

T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

**İZNİK GÖLÜ SU KALİTE PARAMETRELERİNİN  
YAPAY SİNİR AĞLARI YÖNTEMİ İLE  
DEĞERLENDİRİLMESİ**

**YÜKSEK LİSANS TEZİ**

**Edanur KAYA**

**Enstitü Anabilim Dalı : ÇEVRE MÜHENDİSLİĞİ**  
**Tez Danışmanı : Dr. Öğr. Üyesi Berna KIRIL MERT**

**Haziran 2022**

T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

**İZNİK GÖLÜ SU KALİTE PARAMETRELERİNİN  
YAPAY SINIR AĞLARI YÖNTEMİ İLE  
DEĞERLENDİRİLMESİ**

**YÜKSEK LİSANS TEZİ**

**Edanur KAYA**

**Enstitü Anabilim Dalı : ÇEVRE MÜHENDİSLİĞİ**

**Bu tez 27/06/2022 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.**

## **BEYAN**

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Edanur KAYA

19.05.2022

## **TEŐEKKÜR**

Yüksek lisans eğitiminin boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Dr. Öğr. Üyesi Berna KIRIL MERT'e ve desteklerini esirgemeyen Prof. Dr. Taner YONAR, Arş. Gör. Nihan ÖZENGİN'e teşekkürlerimi sunarım.

Tüm hayatım boyunca her konuda bana destek olan, maddi ve manevi desteklerini esirgemeyen, bugünlere gelmemi sağlayan canım annem Semra KAYA'ya, teşekkür ederim.

Yüksek lisans eğitiminin boyunca bana her koşulda destek sağlayan değerli arkadaşım Deniz KASAPOĞULLARI'na teşekkür ederim.

## İÇİNDEKİLER

|                                       |      |
|---------------------------------------|------|
| TEŞEKKÜR .....                        | i    |
| İÇİNDEKİLER .....                     | ii   |
| SİMGELER VE KISALTMALAR LİSTESİ ..... | v    |
| ŞEKİLLER LİSTESİ .....                | viii |
| TABLolar LİSTESİ .....                | xi   |
| ÖZET .....                            | xii  |
| SUMMARY .....                         | xiii |

### BÖLÜM 1.

|            |   |
|------------|---|
| GİRİŞ..... | 1 |
|------------|---|

### BÖLÜM 2.

|   |    |
|---|----|
| KAYNAK ARAŞTIRMASI .....  | 3  |
| 2.1. İznik Gölü Genel Bilgi .....   | 3  |
| 2.2. Su Kalitesinde Önemli Parametreler ve Su Kirliliği Kontrolü<br>Yönetmeliği ..... | 4  |
| 2.3. İznik Gölü Su Kirliliği Kaynakları .....   | 7  |
| 2.4. Yapay Sinir Ağları (YSA) .....   | 8  |
| 2.4.1. Genel bilgi .....  | 8  |
| 2.4.2. YSA'nın tanımı .....   | 9  |
| 2.4.3. Yapay sinir ağlarının özellikleri .....  | 10 |
| 2.4.4. YSA'nın yapısı .....   | 11 |
| 2.4.5. Ağ Yapılarına Göre Yapay Sinir Ağları .....                                    | 14 |
| 2.4.5.1. İleri beslemeli yapay sinir ağları .....                                     | 14 |
| 2.4.5.2. Geri beslemeli yapay sinir ağları .....                                      | 15 |
| 2.4.6. YSA'da ağ yapısı seçimi .....  | 16 |
| 2.4.7. Yapay sinir ağlarında öğrenme .....  | 17 |

|   |    |
|---|----|
| 2.4.8. Yapay sinir ağlarında öğrenme algoritmaları .....  | 18 |
| 2.4.8.1. Danışmanlı öğrenme .....   | 18 |
| 2.4.8.2. Danışmansız öğrenme .....  | 19 |
| 2.4.8.3. Destekleyici öğrenme .....   | 19 |
| 2.4.9. Öğrenme algoritmasının seçimi .....  | 20 |
| 2.4.10. Yapay sinir ağlarında ileri besleme geri yayılım algoritması .                                      | 21 |
| 2.4.11. YSA uygulamaları ve kullanım alanları .....   | 22 |
| 2.4.12. Yapay sinir ağı avantajları .....   | 24 |
| 2.5. Yapay Sinir Ağlarında Su Kalitesi İzlenmesi .....  | 25 |
| 2.6. Türkiye’de ve Dünya’da Su Kaynaklarında Su Kalitesinin Yapay Sinir Ağları İle Tahmin Çalışmaları ..... | 26 |

### BÖLÜM 3.

|   |    |
|---|----|
| MATERYAL VE YÖNTEM .....  | 32 |
| 3.1. Materyal .....   | 32 |
| 3.2. Yöntem .....   | 32 |
| 3.2.1. Su kalitesi verilerinin değerlendirilmesi .....                              | 32 |
| 3.2.2. İznik Gölü’nün su taşıyan ve uzaklaştıran dereler .....                      | 34 |
| 3.2.2.1. İznik Gölü’ne giriş yapan dereler .....                                    | 35 |
| 3.2.2.2. İznik Gölü çıkış deresi .....  | 35 |
| 3.2.3. Derelere ait ölçüm noktaları verileri .....                                  | 36 |
| 3.2.3.1. İznik Gölü giriş noktalarının yıllık ortalama ölçüm verileri .....         | 36 |
| 3.2.3.2. İznik Gölü çıkış noktasının yıllık ortalama ölçüm verileri .....           | 39 |
| 3.2.4. İznik Gölü için kullanılan parametrelerin dereler bazında kıyaslanması ..... | 39 |
| 3.2.4.1. pH .....   | 40 |
| 3.2.4.2. İletkenlik (EC) .....  | 40 |
| 3.2.4.3. Biyolojik oksijen ihtiyacı (BOİ) .....                                     | 41 |
| 3.2.4.4. Fosfat (PO <sub>4</sub> P) .....   | 42 |
| 3.2.4.5. Sıcaklık (T) .....   | 43 |

|  |    |
|--|----|
| 3.2.4.6. Çözünmüş oksijen (ÇO) .....   | 44 |
| 3.2.4.7. Kimyasal oksijen ihtiyacı (KOİ) .....                                   | 45 |
| 3.2.4.8. Nitrat azotu (NO <sub>3</sub> N) .....                                  | 46 |
| 3.2.4.9. Nitrit azotu (NO <sub>2</sub> N) .....                                  | 47 |
| 3.2.4.10. Toplam fosfor ve toplam azot (TP,TN) .....                             | 48 |
| <br>   |    |
| BÖLÜM 4.   |    |
| ARAŞTIRMA BULGULARI .....  | 51 |
| 4.1. Sölöz Deresi için Yapılan YSA Modelleri ve R <sup>2</sup> Grafikleri .....  | 52 |
| 4.2. Olukdere için Yapılan YSA Modelleri ve R <sup>2</sup> Grafikleri .....      | 60 |
| 4.3. Karasu Deresi için Yapılan YSA Modelleri ve R <sup>2</sup> Grafikleri ..... | 68 |
| 4.4. Kırandere için Yapılan YSA Modelleri ve R <sup>2</sup> Grafikleri .....     | 76 |
| <br>   |    |
| BÖLÜM 5.   |    |
| TARTIŞMA VE SONUÇ .....  | 84 |
| <br>   |    |
| KAYNAKLAR .....  | 86 |
| ÖZGEÇMİŞ .....   | 94 |

## SİMGELER VE KISALTMALAR LİSTESİ

|                  |  |
|------------------|--|
| °C               | : Derece Santigrat                               |
| AAT              | : Atıksu Arıtma Tesisi                           |
| ABD              | : Amerika Birleşik Devletleri                    |
| AKM              | : Askıda Katı Madde                              |
| ANFIS            | : Adaptive-Network Based Fuzzy Inference Systems |
| ANN              | : Artificial Neural Network                      |
| ART              | : Adaptif Rezonans Teori                         |
| BOİ              | : Biyolojik Oksijen İhtiyacı                     |
| BUSKİ            | : Bursa Su ve Kanalizasyon İdaresi               |
| Ca               | : Kalsiyum                                       |
| CC               | : Korelasyon Katsayısı                           |
| CE               | : Verimlilik Korelasyonu                         |
| Cl               | : Klor   |
| Cu               | : Bakır  |
| ÇKA              | : Çok Katmanlı Ağ                                |
| ÇO               | : Çözünmüş Oksijen                               |
| EC               | : Elektriksel Kondüktivite                       |
| EEG              | : Elektroensefalografi                           |
| Fe               | : Demir  |
| HCO <sub>3</sub> | : Bikarbonat                                     |
| K                | : Potasyum                                       |
| KM               | : Katı Madde                                     |
| km               | : Kilometre                                      |
| km <sup>2</sup>  | : Kilometre Kare                                 |
| KOİ              | : Kimyasal Oksijen İhtiyacı                      |
| LVQ              | : Learning vector quantization                   |



|                    |   |
|--------------------|---|
| m                  | : Metre                                       |
| MAE                | : Mean Absolute Error                         |
| MATLAB             | : Matrix Laboratory                           |
| Mg                 | : Magnezyum                                   |
| Mg/l               | : Miligram/litre                              |
| MLP                | : Multilayer Perceptron                       |
| MLR                | : The Multiple Linear Regression              |
| Mn                 | :Mangan                                       |
| MR                 | : Emar  |
| Na                 | : Sodyum                                      |
| NH <sub>3</sub> N  | : Amonyak Azotu                               |
| Ni                 | :Nikel  |
| NO <sub>2</sub> N  | : Nitrit Azotu                                |
| NO <sub>3</sub> N  | : Nitrat Azotu                                |
| NTU                | : Nephelometric Turbidity Unit                |
| P                  | : Fosfor                                      |
| Pb                 | : Kurşun                                      |
| pH                 | : Potansiyel Hidrojen                         |
| PO <sub>4</sub> -P | : Fosfat                                      |
| R <sup>2</sup>     | :Belirlilik Kat Sayısı                        |
| RBN                | : Radial Based Network                        |
| RMSE               | : Root Mean Square Error                      |
| S                  | : Katı  |
| SKKY               | : Su Kirliliği Kontrol Yönetmeliği            |
| SO <sub>4</sub>    | : Sülfat                                      |
| SPSS               | : Statistical Package for The Social Sciences |
| SS                 | : Su Sıcaklığı                                |
| SSE                | : Sum of Squared Error                        |
| T                  | : Sıcaklık                                    |
| TÇK                | : Toplam Çözünmüş Katı                        |
| TKM                | : Toplam Katı Madde                           |
| TN                 | : Toplam Azot                                 |

|      |  |
|------|--|
| TP   | : Toplam Fosfor                              |
| TS   | : Toplam Sertlik                             |
| WEKA | : Waikato Environment for Knowledge Analysis |
| WHO  | : World Health Organization                  |
| WQI  | : Water Quality Index                        |
| YSA  | : Yapay Sinir Ađı                            |
| YZ   | : Yapay Zeka                                 |
| Zn   | : inko                                      |

## ŞEKİLLER LİSTESİ

|   |    |
|---|----|
| Şekil 2.1. İznik Gölü havzası hidrografya haritası .....  | 4  |
| Şekil 2.2. Yapay sinir ağı hücresi gösterimi .....  | 12 |
| Şekil 2.3. Üç katmanlı yapay sinir ağı (YSA) mimarisi .....                                     | 13 |
| Şekil 2.4. Çok katmanlı yapay sinir ağı .....   | 14 |
| Şekil 2.5. İleri beslemeli bir YSA mimarisi .....   | 15 |
| Şekil 2.6. Geri beslemeli yapay sinir ağı mimarisi .....  | 15 |
| Şekil 2.7. Danışmanlı öğrenme yapısı .....  | 18 |
| Şekil 2.8. Danışmansız öğrenme yapısı .....   | 19 |
| Şekil 2.9. Destekleyici öğrenme yapısı .....  | 20 |
| Şekil 2.10. Çok katmanlı ileri beslemeli sinir ağı .....  | 22 |
| Şekil 3.1. İznik Gölü uydu görüntüsü .....  | 34 |
| Şekil 3.2. Analiz noktalarının 2017-2021 yıllarına ait ortalama pH verileri .....               | 40 |
| Şekil 3.3. Analiz noktalarının 2017-2021 yıllarına ait ortalama iletkenlik verileri ..          | 41 |
| Şekil 3.4. Analiz noktalarının 2017-2021 yıllarına ait ortalama BOİ verileri .....              | 42 |
| Şekil 3.5. Analiz noktalarının 2017-2021 yıllarına ait ortalama fosfat verileri .....           | 43 |
| Şekil 3.6. Analiz noktalarının 2017-2021 yıllarına ait ortalama sıcaklık verileri ..            | 44 |
| Şekil 3.7. Analiz noktalarının 2017-2021 yıllarına ait ortalama ÇO verileri .....               | 45 |
| Şekil 3.8. Analiz noktalarının 2017-2021 Yıllarına Ait Ortalama KOİ Verileri ...                | 46 |
| Şekil 3.9. Analiz noktalarının 2017-2021 yıllarına ait ortalama NO <sub>3</sub> N verileri .... | 47 |
| Şekil 3.10. Analiz noktalarının 2017-2021 yıllarına ait ortalama NO <sub>2</sub> N verileri ..  | 48 |
| Şekil 3.11. Analiz noktalarının 2017-2021 yıllarına ait ortalama TP verileri .....              | 49 |
| Şekil 3.12. Analiz noktalarının 2017-2021 yıllarına ait ortalama TN verileri .....              | 50 |
| Şekil 4.1. Sölöz, TN parametresi için oluşturulan 6-4-1 ysa modeli .....                        | 52 |
| Şekil 4.2. Sölöz, TN parametresi R <sup>2</sup> grafiği .....                                   | 53 |
| Şekil 4.3. Sölöz, TP parametresi için oluşturulan 6-3-1 YSA modeli .....                        | 53 |
| Şekil 4.4. Sölöz, TP parametresi R <sup>2</sup> grafiği .....                                   | 54 |
| Şekil 4.5. Sölöz, ÇO parametresi için oluşturulan 5-2-1 YSA model 1 .....                       | 55 |

|   |    |
|---|----|
| Şekil 4.6. Sölöz, ÇO parametresi model 1 R <sup>2</sup> grafiği .....         | 55 |
| Şekil 4.7. Sölöz, ÇO parametresi için oluşturulan 7-4-1 YSA model 2 .....     | 56 |
| Şekil 4.8. Sölöz, ÇO parametresi model 2 R <sup>2</sup> grafiği .....         | 56 |
| Şekil 4.9. Sölöz, ÇO parametresi için oluşturulan 6-2-1 YSA model 3 .....     | 57 |
| Şekil 4.10. Sölöz, ÇO parametresi model 3 R <sup>2</sup> grafiği .....        | 57 |
| Şekil 4.11. Sölöz, ÇO parametresi için oluşturulan 6-4-1 YSA model 4 .....    | 58 |
| Şekil 4.12. Sölöz, ÇO parametresi model 4 R <sup>2</sup> grafiği .....        | 58 |
| Şekil 4.13. Olukdere, TN parametresi için oluşturulan 6-1-1 YSA modeli .....  | 60 |
| Şekil 4.14. Olukdere, TN parametresi R <sup>2</sup> grafiği .....             | 61 |
| Şekil 4.15. Olukdere, TP parametresi için oluşturulan 6-4-1 YSA modeli .....  | 61 |
| Şekil 4.16. Olukdere, TP parametresi R <sup>2</sup> grafiği .....             | 62 |
| Şekil 4.17. Olukdere, ÇO parametresi için oluşturulan 7-4-1 YSA model 1 ..... | 63 |
| Şekil 4.18. Olukdere, ÇO parametresi model 1 R <sup>2</sup> grafiği .....     | 63 |
| Şekil 4.19. Olukdere, ÇO parametresi için oluşturulan 5-3-1 YSA model 2 ..... | 64 |
| Şekil 4.20. Olukdere, ÇO parametresi model 2 R <sup>2</sup> grafiği .....     | 64 |
| Şekil 4.21. Olukdere, ÇO parametresi için oluşturulan 7-4-1 YSA model 3 ..... | 65 |
| Şekil 4.22. Olukdere, ÇO parametresi model 3 R <sup>2</sup> grafiği .....     | 65 |
| Şekil 4.23. Olukdere, ÇO parametresi için oluşturulan 6-4-1 YSA model 4 ..... | 66 |
| Şekil 4.24. Olukdere, ÇO parametresi model 4 R <sup>2</sup> grafiği .....     | 66 |
| Şekil 4.25. Karasu, TN parametresi için oluşturulan 6-2-1 YSA modeli .....    | 68 |
| Şekil 4.26. Karasu, TN parametresi R <sup>2</sup> grafiği .....               | 69 |
| Şekil 4.27. Karasu, TP parametresi için oluşturulan 6-3-1 YSA modeli .....    | 69 |
| Şekil 4.28. Karasu, TP parametresi R <sup>2</sup> grafiği .....               | 70 |
| Şekil 4.29. Karasu, ÇO parametresi için oluşturulan 5-1-1 YSA model 1 .....   | 71 |
| Şekil 4.30. Karasu, ÇO parametresi model 1 R <sup>2</sup> grafiği .....       | 71 |
| Şekil 4.31. Karasu, ÇO parametresi için oluşturulan 6-4-1 YSA model 2 .....   | 72 |
| Şekil 4.32. Karasu, ÇO parametresi model 2 R <sup>2</sup> grafiği .....       | 72 |
| Şekil 4.33. Karasu, ÇO parametresi için oluşturulan 7-3-1 YSA model 3 .....   | 73 |
| Şekil 4.34. Karasu, ÇO parametresi model 3 R <sup>2</sup> grafiği .....       | 73 |
| Şekil 4.35. Karasu, ÇO parametresi için oluşturulan 6-4-1 YSA model 4 .....   | 74 |
| Şekil 4.36. Karasu, ÇO parametresi model 4 R <sup>2</sup> grafiği .....       | 74 |
| Şekil 4.37. Kırandere, TN parametresi için oluşturulan 6-3-1 YSA modeli ..... | 76 |

|  |    |
|--|----|
| Şekil 4.38. Kırandere, TN parametresi $R^2$ grafiği .....                      | 77 |
| Şekil 4.39. Kırandere, TN parametresi için oluşturulan 6-2-1 YSA modeli .....  | 77 |
| Şekil 4.40. Kırandere, TP parametresi $R^2$ grafiği .....                      | 78 |
| Şekil 4.41. Kırandere, ÇO parametresi için oluşturulan 7-4-1 YSA model 1 ..... | 79 |
| Şekil 4.42. Kırandere, ÇO parametresi model 1 $R^2$ grafiği .....              | 79 |
| Şekil 4.43. Kırandere, ÇO parametresi için oluşturulan 5-3-1 YSA model 2 ..... | 80 |
| Şekil 4.44. Kırandere, ÇO parametresi model 2 $R^2$ grafiği .....              | 80 |
| Şekil 4.45. Kırandere, ÇO parametresi için oluşturulan 6-4-1 YSA model 3 ..... | 81 |
| Şekil 4.46. Kırandere, ÇO parametresi model 3 $R^2$ grafiği .....              | 81 |
| Şekil 4.47. Kırandere, ÇO parametresi için oluşturulan 6-4-1 YSA model 4 ..... | 82 |
| Şekil 4.48. Kırandere, ÇO parametresi model 4, $R^2$ grafiği .....             | 82 |

## TABLULAR LİSTESİ

|  |    |
|--|----|
| Tablo 2.1. Su kalitesi deęişkenlerine ilişkin temel bilgiler .....           | 4  |
| Tablo 2.2. Kıtaiçi su kaynaklarının sınıflarına göre kalite kriterleri ..... | 6  |
| Tablo 2.3. Su kirlilik açısından sınıf deęerleri .....                       | 6  |
| Tablo 2.4. Ağ türleri ve başarılı oldukları alanlar .....                    | 16 |
| Tablo 2.5. Öğrenme algoritmaları ve uygulandıkları alanlar .....             | 20 |
| Tablo 3.1. Sölöz Deresi 2017-2021 yılları analiz ölçüm ortalamaları .....    | 36 |
| Tablo 3.2. Kırandere 2017-2021 yılları analiz ölçüm ortalamaları .....       | 37 |
| Tablo 3.3. Karasu Deresi 2017-2021 yılları analiz ölçüm ortalamaları .....   | 37 |
| Tablo 3.4. Olukdere 2017-2021 yılları analiz ölçüm ortalamaları .....        | 38 |
| Tablo 3.5. Karsak Deresi 2017-2021 yılları analiz ölçüm ortalamaları .....   | 39 |
| Tablo 4.1. Sölöz, YSA model performans deęerleri özet tablosu .....          | 59 |
| Tablo 4.2. Olukdere, YSA model performans deęerleri özet tablosu .....       | 67 |
| Tablo 4.3. Karasu, YSA model performans deęerleri özet tablosu .....         | 75 |
| Tablo 4.4. Kırandere, YSA model performans deęerleri özet tablosu .....      | 83 |

## ÖZET

Anahtar kelimeler: İznik Gölü, su kalitesi, su parametresi, yapay sinir ağıları

Göllerin planlanması ve yönetiminde su kalitesi parametrelerinin izlenmesi önemlidir. Bu çalışma da 2017-2021 yılları için İznik Gölü'ndeki 4 giriş Sölöz, Olukdere, Karasu, Kırandere ve 1 çıkış noktası olmak üzere Karsak Deresi'nden su kalite parametrelerinin ölçüm sonuçları alınmıştır. Giriş noktalarına ait pH, iletkenlik (EC), sıcaklık (T), kimyasal oksijen ihtiyacı (KOİ), biyolojik oksijen ihtiyacı (BOİ), çözünmüş oksijen (ÇO), toplam fosfor (TP), fosfat (PO<sub>4</sub>-P), toplam azot (TN), nitrat azotu (NO<sub>3</sub>N) ve nitrit azotu (NO<sub>2</sub>N) parametreleri alınarak çıkış noktasında TN, TP ve ÇO üzerindeki etkisi incelenmiştir. TN, TP ve ÇO tahmin etmek için çeşitli denemeler yapılarak model çalışmaları için bir yapay sinir ağı (YSA) metodu benimsenmiştir. Model olarak, IBM SPSS istatistik 23 yazılımı kullanılmıştır. TN, TP ve ÇO değerlerinin performans değerlendirmesinde hata miktarını değerlendirmek için hata kareleri toplamı (SSE) ve belirleme katsayısı (R<sup>2</sup>) kullanılmıştır. Sonuçlar, belirleme katsayısının çoğunlukla 1'e yakın olduğunu göstermiş olup YSA analizi, toplam azot, toplam fosfor ve çözünmüş oksijen parametrelerinin kirlilik tahmininin gerçekleşebileceğini göstermiştir. Böylelikle, YSA modellerinin göl suyu kalitesinin uygunluğunu tanımlamak için etkin bir şekilde kullanılacak bir tahmin aracı olduğu görülmüştür. Geliştirilen modeller, gelecekte sürdürülebilir çevre yönetimi yoluyla kirliliğin azaltılmasına yönelik karar sürecini desteklemek için tahmin amacıyla kullanılabilir.

# EVALUATION OF IZNIK LAKE WATER QUALITY PARAMETERS BY ARTIFICIAL NEURAL NETWORKS METHOD

## SUMMARY

Keywords: Lake Iznik, water quality, water parameter, artificial neural networks

It is important to water quality parameters in the planning and management of lakes. In this study, the measurement results of water quality parameters were obtained from Karsak Stream, including 4 inlet Sölöz, Olukdere, Karasu, Kirandere and 1 outlet in Lake Iznik for the years 2017-2021. pH, conductivity (EC), temperature (T), chemical oxygen demand (COD), biological oxygen demand (BOD), dissolved oxygen (DO), total phosphorus (TP), phosphate (PO<sub>4</sub>-P), total nitrogen of the entry points (TN), nitrate nitrogen (NO<sub>3</sub>N) and nitrite nitrogen (NO<sub>2</sub>N) parameters were taken and their effects on TN, TP and DO at the exit point were investigated. Various attempts were made to predict TN, TP and DO, and an artificial neural network (ANN) method was adopted for model studies. IBM SPSS statistical 23 software was used as the model. The sum of squares of error (SSE) and coefficient of determination ( $R^2$ ) were used to evaluate the amount of error in the performance evaluation of TN, TP and DO values. The results showed that the coefficient of determination was mostly close to 1, and the ANN analysis showed that the pollution estimation of the total nitrogen, total phosphorus and dissolved oxygen parameters could be realized. Thus, it has been seen that ANN models are an estimation tool that can be used effectively to describe the suitability of lake water quality. The developed models can be used for prediction in the future to support the decision process for pollution reduction through sustainable environmental management.



## **BÖLÜM 1. GİRİŞ**

Günümüzde yaşamsal faaliyetlerin en önemli ihtiyaçlarından olan ve doğada az miktarda bulunan su kaynaklarının kirlenmesi çevresel sorunların başında gelmektedir. Doğada ki su kaynaklarının fiziksel, kimyasal, radyoaktif, ekolojik ve bakteriyolojik niteliklerinin olumsuz olarak farklılaşması şeklinde gözlenen ve doğrudan ya da dolaylı biçimde biyolojik kaynaklarda, insan sağlığında, balıkçılıkta, suyun kalitesinde ve suyun diğer amaçlar doğrultusunda kullanılmasında kısıtlayıcı bozunma oluşturabilecek enerji ya da madde atıklarının boşaltılması tanımlaması su kirliliği için yapılabilir (Anonim, 2004). Su kirliliğinin meydana gelmesi yaygın olarak, su kaynaklarına atıksuların deşarj edilmesi sonucunda oluşmaktadır. Genel olarak bakılırsa endüstriyel atıksuların neden olduğu kirlilikler ekolojik dengede bozulma yaşanmasına daha çok sebep olmaktadır. Ve oluşan bozulmanın çoğu zaman geriye dönüşü olmayan bir nitelik taşıdığı ortadadır (Tan, 2006). Bursa şehrinde bulunan su kaynaklarında ki kirlilik; sanayi kuruluşlarından kaynaklanan endüstriyel ve evsel nitelikli atıksular, yerleşim merkezlerinden kaynaklanan evsel atıksular, tarım için yapılan sulamalardan sonra oluşmuş drenaj suları, düzensiz katı atık depolama sahalarında meydana gelerek su kaynaklarına erişen süzüntü suları, su havzalarına katı atıkların dökülmesi ile erozyon kaynaklıdır (Ced, 2017).

Güney Marmara Bölgesinde ki İznik Gölü havzasının elverişli toprak ve iklim özelliklerinin yanında sulama imkanlarının var olması ve polikültür tarım uygulaması ile birlikte önemli tarımsal faaliyetlerin üretim merkezlerinden biri olma özelliği taşımaktadır. Güney Marmara'nın en büyük gölü olma özelliğini taşımakta olan İznik Gölünün 12.2 milyar metreküp su hacmi ve yıllık 80 milyon metreküp su randımanı ile takribi olarak 12,000 ha tarımsal alan için sulama yapılmaktadır. Bölgede tarımsal sulama için büyük bir önem taşıyan ve tarım üretiminde su kaynağı olarak önemli etkiye sahip olan göl; su ürünleri üretimi, yüzme, amatör balıkçılık, endüstri suyu temini, günü birlik tatil olanakları ve su sporları ile tarımın yanında, sosyal aktivite

ve endüstriyel anlam da yöre için epeyce önemli bir pozisyonadadır (Başar ve ark. 2003).

Dünya nüfusunun üçte birinin içme suyu yoksunluğu yaşadığı düşünüldüğünde tatlı su göllerine olan kullanım talebi artmıştır. Tatlı su gölleri dünyadaki tatlı su kütlelerinin %70'ini oluşturduğundan tatlı su göllerinin planlanması ve yönetimi alanında su kalite verilerinin yorumlanması önem arz eden bir konudur. (Dede,2009). Su kaynaklarında doğrudan yapılan ölçümler büyük maliyet, zaman ve işçilik gerektirirken modelleme, su kalitesi izleme maliyetini azaltmak için alternatif bir çözüm sunar (Ucun Özel ve ark. 2020). Bu aşamada, Yapay Sinir Ağı (YSA) temelli modellerle bir çok su kalitesi çalışması yapılmıştır. YSA'dan teşhis etme, sınıflandırma, veri ilişkilendirmesi ve yorum yapma gibi birçok alanda yararlanılmaktadır. Bilhassa tahmin çalışmaları için çok iyi sonuçlara ulaşılabilmektedir (Öztemel, 2012).

Bu çalışmada, Bursa Büyükşehir Belediyesi Bursa Su ve Kanalizasyon İdaresi Genel Müdürlüğü (BUSKİ)'den Bursa il sınırları içinde olan İznik Gölü'ne ait su kalitesi parametrelerinin ölçüm verileri alınarak Yapay Sinir Ağı (YSA) ile analiz sonuçlarının değerlendirilmesi amaçlanmıştır. Bu değerlendirmeyi yapmak amacıyla göle gelen ve gölden çıkan su kaynaklarından 5 analiz ölçüm noktası seçilmiştir. Göle giren Sölöz, Olukdere, Kırandere, Karasu da 4 giriş noktası, çıkış noktası ise İznik Gölü'nün tek çıkış ayağı olan Karsak deresi seçilmiştir. Giriş noktalarından pH, EC, T, KOİ, BOİ, ÇO, TP, PO<sub>4</sub>-P, TN, NO<sub>2</sub>N ve NO<sub>3</sub>N parametre verileri alınarak çıkış noktasında TP, TN ve ÇO parametrelerinin birbirleri ile olan ilişkilerine kolerasyon yaptırılarak bakılmış olup tahmin amacıyla YSA modeli çalışılmıştır.

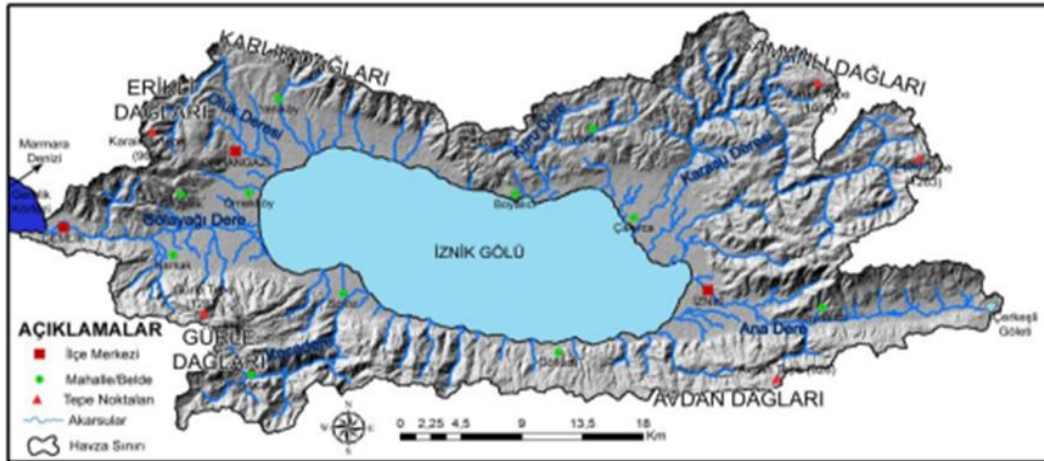
## **BÖLÜM 2. KAYNAK ARAŞTIRMASI**

### **2.1. İznik Gölü Genel Bilgi**

Bursa il sınırları içerisindeki su kaynaklarından olan İznik Gölü ülkemizin en büyük 5. ve Marmara bölgesinin en büyük tatlı su olma özelliğini taşımaktadır. Göl Marmara Deniz'inin güneydoğu bölgesinde yer almaktadır. Kuzey Anadolu Fay Zonu'nun orta kolu üzerinde doğu batı doğrultusunda oluşan bu tektonik gölün derinliği kuzeyden güneye doğru artmaktadır (Meriç ve ark., 2009). Gölün çevresi 92 km uzunluğunda olup 304,18 km<sup>2</sup> 'lik yüz ölçümüne sahiptir. Göle ait en geniş kısımlar Kuzey-Güney doğrultusunda 11,8 kilometre iken, Batı-Doğu doğrultusunda ise 32,35 kilometredir. Göl derinliğinden bahsedecek olursak üzeri deniz seviyesinden 80 metre'den yüksekte ve göl derinliği -70 m. seviyesine kadar inmektedir. Tektonik oluşumlu olan İznik Gölü'nün güney bölümü fay hattına tekabül ettiğinden dolayı en derin kısmı gölün güney kesiminde yer almaktadır (Garipoğlu ve Uzun, 2019).

