

**KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**NAMAZGÂH BARAJINA AİT BUHARLAŞMA MİKTARININ
YAPAY SİNİR AĞI İLE TAHMİN EDİLMESİ**

AYŞE DOĞAN

KOCAELİ 2019

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

NAMAZGAH BARAJINA AİT BUHARLAŞMA MİKTARININ
YAPAY SINIR AĞI İLE TAHMİN EDİLMESİ

AYŞE DOĞAN

Prof. Dr. Mücahit OPAN
Danışman, Kocaeli Üniversitesi

Prof. Dr. Emrah DOĞAN
Jüri Üyesi, Sakarya Üniversitesi

Doç.Dr. Utkan MUTMAN
Jüri Üyesi, Kocaeli Üniversitesi





Tezin Savunulduğu Tarih: 03.05.2019

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışması Namazgâh Barajına ait buharlaşma miktarının yapay sinir ağı yöntemiyle tahmin edilmesi üzerinedir. Yapılan çalışma da birinci aşama da yapay sinir ağı yöntemi ile (YSA) eksik veriler tamamlanırken, ikinci aşama da buharlaşma miktarı tahmini için YSA'da Nonlinear-Autoregressive-with External (NARX) bir model kurulmuştur.

Amaç barajda meydana gelecek buharlaşmanın tahmini için basit bir YSA modeli tasarlamaktır.

Yapay sinir ağları konusunda bana çalışma fırsatı tanıyan, çalışmalarına yön vererek desteğini benden esirgemeyen danışmanım Prof. Dr. Mücahit OPAN'a sonsuz teşekkürlerimi sunarım.

Hayatım boyunca beni destekleyen başta annem ve abilerim olmak üzere bütün aileme sonsuz teşekkürlerimi sunarım.

Ayrıca bugün yaptığımız bütün çalışmalarını gönül rahatlığı ile sunabilmeyi borçlu olduğumuz bütün şehit ve gazilerimize sonsuz minnet duygularımı ve teşekkürlerimi arz ederim.

Nisan – 2019

Ayşe DOĞAN

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	3
1.1. Sebep- Sonuç İlişkinine Bağlı Tahmin Modelleri	3
1.2. Zaman Serisi Analizine Dayanan Tahmin Yöntemleri	3
2. LİTERATÜR TARAMASI	5
2.1. Yapay Sinir Ağları.....	5
3. MATERYAL VE YÖNTEM.....	9
3.1. Yapay Sinir Ağları.....	9
3.1.1. Biyolojik sinir hücresi	10
3.1.2. Yapay sinir hücresi.....	10
3.1.3. Toplama fonksiyonları	13
3.1.4. Aktivasyon fonksiyonları	14
3.1.4.1. Step fonksiyonu.....	14
3.1.4.2. Doğrusal (Linear) fonksiyon.....	15
3.1.4.3. Sigmoid fonksiyonu	16
3.1.4.4. Sinüs fonksiyonu	17
3.1.4.5. Hiperbolik tanjant fonksiyonu	18
3.1.4.6. Logaritmik aktivasyon fonksiyonu.....	18
3.2. Yapay Sinir Ağı Yapısı.....	20
3.3. Yapay Sinir Ağlarında Öğrenme	23
3.3.1. Danışmanlı öğrenme	25
3.3.2. Danışmansız öğrenme	25
3.3.3. Destekleyici öğrenme	25
3.4. Çok Katmanlı Yapay Sinir Ağlarında Öğrenme Algoritması.....	25
3.4.1. Geri yayılım algoritması.....	25
3.4.2. Çıktı katmanında ağırlık güncellemesi.....	27
3.4.3. Öğrenme hızı ve momentum katsayısı	31
3.4.4. Çalışmada kullanılan öğrenme algoritması	32
3.5. Yapay Sinir Ağı Mimarileri	32
3.5.1. Geri beslemeli yapay sinir ağı (GBYSA).....	32
3.5.2. İleri beslemeli yapay sinir ağı	33
3.5.3. Radyal tabanlı yapay sinir ağı (RTYSA)	34
3.6. Zaman Serileri.....	35
3.6.1. Yapay sinir ağlarında zaman serileri.....	35
3.6.2. Doğrusal olmayan otoregresif (Nonlinear Autoregressive).....	36
3.6.3. Doğrusal olmayan otoregresif eksojen (Nonlinear Autoregressive Exogenous)	36

4. ÇALIŞMA ALANI VE YERİ	38
4.1. Kocaeli İli Kandıra İlçesinde Bulunan Namazgâh Barajı.....	38
4.2. Çalışma Alanına Ait Veriler	39
4.3. Eksik Veriler İçin YSA Tahmin Senaryoları	40
4.3.1. Giriş değişkenlerinin belirlenmesi	41
4.3.2. Eldeki verilerin değerlendirilmesi.....	41
4.3.3. Veri gruplarının oluşturulması.....	42
4.3.4. Verilerin programa uygun hale getirilmesi.....	43
4.3.5. Modelin belirlenmesi.....	45
4.3.6. Kurulan YSA'nın eğitimi, test edilmesi ve simule edilmesi	46
4.3.7. Eksik verilerin tamamlanması	49
4.3.8. Buharlaştırma tahmini için kurulan yapay sinir ağı modelleri.....	51
5. SONUÇLAR VE ÖNERİLER.....	56
KAYNAKLAR.....	58
ÖZGEÇMİŞ.....	61



ŞEKİLLER DİZİNİ

Şekil 3.1.	Gerçek nöron hücresinin yapısı.....	10
Şekil 3.2.	Yapay sinir hücresinin yapısı.....	12
Şekil 3.3.	Step fonksiyonunun yapısı.....	15
Şekil 3.4.	Doğrusal fonksiyonun grafiği.....	15
Şekil 3.5.	Sigmoid fonksiyonunun grafiği.....	17
Şekil 3.6.	Sinüs fonksiyonunun grafiği.....	17
Şekil 3.7.	Hiperbolik tanjant fonksiyonu grafiği.....	18
Şekil 3.8.	Logaritmik aktivasyon fonksiyonu grafiği.....	19
Şekil 3.9.	Yapay sinir ağının yapısı.....	20
Şekil 3.10.	Tek katmanlı yapay sinir ağının yapısı.....	22
Şekil 3.11.	Çok katmanlı yapay sinir ağının yapısı.....	22
Şekil 3.12.	Geri beslemeli yapay sinir ağının yapısı.....	23
Şekil 3.13.	Geri beslemeli ağ modeli örneği.....	33
Şekil 3.14.	İleri beslemeli yapay sinir ağının yapısı.....	34
Şekil 3.15.	Radyal tabanlı yapay sinir ağ yapısı.....	34
Şekil 3.16.	Seriye bağlı NARX modeli mimarisi.....	37
Şekil 3.17.	Dışsal girişli NARX modeli mimarisi.....	37
Şekil 4.1.	Namazgâh Barajı'nın uydu görüntüsü.....	39
Şekil 4.2.	Tahminde kullanılan girdi veri gruplarının boyutsuz hali.....	45
Şekil 4.3.	Tahminde kullanılan çıkış veri gruplarının boyutsuz hali.....	45
Şekil 4.4.	Tasarlanan çok katmanlı ağ mimarisi.....	47
Şekil 4.5.	Model davranışı grafiği.....	48
Şekil 4.6.	Deneysel hata düzeyi grafiği.....	48
Şekil 4.7.	Modelin tahmini ve gerçekleşen buhar basıncı karşılaştırma grafiği.....	49
Şekil 4.8.	İBGYYSA ile tahmin edilen buhar basıncı ve gerçekleşen buhar basıncı grafiği.....	49
Şekil 4.9.	Ağın model davranışı performans değeri.....	50
Şekil 4.10.	Deneysel hata grafiği.....	50
Şekil 4.11.	2016 yılına ait İBGYYSA ile tahmin edilen 82 günlük buhar basıncı değerleri grafiği.....	51
Şekil 4.12.	Modelde kullanılan girdi ve çıktı veri gruplarının normalize değerleri.....	52
Şekil 4.13.	Buharlaşma tahmini için en iyi performansı veren modelin mimarisi.....	54
Şekil 4.14.	Günlük buharlaşma tahmini için en iyi performansı veren modelin çıktısı ve hedef değer grafiği.....	55
Şekil 4.15.	Buharlaşma tahmini için en iyi performansı veren modelin deneysel hata grafiği.....	55

TABLolar DİZİNİ

Tablo 3.1. Toplama fonksiyonları.....	14
Tablo 3.2. Aktivasyon fonksiyonu örnekleri	19
Tablo 4.1. Tahminde kullanılacak Kocaeli Meteoroloji Müdürlüğü AĞİ verilerinin yapısı.....	40
Tablo 4.2. Tahminde kullanılacak buharlaşma verilerinin yapısı.....	40
Tablo 4.3. Verilere ait genel şema.....	42
Tablo 4.4. 2017 verileri için tasarlanan ağıın eğitim parametreleri	47
Tablo 4.5. Bayesian Regularization öğrenme algoritmasıyla elde edilen sonuçlar	53
Tablo 4.6. Scaled Conjugate Gradient öğrenme algoritmasıyla elde edilen sonuçlar	53
Tablo 4.7. Levenberg- Marquardt öğrenme algoritmasıyla elde edilen sonuçları.....	53
Tablo 4.8. YSA tahmin modellerinden alınan sonuçlar	54

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 eğitim değeri
θ_k^{\ominus}	: Eğitim değerini
∂	: Eşik değeri
A	: Ağırlıklar
E	: Hata değeri
$f_{(\text{net})}$: Aktivasyon fonksiyonu işlevi
G	: Girdiler
h	: 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 Yayınımı Yapay Sinir Ağı
İSU	: İzmit Su ve Kanalizasyon İdaresi
LM	: Levenberg Marquardt
MLP	: Multilayer Perceptrons (Çok Katmanlı Algılayıcı)
MSE	: Mean Square Error (Hata Kareler Ortalaması)
NAR	: Nonlinear Autoregressive (Doğrusal Olmayan Otoresif)
NARX	: Nonlinear Autoregressive Exogenous (Doğrusal Olmayan Otoresif Eksojen)
PM	: Penman Yöntemleriyle
RTYSA	: Radyal Temelli Yapay Sinir ağı
YSA	: Yapay Sinir Ağı
YSH	: Yapay Sinir Hücresi

NAMAZGÂH BARAJINA AİT BUHARLAŞMA MİKTARININ YAPAY SİNİR AĞI İLE TAHMİN EDİLMESİ

ÖZET

Suyun kontrolü açısından ve susuzluktan dolayı meydana gelecek hayati problemlerin çözümü için buharlaşma önemli bir faktördür. Göllerde, göletlerde ve barajlarda meydana gelen buharlaşma pek çok değişkene bağlı olduğundan modellenebilirlik açısından bu tür problemleri çözümlenmek güç olmaktadır. Bu çalışmada birinci aşama da İleri Beslemeli Geri Yayılımlı Yapay Sinir Ağı(İBGYYSA) modeliyle eksik veriler tamamlanırken, ikinci aşama da buharlaşma tahmini için zaman serisi analiziyle basit bir YSA modeli kurulmuştur. Modelleme de minimum sıcaklık, ortalama sıcaklık, rüzgâr şiddeti ve buhar basıncı girdi verisi olarak değerlendirilirken, buharlaşma miktarı çıktı olarak ele alınmıştır. Girdi ve çıktı olarak kullanılan bu hidrometeorolojik veriler arası ilişki doğrusal olmadığı için problem çözümünde çok katmanlı bir ağ modeli tercih edilmiştir. Tasarlanan çok katmanlı ağda kullanılan aktivasyon fonksiyonuna uygunluk açısından veriler normalizasyon işlemi ile Matrix Laboratory(MATLAB) programına uygun hale getirilmiştir. Çok katmanlı ağ için kullanılacak öğrenme algoritması belirlenirken üç algoritma içinde aynı nöron sayıları denenerek modellenmeler yapılmıştır. Sırasıyla Levenberg-Marquardt(LM), Bayesian Regularization, Scaled Conjugate Gradient öğrenme algoritmalarından problem karşısında en iyi performansı öğrenme algoritmasının diğer algoritmalara oranla daha iyi performans sergilediği tespit edilmiştir. Modelde gizli katmanda bulunması gereken nöron sayısı deneme yanılma ile belirlenirken, hatayı minimize etmede probleme uyarlandığında diğer öğrenme algoritmalarına oranla daha iyi sonuç alındığı için problemde LM öğrenme algoritması kullanılmıştır. En iyi model belirlenirken hata düzeyi için Mean Square Error (MSE-Hata Kareler Ortalaması) ve Belirlilik R^2 katsayıları dikkate alınmıştır. Sonuç olarak zaman serisi analiziyle buharlaşma miktarı tahmini için NARX modeliyle LM öğrenme algoritması kullanılarak probleme çözüm bulunmuştur.

Anahtar Kelimeler: Buharlaşma Tahmini, Eksik Veri Tahmini, Namazgâh Barajı, Yapay Sinir Ağları.

ESTIMATION OF THE VAPORIZATION AMOUNT OF NAMAZGÂH RESERVOIR BY ARTIFICIAL NEURAL NETWORK

ABSTRACT

Evaporation is an important factor for solving the vital problems that will occur due to the control of water and water. As evaporation in lakes, ponds and dams is dependent on many variables, it is difficult to analyze such problems in terms of modeling. In this study, while the missing data were completed with a feed-backed artificial neural network model in the first stage, in the second stage a simple ANN model was established by time series analysis for the evaporation estimation. While modeling, minimum temperature, average temperature, wind strength and vapor pressure are considered as input data, the amount of evaporation is considered as output. Since the relationship between these hydrometeorological data is not linear and used as input and output, a multi-layered network model is preferred in problem solving. For the purpose of conformity to the activation function used in the multi-layer network, the data were adapted to the MATLAB program by the normalization process. While determining the learning algorithm to be used for multi-layer network, the same neuron numbers were tried and modeled in three algorithms. LM, Bayesian Regularization, Scaled Conjugate Gradient learning algorithms were found to perform better than other algorithms LM learning algorithm. While the number of neurons that should be present in the hidden layer in the model was determined by trial and error, the problem was used by the LM learning algorithm because it was better than other learning algorithms. When determining the best model, MSE and R^2 coefficients were taken into account for error level. As a result, with the NARX model, a solution was found to the problem by using the LM learning algorithm to estimate the amount of evaporation by time series analysis.

Keywords: Evaporation Estimation, Missing Data Estimation, Namazgâh Reservoir, Artificial Neural Networks.

GİRİŞ

Akarsular üzerinde enerji üretimi, içme ve kullanma suyu, taşkın kontrolü başta olmak üzere birçok amaç göz önünde bulundurularak barajlar inşa edilmektedir. Gerek barajlarda olsun gerekse göl ve göletlerde olsun buharlaşma miktarı önemli bir faktör olmaya devam etmektedir. Buralarda meydana gelen buharlaşma temelde hidrometeorolojik faktörlerin bir bileşkesi olarak kabul edilebilir. Yüzey alanı ve derinlik buharlaşma miktarında önemli bir faktör olmakla birlikte mevcut enerji ve gerçekleşen enerji transferi buharlaşma üzerindeki diğer etkenlerdir. Hayati öneme sahip su ihtiyacının göllerden, göletlerden ya da barajlardan karşılanması buharlaşma miktarının tahminini de bir o kadar önemli kılmaktadır. Gerçekleşen buharlaşma miktarını tahmin etmek için buharlaşma tavaları ve meteorolojik verilere dayanan yöntemler kullanılmaktadır. Buharlaşmaya sebep olan faktörler arası doğrusal olmayan bir ilişki mevcut olduğu için buharlaşma tahmini için genelleştirilmiş tek formül kullanmak mümkün değildir. Bu yüzden farklı çözüm teknikleri üzerine çalışmalar devam etmektedir ki bunlardan biri de son yıllarda çeşitli problem çözümleri için hızlı kullanılmakta olan YSA olmuştur. YSA günlük yaşamın hemen hemen her alanına uygulanmaya devam etmektedir. Hidrolojik çevrim dahilinde olan pek çok problemin çözümünde kullanılan YSA, buharlaşma tahmini içinde son çalışmalarla tatminkar sonuçlar vermiştir. Doğrusal olmayan ilişkileri çözmekte oldukça başarılı olan çok katmanlı yapay sinir ağları en çok tercih edilenler arasında yerini almaktadır. YSA kullandığı aktivasyon fonksiyonu sayesinde karmaşık olan veriler arası ilişkiyi çözmekte oldukça başarılıdır. Bu çalışma da zaman serisi analizi yardımıyla NARX bir modelle Namazgâh Barajına ait buharlaşma miktarı tahmini YSA ile modellenmiştir.

Ağın öğrenmeyi sağlayabilmesi için yeterli eğitim verisi olması gerekmektedir. Aksi takdirde öğrenme sağlanamamaktadır. Veri setinin yanında kullanılacak eğitim parametreleri de öğrenme için büyük önem arz etmektedir. Bu çalışma kapsamında kullanılan Namazgâh Barajına ait buharlaşma verileri Kocaeli İSU Genel Müdürlüğü'nden alınırken, minimum sıcaklık, ortalama sıcaklık, rüzgâr şiddeti ve su

buharı basıncı veriler ise Tarım ve Orman Bakanlığı Kocaeli Meteoroloji Genel Müdürlüğü'nden alınmıştır.

