DİCLE NEHRİNDE ÇÖZÜNMÜŞ OKSİJEN DERİŞİMİNİN YAPAY SİNİR AĞLARIYLA MODELLENMESİ

DUÇEM M. KILAVUZ

NİSAN 2022

DİYARBAKIR

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DİCLE NEHRİNDE ÇÖZÜNMÜŞ OKSİJEN DERİŞİMİNİN YAPAY SİNİR AĞLARIYLA MODELLENMESİ

DUÇEM M. KILAVUZ

DİCLE ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM-ÖĞRETİM VE SINAV YÖNETMELİĞİNİN BİR PARÇASI OLARAK İNŞAAT MÜHENDİSLİĞİ ANA BİLİM DALI HİDROLİK VE SU KAYNAKLARI MÜHENDİSLİĞİ PROGRAMI YÜKSEK LİSANS TEZİ
OLARAK HAZIRLANMIŞTIR

NİSAN 2022

DİYARBAKIR

DİCLE NEHRİNDE ÇÖZÜNMÜŞ OKSİJEN DERİŞİMİNİN YAPAY SİNİR AĞLARIYLA MODELLENMESİ

Duçem M. KILAVUZ tarafından Dicle Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin bir parçası olarak hazırlanan bu çalışma, aşağıda bilgileri yazılı jüri üyeleri tarafından değerlendirilerek **Hidrolik ve Su Kaynakları Mühendisliği Ana Bilim Dalı**'nda **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Prof. Dr. Neslihan DALKILIÇ _____
Müdür, **Fen Bilimleri Enstitüsü**

Prof. Dr. Fevzi ÖNEN _____
Danışman, **İnşaat Mühendisliği Bölümü,**
Dicle Üniversitesi

Sınav Jürisi:

Doç. Dr. Nizamettin HAMİDİ **(*)** _____
İnşaat Mühendisliği Bölümü, Dicle Üniversitesi

Prof. Dr. Fevzi ÖNEN **(**)** _____
İnşaat Mühendisliği Bölümü, Dicle Üniversitesi

Dr. Öğr. Üyesi Gökmen ÖZTÜRKMEN _____
İnşaat Mühendisliği Bölümü, Gaziantep Üniversitesi

ONAY

Savunma Tarihi: 19 / 04 / 2022

(*) Sınav Jürisi kısmının birinci satırına Jüri Başkanının bilgilerini yazınız.
(**) Sınav Jürisi kısmının ikinci satırına Tez Danışmanının bilgilerini yazınız.

Dicle Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışmasında yer alan tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, bahse konu bu kural ve ilkelerin gerektirdiği üzere, bu çalışmada özgün olmayan tüm bilimsel içerikleri kurallara uygun biçimde alıntılayıp kaynak gösterdiğimi beyan ederim. Beyanımla çelişen herhangi bir delil bulunduğu takdirde tüm sorumluluğu üstleneceğimi kabul ederim.

Ad, Soyad: Duçem M. KILAVUZ

İmza:

TEŞEKKÜR

Her anımda yanımda olan aileme; çalışma süresince bilgi, deneyim ve yönlendirmeleriyle her zaman destek olan danışman hocam Prof. Dr. Fevzi Önen'e teşekkürlerimi sunarım.

Değerli fikirleri ve katkıları için Doç. Dr. Nizamettin Hamidi'ye teşekkürü borç bilirim.

Çalışmadaki verilerin temin edildiği Devlet Su İşleri 10. Bölge Müdürlüğü'ne teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR v
İÇİNDEKİLER vi
ŞEKİLLER LİSTESİ viii
TABLOLAR LİSTESİ x
SİMGELER VE KISALTMALAR LİSTESİ xi
ÖZET xiii
ABSTRACT xiv
1. GİRİŞ 1
1.1 Çalışmanın Anlam ve Önemi 1
1.2 Çalışmanın Amacı ve Kapsamı 6
1.3 Tez Düzeni 6
2. ÖNCEKİ ÇALIŞMALAR 8
2.1 Su Kalitesi İzlenmesi Konusunda YSA Kullanımı ile İlgili Çalışmalar 8
2.2 Nehir Suyu Kalitesinde YSA Kullanımı ile İlgili Çalışmalar 9
3. MATERYAL VE METOT 13
3.1 Çalışma Alanı 13
3.2 Veri Temini 15
3.3 Yapay Sinir Ağı Yöntemi 15
3.3.1 Genel bakış 15
3.3.2 YSA temel bileşenleri 16
3.3.3 YSA türleri 25
3.3.4 YSA modellemesinde öğrenme 28
3.3.5 YSA avantajları ve dezavantajları 32
3.3.6 Veri normalizasyonu 34
4. BULGULAR VE TARTIŞMA 36

4.1 Dicle Barajı İstasyonu İçin Model Çıktıları 38
4.2 Ongözlü Köprü İstasyonu İçin Model Çıktıları 50
4.3 Yorumlama 62
5. SONUÇ VE ÖNERİLER 63
KAYNAKLAR 65
ÖZGEÇMİŞ 72

ŞEKİLLER LİSTESİ

Şekil 1.1 Suyun niteliği ile ilgili yapılan modelleme çalışmalarının kronolojik gelişimi [10] 5
Şekil 3.1 İstasyon noktaları lokasyonu. 14
Şekil 3.2 Sinir ağı yapısında bulunan nöron ait şema [40] 18
Şekil 3.3 Doğrusal aktivasyon fonksiyonu 20
Şekil 3.4 Sigmoid aktivasyon fonksiyonu 20
Şekil 3.5 Hiperbolik tanjant aktivasyon fonksiyonu 21
Şekil 3.6 Temel olarak yapay sinir hücresinin mimarisi [39] 22
Şekil 3.7 Algılayıcı olarak çok katmanlı biçimindeki ağ oluşumu [49] 23
Şekil 3.8 Katmanların Yapay Sinir Ağı içindeki bağlantıları [39] 24
Şekil 3.9 YSA ile giriş, çıkış bağlantısı [39] 34
Şekil 4.1 Dicle Barajı istasyonu M1 modeli saçılma diyagramı 40
Şekil 4.2 Dicle Barajı istasyonu M2 modeli saçılma diyagramı 41
Şekil 4.3 Dicle Barajı istasyonu M3 modeli saçılma diyagramı 41
Şekil 4.4 Dicle Barajı istasyonu M4 modeli saçılma diyagramı 42
Şekil 4.5 Dicle Barajı istasyonu M5 modeli saçılma diyagramı 43
Şekil 4.6 Dicle Barajı istasyonu M6 modeli saçılma diyagramı 43
Şekil 4.7 Dicle Barajı istasyonu M7 modeli saçılma diyagramı 44
Şekil 4.8 Dicle Barajı istasyonu M8 modeli saçılma diyagramı 45
Şekil 4.9 Dicle Barajı istasyonu M9 modeli saçılma diyagramı 45
Şekil 4.10 Dicle Barajı istasyonu M10 modeli saçılma diyagramı 46
Şekil 4.11 Dicle Barajı istasyonu M11 modeli saçılma diyagramı 47
Şekil 4.12 Dicle Barajı istasyonu M12 modeli saçılma diyagramı 47
Şekil 4.13 Dicle Barajı gerçek değerler ile M2 model değerleri ilişkisi 49
Şekil 4.14 Dicle Barajı gerçek değerler ile M2 modeli tahmin değerlerinin karşılaştırılması 49
Şekil 4.15 Ongözlü Köprü istasyonu M1 modeli saçılma diyagramı 52
Şekil 4.16 Ongözlü Köprü istasyonu M2 modeli saçılma diyagramı. 53
Şekil 4.17 Ongözlü Köprü istasyonu M3 modeli saçılma diyagramı 53
Şekil 4.18 Ongözlü Köprü istasyonu M4 modeli saçılma diyagramı 54
Şekil 4.19 Ongözlü Köprü istasyonu M5 modeli saçılma diyagramı 55
Şekil 4.20 Ongözlü Köprü istasyonu M6 modeli saçılma diyagramı 55

Şekil 4.21 Ongözlü Köprü istasyonu M7 modeli saçılma diyagramı. 56
Şekil 4.22 Ongözlü Köprü istasyonu M8 modeli saçılma diyagramı 57
Şekil 4.23 Ongözlü Köprü istasyonu M9 modeli saçılma diyagramı 57
Şekil 4.24 Ongözlü Köprü istasyonu M10 modeli saçılma diyagramı 58
Şekil 4.25 Ongözlü Köprü istasyonu M11 modeli saçılma diyagramı 59
Şekil 4.26 Ongözlü Köprü istasyonu M12 modeli saçılma diyagramı 59
Şekil 4.27 Ongözlü Köprüsü gerçek değerler ile M1 model değerleri ilişkisi..... 61
Şekil 4.28 Ongözlü Köprüsü gerçek değerler ile M1 modeli tahmin değerlerinin karşılaştırılması 61

TABLOLAR LİSTESİ

Tablo 1.1 Suyun oksijen çözebilme miktarı ile sıcaklık arasındaki bağlantısı 4
Tablo 3.1 İstasyonlara ait coğrafi bilgiler 14
Tablo 3.2 Toplama fonksiyonunun çeşitleri [39]. 18
Tablo 3.3 Farklı türde aktivasyon fonksiyonları [39] 21
Tablo 4.1 Her bir istasyonun bütün parametreleri için toplam veri adedi. 36
Tablo 4.2 Kullanılan YSA yapıları. 37
Tablo 4.3 İstasyonlardaki model kombinasyonları 37
Tablo 4.4 Dicle Barajı model sonuçları 38
Tablo 4.5 Dicle Barajı istasyonu model performans değerleri 48
Tablo 4.6 Ongözlü Köprü model sonuçları. 50
Tablo 4.7 Ongözlü Köprü istasyonu model performans değerleri. 60

SİMGELER VE KISALTMALAR LİSTESİ

Simge	Açıklama
TDS	Toplam Çözünmüş Katı Madde
Cl	Klor
Mn	Mangan
R^2	Determinasyon Katsayısı
T	Sıcaklık
NH_3	Amonyak
H_2S	Hidrojen Sülfür
EC	Elektriksel İletkenlik
NO_2-N	Nitrit Azotu
NO_3-N	Nitrat Azotu
BOD_5	Beş günlük biyokimyasal oksijen ihtiyacı
O-PO_4	Fosfat
Fe	Demir
Na	Sodyum
Ca	Kalsiyum
Mg	Magnezyum
X_n	Normalleştirilmiş Veri
G_i	Girdiler
A_i	Ağırlıklar
X	Girdi Vektörü
Y	Çıktı Vektörü
τ_w	Zaman Sabiti

Kısaltma	Açıklama
BOİ	Biyokimyasal oksijen ihtiyacı
BPN	Geri Yayılım Sinir Ağı
ÇKA	Çok Katmanlı Algılayıcı
ÇO	Çözünmüş Oksijen
DSİ	Devlet Su İşleri
FFBPNN	Feed Forward Back Propagation Neural Network
FFNN	Feed Forward Neural Network
GA	Genetik Algoritma
GRNN	Generalized regression neural network
İBGYSA	İleri Beslemeli Geriye Yayılım Sinir Ağ
LM	Levenberg-Marquardt
LULC	Landuse/Landcover
OKH	Ortalama Karesel Hata
OMH	Ortalama Mutlak Hata
RBFNN	Radial Basis Function Neural Network
RL	Reinforcement learning
YSA	Yapay Sinir Ağı
WQ	Water Quality
WQI	Water Quality Index

ÖZET

DİCLE NEHRİNDE ÇÖZÜNMÜŞ OKSİJEN DERİŞİMİNİN YAPAY SİNİR AĞLARIYLA MODELLENMESİ

Kılavuz, Duçem M.
Yüksek Lisans, Hidrolik ve Su Kaynakları Mühendisliği Bölümü
Danışman: Prof. Dr. Fevzi Önen
Nisan 2022, 87 sayfa

Gittikçe küreselleşen Dünya'da önemli sorunlardan birisi olan su kirliliği konusundaki çalışmalar artarak devam etmektedir. Kirliliğin kontrol altına alınabilmesinde, su kalite çalışmalarının katkısı önemlidir. Suların nitelik olarak standartlara uygun olması gerekliliğinden dolayı su kalitesi üzerine analiz çalışmaları yapılmaktadır. Sucul ortamın dengesini direkt etkileyebilen, su kalitesinin önemli bir parametresi olan çözünmüş oksijenin ele alınması, su kalitesinin yorumlanmasında oldukça önem taşımaktadır. Bu çalışmada, Devlet Su İşleri (DSİ) 10. Bölge Müdürlüğü'nden temin edilen veriler kullanılarak, Dicle nehri alt havzasının çözünmüş oksijen parametresi Yapay Sinir Ağı yöntemi ile modellenmiştir. İstasyon olarak Dicle barajı ve Ongözlü köprü istasyon noktalarına ait veriler kullanılarak, girdi olarak Matlab programı yardımıyla işlenip, çözünmüş oksijen için farklı yapı ve kombinasyonlarda YSA modelleri oluşturulmuştur. Verilerden en iyi çıktıyı almak amacıyla ham verilere normalizasyon tekniği uygulanmıştır. Normalize edilen veriler yapay sinir ağlarında işlenerek tahmin modelleri oluşturulmuştur. Tahmin modelleri her bir istasyon için toplam on iki model olup, bunlar arasındaki performans analizi için R^2 (determinasyon katsayısı), OMH (ortalama mutlak hata) ve OKH (ortalama karesel hata) değerleri hesaplanarak, yorumlanmıştır. En uygun çıktıyı veren modeller, her iki gözlem noktasında da yapı olarak İleri Beslemeli Geriye Yayılım Sinir Ağı (İBGYSA) olup algoritma olarak ise Levenberg – Marquardt backpropagation(trainlm)'dır. Nehir suyu çözünmüş oksijeninin modellenmesinde yapay sinir ağlarının kullanılan veri sayısı, zaman ve maliyet açılarından başarılı ve verimli çıktılar oluşturduğu görülmüştür. Diğer yandan sinir ağlarından faydalanılarak su niceliğinden bağımsız bir şekilde su kütlesinin analiz çalışmaları mümkün olup, kirlilik parametrelerinin tayini rahatlıkla gerçekleştirebilmektedir. Her çalışmanın kendi bölgesindeki elzem kirlilik kaynakları belirlenerek, kalite parametrelerinin analiz çalışması sinir ağları aracılığıyla verimli bir şekilde gerçekleştirilebilir.

Anahtar Kelimeler: Dicle Nehri, Su Kalitesi, Çözünmüş Oksijen, Yapay Sinir Ağı

ABSTRACT

MODELING OF DISSOLVED OXYGEN CONCENTRATION OF THE TIGRIS RIVER WITH ARTIFICIAL NEURAL NETWORKS

Kılavuz, Duçem M.
Master of Science in Department of Hydraulic and Water Resources Engineering
Supervisor: Prof. Dr. Fevzi Önen
April 2022, 87 pages

Studies on water pollution, which is one of the important problems in an increasingly globalized world, are increasingly continuing. Contribution of water quality studies is important in controlling pollution. Analysis studies are carried out on water quality due to the requirement that the waters comply with the standards in terms of quality. Addressing dissolved oxygen, which is an important parameter of water quality, which can directly affect the balance of the aquatic environment, is very important in the interpretation of water quality. In this study, the dissolved oxygen parameter of the Tigris sub-basin was modeled with the Artificial Neural Network method, using the data obtained from the 10th Regional Directorate of State Hydraulic Works (DSI). The data of the Dicle dam and Ongözlü bridge station points were taken as stations, processed with the help of Matlab program as input, and ANN models with different structures and combinations were created for dissolved oxygen. In order to get maximum efficiency from the data, the normalization technique was applied to the raw data. Prediction models were created by processing the normalized data in artificial neural Networks. Forecast models are twelve models in total for each station, and values such as R^2 (coefficient of determination), MAE (mean absolute error) and MSE (mean square error) were calculated and interpreted for the performance analysis among them. The models that give the most favorable output are Feed Forward Backpropagation Neural Network (FFBPNN) at both observation points and Levenberg – Marquardt backpropagation(trainlm) as an algorithm. In the modeling of river water dissolved oxygen, it has been seen that artificial neural networks create successful and efficient outputs in terms of the number of data used, time and cost. On the other hand, analysis studies of water bodies can easily determine the pollutant parameters by making use of neural networks independently of water quantity. By determining the essential pollution sources in its region of each study, the analysis of the parameter can be carried out efficiently through neural networks.

Keywords: Tigris River, Water Quality, Dissolved Oxygen, Artificial Neural Network

1. GİRİŞ

Canlıların hayatlarını sürdürebilmesinde vazgeçilmez bir unsur olan suyun, belirli bir kaliteye sahip olması gerekir. Bu anlamda, modelleme araçları yardımıyla farklı yapılarda kalite tahmin mimarileri elde edilmektedir. Bu çalışmada, Dicle nehrinin alt havzası için yapay sinir ağları aracılığıyla çözünmüş oksijenin modellenmesi amaçlanmıştır. Bu çalışmada çözünmüş oksijen, modellenmesi hedeflenen parametre olarak tercih edilmiştir. Bu parametre seçiminin sebebi; sulardaki çözünmüş haldeki en önemli gazlardan olan oksijenin, ulusal ve uluslararası kriter ve standartlara göre belirli bir seviyede olması gerekliliğinden dolayıdır. Yeteri oranda ÇO muhtevasının olmayışı, sucul ortamın dengesini direk ve dolaylı yönlerden olumsuz olarak etkileyebilmektedir. Örneğin, su ortamındaki canlı çeşitliliğini azaltmasının yanı sıra sudan faydalanılma yüzdesini de dolaylı olarak etkilemektedir. Bu bölümde konu geniş anlamda ele alınarak öncelikle çalışmanın tanımı yapılarak, amacı üzerinde durulmuş ve son olarak tezin bölümleri hakkında açıklamalarda bulunulmuştur.

1.1 Çalışmanın Anlam ve Önemi

Yaşamsal olayların gerçekleşebilmesinde suyun varlığının, niteliğinin ve devamlılığının önemi yadsınamaz bir gerçekliğe sahiptir. Suya bütün yaşayan varlıklar muhtaçtır. Dağıtma düzeni, yapılan arındırma ile hidrolojik çevrim biçimindeki farklı etmenler, suyun kalitesini belirler. Suyun niteliği, henüz bulutta form olarak buhar biçiminden yağış olarak iniş şekline ulaşıncaya kadar meydana gelir. İçilebilir durumdaki suların niteliği neredeyse tüm canlı varlıklar açısından çok değerlidir. Su kirliliği yüzünden yaşamları devam ettirilemez durumda olan sayısız canlı, varlıklarını belli bir su birikintisi içerisinde sonlandırmaktadır. Gelişmiş yapıdaki ülkeler açısından da su kalitesi, çok fazla önemsenen çevre sağlığı problemleri içerisinde var olma niteliğini devam ettirmektedir. Patojenik mikroorganizmaların esas kirlilik bulaştırıcı niteliği devam etmekte olup; fazla miktarda gübre, kimyasal ilaç alışkanlığı, hızla ivmelenen endüstrileşme ve uygunsuz endüstriyel yapılanmadan dolayı su rezervlerindeki kirlilik kimyasal açıdan zamanla yükselmektedir [1].

Suya olan ihtiyaç yakın zamanlarda artış göstermiştir. Su rezervlerinin korunarak, en kazançlı biçimde faydalanılmasının mümkün kılınması; yer küredeki yararlanılabilir

su niceliğinin sınırlı olmasından dolayı çok fazla ön plana çıkmaktadır. Suyun etkili ve verimli bir biçimde kullanılabilmesi için belirli bir niteliğe sahip oluşu, yaşamsal derecede önem teşkil etmektedir. Su niteliğinde yabancı materyallerin tesiri; materyallerin bütünüyle saptanıp, su membasına ait yararlanma bölgesinde geçerli kalite ihtiyaçlarının belirlenmesinin ardından saptanabilir [2].

"Çoğu kez belli bir kullanım amacına elverişliliği bakımından suya ait biyolojik, kimyasal ile fiziksel vasıflar" ifadesi, geniş çaptaki su niteliğinin açıklamasıdır. Balıkçılık, zirai uygulamalar, rekreasyon, endüstri ve içme suyu şeklinde sudan birden çok yararlanma biçiminin olduğu çoğumuzun malumudur. Buradaki yararlanmaları geliştirmek adına, böylesine tanımlanmış faydalı amaçlara hizmet eden, değişik biçimde ele alınmış biyolojik, kimyasal ve fiziksel ölçütler mevcuttur [3].

Suyun kalite tayininin yapılması, rezervlerinde nitelik olarak öne çıkan kalite parametrelerinin takibi ve analizinin gerçekleştirilmesiyle, sudan yeterli biçimde faydalanılma mümkün kılınabilir. Dolayısıyla kalite izlenmesi ve modellenmesi çalışmaları, zamanla daha büyük bir role sahip olmaktadır. Suyun kalitesi, sudan yararlanılmasına dair etkisi olan faktördür. Sularda kirlilik oluşumu; rezervlerin küçülmesi, kalitesinin kötüleşmesi; uygunsuz toprak işlemleri, nüfus ile sanayinin seri bir şekilde yükselmesi ve aşırı zirai uygulamalardan dolayıdır. Kalite yönetiminin kapsamında, sudaki kalitenin muhafaza edilip denetlenmesi, faydalı olarak gerek şuan gerekse de ilerisi için suyun kullanılması hedefi bulunmaktadır [4].

Yeterli seviyedeki bir çözünmüş oksijen (ÇO), sucul hayatın tamamı açısından yaşamsal tesire sahiptir. Bir asır geçmiş zamandır, yetersiz ÇO derişimlerinin nehirlerde oluşturduğu sorunlar tanımlanmış olup, yetersiz düzeydeki ÇO derişimlerinin sonuçları ya da doğal biçimde yeterli oksijeni azalmış nehrin yapısındaki fazlaca anaerobik şartların tesiri; balık kayıpları ile kokularına ve başka yaşamsal sıkıntıları olan dengesiz bir çevre oluşumuna yol açmaktadır. Sucul ortamdaki hayvanlar soluma biçimlerini, ÇO derişimi düştüğünde farklılaştırmaya ya da etkinlik düzeylerini düşürmeye mecbur edilirler [5].

Biyokimyasal başkalaşma ile bir akarsudaki çözünmüş oksijen muhtevasının farklılaşması arasında belli bir bağlantı vardır. Akarsuların bünyesine sarfiyat ile topak yıkanması şeklinde aktarılan organik materyallerin oksidasyon işlemi sonucu başkalaşma meydana gelir. Oksidan organik ajanlar ve kimi yükseltgeyici bakteriler aracılığıyla organik materyalin kademeli olarak oksitleşmesi ve de dengelenmesi yapılır [6].

Suyun nitelik olarak yeterliliğinin belirlenmesinde, çözünmüş gazlar baskın bir biçimde etkilidirler. Gaz olarak oksijenin sudaki çözünme oranı, suyun kullanılabilirliğine dair baskın bir etmendir. Özellikle nehir suları gibi geniş su birikintilerinde, çözünmüş oksijen muhtevasının kararlaştırılması ve bu anlamda modellemelerin yapılması çalışmaları kaçınılmazdır. Birçok gaz suda ayrışır. Laboratuardaki incelemeler yardımıyla miktar ile niteliksel yönlerden sudaki dağılmış olan gazlar saptanabilir. Gazlar içerisinden bilhassa oksijen ile karbondioksit derişimlerinin elde edilmesi son derece önemlidir.

Winkler metodu ile (Mn^{2+}'den yükseltgenme ile Mn^{4+} oluşumu) oksijen miktarı analitik biçimde belirlenir. Ek olarak, oksijen elektrotlarından da daimi biçimde oksijen yoğunluğunun tayin edilebilmesi amacıyla faydalanılmaktadır [7]. Suyun sahip olduğu tuzluluk oranı ile sıcaklığı, sudaki oksijenin çözünme oranını belirler. Artan sıcaklık ile beraber sudaki ayrışan oksijen miktarının azaldığı gözlemlenir. Suyun kirliliğinde en etkili parametrelerin içerisinde çözünmüş oksijen vardır. Havanın oksijen muhtevası ve bakterilerin sucul ortamındaki fotosentezi ile meydana gelen oksijen, suyun ayrışmış haldeki oksijenini (Çözünmüş Oksijen=ÇO) oluşturur. Sudaki mineral dozajı, havada bulunan oksijenin kimyasal basıncı ve su kütlesine ait sıcaklık su bünyesindeki oksijenin çözünürlüğü üzerinde etkiye sahiptir [1].

Tatlı sularda havadaki oksijen; basınç olarak 1 atm'de, sıcaklık olarak 0°C ile 35°C'de sırasıyla 14.6 mg/l ile 7 mg/l kadar çözünür. Belli bir sıcaklıkta, sudaki oksijen dağılımının atmosfer basıncına bağlı oluşu, oksijen gazının su içerisinde son derece düşük miktarda ayrışabilme özelliğinden kaynaklanmaktadır. Isı değiştiriciler, su tertibatı ile kazanlar çözünmüş oksijenden dolayı yıpranabilir. Suyun oksijen

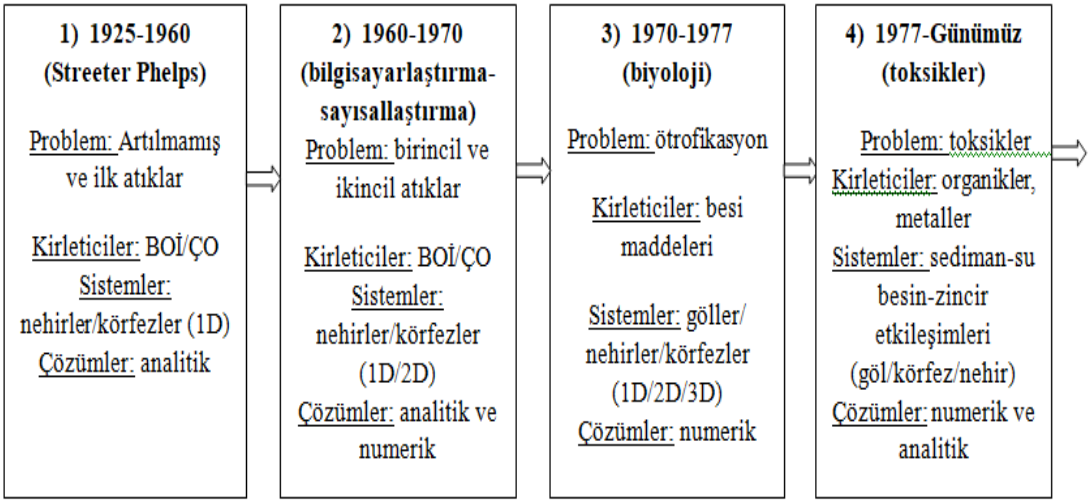
ayrıştırabilme kabiliyeti, mineral oranı ile değişmektedir. Kuyu ve deniz sularında çözünmüş oksijen, taze sulara göre daha düşüktür [8].