1963 yılında gölün sularını ve taşkınları kontrol edebilmek adına gölün batısına set inşa edilmiştir. İnşa edilen seddin gerisinde bulunan 416 hektarlık sulak alan kurutulmuş, bu bölgede kavaklıklar oluşturulmuştur (Meşeli, 2010).

İznik Gölü Marmaranın güneyinde bulunan Bursa il sınırları içinde yer almasına karşın göl havzasında belli bölümler Kocaeli ve Yalova sınırları içerisinde yer almaktadır. Havzanın batı kısmında ise Erikli Dağı ve Gemlik Körfezi bulunurken Göl Havzası'nın kuzey kısmında Samanlı ile Karlık Dağları, güney kısmında ise Avdan Dağları ve Gürle Dağları bulunmaktadır. İznik Gölü'nün içinde yer aldığı havzada Şekil 2.1.'de görüldüğü gibi birden fazla irili ufaklı akarsu bulunmakta olup akarsuların çoğunun boyları oldukça kısadır ve mevsimlik akarsu özelliği göstermektedir (Garipoğlu ve Uzun, 2019).



Şekil 2.1. İznik Gölü havzası hidrografya haritası (Garipoğlu ve Uzun, 2019).

## 2.2. Su Kalitesinde Önemli Parametreler ve Su Kirliliği Kontrolü Yönetmeliği

Su kalitesinin, çevre ve insan üzerindeki önemli etkilerinin olması, rezervuar yönetimi için en kritik konular arasında yer almasını sağlamaktadır (Chou ve ark., 2018). Bu su kalitesi değişkenlerini ölçebilen basit ve pratik sensörlerin olduğu Tablo 2.1.'de gösterilmiştir (Chen ve ark., 2020).

Tablo 2.1. Su kalitesi değişkenlerine ilişkin temel bilgiler (Chen ve ark.,2020)

| Su Kalitesi Değişkenleri | Kategoriler | Birim | Başlıca Sensörler | Araştırma Senaryoları   |
|--------------------------|-------------|-------|-------------------|---|
| ÇO                       | Kimyasal    | mg/l  | ✓                 | nehir, göl, rezervuar, AAT, göletler, kıyı suları, dere, drenaj |
| BOİ                      | Kimyasal    | mg/l  | -                 | nehir, göl, AAT, maden suyu deney sistemi                       |
| KOİ                      | Kimyasal    | mg/l  | -                 | nehir, göl, rezervuar, AAT, yeraltı suyu, maden suyu            |
| SS                       | Fiziksel    | °C    | ✓                 | nehir, göl, göletler, havza, akış, kıyı suları                  |
| Klorofil-a               | Kimyasal    | µg/L  | ✓                 | göl, rezervuar, yüzey suyu, kıyı suları                         |
| pH                       | Fiziksel    | -     | ✓                 | nehir, göl, AAT, dere, kıyı suları                              |
| KM                       | Fiziksel    | mg/l  | -                 | nehir, dere, kıyı suları, dere, havza                           |
| EC                       | Fiziksel    | µm/cm | ✓                 | nehir, göl, rezervuar, yeraltı suyu, dere                       |

Tablo 2.1. (Devamı)

| Su Kalitesi Değişkenleri | Kategoriler | Birim | Başlıca Sensörler | Araştırma Senaryoları                                     |
|--------------------------|-------------|-------|-------------------|---|
| TP                       | Fiziksel    | µg/L  |                   | nehir, göl, AAT   |
| NH <sub>3</sub> N        | Kimyasal    | mg/l  | ✓                 | nehir, göl, rezervuar, yeraltı suyu deney sistemi         |
| Bulanıklık               | Fiziksel    | NTU   | ✓                 | nehir, dere   |
| NO <sub>3</sub>          | Kimyasal    | mg/l  | -                 | nehir, yeraltı suyu, havza, kuyular, akifer deney sistemi |
| TÇK                      | Fiziksel    | mg/l  | -                 | nehir, yeraltı suyu, drenaj                               |
| S                        | Fiziksel    | psu   | -                 | yeraltı suları, kıyı suları                               |
| Toplam Azot              | Kimyasal    | mg/l  | -                 | göl, AAT, kıyı suları                                     |
| B                        | Fiziksel    | mg/l  | -                 | nehir   |
| TS                       | Fiziksel    | mg/l  | -                 | nehir   |
| TOK                      | Kimyasal    | mg/l  | -                 | nehir   |
| TKM                      | Fiziksel    | mg/l  | -                 | nehir   |
| NO <sub>2</sub>          | Kimyasal    | mg/l  | -                 | yeraltı suyu  |
| PO <sub>4</sub>          | Fiziksel    | mg/l  | -                 | deneysel sistem   |
| SD                       | Fiziksel    | cm    | -                 | göl   |

Su Kirliliği Kontrolü Yönetmeliği (SKYY)'nin hedefi, yer altı ve yerüstü su kaynaklarının korunması ve en iyi şekilde kullanılmasının sağlanmasıdır. Aynı zamanda su kirliliğinin önlenmesi ve sürdürülebilir çevre hedefleri ile uyumlu hukuki ve teknik esasları belirlemektir (Aksoy, 2018). Çalışma kapsamında incelenen su kalite parametrelerinin SKKY'ye göre uygun sınıfları Tablo 2.2.'de gösterilmiştir.

Tablo 2.2. Kıtaiçi su kaynaklarının sınıflarına göre kalite kriterleri (Aksoy, 2018)

| SU KALİTE PARAMETRELERİ  | SU KALİTE SINIFLARI |                |                  |                 |
|--|---------------------|----------------|------------------|-----------------|
|  | I                   | II             | III              | IV              |
| <b>A) Fiziksel ve inorganik- kimyasal parametreler</b>             |                     |                |                  |                 |
| 1) Sıcaklık (°C)   | 25                  | 25             | 30               | > 30            |
| 2) pH  | 6.5-8.5             | 6.5-8.5        | 6.0-9.0          | 6.0-9.0 dışında |
| 3) Çözünmüş oksijen (mg O <sub>2</sub> /L) <sup>a</sup>            | 8                   | 6              | 3                | < 3             |
| 4) Oksijen doygunluğu (%) <sup>a</sup>                             | 90                  | 70             | 40               | < 40            |
| 5) Klorür iyonu (mg Cl <sup>-</sup> /L)                            | 25                  | 200            | 400 <sup>b</sup> | > 400           |
| 6) Sülfat iyonu (mg SO <sub>4</sub> <sup>-</sup> /L)               | 200                 | 200            | 400              | > 400           |
| 7) Amonyum azotu (mg NH <sub>4</sub> <sup>+</sup> -N/L)            | 0.2 <sup>c</sup>    | 1 <sup>c</sup> | 2 <sup>c</sup>   | > 2             |
| 8) Nitrit azotu (mg NO <sub>2</sub> <sup>-</sup> -N/L)             | 0.002               | 0.01           | 0.05             | > 0.05          |
| 9) Nitrat azotu (mg NO <sub>3</sub> <sup>-</sup> -N/L)             | 5                   | 10             | 20               | > 20            |
| 10) Toplam fosfor (mg P/L)   | 0.02                | 0.16           | 0.65             | > 0.65          |
| 11) Toplam çözünmüş madde (mg/L)                                   | 500                 | 1500           | 5000             | > 5000          |
| 12) Renk (Pt-Co birimi)  | 5                   | 50             | 300              | > 300           |
| 13) Sodyum (mg Na <sup>+</sup> /L)                                 | 125                 | 125            | 250              | > 250           |
| <b>B) Organik parametreler</b>                                     |                     |                |                  |                 |
| 1) Kimyasal oksijen ihtiyacı (KOİ) (mg/L)                          | 25                  | 50             | 70               | > 70            |
| 2) Biyolojik oksijen ihtiyacı (BOİ) (mg/L)                         | 4                   | 8              | 20               | > 20            |
| 3) Toplam organik karbon (mg/L)                                    | 5                   | 8              | 12               | > 12            |
| 4) Toplam kjeldahl-azotu (mg/L)                                    | 0.5                 | 1.5            | 5                | > 5             |
| 5) Yağ ve gres (mg/L)  | 0.02                | 0.3            | 0.5              | > 0.5           |
| 6) Metilen mavisi ile reaksiyon veren yüzey aktif maddeleri (mg/L) | 0.05                | 0.2            | 1                | > 1.5           |
| 7) Fenolik maddeler (uçucu) (mg/L)                                 | 0.002               | 0.01           | 0.1              | > 0.1           |
| 8) Mineral yağlar ve türevleri (mg/L)                              | 0.02                | 0.1            | 0.5              | > 0.5           |
| 9) Toplam pestisid (mg/L)  | 0.001               | 0.01           | 0.1              | > 0.1           |

Su sınıflarına ait kalite sınıfları Tablo 2.3.'de gösterilmiştir.

Tablo 2.3. Su kirlilik açısından sınıf değerleri (Aksoy,2018)

| Su Sınıfları | Kalite Sınıfları   |
|--------------|--------------------|
| Sınıf I      | Yüksek kaliteli su |
| Sınıf II     | Az kirlenmiş su    |
| Sınıf III    | Kirli su           |
| Sınıf IV     | Çok kirlenmiş su   |

### 2.3. İznik Gölü Su Kirliliği Kaynakları

İznik Gölü'ne su kirliliği yönünden bakıldığında Türkiye Çevre Atlasına göre kirlilik görülen göller arasında yer almaktadır (Anonim, 2004). Tarım için kullanılan zirai ilaç ve gübreler, İznik ve Orhangazi'deki sanayilerden kaynaklanan kimyasal maddeler gölde kıyı bitkilerinin ve canlıların ölümüne sebep olmaktadır (Budakoğlu, 2000).

Gölün çevresindeki endüstriyel, tarımsal çalışmalar ve kentleşme sonucu oluşan atıklar, göle giriş yapan derelere veya direk göle ulaşmaktadır. Bu sebep ile göl son senelerde hızlı bir kirlenme aşamasına girmiştir. Bunun yanında, tarım sulaması başta olmak üzere gölden mevcut yararlanma da devam etmektedir. İznik'in batısından yolcu ve yük trafiğinin fazla olduğu İstanbul-Bursa karayolu geçmektedir. Bölgenin doğu kesimi ile İznik ilçesi ise çok yoğun bulunmayan sapa bir yol üzerinde kalmaktadır. Zengin arkeolojik alanları, tarihsel doku, mevsimsel spor faaliyetlerine elverişli dağları, sağlık turizminde gerekli bulunan termal alanları ve kıyı turizmi seçenekleri ile turizm açısından yüksek potansiyele sahiptir (Anonim, 2019).

İznik Gölü havzasında 60'ın üstünde yerleşim yeri bulunmaktadır. Bu yerleşim alanlarından, gölün doğu kıyısında yer alan İznik ve gölün batısında bulunan Orhangazi'nin İlçe düzeyinde büyük yerleşmeleri, Sölöz, Yeniköy ve Elbeyli yerleşkeleri kasaba niteliğinde olup, diğerleri ise irili ufaklı köylerdir. Bahsedilen göle kıyısı olan yerleşim birimlerinde geçim sulu tarım, zeytincilik ve sebze meyve üretimi ile sağlanmaktadır. Bundan dolayı zirai ilaç ve gübre kullanımı yörede fazlası ile yaygındır. Gölün suyu ile neredeyse 9000 hektarlık sulu tarım arazisi sulanmaktadır. Hala yapılmakta olan sulama tesisleri ile 7000 hektar alanın daha artırılması beklenmektedir. Gölün yakınlarında bulunan tüm tarla bahçe sahipleri kesintisiz ve istisnasız şekilde gölden motopomlarla su çekerek tarım arazilerinde sulama yapmaktadırlar (Meşeli, 2010). Batıda bulunan Orhangazi'de ise geçim balıkçılık, tarım, hayvancılık ile iplik sanayisi ve depolama hizmetleri, tekstil ve madencilikten (taş ocakları) sağlanmaktadır (Garipoğlu ve Uzun, 2019). Orhangazi'den ve İznik'ten gelen azot yükü fazladır (Budakoğlu, 2000).

Karsak Deresi, İznik Gölü ve Gemlik Körfezi arasında olup İznik Gölü'nün boşalmasını sağlayan Gemlik ilçesinin en fazla su taşıyan akarsuyudur. İznik Göl ve havzasında kirlilik kaynaklarına maruz kalan Karsak Deresi, içeriğindeki birçok kirleticiyi Gemlik Körfezi'ne taşımaktadır. Taşıdıkları özelliklerine göre İznik Gölü Havzası'ndaki sanayi tesisleri iki temel grup altında toplanmaktadır. İlk grupta bulunanlar, yakın bölgeden temin edilmiş ham maddeleri kullanarak üretim gerçekleştiren ve üretilen ürünleri yakın bölgelerdeki piyasaya sunan orta ya da küçük ölçekli sanayi tesisleri; ikinci grupta bulunanlar ise kullanım yapılan ham maddeyi önemli derecede araştırma sahasının dışından temin ederek, üretmiş olduğu ürünleride ülke içine veya yurt dışına gönderim sağlayan büyük ölçekli sanayi tesisleri olarak gruplandırılırlar. Kirlilik izleme çalışması yapılan bu bölge için sanayi faaliyetlerinin ikili yapıya sahip olduğu görülmektedir. Bölgedeki sanayi kuruluşları ve özel şirketlerin atık sularının yanı sıra Orhangazi güney bölümünün fosseptik suları da Karsak Deresi aracılığı ile Gemlik Körfezi'ne taşınmaktadır (Meşeli, 2010).

## **2.4. Yapay Sinir Ağları (YSA)**

### **2.4.1. Genel bilgi**

Yapay Zeka (YZ), insan beynine ait olan çalışma prensibini taklit etmekte aynı zamanda geliştirilmesi üzerine çalışma yapmaktadır. Yaşam boyu ortaya çıkan problemleri insan beyni geçmiş deneyimlerini ve eğitimlerini baz alarak çözüme odaklıdır. Önceden yaşanmış olay ve şartlardan elde edilen deneyimler, yeni bir sorun ile karşı karşıya kalındığında kullanılır. Beynin bilişsel becerisi olan öğrenme bu süreçte devreye girer. Beynin öğrenme ile oluşum sağladığı çözüm metodları, karşı karşıya kalınan durumlarda eylem ortaya koyar. Yapılan YZ çalışmaları ile, insana ait bilişsel açıdan idrak, çıkarım, düşünme, karar verme gibi beceriler, yazılım ile gerçekleştirilmek istenmektedir (Yılmaz, 2015).



İnsan beynine ait işlevleri modeller ile anlamaya çalışmayı, insana ait zihinsel becerileri, öğrenme, bilgi edinme, icat etmede uygulama yaptıkları taktik ve yöntemleri araştırmayı, araştırılan yöntemleri örgün hale getirdikten sonra bilgisayar ortamında uygulamayı, bilgisayarın kullanımı için kolaylık sağlayacak uzman sistemler, arayüzler, yapay zeka iş yardımcıları, genel bilgi sistemleri, ve zeki robot timleri ile bilimsel araştırma ve buluş için araştırma destekleri geliştirmeyi amaçlayan YZ teknikleri sezgisel algoritma, bulanık mantık, uzman sistem ve yapay sinir ağlarıdır (Saraç, 2004).

#### **2.4.2. YSA'nın tanımı**

YSA'lar güncel bilgiler oluşturabilme, öğrenerek yeni veriler üretebilme ve keşfetme yeteneği gibi özelliklere sahip olan insan beynini herhangi bir destek almadan kendiliğinden gerçekleştirebilmek hedefi ile gelişim gösteren bilgisayar sistemleridir. Bu tip becerileri gerçekleştirebilmek geleneksel program yöntemleri ile güç veya mümkün olmamaktadır. YSA programlamalarının bu sebep ile, fazlasıyla zor ya da mümkünatı olmayan durumlar dahilinde geliştirilen, adaptif veri işleme ile ilgili bilgisayar bilim dalı olduğunu söylemek mümkündür (Öztemel, 2012).

Yapay zeka biliminin bir alt dalı yapay sinir ağlarıdır. YSA'lar kendilerine insan beyninin çalışma kuralını model edinmiş sistemlerdir. Modern bilimde en güncel konuların başında yapay sinir ağlarının öğrenme, adaptasyon, tanımlama, az veri ile çalışma, seri çalışma gibi kabiliyetleri gelmektedir. Yapay sinir ağları, öğrenme ile bilgi ve deneyimlerin artırılması ve öğrenimden yararlanılarak bir sonuç oluşturulması kuralı ile çalışmaktadır (Öztemel, 2012).

YSA'lar, deneme yaparak öğrenme ve genelleştirme gibi işlevlerini insan beyin fonksiyonundan esinlenerek yapmaktadırlar. Gelecek için tahmin yapay sinir ağının kullanıldığı kıymetli alanlardan biridir. Fark edilmesi zor ilişki ve datalar arasındaki bilinmeyen yapay sinir ağları ortaya çıkarabilir (Zhang ve ark., 1998).

### 2.4.3. Yapay sinir ağlarının özellikleri

Öğrenme; problemi öğrenmesi adına YSA'nın probleme ait giriş datalarına karşılık gelen çıkış datalarının ya da sadece giriş datalarının sağlanması gerekmektedir. Sistem giriş ve çıkış arasında ilişkiyi tanımlayan ağırlık verilerinin elde edilmesi öğrenme sürecidir (Ayyıldız ve Zeybek, 2015).

Doğrusal Olmama; yapay sinir ağlarını oluşumunu sağlayan yapay sinir hücreleri için seçim yapılan aktivasyon fonksiyonu yardımıyla yapay sinir ağlarının doğrusal veya doğrusal olmayan modelleme oluşturulması sağlanır. YSA'nın bu özelliği günümüzde karşımıza çıkan doğrusal olmayan ilişkiler içeren problemler düşünüldüğünde anlaşılabilir (Hamzaçebi, 2011).

Genelleme; YSA'lar daha önce elde edilen deneyimden öğrenebilir, yeni bir veri kümesine bir kez eğitilmeleri halinde direk cevap verebilir. Mevcut bir örneği baz alarak diğer örnekler için açıklama yapabilir (Tolon ve Tosunoğlu, 2008).

Hata Toleransı; paralel bilgi işleme sistemlerinde problem, parçalar halinde baz alındığında ve sistemin her bir elemanı ayrı bir parçanın çözümünü gerçekleştirdiğinden karşılaşılabilecek hatalara karşı daha büyük tolerans mevcuttur. Bu esneklik sayesinde tasarımdaki, herhangi bir ağ kısmının zarar görmesi halinde tüm ağda işlevsel bir sorun oluştuğu düşünülmemelidir. Çünkü işlevini kaybeden nöron oranında bir performans kaybı gerçekleşecek olup, tatminkar sonuçlara ulaşılabilir (Dede ve Sazlı, 2008).

Paralellik; işlem hızı bilgi işleme sistemlerinde üstünde durulması gereken önemli bir konudur. Fakat problem bütününe tüm parçalarının sırası ile işlendiği seri metodlar karmaşık işlemler için bir hayli yavaşlatıcı olmaktadır. Bundan dolayı yapay sinir ağlarının problemlere paralel bilgi işleminin getirdiği hızlı çözüm özelliği büyük önem taşır, çünkü gerçek zamanlı sistemlerin temelinde paralel bilgi işleme yöntemleri yatmaktadır (Dede ve Sazlı, 2008).

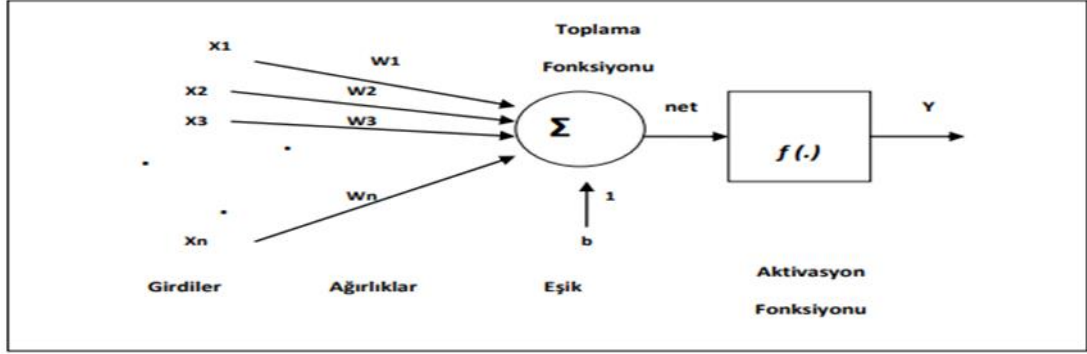
Analiz ve Tasarım Kolaylığı; yapay sinir ağı'nın ana işlem ögesi olan hücre yapısı ve modeli, tüm yapay sinir ağ yapılarında takribi aynıdır. Bu nedenle, YSA'nın değişik uygulama alanlarındaki yapıları da standart yapı hücrelerinden oluşacaktır. Farklı uygulama alanlarındaki YSA'lar bu nedenle aynı öğrenme algoritma ve teorilerini paylaşabilirler. Problemlerin YSA ile çözümünde bahsedilen özellik büyük bir kolaylık sağlayacaktır (Baykan, 2007).

Eksik Veri İle Çalışabilme; eğitimden sonra YSA'lar eksik bilgi ile çalışabilir ya da gelmiş olan örneklerde eksik bilgi olsa dahi sonuç verebilirler. Çalışmaya eksik bilgiyle de devam edebilirler. Geleneksel sistemler tam tersine eksik bilgi ile çalışmazlar. Tam bu noktaya dikkat çekmekte yarar vardır. Eksik bilgi YSA'nın çalışırken düşük performans sergileyeceğini göstermez. Eksik olan bilginin önemi ile performans düşüklüğü bağıntılıdır. Ağ eğitim esnasında kendisi için önemli olan bilgiyi öğrenmektedir. Bu mevzuda kullanıcıların fikri bulunmamaktadır. Eksik olan bilginin önemi, ağ performansı düşük olunca anlaşılabilir. Fakat ağ performansında düşme olmadığı görülürse, eksik bilginin öneminin bulunmadığı anlaşılır (Öztemel, 2012).

#### **2.4.4. YSA'nın yapısı**

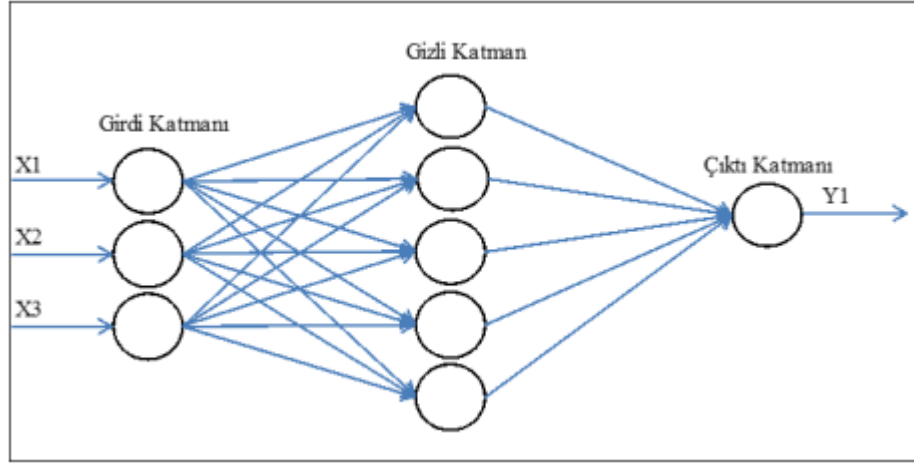
YSA nöron adında bir sıra işlem ögesini içeren ve toplu olan komplike ve doğrusal olmayan ilişkiyi, insanın sahip olduğu öğrenme becerisini taklit edip öğrenerek tekrar edebilen model yaklaşımıdır. YSA'daki sıralı biçimde olan nöronlar düzenlendikten sonra nöronların üretmiş olduğu sinyalin sonraki kademesinde var olan nöronlar için giriş değeri teşkil etmesi sağlanmış olur. Ağırlıkla anılan katsayılar ile, nöronların arasındaki bağıntı gerçekleştirilir. Böylece, dizili kademelerde türetilmiş sinyaller çıktı katmanına iletilerek bağımlı değişken değeri tahmin edilmesinde kullanılır. Yapay sinir ağlarının nöron arasında var olan ağırlıklara ilave olarak, diğer önemli ögesi de aktivasyon fonksiyonudur. Nörona gelen girdi sinyalini, çıktı sinyaline dönüştüren matematiksel fonksiyon aktivasyon fonksiyonudur. YSA'nın tahmin becerisini iyileştirmek adına farklı aktivasyon fonksiyonları içinde en uygunun seçilmesi gerekmektedir (Demir, 2017).

Yapay sinir ağı çalışmasının ana oluşumları en küçük birim olan yapay sinir hücresi olarak adlandırılır. Kolay biçimde gösterilecek olursa yapay sinir hücresi Şekil 2.2.'de gösterildiği şekilde girdi, ağırlık, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı olarak toplam 5 temel bileşenden meydana gelmektedir (Kaynar ve ark. 2010).



Şekil 2.2. Yapay sinir ağı hücresi gösterimi (Kaynar ve ark., 2010).

Katmanlar halinde birleşen nöronlar, yapay sinir ağı yapısını oluşturmaktadır. Farklı ağırlık ve fonksiyonlar ile bir araya gelen nöronlar ile meydana gelen katmanlar yapı olarak farklıdır. Yapay sinir ağlarında üç çeşit katman bulunmaktadır (Dede ve Sazlı, 2008). Yapı olarak bakıldığında en temel yapay sinir ağı yapısı Şekil 2.3.'de gösterildiği gibidir. Girdi katmanı, saklı katman ve çıktı katmanı ile birlikte üç farklı katman bulunur. Katmanlar nöron veya işlem elemanı şeklinde isimlendirilen bir yada birden fazla yapay sinir hücresinden meydana gelmektedir (Eren ve Turp, 2011).

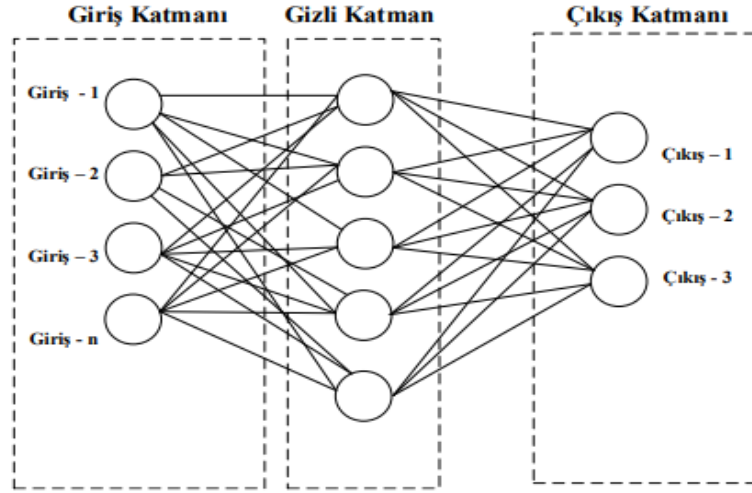


Şekil 2.3. Üç katmanlı yapay sinir ağı (YSA) mimarisi (Çekim, 2017).

Dış dünyadan bilgileri alan girdi katmanında ki proses elemanları bilgiyi ara katmana iletmekle sorumludurlar. Bilgi katmanında bazı ağlarda herhangi bir şekilde işleme gerçekleşmez. Girdi katmanından saklı katmana gelmiş olan veriler işlendikten sonra çıktı katmanına gönderilir. Ara katmanlarda bilgi işleme gerçekleştirilir. Bir ağda birden çok ara katman var olabilir. Farklı kaynaklarda ara katman gizli katman ya da saklı katman şeklinde de adlandırılmaktadır. Çıktı katmanında ara katmandan gelen verilerin işlenmesini gerçekleştiren proses elemanları, girdi katmanından gelen girdi setleri için üretimi gereken çıktıyı üretmiş olurlar (Civelekoğlu, 2006).

Herhangi bir problemin YSA yöntemi ile modellenmesindeki en önemli kısım, problem için en iyi çözüm yolu sağlayarak en uyumlu ağ mimarisini, yani saklı katman sayısı ile saklı katmanlarda işlem eleman sayısının belirlenmesidir. Modellemede kullanılacak olan parametre sayısına girdi ve çıktı katmanındaki işlem elemanı sayısı eşitken, modellenecek problemin zorluğuna göre saklı katman sayısı ile her saklı katmana ait işlem eleman sayısı değişiklik göstermektedir. Modellemesi istenen problemlerde datalar arasında olan ilişki karmaşık bir durum aldıkça oluşacak olan ağ mimarisinin gizli katman sayısı ile her katmanda olan işlem eleman sayısı buna istinaden artış göstermektedir (Eren ve Turp, 2011). Tek katmanlı yapay sinir ağları yalnızca girdi katmanı ve çıktı katmanından oluşmaktadır. Karmaşık işlem hesaplamaları yapıldığında tek katmanlı ağlar zayıf kalabilmektedir. Girdi ile çıktıkatmanlarına ek olarak birden çok saklı katman bulunduran ağlar çok katmanlı

ağ yapılarıdır. Bahsedilen ağ yapıları eğitim ve test süreçleri ile çalıştırılır. Ağırlık hesaplaması eğitim aşaması ve öğrenme algoritması için yapılarak elde edilen veriler için çıktı hesaplanır (Yavuz ve Deveci, 2012). Şekil 2.4.'de çok katmanlı ysa gösterilmiştir.




Şekil 2.4. Çok katmanlı yapay sinir ağı (Yılmaz, 2015).

#### 2.4.5. Ağ Yapılarına Göre Yapay Sinir Ağları

Nöronlar arasında ya da dış ortama iletilen bilgi akış yönünü, nöronların birbirine bağlanma şekilleri belirlemektedir. Ağ yapıları nöronlar arasındaki bağlantı biçiminden kaynaklı olarak ileri ve geri beslemeli şeklinde ikiye ayrılmaktadır (Alan, 2013).

##### 2.4.5.1. İleri beslemeli yapay sinir ağları


İleri beslemeli yapay sinir ağları, giriş katmanı, bir ya da daha çok ara katman ve bir çıkış katmanından oluşur. Bilgi akış yönü girişten çıkışa doğrudur. Bilgi giriş katmanından alındıktan sonra gizli katmanlara aktarılır. Gizli katmanlarda gelen bilgi ağırlıkları ile değerlendirilip çıkış üretilmesi adına bir sonraki katmana iletim sağlanır. Yapay sinir ağlarının bu tipleri katmanlar arasındaki ilerlemede genelde “geri yayılım” yaparak ağırlıkları problemin uygun çözümü adına düzenler (Alan, 2013). Şekil 2.5.'de İleri beslemeli bir YSA mimarisi gösterilmiştir.



Şekil 2.5. İleri beslemeli bir YSA mimarisi (Subaşı,2010).

#### 2.4.5.2. Geri beslemeli yapay sinir ağları

Geri beslemeli ağ yapılarının, ileri beslemeli ağlardan farkı bilginin sonraki katmana aktarılmaz olmasıdır. Bir katmandan bir önceki katmana bilgi aktarımı olduğu gibi aynı katmanda ki farklı hücreye de aktarılabilir. Geri beslemeli ağlar için bilgi akışı her iki yönde olabilmektedir. Bu durum geri beslemeli ağları doğrusal olmaktan kurtarıp dinamik özellik kazandırır. Şekil 2.6.'da geri beslemeli bir YSA mimarisi yer gösterilmiştir. (Alan, 2013).



Şekil 2.6. Geri beslemeli yapay sinir ağı mimarisi (Şanlı, 2018).