Tez çalışması genel olarak giriş, literatür taraması, kullanılan materyal ve yöntem, uygulama ve sonuçlar kısmından oluşmaktadır.

Bu çalışma da toplam da 1540 veri ile işlem yapılırken veriler eğitim, test ve onaylama verisi olarak sınıflandırılmıştır. Sınıflandırma işleminden önce veriler kullanılacak aktivasyon fonksiyonuna uyarlanabilmesi için normalizasyon işlemiyle MATLAB programına uygun hale getirilmiştir [1]. Normalize işleminin yapılmasının en temel sebebi veri seti içinde uç değerlerin mevcudiyetinin olmasıdır. Amaç bu uç değerlerin veri seti dağılımındaki etkisini en aza indirmektir.

Modelde giriş verisi olarak minimum sıcaklık, ortalama sıcaklık, su buharı basıncı ve rüzgâr şiddeti giriş verisi olarak ele alınırken, çıkış olarak buharlaşma miktarı verilmiştir. İBGYYSA modeli kullanılarak mevcut veriler yardımıyla eksik buhar basıncı verileri tamamlanmıştır. Eksik buhar basıncı değerleri için YSA modeli tasarlanırken minimum ve ortalama sıcaklık giriş verisi olarak ağa verilir çıkışa buhar basıncı verilmiştir. Gizli katman veriler arası ilişkiyi çözüleme de ve eğitim performansını yükseltme açısından oldukça iyi olduğundan dolayı ağ tarafından veriler arası ilişki kolayca çözümlenmiştir. Çalışmanın ikinci aşamasında ise buharlaşma tahmini için çok katmanlı ağ modelleri kurulmuştur. Gizli katmanda bulunması gereken nöron sayısına deneme yanılma yoluyla karar verilmiştir. En iyi sonucu veren model belirlenirken hata düzeyi için MSE ve R^2 katsayıları dikkate alınmıştır. MSE'nin sıfıra yakınlığı ve R^2 'nin 1'e yakınlığı değerlendirme ölçütü olmuştur.

Kurulan model sonucunda zaman serisi analizi ile NARX modelinin buharlaşma miktarı tahminin de yeterli veri olması durumunda oldukça iyi sonuçlar üreteceği sonucuna varılmıştır.

1. TAHMİN YÖNTEMLERİ

Eldeki verilere dayanarak olaylar hakkında tahmin yapmak mümkün olabilmektedir. Kişiyeye özgü tahminlerde aynı verisi kümesi için farklı tahminler yapılabilmektedir.

Fakat sayısal bilgiye dayanan tahminlerde matematiksel modelleme teknikleri devreye girdiği için aynı durum burada söz konusu değildir. Bu tahmin yöntemlerinin temelinde mevcut veriye ait sayısal dokümana bakılarak gelecekte de bu sürecin hemen hemen böyle işleyeceği kabul edilmektedir. Geçmiş dönem verileri kullanılarak işleyen süreç çözümlenir ve ilerleyen zamanda bu süreç hakkında bir takım tespitler yapılır.

Bu tür tahminlerin tutarlı olabilmesi için baz alınan yaklaşımlar sebep sonuç ilişkisi ve zaman serisi analizlerine bağılı iki temel yaklaşımdır.

1.1. Sebep- Sonuç İlişkisine Bağılı Tahmin Modelleri

Sebep sonuç ilişkisine dayanan yaklaşımda sırasıyla açıklayan ve açıklanan olmak üzere iki temel değişken mevcuttur. Regresyon tekniğı bağımlı ve bağımsız değişken arasındaki ilişkiyi çözmeye çalışılırken sebep sonuç ilişkisine dayanan tahminlerin matematiksel modeline uygun örneklerden birini teşkil etmektedir. Bu tür tahminler geçmiş döneme ait verilerden yola çıkarak veriler arası ilişkiyi çözmeye yoluyla geleceğe dair verilerin nasıl değişkenlik göstereceğı hususunda fikir vermektedir ancak 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 analizleriyle zamana göre sıralanmış değişkene ait veriler kullanılarak geleceğe dair tahminlerde bulunulabilmektedir. Zaman serisinde seriye ait doğru model seçimi ve buna uygun doğru parametre tercihi olayın çözümlenmesi açısından büyük önem taşımaktadır.

Zaman serisi analizlerine dayalı tahminler için son zamanlarda doğrusal olmayan ilişkileri çözmeye yarayan pek çok model geliştirilmiştir. Fakat gelenekselleşmiş modellere göre daha esnek olan tekniklere yönelik araştırmalar devam etmiştir. Bu tekniklerden biri de YSA modelleridir [1].



2. LİTERATÜR TARAMASI

2.1. Yapay Sinir Ağları

Çalışma da çok katmanlı bir yapay sinir ağı tercih edilmiştir. Dolayısıyla John Hopfield'in çalışması ve çok katmanlı ağlar üzerine geliştirilen Geri Yayılım Öğrenme Algoritmaları çalışmanın temelini oluşturmaktadır.

Hopfield, National Academy of Science'a sunduğu çalışmasında sinir ağlarının matematiksel analizle çalışma aşamalarını ele almıştır [2].

Rumelhart ve arkadaşları YSA'yı sağlam bir matematik temeline dayandırmakta başarılı çalışmalar yapmışlardır [3].

Broomhead ve Lowe, Radyal Tabanlı Fonksiyon Ağları üzerine çalışmalar yapmışlardır. Yapılan bu çalışmayla sayısal analiz ile sinir ağları arasında yakın bir ilişki kurulmaya başlanmıştır. Bu ilişkiyi izah eden temel varsayım aşağıda kısaca özetlenmektedir [4].

Bilgi alma sürecini ilgili sinir hücrelerinde bulunan nöronlar vasıtasıyla başlatılmaktadır.

Bilgi işlevi nöronlar arası ağırlıklarla sağlanmaktadır.

Her bir bağlantının sahip olduğu bir ağırlık değeri mevcuttur.

Nöron çıktısı, ait olduğu net girdisinin aktivasyon fonksiyonundan geçirilmesiyle dış dünyaya sunulur.

Gruplandırılmış sinir hücreleri birbiriyle bağlantılı olan katmanları meydana getirmektedir. Aynı katman da bulunan nöronların işlevleri benzerdir.

1980'lerden günümüze YSA konusunda pek çok makale yazılmakla birlikte çalışmalar gün geçtikçe hız kazanmaktadır ve YSA pek çok farklı alana da

uygulanmaya devam etmektedir. Bu alanlardan biri de su kaynakları mühendisliğidir. Günümüz de bu alanda sayısızca makale bulmak mümkündür.

Jensen ve diğ. Ekinlerin Evapotransporasyonunu (ET) tahmin etmek için Penman-Monteith (PM) yöntemine ve A sınıfı tava buharlaşmasına dayanarak, Meksika'daki İklim Normlarına (1941-1970) dâhil olan 60 hava gözlem evinden gelen bilgileri kullanarak "Kp tava buharlaştırma ve ET aylık haritalarını" tahmin etme yöntemiyle başarılı bir çalışma sergilemişlerdir [5].

Burman ve Pochop yaptıkları çalışma ile su kaynaklarından buharlaşma ve bitkilerden yayılan buharlaşma tahmini sorununu ele almışlardır. Bitkisel üretim ile ET arası ilişki analiz edilmeye çalışılarak, doğrudan terlemenin tahmin edilmesi ve referans ürün ET hesaplanmasında çözüm yolu başarıyla ortaya koymuşlardır [6].

Abtew ve diğ. tarafından Amerika Birleşik Devletleri'nde bulunan, Subtropikal Güney Florida'da bulunan Okeechobee Gölüne ait beş yıllık meteorolojik veri (1993-1997) analizlerde kullanılarak ortalama yıllık buharlaşma 132 cm olarak bulunmuştur [29]. Bu çalışma ile geliştirilen basit modeller, güneş ışığından veya maksimum hava sıcaklığından günlük göl buharlaşmasını tahmin etmek için önerilmektedir. Su yönetimi amacıyla günlük göl buharlaşma tahminini sağlamadaki uygulanabilirliklerini karşılaştırmak için yedi buharlaşma tahmin yöntemi değerlendirilmiştir. Yapılan analizlerle Okeechobee Gölü çevresindeki yedi tava buharlaşma istasyonu için aylık tava katsayıları ve yıllık ortalama tava katsayıları başarıyla üretilmiştir.

Doğan ve diğ., İBGYYSA ve Radyal Temelli Yapay Sinir Ağı (RTYSA) modeli kullanarak, YSA'da Sapanca Gölü için günlük buharlaşma miktarı tahminini yapmakla birlikte PM modeli ile karşılaştırmışlardır. Değişken olarak minimum ve maksimum sıcaklık, rüzgâr hızı, göreceli nem, gerçek güneşlenme süresine bağlı olarak buharlaşma için İBGYYSA ve RTYSA modelleri uygulanmıştır. İBGYYSA yöntemiyle ölçülen günlük buharlaşma miktarının gerçeğe daha yakın olduğu tespitinde bulunulmuştur [7].

Üneş ve diğ., çalışmalarında Tahtaköprü barajındaki aylık buharlaşma miktarının tahminini YSA metodu kullanılarak araştırmışlardır. Baraj haznesi aylık buharlaşma

miktarının tahmininde kullanılan YSA modellerinin klasik yöntemlerle kıyaslandığında daha iyi bir yaklaşım verdiği sonucuna ulaşılmıştır [8].

Singh ve diğ., Hindistan'da Madhya Pradesh'in Malwa bölgeleri için çoklu doğrusal regresyon modeli, Çok Katmanlı Algılayıcı (MLP) ve YSA modelini kullanarak haftalık buharlaşma simülasyonunu incelemeye çalışılmışlardır. Çalışmalarında nöral ağ modelini eğitmek için farklı hava değişkenlerinin dört kombinasyonu kullanılmışlardır. Çoklu doğrusal regresyon modeli, girdi olarak yalnızca maksimum sıcaklığı ve bağıl nemi içerir ancak simülasyon sonucu tatmin edici çıkmamıştır, MLP modeli, antrenman sırasındaki minimum ve maksimum sıcaklık, rüzgar hızı ve bağıl nemden ve ayrıca geçerlilik sürelerinden oluşan veriler için oldukça iyi performans göstermiştir. MLP modelinin haftalık açık tava buharlaşmasını simüle etmek, eksik verileri tahmin etmek ve gözlenen buharlaşma verilerini kontrol etmek için alternatif bir model olarak kullanılabilmesi sonucuna ulaşılmıştır. Yağış verilerinin meteorolojik değişkenlere dâhil edilmesinin, modelin performansını iyileştirmediğine dikkat çekmişlerdir [9].

Gümüş ve arkadaşları, çalışmalarında aylık ortalama buharlaşma tahminini elde etmek için YSA, Bulanık Mantık Yapay Sinir Ağı (ANFIS) ve Gen Ekspresyon Programlama (GEP) yöntemleri kullanılmışlardır [10]. Aylık ortalama sıcaklık (Co), nem (%), rüzgâr hızı (m/s), basınç (hPa), güneşlenme şiddeti (cal / cm^2) ve güneşlenme süresi (saat) iklimsel verilerini kullanarak, Adana istasyonundaki aylık ortalama buharlaşma tahmin edilmiştir. Farklı girdi parametreleri kombinasyonları oluşturularak, YSA, ANFIS ve GEP metotları kullanılarak elde edilen sonuçlar karşılaştırılmış ve elde edilen sonuçlar neticesinde, kullanılan tüm metotların buharlaşma tahmininin kabul edilebilir derecede başarılı olduğu ancak ANFIS metodunda 6 girdili kombinasyonun, oluşturulan tüm modeller içerisinde en başarılı sonucu verdiği sonucuna ulaşılmıştır.

Aksu, tarafından yapılan çalışmada uzun zaman gerektiren birçok meteorolojik girdi yerine, bu girdileri şekillendiren doğal veriler ve daha az meteorolojik veri kullanılarak Evapotransporasyon (Buharlaşma ve Terleme) tahmin etmeye çalışılmıştır [11]. Bu kapsamda; zaman, enlem, yükseklik ve denize mesafe gibi konum değişkenleriyle, bağıl nem ve rüzgâr hızı gibi meteorolojik değişkenler girdi

olarak, Evapotransporasyon deęerleri de ıktı (hedef) olarak senaryolar oluřturulmuřtur. LM algoritması ve farklı yinelemelerle eęitilerek denenen modellerde tahmin bařarısı en yksek YSA olarak belirlemiřtir. Ayrıca Kksal ve dię., buharlařmaya dair 1990-2015 yılları arasında Karacabey Ovası'na ait, Landsat 5 TM ve Landsat 8 uydu grntleri iřlenerek, Vejetasyon ve Evapotranspirasyon durumunu temsil eden haritalar hazırlamıřlardır [12]. Aynı dnemlere ait grntleri kendi ierisinde deęerlendirerek, Karacabey Ovası'nda sz konusu zaman diliminde sulama suyu kullanım durumu ve bitkisel retim desenindeki genel deęiřimler deęerlendirilmiřtir ve buharlařmaya dair dięer alıřmalardan farklı bir alıřma ortaya konulmuřtur.

zel ve Bykyıldız, yntemi Konya Kapalı Havzası'nda yer alan Karaman istasyonuna ait meteorolojik parametreleri kullanılarak uygulamıřlardır ve farklı giriř kombinasyonları ile aylık buharlařma miktarını tahmin etmeye alıřmıřlardır Bu amala YSA, Destek Vektr Regresyonu (DVR), Adaptif Aę Tabanlı Bulanık ıkarım Sistemi (ANFIS) metotları denenmiřtir. Sonu olarak DVR, aylık buharlařma tahmininde dięerlerinden daha tatmin edici olduęunu vurgulamıřlardır [13].

Bu alıřmada ise Kocaeli ili Kandıra ilesine ait Tarım ve Orman Bakanlıęı Kocaeli Meteoroloji Genel Mdrlę arařtırma gzlem istasyonlarından alınan gnlk meteorolojik veriler (Rzgr Őiddeti, Minimum Sıcaklık, Ortalama Sıcaklık ve Su Buharı Basıncı) giriř verisi olarak kullanılmıřtır. Namazgh Barajı'na ait buharlařma miktarı hedef deęiřken olup baraja ait buharlařma miktarı tahmin edilmeye alıřılmıřtır. NARX doęrusal olmayan veriler arası iliřkiyi zebilen YSA modelinin kurulan dięer aęlara oranla tutarlı sonular verdięi grlmřtir. Baraj, gl veya gletlerde gerekleřen buharlařma miktarı tahmini iin kurulan YSA modellerinden LM algoritmasının tahminde daha iyi sonu verdięi kanısına varılmıřtır.

3. MATERYAL VE YÖNTEM

Yapay Zekâ, insana ait sinir sisteminin çalışma prensiplerini yazılım ortamına aktararak makinelere dair günlük hayatta daha aktif bir kullanım ortaya koymaktadır. Başka bir deyişle insan seviyesinde olan makineler ortaya çıkarma isteğinin bir ürünüdür.

İnsan beyni deneyimleyerek öğrenmeye açık olmakla birlikte öğrendiklerini birleştirip olağan problemlere çözümler getirme ve bu çözüm yollarını geliştirme kapasitesine sahiptir. İnsan beyninin bu işlevi yerine getirme aşamalarını algoritmalar aracılığı ile makinelere öğretme ise yapay öğrenme olarak tanımlanabilir. Kısaca disiplinler arası diyalog diye tanımlanabilir.

Yapay öğrenmeye ihtiyaç ise insan beyninin birçok sayısal işlemi bir arada yapma ve hafızaya alma noktasında yeterli hıza sahip olamamasından doğmaktadır. Bu eksikliğe çözüm getirmek amacıyla yapay öğrenme ile makinelere davranış sergileme yeteneği kazandırılmak istenmektedir. Bu nokta da yaşanan gelişmeler sayesinde özellikle son yirmi yıllık süreçte hemen hemen günlük yaşamın her alanında yapay öğrenme kullanılmaya başlanmıştır. YSA'lar da yapay öğrenme tekniklerinden biridir. Çalışma da ise YSA yöntemi kullanılmıştır.


3.1. Yapay Sinir Ağları

İnsan beyninin çalışma sürecinin matematiksel olarak modellenmesine YSA denilmektedir. Bir YSA yapay sinir hücrelerinin gruplaşmasıyla meydana gelmektedir. Aynı işlevi yerine getirmekle sorumlu olan yapay sinir hücreleri eş zamanlı çalışma kapasitesine sahip olduğundan pek çok karmaşık olan problemlere kısa zamanda çözüm bulabilmektedir. Bu hücreler vasıtasıyla öğrenme gerçekleşirken kullanılan veriler eğitim, test ve onaylama verileri olarak sınıflandırılmaktadır. Bu verilerden öğrendikleriyle genelleştirmeler yaparak daha önceden görmediği örneklere ya da problemlere çözüm sunabilmektedir.

YSA'ların bütün bu çalışma mekanizmasını anlamının temelinde insan beyninin çalışma mekanizmasını çözmek yatmaktadır [16].

3.1.1. Biyolojik sinir hücresi

İnsan beyni sinir hücrelerinin işlevi dendrit, akson, çekirdek ve bağlantı bloklarının görev paylaşımına dayanmaktadır. Şekil 3.1’de insana ait nöron hücresinin modeli yer almaktadır.



