

**DOĞANCI BARAJI'NDA METEOROLOJİK VERİLER  
İLE SU KALİTESİ VE SU SEVİYESİ ARASINDAKİ  
İLİŞKİNİN YAPAY SİNİR AĞLARI İLE  
MODELLENMESİ**

**Asifa ANWAR**



T.C.  
BURSA ULUDAĞ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

**DOĞANCI BARAJI'NDA METEOROLOJİK VERİLER İLE SU KALİTESİ VE SU  
SEVİYESİ ARASINDAKİ İLİŞKİNİN YAPAY SİNİR AĞLARI İLE  
MODELENMESİ**

Asifa ANWAR  
0000-0002-3317-2816

Doç. Dr. Aslıhan KATİP  
(Danışman)

YÜKSEK LİSANS TEZİ  
ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI

BURSA– 2023  
**Her Hakkı Saklıdır.**

## TEZ ONAYI

Asifa ANWAR tarafından hazırlanan “Doğancı Barajı’nda Meteorolojik Veriler ile Su Kalitesi ve Su Seviyesi Arasındaki İlişkinin Yapay Sınır Ağları ile Modellenmesi” adlı tez çalışması aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Uludağ Üniversitesi Fen Bilimleri Enstitüsü Çevre Mühendisliği Anabilim Dalı’nda Yüksek Lisans Tezi olarak kabul edilmiştir.

<b>Danışman :</b>	Doç. Dr. Aslıhan KATİP	
<b>Başkan :</b>	Doç. Dr. Aslıhan KATİP 0000-0002-3210-6702 <u>Bursa Uludağ Üniversitesi,</u> <u>Mühendislik Fakültesi,</u> <u>Çevre Mühendisliği Anabilim Dalı</u>	İmza
<b>Üye :</b>	Prof. Dr. Gizem Eker Şanlı 0000-0002-3317-2816 <u>Bursa Uludağ Üniversitesi,</u> <u>Mühendislik Fakültesi,</u> <u>Çevre Mühendisliği Anabilim Dalı</u>	İmza
<b>Üye :</b>	Doç. Dr. Ayla Bilgin 0000-0002-1873-6038 <u>Artvin Çoruh Üniversitesi,</u> <u>Mühendislik Fakültesi,</u> <u>Çevre Mühendisliği Anabilim Dalı</u>	İmza

**Yukarıdaki sonucu onaylarım**

**Prof. Dr. Ali Kara**

**Enstitü Müdürü**

.././....

## Bilimsel Etik Bildirim Sayfası

**B.U.Ü. Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında;**

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

**beyan ederim.**

21.06.2023

Asifa ANWAR

## TEZ YAYINLANMA FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezin/raporun tamamını veya herhangi bir kısmını, basılı (kâğıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma izni Bursa Uludağ Üniversitesi'ne aittir. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları ile tezin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları tarafımıza ait olacaktır. Tezde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alınarak kullanıldığını ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederiz.

Yükseköğretim Kurulu tarafından yayınlanan “**Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge**” kapsamında, yönerge tarafından belirtilen kısıtlamalar olmadığı takdirde tezin YÖK Ulusal Tez Merkezi / B.U.Ü. Kütüphanesi Açık Erişim Sistemi ve üye olunan diğer veri tabanlarının (Proquest veri tabanı gibi) erişimine açılması uygundur.

Danışman Adı-Soyadı  
Tarih

Öğrencinin Adı-Soyadı  
Tarih

İmza

Bu bölüme kişinin kendi el yazısı ile okudum  
anladım yazmalı ve imzalanmalıdır.

İmza

Bu bölüme kişinin kendi el yazısı ile okudum  
anladım yazmalı ve imzalanmalıdır.

## ÖZET

Yüksek Lisans Tezi

### DOĞANCI BARAJI'NDA METEOROLOJİK VERİLER İLE SU KALİTESİ VE SU SEVİYESİ ARASINDAKİ İLİŞKİNİN YAPAY SINIR AĞLARI İLE MODELLENMESİ

**Asifa ANWAR**

Bursa Uludağ Üniversitesi  
Fen Bilimleri Enstitüsü  
Çevre Mühendisliği Anabilim Dalı

**Danışman:** Doç. Dr. Aslıhan KATİP

Nüfus artışı, endüstrileşme ve aşırı enerji tüketimi iklim değişikliğine yol açtı ve barajlar gibi su kaynaklarını etkilemektedir. Bu etkileri anlamak için bu çalışmada meteorolojik parametreler dikkate alınarak ileri beslemeli sinir ağları (IBSA) kullanılmıştır. Modelin başarısı, gözlenen ve tahmin edilen veriler arasındaki ortalama kare hataya ve korelasyon katsayısına dayanarak belirlenmiştir. İlk modellemede meteorolojik girdiler ve çıktı olarak Doğancı Barajı su kalitesi verileri kullanılarak üç farklı model test edilmiştir. Bu modellemede, en düşük OKH (1,20) ve en yüksek korelasyona (0,98) sahip olan modelde hava sıcaklığı, güneş radyasyonu ve güneş yoğunluğu gibi girişlerle Doğancı Barajı su sıcaklığı, pH, çözülmüş oksijen, manganez, arsenik ve demir konsantrasyonu çıktı olarak kullanılmıştır. İkinci modellemede, farklı meteorolojik girişler ve su bütçesi parametrelerinin çıktıları kullanılarak üç model test edilmiştir. Bu modellemede, hava sıcaklığı, güneş radyasyonu, güneş yoğunluğu, buharlaşma ve evapotranspirasyon gibi girişler kullanılarak Doğancı Barajı hacmi, gelen ve giden su akışı ve su seviyesi gibi çıktılarıyla daha düşük OKH (0,60) ve daha yüksek korelasyon (0,99) elde edilmiştir. Son olarak, Doğancı Barajı'nın su kalitesi parametreleri arasındaki ilişkiyi belirlemek için iki farklı model daha test edilmiştir. İyi performans gösteren modelde ( $2,5 \times 10^{-4}$  hata değeri ve 0,92 korelasyon değeri) su sıcaklığı, alkalinite, pH ve çözülmüş oksijen gibi girişlerle arsenik, mangan ve demir gibi iz elementlerin konsantrasyonları incelenmiştir. Bu çalışmanın sonuçlarına göre, hava sıcaklığı, güneş radyasyonu ve güneş yoğunluğunun bir barajın su kalitesi ve su bütçesini etkilediği görülmektedir. Bu çalışma, yapay sinir ağlarının meteorolojik parametrelerle bir barajın hidrolojisi ve su kalitesi hakkında tahminler yapmak ve etkileşimleri belirlemek için uygun bir araç olduğunu göstermiştir.

**Anahtar Kelimeler:** Doğancı Barajı, ileri beslemeli yapay sinir ağları, eğitim algoritmaları, meteorolojik parametreler, su kalitesi, su seviyesi.

**2023, vii + 57 sayfa**

## ABSTRACT

MSc Thesis

### MODELING THE RELATIONSHIP BETWEEN METEOROLOGICAL AND DOĞANCI DAM'S WATER QUALITY AND WATER LEVEL DATA USING ARTIFICIAL NEURAL NETWORKS

**Asifa ANWAR**

Bursa Uludağ University  
Graduate School of Natural and Applied Sciences  
Department of Environmental Engineering

**Supervisor:** Doç. Dr. Aslıhan KATİP

Population growth, industrialization and excessive energy consumption have led to climate change and are affecting water resources such as dams. To understand these effects, feed-forward neural networks (FFNN) were used in this study, taking into account meteorological parameters. The success of the model was determined based on the mean square error and correlation coefficient between the observed and predicted data. In the first modeling, three different models were tested using meteorological data as input and the water quality data of Doğancı Dam as output. In this modeling, the model with the lowest mean square error (1.20) and the highest correlation (0.98) utilized meteorological inputs such as air temperature, solar radiation, and solar intensity to predict the output parameters, which include water temperature, pH, dissolved oxygen, manganese, arsenic, and iron concentrations of Doğancı Dam. In the second modeling, three models were tested using different meteorological inputs and outputs of water budget parameters. In this modeling, using inputs such as air temperature, solar radiation, solar intensity, evaporation, and evapotranspiration, the Doğancı Dam's water volume, water level, incoming and outgoing water flow were predicted with a lower mean square error (0.60) and a higher correlation (0.99). Finally, two different models were tested to determine the relationship between Doğancı Dam's water quality parameters. In the well-performing model (error value of  $2.5 \times 10^{-4}$  and correlation value of 0.92), inputs such as water temperature, alkalinity, pH and dissolved oxygen and outputs such as concentrations of trace elements (arsenic, manganese and iron) were investigated. According to the results of this study, it is seen that air temperature, solar radiation and solar intensity affect the water quality and water budget of a dam. This study showed that neural networks are a suitable tool to make predictions about the hydrology and water quality of a dam and determine their interactions with meteorological parameters.

**Keywords:** Doğancı Dam, feed forward artificial neural networks, training algorithms, meteorological parameters, water quality, water level.

**2023, vii + 57 pages**

## TEŐEKKÜR

Arařtırma sürecim boyunca bana deęerli rehberlik ve desteęini sunan danıřmanım Doç. Dr. Aslıhan KATİP'e içtenlikle teőekkür etmek isterim. Ayrıca bu deęerli arařtırmayı gerçekleřtirmek için verileri saęlayan Bursa Su ve Kanalizasyon İdaresi ve Bursa Meteoroloji Müdürlüęü'ne teőekkür etmek isterim. Yurtdıřı Türkler ve Akraba Topluluklar Başkanlığı'na Türkiye'de yüksek lisans yapma bursu saęladıkları için teőekkür etmek istiyorum. Arařtırmalarım sırasında bana saęladığı kaynak ve imkanlar için Bursa Uludaę Üniversitesi'ne teőekkür ederim. Son olarak, sürekli motivasyon ve dualarıyla yanımda olan ebeveynlerime, arkadaşlarıma ve kardeřlerime de teőekkür ederim.

Asifa ANWAR

21/06/2023



## İÇİNDEKİLER

	Sayfa
ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ.....	v
ŞEKİLLER DİZİNİ.....	vi
ÇİZELGELER DİZİNİ.....	vii
1. GİRİŞ.....	1
2. KAYNAK ARAŞTIRMASI.....	4
2.1. Yapay Sinir Ağları.....	4
2.2. YSA Kullanarak Su Kalitesi Tahmini.....	6
2.2.1. İklim değişikliğinin su kalitesine etkilerine ilişkin tahmin çalışmaları.....	8
2.3. YSA Kullanarak Su Bütçesi Tahmin Çalışmaları.....	9
2.3.1. YSA ile iklim değişikliğinin su bütçesine etkisinin tahmin çalışmaları.....	10
2.4. Türkiye'de İklim Değişikliği ve Araştırmanın Önemi.....	11
3. MATERYAL VE YÖNTEM.....	13
3.1. Çalışma Alanı.....	13
3.2. İleri Beslemeli Sinir Ağları (İBSA).....	14
3.2.1. İleri beslemeli sinir ağının eğitimi.....	15
3.2.2. Eğitim algoritmaları.....	16
3.2.3. Performans değerlendirmesi.....	17
3.3. Modelleme Verileri.....	17
3.3.1. İklim değişikliğinin Doğancı Barajı su kalitesine etkisinin modellenmesi.....	17
3.3.2. İklim değişikliğinin Doğancı Barajı su bütçesine etkisinin modellenmesi.....	19
3.3.3. Doğancı Barajı su kalitesinin modellenmesi.....	20
3.4. YSA Uygulanması.....	21
3.5. Test Edilen Model Yapıları.....	22
4. BULGULAR VE TARTIŞMA.....	24
4.1. Birinci Modelleme: İklim Değişikliğinin Doğancı Barajı Su Kalitesi Üzerindeki Etkisinin Tahmini.....	24
4.2. İkinci Modelleme: İklim Değişikliğinin Doğancı Barajı Su Bütçesine Etkisinin Tahmin Edilmesi.....	31
4.3. Üçüncü Modelleme: Doğancı Barajı Su Kalitesi Parametrelerinin Kendi İçerisinde Modellenmesi.....	37
5. SONUÇLAR.....	42
5.1. Öneriler.....	45
KAYNAKLAR.....	47
ÖZGEÇMİŞ.....	57

## SİMGELER ve KISALTMALAR DİZİNİ

<b>Simgeler</b>	<b>Açıklama</b>
$a$	Nöronun sinyali
$b$	Eşik değeri
$c_k$	Algoritmanın gradyanı
$D_i$	Normalize edilmiş veri
$D_{mak}$	Maksimum normalize edilmiş veri
$D_{min}$	Minimum normalize edilmiş veri
$e_i$	Ağ hatalarının vektörü
$f$	Aktivasyon fonksiyonu
$J$	Jacobian matrisi
$\eta^2$	Etki büyüklüğü
$w_i$	Giriş nöronun ağırlığı
$y_k$	Gözlemlenen çıktı değeri
$\hat{y}_k$	Tahmini çıktı değeri
$\sum$	Toplama
$\mu$	Skaler miktarı
$Z$	Toplam giriş nöronun sayısı

<b>Kısaltmalar</b>	<b>Açıklama</b>
ABD ÇKA	Amerika Birleşik Devletleri Çevre Koruma Ajansı
AKM	Askıda Katı Madde
BUSKİ	Bursa Su ve Kanalizasyon İdaresi
ÇO	Çözünmüş Oksijen
DSÖ	Dünya Sağlık Örgütü
EGY	Esnek Geri Yayılım
İBSA	İleri Beslemeli Sinir Ağları
LM	Levenberg-Marquardt
OKH	Ortalama Kare Hatası
R	Korelasyon Katsayısı
TS	Türk Standartları
YSA	Yapay Sinir Ağları
YZ	Yapay Zekâ

## ŞEKİLLER DİZİNİ

		<b>Sayfa</b>
Şekil 2.1.	Yapay nöronun çalışması.....	4
Şekil 2.2.	Yapay sinir ağları kullanılarak gerçekleştirilen adımlar...	5
Şekil 3.1.	Doğancı Barajı'nın uydu görüntüsü (Map, 2023b) .....	13
Şekil 3.2.	Bursa şehir haritası ve Türkiye'deki konumu (Map, 2023a) .....	14
Şekil 3.3.	İleri beslemeli sinir ağının yapısı.....	15
Şekil 4.1.	Birinci modelleme: EGY eğitim algoritması ve LM eğitim algoritması kullanan modellerin korelasyon katsayılarının grafiksel gösterimi.....	27
Şekil 4.2.	İkinci modelleme: EGY ve LM eğitim algoritmaları kullanılarak test edilen modellerin korelasyon grafikleri ...	36
Şekil 4.3.	Üçüncü modelleme: EGY ve LM eğitim algoritmaları kullanılarak yapay sinir ağlarından elde edilen korelasyon grafikleri.....	39

## ÇİZELGELER DİZİNİ

		<b>Sayfa</b>
Çizelge 3.1.	Bursa meteorolojik parametreleri istatistikleri (1990-2019)	18
Çizelge 3.2.	Doğancı Barajı su kalitesi parametreleri istatistikleri (1990-2019) .....	19
Çizelge 3.3.	Kullanılan meteorolojik ve hidrolojik verilerin istatistikleri (1999-2019) .....	20
Çizelge 3.4.	Doğancı Barajı su kalitesi parametreleri istatistikleri (1990-2020) .....	21
Çizelge 4.1.	Birinci modelleme: İleri beslemeli sinir ağı modellemesi sonuçları.....	26
Çizelge 4.2.	Meteorolojik parametrelerle baraj su kalitesi tahmini.....	29
Çizelge 4.3.	Birini modelleme: Algoritmaları karşılaştırırken modellerin (a) R ve (b) OKH değerleri için ANOVA sonuçları.....	30
Çizelge 4.4.	İkinci modelleme: İleri beslemeli sinir ağlarından elde edilen sonuçlar .....	32
Çizelge 4.5.	Meteorolojik parametreleri kullanarak barajı su bütçesi tahmini.....	34
Çizelge 4.6.	İkinci modelleme: Algoritmaları karşılaştırırken modellerin (a) R ve (b) OKH değerleri için ANOVA sonuçları .....	37
Çizelge 4.7.	Üçüncü modelleme: İBSA modellemesinden elde edilen sonuçların analizi .....	38
Çizelge 4.8.	İBSA kullanımıyla barajın su kalitesi tahmininde geçmiş literatür özeti.....	41

## 1. GİRİŞ

İklim deęişiklięi, dünya genelinde acil bir sorun olup, ekosistemleri ve doęal kaynakları büyük ölçüde etkilemektedir (Morrisette ve Rosenberg, 2016). Bu etkilenen alanlardan biri de su kaynaklarıdır. Nüfus artışı, sanayileşme, aşırı enerji tüketimi ve ormansızlaşma gibi nedenlerle artan sera gazı emisyonları, iklim modellerinde öngörülemeyen deęişikliklere ve sonuç olarak su kaynaklarına etki etmektedir (Palmer vd., 2008).

İklim deęişikliğinin su kaynakları üzerindeki etkileri çeşitlidir. Yükselen sıcaklıklar, deęişen yağış modelleri, aşırı hava olaylarının artan sıklığı ve yoğunluğu ve hidrolojik döngülerdeki deęişiklikler su kaynaklarının miktarını, kalitesini ve mevcudiyetini etkiliyor (Simonovic, 2017). Bu deęişiklikler, özellikle tatlı su temini için rezervuarlara ve barajlara büyük ölçüde güvenen bölgelerde, su kaynaklarının sürdürülebilir kullanımının yönetimi ve sağlanması için önemli zorluklar oluşturmaktadır.

Özellikle barajlar, içme suyu temini gibi çeşitli amaçlar için su kaynağının depolanması ve düzenlenmesinde önemli bir rol oynamaktadır (Altınbilek, 2002). Ancak, iklim deęişikliğinin bu su kaynakları üzerindeki etkileri, su kalitesi ve miktarı üzerinde olumsuz etkilere yol açarak, içme suyu ve ekolojik sağlık açısından uygunluğunu etkileyebilir (Molina-Navarro vd., 2014). Bu nedenle, iklim deęişikliğinin baraj hidrolojisi üzerindeki potansiyel etkilerini anlamak ve öngörebilmek, etkili yönetim stratejileri geliştirmek ve toplumlara güvenli ve temiz içme suyu sağlamak için önem arz etmektedir.

Son yıllarda, yapay sinir aęları (YSA), iklim deęişikliğinin su kaynakları üzerindeki etkileri de dahil olmak üzere karmaşık çevresel olayları modellemede ve tahmin etmede güçlü araçlar olarak ortaya çıkmıştır (Hydrology, 2000). YSA'lar, insan beyninin yapısına ve işleyişine benzeyen, büyük veri setlerinden öğrenebilen ve tahminler yapabilen hesaplamalı modellerdir. YSA'lar, doğrusal olmayan ilişkileri yakalama yetenekleri ile dikkate değer bir doğruluk ve sağlamlığa sahiptir (Thakur ve Konde, 2021).

YSA'ların su kaynakları yönetiminde kullanılmasının, iklim deęişikliğinin barajlardaki su dinamikleri üzerinde yarattığı zorlukları ele almada etkili olduğu kanıtlanmıştır. Sıcaklık, yağış, güneş radyasyonu ve yoğunluğu, rüzgâr hızı ve buharlaşma gibi meteorolojik parametreleri entegre ederek, YSA'lar, iklim deęişikliğinin su kalitesi parametreleri üzerindeki potansiyel etkileri konusunda değerli bilgiler sunabilir. Bunlar

arasında sıcaklık, pH, çözülmüş oksijen ve iz elementlerin konsantrasyonları ve ayrıca hacim, su seviyesi, gelen ve giden su miktarı gibi su bütçesi parametreleri yer almaktadır (Fabian vd., 2023; Nourani vd., 2014).

YSA'ların avantajları, büyük ve karmaşık veri kümelerini işleme yetenekleridir. Geçmiş veriler üzerinde eğitilerek, YSA'lar, meteorolojik ve hidrolojik parametreler arasındaki desenleri ve ilişkileri öğrenebilir, bu da gelecekteki sonuçları tahmin etmelerini ve su kaynakları yönetiminde karar alma süreçlerine destek olmalarını sağlar. Bunun yanında, YSA'lar su kalitesi parametreleri arasındaki ilişkileri değerlendirebilmektedir (May vd., 2011; Najah vd., 2013).

Bu çalışmanın amacı, iklim değişikliğinin Bursa ili Doğancı Barajı'nın su kalitesi ve su bütçesi üzerindeki etkilerini YSA kullanarak değerlendirmektir. Meteorolojik ve hidrolojik (su kalitesi ve su bütçesi) verileri kullanılarak, baraj su parametrelerindeki değişiklikleri etkin bir şekilde tahmin edebilen, sağlam ve doğru YSA modelleri geliştirilmesi amaçlanmaktadır. Bursa'da yaşayan halkın su ihtiyacını karşılayan Doğancı Barajı'nın kalitesinde son birkaç yılda iklim değişikliği ile ilişkilendirilebilecek değişiklikler olmuştur (Fural vd., 2022; Ustun, 2011). Bu nedenle, bu araştırma yerel ve uluslararası perspektiften ve barajın sürdürülebilirliği açısından önemlidir.