### 2.4.6. YSA'da ağ yapısı seçimi

Uygulama problemine göre, yapay sinir ağı tasarımı süresince ağ yapısı seçilmelidir. Seçilen ağların, hangi problemlerde daha iyi olduğunun farkında olunması önem arz etmektedir. Kullanım hedefi ile o alan için başarı gösteren ağ türleri Tablo 2.4.'de gösterilmiştir (Saraç, 2004).

Tablo 2.4. Ağ türleri ve başarılı oldukları alanlar (Saraç, 2004).

| Kullanım Amacı      | Ağ Türü                   | Ağ Kullanımı  |
|---------------------|---------------------------|---|
| Tahmin              | ÇKA                       | Ağ'a verilen girdi verilerinden bir çıktı değerinin tahmini           |
|                     | LVQ                       |   |
| Sınıflandırma       | ART                       | Girdi değerlerinin hangi sınıfa ait olduklarının belirlenmesi         |
|                     | Counterpropagation        |   |
|                     | Olasılıklı Sinir Ağları   |   |
|                     | Hopfield                  |   |
| Veri İlişkilendirme | Boztman Machine           | Girdilerdeki hatalı bilgilerin bulunup, eksik bilgilerin tamamlanması |
|                     | Bidirectional Associative |   |
|                     | Memory                    |   |

Uygun olan yapay sinir ağı yapısı seçimi, önemli derecede ağ için kullanımı düşünülen, öğrenme algoritmasına da bağlıdır. Ağ için kullanılacak olan, öğrenme algoritması seçimi yapıldığında, algoritma için gerekli mimaride doğrudan seçilmiş olacaktır. Örnek vermek gerekirse, geri yayılım algoritması ileri beslemeli ağ yapısını gerektirmektedir (Saraç,2004).



### 2.4.7. Yapay sinir ağlarında öğrenme

Biyolojik sistemlerde öğrenme, nöronların arasında bulunan sinaptik bağlantıların ayarlanması sonucu olur. İnsan doğumu ile birlikte yaşayarak öğrenme sürecine girmiş olur. Bahsedilen süreçte beyin devamlı bir gelişim gösterir. Yaşanmışlıktan elde edilen tecrübeler ile sinaptik bağlantı ayarı yapılır hatta yeni bağlantılar oluşturulur. Bu şekilde öğrenme gerçekleşmiş olur. YSA içinde aynı durum geçerlidir. Eğitim yolu ile örnek veriler kullanılarak, öğrenme gerçekleştirilir. Bir diğer deyişle gerçekleşme girdi ve çıktı verilerinin işlenmesi, yani eğitim algoritmasının bu verilerle bağlantı ağırlıklarını bir yakınsama sağlanana kadar, tekrar ederek ayarlamasıyla olur. Yapay sinir ağları matematiksel sistemlerdir. Nöronlardan sinyalleri alan işlem elemanı bunları, birleştirip dönüştürerek sayısal bir sonuç ortaya çıkartır ( Sattar, 2007).

Yapay sinir ağları, girdi ve çıktı değişkenlerinin arasında herhangi bir ön bilgi ihtiyacı hissetmeden ya da varsayımda yapmadan, doğrusal olmayan modelleme sağlayabilmektedirler. Girdi bilgilerine karşılık olarak çıktı bilgileri ağa verilip, girdi-çıkı arasında oluşan ilişkiyi ağı öğrenmesi sağlanır ve eğitim gerçekleştirilmiş olur. Genelde tercih edilen bu yöntem öğreticili öğrenme olarakta adlandırılır (Hamzaçelebi ve Kutay, 2004).

Yapay sinir ağında temelde iki görev gerçekleşmektedir. Bu iki görev sırasıyla, ilk olarak öğrenme ardına hatırlamadır. YSA'nın öğrenme aşamasında, giriş ve çıkış değerlerine istinaden ağırlık değerleri, ayarlanmaya çalışılmaktadır. Daha sonra hatırlama sırasında yapay sinir ağları, giriş verilerine uygun çıkış verileri üretmeye çalışmaktadır. Burada öğrenme sürecinde ağırlık ayarlaması yapılırken, YSA iterasyonlar gerçekleştirmektedir. YSA'nın hata oranını yayılım algoritmaları iterasyonlarla belli bir dereceye kadar düşürmeyi hedeflemektedir (Lin, 1996).

YSA'ları diğer yaklaşımlardan ayıran en temel özellikten biri öğrenmedir. Problemi öğrenebilmesi adına yapay sinir ağları giriş verilerine karşılık gelen çıkış verilerini veya yalnız giriş verilerini sağlamalıdır. Öğrenme kümesi yeterli sayıda giriş ve çıkış

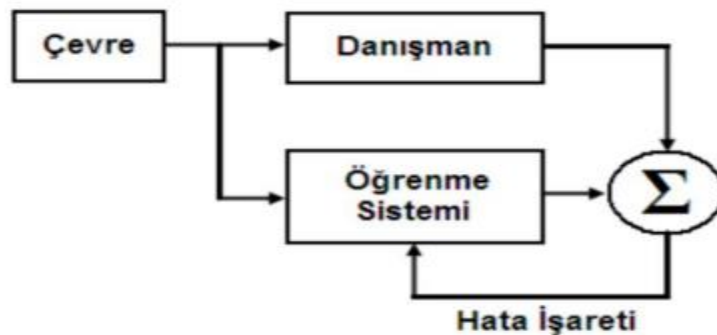
verileri ile tanımlanmış örnek içermelidir. Öğrenme süreci, sistem giriş ve çıkışları arasında olan ilişkiyi veya giriş verileri arasındaki ilişkiyi tanımlayan ağırlık verilerinin elde edilme süreci olarak da tanımlanabilir. Bu özellik yapay sinir ağına öğrenme algoritması kullanımı ile kazandırılmış olur (Yaşar, 2004).

#### 2.4.8. Yapay sinir ağlarında öğrenme algoritmaları

YSA'nın girdi verisine istinaden çıktı üretebilmesinin yolu ağı öğrenbilmesidir. Öğrenme birden fazla yöntemle gerçekleştirilebilir. Yapay sinir ağları öğrenme algoritmalarına göre danışmanlı, danışmansız ve destekleyici öğrenme olarak 3'e ayrılmaktadır (Sezginer, 2015).

##### 2.4.8.1. Danışmanlı öğrenme


Danışmanlı öğrenme esnasında ağa girdi değeri ile beraber çıktı değeri verilmektedir. Verilen girdi değerleri için istenen çıkış değerlerini oluşturabilmek adına ağ kendine ait ağırlıklarını günceller. Ağda ki çıktıları ile beklenen çıktı arasında hata hesaplaması yapılır ve ağa ait yeni ağırlıklar bahsedilen hata payına göre düzenlenir. Hata payı hesaplamasında ağa ait tüm çıktılar ile beklenen çıktılar arasındaki fark hesaplaması yapılarak çıkan fark için her hücreye düşmüş olan hata payı bulunur. Sonrasında her hücre kendine gelen ağırlıkları günceller (Sezginer, 2015). Şekil 2.7.'de danışmanlı öğrenme yapısı gösterilmiştir.



Şekil 2.7. Danışmanlı öğrenme yapısı (Şanlı, 2018).

### 2.4.8.2. Danışmansız öğrenme


Danışmansız öğrenme, anlaşılabilirliği gibi danışman ihtiyacı olmadan, ağ davranışını kendi kendine öğrenebilen bir algoritmadır. Danışmansız öğrenmede girdi verileri ağ tarafından daha detaylı yorumlanıp aralarındaki benzerlik ortaya konur. Bu özelliklerinden dolayı bu tip ağlar genelde sınıflandırma problemlerinin çözümü aşamasında tercih edilir. Sadece yapay sinir ağlarının girdileri ile işlem yapıldığından danışmansız öğrenmede ki ağ hızı, danışmanlı öğrenmeye oranla daha yüksek olmaktadır (Dede ve Sazlı, 2008). Şekil 2.8.'de danışmansız öğrenme yapısı gösterilmiştir.



Şekil 2.8. Danışmansız öğrenme yapısı (Dede ve Sazlı, 2008).

### 2.4.8.3. Destekleyici öğrenme

Destekleyici öğrenme stratejisinde, beklenen çıktı değeri net olarak bilinmemektedir. Bu noktada sadece üretilmiş çıktının doğruluğuna bakılır. Sistemden verilen girdiye karşılık çıktı üretmesi beklenir. Girdi-Çıktı uygunluğuna öğretmen tarafından kontrol sağlanarak sisteme doğru ya da yanlış şeklinde sinyal gönderimi yapılır (Öztemel, 2003). Bu yöntem ile ağa girdiler verilir buna karşı çıktı üretimi beklenip bu çıktıların doğru olduğuna dair bir skor veya dererece bildirilmektedir (Jain, 1996). Şekil 2.9.'da destekleyici öğrenme yapısı gösterilmiştir.



Şekil 2.9. Destekli öğrenme yapısı (Şanlı, 2018).

#### 2.4.9. Öğrenme algoritmasının seçimi

Yapay sinir ağlarında uygulama başarısını, yapı seçiminden sonra belirleyen en önemli etken öğrenme algoritmasıdır. Ağ yapısı genelde öğrenme algoritması seçiminde belirleyici faktördür. Seçilen ağ yapısına bağlı olarak ağ üzerinde kullanılacak öğrenme algoritması seçilir. Yapay sinir ağlarının gelişimi için birden çok sayıda öğrenme algoritması vardır. Bu algoritmalar arasında belirli tip uygulamalarda bazı algoritmaların daha uygun olduğunu söylemek mümkündür. Eğer algoritmalar uygun oldukları uygulama alanlarına göre sınıflandırılırlarsa, gruplar ile içinde bulunacak öğrenme algoritmaları aşağıda bulunan Tablo 2.5.'de ki gibi özetlenebilir (Saraç, 2004).

Tablo 2.5. Öğrenme algoritmaları ve uygulandıkları alanlar (Saraç, 2004).

| Uygulama Tipi | Yapay Sinir Ağları                      |
|---------------|---|
| Öngörü Tanıma | Geri Yayılım                            |
|               | Delta Bar Delta                         |
|               | Geliştirilmiş Delta Bar Delta           |
|               | Yönlendirilmiş Rastsal Tarama           |
|               | Geri yayılım içinde Self Organizing Map |
|               | Higher Order Neural Networks            |

Tablo 2.5. (Devamı)


|  |   |
|--|---|
| <b>Sınıflandırma</b>                                 | Learning Vektor Quantization            |
|  | Counter - Propagation                   |
|  | Olasılıklı Yapay Sinir Ağları           |
| <b>Veri İlişkilendirme (Data Association)</b>        | Hopfield                                |
|  | Boltman Makinesi                        |
|  | Bidirection Associative Memory          |
|  | Spantion - temporal Pattern Recognition |
| <b>Veri Kavramlaştırma (Data Conceptuallization)</b> | Adaptive Resonance Network              |
|  | Self Organizing                         |

#### 2.4.10. Yapay sinir ağlarında ileri besleme geri yayılım algoritması

YSA'lar en fazla tahmin amacıyla kullanılmaktadır. Yapay sinir ağlarında tahmin için genelde kullanımı olan öğrenme algoritması geri yayılımdır. Bu algoritma ileri beslemeli ve çok katmanlı ağ mimarisi gerektirir. Geri yayılım algoritmasının, geri yayılım ismini alma sebebi hataları çıkıştan geriye doğru azaltmaya çalışmasıdır. Ağa örnekler öğretilerek, hedef değer verilir. Öğrenme sürecinde her örnekte ağın çıkış değeri ile hedef değeri kıyaslanır (Dede, 2009). İleri beslemeli geri yayımlı yapay sinir ağları su kaynaklarında en fazla kullanılan yapay sinir ağı metodudur (Yılmaz, 2009).

Yapay sinir ağlarında en çok kullanım alanına sahip olan model çeşitlerinden biridir. Bu tür yapay sinir ağlarında çok katmanlı bir mimari kullanılır. Çok katmanlı mimari doğrusal olmayan problemlerin çözümleri için tasarlanmıştır. Hem günlük karşılaşılan neredeyse bütün doğrusal olmayan problemleri çözebilme yeteneğinden dolayı hem de birçok öğrenme algoritması bu ağlarda kullanılabildiğinden yaygın olarak kullanılır. Çok katmanlı ağ modelleri danışmalı öğrenme algoritmasını kullanırlar. Ağ girdi ve çıktı setleri beraber verilir, ağ girdi değerleri ile eğitilir.

Eğitme işlemi sonucu sistemden verilen girdiye karşılık gelen sonucu tahmin etmesi beklenir. Sistemden dış dünyaya aktarılan sonuç ile gerçek değer karşılaştırılır ve hata oranı bulunur. Bağlayıcı ağırlıkları değiştirilerek bu farkın en aza indirgenmesi sağlanır (Atasoy, 2012).



Şekil 2.10. Çok katmanlı ileri beslemeli sinir ağı (Haykin, 1999).

Çok katmanlı ileri beslemeli sinir ağlarında Şekil 2.10.'da olduğu gibi bir ya da birden çok gizli katman kullanılır. Bilgi akışı ileriye doğrudur. Bir katmandaki nöronların her birinin bir sonraki katmandaki nöronların hepsine gitmesi gerekir. Gizli katmandaki nöronlar türevlenebilir aktivasyon fonksiyonuna sahip olmalıdır. Gizli katmanlar ile ağ daha karmaşık problemleri çözebilmektedir. Bu ağ yapısına sahip modellerde genelde geri yayılım algoritması kullanılmaktadır (Manisalı, 2020).

#### 2.4.11. YSA uygulamaları ve kullanım alanları

Yapay sinir ağları hem yapısal açıdan çeşitli olması hem de öğrenme algoritmalarının çeşitliliği bakımından karmaşık problemlerin çözümü için modelin kurulmasında oldukça farklı olanaklar sunmaktadır (Efe ve Kaynak, 2000). Yapay sinir ağı modelleri kurularak yapılan uygulamalara bakıldığında sayının oldukça fazla olduğu ve her geçen gün bu sayının arttığı görülür. Yapay sinir ağlarını her gün kullandığımız telefonlarda, elektronik aletlerde, parmak izi kullandığımız güvenlik sistemlerinde görmek mümkündür. Yapay sinir ağlarının genellikle tahmin, sınıflandırma ve modelleme, veri yorumlama işlemlerinde kullanılır. Yapay sinir ağ uygulamalarını alt başlıklara ayıracak olursak;

- Endüstriyel Uygulamalar
- Savunma Uygulamaları
- Sağlık Uygulamaları
- Diğer Uygulamalar

Endüstriyel Sistem: Yapay sinir ağları endüstriyel uygulamalarda oldukça yaygın bir şekilde kullanılmaktadır. Bu kullanım alanlarının hepsini sıralamak mümkün değildir. Ancak örnek verilecek olursa; imalatta proses hataları teşhisi, makine bakımı, kalite kontrollerin görsel teşhisi, gezgin satıcı problemi, üretim planlamada optimizasyon çalışmaları, cep telefonlarında parmak izi ve sesle çalışabilme uygulamaları, müşteri tatmini ve pazar verilerinin değerlendirilmesi ve analizi vs. gibi alanlarında karşımıza çıkmaktadır. Görüldüğü gibi yapay sinir ağları endüstriyel uygulamalarda imalattan müşteri memnuniyetine kadar yayılmış geniş bir alana yayılmıştır (Öztemel, 2016).

Savunma Sistemleri: Savunma sistemlerinde de yapay sinir ağ uygulamaları endüstriyel sistem kadar gelişmiştir. Bu alandaki yapay sinir ağ uygulamalarına örnek verecek olursak; sinyal ve görüntü işleme, mayın detektörleri, hedef seçme, radar, askeri uçakların uçuş yörüngelerinin belirlenmesi ve optimizasyonu, vs. şeklindedir. 45 Savunma sistemlerinde geliştirilen uygulamalar askeri hayata büyük fayda sağlamaktadır (Şahin, 2019).

Sağlık Uygulamaları: Yapay sinir ağının önemli uygulama alanlarının biri de sağlık alanındaki çalışmalardır. Yapay sinir ağının sağlık uygulamalarındaki başarısının artması ile birlikte daha gelişmiş tanı ve tedavi yöntemlerine ışık tutacaktır. Bu alandaki uygulamalara bakarsak EEG, MR, kalite artırımı, ilaç etkileri analizi, kanserli hücre analizinde, kan analizi sınıflandırma, kalp krizi erken teşhis ve tedavisi vs. örnek olarak verilebilir (Gönül ve ark., 2015).

Diğer Alanlarda Uygulamalar: Yapay sinir ağı yukarıdaki alanlar dışında oldukça geniş alanlarda kullanılmaktadır ve bunları sıralamak mümkün değildir. Yukarıdaki

alanlar dışındaki uygulamalara örnek verecek olursak güvenlik de yüz eşleştirme, kredi kartı hileleri saptama, parmak izi; dil de dil tercümesi, sözcük tanıma; finasta hedef belirleme, döviz kuru belirleme, risk analizi, uzay (Uçuş simülasyonları, otomatik pilot uygulamaları), komponentlerin hata denetimleri örnek verilebileceği gibi bu alanların ve örneklerin sayısı arttırılabilirler (Eroğlu, 2020).

#### **2.4.12. Yapay sinir ağı avantajları**

- YSA'lar daha önce kazandıkları deneyimlerinden öğrenip, bir kez eğitildikleri zaman yeni girdi verilerine direkt cevap verebilir. Örnek üzerinden giderek başka örnekleri açıklayabilir.
- Bilinmeyen ilişkileri veriler ile akıllı davranarak ortaya çıkarabilmektedir. Bu özellik uygulama açısından önem teşkil etmektedir.
- Ağa ait parametreler örneğin; ağırlık katsayısı, yapısı değiştiğinde somut problem çözümleri için adapte olabilme özelliğine sahiptir.
- Ağlar doğrusal olmadığından karmaşık problemler, daha doğru şekilde çözülebilirler (Ayyıldız ve Zeybek, 2015).
- Bilgileri hızlı işlemesi, paralel çalışması ve kolayca gerçekleştirilebilir özelliği itibarıyla şekil tanıma, ilişki kurma, genelleme ve sınıflandırma gibi birçok alanda kullanılır.
- YSA'lar kendilerini hata yaparak ve eğitim yolu ile öğrenerek geliştirir.
- Maliyet yönünden bakıldığında yapay sinir ağı uygulamaları düşük maliyetlidir. Bu özelliği tercih sebeplerinden biri olmaktadır (Akgürbüz, 2017).

Eğer özetlenecek olursa yapay sinir ağlarının; doğrusal olmayan yapıları modellenmesi, yapı bakımından paralel dağılmış olması, genelleme yapma ve öğrenme becerisi, hata toleransına sahip olabilmesi, eksik bilgi olduğunda



çalışmaya devam etmesi, uyarlanabilirliği, analiz ve tasarım kolaylığı gibi özelliklere sahiptir. Bu nitelikler finans, işletme, mühendislik, tıp gibi değişik alanlarda tercih edilmesini sağlamıştır (Hamzaçebi, 2011). Yapay zeka yöntemlerinden biri olan YSA birden fazla doğa biliminde kullanıldığı gibi su yönetimi uygulamalarının yanında, su kalite parametreleri için de kullanılmaktadır (Yılmaz, 2015).

## **2.5. Yapay Sinir Ağlarında Su Kalitesi İzlenmesi**

Dünya üzerinde ki tatlı su kaynaklarının sınırlı olmasının yanında ülkemizde, dünya üzerinde su kaynaklarının kısıtlı olduğu bir coğrafyada bulunmaktadır. Su yönetiminin ülkemizde gerekli dikkat ve uygun politikalar uygulanarak yürütülmesi büyük önem kazanmıştır. Nüfusun artması ile beraber tüm sektörlerde artışı beklenen su talebi ve küresel iklim değişiminin en iyi şekilde yönetimi gerekmektedir (Aküzüm ve ark., 2010). Suyun yönetimi aşamasında, suyun kalitesi büyük öneme sahip olacaktır ve su kalitesinin korunmasının yanında sürdürülebilirliğinde sağlanması ciddi anlamda önem arz etmektedir.

Su kalitesi yalnız insan hayatı için değil, diğer canlıların yaşamlarında önemsenmesi gerekli olan bir kavramdır. İlk aşamada su kalitesi atmosferdeki su oluşumunun yeryüzüne yağmur ve kar şeklinde düşmesi ile olur. Hidrolojik döngü ile birlikte su dolaşımı esnasında su kirliliği çevresel etki neticesinde oluşacak olup kirlenme bölgeler arasında taşınabilmektedir. Suların doğal kirlenmesinin yanında insan aracılığı ile oluşturulan endüstriyel faaliyetlerle beraber kimyasal, fiziksel, biyolojik ve radyoaktif kirlilikler ortaya çıkmaktadır. (Megep Yayınları, 2011).

Yaşanılan çevre devamlı bir değişim içindedir. Yaşanılan değişimin günümüz ve gelecek açısından değerlendirilmesi yapıldığında çevre için ne tür etkileri olacağını tahmin edebilmek önemli kazanımlar sağlayacaktır. Elde edilen geçmiş yıllara ait verilerle yapılmış olan su kalitesiyle ilgili çalışmalarda tahmin yapılabilmesi, problemlerin çözümleri için önemli derecede kolaylık sağlamaktadır (Yılmaz, 2015).

## 2.6. Türkiye’de ve Dünya’da Su Kaynaklarında Su Kalitesinin Yapay Sinir Ağları İle Tahmin Çalışmaları

Türkiye’de ve Dünyada bilim insanları akarsularda, göllerde su kalitesi ve kirlilik üzerine birçok çalışma yapmıştır. Yapılmış olan bu çalışma örnekleri aşağıda sıralanmıştır.

Terzi (2006) çalışmasında, Eğirdir Gölü’ne ait günlük su sıcaklığını tahmin edebilmek adına güneş ışınımı, günlük hava sıcaklığı, ve nisbi nem parametrelerini kullanmış olup bir, iki ve üç girdili farklı yedi yapay sinir ağ modeli geliştirmiştir. Modellerde gelişim sağlanabilmesi için kullanılmış olan eğitim verileri 2000-2001-2002 yıllarına ait günlük veri değerlerini içerirken test verileri 2003 yılına ait günlük veriler ile oluşturulmuştur. Geliştirilmiş olan modeller için performans irdelemesi yapıldığında, hava sıcaklığı parametresine bağımlı olan bir, iki ve üç girdili dört adet modelin geçerli sonuç vermesi ile birlikte günlük su sıcaklığı tahmin etmede kullanılabilir oldukları bu çalışma ile görülmüştür.

Tüzün ve ark. (2007) çalışmalarında, Kaplıkaya Barajının mekana ve zamana bağlı ÇO (çözünmüş oksijen) konsantrasyon değerinin Yapay Sinir Ağı modellenmesinde başarı sağladığı izlenmiştir. En iyi modelin bulunması gizli tabaka sayısını ve tabakadaki hücre sayısı değiştirilerek sağlanmıştır. Levenberg-Marquardt algoritması eğitim için kullanılmış ve modelin performansını veri miktarının etkilediği sonucuna ulaşılmıştır.

Elhatip ve Kömür (2008) yapmış oldukları çalışmada, Mamasin Barajında çözünmüş oksijen ve EC’nin arazi ölçümleri ile yapay sinir ağı sonuçları kıyas edilmiştir. Toplam azot, AKM, sıcaklık ve yağış verilerinin giriş parametresi olarak kullanıldığı YSA’da çıkışların ölçüm değerlerine yakın sonuçlar verdiği görülmüştür.

Ucun Ozel ve ark. (2020) yılında, Bartın Nehri üzerinde Cu, Fe, Zn, Mn, Ni ve Pb analizleri yapılmış olup, analiz sonuçları YSA ve uyarlanabilir nöro-bulanık çıkarım

sistemi (ANFIS) ile modellenmiştir. Aralık 2012 ile Aralık 2013 arasında 1 yıl süreyle Bartın Nehri üzerinde seçilen 3 istasyondan örnekler alınmış ve ağır metal konsantrasyonlarını tahmin etmek için verilere radyal tabanlı sinir ağı, çok katmanlı algılayıcı sinir ağı modelleri ve ANFIS modeli uygulanmıştır. Çalışma sonucunda, test aşamasında tüm ağır metal modellerinin RMSE ve MAE değerlerinin çok düşük hata değerlerine sahip olduğu ve MLP kullanılarak oluşturulan modellerin test aşamasında  $R^2$  değerlerinin 0.77'den yüksek olduğu; RBN yöntemi kullanılan modellerin test aşaması  $R^2$  değerlerinin 0.773 ile 0.989 arasında değiştiği ve ANFIS modelinin test aşaması  $R^2$  değerinin 0.80'den yüksek olduğu tespit edilmiştir. Test değerlendirme sonuçları dikkate alındığında MLP, RBN ve ANFIS modellerinin ağır metal türlerine göre, Cu, Zn ve Mn için RBN, Ni için MLP modeli ve Fe ve Pb için ANFIS modeli başarılı olmuştur. Sonuçlara göre yapay zeka modelleri ve nispeten kolay ölçülebilir parametrelerle ağır metal içerikleri yaklaşık olarak tahmin edilebilir böylece nehirlerde ki canlı yaşamına zarar veren ağır metalleri hem hızlı hem de ekonomik olarak tespit etmek mümkün olduğu belirtilmiştir.

Terzi ve Köse, (2012) nin yaptığı bu çalışmada, yapay sinir ağı yöntemi ile Göksu Nehri'nin akım tahmini yapılmıştır. Kırkkavak (1719), Hamam (1720) ve Karahacılı (1714) Göksu Nehri'nin 1990-2010 yıllarında akım gözlem istasyonlarından elde edilen günlük akım değerleri ile yapay sinir ağ modelleri geliştirilmiştir. Performans değerlendirilirken, geliştirilmiş olan modellerde ortalama mutlak hata ve belirginlik katsayısı değerleri kullanılmıştır. Model performansları için değerlendirme yapıldığında, YSA metodunun akım tahmini için kullanılabilir olduğu görülmüştür.

Chebud ve ark. (2012), Ekosistem restorasyonu öncesi ve sonrasında yağışlı ve kurak mevsimlerde klorofil-a, bulanıklık ve fosfor gibi su kalitesi parametrelerini ölçmek için bir sinir ağı modeli geliştirilmiş olup sonuçlar, geliştirilen sinir ağı modelinin, gözlemlenen ve simüle edilen su kalitesi parametreleri arasında mükemmel bir ilişki sağladığını göstermiştir. Florida Everglades'deki belirli bir bölge için 1998–1999'da ve 2009–2010'da (kuru ve yağışlı mevsimler)  $R^2 > 0.95$ 'te korelasyon göstermiştir. Ayrıca, kök ortalama kare hata değerleri fosfor, bulanıklık ve klorofil-a için sinir ağı eğitimi ve doğrulama aşamalarında sırasıyla  $0.03 \text{ mg L}^{-1}$ ,  $0.5 \text{ NTU}$  ve  $0.17 \text{ mg m}^{-3}$ 'ün

altında olduğu çalışmada belirtilmiştir. Geliştirilen metodoloji kullanılarak, seçilen su kalitesi parametrelerinin zamansal ve mekansal dinamikleri araştırılmış. Ek olarak, su sütununda depolanan fosfor ve klorofil-a miktarları hesaplanıp ve bu metodolojinin karmaşık ekosistemlerdeki su kalitesi parametrelerini tahmin etmedeki faydasından bahsedilmiştir.

Kadam ve ark. (2019), çalışmalarında Hindistan'ın Batı Ghat bölgesinin doğu yamaçlarında yer alan Shivganga Nehri havzasından içme amaçlı yeraltı su kalitesi uygunluğu tahmininde yapay sinir ağı (YSA) ile çoklu doğrusal regresyon yani MLR teknikleri uygulamıştır. Bunun ışığında, 2015 yılının muson öncesi ve sonrası mevsimlerinde ana katyonlar ve anyonlar için otuz dört (34) temsili yeraltı suyu numunesi toplanmış ve analiz edilmiştir. TÇK, EC, pH, TS, Ca gibi fizikokimyasal parametreler, HCO<sub>3</sub>, Na, K, Cl, Mg, SO<sub>4</sub>, NO<sub>3</sub> ve PO<sub>4</sub> su kalitesi indeksi (WQI) hesaplamak için kabul edilmiştir. Analitik sonuçlar neticesinde, tüm parametrelerin kabul edilebilir aralıkta olduğunu doğrulanmış; bununla birlikte EC, TÇK, TS, Ca ve Mg, değerleri için WHO içme standartlarının arzu edilen limitini aşmakta olduğu dile getirilmiştir.. Yeraltı suyunun içmeye uygunluğu WQI yöntemiyle belirlenmiş ve WQI değeri muson öncesi ve sonrası mevsimlerde sırasıyla 25.75 ile 129.07 ve 37.54 ile 91.38 arasında değişmektedir. Sadece bir örnek (DW<sub>5</sub>), evsel ve tarımsal atık girişi nedeniyle içme için düşük kaliteyi gösteren 129.07 WQI değerini göstermektedir. WQI tabanlı yeraltı suyu kalitesinin tahmini için tutarlı ve kesin bir model oluşturma görüşünde, YSA mimarisinde bir Levenberg-Marquardt üç katmanlı geri yayılım algoritması kullanılmıştır. Sonuçlar, YSA modelinin tahminlerinin tatmin edici olduğunu ve her iki mevsim için tutarlı bir şekilde kabul edilebilir performansı doğruladığını göstermiştir.. Önerilen YSA modeli, içme amaçlı benzer yeraltı suyu kalitesi tahmin çalışmalarında faydalı olabileceği görülmüştür.

Najah ve ark. (2011), Bu çalışmada, çok katmanlı algılayıcı sinir ağları, topluluk sinir ağları ve destek vektör makinesi dahil olmak üzere su kalitesi parametrelerinin tahmininde farklı yapay zeka teknikleri araştırılmıştır. Şu parametreler araştırılmıştır: çözülmüş oksijen, biyokimyasal oksijen ihtiyacı ve kimyasal oksijen ihtiyacı. Girdi parametrelerinin model üzerindeki etkisini değerlendirmek için duyarlılık analizi

benimsenmiştir. Önerilen modelin performansını değerlendirmek için üç istatistiksel indeks kullanılmıştır; korelasyon katsayısı (CC), ortalama kare hatası (MSE) ve verimlilik korelasyonu (CE). Bu çalışmanın temel amacı doğrultusunda, bu parametreleri ölçmek için maliyeti ve emeği azaltabilecek su kalitesi parametrelerini tahmin etmek için hesaplama açısından verimli ve sağlam bir yaklaşım gelişmiştir. Bu araştırma da nehir suyu kalitesi dinamiklerinin önemli ölçüde değiştiği Malezya, Johor Eyaletindeki Johor nehri üzerine yoğunlaşmıştır.

Elzwayie ve ark. (2017), tropikal “Malezya” ve kurak “Libya” da hem kirli hem de kirlenmemiş göl su kütlelerinde bulunan ağır metal içeriğindeki değişiklikleri iklim ve kirlilik koşullarına bağlı olarak modellemek için radyal tabanlı fonksiyon sinir ağı algoritmasını kullanmışlardır. Çalışma farklı iklim koşulları altında yürütülmüş ve fizikokimyasal parametre verilerinin (ör. pH, EC, WT, ÇO, TÇK, TSS, Cl, NO<sub>3</sub>, PO<sub>4</sub>, SO<sub>4</sub>) ve klimatolojik parametrelerin (ör. hava sıcaklığı, nem ve yağış) girdi verileri olarak kullanılmıştır. Üç farklı senaryo değerlendirilmiş ve genel olarak tüm bu senaryolardan elde edilen sonuçlar yüksek düzeyde doğruluk göstermiştir.

Isiyaka ve ark. (2019), 8 yılda sekiz bölgeden elde edilen on dört su kalitesi fizikokimyasal parametresini incelemiş ve su kalitesi modellenmesi için en iyi girdi kombinasyonunu geliştirmeyi amaçlamıştır. Çalışma sonuçlarının oldukça tatmin edici olduğunu belirtmişler ve su kirliliğinin izlenmesi için YSA kullanılması gerektiğini öne sürmüşlerdir.