Şekil 3.1. Gerçek nöron hücresinin yapısı [32]

Dendritler aldıkları sinyalleri çekirdeğe iletmekle sorumludur, fakat sinyali çekirdeğe iletmeye noktasında dendritlerin görevi yerine getirme işlevi farklılık gösterebilir yani her dendrit aynı ölçüde sinyal iletimi yapamayabilir. Dendritlerden gelen sinyalleri toplama görevi gören çekirdek aldığı sinyalleri aksonlara iletmekle sorumludur. Akson ucunda yer alan sinapslar aracılığıyla işleme tabi tutulan sinyaller, eşik değerlendirmesinden sonra indirgeme yoluyla diğer hücreye iletilir. Son döngü sinapslar da olduğundan dolayı öğrenmenin gerçekleştiği yer olarak sinapsların kabul görmesinde sakınca bulunmamaktadır. Yukarıda ifade insan sinir sisteminin çalışma prensibi yapay sinir ağlarının temel taşlarını oluşturmaktadır.

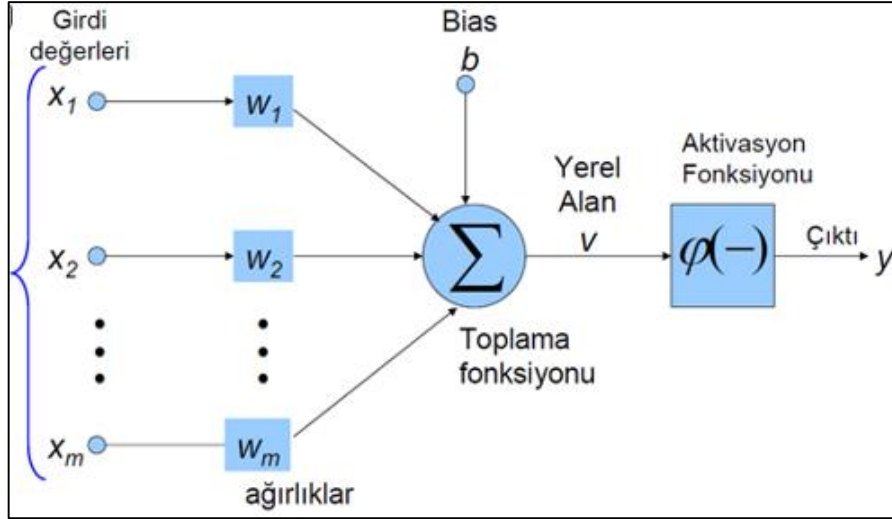
3.1.2. Yapay sinir hücresi

İnsan beyni deneyimler vasıtasıyla öğrendiklerini uzun süreli belleğe ya da kısa süreli belleğe kaydetme işlevi görebilmektedir. Bu işlev insan beyni sinir hücreleri vasıtasıyla gerçekleştirilmektedir ve bunu yerine getirirken sinir hücreleri için olayların tekrarı ve önemliliği önemli bir koşul olmaktadır. Olayların tekrarı insan sinir hücreleri arasında daha güçlü bağıntılara sebep olmasından dolayı öğrenme

olayı daha güçlü olmaktadır. Tekrar edilmeyen bilgiler sinir hücreleri arasındaki bağlantıların zayıflamasına sebep olmakla birlikte öğrenme olayı bağlantı zayıflığından dolayı istenildiği şekilde gerçekleşmemektedir.

YSA'lar da aynı durum söz konusudur. Ağın temel yapı taşı olan proses eleman diye de isimlendirilen yapay sinir hücreleri mevcuttur. Öğrenmenin gerçekleşmesi için ağın performansın da hangi verinin daha büyük öneme sahip olduğunu belirleyen sayısal değerlere sahip bu elemanlar arasındaki bağlantılar ağırlık olarak tanımlanmaktadır. Yani diğer bir ifade ile ağırlıklar girişlerin etkisi diye tanımlanabilir. Bu bağlantı ağırlıkları başlangıçta rastlantısal olarak belirlenirken daha sonra değiştirilerek öğrenmeye en uygun katsayılar olarak belirlenir. Belirlenen en uygun ağırlıklar vasıtasıyla öğrenme olayı gerçekleşir. Nöronlar arası bağlantı ağırlıkları öğrenmede büyük ölçüde öneme sahip olduğu için problemi çözmek açısından doğru mimari tasarımının yanında kullanılan nöron sayısı ve kullanılan katman sayısı özellikle çok katmanlı ağlar için büyük önem arz etmektedir. Çok katmanlı ağlar da bir katmanın çıktısı kendinden sonra gelen katmanın girdisi olarak değerlendirilir. Bu ağlarda hesaplama yönü ileri doğru iken hatayı yayma yönü geriye doğrudur. Uygun ağırlıkları bulana kadar ağırlık güncellemesi yapılır güncellemeler sonunda hedef değer ile ağın çıktısı arasında hesaplanan hatalar azaltılması geri yayımlı ağlarda dereceli alçalma diye tabir edilmektedir. Minimum hata düzeyi yakalanan kadar ağırlık güncellemesi yoluyla öğrenme devam eder. Minimum hata düzeyinin yakalanması ağ için en uygun ağırlık matrisinin belirlendiği anlamını taşımaktadır. Ağın artık hiç görmediği örneklere çözüm üretebilecek seviye geldiği anlamını taşımaktadır. YSA 'nın en büyük avantajı da bu olmuştur ki yaptığı genelleştirmeler vasıtasıyla görmediği örneklere çözüm üretebilecek kapasiteye sahip olabilmesidir. Bu işlemin yapılması da ağırlıkların güncellemesiyle mümkündür.

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 [34]

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

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

Giriş değerleri yani girdiler ilgili ağırlıkları ile çarpılırlar ve çarpım değerleri 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;

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

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

Aktivasyon fonksiyonu İBGYYSA için büyük önem arz eder. Çünkü geri beslemeli ağlarda hesaplanan hata geriye doğru yayılırken, katmanlar yeni ağırlıklarla beslenir hata geriye doğru yaymak için türevi alınabilen bir fonksiyona ihtiyaç duyulmaktadır. Çıkışa aktarılan değere aktivasyon işlemi $f(x)$ uygulanır. Aktivasyon işleminden sonra bu çıkış olabilirken başka bir katman girişi de olabilmektedir. Aktivasyon işlemi uygulanmasının sebebi ise ağırlık çıkışını doğrusallıktan kurtarmaktır. Çünkü doğrusallık tek dereceli polinomları kapsamaktadır diğer bir ifade ile lineer durumlar için geçerlidir. Doğrusal olmayan problemlere çözüm bulabilmek ve nonlinear olan anlamlı özelliklerin ağı tarafından daha güçlü bir şekilde anlaşılabilmesi için aktivasyon fonksiyonu aktif hale getirilir.

Aktivasyon fonksiyonları çalışma prensiplerine göre farklılık gösterebilmektedir. YSA'larda kullanılan temel toplama ve aktivasyon fonksiyonları aşağıdaki gibidir:

3.1.3. Toplama fonksiyonları

Yapay sinir hücresine gelen net girdi hesaplama işlemi için kullanılan fonksiyondur. En çok tercih edilen fonksiyon ise ağırlıklı toplamı bulan fonksiyondur. Yani her girdi ilişkili olduğu ağırlık değeri ile çarpılarak toplam bulunur. 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)

Kimi toplama fonksiyonları girdi değerlerini dikkate alırken kimi fonksiyonlarda girdi sayısı önemli olabilmektedir.

Dolayısıyla bu farklılığı taşıdığından dolayı bazı toplama fonksiyonları örnekleri aşağıda Tablo 3.1 ile verilmiştir [16].

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 bulduktan 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

Bir diğer adı ise basamak fonksiyonu olan bu fonksiyon ikili değer almaktadır. Daha çok çıkış katmanında tercih edilen bu fonksiyon ikili bir sınıflayıcı olarak değerlendirilmektedir. Türevi alındığında ağı için bir önemi kalmadığından dolayı özellikle çok katmanlı ağlarda tercih edilen fonksiyon değildir. Şekil 3.3'te step fonksiyonunun grafiği yer almaktadır. Bu fonksiyonun denkleminin matematiksel gösterimi Denklem (3.5)'te verildiği şekildedir;

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

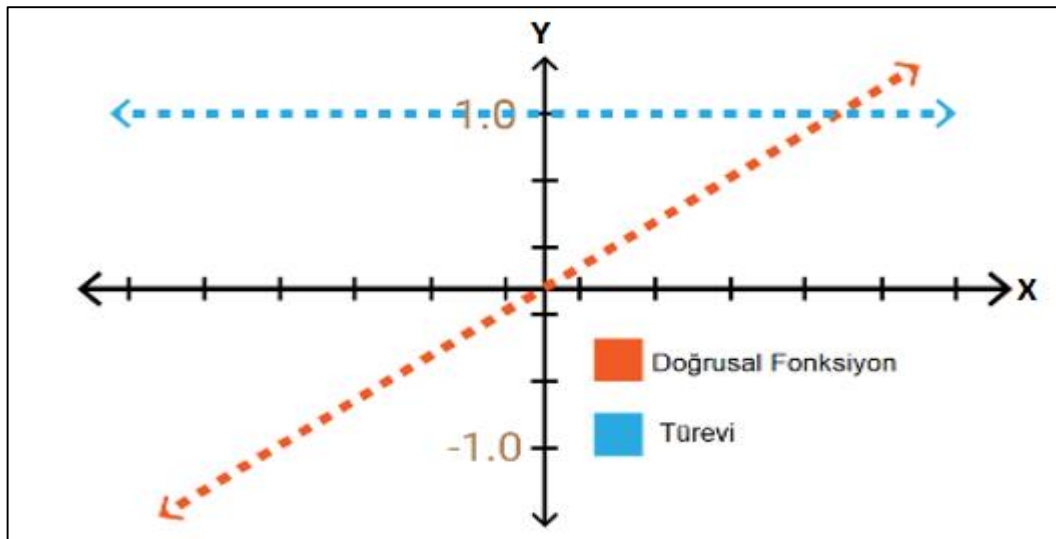


Şekil 3.3. Step fonksiyonunun yapısı [33]

3.1.4.2. Doğrusal (Linear) fonksiyon

YSA'lar hatayı geri yayarken geri yayılım algoritması kullanmaktadır. Dolayısıyla doğrusal fonksiyonumuz $g(x)=x$ olduğu için türevi alındığında sabit bir sayıya ulaşılmış olmaktadır. Yani verdiğimiz girdi değerleri çıktı olarak üretilmektedir.

Türevlenebilir fonksiyon olmasından dolayı tercih edilse de girişi çıkış olarak verdiğinden çok katmanlı ağlarda ara katmanı işlevsiz bıraktığı gerçeği göz ardı edilmemelidir. Doğrusal fonksiyonun grafiği Şekil 3.4'te yer almaktadır.



Şekil 3.4. Doğrusal fonksiyonun grafiği [33]


3.1.4.3. Sigmoid fonksiyonu

Sigmoid fonksiyonu türevlenebildiği ve ayrıca ürettiği değerler sıfır ve bir arasında değerler aldığı ve süreklilik arz ettiği için geri yayınlımlı ağlarda sıkça tercih edilmektedir. Özellikle geri yayınlımlı ağlar için kullanılan aktivasyon fonksiyonunun önemi çok büyüktür ve genellikle çok katmanlı ağlarda aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılır. Tercih edilmesinin sebebi ise kolay türevlenebilir olmasının yanında süreklilik arz etmesidir. Sigmoid fonksiyonunun matematiksel ifadesinin denklemi Denklem (3.6)'da verildiği gibi olur;

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

Yukarıdaki formül incelendiğinde işlem sonunda elde edilecek değer rasyonel bir ifade olmakla birlikte basit bir kesir ifadesi olmaktadır. Bundan dolayı da kimi yer de bu fonksiyon sıkıştırma fonksiyonu olarak da adlandırılmaktadır. Aşağıda Şekil 3.5'te sigmoid fonksiyonunun grafiği yer almaktadır.

Grafikten anlaşılacağı üzere belli bir değerden sonra x değerlerindeki değişim y üzerinde çok değişime sebep olmamaktadır. Bu yüzden belirli aralıklarda çok iyi bir sınıflayıcı olarak da değerlendirilebilirken belli bir değerden sonra çok iyi bir çıktı üretemeyebilir çünkü değişmeyen y değeri dikkate alındığında bu ağın düşük eğime sahip olduğu anlamını taşımaktadır. Yani bu noktalarda ağın takılmasına sebep olabilmektedir. Bu nokta yapılacak modellemelerde sigmoid fonksiyonu kullanılırken göz önünde bulundurulması gereken faktörlerden biridir. Fakat bu fonksiyon öğrenme hızının yüksek olmasından dolayı ve türevlenebilir olduğundan dolayı en çok tercih edilenler sıralamasında ilk sıralarda yerini korumaktadır. Bu çalışma da ise kullanılan öğrenme algoritmasından dolayı gizli katmanda Sigmoid fonksiyonu kullanılmıştır. Fonksiyon çıktı üretme konusunda ağın hızını arttırmaktadır. En çok tercih edilen fonksiyon olmasının en temel sebebi ise ağın performansına hız kazandırmasıdır.




Şekil 3.5. Sigmoid fonksiyonunun grafiği [33]

3.1.4.4. Sinüs fonksiyonu

Trigonometrik bir fonksiyon olan sinüs fonksiyonu pozitif ve negatif değerler üretme yeteneğine sahiptir ve çıktılarını sinüs dalgalarına paralel olarak sunmaktadır. 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 [35]

3.1.4.5. Hiperbolik tanjant fonksiyonu

Türevinin alınabilmesi ve hem pozitif hem de negatif değerler üretebildiği için çok katmanlı ağlarda en çok kullanılan fonksiyonlardandır. 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 grafiği [33]

3.1.4.6. Logaritmik aktivasyon fonksiyonu

Logaritmik aktivasyon fonksiyonu da çıktı olarak pozitif ve negatif değerler vermektedir. Türevlenebilir olduğundan çok katmanlı ağlarda tercih edilebilmektedir. Çalışma mekanizması Hiperbolik Tanjant Fonksiyonuna benzemektedir. 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

Daha pek çok aktivasyon fonksiyonu bulunmaktadır. Fakat tercih sırasında Hiperbolik Tanjant ve Sigmoid fonksiyonları en çok tercih edilenler arasında olmaktadır.

Geniş bir sınıflayıcı kapsamı olduğundan dolayı Hiperbolik Tanjant tercih edilirken, Sigmoid fonksiyonu öğrenme hızı biraz daha düşük olan durumlar için tercih edilebilmektedir. Genel olarak en çok kullanılan 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 $F(\text{NET}) = \begin{cases} 1 & \text{if } \text{NET} > \text{eşik değeri} \\ 0 & \text{if } \text{NET} < \text{eşik değeri} \end{cases}$	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

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

3.2. Yapay Sinir Ağı Yapısı

Yapay sinir hücrelerinin ağırlıklar vasıtasıyla bağlanıp gruplaşmasıyla YSA meydana gelmektedir. Aynı işlevi gören yapay sinir hücrelerinin grup kurmasıyla ağı yapısında giriş katmanı, probleme bağlı değişkenlik gösteren gizli katman ya da katmanlar ve çıkış katmanı kavramlarını ortaya çıkarmaktadır. Aynı katmanda bulunan hücreler aynı işlevi meydana getirdikleri için kendi katmanındaki hücrelerle bağıntıları bulunmamaktadır.

İşlemci hücrelerin eş zamanlı çalışmasından dolayı öğrenme hızı yüksek olan çok katmanlı ağlar ve diğer ağların çalışma mekanizması temelde öğrenme algoritmalarına dayanmaktadır. YSA'nın yapısı Şekil 3.9'da gösterilmektedir.



Şekil 3.9. Yapay sinir ağının yapısı [36]

Girdi katmanı nöronları dışarıdan gelen veriyi almakla sorumludur diğer bir ifade ile ağ için taşıyıcılık görevi üstlenmektedirler.

Girdi katmanı nöronları aynı zamanda aldıkları bilgiyi kendinden sonra varsa ara katmana yoksa da çıktı katmanına iletmekle sorumludurlar. Çözülecek probleme bağlı olarak gizli katman bir ya da birden fazla olabilmektedir. Tanımlanacak olan gizli katman sayısı ve bu katmandaki nöron sayısı problemin karmaşıklığına bağlı olarak değişkenlik göstermektedir.

Bu iki faktörün olması gereken değerden fazla tanımlanması bu ağın salınımlar yapmasına neden olurken, olması gereken değerden küçük tanımlanması da olayı öğrenme de ağın yetersizliğine sebebiyet vermektedir. Bunu belirleme yolu ise deneme yanılma yöntemi olmakla birlikte kullanılan tek yoldur.


YSA'lar da nöron bozulmaları ağın modelinin işlev kaybına sebebiyet vermemektedir ki bu da YSA'nın en büyük avantajlarından biri sayılmaktadır. YSA'lar her düğümde hata hesaplama özelliğinden dolayı hesapladığı son tahmin hatasını minimize etmede geleneksel yöntemlere göre çok daha iyi sonuç verebilmektedir. İstedığımız çıktıyı veren hatayı bulup onu geriye doğru azaltma eğilimindedir. Ağ için hatanın belli bir değerinden sonra yani sıfıra yakın olması durumu iyi bir eğitimin olduğu ve ağ için artık eğitimin tamamlanması anlamını taşımaktadır.

Yapılarına göre değişkenlik gösteren YSA'lar ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olmak üzere temel de iki başlık altında sınıflandırılabilir.