Tablo 1.1'de sudaki oksijen çözünürlüğünün sıcaklığa bağlı olarak değişimi görülmektedir.

Tablo 1.1 Suyun oksijen çözebilme miktarı ile sıcaklık arasındaki bağlantısı [9]

Sıcaklık °C	Çözünebilen Oksijen mg/1	Sıcaklık °C	Çözünebilen Oksijen mg/l	Sıcaklık °C	Çözünebilen Oksijen mg/1
0	14.6	12	10.8	24	8.5
1	14.2	13	10.6	25	8.4
2	13.8	14	10.4	26	8.2
3	13.1	15	10.2	27	8.1
4	13.1	16	10.0	28	7.9
5	12.8	17	9.7	29	7.8
6	12.5	18	9.5	30	7.6
7	12.2	19	9.4	35	7.1
8	11.9	20	9.2	40	6.6
9	11.6	21	9.0	45	6.1
10	11.3	22	8.8	50	5.6
11	11.1	23	8.7		

Suyun kalitesinin belirlenmesi konusunda modelleme araçları geliştirilmiş olup, kalite analiz çalışmalarında bu araçlardan geçmiş yıllardan günümüze kadarki süreçte farklı su kütleleri üzerinden istifade edilmiştir. Suya ait kalite modelleme araçlarından faydalanarak, su kaynağındaki kirleticilerin derişimlerine dair ön görüde bulunmak, tahmin modellemeleri oluşturmak amaçlanır [10]. Kronolojik olarak su kalitesi konusundaki modellemelerin gelişimi aşağıdaki Şekil 1.1 ile ifade edilmiştir.



Şekil 1.1 Suyun niteliği ile ilgili yapılan modelleme çalışmalarının kronolojik gelişimi [10]

Simüle etme programlarının kullanımının ehemmiyeti; sanayi ve domestik kirli su boşalımlarının ıslah edilmesini için gözetleme tasarımlarının mümkün kılınabilirliği ve tahliyelerdeki düşüşlerin ne tür niceliklerde sağlanması gerektiğini belirlediğinden dolayıdır. [4].

Nehir kirlenmesini tetkik etmede değerli değişkenlerden biri çözünmüş oksijen etkenidir. Zirai uygulamalardan meydana gelen gübrelik dışkı ile haşere ilacı, imalathane çöpleri, lağım pisliği ve yüzeysel akıntı yoluyla nakledilen maddeler, nehirlere kirlilik bulaştırıcı faktörlerden olup, noktasal ile noktasal olmayan türdeki kirlilik kaynaklarıdır. Hıfzıssıhha yönünden, akarsulardan temizleme kuruluşları olmaksızın şehir çöpüne karşı bir vasıta biçiminde faydalanılması zararlı neticelere sebep olmaktadır [11].

Çevre ile sudaki bozulmalara dair şiddetli kaygılardan dolayı, geçtiğimiz zamanlarda su kalitesine ait tetkikler giderek ön plana çıkmıştır. Su niteliğinde tesiri olan etmenleri ve kirliliğin nedenleri ile sonucundaki kirlenme düzeylerinin farklılaşmasını belirlemek, nehir suyuna ait kalite tetkik yazılımlarının en öncelikli hedefidir [12].

Özel olarak, birden fazla farklı amaçla faydalanılan nehir sularının kalitesinin değerlendirilmesi, gittikçe artan bir öneme sahiptir. Ayrıca, modelleme yardımıyla su

kalite parametrelerinin işlenerek çözünmüş oksijenin belirlenebilmesi, nehir suları gibi stratejik olarak öne çıkan sular için çok kullanılan bir yöntemdir.

1.2 Çalışmanın Amacı ve Kapsamı

Bu çalışma kapsamında, su kütlesi olarak Dicle nehir alanında bulunan Dicle barajı ve Ongözlü köprü isimli istasyonlarının oluşturduğu alt havza seçilmiştir. Su kütlesi olarak belirlenen bu alt havza için suyun kalitesinin değerlendirilmesi amaçlanmıştır. Bu bağlamda, kalite parametreleri içerisinde analiz edilmesinin büyük etkisi olan çözünmüş oksijen için modeller oluşturulmuştur. Modelleme için Yapay zeka modellerinden olan Yapay Sinir Ağı (YSA) modeli kullanılmıştır. Çalışmada üç farklı eğitim algoritması, iki transfer fonksiyonu ve iki ayrı gizli katman sayısına göre YSA yapıları elde edilmiştir. Dicle nehri için iki farklı istasyonun verileri DSİ 10. Bölge Müdürlüğü'nden alınmıştır. Bu istasyonların her biri için 14 farklı kalite parametresi girdi olarak işlenerek, çözünmüş oksijen tayini için YSA'da farklı tahmin modellerine ulaşılmak hedeflenmiştir. Böylece YSA ile elde edilen sonuçlara dair hata değerleri ve korelasyon katsayıları değerlendirilerek, su kaynaklarında kalite analizleri konusunda YSA'nın etkinliği tespit edilmeye çalışılmıştır.

1.3 Tez Düzeni

Tez toplamda altı bölümden oluşmakta olup, ilk kısım olan Giriş'te probleme dair genel konsept açıklanıp, bu çalışmanın amaç ve kapsamı ele alınmıştır. Bu kısımda ele alınan problemin tanıtımının ardından önemine yer verilmiştir.

İkinci bölümde ise, su kalitesi parametrelerinin kullanılarak Yapay Sinir Ağı'nda tahmin modellerinin oluşturulmasına dair literatürde yapılan önceki çalışmalara dair bilgilere yer verilmiştir. Bu bilgilendirmeler kendi içerisinde su kalitesi, nehirlerdeki su kalitesinin önemi, çözünmüş oksijenin su kalitesindeki ve bilhassa nehirlerdeki önemi gibi birçok farklı konu başlığına atıfta bulunulacak şekilde detaylandırılmıştır.

Üçüncü kısımda materyal ve metot başlığı adı altında, tezde söz konusu olan bölgenin tanıtımı, ham verilerin temini, bilgileri ve bu verilerin işleniş biçimini ifade eden modelleme aracı YSA'ya ait bilgilere yer verilmiştir. Çalışmadaki yöntemi ifade eden YSA yapısına ait açıklamalar, genel bilgilerden başlanıp, özel

açıklamalarda bulunularak devam edilmiştir. Ayrıca verilerin işlem görmesi aşamasında kullanılan normalizasyon yöntemi açıklayıcı ifadelerle belirtilmiştir.

Oluşturulan YSA mimarilerinden edinilen çıktılar ise dördüncü bölümde ifade edilmiştir. Bulgu olarak, her iki istasyon için de edinilen model tahmin çıktıları belirtilmiştir. Ardından bu sonuçların yorumlanması bu kısımda açıklanmıştır.

Son olarak çalışmaya dair sonuç ve öneriler ise beşinci kısımda açıklanmıştır. Bu kısımda çalışmanın amaç ve kapsamından itibaren edinilen sonuçlar ve bu sonuçlara dair değerlendirmelerde bulunulmuştur. Yapılan çıkarımlara ek olarak, yapılabilecek sonraki uygulama ve araştırma faaliyetlerine yönelik önerilerde bulunulmuştur.

2. ÖNCEKİ ÇALIŞMALAR

Günümüzde Yapay Sinir Ağları'nın kullanımı yaygın bir hal almış olup; modelleme aracı biçiminde farklı bilim dallarına ait konularda, değişik amaç ve kapsamlarda kullanılmaktadır. Bu doğrultuda birçok örnek çalışma yapılmış olup, performans olarak elverişli sonuçlar oluşturduğu yorumlanmıştır.

2.1 Su Kalitesi İzlenmesi Konusunda YSA Kullanımı ile İlgili Çalışmalar

YSA'nın birden çok farklı alanda kullanımı mevcut olup; nehir, göl, baraj veya yer altı suyu gibi farklı su kütlelerinin kalite çalışmalarında sıklıkla yararlanıldığı görülmektedir. Özellikle su kalitesi belirleme çalışmalarında birçok farklı YSA analiz örneği görülmektedir. Su kaynakları ile çevre alanlarındaki modellemelerde yapay sinir ağları (YSA)'nın kullanımı, 1990'lı yılların başından itibaren artış göstermektedir. YSA aracılığıyla su kütlelerine ait farklı parametreler kullanılarak, analizi hedeflenen değişkenler için farklı modeller oluşturulabilmektedir. Birçok araştırmada, su kalitesine ait birden fazla değişken modellenmiştir [13].

Modelleme aracı olarak YSA'nın kullanıldığı örneklerde, başarılı sonuçlar veren belli başlı yapılar bulunmaktadır. Bunlar arasında çoğunlukla ileri beslemeli türdeki geri yayılım ağ yapıları öne çıkmaktadır. Yapılan farklı çalışmalarda, özel olarak Levenberg-Marquardt algoritması ile edinilen tahmin sonuçların düşük hata değerleri ortaya koyduğu, sıklıkla gözlemlenmiştir. Bu araştırma, üç katmanlı ileri beslemeli geri yayılım kavramalı Levenberg-Marquardt sinir ağlarıyla WQ (su kalitesi) parametreleri ve LULC (arazi kullanımı ve arazi örtüsü) yüzde oranlarının bağlantılarını anlamak için yapılmıştır. Su ve çevre uygulamalarında ağ olarak ileri beslemeli, öğrenme olarak geriye yayılım Levenberg-Marquardt yapısı verimli bir şekilde çalıştırılmıştır. [14].

Tasarımlarda, suyun niteliğindeki değişimleri belirlemek esaslı bir ihtiyaçtır. Evvelden beri YSA'lar, birkaç su membasının birlikte olması halinde dahi kalite düzeylerini sağlıklı biçimde modellemişlerdir. Birçok çevre problemine açıklık getirmek amacıyla YSA mimarilerinden faydalanılmıştır. Örnek olarak; birtakım YSA yapıları, nehirlerin su kalitesine ait parametreleri ön görmede kullanılmıştır. Bu uygulamada, eyalet olarak Sudan'nın Kızıldeniz'indeki su kaynaklarının içilebilirliği

ve kalitesi değerlendirmiştir. WQI'yı araştırmak için oluşturulan YSA'da; girdi verilerinin öğrenme, doğrulama ve test etme aşamalarına dayalı bulguları çoğunlukla 1:1 ile sınırdaş olarak korelasyon ortaya koymuştur [15].

2.2 Nehir Suyu Kalitesinde YSA Kullanımı ile İlgili Çalışmalar

Nehir sularındaki kalite değerlerinin incelenip, yorumlanması hususlarında YSA'dan birçok kez faydalanılmıştır. Önceden oldukça sınırlı olan YSA çalışmalarından, özellikle Hindistan su kalitesinin modellenmesinde faydalanılmıştır.

Bir akıştaki çözünmüş oksijenin tayini amacıyla, konuyla alakalı tasarılar yapılarak, değişik deterministik modeller geçmişten beri uygulanmaktadır. Uygulamada tabii yapıların, en sofistike deterministik sistemlere dahi aşırı komplike gelmesinden dolayı, çoğunlukla modellemenin istatistik bilimi açısından tutarlılığı yetersizdir. YSA'lar aracılığıyla akarsuyun kalite tayini için süratli ve değişken bir biçimde modellemeler elde edilebilir. Geçtiğimiz senelerde YSA'lar bilhassa analiz öngörüsü ve şekil tanımada uygulandığı zaman, regresyon aygıtları biçiminde fevkalade bir verim ortaya koymuştur [16].

2013 yılında Malezya Johor Nehri Havzası su niteliğinin öngörülebilmesi için yüzey akış ağları (nehirler) bölgesinde Najah ve çalışma ekibinin yaptığı çalışmada; çok katmanlı yapıdaki algılayıcı sinir ağları, radyal temelli sinir ağları (RBF-NN) ve lineer regrasyon mimarileri şekillendirilmiştir [17]. Nehir çalışmaları, farklı bölgelerden değişik örneklerle benzer biçimde çoğaltılabilir;

2017 yılında Hindistan'daki nehirlerden olan Hooghly için etkili bir şekilde su kalitesinin incelenebilmesi adına Chatterjee ve ekibi, birçok su numunesini nehirden temin ettikten sonra YSA'da bulunan çok amaçlı GA (Genetik Algoritma)'yı kullanmışlardır. 2019 yılındaki benzer bir çalışmada ise, Hindistan'ın Shivganga Nehri suyunun içilebilirlik açısından elverişliliğini anlamak adına Kadam ve arkadaşları havza yer altı suyundan 34 su numunesi elde ederek, tahlil etmişlerdir [18].

Kim ve Seo Güney Kore, Nakdong Nehri'nin bulanıklık ve pH gibi su kalite parametrelerini değerlendirmek amacıyla 2015 senesinde birleşik veri gruplaştırma yöntemini kullanarak YSA'ları bütünleştirmiştir. Uğraşları, pis suyun kökenlerini incelemek ve bu sudan dolayı ortaya çıkan rahatsızlıkların yayılmasını önlemektir. [19].

Bu çalışmada, parametre olarak çözünmüş oksijen incelenip, suların kalitesindeki önemi vurgulanmaktadır. Parametre olarak ÇO, birçok farklı açıdan su niteliği üzerinde etkiye sahiptir. Nehirde kimi menzillerde oksijensiz solunum şartlarının oluşumu, nehirde oksijenden faydalanma yüzdesinin oksijenin temin edilmesinden fazla olduğu durumda gerçekleşir. Buradaki alanlar ya da akışlar rahatlıkla gözlemlenir, çünkü başka gazlarla beraber parçalanma sonucunda kükürtlü hidrojen (H_2S) ile amonyak (NH_3) meydana gelir. Bu tarz değişimlerin sonuçları, sucul hayata da yansımaktadır. Kirliliğin oluşumundan itibaren, türlerin sayı ve çeşidinde kayda değer farklılıklar oluşur. Yetersiz seviyede çözünmüş oksijen ve çoğalan türbidite ile oturan katı materyal niceliği, balıkların varoluşunu olumsuz yönde etkiler [20].

Su kaynaklarındaki çözünmüş oksijen adına derişim saptamanın verimini, sunulan model ortaya koymaktadır [21]. Benzer şekilde çözünmüş oksijenin öne çıktığı çalışmalar daha önceden de gerçekleştirilmiştir.

Surma Nehri ÇO parametresinin analizi, küçük değişken setinden radyal taban işlevli (RBFNN) ve ileri beslemeli yapılı sinir ağı (FFNN) yoluyla düşük hatalı olarak gerçekleştirilmiştir. Buradaki araştırmada; çözünmüş oksijenin Surma Nehri' ne ait öngörüsü için YSA modelleyicilerinden faydalanılmıştır [21].

Tisza Nehri'nde ÇO muhtevasını belirlemek adına, YSA (GRNN ve RBFNN) ve lineer regresyondan yararlanılarak; 13 numune noktana ait elektriksel iletkenlik, sıcaklık, akış ve pH'nin olduğu parametreler kaydedilmiştir. R^2 ile OKH'den faydalanılarak modellerin başarı oranı yorumlanmıştır [22].

Modelleme araçları içerisinde YSA'dan faydalanılma yüzdesinin artış gösterdiği görülmektedir. Gün geçtikçe YSA'dan daha fazla yaralanılmasının nedeni; akıntı,

farklı su kalitesi parametreleri, su düzeyi ve yağış miktarı gibi bir grup su kaynağı değişkenlerinin analiz edilebilmesi ve modellenebilmesindendir [23].

Mekan ve zaman modellemesi açısından, Singapur bölgesi Doğu Johor Boğazı için YSA modeli oluşturularak, deniz suyunun hafta bazındaki sıcaklığı örneklenmiştir. YSA yapısı olarak, 0.3 ilk ağırlıklı üç gizli katmanlı geri yayılımlı, farklı transfer fonksiyonları olan (wardnet) mimari oluşturulmuştur. Bu çalışmada hedeflenen, YSA' da girdi olarak karmaşık, durağan olmayan ve aşamalı biçimdeki deniz suyu kalite parametrelerini ölçmektir. Deniz suyu için kalite tahmini YSA aracılığıyla geçmiş ölçüm değerlerindeki gizli bağlantılar çözülerek, basit bir şekilde gerçekleştirilmiştir [24].

Yani sucul ortamlarda ve su kaynak idaresinde, nehir suyu kalitesinin ön görülmesi temel bir husustur. Buradaki araştırmanın hedefi, nehirdeki kalite girdilerini modellemektir. YSA yapısı ile elde edilen elverişli yapılar: uzluluk tayininde tutarlılık; operatör ile teçhizatların denetlenmesi; olmayan girdilerin belirlenebilmesi; ölçüm araçlarının ayarlanması; nitelikli girdiklere dair tahmin kabiliyeti; bilimsel amaçlar sonucu edinilen çıktılarda mimariye göre hassasiyet incelemesi imkanı ve deneysel güçlüklerdeki şartları elverişli duruma ulaştırmak biçiminde sıralanmıştır. Su nitelik parametrelerini modellemek amacıyla oluşturulan bütün elverişli YSA yapılarındaki R'ler 0.99'a yakın çıkmıştır. Alkaliniteyi modellemek amacıyla yetiştirilmiş YSA yapısı, R çıktısıyla 0.82'ye karşılık gelmiştir [25].

Elhatip ve Kömür yaptıkları çalışmada Mamasin Barajı'nın su niteliğini, 2008 senesinde simüle etmişlerdir. Edinilen değerler, YSA'ların sonuçları öngörmedeki kabiliyetini ortaya koymuştur. Çıkış verisini, Mamasin Baraj alanındaki tahliye ile tekrar doldurma bölgelerinin su kalite değişkenleri oluşturmuştur [26].

2009 senesinde YSA model yapılarındaki kavrama, doğrulama ile test etme işleminden yararlanılarak, Gomti nehrindeki (Hindistan) biyokimyasal oksijen ihtiyacı (BOİ) ile çözünmüş oksijen (ÇO) miktarlarının tayini Singh ve çalışma arkadaşları tarafından amaçlanmıştır. Nehirdeki su kalitesini değerlendirmek için ölçüm süresi 10 senelik olan, on bir su kalite parametresi ele alınmış olup, iki değişik

modelleme yapısı uygulanmıştır. BOİ ve ÇO için oluşturulan mimarilerden elde edilen veriler sonucunda OKH ile korelasyon katsayısı (R^2) hesaplanmıştır. Bu araştırma, model olarak sinir ağlarının nehir sularında başarılı biçimde kalite değerlendirmesi yapabildiğini ortaya çıkarmıştır [27].

3. MATERYAL VE METOT

Bu tez çalışmasında kapsam olarak, Dicle nehri alt havzası su kalite parametrelerinden çözünmüş oksijenin saptanabilmesi için YSA metodu kullanılarak farklı modeller oluşturularak incelemeler yapılmıştır. Çalışmada ÇO parametresinin seçilmesinin nedeni, Dicle nehrindeki ÇO derişiminin öneminden dolayıdır. Kalite standartları gereği nehir sularındaki ÇO seviyesinin belirli bir aralıkta olması gerekmektedir. Aksi durumda, sudaki ve su dışındaki tüm canlıların yaşantısı olumsuz yönde etkilenebilmektedir.

Çalışma kapsamında kalite parametrelerine faktör analizinin yapılması tercih edilmemiştir çünkü kısıtlı veri sayısı ile çalışma yapıldığından dolayı verilerin daha fazla azaltılarak, modelin performansını düşürmemek amaçlanmıştır. Tezin bu kısmında, sırasıyla çalışmada kullanılan materyal ve uygulanan metot açıklanmıştır. Aşamaları başlık halinde ifade etmek gerekirse; çalışma bölgesine dair bilgiler, veri temini ve modelleme yöntemi olarak yapay sinir ağı açıklanmıştır.

3.1 Çalışma Alanı

Bu tez kapsamında üzerinde çalışılan bölge Dicle nehri olup, alt havzasında bulunan iki istasyona ait veriler işlenerek modellemede kullanılmıştır. Eski dönemlerden günümüze kadarki süreçte Dicle, nehir olarak önemli olup, su rezervi olarak tarihi Mezopotamya medeniyetleri için temel vazife üstlenmiştir. Türkiye'deki Doğu Anadolu'nun Toros'larından çıkan Dicle Nehri, Cizre'ye güneydoğuda yol izleyerek varır, Suriye ve Türkiye bağlantısını Irak'a yetişmeden evvel 32 km olarak meydana getirir. Totalde 1900 km'lik nehir uzunluğuna sahip olup, bu uzunluğun Türkiye'deki kısmı 523 km'dir. Su depolama olarak ortalama 57.614 km^2'lik bölgeyi tahliye eder [28].

Ekim ile Ağustos ayları arası en az, Nisan ile Şubat ayları aralığında en fazla akış meydana gelir. Nehre ait yıllık yaklaşık 28.3 m^3/s'lik debi Diyarbakır (memba) ve 211.8 m^3/s'lik kısmı ise Cizre'deki(mansap) kısımlarında elde edilmiştir [29].

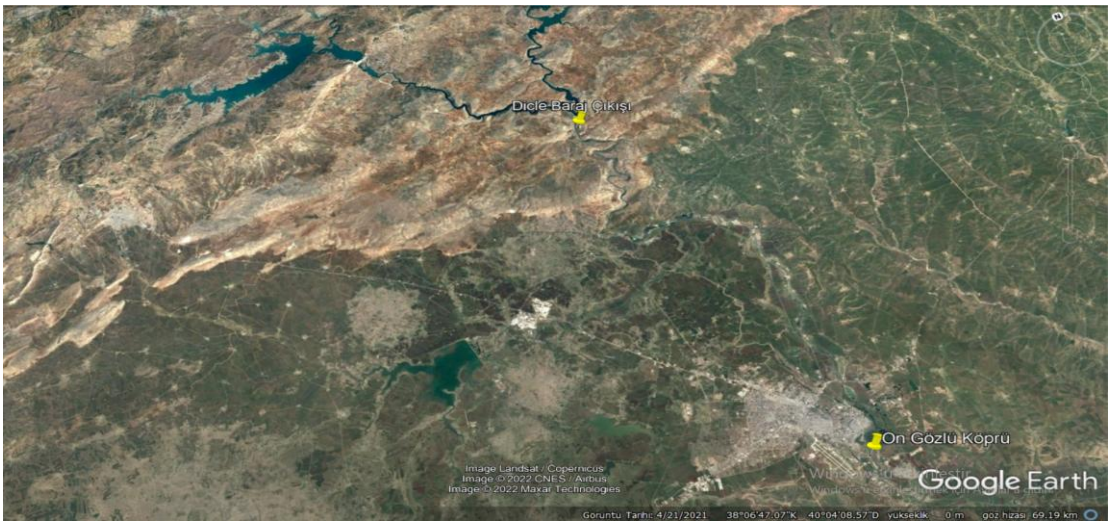
Dicle Nehri'ne endüstriyel oluşumların kirli suları direk veya lağım suyu aracılığıyla boşaltması, nehre paralel yerleşik düzenin pis su tahliyesi, nehre yakın konumda yer

alan petrol noktalarının sebep olduğu akıntılar Dicle Nehri üzerinde önemli etkiye sahiptir. Ek olarak, maden uygulamalarından dolayı Dicle ırmak yatağında farklılaşmalar olup, kimi noktalarda kirlilik etmenleri tarafından bozulmalar meydana gelmektedir [30].

Havza üzerinde Dicle barajı ve Ongözlü köprü istasyonları seçilerek, bu gözlem yerlerine ait ölçüm değerleri kullanılıp, YSA'da ÇO belirlenmesi için tahmin modelleri ortaya çıkarılmıştır. Dicle nehrinin, bünyesinde kirlilik barındıran kaynaklara sahip oluşu; tarım, hayvancılık, evsel atıklar ile sanayi atıklarından gibi farklı kirletici parametrelerin mevcudiyetinden dolayıdır. Aşağıdaki Tablo 3.1'de verilerin elde edildiği istasyonlara ait coğrafi ifadeler yer almaktadır. Bölge olarak kullanılan Dicle nehrindeki alt havzasında yer alan iki istasyonun lokasyonu Şekil 3.1'de yer almaktadır.

Tablo 3.1 İstasyonlara ait coğrafi bilgiler

İSTASYON NO	İSTASYON ADI	ENLEM KOORDİNATLARI	BOYLAM KOORDİNATLARI	İLİ
26 10 02 119	Dicle Barajı	602323,4390	4230973,1132	DİYARBAKIR
26 10 00 013	Ongözlü Köprü	608060,0000	4194190,0000	DİYARBAKIR



Şekil 3.1 İstasyon noktaları lokasyonu

3.2 Veri Temini

Dicle nehrinin havza olarak alt kısmında yer alan istasyonlara ait su kalite parametlerinin değerleri, DSİ 10. Bölge Müdürlüğü'nden temin edilmiştir. İstasyonlar; Dicle barajı ve Ongözlü Köprü isimli olup, bu istasyon verilerinden 15 su kalite parametresi seçilip modellemede kullanılmıştır. Girdi verisi olarak seçilen parametreler; T (°C), pH (-), EC (mikromhos/cm), TDS (mg/L), Cl (mg/lt), NO_2-N (mg/L), NO_3-N (mg/L), BOD_5 (mg/L), O-PO_4 (mg/L), Fe (mg/L), Mn (mg/L), Na (mg/L), Ca (mg/L) ve Mg (mg/L) olup, bu parametreler kullanılarak çözünmüş oksijen için tahmin modelleri elde edilmiştir. Bu 14 parametre, sudaki oksijen çözünürlüğünün üzerindeki önemli etkilerinden dolayı girdi olarak seçilmiştir. Her bir istasyon için kendi girdi ve çıktı verileri kullanılarak analizler yapılmıştır. Çalışma kapsamında, 2011 ile 2015 yılları arasındaki veriler kullanılmıştır.

3.3 Yapay Sinir Ağı Yöntemi

Sinir ağı başlangıçta insan beyninin ne şekilde işlediğini açıklayan bir kavram biçiminde, 1800'lerin sonlarında ifade edildi. Bilgisayarlarda biyolojik sinir ağını ve insana ait beyni yansıtmaya gayret eden yapılar Yapay sinir ağları (YSA)'dır. Öğrenim, öğrenilen bilginin depolanması ve genelleştirme gibi insana ait nitelikleri ağırlıklarla bağlantılı birçok nöronun meydana getirdiği bir yapıyı kullanarak taklit edebilirler [31].