Bu araştırmanın sonuçları, barajlardaki suyla ilgili parametreler üzerindeki iklim değişikliğinin etkilerini daha geniş bir şekilde anlamamıza ve su kaynakları yöneticileri ve politika yapıcıları için değerli bilgiler sağlamamıza katkıda bulunacaktır. Meteorolojik ve barajın hidrolojik verilerinden yararlanan YSA'lar, bu parametreler arasında var olan karmaşık ilişkiler hakkında değerli bilgiler sağlaması amaçlanmıştır. Bu, barajlara güvenen topluluklara güvenli ve temiz içme suyu temin edilmesini sağlayacaktır.

### **Araştırma Soruları ve Amaçları**

Araştırma soruları şunlardır:

- a) Doğancı Barajı'ndaki su kalitesi veya su bütçesi dinamiklerini etkileyen temel meteorolojik parametreler nelerdir?
- b) Yapay sinir ağları, iklim değişikliğine yanıt olarak hidrolojik parametrelerdeki değişiklikleri doğru bir şekilde modelleyip tahmin edebilir mi?

- c) Farklı meteorolojik girdi kombinasyonları, yapay sinir ağı modellerinin barajlardaki hidrolojik deęişiklikleri tahmin etme performansını nasıl etkiler?
- d) Yapay sinir aęları, Doęancı Barajı'nın farklı su kalitesi parametreleri arasında bir ilişki geliştirebilir mi?
- e) Doęancı Barajı'nın hidrolojik parametreleri için hangi eğitim algoritması, esnek geri yayılım mı yoksa Levenberg-Marquardt mı, daha doęru tahminler sunar?

Bu nedenle, tezin amaçları şunlardır:

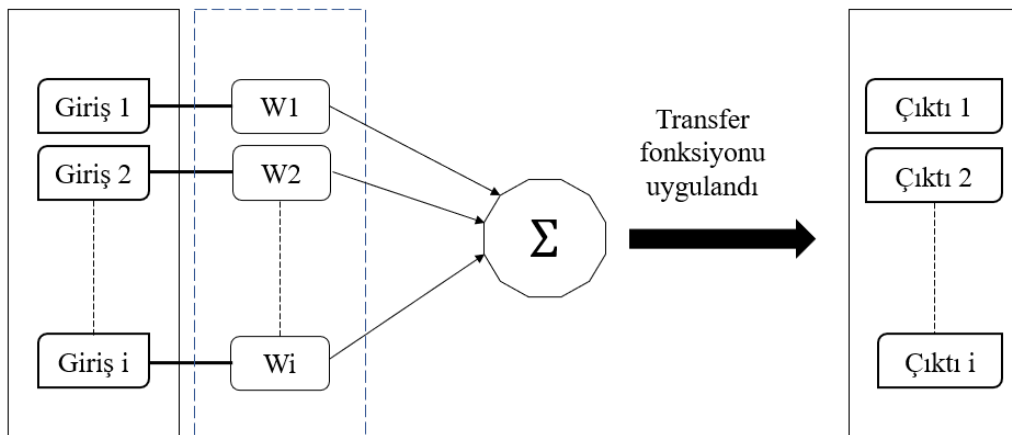
- İklim deęişikliğine yanıt olarak Doęancı Barajı'nın su kalitesi ve su miktarı parametrelerindeki deęişiklikleri doęru bir şekilde tahmin edebilen yapay sinir ağı modelleri geliştirmek.
- Farklı yapay sinir ağı modellerinin farklı girdi ve çıktı kombinasyonlarını kullanarak performansını deęerlendirmek.
- Doęancı Barajı'nın su dinamiklerini tahmin etmede esnek geri yayılım ve Levenberg-Marquardt eğitim algoritmalarının etkinliğini karşılaştırmak.

## 2. KAYNAK ARAŞTIRMASI

Hidrolojide geleneksel yaklaşımları kullanan önceki matematiksel modelleme araştırmaları genellikle süreç tabanlı veya istatistiksel modellere odaklanmıştır (Shen vd., 2021). Son zamanlarda, yapay zekâ (YZ) kullanılarak hidroloji üzerine büyük miktarda araştırma yapılmıştır (Kingston vd., 2008; Lange ve Sippel, 2020). Bunlardan biri de yapay sinir ağlarıdır. Bu tez bölümünde, genel olarak ve değişen iklim koşullarıyla birlikte barajın su kalitesini ve su bütçesinin tahmin etmek için YSA'nın önceki literatürdeki kullanımından bahsedilecektir.

### 2.1. Yapay Sinir Ağları

Yapay sinir ağları, insan beynine benzer şekilde çalışır. Bu ağlar, nöron adı verilen (beyin sinirlerine benzer) birbirine bağlı düğümlerden oluşur. Bu nöronlar, algoritmalar veya matematiksel işlemler kullanarak bilgiyi işleyebilir ve çıkış katmanına iletebilir. Nöronlar ağ içinde ağırlıklı bağlantılarla birbirlerine bağlanmıştır. Bu nöronlar bağımsız elemanlar gibi çalışır ve ağırlıklı girişlerin toplamının nasıl bir çıkış değerine çevrileceğini belirleyen bir transfer fonksiyonuyla ilişkilidir. Gizli katmandaki nöronlar veya çıkış nöronları, altındaki her bir birimden birden fazla ağırlıklı giriş sinyali alır (Kukreja vd., 2016).




Şekil 2.1. Yapay nöronun çalışması



Şekil 2.1'de gösterildiği gibi, girişler belirli bir nöronun başında belirli bir ağırlıkla ilişkilendirilir, yani her bir giriş ayrı bir ağırlıkla çarpılır. Çarpılan tüm değerler daha sonra eşik değerleri ile toplanır ve bunlar daha sonra aktivasyon fonksiyonu olarak da bilinen bir transfer fonksiyonu yoluyla çıkışlara iletilir. Çıkış bir veya birden fazla olabilir. Bilgi her bir çıkışa aktarılır.

Yapay sinir ağı (YSA) tahmin modelleri, özellikle karmaşık süreçlerin olduğu birçok amaç için yardımcı, doğru ve kullanımı kolay bir tahmin aracı olduğu kanıtlanmıştır (Noor vd., 2010). YSA'lar, su modellenmesine birçok fayda sağlar, mesela: (i) modelleme için entegre algoritmaların bir koleksiyonuna ihtiyaç duyulmaması, böylece modelleme yaklaşımının daha hızlı ve adapte edilebilir olması; (ii) lineer olmayan ilişkilerin minimal zorlukla dikkate alınabilmesi (Tabari ve Hosseinzadeh Talae, 2015); ve (iii) bireyin uzmanlığının modelin tasarımına uygulanabilmesi (O'reilly vd., 2018).

YSA aşağıdaki temel özelliklere sahiptir; işleme öğeleri, giriş düğümleri (bilginin depolandığı yer) arasındaki ağırlıklı bağlantılar, paralelleştirme ve dağıtılmış kontrol ve bilişsel yapıların otomatik öğrenmesi. YSA'ların amacı, belirli ağlardaki arızaları giderirken, büyük paralel işlem birimleri ağını eğiterek hızlı bir şekilde bulgu sağlamaktadır (Kang vd., 2015). Şekil 2.2, YSA modellemesinin önemli adımlarını bir akış şemasıyla vurgular.



**Şekil 2.2.** Yapay sinir ağı kullanılarak gerçekleştirilen adımlar

Mühendislik uygulamalarında genellikle kullanılan YSA türleri arasında ileri beslemeli sinir ağı, evrişimli sinir ağı ve tekrarlayan sinir ağı bulunur. İleri beslemeli sinir ağı bir çıkış katmanı ve bir veya daha fazla gizli katmana sahiptir. Evrişimli sinir ağı, girdileri özellik haritalarına işleyen katmanlara sahiptir ve görüntü işlemede kullanılır. Son olarak, tekrarlayan sinir ağı modelleri geri besleme döngüleriyle zaman serisi girdilerle uğraşır (Jain vd., 1996; Zou vd., 2008).

YSA, erozyon, hava kirliliđi, su kirliliđi, su tüketimi, enerji tüketimi vb. tahmin etmek için kullanılır (Yetilmezsoy vd., 2011). Bir YSA, en iyi ilişkilere uyması ve sağlanan verilere dayalı tüm olası ilişkileri izlemesi için çok uygundur (Hydrology, 2000).

## 2.2. YSA Kullanarak Su Kalitesi Tahmini

Su kalitesi, bir sucul sistemde önemli bir rol oynamaktadır ve su kirliliđinin derecesini gösterir. Yüzey sularının ve barajların su kalitesi, insanların günlük ihtiyaçlarını karşılamak için onlara güvenmeleri açısından büyük öneme sahiptir. Bazı bölgelerde, baraj suyu, taşan nehir suyundaki kirleticiler ve tortulardan dolayı hızla kirlenmektedir. Ayrıca, iklim deđişikliđi gün geçtikçe ötrofikasyona ve alg patlamalarına yol açarak su kalitesini etkilemektedir (Nazari-Sharabian vd., 2019). Bu nedenle, barajın su kalitesinin izlenmesi ve korunması, halkın güvenliđi ve sürdürülebilirliđi desteklemek için hayati önem taşımaktadır.

Küresel ısınma nedeniyle hava sıcaklığında bir artış, su kütlelerinin sıcaklığını da deđiştirecektir. Bu da sucul organizmaların büyüme ve gelişmesini etkileyen ana parametrelerden biri olan su sıcaklığını ve su kütlelerinde gerçekleşen kimyasal süreçleri etkiler (Jeppesen vd., 2015). Su kütlelerinin ısınma ve sođuma süreci, güneş radyasyonu, hava sıcaklığı ve rüzgâr hızı gibi meteorolojik parametrelerden büyük ölçüde etkilenir (Syafii vd., 2017). Bu koşullar altında, su kalitesinin tahmin edilmesi, ekosistem sürdürülebilirliđi, çevresel izleme ve insanların yaşam sürdürülebilirliđi açısından hayati önem taşır.

Yapay sinir ađı modellemesi, su kalitesi ile meteorolojik parametreler arasındaki anlamlı bir ilişkiyi sağlayabilir (Hébert vd., 2015). Sağlanan verilere dayanarak, belirli bir noktadaki su kalitesinin gelecekteki deđişim eğilimini tahmin eder (Zhang ve Gao, 2015). Karmaşıklık nedeniyle, doğrusal, dinamik veya stokastik programlama gibi geleneksel yöntemler, geniş verilerle başa çıkmak için yeterince verimli olmadığından tahminler için tercih edilmez (Al-Jarrah vd., 2015). Bu tür geleneksel yöntemlerin çok amaçlı rezervuarlarla başa çıkma konusunda yetersiz olduğu bildirilmiştir (Garousi-Nejad vd., 2016). Daha önceki çalışmaların çođu, evrimsel tekniklerin klasik tekniklere göre daha yetenekli olduğunu ve çeşitli amaç fonksiyonlarıyla başarılı bir şekilde başa çıkabildiđini

iddia etmektedir (Allawi vd., 2018). Ayrıca, geleneksel istatistiksel yöntemlerin aksine, yapay sinir ağları daha az önceden varsayım gerektirir ve daha yüksek hassasiyet elde eder (Büyükşahin ve Ertekin, 2019).

Son zamanlarda, YSA'lar, pH, sıcaklık, çözülmüş oksijen ve iz element konsantrasyonları gibi su kalitesi ölçütlerini tahmin etmede büyük potansiyel göstermiştir (Pule vd., 2017). Hava durumu, su akış hızları ve arazi kullanımı gibi bir dizi girdi değişkenine dayanarak, YSA'ler barajlarda su kalitesi parametrelerini tahmin etmek ve kirlilik olası nedenlerini belirlemek için kullanılabilir (Zhu vd., 2022).

Araştırmacılar barajlardaki su kalitesini tahmin etmek için yaygın olarak yapay sinir ağlarını kullanmaktadır. 2012 yılında, Portekiz'deki Monte Novo barajı için yapay sinir ağı yapısı seçilerek, suyun çözülmüş oksijen ve askıda katı madde konsantrasyonunu önümüzdeki 15 yıl için tahmin etmek amacıyla kullanılmıştır. Çalışmada, pH, iletkenlik, çözülmüş oksijen, su sıcaklığı ve depolanan su hacmi gibi verileri test edilen modellere girdi olarak kullanılmıştır. Gözlemlenen ve tahmin edilen değerler arasında iyi bir uyum görülmüş, eğitim seti için korelasyon katsayısı değerleri 0,995 ile 0,998 arasında, test seti için ise 0,994 ile 0,996 arasında değişmiştir (Vicente vd., 2012). Benzer şekilde, yapay sinir ağları, Kuzey Tayvan'daki Feitsui Barajı'ndaki çözülmüş oksijen konsantrasyonunu tahmin etmek için kullanılmıştır. Modeller, su sıcaklığı, pH, iletkenlik, bulanıklık, askıda katı madde ve amonyum azotu konsantrasyonu, toplam sertlik ve alkalinite gibi girdi verilerini kullanarak suyun çözülmüş oksijen konsantrasyonunu hedeflemiştir. Yapay sinir ağı modellerinin performansı, ölçülen ve modelleme ile elde edilen çözülmüş oksijen değerlerinden hesaplanan ortalama mutlak hata, kök ortalama kare hatası ve korelasyon katsayısı ile değerlendirilmiştir. Eğitim ve test aşaması için yüksek bir korelasyon katsayısı (0,89) ve düşük hatalar (0,32 ila 0,98 arasında) gözlenmiş, yapay sinir ağlarının güvenilirliği ortaya konmuştur (Chen ve Liu, 2014). 2017 yılında Karaj Barajı'ndaki toplam çözülmüş katıların yapay sinir ağları ile tahmin edilmesi sağlanmıştır (Asadollahfardi vd., 2017). Aynı şekilde, Keban Barajı'ndaki klorofil-a konsantrasyonu, alkalinite, pH, su sıcaklığı, elektriksel iletkenlik ve çözülmüş oksijen, fosfatlar ve nitratlar gibi parametrelerin yapay sinir ağlarına girdi olarak kullanılarak tahmin edilmiştir. Model, hedeflenen ve simüle edilen veriler arasında yüksek bir korelasyon (0,95) göstermiştir (Karul vd., 2000).

Türkiye'deki Köyceğiz Gölü'ndeki su kalitesinin değerlendirilmesi ve tahmin edilmesi için de YSA kullanılmıştır. Aylık ortalama sıcaklık, pH, elektriksel iletkenlik ve çözülmüş oksijen konsantrasyonu değerleri girdi olarak kullanılmış, amonyum azotu, toplam azot, fosfor, klorofil-a ve koliform bakteri konsantrasyonları ise çıktı olarak kullanılmıştır. Sonuçlar, gölün ötrofik olduğunu ve ölçülen ve tahmin edilen parametreler arasında düşük bir hata (0,046) ve yüksek bir korelasyon değeri (1) olduğunu ortaya koymuştur (Özçelik, 2015). Benzer şekilde, havzalardaki su kalitesi tahminleri YSA kullanılarak yapılmıştır (Kalin ve Isik, 2010).

2018 yılında, su sıcaklığı, biyokimyasal oksijen ihtiyacı, askıda katı maddeler, kimyasal oksijen ihtiyacı ve amonyak konsantrasyonu için YSA, destek vektör makineleri, sınıflandırma ve regresyon ağaçları ve doğrusal regresyon kullanılarak Tayvan rezervuarlarında su kalitesi belirlendi. Karşılaştırma sonucunda YSA modelinin geleneksel hidrolojik istatistiksel yöntemlere göre daha doğru olduğu gözlemlenmiştir (Chou vd., 2018). Harşit akarsuyunun yüzey suyu kalitesi için yapılan başka bir çalışma, YSA'nın istatistiksel yöntemlerden daha iyi olduğunu kanıtlamıştır (Bayram, 2011).

### **2.2.1. İklim değişikliğinin su kalitesine etkilerine ilişkin tahmin çalışmaları**

YSA, iklim değişikliğinin su kalitesi üzerindeki etkisini incelemek için de kullanılmaktadır. Namgang baraj havzasına önceki hidrolojik iklim değişikliği senaryoları uygulandıktan sonra su kalitesi (askıda katı madde, toplam azot, toplam fosfor, çözülmüş oksijen, biyokimyasal oksijen ihtiyacı ve klorofil-a) iklim değişikliği altında tahmin edilmiştir (Kang vd., 2015). Aynı yılında, YSA, Kuzey Çin'deki Yuqiao Barajı'nın içme suyu kaynağının de ötrofikasyon tehdidi altında olduğunu tahmin etmiştir. Çalışmada elde edilen hatalar 0,003'ten küçük ve doğrulamada korelasyon katsayısı 0,99 olarak bulundu. Bu sonuçlar ayrıca YSA'nın su kalitesini tahmin etmedeki geçerliliğini de göstermektedir (Zhang vd., 2015). İran'da Dez Barajı'ndaki trofik durum indeksi, ileri beslemeli sinir ağı kullanılarak değerlendirilmiştir. Modelin girdileri toplam nitrojen, nitratlar, amonyak, toplam fosfor, fosfatlar, klorofil-a, çözülmüş oksijen ve derinlikti. Korelasyon katsayısı 0,84 çıkmıştır (Saghi vd., 2015).

2017 yılında Adelaide, Güney Avustralya'nın içme suyu sağlayan yarı kurak Millbrook havzasında yapılan araştırmada YSA aracı kullanılmıştır. Modelleme, yağış, maksimum ve minimum sıcaklık, güneş radyasyonu, bağıl nem ve rüzgâr hızı gibi faktörleri dikkate almıştır (Nguyen vd., 2017). Meteorolojik faktörleri dikkate alarak, Shi Nehri barajında 2021 yılı için toplam azot ve fosfor miktarı gelişmiş dinamik regresyon yapay sinir ağı ile tahmin edilmiştir. Ortalama bağıl hata yaklaşık %1'idi ki bu oldukça azdır. Çalışma YSA'nın faydalı uygulanabilirliğini göstermiştir (Wang vd., 2021). İklim değişikliği açısından, Sapanca Gölü'nün uzun vadeli su temini için meteorolojik faktörlerin (yağış, buharlaşma, bağıl nem, sıcaklık ve rüzgâr hızı) su kalitesi üzerindeki etkisi belirlenmiştir (Sonmez vd., 2013). Mamasin Barajı için yağış, su sıcaklığı, askıda katı madde ve toplam azot konsantrasyonları kullanılarak elektrik iletkenliği ve çözülmüş oksijenin (ÇO) YSA modeliyle tahmin edilmesi sağlanmıştır. Bu çalışma için ortalama mutlak hata 4,72 ile 6,46 arasında bulunmuştur (Elhatip ve Kömür, 2008).

### **2.3. YSA Kullanarak Su Bütçesi Tahmin Çalışmaları**

İklim değişikliği günümüzde önemli bir çevre sorunudur. Nehirlerde ve akarsularda su akışı, değişen hava koşullarıyla önemli ölçüde değişir ve yüksek akışlarda sel, düşük akışlarda ise kuraklık gibi sorunlara neden olabilir (Cooper vd., 2013). Barajlar, yüksek akış dönemlerinde suyu depolayarak düşük akış dönemlerinde suyun yavaşça salınmasını sağlarlar (Kondolf vd., 2014). Aynı zamanda bu barajlar içme suyu ve sulama amacıyla su temin etmektedirler (Hogeboom vd., 2018). Bu nedenle, barajlardaki su miktarının doğru bir şekilde tahmin edilmesi, su yönetimi sorunlarını azaltmak için önerilir. Ancak, barajlardaki su miktarının tahmin edilmesi çeşitli faktörlere, yani akarsu parametrelerine ve iklimsel değişimlere dayanır (Chamoglou vd., 2014). Barajdaki su ayrıca buharlaşabilir veya çevredeki kayalara veya toprağa sızabilir (Mahmood vd., 2014). Akarsuların taşıdığı sedimentler, bir barajın depolama kapasitesini azaltabilir (Casserly vd., 2020). Dolayısıyla, birçok koşul barajlardaki su miktarını etkileyebilir.

Son zamanlarda yapılan modellemeler, su bütçesini, yani bir su kütesine giren ve çıkan su hacmini ve önceden mevcut verilere dayanarak su seviyesi değişikliklerini simüle etmeyi desteklemiştir (Zhang vd., 2018). Yıllardır, su bütçesi modellenmesi geleneksel istatistiksel yöntemlere dayanmaktaydı, ancak dikkat yapay zekâ (YZ) tekniklerine

kaymıştır. YZ teknikleri çerçevesinde, bulanık sinir ağları, yapay sinir ağları (YSA) ve genetik algoritmalar hidrolojik modelleme için kullanılmıştır (Nourani vd., 2019; Tabbussum ve Dar, 2021). Çoğu model, sağlamlığı ve hata olasılığının daha az olması nedeniyle YSA'ya dayanmaktadır (Yaseen vd., 2020).

Barajların su bütçesini ve su seviyesini tahmin etmek için YSA kullanılarak yapılan araştırmalar bulunmaktadır. ABD'deki Millers Ferry barajı rezervuar seviyesi YSA kullanılarak tahmin edilmiştir (Üneş vd., 2015). Bir çalışmada, Dez barajının aylık akışı değerlendirmek için otoregresif YSA modelleri karşılaştırılmıştır. Modelleme sonucunda ortalama karekök hatası 0,6 ile 1,1 arasındaydı (Valipour vd., 2013). İran'daki Sefidroud barajının su bütçesini tahmin etmek için farklı statik ve dinamik YSA'lar kullanılmıştır. Bu ağlar, statik ileri beslemeli ve doğrusal olmayan otoregresif sinir ağlarını içermektedir (Hadiyan vd., 2020). Hindistan'da Sukhi barajı su seviyesi tahmini için YSA uygulaması yapılmıştır. Sinir ağları, düşük bir hataya (0,74 ila 0,84 arasında değişen) ve yüksek bir korelasyona (0,95'e kadar) sahipti (Rani ve Parekh, 2014). Yapay sinir ağları, baraj veya rezervuar seviyesi dalgalanmalarını tahmin etmek için sıklıkla tercih edilmektedir (Üneş vd., 2019).