Sinshaw ve ark. (2019), Su kütlesindeki karmaşık kimyasal ve fiziksel süreçlerden dolayı su kalitesi değişkenlerinin doğrusal olmaması modelleme sürecini zorlaştırmaktadır. Bu çalışmada, birbiriyle ilişkili ve kolayca ölçülebilir su kalite parametreleri kullanarak ABD göllerindeki toplam azot (TN) ve toplam fosforun (TP) yaz konsantrasyonunu tahmin eden bir model geliştirmek için doğrusal olmayan ilişkiler için güçlü bir hesaplama aracı olan yapay sinir ağı (YSA) yaklaşımı kullanılmıştır. Bölgesel ve ulusal veri setlerini kullanan iki ANN modeli ve bir doğrusal regresyon modeli, çıktılarla istatistiksel olarak ilişkilendirilen üç girdi (pH, iletkenlik ve bulanıklık) kullanılmış, test edilmiş ve onaylanmıştır. YSA modellerinin

tahmini doğruluğu, sürekli olarak doğrusal regresyon modelinden daha iyi performans göstermiş olup, bölgesel veri setleri için YSA modellerinin istatistiksel doğruluğu, ulusal veri setinden daha üstün olduğu görülmüştür. Bir duyarlılık analizi, pH'ın besinler için en belirleyici parametre olduğunu göstermiştir. Bu sonuçlar, YSA modelleme tekniğinin bölgesel göllerdeki besin konsantras-yonlarının genel bir tahmini için bir tarama aracı olabileceğini göstermiştir.

Akner ve ark. (2021), çalışmalarında Sapanca gölünde ki çözünmüş oksijen (ÇO) konsantrasyonunu tahmin etmek için yapay sinir ağı kullanmıştır. pH, Magnezyum (Mg), Sıcaklık, Kimyasal Oksijen İhtiyacı (KOİ), Ortofosfat (o-PO<sub>4</sub>), Nitrat Azotu (NO<sub>3</sub>-N) ve Nitrit Azotu (NO<sub>2</sub>-N) bağımsız parametreler olarak kullanılmıştır. Çalışmada YSA modeli ve geleneksel çoklu doğrusal regresyon (MLR) analizi kıyas edilmiştir ve YSA modelinin daha başarılı sonuçlar verdiği görülmüştür. IBM SPSS İstatistikleri, Sürüm 21.0. ile geliştirilen model için, gelecekte eksik verileri tamamlamak ve sürdürülebilir çevre yönetimi yoluyla kirliliğin azaltılmasına yönelik karar sürecini desteklemek için tahmin amacıyla kullanılabilmesi çalışmada belirtilmiştir. Sapanca Gölü için çalışma sonucunda ötrofikasyon tehdidi ortaya çıkmıştır. Çalışmada ki temel amaç YSA ve ötrofikasyon modellerinin çıktıları ile hızlı kentleşme sorununa dikkat çekmiş ve bilimsel altyapıyı oluşturmuştur. Çalışmada Sapanca Gölü su bütçesinin korunmasının mevcut kirliliği ortadan kaldırmak için ekolojik sürdürülebilirlik açısından birincil çözüm yöntemi olduğu anlaşılmıştır.

Khudair ve ark. (2018), bu çalışma Bağdat Şehri'nde içme amaçlı WQI'ye dayalı yeraltı suyu kalitesini incelemiştir. Araştırmanın yürütülmesi için Bağdat şehrinin El-Karkh ve Al-Rusafa taraflarındaki 114 kuyudan alınan su örneklerini temsil eden Bağdat Su Kaynakları Bakanlığı'ndan veriler toplanmıştır. WQI'yi belirlemek amacıyla, pH, Klorür (Cl), Sülfat (SO<sub>4</sub>) ve Toplam çözünmüş katılar (TÇK), gibi dört su parametresi dikkate alınmıştır. Hesaplanan WQI'ye göre, yeraltı suyu numunelerinin mükemmel, iyi, zayıf, çok zayıf ve insan içme amacına uygun olmayan kalite sınıflarına göre dağılımı, sırasıyla %14,9, %39,5, %22,8, %6,1 ve %16.7 olarak bulunmuştur. Ek olarak, yeraltı suyu WQI'sindeki değişiklikleri tahmin

etmede yapay sinir ağı modeli geliştirebilmek adına IBM SPSS Statistics 19 yazılımı (SPSS) kullanılmıştır. Bu YSA modelinin uygulanmasıyla, elde edilen sonuçlar yüksek tahmin verimliliği göstermiştir. Hata fonksiyonlarının karelerinin toplamı (eğitim ve test örnekleri için) ve determinasyon katsayısı ( $R^2$ ), sırasıyla (0,038 ve 0,005) ve 0,973 olduğu bulunmuştur. Bununla birlikte, pH ve CI parametreleri model tahminini önemli ölçüde etkilemiş dolayısıyla YSA modeli kullanılarak gerçekleştirilen tahminde önemli faktörler haline gelmiştir.

Abbas ve ark. (2019), çalışmalarında Bağdat şehrinde Dicle Nehri boyunca su kalitesinin göstergesi ve Toplam Çözünmüş Katıların (TÇK) tahmini için Yapay Sinir Ağı ve Çoklu Doğrusal Regresyon modelleri kullanılmıştır. Bu modelleri oluşturmak için Dicle Nehri üzerindeki dört su arıtma tesisinin 2013 ve 2017 yılları arasındaki girişlerinden beş su parametresi seçildi. Seçilen su parametreleri Toplam Çözünmüş Katılar, Toplam Sertlik, Elektriksel İletkenlik (EC), sülfat ( $SO_4$ ) ve Toplam Katılar olmuştur. Sonuçlar, Dicle nehri su kalitesinin Dünya Sağlık Örgütü (WHO) ve Irak standart içme suyu şartnamelerine göre içmeye uygun olduğunu göstermiş, YSA ve MLR modellerinin performansları belirleme katsayısı ( $R^2$ ) kullanılarak değerlendirilmiştir. Sonuçlar, MLR ve ANN için hesaplanan  $R^2$  değerlerinin sırasıyla 0.797, 0.813 olduğunu göstermiş; ve duyarlılık analizi, TK ve TS'nin TÇK'yi öngörmede yüksek etkilere sahip olduğunu göstermiştir.

## **BÖLÜM 3. MATERYAL VE YÖNTEM**

### **3.1. Materyal**

Bu çalışmada, Bursa Su ve Kanalizasyon İdaresi Genel Müdürlüğü (BUSKİ)' den alınan İznik Gölü'nün belirli ölçüm noktalarına ait su kalitesi parametre verileri kullanılarak bir yapay sinir ağı olan IBM SPSS V.23 programında Neural Network modülü kullanılarak ölçüm sonuçları ile İznik Gölü'nde ki su kalitesinin değerlendirilmesi amaçlanmıştır.

pH, iletkenlik (EC), sıcaklık (T), biyolojik oksijen ihtiyacı (BOİ), kimyasal oksijen ihtiyacı (KOİ), çözünmüş oksijen (ÇO), toplam fosfor (TP), topşam azot (TN), fosfat (PO<sub>4</sub>-P), nitrit azotu (NO<sub>2</sub>N), ve nitrat azotu (NO<sub>3</sub>N) parametrelerinin analiz ölçümleri BUSKİ'den alınarak bu parametrelerden çeşitli model denemeleri yapılarak TP, TN ve ÇO parametreleri için tahmin sonuçları elde edilmiştir.

### **3.2. Yöntem**

#### **3.2.1. Su kalitesi verilerinin değerlendirilmesi**

Çalışmada, İznik Gölü için su kalitesi değerlendirilmesi yapılabilmesi adına göle giriş ve çıkışı olan belirli dereler giriş-çıkış noktası olarak seçilmiştir. Seçilen beş analiz noktasından, dört giriş noktası ve bir çıkış noktası baz alınmıştır. Giriş analiz noktaları Sölöz deresi, Kırandere, Karasu Deresi ve Olukdere olup göl çıkış analiz noktası ise Karsak Deresi olarak belirlenmiştir. Giriş kontrol noktalarına ait pH, EC, T, KOİ, BOİ, ÇO, TP, PO<sub>4</sub>-P, TN, NO<sub>2</sub>N ve NO<sub>3</sub>N parametre verileri girdi olarak çıkış analiz noktasında ise ÇO, TP ve TN parametreleri tahmin amacıyla çıktı verisi olarak kullanılmıştır. Geri yayılım eğitim algoritması kullanan çok katmanlı algılayıcı, IBM SPSS istatistik 23 yazılımı ile parametre verileri kullanılarak model



denemeleri yapılmıştır. Programda çok katmanlı yapay sinir ağı kullanılmıştır. Modellerde ara katmanlardaki nöron sayısı 1 ile 4 arasında farklılık göstermiştir. Modeller çalıştırılırken aktivasyon fonksiyonu ara katmanlarda hiperbolik tanjant, sigmoid fonksiyonu olarak seçilmiştir. Döngü sayısı 1000, minimum nispi değişiklik 0.0001 ve hata oranında minimum değişiklik 0.001'dir.

Modelin doğruluğu ve performansını değerlendirebilmek amacıyla iki istatistiksel indeks kullanılmıştır; belirleme katsayısı ( $R^2$ ), kareler toplamı hatası (SSE). Modeller arasında doğrusal ilişkiyi belirleyebilmek adına  $R^2$  kullanılırken, model hata ölçümleri için SSE kullanılmıştır. SSE, elde edilen tahmin değerinin gerçek değerinden toplam farkını ölçmek için kullanılan istatistiksel yöntemlerden biridir (Obiewa ve ark., 2020).

Hata kareleri toplamı (SSE) gözlemlenen değerlere kıyasla tahmin edilen değerlerin kare farkının toplamını temsil eder. Daha düşük SSE, daha iyi model performansını göstermektedir (Denklem 3.1)

$$SSE = \sum_{i=1}^n (S_{obs} - S_{cal})^2 \quad (3.1)$$

N, tahmin edilen toplam veri kümesi sayısı,  $S_{obs}$  metal katyon konsantrasyonunun gözlemlenen değeri ve  $S_{cal}$  çıkış konsantrasyonu hesaplanan (YSA değeri) değeridir (Obiewa ve ark., 2020).

Korelasyon Katsayısı ( $R^2$ ) Bir modelin  $R^2$  değerinin 1'e yakın olması, tahmin becerisinin o derecede iyi olduğunu gösterir (Denklem 3.2) (Arefinia ve ark., 2020).

$$r = \frac{\sum (S_{obs} - \bar{S}_{obs})x(S_{cal} - \bar{S}_{cal})}{\sqrt{(\sum (S_{obs} - \bar{S}_{obs})^2)x(\sum (S_{cal} - \bar{S}_{cal})^2)}} \quad (3.2)$$

Şcal, hesaplanan ortalama konsantrasyondur. Simüle edilen ve gözlemlenen veriler arasındaki korelasyonun gücünü karakterize eder. Bir'e yakın olan r değerleri iyi bir modeli göstermektedir (Obiewa ve ark., 2020).

### 3.2.2. İznik Gölü'nün su taşıyan ve uzaklaştıran dereler

İznik Gölü Havzanının jeomorfolojik yapısından kaynaklı olarak gölün kuzey ve güney kısımlardaki akarsu uzunluğu genellikle kısa olup Kuzey-Güney yönünde akmakta iken gölün doğu ve batısındaki akarsular ise daha uzun boylu olup D-B doğrultusunda akmaktadırlar. Bölgede ki önemli dereler; Kocadere (Sölöz Deresi), Karasu Deresi (Karadere), Kuru Dere, Oluk Dere, Kırandere ve Karsak (Gölayağı) havzanın başlıca önemli derelerindendir (Garipoğlu ve Uzun, 2019). Bahsedilen dereler Şekil 3.1.'de İznik Gölü uydu görüntüsünde gösterilmiştir.



Şekil 3.1. İznik Gölü uydu görüntüsü

### 3.2.2.1. İznik Gölü'ne giriş yapan dereler

Olukdere, doğrudan Orhangazi ilçesine sınırı olan deredir. Yalova yolu köprüsüne varılana kadar dere içindeki su kalitesi iyidir. Ancak bahsedilen yerden itibaren bağlanan Orhangazi ve civarındaki yakın yerleşim birimlerinin kanalizasyon atıkları, Orhangazi'de bulunan sanayi firmaları, küçük zeytinyağı fabrikaları, Orhangazi Belediyesi Mezbahasının atık suları büyük ölçüde su kalitesini etkilemektedir (Dede, 2009).

Sölöz Deresi, yağış havzası en büyük dere olup göle mansap olur. Sölöz mevkisi'nin kanalizasyon atıkları bu dereye deşarj edilmektedir (Dede, 2009). Yaklaşık 92 km<sup>2</sup>'lik bir alanın sularını boşaltan bu derenin ortalama akım değeri 1,068 m<sup>3</sup>/sn'dir (Meşeli,2010).

Karasu Deresi, göle dökülen önemli akarsulardandır. 273 km<sup>2</sup>'lik bölge sularını toplayan Karasu dersi 2,4 m<sup>3</sup>/sn akış ile göle dökülmektedir.

Kuru Dere'nin, bir diğer adı Derbent'dir. Kuru Dere'nin göle döküldüğü alanda, Sölöz ve Karasu deltaları ile kıyaslama yapıldığında açık biçimde küçük sayılabilecek bir delta oluşmuştur. Taşınan yük miktarının düşük olmasına akarsuyun az yağış alan küçük bir havza olması sebep olmuştur (Akbulak,2006).

Kırandere Avdan Dağı'nın kuzey aklanından doğan Karanlık Dere, ovada doğudan gelen Ana Dere ile birleşerek Kırandere adını alır ve batıya yönelir (Yazıcı, 2020).

### 3.2.2.2. İznik Gölü çıkış deresi

Karsak Deresi, İznik Gölü'nün batı tarafından gölün artan suları Doğu-Batı doğrultusunda bir akım göstererek Gemlik Körfezi'nden Marmara Denizi'ne boşalım sağlamaktadır. (Garipoğlu ve Uzun, 2019).

### 3.2.3. Derelere ait ölçüm noktaları verileri

Ölçüm noktalarının 2017-2021 yıllarında belirli mevsim aylarında yapılan analiz sonuçlarının, parametre bazında yıllık ortalamaları alınarak sonuçlar giriş-çıkış noktaları için tablolar haline getirilmiştir.

#### 3.2.3.1. İznik Gölü giriş noktalarının yıllık ortalama ölçüm verileri

Gölün giriş noktaları olan Sölöz, Kırandere, Karasu ve Olukdere'den girdi verisi olarak YSA'da kullanılarak pH, EC, T, KOİ, BOİ, ÇO, TP, PO<sub>4</sub>-P, TN, NO<sub>2</sub>N ve NO<sub>3</sub>N parametreleri alınmış olup numune ölçüm verilerinin noktasal bazda yıllık ortalamaları Tablo 3.1., 3.2., 3.3. ve 3.4.'te gösterilmiştir.

Tablo 3.1. Sölöz Deresi 2017-2021 yılları analiz ölçüm ortalamaları

| YIL  | PH   | EC     | BOİ   | TN   | PO <sub>4</sub> -P | T      | ÇO   | KOİ   | NO <sub>3</sub> N | NO <sub>2</sub> N | TP    |
|------|------|--------|-------|------|--------------------|--------|------|-------|-------------------|-------------------|-------|
|      | -    | µm/cm  | mg/L  | mg/L | mg/L               | °C     | mg/L | mg/L  | mg/L              | mg/L              | mg/L  |
| 2017 | 7,75 | 581,25 | 2,75  | 0,96 | 0,12               | 14,85  | 7,9  | 16,75 | 0,416             | 0,056             | 0,146 |
| 2018 | 8,04 | 541,66 | 117,6 | 2,76 | 1,42               | 13,466 | 7,18 | 309   | 0,193             | 0,01              | 1,672 |
| 2019 | 7,98 | 576,25 | 4,33  | 1,63 | 0,205              | 17,4   | 7,4  | 14,5  | 0,342             | 0,18              | 0,249 |
| 2020 | 8,23 | 520    | 3     | 2,14 | 0,14               | 10,4   | 9,75 | 20    | 0,915             | 0,1               | 0,47  |
| 2021 | 8,42 | 497    | 2,5   | 0,87 | 0,123              | 9,65   | 9,8  | 16    | 0,256             | 0,11              | 0,098 |

Sölöz deresi için yıl bazında bakıldığında en yüksek pH 8,42 ile 2021 yılında ölçülmüştür. İletkenlik (EC) 581,25 µm/cm ile 2017 yılında en yüksek değerini görmüştür. Biyolojik oksijen ihtiyacı (BOİ), 2018 yılında 117,6 mg/l deęeriyle dięer yıllara kıyasla büyük bir artış göstermiştir. Kimyasal oksijen ihtiyacı (KOİ), BOİ gibi en yüksek deęerini 309 mg/l ile 2018 yılında görmüştür. Toplam azot (TN) ve toplam fosfor (TP), yıl kıyasında artış-azalış göstermiş olup en yüksek ölçümler sırasıyla 2,76 mg/l ve 1,672 mg/l ile 2018 yılındadır. PO<sub>4</sub>-P içinde 2018 yılı 1,42 mg/l ile en yüksek konsantrasyonun görüldüğü yıldır. Sıcaklığın (T), en yüksek olduęu ortalama deęeri 2019'da 17,4°C olmuştur. Çözünmüş oksijen (ÇO), en düşük olduęu olduęu yıl 2018 yılı olup konsantrasyonu 7,18 mg/l'dir. Nitrat azotu (NO<sub>3</sub>N), 2020 yılında 0,915 mg/l konsantrasyonu ile en yüksek deęerine ulaşmıştır. Nitrit

azotu (NO<sub>2</sub>N) yıl bazında ortalama ölçüm değerlerine bakıldığında yakın konsantrasyon değerleri göstermiştir.

Tablo 3.2. Kırandere 2017-2021 yılları analiz ölçüm ortalamaları

| YIL  | PH<br>- | EC<br>µm/cm | BOİ<br>mg/L | TN<br>mg/L | PO <sub>4</sub> -P<br>mg/L | T<br>°C | ÇO<br>mg/L | KOİ<br>mg/L | NO <sub>3</sub> N<br>mg/L | NO <sub>2</sub> N<br>mg/L | TP<br>mg/L |
|------|---------|-------------|-------------|------------|----------------------------|---------|------------|-------------|---------------------------|---------------------------|------------|
| 2017 | 8,7     | 726         | 2           | 2,62       | 0,1                        | 14,9    | 11,1       | 18          | 2,37                      | 0,03                      | 0,11       |
| 2018 | 8,46    | 704,5       | 2,25        | 2,67       | 0,09                       | 19,08   | 10,8       | 14          | 2,26                      | 0,09                      | 0,06       |
| 2019 | 8,01    | 746,75      | 2,5         | 3,54       | 0,1                        | 16,25   | 13,5       | 16,7        | 2,15                      | 0,11                      | 0,10       |
| 2020 | 8,8     | 722,33      | 2,33        | 1,59       | 0,1                        | 23,65   | 11,7       | 22,3        | 1,31                      | 0,11                      | 0,07       |
| 2021 | 8,49    | 688         | 2           | 4,52       | 0,1                        | 8,25    | 13,3       | 16          | 2,94                      | 0,1                       | 0,079      |

Kırandere için yıl bazında bakıldığında en yüksek pH 8,8 ile 2020 yılında, iletkenlik (EC) 746,75 µm/cm ile 2019 yılında, biyolojik oksijen ihtiyacı (BOİ), yıllara genel olarak bakıldığında yakın konsantrasyon değerlerine sahiptir. Kimyasal oksijen ihtiyacı (KOİ), en yüksek değerini 22,3 mg/l ile 2020 yılında görmüştür. Toplam azot (TN) yıl kıyasında artış-azalış göstermiş olup en yüksek ölçüm 2021 yılında 4,52 mg/l'dir. Toplam fosfor (TP), yıl ortalamalarında konsantrasyon değerinde çok fark göstermemiş olup PO<sub>4</sub>-P içinde aynı durum geçerlidir. Sıcaklığın (T), en yüksek olduğu ortalama değeri 2020'da 23,65 °C olmuştur. Çözünmüş oksijen (ÇO), en düşük olduğu yıl 2018 olup konsantrasyonu 10,8 mg/l'dir. Nitrat azotu (NO<sub>3</sub>N), 2021 yılında 2,94 mg/l konsantrasyonu ile en yüksek değerine ulaşmıştır. Nitrit azotu (NO<sub>2</sub>N) yıl bazında ortalama ölçüm değerlerine bakıldığında yakın konsantrasyon değerleri göstermiştir.

Tablo 3.3. Karasu Deresi 2017-2021 yılları analiz ölçüm ortalamaları

| YIL  | PH<br>- | EC<br>µm/cm | BOİ<br>mg/L | TN<br>mg/L | PO <sub>4</sub> -P<br>mg/L | T<br>°C | ÇO<br>mg/L | KOİ<br>mg/L | NO <sub>3</sub> N<br>mg/L | NO <sub>2</sub> N<br>mg/L | TP<br>mg/L |
|------|---------|-------------|-------------|------------|----------------------------|---------|------------|-------------|---------------------------|---------------------------|------------|
| 2017 | 8,48    | 379         | 2           | 0,652      | 0,11                       | 13,1    | 10,6       | 16,4        | 0,395                     | 0,03                      | 0,15       |
| 2018 | 8,01    | 437         | 2           | 0,702      | 0,077                      | 18,4    | 9,69       | 13,2        | 0,25                      | 0,08                      | 0,032      |
| 2019 | 8,28    | 1021,5      | 2,25        | 1,377      | 0,1                        | 13,6    | 11,1       | 15,7        | 1,067                     | 0,1                       | 0,049      |
| 2020 | 8,38    | 559         | 2           | 0,97       | 0,1                        | 15,9    | 10,5       | 18,3        | 0,203                     | 0,1                       | 0,032      |
| 2021 | 8,54    | 341         | 2           | 0,64       | 0,1                        | 12,9    | 10,9       | 16          | 0,47                      | 0,1                       | 0,025      |

Karasu deresi için yıl bazında bakıldığında en yüksek pH 8,54 ile 2021 yılında, iletkenlik (EC) 1021,5 µm/cm ile 2019 yılında büyük artış göstermiştir. Biyolojik

oksijen ihtiyacı (BOİ), yıllara genel olarak bakıldığında yakın konsantrasyon değerlerine sahiptir. Kimyasal oksijen ihtiyacı (KOİ), en yüksek değerini 18,3 mg/l ile 2020 yılında görmüştür. Toplam azot (TN) yıl kıyasında artış-azalış göstermiş olup en yüksek ölçüm 2019 yılında 1,377 mg/l'dir. Toplam fosfor (TP), yıl ortalamalarında konsantrasyon değerinde çok fark göstermemiş olup PO<sub>4</sub>-P içinde aynı durum geçerlidir. Sıcaklığın (T), en yüksek olduğu ortalama değeri 2018'de 18,4 °C olmuştur. Çözünmüş oksijen (ÇO), en düşük olduğu yıl 2018 olup konsantrasyonu 9,69 mg/l'dir. Nitrat azotu (NO<sub>3</sub>N), 2019 yılında 1,067 mg/l konsantrasyonu ile en yüksek değerine ulaşmıştır. Nitrit azotu (NO<sub>2</sub>N) yıl bazında ortalama ölçüm değerlerine bakıldığında yakın konsantrasyon değerleri göstermiştir.

Tablo 3.4. Olukdere 2017-2021 yılları analiz ölçüm ortalamaları

| YIL  | PH   | EC<br>µm/cm | BOİ<br>mg/L | TN<br>mg/L | PO <sub>4</sub> -P<br>mg/L | T<br>°C | ÇO<br>mg/L | KOİ<br>mg/L | NO <sub>3</sub> N<br>mg/L | NO <sub>2</sub> N<br>mg/L | TP<br>mg/L |
|------|------|-------------|-------------|------------|----------------------------|---------|------------|-------------|---------------------------|---------------------------|------------|
| 2017 | 8,18 | 478         | 5,5         | 1,13       | 0,21                       | 15,4    | 8,65       | 16          | 0,615                     | 0,1                       | 0,318      |
| 2018 | 8,04 | 394,5       | 2           | 2,66       | 0,105                      | 15,3    | 8,24       | 16          | 1,05                      | 0,1                       | 0,154      |
| 2019 | 7,86 | 484         | 3           | 2,23       | 0,11                       | 16,2    | 8,43       | 12,33       | 0,886                     | 0,1                       | 0,14       |
| 2020 | 8,44 | 467         | 2           | 1,17       | 0,1                        | 13,1    | 9,9        | 11          | 0,86                      | 0,1                       | 0,087      |
| 2021 | 8,12 | 524         | 4,5         | 1,68       | 0,1                        | 16,1    | 8,35       | 18          | 0,87                      | 0,13                      | 0,146      |

Olukdere için yıl bazında bakıldığında en yüksek pH 8,44 ile 2020 yılında, iletkenlik (EC) 524 µm/cm ile 2021 yılında, biyolojik oksijen ihtiyacı (BOİ), yıllara genel olarak bakıldığında en yüksek konsantrasyon değerlerini 5,5 mg/l ile 2017 yılında görmüştür. Kimyasal oksijen ihtiyacı (KOİ), en yüksek değerini 18 mg/l ile 2021 yılında görmüştür. Toplam azot (TN) yıl kıyasında artış-azalış göstermiş olup en yüksek ölçüm 2018 yılında 2,66 mg/l'dir. Toplam fosfor (TP), yıl ortalamalarında konsantrasyon değerinde çok fark göstermemiş olup PO<sub>4</sub>-P içinde aynı durum geçerlidir. Sıcaklığın (T), en yüksek olduğu ortalama değeri 2019'da 16,2 °C olmuştur. Çözünmüş oksijen (ÇO), en düşük olduğu yıl 2018 olup konsantrasyonu 8,24 mg/l'dir. Nitrat azotu (NO<sub>3</sub>N), 2018 yılında 1,05 mg/l konsantrasyonu ile en yüksek değerine ulaşmıştır. Nitrit azotu (NO<sub>2</sub>N) yıl bazında ortalama ölçüm değerlerine bakıldığında yakın konsantrasyon değerleri göstermiştir.

### 3.2.3.2. İznik Gölü çıkış noktasının yıllık ortalama ölçüm verileri

Göl çıkış noktası olan Karsak Deresinden çıktı verisi olarak YSA'da kullanılmak üzere TN (mg/l), TP (mg/l) ve ÇO (mg/l) parametreleri alınmış olup verilerin yıllık ortalamaları Tablo 3.5.'de gösterilmiştir.

Tablo 3.5. Karsak Deresi 2017-2021 yılları analiz ölçüm ortalamaları

| YIL  | PH   | EC<br>µm/cm | BOİ<br>mg/L | TN<br>mg/L | PO <sub>4</sub> P<br>mg/L | T<br>°C | ÇO<br>mg/L | KOİ<br>mg/L | NO <sub>3</sub> N<br>mg/L | NO <sub>2</sub> N<br>mg/L | TP<br>mg/L |
|------|------|-------------|-------------|------------|---------------------------|---------|------------|-------------|---------------------------|---------------------------|------------|
| 2017 | 8,29 | 749         | 2           | 0,74       | 0,06                      | 17,7    | 10,075     | 17,33       | 0,43                      | 0,055                     | 0,06       |
| 2018 | 8,39 | 571         | 2           | 0,75       | 0,1                       | 17,0    | 10,38      | 16          | 0,35                      | 0,1                       | 0,026      |
| 2019 | 8,13 | 550         | 2           | 1,15       | 0,1                       | 13,8    | 10,39      | 14,66       | 0,305                     | 0,1                       | 0,394      |
| 2020 | 8,33 | 498         | 2           | 0,34       | 0,1                       | 10,4    | 10,25      | 12          | 0,17                      | 0,1                       | 0,188      |
| 2021 | 8,33 | 653         | 2           | 0,81       | 0,15                      | 9,15    | 10,9       | 16          | 0,35                      | 0,1                       | 0,032      |

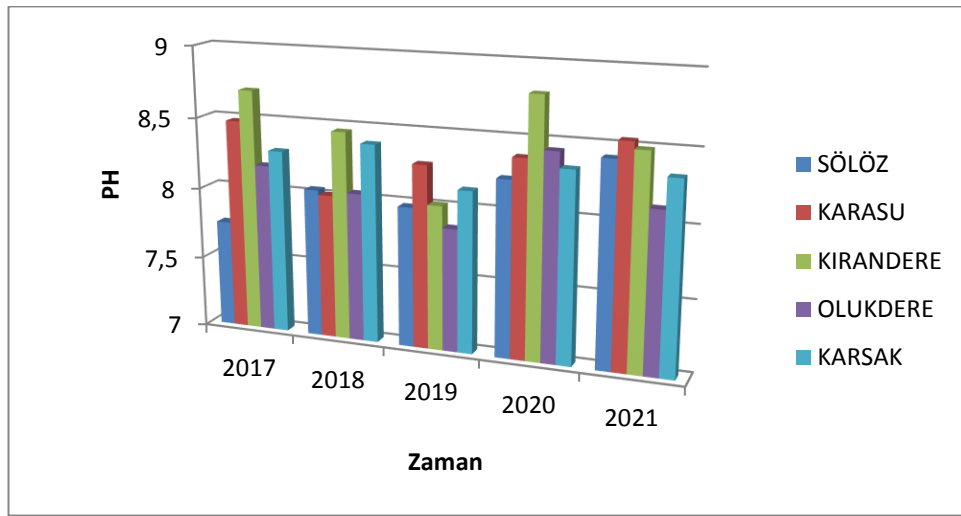
Karsak çıkış deresi için yıl bazında bakıldığında en yüksek pH 8,39 ile 2018 yılında, iletkenlik (EC) 749 µm/cm ile 2017 yılında'dır. Biyolojik oksijen ihtiyacı (BOİ), yıllara genel olarak bakıldığında aynı konsantrasyon değeri göstermiştir. Kimyasal oksijen ihtiyacı (KOİ), en yüksek değerini 17,33 mg/l ile 2017 yılında görmüştür. Toplam azot (TN) yıl kıyasında artış-azalış göstermiş olup en yüksek ölçüm 2019 yılında 1,15 mg/l'dir. Toplam fosfor (TP), yıl ortalamalarında konsantrasyon değerinde çok fark göstermemiş olup PO<sub>4</sub>-P içinde aynı durum geçerlidir. Sıcaklığın (T), en yüksek olduğu ortalama değeri 2017'de 17,7 °C olmuştur. Çözünmüş oksijenin (ÇO), en düşük olduğu yıl 2017 olup konsantrasyonu 10,075 mg/l'dir. Nitrat azotu (NO<sub>3</sub>N) ve Nitrit azotu (NO<sub>2</sub>N) yıl bazında ortalama ölçüm değerlerine bakıldığında yakın konsantrasyon değerleri göstermiştir.

### 3.2.4. İznik Gölü için kullanılan parametrelerin dereler bazında kıyaslanması

Giriş-çıkış noktaları olarak seçilen dereler (Sölöz, Karasu, Olukdere, Kırandere ve Karsak) için 2017-2021 parametre verileri hakkında bilgilerle noktasal bazda oluşturulan grafikler aşağıda verilmiş olup Kıtaiçi Yerüstü Su Kaynaklarının Genel Kimyasal ve Fizikokimyasal Parametreler Açısından Sınıflarına Göre Kalite Kriterleri açısından değerlendirmeler yapılmıştır.

### 3.2.4.1. pH

pH, bir su çözeltisinin asitliğinin ya da bazikliğinin ölçüsüdür. pH ölçeği genellikle 0 ila 14 arasındadır. Ölçek lineer değil, logaritmiktir. Örneğin, pH'ı 6 olan bir çözelti, pH'ı 7 olan bir çözeltilerden on kat daha asidiktir. pH'ı 7.0'ın altında olan su asidik olarak kabul edilirken, pH değeri 7.0'dan büyük olan su, bazik veya alkali olarak kabul edilir (Gorde ve Jadhav, 2013). Sudaki canlı yaşamında da pH değerinin 6.5-7.5 arasında olması gereklidir (Korkut, 2012).



