yazılırsa δ_{nk}^Θ , eşitlikte kullanılması ile denklemin yeni formatı Denklem (3.46)'deki gibi olur;

$$\nabla_n w_{ji}^g = \eta f_j^{g'} \text{net}_{nj}^g x_{ni} \sum_k \delta_{nk}^\Theta w_{kj}^\Theta \quad (3.46)$$

Çıktı katmanından hata gizli katmana iletilir dolayısıyla gizli katmanda hesaplanacak güncel hata çıktıdan gelen hataya bağlı olmaktadır. Gizli katmanda hesaplanan hata değerini kullanmada dikkate alınan Denklem (3.47)'deki gibidir;

$$\delta_{nj}^g = f_j^{g'} \text{net}_{nj}^g \sum_k \delta_{nk}^\Theta w_{kj}^\Theta \quad (3.47)$$

Hesaplanan hataya göre belirlenecek gizli katman güncel ağırlık değerleri için dikkate alınan denklem ise Denklem (3.48) olarak verilmiştir [24];

$$w_{ji}^g(t+1) = w_{ji}^g(t) + \eta \delta_{nj}^g x_i \quad (3.48)$$

3.4.3. Öğrenme hızı ve momentum katsayısı

YSA' da gerçekleşen anlık sıçramaların önüne geçmek için momentum katsayısı tanımlanır. Momentum katsayısı hesaplanan eski ağırlığın güncel ağırlığa ilave edilirken denklemde etkili olan katsayıdır.

Momentum katsayısının gerekliliği güncel ağırlık hesabında hesaplanan önceki ağırlığın tamamen göz ardı edilmeyip bir katsayıyla işleme dahil edilmesinden ötürü ortaya çıkmış ve sıfır bir aralığında olan gerçel bir sayıdır. Uzun vadede gerçekleşecek öğrenmenin maliyetini azaltma ihtiyacından dolayı ortaya çıkan diğer katsayı ise öğrenme katsayısıdır. Ayrıca öğrenme katsayısının olması gereken değerden büyük tanımlanması ağırlığın ezberlemesine neden olabilir ve bu da genelleme özelliğinin kaybına sebep olması demektir.

Öğrenme katsayısı sıfır ve bir arasında değer alan adım büyüklüğünü tanımlama katsayısı olarak da tanımlanabilir. Ağırlık güncelleme kuralı Denklem (3.49)'daki bağıntıya göre yapılmaktadır [24];

$$\nabla W_{ij}^k(K+1) = \mu \nabla W_{ij}^k(K) + \eta \delta_i^{k+1} \Theta_j^k \quad (3.49)$$

μ = momentum katsayısı

η = öğrenme hızı

3.4.4. Çalışmada kullanılan öğrenme algoritması

Geri yayılım ağlarında kullanılan öğrenme algoritmalarından biri hızlı ve kararlı yapıya sahip olan LM öğrenme algoritmasıdır. Çalışma prensibinde ise dik iniş kuralı bulunmaktadır. Bu yüzden bu öğrenme algoritmasından faydalanılmıştır.


3.5. Yapay Sinir Ağı Mimarileri

Tasarlanan mimarilerde kullanılan aktivasyon fonksiyonu, öğrenme parametreleri, ağırlıkların güncellemeleri durumlarına göre farklılık yaratabilmektedir.

3.5.1. Geri beslemeli yapay sinir ağı (GBYSA)

En az bir tane sinir hücresi kendisinden sonra gelen sinir hücresinin çıktısı ile besleniyorsa bu tür ağara geri beslemeli ağlar denilmektedir. Sözü edilen durum aynı katmanda bulunan hücreler arasında olabilirken farklı katman hücreleri arasında da gerçekleşebilir bunun için bir kısıtlama bulunmamaktadır.

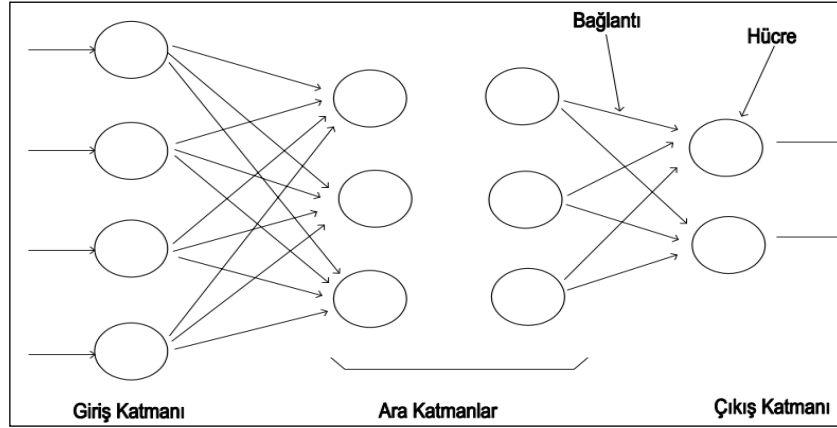
Dinamik ağ modellemeleri geri besleme gecikmesine sahip modellemelere örnek verilebilmektedir. Şekil 3.13'te geri beslemeli bir ağ modeli örnek teşkil edebilir.



Şekil 3.13. Geri beslemeli ağ modeli örneği [25]

3.5.2. İleri beslemeli yapay sinir ağı

İleri beslemeli bir yapay sinir ağı giriş katmanındaki nöronlar aracılığı ile bilgiler gizli katmana ardından oradaki nöronlar vasıtasıyla da çıktı katmanına iletilir. Katmanlar için besleme yönü ileri yönüdür. Giriş katmanı çıkışı gizli katman için girdi görevi görürken gizli katman çıktıları ise çıkış katmanını için girdi görevi görmektedir. İleri beslemeli yapay sinir ağının yapısı Şekil 3.14 ile gösterilmiştir.



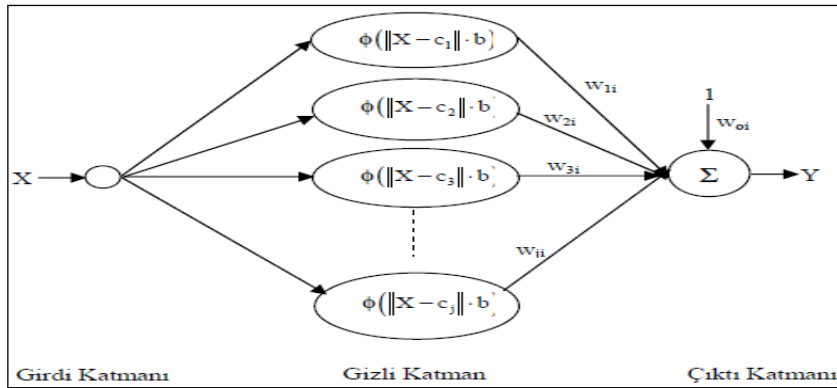
Şekil 3.14. İleri beslemeli yapay sinir ağının yapısı [26]

3.5.3. Radyal tabanlı yapay sinir ağı (RTYSA)

Radyal tabanlı ağlar katman sayısı bakımından çok katmanlı ağlara benzese de işleyiş açısından farklılık göstermektedir. Diğer ağların aksine giriş katmanından gelen ağırlıklandırılmış veriyi kullanmaz. Radyal aktivasyon fonksiyonlarını işleme alır.

Bu yüzden bu tür ağlarda giriş katmanından ara katmana sabit bir dönüşüm uygulanmaktadır.

Orta katmandan ve çıkış katmanına ise girişler ile temel fonksiyon merkezi arası mesafe baz alınarak işlemler yapılır. Başka bir deyişle, doğrusal dönüşüm işlemi uygulanır gibi düşünülebilir. Şekil 3.15'te Radyal Temelli bir yapay sinir ağı yapısı verilmiştir.



Şekil 3.15. Radyal tabanlı yapay sinir ağı yapısı

Bu mimarilerin dışında günümüzde daha karmaşık mimarileri taşıyan modellerde bulunmaktadır.