### **2.3.1. YSA ile iklim değişikliğinin su bütçesine etkisinin tahmin çalışmaları**

YSA iklim değişikliğinin barajlardaki su miktarı üzerindeki etkilerini incelemek için kullanılmıştır. Malezya'daki Batu barajında buharlaşmayı YSA ve iklim tabanlı modeller kullanarak meteorolojik veriler, yani hava sıcaklığı, nispi nem, rüzgâr hızı, yağış, güneşlenme süresi ve güneş radyasyonu, kullanılarak bulunmuştur (Benzaghta vd., 2012). ABD'de 2017 yılında Norris barajının iklim değişikliği etkilerinin uzun vadeli bir değerlendirmesi YSA kullanılarak yapılmıştır (Rungee ve Kim, 2017). YSA'nın bir diğer uygulaması da Nijerya'da yapılan Asa ve Kampe barajlarında iklim değişkenliğinin etkisinin değerlendirilmesidir (Salami vd., 2015).

Doğru bir tahmin aracı olan YSA, Türkiye'deki barajların su bütçesini ve su seviyelerini tahmin etmek için kullanılmıştır. Türkiye'nin Ermenek hidroelektrik barajı rezervuarına günlük akış, derin tekrarlayan sinir ağı modelleri kullanılarak simüle edilmiştir (Apaydin vd., 2020). İklim faktörlerini dikkate alarak, Tahtalı ve Gördes barajlarının akışlarındaki yağış ve sıcaklık değişikliklerinin 2010-2099 yılları için etkisi değerlendirilmiştir

(Okkan, 2009). Namazgah barajının akışı da YSA kullanılarak hava sıcaklığı, buhar basıncı ve yağış gibi girdi verileriyle tahmin edilmiştir (Raşit, 2019). YSA'nın etkinliği, seçilen girdilerle çıktı arasındaki ilişkiye ve sinir ağlarının işleyişinin anlaşılmasına dayanmaktadır (Mata, 2011).

YSA, nehir, göl ve yeraltı suyu seviyesini tahmin etmek için kullanılmış ve sonuçları iklim değişikliği ile ilişkilendirmiştir. Bir örnek olarak, Irak'ın güneyindeki Basra ili Qurna kentinde Dicle Nehri'nin su seviyesini tahmin etmek amacıyla geri yayılma algoritmali yapay sinir ağları (YSA) kullanılmıştır. Sonuçlar, geri yayılma algoritmali YSA'ların, Dicle Nehri'nin kısa vadeli aşamasını tahmin etmek için güçlü bir teknik olduğunu göstermiştir (Al Aboodi vd., 2009). Bir çalışmada, yapay sinir ağları ve çoklu regresyon analizi, ortalama yağış, aylık maksimum yağış, basınç, sıcaklık, bağıl nem, rüzgâr hızları, buharlaşma ve ortalama akış değerlerini kullanarak Göksu Deresi'nin aylık ortalama akımlarını ve maksimum yağışını tahmin etmiştir. Araştırmalar sonucunda planlama faaliyetleri, su yapısı hesapları, taşkın ve dere yatağı iyileştirmeleri yapılmıştır (Fırat, 2019). Benzer şekilde, Serwy Gölü'nün (Kuzeydoğu Polonya'da) yüzey seviyesi dalgalanmaları, girdi olarak maksimum günlük ve minimum hava sıcaklığı, rüzgâr hızı, bağıl nem ve dikey sirkülasyon kullanılarak YSA yardımıyla araştırılmıştır. Çalışma çok katmanlı algılayıcı YSA kullanımını desteklemiştir (Piasecki vd., 2017).

#### **2.4. Türkiye'de İklim Değişikliği ve Araştırmanın Önemi**

Hükümetler arası İklim Değişikliği Paneli'nin Temsilci Yoğunluk Yolu 8,5 senaryosuna göre, Türkiye'de, Akdeniz iklim kuşağı da dahil olmak üzere, 2020-2050 yaz aylarında hava sıcaklığının 1970-2000 yıllarına kıyasla 2°C artacağı tahmin edilmektedir. Aynı zamanda, yıllık yağış miktarının 157 mm azalacağı tahmin edilmektedir (Pachauri vd., 2014). Bu nedenle, barajlar gibi içme suyu kaynaklarının kalitesinin ve bütçesinin tahmin edilmesi yaşam için önemlidir.

Bu araştırma Bursa'daki Doğanlı Barajı'nı hedeflemektedir. Doğanlı Barajı, Türkiye'deki Bursa şehrinde yaşayan nüfusun başlıca su kaynaklarından biridir (Koç vd., 2007). Bursa'nın içme suyu kaynakları, nüfus artışı ve plansız kentsel gelişme nedeniyle azalmıştır (Solmaz ve Yalili, 2002). Ayrıca, Doğanlı Barajı'nın su kalitesinin özellikle

ađır metal konsantrasyonunun artmasıyla azaldığı gözlemlenmiştir (Ustun, 2011). Doğancı Barajı'nın üzerinde inşa edildiđi Nilüfer çayında yapılan arařtırmalarda yüksek polimerik aromatik hidrokarbon (PAH) konsantrasyonları belirlenmiştir (Karaca ve Tasdemir, 2014).

Bursa'da 21. yüzyılda sıcaklık da geçen yüzyıla göre 0,5°C artmıştır. Bursa için 2019'da Standartlaştırılmış Yađış İndeksi (SYI) kullanılarak yapılan bir çalışmada, uzun süreli bir kuraklık öngörölmüştür (Vaheddoost, 2019). YSA ayrıca, "Bursa İli için Yapay Sınır Ađı Kullanarak Meteorolojik Kuraklık Analizi" adlı bir çalışmada Bursa'da kuraklık olasılıklarını tahmin etmiştir (Katip, 2018). Aynı şekilde, Doğancı Barajı'nın su bütçesi, 2011 yılına kıyasla %92'den %72'ye düşmüştür (BUSKI, 2021). Bu nedenle, bu araştırma, yapay sınır ađlarının farklı meteorolojik parametre kombinasyonlarını kullanarak Doğancı Barajı'nın su kalitesi ve su bütçesi üzerindeki iklim deđişikliđi etkilerini incelemeyi amaçlamaktadır.

Dünyadaki içme suyu barajlarının su seviyelerinin ve hacimlerinin yanı sıra su kalitesinin tahmin edilmesi, iklim deđişikliğine uyum sağlamak için önemlidir. Bilindiđi kadarıyla, bu çalışma daha önce Doğancı Barajı'nda yerel olarak yapılmamış olup, su yönetimi açısından benzersiz ve eşit derecede önemlidir.



### 3. MATERYAL VE YÖNTEM

Tezin bu bölümü, çalışma bölgesini ve yapılan araştırmada kullanılan tüm metodolojiyi açıklamaktadır. Bu çalışma Bursa Doğancı Barajı üzerine yapılmıştır. İklim değişikliğinin Doğancı Barajı'nın su kalitesi ve su bütçesi üzerindeki etkileri ileri beslemeli sinir ağıları kullanılarak analiz edilmiştir.

#### 3.1. Çalışma Alanı

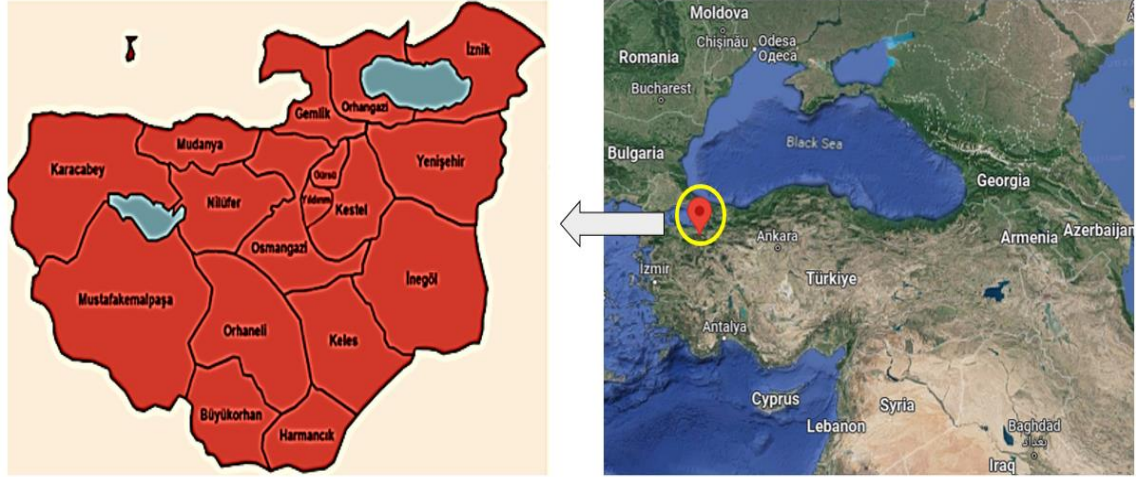
Bu çalışmada, Türkiye'nin Bursa şehrinin nüfusuna içme suyu sağlayan Doğancı Barajı'nın su kalitesi ve su bütçesi, meteorolojik parametreler kullanılarak yapay sinir ağı (YSA) yardımıyla araştırılmıştır. Doğancı Barajı'nın su hacmi 2 520 000 metreküp, nehir yatağından yüksekliği 65 metre, maksimum su seviyesindeki hacmi yaklaşık 43 metreküp ve normal su seviyesindeki alanı 1,55 kilometrekaredir. Yılda yaklaşık 125 hektar metreküp içme suyu sağlamaktadır (BUSKI, 2023). Türkiye Devlet Su İşleri Genel Müdürlüğü barajın sahibi ve işletmecisidir (Bursa Metropolitan Municipality, 2023).



Şekil 3.1. Doğancı Barajı'nın uydu görüntüsü (Map, 2023b)

Diğer yandan, Bursa Türkiye'nin Marmara Bölgesi'nin güneydoğusunda bulunan bir şehirdir. Bursa'nın iklimi, Marmara ve Ege bölgeleri arasında konumundan etkilenmektedir. Marmara Denizi'ne daha yakın olan kuzey Bursa, ılıman ıslak kışlar ve sıcak, kuru yazlarla Akdeniz iklimine sahiptir. Buna karşılık, Bursa'nın güneyi ve iç


kesimleri, iç batı Anadolu bölgesine daha yakın olan bölgeler, sıcak yazlar ve soğuk kışlarla kıtasal bir iklime sahiptir. Ayrıca, Bursa'da Ocak ve Şubat ayları arasında bir veya iki hafta kar yağışı da görülür. 2019 yılında yapılan nüfus sayımına göre, Türkiye'nin en kalabalık dördüncü şehri olan Bursa'nın nüfusu 3 056 120'dir. Bursa farklı ilçelere ayrılmıştır. Önemli olarak görülen bazı ilçeleri: Osmangazi, Yıldırım, Nilüfer, Gürsu, Kestel, vb. Bursa büyükşehir statüsüne sahip bir şehirdir (Erünal, 2020).



Şekil 3.2. Bursa şehir haritası ve Türkiye'deki konumu (Map, 2023a)

### 3.2. İleri Beslemeli Sinir Ağları (İBSA)

Bu çalışmada, araştırmacıların yaygın olarak tercih ettiği çok katmanlı ileri beslemeli sinir ağı modeli seçilmiştir. (Asadollahfardi vd., 2017; El-Mahdy vd., 2021; Özçelik, 2015; Rani ve Parekh, 2014; Üneş vd., 2015). İleri beslemeli ağlar genellikle eğitim için geri yayılım algoritmaları kullanır. İleri beslemeli sinir ağı, verinin girişten çıkışa doğru tek yönlü veya ileri yönlü olarak aktığı bir yapay sinir ağıdır ve geri dönüş döngüleri içermez. Aksi takdirde, katman sayısı, yapay nöronlar arasındaki bağlantı sayısı ve kullanılacak aktarım fonksiyonu türü gibi parametreler sınırlanmamıştır (Krenker vd., 2011). Başka bir deyişle, tüm bu parametrelerin seçim seçeneği açıktır ve sonuçların doğruluğuna göre değiştirilebilir. İleri beslemeli bir sinir ağı, Şekil 3.3'te gösterildiği gibi giriş, gizli ve çıkış katmanlarına sahip çok katmanlı bir algılayıcıdır.



**Şekil 3.3.** İleri beslemeli sinir ağının yapısı

Şekil 3.3'teki daireler nöronları temsil etmektedir. Bilgi giriş katmanına girer ve ardından gizli katman aracılığıyla çıkış katmanına ilerler. Bir yapay sinir ağı için gizli bir katman, giriş verilerinin toplu işlenmesini gerçekleştirir ve yapay sinir ağının girişler arasındaki doğrusal olmayan ilişkileri belirlemesine olanak sağlar. Gizli katmanda her nöron için girişlere ağırlıklar ve sapmalar uygulanarak bir çıkış üretilir.

### 3.2.1. İleri beslemeli sinir ağının eğitimi

İleri beslemeli sinir ağı, eğitim ve tahmin modunda çalışır. Eğitim modunda ağırlıklar başlangıçta rastgele değerlerle başlar ve iteratif olarak ayarlanır. Her bir eğitim setinin tekrarını ifade etmek için epoklar kullanılır. Ağ, her epok'ta hata miktarını en aza indirmek için değerleri değiştirir. Tamamlanması için eğitimin birden çok epok üzerinden geçmesi gerekmektedir (Svozil vd., 1997). İleri beslemeli sinir ağının çıktısı aşağıdaki gibi eşitlenebilir:

$$\text{Çıktı} = f(a) \quad (3.1)$$

Denklem 3.1'de  $f$  aktivasyon fonksiyonunu,  $a$  ise nöron sinyalini temsil etmektedir ve aşağıdaki gibi tanımlanır:

$$a = \sum_{i=1}^Z w_{ixi} + b_i \quad (3.2)$$

Burada  $w_i$  giriş nöronunun ağırlığını,  $Z$  ise toplam giriş nöronunun sayısını temsil etmektedir. Toplama aşamaları her gizli nöron  $i$  için gerçekleşir. Genellikle, her giriş

nöronunun toplamı ağırlıklı olarak işlenir ve genellikle aktivasyon fonksiyonları kullanılır (Ojha vd., 2017; Svozil vd., 1997).

### 3.2.2. Eğitim algoritmaları

Bu çalışmada, ileri beslemeli sinir ağlarını kullanarak modelin en iyi şekilde eğitildiğini ve doğru modellerin sunulduğunu belirlemek için esnek geri yayılım (Benzaghta vd., 2012; Mohamad ve Ishak, 2019) ve Levenberg-Marquardt algoritmaları kullanılmıştır (Çalım, 2008; Damla vd., 2020).

#### 3.2.2.1 Levenberg-Marquardt algoritması

Levenberg-Marquardt (LM) algoritması, ikinci derece eğitim hızına yaklaşmak için Hessian matrisini hesaplama gereksinimi olmadan geliştirilmiştir. Levenberg-Marquardt algoritması, Hessian matrisini aşağıdaki gibi yaklaşık olarak hesaplar:

$$c_{k+1} = c_k - (J^T J + \mu I)^{-1} J^T e \quad (3.3)$$

Burada  $c_k$  algoritmanın gradyanını,  $J$  Jacobian matrisini (hata türevlerini ağırlıklar ve nöronların eşik değerleri ile birlikte içeren) ve  $e$  ağ hatalarının vektörünü temsil eder.  $\mu$  algoritmanın bir skaler miktarıdır.  $\mu$ , her algoritma iterasyonunda performans fonksiyonunun azalmasıyla her çalışmadan sonra azaltılır. Bu eğitim algoritması, ileri beslemeli sinir ağlarda diğer geleneksel gradyan iniş tekniklerine göre daha iyi bir optimizasyon yapmaktadır (Kişi ve Uncuoğlu, 2005).

#### 3.2.2.2 Esnek geri yayılım algoritması

Çok katmanlı ileri beslemeli sinir ağlarında gizli katmanlarda sigmoid transfer fonksiyonları sıkça kullanılır. Sigmoid fonksiyonlarının eğimi, girdi büyüklüğü arttıkça sifira yaklaşmalıdır. Ağırlıklar ve eşik değerleri ideal değerlerinden uzak olsa bile, gradyanın büyüklüğü çok küçük olabilir ve bu da ağırlıklar ve eşik değerlerinde az değişikliklere neden olabilir. Esnek geri yayılım (EGY) eğitim yöntemi, bu kısmi türev büyüklüklerinin zararlı etkilerini ortadan kaldırmayı amaçlar. Ağırlık kayması derecesini belirleyen farklı bir güncelleme değeri kullanır. Bir ağırlığın performans fonksiyonunun

türevi iki iterasyonda aynı işarete sahipse, her ağırlık ve eşik değeri bir faktörle artırılır. Ağırlık türevi işaret değiştirdiğinde güncelleme değeri bir faktörle azaltılır. Sıfır türevler, güncelleme değerini aynı tutar (Kişi ve Uncuoğlu, 2005).

### 3.2.3. Performans değerlendirmesi

İleri beslemeli yapay sinir ağı, modelin yüksek bir korelasyon katsayısı R ve düşük bir ortalama karesel hata (OKH) ile doğru tahminler yapar. Korelasyon katsayısı (R değeri), tahmin edilen çıkış değerlerinin hedef çıkışlarla ne kadar iyi ilişkilendiğini gösterir ve modelin tahmin etme verimliliği hakkında bir fikir verir. R değerleri -1 ile 1 arasında değişebilir, 1 pozitif bir korelasyonu gösterir (Taylor, 1990). Bununla birlikte, OKH hata miktarını ifade eder ve aşağıdaki formül kullanılarak hesaplanır:

$$OKH = \frac{1}{M} \sum_{j=1}^M (y_k - \hat{y}_k)^2 \quad (3.4)$$

Denklem 3.4'de M toplam çıkış değerlerinin toplam sayısını,  $y_k$  gözlenen çıkış değerini ve  $\hat{y}_k$  aynı parametrenin tahmini değerini temsil eder. Hata değeri ne kadar düşük olursa, tahmin o kadar iyi olur ve daha verimli bir eğitim algoritmasını belirlemeye yardımcı olur (Wu vd., 2011). Hata, gerçek ve model çıkışları arasındaki farkı yorumlar, bu yüzden en düşük değer hedeflenen çıkışlardan mümkün olduğunca az fark olduğunu gösterir.

## 3.3. Modelleme Verileri

Bu araştırmada, ileri beslemeli sinir ağları kullanılarak üç farklı modelleme yapılmıştır. İlk iki çalışma, Doğancı Barajı'nın su kalitesi ve su bütçesi üzerinde iklim değişikliğinin etkisini incelemek amacıyla gerçekleştirilmiştir. Son çalışma, Doğancı Barajı'nın farklı su kalitesi parametreleri arasındaki ilişkiyi belirlemek için modelleme yapmaktadır.

### 3.3.1. İklim değişikliğinin Doğancı Barajı su kalitesine etkisinin modellenmesi

Yapay sinir ağları ile modelleme çalışmalarında, düzenli ve uzun yıllara ait verilere ulaşmak modellerin doğruluğu açısından büyük önem taşımaktadır. Bu nedenle 30 yıllık veriler kullanılmıştır. Bursa'da şehrin farklı ilçelerine dağılmış 16 adet meteoroloji istasyonu bulunmaktadır. Merkez Bursa İstasyonuna ait aylık meteorolojik veriler Orman

ve Su İşleri Bakanlığı'na bağlı Bursa Meteoroloji Müdürlüğü'nden alınmıştır. Diğer yandan, Doğancı Barajı'nda tek bir istasyona ait aylık su kalitesi verileri Bursa Su ve Kanalizasyon İdaresi'nden elde edilmiştir. Şekil 3.1'de Doğancı Barajı'na ait örnekleme noktası gösterilmiştir. İncelen meteorolojik ve su kalitesi verileri, 1990-2019 dönemini kapsayan ve her parametre için 360 (aylık ortalama) değeri içermektedir. Verilerin karmaşık ve birkaç eksik değeri içermektedir. Elde edilen veriler ham formatta veya basılı bir kopya halindeydi. Modelleme için, değerler ayrı bir Excel dosyasına girilmiştir ve her parametre için yeniden düzenlenmiştir. Eksik değerler göz ardı edilmiştir ve ardından modelleme için veri normalizasyonu yapılmıştır. Normalizasyon işlemi genellikle aykırı değerler veya eksik değerlerden etkilenmemektedir.

Meteorolojik veriler buhar basıncı (hPa), bağıl nem (%), hava sıcaklığı (°C), rüzgâr hızı (m/s), yağış (mm), global güneş radyasyonu (kWh/m<sup>2</sup>), güneş yoğunluğu (cal/cm<sup>2</sup>), evapotranspirasyon (mm), kar kalınlığı (cm) ve buharlaşma (mm) gibi parametrelerden oluşmaktadır. Doğancı Barajı'nın su kalitesi için ise pH, bulanıklık (NTU), su sıcaklığı (°C), askıda katı madde (AKM) (mg/L), çözünmüş oksijen (ÇO) (mg/L), alkalinite (mg/L) ve demir (mg/L), mangan (mg/L) ve arsenik (mg/L) gibi iz elementlerinin aylık ortalama değerleri bulunmaktadır. Tüm bu parametrelerin istatistiksel değerleri Çizelge 3.1 ve 3.2'de listelenmiştir.