Şekil 3.2. Analiz noktalarının 2017-2021 yıllarına ait ortalama pH verileri


İznik Gölü analiz noktalarında ki 2017-2021 yıllarına ait dere bazında yıllık ortalama pH ölçüm değerlerine ait grafik Şekil 3.2.'de görüldüğü gibidir. Kol bazında yıllara ait ortalama pH değerleri alındığında, Sölöz, Karasu, Kırandere, Olukdere ve Karsak deresine ait ortalama analiz sonuçlarına göre tüm dereler I.Sınıf Yüksek Kaliteli Su (Çok iyi su) olduğu görülmektedir.

### 3.2.4.2. İletkenlik (EC)

İletkenlik, sulu bir çözeltinin elektrik akımı taşıma kapasitesinin sayısal bir ifadesidir. İletkenlik iyonların varlığına, bunların toplam konsantrasyonuna, hareketliliğine, değerlik ve bağlı konsantrasyonlarına ve sıvının sıcaklığına bağlıdır. Çoğu inorganik asit, baz ve tuzların çözeltileri nispeten iyi iletkenlerdir (Gorde ve



Jadhav, 2013). Elektriksel iletkenlik sudaki çözünmüş katı madde ile ilgili bir indekstir. Yüksek elektriksel iletkenlik değerleri, yüksek kimyasal ayrışma ile açıklanabilir (Oinam ve ark., 2011).




Şekil 3.3. Analiz noktalarının 2017-2021 yıllarına ait ortalama iletkenlik verileri

İznik Gölü analiz noktalarında ki 2017-2021 yıllarına ait dere bazında yıllık ortalama EC ölçüm değerlerine ait grafik Şekil 3.3.'de görüldüğü gibidir. SKKY'ye göre su kalitesi sınıflandırması yapılmamıştır. Ancak 2019 yılında Karasu deresinden gelen iletkenlik değeri hızlı bir yükseliş göstermiş ve 1021,5 µm/cm pik yapmıştır.

### 3.2.4.3. Biyolojik oksijen ihtiyacı (BOİ)

Biyolojik oksijen ihtiyacı (BOİ), su kütlesinin kirlilik durumunu tahmin etmede çok önemli bir parametredir (Pradeep ve ark., 2012). BOİ doğrudan gölde bulunan ölü organik maddenin ayrışması ile bağlantılıdır ve dolayısıyla daha yüksek BOİ değerleri kirlilik durumu ile doğrudan ilişkilendirilebilir ve ÇO konsantrasyonu ile ters bir ilişkiye sahiptir (Namdev ve ark.,2011).




Şekil 3.4. Analiz noktalarının 2017-2021 yıllarına ait ortalama BOİ verileri

İznik Gölü analiz noktalarında ki 2017-2021 yıllarına ait dere bazında yıllık ortalama BOİ ölçüm değerlerine ait grafik Şekil 3.4.'de görüldüğü gibidir. Kol bazında yıllara ait ortalama BOİ değerleri alındığında, Sölöz, Karasu, Kırandere, Olukdere ve Karsak deresine ait ortalama analiz sonuçlarına göre sırasıyla IV.Sınıf Çok Kirlenmiş Su (Zayıf su), I.Sınıf, I.Sınıf, I.Sınıf, I.Sınıf Yüksek Kaliteli Su (Çok iyi su) olduğu görülmektedir.

#### 3.2.4.4. Fosfat (PO<sub>4</sub>P)

Fosfat, rezervuar verimliliğinin korunmasında önemli besleyici ve sınırlayıcı faktörlerden biridir (Jones ve Lee, 1982). Ortofosfatlar parçalanma olmaksızın biyolojik metabolizmaya alınabilmelerine karşılık polifosfatlar, iki veya daha fazla fosfor, oksijen ve bazı durumlarda hidrojen atomlarıyla kompleks bir molekül şeklindedir (Metcalf ve ark., 1991). Ortofosfatlar daha hızlı absorbe edildikleri için ötrofikasyon sürecinde azottan daha etkilidirler (Sharpley ve ark., 2001).




Şekil 3.5. Analiz noktalarının 2017-2021 yıllarına ait ortalama fosfat verileri

İznik Gölü analiz noktalarında ki 2017-2021 yıllarına ait dere bazında yıllık ortalama  $PO_4\text{-P}$  ölçüm değerlerine ait grafik Şekil 3.5.'de görüldüğü gibidir.  $PO_4\text{-P}$  konsantrasyon değeri 2018 yılında Sölöz deresinde en yüksek değere ulaşmıştır. Diğer yıllarda da yakın konsantrasyon değerleri birbirini takip etmiştir.

#### 3.2.4.5. Sıcaklık (T)

Bir su kaynağının fiziksel, biyolojik ve kimyasal özelliklerinin birçoğu sıcaklıktan doğrudan etkilendiğinden, su sıcaklığı çok önemlidir (Srivastava ve Kumar, 2013). Sıcaklık, sucul yaşamın devamı için en önemli faktörlerden biridir (Gupta ve ark., 2009).



Şekil 3.6. Analiz noktalarının 2017-2021 yıllarına ait ortalama sıcaklık verileri


İznik Gölü analiz noktalarında ki 2017-2021 yıllarına ait dere bazında yıllık ortalama Sıcaklık (°C) ölçüm değerlerine ait grafik Şekil 3.6.'da görüldüğü gibidir. Kol bazında yıllara ait ortalama Sıcaklık (°C) değerleri alındığında, Sölöz, Karasu, Kırandere, Olukdere ve Karsak deresine ait ortalama analiz sonuçlarına göre tüm dereler I.Sınıf Yüksek Kaliteli Su (Çok iyi su) olduğu görülmektedir.

#### 3.2.4.6. Çözünmüş oksijen (ÇO)

Çözünmüş oksijen, su kalitesi değerlendirmesinde önemli bir parametredir ve suda hakim olan fiziksel ve biyolojik süreçleri yansıtır. Çoğu suda yaşayan organizma için en önemli gazdır; solunum için serbest oksijen veya çözünmüş oksijen gereklidir (Uddin ve ark., 2014). Doğal sularda çözünmüş oksijen konsantrasyonu, oksijenin atmosferdeki kısmi basıncı, su içerisindeki konsantrasyonu ve sıcaklığa bağlı olarak değişir (Avvannavar ve ark., 2008).

Çözünmüş oksijen seviyeleri çok düştüğünde canlı yaşamları tehlikeye düşer. Sudaki düşük çözünmüş oksijen seviyeleri, olası kirliliğin bir işaretidir. Bir su kütlesinde yüksek çözünmüş oksijen değeri varsa, su kalitesinin çözünmüş oksijen değerine göre iyi olduğu anlamına gelir. Öte yandan, bir su kütlesinde düşük çözünmüş

oksijen değeri varsa, su kalitesi çözülmüş oksijen değerine göre kötü olarak kabul edilir (Srivastava ve Kumar, 2013).




Şekil 3.7. Analiz noktalarının 2017-2021 yıllarına ait ortalama ÇO verileri

İznik Gölü analiz noktalarında ki 2017-2021 yıllarına ait dere bazında yıllık ortalama ÇO ölçüm değerlerine ait grafik Şekil 3.7.'de görüldüğü gibidir. Kol bazında yıllara ait ortalama ÇO değerleri alındığında, Sölöz, Karasu, Kırandere, Olukdere ve Karsak deresine ait ortalama analiz sonuçlarına göre tüm derelerin I.Sınıf Yüksek Kaliteli Su (Çok iyi su) olduğu görülmektedir.

### 3.2.4.7. Kimyasal oksijen ihtiyacı (KOİ)

KOİ, biyolojik olarak parçalanabilen kirleticilerin oksijen ihtiyacını ve biyolojik olarak parçalanamayan oksitlenebilen kirleticilerin oksijen ihtiyacını ölçer. KOİ, sadece bakteri gibi biyolojik olarak aktif maddelerin miktarını ölçmek için değil aynı zamanda sudaki biyolojik olarak aktif olmayan organik madde miktarını ölçmek için kullanılan bir su kalitesi ölçüsüdür (Gupta ve ark., 2009). KOİ, sudaki kirliliğin boyutunu değerlendirmek için güvenilir bir parametredir. Organik madde ve inorganik madde konsantrasyonu arttıkça suyun KOİ'si artar (Boyd, 1981).




Şekil 3.8. Analiz noktalarının 2017-2021 Yıllarına Ait Ortalama KOİ Verileri

İznik Gölü analiz noktalarında ki 2017-2021 yıllarına ait dere bazında yıllık ortalama KOİ ölçüm değerlerine ait grafik Şekil 3.8.'de görüldüğü gibidir. Kol bazında yıllara ait ortalama KOİ değerleri alındığında, Sölöz, Karasu, Kırandere, Olukdere ve Karsak deresine ait ortalama analiz sonuçlarına göre sırasıyla IV.Sınıf Çok Kirlenmiş Su (Zayıf su), I.Sınıf, I.Sınıf, I.Sınıf, I.Sınıf Yüksek Kaliteli Su (Çok iyi su) olduğu görülmektedir.

#### 3.2.4.8. Nitrat azotu (NO<sub>3</sub>N)

Nitratlar, azotun oksitlenmiş formunun bir ölçüsüdür ve su ortamlarında temel bir makro besindir (Srivastava ve Kumar, 2013). Nitrat, nitrifikasyon işlemi, yani aerobik bakterilerin etkisiyle NO<sub>2</sub>'nin NO<sub>3</sub>'e oksidasyonu yoluyla oluşturulur. Su bitkileri tarafından doğrudan alınmayan nitrat, anaerobik tortularda denitrifiye edilir (Furnas, 2018). Sudaki nitratın ana kaynaklarından bazıları insan ve hayvan atıkları, endüstriyel atıklar, gübre ve kimyasalların kullanımındır.




Şekil 3.9. Analiz noktalarının 2017-2021 yıllarına ait ortalama NO<sub>3</sub>N verileri

İznik Gölü analiz noktalarında ki 2017-2021 yıllarına ait dere bazında yıllık ortalama NO<sub>3</sub>N ölçüm değerlerine ait grafik Şekil 3.9.'da görüldüğü gibidir. Kol bazında yıllara ait ortalama NO<sub>3</sub>N değerleri alındığında, Sölöz, Karasu, Kırandere, Olukdere ve Karsak deresine ait ortalama analiz sonuçlarına göre tüm derelerin I.Sınıf Yüksek Kaliteli Su (Çok iyi su) olduğu görülmektedir. Kırandereden gelen NO<sub>3</sub>N konsantrasyonu tüm yıllarda diğer derelere göre daha yüksektir.

#### 3.2.4.9. Nitrit azotu (NO<sub>2</sub>N)

Nitrit, amonyumun nitrata oksidasyonunda bir ara maddedir. Yüksek bir ortam nitrit konsantrasyonu, tatlı su balıkları için potansiyel bir sorundur, çünkü nitrit, klorür ile rekabet halinde solungaçlardan aktif olarak alınır. Nitrit, balıklar için iyi bilinen bir toksik maddenin yanı sıra iyon düzenleyici, solunum, kardiyovasküler, endokrin ve boşaltım süreçleri dahil olmak üzere birçok fizyolojik işlevi bozan bir maddedir (Kroupova ve ark., 2005).



Şekil 3.10. Analiz noktalarının 2017-2021 yıllarına ait ortalama NO<sub>2</sub>N verileri


İznik Gölü analiz noktalarında ki 2017-2021 yıllarına ait dere bazında yıllık ortalama NO<sub>2</sub>N ölçüm değerlerine ait grafik Şekil 3.10.'da görüldüğü gibidir. Kol bazında yıllara ait ortalama NO<sub>2</sub>N değerleri alındığında, Sölöz, Karasu, Kırandere, Olukdere ve Karsak deresine ait ortalama analiz sonuçlarına göre tüm derelerin I.Sınıf Yüksek Kaliteli Su (Çok iyi su) olduğu görülmektedir. Sölöz Deresi gelen NO<sub>2</sub>N konsantrasyonu 2019 yılında diğer derelere göre pik yapmıştır.

### 3.2.4.10. Toplam fosfor ve toplam azot (TP,TN)

Bitkisel ve hayvansal üretim için temel bir besin maddesi olan fosfor (P), gelişmiş dünyada su kalitesi bozulmalarının en yaygın biçimlerinden biri olan tatlı su ötrofikasyonunu hızlandırabilir. Tarım, çevrede önemli bir P kaynağı olarak kabul edilmektedir (Sharpley ve ark.,2001). Azot, gübrelerde, insan ve hayvan atıklarında, bahçe atıklarında ve havada bulunan temel bir bitki besin maddesidir. Azot ayrıca göllere ve akarsulara inorganik azot ve amonyak olarak girebilir. Azot, sucul sistemlere birçok biçimde girebildiğinden, bu sistemlerde bol miktarda mevcut azot bulunur (Gorde ve Jadhav, 2013). Yüzey sularında azot ve fosfor bileşenleri nütrient kirliliğe sebep olan önemli bileşenler olup, konsantrasyonları yüksek olduğunda ötrofikasyona neden olabilmektedirler. İznik Gölü havzasında ve ovalarda da yoğun tarım yöntemleri kullanılarak başta zeytin olmak üzere çeşitli ürünler yetiştirilmekte;




bu ovaları çevreleyen yayla alanlarında kuru tarım teknikleri kullanılarak tahıl ve yem bitkileri yetiştirilmektedir (Yazgan ve Demirtaş, 2005). İznik Gölü Havzası'ndaki tarım alanlarının oranı küçük gibi görünse de bu alanlar nüfusun çoğunluğu tarafından geçimini sağlamak için yoğun olarak kullanılmaktadır (Akpınar ve Bulut, 2010).



Şekil 3.11. Analiz noktalarının 2017-2021 yıllarına ait ortalama TP verileri

İznik Gölü analiz noktalarında ki 2017-2021 yıllarına ait ortalama TP ölçüm değerlerine ait grafik Şekil 3.11.'de görüldüğü gibidir. Kol bazında yıllara ait ortalama TP değerleri alındığında, Sölöz, Karasu, Kırandere, Olukdere ve Karsak deresine ait ortalama analiz sonuçlarına göre tüm derelerin II.Sınıf İyi Su (Az kirlenmiş su), I.Sınıf, I Sınıf Yüksek Kaliteli Su, II.Sınıf (Az kirlenmiş su), I Sınıf Yüksek Kaliteli Su olduğu görülmektedir. Sölöz Deresinden gelen TP konsantrasyonu 2018 yılında diğer derelere göre en yüksek değeri görmüştür.



Şekil 3.12. Analiz noktalarının 2017-2021 yıllarına ait ortalama TN verileri

İznik Gölü analiz noktalarında ki 2017-2021 yıllarına ait ortalama TN ölçüm değerlerine ait grafik Şekil 3.12.'de görüldüğü gibidir. Kırandereden gelen TN konsantrasyonu diğer derelere göre 2019 ve 2021 yıllarında yüksek konsantrasyon değerleri göstermiştir.

## **BÖLÜM 4. ARAŞTIRMA BULGULARI**

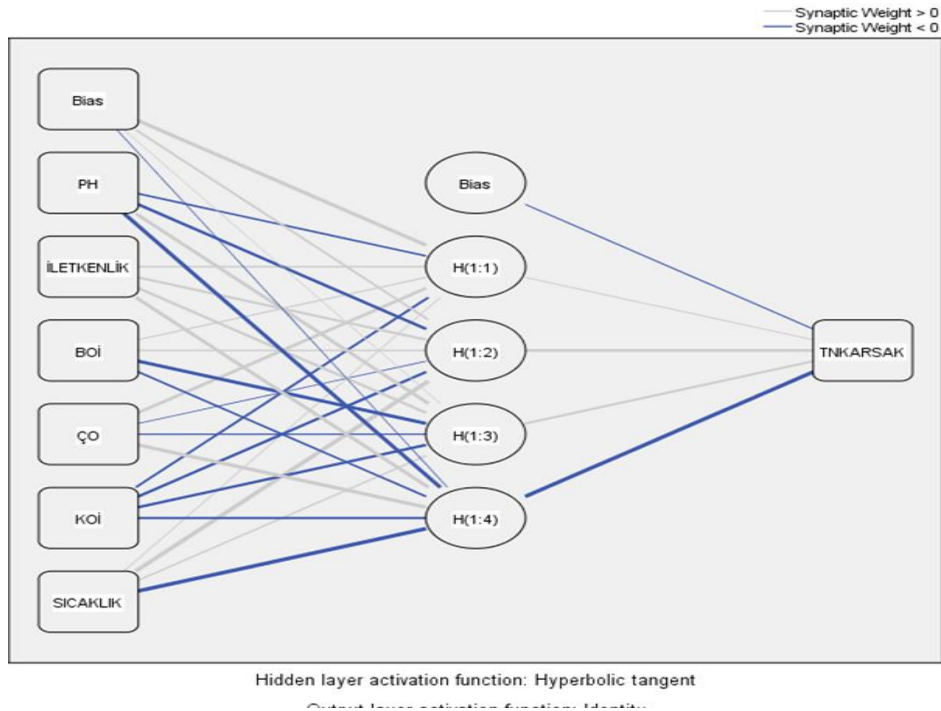
Uzak konumlu su havzalarında veya büyük su kütlelerinde, su kalitesi parametrelerinin izlenmesi, yüksek maliyetler ve saha erişilemezliği nedeniyle çoğu zaman mümkün olmadığından yapılan bir çalışmada geniş ve lojistik açıdan zor bir alanda su kalitesi parametrelerini tahmin etmek için uygun maliyetli uzaktan algılama tabanlı bir metodoloji geliştirilmiştir (Chebud ve ark., 2012).

Yapılan bir çalışmada Tayvan'daki 20 rezervuardaki istasyonlardan on yıl boyunca (1995-2016) toplanan veriler, modelleme sisteminin girdisi olarak önceden işlenmiştir. Uygulama çeşitliliği için RapidMiner Studio, Azure Machine Learning Studio, IBM SPSS Modeli, WEKA ve MATLAB olmak üzere beş veri madenciliği yazılım paketini kullanarak suyun kalitesini tahmin etmek için temel modeller, topluluk modelleri ve hibrit bir metasezgisel regresyon modeli önerilmiştir. Kapsamlı karşılaştırma, bir katmanlama yöntemine dayanan topluluk YSA modelinin, diğer tekli, topluluk modellerinden ve hibrit metasezgisel regresyon modelinden daha iyi olduğunu göstermiştir. Hem tahminin doğruluğu hem de uygulamanın etkinliği, uygulayıcıları suyun yönetimiyle ilgili çalışmaların planlanmasında desteklemek için kabul edilir düzeyde olduğu görülmüştür. Bu çalışma su kalitesi parametrelerinin değerlendirilmesi için kullanılabilir bir yaklaşım sağlamaktadır. Elde edilen sonuçlar, IBM SPSS Modelinin temel analizin geliştirilmesinde en etkili olduğunu göstermiştir. 15 ayrı modelin hepsinde IBM SPSS en iyi performansı vermiştir. Bu nedenle hızlı ve basit veri analizi gerektiğinde su kalitesi tahminleri yapmak için önerilmektedir. IBM SPSS Modeli kullanılarak uygulanan katmanlama yönteminin, rezervuarlardaki suyun kalitesini tahmin etmede en doğru yöntem olabileceği vurgulanmıştır. Analistler, IBM SPSS Modeli yazılım paketini kullanarak makul doğrulukla hızlı ve basit tahminlerde bulunabileceği


sonucuna varılmıştır (Chou ve ark., 2018). Bundan dolayı yapılan bu çalışmada İznik Gölü'nün su kalitesini tahmin etmede IBM SPSS istatistik 23 yazılımı kullanılmıştır.

#### 4.1. Sölöz Deresi için Yapılan YSA Modelleri ve R<sup>2</sup> Grafikleri

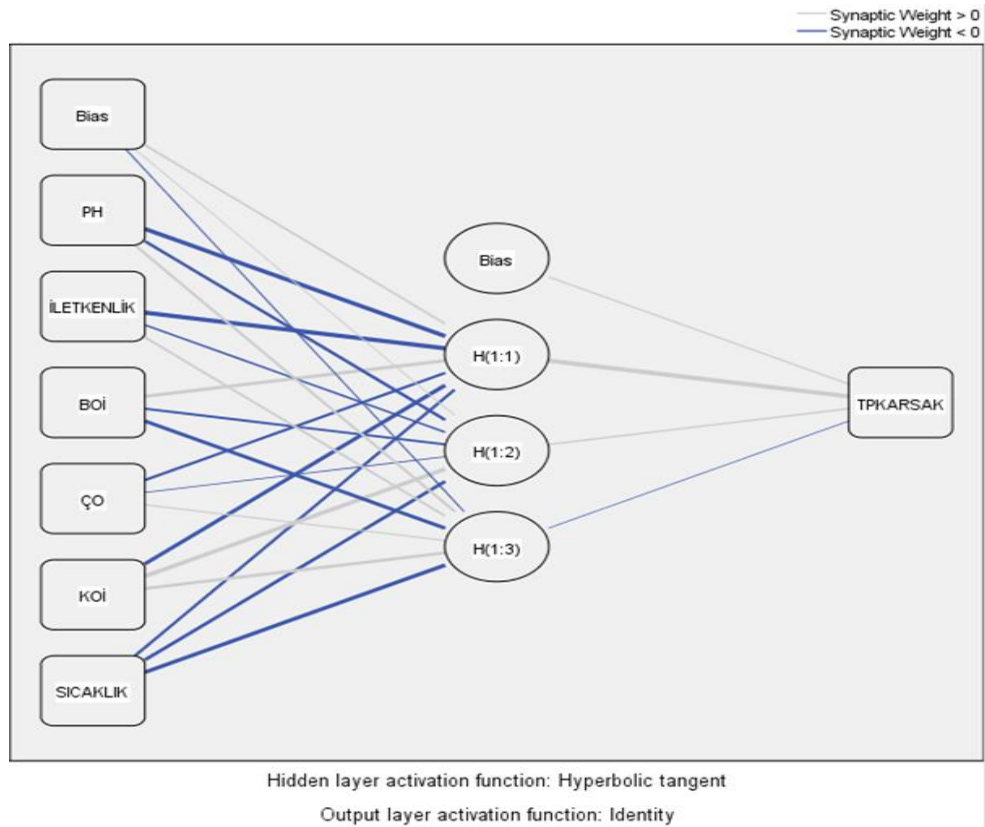
Sölöz deresine ait pH, EC, T, KOİ, BOİ, ÇO, TP, PO<sub>4</sub>-P, TN, NO<sub>2</sub>N ve NO<sub>3</sub>N toplam 11 parametre girdi verisi şeklinde baz alınarak çeşitli model denemeleri yapılmıştır. Çıktı verisi olarak Karsak deresinin TP, TN ve ÇO parametreleri ile korelasyon sağlanarak en iyi R<sup>2</sup> değerini veren modellerin oluşturulması amaçlanmıştır. Programda modelleme yapılırken aktivasyon fonksiyonu olarak sigmoid ve hiperbolik tanjant fonksiyonları seçilmiştir. Sölöz Deresi için oluşturulan modellerde ara katmandaki nöron sayıları 2 ile 4 arasında değişiklik göstermiştir. Programda oluşturulan YSA modelleri ve R<sup>2</sup> grafikleri Şekil 4.1., 4.2., 4.3., 4.4., 4.5., 4.6., 4.7., 4.8., 4.9., 4.10., 4.11., 4.12.'de verilmiştir.




Şekil 4.1. Sölöz, TN parametresi için oluşturulan 6-4-1 ysa modeli



Şekil 4.2. Sölöz, TN parametresi R<sup>2</sup> grafiği

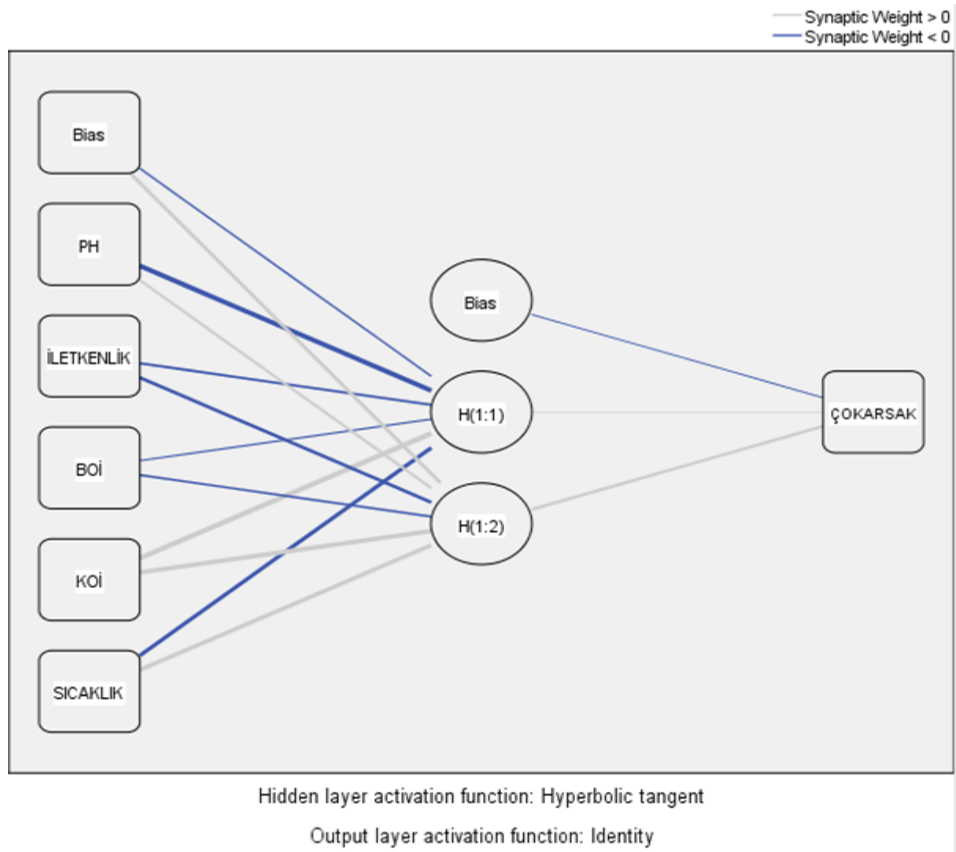


Şekil 4.3. Sölöz, TP parametresi için oluşturulan 6-3-1 YSA modeli




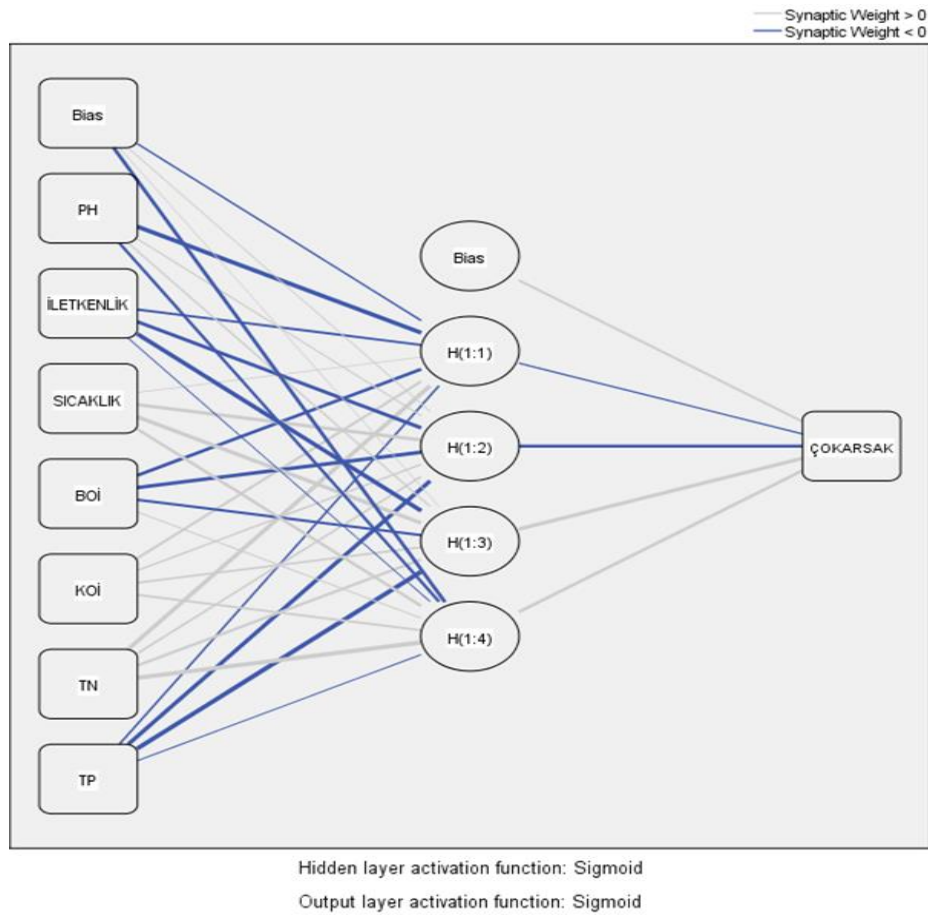
Şekil 4.4. Sölöz, TP parametresi  $R^2$  grafiği

TN ve TP çıkış parametreleri için sırasıyla 6-4-1 ve 6-3-1 modelli yapay sinir ağı modelleri kullanılmıştır. Kullanılan YSA modellerinde korelasyon katsayısı TN, TP için sırasıyla 0,752 ve 0,658'dir. Sonuçlar çalışılan YSA modellerinin giriş parametreleri ile iyi ilişki kurduğu ve kirlilik tahmini için kullanılabileceğini göstermiştir. Doğal sulardaki azot ve fosfor bileşimlerindeki artış önemli değişikliklere neden olur. İznik Gölü havzasında da tarımsal faaliyetler oldukça yaygın olduğundan gübre kullanımı gölde kirliliğe sebep olmaktadır. Fosfor bileşimleri gübrelerde ve birçok deterjanda bulunur. Yüksek fosfor konsantrasyonları, su kütlelerinde alg büyümesinin doğal olarak fosforla sınırlı olduğu başka bir soruna neden olur. Fosfor bileşimlerinde ki artış, alg patlamasının uyarılmasına ve ötrofikasyon sürecinin hızlanmasına neden olabilmektedir (Helmer ve Hespanhol 1997; Bernhardt ve ark., 2008).