3.3.1 Genel bakış

Yaygın anlamdaki YSA, beynin herhangi bir fonksiyonu gerçekleştirme biçimini modellemek amacıyla planlanan bir yapı biçiminde ifade edilebilir. YSA, çoğunlukla katmanlar biçiminde ayarlanır ve kendi aralarında farklı biçimlerde bağ oluşturan yapay sinir hücrelerinden meydana gelir. Bilginin öğrenme aşamasından sonra muhafaza edildiği ve genele yayma kabiliyeti olan paralel paylaştırılmış bir sistem olan YSA, beynin veriyi geliştirme biçimiyle bağdaşır [32].

Silikondaki belli zeka düzeylerini başarıyla ifade etmeye çalışan araştırmacılar, veriyi paralel biçimde işleyen birbiri ile bağlantılı haldeki yüz milyarlarca nöronun olduğu insan beyninin ileri fonksiyonelliğinden ilham almışlardır. İnsanın his ve farkındalık simülasyonu henüz bilim kurgu dünyasında olmasına karşın bu bölümde

biz, evrensel işlev yaklaşımlayıcıları biçiminde yapay sinir ağlarını ele alıyoruz. Yapay bir sinir ağı (veya basitçe sinir ağı); bir nöron giriş katmanı (veya düğüm, birim), bir veya iki (veya hatta üç) gizli nöron katmanı ve son bir çıktı nöron katmanından meydana gelir [33].

YSA'ların temel niteliği, biyolojik bir nöronun esaslarından oluşmaktadır. Biyolojik nöron mantıksal süreç birimi ilkesi ile çalışıp, beynin esas birimidir. Nöron türleri çoğunlukla şunlardır: 1) girdi ve çıktı bağlantılarını yaklaşık 100 mikronda olan ve yerel biçimde işlevselliği olan aracı nöron hücreler; 2) beynin ayrı alanlarını birbirine bağlayan, yani beyni kaslara veya başka organların beyin ile bağlantısını yapan çıkış hücreleri [34].

Yapay sinir ağları, Turing makineleri ile kökenini alan yapay zeka ile ilgili en çok incelemede bulunulan konudur. Aslında Yapay Sinir Ağları, bütünüyle insana ait beynin esas alınarak şekillendirilmiş olduğu bir teknolojidir [35].

Çoğunlukla bilinmeyen veya karmaşık davranış biçimleri veyahut arka plandaki fiziksel süreçleri olan karmaşık yapıları modelleyebildiğinden dolayı su kaynakları değişkenlerini modellemede veya öngörüde bulunmada gün geçtikçe YSA modellerinden, daha sık faydalanılmaktadır. Lineer olmayan yapıdaki modelleme aygıtı olan YSA, birçok giriş verisini (bağımsız değişkenler) ele alarak bir veyahut daha çok miktarda çıktı verisini (bağımlı değişkenler) saptayabilmektedir [36].

3.3.2 YSA temel bileşenleri

Bu bölümde Yapay Sinir Ağı işleyişine ait temel teorik bilgiler verilecektir.
Hiyeraşik biçimde bağlanan ve paralel biçimde faaliyet gösterebilen yapay hücreler, YSA'ları meydana getirir. Biyolojik sinir sistemine ait nöronlar ile yapay hücrelerin aynı olduğu varsayımı yapılır, ek olarak proses elementleri olarak anılabilirler. Her bir proses elementi; nöronun girdileri, toplama işlevi, ağırlıkları, aktivasyon/transfer fonksiyonu ve çıkışı olacak şekilde beş ana öğeden meydana gelmektedir [37].

Esas olarak bir YSA modelinin yapısı çoğunlukla üç ayrı katmandan meydana gelir; modele girdilerin sunulduğu, girdiye ait ağırlıklı toplamın gerçekleştirildiği girdi

katmanı, girdinin işlendiği gizli katman veya katmanlar ve YSA'ya ait sonuçların oluşturulduğu çıktı katmanı. Nöron ya da düğüm olarak adlandırılan temel öğeler her katmanı meydana getirir. Nöron yapısını, Sınır koşullarıyla parametreleştirilmiş doğrusal olmayan bir cebirsel fonksiyon oluşturur [38].

Girdiler:
Dış dünya tarafından bir yapay sinir hücresine (proses elemanına) aktarılan verilerdir. Ağın belirlemesi beklenen örnekler vasıtasıyla girdiler saptanır. Yapay sinir hücresine dış dünyadakine benzer şekilde diğer hücrelerden ya da kendisinden de veriler ulaşabilir.

Ağırlıklar:
Yapay hücreye ulaşan verinin ehemmiyeti ve hücreye tesirini ağırlıklar ifade eder. Ağırlıkların küçük veya büyüklüğü, önemli ya da önemsiz oluşu hakkında bilgi vermez.

Toplama Fonksiyonu:
Bir hücreye ulaşan net girdi bilgisini belirleyen fonksiyondur. Bu amaçla farklı fonksiyonlar çalıştırılmaktadır. Ağırlıklı toplamı saptamak, kullanım olarak en geniş alana yayılmış halidir. Bütün ulaşan girdi değeri burada ağırlığıyla çarpılarak birbirine eklenir. Sonuç olarak ağa ulaşan net girdi elde edilir. Formül olarak şöyle ifade edilir.

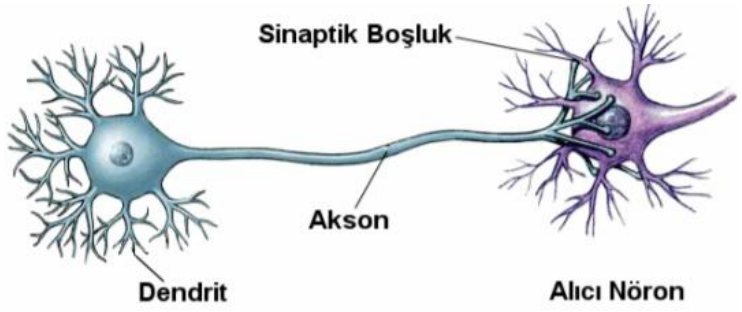
$$NET = \sum_{i}^{n} G_i A_i \tag{3.1}$$

Bu formülizasyonda; girdiler "*G*", ağırlıklar "*A*", hücreye ulaşan toplam girdi (proses elemanı) adedi ise n ile ifade edilmektedir. Ancak, sürekli bu şekildeki formülizasyonlardan faydalanmak YSA'larda zorunlu değildir. Toplama fonksiyonu olarak, farklı yapıdaki formüllerin işleme tabi tutulduğu gerçekleştirilen literatür incelemelerinden anlaşılmaktadır [39]. Aşağıdaki Tablo 3.2'de farklı toplama fonksiyonları örnekleri yer almaktadır.

Tablo 3.2 Toplama fonksiyonunun çeşitleri [39]

Net Giriş	Açıklama
Çarpım Net Girdi=$\prod_i G_i A_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbiri ile çarpılarak net girdi hesaplanır.
Maksimum Net Girdi= Max ($G_i A_i$) , i=1….N	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en büyüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
Minimum Net Girdi=Min ($G_i A_i$) , i=1….N	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en küçüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
Çoğunluk Net Girdi= $\sum_i \text{sgn}(G_i A_i)$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
Kumülatif toplam Net Girdi=Net(eski)+$\sum_i (G_i A_i)$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha sonra gelen bilgilere eklenerek hücrenin net girdisi bulunur.

Aşağıdaki Şekil 3.2'de nöronun sahip olduğu yapının biyolojik olarak ifadesi gösterilmektedir.



Şekil 3.2 Sinir ağı yapısında bulunan nöron ait şema [40]

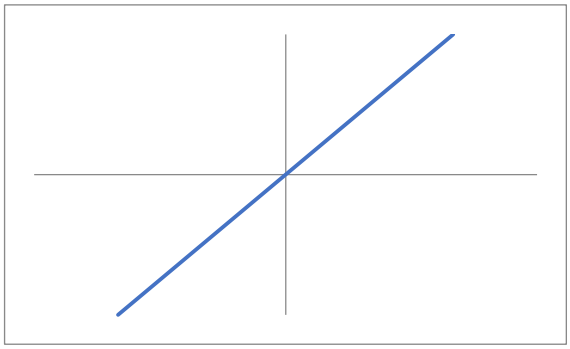
Aktivasyon fonksiyonu:
Hücreye ulaşan net girdi üzerinde çalışarak, girdiye karşılık oluşturulan çıktı verisini bu fonksiyon oluşturur. Çıktı verisini elde etmek amacıyla aktivasyon fonksiyonu için de toplama fonksiyonundakine benzer şekilde farklı formülizasyonlardan faydalanılır [39].

Dizaynırın girişimleri ile en makul aktivasyon fonksiyonu elde edilir. Elde edilen girdi katmanındaki veriler bağlantılardaki ağırlıklar aracılığıyla işlem elemanına ulaşır. Ağırlıklar, ara katmana ait işlemde etkisi bulunan girdinin matematiksel olarak katsayısını ifade eder. En sık faydalanılan aktivasyon fonksiyonu, sigmoid ve tanjant hiperbolik biçimindeki aktivasyon fonksiyonlarıdır. Farklı aktivasyon fonksiyonlarının YSA yapılarında uygulaması mevcuttur [41]:

- Doğrusal Aktivasyon Fonksiyonu
- Sigmoid Aktivasyon Fonksiyonu
- Tanjant Hiperbolik Aktivasyon Fonksiyonu

Bir aktivasyon fonksiyonu, transfer fonksiyonu biçiminde de isimlendirilip farklı türlerde ve çoğunlukla lineer olmayan yapıdaki fonksiyondur. Doğrusal fonksiyonlarda girdi ve çıktı arasında doğru orantılı ilişkinin varlığından dolayı doğrusal fonksiyonlar tercih edilmemektedir. Başlangıçtaki YSA girişimlerinin muvaffakiyetsiz bir şekilde neticelenmesinin esas sebebi işte bu hususdur [42].

Doğrusal aktivasyon fonksiyonu:
Çok katmanlı yapay sinir ağlarına ait çıkış katmanlarında veya doğrusal yapay sinir ağlarında fonksiyon olarak doğrusal aktivasyondan faydalanılmaktadır. Sınırlı bir açıklıkta kısıtlandığı durumda doğrusal fonksiyon, rampa fonksiyonu halini alır. $y = ax$ olarak aktivasyon fonksiyonu ifade edilebilir. a sabit sayı olarak fonksiyonda yer alır [41]. Fonksiyon olarak doğrusal aktivasyonun grafiği aşağıdaki Şekil 3.3'te belirtilmiştir.



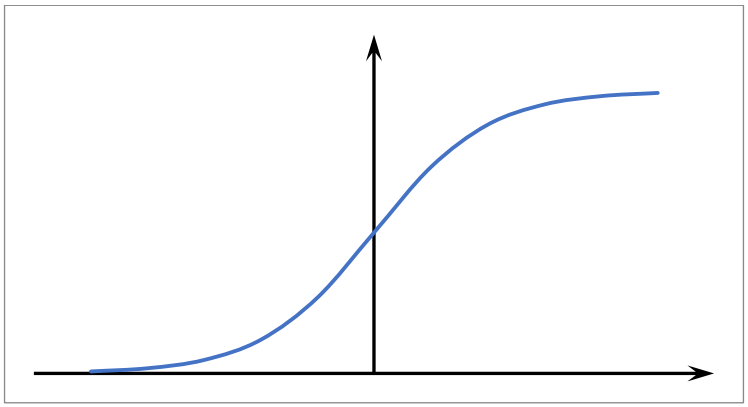
Şekil 3.3 Doğrusal aktivasyon fonksiyonu

Sigmoid aktivasyon fonksiyonu:

Aktivasyon fonksiyonu olarak çoğunlukla s-şekilli Sigmoid fonksiyonundan faydalanılmaktadır, form olarak aşağıdaki denklemler ifade edilir.

$$F(NET) = \frac{1}{1 + e^{-x}} \tag{3.2}$$

Burada "x" o düğüme ait bütün ağırlıklı girdilerin toplamına karşılık gelmektedir. Asimptotlar 0 ve 1 veya -1 ve 1 olacak biçimde fonksiyon ölçeklenir. Çıktı katmanı dahil olmak üzere her bir ardışık katman için bu işlem yinelenir [43]. Grafik biçimi olarak aktivasyon fonksiyonu aşağıdaki Şekil 3.4'te gösterilmiştir.



Şekil 3.4 Sigmoid aktivasyon fonksiyonu

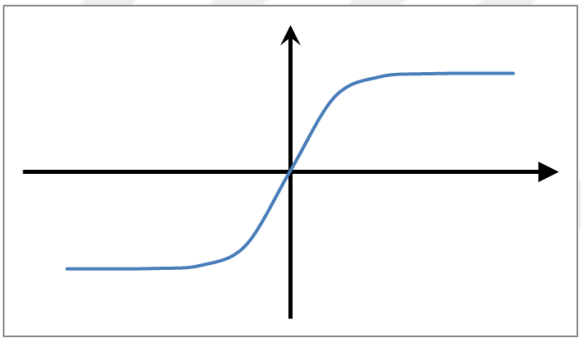
Tanjant hiperbolik aktivasyon fonksiyonu:

Sigmoid fonksiyonu gibi YSA'larda sıklıkla faydalanılan bir başka fonksiyondur. Ek olarak, negatif parametrelere sahip zaman serilerini işleyebilmesi, bu fonksiyonun sigmoid yapılı fonksiyona kıyasla sahip olduğu üstünlüktür. Özet olarak, 0 ve 1

aralığında sigmoid fonksiyonunda çıktı sonucu alınmasına karşın, hiperbolik tanjant çıktı sonucu -1 ve 1 aralığında elde edilir [44]. Bu aktivasyon fonksiyonuna ait formülün ifade biçimi şöyledir:

$$f(x) = \frac{e^{x} - e^{-x}}{e^{x} + e^{-x}} \tag{3.3}$$

Tanjant hiperbolik aktivasyon fonksiyonun grafiği Şekil 3.5'te gösterilmektedir. Başka tür aktivasyon fonksiyonları; parçalı doğrusal, basamak ve kutuplamalı basamak fonksiyonudur. Başka tip aktivasyon fonksiyonu örnekleri Tablo 3.3'te gösterilmiştir.



Şekil 3.5 Hiperbolik tanjant aktivasyon fonksiyonu

Tablo 3.3 Farklı türde aktivasyon fonksiyonları [39]

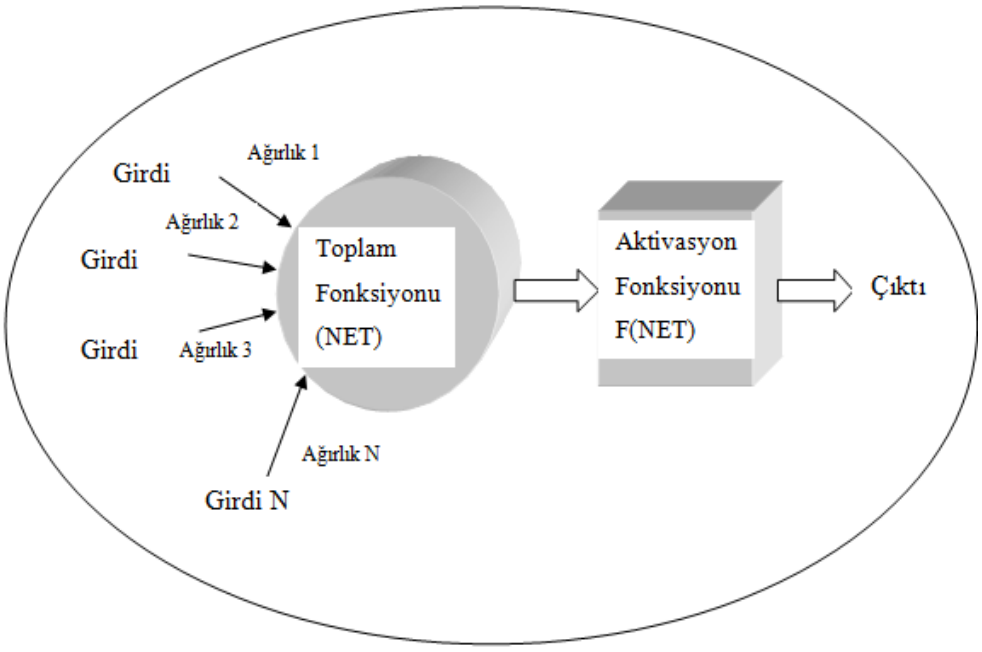
Aktivasyon fonksiyonu	Açıklama
Lineer fonksiyon F(NET)=NET	Gelen girdiler olduğu gibi hücrenin çıktısı olarak kabul edilir.
Step fonksiyonu F(NET) = {1, if NET > eşik_değer {0, if NET <= eşik_değer	Gelen NET girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır.
Sinüs fonksiyonu F(NET)=Sin(NET)	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.

Tablo 3.3 (Devam)

Eşik Değer fonksiyonu F(NET)= {0 if NET<=0 {NET if 0<NET<1 {1 if NET>=1	Gelen bilgilerini 0 veya 1'den büyük veya küçük olmasına göre bir değerler alır. 0 ve 1 arasında değerler alabilir. Bunların dışında değerler alamaz.
Hiperbolik tanjant fonksiyonu $F(NET)=(e^{NET}+e^{-NET})/(e^{NET}-e^{-NET})$	Gelen NET girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.

Hücrenin Çıktısı:

Aktivasyon fonksiyonu aracılığıyla elde edilen çıktı sonucudur. Öteki hücreye ya da dış dünyaya elde edilen çıktı iletilir. Hücre bizzat çıktı verisini girdi biçiminde de tarafına iletebilir. Birçok çıktı sonucuna sahip olan proses elemanının buna karşın ancak tek çıktısı bulunmaktadır. Proses elemanı ağ biçiminde sunulduğunda birçok çıktı sonucuna sahip olduğu anlaşılmaktadır. Yalnızca sunum maksadı bu durumu oluşturur. Proses elemanından üretilen esasen sadece bir çıktı sonucu mevcuttur. Birçok proses elemanı eş sonucu girdi verisi biçiminde almaktadır [39]. Aşağıdaki Şekil 3.6'da yer alan görsel, çıktı verisinin sinir hücresi tarafından oluşumunu şematik olarak göstermektedir.



Şekil 3.6 Temel olarak yapay sinir hücresinin mimarisi [39]

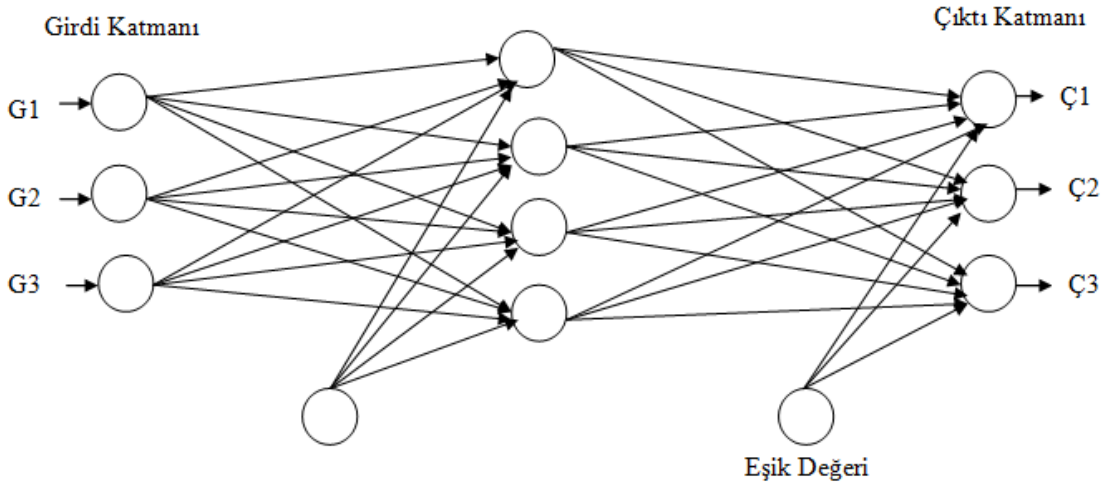
Yapay Sinir Ağının Yapısı:

Yalnızca girdi ile çıktı katmanlarına sahip yapay sinir ağı, tek katmanlı ağ olarak adlandırılmaktadır [45]. Birden çok gizli katman ile girdi ve çıktı katmanına sahip ağlar çok katmanlı ağlardır [46].

Genellikle çalışmalarda asgari üç katmanlı(girdi katmanı, gizli katman ve çıktı katmanı) ağ yapısına ihtiyaç duyulmaktayken, bir eleman veya bir tabakaya sahip kimi elverişli ağ yapıları düzenlenebilmektedir [47].

Kompleks sorunları analiz etmede, yalnızca girdi ile çıktı katmanına sahip ağlar eksik kalmaktadırlar. Minimum bir gizli tabakanın yapay sinir ağında mevcudiyeti belirtilen karmaşık sorunların olduğu durumlarda zorlukları ortadan kaldırmaktadır [48].

Üç katmana ait proses elemanları ile katmanların bağlantısı Şekil 3.7'de gösterilmiştir. Şekilde proses elemanları yuvarlak biçimde ifade edilmiştir. Paralel biçimde olan elemanlar bütün katmanlarda mevcuttur. Bağlantılar proses elemanları arasındaki çizgiler ile ifade edilmiştir. Yapay sinir ağı proses elemanları ile bağlantılardan meydana gelmektedir. Öğrenme aşamasında bağlantılara ait ağırlık değerleri saptanmaktadır [39].



Şekil 3.7 Algılayıcı olarak çok katmanlı biçimindeki ağ oluşumu [49]

YSA, çoğunlukla katmanlar halinde planlanıp, farklı biçimlerde yapay sinir hücrelerinin bir araya gelmesi ile meydana gelir [50].

Hücreler genellikle 3 katman biçiminde olup, paralel biçimde katmanlarda buluşup ağı meydana getirirler. Katmanlar [39]:

- Girdi katmanı:

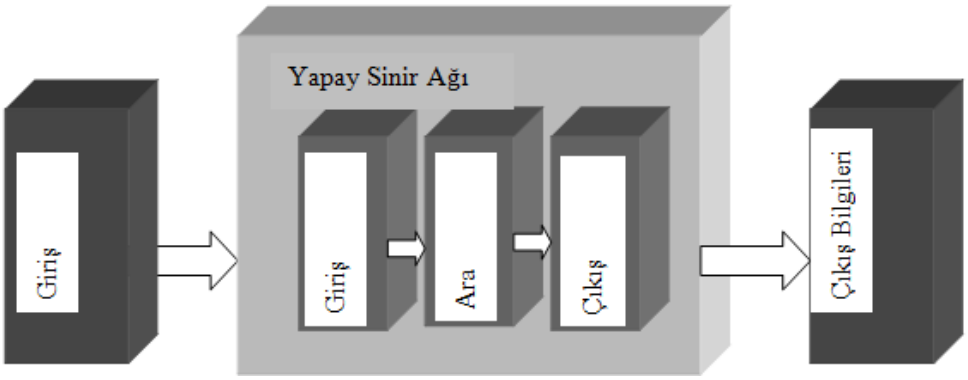
Dışarıdan verileri elde edip ara katmanlara iletmek buradaki proses elemanlarının görevidir.

- Ara katmanlar

Çıktı katmanına, girdi katmanından elde edilen verileri kullanarak ulaştırırlar. Verilerin kullanılma işlemi ara katmanlarda yapılmaktadır. Ağın birçok sayıda ara katmana sahip olması mümkündür.

- Çıktı katmanı

Ara katmandan elde edinilen verilerin kullanılıp ağa ait girdi katmanından gönderilen girdi setine oluşturulması ihtiyaç duyulan çıktı verisi, buradaki proses elemanları tarafından oluşturulur. Dışarıya elde edilen çıktı verisi iletilir [39].
Söz konusu 3 katman arasındaki bağlantı Şekil 3.8'de gösterilmektedir.



Şekil 3.8 Katmanların Yapay Sinir Ağı içindeki bağlantıları [39]

Esasen iki evre ağların çalışma ilkesini belirlemektedir, bunlar eğitim ile test safhalarıdır. Model eğitimi safhasında belirlenen öğrenme işlemcisine bağlı olarak ağırlıklar elde edilip, bunlara bağlı olarak çıktı verisine ulaşılır [46].

YSA model eğitiminde optimum neticeye varana kadar, birden fazla uygulama uygulanabilmektedir. Ara katmana ait eleman adedini düşürüp yükseltmek, momentum ve öğrenmeye dair katsayı çeşitlendirilmesi yapmak, ara katman ve iterasyon adedinde yükseltme örnek olarak, verilebilir. [51].

3.3.3 YSA türleri

Bir yapay sinir ağı, iki ya da daha çok yapay nöron bir araya geldiğinde oluşur. Yapay sinir ağlarının sahip olduğu esas yaşam sorunlarını halletmede, tekli yapay nöron kullanışlı değildir. Esasen, bilginin ana yapı taşlarında (yapay nöronlar) doğrusal olmayan, paralel, yayılmış ve yerel biçimde ele alınan, karmaşık haldeki gerçek yaşam sorunlarını halletme kabiliyeti yapay sinir ağlarında mevcuttur [52].
Hücrelerin farklı biçimlerde bir araya gelmesiyle, yapay sinir ağları meydana gelir [53].

Ağdaki akışın ve nöronların bağlantı yönü açısından YSA'lar yapıları cinsinden sınıflandırılır [41].

- Yapılarına göre YSA

İleri beslemeli (feedforward) ile geri beslemeli (feedback ya da recurrent) olacak biçimde, sinir ağına ait işaret akıntı yönüne göre iki tür ağ mevcuttur [54].

- İleri Beslemeli Sinir Ağı

İleri yönlü bilgi akımının mevcudiyetinden dolayı ağ, ileri beslemeli biçiminde ifade edilir. YSA'nın en temel ve ilk model biçimi İleri Beslemeli Sinir Ağı(İBSA)'dır. İBSA'nda girdi katmanından rastgele gizli bir katmana geçiş yapan bilgi, çevrimsiz/döngüsüz bir şekilde çıktı katmanına doğru ilerler [55].

Derin ileri beslemeli sinir ağları, ileri beslemeli ağlarının değerli bir türüdür. Derin ileri Besleme'ler, birçok gizli katmanı genellikle 7-10 taneyi birleştirerek sinir ağını meydana getirirler. Aktivasyon birimi için radyal esaslı birimler kullanan radyal tabanlı ağ, ileri besleme'nin ikinci değerli türüdür [56]. Kategorize etme, işlev yaklaşımı, gözetim ile zaman serisi öngörüsü gibi çok sayıda kazanımlar, genel ileri beslemeli ağlardaki gibi radyal temelli işlevli ağlarında da mevcuttur [57].

Sürekli ileri doğru işaret iletiminin gerçekleştiği anlaşılmaktadır. Eğitim sırasında, geriye döngülerde bağlantılara ait ağırlıklar değişmezlerken, ileri beslemeli yapıdaki bağlantılara ait ağırlıklar başkalaştırılabilir [54].