**Çizelge 3.1.** Bursa meteorolojik parametreleri istatistikleri (1990-2019)

Parametre (Aylık ortalama değerler)	Minimum- Maksimum (Ortalama± Standart Sapma)
Buhar Basıncı (hPa)	4,65-22,52 (11,92±4,53)
Bağıl Nem (%)	49,11-87,86 (69,19±7,53)
Hava Sıcaklığı (°C)	1,00-27,64 (14,89±7,22)
Rüzgâr Hızı (m/s)	0,77-3,30 (1,99±0,46)
Yağış (mm)	0,00-26,70 (1,94±1,99)
Güneş Radyasyonu (kWh/m <sup>2</sup> )	0,05-7,16 (3,38±2,09)
Güneş Yoğunluğu (cal/cm <sup>2</sup> )	53,13-644,72 (322,47±155,49)
Evapotranspirasyon (mm)	0,09-30,15 (4,74±3,38)
Kar Kalınlığı (cm)	0,00-30,75 (0,97±3,02)
Buharlaşma (mm)	1,00-13,30 (5,12±2,50)

**Çizelge 3.2.** Doğancı Barajı su kalitesi parametreleri istatistikleri (1990-2019)

Parametre (Aylık izleme verileri)	Minimum- Maksimum (Ortalama± Standart Sapma)	ABD ÇKA Standartları <sup>a</sup> (USEPA, 2009)	DSÖ Standartları <sup>b</sup> (WHO, 2022)	Türk Standartları (TS266, 2005)
pH	7,443-8,451 (8,048±0,229)	6,5-8,5	6,5-8,0	6,5-9,5
Bulanıklık (NTU)	0,730-85,75 (6,378±7,384)	1	5	1
Su Sıcaklığı (°C)	5,214-23,206 (12,713±4,289)	-	-	-
Askıda Katı Madde (mg/L)	0,000-38,375 (4,983±5,875)	-	-	-
Çözünmüş Oksijen (mg/L)	0,800-9,913 (5,036±2,830)	-	-	-
Alkalinite (mg/L)	134,000-209,250 (169,120±20,463)	-	-	-
Demir (mg/L)	0,010-0,175 (0,047±0,032)	0,3	0,3	0,2
Mangan (mg/L)	0,013-0,288 (0,048±0,038)	0,05	0,1	0,05
Arsenik (mg/L)	0,004-0,006 (0,005±0,001)	0,01	0,01	0,01

a,b- ABD ÇKA, Amerika Birleşik Devletleri Çevre Koruma Ajansı anlamına gelir ve DSO, Dünya Sağlık Örgütü'nün kısaltılmış halidir

### 3.3.2. İklim değişikliğinin Doğancı Barajı su bütçesine etkisinin modellenmesi

Bursa Meteoroloji Müdürlüğü ile aylık meteorolojik verileri toplamak için iletişime geçilmiştir. Bu veriler, 1999-2019 tarihleri arasında Bursa'da bulunan on altı farklı konumu temsil eden verilerdir. Öte yandan, Doğancı Barajı için 1999-2021 tarihleri arasındaki hidrolojik veriler, Bursa Su ve Kanalizasyon İdaresi'nden (BUSKİ) elde edilmiştir. Meteorolojik veriler, aylık ortalama değerleri içermekte olup, bunlar bağıl nem, buhar basıncı, hava sıcaklığı, rüzgâr hızı, günlük toplam global güneş radyasyonu, güneş yoğunluğu, yağış, buharlaşma, evapotranspirasyon ile kar kalınlığıdır. Hidrolojik veriler, Doğancı Barajı'nın aylık ortalama hacmi, gelen ve giden su debisi ve su seviyesini içermektedir. Modeller, 1999-2019 yıllarına ait verilerle eğitilmiş ve test edilmiştir, çünkü bu yıllarda her iki değişken için de değerler tamdır. Her parametre için 252 değerden oluşan bir veri seti elde edilmiştir. Araştırma için seçilen parametrelerin istatistiksel değerleri Çizelge 3.3'te verilmiştir.

**Çizelge 3.3.** Kullanılan meteorolojik ve hidrolojik verilerin istatistikleri (1999-2019)

Parametreler	Ortalama ± Standart Sapma	Aralık (Minimum-Maksimum)
<b>Bursa'nın Meteorolojik Parametreleri (Aylık ortalama değerler)</b>		
Buhar Basıncı (hPa)	12,09±4,59	5,01-22,52
Hava Sıcaklığı (°C)	15,24±7,23	2,18-27,64
Bağıl Nem (%)	69,56±7,56	50,13-87,86
Rüzgâr Hızı (m/s)	2,06±0,46	0,77-3,30
Yağış (mm)	1,94±2,20	0,00-26,70
Güneş Radyasyonu (kWh/m <sup>2</sup> )	3,38±2,09	0,05-7,16
Güneş Yoğunluğu (cal/cm <sup>2</sup> )	323,12±161,83	53,13-644,72
Evapotranspirasyon (mm)	4,60±4,05	0,09-30,15
Buharlaşma (mm)	5,26±2,55	1,00-13,30
Kar Kalınlığı (cm)	0,98±3,18	0,00-30,75
<b>Doğancı Barajı'nın Hidrolojik Parametreleri (Aylık ortalama değerler)</b>		
Hacim (hm <sup>3</sup> )	29,80±7,88	8,92-41,35
Gelen Su Debisi (m <sup>3</sup> /gün)	497783,67±530709,90	1555,20-2959638,17
Giden Su Debisi (m <sup>3</sup> /gün)	239507,67±57012,68	44250,00-398533,68
Su Seviyesi (m)	325,40±6,05	305,38-333,35

İstatistik analizden anlaşılacağı üzere, incelenen tüm yıllar boyunca, barajdaki giriş suyu akış hızının çıkış akış hızından daha yüksek olduğu gözlemlenmiştir. Baraja gelen su miktarı, Uludağ'ın kış aylarındaki karlarının erimesiyle artmaktadır. İklim değişikliği ve artan nüfus, bu parametrelerde değişikliklere neden olabilir.

### 3.3.3. Doğancı Barajı su kalitesinin modellenmesi

Doğancı Barajı'nın su kalitesi parametrelerine ait veriler, Bursa Su ve Kanalizasyon İdaresi'nden (BUSKİ) elde edilmiştir. Bu veriler, su sıcaklığı, alkalinite, bulanıklık, pH, askıda katı madde, çözülmüş oksijen, arsenik, mangan ve demir konsantrasyonları gibi parametreleri içermektedir. Veriler, 1990-2020 dönemi için aylık ortalama değerlere sahiptir. Bu nedenle, yapay sinir ağı (YSA) modellenmesi belirtilen dönem için yapılmıştır. Tüm su kalitesi parametreleri için verilerin 372 değeri bulunmaktadır. Doğancı Barajı'nın su kalitesi verilerinin bazı istatistiksel özellikleri Çizelge 3.4'te verilmiştir.



**Çizelge 3.4.** Doğancı Barajı su kalitesi parametreleri istatistikleri (1990-2020)

Parametreler (Aylık Ortalama Değerler)	Ortalama±Standart Sapma	Minimum- Maksimum	ABD ÇKA Standartları <sup>c</sup> (USEPA, 2009)	DSÖ Standartları <sup>c</sup> (WHO, 2022)	Türk Standartları (TS266, 2005)
pH	8,047±0,226	7,443-8,451	6,5-8,5	6,5-8,0	6,5-9,5
Bulanıklık (NTU)	6,207±7,312	0,388-85,752	1	5	1
Su Sıcaklığı (°C)	12,881±4,367	5,214-23,206	-	-	-
Askıda Katı Madde (mg/L)	4,816±5,791	0,000-38,375	-	-	-
Çözünmüş Oksijen (mg/L)	5,036±2,830	0,800-9,912	-	-	-
Alkalinite (mg/L)	175,050±25,070	134,000- 242,000	-	-	-
Demir (mg/L)	0,043±0,030	0,007-0,175	0,3	0,3	0,2
Mangan (mg/L)	0,047±0,037	0,013-0,288	0,05	0,1	0,05
Arsenik (mg/L)	0,005±0,001	0,003-0,006	0,01	0,01	0,01

c,ç - ABD ÇKA, Amerika Birleşik Devletleri Çevre Koruma Ajansı'nın kısaltmasıdır ve DSÖ, Dünya Sağlık Örgütü'nün kısaltılmış halidir

### 3.4. YSA Uygulanması

Verilerin toplanmasının ardından, bir sonraki adım YSA kullanarak modellemeyi içermektedir. Bu çalışmada, yazılım olarak MATLAB R2022a kullanılmıştır. Yapay sinir ağı uygulaması, bir girdi katmanı, bir gizli katman ve bir çıktı katmanı içeren ileri beslemeli sinir ağlarından oluşmaktadır. İlk olarak, yanlış veya eksik verilerin kaldırılmasıyla veriler temizlenmiştir. Bu çalışmada, sağlanan verilerin %70'i model eğitimi için kullanılmıştır ve kalan %30'u test ve doğrulama için kullanılmıştır (Benzaghta vd., 2012; Kang vd., 2015; Rezaeianzadeh vd., 2016; Zhang vd., 2015). Modellerin eğitimi öncesinde veri normalizasyonu aşağıdaki denklem kullanılarak yapılmıştır:

$$D = \frac{D_i - D_{min}}{D_{mak} - D_{min}} \quad (3.5)$$

Denklem 3.5'te D boyutsuz normalize edilmiş bir değeri temsil etmektedir. Di ise verinin ith ölçümü için normalize edilmiş değeri, Dmak ve Dmin ise tüm eğitim ve test verilerinin maksimum ve minimum normalize edilmiş verilerdir.

Genellikle eğitim sırasında hata değerine dayanarak ağırlıkların ve eşik değerlerinin ayarlarını yapmaktadır. Eğer ağ veriye aşırı uyum sağlarsa, OKH değeri doğrulama sırasında artmaktadır. Diğer taraftan, test verileri modelin performansını doğrulamaktadır. Burada, ileri beslemeli sinir ağı gizli katmanda sigmoid aktivasyon fonksiyonu ve çıkış katmanda doğrusal aktivasyon fonksiyonu kullanmıştır, bu da sağlam bir sonuç için önerilir (Glorot ve Bengio, 2010). Epok sayısı 1000 olarak belirlenmiştir. (Buhari ve Adamu, 2012). OKH hedef olarak 0 olarak belirlenmiştir. İlk ağırlık değişimi 0,07 olarak ayarlanmıştır. Mevcut modellemede gizli katmandaki düğüm sayısı deneme yanılma yöntemiyle seçilmiştir. Bir ila elli arasında değişen gizli düğümler denenmiş ve modeller on düğümde daha iyi ve daha istikrarlı bir performans göstermiştir. Bu nedenle, her bir model için on gizli düğüm seçilmiştir. Tahmin için en uygun algoritmayı belirlemek amacıyla iki eğitim algoritması (EGY ve LM) test edilmiştir. Her iki algoritmanın da birbiriyle ilişkili avantajları ve dezavantajları vardır, ancak amaç, sağlanan veriler için en doğru olanı tespit etmektir.

### **3.5. Test Edilen Model Yapıları**

İlk modellemede meteorolojik parametreler girdi olarak alınmış ve barajın su kalitesi parametreleri yapay sinir ağlarının çıktıları olarak tanımlanmıştır. Meteorolojik parametreler giriş olarak alınmış ve barajın su kalite parametreleri sinir mimarisinin çıktıları olarak tanımlanmıştır. Üç farklı giriş ve çıktı kombinasyonu modellenmiş ve test edilmiştir. İlk modelde, hava sıcaklığı, global güneş radyasyonu ve güneş yoğunluğu giriş parametreleri olarak alınmış ve buna karşılık su sıcaklığı, pH, çözünmüş oksijen, mangan, arsenik ve demir konsantrasyonları çıktı olarak seçilmiştir. İkinci tanımlanan modelde, rüzgâr hızı, buharlaşma, buhar basıncı ve evapotranspirasyon giriş parametreleri olarak alınmış ve buna karşılık barajın su sıcaklığı, pH, bulanıklık, çözünmüş oksijen, askıda katı madde, arsenik ve demir konsantrasyonları seçilmiştir. Son olarak, yağış, kar kalınlığı ve bağıl nem, sırasıyla su sıcaklığı, pH, alkalinite, bulanıklık, çözünmüş oksijen, askıda katı madde, arsenik, mangan ve demir konsantrasyonlarını modellerken kullanılmıştır.

İkinci modelleme, meteorolojik parametrelerin girdi olarak ve Doğancı Barajı'nın su bütçesi parametrelerinin çıktı olarak alınmasıyla yapılmıştır. Üç farklı model eğitilmiş ve test edilmiştir. İlk modelde, aylık ortalama hava sıcaklığı, buharlaşma,

evapotranspirasyon, güneş radyasyonları ve güneş yoğunluğunun giriş olarak kullanılmış ve Doğancı Barajı'nın su seviyesi, hacmi, gelen ve giden su akış hızı hedeflenmiştir. Her modelde çıkışlar aynı tutulmuştur. Tek fark giriş parametrelerinde olmuştur. İkinci modelde, aylık ortalama rüzgâr hızı ve buhar basıncı giriş olarak kullanılmıştır. Son modelde ise aylık ortalama yağış, kar kalınlığı ve bağıl nem giriş parametreleri olarak seçilmiştir. Korelasyon katsayısı (R) ve OKH, en iyi tahmin uyumunu belirlemek için karşılaştırılmıştır.

Son modelleme ise Doğancı Barajı'nın su kalitesi parametrelerinin farklı kombinasyonlarını girdi ve çıktı olarak ele alıp birbirleri üzerindeki etkilerini görmek için yapılmıştır. Birinci modelde, Doğancı Barajı'nın su sıcaklığı, bulanıklık ve pH değerlerini giriş parametreleri olarak kullanırken, çözülmüş oksijen, alkalinite ve askıda katı madde, arsenik, mangan ve demir konsantrasyonları çıkış olarak belirlenmiştir. Benzer şekilde, ikinci modelde su sıcaklığı, alkalinite, pH ve çözülmüş oksijen konsantrasyonu giriş parametreleri olarak tanımlanmıştır. İkinci modelinin çıktıları, arsenik, mangan ve demir gibi iz metallerin konsantrasyonları olarak seçilmiştir.

Literatür taramasında (Bölüm 2) belirtildiği gibi, bir barajın su kalitesi ve su bütçesi üzerine tahminler yapmak için önceki çalışmalarda farklı meteorolojik parametre kombinasyonları kullanılmıştır. Bu nedenle, mevcut modellemelerde meteorolojik ve Doğancı Barajı'nın su kalitesi ve su bütçesi parametrelerinin kombinasyonu, önceki çalışmalara dayanarak yapılmıştır. Meteorolojik ve Doğancı Barajı suyu arasındaki ilk modellemelerden bahsederken, daha önce incelenen çalışmalarda iz element konsantrasyonlarının analiz için dikkate alınmadığı görülmüştür. İz elementler, artan antropojenik kirlilik ve iklim değişikliği ile bağlantılı olarak bir barajın su kalitesinin tahmin edilmesinde önemli parametrelerdir. Araştırmamızda bu parametrelerin dikkate alınması çalışmanın özgünlüğünü de ortaya koymaktadır. Öte yandan, su bütçesi hakkında konuşulduğunda, çoğu çalışma meteorolojik parametreleri dikkate alarak barajın su seviyesi tahminleri ile ilgilenmektedir. İkinci modellemede test edilen tüm modellerde, Doğancı Barajı'nın hacmi ve gelen ve giden su akışı, su seviyesi ile birlikte değerlendirilmiştir.

## 4. BULGULAR VE TARTIŞMA

Bu bölümde, yapay sinir ağları modellemesinden elde edilen sonuçlar ve bunların benzer alanda yapılmış önceki çalışmalarla karşılaştırması verilmektedir. Ayrıca elde edilen sonuçların istatistiksel analizi yapılarak yapılan modellemeye uygun eğitim algoritması belirlenmektedir.

### 4.1. Birinci Modelleme: İklim Değişikliğinin Doğancı Barajı Su Kalitesi Üzerindeki Etkisinin Tahmini

Çizelge 3.1'den gözlemlenebileceği gibi, minimum ortalama hava sıcaklığı 1°C olarak belirlenmiştir. Ancak, tüm çalışma yıllarında suyun minimum sıcaklığı 5,21°C olarak tespit edilmiştir (Çizelge 3.2). Bununla birlikte, suyun maksimum ortalama sıcaklığı havanınkinden daha düşüktür. Bunun nedeni, suyun hidrojen bağları nedeniyle yüksek bir ısı kapasitesine sahip olmasıdır. Su, sıcaklığı önemli ölçüde artırmadan büyük miktarlarda ısıyı emme yeteneğine sahiptir. İkinci dikkat çekici özellik, Doğancı Barajı'nın suyundaki bazı iz elementlerin konsantrasyonudur. En yüksek konsantrasyon mangandır (ortalama 0,05 mg/L), en düşük konsantrasyon ise arsenikte bulunmaktadır (ortalama 0,005 mg/L). Mangan için ortalama değer, ABD ÇKA ve TS 266 içme suyu kalite standartları tarafından belirlenen sınıra neredeyse dokunmaktadır ve maksimum değer (0,288 mg/L) dikkate alınan tüm içme suyu kalite standartlarını aşmaktadır. Bu durum, içme suyu tüketimindeki yüksek mangan konsantrasyonlarının insanlarda nörolojik hastalıklara yol açabileceği için endişe verici olabilmektedir (WHO, 2022). Demir ve arsenik konsantrasyonları için ortalama değerler, içme suyu standartlarına uygun görünmektedir. Bununla birlikte, arsenik durumunda bile, ABD ÇKA yönergelerine göre uzun süreli maruziyette küçük konsantrasyonlar tehdit oluşturabilir (Pontius vd., 1994). Bulanıklık değerlerine bakıldığında, Doğancı Barajı için ortalama değer 6.378 NTU'dur ve bu, ABD ÇKA, DSÖ ve Türk standartları tarafından belirlenen içme suyu sınırlarından daha yüksektir. Bulanıklığın artışı, iklim değişikliğinden kaynaklanan daha güçlü fırtınalar, yüksek su seviyeleri veya barajdaki su hızının artması nedeniyle erozyondan kaynaklanabilir (Jeppesen vd., 2015). Bununla birlikte, bu durum Doğancı Barajı suyunu kullanmakta olan insanlar üzerinde olumsuz etkilere neden olabilir.

Çok katmanlı ileri beslemeli sinir ağları kullanılarak yapılan modelleme sonuçları Çizelge 4.1’de verilmiştir. Model 1a’yı düşündüğümüzde, üç meteorolojik giriş (hava sıcaklığı, global güneş radyasyonu ve güneş yoğunluğu) ve Doğancı Barajı'nın su kalitesine ait altı çıktı (su sıcaklığı, pH, çözünmüş oksijen, mangan, arsenik ve demir konsantrasyonları) için çalışmanın oldukça başarılı olduğu sonucuna varılmıştır. Eğitim, test, doğrulama ve tüm veri seti için R değeri 0,93-0,99 arasında bulunmuş ve gözlenen ve tahmin edilen veriler arasında güçlü bir ilişki olduğunu göstermiştir. Ortalama kare hata (OKH) değeri de düşüktür, yani yaklaşık olarak LM algoritması kullanıldığında 1,20 ve EGY algoritması kullanıldığında 1,68'dir.

Model 2a'ye gelindiğinde, tam veri setine bakıldığında, R değeri eğitim algoritmaları göz önünde bulundurulduğunda 0,81-0,86 arasında bulunmuştur. Bu, gözlenen ve tahmin edilen uyum arasında iyi bir ilişki olduğunu göstermektedir, ancak model 1a kadar güçlü değildir. OKH değeri de model 1a'dan daha yüksektir ve çalışmada test edilen her iki eğitim algoritması için 6,26 ila 11,91 arasında değişmektedir.

Model 3a’da ise, su sıcaklığı, pH, alkalinite, bulanıklık, çözünmüş oksijen, askıda katı madde, arsenik, mangan ve demir konsantrasyonları olmak üzere dokuz su kalitesi parametresi, giriş olarak yağış, kar kalınlığı ve nispi nem alınmıştır. Sonuçlar, tüm veri seti için birinci iki modele kıyasla daha düşük bir korelasyon katsayısı elde ettiğini göstermiştir, yani yaklaşık olarak 0,58 ila 0,66 arasındadır ve zayıf bir tahmin uyumunu işaret etmektedir. OKH değerleri hakkında konuşulduğunda, LM algoritması kullanıldığında 11,16 ve EGY algoritması kullanıldığında 11,01 arasında değişmektedir, bu da model 1a'dan daha yüksektir.

Tüm test edilen modelleri karşılaştırdığımızda, model 1a'nın, gözlenen ve tahmin edilen değerler arasında daha düşük bir OKH (1,20-1,68) ve daha yüksek bir R (0,93-0,99) ile daha güvenilir bir tahmin yeteneği gösterdiği görülmüştür. OKH değeri ne kadar sıfıra yakınsa, tahminler o kadar güvenilir olmaktadır. Bu çalışmanın sonuçları önceki araştırmalardaki değerlerle karşılaştırılarak, modelin güvenilirliği değerlendirilmiştir. Model yapılarının çalışma verimleri büyüklük sıralamalarına göre değerlendirildiğinde, OKH değerine göre Model3a>Model2a>Model1a, R değeri ise, Model1a>Model2a>Model3a şeklinde bulunmuştur.