Yapılan her iterasyon sonucunda ağırlıklar yeniden belirlenir uygun ağırlığın belirlenmesi hata oranının sifıra yakınlığı ile değerlendirilir. Uygun ağırlıklar belirlene kadar döngü bu şekilde çalışmaktadır. Belirlenen doğru ağırlıklar sonucu eğitim tamamlanmış sayılmaktadır.

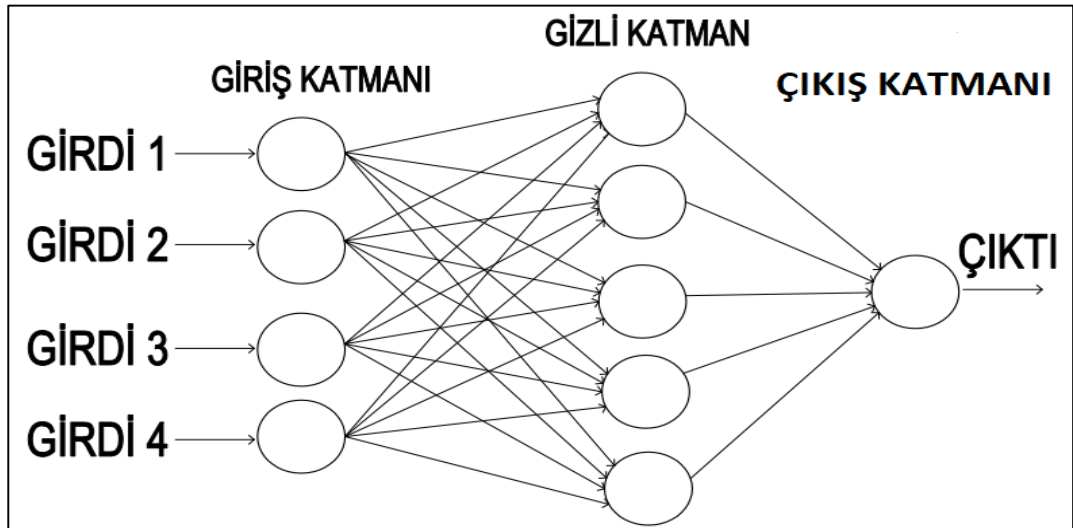
YSA'lar ileri beslemeli ağlar ve geri yayımlı ağlar olmak üzere iki başlık altında toplanabilir. İleri beslemeli ağlarda bağlantılar aracılığı ile katmanlar sadece ileri doğru beslenirken geri beslemeli ağlar da katmanlar geriye doğru da beslenmektedir.

İleri beslemeli ağlar da kendi içinde tek ve çok katmanlı ağlar olmak üzere ayrılmaktadır. Tek katmanlı ağ nöronları ile çıktı nöronları arasında ara nöronlar bulunmamaktadır ve katmanlar sadece ileri doğru beslenmektedir. Tek katmanlı YSA yapısı Şekil 3.10'da gösterilmiştir.



Şekil 3.10. Tek katmanlı yapay sinir ağının yapısı [37]


Çok katmanlı ağlar da 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 ağlar da 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 [38]

3.3. Yapay Sinir Ağlarında Öğrenme

YSA mevcut verilerden faydalanıp veriler arası ilişkiyi çözerek ağa çıktı sunabilme kapasitesine sahiptir.

Ağa sunulan girişler rastlantısal belirlenen ağırlıklarla çarpılarak toplama fonksiyonunda birleştirilip daha sonra bir aktivasyon fonksiyonundan geçirilip çıktı üretilir. 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 ağın 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;

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

E: Hata değeri

Ağ bu en uygun ağırlıkları belirlerken öğrenmeyi gerçekleştirmek için bir takım öğrenme algoritmalarından faydalanır. Ağ öğrenme türlerini üç ana başlık altında incelemek mümkündür [30].

Danışmanlı, danışmansız ve destekleyici öğrenme olmak üzere;

3.3.1. Danışmanlı öğrenme

Girdilerle birlikte çıktılarında ağa sunulduğu öğrenme biçimidir. Öğrenme sürecinden sonra ağ gerçek çıktı ile ürettiği çıktıları karşılaştırarak mevcut hatayı en aza indirmekle sorumludur bunu da ilgili öğrenme algoritması kullanılarak ağırlık güncellemesi yoluyla yapmaktadır. Ağırlık matrisindeki değişim hatanın kabul edilebilir düzeye ulaşması ile değerlendirilir. Geri yayılım ağırları örnek verilebilir.

3.3.2. Danışmansız öğrenme

Sadece girdilerin ağa verildiği öğrenme biçimidir. Çıktı ağa sunulmadığı için bu öğrenme türündeki asıl amaç girdiler arası istatistiksel ilişkinin çözümlenebilmesidir. Girdiler ağ için çıktı vazifesi görmektedir. Bu veriler arası ilişkinin ortaya konulması ağı öğrenmesi olarak değerlendirilir. Hopfield ve Kohonen Ağları bu gruba girmektedir.

3.3.3. Destekleyici öğrenme

Destekleyici öğrenme de çıktı sisteme verilmez üretilen çıktıya olumlu ya da olumsuz sinyal verilmektedir. Ağ ağırlıklarının düzenlenmesi bu sinyal değerlendirmesine göre yapılır.

3.4. Çok Katmanlı Yapay Sinir Ağlarında Öğrenme Algoritması

3.4.1. Geri yayılım algoritması

Çok katmanlı ağların genelinde algoritma olarak geri yayılım algoritması kullanılmaktadır. Bu algoritma da nöronlar arası tam bir bağlantı bulunur, ileri doğru beslenmekle birlikte danışmanlı öğrenme gerçekleşmektedir bu tür ağlarda. Gizli katman sayısı probleme göre değişkenlik göstermekle birlikte girdi katmanı, gizli katman, çıktı katmanı olmak üzere en az üç katmandan oluşmaktadır.

Ağa verilen bilgi ağırlıklar vasıtasıyla nörondan nörona doğru çıktı katmanına kadar iletilir. Çıktı katmanında hesaplanan çıktı değeri ile olması gereken gerçek değer karşılaştırılır ve hesaplanan fark ağ tarafından hata olarak belirlenir. Belirlenen bu hata girdi katmanına doğru katmanlar tarafından paylaşılır. Ve dikkate alınacak hata oranına bağlı olarak bağlantı ağırlıkları yeniden düzenlenir. En uygun ağırlıkların belirlendiği sürece kadar işleme bu şekilde devam edilir.

Doğru ağırlıkların belirlenmesi eğitimin gerçekleştiği anlamını taşımaktadır. Eğitimde öğrenilen bilgiler vasıtasıyla ki bilgi işleme işlevi ara katman aracılığı ile olmaktadır ki bu ağ aracılığı ile eğitim sonrasında daha öne hiç görülmeyen ya da eksik bilinen veri setine ağ cevap verebilmektedir.

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 vektör girdi katmanından alınarak gizli katmanda işleme tabi tutulmaya başlar.

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

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

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

$$i_{nj} = f_j^h(\text{net}_{nj}^h) \quad (3.18)$$

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

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

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

Eşitlikleri kullanılarak hesaplama işlemi yapılmaktadır.

Ağ öğrenmesinde kullanılan bir takım öğrenme kuralları mevcuttur.

En küçük kareler öğrenme kuralı Denklem (3.21)'de verilmiştir [30];

$$W(t+1)_i = W(t)_i + 2 \times \mu \times \varepsilon_{k0} \times X_{ki} \quad (3.21)$$

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. En küçük kareler kuralının türevi alınarak hata değeri aşağıda verilen Denklem (3.22) formül üzerinden hesaplanır;

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

Ancak çok katmanlı ağlar için bu formül yeterli olmayacaktır dolayısıyla hesaplama tek bir çıktı düğümünün hatası üzerinden formülize edilmelidir. Tek bir çıktı düğümü hatası $\delta_{\text{düğüm}}$, bütün düğümlerin toplam hatası ise $E_{\text{düğüm}}$ diye formülize edilirse bir düğümden hesaplanan hata 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;

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

Denklem (3.17)'de $\frac{1}{2}$ kullanılmasının sebebi hata geriye dönük yayılırken türev almada kolaylık sağlamasından kaynaklıdır, en son hesaplanan hata da sabit olarak değerlendirileceği için sonucu değiştirme de $\frac{1}{2}$ 'nin etkisi bulunmamaktadır.

Ağırlıkların hangi yönde değişeceğinin belirlenebilmesi için E_n değerinin negatif gradyeni hesaplanmalı ve hesaplamanın kolaylığı açısından ∇E_n değeri ağırlık uzayı düzlemi olarak düşünülmesinde fayda bulunmaktadır. İlgili bağıntılar Denklem (3.25) ve (3.26) ile verilmiştir;

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

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

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

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

η : öğrenme hızı

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

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

Denklem (3.26) ve (3.27)'deki denklemler birlikte çözülerek Denklem (3.28)'deki denkleme ulaşılır. Bu da negatif gradyen ağırlık değişim miktarını vermektedir. Çıktı katmanı ağırlıklarının matematiksel hesabı aşağıda Denklem (3.29) ve (3.30) denklemleri kullanılarak elde edilir;

$$\Delta_n W_{kj}^{\Theta}(t) = \eta \times (g_{nk} - t_{nk}) f_k^{\Theta} (net_{nk}^{\Theta}) i_{nj} \quad (3.29)$$

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

Bütün bu denklemlerden yola çıkarak çıktı değerimiz için iki fonksiyon söz konusudur ki bunlarda Denklem (3.31) ve (3.32) ile verilmiştir;

$$f_k^{\Theta} (net_{jk}^{\Theta}) = net_{jk}^{\Theta} \quad (3.31)$$

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

Bir numaralı fonksiyon doğrusal bir fonksiyon diye isimlendirilirken iki numaralı fonksiyon sigmoid fonksiyonu adını almaktadır, bir diğer adıyla sıkıştırma fonksiyonu diye ifade edilir. Problemin çözümüne uygun olarak çıktı fonksiyonu doğrusal ya da sigmoid olarak tercih edilebilir. Çok katmanlı ağlarda geriye doğru hata yayma işlevinden dolayı türev alma işleminin gerekliliğinden kaynaklı aktivasyon fonksiyonu olarak sigmoid fonksiyonu tercih edilir. İlgili bağıntılar Denklem (3.33) ve (3.34) ile verilmiştir;

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

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

Denklemlerde gerekli düzenlemeler yapılıncaya 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 değerlerinin yeniden güncellenmesi için aşağıdaki eşitlikler dikkate alınır ve bu işlem için Denklem (3.37) ve Denklem (3.38) kullanılır. Denklem (3.37) gerekli işlemler kullanılarak Denklem (3.38)'deki gibi son halini alır;

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

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

Bu durum da ağırlık düzenlemeleri için kullanılacak en genel eşitlik, Denklem (3.39) ile tanımlanabilir;

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

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 hesaplanabilmektedir. 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)'teki elde edilir.

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

Çıktı katmanı toplam hatası eşitlikte yerine yazılırsa olan δ_{nk}^Θ , eşitlikte kullanılması ile denklemin yeni formatı Denklem (3.46)'deki gibi yazılabilir;

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

Çıktı katmanından hata gizli katmana iletilir dolayısıyla gizli katmanda hesaplanacak güncel hata çıktıdan gelen hataya bağlıdır. Gizli katman da hesaplanacak hata değerini kullanmada dikkate alınan Denklem (3.47)'deki denklemdir;

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

Hataya bağılı olarak belirlenecek gizli katman güncel değeri için dikkate alınan denklem ise Denklem (3.48) olarak verilmiştir [30];

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

3.4.3. Öğrenme hızı ve momentum katsayısı

YSA'larda ağırlıklar güncellenirken ağda meydana gelebilecek anlık sıçramaların önüne geçebilmek için momentum katsayısı tanımlanır. Aynı zamanda ağdaki takılmaların önüne geçebilmek için çok katmanlı ağlarda momentum katsayısı tanımlanır. Bu katsayı hesaplanan eski ağırlığın güncel ağırlığa ilave edilmesiyle ilişkilendirilir.

Bu katsayının gerekliliği güncel ağırlık hesabında hesaplanan önceki ağırlığın tamamen göz ardı edilmeyip bir katsayıyla işleme dahil edilmesinden kaynaklıdır. Sıfır bir aralığında olan gerçel bir sayıdır. Öğrenme katsayısının tanımlanma amacı ise verilerin ağ tarafından öğrenilmesi için uzun zaman gerekebilir bundan kaynaklı gerçekleşecek olan maliyeti azaltmak için tanımlanmaktadır. Ayrıca öğrenme katsayısı olması gereken değerden büyük tanımlanırsa bu ağın öğrenmesinden çok ezberlemesine sebep olabilir başka bir deyişle ağ öğrenmek yerine veriye uyar (ezberleme) ki bu da ağın genelleyebilme özelliğinin kaybolmasına sebep olmaktadır. Elde edeceğimiz hata düzeyinin yüksek olacağı anlamını taşımaktadır.

Öğrenme katsayısının büyük tanımlanması ve lokal minimuma ulaşma ihtimali azalır ancak küçük bir değer alınırsa bu işlem maliyetini artırırsa da lokal minimuma ulaşma ihtimalini yükseltir.

Öğrenme katsayısı adım büyüklüğü belirleme işlemi olarak da tanımlanabilir. Sıfır ve bir aralığında kullanılan bir katsayıdır. Ağırlık güncelleme kuralı Denklem (3.49)'daki bağıntıya uygun gerçekleştirilmektedir [30];

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

μ : momentum katsayısı

η : öğrenme hızı

3.4.4. Çalışmada kullanılan öğrenme algoritması

Geri yayılım ağlarında kullanılan öğrenme algoritmalarından olan LM öğrenme algoritması en çok kullanılan algoritmadır ve temelinde de dik iniş kuralı bulunmaktadır.

Diğer öğrenme algoritmalarından daha iyi olmasının sebebi ise hızlı ve kararlı bir yapıya sahip olmasıdır. Dolayısıyla bu çalışmada da bu algoritma kullanılarak yapılmıştır.

Lokal minimuma takılma ihtimali de olmasına karşın en çok tercih edilen öğrenme algoritmalarından biri olmaya devam etmektedir.


3.5. Yapay Sinir Ağı Mimarileri

Yapay sinir hücrelerinin bağlantılar aracılığı ile bir araya gelmesiyle oluşturdukları yapıya YSA denilmektedir. Yapıdaki farklılık kullanılan aktivasyon fonksiyonuna, öğrenme parametrelerine, ağırlıkların güncellenme durumlarına göre farklılık göstermektedirler.

3.5.1. Geri beslemeli yapay sinir ağı (GBYSA)

En çok kullanılan ağlardan biri GBYSA'lardır. En az bir sinir hücre kendisi ya da kendisinden sonra gelen hücrenin çıktısıyla besleniyorsa bu ağlar GBYSA olarak nitelendirilir. Bu işlem tek katmanda bulunan hücre tarafından da olabilirken aynı zamanda farklı katman hücrelerince de gerçekleşebilmektedir.

Eğer bu işlem geri besleme gecikmesine sahip bir eleman üzerinden gerçekleşiyorsa ilgili ağ doğrusallıktan uzak bir dinamik ağ modeli davranışı göstermektedir. Şekil 3.13'de GBYSA modeli örneği gösterilmiştir.




Şekil 3.13. Geri beslemeli ağ modeli örneği

3.5.2. İleri beslemeli yapay sinir ağı

İleri beslemeli yapay sinir ağı temelde üç katmandan oluşmaktadır ki bunlar sırasıyla giriş, gizli ve çıktı katmanıdır. Giriş katmanı verileri tutan katman iken gizli katman sonuca göre kendisini eğiten katmandır ve son olarak çıktı katmanı ise çıktıyı dış dünyaya sunan katmandır. Ayrıca gizli katman sayısı probleme bağlı olarak değişkenlik gösteren katmandır. Bir ileri beslemeli yapay sinir ağı için gizli katman giriş katmanından gelen bilgiyi işleme koyan katman olarak düşünülebilir. Matematiksel işlevin gerçekleştiği yerdir. Bu yüzden ağ modellemelerinde gizli katman çok büyük önem taşımaktadır. Bir ileri beslemeli yapay sinir ağı giriş katmanındaki nöronlar aracılığı ile aldığı bilgileri nöronlar arası ağırlıklar vasıtasıyla değişime uğratmadan saklı katmana iletmektedir. Saklı katmanda işlev fonksiyonları aracılığı ile işleme tabi tutulan veriler varsa kendinden sonraki gizli katmana yoksa da çıkış katmanı nöronlarına iletilerek işlem dış dünyaya sunulan çıktı ile son bulmaktadır.

Giriş katmanı çıkışı, saklı katman için giriş görevi görmekteyken son saklı katman çıkışı da çıktı katmanı için giriş görevi görmektedir. İleri beslemeli yapay sinir ağının yapısı Şekil 3.14 ile gösterilmiştir.