Gizli katmanlar yoluyla aktivasyon düzeyi hesaplamaları çıktı katmanına doğru geçiş yaptıkça, ileri yayılma safhası sürer. Bütün nöronların kendisine ait girdi değerlerini toparlaması ile transfer işlevine çıktı değerini elde etmek amacıyla başvurur. Ardından, son cevabı diğer bir deyişle hesaplanan hedef değeri, ağa ait çıktı katmanı oluşturur [58].

- Geri beslemeli yapay sinir ağları

Minimum bir hücre, izleyen katmanlarda bulunan hücreler tarafından da geri beslemeli sinir ağı yapısında desteklenir. Ağ, yalnızca ileri yönde olmayan geri yönde de bilgi akışı olanağı tanıyan mimaridedir [59].

İleri yöne ilaveten geri yönde de mesajların varlığı geri besleme yapılı ağlarda söz konusu olup, bağlantı noktalarına ait çıktı verileri kendisine ait ya da geçmiş katmanları geri besleyebilme kabiliyetine sahiptirler. Dolayısıyla, o esnaya ait girdi verilerine ilaveten gerideki girdi verileri de çıktı veri işareti tarafından dinamik biçimde aksettirilebilir [60].

Dinamik mimarili bir ağ varlığı geri besleme yapılı ağlarda mümkündür. Bölge bazlı olarak yayılmış hafızanın varlığı, bu tipteki ağlara ait önemli bir niteliktir. Yani, o zamana ek olarak geçmiş zamanlardaki girdi verilerine dair bilgiyi, ağa ait belli bir zamandaki çıktı verisi içermektedir. Karşılaştırma yapıldığında bu ağlara ait gönderme hızı, ileri besleme yapılı ağlardan azdır. Bu durum, geri beslemenin ağ bütününe döngülerden dolayı belli bir rötar yaptırmasından kaynaklanmaktadır [61]. Mimarisi, bilhassa eski zamanlarda öngörü kullanımları açısından elverişlidir. Geri besleme yapılı ağlara misal olarak Jordan, Hopfield ve Elman verilebilir [62].

- Öğrenme Algoritmaları Yönünden YSA'lar

Farklı işlemler temel alınarak bilgi edinimini mümkün kılan yapay sinir ağı algoritmaları aracılığıyla uygulamalar yapılabilir. Ele alınan işlemler çoğunlukla üç bilgi edinme işlemi ile bu işlemlerin kombine edilmiş halleridir [63].

İstenilen çıktı verisinin tanınma veya tanınmamasına bağlı olarak, YSA'da öğrenme ya da adaptasyon sağlayan algoritmalar üç çeşitte kategorize edilirler [64]:

- Gözetimli (supervised) öğrenme
- Gözetimsiz (unsupervised) öğrenme
- Takviyeli (reinforced) öğrenme [64].

Danışmanlı (gözetimli) türdeki kavrama yapısına ait bütün eğitim sürecinde, gerçek veri ile çıkış verisi aralarındaki uyuşmazlık azaltılmaya gayret edilerek, birleşme noktaları aralarındaki ayrım yenilenip uyuşmazlık miktarının azaltılması yönünde çabalanır. Bilhassa ileri beslemeli yapıdaki ağlarda daha çok kullanılan Danışmanlı kavrama biçimi, YSA'da yoğunlukla faydalanılan işlemlerdendir [65].

Danışmansız yapılı kavramada, öğrenme aşamasında sadece örnek giriş verileri YSA'ya gönderilmektedir. Uygun çıktıya dair malumatı olmayan yapı, kendiliğinden girdi bilgilerini temel alarak örnekler. Dolayısıyla bütün örnekleri sistem, giriş kısmında temin edilen girdileri kullanarak kendi içerisinde kategorize etmekte olup, öz talimatlarını oluşturmaktadır [66].

Büsbütün sezgi yoluyla algılanabildiğinden dolayı denetimli ile denetimsiz kavrama konseptlerinin ne şekilde işleneceğini anlamak diğerlerine nazaran rahattır. Ancak takviye öğrenme (RL)'de bir miktar daha tanımlaya ihtiyaç duyulur. Bir faktör kendi ortamına ne şekilde karşılık vereceğini herhangi bir RL vazifesinde kavrayıp, sonuç olarak zaman içerisinde işleme gücüne ait kimi sonuçları en üst düzeye çıkarılır [67].

- Öğrenme Zamanı Yönünden YSA'lar

Öğrenme zamanı açısından YSA'da Statik ve Dinamik olmak üzere iki farklı tür mevcuttur.

- Statik Öğrenme

Eğitilme, öğrenme talimatı statik olan YSA'larda uygulanmadan önce gelmektedir. Eğitimin nihayetlendirilmesinin ardından ağdan arzu edilen biçimde faydalanılabilir. Lakin ağa ait ağırlıklarda uygulama aşamasında hiçbir farklılık gerçekleşmez [68].
ÇKA (çok katmanlı algılatıcı)'dan yararlanılan statik ağlar çoğunlukla belleği olmayan düğüm eşitliği aracılığıyla nitelendirilir [69].

- Dinamik Öğrenme

Öte yandan dinamik yapılı ağlar hafızalı sisteme sahiptirler. Sıklıkla türevsel ya da kalanlar denklemi ile düğüm eşitliği anlatılmaktadır. Durum geri beslemesi yapılı ağlar, ileri beslemeli dinamik yapılı ağlar ve çıktı geri beslemeli mimarili ağlar olmak üzere üç değişik kategoride sınıflandırılabilirler. Örneklemeyi arzu ettiğimiz gerçek yeryüzündeki yapıların birçoğu doğrusal olmayan biçimindeki dinamik mimariye sahip olduklarından, bu ağlar önemlidir [69].

3.3.4 YSA modellemesinde öğrenme

Öğrenme kuralını, ağırlıkları giriş verilerini temel alarak başkalaştıran matematik eşitliği oluşturur. Ek olarak, öğrenme prensibi girdi verisi ağa eklendiği sürece, ekstra tutarlı çıkış verilerinin sinir ağlarında elde edilmesine olanak tanımaktadır [70].

Kavrama kuralı; aktivasyon işlevi ve girdi işaretleri aracılığıyla sunulan verilere karşılık olarak, yerel hafızadaki tüm ağırlıkların ya da bazılarının başkalaştırılmasını sağlayan eşitlik biçiminde tanımlanır. Öğrenme prensibi, proses unsurunun girdiye ait izlerin tabiatına dayanarak giderek farklılaşmasına olanak tanır. Böylece, ağ başlı başına veriyi ayarlayıp diğer bir ifadeyle öğrenebilir, talep edilen sonuçlara bizzat adapte edebilir [71].

YSA'da istenilen sonuç ile çıkış verisi arasındaki ayrımın, test etme ve yanılma yöntemi ile düşürülmesi kavramanın temelini oluşturmaktadır. Çok sayıda farklı optimizasyon metodunun varlığına karşın, YSA'ya ait eğitimde en elverişli çıktıya teminat verebilecek genelleyici yapılı bir algoritma mevcut değildir [72]. Kimi öne çıkan öğrenme kuralları şunlardır: Rastlantısal (Hebb) Öğrenme, Delta Öğrenme Kuralı, Hopfield Öğrenme, Kompetif (Kohonen) Öğrenme' dir.

Rastlantısal (Hebb) Öğrenme:

Hebb kuralı, sinir ağını çağrışımsal bir aygıta çevirmede en rahat ve daha geniş ölçüde ele alınan bir ağırlık tercihi şeklinde tanımlanır [73]. Hebb kuralına ait daha rahat formüle ediş biçimlerinden biri şöyle ifade edilmektedir.

$$\tau_w \frac{dw_i}{dt} = f(w_i) r^{out} r_i{}^{in} \tag{3.4}$$

Burada zaman sabiti "τ_w" ve "t" zamanı farklılaştıkça, i'ninci girdiye ait ağırlık w_i değişir. Bu sabit, değişim yüzdesine ek olarak önceden ayarlı dayanım etmenini kapsamaktadır [74].

Bu tip öğrenme biçiminde, başlangıçta sıfıra yakınlaşan miktarlar ile harekete geçilmelidir. Çıktı ile girdi değerlerinin çarpma işlemi sonucu negatif olduğu durumda ağırlık olarak w_{ij} kadar azalış, pozitif olduğunda bir artış meydana gelir [75].

Delta Öğrenme Kuralı:

Elde edilmesi amaçlanan veri ve YSA sonucu oluşan çıktı verisine ait karesel formdaki ortalama hata minimum olacak biçimde ağırlıklar başkalaştırılır [40].

Farklı algılayıcı türdeki eğitim metoduyla bu kural aynı doğrultudadır. Devamlı türdeki algılayıcı biçiminde de tanımlanabilir. Çok katmanlı ağlarda delta prensibinin genelleştirilmesi mümkündür [76]. Sıklıkla, model ikilisini meydana getiren hedef çıkış modeli ile giriş modeli arasındaki bağlantıya göre delta kuralı işlenir, öyle ki girdi katmanına bir girdi örneği takdim edildiğinde, birimlere ait çıkış katmanında uygun çıkış örneği belirecektir [77].

Hopfield Öğrenme:

John Hopfield' ın ileri sürdüğü tekrarlı YSA'nın bir versiyonu biçiminde, Hopfield sinir ağı ele alınabilir. Daha evvel Wilhelm Lenz' ın harekete geçmesiyle, bu engin yapı ifade edilmiştir. Hopfield ağlara, çift başlangıç düğümlü ilişkisel bellek yapısı biçiminde davranılabilir [78].

YSA'ya ait modellerde, ilişkisel belleği ele almada en gözde modellerden biri Hopfield türdeki ağlardır [79]. Hopfield'ın esas görüşüne göre, bilgiyi muhafaza etmede kullanılan ayrıcalıklı rejimler, çekim noktası olarak sabitlenmiştir, lakin yapılan testler (örneğin, Korn Faure, 2003) bilgiyi tutmada döngülerden faydalanıldığını ve döngüsel biçimdeki "hafıza torbalarının" meydana getirdiği sisteme ait geri plan şeklinde, düzensiz dinamiklerin belirdiğini ortaya koymaktadır [79, 80].

Kompetif (Kohonen) Öğrenme:

Değişik bir kavrama formuna sahip olan başka bir ağ mimarisi, Tewo Kohmen tarafından düşünülmüştür. Bu ağlara ait öğrenme biçimi gözetimsiz olup öyle ki kimi açılardan daha çok insanın kavrama tarzına yakındır. Giriş verisi ile en fazla benzerlik gösteren düğüm, kavrama aşamasında saptanır. Daha sonra ağırlıkların farklılaştırılması, giriş verileri ile ağırlıkların ayrıklığının azaltılması esas alınarak yapılır [81].

Kohonen kuralı, bir nörona ait ağırlıkların girdi vektörünü kavramasına olanak tanıdığından dolayı, tanımlama aplikasyonlarında kullanışlıdır. Sonuç itibariyle, girdi vektörü ile en çok paralelliği olan ağırlık vektörüne sahip olan nöron, daha fazla yakınlığı mümkün kılacak biçimde yenilenir. Kazanan nörona ait kazanma yüzdesi; çok daha değişik giriş vektörü ile karşılaştığında düşerek, yarışı başka bir durumda benzeşen bir vektör takdim edildiğinde yükselerek değişmektedir [82].

Almaç (Perceptron):

Algılayıcı, sadece bilgi toplama amacıyla faydalanılan ve ilk nöron katmanı (girdi katman) ile değişmeyen ağırlıklı ilişkileri mevcut olan retinaya sahip ileri beslemeli yapıdaki bir ağ biçimidir. Sabit ağırlığa ait katmanı, minimum bir eğitilebilir ağırlık takip eder. İzleyen katmanlar ile nöron katmanı bütünüyle ilişkilidir [83].

Çok katmanlı almaç (Multi-Layer Perceptron):

Çok katmanlı algılayıcı (ÇKA), YSA'ya ait bir türdür. YSA'nın en sade biçimi, algılayıcı olarak adlandırılır. Algılayıcıyı, bir çıktı ile iki girdinin oluşturduğu nöron

meydana getirir. ÇKA'larda, döngüsüz biçimde giriş ile çıkış arası sinyaller iletilmektedir. Bu şekilde nöron çıktıdan bağımsız hale gelmektedir [84].

Çok Katmanlı Algılayıcı (ÇKA), giriş verileri ile bunlara yanıt olarak oluşması hedeflenen çıkış verilerinin ifade edildiği bir yapıdan oluşur. Meydana getirilen ağ yardımıyla, temin edilen giriş verisine bağlı olarak çıktı verisi üretilir. Girdi katmanı, takdim edilen verilerin ara katmana gönderildiği yerdir. Tek bir tane ya da daha fazla ara katman adedi mümkündür. Girdi katmanından aktarılan veriler, bu katmanda geliştirilir. Çıkış verisinin oluşumu, ara katmandan ulaşan değerlerin çıktı katmanında tüm girdiler için ayrı olacak şekilde üretilmesiyle gerçekleşir. Bütün katmanlar, proses elemanları arasındaki ilişkiye sahiptir [85].

Geriye yayılım (Back-Propagation) algoritması:
En iyi olan sonuca erişebilmek adına, geri yayılım algoritması katmanların birbirleri ile olan ilişkilerini kuvvetlendirecek biçimde planlanmıştır. Katmanlara ait farklı elemanların yüksek benzer ilişkilerinin bir kombinasyonu, sinaptik ağırlığa ait boyuta denk olmaktadır (gizli katmana ait sinaps katmanları ile giriş değişkenleri gibi). İki fazlı iletme-uyarlama döngüsünden faydalanarak öngörülen çıkış verileri, hataya(sapma) değer biçmek amacıyla arzu edilen çıktılarla mukayese edilir. Bu sapmaların çıkış katmanından gizli katmana ait sinaps katmanlarına geri iletimi, bu katmanlar tarafından öngörülen çıkış verisine uygulanan yardımlar temel alınarak yapılır. Ağa ait her bir nöron toplam yanılgılara izafi desteğini ifade eden bir hat değerine ulaşıncaya kadar, bu işlem tekrarlanır [86].

Geri yayılım (BP); ağa ait yapısal karakteristikleri kıyaslayan, lineer olmayan fonksiyonları ele alış biçimindeki hızlı çözümleme, kuvvetli işleyiş ve kolay bir ağ bünyesi ile donatılmış bir çeşittir. İlaveten, daha fazla uygulanabilirliğinin nedeni gerçekteki gibi ufak bir sorunun olmayışıdır [87].

BPN (Geri yayılımlı sinir ağı) tüm YSA tipleri içerisinde hatayı ters yayılma esasıyla ele alan oldukça gelişmiş, yaygın kullanımlı çok katmanlı ileri beslemeli türdeki sinir ağlarından biridir. İstatistik biliminin gösterdiğine göre, sinir ağı yapıları içerisinde

BPN'ler sinir ağlarının esas olarak farklı biçimlerini % 80'ne değin kullanılmaktadır [88].

Levenberg-Marquart algoritması:
Lineer olmayan en küçük kareler sorunlarını halletmek amacıyla, 1960'ların başında Levenberg-Marquardt algoritması çıkarılmıştır. En küçük kareler yöntemlerinin meydana çıkışı; bir grup veri noktası ile örnek fonksiyonunun sapmalarının kareleri toplamı biçiminde belirtilerek yanılgıyı en aza indirgemeyi amaçlayan parametrelerle ifade edilmiş matematiksel bir model yapısıyla gerçekleştirilmiştir. Model parametrelerinin lineer olduğu durumda, parametreler de en küçük kareler amacıyla karesel olur [89].

Faydalanmada en çok yaygın olan algoritma, Levenberg-Marquardt (LM) algoritmasıdır. Basit gradyan iniş ile diğer birleşik gradyan metotlarına kıyasla geniş problem yelpazesinde daha üstündür [90]. Lineer olmayan en küçük kareler türündeki algoritmalar ile yetiştirilmesinin nedeni, sinir ağının aslında en küçük kareler biçimindeki bir sorun oluşundandır. Bunlar içinde, aşırı küresel emniyet çevresi olan bir güvenlik çevresi temelli metot Levenberg-Marquardt'dır. Bu metod uygulamada fazlasıyla başarılı olup, orta boyuta sahip yapay sinir ağlarını yapılandırmada en çok kazançlı algoritma biçiminde ele alınır [91].

3.3.5 YSA avantajları ve dezavantajları

YSA da diğer tüm yöntem, benzetim, model ya da yazılımlara benzer şekilde bazı avantaj ile dezavantajlara sahiptir. Fakat kazanım ile kayıplardan çıkarım yapıldığında var olan metotlardan farklı olarak daha fazla kazançlı, süratli ve tutarlı çıktılar ürettiği görülmektedir [92].

- Avantajlar

Bir veyahut daha çok hücrenin dağılması, YSA'ların ait veriyi meydana getirişine engel olmaz. Ağlar, bu nitelik sayesinde hata toleransı edinirler [92].

Hücre YSA'nın sahip olduğu esas proses elemanı olup, lineer değildir. Sonuç olarak, hücrelerin bir araya gelmesiyle oluşan YSA'nın kendisi de lineer olmayıp, bu niteliği

tüm ağda mevcut biçimdedir. Lineer olmayan kompleks sorunların halledilmesinde, bu vasfıyla YSA en değerli aygıttır. Ele aldığı sorundaki farklılıklara bağlı olarak, YSA ağırlıklarını düzenler. Dolayısıyla, YSA belli bir soruna çare bulmak gayesiyle yetiştirilip, sorundaki farklılaşmalara dayanarak yeniden eğitilebilip, asıl süreçte de farklılaşmalar sürekli olduğunda eğitim sürdürülebilir. Bu yeteneğinden dolayı YSA'dan sinyal işleme, yapı teşhisi, kontrol ve uyarlamalı model tanıma tarzındaki alanlarda aktif bir biçime faydalanılır [35].

Kendiliğinden kavrayabilme ile düzenleme kabiliyetlerine sahiptir [93]. Ağın eğitme faaliyeti tamamlanmış olması durumunda, yüklenen verilerdeki küçük farklılıklara biraz kayıtsız kalabilir. Bir başka deyişle, devamlı benzer reaksiyonu ortaya koyar. Asıl evrendeki etraftan iletilen etkenler aracılığıyla şekilsizliklerin oluştuğu verileri gözlemlemek adına, bu vasfı değerlidir. Böylece, bilgisayarlarda faydalanılan alışılmış uygulamaları aşarak kusursuz bir yapıya sahip olmayan, bünyesinde barındığımız evreni kavrayabilmek amacıyla açıklanmış bir yapıya sahiptir [94].

Bilmediği verilere dair talimatları, ağ bünyesine verilen örneklerden genellemeler yaparak elde edebilirler [39]. YSA tüm bu avantajlara karşın, kimi dezavantajları da bünyesinde barındırmaktadır.

Nitelik olarak kara kutu vasfına sahiptir. Soruna karşı çıkar yol meydana getirildiğinde, ne şekilde ve niçin gerçekleştirdiğine dair YSA fikir belli etmez. Kesin bir kaide YSA mimarisinin oluşturulmasında mevcut değildir. Test etme, yanılma ve tecrübe etme vasıtasıyla elverişli ağ biçimi oluşturulmaktadır [92]. Aşağıdaki Şekil 3.9'da YSA yapısının çıktı oluşturma aşamasındaki belirsizliği ifade edilmektedir.

Girdi Vektörü: $X=(X_1, X_2, X_3, X_4, X_5, X_6 \ldots)^T$

Çıktı Vektörü: $Y=(Y_1, Y_2, Y_3, Y_4, Y_5, X_6 \ldots)^T$



Şekil 3.9 YSA ile giriş, çıkış bağlantısı [39]

Ne kadar sürede ağ eğitiminin sonlandırılacağına dair belli bir metot mevcut değildir. En iyi sonuçları veren bir yapı hala oluşturulmamıştır. Bu durum bir hayli önemi olan bir husus olup, halledilmesi amacıyla araştırmaların gerçekleştirilmesi gereklidir [39].

3.3.6 Veri normalizasyonu

Sinir ağı yetiştirilmesinde daha fazla kazanım sağlanabilmesi, önceden işlem basamaklarının ağın girdileri ve amaçlarına uygulanmasıyla mümkün olur. Ağın girdi işleme işlevleri ile ağdan faydalanırken, giriş verileri daha elverişli biçime çevrilir. Girdilerin eğitim için yeterli seviyeye gelmelerinde, işlenmemiş verilerin normalleştirilmesinin etkisi önemlidir. Sinir ağları, normalleştirme olmaksızın fazlaca ağır biçimde eğitilebilirlerdi. Normalleştirmeden faydalanılarak, ayarlanan veri grubunun en az yanılgıyla ağın kavrama kabiliyetini ilerletebilmesi gerçekleştirilir [95]. Değişik normalizasyon tekniklerinin (Medyan, Min -Max kuralı, Z-Score ve Sigmoid gibi) varlığına karşın, bu çalışmada Min -Max kuralından faydalanılmıştır. Bu şekilde bütün veriler 0 ile 1 arasında ayarlanmıştır.

Min-max normalizasyonu:

Doğrusal biçimde girdilerin normalizasyonu Min-Max metoduyla gerçekleştirilir. Herhangi bir girdinin edinebileceği en fazla değer, maksimum olmasına karşın; giriş verisinin sahip olabileceği en az değer minimum olarak adlandırılır [46]. Aşağıdaki formülden faydalanılarak, min-max normalizasyon tekniği uygulanabilir;

$$X_n = \frac{(x_0 - x_{min})}{x_{max} - x_{min}} \tag{3.5}$$

"x_0" asıl girdi verisini, "X_n" normalleştirilmiş veriyi, "x_{max}" ve "x_{min}" ise sırasıyla maksimum ile minimum girdiyi temsil etmektedirler [96]. Verimli bir şekilde YSA'dan faydalanabilmek adına verilerin normalize edilmesi gerekliliğinden dolayı, min-max metodu uygulanarak normalizasyon sağlanmıştır.

Oluşturulan YSA modellerinin analizinin yapılabilmesi amacıyla OKH (ortalama karesel hata), R^2 (determinasyon katsayısı) ile OMH (ortalama mutlak hata) hesaplanmıştır. Böylece performans olarak başarılı olan model yapısı rahatlıkla yorumlanmıştır. Bu analizler, tezin bir sonraki kısmı olan Bulgular ve Tartışma kısmında yer almaktadır.

4. BULGULAR VE TARTIŞMA

Tezin bir önceki bölümünde ele alınan verilerin, söz edilen metotlar aracılığıyla işlenmesiyle edinilen bulgular ve bu verilerin yorumlanması tezin bu kısmında açıklanmıştır. Dicle nehri alt havzasında bulunan Dicle barajı ve Ongözlü köprü adındaki iki farklı gözlem istasyonuna ait farklı tarihlerdeki veriler kullanılarak, çözünmüş oksijen için tahmin modelleri oluşturulmuştur. Modelleme aracı olarak Yapay Sinir Ağı kullanılmıştır. Her istasyon için de kendi içerisinde girdi ile çıktılar işlenerek, istasyon bazında bir uygulama yapılmıştır. DSİ 10. Bölge Müdürlüğü'nden alınan veriler, normalizasyon işleminin ardından YSA yöntemi kullanılarak işlem görmüştür [97]. İki istasyon için de 14 farklı parametreye (T (°C), pH (-), EC (mikromhos/cm), TDS (mg/L), Cl (mg/lt), NO_2-N (mg/L), NO_3-N (mg/L), BOD_5 (mg/L), O-PO_4 (mg/L), Fe (mg/L), Mn (mg/L), Na (mg/L), Ca (mg/L) ve Mg (mg/L)) ait veriler kullanılmıştır. Bu veriler yapay sinir ağında analiz edilerek çözünmüş oksijen tahmini için modeller oluşturulmuştur.

Verilerin %70'i eğitim, %15'i test ve geriye kalan %15'i ise doğrulama için kullanılmıştır. Aşağıdaki Tablo 4.1'de her bir istasyon için kullanılan toplam veri adedinin eğitim, test ve doğrulama aşamalarındaki sayıları gösterilmiştir.

Tablo 4.1 Her bir istasyonun bütün parametreleri için toplam veri adedi

İstasyon Adı	Dicle Barajı	Ongözlü Köprü
Veri Sayısı	255	255
Eğitim verisi	179	179
Test verisi	38	38
Doğrulama	38	38

Faydalanılan yapay sinir ağında eğitim algoritması olarak üç farklı algoritma kullanılmıştır. Bunlar Levenberg – Marquardt backpropagation (trainlm), Bayesian Regularization backpropagation (trainbr) ve Scaled Conjugate Gradient backpropagation (trainscg)'dir. Transfer fonksiyonu olarak ise Log-Sigmoid (logsig) ve Tan-Sigmoid (tansig) fonksiyonlarından yararlanılmıştır. Gizli nöron sayısı 10 ve 5 olarak uygulanmıştır. Yapısına göre ise uygulanan ağ, İleri Beslemeli Geriye Yayılımlı Sinir Ağı yapısındadır. Bu bağlamda üç farklı eğitim algoritması, iki değişik aktivasyon fonksiyonu ve iki farklı gizli nöron sayısı kullanılarak,

kombinasyon olarak toplamda on iki farklı model elde edilmiştir. Çalışma kapsamında Dicle nehri alt havzasındaki her iki istasyon için de ÇO parametresini tayin etmek amacıyla oluşturulan YSA yapılarına ait bilgiler aşağıdaki Tablo 4.2'de özetlenmiştir.

Tablo 4.2 Kullanılan YSA yapıları

Eğitim Algoritması:	Levenberg–Marquardt backpropagation (trainlm)
	Bayesian Regularization backpropagation (trainbr)
	Scaled Conjugate Gradient backpropagation (trainscg)
Transfer Fonksiyonu:	Log-Sigmoid (logsig) Tan-Sigmoid (tansig)
Gizli Nöron Sayısı:	10 5
Ağ Yapısı:	İleri Beslemeli Geriye Yayılım Sinir Ağı

Sonuç itibariyle, her iki gözlem noktası için de YSA'da farklı model kombinasyonları oluşturulup, her biri için 12 farklı modelleme elde edilmiştir. Bu modellerin hangi tür kombinasyonlar ile edinildiği aşağıdaki Tablo 4.3'te verilmiştir.