3.6. Zaman Serileri

Zaman serisi, ölçümü belli bir sıra ile yapılmış parametreye ait örneklerin sayısal değerlerinden oluşur. Zaman serisine ait farklı parametreler kullanılarak olaylar hakkında öngörü de bulunmak mümkün olabilmektedir. Bu çalışmada da birkaç parametreye ait zaman serisi kullanılarak dinamik programlama tabanlı modellemeler yapılmıştır. Elde edilen hata değerleri Radyal tabanlı ağ modelinden elde edilen hata ile karşılaştırılmıştır. Eldeki örneklere ait gözlem dönemlerinin gün, ay, yıl olması çok önem arz etmez. Önemli olan eşit aralıklarla yapılmasıdır [27].

Parametreye ait zamanla değişen değerlerin ifadesi matematiksel olarak Denklem (3.50) ifade edildiği şekildedir;

$$f(X_p)=(X_1, X_2, X_3, \dots, X_p) \quad (3.50)$$

3.6.1. Yapay sinir ağlarında zaman serileri

YSA' da ağlar, statik ve dinamik ağlar diye ayrılır. Eğer ağın kullanımı sırasında ağ öğrenmeye devam etmiyorsa bu tür ağlar statik ağlardır. Fakat öğrenme devam ediyorsa bu tür ağlar dinamik ağ sınıfına girmektedir. Temel farklılık ağın iç döngüsüne dayanmaktadır. Statik ağlarda hem zaman faktörü değişken olarak alınmaz hem de geri besleme gecikmesi yoktur. Dinamik ağlarda ise tersi durum söz konusudur. NARX ağları bu sınıfa girmektedir. Çünkü geri besleme gecikmesine sahip ağlardır.

Problemler üzerinde bağımsız değişkenler arttıkça problemi çözümlenmek o kadar güçleşmektedir. Aynı şekilde zamanla değişimlerdeki farklılıkta güçleştiren diğer etkendir. Bu yüzden bu tür problemleri çözümlenmek açısından dinamik ağ tercih etmek işlemleri kolaylaştırır. Çünkü hem zaman hem de doğrusal olmayan ilişkileri çözmekte oldukça iyi olan ağlardır. Bu çalışma da dinamik ağ modeli üzerinedir.

3.6.2. Doğrusal olmayan otoregresif (Nonlinear autoregressive)

Bu modellemede tek değişken üzerinden problem çözümlenmektedir. Geçmiş dönem özelliklerinden faydalanılarak gelecek hakkında tahmin yapılır. Yani diziye ait sadece

bir adet girdi serisi ile problem çözümlenmek istenmektedir. Bu döngünün matematiksel ifadesinin denklemi Denklem (3.51) ile verilmiştir [27];

$$y_{(t)} = f(y_{(t-1)}, y_{(t-2)}, \dots, y_{(t-2)}) \quad (3.51)$$

Akışı etkileyen parametreler birden fazla olduğundan dolayı NAR modeli bizim problemimize uygun çözüm yolu sunmakta yetersiz kalmaktadır.

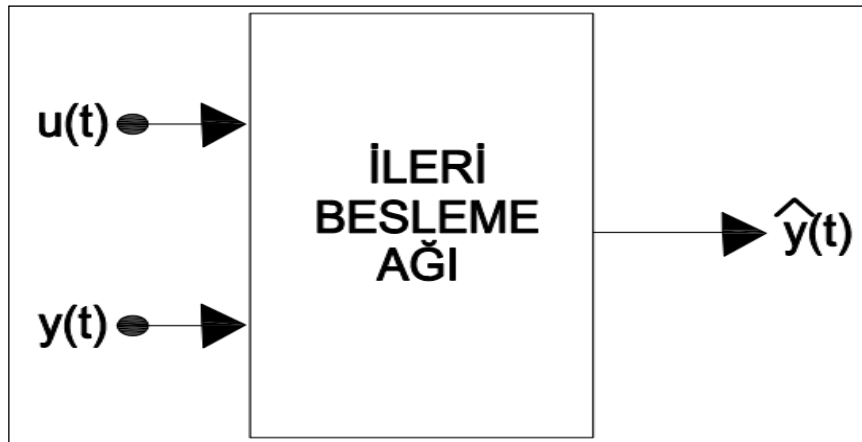
3.6.3. Doğrusal olmayan otoregresif eksojen (Nonlinear autoregressive exogenous)

Zaman serisi problemlerinde en çok tercih edilen ağlardan biridir. Modelleme sırasında belirtilen gecikme aralıklarıyla çıkışlar tekrar ağın girişine gönderilerek işlemler yapılmaktadır.

Ağın döngüsünün matematiksel ifadesinin denklemi Denklem (3.52)'de verilmiştir [27];

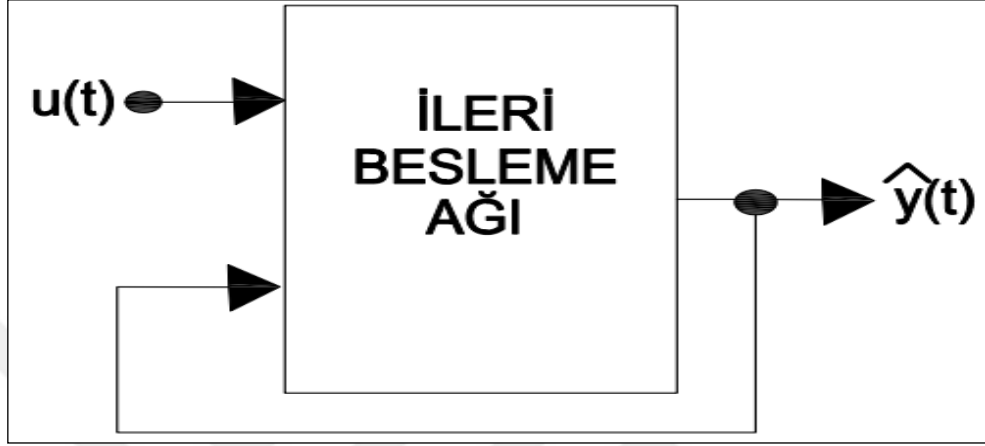
$$y(t) = f(y(t-1), y(x-2), \dots, y(x-ny), y(t-1), u(t-2), \dots, u(t-nu)) \quad (3.52)$$

Kendinden önceki çıkış değerleri ve girişler dikkate alınarak çıkış değeri olan $y(t)$, hesaplanmaktadır. Tahmini istenilen çıkış değeri ağa diğer girdi parametrelerinin yanında giriş olarak sunulmaktadır. Doğrusal olmayan problemlerin çözümü için tercih edilebilir.. Şekil 3.16 ile ise seriye bağlı bir yapay sinir ağı modeli gösterilmiştir.



Şekil 3.16. Seriye bağlı NARX modeli mimarisi

Şekil 3.17 ' den de anlaşıldığı üzere ağ tarafından tahmin edilen değer girişe tekrar gönderilmektedir. Girişler eldeki örnek uzayı iken çıkışlar ağın tahmini olmaktadır. Tahmin edilmesi istenen çıktının önceki değerleri bu tür ağlarda dikkate alınmaz. Şekil 3.17 ile dışsal girişi bir yapay sinir ağı modeli verilmiştir.



