

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY SİNİR AĞLARI İLE İZNİK GÖLÜ AĞIR
METAL PARAMETRELERİNİN
DEĞERLENDİRİLMESİ**

**YÜKSEK LİSANS TEZİ
Deniz KASAPOĞULLARI**

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

Haziran 2022

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YAPAY SİNİR AĞLARI İLE İZNİK GÖLÜ AĞIR
METAL PARAMETRELERİNİN
DEĞERLENDİRİLMESİ**

YÜKSEK LİSANS TEZİ

Deniz KASAPOĞULLARI

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.

Deniz KASAPOĞULLARI

19.05.2022

TEŞEKKÜR

Yüksek lisans eğitimim 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 Kırıl 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 ailem; annem Aysun KASAPOĞULLARI, babam Ali KASAPOĞULLARI, ablam Derya OĞUZ'a teşekkür ederim.

Yüksek lisans eğitimim boyunca bana her koşulda destek sağlayan değerli arkadaşım Edanur KAYA'ya teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	v
ŞEKİLLER LİSTESİ	viii
TABLOLAR LİSTESİ	xiii
ÖZET	xiv
SUMMARY	xv

BÖLÜM 1.

GİRİŞ	1
-------------	---

BÖLÜM 2.

KAYNAK ARAŞTIRMASI	3
2.1. İznik Gölü	3
2.2. İznik Gölü Su Kalitesi	4
2.3. Yapay Sinir Ağları (YSA)	7
2.3.1. Yapay zeka	7
2.3.2. Yapay sinir ağları	7
2.3.3. Biyolojik sinir sistemi	8
2.3.4. Yapay sinir ağı hücresi	9
2.3.4.1. Girdiler	10
2.3.4.2. Ağırlıklar	11
2.3.4.3. Toplama işlevi	11
2.3.4.4. Aktivasyon fonksiyonu	11
2.3.4.5. Çıkış fonksiyonu	11
2.3.5. Yapay sinir ağlarında genel yapı	12

2.3.6. Yapay sinir ağlarının genel özellikleri	13
2.3.7. Yapay sinir ağlarının uygulama alanları	14
2.3.8. Yapay sinir ağlarında öğrenme	15
2.3.9. Yapay sinir ağlarının öğrenme algoritmaları	16
2.3.9.1. Eğitici (gözetimli) öğrenme	16
2.3.9.2. Eğitici (gözetimsiz) öğrenme	17
2.3.9.3. Pekiştirmeli (destekleyici) öğrenme	17
2.3.10. Yapay sinir ağ modelleri	18
2.3.10.1. Tek katmanlı algılayıcılar	18
2.3.10.2. Çok katmanlı algılayıcılar (geriye yayılım)	19
2.3.10.3. İleri beslemeli yapay sinir ağları	19
2.3.10.4. Geri beslemeli yapay sinir ağları	20
2.3.10.5. Radyal tabanlı yapay sinir ağları	21
2.3.11. Yapay sinir ağlarının avantajları	21
2.4. Yapay Sinir Ağlarında Su Kalitesinin Ağır Metaller Bakımından İzlenmesi.....	22
2.5. Türkiye’de ve Dünya’da Su Kaynaklarında Su Kalitesinin Yapay Sinir Ağları ile Tahmin Çalışmaları	24

BÖLÜM 3.

MATERYAL VE YÖNTEM	29
3.1. Materyal	29
3.2. Yöntem	29
3.2.1. Çalışılan parametrelerin tanımı	29
3.2.1.1. pH	29
3.2.1.2. İletkenlik	30
3.2.1.3. Sıcaklık	30
3.2.1.4. Renk	30
3.2.1.5. Çözülmüş oksijen	31
3.2.1.6. Biyolojik oksijen ihtiyacı	31
3.2.1.7. Kimyasal oksijen ihtiyacı	31
3.2.1.8. Ağır metaller	32
3.2.2. Ağır metal verilerinin değerlendirilmesi	32