Tablo 4.3 İstasyonlardaki model kombinasyonları

	Model	**Eğitim Algoritması**	**Aktivasyon Fonksiyonu**	**Gizli Nöron Sayısı**
Dicle Barajı ve Ongözlü Köprü İstasyonları	M1	trainlm	logsig	5
	M2	trainlm	tansig	5
	M3	trainlm	logsig	10
	M4	trainlm	tansig	10
	M5	trainbr	logsig	5
	M6	trainbr	tansig	5
	M7	trainbr	logsig	10
	M8	trainbr	tansig	10
	M9	trainscg	logsig	5
	M10	trainscg	tansig	5
	M11	trainscg	logsig	10
	M12	trainscg	tansig	10

4.1 Dicle Barajı İstasyonu İçin Model Çıktıları

Veriler, yıl olarak 2011-2015 arasında olup, ortalama 3 aylık periyotlar ile yapılan ölçümlerden oluşmaktadır. Normalizasyon aşamasından geçen veriler, YSA'da kullanılarak model sonuçları elde edilmiştir.

Toplamda on iki farklı tahmin modeli elde edilmiştir. Bu modellerdeki tahmin değerleri ve gerçekteki ölçülen değerler kullanılarak determinasyon katsayıları hesaplanmıştır. Bu katsayılar aracılığıyla modeller arasında başarı kıyaslaması yapmak amaçlanmıştır. Dicle barajı istasyonu için elde edilen sonuçlara ait model çıktıları aşağıdaki Tablo 4.4'te yer almaktadır.

Tablo 4.4 Dicle Barajı model sonuçları

	M1		**M2**		**M3**		**M4**	
	Gerçek	**Tahmin**	**Gerçek**	**Tahmin**	**Gerçek**	**Tahmin**	**Gerçek**	**Tahmin**
Dicle Barajı	10,000	10,147	10,000	10,000	10,000	10,141	10,000	10,342
	8,400	9,366	8,400	8,400	8,400	8,057	8,400	9,087
	9,200	8,999	9,200	9,200	9,200	9,410	9,200	9,225
	9,800	9,474	9,800	10,611	9,800	8,529	9,800	8,981
	9,900	9,888	9,900	10,700	9,900	8,803	9,900	7,721
	7,300	9,697	7,300	7,300	7,300	7,062	7,300	7,277
	8,900	8,657	8,900	8,900	8,900	7,999	8,900	9,018
	9,700	8,609	9,700	9,700	9,700	9,162	9,700	9,608
	9,900	8,801	9,900	10,646	9,900	9,463	9,900	9,665
	8,300	7,586	8,300	7,574	8,300	9,618	8,300	8,923
	7,100	8,419	7,100	7,100	7,100	6,880	7,100	7,571
	10,100	8,556	10,100	10,100	10,100	10,055	10,100	10,157
	9,800	9,584	9,800	10,700	9,800	9,403	9,800	10,372
	9,500	8,401	9,500	8,585	9,500	8,960	9,500	8,693
	8,000	8,442	8,000	8,000	8,000	7,851	8,000	7,902
	12,200	10,699	12,200	10,700	12,200	9,958	12,200	9,572
	10,800	9,804	10,800	10,700	10,800	9,733	10,800	9,686
$\mathbf{R^2}$	0,312		0,779		0,643		0,450	

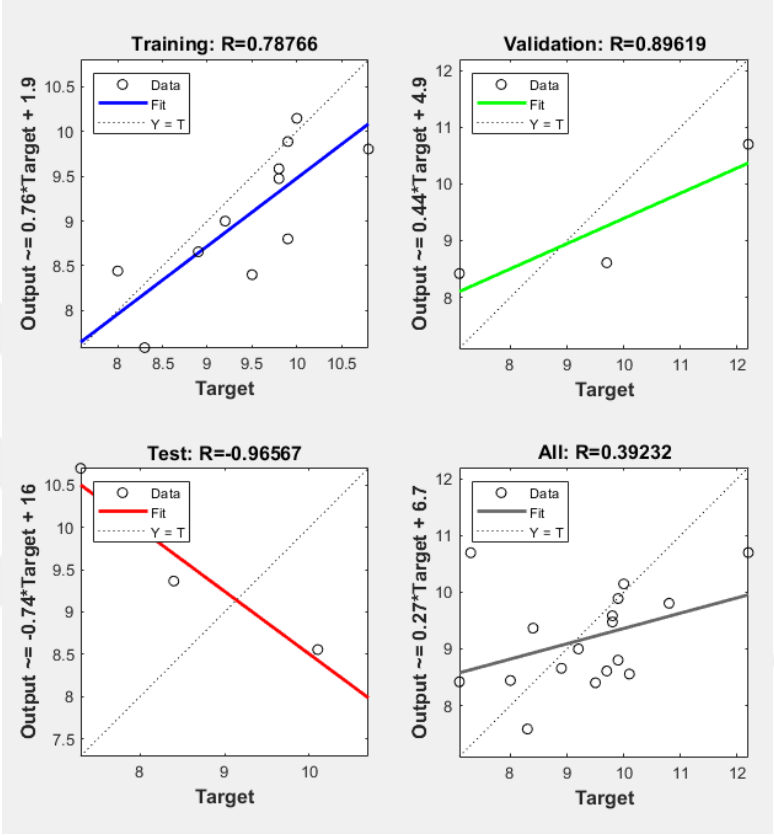
Tablo 4.4 (Devam)

	M5		M6		M7		M8	
	Gerçek	**Tahmin**	**Gerçek**	**Tahmin**	**Gerçek**	**Tahmin**	**Gerçek**	**Tahmin**
Dicle Barajı	10,000	9,338	10,000	9,506	10,000	9,454	10,000	9,499
	8,400	9,296	8,400	9,167	8,400	9,416	8,400	9,117
	9,200	9,286	9,200	9,261	9,200	9,423	9,200	9,363
	9,800	9,286	9,800	9,209	9,800	9,415	9,800	9,238
	9,900	9,298	9,900	9,171	9,900	9,430	9,900	9,277
	7,300	9,311	7,300	9,125	7,300	9,459	7,300	9,251
	8,900	9,280	8,900	9,214	8,900	9,399	8,900	9,192
	9,700	9,283	9,700	9,368	9,700	9,414	9,700	9,282
	9,900	9,286	9,900	9,349	9,900	9,428	9,900	9,310
	8,300	9,274	8,300	9,300	8,300	9,397	8,300	9,303
	7,100	9,288	7,100	9,034	7,100	9,420	7,100	9,200
	10,100	9,301	10,100	9,714	10,100	9,502	10,100	9,647
	9,800	9,307	9,800	9,473	9,800	9,451	9,800	9,543
	9,500	9,279	9,500	9,019	9,500	9,403	9,500	9,052
	8,000	9,281	8,000	9,010	8,000	9,387	8,000	8,622
	12,200	9,324	12,200	9,383	12,200	9,462	12,200	10,476
	10,800	9,318	10,800	9,261	10,800	9,448	10,800	9,391
R^2	0,221		0,312		0,195		0,514	

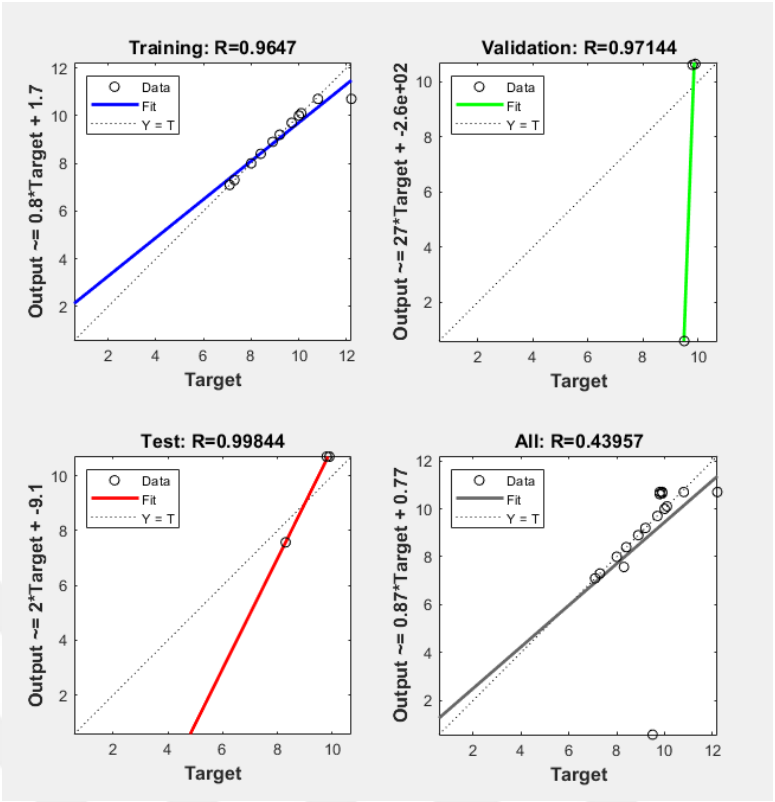
Tablo 4.4 (Devam)

	M9		M10		M11		M12	
	Gerçek	**Tahmin**	**Gerçek**	**Tahmin**	**Gerçek**	**Tahmin**	**Gerçek**	**Tahmin**
Dicle Barajı	10,000	10,700	10,000	9,790	10,000	9,627	10,000	10,462
	8,400	10,700	8,400	8,701	8,400	8,493	8,400	9,608
	9,200	10,700	9,200	9,257	9,200	9,472	9,200	8,941
	9,800	10,700	9,800	9,221	9,800	8,852	9,800	9,605
	9,900	10,700	9,900	9,283	9,900	9,944	9,900	9,379
	7,300	10,700	7,300	9,734	7,300	7,379	7,300	10,484
	8,900	10,700	8,900	8,244	8,900	9,194	8,900	9,064
	9,700	10,700	9,700	8,339	9,700	9,749	9,700	9,604
	9,900	10,700	9,900	9,494	9,900	9,819	9,900	10,180
	8,300	10,700	8,300	8,434	8,300	9,636	8,300	8,052
	7,100	10,700	7,100	7,837	7,100	6,679	7,100	7,749
	10,100	10,700	10,100	10,582	10,100	9,912	10,100	4,856
	9,800	10,700	9,800	9,808	9,800	10,618	9,800	10,158
	9,500	10,700	9,500	9,094	9,500	9,408	9,500	7,020
	8,000	10,700	8,000	8,043	8,000	8,257	8,000	7,923
	12,200	10,700	12,200	9,758	12,200	9,882	12,200	10,418
	10,800	10,700	10,800	9,510	10,800	10,561	10,800	9,984
R^2	0,001		0,339		0,640		0,046	

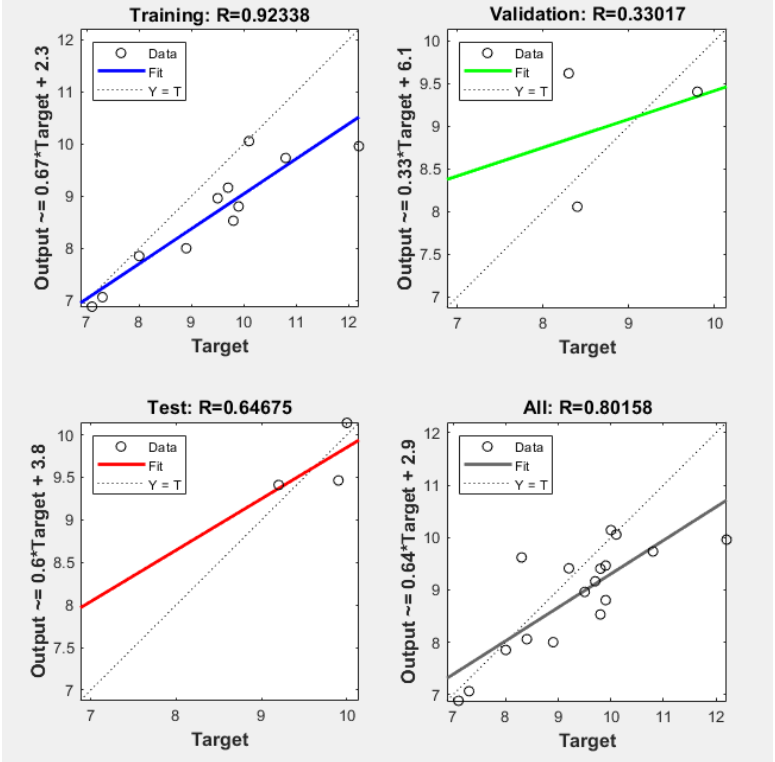
Dicle barajının Matlab programındaki YSA yapılarından elde edilen M1 model sonuçları Şekil 4.1'de, M2 modeli Şekil 4.2, M3 modeli ise Şekil 4.3'te gösterilmektedir.



Şekil 4.1 Dicle Barajı istasyonu M1 modeli saçılma diyagramı

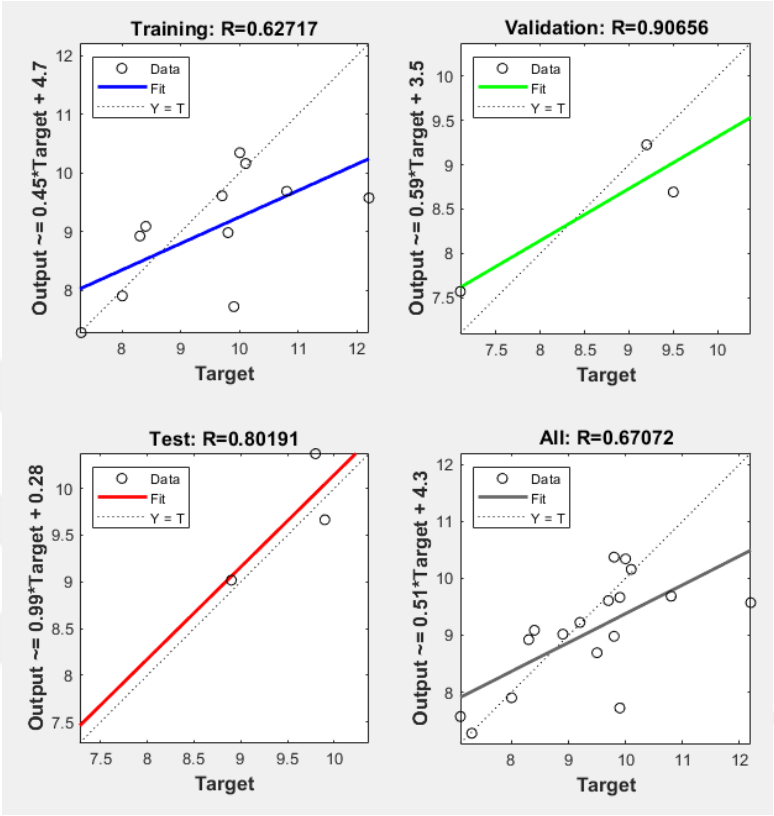


Şekil 4.2 Dicle Barajı istasyonu M2 modeli saçılma diyagramı

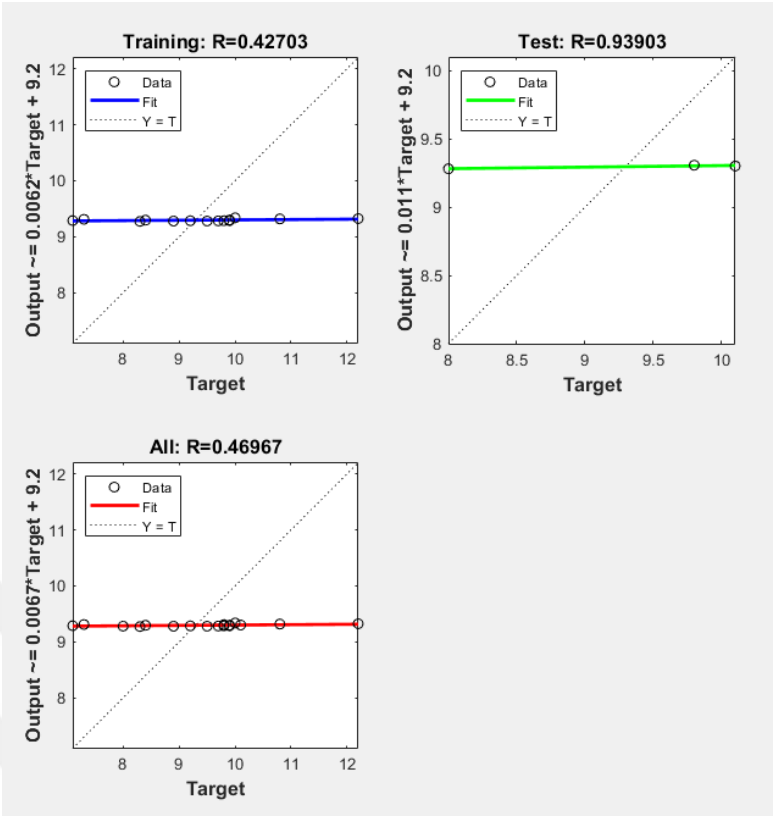


Şekil 4.3 Dicle Barajı istasyonu M3 modeli saçılma diyagramı

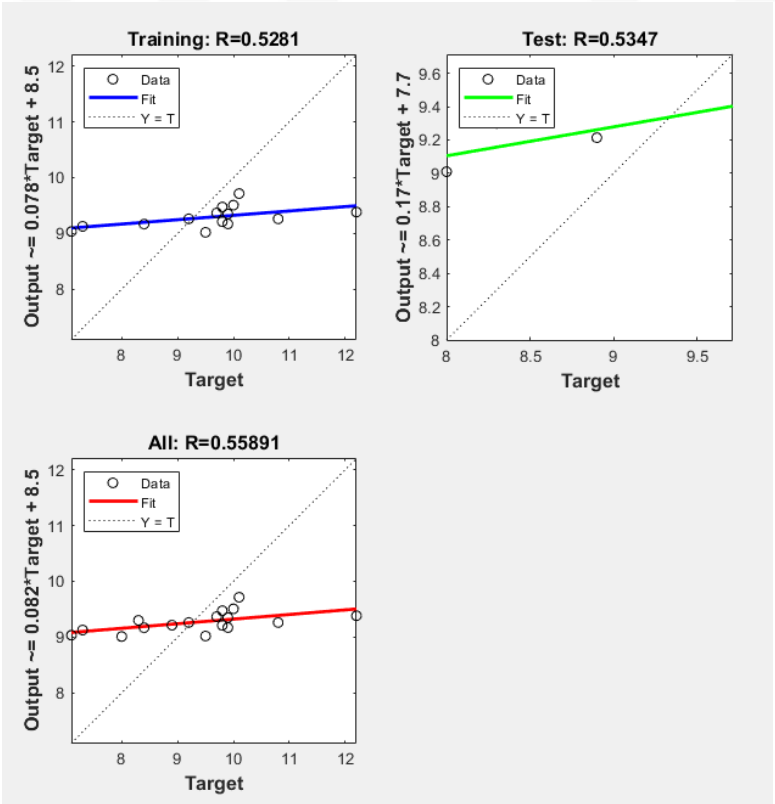
M4 model kombinasyonu için Şekil 4.4'te, M5 modeli Şekil 4.5'te, M6 modeli ise Şekil 4.6'da gösterilmektedir.



Şekil 4.4 Dicle Barajı istasyonu M4 modeli saçılma diyagramı

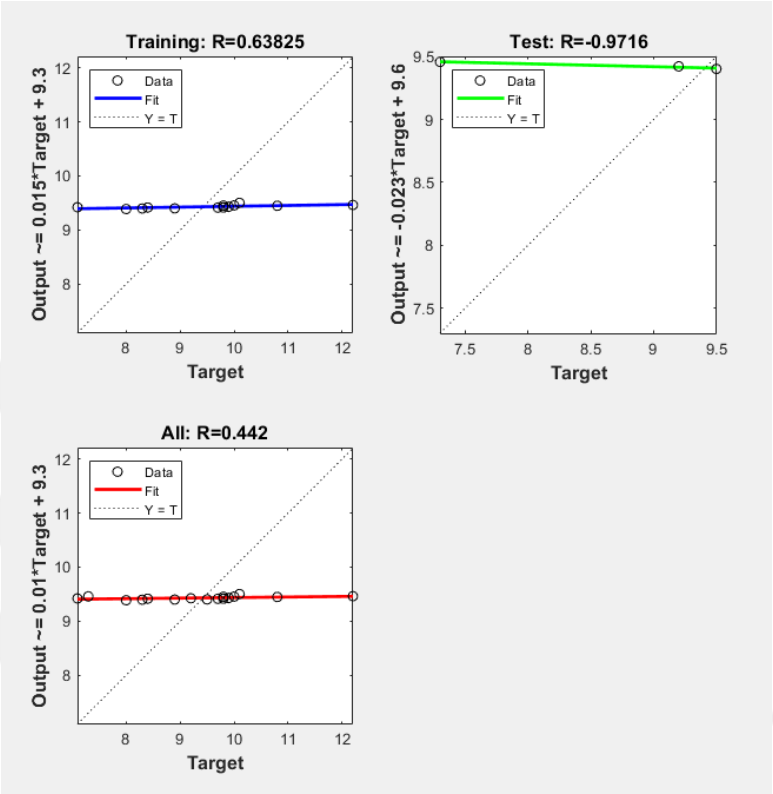


Şekil 4.5 Dicle Barajı istasyonu M5 modeli saçılma diyagramı

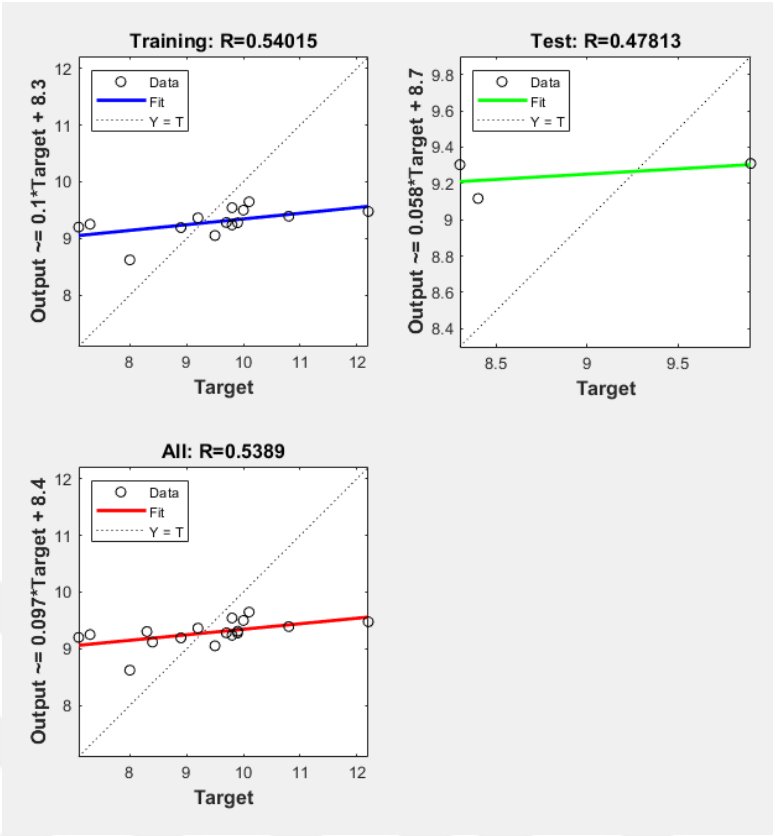


Şekil 4.6 Dicle Barajı istasyonu M6 modeli saçılma diyagramı

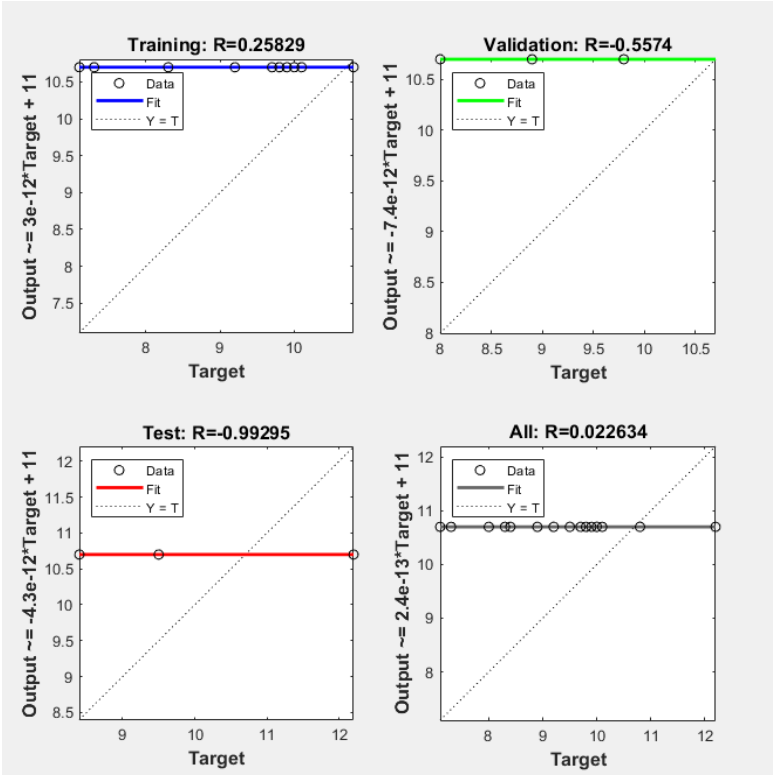
Şekil 4.7'de M7 modeli, M8 modeli Şekil 4.8'de ve M9 modeli sonuçları ise Şekil 4.9'da yer almaktadır.