Şekil 3.17. Dışsal girişi NARX modeli mimarisi

4. ÇALIŞMA ALANI VE YERİ

4.1. Kocaeli İli Kandıra İlçesinde Bulunan Namazgâh Barajı

Bu çalışmada Kocaeli ilinin Kandıra ilçesinde bulunan Namazgâh Barajı'na ait örneklerden oluşan veri setine dayanarak akış tahmini için basit bir YSA modeli kurulmuştur. Akışın tahmini için zaman serisine dayalı doğrusal olmayan ilişkiyi çözümlenmekte oldukça iyi olan NARX modeli tercih edilmiştir. Kocaeli ilinin hemen hemen 33 km kuzeyinde ve Kandıra ilçesinin de 4 km güneybatısında Namazgâh Deresi üzerine kurulmuş olan Baraj, Kandıra ilçesi, Derince, Körfez ve İzmit ilçelerinin kuzey bölgeleri dahil olmak üzere 259 köy ve mahallenin su ihtiyacını karşılamak üzere tasarlanmıştır. Barajdan tesise 2014 yılında su verilmeye başlanmış olmakla birlikte baraj 34,5 m gövde yüksekliği, 504 m kret uzunluğu ve 25 milyon m³ su depolama kapasitesine sahiptir. Baraj Hacılar ve Sarnıçlar dereleri tarafından beslenmektedir. Baraja ait genel yapı Şekil 4.1'de gösterilmektedir.



Şekil 4.1. Namazgâh Barajı'nın uydu görüntüsü

4.2. Çalışma Alanına Ait Veriler

Çalışma alanına ait veri seti, Tarım ve Orman Bakanlığı Kocaeli Meteoroloji Genel Müdürlüğü tarafından araştırma gözlem istasyonlarından alınan minimum sıcaklık,

ortalama sıcaklık, havadaki su buharı basıncı ve yağışın günlük ölçümlerinin yanında, Kocaeli İsu Genel Müdürlüğüne ölçümü yapılan Namazgâh Barajına ait günlük akış verileri elde edilerek oluşturulmuştur. Probleme NARX modeli uyarlanmıştır. En sonda ise Radyal Tabanlı ağ modeliyle elde edilen hata değerleri karşılaştırılmıştır. Minimum sıcaklık, ortalama sıcaklık, havadaki su buharı basıncı ve yağış girişi verisi olarak kullanılıp çıkış olarak akış verilmiştir. Tahmin modelinde kullanılan verilere dair istatistiksel hesaplamalar sırasıyla Tablo 4.1 ve 4.2’de verilmiştir.

Tablo 4.1. Tahminde kullanılacak Kocaeli Meteoroloji Müdürlüğü AGİ verilerinin yapısı

İstasyon Adı / No	Veri Adı	Veri sayısı	X_(min)	X_(maks)	X_ort	S_x
KANDIRA / 18104	Minimum sıcaklık	308	-15	22,5	8,209524	7,19107
KANDIRA / 18104	Ortalama Sıcaklık	308	-6,3	26,8	13,83333	7,42246
KANDIRA / 18104	Havadaki Su Buharı	308	1,2	25,6	13,02897	5,64934
KANDIRA / 18104	Yağış	308	0	72,16	3,0	7,091648

Tablo 4.2. Tahminde kullanılacak akış verilerinin yapısı

	Veri Aralığı	Veri sayısı	X_(min)	X_(maks)	X_ort	S_x
Baraja Ait Akış: (m ³ /gün) -Ort.	1.1.2016-12.31.2016	308	2004,415	1943,294	100,637	233658,4
Baraja ait dönemsel kotlar:	-----	Talveg Kotu	Minimum İşletme Kotu	Dolu Savak Kotu	Maksimum işletme kotu	Taşkın kotu
		31,5	46	51	60	60,42

4.3. YSA Tahmin Senaryoları

Hidrolojik çevrimin karmaşık problemlerinden biri de barajlarda olabilecek akışın tahminidir. Birden fazla değişken etkili olduğu için durum daha da zorlaşmaktadır. Akış güneş radyasyonu, sıcaklık, rüzgâr hızı, rölatif nem, atmosfer basıncı ve diğer çevresel koşullarla birlikte temel olarak iklimsel değişikliklerden ötürü oluşmaktadır.

İstatistiksel yöntemlerin aksine bu çalışmada ise geliştirilen son modelleme tekniklerinden biri, doğrusal olmayan problemlerin çözümünde sıkça tercih edilen YSA kullanılmıştır.

4.3.1. Giriş deęişkenlerinin belirlenmesi

Girdi parametrelerinin doęru seilmesiyle kurulacak YSA modelinin performansı artırılabilir. Problemi etkileyen faktörler deęişkenlik gösterdiğinden dolayı, doęru modelin tespiti güçleşebilmektedir. Bu yüzden akış üzerinde etkili olan minimum sıcaklık, ortalama sıcaklık, havadaki su buharı basıncı ve yağışa ait günlük ölçümlerin giriş verisi olarak deęerlendirilip, Namazgâh Barajına ait günlük akış verileri çıkış olarak kullanılarak Matlab programı yardımıyla YSA modellemesi yapılmıştır.

Modellemelerde kurulan mimariden sonra aęın eğitim ve test aşamaları için kullanılan parametrelerde önemlidir. Modelleme süreci aşamaları aşağıdaki gibidir.

1. Veri Seti Deęerlendirmesi
2. Giriş ve Çıkış Parametrelerinin Belirlenmesi
3. Veri Setinin Normalizasyonu
4. Modelin ve Eğitim Parametrelerinin Belirlenmesi
5. YSA Eğitimi
6. YSA'nın Test Edilmesi

4.3.2. Eldeki verilerin deęerlendirilmesi

Çalışma alanına ait veri seti Tarım ve Orman Bakanlığı Kocaeli Meteoroloji Genel Müdürlüğü tarafından araştırma gözlem istasyonlarından alınan minimum sıcaklık, ortalama sıcaklık, havadaki su buharı basıncı ve yağış verilerine ait günlük ölçümlerinin yanında, Kocaeli İsu Genel Müdürlüğünce ölçümü yapılan Namazgâh Barajına ait günlük akış verilerinden oluşmaktadır.

4.3.3. Veri gruplarının oluşturulması

Öğrenme performansını etkileyen en önemli faktör veri setidir. Çünkü aęın öğrenmesi bu veriler üzerinden gerçekleşmektedir. Veri seti gruplandırılırken eğitim, test ve onaylama verisi olarak ayrıştırılır. Çalışmada kurulan modellemelerde 4 giriş verisi 1 tane de çıkış verisi kullanılmıştır.

- Öğrenme Grubu: En uygun ağırlığı belirlemek için kullanılan veri grubudur. Başka bir deyişle veriler arası ilişkinin çözüldüğü öğrenmenin gerçekleştiği gruptur.

- Onaylama Grubu: Ağ topolojisinde kullanılacak uygun parametrelerin tercihi için ayrılan gruptur. Ağ performansının bozulmaya başladığı noktada gerekli birim sayılarını belirler. Yani hata düzeyinin minimum olduğu noktadaki ağı ve ilgili ağırlıkları kaydetme görevini yerine getirir.
- Test Grubu: Ağın önceden gördüğü bir veri değildir. Öğrenmede kullanılmaz ancak öğrenmenin ne oranda gerçekleştiği hakkında fikir veren gruptur.

Verilerin sınıflandırma işlemi hem ağ tarafından yapılabilirken hem de kişi programlar aracılığı ile kendisi de yapabilmektedir. Veri kümesi sınıflandırma yüzdesi %70 öğrenme, %15 test, % 15 onaylama olarak değerlendirilmiştir.

4.3.4. Verilerin programa uygun hale getirilmesi

YSA'nın çalışma prensibinde ilk aşama eldeki örneklerin ağa tanıtılma aşaması olmaktadır. Çünkü YSA rakamlara duyarlıdır. Farklı durumlar için bazen numerik olmayan faktörleri de dikkate almak gerekebilir. Bu yüzden bunların da bir şekilde sayısal veri ile ifade edilmesi gerekmektedir. Dönüştürme işlemi girdi ve çıktı verilerine uygulanıp bunlar numerik tanımlanması ağın performansı açısından bu durumun oldukça olumlu etkiye sahip olmasına sebep olur. Dönüşüm sadece girdilere uygulanırsa gerçek çıktı ve tahmin edilen çıktı arasında hata tespiti yapmak güçleşmektedir. O yüzden tüm veriye dönüşüm uygulamak önem arz etmektedir.