Şekil 4.5. Sölöz, ÇO parametresi için oluşturulan 5-2-1 YSA model 1

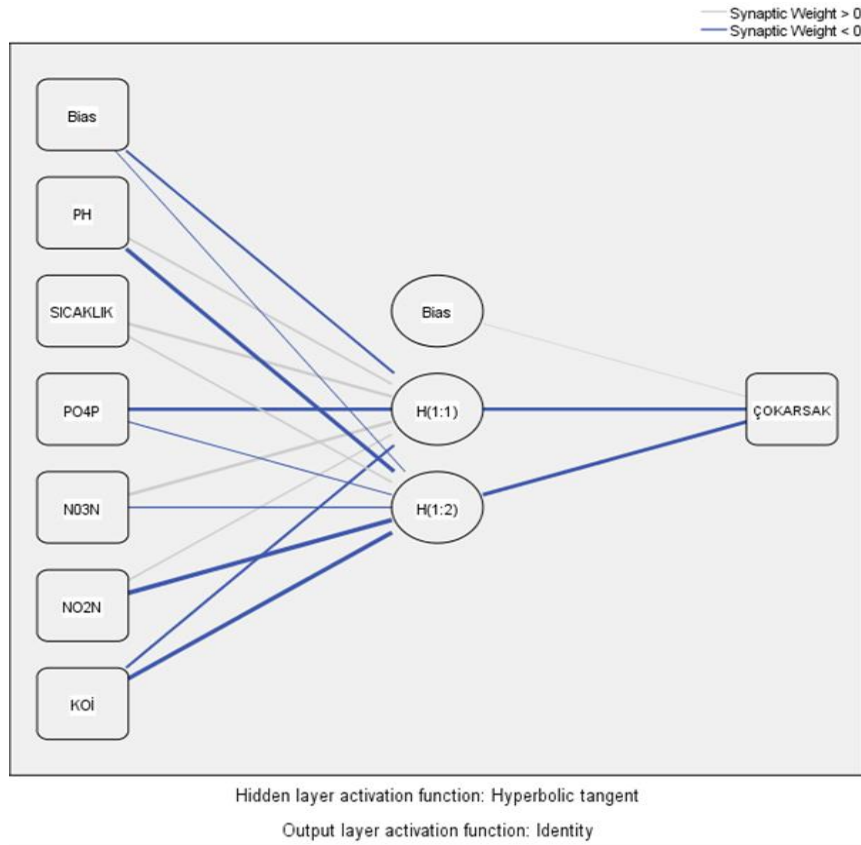
Şekil 4.6. Sölöz, ÇO parametresi model 1  $R^2$  grafiği




Şekil 4.7. Sölöz, ÇO parametresi için oluşturulan 7-4-1 YSA model 2

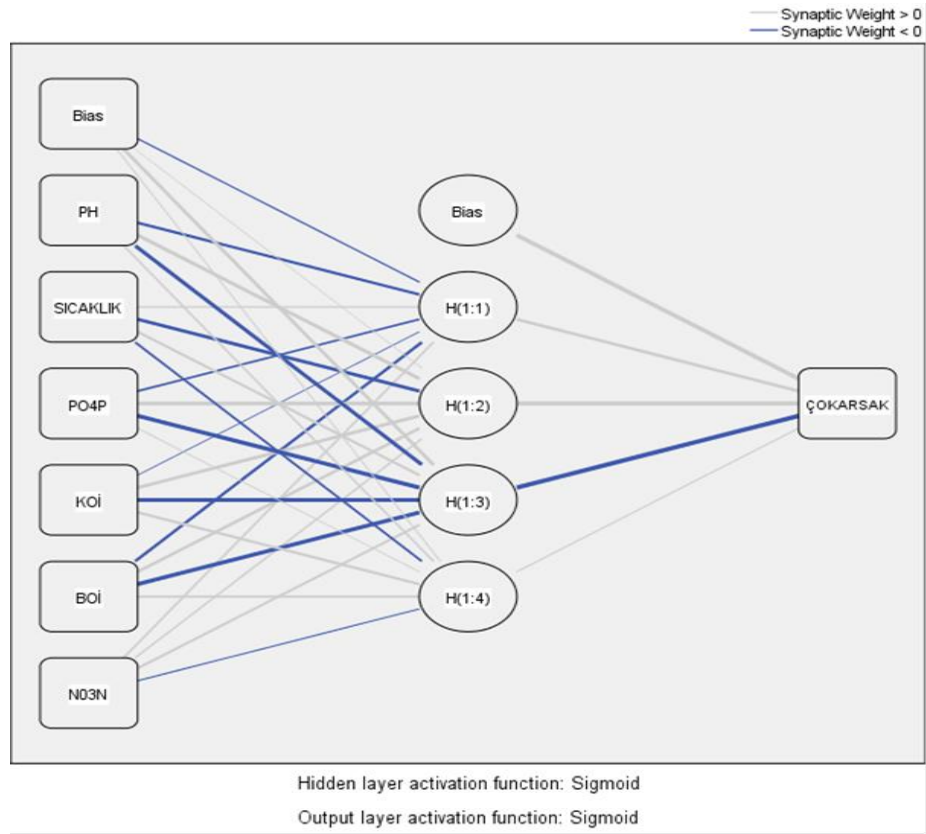
Şekil 4.8. Sölöz, ÇO parametresi model 2  $R^2$  grafiği






Şekil 4.9. Sölöz, ÇO parametresi için oluşturulan 6-2-1 YSA model 3

Şekil 4.10. Sölöz, ÇO parametresi model 3  $R^2$  grafiği



Şekil 4.11. Sölöz, ÇO parametresi için oluşturulan 6-4-1 YSA model 4



Şekil 4.12. Sölöz, ÇO parametresi model 4 R<sup>2</sup> grafiği

pH, EC, T, KOİ, BOİ, TP, PO<sub>4</sub>-P, TN, NO<sub>2</sub>N ve NO<sub>3</sub>N girdi parametreleri kullanılarak ÇO çıktı olarak alındığı 4 farklı model çalışılarak en iyi R<sup>2</sup> değerine ulaşmak amaçlanmıştır. Bu modeller arasında girdi olarak PH, T, BOİ, PO<sub>4</sub>P, NO<sub>3</sub>N, KOİ parametrelerinin kullanıldığı 6-4-1 YSA mimarisine sahip olan model en iyi R<sup>2</sup> değerini 0,966 ile vermiştir. Singh ve ark. (2009), yapmış oldukları çalışmada Hindistan'ın Gomti Nehri'nde 10 yıl 8 gözlem istasyonundan aylık olarak ölçülen 11 su kalite parametresi verileri ile ÇO ve BOİ'yi çıktı olarak YSA ile modellemişlerdir. Çalışmada ki model performans kriterlerinden biri korelasyon katsayısı (R<sup>2</sup>) olup ÇO için 0.76 sonucuna ulaşmışlardır. Geleneksel yöntemlere nazaran YSA'ların su kalitesi modellemeleri için iyi bir yöntem olduğu çalışmada ortaya konmuştur.

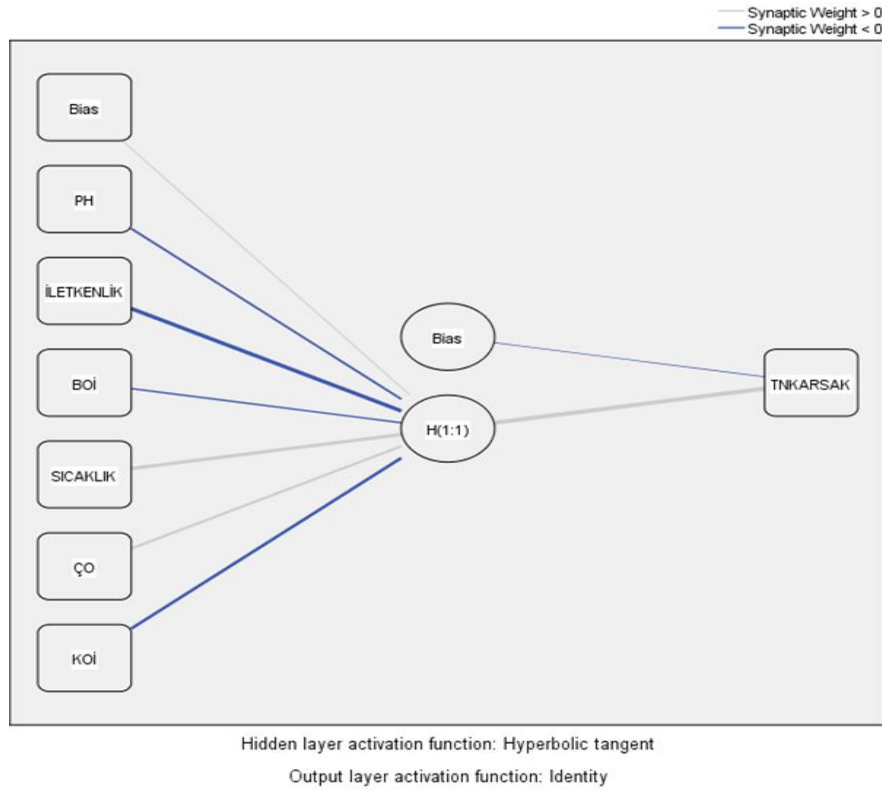
Sölöz Deresi için çalıştırılan tüm modellerin girdi verileri, ara katman sayısı, aktivasyon fonksiyonu, çıktı verisi, eğitim-test aşamasındaki hata kareleri toplamı(SSE) ve korelasyon katsayısı (R<sup>2</sup>) değerleri Tablo 4.1.'de verilmiştir.

Tablo 4.1. Sölöz, YSA model performans değerleri özet tablosu


| GİRDİLER   | ARA KATMAN | AKTİVASYON FONKSİYONU | ÇIKTI | EĞİTİM SSE | TEST SSE | R <sup>2</sup> |
|--|------------|-----------------------|-------|------------|----------|----------------|
| pH, EC, T, KOİ, BOİ, ÇO  | 4          | Hyperbolic tangent    | TN    | 0,010      | 0,062    | <b>0,752</b>   |
| pH, EC, T, KOİ, BOİ, ÇO  | 3          | Hyperbolic tangent    | TP    | 0,702      | 0,026    | <b>0,658</b>   |
| pH, EC, T, KOİ, BOİ  | 2          | Hyperbolic tangent    | ÇO    | 0,014      | 0,327    | <b>0,811</b>   |
| pH, EC,T,KOİ, BOİ TP,TN  | 4          | Sigmoid               | ÇO    | 0,001      | 0,052    | <b>0,872</b>   |
| pH,T,PO <sub>4</sub> -P,NO <sub>3</sub> N, NO <sub>2</sub> N,KOİ | 2          | Hyperbolic tangent    | ÇO    | 0,128      | 0,07     | <b>0,926</b>   |
| pH,T, BOİ, PO <sub>4</sub> -P, NO <sub>3</sub> N,KOİ             | 4          | Sigmoid               | ÇO    | 0,003      | 0,01     | <b>0,966</b>   |

#### 4.2. Olukdere için Yapılan YSA Modelleri ve R<sup>2</sup> Grafikleri

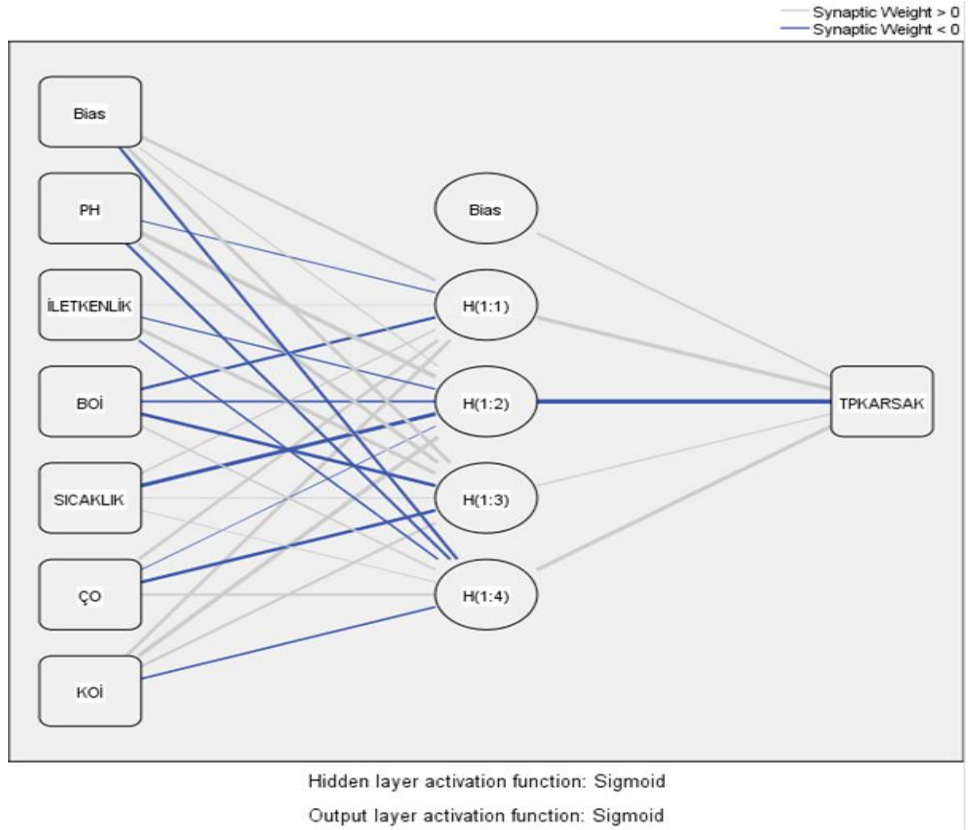
Olukdere'ye ait pH, EC, T, KOİ, BOİ, ÇO, TP, PO<sub>4</sub>-P, TN, NO<sub>2</sub>N ve NO<sub>3</sub>N toplam 11 parametre girdi verisi şeklinde baz alınarak çeşitli model denemeleri yapılmıştır. Çıktı verisi olarak Karsak deresinin TP, TN ve ÇO parametreleri ile korelasyon sağlanarak en iyi R<sup>2</sup> değerini veren modellerin oluşturulması amaçlanmıştır. Programda modelleme yapılırken aktivasyon fonksiyonu olarak sigmoid ve hiperbolik tanjant fonksiyonları seçilmiştir. Olukdere için oluşturulan modellerde ara katmandaki nöron sayıları 1 ile 4 arasında değişiklik göstermiştir. Programda oluşturulan YSA modelleri ve R<sup>2</sup> grafikleri Şekil 4.13., 4.14., 4.15., 4.16., 4.17., 4.18., 4.19., 4.20., 4.21., 4.22., 4.23. ve 4.24.'te verilmiştir.




Şekil 4.13. Olukdere, TN parametresi için oluşturulan 6-1-1 YSA modeli



Şekil 4.14. Olukdere, TN parametresi R<sup>2</sup> grafiği

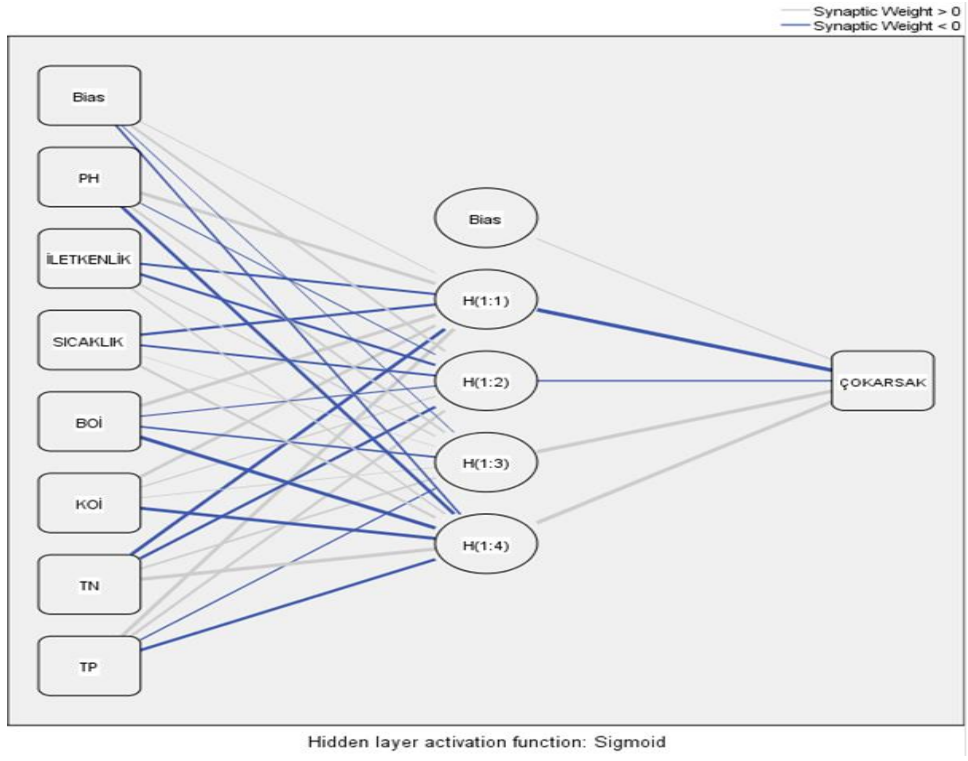


Şekil 4.15. Olukdere, TP parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.16. Olukdere, TP parametresi R<sup>2</sup> grafiği

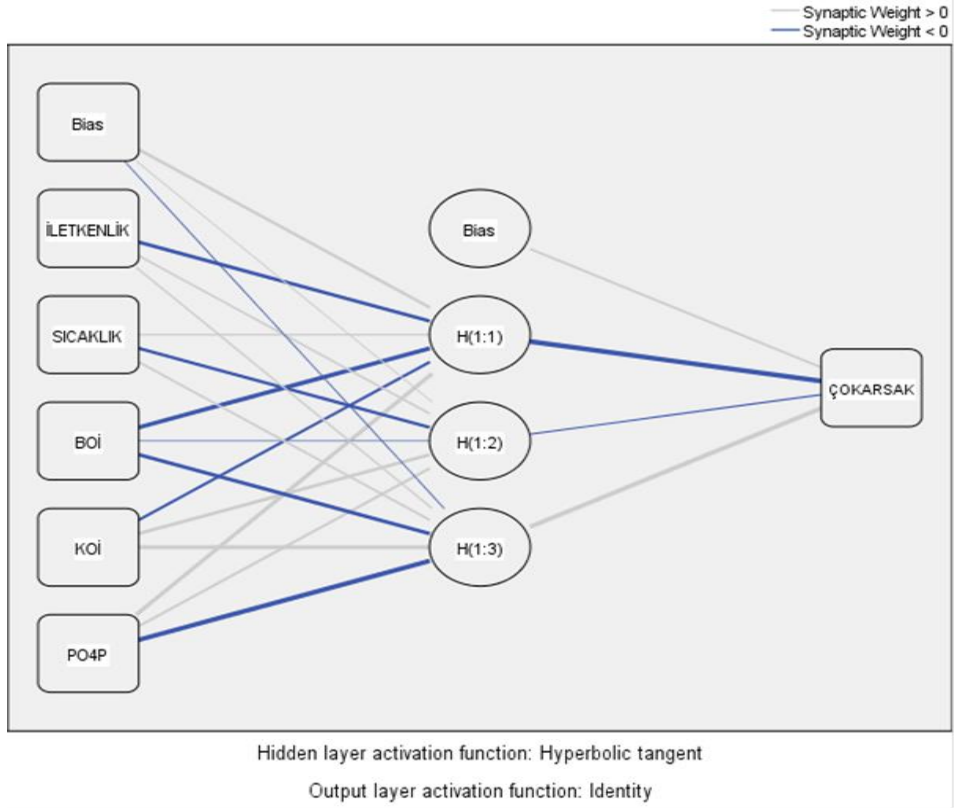
TN ve TP çıkış parametreleri için sırasıyla 6-1-1 ve 6-4-1 modelli yapay sinir ağı modelleri kullanılmıştır. Kullanılan YSA modellerinde korelasyon katsayısı TN, TP için sırasıyla 0,997 ve 0,835'dir. Sonuçlar çalışılan YSA modellerinin giriş parametreleri ile iyi ilişki kurduğu ve kirlilik tahmini için kullanılabilirliğini göstermiştir. İznik Gölü Havzası'nda tarımsal amaçlı yoğun bir gübre kullanımı olduğu düşünülmektedir (Teksoy ve ark., 2019). Besin maddeleri (gübreler dahil) ve tarım ilaçları ve herbisitler, yağmurdan kaynaklanan akışlarla nehirlere ve göllere taşınır. Gübrelerdeki azot, fosfat ve potasyum doğal sularda önemli değişikliklere neden olur. Öte yandan, suni gübrelerin bilinçsiz ve aşırı kullanımı, arazilerin iç içe geçmesine ve doğal döngü içerisinde su kirliliği ve benzeri olumsuz etkilere neden olmaktadır ([https://www.sbb.gov.tr.](https://www.sbb.gov.tr), Erişim Tarihi: 01.05.2022).




Şekil 4.17. Olukdere, ÇO parametresi için oluşturulan 7-4-1 YSA model 1



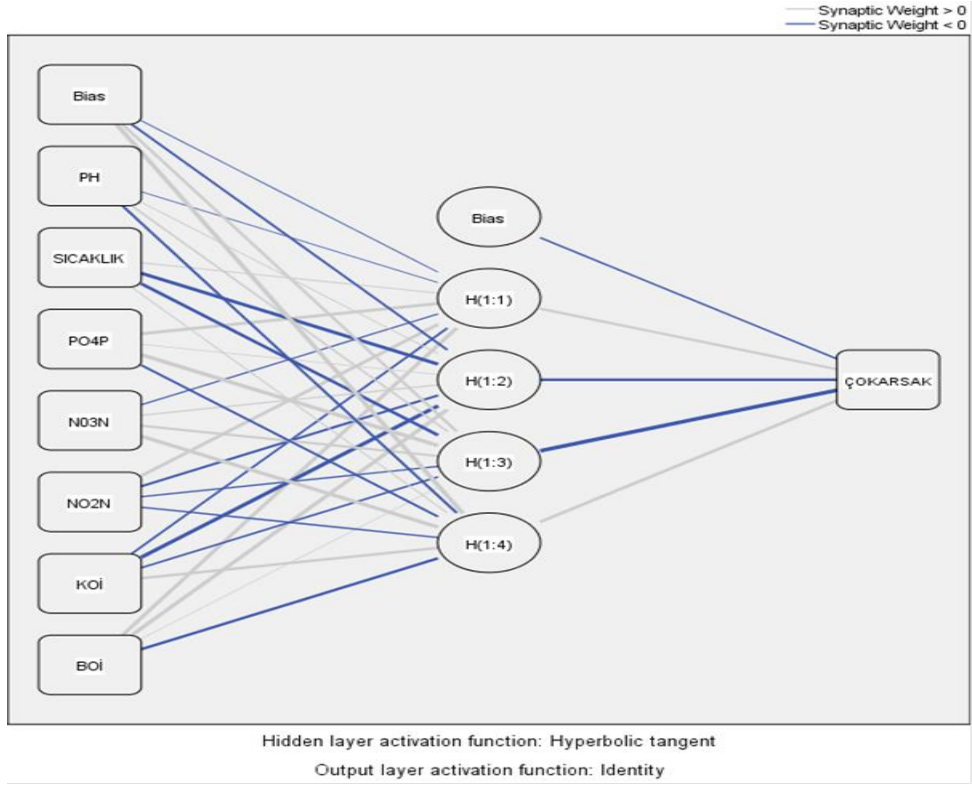
Şekil 4.18. Olukdere, ÇO parametresi model 1  $R^2$  grafiği




Şekil 4.19. Olukdere, ÇO parametresi için oluşturulan 5-3-1 YSA model 2

Şekil 4.20. Olukdere, ÇO parametresi model 2  $R^2$  grafiği

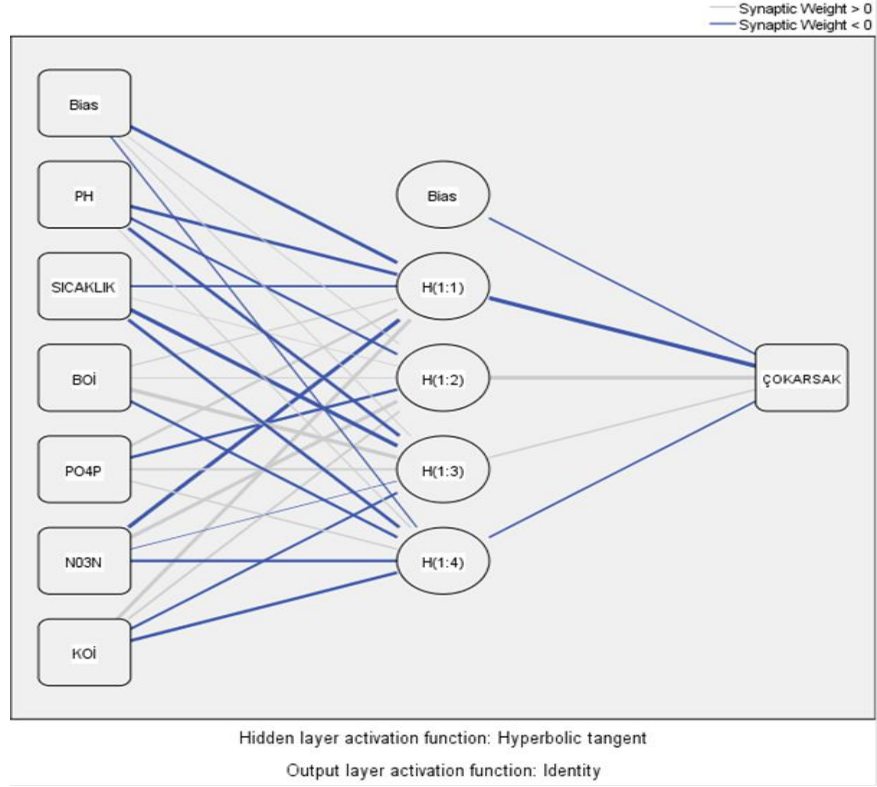





Şekil 4.21. Olukdere, ÇO parametresi için oluşturulan 7-4-1 YSA model 3



Şekil 4.22. Olukdere, ÇO parametresi model 3  $R^2$  grafiği



Şekil 4.23. Olukdere, ÇO parametresi için oluşturulan 6-4-1 YSA model 4



Şekil 4.24. Olukdere, ÇO parametresi model 4  $R^2$  grafiği

pH, EC, T, KOİ, BOİ, TP, PO<sub>4</sub>-P, TN, NO<sub>2</sub>N ve NO<sub>3</sub>N girdi parametreleri kullanılarak ÇO çıktı olarak alındığı 4 farklı model çalışılarak en iyi R<sup>2</sup> değerine ulaşmak amaçlanmıştır. Bu modeller arasında girdi olarak PH, T, BOİ, PO<sub>4</sub>P, NO<sub>3</sub>N ,KOİ parametrelerinin kullanıldığı 6-4-1 YSA mimarisine sahip olan model en iyi R<sup>2</sup> değerini 0,962 ile vermiştir. Sengorur ve ark. (2005), bir benzer çalışmayı su kalitesi verileri ile YSA kullanarak ÇO parametresinin tahminini yapmışlardır. Modelin performans değerlendirmesi için Ortalama Kare Hatası ile R<sup>2</sup> verileri baz alınmıştır. R<sup>2</sup> değeri 0.9186 olan YSA modeli ile tahminin iyi sağlandığı belirtilmiştir. Böylece su kütlelerinde, yaşanabilecek sorunların önceden tahmin edilmesi aşamasında YSA'ların önemli olduğu ortaya konmuştur.

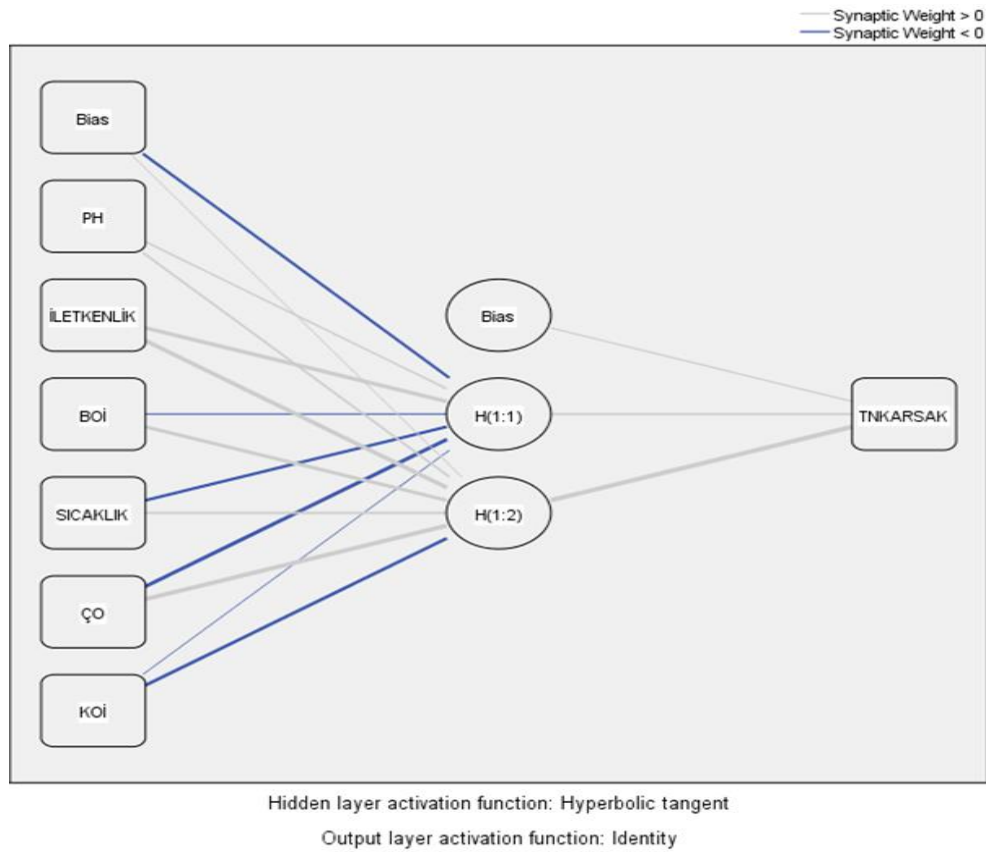
Olukdere için çalıştırılan tüm modellerin girdi verileri, ara katman sayısı, aktivasyon fonksiyonu, çıktı verisi, eğitim-test aşamasındaki hata kareleri toplamı (SSE) ve korelasyon katsayısı (R<sup>2</sup>) değerleri Tablo 4.2.'de verilmiştir.

Tablo 4.2. Olukdere, YSA model performans değerleri özet tablosu


| GİRDİLER  | ARA KATMAN | AKTİVASYON FONKSİYONU | ÇIKTI | EĞİTİM SSE | TEST SSE | R <sup>2</sup> |
|---|------------|-----------------------|-------|------------|----------|----------------|
| pH, EC, T, KOİ,BOİ,ÇO   | 1          | Hyperbolic tangent    | TN    | 0,006      | 0,002    | <b>0,997</b>   |
| pH, EC, T, KOİ,BOİ,ÇO   | 4          | Sigmoid               | TP    | 0,001      | 0,083    | <b>0,835</b>   |
| pH,EC,T,KOİ, BOİ TP,TN  | 4          | Sigmoid               | ÇO    | 0,229      | 0,141    | <b>0,690</b>   |
| EC, T, KOİ, BOİ, PO <sub>4</sub> -P                                       | 3          | Hyperbolic tangent    | ÇO    | 0,01       | 0,182    | <b>0,887</b>   |
| pH, T, PO <sub>4</sub> -P, NO <sub>3</sub> N, NO <sub>2</sub> N, KOİ, BOİ | 4          | Hyperbolic tangent    | ÇO    | 0,124      | 0,029    | <b>0,942</b>   |
| pH, T, BOİ, PO <sub>4</sub> -P, NO <sub>3</sub> N ,KOİ                    | 4          | Hyperbolic tangent    | ÇO    | 0,011      | 0,00     | <b>0,962</b>   |

### 4.3. Karasu Deresi için Yapılan YSA Modelleri ve R<sup>2</sup> Grafikleri

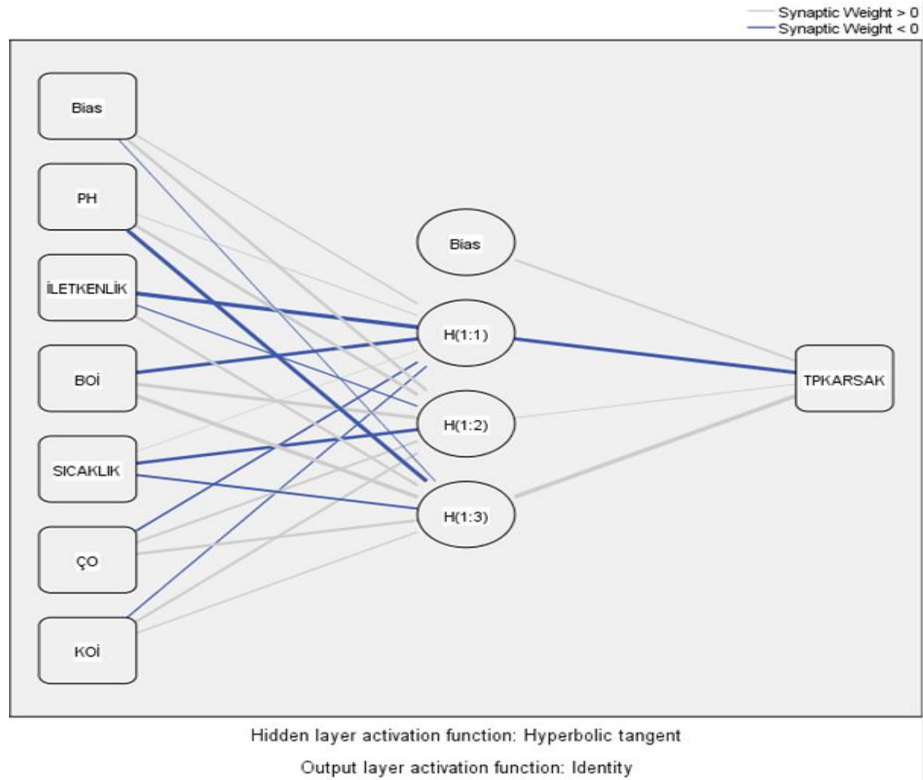
Karasu Deresi'ne ait pH, EC, T, KOİ, BOİ, ÇO, TP, PO<sub>4</sub>-P, TN, NO<sub>2</sub>N ve NO<sub>3</sub>N toplam 11 parametre girdi verisi şeklinde baz alınarak çeşitli model denemeleri yapılmıştır. Çıktı verisi olarak Karsak deresinin TP, TN ve ÇO parametreleri ile korelasyon sağlanarak en iyi R<sup>2</sup> değerini veren modellerin oluşturulması amaçlanmıştır. Programda modelleme yapılırken aktivasyon fonksiyonu olarak sigmoid ve hiperbolik tanjant fonksiyonları seçilmiştir. Karasu Deresi için oluşturulan modellerde ara katmandaki nöron sayıları 1 ile 4 arasında değişiklik göstermiştir. Programda oluşturulan YSA modelleri ve R<sup>2</sup> grafikleri Şekil 4.25., 4.26., 4.27., 4.28., 4.29., 4.30., 4.31., 4.32., 4.33., 4.34., 4.35. ve 4.36.'da verilmiştir.