Şekil 4.7 Dicle Barajı istasyonu M7 modeli saçılma diyagramı

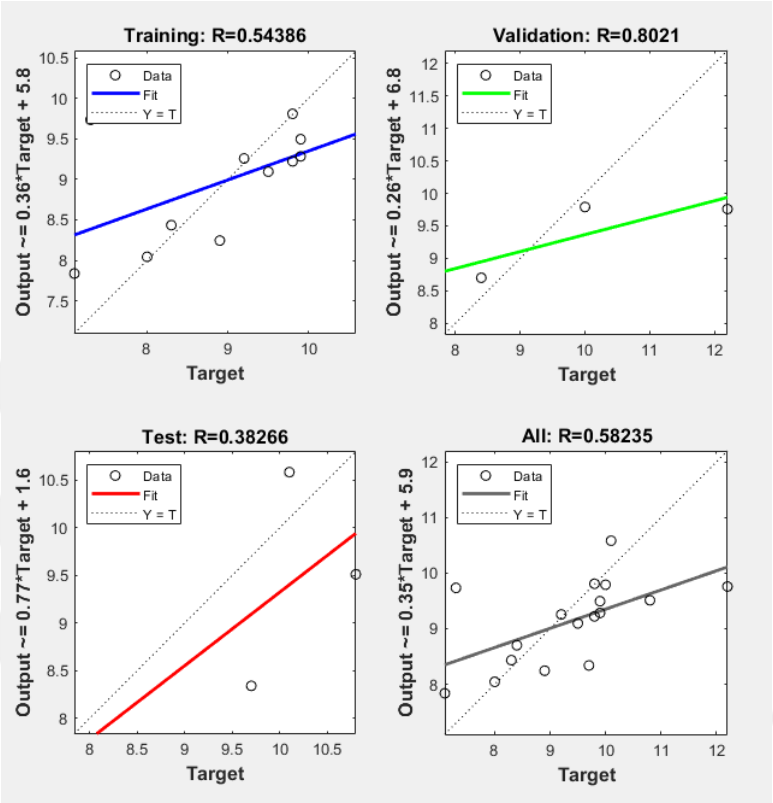


Şekil 4.8 Dicle Barajı istasyonu M8 modeli saçılma diyagramı

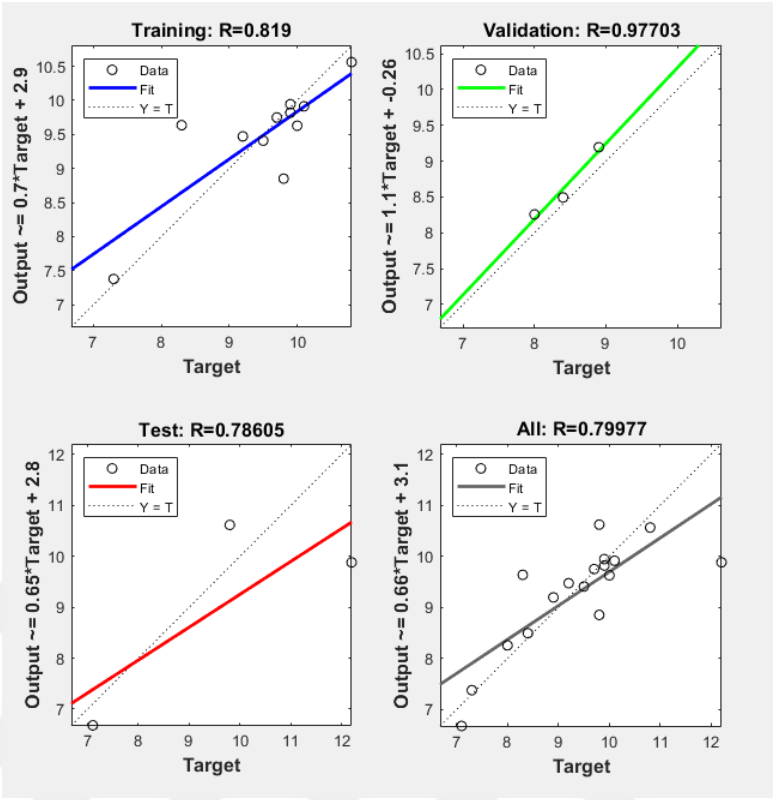


Şekil 4.9 Dicle Barajı istasyonu M9 modeli saçılma diyagramı

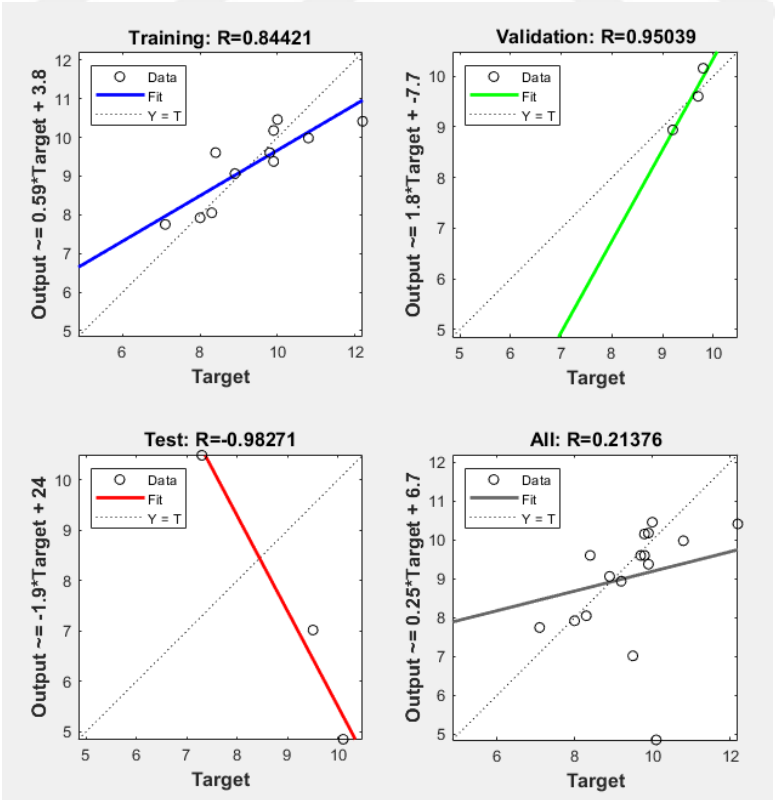
M10 modeli çıktıları Şekil 4.10'da, M11 modeli Şekil 4.11'de ve M12 modeli Şekil 4.12'de gösterilmektedir.



Şekil 4.10 Dicle Barajı istasyonu M10 modeli saçılma diyagramı



Şekil 4.11 Dicle Barajı istasyonu M11 modeli saçılma diyagramı

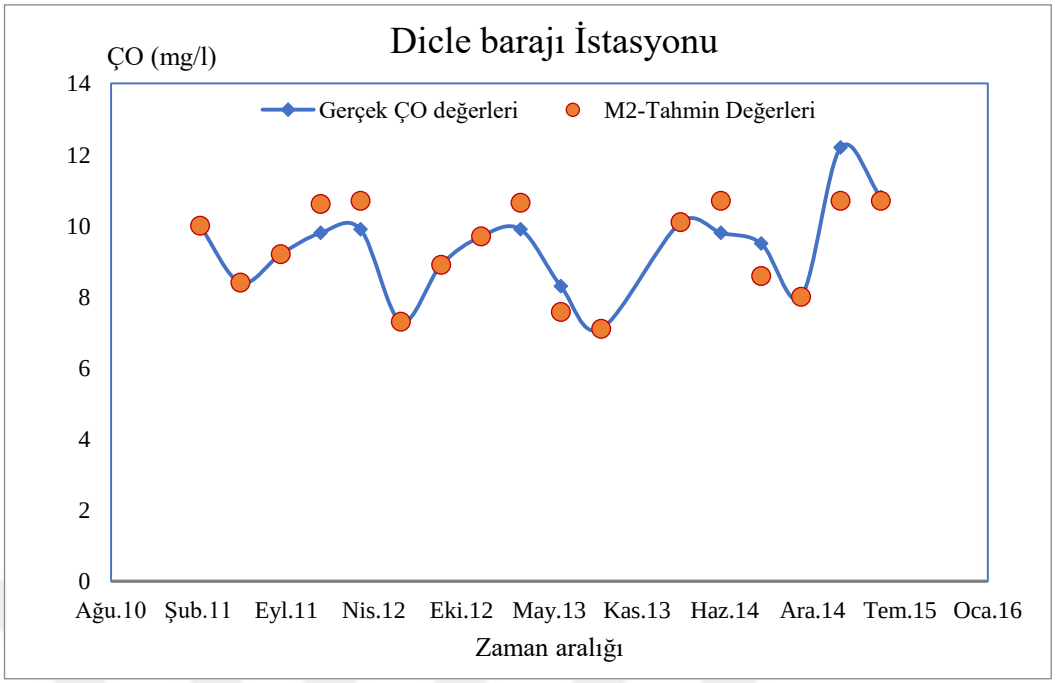


Şekil 4.12 Dicle Barajı istasyonu M12 modeli saçılma diyagramı

Elde edilen YSA yapısına ait performans değerlendirmesi yapabilmek adına R^2 (determinasyon katsayısı), OMH (ortalama mutlak hata) ve OKH (ortalama karesel hata) değerleri elde edilmiş olup, Tablo 4.5'te Dicle barajı istasyonu için edinilen değerler yer almaktadır. Bu değerlendirme aşamasında R^2 değerinin 1'e, hata değerlerinin ise 0'a yakınlıklarına göre en iyi sonucu veren kombinasyona ait modeller belirlenmiştir. Bu anlamda sonuçlar incelendiğinde hata değerlerinin 0'a en yakın, determinasyon katsayısının ise 1'e en yakın olduğu model M2 olarak yorumlanmıştır. Yani Dicle nehri alt havzasına ait gerçek ÇO değerleri ile en uyumlu ve paralel sonuçlar, eğitim algoritması olarak Levenberg – Marquardt backpropagation (trainlm), transfer fonksiyonu olarak Tan-Sigmoid (tansig) ve gizli nöron sayısının 5 olduğu İleri Beslemeli Geriye Yayılım Sinir Ağı (İBGYSA) ile elde edilmiştir. En iyi sonucu veren M2 modeli grafik bilgileri Şekil 4.13'te yer almaktadır.

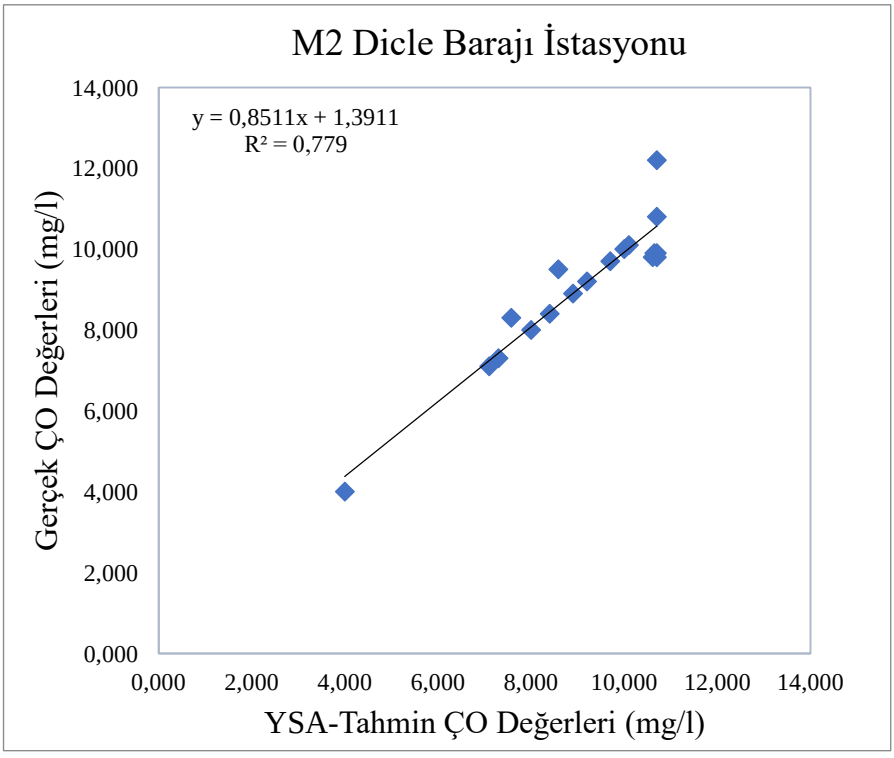
Tablo 4.5 Dicle Barajı istasyonu model performans değerleri

	Model	**Eğitim Algoritması**	**Maksimum Hata**	**R^2**	**OMH**	**OKH**
Dicle Barajı	M1	trainlm	2,397	0,312	0,842	1,096
	M2	trainlm	1,500	0,779	0,382	0,370
	M3	trainlm	2,242	0,643	0,656	0,751
	M4	trainlm	2,628	0,450	0,641	0,932
	M5	trainbr	2,876	0,221	0,970	1,493
	M6	trainbr	2,817	0,312	0,892	1,301
	M7	trainbr	2,738	0,195	0,941	1,487
	M8	trainbr	2,100	0,514	0,814	1,009
	M9	trainscg	3,600	0,001	1,541	3,341
	M10	trainscg	2,442	0,339	0,715	1,048
	M11	trainscg	2,318	0,640	0,465	0,553
	M12	trainscg	5,244	0,046	1,060	2,965



Şekil 4.13 Dicle Barajı gerçek değerler ile M2 model değerleri ilişkisi

Ayrıca Dicle barajı için en başarılı performansı veren M2 modeline ait çıktı verileri ile gerçek ÇO değerleri arasındaki ilişkideki determinasyon katsayısı (R^2)'nin değeri aşağıdaki Şekil 4.14'te gösterilmektedir.



Şekil 4.14 Dicle Barajı gerçek değerler ile M2 modeli tahmin değerlerinin karşılaştırılması

4.2 Ongözlü Köprü İstasyonu İçin Model Çıktıları

Benzer şekilde, tüm işlemler bir diğer istasyon olan Ongözlü köprüsü için de tekrarlanmıştır. 2011-2015 yıllarına ait veriler, normalizasyon işleminin ardından YSA yapısında işlenmiştir. Buradaki amaç, eğitim verileriyle en güçlü modeli kurmaktır.

Modelleme olarak on iki farklı tahmin modeli elde edilmiştir. Bu modellerin her biri için gerçek ve tahmin değerleri temel alınarak determinasyon katsayısı hesaplanmıştır. Uygulama sonucu elde edilen tahmin değerleri Tablo 4.6'da ifade edilmiştir.

Tablo 4.6 Ongözlü Köprü model sonuçları

	M1		**M2**		**M3**		**M4**	
	Gerçek	**Tahmin**	**Gerçek**	**Tahmin**	**Gerçek**	**Tahmin**	**Gerçek**	**Tahmin**
Ongözlü Köprüsü	8,500	8,632	8,500	8,561	8,500	8,832	8,500	7,752
	6,200	6,200	6,200	6,200	6,200	9,344	6,200	5,705
	8,000	9,792	8,000	6,018	8,000	7,296	8,000	7,106
	10,000	10,000	10,000	10,700	10,000	9,690	10,000	9,887
	10,200	10,200	10,200	10,199	10,200	9,676	10,200	8,773
	5,200	5,200	5,200	5,200	5,200	7,100	5,200	5,626
	6,700	4,952	6,700	6,379	6,700	4,373	6,700	7,818
	8,800	8,094	8,800	8,800	8,800	9,032	8,800	9,369
	7,600	7,600	7,600	0,000	7,600	7,557	7,600	7,490
	7,400	7,400	7,400	9,442	7,400	9,057	7,400	8,041
	8,300	8,300	8,300	8,301	8,300	8,514	8,300	7,746
	10,700	10,700	10,700	10,698	10,700	9,499	10,700	9,549
	10,200	10,200	10,200	10,200	10,200	9,781	10,200	8,984
	8,400	8,400	8,400	8,400	8,400	8,679	8,400	6,358
	7,500	7,500	7,500	6,911	7,500	8,459	7,500	6,771
	10,000	10,680	10,000	10,000	10,000	9,831	10,000	9,317
	6,200	6,200	6,200	6,200	6,200	6,931	6,200	7,684
$\mathbf{R^2}$	0,873		0,464		0,447		0,661	

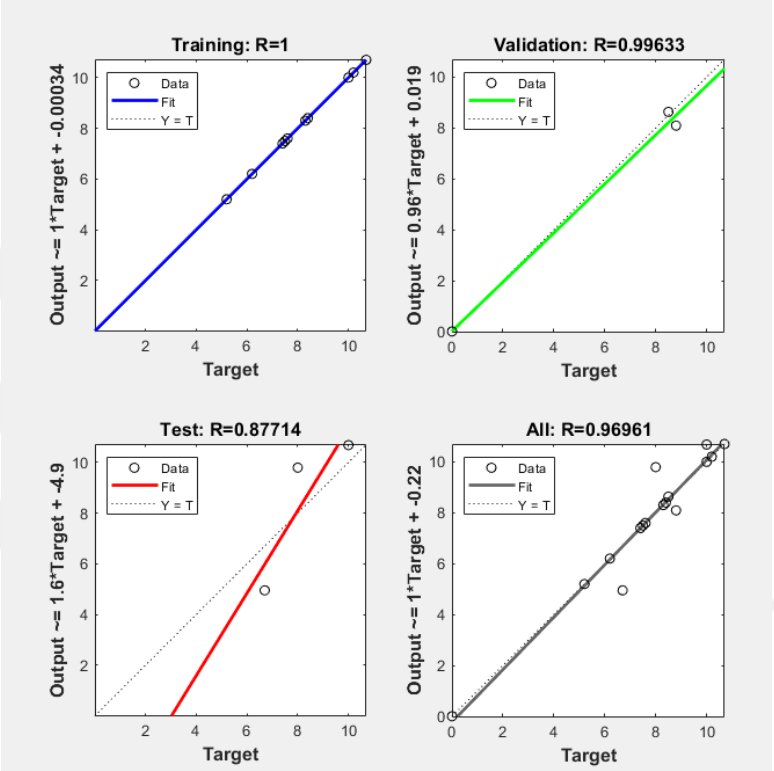
Tablo 4.6 (Devam)

	M5		M6		M7		M8	
	Gerçek	**Tahmin**	**Gerçek**	**Tahmin**	**Gerçek**	**Tahmin**	**Gerçek**	**Tahmin**
Ongözlü Köprüsü	8,500	8,870	8,500	8,630	8,500	8,806	8,500	8,811
	6,200	6,473	6,200	6,928	6,200	6,673	6,200	6,498
	8,000	7,786	8,000	7,750	8,000	7,906	8,000	7,418
	10,000	9,525	10,000	9,078	10,000	9,504	10,000	9,743
	10,200	9,021	10,200	8,680	10,200	9,007	10,200	9,225
	5,200	5,510	5,200	6,599	5,200	6,051	5,200	5,079
	6,700	7,848	6,700	6,866	6,700	7,322	6,700	6,790
	8,800	9,164	8,800	9,105	8,800	9,117	8,800	9,253
	7,600	7,765	7,600	7,820	7,600	7,739	7,600	7,652
	7,400	9,393	7,400	8,981	7,400	9,206	7,400	9,582
	8,300	9,211	8,300	8,780	8,300	9,026	8,300	9,260
	10,700	9,415	10,700	9,107	10,700	9,282	10,700	9,595
	10,200	8,865	10,200	8,299	10,200	8,525	10,200	9,032
	8,400	9,029	8,400	8,973	8,400	8,651	8,400	8,635
	7,500	7,643	7,500	7,854	7,500	7,773	7,500	7,560
	10,000	8,990	10,000	8,695	10,000	8,880	10,000	9,539
	6,200	6,665	6,200	7,288	6,200	7,001	6,200	6,574
R^2	0,694		0,641		0,716		0,751	

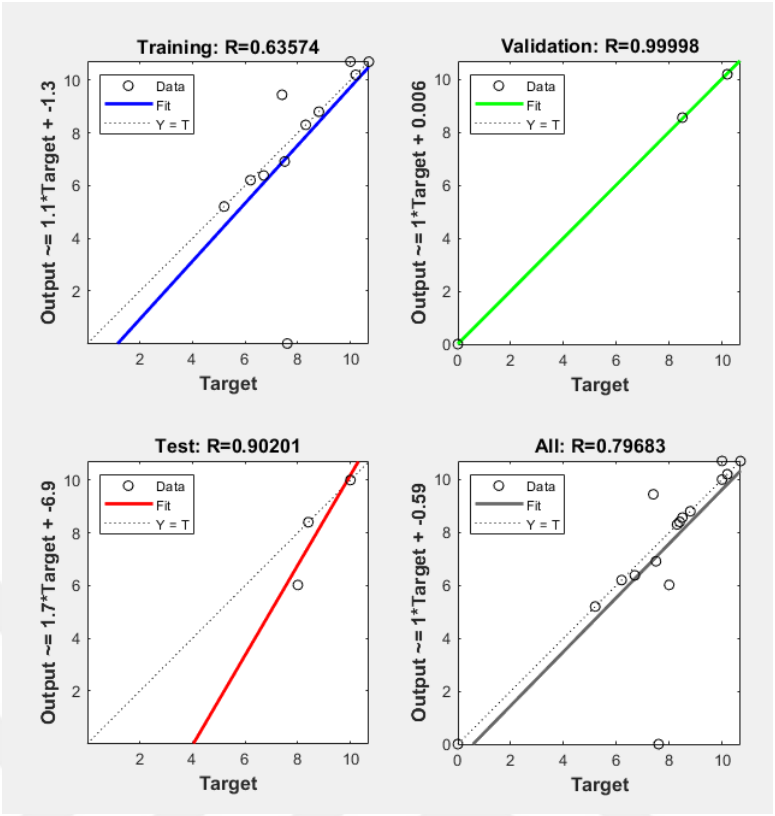
Tablo 4.6 (Devam)

	M9		M10		M11		M12	
	Gerçek	**Tahmin**	**Gerçek**	**Tahmin**	**Gerçek**	**Tahmin**	**Gerçek**	**Tahmin**
Ongözlü Köprüsü	8,500	10,700	8,500	8,996	8,500	9,837	8,500	9,492
	6,200	10,700	6,200	7,279	6,200	5,714	6,200	6,785
	8,000	10,700	8,000	7,238	8,000	8,275	8,000	7,989
	10,000	10,700	10,000	9,795	10,000	10,364	10,000	9,356
	10,200	10,700	10,200	8,547	10,200	9,137	10,200	9,379
	5,200	10,700	5,200	5,162	5,200	5,483	5,200	5,607
	6,700	10,700	6,700	5,077	6,700	7,226	6,700	6,459
	8,800	10,700	8,800	9,784	8,800	10,415	8,800	8,787
	7,600	10,700	7,600	6,663	7,600	7,954	7,600	7,466
	7,400	10,700	7,400	8,915	7,400	7,931	7,400	9,557
	8,300	10,700	8,300	8,418	8,300	8,034	8,300	9,259
	10,700	10,700	10,700	9,538	10,700	10,102	10,700	9,459
	10,200	10,700	10,200	8,786	10,200	9,899	10,200	9,225
	8,400	10,700	8,400	8,760	8,400	8,374	8,400	8,491
	7,500	10,700	7,500	7,921	7,500	6,862	7,500	6,772
	10,000	10,700	10,000	9,359	10,000	9,324	10,000	9,423
	6,200	10,700	6,200	7,184	6,200	6,240	6,200	6,013
R^2	0,164		0,626		0,816		0,723	

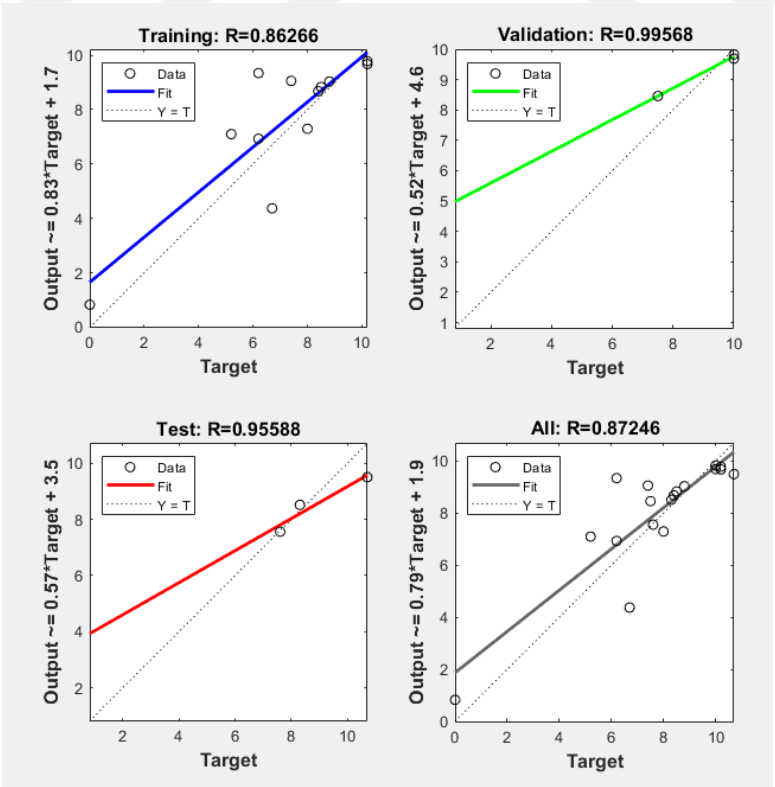
Ongözlü köprü istasyonu için de her bir tahmin model çıktısının elde edilişi, Matlab yardımıyla oluşturulan YSA mimarileri sonucu gerçekleşmiştir. M1 modelinin çıktıları Şekil 4.15'te, M2 modeli Şekil 4.16'da ve M3 modeli Şekil 4.17'de gösterilmiştir.