Hedef değer ile ağ çıktısı arasında ki uyumun sağlanması için veri setinin kullanılacak programa uygun hale getirilmesi birinci aşamadır. Bu işlem hem girdi hem de çıktı için normalizasyon olarak ifade edilir. Yani kısaca bütün veriyi [0-1] aralığına indirgeme işlemidir. Normalizasyon işlemi için kabul gören varsayımlardan bazıları aşağıda verilmiştir.

- Doğrusal Dönüşüm: Verileri [0-1] aralığında indirgeme işlemidir. Matematiksel ifadesinin denklemi Denklem (4.1)'de verildiği şekilde olur [1];

$$X_n = \frac{X_0 - X_{\min}}{X_{\max} - X_{\min}} \quad (4.1)$$

- Doğrusal Dönüşüm: Verileri [a-b] aralığında normalleştirir bu dönüşüme ait denklem Denklem (4.2)'de gösterildiği gibi olur [1];

$$X_n = (b-a) \frac{X_0 - X_{\min}}{X_{\max} - X_{\min}} + a \quad (4.2)$$

- Basit Normalizasyon: En basit normalizasyon ifadesidir denilebilir bu dönüşüme ait denklem Denklem (4.3)'te verildiği gibidir [1];

$$X_n = \frac{X_0}{X_{\max}} \quad (4.3)$$

- İstatiksel Normalizasyon: İstatistiksel verilerden faydalanılarak veri dönüştürmekte mümkün olabilmektedir. İstatistiksel normalizasyonda kullanılan denklem Denklem (4.4)'te verildiği gibi olmaktadır [1];

$$X_n = \frac{X_0 - \bar{X}}{s} \quad (4.4)$$

X_n : Normalize edilmiş veri

X_0 : Ağa sunulan gerçek veri değeri

X_{\max} : Normalize edilecek verilerin maksimum değeri

X_{\min} : Normalize edilecek verilerin minimum değeri

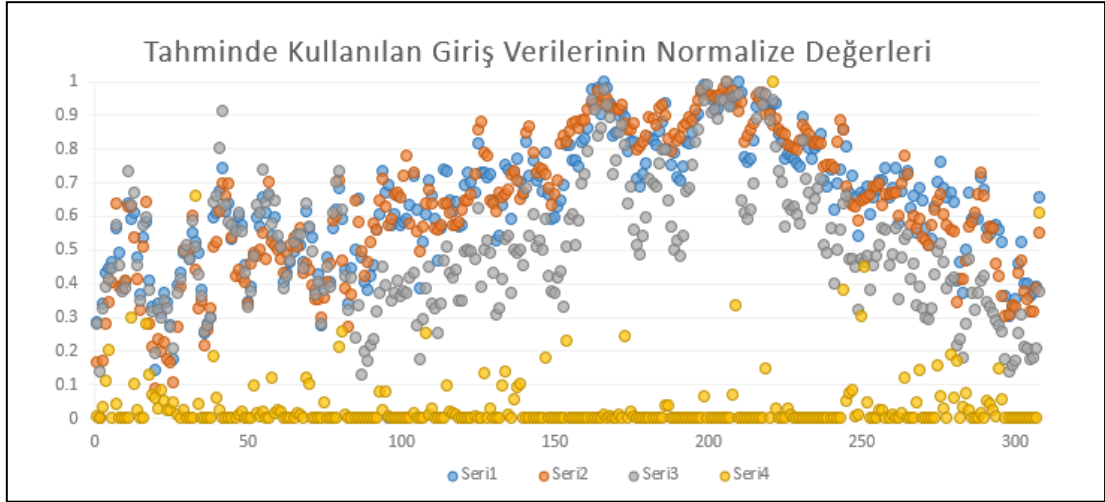
\bar{X} : Normalize edilecek verilerin ortalama değerleri

S: Normalize edilecek veri grubunun standart sapması

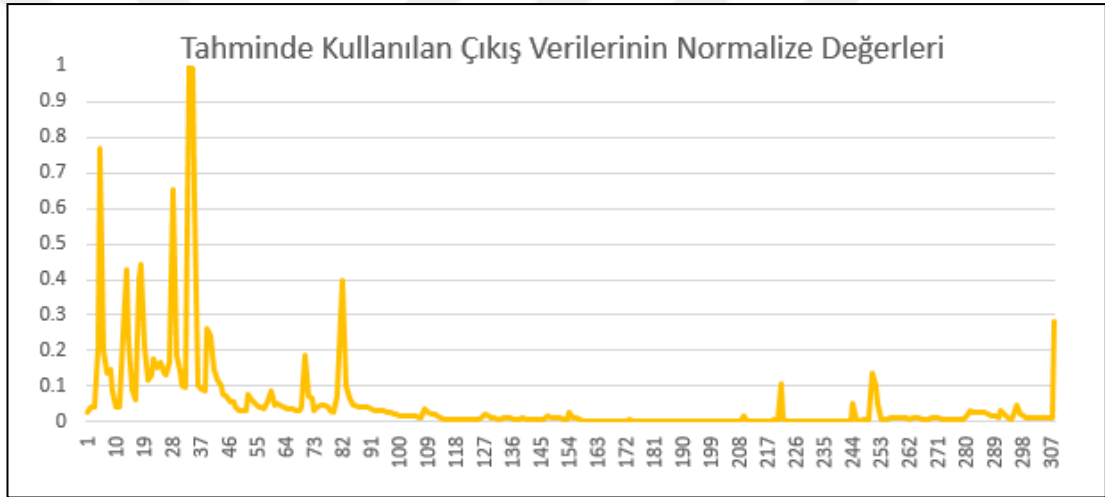
Doğrusal dönüşüm çalışmaya ait verileri [0-1] aralığında normalize eder. Bu dönüşüme ait denklemin matematiksel ifadesi Denklem (4.5) ile verildiği şekilde olur [1];

$$X_n = \frac{X_0 - X_{\min}}{X_{\max} - X_{\min}} \quad (4.5)$$

Giriş olarak sınıflandırılan veriye ait normalize değerler Şekil 4.2 ile gösterilmiştir, Şekil 4.3'te ise tahminde kullanılan çıkış veri grubunun normalize değerleri verilmektedir.



Şekil 4.2. Tahminde kullanılan girdi veri gruplarının boyutsuz hali



Şekil 4.3. Tahminde kullanılan çıktı veri grubunun boyutsuz hali

4.3.5. Modelin belirlenmesi

Mimari tasarım model belirleme işleminin birinci aşaması iken, ağı eğitme parametrelerini belirleme işlemi ise ikinci aşamayı oluşturmaktadır. Kullanılacak ağ çok katmanlı bir ağ ise öncelikle gizli katman sayısı ve bu katmanda bulunacak nöron sayısına karar verilir. Tasarlanan bu mimarinin doğru performansı doğru ağ özelliklerinin seçimiyle mümkündür. Kullanılacak öğrenme algoritması bu noktada önem kazanmaktadır. Çünkü hatayı geriye doğru yayma işlemi kullanılan algoritmaya bağlıdır ki çok katmanlı ağlarda bu çoğunlukla geri yayılım algoritmasıdır. Kullanılan öğrenme algoritmalarının kullandığı aktivasyon fonksiyonu önemlidir. Çünkü hata eğimini belirlemek kullanılan aktivasyon fonksiyonuyla bağlantılıdır. Etkili olan diğer bir faktör ise ağı deneme sayısı ve iterasyon sayıları olmaktadır. Model belirleme

işleminde en etkili faktörler yukarıdaki gibidir. Çalışmada oluşturulan veri seti normalizasyon işlemiyle programa uygun hale getirilip uygun mimari tasarım belirlenirken bu faktörlere dikkat edilerek işlemler yapılmıştır.