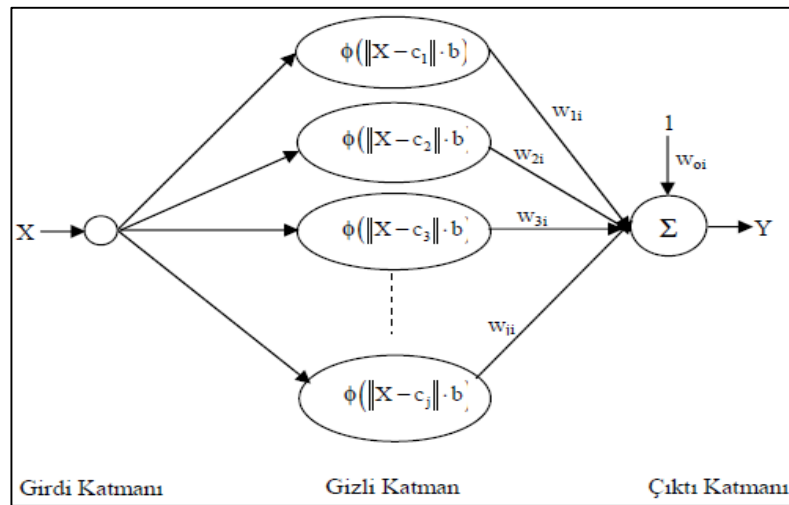


Şekil 3.14. İleri beslemeli yapay sinir ağının yapısı

3.5.3. Radyal tabanlı yapay sinir ağı (RTYSA)

Radyal tabanlı ağlar diğer ağlara girdi katmanı, saklı katman ve çıkış katmanı taşınması açısından bezese de, bunların aksine girişten gelen ağırlıklandırılmış verileri kullanmak yerine radyal aktivasyon fonksiyonları yardımıyla giriş katmanından orta katmana sabit dönüşüm uygular.

Orta katmandan ve çıkış katmanına doğru ise girişler ile temel fonksiyon merkezi arası mesafe dikkate alınarak hesaplama yapılır. Diğer bir deyişle ilgili bu iki katman arasında ise doğrusal bir dönüşüm gerçekleştirilir. Şekil 3.15'te Radyal temelli bir yapay sinir ağı yapısı verilmiştir.



Şekil 3.15. Radyal tabanlı yapay sinir ağı yapısı [22]

Literatürde bu mimariler dışında son zamanlarda daha kompleks mimariye sahip ağ modelleri de geliştirilmektedir.

3.6. Zaman Serileri

Zaman serisi, ölçümü belirli aralıklarla yapılmış değişkene ait sıralı gözlem değerlerinin sayısal değerleriyle ifade edilebilir. Bir ya da birkaç parametreye ait zaman serileri kullanılarak gelecek hakkında tahminlerde bulunmak için kullanılan dinamik bir filtreme çeşidi probleme uyarlanmıştır. Bu gözlem dönemlerinin gün, ay, yıl olması çok farklılık yaratmamaktadır önemli olan eşit aralıklarla yapılmasıdır [27].

Bir değişkenin zamanla değişen değerleri 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'larda öğrenme iç döngüsüne göre ağlar statik ve dinamik olarak ayrılmaktadır. Statik ağlarda ağı kullanımı sırasında öğrenme gerçekleşmez. Başka bir deyişle ağ kullanılıyorsa öğrenme işlemi sonlanmış demektir.

Statik ağlar zaman faktörünü dikkate almadan çıktı üreten ağlar olmakla birlikte geri besleme gecikmesine sahip değildirler.

Dinamik ağ ise kullanıma aşamasında da öğrenme kapasitesi taşımaktadırlar. Zamana göre değişkenlik gösteren parametrelerin olduğu problemlerin çözümü için bu ağlar tercih edilmektedir.

Geri beslemeli ağlardan çok katmanlı ağlar bu sınıfta değerlendirilmektedir.

Günlük yaşamda karşılaşılan problemler ya da mühendislik problemlerini oluşturan etkenler birden fazla olabilmektedir. Bu değişkenlerin zamanla değişimi de problemi çözmemizde zorlanmamıza sebebiyet vermektedir. Dolayısıyla dinamik ağlar zamana bağlı problemlerin çözümün de büyük bir kolaylık sağlamaktadır.

Bizim çalışmamızda buharlaşma miktarı zamana bağlı olarak değiştiği için doğrusal olmayan oto-regresif modelleme ile probleme çözüm bulma yoluna gidilmiştir.

3.6.2. Doğrusal olmayan otoregresif (Nonlinear Autoregressive)

Bu modelleme de bir dizi serinin gelecekte alacağı değer geçmişteki değerleri dikkate alınarak tahmin edilmeye çalışılmaktadır. Bu diziye ait sadece bir adet girdi serisi ile problem çözümlenmek istenmektedir. Bu döngünün matematiksel ifadesinin denklemi Denklem (3.51) ile verilmiştir [27];

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

Buharlaşmayı etkileyen birden fazla değişken mevcut olabilmektedir.

NAR modeli doğrusal olmayan regresyon tabanlı olsa da çözüme tek değişken üzerinden gidildiği için bizim problemimize uygun çözüm yolu sunmamakta kısıtlı kalmaktadır.


3.6.3. Doğrusal olmayan otoregresif eksojen (Nonlinear Autoregressive Exogenous)

Son zamanlarda zaman serisi problemlerinde çokça tercih edilen bir dinamik tabanlı ağ modeli olmaktadır. Modelleme yapılırken belirtilen gecikme aralıklarıyla çıkışlar tekrar ağın girişine gönderilmektedir.

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

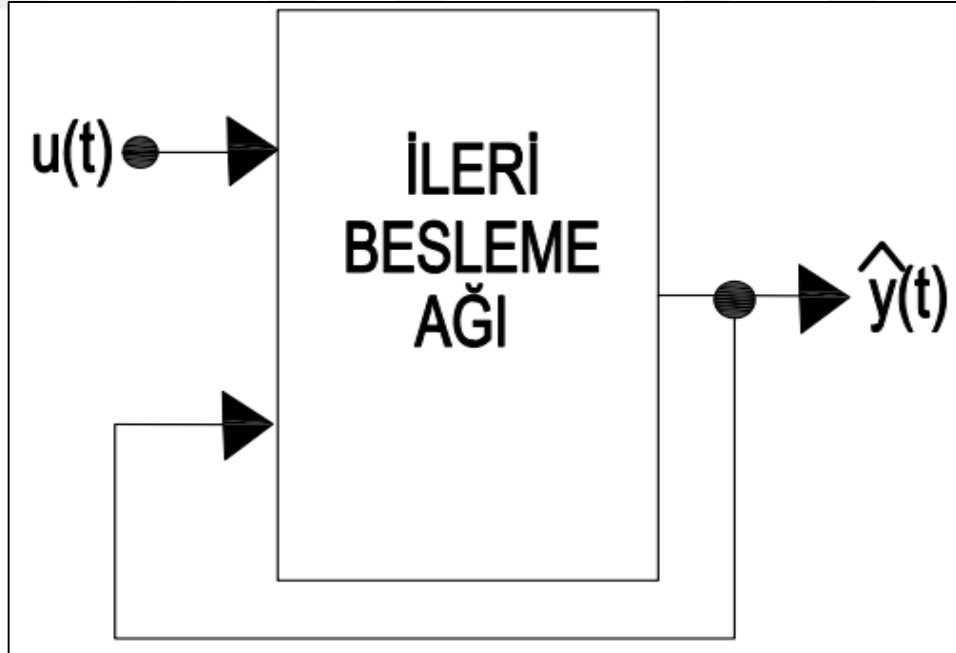
$$y(t) = f(y(t-1), y(x-2), \dots, y(x-ny), y(t-1), u(t-2), \dots, u(t-nu)) \quad (3.52)$$

Çıkış değerimiz olan $y(t)$, kendinden önceki çıkış değerleri ve girişler dikkate alınarak hesaplanmaktadır. Tahmin edilmek istenen çıkış değeri ağa diğer girdi parametrelerinin yanında giriş olarak verilmektedir. Doğrusal olmayan problemlerin çözümü için tasarlanan dinamik olan bu ağ pek çok alanda kullanılabilir. Şekil 3.16 ile ise seriye bağlı bir YSA modeli gösterilmiştir.



Şekil 3.16. Seriyeye bağlı NARX modeli mimarisi

Şekilden de anlaşıldığı üzere ağ tarafından tahmin edilen değer girişe tekrar gönderilmektedir. Girişler eldeki veri setinin geçmiş dönemlerine ait örneklerden oluşurken çıkış ağın tahmin değeri olmaktadır. Tahmini istenilen değer önceki zaman serisi değerleri dikkate alınmamaktadır. Şekil 3.17 ile dışsal girişi bir YSA modeli verilmiştir.



Şekil 3.17. Dışsal girişi NARX modeli mimarisi

4. ÇALIŞMA ALANI VE YERİ

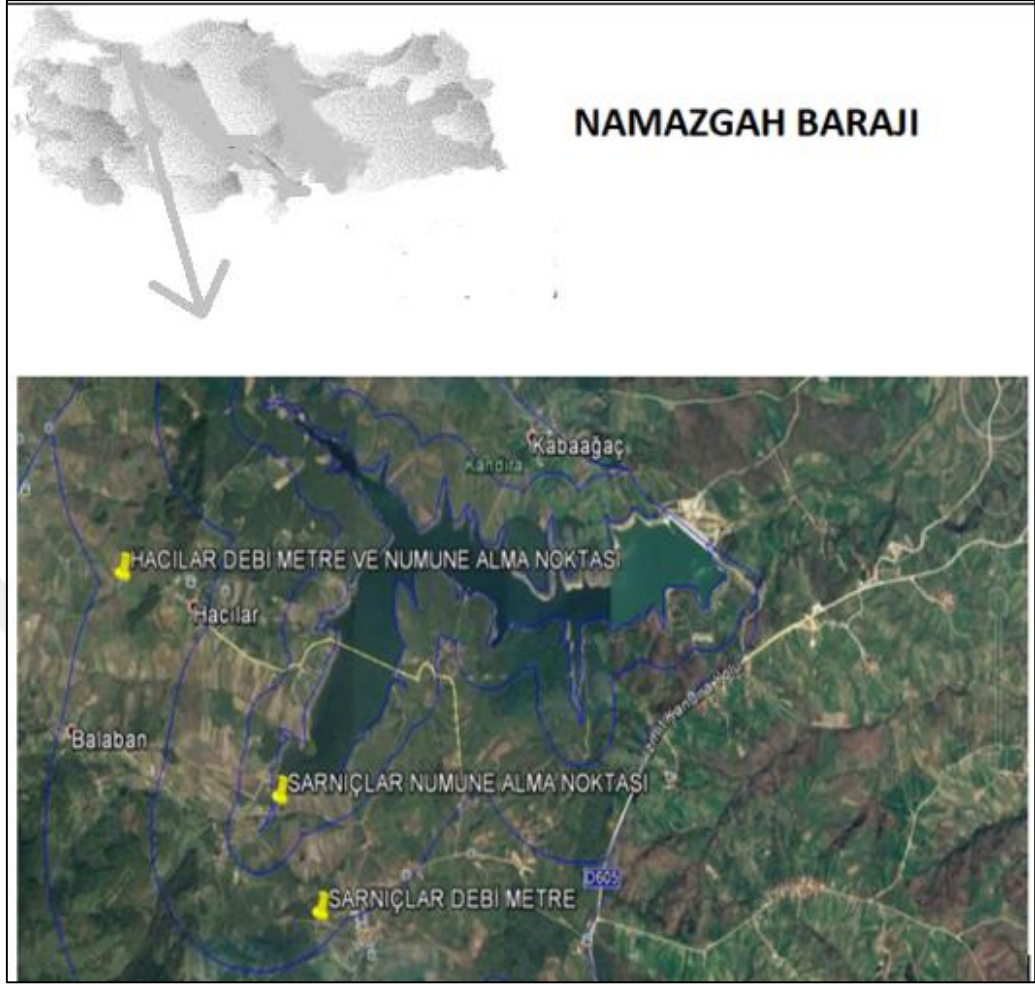
4.1. Kocaeli İli Kandıra İlçesinde Bulunan Namazgâh Barajı

Bu çalışma da Kocaeli ilinin Kandıra ilçesinde bulunan Namazgâh Barajı'na ait gözlemlenen verilerden yola çıkılarak barajda gerçekleşen buharlaşmanın seriye dayalı doğrusal olmayan bir YSA modeli ile tahmini gerçekleştirilmiştir.

Bu alanın çalışma alanı seçilmesinde en büyük etken yeni bir baraj olması ve üzerinde yapılan çok çalışma bulunmamasıdır. Bu çalışma gelecekte yapılacak çalışmalara referans noktası olması açısından oldukça önemlidir. Yapılan yeni barajlarda gelecekte daha sağlıklı çalışmaların yapılabilmesi için ilgililerin barajlara ait verilerin depolaması konusunda gereken hassasiyeti göstermeleri önemlidir.

Baraj, Kocaeli ilinin hemen hemen 33 km kuzeyinde ve Kandıra ilçesinin de 4 km güneybatısında Namazgah Deresi üzerine kurulmuş olup, Kandıra ilçesi, Derince, Körfez ve İzmit ilçelerinin kuzey bölgeleri dahil olmak üzere 259 köy ve mahallenin su ihtiyacını karşılamak üzere tasarlanmıştır. Sadece su ihtiyacını karşılamak için değil ayrıca dere taşkını önlemesi, tarımsal sulama ve elektrik enerjisi üretimi de amaçlanan diğer faktörler arasındadır. Geçmişte baraj gölüne sahip olmayan Kandıra bölgesi su sıkıntısı çekmiştir. Namazgâh barajı su sıkıntısı çeken bölge için su teminini garanti altına almıştır.

Barajda 2013 yılında su tutulmaya başlanmış ve 2014 yılında ilk kez hanelere su dağıtma işlemi gerçekleştirilmiştir. Barajdan tesise 2014 yılında su verilmeye başlanmış olmakla birlikte baraj 34,5 m gövde yüksekliği, 504m kret uzunluğu ve 25 milyon m³ su depolama kapasitesine sahiptir. Baraj Hacılar ve Sarnıçlar dereleri tarafından beslenmektedir. Baraja ait genel yapı baraja ait numune alma noktaları 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 ve rüzgâr şiddetine ait günlük ölçümlerinin yanında, Kocaeli İsu Genel Müdürlüğünce ölçümü yapılan Namazgâh Barajına ait günlük buharlaşma verileri elde edilerek oluşturulmuştur. Modelleme süreci eksik verilerin tamamlanması ve buharlaşmanın tahmin aşaması olarak iki aşamadan oluşmaktadır. Meteoroloji genel müdürlüğünden alınan ilgili yıla ait havadaki su buharı verilerinin bir kısmı eksik ölçülmüş olduğundan öncelikle bu ölçümü eksik yapılmış olan bu verilerin tamamlanması için İBGYYSA modeli kurulmuştur. Eksik verilerin tamamlanması işleminden sonra, minimum sıcaklık, ortalama sıcaklık, havadaki su buharı değeri ve rüzgâr şiddeti giriş verisi olarak kullanılıp çıkış olarak

buharlaşma 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	Rüzgâr Şiddeti	308	1,7	41,5	7,279464	3,27158

Tablo 4.2. Tahminde kullanılacak buharlaşma verilerinin yapısı

	Veri Aralığı	Veri sayısı	X_(min)	X_(maks)	X_ort	S_x
Baraja Ait Buharlaşma: (m ³ /gün) -Ort	1.1.2016-12.31.2016	308	342,52565	21579,324	8333,4716	5325,9343
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. Eksik Veriler İçin YSA Tahmin Senaryoları

Hidrolojik çevrimin karmaşık problemlerinden biri de buharlaşma tahminidir. Problem birden fazla değişkene bağlı olduğu ve bölgesel olarak çokça farklılık arz ettiğinden dolayı buna yönelik modelleme tespiti yapmak doğal olarak zorlaşmaktadır. Buharlaşma güneş radyasyonu, sıcaklık, rüzgâr hızı, rölatif nem, atmosfer basıncı ve diğer çevresel koşullarla birlikte temel olarak iklimsel değişikliklerden ötürü meydana gelmektedir. Kontrol altında tutmak güç olduğundan dolayı doğrudan buharlaşma tavaları kullanılarak buharlaşma tahmini yapılmakla birlikte meteorolojik veriler yardımıyla da modelleme yapılabilmektedir.

Geliştirilen son modelleme tekniklerinden biri doğrusal olmayan problemlerin çözümünde sıkça tercih edilen YSA’lar olmuştur. YSA’lar hidrolojik çevrim içinde iklimsel değişkenliklere bağlı pek çok problemin çözümlene modeli olarak artık günümüzde sıkça kullanılmaktadır, kullanılmaya ve geliştirilmeye de devam etmektedir.

4.3.1. Giriş deęişkenlerinin belirlenmesi

Kurulacak bir YSA modeli için doęru girdi parametrelerinin belirlenmesinin önemi çok büyüktür. Problemi etkileyen pek çok faktör olduğundan dolayı doęru modelin tespiti zaman alabilmektedir. Minimum sıcaklık, ortalama sıcaklık, havadaki su buharı ve rüzgâr şiddetine ait günlük ölçümlerin giriş verisi olarak değerlendirilip Namazgâh Barajına ait günlük buharlaşma verileri çıkış olarak kullanılarak MATLAB programı yardımıyla YSA modellemesi yapılmıştır.