Şekil 4.25. Karasu, TN parametresi için oluşturulan 6-2-1 YSA modeli



Şekil 4.26. Karasu, TN parametresi R<sup>2</sup> grafiği

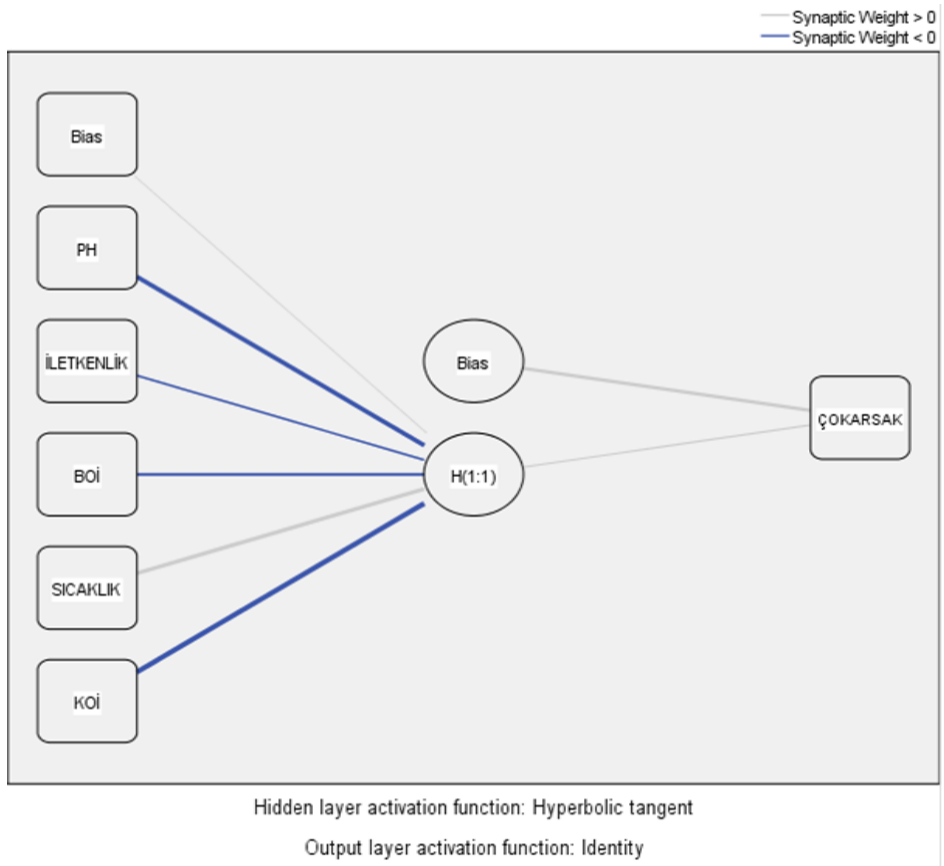


Şekil 4.27. Karasu, TP parametresi için oluşturulan 6-3-1 YSA modeli




Şekil 4.28. Karasu, TP parametresi  $R^2$  grafiği

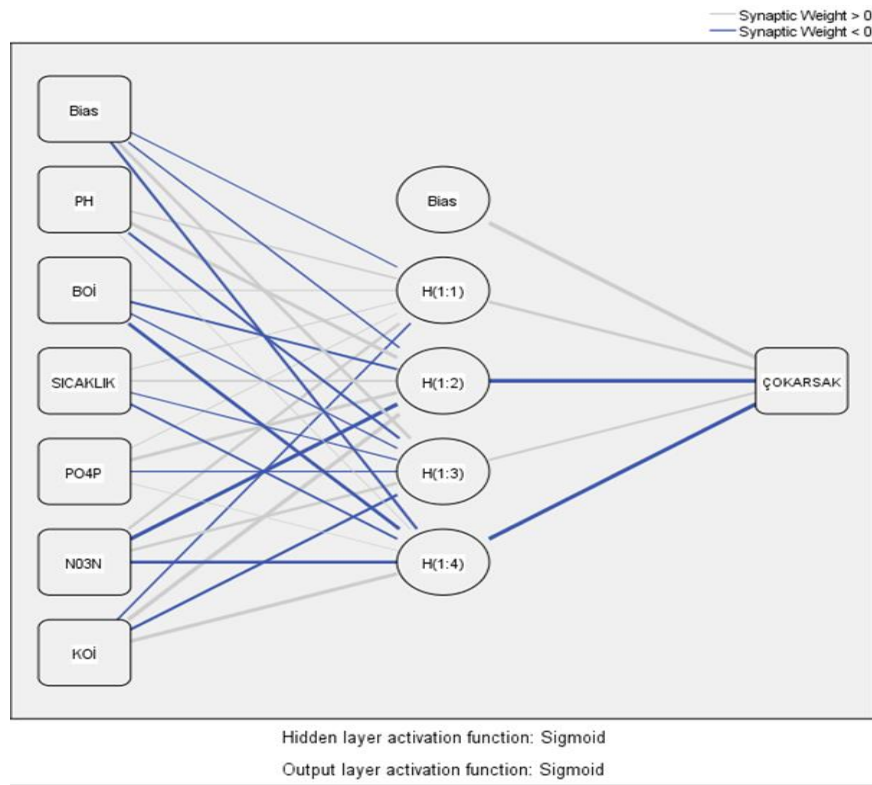
TN ve TP çıkış parametreleri için sırasıyla 6-2-1 ve 6-3-1 modelli yapay sinir ağı modelleri kullanılmıştır. Kullanılan YSA modellerinde korelasyon katsayısı TN, TP için sırasıyla 0,995 ve 0,899'dur. Sonuçlar çalışılan YSA modellerinin giriş parametreleri ile iyi ilişki kurduğu ve kirlilik tahmini için kullanılabileceğini göstermiştir.



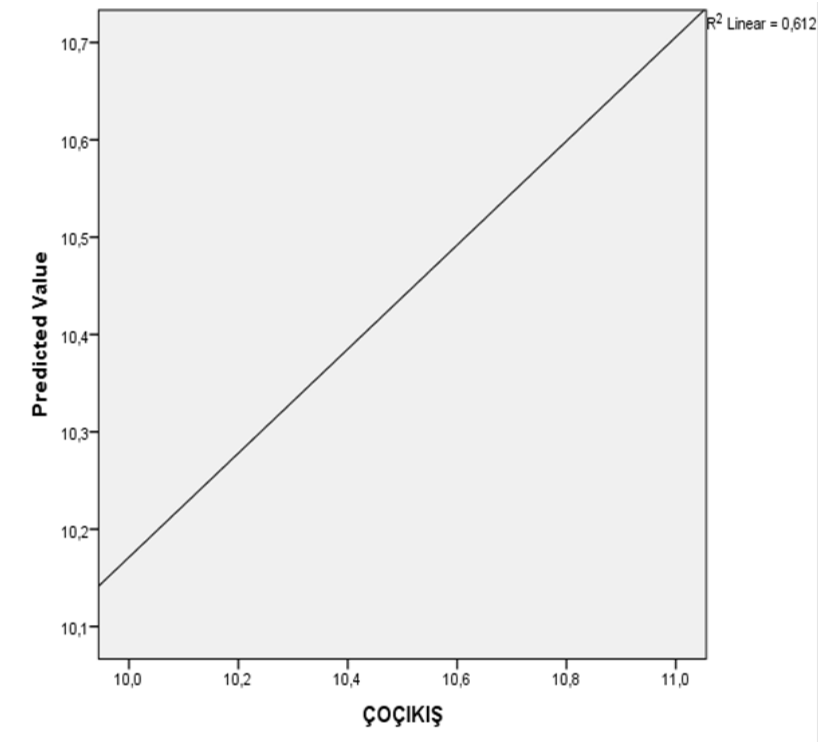
Şekil 4.29. Karasu, ÇO parametresi için oluşturulan 5-1-1 YSA model 1



Şekil 4.30. Karasu, ÇO parametresi model 1  $R^2$  grafiği

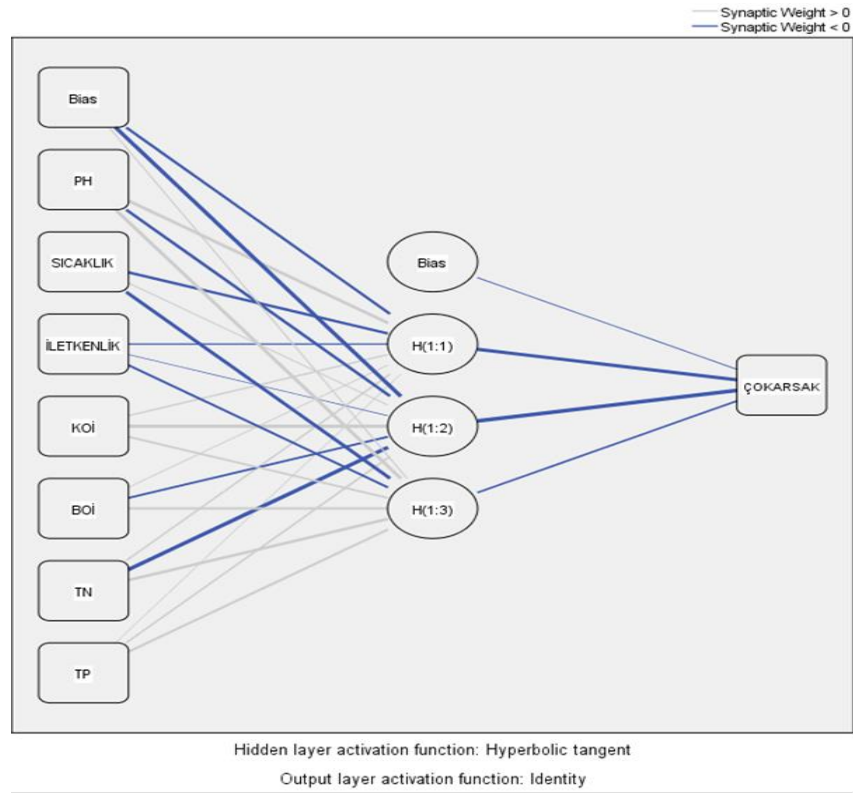


Şekil 4.31. Karasu, ÇO parametresi için oluşturulan 6-4-1 YSA model 2




Şekil 4.32. Karasu, ÇO parametresi model 2  $R^2$  grafiği

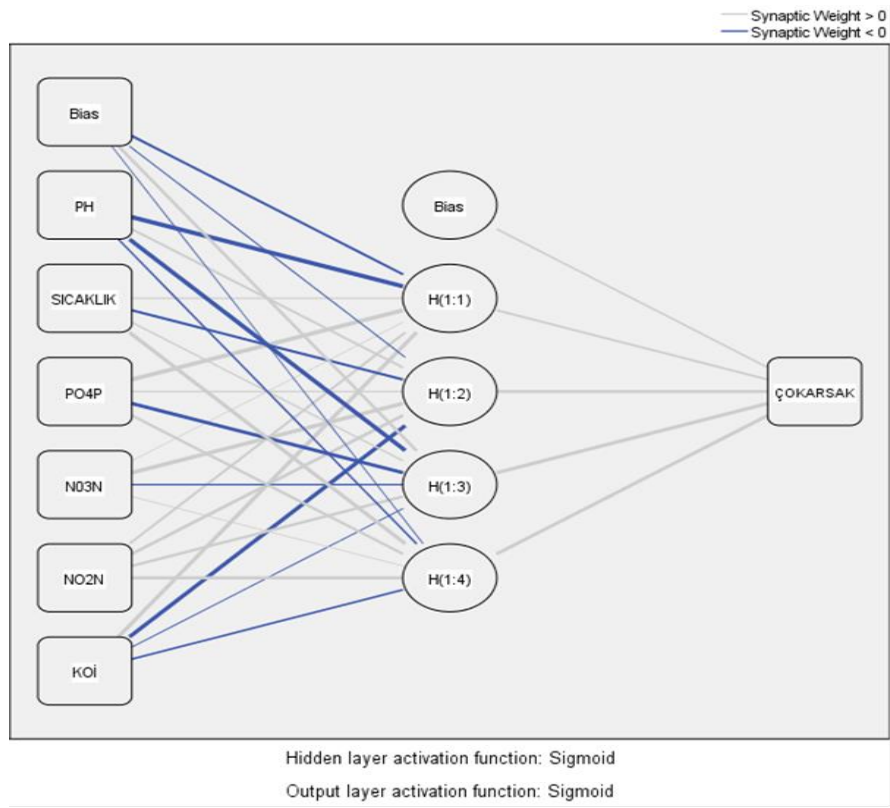





Şekil 4.33. Karasu, ÇO parametresi için oluşturulan 7-3-1 YSA model 3



Şekil 4.34. Karasu, ÇO parametresi model 3  $R^2$  grafiği



Şekil 4.35. Karasu, ÇO parametresi için oluşturulan 6-4-1 YSA model 4



Şekil 4.36. Karasu, ÇO parametresi model 4  $R^2$  grafiği

pH, EC, T, KOİ, BOİ, TP, PO<sub>4</sub>-P, TN, NO<sub>2</sub>N ve NO<sub>3</sub>N girdi parametreleri kullanılarak ÇO çıktı olarak alındığı 4 farklı model çalışılarak en iyi R<sup>2</sup> değerine ulaşmak amaçlanmıştır. Bu modeller arasında girdi olarak PH, T, PO<sub>4</sub>-P, NO<sub>3</sub>N, NO<sub>2</sub>N, KOİ parametrelerinin kullanıldığı 6-4-1 YSA mimarisine sahip olan model en iyi R<sup>2</sup> değerini 0,974 ile vermiştir. Çözünmüş oksijen tahmini Akkoyunlu ve ark. (2011), çalışmalarında da yapılmıştır. Çalışmalarının ilk bölümünde, ÇO değişkenini tahmin etmek için beş parametre (TÇK, pH, iletkenlik, göl derinliği ve göl sıcaklığı) kullanmışlardır. İkinci bölümde, bağımsız girdi değişkenleri olarak sadece sıcaklık ve derinliği kullanmışlardır. ÇO TDS, pH ve iletkenlikten dolayı olarak etkilenebileceğinden, sıcaklık ve derinlik ÇO değerlerini doğrudan etkilediğinden giriş parametre sayısını düşürmüşlerdir. MLR ve iki farklı YSA yöntemi kullanmışlardır. Performans değerlendirme kriterleri ve grafiklerde, MLR performansının iki YSA yönteminden oldukça düşük olduğu belirtilmiştir. Her iki YSA yöntemi, ÇO varyasyonunu göl derinliği ile modellemede başarılı olduğu çalışmada görülmüştür.

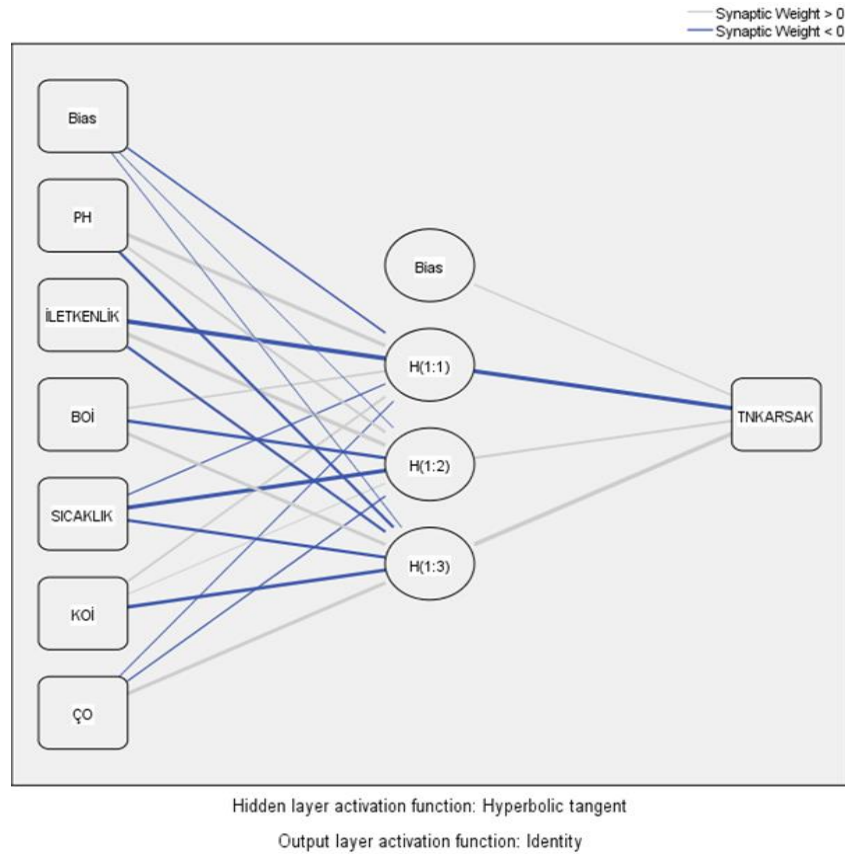
Karasu Deresi için çalıştırılan tüm modellerin girdi verileri, ara katman sayısı, aktivasyon fonksiyonu, çıktı verisi, eğitim-test aşamasındaki hata kareleri toplamı(SSE) ve korelasyon katsayısı (R<sup>2</sup>) değerleri Tablo 4.3.'de verilmiştir.

Tablo 4.3. Karasu, YSA model performans değerleri özet tablosu


| GİRDİLER  | ARA KATMAN | AKTİVASYON FONKSİYONU | ÇIKTI | EĞİTİM SSE | TEST SSE | R <sup>2</sup> |
|---|------------|-----------------------|-------|------------|----------|----------------|
| pH, EC, T, KOİ,BOİ,ÇO   | 2          | Hyperbolic tangent    | TN    | 0,012      | 0,00     | <b>0,995</b>   |
| pH, EC, T, KOİ, BOİ, ÇO   | 3          | Hyperbolic tangent    | TP    | 0,010      | 0,025    | <b>0,899</b>   |
| pH, EC, T, KOİ,BOİ  | 1          | Hyperbolic tangent    | ÇO    | 0,300      | 3,108    | <b>0,374</b>   |
| pH,T,BOİ,PO <sub>4</sub> P, NO <sub>3</sub> N ,KOİ              | 4          | Sigmoid               | ÇO    | 0,101      | 0,00     | <b>0,612</b>   |
| pH,EC,T,KOİ,BOİ, TP,TN  | 3          | Hyperbolic tangent    | ÇO    | 0,025      | 0,060    | <b>0,955</b>   |
| pH,T,PO <sub>4</sub> P,NO <sub>3</sub> N, NO <sub>2</sub> N,KOİ | 4          | Sigmoid               | ÇO    | 0,009      | 0,00     | <b>0,974</b>   |

#### 4.4. Kırandere için Yapılan YSA Modelleri ve $R^2$ Grafikleri

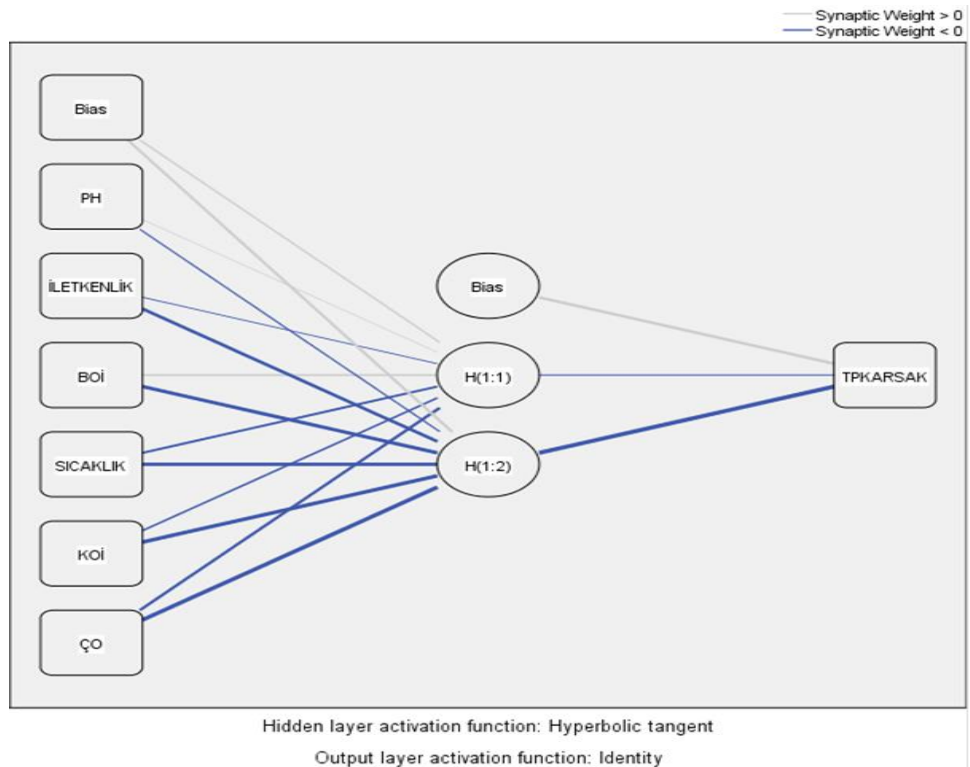
Kırandere'ye ait pH, EC, T, KOİ, BOİ, ÇO, TP, PO<sub>4</sub>-P, TN, NO<sub>2</sub>N ve NO<sub>3</sub>N toplam 11 parametre girdi verisi şeklinde baz alınarak çeşitli model denemeleri yapılmıştır. Çıktı verisi olarak Karsak deresinin TP, TN ve ÇO parametreleri ile korelasyon sağlanarak en iyi  $R^2$  değerini veren modellerin oluşturulması amaçlanmıştır. Programda modelleme yapılırken aktivasyon fonksiyonu olarak sigmoid ve hiperbolik tanjant fonksiyonları seçilmiştir. Kırandere için oluşturulan modellerde ara katmandaki nöron sayıları 2 ile 4 arasında değişiklik göstermiştir. Programda oluşturulan YSA modelleri ve  $R^2$  grafikleri Şekil 4.37., 4.38., 4.39., 4.40., 4.41., 4.43., 4.44., 4.45., 4.46., 4.47. ve 4.48.'de verilmiştir.




Şekil 4.37. Kırandere, TN parametresi için oluşturulan 6-3-1 YSA modeli



Şekil 4.38. Kırandere, TN parametresi R<sup>2</sup> grafiği

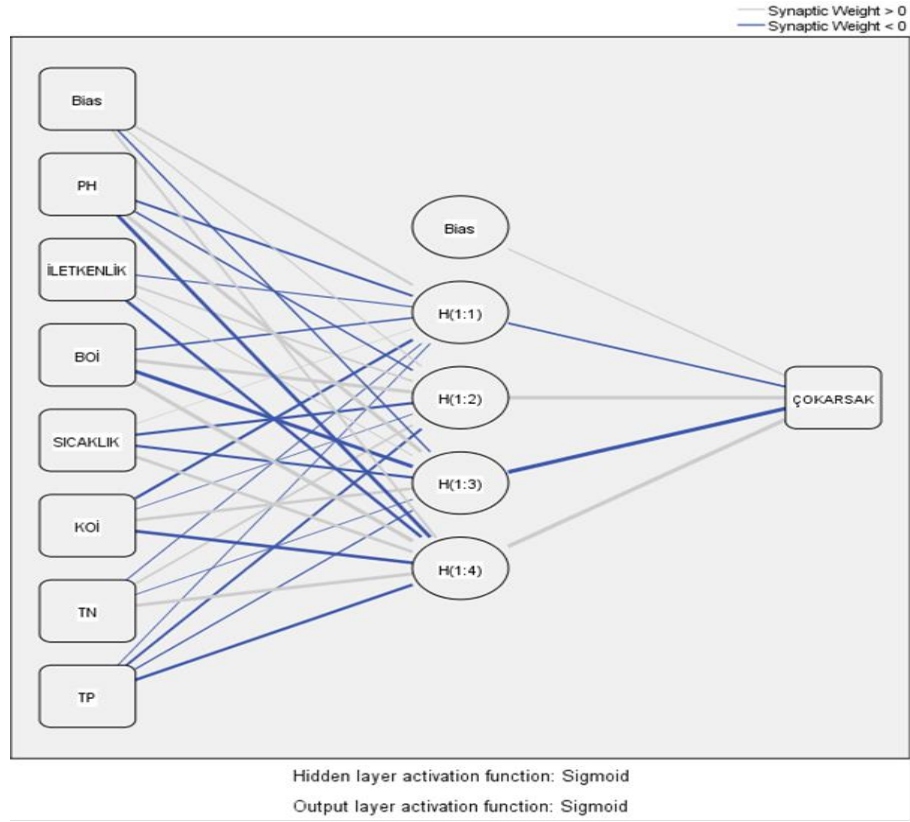


Şekil 4.39. Kırandere, TN parametresi için oluşturulan 6-2-1 YSA modeli




Şekil 4.40. Kırandere, TP parametresi R<sup>2</sup> grafiği

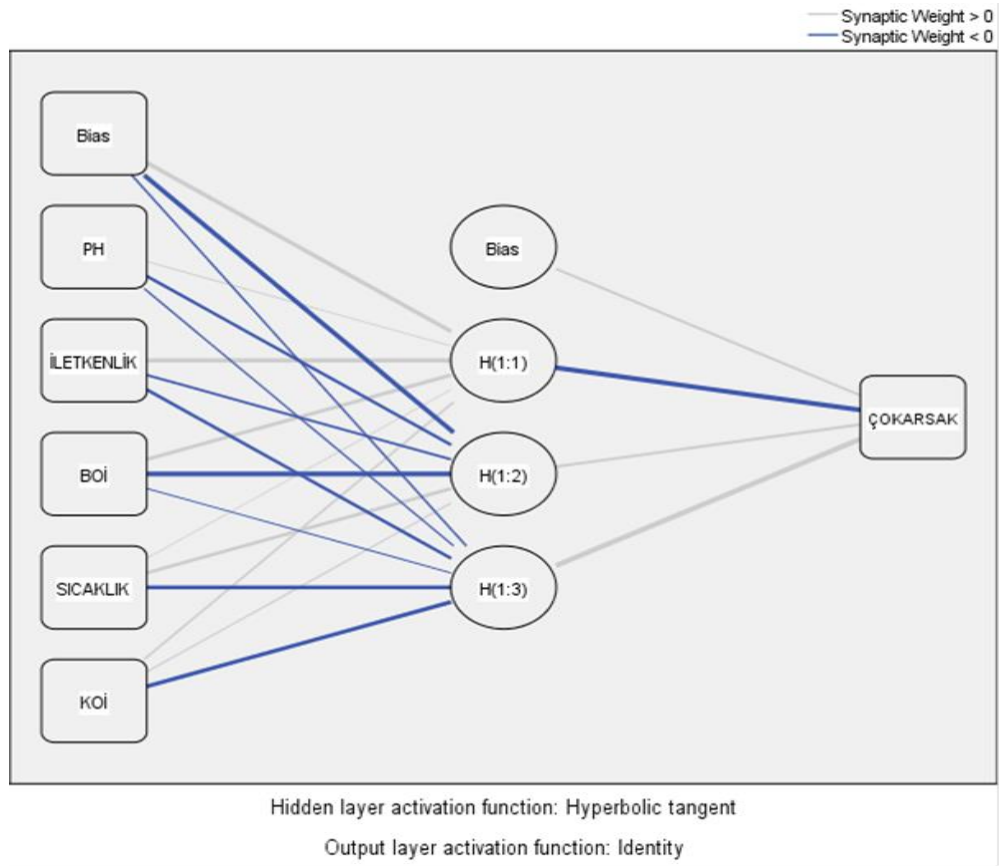
TN ve TP çıkış parametreleri için sırasıyla 6-3-1 ve 6-2-1 modelli yapay sinir ağı modelleri kullanılmıştır. Kullanılan YSA modellerinde korelasyon katsayısı TN,TP için sırasıyla 0,952 ve 0,889'dur. Sonuçlar çalışılan YSA modellerinin giriş parametreleri ile iyi ilişki kurduğu ve kirlilik tahmini için kullanılabileceğini göstermiştir. Sinshaw ve arkadaşlarında 2019 yılında yapmış oldukları çalışmalarında ABD göllerindeki toplam azot (TN) ve toplam fosforun (TP) yaz konsantrasyonunu tahmin eden bir model geliştirmek için doğrusal olmayan ilişkiler için güçlü bir hesaplama aracı olan yapay sinir ağı (YSA) yaklaşımı kullanılmıştır. Bölgesel ve ulusal veri setlerini kullanan iki YSA modeli ve bir doğrusal regresyon modeli, çıktılarla istatistiksel olarak ilişkilendirilen üç girdi (pH, iletkenlik ve bulanıklık) kullanılmış, test edilmiş ve onaylanmıştır. YSA modellerinin tahmin etmede ki doğruluğu, sürekli olarak doğrusal regresyon modelinden daha iyi performans göstermiştir.