Şekil 4.15 Ongözlü Köprü istasyonu M1 modeli saçılma diyagramı

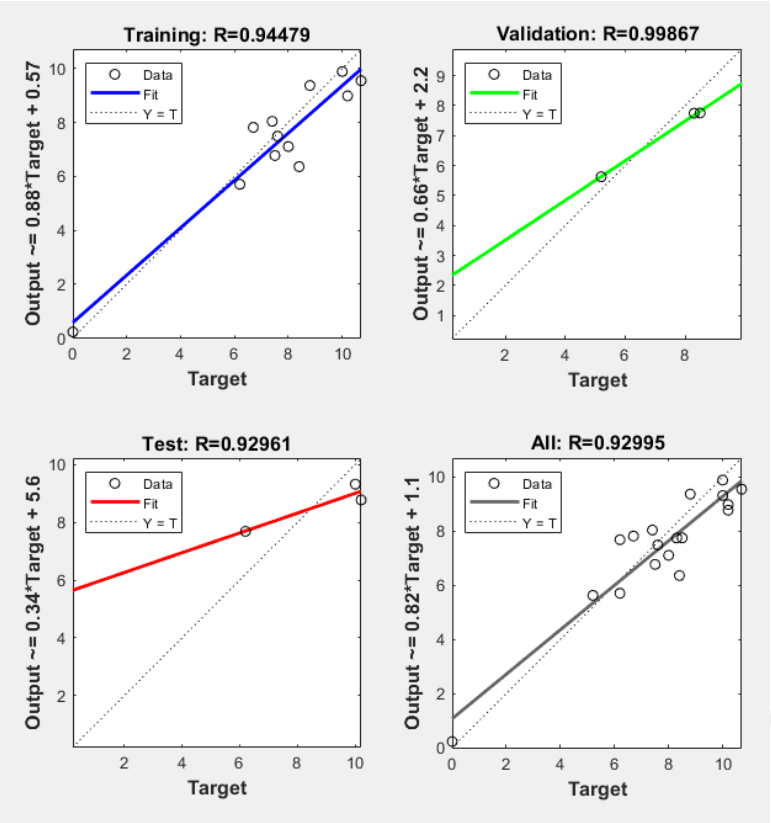


Şekil 4.16 Ongözlü Köprü istasyonu M2 modeli saçılma diyagramı

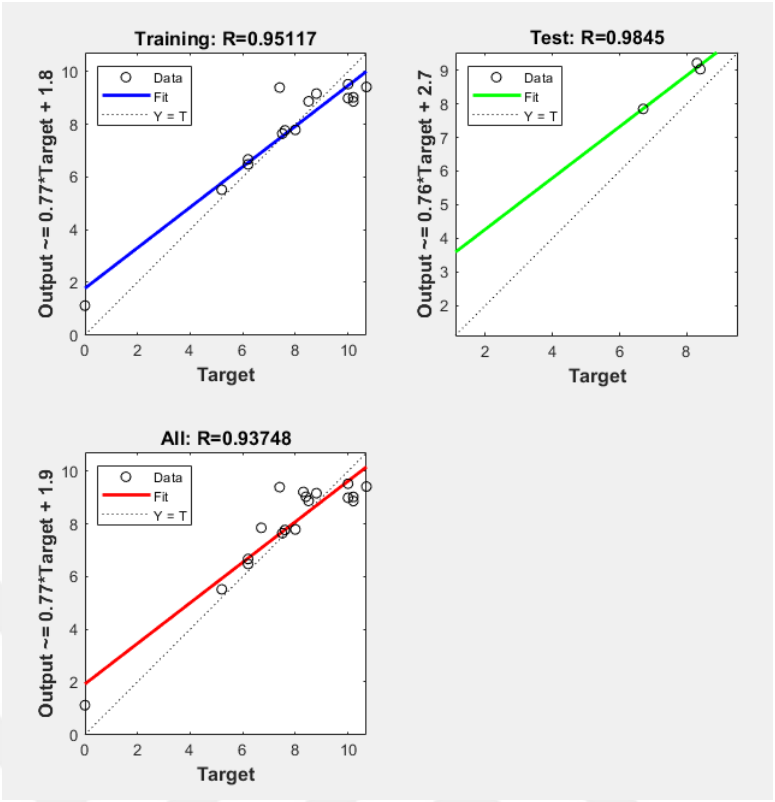


Şekil 4.17 Ongözlü Köprü istasyonu M3 modeli saçılma diyagramı

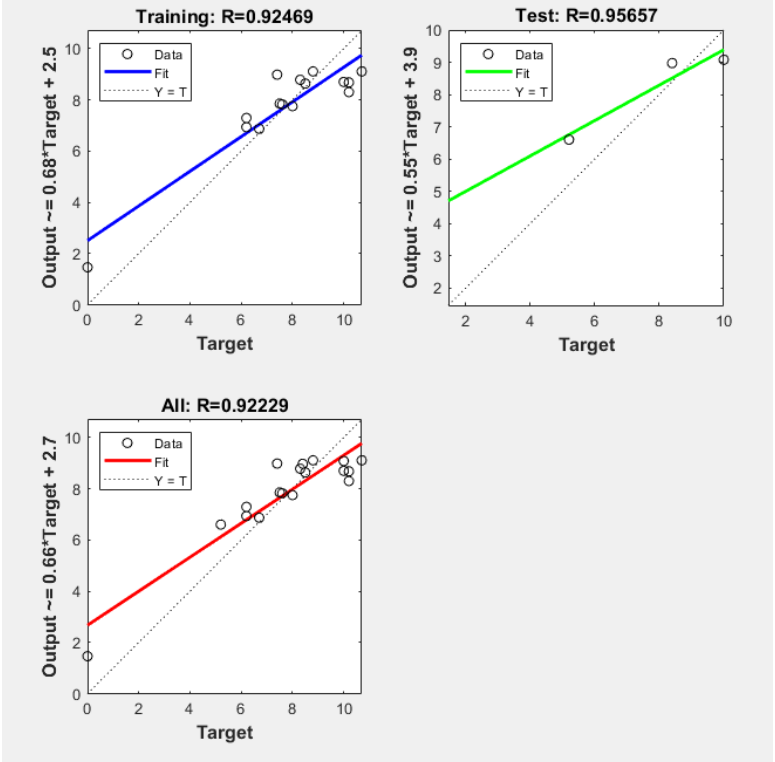
M4 model değerleri Şekil 4.18'de, Şekil 4.19'da M5 modeli ve Şekil 4.20'de M6 modellemesinin grafikleri gösterilmektedir.



Şekil 4.18 Ongözlü Köprü istasyonu M4 modeli saçılma diyagramı

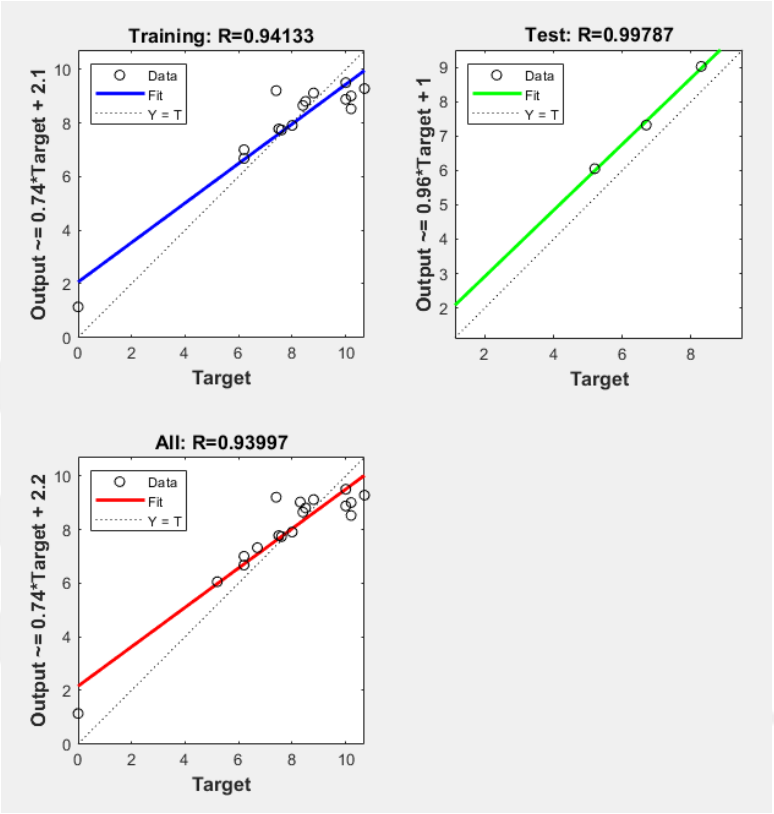


Şekil 4.19 Ongözlü Köprü istasyonu M5 modeli saçılma diyagramı

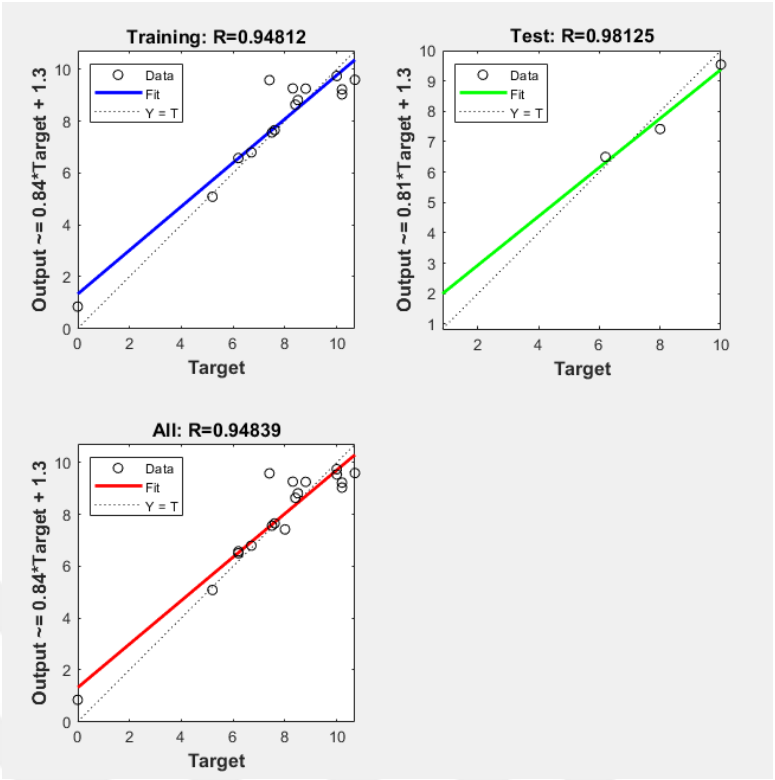


Şekil 4.20 Ongözlü Köprü istasyonu M6 modeli saçılma diyagramı

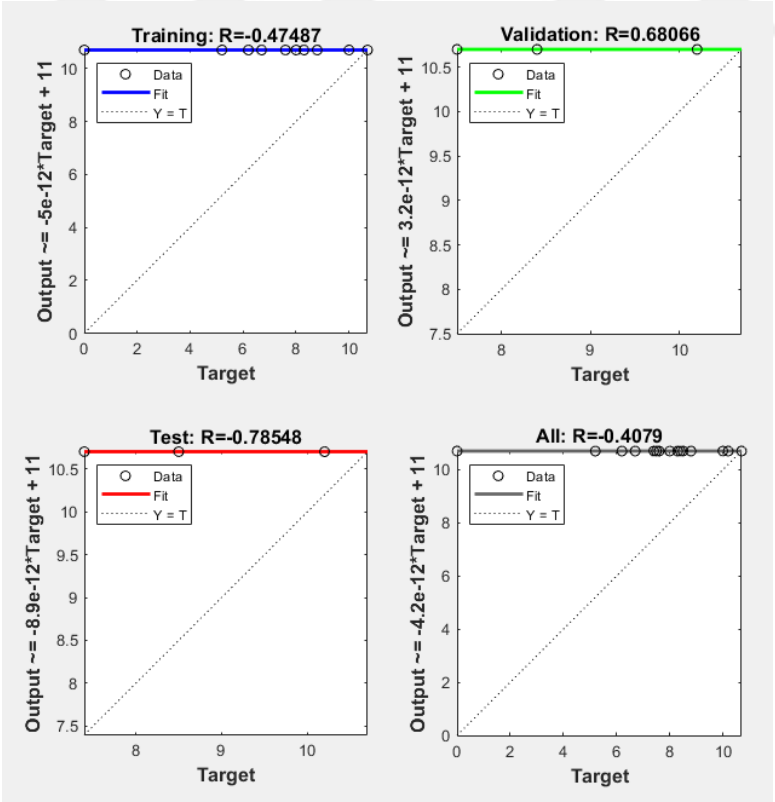
M7 tahmin modeli çıktıları Şekil 4.21'de, M8 modeli Şekil 4.22'de ve M9 modeli Şekil 4.23'te belirtilmiştir.



Şekil 4.21 Ongözlü Köprü istasyonu M7 modeli saçılma diyagramı

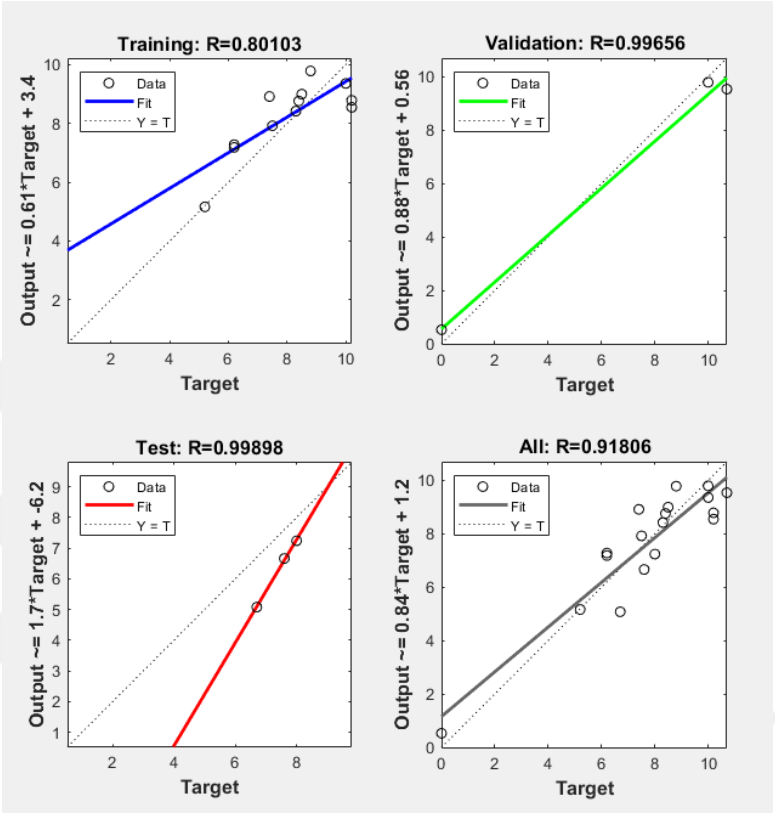


Şekil 4.22 Ongözlü Köprü istasyonu M8 modeli saçılma diyagramı

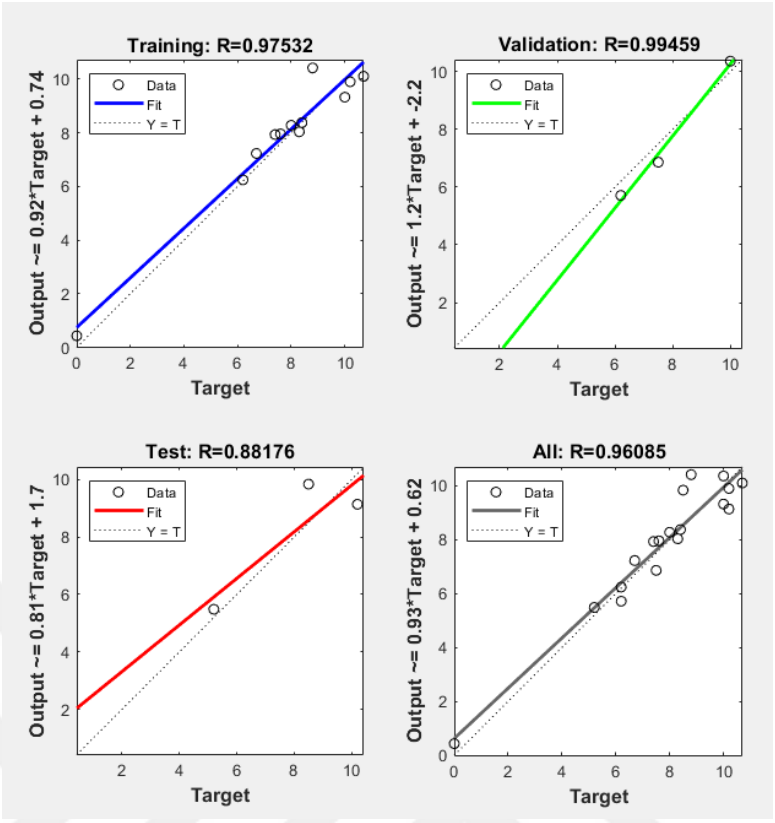


Şekil 4.23 Ongözlü Köprü istasyonu M9 modeli saçılma diyagramı

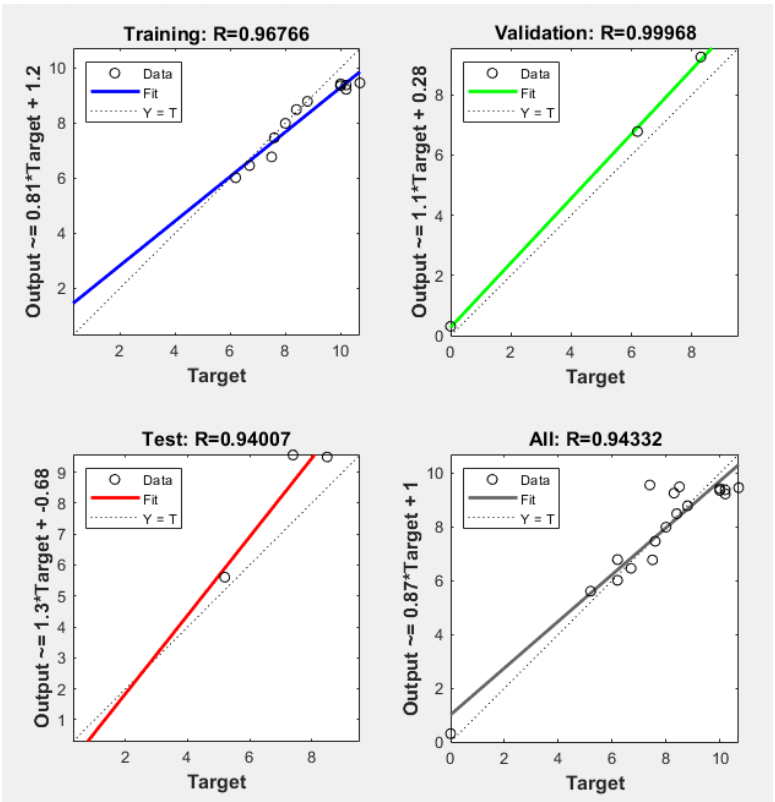
M10 modeli için çıktı sonuçları Şekil 4.24'te, M11 için modelleme sonucu Şekil 4.25'te ve M12 tahmin çıktıları Şekil 4.26'da gösterilmiştir.



Şekil 4.24 Ongözlü Köprü istasyonu M10 modeli saçılma diyagramı



Şekil 4.25 Ongözlü Köprü istasyonu M11 modeli saçılma diyagramı



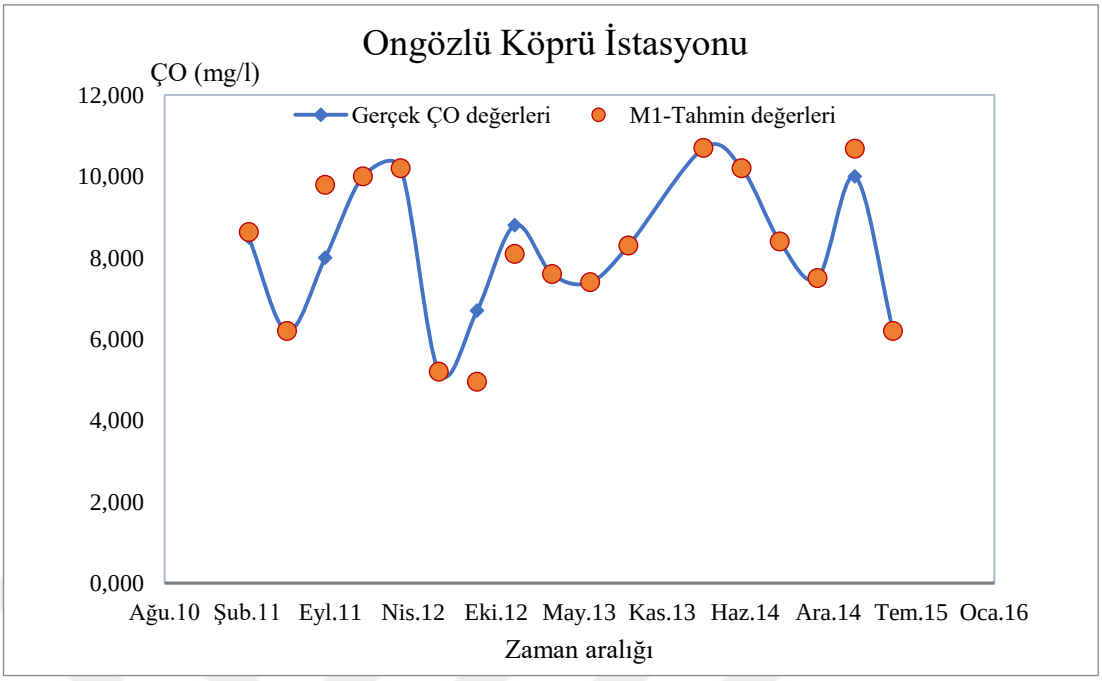
Şekil 4.26 Ongözlü Köprü istasyonu M12 modeli saçılma diyagramı

Model verileri kullanılarak hesaplanan OMH (ortalama mutlak hata), R^2 (determinasyon katsayısı) ve OKH (ortalama karesel hata) değerleri temel alınarak, performans başarısına bakıldığında M1 model çıktılarının en düşük hata değerlerine sahip olup, gerçek değerlerle daha yakın ilişkili olduğu çıkarımı yapılmıştır.

M1 YSA yapısı ise; eğitim algoritması olarak Levenberg – Marquardt backpropagation (trainlm), aktivasyon fonksiyonu Log-Sigmoid (logsig) ve 5 gizli nöronlu İleri Beslemeli Geriye Yayılım biçimindedir. Model hata değerleri hesaplamalarına ait veriler aşağıdaki Tablo 4.7'de gösterilmiş olup, en başarılı model olan M1 modeline ait grafik Şekil 4.27'de belirtilmiştir.

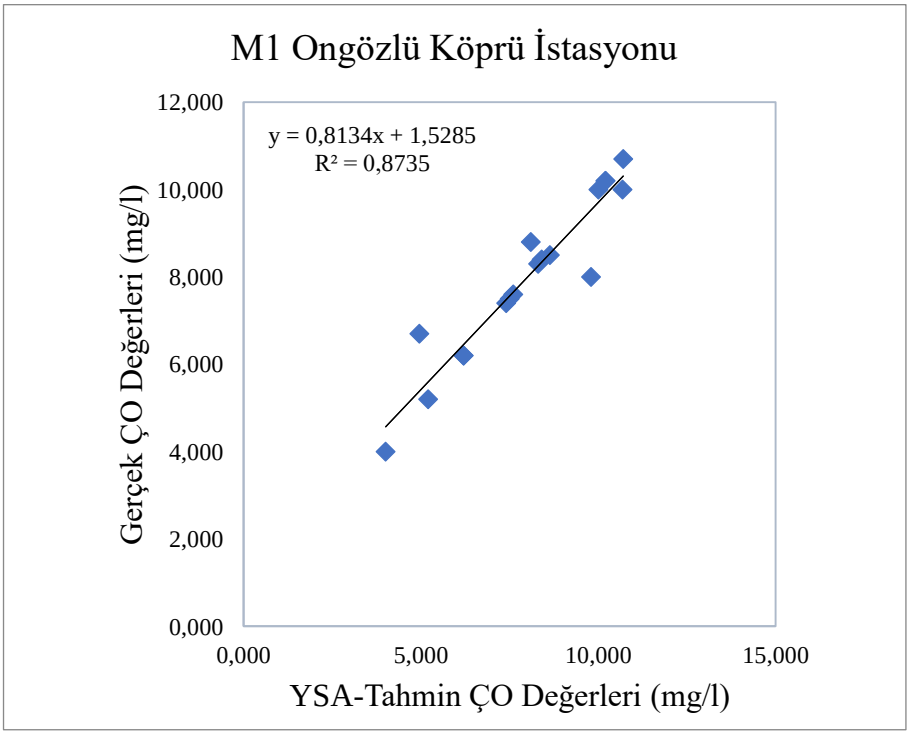
Tablo 4.7 Ongözlü Köprü istasyonu model performans değerleri

	Model	**Eğitim Algoritması**	**Maksimum Hata**	**R^2**	**OMH**	**OKH**
Ongözlü Köprüsü	M1	trainlm	1,792	0,873	0,298	0,426
	M2	trainlm	7,600	0,464	0,782	3,930
	M3	trainlm	3,144	0,447	0,891	1,524
	M4	trainlm	2,042	0,661	0,847	0,959
	M5	trainbr	1,993	0,694	0,722	0,785
	M6	trainbr	1,901	0,641	0,854	1,066
	M7	trainbr	1,806	0,716	0,739	0,815
	M8	trainbr	2,182	0,751	0,570	0,615
	M9	trainscg	5,500	0,164	2,471	8,574
	M10	trainscg	1,653	0,626	0,847	0,976
	M11	trainscg	1,615	0,816	0,552	0,478
	M12	trainscg	2,157	0,723	0,633	0,684



Şekil 4.27 Ongözlü Köprüsü gerçek değerler ile M1 model değerleri ilişkisi

Aşağıdaki Şekil 4.28'de Ongözlü köprü gözlem noktası için en başarılı performansı veren M1 tahmin modelinin çıktıları ile ölçülen gerçek ÇO değerleri arasındaki ilişkinin determinasyon katsayısı (R^2) grafiği gösterilmektedir.



Şekil 4.28 Ongözlü Köprüsü gerçek değerler ile M1 modeli tahmin değerlerinin karşılaştırılması

4.3 Yorumlama

YSA modelleme araçlarının kısa sürede, elverişli ve pratik bir uygulama aşaması ile başarılı çıktılar oluşturmasından dolayı modelleme olarak eski tarihlerden beri kullanılmaktadır. Nitekim literatüre bakıldığında çok sayıda su bilimi modelleme çalışmalarında yapay sinir ağı kullanımı mevcuttur.

Elde edilen tüm bulguları yorumlamak gerekirse, YSA'nın su kalitesi tayininde etkili bir role sahip olduğu görülmektedir. En elverişli YSA yapısının oluşturulmasıyla düşük hata değerlerine sahip modeller rahatlıkla elde edilebilmektedir. Özellikle veri adedinin kısıtlı olması durumunda dahi, farklı senaryo ve kombinasyonlar ile başarılı çıktılar edinilebilir. Bu anlamda literatür araştırması yapıldığında su biliminde ve bilhassa su kalite parametreleri konusunda YSA'dan faydalanılan çok sayıda çalışma mevcuttur.

Her iki istasyon için de sonuçlara bakıldığında, en başarılı modelleme İleri Beslemeli yapılı Levenberg – Marquardt backpropagation (trainlm) algoritmasının olduğu görülmektedir. Yapılan benzer birçok çalışmada İleri Beslemeli türdeki Geri yayılım biçimli Levenberg algoritmasının başarılı sonuçlar verdiği görülmektedir. Özellikle çözünmüş oksijen tayininin su kalitesi takibindeki öneminden dolayı, YSA gibi etkin sonuçlar oluşturan bir modelleme aracı yaygın kullanıma sahiptir. YSA modellemeleri ile nehirlerdeki ÇO değerinin saptanması çalışmalarındaki sonuçlar, bu modelleme aracının etkinliğini ortaya koymaktadır.

5. SONUÇ VE ÖNERİLER

Su kalitesinin yorumlanabilmesinde, modelleme programlarının kullanılması son zamanlarda popülerleşerek artmaktadır. Kaliteyi etkileyen önemli bir parametre olan ÇO verilerinin ele alınarak, farklı kombinasyonlarda tahmin modelleri üretilebilmektedir. Çözünmüş oksijeni etkileyen parametreler seçilerek yapılan bu çalışmada, girdi olarak 14 su kalite parametresi kullanılmıştır. Bu çalışmadaki kısıt; giriş verilerinin kısıtlı olduğundan dolayı parametrelere faktör analizi uygulanmamıştır.

Bu tarz bir çalışmada, suyun sahip olduğu kaliteyi etkileyen en temel parametrelerden biri olan çözünmüş oksijen, modelleme aracı olarak YSA yöntemi ile verimli bir şekilde modellenmiştir. Dicle nehrinin alt havzasında yer alan Dicle barajı ve Ongözlü köprü istasyonlarının her biri için on iki farklı model elde edilmiştir. Girdi olarak on dört su kalite parametresi kullanılmış olup, çıktı verisi olarak ise çözünmüş oksijene ait veriler üretilmiştir. Sonuçların yorumlanabilirliği açısından R^2 ile OKH ve OHM gibi katsayı ile hata değerleri hesaplanmıştır.