Veri seti için model uygunluk ölçütleri belirleme aşamasında değerlendirmeye alınan faktörler aşağıdaki gibidir:

- Öğrenme veri kümesi için ortalama mutlak hatanın sifira yakınlığı çok önemlidir. Öğrenme kümesinde bu değerin sifira yakınlığı belirliliğinde bire yakınlığı test verileri için yapılacak tahminde anlamlı sonuçlar alınacağıının sinyalinin vermektir.
- Test verisi için hesaplanan ortalama mutlak hataya bakılır bu değer sifira ne kadar yakınsa, tasarlanan ağ mimarisi o kadar güçlü ve kaliteli demektir.
- Onaylama verisi için verinin ortalama mutlak hatasına bakarak eğitimin durdurulup durdurulmamasına karar veren mekanizmadır. Dolayısıyla bu değerinde sifira yakın olması oldukça önemlidir.
- Belirlilik Katsayısı R^2 diye de ifade edilmektedir. 1'e yakın değer alması önemlidir, 1'e yakın olması modelin ve mimarinin kaliteli olduğunu gösterir.

Veri setinin geniş kapsamlı olması öğrenme açısından oldukça iyi sonuç vermektir. Ve öğrenme ne kadar iyi gerçekleşirse ağın daha önce görmediği test verisi doğru tahmin yapması olasılığı o kadar yüksek olur.

4.3.6. Kurulan YSA'nın eğitimi, test edilmesi ve simule edilmesi

Veriler arası göremediğimiz durumlarda mevcut olabilir. Böylesi durumlar için YSA oldukça iyi sonuçlar vermektir. Çünkü veri setinde fark edilmeyen ilişkileri de sahip olduğu gizli katman sayesinde çözümleyebilmektedir.

Bu çalışmada bir tane gizli katman kullanılıp gizli katmana uygun nöron sayısı 5-50 arasında değerlerle deneme yanılma yolu ile belirlenmeye çalışılmıştır. Kurulan modeller arasında en iyi model belirlenmeye çalışılırken MSE değerinin sifira, R^2 değerininse 1'e yakın olması istenir.

Öğrenme, onaylama ve test verileri için R^2 değerlerinin birbirine yakın olması tutarlı bir sonuca sahip bir model olduğunu göstermektedir, birbirine uzak R^2 değerlerinde ise tersi durum söz konusudur. Öğrenme verileri için 1'e yakın belirlilik katsayısı test verilerine doğru çıktı üretileceğini göstermektedir.

YSA örnek veri setinden yaptığı genelleştirmelere dayanarak yeni örneklerle çıktı üretebilmektedir. Bu durum YSA'nın istatistikî yöntemlere göre avantaj sağlamasına sebep olmaktadır. Bundan dolayı modellemede YSA yönteminden faydalanılmıştır.

4.3.7. Akış tahmini için kurulan yapay sinir ağı modelleri

YSA'da model kurmak için veri depolama kadar doğru parametre seçimi de önemlidir. Doğru parametre tercihi ile belirlenen giriş ve çıkışlar sayesinde problem için basit bir model kurmak oldukça kolay hale gelebilir.

Özellik sayısını azaltıp kurulan modeller için çıkış üretmek basit bir model diye tabir edilebilir. Basit modelden kasıt özellik sayısını azaltmaktan ibarettir. Bu çalışmada akış üzerinde etkisi bulunan meteorolojik parametreler dikkate alınarak mevcut veri yardımıyla basit bir otoregresif YSA modeli kurulmuştur. Sebep olan parametreler dikkate alınarak mevcut veri yardımıyla zaman serisi de göz önünde bulundurularak basit bir model kurulmuştur.

Çalışmada minimum sıcaklık, ortalama sıcaklık, su buharı basıncı ve yağışa bağlı akış tahmini yapılmıştır. Bu beş parametreye ait toplamda 1540 veri işleme konulmuştur. Bu verilerin %70'i öğrenme, %15 test, %15 onaylama verisi olarak sınıflandırılmıştır.

Test, onaylama ve öğrenme verisi seçilirken seçim rastgele yapılmıştır. Çalışmada kullanılan veriler programa uygun hale getirilmek için normalizasyon işlemine tabi tutulmuştur. Böylelikle örnek veri seti [0-1] arasına indirgenmiştir.

Gizli katman sayısı bir olarak belirlenip, gizli katmanda bulunması gereken nöron sayısına deneme yanılma yolu ile karar verilmiştir. Modellemede kullanılması gereken öğrenme algoritması belirlenirken üç farklı öğrenme algoritması denenmiştir. Bu algoritmalar sırasıyla LM, Bayesian Regularization, Scaled Conjugate Gradient' tir. Bu öğrenme algoritmaları için aynı nöron sayısı denenerek hangi algoritmanın daha iyi performans sergilediği analiz edilmiştir. Bu öğrenme algoritmaları için kurulan modellemelerden alınan sonuçlar aşağıda verilmiştir. LM, Bayesian Regularization, Scaled Conjugate Gradient algoritmaları kullanılarak elde edilen modelleme sonuçları Tablo 4.5, Tablo 4.6 ve Tablo 4.7 ile verilmiştir.

Tablo 4.3. Bayesian Regularization öğrenme algoritmasıyla elde edilen sonuçlar

Model	Gizli Katman Nöron Sayısı	Eğitim R ²	Test R ²	Eğitim MSE	Test MSE
1	5	0,995517	0,729469	1,28401e ⁻⁴	3,34881e ⁻²
2	10	0,996540	0,686798	1,07923e ⁻⁴	1,28954e ⁻¹
3	15	0,998079	0,806015	4,88406e ⁻⁵	1,37183e ⁻¹
4	20	0,999899	0,767684	3,27793e ⁻⁶	7,97301e ⁻²
5	25	0,999999	0,588932	1,30788e ⁻⁸	6,74436e ⁻²

Tablo 4.4. Scaled Conjugate Gradient öğrenme algoritmasıyla elde edilen sonuçlar

Model	Gizli Katman Nöron Sayısı	Eğitim R ²	Onaylama R ²	Test R ²	Eğitim MSE	Onaylama MSE	Test MSE
1	5	0,81607	0,399853	0,703542	3,374e ⁻³	3,7332e ⁻²	2,4173e ⁻²
2	10	0,771820	0,802084	0,52361	5,146e ⁻³	8,0552 e ⁻³	1,8929e ⁻³
3	15	0,696277	0,692226	0,62769	1,0201e ⁻²	4,5681e ⁻³	1,3613e ⁻³
4	20	0,77949	0,690209	0,77482	6,9565e ⁻³	7,8972e ⁻³	5,6064e ⁻²
5	25	0,71151	0,764577	0,63069	8,8804e ⁻³	4,7389e ⁻³	7,802e ⁻²

Tablo 4.5. Levenberg- Marquardt öğrenme algoritmasıyla elde edilen sonuçları

Model	Gizli Katman Nöron Sayısı	Eğitim R ²	Onaylama R ²	Test R ²	Eğitim MSE	Onaylama MSE	Test MSE
1	5	0,820361	0,846732	0,810362	5,5994e ⁻³	2,7148e ⁻³	1,4646e ⁻²
2	10	0,82048	0,466646	0,782760	6,4785e ⁻³	1,58682e ⁻²	3,9295e ⁻³
3	15	0,86060	0,503929	0,823968	2,7711e ⁻³	1,84410e ⁻²	7,9463e ⁻³
4	20	0,93667	0,328017	0,886740	1,8258e ⁻³	2,7651e ⁻²	1,94673e ⁻³
5	25	0,89094	0,621550	0,864860	1,8015e ⁻³	2,0368e ⁻²	3,3037e ⁻³

Probleme uyarlanan öğrenme algoritmalarının verdiği sonuçlar karşılaştırıldığında LM öğrenme algoritmasının diğer iki algoritmaya oranla daha iyi çözüm ürettiği görülmüştür. Sonuçlar analiz edildiğinde öğrenme yüzdesi yüksek olmasına rağmen test verilerine oldukça düşük cevap verildiği de gözlemlenmiştir. Bunun sebebi ise ağın bazı noktalarda öğrenme yerine veriye uyma durumunun mevcudiyetidir. Başka bir deyişle veriyi öğrenmek yerine veriyi ezberlemesi durumudur. LM öğrenme algoritmasının öğrenme ve test verileri için daha tutarlı sonuçlar ürettiği ve hatayı minimize etmede oldukça iyi performans sergilediği görülmüştür. LM öğrenme algoritmasının diğer algoritmalara üstünlük sağlamasının temel sebeplerinden biri de öğrenmede hızlı performans sergilemesidir. Öğrenme gerçekleştikçe iterasyonlar sonucu hata oranı azaltılamıyorsa bir süre sonra eğitim kendiliğinden ağ tarafından

durdurulur. Bu noktada sınıflandırılan onaylama verileri devreye girer ve en iyi ağırlıklar kayıt altına alınır. Dolayısıyla doğrusal olmayan problemler için bu öğrenme algoritması oldukça avantajlı olduğu kanısına varılmıştır.