MATLAB programı yardımıyla oluşturulan modellerin birinci ayağını kurulan mimari oluştururken ikinci ayağı ise aęın eğitim ve test aşamalarıdır. Modelleme süreci döngüsü sırasıyla aşağıdaki gibidir:

1. Eldeki Verilerin Deęerlendirilmesi
2. Veri Gruplarının Oluşturulması
3. Veri Gruplarının Programa uygun hale getirilmesi
4. Modelin Belirlenmesi
5. YSA'nın Eğitimi
6. YSA'nın Test Edilmesi
7. YSA'nın Simule 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 ve rüzgâr şiddetine ait günlük ölçümlerinin yanında, Kocaeli İsu Genel Müdürlüğünce ölçümü yapılan Namazgâh Barajına ait günlük buharlaşma verileriyle oluşturulmuştur.

Elde edilen bu veriler deęerlendirildiğinde ölçümü eş zamanlı istenen giriş verilerinden su buharı verilerinin ilk üç aylık ölçümünün eksik yapıldığı tespit edilmiştir. Öncelikle eksik verilerin tespiti için bir YSA modeline ihtiyaç duyulduğu ortaya çıkmıştır. Verilere ait genel yapı Şekil 4.2'de gösterilmiştir.

Tablo 4.3. Verilere ait genel şema

	Min Sıcaklık(°C)	Ortalama Sıcaklık(°C)	Buhar Basıncı(hPa)	Rüzgâr Şiddeti(m/sn)	Buharlaşma (m ³ /gün)
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
18	-4,7	3,5	Eksik	5,9	80013,4031
19	-0,1	5,6	Eksik	6	96239,08866
20	2,8	7	Eksik	5,3	94258,93241
21	0,1	8,9	Eksik	7,4	85704,31273
22	6,1	13,1	Eksik	7,1	66025,62436
23	8,2	13,6	Eksik	9,9	52893,63603
24	10,6	17,1	Eksik	12,1	141701,815
25	7,1	9,1	Eksik	7,9	579556,6484
26	1,5	6,5	Eksik	9,7	775850,6312
27	-2,3	2,7	Eksik	7,3	201529,0168
28	1,6	5,9	Eksik	4,2	134892,7089
1	3,8	15	7	6,2	93623,12945
2	9,3	12,9	9,4	8,3	91071,98218
3	2,8	10,1	4,3	6,8	87520,00053
4	0,1	7,7	6	5,7	87058,53496
5	-0,7	9	5,3	5,2	86402,09039
6	0,8	11	6,4	5,6	81683,80156
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-
-	-	-	-	-	-

4.3.3. Veri gruplarının oluşturulması

Veri gruplarının oluşturulması öğrenme performansında doğrudan etkilidir. Ağ için veriler eğitim, test, onaylama verisi olarak sınıflandırılır. Sınıflandırma da en iyi performans için giriş ve çıkış verisi belirlenir. Çalışmada kurulan modellemelerde 4 giriş verisi bulunurken 1 tane de çıkış verisi mevcuttur:

- Öğrenme Kümesi: Girdi verilerine uygun olan ağırlıkların belirlendiği gruptur. Veriler arası ilişkinin çözüldüğü üzerinde öğrenmenin gerçekleştiği veri kümesidir.
- Onaylama Kümesi: Ağ topolojisinin belirlenmesi için uygun parametreleri belirleyen veri kümesidir. Ağ performansının bozulmaya başladığı noktada gerekli birim sayılarını belirlemede devreye girer. Hata düzeyinin minimum olduğu noktadaki ağı ve ilgili ağırlıkları kaydetme vazifesi görür.

- Test Kümesi: Sınıflandırılan bu veriler öğrenme aşamasında kullanılmaz. Sadece öğrenmenin ne oranda gerçekleştiğine dair bilgi almamızı sağlar. Ağa eğitim sürecinde gösterilmeyen gruptur.

Verilerin sınıflandırma işlemi hem ağ tarafından yapılabilirken hem de kişi programlar aracılığı ile kendisi de yapabilmektedir. Ağ tarafından belirlenen veriler genellikle rastgele seçilir ve bu çalışmada da eksik veri tamamlama aşamasında %70 eğitim, %15 test, %15 ise onaylama verisi olarak sınıflandırılırken, tahmin kısmı için bu dağılımda değişiklikler yapılmıştır. Veri kümesi sınıflandırma yüzdesi %70 öğrenme, %15 test, %15 onaylama olarak değerlendirilmiştir.

4.3.4. Verilerin programa uygun hale getirilmesi

YSA'lar çalışma prensibi rakamlara dayanmaktadır. Problem için eldeki örneklerin ağa tanıtılma aşaması büyük önem arz etmektedir. Çünkü bazen probleme dair numerik olmayan faktörlerde çözüm için etkili olabilmektedir. Dolayısıyla bunların da sayı ile ifade edilmesi gerekmektedir. Dolayısıyla dönüştürme işlemi hem çıktı ve hem girdilere uygulanırsa bu ağın performansı açısından olumlu bir etkide bulunur. Girdiye uygulanıp çıktıya uygulanmazsa dönüşüm ağın çıktısı ile gerçek çıktı arasındaki hata tespiti mümkün olamamaktadır. Dolayısıyla çözümü gereken problemler için bu faktör göz önünde bulundurulmalıdır.

Hedeflediğimiz değerlerin kurulacak ağ modelinin çıktısı ile aynı aralıkta olması gerekmektedir. Bundan dolayı verilerin programın kullanımına uygun hale getirilmesi şarttır. Dolayısıyla bu işlem hem girdiler üzerine hem de çıktılar üzerine yapılan normalleştirme işlemiyle gerçekleştirilir. Normalleştirme işlemi için farklı yaklaşımlar bulunmaktadır. Bunlardan bazıları aşağıda verilmiştir.

- Doğrusal Dönüşüm: Verileri [0-1] aralığında normalleştirmektedir. 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 sade Normalizasyon şeklidir denilebilir bu dönüşüme ait denklem Denklem (4.3)'te verildiği gibidir [1];

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

- İstatiksel Normalizasyon: Veri normalleştirilmesinde istatistiksel bilgilerden de faydalanılır ve normalizasyonda kullanılan denklem Denklem (4.4)'te verildiği şekilde olur [1];

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

X_n : Normalleştirilmiş veri

X_0 : Gerçek veri değeri

X_{\max} : Normalleştirilecek Verinin maksimum değeri

X_{\min} : Normalleştirilecek verinin minimum değeri

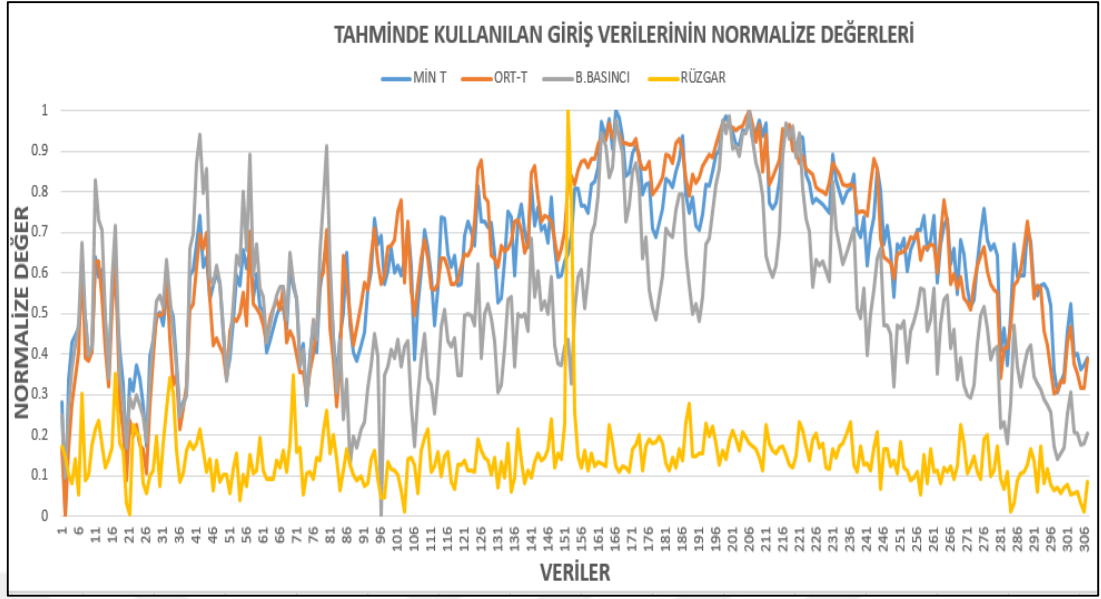
\bar{X} : Normalleştirilecek verilerin ortalaması

S: Normalizasyon verilerinin standart sapması

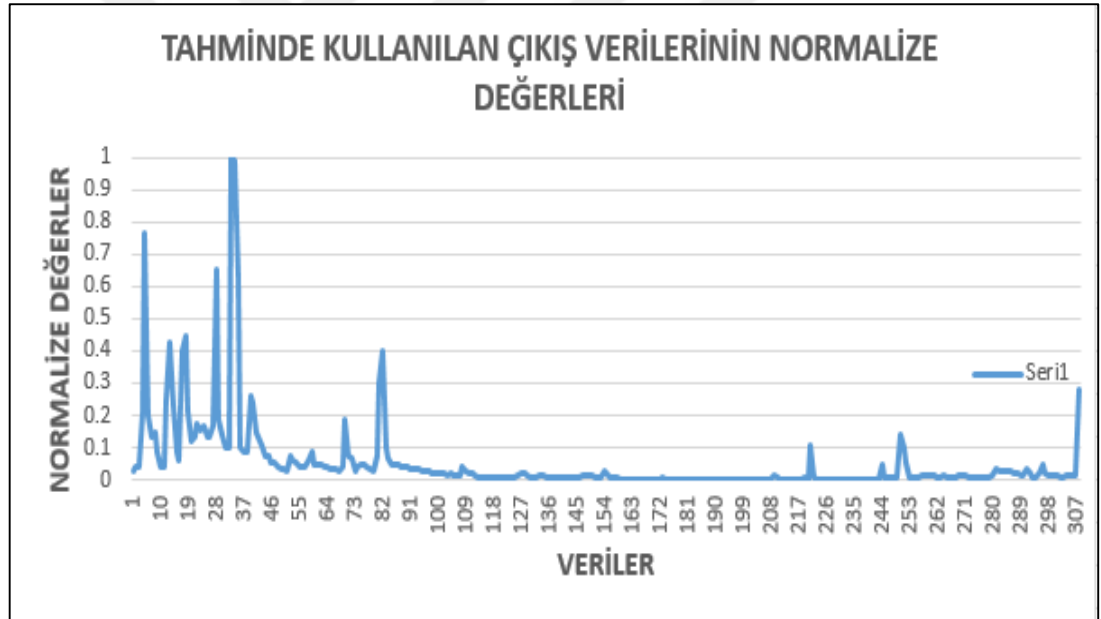
Çalışmada verileri [0-1] aralığında normalleştirilen doğrusal dönüşüm formülü kullanılır ve bu dönüşümde kullanılan denklemin matematiksel ifadesi Denklem (4.5) ile verildiği şekilde olur [1];

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

Çalışmada tahmin için kullanılacak giriş verilerinin normalize edilmiş değerleri aşağıda Şekil 4.2 ile gösterilirken, Şekil 4.3'te ise tahminde kullanılan çıkış veri grubunun boyutsuz hali gösterilmiştir.



Şekil 4.2. Tahminde kullanılan girdi veri gruplarının boyutsuz hali



Şekil 4.3. Tahminde kullanılan çıkış veri gruplarının boyutsuz hali

4.3.5. Modelin belirlenmesi

Model belirleme işlemi mimari tasarım ve ağ özelliklerini belirleme aşamalarından oluşmaktadır. Öncelikle mimari de kullanılacak gizli katman sayısı ve burada dikkate alınacak nöronlar belirlenmektedir. Belirlenen bu mimarinin doğru işlevi için ağ özelliklerini de belirlemek gerekmektedir. Bu da aktivasyon fonksiyonu ve hata fonksiyonlarının doğru tercihiyle çözülmektedir. Bir diğer faktör ise uygunluk ölçütleri, ağın deneme sayısı ile birlikte belirlenen iterasyon sayısı olmaktadır.

Analiz edilip programa uygun hale getirilen verilere uygun mimari tasarımı bu faktörlere dikkat edilecek şekilde gerçekleştirilmiştir.

Programın hesapladığı uygunluk ölçütlerinden aşağıdaki faktörler dikkate alınarak değerlendirme yapılmıştır:

- Test Örnek Uzayı İçin Hesaplanan Hata: Test verisi için hesaplanan ortalama mutlak hataya bakılır bu değer sığra ne kadar yakınsa tasarlanan ağ mimarisi o kadar güçlü ve kaliteli demektir.
- Öğrenme Örnek Uzayı İçin Hesaplanan Hata: Öğrenme veri kümesi için ortalama mutlak hataya bakılır, değerlendirme için sığra yakınlık önemli faktördür.
- Sorgulama Örnek Uzayı İçin Hesaplanan Hata: İlgili verinin ortalama mutlak hatasına bakılır değerlendirme test ve öğrenme durumlarına benzerdir yani sığra yakınlık önemlidir.
- Belirlilik Katsayısı: R^2 diye de ifade edilmektedir. 1 yakın değer alması önemlidir, 1'e yakın olması mimarinin kaliteli olduğunu gösterir.

Sahip olunan veri ölçüsünde YSA'da öğrenme gerçekleştiğinden dolayı su buharı verilerinde eksik ölçümlerin yöntem yardımıyla tamamlanıp veri setinin daha geniş kapsamlı olması amacıyla 2016 yılına ait ilk üç aylık su buharına ait ölçümler eksik verildiğinden eksik verileri tamamlama yoluna gidilmiştir.

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

Veriler arası doğrusal olmayan bir ilişki mevcut olduğu için hatayı minimize etmede diğer ağlardan daha tercih edilebilir olduğundan ileri beslemeli geri yayımlı çok katmanlı bir ağ üzerinden probleme çözüm bulunmak istenmiştir.

Su buharı verilerine ait 2017 yılının 12 aylık ölçümü tam olan veriler üzerinden model kurulmaya çalışılmıştır.

Girdi değişkenleri olarak minimum ve ortalama sıcaklık belirlenirken çıktı parametresi su buharı basıncı verilmiştir. Veriler %70 Eğitim, %15 onaylama ve %15 test verisi olarak sınırlandırılmıştır.

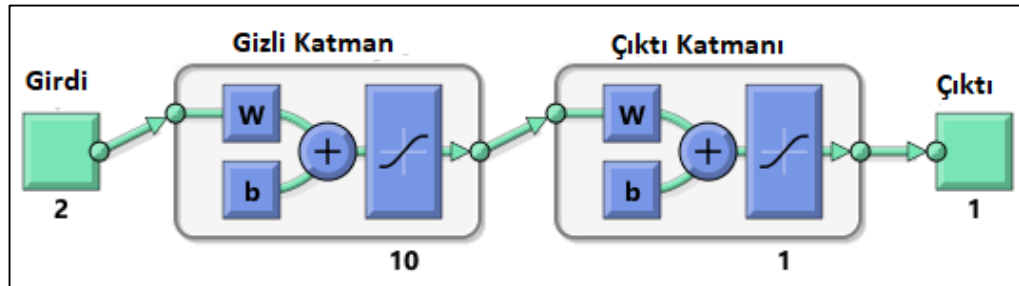
Bir tane gizli katman kullanılıp gizli katmana uygun nöron sayısı 1-15 arasında deneme yanılma ile tespit edilmiş. Kurulan modeller içinde başarılı performans

sahip model tespit edilirken MSE değerinin sıfıra R^2 değerininse 1 yakın olması istenir.

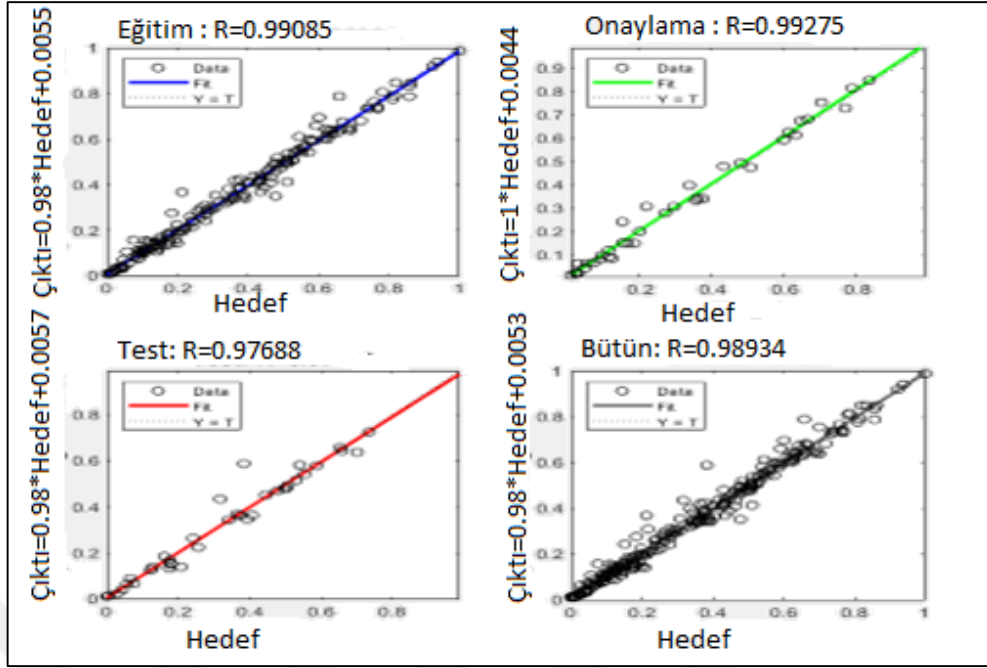
R^2 değerlerinin birbirine yakın olması tutarlı bir sonuca sahip bir model olduğunu göstermektedir, birbirine uzak R^2 değerlerinde ise tersi durum söz konusudur. Tablo 4.4'te 2017 verileri için tasarlanan ağ parametreleri yer alırken, 2017 verileri için en iyi performansı veren ağ mimarisi, model davranışı, deneysel hata düzeyi, model çıktısı ve hedef değer karşılaştırması, tahmin edilen ve gerçek buhar basıncı değerlerinin karşılaştırılması, tahmin ve gerçek değer arası korelasyon katsayısı sırasıyla Şekil 4.4'de Şekil 4.8'e kadar gösterilmektedir.