3.2.2.1. YSA modellemesi ve uygulaması	33
3.2.3. İznik Gölü giriş çıkış noktalarından alınan numune yerleri	34
3.2.4. Gözlem noktaları su kalite verileri	36
3.2.4.1. İznik Gölü giriş noktaları ölçümleri	36
3.2.4.2. İznik Gölü çıkış noktası ölçümü	39
 BÖLÜM 4.	
ARAŞTIRMA BULGULARI	41
4.1. Karasu Deresi için Yapılan YSA Modelleri ve R^2 Grafikleri	41
4.2. Olukdere için Yapılan YSA Modelleri ve R^2 Grafikleri	60
4.3. Kırandere için Yapılan YSA Modelleri ve R^2 Grafikleri	80
4.4. Sölöz için Yapılan YSA Modelleri ve R^2 Grafikleri	99
4.5. Bağımsız Değişkenin Önemi	118
 BÖLÜM 5.	
TARTIŞMA VE SONUÇ	122
KAYNAKLAR	124
ÖZGEÇMİŞ	132

SİMGELER VE KISALTMALAR LİSTESİ

°C	: Derece santigrat
ABD	: Amerika Birleşik Devletleri
Ag	: Gümüş
Al	: Alüminyum
ANFIS	: Adaptive-Network Based Fuzzy Inference Systems
ANN	: Artificial Neural Network
As	: Arsenik
B	: Bor
Ba	: Baryum
BOİ	: Biyolojik Oksijen İhtiyacı
BUSKİ	: Bursa Su ve Kanalizasyon İdaresi
C	: Karbon
Ca	: Kalsiyum
Cd	: Kadmiyum
Co	: Kobalt
Cr	: Krom
Cu	: Bakır
ÇO	: Çözülmüş Oksijen
DVM	: Destek Vektör Makinası
EC	: Elektriksel Kondüktivite
Fe	: Demir
Hg	: Cıva
K	: Potasyum
km	: Kilometre
km ²	: Kilometrekare
KOİ	: Kimyasal Oksijen İhtiyacı

L	: Litre
LVQ	: Learning Vector Quantization
m	: Metre
MATLAB	: Matrix Laboratory
mg	: Miligram
Mg	: Magnezyum
MLR	: The Multiple Linear Regression
mm	: Milimetre
Mn	: Mangan
mS/cm	: Milisiemens/santimetre
N	: Azot
Na	: Sodyum
Ni	: Nikel
NO ₂ -N	: Nitrit Azotu
NO ₃ -N	: Nitrat Azotu
o-PO ₄	: Ortofosfat
P	: Fosfor
Pb	: Kurşun
pH	: Potansiyel Hidrojen
Ppb	: Milyarda bir
R ²	: Belirleme Katsayısı
Rb	: Rubidyum
Sb	: Antimon
Si	: Silisyum
SN	: Kalay
SO ₄	: Sülfat
SPSS	: Statistical Package for the Social Sciences
Sr	: Stronsiyum
SS	: Suspended Solids
SSE	: Sum of Squares Error
TÇK	: Toplam Çözünmüş Katı Madde
Th	: Toryum
Ti	: Titanyum

TOC	: Toplam Organik Karbon
U	: Uranyum
V	: Vanadyum
WEKA	: Waikato Environment for Knowledge Analysis
YSA	: Yapay Sinir Ağı
Zn	: Çinko
Zr	: Zirkon



ŞEKİLLER LİSTESİ

Şekil 1.1. İznik Gölü Havzası hidrografi haritası	1
Şekil 2.1. Bazı ağır metallerin kaynakları ve etkileri	6
Şekil 2.2. Biyolojik sinir sisteminin blok gösterimi.....	9
Şekil 2.3. Yapay bir nöronun yapısı.....	10
Şekil 2.4. Yapay sinir ağları genel mimarisi	12
Şekil 2.5. Eğitici öğrenme yöntemi.....	16
Şekil 2.6. Eğitici öğrenme yöntemi	17
Şekil 2.7. Destekleyici öğrenme yöntemi	18
Şekil 2.8. Tek katmanlı algılayıcı.....	18
Şekil 2.9. Çok katmanlı algılayıcı modeli.....	19
Şekil 2.10. İleri beslemeli ağ yapısı	20
Şekil 2.11. Geri beslemeli ağ yapısı.....	20
Şekil 2.12. Radyal tabanlı fonksiyon ağı	21
Şekil 3.1. İznik Gölü uydu görüntüsü	35
Şekil 4.1. Karasu SN parametresi için oluşturulan 6-4-1 YSA modeli.....	42
Şekil 4.2. Karasu SN parametresi R^2 grafiği.....	42
Şekil 4.3. Karasu As parametresi için oluşturulan 8-7-1 YSA modeli	43
Şekil 4.4. Karasu As parametresi R^2 grafiği	43
Şekil 4.5. Karasu Fe parametresi için oluşturulan 6-4-1 YSA modeli.....	44
Şekil 4.6. Karasu Fe parametresi R^2 grafiği.....	44
Şekil 4.7. Karasu Mn parametresi için oluşturulan 6-1-1 YSA modeli	45
Şekil 4.8. Karasu Mn parametresi R^2 grafiği	45
Şekil 4.9. Karasu Cu parametresi için oluşturulan 5-3-1 YSA modeli	46
Şekil 4.10. Karasu Cu parametresi R^2 grafiği	46
Şekil 4.11. Karasu Pb parametresi için oluşturulan 6-3-1 YSA modeli.....	47
Şekil 4.12. Karasu Pb parametresi R^2 grafiği.....	47