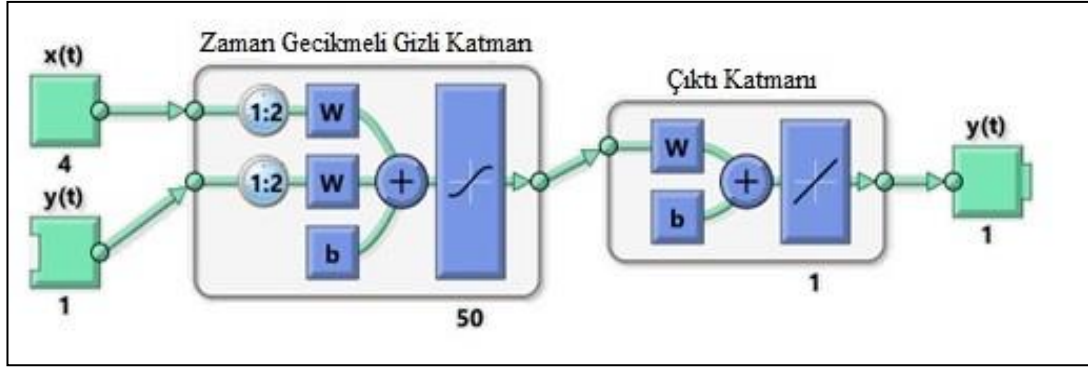
Bu çalışmada zaman serisine dayanan geri besleme gecikmesine sahip Nonlinear Doğrusal Olmayan Otoregresif olarak tabir edilen NARX modeli kullanılmıştır. Modelleme diğerlerine kıyasla daha iyi sonuç verdiği için LM Öğrenme Algoritması tercih edilmiştir. En iyi performans belirlenirken hata kareler ortalaması ve regresyon katsayısı dikkate alınmıştır. LM öğrenme algoritması kullanılarak yapılan analizlerde geri besleme gecikmesine sahip modeller için farklı nöron sayıları denenerek en iyi öğrenmenin gerçekleştiği duruma gizli katman nöron sayısına 50 olarak karar verilmiştir.

Kurulan farklı modellemeler için alınan sonuçlar Tablo 4.6’da gösterilmiştir:


Tablo 4.6. YSA tahmin modellerinden alınan sonuçlar

GK NS	Geri Besleme Gecikmesi	Eğitim MSE	Test MSE	Eğitim R ²	Onaylama R ²	Test R ²
5	1:2	5,59949e ⁻³	1,4647e ⁻²	0,820361	0,846732	0,810362
10	1:2	6,47850e ⁻³	3,9295e ⁻³	0,820486	0,466646	0,782760
15	1:2	2,77118e ⁻³	7,9463e ⁻³	0,860600	0,503929	0,823968
20	1:2	1,82580e ⁻³	1,9467e ⁻³	0,936672	0,328017	0,886740
25	1:2	1,80158e ⁻³	3,3037e ⁻³	0,890946	0,621550	0,864860
30	1:2	2,68447e ⁻³	5,2357e ⁻³	0,929572	0,382153	0,909400
35	1:2	1,23259e ⁻³	5,21256e ⁻³	0,946861	0,574430	0,824025
40	1:2	1,59016e ⁻³	6,78156e ⁻³	0,934399	0,431682	0,842424
45	1:2	3,86334e ⁻³	8,0035e ⁻³	0,889162	0,672671	0,878724
50	1:2	9,23728e ⁻⁴	3,61243e ⁻⁴	0,962423	0,413256	0,896031

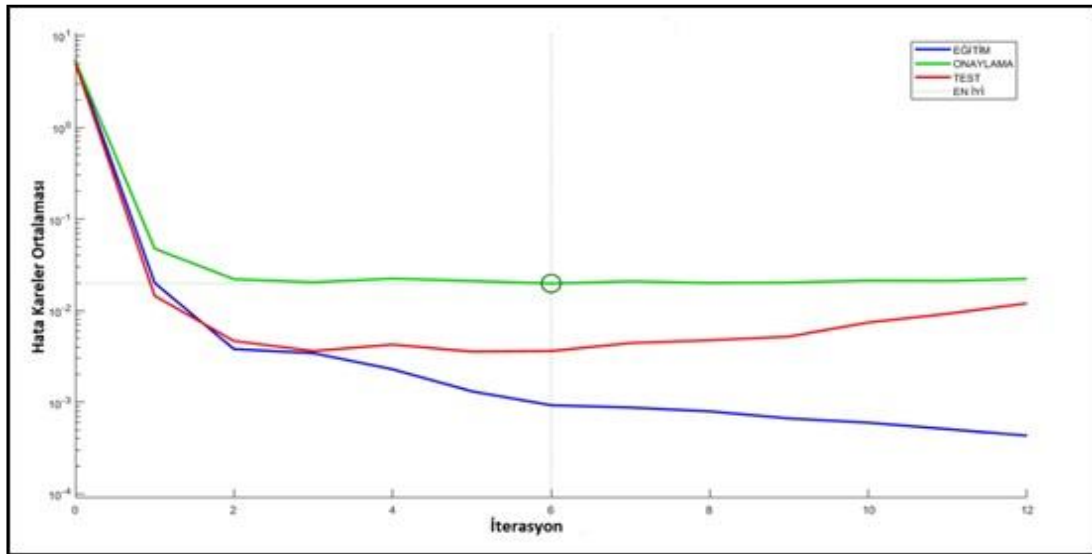
En iyi performansı sergileyen modele ait Şekil 4.4’te mimari, Şekil 4.5’te hedef değer ve çıktının karşılaştırılması, Şekil 4.6’da deneysel hata grafiği görülmektedir.



Şekil 4.4. Akış tahmini için en iyi performansı veren modelin mimarisi

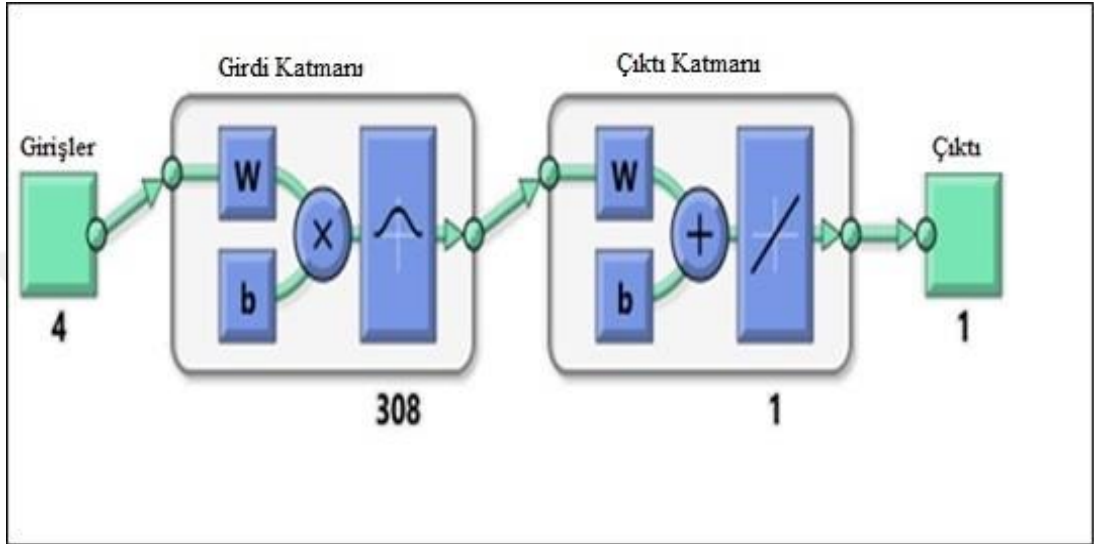


Şekil 4.5. Akış tahmini için en iyi performansı veren modelin çıktısı ve hedef değer grafiği