**Çizelge 4.1.** Birinci modelleme: İleri beslemeli sinir ağı modellemesi sonuçları

Model	Girişler (Aylık ortalama değerler)	Çıktılar (Aylık ortalama değerler)	YSA Yapısı	Denetleme				OKH
				R Değerleri				
				Eğitim	Deneme	Doğrulama	Tüm Veri Kümesi	
Model 1a.	<ul style="list-style-type: none"> <li>Hava sıcaklığı (°C)</li> <li>Global güneş radyasyonu (kWh/m<sup>2</sup>)</li> <li>Güneş yoğunluğu (cal/cm<sup>2</sup>)</li> </ul>	<ul style="list-style-type: none"> <li>Su sıcaklığı (°C)</li> <li>pH</li> <li>Çözünmüş oksijen (mg/L)</li> <li>Arsenik (mg/L)</li> <li>Mangan (mg/L)</li> <li>Demir (mg/L)</li> </ul>	3-10-6	EGY: 0,99031 LM: 0,99252	EGY: 0,93702 LM: 0,93271	EGY: 0,97481 LM: 0,98139	EGY: 0,98246 LM: 0,98419	EGY: 1,6807 LM: 1,1995
Model 2a.	<ul style="list-style-type: none"> <li>Rüzgâr hızı (m/s)</li> <li>Buharlaşma (mm)</li> <li>Buhar basıncı (hPa)</li> <li>Evapotranspirasyon (mm)</li> </ul>	<ul style="list-style-type: none"> <li>Su sıcaklığı (°C)</li> <li>pH</li> <li>Bulanıklık (NTU)</li> <li>Çözünmüş oksijen (mg/l)</li> <li>Askıda katı madde (mg/l)</li> <li>Arsenik (mg/l)</li> <li>Demir (mg/l)</li> </ul>	4-10-7	EGY: 0,81675 LM: 0,89479	EGY: 0,85025 LM: 0,73438	EGY: 0,74738 LM: 0,84478	EGY: 0,80832 LM: 0,85980	EGY: 11,9053 LM: 6,2589
Model 3a.	<ul style="list-style-type: none"> <li>Toplam yağış (mm)</li> <li>Kar kalınlığı (cm)</li> <li>Bağıl nem (%)</li> </ul>	<ul style="list-style-type: none"> <li>Su sıcaklığı (°C)</li> <li>pH</li> <li>Alkalinite (mg/l)</li> <li>Bulanıklık (NTU)</li> <li>Askıda katı madde (mg/l)</li> <li>Çözünmüş oksijen (mg/l)</li> <li>Arsenik (mg/l)</li> <li>Mangan (mg/l)</li> <li>Demir (mg/l)</li> </ul>	3-10-9	EGY: 0,69934 LM: 0,68462	EGY: 0,51694 LM: 0,35175	EGY: 0,74147 LM: 0,74684	EGY: 0,66439 LM: 0,57835	EGY: 11,0110 LM: 11,1604


R değeri, gözlenen ve tahmin edilen veriler arasındaki korelasyonu göstermektedir. OKH değeri ise ortalama kare hatasını temsil etmektedir.

Bu tartışma, tüm modellerin tam veri setleri için elde edilen R değerlerini karşılaştıran Şekil 4.1'e bakılarak daha da güçlendirilebilir. Model 1a'da veri noktalarının homoskedastik olduğu (çok az aykırı değerle) görüldü, bu da tahmininde güvenilirliğini


göstermektedir. Noktalar, korelasyon çizgisi boyunca yayılmıştır, bu da gözlenen ve tahmin edilen değerler arasında tutarlılık olduğunu göstermektedir.

### Esnek Geri Yayılım Algoritması


### Levenberg-Marquardt Algoritması




Model 1a




Model 1a




Model 2a



Model 2a



Model 3a



Model 3a

Şekil 4.1. Birinci modelleme: EGY eğitim algoritması ve LM eğitim algoritması kullanan modellerin korelasyon katsayılarının grafiksel gösterimi

Yapılan diğler çalıřmalara göre, Kang vd. (2015) benzer bir çalıřması için korelasyon katsayısı aralıđı test ve dođrulama için 0,66-0,71 arasında bulunmuřtur (Çizelge 4.2). Benzer řekilde, Park vd. (2015) çalıřmasında korelasyon deđer 0,71 ile 0,74 arasında bulunmuřtur. Bu çalıřmada elde edilen model 1a için korelasyon katsayısı (0,93 ile 0,99 arasında) daha önce bahsedilen çalıřmalardan daha yüksektir. Ayrıca, Zhang vd. (2015) analiziyle elde edilen R deđerleriyle karřılařtırıldıđında, eđitim, test ve dođrulama ařamalarının tamamı için önerilen model 1a için deđerler daha yüksektir.

Önceki bahsedilen çalıřmalarda R-deđerlerinin aralıđı 0,59 ile 0,99 arasında bulunmaktadır. Tüm veri seti için korelasyon katsayısı en yüksek deđer model 1a (0,98'a kadar) için saptanmıřtır, en düşük deđer ise model 3a (0,58-0,66) için bulunmuřtur. Bu durum, tüm tanımlanan modellerin korelasyon deđerlerinin daha önce yapılan çalıřmaların aralıđında olduđunu göstermektedir. Ancak, karřılařtırma yapıldıđında model 1a, diđer test edilen modellere göre iyi bir performans sergilemiřtir.

Dikkate alınan bir diđer faktör hata deđerleridir. Daha önce listelenen çalıřmalarda, iyi performans gösteren modeller için hata deđerleri 0,003 ile 3,12 arasında yer almaktadır. Çizelge 4.2'de listelenen diđer çalıřma 2a (0,003-0,01) ve çalıřma 4a (0,05-0,06) için hata deđerleri, önerilen model 1a'dan (1,20-1,68) daha düşüktür. Ancak, hata deđerlerinin üst sınırı (3,12), önerilen model 1a'ninkinden daha büyüktür. Bu çalıřmada diđer test edilen modellerin hata deđerleri hakkında konuřursak, model 2a'nın en düşük hata deđer 6,26 iken, model 3a'nın hata deđer 11,01'dir. Bu deđerler, geçmiř literatürde belirtilen hata aralıđının üzerindedir. Hata deđerleri ne kadar yüksek olursa, gerçek ve tahmin edilen deđerler arasında o kadar fazla fark olma ihtimali artar. Bu durum, model 1a'nın barajların su kalitesiyle ilgili tahminler için en geçerli model olduđunu göstermektedir.

Bu nedenle, model 1a'nın Dođancı Barajı su kalitesinin gelecekteki tahminleri için kullanılabileceđi görölmüřtür. Ayrıca, R ve OKH deđerlerinin giriş ve çıkıř parametrelerine göre deđiřtiđi görölmektedir. Diđer çalıřmalarda su kalitesi ile yađıř, hava sıcaklıđı, atmosfer basıncı, nem, rüzgâr hızı ve güneř radyasyonunun iliřkili olduđu görölmüřtür. Ancak, bu çalıřmada, önerilen en iyi model yapısı olan model 1a için aylık ortalama hava sıcaklıđı, aylık ortalama toplam günlük global güneř radyasyonu ve güneř yoğunluđu parametreleri Dođancı Barajı'nın aylık ortalama su sıcaklıđı, pH, aylık ortalama çözünmüř oksijen, arsenik, mangan ve demir konsantrasyonları üzerinde



etkilerini tahmin etmek için giriş olarak kullanılmıştır. Bu çalışmada test edilen bu meteorolojik parametreler diğer çalışmalara ve model 2a ve model 3a'ya göre daha güvenilir sonuçlar vermiştir.

Birinci modelleme çalışmasında, model 1a sonuçlarına göre, hava sıcaklığı, güneş radyasyonu ve güneş yoğunluğu parametreleri Doğancı Barajı'nın su kalitesini en çok etkileyebilecek parametreler olarak bulunmuştur. Diğer yandan, model 3a'nın performansına göre meteorolojik parametreler arasında yağış, nem ve kar kalınlığı parametrelerinin su kalitesini tahmin etmede en az etkili olduğu belirlenmiştir.

İklim Değişikliği Hükümetler Arası Paneli (IPCC) hava sıcaklığında artış olacağını öngörmektedir. Bu artış, Doğancı Barajı'nın su kalitesini olumsuz yönde etkileyebilir. Örnek olarak, bu durum baraj suyunun sıcaklık düzeyinde artışa ve aynı zamanda çözünmüş oksijen konsantrasyonunda azalmaya neden olabilir (Mosley, 2015). Dolayısıyla, su kalitesinin olumsuz değişimleriyle başa çıkabilmek için önceden alınacak tedbirler, söz konusu modellemeler yoluyla ele alınabilecektir.

**Çizelge 4.2.** Meteorolojik parametrelerle baraj su kalitesi tahmini

Çalışma	Girdi (Meteorolojik parametreler)	Çıktı (Baraj için su kalitesi parametreleri)	İleri Beslemeli Sinir Ağı Yapısı	Korelasyon Katsayısı <sup>d</sup>	Hata Değerleri <sup>e</sup>	Referans
Diğer Çalışma 1a.	Günlük yağış, maksimum ve minimum sıcaklık ve nem	Askıda katı madde, toplam nitrojen ve toplam fosfor	1 giriş, 1 gizli ve 1 çıkış katmanı	0,66-0,71	0,11-3,12	(Kang vd., 2015)
Diğer Çalışma 2a.	Günlük atmosferik sıcaklık, yağış ve güneşlenme saatleri	Su sıcaklığı, toplam fosfor ve klorofil-a	1 giriş, 3 gizli ve 1 çıkış katmanı	0,59-0,99	0,003-0,01	(Zhang vd., 2015)
Diğer Çalışma 3a.	Güneş radyasyonu ve rüzgâr hızı	Klorofil-a	1 giriş, 1 gizli ve 1 çıkış katmanı	0,71-0,74	-	(Park vd., 2015)
Diğer Çalışma 4a.	Günlük yağış	İletkenlik ve çözünmüş oksijen	1 giriş, 2 gizli ve 1 çıkış katmanı	-	0,05-0,06	(Elhatip ve Kömür, 2008)

d,e Hata ve korelasyon katsayısı değerleri aralığı eğitim, test ve doğrulama içindir

ANOVA, "Varyans Analizi" olarak adlandırılan bir istatistiksel yöntemdir. ANOVA, veri grupları arasındaki farkların istatistiksel olarak anlamlı olup olmadığını belirlemede kullanılır. Boş hipotez, iki veya daha fazla grubun ortalamaları arasında istatistiksel olarak anlamlı bir fark olmadığını belirtirken, alternatif hipotez ise iki veya daha fazla grubun ortalamaları arasında anlamlı bir fark olduğunu ifade eder. Eğer p değeri, belirlenen anlamlılık düzeyi 0.05'ten büyükse, bu durumda incelenen grupların ortalama

değerleri ve varyansları arasında kritik farklılıkların olmadığı sonucuna ulaşılır (Kim, 2014).

Önceki araştırmalarda, meteorolojik parametreler kullanarak su kütlelerinin su kalitesini tahmin etmek için farklı yapay teknikler kullanılarak elde edilen sonuçlar arasındaki anlamlı farklılıkları belirlemek için ANOVA yöntemi kullanılmıştır (Merdun ve Çinari, 2010; Said ve Khan, 2021; Solanki vd., 2015; Tselemonis vd., 2023; Zubaidi vd., 2020). Ancak, bilindiği kadarıyla, LM ve EGY eğitim algoritmalarının R ve OKH değerlerini karşılaştırmak için bu yöntem daha önce kullanılmamıştır.

Bu çalışmada p değeri (R için  $p=0,946$  ve OKH için  $p=0,209$ ) anlamlılık düzeyi göre 0.05'ten yüksek bulunduğu için, esnek geri yayılı algoritma ve Levenberg-Marquardt eğitim algoritması arasında istatistiksel değerlendirmeye (varyans analizi-ANOVA) göre iki eğitim algoritması arasında anlamlı bir fark olmadığı görülmüştür. Ayrıca, etki büyüklüğü çok küçük olup (0,001 ile 0,05 arasında), bu da algoritmalar arasındaki farkın önemsiz olduğunu daha da vurgulamaktadır. Bu istatistiksel inceleme JASP 0.16.3 sürümünde yapılmıştır (Goss-Sampson, 2019).

Ancak, görsel olarak analiz edildiğinde, Levenberg-Marquardt eğitim algoritmasının korelasyon ve ortalama kare hatası değerlerine dayanarak elastik geri yayılı algoritmadan daha iyi bir performansa sahip olduğu söylenebilir. En iyi model olan model 1a'da baktığımızda, Levenberg-Marquardt algoritması kullanılarak korelasyon katsayısı 0,984 ve OKH 1,20 bulunmuştur. Esnek geri yayılı algoritma kullanıldığında ise bu değerler sırasıyla 0,982 ve 1,68'dir. Bu değerler yeterince yakın olsa da, LM algoritması daha yüksek performansa sahiptir.

**Çizelge 4.3.** Birini modelleme: Algoritmaları karşılaştırırken modellerin (a) R ve (b) OKH değerleri için ANOVA sonuçları

Parametreler	Kareler Toplamı	df	Ortalama Kare	F	p	$\eta^2$
Algoritmalar	$1,796e^{-4}$	1	$1,796e^{-4}$	0,005	0,946	0,001
Artıklar	0,137	4	0,034			

(a)

Parametreler	Kareler Toplamı	df	Ortalama Kare	F	p	$\eta^2$
Algoritmalar	5,956	1	5,956	0,209	0,671	0,050
Artıklar	113,746	4	28,437			

(b)

## 4.2. İkinci Modelleme: İklim Değişikliğinin Doğancı Barajı Su Bütçesine Etkisinin Tahmin Edilmesi

Detaylı analizden elde edilen sonuçlar Çizelge 4.4'te verilmiştir. Tüm modeller için R ve OKH değerlerine bakılarak, model 1b'nin en iyi uyumu sağladığı görülebilir. Her iki algoritma da dikkate alındığında, model 1b tüm veri seti için yüksek bir R değerine sahiptir (0,99). Ayrıca, diğer modellere göre en düşük OKH'ye sahiptir (LM için 0,59 ve EGY kullanıldığında ise 46,8), diğer modellerde ise doğrulama aşamasında önemli ölçüde büyük hatalar bulunmaktadır. Başka bir deyişle, tüm modeller aynı çıkış parametrelerine sahiptir, ancak analiz, hava sıcaklığı, güneş radyasyonu, güneş yoğunluğu, buharlaşma ve evapotranspirasyonu giriş meteorolojik parametreleri olarak kullanan modelin, Doğancı Barajı'nın hidrolojik verilerindeki değişime en çok tanımlayan ve ilişkilendiren model olduğunu göstermektedir. Bu nedenle, model 1b'nin meteorolojik parametrelerindeki bir değişikliğin, barajın su hacmi, akış hızları ve seviyesi üzerinde önemli bir etkiye sahip olabileceği yorumlanabilir.

Model 2b ve Model 3b'deki hataların büyüklüğü oldukça yüksektir (genel olarak  $2,4 \times 10^{10}$  ila  $7,9 \times 10^{10}$  arasında değişmektedir) ve R değerleri de model 1b'ye göre daha düşüktür (model 2b için yaklaşık olarak 0,82 ila 0,83 ve model 3b için 0,68 ila 0,70). Model 2b'deki girişler rüzgâr hızı ve buhar basıncıdır. Benzer şekilde, model 3b'de yağış, kar kalınlığı ve bağıl nem giriş olarak kullanılmıştır. Model 2b'de gözlenen ve tahmin edilen değerler arasında iyi bir korelasyon göstermektedir. Bununla birlikte, kullanılan eğitim algoritmasının türüne bakılmaksızın oldukça yüksek olan hata göz önüne alındığında, bu, Doğancı Barajı'nın hidrolojisinin gelecekteki tahminleri için tercih edilebilir bir model olmayabilir. Benzer şekilde, model 3b'de barajın hidrolojik parametreleri için gözlenen ve tahmin edilen değerler için model 2b'ye kıyasla daha düşük bir korelasyon (0,70'ye kadar) vermiştir.

Bu nedenle, analiz sonuçlarından elde edilen bulgulara göre model 1b'nin en yüksek korelasyon ve en düşük hata değerine sahip olduğu ve dolayısıyla en iyi performansı sergilediği söylenebilir. Ardından, model 2b iyi sonuçlar göstermiştir. Model 3b ise en yüksek hata değerine ve en düşük korelasyon değerine sahiptir. Tüm modeller, Doğancı Barajı'nın su hacmi, seviyesi, gelen ve giden su akışını tahmin etmek için kullanılmıştır.

**Çizelge 4.4.** İkinci modelleme: İleri beslemeli sinir ağlarından elde edilen sonuçlar

Model	Girişler (Aylık ortalama değerler)	Çıktılar (Aylık ortalama değerler)	YSA Yapısı	Denetleme				OKH
				R Değerleri				
				Eğitim	Deneme	Doğrulama	Tüm Veri Kümesi	
Model 1b.	<ul style="list-style-type: none"> <li>Hava sıcaklığı (°C)</li> <li>Güneş radyasyonu (kWh/m<sup>2</sup>)</li> <li>Güneş yoğunluğu (cal/cm<sup>2</sup>)</li> <li>Buharlaşma (mm)</li> <li>Evapotranspirasyon (mm)</li> </ul>	<ul style="list-style-type: none"> <li>Hacim (hm<sup>3</sup>)</li> <li>Gelen su debisi (m<sup>3</sup>/gün)</li> <li>Giden su debisi (m<sup>3</sup>/gün)</li> <li>Su seviyesi (m)</li> </ul>	5-10-4	EGY: 0,99823 LM: 1	EGY: 1 LM: 1	EGY: 0,99926 LM: 0,99999	EGY: 0,9982 LM: 0,99996	EGY: 46,8353 LM: 0,59257
Model 2b.	<ul style="list-style-type: none"> <li>Rüzgâr hızı (m/s)</li> <li>Buhar basıncı (hPa)</li> </ul>	<ul style="list-style-type: none"> <li>Hacim (hm<sup>3</sup>)</li> <li>Gelen su debisi (m<sup>3</sup>/gün)</li> <li>Giden su debisi (m<sup>3</sup>/gün)</li> <li>Su seviyesi (m)</li> </ul>	2-10-4	EGY: 0,83633 LM: 0,89876	EGY: 0,79397 LM: 0,62345	EGY: 0,85413 LM: 0,93957	EGY: 0,82412 LM: 0,83057	EGY: 3,9x10 <sup>10</sup> LM: 2,4x10 <sup>10</sup>
Model 3b.	<ul style="list-style-type: none"> <li>Yağış (mm)</li> <li>Kar kalınlığı (cm)</li> <li>Bağıl nem (%)</li> </ul>	<ul style="list-style-type: none"> <li>Hacim (hm<sup>3</sup>)</li> <li>Gelen su debisi (m<sup>3</sup>/gün)</li> <li>Giden su debisi (m<sup>3</sup>/gün)</li> <li>Su seviyesi (m)</li> </ul>	3-10-4	EGY: 0,69929 LM: 0,69352	EGY: 0,70283 LM: 0,76260	EGY: 0,60448 LM: 0,65079	EGY: 0,68580 LM: 0,69542	EGY: 7,9x10 <sup>10</sup> LM: 6,7x10 <sup>10</sup>

Elde edilen hata ve katsayı değerleri model 1b için önceki çalışmalardan elde edilen değerlerle karşılaştırılmıştır (Çizelge 4.5). Hatalara bakıldığında, model 1b'deki LM eğitim algoritması kullanılarak elde edilen OKH değeri 0,59 olarak bulunmuştur ve Çizelge 4.5'te listelenen çalışmalar 1b ve 6b'den daha yüksektir. Bununla birlikte, Norris, Doroozdan, Asa, Kampe ve Batu barajları üzerinde yapılan benzer çalışmalarla karşılaştırıldığında daha düşüktür, bu da tahminler için kabul edilebilir olduğunu göstermektedir. EGY eğitim algoritmasını kullanan model 1b için hata, 3b. çalışma (Doroozdan barajında) hariç, listelenen tüm çalışmalardan daha yüksek olan 46,84'tir. Hatalar mümkün olduğunca düşük olmalıdır, bu nedenle LM eğitim algoritmasının çalışmamızda daha iyi performans gösterdiği düşünülmektedir.

Dikkate alınan önceki arařtırmaların hata aralıđı 0,11 ila  $34,6 \times 10^6$  arasında deđiřmektedir. Model 2b'nin hata deđerı  $3,9 \times 10^{10}$ 'a kadar ıkarken, model 3b'nin hata deđerı  $6,7 \times 10^{10}$  ila  $7,9 \times 10^{10}$  arasında deđiřmektedir. Bu hata deđerleri, diđer önceki yapılan alıřmalardan belirlenen aralıđın üzerindedir. Bu modellemede test edilen modeller arasında, bu aralıktaki OKH deđerine sahip olan tek model 1b'dir. Bu nedenle, model 1b, meteorolojik parametreler kullanılarak su bütesi için gelecekteki tahminler aısından güvenilir bir seenektir.

Öte yandan, korelasyon katsayılarını karřılařtırırken, model 1b için R deđerı tüm veri seti için yaklaşık olarak 0,99 olarak bulunmuřtur. Bu R deđerı, izelge 4.5'te verilen diđer ilgili alıřmalardan daha yüksek olup, 4b (R: 0,99), 5b (R: 0,96) ve 6b (R: 0,99) numaralı alıřmalara en yakın deđerdir. Eđitim algoritmaları tartıřıldıđında, LM ve EGY algoritmalarının gözlenen ve tahmin edilen sonular arasında neredeyse aynı yüksek korelasyona sahip olduđu görölmüřtür.