Şekil 4.41. Kirandere, ÇO parametresi için oluşturulan 7-4-1 YSA model 1



Şekil 4.42. Kirandere, ÇO parametresi model 1  $R^2$  grafiği

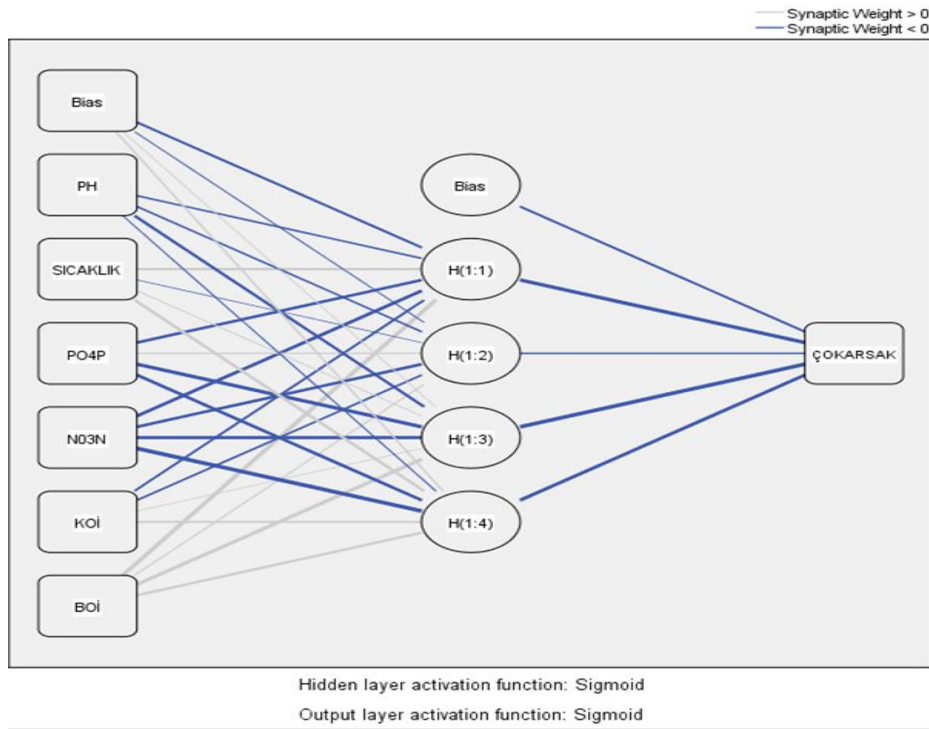


Şekil 4.43. Kırandere, ÇO parametresi için oluşturulan 5-3-1 YSA model 2




Şekil 4.44. Kırandere, ÇO parametresi model 2  $R^2$  grafiği

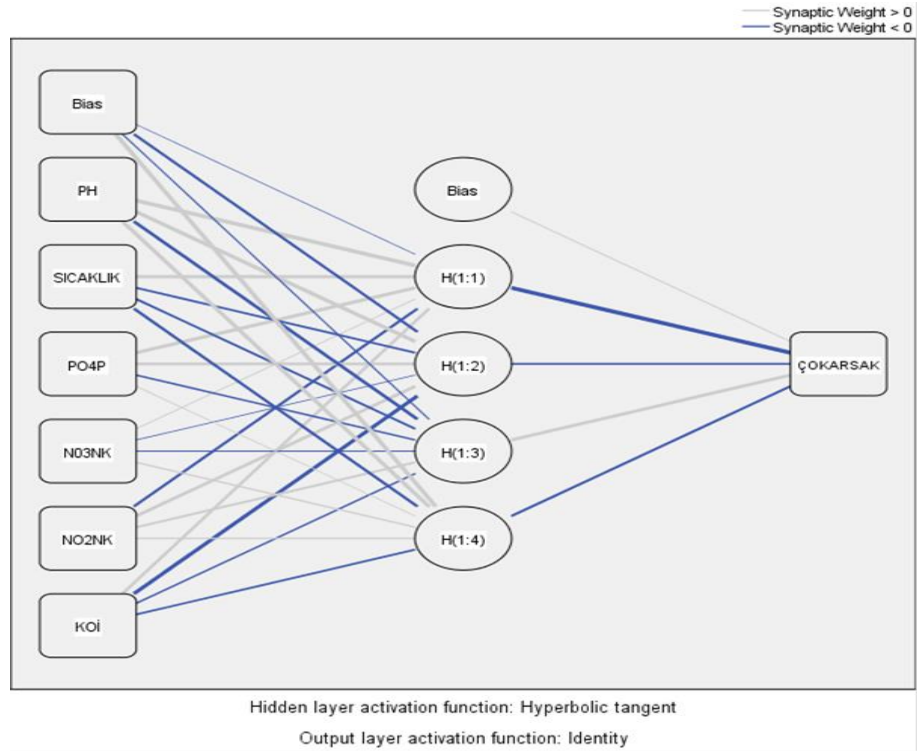





Şekil 4.45. Kırandere, ÇO parametresi için oluşturulan 6-4-1 YSA model 3



Şekil 4.46. Kırandere, ÇO parametresi model 3  $R^2$  grafiği



Şekil 4.47. Kırandere, ÇO parametresi için oluşturulan 6-4-1 YSA model 4



Şekil 4.48. Kırandere, ÇO parametresi model 4,  $R^2$  grafiği

pH, EC, T, KOİ, BOİ, TP, PO<sub>4</sub>-P, TN, NO<sub>2</sub>-N ve NO<sub>3</sub>-N girdi parametreleri kullanılarak ÇO çıktı olarak alındığı 4 farklı model çalışılarak en iyi R<sup>2</sup> değerine ulaşmak amaçlanmıştır. Bu modeller arasında girdi olarak pH,T, PO<sub>4</sub>-P, NO<sub>3</sub>N NO<sub>2</sub>N, KOİ parametrelerinin kullanıldığı 6-4-1 YSA mimarisine sahip olan model en iyi R<sup>2</sup> değerini 0,999 ile vermiştir. Su kirliliğinde önemli parametrelerden birisi de ÇO'dur. Su sıcaklığı ve suda bulunan mineral konsantrasyonuna göre oksijenin sudaki çözünürlüğü değişmektedir. Suda oksijenin azalması beraberinde anaerobik bozunmayı meydana getirir. Su kokusunda değişmelere sebep olur. Belli aralıklarda ölçüm yapılan su kalitesi parametrelerinin takibi ile oluşabilecek sorunların önceden engellenmesi sağlanabilir (Çıtakoğlu ve Özeren, 2021).

Kırandere için çalıştırılan tüm modellerin girdi verileri, ara katman sayısı, aktivasyon fonksiyonu, çıktı verisi, eğitim-test aşamasındaki hata kareleri toplamı(SSE) ve korelasyon katsayısı (R<sup>2</sup>) değerleri Tablo 4.4.'de verilmiştir.

Tablo 4.4. Kırandere, YSA model performans değerleri özet tablosu

| GİRDİLER   | ARA KATMAN | AKTİVASYON FONKSİYONU | ÇIKTI | EĞİTİM SSE | TEST SSE | R <sup>2</sup> |
|--|------------|-----------------------|-------|------------|----------|----------------|
| pH, EC, T, KOİ,BOİ,ÇO  | 3          | Hyperbolic tangent    | TN    | 0,059      | 0,041    | <b>0,952</b>   |
| pH, EC, T, KOİ,BOİ,ÇO  | 2          | Hyperbolic tangent    | TP    | 0,00       | 0,340    | <b>0,889</b>   |
| pH, EC,T,KOİ, BOİ TP,TN  | 4          | Sigmoid               | ÇO    | 0,227      | 0,00     | <b>0,574</b>   |
| pH, EC, T, KOİ, BOİ  | 3          | Hyperbolic tangent    | ÇO    | 0,001      | 0,495    | <b>0,743</b>   |
| pH, T, PO <sub>4</sub> -P, NO <sub>3</sub> N, KOİ, BOİ               | 4          | Sigmoid               | ÇO    | 0,165      | 0,006    | <b>0,770</b>   |
| pH, T, PO <sub>4</sub> -P, NO <sub>3</sub> N, NO <sub>2</sub> N, KOİ | 4          | Hyperbolic tangent    | ÇO    | 0,007      | 0,00     | <b>0,999</b>   |

## BÖLÜM 5. TARTIŞMA VE SONUÇ

Göllerin planlanması ve yönetiminde su kalitesi parametrelerinin izlenmesi önemlidir. Su kaynaklarının laboratuvarlarında su kalitesinin deneysel analizi zaman alıcı ve pahalıdır. Su kalitesi tahmini, çevresel izleme, ekosistem sürdürülebilirliğinde önemli rol oynamaktadır. Geleneksel tahmin yöntemleri, su kalitesinin doğrusal olmayan durumlarını yakalayamamaktadır. Son yıllarda, yapay sinir ağlarının (YSA) hızlı gelişimi, onları su kalitesi tahmininde önemli bir yere getirmiştir.

Bu çalışma da, İznik Gölü'ndeki su kalitesi parametrelerinin yapay sinir ağı ile tahmin çalışmaları yapılmış ve su kalitesi parametrelerinin izlenmesi için farklı modeller denenmiştir. İstatiksel bir yöntem olan IBM SPSS V.23 programında neural network modülü kullanılarak modeller çalıştırılmıştır. BUSKİ Genel Müdürlüğünden 2017-2021 yılları arasındaki Karasu, Olukdere, Kırandere, Sölöz için pH, EC, T, KOİ, BOİ, ÇO, TP, PO4-P, TN, NO2-N ve NO3-N parametreleri ortalamaları; Karsak Deresi için TN, TP ve ÇO ortalamaları alınmıştır. Bu parametreler kullanılarak çeşitli denemeler yapılmış ve YSA temelli model oluşturmak amaçlanmıştır. 4 giriş ölçüm noktası için denemeler TN ve TP parametrelerinde aynı model uygulanarak en iyi sonuç alınmış olup ÇO de 4 farklı ysa modelleri oluşturulmuş ve en iyi model baz alınmıştır. Programda çok katmanlı YSA kullanılmış olup aktivasyon fonksiyonları için ise hiperbolik tanjant ve sigmoid kullanılmıştır. Döngü sayısı 1000, minimum nispi değişiklik 0.0001 ve hata oranında minimum değişiklik 0.001'dir. Nöronların sayısı 1 ve 4 arasında değişiklik göstermiştir. Sonuçların performanslarını değerlendirmek için hata kareleri toplamı (SSE) ve belirleme katsayısı ( $R^2$ ) kullanılmıştır.

Sölöz için oluşturulan YSA modellerinde çıkan belirleme katsayısı ( $R^2$ ) değerleri, TN, TP ve ÇO için sırasıyla 0,752, 0,658 ve 0,966 bulunmuştur. Olukdere için

oluřturulan YSA modellerinde ıkan belirleme katsayısı ( $R^2$ ) deęerleri, TN, TP ve O iin sırasıyla 0,997, 0,835 ve 0,962 bulunmuřtur. Karasu iin oluřturulan YSA modellerinde ıkan belirleme katsayısı ( $R^2$ ) deęerleri, TN, TP ve O iin sırasıyla 0,995, 0,899 ve 0,974 bulunmuřtur. Kırandere iin oluřturulan YSA modellerinde ıkan belirleme katsayısı ( $R^2$ ) deęerleri, TN, TP ve O iin sırasıyla 0,952, 0,889 ve 0,999 bulunmuřtur. ıkan  $R^2$  sonuları oęunlukla 1'e yakın geldięi iin YSA'nın tahmin etme doęruluęunu ispatlar nitelięinde olmuřtur. Hata kareleri toplamı(SSE) deęerleri, baz alınan modellerin test ve eęitim srecinde 0'a yakın deęerler almıř olup tahmin alıřmasında IBM SPSS V.23 modlnn doęru sonular verebildięi grlmřtir. YSA'nın gldeki su kalitesini tahmin etmek iin kullanımı kolay ve uygun maliyetli bir alternatif yntem olduęu sonucuna varılabilir.

## KAYNAKLAR

- Abbas, S. H., Khudair, B. H., & Jaafar, M. H. (2019). Water quality assessment and total dissolved solids prediction for Tigris river in Baghdad city using mathematical models. *Journal of Engineering Science and Technology*, 14(6), 3337-3346.
- Akbulak, C., (2006) İznik Gölü Depresyonunun Beşeri ve İktisadi Coğrafya Açısından İncelenmesi İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Coğrafya Anabilim Dalı, Doktora Tezi, İstanbul.
- Akgürbüz, Z. B. (2017). Gökçekaya Barajı enerji üretim miktarının yapay sinir ağları ile değerlendirilmesi (Master's thesis, Sakarya Üniversitesi).
- Akiner, ME ve Akiner, İ. (2021). Sapanca içme suyu kaynağı gölünün su kalitesi analizi ve sürdürülebilir çevre yaklaşımı bağlamında kirlilik sorununun çözümüne yönelik öneriler. *Sürdürülebilirlik* , 13 (7), 3917.
- Akkoyunlu, A., Altun, H., & Cigizoglu, H. K. (2011). Depth-integrated estimation of dissolved oxygen in a lake. *Journal of Environmental Engineering*, 137(10), 961-967.
- Akpınar, E., & Bulut, Y. (2010). Ülkemizde alternatif turizm bir dalı olan ekoturizm çeşitlerinin bölgelere göre dağılımı ve uygulama alanları. *Ulusal Karadeniz Ormanlık Kongresi*, 4(1), 1575-1594.
- Aksoy, B. (2018). Mevsimsel değişikliğin Filyos Çayı su kalitesine etkisinin yapay sinir ağı ile belirlenmesi.
- Aküzüm, T., Çakmak, B. ve Gökalp, Z. (2010). Türkiye’de su kaynakları yönetiminin değerlendirilmesi. *Tarım Bilimleri Araştırma Dergisi*, 3 (1), 67–74. <http://ijans.org/index.php/ijans/article/view/86>.
- Alan, E. (2013). Yapay sinir ağları yaklaşımı ile curuflarda fosfor kapasitelerinin incelenmesi (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- Anonim (2019), Bursa İli 2019 Yılı Çevre Durum Raporu. Türkiye Cumhuriyeti Bursa Valiliği Çevre ve Şehircilik İl Müdürlüğü.

- Anonim 2004. Türkiye Çevre Atlası, T.C. Çevre ve Orman Bakanlığı, ÇED ve Planlama Genel Müdürlüğü Çevre Envanteri Dairesi Başkanlığı, Ankara. s: 10.
- Arefinia, A., Bozorg-Haddad, O., Oliazadeh, A., & Loáiciga, H. A. (2020). Reservoir water quality simulation with data mining models. *Environmental Monitoring and Assessment*, 192(7), 1-13.
- Atasoy, S. (2012). Yapay Sinir Ağları ve Sinirsel Bulanık Ağlar ile İnsan Kaynaklarında Performans Yönetimi Modellenmesi.
- Avvannavar, S. M., & Shrihari, S. J. E. M. (2008). Evaluation of water quality index for drinking purposes for river Netravathi, Mangalore, South India. *Environmental monitoring and assessment*, 143(1), 279-290.
- Ayyıldız, H. Y., & Zeybek, Z. T. D. (2015). Tekstil atık suyunun çöktürmeyle arıtımında yapay sinir ağı kullanılarak arıtımının modellenmesi ve ph denetimi (Doctoral dissertation, Ankara Üniversitesi Fen Bilimleri Enstitüsü Kimya Mühendisliği Anabilim Dalı).
- Başar, H., Gürel, S., Katkat, A.V., 2003. İznik Gölü Havzasında Değişik Su Kaynakları ile Sulanan Toprakların Ağır Metal İçeriklerinin İncelenmesi. *Uludağ Üniversitesi Ziraat Fakültesi Dergisi*, Cilt 18., Sayı 1, 3 : 93 – 104.
- Baykan, U. N. (2007). İnşaat Projelerinde Kaynak İhtiyacının Yapay Sinir Ağları Yaklaşımı ile Tahmini, Doktora Tezi, Gazi Üniversitesi, Fen Bilimler Enstitüsü, Ankara.
- Bernhardt, E. S., Band, L. E., Walsh, C. J., & Berke, P. E. (2008). Understanding, managing, and minimizing urban impacts on surface water nitrogen loading. *Annals of the New York Academy of Sciences*, 1134(1), 61-96.
- Boyd C. Water quality in warm water fish ponds. Craft master printers. Inc. Albana, 1981.
- Budakoğlu, M. (2000). İznik Gölü Hidrojeokimyası ve sonuçların jeostatistik değerlendirmesi (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- C. Lin ve G. Lee, *Neural Fuzzy Systems*, Prentice Hall, 1996, pp. 236-239.
- Ced, 2017. Bursa İli 2016 Yılı Çevre Durum Raporu, Bursa Valiliği Çevre ve Şehircilik İl Müdürlüğü, Hazırlayan: ÇED ve Çevre İzinleri Şube Müdürlüğü-Bursa. s: 21-44.
- Chapman, D. (2021). *Water quality assessments: a guide to the use of biota, sediments and water in environmental monitoring*. CRC Press.

- Chebud, Y., Naja, GM, Rivero, RG ve Melesse, AM (2012). Uzaktan algılama ve yapay sinir ağı kullanarak su kalitesi izleme. *Su, Hava ve Toprak Kirliliği* , 223 (8), 4875-4887.
- Chen, Y., Song, L., Liu, Y., Yang, L., & Li, D. (2020). A review of the artificial neural network models for water quality prediction. *Applied Sciences*, 10(17), 5776.
- Chou, J. S., Ho, C. C., & Hoang, H. S. (2018). Determining quality of water in reservoir using machine learning. *Ecological informatics*, 44, 57-75.
- Civelekoğlu, G. (2006). Arıtma proseslerinin yapay zekâ ve çoklu istatistiksel yöntemler ile modellenmesi (Doctoral dissertation, Fen Bilimleri Enstitüsü, Süleyman Demirel Üniversitesi).
- Çekim, M. (2017). Tütün Yaprağına Bakır (Cu<sup>2+</sup>) Biyosorpsiyonu Sonucu Oluşan Organik Kirliliğin (KOİ) Yapay Sinir Ağları İle Tahmin Edilmesi. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 20(4), 181-189.
- Çıtakoğlu, H., & Özeren, Y. (2021). Sakarya Havzası Su Kalitesi Parametrelerinin Yapay Sinir Ağları ile Modellenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (24), 10-17.
- Dede, A. (2009). İznik göl suyu kalite parametrelerinin yapay sinir ağlarıyla değerlendirilmesi (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- Dede, G. Y., & Sazlı, M. H. T. D. (2008). Yapay sinir ağları ile konuşma tanıma (Doctoral dissertation, Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektronik Mühendisliği Anabilim Dalı).
- Demir, N. M. (2017). Biyolojik Atıksu Arıtma Tesislerinde Karbon Ve Azot Giderim Verimlerinin Tahmini Amacıyla Yapay Sinir Ağlarının Kullanımı. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 6(2), 375-386.
- Efe, Ö., Kaynak, O. (2006). Yapay Sinir Ağları ve Uygulamaları. İstanbul: Boğaziçi Üniversitesi Yayınları.
- Elhatip, H. ve Kömör, M.: A., 2008. Evaluation of water quality parameters for the Mamasin dam in Aksaray City in the central Anatolian part of Turkey by means of artificial neural networks *Environ Geol* 53:1157–1164.
- Elzwayie A, El-Shafie A, Yaseen ZM, Afan HA, Allawi MF (2017). RBFNN-based model for heavy metal prediction for different climatic and pollution conditions. *Neural Comput Applic* 28(8):1991– 2003.



- Eren, B., Turp, M.S. (2011). Sızıntı Suyundan Nikel (II) İyonları Giderim Veriminin Yapay Sinir Ağları İle Tahmin Edilmesi, e-Journal of New World Sciences Academy Engineering Sciences, 1A0161, 6, (1), 398-405.
- Eroğlu, A. (2020). Galvaniz kaplama kalitesini etkileyen parametrelerin yapay sinir ağları ile analiz edilerek hatalı ürünlerin minimuma indirgenmesi ve bir uygulama (Master's thesis, Kırıkkale Üniversitesi).
- Furnas, M. J. (2018). The behavior of nutrients in tropical aquatic ecosystems. In *Pollution in tropical aquatic systems* (pp. 29-65). CRC Press.
- Garipoğlu N., Uzun M., 2019. İznik Gölü Havzası'nda Doğal Ortam Koşulları, Değişimler ve Muhtemel Risklerin Havza Yönetimi ve Planlamasına Etkisi. *Doğu Coğrafya Dergisi*, 1-15.
- Gorde, S. P., & Jadhav, M. V. (2013). Assessment of water quality parameters: a review. *J Eng Res Appl*, 3(6), 2029-2035.
- Gönül, Y., Ulu, Ş., Bucak, A., & Bilir, A., Yapay Sinir Ağları ve Klinik Araştırmalarda Kullanımı. *Genel Tıp Dergisi*, 25(3), (2015).
- Gupta, P., Vishwakarma, M., & Rawtani, P. M. (2009). Assessment of water quality parameters of Kerwa Dam for drinking suitability. *International Journal of Theoretical & Applied Sciences*, 1(2), 53-55.
- Hamzaçebi, C. (2011). Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı, Ekin Yayınevi, Bursa, 17-18.
- Hamzaçebi, C., & Kutay, F. (2004). Yapay sinir ağları ile türkiye elektrik enerjisi tüketiminin 2010 yılına kadar Tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19(3).
- Haykin, S. (1999). *Self-organizing maps. Neural networks-A comprehensive foundation*, 2nd edition, Prentice-Hall.
- Helmer, R., & Hespanhol, I. (1997). *Water pollution control: a guide to the use of water quality management principles*. CRC Press.
- <https://docplayer.biz.tr/17047395-Iznik-golu-su-kalitesinin-fitoplankton-gruplarina-gore-belirlenmesi.html> Erişim Tarihi:13.04.2022
- [https://www.sbb.gov.tr/wpcontent/uploads/2018/11/08\\_SuHavzalariKullanimiveYonnetimi.pdf](https://www.sbb.gov.tr/wpcontent/uploads/2018/11/08_SuHavzalariKullanimiveYonnetimi.pdf)) Erişim Tarihi: 01.05.2022
- Isiyaka, H. A., Mustapha, A., Juahir, H., & Phil-Eze, P. (2019). Water quality modelling using artificial neural network and multivariate statistical techniques. *Modeling Earth Systems and Environment*, 5(2), 583-593.

- Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- Jones, R., & Lee, GF (1982). Fosfor yüklerinin ötrofikasyonla ilgili su kalitesi üzerindeki etkisini değerlendirmede son gelişmeler. *Su Araştırması* , 16 (5), 503-515.
- Kadam, AK, Wagh, VM, Muley, AA ve diğerleri. Hindistan, Shivganga Nehri havzasında yapay sinir ağı ve çoklu doğrusal regresyon modelleme yaklaşımı kullanılarak su kalitesi indeksinin tahmini. modeli. *Dünya Sist. Çevre*. 5, 951–962 (2019). <https://doi.org/10.1007/s40808-019-00581-3>.
- Kaynar, O., Tastan, S., & Demirkoparan, F. (2010). Ham Petrol Fiyatlarının Yapay Sınır Ağları İle Tahmini/Crude Oil Price Forecasting With Artificial Neural Networks. *Ege Akademik Bakis*, 10(2), 559.
- Khudair, BH, Jasim, MM ve Alsaqqar, AS (2018). Yeraltı suyu kalitesinin tahmini için yapay sinir ağı modeli. *İnşaat mühendisliği dergisi* , 4 (12), 2959-2970.
- Korkut Ş., «Su Kalitesi Yönetimi Ders Notları,» Bülent Ecevit Üniversitesi, Zonguldak, 2012.
- Kroupova, H., Machova, J., & Svobodova, Z. (2005). Nitrite influence on fish: a review. *Veterinarni medicina-praha-*, 50(11), 461.
- Mandic, D. P. and Chambers, J. A. 2001. *Neural Networks for Prediction - Learning Algorithms, Architectures and Stability*, John Wiley & Sons Ltd.
- Manisalı, H. (2020). Elektrik Empedans Tomografide Eliptik Yapılardaki İletkenlik Dağılımları Geriçatım Probleminin Yapay Sinir Ağları İle İncelenmesi.
- Meriç E., Nazık A., Avşar N., Alpar B., Ünlü S., Gökşan E., 2009. Kuvaterner'de olası Marmara Denizi İznik Gölü Başlantısının delilleri: İznik Gölü (Bursa-KB Türkiye) güncel sedimanlarındaki Ostrakod ve Foraminiferlerin değerlendirilmesi. *İstanbul Yerbilimleri Dergisi*, 1-19.
- Meşeli A., 2010. İznik Gölü Havzasında Çevre Sorunları. *Dicle Üniversitesi Ziya Gökalp Eğitim Fakültesi*, 14 (2010), 134-148.
- Metcalf, E., Eddy, H. P., & Tchobanoglous, G. (1991). *Wastewater Treatment, Disposal, and Reuse*.
- Najah, A., El-Shafie, A., Karim, O. A., & El-Shafie, A. H. (2013). Application of artificial neural networks for water quality prediction. *Neural Computing and Applications*, 22(1), 187-201.

- Namdev, G. R., Bajpai, A., & Malik, S. (2011). Assessment of chemical fertilizers on the quality of water at Hathaikheda reservoir in Bhopal (MP). *International Journal of Pharma and Bio Sciences*, 2(3), 264-268.
- Obiewa, J. O., Karuki, D. K., & WACHIRA-MBUI, D. N. (2020). Artificial Neural Network for Prediction of Pollution Load of Lead, Copper, and Cadmium in a Water Resource: A case Study of River Sosiani, Eldoret Municipality, Kenya. *Africa Journal of Physical Sciences ISSN: 2313-3317*, 5(2).
- Oinam, J. D., Ramanathan, A. L., Linda, A., & Singh, G. (2011). A study of arsenic, iron and other dissolved ion variations in the groundwater of Bishnupur District, Manipur, India. *Environmental Earth Sciences*, 62(6), 1183-1195.
- Okkan, U., & Mollamahmutođlu, A. (2010). Çoruh Nehri günlük akımlarının yapay sinir ađları ile tahmin edilmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 14(3), 251-261.
- Öztemel, E. (2003). *Yapay sinir ađları*. PapatyaYayincılık, İstanbul.
- Öztemel, E. (2012). *Yapay Sinir Ađları*. Papatya Yayincılık, Ankara.
- Öztemel, E., *Yapay Sinir Ađları*, Papatya Bilim, İstanbul, Ankara, İzmir, Adana, 2016.
- Pradeep, V., Deepika, C., Urvi, G., & Hitesh, S. (2012). Water quality analysis of an organically polluted lake by investigating different physical and chemical parameters. *Int. J. Res. Chem. Environ*, 2(1), 105-111.
- Saraç, T. (2004). *Artificial Neural Networks*. Seminar Project, Gazi University, Industrial Engineering Department, Ankara.
- Sattar, M. T., Fard, A. F., Docherkhesaz, M., & Öztürk, F. (2007). Yapay sinir ađları yöntemi ile savalan sulama rezervuarının simülasyonu. *Journal of Agricultural Sciences*, 13(04), 337-345.
- Sellami, I., Hamza, A., Bouain, A., Aleya, L., & Ayadi, H. (2012). Trophic condition of seven mediterranean freshwater reservoirs: Environmental factors and zooplanktonic community.
- Sengorur, B., Dogan, E., Koklu, R., & Samandar, A. (2005). Dissolved oxygen estimation using artificial neural network for water quality control. *Electronic Letters on Science and Engineering*, 1(2), 13-16.
- Sezginer, S. (2015). Yapay sinir ađları ile elektriksel sistemlerde aşırı akım kavramı için kontrol sistemleri tasarımı.
- Sharifahmadian, A. (2015). Numerical models for submerged breakwaters: coastal hydrodynamics and morphodynamics. Butterworth-Heinemann.

- Sharpley, A. N., McDowell, R. W., & Kleinman, P. J. (2001). Phosphorus loss from land to water: integrating agricultural and environmental management. *Plant and soil*, 237(2), 287-307.
- Singh, K. P., Basant, A., Malik, A., & Jain, G. (2009). Artificial neural network modeling of the river water quality—a case study. *Ecological modelling*, 220(6), 888-895.
- Sinshaw, T. A., Surbeck, C. Q., Yasarer, H., & Najjar, Y. (2019). Artificial neural network for prediction of total nitrogen and phosphorus in US Lakes. *Journal of Environmental Engineering*, 145(6), 04019032.
- Srivastava, G., & Kumar, P. (2013). Water quality index with missing parameters. *International Journal of research in Engineering and Technology*, 2(4), 609-614.
- Subaşı, H., & Ersü, Ç. B. (2010). Yapay Sinir Ağı İle Atıksu Arıtma Performansının Modellenmesi (Doctoral dissertation, Yüksek Lisans Tezi, Adana).
- Şahin, M. (2019). İç Mekân Aydınlatma Sistemlerinde Ortalama Aydınlik Düzeyinin Yapay Sinir Ağları İle Tahmini. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi* , 19 (2), 348-360.
- Şanlı, E. (2018). Yapay Sinir Ağı Kontrollü Otonom RC Araç Uygulaması (Master's thesis, İstanbul Gelişim Üniversitesi Fen Bilimleri Enstitüsü).
- Tan, A. 2006. Atık sularda bazı kirlilik parametrelerinin incelenmesi, Yüksek Lisans Tezi Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne. s: 34-36.
- Teksoy, A., Katip, A., & Nalbur, B. E.(2019). Karsak Deresi'nde Su Kalitesinin Gizlenmesi Ve Gemlik Körfezi'ne Etkisinin Değerlendirilmesi.
- Terzi, Ö. & Köse, M. (2012). YAPAY SİNİR AĞLARI YÖNTEMİ İLE GÖKSU NEHRİ'NİN AKIM TAHMİNİ . *Uluslararası Teknolojik Bilimler Dergisi* , 4 (3) , 1-7.
- Terzi, Ö., 2006. Yapay Sinir Ağları Metodu ile Eğirdir Gölü Su Sıcaklığının Tahmini, Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü Dergisi, 10-2, 297-302.
- Tolon, M., Tosunoğlu, N. (2008). Tüketici tatmini verilerinin analizi: Yapay sinir ağları ve regresyon analizi karşılaştırılması. *Gazi Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 10/2, 247-259.
- Türkiye Cumhuriyeti Milli Eğitim Bakanlığı, Mesleki Eğitim ve Öğretim Sisteminin Güçlendirilmesi Projesi (MEGEP) Yayınları (2011). Suların Analiz Parametreleri, Çevre Sağlığı, Ankara.

- Tüzün, İ., Soyupak, S., İnce, Ö., ve Başaran, G., 2007. Application of Artificial Neural Network-Based Approach for Calculating Dissolved Oxygen Profiles in Kapulukaya Dam Reservoir, *International Journal of Ecology & Development*, Vol. 7, No. S07.
- Ucun Ozel, H., Gemici, B. T., Gemici, E., Ozel, H. B., Cetin, M., & Sevik, H. (2020). Application of artificial neural networks to predict the heavy metal contamination in the Bartın River. *Environmental Science and Pollution Research*, 27(34), 42495-42512.
- Uddin, M. N., Alam, M. S., Mobin, M. N., & Miah, M. A. (2014). An Assessment of the River water quality parameters: A case of Jamuna River. *Journal of environmental science and natural resources*, 7(1), 249-256.
- Wetzel, R.G., G., R., 1975. *Limnology*. Saunders College Publishing/Holt, Rhinehart and Winston, Philadelphia, Pennsylvania
- Wilamowski, B. M., Chen, Y., & Malinowski, A. (1999, July). Efficient algorithm for training neural networks with one hidden layer. In *IJCNN'99. International Joint Conference on Neural Networks. Proceedings (Cat. No. 99CH36339)* (Vol. 3, pp. 1725-1728). IEEE.
- Yaşar, M. (2004). Günlük akışlardaki boşlukların yapay sinir ağları kullanılarak tamamlanması (Master's thesis, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü).
- Yavuz, S., ve Deveci, M. (2012). İstatistiksel normalizasyon tekniklerinin yapay sinir ağın performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167–187.
- Yazgan, S., & Demirtaş, Ç. (2005). Bursa-İzmit yöresinde sırık domates sulamasında damla sulama yönteminin kullanımı ve karşılaşılan sorunlar. *Uludağ Üniv. Zir. Fak. Derg.*, 19(1), 91-100.
- Yazıcı, Ö.(2020). İzmit-Mekece Arasında Jeomorfolojik Gözlemler. *Anemon Muş Alparslan Üniversitesi Sosyal Bilimler Dergisi*, 8(1), 125-138.
- Yılmaz, B. (2015). Akarçay havzasında çözünmüş oksijen değerlerinin yapay sinir ağları ile belirlenmesi. Uzmanlık Tezi. T.C. Orman ve Su İşleri Bakanlığı Su Yönetimi Genel Müdürlüğü, Ankara. Erişim adresi [https://www.tarimorman.gov.tr/SYGM/Belgeler/TEZLER/BekirYilmazTez%20\(2\).pdf](https://www.tarimorman.gov.tr/SYGM/Belgeler/TEZLER/BekirYilmazTez%20(2).pdf)
- Yılmaz, E. C. (2009). Bir atıksu arıtma tesisinin girişindeki biyolojik oksijen ihtiyacının yapay sinir ağları kullanılarak modellenmesi (Master's thesis, Sakarya Üniversitesi).
- Zhang, G., Patuwo, B.E., Hu, M.Y. (1998). Forecasting With Artificial Neural Networks: The State of the Art, *Inter. Journal of Forecasting*, Cilt 14, 35-62.

## ÖZGEÇMİŞ

**Adı Soyadı** :Edanur KAYA

### ÖĞRENİM DURUMU

| Derece        | Eğitim Birimi  | Mezuniyet Yılı |
|---------------|--|----------------|
| Yüksek Lisans | Sakarya Üniversitesi / Fen Bilimleri Enstitüsü<br>/ Çevre Mühendisliği | Devam ediyor   |
| Lisans        | Sakarya Üniversitesi / Mühendislik Fakültesi /<br>Çevre Mühendisliği   | 2018           |
| Lise          | Ertuğrulgazi Anadolu Lisesi  | 2012           |

### İŞ DENEYİMİ

| Yıl        | Yer         | Görev |
|------------|-------------|-------|
| 2019-Halen | KUTLU TMGDK | TMGD  |

### YABANCI DİL

İngilizce