Şekil 4.6. Akış tahmini için en iyi performansı veren modelin deneysel hata grafiği


NARX modelinden elde edilen sonuçlar değerlendirilip karmaşık problemlere oldukça iyi çözüm üreten Radyal tabanlı ağ modelinden elde edilen hata değerleriyle karşılaştırılmıştır. Şekil 4.16’da ise Kurulan Radyal tabanlı ağ modelinin mimarisi verilmiştir. Tablo 4.7’de Radyal tabanlı bir ağ modelinden elde edilen MSE değerleri verilmiştir.



Şekil 4.7. Radyal Tabanlı Ağ Modelinin Mimarisi

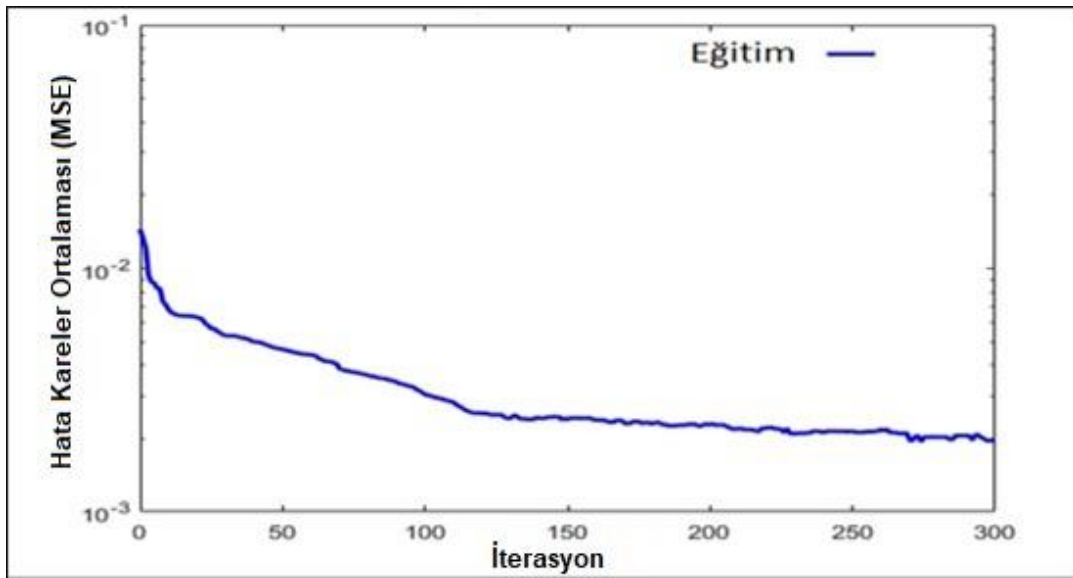
Tablo 4.7. Akış tahmini için Radyal Tabanlı Ağ Modeli MSE Hata Değerleri

MODEL	Radyal Tabanlı ağ, Nöron	MSE
1	0	0,014487
2	50	0,004659
3	100	0,003031
4	150	0,002392
5	200	0,002290
6	250	0,002140
7	300	0,001965



Şekil 4.8. NARX ve Radyal Tabanlı Ağ modelinin MSE değeri karşılaştırma grafiği

Radyal tabanlı ve NARX modellerine ait grafikler incelendiğinde gizli katman sayısını arttırmaya gerek kalmadan nöron sayısı artırılınca minimum hata düzeyine yaklaşıldığı görülmektedir. Nöron sayısındaki arttırma işlemiyle hedeflenen hata düzeyi yakalanmamış olsaydı, ikinci işlem olarak gizli katman sayısı artırma işlemi çözüm olarak denenebilirdi. Nöron sayısındaki arttırma işlemi problemin çözümü için yeterli olduğundan ikinci bir gizli katmana gerek duyulmamıştır. NARX’de ufak tefek farklılıklar olmasına rağmen her iki model için nöron sayısını arttırıldığında hata düzeyinin azaldığı görülmüştür.



Şekil 4.9. Radyal Tabanlı Ağ modelinin deneysel hata grafiği

5. SONUÇLAR VE ÖNERİLER

Çalışmada giriş verisi olarak minimum sıcaklık, ortalama sıcaklık, su buhar basıncı ve yağış kullanılırken çıkış verisi olarak akış kullanılmıştır. Çıkış verisini etkileyen birden fazla parametre mevcut olduğundan dolayı geri besleme gecikmesine sahip çok katmanlı bir YSA modeli kurulmuştur. Doğru aktivasyon tercihi ile doğrusal olmayan ilişkilerde çok katmanlı ağlar yardımıyla kolaylıkla çözümlenebilir. Çalışmada da bir gizli katmana sahip çok katmanlı bir model kullanılmıştır. YSA'ya veriler arası ilişkiyi çözümlenemeyebilmesi için herhangi bir ön bilgi sunulmasına gerek yoktur. Bu da YSA'nın avantajları arasında sayılabilir. YSA'da bulunan nöronlarda bir bozukluk meydana gelse bile herhangi bir veri kaybı yaşanmamaktadır. Bu da YSA modellerinin esnekliğini göstermektedir. Bu yüzden modellemelerden, problemin çözümü için başarılı sonuçlar alınmıştır. Akış tahmini için zaman serisi analizi kullanılmıştır. Tahmin modellerinin sonuçları, hata kareler ortalaması MSE ve R^2 belirlilik katsayıları dikkate alınarak değerlendirilmiştir. MSE'nin sıfıra yakınlığı R^2 'nin ise 1 yakınlığı değerlendirme ölçütü olarak dikkate alınmıştır. Elde edilen sonuçlar:

- Problem çözümü için tek katmanlı ağ yetersiz kalmıştır ve çok katmanlı ağ tasarlanmıştır.
- LM öğrenme algoritmasının akış tahmini problemi için Bayesian Regularization, Scaled Conjugate Gradient algoritmalarına göre hatayı minimize etmede daha iyi olduğu sonucuna varılmıştır.
- Zaman serisi analizine dayanan NARX modeli ile problem çözümlenmiştir. Sonuçlar Radyal tabanlı ağ modeliyle karşılaştırılmıştır. NARX modelinden elde edilen MSE, Radyal tabanlı YSA modeli ile karşılaştırılmıştır. NARX 'in daha az iterasyonla daha az nöron sayısı kullanılarak aynı hata düzeyine ulaştığı tespit edilmiştir.
- Problemin çözümü için gerekli gizli katman sayısı deneme yanılma yolu ile 1 olarak tespit edilmiştir. Neticede çözümde 3 katmanlı ağ yeterli olmuştur
- Gizli katmanda bulunması gereken nöron sayısı en iyi performans kriterine göre 50 olarak belirlenmiştir

- Eğitim verileri için öğrenme de %96'lık başarı sağlanarak test verilerine ise %90 doğru cevap alınmıştır. Hata kareler ortalamasının da sifıra yakın olduğu sonucuna ulaşılmıştır.
- Geri besleme gecikmesine sahip dinamik ağ tabanlı NARX modelinin akış tahmini olumlu sonuçlar üretebileceği kanısına varılmıştır.
- Radyal Tabanlı ve NARX modellerinde nöron sayısı artırıldığında, hata kareler ortalaması (MSE)'nin azaldığı görülmüştür.