Tablo 4.4. 2017 verileri için tasarlanan ağın eğitim parametreleri

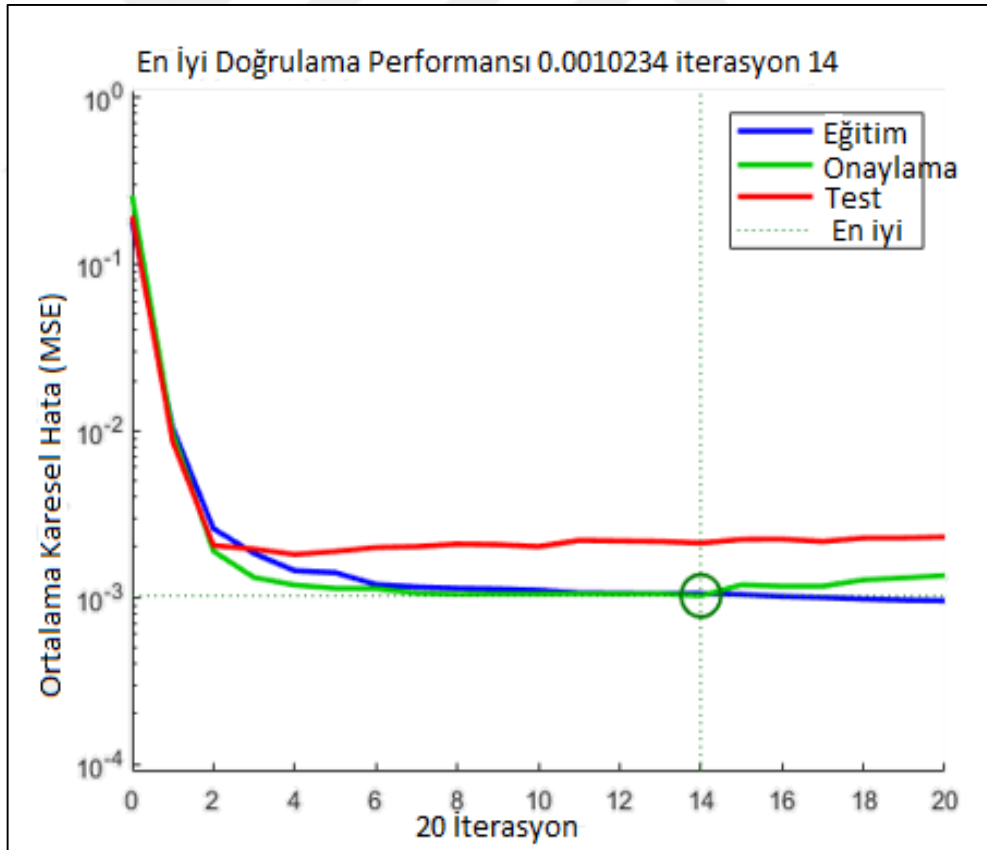
Parametre	Değer
Saklı katman sayısı	1
Saklı katman nöron sayısı	10
İterasyon sayısı	1000
Girdi-çıkıtı	2-1
Öğrenme katsayısı	0,001
Momentum Katsayısı	0,1
Veri seçimi	Random
Öğrenme Algoritması	Levenberg-Marquardt
Performans	Mean squared Error (MSE)
Aktivasyon Fonksiyonu	Tanjant hiperbolik, sigmoid




Şekil 4.4. Tasarlanan çok katmanlı ağ mimarisi



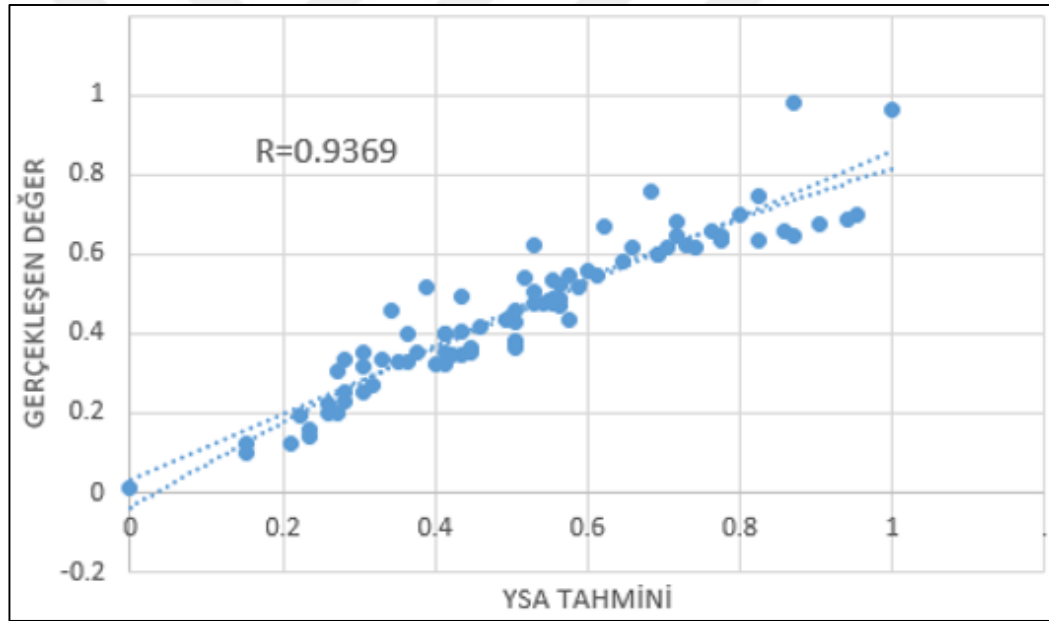
Şekil 4.5. Model davranışı grafiği



Şekil 4.6. Deneysel hata düzeyi grafiği



Şekil 4.7. Modelin tahmini ve gerçekleşen buhar basıncı karşılaştırma grafiği

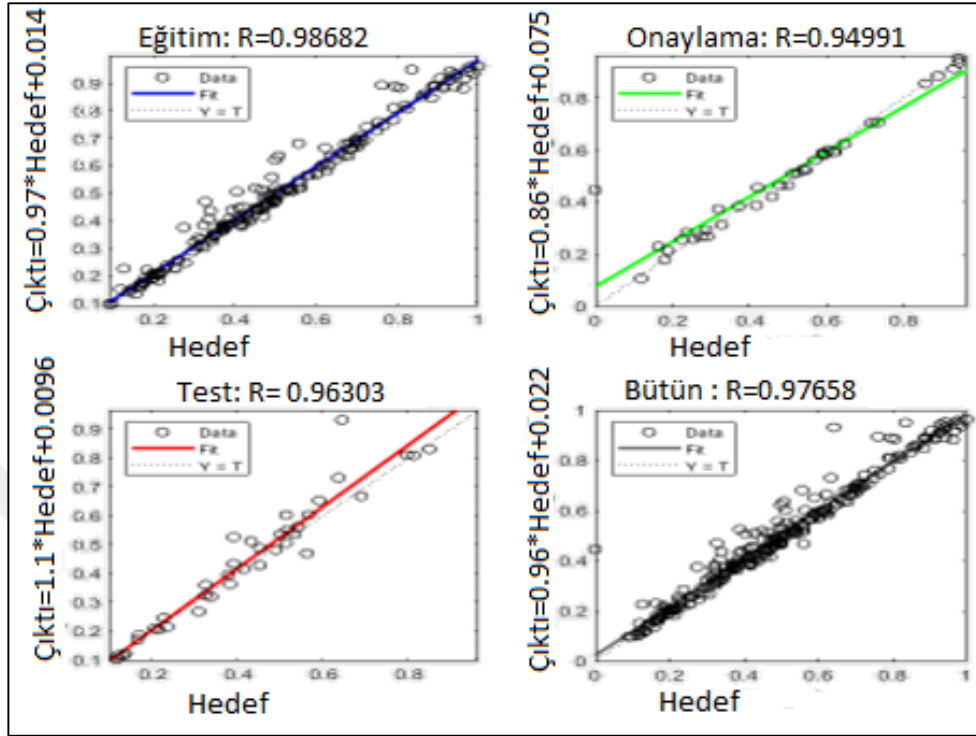


Şekil 4.8. İBGYYSA ile tahmin edilen buhar basıncı ve gerçekleşen buhar basıncı grafiği

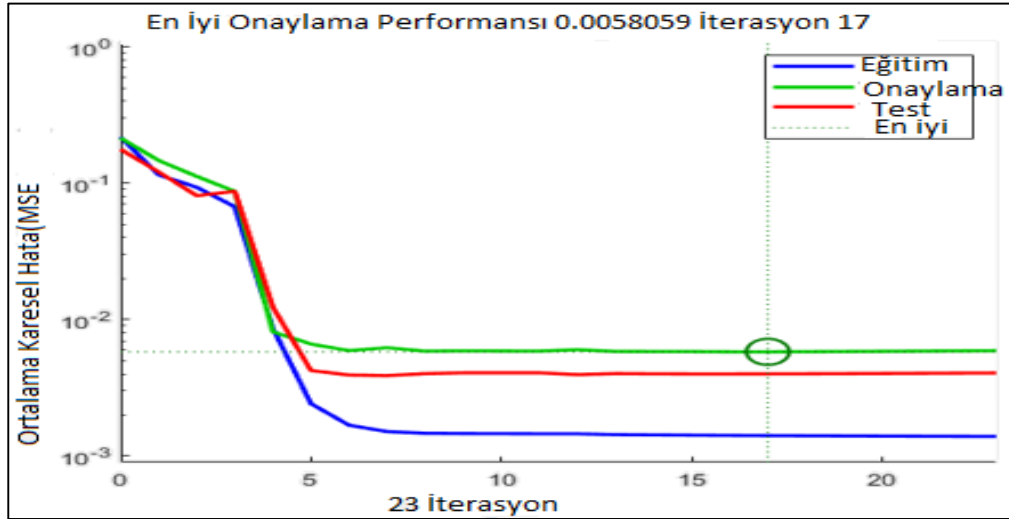
4.3.7. Eksik verilerin tamamlanması

2017 verilerine dair analiz sonuçları değerlendirildiğinde hata düzeyinin 10^{-3} 'e kadar azaltıldığı görülmektedir. Ağın performansı tatminkâr olduğundan dolayı aynı işlemi 2016 verileri için uygulamakta sakınca görülmemektedir. Aynı işlem 2016 verilerine uygulandığında ağ parametreleri aynı olmak şartıyla elde edilen sonuçlar aşağıda verilmiştir. Model davranışı performans değerleri Şekil 4.9'da, deneysel hata grafiği

Şekil 4.10'da, 2016 yılına ait YSA'da tahmin edilen eksik verilerin grafiği Şekil 4.11 ile gösterilmektedir.



Şekil 4.9. Ağın model davranışı performans değeri



Şekil 4.10. Deneysel hata grafiği




Şekil 4.11. 2016 yılına ait İBGYYSA ile tahmin edilen 82 günlük buhar basıncı değerleri grafiği

YSA' nın temel amacı tecrübelerden faydalanıp daha önce görmediği mevcut veriye çıktı sunabilmektir. Bu özellikten faydalanıp eldeki veriler yardımıyla eksik veriler tamamlanmış ve YSA'nın az girdi parametresiyle dahi genelleme yapabilme özelliği bir kez daha ortaya konulmuştur. Modellemenin ikinci aşaması tamamlanmış verilerle kurulmuş ve buharlaşma tahmini zaman serisi analiziyle YSA' da modellenmiştir.

4.3.8. Buharlaşma tahmini için kurulan yapay sinir ağı modelleri

Veri depolama öğrenmeyi gerçekleştirmenin ilk şartlarından biridir. Ağın öğrenmesinde kullanılacak veri setinin yeterli olması çok önem taşımaktadır. Aksi takdirde öğrenme gerçekleşmediğinden ağın doğru çıktı vermesi de beklenmemelidir. Aynı zaman da dikkat edilmesi gereken bir diğer husus doğru parametre tercihidir. Doğru parametre tercihi ile modelleme de kullanılan özellik sayısı azaltılıp basit model kurulabilir. Yapılan doğru parametre tercihi ile veri setinin karmaşıklığı da önlenmiş olmaktadır.

Basit modelden kasıt özellik sayısını azaltmaktan ibarettir. Bu çalışma da buharlaşmaya sebep olan parametreler dikkate alınarak mevcut veri yardımıyla zaman serisi de göz önünde bulundurularak basit bir model kurulmuştur. Modelleme de kullanılan girdi ve çıktı parametreleri aşağıda Şekil 4.12 ile verilmiştir.



Şekil 4.12. Modelde kullanılan girdi ve çıktı veri gruplarının normalize değerleri

Çalışma da minimum sıcaklık, ortalama sıcaklık, rüzgâr şiddeti ve buhar basıncına bağlı buharlaşma tahmini yapılmak istenmiştir. Bu beş parametreye ait toplamda 1540 veri işleme konulmuştur. Bu verilerin %75'i öğrenme, %20 test, %5 onaylama verisi olarak ayrılmıştır.

Veriler sınıflandırılmadan önce veriyi [0-1] arasına indirgeyen doğrusal dönüşüm normalizasyon işlemi uygulanmıştır. MATLAB programına uygun hale getirilen bu veriler minimum sıcaklık, ortalama sıcaklık, rüzgâr şiddeti, buhar basıncı giriş verisi olarak tanımlanmıştır ağa çıkış olarakta buharlaşma verilmiştir.

Bir gizli katman belirlenip deneme yanılma yoluyla gizli katmanda olması gereken nöron sayısı tespit edilmeye çalışılmıştır. Öğrenme algoritması belirlenirken 3 farklı algoritma üzerinde çalışılmıştır. Bunlar sırasıyla LM, Bayesian Regularization, Scaled Conjugate Gradient öğrenme algoritmalarıdır. Bu öğrenme algoritmaları için farklı nöron sayısı denenerek hangi algoritmanın daha iyi sonuç verebildiği tespit edilmeye çalışılmıştır. Sırasıyla 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 4.5. Bayesian Regularization öğrenme algoritmasıyla elde edilen sonuçlar

Model	GK-NS	Eğitim R ²	Test R ²	Eğitim MSE	Test MSE
1	5	9,7774e ⁻¹	4,2789e ⁻¹	5,7568e ⁻⁴	2,1307e ⁻³
2	10	9,9691e ⁻¹	1,1039e ⁻¹	1,0372e ⁻⁴	2,7260e ⁻²
3	15	9,9915e ⁻¹	8,5247e ⁻¹	2,9355e ⁻⁵	2,0305e ⁻¹
4	20	9,9991e ⁻¹	1,8550e ⁻¹	2,4543e ⁻⁶	5,6022e ⁻²
5	25	9,9951e ⁻¹	7,5331e ⁻¹	7,1669e ⁻⁹	6,1608e ⁻²

Tablo 4.6. Scaled Conjugate Gradient öğrenme algoritmasıyla elde edilen sonuçlar

Model	GK-NS	Eğitim R ²	Onaylama R ²	Test R ²	Eğitim MSE	Onaylama MSE	Test MSE
1	5	7,6980e ⁻¹	7,9556e ⁻¹	5,8126e ⁻¹	7,1789e ⁻³	1,1663e ⁻³	1,0705e ⁻²
2	10	8,6050e ⁻¹	8,6050e ⁻¹	5,2113e ⁻¹	8,4924e ⁻³	1,6331e ⁻³	6,7604e ⁻³
3	15	2,2684e ⁻¹	2,2684e ⁻¹	8,8783e ⁻²	4,6868e ⁻³	2,3125e ⁻²	6,7209e ⁻³
4	20	3,9168e ⁻¹	3,9168e ⁻¹	5,7329e ⁻¹	1,5664e ⁻³	1,8800e ⁻²	2,0737e ⁻²
5	25	8,0047e ⁻¹	8,0047e ⁻¹	2,8564e ⁻¹	8,5962e ⁻³	1,3234e ⁻²	1,3425e ⁻²

Tablo 4.7. Levenberg- Marquardt öğrenme algoritmasıyla elde edilen sonuçları

Model	GK-NS	Eğitim R ²	Onaylama R ²	Test R ²	Eğitim MSE	Onaylama MSE	Test MSE
1	5	8,2070e ⁻¹	9,7535e ⁻¹	8,00e ⁻¹	4,7303e ⁻³	7,8218e ⁻⁴	5,3400e ⁻³
2	10	9,8635e ⁻¹	9,7298e ⁻¹	9,1864e ⁻¹	5,4174e ⁻⁴	1,6331e ⁻⁴	1,7090e ⁻³
3	15	8,1776e ⁻¹	7,0690e ⁻¹	9,6501e ⁻²	5,7542e ⁻³	2,3125e ⁻³	1,3760e ⁻³
4	20	9,8304e ⁻¹	5,0945e ⁻¹	7,8474e ⁻¹	4,4838e ⁻⁴	1,8800e ⁻²	1,2793e ⁻²
5	25	8,4918e ⁻¹	8,1136e ⁻¹	7,7342e ⁻¹	4,3400e ⁻³	1,3234e ⁻³	6,2188e ⁻³

Öğrenme algoritmalarının aynı probleme uyarlandığından verdiği sonuçlar karşılaştırıldığında Bayesian Regularization Öğrenme Algoritmasının her ne kadar eğitim verileri için vermiş olduğu yüzde yüksek gibi görünse de test verileri için verdiği yüzde düşük olmuştur. Bu da öğrenmeden ziyade veriye uymuş olduğunu göstermektedir. LM Öğrenme Algoritması sonuçlarının hem eğitim hem de test verileri için daha tutarlı sonuçlar verdiği görülmektedir. LM öğrenme algoritması kullanılarak gizli katmanda bulunan nöron sayısı 10 olduğu zaman başarı eğitim, onaylama ve test verileri için %90 üzeri olduğu görülmüştür. LM öğrenme algoritmasının avantajlarından biri genelleme olayı azalmaya başladığında eğitim kendiliğinden durdurulur. Örnek uzayı için ortalama karesel hata artmaya başlıyorsa bu da durdurulma sinyallerinden biri olmaktadır. Bu algoritma hem zaman serisi analizlerinde hem de doğrusal olmayan ilişkilerin çözümlenmesinde tercih edildiğinde başarılı sonuçlar verebilir.