Dicle barajı istasyon noktası için OKH=0,370, OMH=0,382 ve R^2=0,779 ile determinasyon katsayısı 1'e en yakın olan model M2 modeli olmuştur. En başarılı çıkış verisini veren bu modelin mimarisi; İleri Beslemeli Geriye Yayılım Sinir Ağı, Levenberg – Marquardt backpropagation (trainlm) algoritması, Tangent Sigmoid aktivasyon fonksiyonu ve sinir ağındaki gizli nöron sayısının 5 olduğu yapıdan meydana gelmektedir. Böylece M2 modelinin tahmin değerleri ile gerçek çözünmüş oksijen verileri arasındaki paralellik öne çıkmıştır.

Ongözlü köprü istasyonu için hata değerleri en düşük olan OKH=0,426, OMH=0,298 ve R^2=0,873 ile en yüksek determinasyon katsayısını veren M1 modeli öne çıkmıştır. M1 yapı olarak; İleri Beslemeli Geri Yayılımlı Sinir Ağı, Levenberg – Marquardt backpropagation (trainlm) algoritması, sinir ağındaki gizli nöron sayısının 5 olduğu, aktivasyon fonksiyonu olarak ise logaritmik-Sigmoid kombinasyonundan elde edilmiştir.

Bu çalışma sonucunda, kısıtlı veri seti ile Dicle nehri alt havzası için çözünmüş oksijen tayini, yapay sinir ağı kullanılarak başarıyla modellenmiştir. Modelleme sonuçlarındaki hassasiyet ve hata oranları göz gönüne alındığında, yapay sinir ağlarının çözünmüş oksijen tayininde başarılı ve pratik bir araç olduğu ortaya çıkmaktadır. Farklı modelleme teknikleri kullanılarak da ÇO adına öngörüde bulunulabilir ancak YSA kimi yönleriyle daha üstün bir araç olup, özellikle veri seti konusunda avantajlı bir modelleyicidir. Genellikle veri setinin büyüklüğüne göre program sonuçların başarı oranı doğru orantılı olsa da, uygun yapı ve kombinasyon biçimiyle küçük bir veri kümesinden dahi YSA ile başarılı sonuçların edinilmesi mümkündür. Bu yönüyle YSA, modelleme aracı olarak son derece öne çıkan, faydalı ve sık kullanılan bir araçtır. Elde edilen R^2 ve hata değerleri, yapılan benzer çalışmalarla kıyaslanabilir nitelikte olup, üstün başarı oranı sağlamaktadır.

Sonraki araştırma ve uygulama çalışmalarına öneri olarak; bu çalışmada çözünmüş oksijen için modeller oluşturulmuş olsa da esasen sadece ÇO değil, diğer su kalite parametreleri de YSA ile başarıyla tahmin edilebilir. Su kütlesinin kullanım amacına bağlı olarak hangi parametrelerin önemi fazla ise, her biri için YSA'dan faydalanılarak tahmin çalışmaları yürütülebilir. Öte yandan oluşturulabilecek uygun modelleme yapıları ile sadece nehir suları ile kısıtlı kalınmadan, deniz ve okyanus gibi büyük su kütlelerinin kalite incelemesinde de YSA ile etkili sonuçlar elde edilebilir.

Ayrıca veri sayısının yani girdinin daha fazla olması durumunda, hedeflenen parametrelere dair daha iyi sonuçlar edinilebilir. Özellikle daha fazla parametre ile çalışıldığında; girdilere kendi aralarında faktör analizi yapılarak, çalışılan bölge için en etkili ve önemli girdiler belirlenip, modellemeler yapıldığında sonuçlara dair edinilen katsayı ve hata değerlerinde daha başarılı olunabilir.

Ek olarak, istasyon sayısındaki artış ile daha kapsamlı model sonuçları elde edilebilir. Bu çalışmada kullanılan eğim, test ve doğrulama yüzdelerindeki oranlar değiştirilerek, farklı başarı oranlarına sahip YSA yapıları denenebilir.

KAYNAKLAR

[1] Ç. Güler ve Z. Çobanoğlu, Su Kalitesi, Çevre Sağlığı Temel Kaynak Dizisi No: 43, Türkiye Cumhuriyeti Sağlık Bakanlığı, Sağlık Projesi Genel Koordinatörlüğü, 1997.

[2] I. Salihoğlu, "Giriş," Su Kirlenmesi ve Denetimi, DSİ Basım ve Foto-Film İşletme Müdürlüğü Matbaası, 1978, s.5.

[3] M. Daniels, T. Scott, B. Haggard, vd. "What Is Water Quality?," Agriculture and Natural Resources, FSA9528-PD-4-09N, 1914, s.1.

[4] E. Yenici, Havza Ölçeğinde Su Kalite Yönetimi: Büyük Menderes Nehir Havzası Örnek Çalışması, Yüksek Lisans Tezi, İstanbul: İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2010.

[5] B. A. Cox, "A review of currently available in-stream water-quality models and their applicability for simulating dissolved oxygen in lowland rivers," The Science of the Total Environment, c. 314, sayı 316, s. 335–377, 2003.

[6] H. W. Streeter ve E. B. Phelps, A Study of the Pollution and Natural Purification of the Ohio River, U.S. Department of Health , Education, & Welfare, 1958.

[7] O. Uslu ve A. Türkman, Su Kirliliği ve Kontrolü, T.C. Başbakanlık Çevre Genel Müdürlüğü Yayınları Eğitim Dizisi, 1987.

[8] *Suların Analiz Parametreleri 850CK0011*, T.C. Eğitim Bakanlığı Çevre Sağılığı, 2011. Erişim tarihi: 6 Aralık 2021. http://www.sandoramuhendislik.com/Cevre_Sagligi_Su_Analizi.pdf

[9] L. S. Clesceri, A. E. Greenberg ve A. D. Eaton, "Standard Methods for the Examination of Water and Wastewater," American Public Health Association, American Water Works Association, Water Environment Federation, 1999, s. 1351.

[10] G. Kıymaz, *Su Kalitesi Modellemesi,* T.C. Tarım ve Orman Bakanlığı, Su Yönetimi Genel Müdürlüğü, İzleme ve Su Bilgi Sistemi Dairesi Başkanlığı Modelleme Çalışma Grubu, 2019. Erişim tarihi: 6 Aralık 2021. https://www.tarimorman.gov.tr/SYGM/Belgeler/Su%20Kalitesi%20H%C4%B0E%20Haber%202019/Su%20Kalitesi%20Modellemesi.pdf

[11] H. Ucun Özel ve B. T. Gemici, "Bartın Irmağı Kirlilik Profilinin Fiziksel Parametrelerle Belirlenmesi," Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi, c. 7, sayı 1, 2016, s. 52-58.

[12] S. Kalaycı ve E. Kahya, "Susurluk Havzası Nehirlerinde Su Kalitesi Trendlerinin Belirlenmesi," Tr. J. of Engineering and Environmental Science, c. 22, 1998, s. 503-514.

[13] W. Wu, G. C. Dandy ve H. R. Maier, "Protocol for developing ANN models and its application to the assessment of the quality of the ANN model development process in drinking water quality modelling," Environmental Modelling & Software, c. 54, 2014, s. 108-127.

[14] L. Kalin, S. Isik, J. E. Schoonover vd. “Predicting Water Quality in Unmonitored Watersheds Using Artifi cial Neural Networks,” Journal of Environmental Quality, c.39, 2010, s. 1429-1440.

[15] M. Ismael, A. Mokhtar, M. Farooq vd. “Assessing drinking water quality based on physical, chemical and microbial parameters in the Red Sea State, Sudan using a combination of water quality index and artificial neural network model,” Groundwater for Sustainable Development, c. 14, 2021, s. 100612.

[16] A. Sarkar ve P. Pandey, “River Water Quality Modelling using Artificial Neural Network Technique,” Aquatic Procedia, c. 4, 2015, s. 1070-1077.

[17] A. Najah, A. El-Shafie ve O. A. Karim, “Application of artificial neural networks for water quality prediction,” Neural Comput & Applic, c. 22, 2013, s. 187-201.

[18] S. Chatterjee, S. Sarkar, N. Dey vd. "Water quality prediction: Multi objective genetic algorithm coupled artificial neural network based approach," 2017 IEEE 15th International Conference on Industrial Informatics (INDIN), 2017, s. 963-968.

[19] S. E. Kim ve l. W. Seo, “Artificial Neural Network ensemble modeling with conjunctive data clustering for water quality prediction in rivers,” Journal of Hydro-environment Research, c. 9, sayı 3, 2015, s. 325-339.

[20] O.C. Turgay, *Su Kirliliği*, Ankara Üniversitesi Açık Ders Malzemeleri, 2017. Erişim tarihi: 6 Aralık 2021. https://acikders.ankara.edu.tr/pluginfile.php/81430/mod_resource/content/0/5-6.%20Su%20kirlili%C4%9Fi.pdf

[21] A.A. M. Ahmed, “Prediction of dissolved oxygen in Surma River by biochemical oxygen demand and chemical oxygen demand using the artificial neural networks (ANNs),” Journal of King Saud University - Engineering Sciences, c. 29, sayı2, 2017, s. 151-158.

[22] A. Csábrági, S. Molnár, P. Tanos, József vd. “Estimation of dissolved oxygen in riverine ecosystems: Comparison of differently optimized neural networks,”Ecological Engineering, c. 138, 2019, s. 298-309.

[23] H. R. Maier ve G. C. Dandy, “Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications,”Environmental Modelling & Software, c. 15, sayı 1, 2000, s. 101-124.

[24] S. Palani, SY. Liong ve P. Tkalich, “An ANN application for water quality forecasting,” Marine Pollution Bulletin, c. 56, sayı 9, 2008, s. 1586-1597.

[25] M. Salari, E. S. Shahid, S. H. Afzali vd. “Quality assessment and artificial neural networks modeling for characterization of chemical and physical parameters of potable water,” Food and Chemical Toxicology, c. 118, 2018, s. 212-219.

[26] H. Elhatip ve M. Kömür, “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* , c. 53, 2008, s. 1157-1164.

[27] K. Singh, A. Basant, A. Malik vd. “Artificial Neural Network Modeling of the River Water Quality-A Case Study,” Ecological Modelling, c. 220, 2009, s. 888-895.

[28] E.N. Akbulut, S. Bayari, A. Akbulut ve Y. Şahin, "Rivers of Turkey," Rivers of Europa, In: K. Tockner, C.T. Robinson, U. Uehlinger (Eds.), Academic Press, New York, 2009, s. 643–672.

[29] Anonymous, "Mean Monthly Flow Values of the Tigris River in the Period 2008–2009," General Directorate of Electrical Power Resources Survey and Development Administration, Ankara, 2009.

[30] H. Yıldız, Yukarı Dicle Havzasında Su Kalitesinin Zenginleşme Faktörü Kullanılarak Zamana ve Mekana Bağlı Değişiminin İncelenmesi, Yüksek Lisans Tezi, Ankara: Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, 2013.

[31] G. Steyl, Application of Artificial Neural Networks in the Field of Geohydrology, Yüksek Lisans Tezi, Güney Afrika: University of the Free State, Institute of Groundwater Studies Faculty of Natural- and Agricultural Sciences, 2009.

[32] *Yapay Sinir Ağları Hakkında*. Erişim tarihi: 6 Haziran 2021. http://www.akademiya payzeka.com/DesktopDefault.aspx?tabindex=4&tabid=4

[33] S.-C. Wang, Interdisciplinary Computing in Java Programming, Kluwer Academic Publishers, 2003.

[34] R. Beale ve T. Jackson, Neural Computing: An Introduction, Adam Hilger imprint by IOP Publishing Ltd Techno House, 1990.

[35] H. Ergezer, M. Dikmen ve E. Özdemir, "Yapay Sinir Ağları Ve Tanıma Sistemleri," Pivolka, c. 2, sayı 6, 2003, s. 14-17.

[36] S. Fogelman, H. Zhao, M. Blumenstein vd. "Estimation of oxygen demand levels using UV-Vis spectroscopy and artificial neural networks as an effective tool for real-time, wastewater treatment control", Sydney, Australia: 1st Australian Young Water Professionals Conference, Proceedings of the 1st Australian Young Water Professionals Conference, (s. 15-17), 2006.

[37] S. Açıkalın, Estimation of Efficiency Urban Wastewater Treatment Plant by Artificial Neural Network, Yüksek Lisans Tezi, Sakarya: Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, 2007.

[38] G. Dreyfus, J.-M. Martinez, M. Samuelides vd. "Reseaux de Neurones: Methodologie et Applications," Editions Eyrolles, Paris, France, 2002.

[39] E. Öztemel, Yapay Sinir Ağları, Papatya Yayıncılık, 2006.

[40] M. O. Öğücü, Yapay Sinir Ağları ile Sistem Tanıma, Yüksek Lisans Tezi, İstanbul: İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2006.

[41] M. Yetkin, Tanker Şamandıra Bağlama Sistemlerinin Yapay Sinir Ağları Tekniğiyle Optimizasyonu, Yüksek Lisans Tezi, İstanbul: İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2014.

[42] M.L. Minsky ve S. Papert, Perceptrons, MA: MIT Press, Cambridge, 1969.

[43] D. Silverman ve J. A. Dracup, "Artificial Neural Networks and Long-Range Precipitation Prediction in California," Journal of Applied Meteorology, c. 39, sayı 1, 2000, s. 57-66.

[44] O. Taşova, Yapay Sinir Ağları ile Yüz Tanıma, Yüksek Lisans Tezi, İzmir: Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, 2011.

[45] Ç. Elmas, Yapay Sinir Ağları, Seçkin Yayıncılık, Ankara, 2003.

[46] S. Yavuz ve M. Deveci, "İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi," Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, sayı 40, 2012, s.167-187.

[47] H. Yurtoğlu, Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler için Türkiye Örneği, Uzmanlık Tezi, DPT Uzmanlık Tezleri, Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü, 2005.

[48] Ç. Elmas, Yapay Zekâ Uygulamaları, Seçkin Yayıncılık, Ankara, 2010.

[49] B. Tunca, Tip II Regresyona Yapay Sinir Ağları Yaklaşımı, Yüksek Lisans Tezi, Afyon: Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, 2019.

[50] E. Kabalcı, *Yapay Sinir Ağları (Artificial Neural Networks),* 2015. Erişim Tarihi: 8 Aralık 2021. https://ekblc.files.wordpress.com/2014/02/ysa.pdf

[51] A. Bayram, Harşit Çayı Su Kalitesinin Mevsimsel Değişiminin İncelenmesi ve Askı Madde Konsantrasyonunun Yapay Sinir Ağları Yöntemi ile Tahmin Edilmesi, Doktora Tezi, Trabzon: Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2011.

[52] K. Suzuki, Artificial Neural Networks – Methodological Advances and Biomedical Applications, Published by InTech, 2011.

[53] M. Ö. Efe ve O. Kaynak, Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi, İstanbul, 2000.

[54] D. Aşkın, İ. İskender ve A. Mamizadeh, "Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformatör Sargısının Termal Analizi," Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, c. 26, sayı 4, 2011, s. 905-913.

[55] O. I. Abiodun, A. Jantan, A. E. Omolara vd. "Comprehensive Review of Artificial Neural Network Applications to Pattern Recognition," In IEEE Access, c. 7, 2019, s. 158820-158846.

[56] D. S. Broomhead ve D. Lowe, Radial Basis Functions, Multi-Variable Functional Interpolation and Adaptive Networks, Controller HMSO, London, 1988.

[57] S. L. Brunton ve J. N. Kutz, "Chapter 6: Neural Networks and Deep Learning," Data-Driven Science and Engineering: Machine Learning, Dynamical Systems, and Control, Cambridge University Press, 2019, s. 227-291.

[58] Y.-S. Park ve S. Lek, "Artificial Neural Networks: Multilayer Perceptron for Ecological Modeling," Ecological Model Types, Candice Janco-Elsevier, 2016, s. 123-140.

[59] Ö. Asilkan ve S. Irmak, "İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları İle Tahmin Edilmesi," Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, c. 14, sayı 2, 2009, s. 375-391.

[60] S. Haykin, Neural networks : a comprehensive foundation, Prentice Hall, New Jersey, 1999.

[61] G. Dede, Yapay Sinir Ağları ile Konuşma Tanıma, Yüksek Lisans Tezi, Ankara: Ankara Üniversitesi, Fen Bilimleri Enstitüsü, 2008.

[62] M. Erler, E. Beşdok ve Ş. Sağıroğlu, "Mühendislikte Yapay Zeka Uygulamaları-I: Yapay Sinir Ağları," Ufuk Kitabevi, 2003.

[63] F. Adıyaman, Talep tahmininde yapay sinir ağlarının kullanılması, Yüksek Lisans Tezi, İstanbul: İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2007.

[64] E. Güreşen, Dinamik yapay sinir ağları sistemi önerisi, Doktora Tezi, İstanbul: İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2014.

[65] F. Bayır, Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama, Yüksek Lisans Tezi, İstanbul: İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, 2006.

[66] R. Kurt, S. Karayılmazlar, E. İmren vd. "Yapay Sinir Ağları İle Öngörü Modellemesi: Türkiye Kâğıt-Karton Sanayi Örneği," Bartın Orman Fakültesi Dergisi, c. 19, sayı 2, 2017, s. 99-106.

[67] A. L. Edelen ve D. Edstrom, "Neural Networks for Modeling and Control of Particle Accelerators," In IEEE Transactions on Nuclear Science, c. 63, s. 2, 2016, s. 878-897.

[68] Y. Kaya, Türk Telekomünikasyon A.Ş.'de elektrik enerjisi tüketiminin yapay sinir ağları ile yerel tahmini, Yüksek Lisans Tezi, İstanbul: Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2010.

[69] D. R. Hush ve B. G. Horne, "Progress in Supervised Neural Networks," In IEEE Signal Processing Magazine, c. 10, sayı 1, 1993, s. 8-39.

[70] P. Bayru, Elektronik Basında Tüketici Tercihleri Analizi: Yapay Sinir Ağları ile Lojit Modelin Performans Değerlendirilmesi, Doktora Tezi, İstanbul: İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, 2007.

[71] T. Sancaktar, Ysa Destekli Kalman Filtresi İle Hedef İzleme, Yüksek Lisans Tezi, İstanbul: İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2002.

[72] G. Doğan, Yapay Sinir Ağları Kullanılarak Türkiye'deki Özel Bir Sigorta Şirketinde Portföy Değerlendirmesi, Yüksek Lisans Tezi, Ankara: Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, 2010.

[73] S. G. Jiménez, Multilayer neural networks: learning models and applications, Doktora Tezi, Spain: Universitat de Barcelona, Departament d'Estructura i Constituents de la Mat` eria, 1994.

[74] E. Kuriscak, P. Marsalek, J. Stroffek vd. "Biological context of Hebb learning in artificial neural networks, a review," Neurocomputing, c. 152, 2015, s. 27-35.

[75] A. Moumin, Yapay Sinir Ağları ve Genetik Algoritmaların Uçuş Kontrol Sistemlerine Uygulanması, Yüksek Lisans Tezi, İstanbul: İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 1995.

[76] J. M. Zurada, Introduction to Artificial Neural Systems, By West Publishing Company, 1992.

[77] G. O. Stone, "An Analysis of the Delta Rule and the Learning of Statistical Associations," Parallel Distributed Processing: Explorations in the Microstructure of Cognition, MIT Press, 1986, s. 444-459.

[78] H. Chen ve Q. Lian, "Poverty/investment Slow Distribution Effect Analysis Based On Hopfield Neural Network," Future Generation Computer Systems, c. 122, sayı 11, 2021, s. 63-68.

[79] C. Zhang, G. Dangelmayr ve I. Oprea, "Storing cycles in Hopfield-type networks with pseudoinverse learning rule: Admissibility and network topology," Neural Networks, c. 46, 2013, s. 283-298.

[80] H. Korn ve P. Faure, Is there chaos in the brain? II. Experimental evidence and related models," Comptes Rendus Biologies, c. 326, sayı 9, 2003, s. 787-840.

[81] J. M. Bishop and R. J. Mitchell, "Neural networks-an introduction," IEE Colloquium on Neural Networks for Systems: Principles and Applications, (s. 1/1-1/3), 1991.

[82] H. Demuth ve M. Beale, Neural Network Toolbox User's Guide, by The MathWorks, Inc, 2000.

[83] D. Kriesel, *A Brief Introduction to Neural Networks*, 2007. Erişim Tarihi: 6 Aralık 2021. https://www.dkriesel.com/_media/science/neuronalenetze-en-zeta2-2col-dkrieselcom.pdf

[84] I. Ozsahin ve D. Ozsahin, "Neural Network Applications in Medicine," Biomedical Signal Processing and Artificial Intelligence in Healthcare, Academic Press publications, 2020, s. 183-206.

[85] İ. Gör, "Çok Katmanlı Algılayıcı Yapay Sinir Ağı ile Lineer Diferansiyel Denklem Sisteminin Çözümü," 18. Akademik Bilis¸im Konferansı, 2016.

[86] S. Amin, "Backpropagation – Artificial Neural Network (BP-ANN): Understanding gender characteristics of older driver accidents in West Midlands of United Kingdom," Safety Science, c. 122, 2019.

[87] X. Han, Z. Wei, B. Zhang vd. "Crop evapotranspiration prediction by considering dynamic change of crop coefficient and the precipitation effect in back-propagation neural network model," Journal of Hydrology, c. 596, 2021.

[88] J. W. Zhou, Y. S. Wei, J. Qin vd. "MATLAB application in mathematical modeling," 1st ed. Beijing: Beihang University Press, 2011.

[89] H. P. Gavin, "The Levenberg-Marquardt algorithm for nonlinear least squares curve-fitting problems," Department of Civil and Environmental Engineering, Duke University, s. 1-19, 2020.

[90] A. Ranganathan, *The Levenberg-Marquardt Algorithm*, Honda Research Institute USA, 2004. Erişim tarihi: 6 Aralık 2021. https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.135.865&rep=rep1&type=pdf

[91] S. M. A. Burney, T. Jilani ve C. Ardil, “Levenberg-Marquardt Algorithm for Karachi Stock Exchange Share Rates Forecasting,” International Journal of Computational Intelligence, c. 1, sayı 3, 2005, s. 144-149.

[92] B. Yılmaz, “Maliyet Fonksiyonun Belirlenmesinde Yapay Sinir Ağı Modellerinin Kullanımı,” Muhasebe ve Finansman Dergisi, s. 329-344, 2019.

[93] Y. Gönül, Ş. Ulu, A. Bucak vd. “Yapay sinir ağları ve klinik araştırmalarda kullanımı,” Genel Tıp Dergisi, c. 25, 2015, s. 104-111.

[94] G. Akkaya, “Yapay Sinir Ağları ve Tarım Alanındaki Uygulamaları,” Atatürk Üniversitesi Ziraat Fakültesi, c. 38, sayı 2, s. 195-202, 2007.

[95] T. Jayalakshmi ve A. Santhakumaran, “Statistical Normalization and Back Propagation for Classification,” International Journal of Computer Theory and Engineering, c. 3, sayı 1, 2011, s. 89-93.

[96] Ü. Şenol ve Z. Musayev, “Rüzgar Enerjisinden Elektrik Üretiminin Yapay Sinir Ağları İle Tahmini,” Bilge Uluslararası Fen ve Teknoloji Araştırmaları Dergisi, c. 1, sayı 1, 2017, s. 23-31.

[97] DSİ, “Su Kalitesi Analiz Değerleri (Yayınlanmamış 2011-2015 Yıllarına Ait Veriler),” Diyarbakır, Devlet Su İşleri 10. Bölge Müdürlüğü Laboratuvarı.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyad, Ad:	Kılavuz, Duçem M.
Web sayfası (Research Gate, Academia, vs.)	

Eğitim Bilgileri

Derece	Kurum	Mezuniyet Yılı
Yüksek Lisans	Dicle Üniversitesi	2022
Lisans	İstanbul Teknik Üniversitesi	2019
Lise	Selahaddini Eyyübi Anadolu Lisesi	2014

İş Deneyimi

Dönem (Yıl)	Şirket, Kurum	Görev
2020-Devam ediyor	Hakkari Üniversitesi	Araştırma Görevlisi

Yabancı Dil

İngilizce, ileri düzey

Yayınlar

1.

2.

3.

4.

Özel İlgiler

Müzik, Felsefe

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ BENZERLİK BİLDİRİMİ FORMU

Öğrencinin Adı, Soyadı	Duçem Medya KILAVUZ		
Öğrenci No	19806003		
Ana Bilim Dalı	Hidrolik ve Su Kaynakları Mühendisliği		
Program Türü	Proje ☐	Yüksek Lisans ☒	Doktora ☐
Tez Danışmanı (Ünvanı, Adı, Soyadı)	Prof. Dr. Fevzi ÖNEN		
(Varsa) II. Tez Danışmanı (Ünvanı, Adı, Soyadı)			
Tez Başlığı	Dicle Nehrinde Çözünmüş Oksijen Derişiminin Yapay Sinir Ağlarıyla Modellenmesi		
RAPOR BİLGİLERİ			
Raporlama Aşaması	Tez Savunma Sınavı Öncesi		
Sayfa Sayısı	87		
Raporlama Tarihi	22/04/2022		
Benzerlik Oranı (%)	%8		

Yukarıda bilgileri verilen tez çalışmamın toplam 87 sayfalık kısmına ilişkin, 22/04/2022 tarihinde tez danışmanım tarafından Turnitin isimli intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı %8 olarak tespit edilmiştir.

Uygulanan filtrelemeler:

☐Başlangıç Bölümleri (Kabul ve Onay sayfası, Teşekkür sayfası, Özet/Abstract) hariç

☐Kaynaklar hariç

☐Alıntılar dâhil

☒Diğer (Her şey dahil)

Tezimin benzerlik oranı, Dicle Üniversitesi Fen Bilimleri Enstitüsü İntihal Raporu Uygulama Esaslarında belirtilen üst sınır benzerlik oranını aşmamaktadır. Benzerlik oranım üst sınır benzerlik oranının altında olsa dahi aksinin tespit edilmesi durumunda her türlü yasal sorumluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu bildirir, gereğini arz ederim.

Öğrencinin Adı, Soyadı: Duçem Medya KILAVUZ
Tarih: 26/04/2022
İmza:

Danışman Adı, Soyadı: Prof. Dr. Fevzi ÖNEN İmza:

Tarih: 26/04/2022

Ana Bilim Dalı Başkanı Adı, Soyadı: Prof. Dr. Z. Fuat TOPRAK İmza:

Tarih: 26/04/2022