Gelecekteki çalışmalar açısından verilerin depolanması büyük önem taşımaktadır;

- Zaman serisine dayanan modelin daha fazla veri seti olduğunda daha iyi öğrenme sağlayacağına ve tutarlı sonuçlar üretebileceğine kanaat getirilmiştir. Bu yüzden veri depolama merkezlerinin bu konuda gereken hassasiyeti göstermeleri gerekmektedir.
- Yağış ve akış konusunda yapılacak olan çalışmalar havza yönetimi, baraj yönetimi, iklim değişikliği ile de ilişkilendirilip daha farklı çalışmalar da ortaya konulabilir.
- YSA öğrenme algoritmaları üzerinde yapılacak çalışmalarla hemen hemen bütün hidrolojik problemlerin çözümü için daha fazla kullanım alanına sahip olabilir. Gerek diğer hidrolojik problemler için, gerekse akış tahmini için NARX modeli ideal bir çözümleyicidir.
- NARX modeli su kaynakları mühendisliğince tespit edilen farklı problemlerin çözümü içinde kullanılabilceği ve farklı problemlerde de denenmesi önerilmektedir.

KAYNAKLAR

- [1] Hamzaçebi C., *Yapay Sinir Ağları Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı Yapay Sinir Ağları*, 1. Baskı, Ekin Yayınevi Yayıncılık, Bursa, 2011.
- [2] Hopfield J., Neural Networks and Physical Systems with Emergent Collective Computational Abilities, *Proceedings of the National Academy of Sciences*, 1982, **7**, 2554–2558.
- [3] Rumelhart D., McClelland J., *Parallel Distributed Processing*, 1st ed., MIT Press, Cambridge, 1986.
- [4] Broomhead D. S., Lowe D., Multi-Variable Functional Interpolation and Adaptive Networks, *Complex Systems*, 1988, **2**, 327-355.
- [5] Alp M. ve Cıgızoğlu H.K. Farklı yapay sinir ağı metodları ile yağış-akış ilişkisinin modellenmesi, *İTÜ dergisi*, 2004, **3**(1), 80-88.
- [6] Yerdelen C., Mevsimlik kar erimesinin yapay sinir ağları yöntemi ile tahmin edilmesi, *S.Ü Müh.-Mim. Fak. Dergisi*, 2006, **21**, 3-4.
- [7] Öcal O., Yapay Sinir Ağları Algoritması Kullanılarak Havzalarda Yağış-Akış-Katı Madde İlişkisinin Belirlenmesi, Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli, 2007, 200807.
- [8] Özdemir H., SCS CN Yağış-Akış Modelinin CBS ve Uzaktan Algılama Yöntemleriyle Uygulanması: Havran Çayı Havzası Örneği(Balıkesir), *Coğrafi Bilimler Dergisi*, 2007, **5**(2), 1-12.
- [9] Yurdusev M.A., Acı M., Turan M.E., İçağa Y., Akarçay Nehri Aylık Akımlarının Yapay Sinir Ağları ile Tahmini, *C.B.Ü Fen Bilimleri Dergisi*, 2008, **4**(1), 73-88.
- [10] Partal T., Kahya E., Cıgızoğlu K., Yağış verilerinin yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini, *İTÜ dergisi*, 2008, **7**(3), 73-85.
- [11] Dahamsheh A., Aksoy H., Kurak bölge aylık yağışlarının Markov zinciri eklenmiş koşullu ileri beslemeli geri yayılım yapay sinir ağları ile tahmini, *İTÜ dergisi*, 2009, **8**(6), 37-48.
- [12] Okkan U., Mollamahmutoğlu A., Çoruh Nehri Günlük Akımlarının Yapay Sinir Ağları ile Tahmin Edilmesi, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 2010, **14**(3), 251-261.

- [13] Yarar A., Susurluk Havzası Yağış Akış Verilerinin Modellenmesi, Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya, 2010, 276336.
- [14] Saplıoğlu K., Çimen M., Yapay Sinir Ağlarını Kullanarak Günlük Yağış Miktarının Tahmini, *Mühendislik Bilimleri ve Tasarım Dergisi*, 2010, **1**(1), 14-21.
- [15] Can M., Yapay Sinir Ağları ile Akım Tahmini: Mahmudiye Göleti Örneği, Yüksek Lisans Tezi, İstanbul Kültür Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2012, 320796.
- [16] Gümüş V., Soydan N.G., Şimşek O., Aköz M.S., Kırkgöz M.S., Yağış-Akış İlişkisinin Belirlenmesinde Farklı Yapay Sinir Ağı Yöntemlerinin Karşılaştırılması, *Çukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 2013, **28**(1), 37-49.
- [17] Yüksek Ö., Babacan H.S., Saka F., Yağış-Akış Modellemesinde Optimum Yapay Sinir Ağı Yapısının Araştırılması, *Türk Hidrolik Dergisi*, 2018, **2**(1), 31-37.
- [18] Doğan A., Opan M., Namazgah Barajına Ait Eksik Su Kalite Değerlerinin Yapay Sinir Ağları Yöntemi ile Tahmin Edilmesi, 3. *Uluslararası Mühendislik Mimarlık ve Tasarım Kongresi*, Kocaeli, Türkiye, 4-5 Mayıs 2018.
- [19] Doğan A., Opan M., Namazgah Barajına Ait Buharlaşma Miktarının Yapay Sinir Ağı ile modellenmesi, 4. *Uluslararası Mühendislik Mimarlık ve Tasarım Kongresi*, İstanbul, Türkiye, 23-24 Nisan 2019.
- [20] <https://www.mehmettanselyildiz.com/l/sinir-hucresinin-yapisi-ve-aksonlar/> (Ziyaret Tarihi: 7 Mayıs 2019)
- [21] Öztemel E., *Yapay Sinir Ağları*, 4. Baskı, Papatya Yayıncılık Eğitim, İstanbul, 2016.
- [22] <https://www.medium.com/2019.4.14/aktivasyonfonksiyonlari> (Ziyaret tarihi: 7 Mayıs 2019).
- [23] <https://industryolog.com/matlab-egitimleri-4-artis-duzenleme/> (Ziyaret tarihi: 7 Mayıs 2019).
- [24] Akpınar H., *Yapay Sinir Ağları ve Kredi Taleplerinin Değerlendirilmesinde Bir Uygulama Önerisi*, 1. Baskı, İstanbul Üniversitesi İşletme Fakültesi Sayısal Yöntemler Ana Bilim Dalı, İstanbul, 1993.
- [25] <https://bilimfili.com/dunyayi-degistirmekte-olan-yapay-sinir-aglari-nedir/> (Ziyaret Tarihi: 8 Mayıs 2019).
- [26] <http://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/> (Ziyaret Tarihi: 8 Mayıs 2019).

- [27] MATLAB, *MATLAB Documentation Neural Network Toolbox Help, Version 7.0*, Release 14, The MathWorks Inc., 2004.



KİŞİSEL YAYIN VE ESERLER

Akgün A.R., Opan M., Dođan A., Namazgah Barajında Meteorolojik Veriler Kullanılarak Yapay Sinir Ağları İle Akışın Tahmin Edilmesi, *4. Uluslararası Mühendislik Mimarlık ve Tasarım Kongresi*, İstanbul, Türkiye, 23-24 Nisan 2019.



ÖZGEÇMİŞ

Ahmet Raşit Akgün 1994 yılında İzmit'te doğdu. İlköğretimini Derince Cumhuriyet İlköğretim Okulu'nda lise eğitimini 2012 yılında Kocaeli Anadolu Lisesi'nde tamamladı. Aynı yıl Namık Kemal Üniversitesi Çorlu Mühendislik Fakültesi İnşaat Mühendisliği bölümünde öğrenim hayatına başladı ve 2016 yılında mezun olarak İnşaat Mühendisi unvanını aldı. 2017 yılında Kocaeli Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalında Yüksek Lisans programına başladı.