Modellemede zaman serisine dayanan geri besleme gecikmesine sahip NARX modeli tercih edilmiştir. Modelleme de diğerlerine kıyasla daha iyi sonuç verdiği için

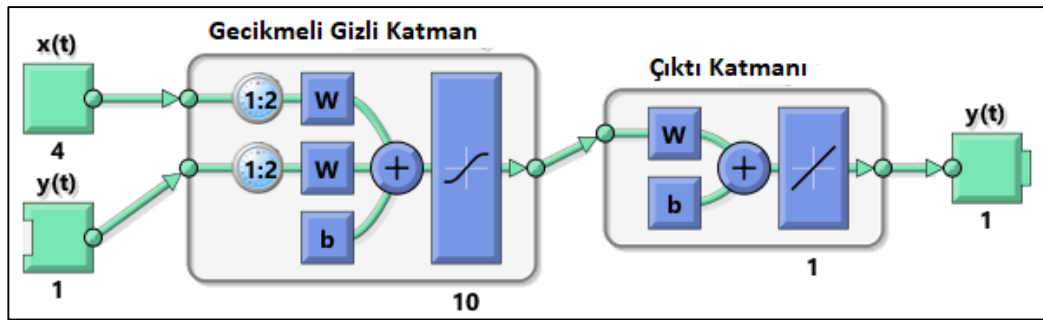
LM öğrenme algoritması tercih edilmiştir. Gizli katmanda bulunması gereken nöron sayısı belirlilik katsayısı ve hata kareler ortalaması dikkate alınarak en iyi performansı veren modelde nöron sayısı 10 olarak belirlenmiştir.

Kurulan farklı modellemeler için alınan sonuçlar Tablo 4.8'de gösterilmiştir:


Tablo 4.8. YSA tahmin modellerinden alınan sonuçlar

GK NS	Geri Besleme Gecikmesi	Eğitim MSE	Test MSE	Eğitim R ²	Onaylama R ²	Test R ²
1	1:2	7,26314e ⁻³	2,9359e ⁻³	0,741434	0,827013	0,815327
2	1:2	2,39231e ⁻³	9,4446e ⁻³	0,787275	0,729863	0,855551
3	1:2	2,38713e ⁻³	9,33184e ⁻³	0,738067	0,800042	0,523470
4	1:2	4,41508e ⁻³	9,19651e ⁻³	0,857438	0,770530	0,389281
5	1:2	7,9925e ⁻³	8,8908e ⁻³	0,786249	0,777986	0,735708
6	1:2	4,2898e ⁻³	6,6294e ⁻³	0,799690	0,937062	0,775456
7	1:2	4,8496e ⁻³	7,1972e ⁻³	0,814350	0,356219	0,688434
8	1:2	6,2783e ⁻³	4,7497e ⁻³	0,799019	0,798475	0,678181
9	1:2	7,1609e ⁻³	1,0632e ⁻³	0,785112	0,867909	0,718772
10	1:2	1,7090e ⁻³	5,4174e ⁻⁴	0,98635	0,972980	0,91864
11	1:2	5,5649e ⁻³	4,6144e ⁻³	0,817171	0,914418	0,818204
12	1:2	4,3163e ⁻³	2,3923e ⁻³	0,833435	0,956620	0,713634
13	1:2	8,6594e ⁻³	9,3318e ⁻³	0,709923	0,949961	0,742316
14	1:2	5,5186e ⁻³	1,6940e ⁻³	0,814735	0,973673	0,813587
15	1:2	4,9730e ⁻³	8,8908e ⁻³	0,849920	0,816710	0,674590
16	1:2	7,9770e ⁻³	6,6294e ⁻³	0,771636	0,92647	0,77032
17	1:2	5,8771e ⁻³	7,1972e ⁻³	0,765328	0,834021	0,780337
18	1:2	5,4289e ⁻³	4,7497e ⁻³	0,846221	0,591061	0,744151
19	1:2	2,90028e ⁻³	1,0632e ⁻³	0,907917	0,442625	0,477076
20	1:2	3,6770e ⁻³	6,8008e ⁻³	0,890327	0,42543	0,42543


En iyi performansı sergileyen modele ait Şekil 4.14'te mimari, Şekil 4.15'te hedef değer ve çıktının karşılaştırılması, Şekil 4.16'da deneysel hata grafiği görülmektedir.



Şekil 4.13. Buharlaşma tahmini için en iyi performansı veren modelin mimarisini



Şekil 4.14. Günlük buharlaşma tahmini için en iyi performansı veren modelin çıktısı ve hedef değer grafiği



Şekil 4.15. Buharlaşma tahmini için en iyi performansı veren modelin deneysel hata grafiği

5. SONUÇLAR VE ÖNERİLER

Çalışmada kullanılan veriler arasında doğrusal olmayan bir ilişki mevcut olduğundan problem çözümü için İBGYYSA modelleri denenmiştir. Doğrusal olmayan ilişkiler çok katmanlı YSA'lar yardımıyla doğru aktivasyon fonksiyonları tercih edilerek kolayca çözümlenebilir. Yapılan çalışmada YSA'lar kullanılarak İBGYYSA ile eksik veriler tamamlanmış ve buharlaşma tahmini için YSA'nın uygulanabilirliği irdelenmiştir. Tahmin için birinci aşama öncelikle YSA yöntemi kullanılarak eksik buhar basıncı verileri sıcaklığa bağlı olarak tahmin edilmeye çalışılmıştır. Eksik veriler İBGYYSA modeliyle uygun parametreler kullanılarak tahmin edilmiştir. Eksik verilerin tamamlanması için bir gizli katmana sahip YSA mimarisinin problemi çözmek için yeterli olduğu belirlenmiştir. Saklı katmanda bulunan nöron sayısı deneme yanılma yoluyla belirlenirken öğrenme katsayısı deneme yanılma ile 0,001 olarak belirlenmiştir. İkinci aşama da minimum sıcaklık, ortalama sıcaklık, rüzgâr şiddeti, buhar basıncı giriş verisi olarak kullanılıp çıkışa ise buharlaşma verilmiştir. Veri yapılarındaki karmaşıklığın çözümlenebilmesi için YSA'lar herhangi bir ön bilgiye ihtiyaç duymamaktadır. Yapay sinir ağlarında veri kaybı yaşanmamaktadır bu da problem çözümü için büyük avantajdır. Ağ yapısının esnekliği veri uyumunu çözmekte ayrıca avantaj sağlamaktadır. Bu yüzden modellemeler oldukça başarılı sonuçlar vermiştir. Buharlaşma miktarı tahmini için zaman serisi analiziyle uygun bir YSA modelinin tespit edilmesi aşamasıdır. Zaman serisi analizi ile tasarlanan bir modelde buharlaşma tahmini için problem NARX modeliyle çözümlenmiştir. Problem de eğitim, onaylama ve test kümelerine ait yapının model performansı açısından önemi büyüktür. Bu çalışmada veri sınıflandırması rastgele yapılmış ve model davranışları analize tabi tutulmuştur. Tahmin modellerinin sonuçları hata kareler ortalaması MSE ve R^2 dikkate alınarak değerlendirilmiştir. MSE'nin sıfıra yakınlığı R^2 'nin ise 1 yakınlığı değerlendirme ölçütü olarak dikkate alınmıştır. Elde edilen sonuçlar değerlendirildiğinde en iyi performansı veren ağın girdi katmanı, saklı katman, çıktı katmanı olmak üzere üç katmandan oluştuğu ve YSA'nın 10 nörona sahip olan geri besleme gecikmeli çok katmanlı ağ modeli olduğu tespit edilmiştir. LM öğrenme algoritmasının buharlaşma

tahmininde rahatlıkla kullanılabileceđi görülmüştür. Hidrolojik çevrim problemlerinde özellikle zaman serisi analizleri söz konusu olduğunda diğer algoritmalara nazaran daha iyi sonuçlar verdiğiinden LM öğrenme algoritması tercih edilebilir. Verilerin depolanması çalışmalar açısından çok önemli olmaktadır. Gelecekteki çalışmalar adına daha tutarlı sonuçlar elde edebilmek için ilgililere verilerin depolanması konusunda daha hassas davranmaları gerekmektedir. Daha geniş bir veri seti olduğunda bu modellemenin buharlaşma tahmini için daha iyi sonuçlar verebileceđi kanısına varılmıştır. Yeterli ve sağlıklı veri olduğunda ileriki çalışmalarda buharlaşma tahmini için NARX modeli çözüm üretmede kullanılabilir.



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] Jensen R. D., Burman R. G., Allen Evapotranspiration and Irrigation Water Requirements, ASCE Manual 70, ASCE, New York, 1990, 332.
- [6] Burman R., Pochop L. O., Evaporation. Evapotranspiration and Climatic Data, Development in Atmospheric Science, *Elsevier*, 1994, **22**, 278.
- [7] Doğan E., Işık S., Sapanca Gölü Günlük Buharlaşma Miktarının Radyal Temelli Yapay Sinir Ağı Modeli Kullanılarak Tahmin Edilmesi, *Bilimde Modern Yöntemler Sempozyumu*, Kocaeli, Türkiye, 16-18 Kasım 2005.
- [8] Üneş F., Dam Reservoir Level Modeling by Neural Network Approach: A Casestudy, *Neural Network World*, 2010, **4**(10), 461–474.
- [9] Singh R. K., Pawar P. S., Comparative Study of Reference Crop Evapotranspiration (ETO) by Different Energy Based Method with FAO 56 Penman-Monteith Method at New Delhi, *Indian Institutes of Engineering Science and Technology*, 2011, **3**, 7861–7868.
- [10] Gümüş V., Şimşek O., Soydan N. G., Aköz M. S., Yenigün K., Adana İstasyonunda Buharlaşmanın Farklı Yapay Zeka Yöntemleri ile Tahmini, *Dicle Üniversitesi Mühendislik Dergisi*, 2016, **7**(2), 309-318.
- [11] Aksu H., Arıkan A., Satellite-Based Estimation of Actual Evapotranspiration in the Büyük Menderes Basin, *Hydrology Research*, 2017, **48**(2), 559-570.
- [12] Köksal E. S., Çetin S., Demir A. O., Tunca E., Candoğan B. N., Aslan Ş. T., Bursa Karacabey Ovasında Son 25 Yılda Değişen Bitkisel Üretim Deseni ve Sulama Uygulamalarının Uzaktan Algılama ve ET Haritalama Tekniği ile Değerlendirilmesi, *Bursa Uludağ Üniversitesi Ziraat Fakültesi Dergisi*, 2018, **32**(2), 31-43.

- [13] Özel A., Meteorolojik Verileri Kullanarak Aylık Tava Buharlaşmasını Tahmin Etmek için Yapay Zeka Metotlarının Uygulanması, Yüksek Lisans Tezi, Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Konya, 2018, 522348.
- [14] Doğan E., Suspended Sediment Load Estimation in Lower Sakarya River By Using Artificial Neural Networks, Fuzzy Logic and Neuro-Fuzzy Models, *Electronic Letters on Science&Engineering*, 2005, **1**, 22-32.
- [15] Doğan E., Sasal M. Işık S., Suspended Sediment Load Estimation in Lower Sakarya River by Using Soft Computational Methods, *Proceeding of the International Conference on Computational and Mathematical Methods in Science and Engineering*, Alicante, Spain, 27-30 June 2005.
- [16] Öztemel E., Yapay Sinir Ağları, 4. Baskı, Papatya Yayıncılık Eğitim, İstanbul, 2016
- [17] Govindaraju R. S., Rao R. A., Radial-Basis Function Networks, Editors: Govindaraju R. S., Rao R. A., *Artificial Neural Networks in Hydrology*, 2nd ed., Springer, Dordrecht, 93-109, 2000.
- [18] Sudheer P. K., Gosain A. K., Mohana R. D., Saheb S. M., Modeling Evaporation Using an Artificial Neural Network Algorithm, *Hydrological Process*, 2002, **16**, 3189-3202.
- [19] Terzi Ö., Keskin E. M., Yapay Sinir Ağları Yaklaşımı Kullanarak Günlük Tava Buharlaşması Tayini, *İMO Teknik Dergi*, 2005, **16**(79), 3683-3693.
- [20] Terzi Ö., Keskin E. M., Modelling Daily Pan Evaporation, *Journal Applied Science*, 2005, **5**(2) 368-372.
- [21] Kişi Ö., Yapay Sinir Ağları ile Meteorolojik Verileri Kullanarak Buharlaşmanın Modellenmesi, *Bilimde Modern Yöntemler Sempozyumu*, Kocaeli, Türkiye, 16-18 Kasım 2005.
- [22] Doğan E., Işık S., Sapanca Gölü Günlük Buharlaşma Miktarının Radyal Temelli Yapay Sinir Ağı Modeli Kullanılarak Tahmin Edilmesi, *Bilimde Modern Yöntemler Sempozyumu*, Kocaeli, Türkiye, 16-18 Kasım 2005.
- [23] Doğan E., Işık S., Sandalcı M., *Evaporation, Evapotranspiration and Climatic Data, Development in Atmospheric Science*, 22nd ed., Elsevier Science, Amsterdam, 1994.
- [24] Sağıroğlu Ş., Beşdok E., Erler M., *Mühendislikte Yapay Zeka Uygulamaları-1/Yapay Sinir Ağları*, 1. Baskı, Ufuk Kitap, Kayseri, 2003.
- [25] Segal R., Kothari M. L., Shekhar Madnani, Radial Basis Function (RBF) Network Adaptive Power System Stabilizer, *IEEE Transactions Power Systems*, 2000, **15**(2), 722-727.

- [26] Szczurek A., Maciejewska M., Recognition of Benzene, Toluene and Xylene Using TGS Array Integrated with Linear And Non-Linear Classifier, *Talanta*, 2004, **64**, 609–617.
- [27] MATLAB, *MATLAB Documentation Neural Network Toolbox Help, Version 7.0*, Release 14, The MathWorks Inc., 2004.
- [28] Haykin S., *Neural Networks: a Comprehensive Foundation*, 2nd ed., London: Prince Hall, 1999.
- [29] Abtew W., Evaporation Estimation for Lake Okeechobee in South Florida, *Journal of Irrigation and Drainage Engineering*, 2001, **127**(3), 140-147.
- [30] 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.
- [31] <http://www.derinogrenme.com/2017.03.04/yapay-sinir-aglari> (Ziyaret tarihi: 4 Mart 2017).
- [32] <http://www.biyolojidefteri.com/index.php/insanda-sinir-hucres> (Ziyaret tarihi: 16 Nisan 2019).
- [33] <https://medium.com/2019.4.14/aktivasyonfonksiyonlari> (Ziyaret tarihi: 14 Nisan 2019).
- [34] <https://www.psikolojik.gen.tr/yapay-sinir-aglari.html> (Ziyaret tarihi: 5 Nisan 2018).
- [35] <https://industryolog.com/matlab-egitimleri-4-artis-duzenleme/> (Ziyaret tarihi: 16 Nisan 2019).
- [36] <https://www.hostingdergi.com.tr/yapay-zeka-ve-sinir-aglari/> (Ziyaret tarihi: 16 Nisan 2019).
- [37] <https://slideplayer.biz.tr/slide/2460585/> (Ziyaret tarihi: 15 Nisan 2019).
- [38] <http://kod5.org/yapay-sinir-aglari-ysa-nedir/> (Ziyaret tarihi: 03 Mart 2018).

ÖZGEÇMİŞ

1991 yılında Erzurum'da doğdu. İlk ve ortaöğrenimini Erzurum- Horasan Mümtaz Turhan İlköğretim Okulu'nda lise eğitimini ise Erzincan Milliyet Anadolu Öğretmen Lisesi'nde tamamladı. Pamukkale Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği Bölümü'nü 2016 yılında bitirerek İnşaat Mühendisi unvanını aldı. 2017 yılında Kocaeli Üniversitesi Fen Bilimleri Enstitüsü'nde Yüksek Lisans programına başladı.