Şekil 4.13. Karasu Sb parametresi için oluşturulan 9-4-1 YSA modeli.....	48
Şekil 4.14. Karasu Sb parametresi R^2 grafiği.....	48
Şekil 4.15. Karasu Al parametresi için oluşturulan 9-4-1 YSA modeli.....	50
Şekil 4.16. Karasu Al parametresi R^2 grafiği	50
Şekil 4.17. Karasu B parametresi için oluşturulan 8-7-1 YSA modeli	51
Şekil 4.18. Karasu B parametresi R^2 grafiği	51
Şekil 4.19. Karasu Cr parametresi için oluşturulan 8-7-1 YSA modeli.....	52
Şekil 4.20. Karasu Cr parametresi R^2 grafiği	52
Şekil 4.21. Karasu Cd parametresi için oluşturulan 6-4-1 YSA modeli	53
Şekil 4.22. Karasu Cd parametresi R^2 grafiği	53
Şekil 4.23. Karasu Ni parametresi için oluşturulan 6-4-1 YSA modeli.....	54
Şekil 4.24. Karasu Ni parametresi R^2 grafiği.....	54
Şekil 4.25. Karasu Zn parametresi için oluşturulan 8-7-1 YSA modeli	55
Şekil 4.26. Karasu Ni parametresi R^2 grafiği.....	55
Şekil 4.27. Karasu Se parametresi için oluşturulan 8-4-1 YSA modeli.....	56
Şekil 4.28. Karasu Se parametresi R^2 grafiği.....	56
Şekil 4.29. Karasu Ag parametresi için oluşturulan 9-5-1 YSA modeli.....	57
Şekil 4.30. Karasu Ag parametresi R^2 grafiği.....	57
Şekil 4.31. Olukdere SN parametresi için oluşturulan 6-4-1 YSA modeli	61
Şekil 4.32. Olukdere SN parametresi R^2 grafiği	61
Şekil 4.33. Olukdere As parametresi için oluşturulan 6-1-1 YSA modeli.....	62
Şekil 4.34. Olukdere As parametresi R^2 grafiği.....	62
Şekil 4.35. Olukdere Fe parametresi için oluşturulan 9-2-1 YSA modeli	63
Şekil 4.36. Olukdere Fe parametresi R^2 grafiği	63
Şekil 4.37. Olukdere Mn parametresi için oluşturulan 9-5-1 YSA modeli.....	64
Şekil 4.38. Olukdere Mn parametresi R^2 grafiği.....	64
Şekil 4.39. Olukdere Cu parametresi için oluşturulan 9-3-1 YSA modeli.....	65
Şekil 4.40. Olukdere Cu parametresi R^2 grafiği	65
Şekil 4.41. Olukdere Pb parametresi için oluşturulan 6-2-1 YSA modeli	67
Şekil 4.42. Olukdere Pb parametresi R^2 grafiği	67
Şekil 4.43. Olukdere Sb parametresi için oluşturulan 6-3-1 YSA modeli	68
Şekil 4.44. Olukdere Sb parametresi R^2 grafiği	68
Şekil 4.45. Olukdere Al parametresi için oluşturulan 9-2-1 YSA modeli	70