Eđer korelasyon katsayısı 1'e yakınsa, bu durumda tahminlerin dođruluđu artar, ünkü tahmin edilen ıktı deđerleri test edilen deđerlere ok yakındır. Diđer arařtırmalardan (izelge 4.5) elde edilen R deđerleri 0,64 ile 0,99 arasında deđiřmektedir. Önceden bahsedildiđi üzere, model 1b'nin korelasyon katsayısı 0,99'a kadar yüksek bulunmuřtur. Model 2b de korelasyon aısından iyi sonular göstermiř, tüm veri kümesi için R deđerı 0,82-0,83 aralıđında ıkmıřtır. Son olarak, model 3b ortalama bir performans sergilemiř ve tüm veri kümesi için R deđerı 0,68-0,69 aralıđında tespit edilmiřtir. Bu test edilen modellerin tümünün, önceki alıřmaların korelasyon katsayısı aralıđında yer alması, yalnızca korelasyon katsayılarına bakıldıđında tüm modellerin tahminler için kabul edilebilir olduđunu göstermektedir ve model 1b bu bađlamda en iyi performansı sergilemektedir.

Ancak, model 2b ve model 3b'nin hataları önceki alıřmalar ve model 1b ile karřılařtırıldıđında oldukça büyük görünmektedir. Bu nedenle, meteorolojik parametreleri dikkate aldıđımızda, model 1b'nin barajın su bütesi için en dođru tahminleri vereceđi söylenebilir.

İkinci modelleme alıřmasının tüm analizlerinin bir özeti olarak, hava sıcaklıđı, güneř radyasyonu, güneř yoğunluđu, buharlařma ve evapotranspirasyon gibi meteorolojik parametrelerin barajın su hacmi, seviyesi, gelen ve giden akıřı üzerinde yüksek olasılıkla

etkili olduğu tespit edilmiştir. Bu parametreler, barajın hidrolojik özelliklerini belirlemede önemli bir rol oynamaktadır. Ayrıca, birinci modelleme çalışmasıyla uyumlu olarak, yağış, kar kalınlığı ve nem gibi meteorolojik parametrelerin barajın hidrolojik özellikleri üzerinde diğer parametrelere göre daha az etkili olduğu görülmüştür.

Genellikle diğer girişlerle birlikte, barajlardaki suyun simülasyonları için yağış tercih edilen meteorolojik parametredir (önceki çalışmalardan anlaşıldığı kadarıyla). Ancak, çalışmamızda diğer test edilen modellerden daha iyi performans gösteren model 1b, giriş olarak yağışı içermemektedir. Bu nedenle, bu çalışma, yağışın böyle belirlemeler için tek parametre olmadığını ortaya koymaktadır. Bunun yerine, hava sıcaklığı, güneş yoğunluğu veya radyasyon, buharlaşma veya evapotranspirasyon gibi diğer parametreler, barajın su hacmi, akış hızları veya/ve seviyeleri hakkında değerli sonuçlar sağlayabilir. Buna en yakın örneği, Benzaghta vd. (2012) Batu barajı üzerinde yaptığı bir çalışmadır. Bu sonuçlar, barajların su havzaları ve su yönetimi için etkin stratejilerin belirlenmesine ve uygulanmasına katkı sağlayabilir.

**Çizelge 4.5.** Meteorolojik parametreleri kullanarak baraj su bütçesi tahmini

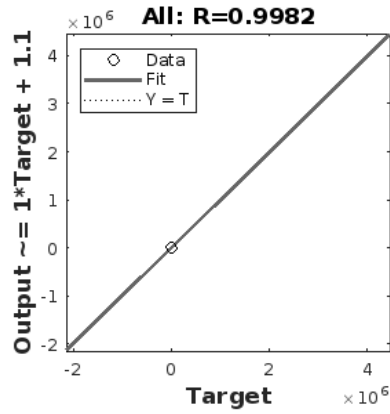
Çalışma	Baraj (Yer)	Girdiler (Meteorolojik parametreler)	Çıktılar (Hidrolojik parametreler)	Hatalar	Korelasyon katsayısı	Referans
Diğer Çalışma 1b.	Yalova Gökçe (Türkiye)	Yıllık Yağış	Baraj su seviyesi	0,11	0,87	(Damla vd., 2020)
Diğer Çalışma 2b.	Norris (Amerika)	Yıllık yağış ve hava sıcaklığı	Baraj giriş hacmi ve su seviyesi	11	0,81	(Rungee ve Kim, 2017)
Diğer Çalışma 3b.	Doroozdan (İran)	Aylık yağış	Baraja giriş hacmi	34,60x10 <sup>6</sup>	0,64	(Rezaeianzadeh vd., 2016)
Diğer Çalışma 4b.	Asa ve Kampe (Nijerya)	Yıllık hava sıcaklığı, yağış ve evapotranspirasyon	Baraja giriş hızı	-	0,99	(Salami vd., 2015)
Diğer Çalışma 5b.	Batu (Malezya)	Günlük hava sıcaklığı, rüzgâr hızı, bağıl nem, yağış, güneşlenme süresi ve güneş radyasyonu	Barajdan buharlaşma	1,22	0,96	(Benzaghta vd., 2012)
Diğer Çalışma 6b.	Yarseli (Türkiye)	Günlük yağış	Baraj su seviyesi	0,135	0,99	(Çalım, 2008)

Ayrıca, Şekil 4.2'deki korelasyon grafiklerini dikkate aldığımızda, model 1b'de korelasyon çizgisinin hedef değişkenlere (barajın su hacmi, akış hızları ve su seviyesi) çok iyi uyduğu fark edilebilir. Bununla birlikte, veriler model 2b ve model 3b'de

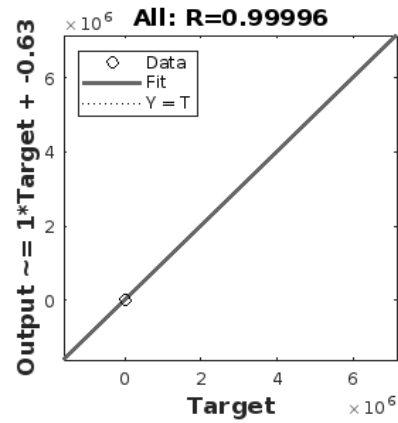
korelasyon çizgisinden dağılmış ve uzaklaşmış durumdadır, bu da verilerin heteroskedastik olduğunu göstermektedir. Bu terim, model 2b ve model 3b için hatalarda önemli bir varyans olduğunu ve korelasyon grafiklerindeki veri noktalarının korelasyon çizgisinden uzaklaşmasına neden olduğunu ifade eder. Bu durum, model 2b ve model 3b'nin model 1b'ye kadar doğru tahminler vermemiş olabileceğini tekrar ortaya koymaktadır.

### Esnek Geri Yayılım Algoritması


### Levenberg-Marquardt Algoritması




Model 1b




Model 1b




Model 2b



Model 2b



Model 3b



Model 3b

**Şekil 4.2.** İkinci modelleme: EGY ve LM eğitim algoritmaları kullanılarak test edilen modellerin korelasyon grafikleri

Çalışmanın ikinci amacı, esnek geri yayılım ve Levenberg-Marquardt algoritmaları arasından en iyi eğitim algoritmasını belirlemektir. İki eğitim algoritmasının kullanıldığı tüm test modelleri için elde edilen korelasyon ve ortalama kare hatası değerlerinin analizi için varyans analizi gerçekleştirilmiştir. İncelenen algoritmalar için R değerleri arasındaki karşılaştırmayı gösteren Çizelge 4.6(a)'ya bakıldığında, p değeri 0,965 ( $p > 0,05$  ve %95 anlamlılık düzeyinde), bu da farklı modeller için sağlanan R değerleri arasındaki farkın anlamlı olmadığını göstermektedir. Etki büyüklüğü ( $\eta^2$ ) de çok küçük olup ( $5,541e^{-4}$ ), bu da iki eğitim algoritması arasındaki farkın ihmal edilebilir olduğunu göstermektedir. Aynı durum, her iki algoritma için OKH değerleri için de geçerliydi, burada p değeri 0,807'dir ve etki büyüklüğü 0,017'dir. Dolayısıyla, her iki eğitim algoritması da verilerimizle aynı performansı sergilemektedir ve ileri beslemeli yapay sinir ağlarını kullanarak bir barajın hidrolojisi üzerinde iklim etkilerini belirlemek için istatistiksel olarak kanıtlandığında uygulanabilir.

Ancak, sonuçları görsel olarak yorumlamak, Levenberg-Marquardt algoritmasına bir avantaj sağlamıştır, çünkü incelenen tüm modeller için korelasyon değerleri daha yüksek ve hata değerleri esnek geri yayılım eğitim algoritmasına göre daha düşük olduğu görülmektedir. Levenberg-Marquardt eğitim algoritmasıyla model 1b'nin ortalama kare hatası değerleri de benzer alanlardaki önceki çalışmalarla uyumlu olduğu saptanmıştır.

Önceki çalışmalarda, baraj veya farklı su kaynaklarında su seviyesini veya su hacmini meteorolojik parametreler kullanarak tahmin etme sürecinde, farklı istatistiksel ve/veya yapay zekâ yöntemleri arasındaki önemli farkları belirlemek için ANOVA yöntemi



kullanılmıştır (El-Kenawy vd., 2022; Iqbal vd., 2021; Sahoo ve Jha, 2013). Ancak, bilindiği kadarıyla Levenberg-Marquardt ve esnek geri yayılım eğitim algoritmalarının bu tahminler için karşılaştırılmasında ANOVA yöntemi kullanılmamıştır. Bu, araştırmanın diğer bir orijinal yönüdür.

**Çizelge 4.6.** İkinci modelleme: Algoritmaları karşılaştırırken modellerin (a) R ve (b) OKH değerleri için ANOVA sonuçları

Parametreler	Kareler Toplamı	df	Ortalama Kare	F	p	$\eta^2$
Algoritmalar	5,298e <sup>-5</sup>	1	5,298e <sup>-5</sup>	0,002	0,965	5,541e <sup>-4</sup>
Artıklar	0,096	4	0,024			

(a)

Parametreler	Kareler Toplamı	df	Ortalama Kare	F	p	$\eta^2$
Algoritmalar	8,627e <sup>+19</sup>	1	8,627e <sup>+19</sup>	0,068	0,807	0,017
Artıklar	5,086e <sup>+21</sup>	4	1,272e <sup>+21</sup>			

(b)

### 4.3. Üçüncü Modelleme: Doğancı Barajı Su Kalitesi Parametrelerinin Kendi İçerisinde Modellenmesi

Çizelge 3.4'e bakarak, Doğancı Barajı'nın suyunun pH değerinin çalışma süresi boyunca çok farklı olmadığı görülebilir, yani 7,4 ile 8 arasında değişmektedir. Bununla birlikte, bulanıklık, su sıcaklığı, askıda katı madde, çözünmüş oksijen ve alkalinite için maksimum ve minimum değerler arasında belirgin bir fark vardı, bu da yüksek standart sapma değerleriyle de belirtilmiştir. Bu fark, Bursa'daki mevsimsel değişikliklerden kaynaklanabilir. İz element değerlerine bakarsak, mangan için ortalama değer (0,047 mg/L), ABD ÇKA ve Türk standartları (0,05 mg/L) tarafından belirlenen sınıra yaklaşmış olup, maksimum değer bu sınırları aşmaktadır. Demir için aralık ve ortalama değerler kabul edilebilir, arsenik konsantrasyonu da sınırlar içinde olduğu görülmektedir, ancak zamanla konsantrasyon artarsa endişe verici olabilir.

Çizelge 4.7, farklı eğitim algoritmaları kullanarak her model için korelasyon katsayısı ve ortalama kare hata değerlerini vermektedir. Söz konusu tablodaki İBSA yapısı, giriş, gizli ve çıkış katmanlardaki nöron veya düğüm sayısını belirtmektedir, yani ilk model üç girişe, on gizli nörona ve altı çıkışa sahip olduğu görülmektedir. İkinci model dört girişe, on gizli ve üç çıkış düğümüne sahiptir.

Sonuçlar, model 1c'nin tam veri seti için ikinci modele göre daha yüksek bir korelasyon katsayısına sahip olduğunu göstermektedir. Bununla birlikte, model 2c'de de giriş ve çıkış değerleri arasında iyi bir korelasyon göstermiş ve R değeri, LM ve EGY eğitim algoritmaları dikkate alındığında, tüm veriler için 0,84 ile 0,92 arasında değişmiştir. Model 2c'nin doğrulama aşamasında, R değeri EGY algoritması kullanılarak 0,44'e düşürülmüştür. Bununla birlikte, LM algoritması kullanıldığında hala yüksek (0,90) kaldığı izlenmiştir. Her iki eğitim algoritması için de tüm veri seti için R değeri yüksek olduğu görülmektedir.


Hatalardan bahsederseniz, model 1c karşılaştırmalı olarak yeterince yüksek hatalara sahip olduğu tespit edilmiştir. İlk model için OKH hataları 58,3 ila 61,5 arasında değişmektedir. Bunun aksine, model 2c çok düşük bir hata ( $2,5$  ila  $7,3 \times 10^{-4}$ ) göstermiştir. Dolayısıyla, hata model 2c'de daha düşük olduğu ve korelasyon katsayısı yeterince yüksek olduğu için, model 2c'nin Doğancı Barajı'nın su kalitesinin daha iyi bir tahminini sağladığı söylenebilir.

**Çizelge 4.7.** Üçüncü modelleme: İBSA modellemesinden elde edilen sonuçların analizi


Model	Girişler (Aylık ortalama değerler)	Çıktılar (Aylık ortalama değerler)	İBSA Yapısı	Denetleme				OKH
				R Değerleri				
				Eğitim	Deneme	Doğrulama	Tüm Veri Kümesi	
Model 1c.	<ul style="list-style-type: none"> <li>Su sıcaklığı (°C)</li> <li>pH</li> <li>Bulanıklık (NTU)</li> </ul>	<ul style="list-style-type: none"> <li>Alkalinite (mg/L)</li> <li>Askıda katı madde (mg/L)</li> <li>Çözünmüş oksijen (mg/L)</li> <li>Arsenik (mg/L)</li> <li>Mangan (mg/L)</li> <li>Demir (mg/L)</li> </ul>	3-10-6	EGY: 0,99129 LM: 0,99373	EGY: 0,98924 LM: 0,99087	EGY: 0,98924 LM: 0,98585	EGY: 0,99011 LM: 0,99186	EGY: 58,2823 LM: 61,4863
Model 2c.	<ul style="list-style-type: none"> <li>Su sıcaklığı (°C)</li> <li>pH</li> <li>Alkalinite (mg/L)</li> <li>Çözünmüş oksijen (mg/L)</li> </ul>	<ul style="list-style-type: none"> <li>Arsenik (mg/L)</li> <li>Mangan (mg/L)</li> <li>Demir (mg/L)</li> </ul>	4-10-3	EGY: 0,99983 LM: 1	EGY: 0,74342 LM: 0,69174	EGY: 0,44447 LM: 0,89927	EGY: 0,84487 LM: 0,92408	EGY: $7,3 \times 10^{-4}$ LM: $2,5 \times 10^{-4}$

Korelasyon grafiklerinden (Şekil 4.3) model 2c için noktaların korelasyon çizgisi boyunca daha geniş bir dağılıma sahip olduğu yorumlanmış, bu da tahminin güvenilirliğini daha da doğrulamıştır. Model 1c'nin karşılaştırmalı olarak daha yüksek bir R değeri (0,99) olsa da, grafikler korelasyon çizgisinin sadece birkaç yoluna odaklanmış gibi görünmüştür. Sonuçlar ayrıca Doğancı Barajı'nda iz element kirliliği ile ilgili yoğun duruma ilişkin araştırmanın amacıyla da uyumlu olduğu saptanmıştır. Barajdaki iz elementlerin konsantrasyonlarının su sıcaklığı, pH, alkalinite ve çözülmüş oksijen konsantrasyonundaki değişikliklerle birlikte değişebileceğini göstermiş, çünkü bunlar arasında yüksek bir korelasyon gösterilmiştir. Bu sorun dikkat gerektirir çünkü demir, mangan ve özellikle arsenik konsantrasyonunun artması halkı etkileyebilmekte ve farklı hastalıkların kök nedeni olabilmektedir.


### Esnek Geri Yayılm Algoritması Levenberg-Marquardt Algoritması




Model 1c



Model 1c



Model 2c



Model 2c

Şekil 4.3. Üçüncü modelleme: EGY ve LM eğitim algoritmaları kullanılarak yapay sinir ağlarından elde edilen korelasyon grafikleri

Mevcut çalışma, önceki literatürdeki birkaç benzer çalışmayla karşılaştırıldığında (Çizelge 4.8), çoğunlukla ileri beslemeli sinir ağında bir giriş, bir gizli ve bir çıkış katmanı kullandığı gözlemlenmiştir. Benzer bir yapı bu çalışmada da kullanılmıştır. Giriş ve çıkış sayılarının değişebildiği ve bu sayı ile yapay sinir ağlarının sağlamlığı arasında belirli bir trendin olmadığı da fark edilmiştir. Başka bir deyişle, giriş veya çıkış sayısını artırma veya azaltma, bu ağların tahmin gücünü etkilemez. Literatürdeki seçilen çalışmaların hata ve korelasyon katsayıları (Çizelge 4.8'de belirtildiği gibi) test, eğitim ve doğrulama sonrası tam veri kümesi için geçerlidir.

Önceki çalışmaların hata değerlerini bu çalışmada test edilen modellerle karşılaştırıldığında, model 1c'nin (58,28-61,49) karşılaştırmalı olarak daha yüksek bir hatası olduğu görülmüştür. Model 2c için ise tam tersi gözlemlendi; hata değeri (2,5 ila  $7,3 \times 10^{-4}$ ), listelenen çalışmalardan önemli ölçüde daha düşük bulunmuştur. Korelasyon katsayısı için model 1c, tüm aşamalarda (LM veya EGY eğitim algoritmaları kullanılarak) tüm çalışmalara kıyasla daha yüksek bir korelasyona sahip olduğu tespit edilmiştir (0,985 ila 0,993'e kadar). Bununla birlikte, model 1c'nin R değeri, çalışma 4c hariç, bahsedilen diğer çalışmalara oldukça yakın olduğu görülmüştür. Öte yandan, model 2c de tüm veri seti için daha yüksek bir R'ye sahipti, yani EGY kullanılarak 0,845 ve LM kullanılarak 0,924 olduğu saptanmıştır. Bu değerler, çalışma 2c (0,659-0,712) ve çalışma 3c (0,710-0,740) ile karşılaştırıldığında daha yüksek olduğu ve çalışma 1c'nin (0,840-0,985) aralığında bulunduğu görülmektedir.

Her iki modelin de karşılaştırılabilir bir R'ye sahip olmasına rağmen, model 1c'nin çok yüksek bir hatası olduğu görülmektedir (61,486'ya kadar ulaşan). Yüksek hata, tahmin edilen ve gözlenen değerler arasındaki büyük farkı gösterir. Bu nedenle, model 1c, Doğancı Barajı'nın su kalitesi izlemesiyle daha uyumlu bulunmaktadır.

Detaylı bir analiz sonrasında, su sıcaklığı, pH, alkalinite ve çözülmüş oksijen gibi su kalitesi parametrelerinde meydana gelen değişikliklerin birlikte, barajdaki iz element konsantrasyonları üzerinde olumsuz etkileri olabileceği söylenebilir.

**Çizelge 4.8.** İBSA kullanımıyla barajın su kalitesi tahmininde geçmiş literatür özeti

Çalışma	Girdiler	Çıktılar	İBSA Yapısı	Korelasyon katsayısı	Hatalar	Referans
Diğer Çalışma 1c.	Kalsiyum, magnezyum, sodyum, klorür, sülfat iyonları ve pH	Toplam çözünmüş katılar	Bir girdi, bir gizli ve bir çıktı katmanı	0,840-0,985	0,011-0,019	(Asadolla hfardi vd., 2017)
Diğer Çalışma 2c.	Askıda katı madde, nitrojen, fosfor, kimyasal ve biyolojik oksijen ihtiyacı	Askıda katı maddeler, toplam nitrojen ve toplam fosfor	Bir girdi, bir gizli ve bir çıktı katmanı	0,659-0,712	2,699-3,120	(Kang vd., 2015)
Diğer Çalışma 3c.	Klorofil-a, fosfat, nitrat-nitrojen ve amonyum nitrojen	Klorofil-a	Bir girdi, bir gizli ve bir çıktı katmanı	0,710-0,740	-	(Park vd., 2015)
Diğer Çalışma 4c.	pH, iletkenlik, çözünmüş oksijen ve su sıcaklığı	Oksitlenebilirlik ve toplam askıda katı madde	Bir giriş, iki gizli ve bir çıkış katmanı	0,994-0,998	0,097-0,300	(Vicente vd., 2012)
Diğer Çalışma 5c.	Askıda katı madde, toplam nitrojen ve su sıcaklığı	İletkenlik ve çözünmüş oksijen	Bir girdi, bir gizli ve bir çıktı katmanı	-	4,720-6,460	(Elhatip ve Kömür, 2008)
Diğer Çalışma 6c.	Fosfatlar, nitratlar, alkalinite, askıda katı madde, pH, su sıcaklığı, iletkenlik, çözünmüş oksijen ve seki derinliği	Klorofil-a	Bir girdi, bir gizli ve bir çıktı katmanı	0,950	-	(Karul vd., 2000)

Son olarak, incelenen modeller için R ve OKH değerleri açısından hangi eğitim algoritmasının daha iyi performans gösterdiğini belirlemek için bir karşılaştırma yapılmıştır. Tam veri kümesi için incelenen modellerin korelasyon değerleri Levenberg-Marquardt algoritması kullanılarak daha yüksek olduğu tespit edilmiştir (her iki model için de 0,9'un üzerinde). Model 1c'deki hata değeri, esnek geri yayılım algoritmasıyla daha düşük olduğu saptanmıştır. (58,28). Bununla birlikte, model 1c için hata değerleri (her iki eğitim algoritması kullanılarak) arasındaki fark büyük değil, yani yaklaşık üç birim olduğu görülmektedir. Daha önce belirtildiği gibi, model 2c, model 1c'den daha iyi performans göstermiş; model 2c'deki hatalar, LM algoritması kullanıldığında daha düşük olduğu sonucuna ulaşılmıştır. Verilen analiz için en iyi modeli (yani model 2c) düşünerek, R değeri daha yüksek olduğu (0,92) ve OKH değeri ( $2,5 \times 10^{-4}$ ), modelleme için LM algoritması uygulandığında daha düşük olduğu saptanmıştır. Bu nedenle, analizden çıkarılan sonuca göre, Levenberg-Marquardt algoritmasının, su sıcaklığı, pH, alkalinite ve çözünmüş oksijen konsantrasyonunu girdi olarak kullanarak baraj su kalitesini (özellikle iz element konsantrasyonunu) belirlemede daha uygun olduğu söylenebilir.

## 5. SONUÇLAR

Daha önce yapılan çalışmalarda yapay sinir ağları (YSA) kullanılmış ve kabul edilebilir sonuçlar elde edilmiştir. Benzer şekilde, bu çalışma için de oldukça faydalı olduğu kanıtlanmıştır. Bu çalışmada bir girdi, bir gizli ve bir çıktı katmanlı olan ileri beslemeli sinir ağları kullanılmıştır.

Araştırma, barajın su kalitesini değerlendirmede hangi iklimsel göstergenin daha önemli olduğunu belirlemiştir. Meteorolojik parametreler ve Doğancı Barajı'nın su kalitesi parametreleri arasındaki ilk modellemede, model 1a, test edilen diğer modeller arasında en iyi sonuçları, daha yüksek korelasyon ve en az hata verdiği görülmektedir. Bu modelde aylık ortalama hava sıcaklığı, aylık ortalama toplam günlük global güneş radyasyonu ve güneş yoğunluğu giriş olarak kullanılmış, Doğancı Barajı'nın aylık ortalama su sıcaklığı, pH ve aylık ortalama çözülmüş oksijen, arsenik, mangan ve demir konsantrasyonları çıktı olarak kullanılmıştır. Ayrıca, çalışmada yapılan modelleme için Levenberg-Marquardt eğitim algoritması, esnek geri yayılı eğitim algoritmasına göre daha iyi sonuçlar vermiştir.

İklim değişikliği çevremizi olumsuz etkilemektedir. Ancak, özellikle meteorolojik parametrelerin değişiminin su bütçesi üzerindeki etkisi son derece önemlidir. İkinci modellemede, bu etkiler incelemiştir. Meteorolojik parametreler, Doğancı Barajı'nın hidrolojik özelliklerinin değişimi üzerindeki etkisini tahmin etmek için kullanılmıştır. Gerçekleştirilen modelleme çalışmasında, 30 yıllık meteorolojik ve hidrolojik parametrelere ait veriler kullanılmıştır. Bu nedenle, analiz, hangi meteorolojik parametrenin bir barajın su bütçesi üzerinde uzun dönemli etkiye sahip olduğunu tahmin edebilmiştir. Bu modellemede, incelenen birinci modelin en iyi performansı gösterdiğini ortaya koymuştur. Yani, hava sıcaklığı, güneş radyasyonu, güneş yoğunluğu, buharlaşma ve evapotranspirasyon en doğru şekilde Doğancı Barajı'nın su hacmi, akış hızları ve su seviyesini tahmin etmektedir. Model 1b, Levenberg-Marquardt eğitim algoritması kullanılarak test edilen diğer modellere göre tüm veri seti için en düşük ortalama kare hatası (0,59) ve en yüksek R (0,99) değerine sahip olduğu sonucuna ulaşılmıştır. Analiz, korelasyon değerleri ve ortalama kare hatası üzerine dayanmaktadır. Ayrıca, esnek geri yayılım veya Levenberg-Marquardt eğitim algoritmalarının kullanılmasının analitik sonuçları istatistiksel olarak etkilemediği görülmüştür. Ancak, R ve OKH değerlerine görsel olarak bakıldığında, Levenberg-Marquardt algoritması esnek geri yayılım

algoritmasından daha iyi performans göstermektedir. Bu nedenle, bu çalışma, yapay sinir ağlarının hidrolojide tahminler için uygunluk ve verimliliğini ve barajların suyunun doğru şekilde simüle edebilecek meteorolojik parametreleri açıklamaktadır.

Doğancı Barajı'nın su kalitesi parametreleri arasındaki üçüncü modelleme çalışmasında (model 2c), dört girişi (su sıcaklığı, pH, alkalinite ve çözülmüş oksijen konsantrasyonu), on gizli düğümü ve üç çıkışı (arsenik, mangan ve demir konsantrasyonları) olan model, tam veri kümesi için daha güçlü bir korelasyon katsayısına ve çok daha düşük bir ortalama kare hata değerine sahip olduğu görülmüştür. Ayrıca, verilen girdi değişkenleri kullanılarak barajın su kalitesini modellemek için Levenberg-Marquardt algoritmasının daha uygun olduğu ortaya çıkmıştır. Bu bulgular, Doğancı Barajı'ndaki iz element konsantrasyonunu etkileyen faktörleri belirlemede yardımcı olmuştur. Bu modellemenin bulguları, Doğancı Barajı'nın su kalitesini yönetme ve izleme konusunda sorumlu olanlara değerli olabilir. Su kalitesini iyileştirmek için planlar geliştirmelerine yardımcı olabilir. Genellikle barajlarda ötrofikasyon da bir sorundur, bu nedenle bu çalışma genel olarak hangi girdi parametrelerinin ötrofikasyona neden olduğunu belirlemek için de genişletilebilir. Bu çalışma, yapay sinir ağlarının baraj su kalitesi tahmin çalışmalarında kullanılması açısından uluslararası öneme sahiptir.

Araştırma sorularının cevapları şunlardır:

**a) Doğancı Barajı'ndaki su kalitesi veya su bütçesi dinamiklerini etkileyen temel meteorolojik parametreler nelerdir?**

- Doğancı Barajı'nın su kalitesini en çok etkileyebilecek meteorolojik parametreler hava sıcaklığı, güneş radyasyonu ve güneş yoğunluğudur. Bu parametreler, su ekosisteminde önemli etkileri olan kritik faktörlerdir ve baraj suyu üzerindeki fiziksel ve kimyasal süreçleri etkileyerek su kalitesinde değişikliklere neden olabilirler.
- Diğer taraftan, Doğancı Barajı'nın su bütçesini, yani su seviyesi, hacmi, gelen ve giden akışı etkileyebilecek meteorolojik parametreler hava sıcaklığı, güneş radyasyonu, güneş yoğunluğu, buharlaşma ve evapotranspirasyondur.

**b) Yapay sinir ağları, iklim değişikliğine yanıt olarak hidrolojik parametrelerdeki değişiklikleri doğru bir şekilde modelleyip tahmin edebilir mi?**

Tüm değerlendirmeler sonucunda elde edilen sinir ağı modellemelerinden elde edilen sonuçları karşılaştırdığımızda, hataların düşük olduğu ve elde edilen korelasyon

katsayılarının yüksek olduğu görülmüştür. Bu değerler aynı zamanda önceki çalışmalarla tutarlı olduğu ve yapay sinir ağlarının barajların hidrolojisi üzerindeki iklimsel etkileri tahmin etmek için sağlam sonuçlar sağladığını göstermektedir. Bu da YSA'nın bu tür tahminler için uygunluğunu göstermektedir.

**c) Farklı meteorolojik girdi kombinasyonları, yapay sinir ağı modellerinin barajlardaki hidrolojik değişiklikleri tahmin etme performansını nasıl etkiler?**

Doğancı Barajı'nın hidrolojisiyle ilgili olarak, tartışma bölümünde detaylı olarak belirtilen belirli meteorolojik parametrelerin seçilen çıktılarla uyumlu olduğu görülmüştür. Test edilen bazı modeller, gözlemlenen ve tahmin edilen değerler arasında çok daha yüksek bir korelasyon sağlamış ve daha az hata vermiştir. Bu modeller en iyi modeller olarak seçilmiştir. Dolayısıyla, seçilen meteorolojik parametrelerin sayısı önemli değildir, ancak bu parametrelerin kombinasyonu hidrolojik modelleme için önemlidir. Örneğin, Doğancı Barajı'nın su bütçesi veya su kalitesi tahminlerinde en iyi modellerde hava sıcaklığı, güneş radyasyonu ve güneş yoğunluğu gibi ortak meteorolojik parametrelerin bulunduğu görülmüştür. Bu durum, bu parametrelerin tahminler için faydalı olabileceğini göstermektedir.

**d) Yapay sinir ağları, Doğancı Barajı'nın farklı su kalitesi parametreleri arasında bir ilişki geliştirebilir mi?**

Daha önce tartışıldığı gibi, su sıcaklığı, pH, alkalinite ve çözülmüş oksijen konsantrasyonu gibi parametreleri girdi olarak alan yapay sinir ağı modelinde arsenik, mangan ve demir konsantrasyonları gibi çıktılar arasında güçlü bir korelasyon fark edilmiştir. Bu nedenle yapay sinir ağlarının Doğancı Barajı'nın su kalitesi parametreleri arasındaki ilişkiyi belirleme konusunda yetenekli olduğunu göstermektedir. Ayrıca iz element konsantrasyonlarını belirleme ve tahmin etme açısından YSA önemlidir ve bu tür çalışmalar daha fazla incelenmelidir.

**e) Doğancı Barajı'nın hidrolojik parametreleri için hangi eğitim algoritması, esnek geri yayılım mı yoksa Levenberg-Marquardt mı, daha doğru tahminler sunar?**

Yapılan tüm modellemeleri dikkate aldığımızda, R ve OKH değerlerini karşılaştırdığımızda Levenberg-Marquardt algoritmasının esnek geri yayılım eğitim algoritmasına göre daha etkili olduğu görülmüştür.



Genel olarak, meteorolojik verileri dikkate almak ve YSA modellerinden faydalanmak suretiyle, iklim deęişiklięinin barajlardaki su kalitesi ve su bütçesi üzerindeki olumsuz etkilerini hafifletmek için bilinçli kararlar ve gerekli önlemler önceden alınabilir. Yapay sinir aęları, bir barajın su kalitesi parametreleri arasındaki iliřkiyi belirlemede de yardımcı olmaktadır. Aynı durum, su bütçesi parametreleri için de geçerlidir.

### 5.1. Öneriler

- a) Geliřmiş Veri Kullanılabilirlięi ve Eriřilebilirlik: Hükümet kurumları, araştırma kuruluşları ve yerel topluluklar da dahil olmak üzere paydařlar arasında veri paylaşımını ve iř birlięini teşvik ederek yüksek kaliteli veri setlerinin eriřilebilirlięini artırmak önemlidir. Bu, daha güçlü ve güvenilir YSA modellerinin geliştirilmesine katkıda bulunacaktır.
- b) Doğrulama ve Genelleme: Baęımsız veri setleri kullanılarak YSA modellerinin doğrulanması için ilave arařtırmalar yapılmalıdır. Bu, modellerin genelleme yeteneęini ve güvenilirlięini deęerlendirmeye yardımcı olacak ve genel olarak tahminleri iyileştirecektir.
- c) Dięer tahminler: Gerçekçi bir senaryo olarak hava sıcaklıęının 2°C arttıęı durumu varsayarak, Doęancı Barajı'nın su kalitesi ve su miktarı parametrelerinin tahmin edildięi başka bir çalıřma yapılabilir.
- d) Farklı Araçların Entegrasyonu: Risk deęerlendirme aracı, iklim deęişiklięinin veya dięer herhangi bir dıř faktörün su kaynaęı parametreleri üzerindeki etkilerini daha iyi anlamak için yapay zekâ araçlarıyla entegre edilebilir. Bu, barajlar dahil olmak üzere su kaynakları için uygun bir yönetim sistemin geliştirilmesinde de faydalı olabilir.
- e) Bu yüksek lisans tezi çalıřmasında elde edilen bulgulara göre, ANOVA yapılması lazım. ANOVA, karřılařtırmalar için faydalı olan iki farklı grup arasındaki istatistiksel olarak önemli farkları belirlemede önemli bilgiler sağlamaktadır.
- f) Bu yüksek lisans tezi çalıřmasındaki bulgulara göre farklı eęitim algoritmaları (gradyent iniři, konjugat gradyent ve/veya Quasi-Newton) ve farklı model yapıları kullanılarak modellenenin geliştirilmesi önerilebilir. Bu tezde yalnızca ileri beslemeli sinir aęı test edilmiřtir. Bařka bir çalıřma, geri beslemeli sinir aęı kullanılarak yapılabilir ve elde edilen sonuçlar bu iki sinir aęı için karřılařtırılabilir.

- g) İklim deęişiklięini gösteren farklı meteorolojik parametreler ile farklı su kalitesi parametreleri arasındaki ilişkilerin denenmesi de faydalı olacaktır.

## KAYNAKLAR

- Al-Jarrah, O. Y., Yoo, P. D., Muhaidat, S., Karagiannidis, G. K., ve Taha, K. (2015). Efficient machine learning for big data: A review. *Big Data Research*, 2(3), 87-93. <https://doi.org/10.1016/j.bdr.2015.04.001>
- Al Aboodi, A. H., Dawood, A. S., ve Abbas, S. A. (2009). Prediction of Tigris River stage in Qurna, south of Iraq, using artificial neural networks. *Engineering and Technology Journal*, 27(13).
- Allawi, M. F., Jaafar, O., Mohamad Hamzah, F., Abdullah, S. M. S., ve El-Shafie, A. (2018). Review on applications of artificial intelligence methods for dam and reservoir-hydro-environment models. *Environmental Science and Pollution Research*, 25(14), 13446-13469. <https://doi.org/10.1007/s11356-018-1867-8>
- Altinbilek, D. (2002). The role of dams in development. *Water Science and Technology*, 45(8), 169-180.
- Apaydin, H., Feizi, H., Sattari, M. T., Colak, M. S., Shamsirband, S., ve Chau, K.-W. (2020). Comparative analysis of recurrent neural network architectures for reservoir inflow forecasting. *Water*, 12(5), 1500.
- Asadollahfardi, G., Zangooei, H., Aria, S. H., ve Danesh, E. (2017). Application of artificial neural networks to predict total dissolved solids at the Karaj Dam. *Environmental Quality Management*, 26(3), 55-72. <https://doi.org/10.1002/tqem.21493>
- Bayram, A. (2011). *Harşit çayı su kalitesinin mevsimsel değişiminin incelenmesi ve askı madde konsantrasyonunun yapay sinir ağları yöntemi ile tahmin edilmesi* (Doktora Tezi) Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon. <http://acikerisim.ktu.edu.tr/jspui/handle/123456789/714>
- Benzaghta, M. A., Mohammed, T. A., Ghazali, A. H., ve Soom, M. A. M. (2012). Prediction of evaporation in tropical climate using artificial neural network and climate based models. *Scientific Research and Essays*, 7(36), 3133-3148.
- Buhari, M., ve Adamu, S. S. (2012). *Short-term load forecasting using artificial neural network*. Paper presented at the Proceedings of the international multi-conference of engineers and computer scientists. 1, 1-71.
- BUSKİ (2023). Barajlar. <https://www.buski.gov.tr/Icerik/IcerikDetay?url=barajlar>
- BUSKİ (2021). Baraj Durumu İstatistikleri. <https://www.buski.gov.tr/Baraj/YillikVerilenTemizSuMiktarlari>
- Büyükşahin, Ü. Ç., ve Ertekin, Ş. (2019). Improving forecasting accuracy of time series data using a new ARIMA-ANN hybrid method and empirical mode decomposition. *Neurocomputing*, 361, 151-163. <https://doi.org/10.1016/j.neucom.2019.05.099>

Çalim, M. M. (2008). *Estimation of dam reservoir level with artificial neural network method* (Yüksek Lisans Tezi) Mustafa Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Antakya. [https://tez.yok.gov.tr/UlusalTezMerkezi/tezDetay.jsp?id=tPtS\\_heSMYicaKWhD0vd6w&no=hXyjBcHCUojyy4SSrKgk7A](https://tez.yok.gov.tr/UlusalTezMerkezi/tezDetay.jsp?id=tPtS_heSMYicaKWhD0vd6w&no=hXyjBcHCUojyy4SSrKgk7A)

Casserly, C. M., Turner, J. N., O'sullivan, J. J., Bruen, M., Bullock, C., Atkinson, S., ve Kelly-Quinn, M. (2020). Impact of low-head dams on bedload transport rates in coarse-bedded streams. *Science of the Total Environment*, 716, 136908.

Chamoglou, M., Papadimitriou, T., ve Kagalou, I. (2014). Key-descriptors for the functioning of a Mediterranean reservoir: The case of the new Lake Karla-Greece. *Environmental Processes*, 1(2), 127-135.

Chen, W.-B., ve Liu, W.-C. (2014). Artificial neural network modeling of dissolved oxygen in reservoir. *Environmental Monitoring and Assessment*, 186(2), 1203-1217. <https://doi.org/10.1007/s10661-013-3450-6>

Chou, J.-S., Ho, C.-C., ve Hoang, H.-S. (2018). Determining quality of water in reservoir using machine learning. *Ecological Informatics*, 44, 57-75. <https://doi.org/10.1016/j.ecoinf.2018.01.005>

Cooper, S. D., Lake, P. S., Sabater, S., Melack, J. M., ve Sabo, J. L. (2013). The effects of land use changes on streams and rivers in mediterranean climates. *Hydrobiologia*, 719(1), 383-425.

Damla, Y., Temiz, T., ve Keskin, E. (2020). Yapay sinir ağı kullanılarak su seviyesinin tahmin edilmesi: Yalova Gökçe barajı örneği. *Kırklareli Üniversitesi Mühendislik ve Fen Bilimleri Dergisi*, 6(1), 32-49. <https://doi.org/10.34186/klujes.754845>

El-Kenawy, E.-S. M., Zerouali, B., Bailek, N., Bouchouich, K., Hassan, M. A., Almorox, J., Kuriqi, A., Eid, M., ve Ibrahim, A. (2022). Improved weighted ensemble learning for predicting the daily reference evapotranspiration under the semi-arid climate conditions. *Environmental Science and Pollution Research*, 29(54), 81279-81299.

El-Mahdy, M. E.-S., El-Abd, W. A., ve Morsi, F. I. (2021). Forecasting lake evaporation under a changing climate with an integrated artificial neural network model: A case study Lake Nasser, Egypt. *Journal of African Earth Sciences*, 179, 104191.

Elhatip, H., ve Kömür, M. A. (2008). Evaluation of water quality parameters for the Mamasin dam in Aksaray City in the central Anatolian part of Turkey by means of artificial neural networks. *Environmental Geology*, 53, 1157-1164. <https://doi.org/10.1007/s00254-007-0705-y>

Erünal, E. (2020). Examining age structure and estimating mortality rates in Ottoman Bursa using mid-nineteenth-century population registers. *Middle Eastern Studies*, 57(2), 179-196. <https://doi.org/10.1080/00263206.2020.1844672>

Fabian, P. S., Kwon, H.-H., Vithanage, M., ve Lee, J.-H. (2023). Modeling, challenges, and strategies for understanding impacts of climate extremes (droughts and floods) on water quality in Asia: A review. *Environmental Research*, 115617.

Fırat, A. (2019). *Yapay sinir ağları ile ortalama debi ve maksimum yağış tahmini İstanbul Göksu dere örneği* (Yüksek Lisans Tezi). Sakarya Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Sakarya.  
<https://acikerisim.subu.edu.tr/xmlui/handle/20.500.14002/999>

Fural, Ş., Kükrer, S., Cürebal, İ., ve Aykır, D. (2022). Ecological degradation and non-carcinogenic health risks of potential toxic elements: a GIS-based spatial analysis for Doğancı Dam (Turkey). *Environmental Monitoring and Assessment*, 194(4), 269.  
<https://doi.org/10.1007/s10661-022-09870-4>

Garousi-Nejad, I., Bozorg-Haddad, O., Loáiciga, H. A., ve Mariño, M. A. (2016). Application of the firefly algorithm to optimal operation of reservoirs with the purpose of irrigation supply and hydropower production. *Journal of Irrigation and Drainage Engineering*, 142(10), 04016041.

Glorot, X., ve Bengio, Y. (2010). *Understanding the difficulty of training deep feedforward neural networks*. Paper presented at the Proceedings of the thirteenth international conference on artificial intelligence and statistics, 249-256.

Goss-Sampson, M. (2019). *Statistical analysis in JASP: A guide for students*. JASP. United Kingdom.

Hadiyan, P. P., Moeini, R., ve Ehsanzadeh, E. (2020). Application of static and dynamic artificial neural networks for forecasting inflow discharges, case study: Sefidroud Dam reservoir. *Sustainable Computing: Informatics and Systems*, 27, 100401.

Hébert, C., Caissie, D., Satish, M. G., ve El-Jabi, N. (2015). Predicting hourly stream temperatures using the equilibrium temperature model. *Journal of Water Resource and Protection*, 7(04), 322. <https://doi.org/10.4236/jwarp.2015.74026>

Hogeboom, R. J., Knook, L., ve Hoekstra, A. Y. (2018). The blue water footprint of the world's artificial reservoirs for hydroelectricity, irrigation, residential and industrial water supply, flood protection, fishing and recreation. *Advances in Water Resources*, 113, 285-294.

Hydrology, (2000). Artificial neural networks in hydrology. I: Preliminary concepts. *Journal of Hydrologic Engineering*, 5(2), 115-123.

Iqbal, N., Khan, A.-N., Rizwan, A., Ahmad, R., Kim, B. W., Kim, K., ve Kim, D.-H. (2021). Groundwater level prediction model using correlation and difference mechanisms based on boreholes data for sustainable hydraulic resource management. *IEEE Access*, 9, 96092-96113.

Jain, A. K., Mao, J., ve Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44. <https://doi.org/10.1109/2.485891>

Jeppesen, E., Brucet, S., Naselli-Flores, L., Papastergiadou, E., Stefanidis, K., Noges, T., Noges, P., Attayde, J. L., Zohary, T., ve Coppens, J. (2015). Ecological impacts of global warming and water abstraction on lakes and reservoirs due to changes in water level and related changes in salinity. *Hydrobiologia*, 750(1), 201-227. <https://doi.org/10.1007/s10750-014-2169-x>

Kalin, L., ve Isik, S. (2010). *Prediction of water quality parameters using an artificial neural networks model*. Paper presented at the World Environmental and Water Resources Congress 2010: Challenges of Change, 3145-3153.

Kang, B., Do Kim, Y., Lee, J. M., ve Kim, S. J. (2015). Hydro-environmental runoff projection under GCM scenario downscaled by artificial neural network in the Namgang Dam watershed, Korea. *KSCE Journal of Civil Engineering*, 19(2), 434-445. <https://doi.org/10.1007/s12205-015-0580-0>

Karaca, G., ve Tasdemir, Y. (2014). Temporal and spatial variations in PAH concentrations in the sediment from the Nilufer Creek in Bursa, Turkey. *Journal of Environmental Science and Health, Part A*, 49(8), 900-912. <https://doi.org/10.1080/10934529.2014.894330>

Karul, C., Soyupak, S., Çilesiz, A. F., Akbay, N., ve Germen, E. (2000). Case studies on the use of neural networks in eutrophication modeling. *Ecological Modelling*, 134(2-3), 145-152. [https://doi.org/10.1016/S0304-3800\(00\)00360-4](https://doi.org/10.1016/S0304-3800(00)00360-4)

Katip, A. (2018). Meteorological drought analysis using artificial neural networks for Bursa City, Turkey. *Applied Ecology and Environmental Research*, 16(3), 3315-3332. [http://dx.doi.org/10.15666/aeer/1603\\_33153332](http://dx.doi.org/10.15666/aeer/1603_33153332)

Kim, H.-Y. (2014). Analysis of variance (ANOVA) comparing means of more than two groups. *Restorative Dentistry and Endodontics*, 39(1), 74-77.

Kingston, G. B., Dandy, G. C., ve Maier, H. R. (2008). Review of artificial intelligence techniques and their applications to hydrological modeling and water resources management part 2—optimization. *Water Resources Research Progress*, 67-99.

Kişi, Ö., ve Uncuoğlu, E. (2005). Comparison of three back-propagation training algorithms for two case studies. *Indian Journal of Engineering and Materials Sciences*, 12(5), 434-442.

Koç, A., Codron, J., Tekelioğlu, Y., Lemeilleur, S., Tozanli, S., Aksoy, S., Bignebat, C., Demirel, R., ve Mencet, N. (2007). *Restructuring of agrifood chains in Turkey*. In: *Regoverning Markets Agrifood Sector Studies (A)*, IIED, London.

Kondolf, G. M., Gao, Y., Annandale, G. W., Morris, G. L., Jiang, E., Zhang, J., Cao, Y., Carling, P., Fu, K., ve Guo, Q. (2014). Sustainable sediment management in reservoirs and regulated rivers: Experiences from five continents. *Earth's Future*, 2(5), 256-280.

Krenker, A., Bešter, J., ve Kos, A. (2011). Introduction to the artificial neural networks. *Artificial Neural Networks: Methodological Advances and Biomedical Applications. InTech*, 1-18.

Kukreja, H., Bharath, N., Siddesh, C., ve Kuldeep, S. (2016). An introduction to artificial neural network. *International Journal of Advanced Research and Innovative Ideas in Education*, 1, 27-30.

Lange, H., ve Sippel, S. (2020). Machine learning applications in hydrology. In *Forest-water interactions* (pp. 233-257): Springer.

Mahmood, R., Pielke Sr, R. A., Hubbard, K. G., Niyogi, D., Dirmeyer, P. A., Mcalpine, C., Carleton, A. M., Hale, R., Gameda, S., ve Beltrán-Przekurat, A. (2014). Land cover changes and their biogeophysical effects on climate. *International Journal of Climatology*, 34(4), 929-953.

Map, Google (2023a). Maps. *Bursa Türkiye*.

<https://www.google.com/maps/place/Bursa/@40.221678,29.0322895,12z/data=!3m1!4b1!4m6!3m5!1s0x14ca1582d8d45695:0x61a00555fc973392!8m2!3d40.1885281!4d29.0609636!16zL20vMDE2MGQ?entry=ttu>

Map, Google (2023b). Maps. *Doğancı Baraj*.

<https://www.google.com/maps/place/Do%C4%9Fanc%C4%B1,+Do%C4%9Fanc%C4%B1+Dam,+16375+Osmangazi%2FBursa/@40.1134,28.9637,17z/data=!3m1!4b1!4m6!3m5!1s0x14ca198e328b0b7b:0x278ca5440c043bf0!8m2!3d40.1134!4d28.9637!16s%2Fm%2F09k5hgt?entry=ttu>

Mata, J. (2011). Interpretation of concrete dam behaviour with artificial neural network and multiple linear regression models. *Engineering Structures*, 33(3), 903-910.

May, R., Dandy, G., ve Maier, H. (2011). Review of input variable selection methods for artificial neural networks. *Artificial Neural Networks-Methodological Advances and Biomedical Applications*, 10(1), 19-45.

Merdun, H., ve Çinari, Ö. (2010). Artificial neural network and regression techniques in modelling surface water quality. *Environment Protection Engineering*, 36(2), 95-109.

Mohamad, R. N. M. R., ve Ishak, W. H. W. (2019). Forecasting the flood stage of a reservoir based on the changes in upstream rainfall pattern. *Journal of Technology and Operations Management*, 14(2), 46-52.

Molina-Navarro, E., Trolle, D., Martínez-Pérez, S., Sastre-Merlín, A., ve Jeppesen, E. (2014). Hydrological and water quality impact assessment of a Mediterranean limno-

reservoir under climate change and land use management scenarios. *Journal of Hydrology*, 509, 354-366.

Morrisette, P. M., ve Rosenberg, N. J. (2016). Climate variability and development. *In Global Development and the Environment* (pp. 89-98): Routledge.

Mosley, L. M. (2015). Drought impacts on the water quality of freshwater systems; Review and integration. *Earth-Science Reviews*, 140, 203-214.

Municipality, B. M. (2023). Bursa's population, climate, and geography. <https://www.bursa.com.tr/en/sayfa/nufus-konum-iklim-ve-cografya-47/>

Najah, A., El-Shafie, A., Karim, O. A., ve El-Shafie, A. H. (2013). Application of artificial neural networks for water quality prediction. *Neural Computing and Applications*, 22, 187-201.

Nazari-Sharabian, M., Taheriyoun, M., Ahmad, S., Karakouzian, M., ve Ahmadi, A. (2019). Water quality modeling of Mahabad Dam watershed–reservoir system under climate change conditions, using SWAT and system dynamics. *Water*, 11(2), 394. <https://doi.org/10.3390/w11020394>

Nguyen, H. H., Recknagel, F., Meyer, W., Frizenschaf, J., ve Shrestha, M. K. (2017). Modelling the impacts of altered management practices, land use and climate changes on the water quality of the Millbrook catchment-reservoir system in South Australia. *Journal of Environmental Management*, 202, 1-11. <https://doi.org/10.1016/j.jenvman.2017.07.014>

Noor, R. M., Ahmad, Z., Don, M. M., ve Uzir, M. (2010). Modelling and control of different types of polymerization processes using neural networks technique: A review. *The Canadian Journal of Chemical Engineering*, 88(6), 1065-1084.

Nourani, V., Baghanam, A. H., Rahimi, A. Y., ve Nejad, F. H. (2014). Evaluation of wavelet-based de-noising approach in hydrological models linked to artificial neural networks. *Computational Intelligence Techniques in Earth and Environmental Sciences*, 209-241.

Nourani, V., Molajou, A., Najafi, H., ve Danandeh Mehr, A. (2019). Emotional ANN (EANN): A new generation of neural networks for hydrological modeling in IoT. *In Artificial intelligence in IoT* (pp. 45-61): Springer.

O'reilly, G., Bezuidenhout, C., ve Bezuidenhout, J. (2018). Artificial neural networks: applications in the drinking water sector. *Water Supply*, 18(6), 1869-1887.

Ojha, V. K., Abraham, A., ve Snášel, V. (2017). Metaheuristic design of feedforward neural networks: A review of two decades of research. *Engineering Applications of Artificial Intelligence*, 60, 97-116. <https://doi.org/10.1016/j.engappai.2017.01.013>



Okkan, U. (2009). *Aylık yağış ve sıcaklık değişimlerinin İzmir içme suyu havzalarının akımlarına etkileri* (Yüksek Lisans Tezi). Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir. <http://hdl.handle.net/20.500.12397/8256>

Özçelik, O. (2015). *Assessment and prediction of water quality parameters in Lake Köyceğiz using artificial neural network approach* (Yüksek Lisans Tezi). Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Ankara. <https://open.metu.edu.tr/handle/11511/25382>

Pachauri, R. K., Allen, M. R., Barros, V. R., Broome, J., Cramer, W., Christ, R., Church, J. A., Clarke, L., Dahe, Q., ve Dasgupta, P. (2014). *Climate change 2014: Synthesis report. Contribution of Working Groups I, II and III to the fifth assessment report of the Intergovernmental Panel on Climate Change*. IPCC.

Palmer, M. A., Reidy Liermann, C. A., Nilsson, C., Flörke, M., Alcamo, J., Lake, P. S., ve Bond, N. (2008). Climate change and the world's river basins: Anticipating management options. *Frontiers in Ecology and the Environment*, 6(2), 81-89.

Park, Y., Cho, K. H., Park, J., Cha, S. M., ve Kim, J. H. (2015). Development of early-warning protocol for predicting chlorophyll-a concentration using machine learning models in freshwater and estuarine reservoirs, Korea. *Science of the Total Environment*, 502, 31-41. <https://doi.org/10.1016/j.scitotenv.2014.09.005>

Piasecki, A., Jurasz, J., ve Skowron, R. (2017). Forecasting surface water level fluctuations of lake Serwy (Northeastern Poland) by artificial neural networks and multiple linear regression. *Journal of Environmental Engineering and Landscape Management*, 25(4), 379-388.

Pontius, F. W., Brown, K. G., ve Chen, C. J. (1994). Health implications of arsenic in drinking water. *Journal-American Water Works Association*, 86(9), 52-63. <https://doi.org/10.1002/j.1551-8833.1994.tb06246.x>

Pule, M., Yahya, A., ve Chuma, J. (2017). Wireless sensor networks: A survey on monitoring water quality. *Journal of Applied Research and Technology*, 15(6), 562-570. <https://doi.org/10.1016/j.jart.2017.07.004>

Rani, S., ve Parekh, F. (2014). Application of artificial neural network (ANN) for reservoir water level forecasting. *International Journal of Science and Research*, 3(7), 1077-1082.

Raşıit, A. (2019). *Namazgâh barajında meteorolojik veriler kullanılarak yapay sinir ağları ile akışın tahmin edilmesi* (Yüksek Lisans Tezi). Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli. <http://dspace.kocaeli.edu.tr:8080/xmlui/handle/11493/16790>

Rezaeianzadeh, M., Stein, A., ve Cox, J. P. (2016). Drought forecasting using Markov chain model and artificial neural networks. *Water Resources Management*, 30(7), 2245-2259.

- Rungee, J., ve Kim, U. (2017). Long-term assessment of climate change impacts on Tennessee Valley authority reservoir operations: Norris Dam. *Water*, 9(9), 649.
- Saghi, H., Karimi, L., ve Javid, A. (2015). Investigation on trophic state index by artificial neural networks (case study: Dez Dam of Iran). *Applied Water Science*, 5(2), 127-136. <https://doi.org/10.1007/s13201-014-0161-2>
- Sahoo, S., ve Jha, M. K. (2013). Groundwater-level prediction using multiple linear regression and artificial neural network techniques: A comparative assessment. *Hydrogeology Journal*, 21(8), 1865.
- Said, S., ve Khan, S. A. (2021). Remote sensing-based water quality index estimation using data-driven approaches: A case study of the Kali River in Uttar Pradesh, India. *Environment, Development and Sustainability*, 1-26.
- Salami, A. W., Ibrahim, H., ve Sojobi, A. O. (2015). Evaluation of impact of climate variability on water resources and yield capacity of selected reservoirs in the north central Nigeria. *Environmental Engineering Research*, 20(3), 290-297.
- Shen, C., Chen, X., ve Laloy, E. (2021). Broadening the use of machine learning in hydrology. *Frontiers in Water*, 3, 38.
- Simonovic, S. P. (2017). Bringing future climatic change into water resources management practice today. *Water Resources Management*, 31(10), 2933-2950.
- Solanki, A., Agrawal, H., ve Khare, K. (2015). Predictive analysis of water quality parameters using deep learning. *International Journal of Computer Applications*, 125(9), 0975-8887.
- Solmaz, S. K. A., ve Yalili, M. (2002). Bursanın içme suyu meselesi ve bazı çözüm önerileri. *Ekoloji*, 11(42), 36-39.
- Sonmez, O., Dogan, E., Ceribasi, G., ve Demir, S. (2013). Impact of climate change on the daily water level fluctuation of Lake Sapanca. *Fresenius Environmental Bulletin*, 22(7), 1895-1903.
- Svozil, D., Kvasnicka, V., ve Pospichal, J. (1997). Introduction to multi-layer feed-forward neural networks. *Chemometrics and Intelligent Laboratory Systems*, 39(1), 43-62. [https://doi.org/10.1016/S0169-7439\(97\)00061-0](https://doi.org/10.1016/S0169-7439(97)00061-0)
- Syafii, N. I., Ichinose, M., Kumakura, E., Jusuf, S. K., Chigusa, K., ve Wong, N. H. (2017). Thermal environment assessment around bodies of water in urban canyons: A scale model study. *Sustainable Cities and Society*, 34, 79-89. <https://doi.org/10.1016/j.scs.2017.06.012>
- Tabari, H., ve Hosseinzadeh Talaei, P. (2015). Reconstruction of river water quality missing data using artificial neural networks. *Water Quality Research Journal of Canada*, 50(4), 326-335.

Tabbussum, R., ve Dar, A. Q. (2021). Performance evaluation of artificial intelligence paradigms—artificial neural networks, fuzzy logic, and adaptive neuro-fuzzy inference system for flood prediction. *Environmental Science and Pollution Research*, 28(20), 25265-25282.

Taylor, R. (1990). Interpretation of the correlation coefficient: a basic review. *Journal of Diagnostic Medical Sonography*, 6(1), 35-39.

Thakur, A., ve Konde, A. (2021). Fundamentals of neural networks. *International Journal for Research in Applied Science and Engineering Technology*, 9, 407-426.

Tselemonis, A., Stefanis, C., Giorgi, E., Kalmpourtzi, A., Olmpasalis, I., Tselemonis, A., Adam, M., Kontogiorgis, C., Dokas, I. M., ve Bezirtzoglou, E. (2023). Coastal water quality modelling using E. Coli, meteorological parameters and machine learning algorithms. *International Journal of Environmental Research and Public Health*, 20(13), 6216.

Türk Standardlari, E. (2005). *Türk Standardı TS 266 (Sular - İnsanı tüketim amaçlı sular)*. <https://intweb.tse.org.tr/Standard/Standard/Standard.aspx?081118051115108051104119110104055047105102120088111043113104073100115103084043078075072076065089>

Üneş, F., Demirci, M., Başar, B., Kaya, Y. Z., ve Varçın, H. (2019). Estimating dam reservoir level fluctuations using data-driven techniques. *Polish Journal of Environmental Studies*, 28(5), 3451–3462. <https://doi.org/10.15244/pjoes/93923>

Üneş, F., Demirci, M., ve Kişi, Ö. (2015). Prediction of millers ferry dam reservoir level in USA using artificial neural network. *Periodica Polytechnica Civil Engineering*, 59(3), 309-318.

USEPA (2009). National Primary Drinking Water Regulations. <https://www.epa.gov/ground-water-and-drinking-water/national-primary-drinking-water-regulations>

Ustun, G. E. (2011). The Assessment of heavy metal contamination in the waters of the Nilufer Stream in Bursa. *Ekoloji*, 20(81), 61-66. <https://doi.org/10.5053/ekoloji.2011.819>

Vaheddoost, B. (2019). *Evaluation of monthly drought using standardized precipitation index in Bursa, Turkey*. Paper presented at the 4th Eurasian Conference on Civil and Environmental Engineering, 17-18.

Valipour, M., Banihabib, M. E., ve Behbahani, S. M. R. (2013). Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir. *Journal of Hydrology*, 476, 433-441.

Vicente, H., Couto, C., Machado, J., Abelha, A., ve Neves, J. (2012). Prediction of water quality parameters in a reservoir using artificial neural networks. *International Journal*

*of Design, Nature and Ecodynamics*, 7(3), 310-319. <https://doi.org/10.2495/DNE-V7-N3-310-319>

Wang, J., Geng, Y., Zhao, Q., Zhang, Y., Miao, Y., Yuan, X., Jin, Y., ve Zhang, W. (2021). Water quality prediction of water sources based on meteorological factors using the CA-NARX Approach. *Environmental Modeling & Assessment*, 26(4), 529-541. <https://doi.org/10.1007/s10666-021-09759-5>

WHO (2022). Drinking water quality guidelines. <https://www.who.int/publications/i/item/9789240045064>

Wu, S., Mcauley, K., ve Harris, T. (2011). Selection of simplified models: I. Analysis of model-selection criteria using mean-squared error. *The Canadian Journal of Chemical Engineering*, 89(1), 148-158.

Yaseen, Z. M., Naganna, S. R., Sa'adi, Z., Samui, P., Ghorbani, M. A., Salih, S. Q., ve Shahid, S. (2020). Hourly river flow forecasting: application of emotional neural network versus multiple machine learning paradigms. *Water Resources Management*, 34(3), 1075-1091.

Yetilmezsoy, K., Ozkaya, B., ve Cakmakci, M. (2011). Artificial intelligence-based prediction models for environmental engineering. *Neural Network World*, 21(3), 193.

Zhang, J., Zhu, Y., Zhang, X., Ye, M., ve Yang, J. (2018). Developing a long short-term memory (LSTM) based model for predicting water table depth in agricultural areas. *Journal of Hydrology*, 561, 918-929.

Zhang, Y., ve Gao, Q. (2015). Comprehensive prediction model of water quality based on grey model and fuzzy neural network. *Chinese Journal of Environmental Engineering*, 9(2), 537-545.

Zhang, Y., Huang, J. J., Chen, L., ve Qi, L. (2015). Eutrophication forecasting and management by artificial neural network: a case study at Yuqiao Reservoir in North China. *Journal of Hydroinformatics*, 17(4), 679-695. <https://doi.org/10.2166/hydro.2015.115>

Zhu, M., Wang, J., Yang, X., Zhang, Y., Zhang, L., Ren, H., Wu, B., ve Ye, L. (2022). A review of the application of machine learning in water quality evaluation. *Eco-Environment and Health*. <https://doi.org/10.1016/j.eehl.2022.06.001>

Zou, J., Han, Y., ve So, S.-S. (2008). Overview of artificial neural networks. *Artificial Neural Networks*, 458, 14-22. <https://doi.org/10.1007/978-1-60327-101-12>

Zubaidi, S. L., Al-Bugharbee, H., Ortega-Martorell, S., Gharghan, S. K., Olier, I., Hashim, K. S., Al-Bdairi, N. S. S., ve Kot, P. (2020). A novel methodology for prediction urban water demand by wavelet denoising and adaptive neuro-fuzzy inference system approach. *Water*, 12(6), 1628.

## ÖZGEÇMİŞ

Adı Soyadı	: Asifa ANWAR
Doğum Yeri ve Tarihi	:
Yabancı Dil	: Urduca ve İngilizce
Eğitim Durumu	
Lise	: Ön Mühendislik
Lisans	: Çevre Mühendisliği
Yüksek Lisans	: Çevre Mühendisliği
Çalıştığı Kurum(lar)	: AMAL for life-Pakistan (sivil toplum kuruluşu)
İletişim (e-posta)	:
Akademik çalışmalar	: Aslıhan Katip, A. A. (2021). Climate change impact on water resources: Global and local situation. 4th International Congress on Agriculture, Environment and Health, Aydın, Türkiye.