Şekil 4.46. Olukdere Al parametresi R^2 grafiği	70
Şekil 4.47. Olukdere B parametresi için oluşturulan 6-3-1 YSA modeli.....	71
Şekil 4.48. Olukdere B parametresi R^2 grafiği.....	71
Şekil 4.49. Olukdere Cr parametresi için oluşturulan 6-5-1 YSA modeli	72
Şekil 4.50. Olukdere Cr parametresi R^2 grafiği	72
Şekil 4.51. Olukdere Cd parametresi için oluşturulan 9-7-1 YSA modeli.....	73
Şekil 4.52. Olukdere Cd parametresi R^2 grafiği.....	73
Şekil 4.53. Olukdere Ni parametresi için oluşturulan 6-3-1 YSA modeli	74
Şekil 4.54. Olukdere Ni parametresi R^2 grafiği	74
Şekil 4.55. Olukdere Zn parametresi için oluşturulan 9-7-1 YSA modeli.....	75
Şekil 4.56. Olukdere Zn parametresi R^2 grafiği.....	75
Şekil 4.57. Olukdere Se parametresi için oluşturulan 9-7-1 YSA modeli	76
Şekil 4.58. Olukdere Se parametresi R^2 grafiği	76
Şekil 4.59. Olukdere Ag parametresi için oluşturulan 6-3-1 YSA modeli	77
Şekil 4.60. Olukdere Ag parametresi R^2 grafiği	77
Şekil 4.61. Kırandere SN parametresi için oluşturulan 6-4-1 YSA modeli	81
Şekil 4.62. Kırandere SN parametresi R^2 grafiği	81
Şekil 4.63. Kırandere As parametresi için oluşturulan 6-4-1 YSA modeli.....	82
Şekil 4.64. Kırandere As parametresi R^2 grafiği	82
Şekil 4.65. Kırandere Fe parametresi için oluşturulan 9-4-1 YSA modeli	83
Şekil 4.66. Kırandere Fe parametresi R^2 grafiği	83
Şekil 4.67. Kırandere Mn parametresi için oluşturulan 5-1-1 YSA modeli.....	84
Şekil 4.68. Kırandere Mn parametresi R^2 grafiği.....	84
Şekil 4.69. Kırandere Cu parametresi için oluşturulan 6-2-1 YSA modeli	85
Şekil 4.70. Kırandere Cu parametresi R^2 grafiği.....	85
Şekil 4.71. Kırandere Pb parametresi için oluşturulan 6-1-1 YSA modeli.....	86
Şekil 4.72. Kırandere Pb parametresi R^2 grafiği	86
Şekil 4.73. Kırandere Sb parametresi için oluşturulan 6-4-1 YSA modeli.....	87
Şekil 4.74. Kırandere Sb parametresi R^2 grafiği	87
Şekil 4.75. Kırandere Al parametresi için oluşturulan 6-2-1 YSA modeli	89
Şekil 4.76. Kırandere Al parametresi R^2 grafiği	89
Şekil 4.77. Kırandere B parametresi için oluşturulan 6-4-1 YSA modeli	90
Şekil 4.78. Kırandere B parametresi R^2 grafiği.....	90

Şekil 4.79. Kırandere Cr parametresi için oluşturulan 6-4-1 YSA modeli	91
Şekil 4.80. Kırandere Cr parametresi R^2 grafiği	91
Şekil 4.81. Kırandere Cd parametresi için oluşturulan 6-4-1 YSA modeli	92
Şekil 4.82. Kırandere Cd parametresi R^2 grafiği.....	92
Şekil 4.83. Kırandere Ni parametresi için oluşturulan 6-2-1 YSA modeli	93
Şekil 4.84. Kırandere Ni parametresi R^2 grafiği	93
Şekil 4.85. Kırandere Zn parametresi için oluşturulan 6-5-1 YSA modeli.....	94
Şekil 4.86. Kırandere Zn parametresi R^2 grafiği.....	94
Şekil 4.87. Kırandere Se parametresi için oluşturulan 6-4-1 YSA modeli	95
Şekil 4.88. Kırandere Se parametresi R^2 grafiği	95
Şekil 4.89. Kırandere Ag parametresi için oluşturulan 5-3-1 YSA modeli	96
Şekil 4.90. Kırandere Ag parametresi R^2 grafiği.....	96
Şekil 4.91. Sölöz SN parametresi için oluşturulan 9-7-1 YSA modeli.....	100
Şekil 4.92. Sölöz SN parametresi R^2 grafiği.....	100
Şekil 4.93. Sölöz As parametresi için oluşturulan 9-7-1 YSA modeli.....	101
Şekil 4.94. Sölöz As parametresi R^2 grafiği.....	101
Şekil 4.95. Sölöz Fe parametresi için oluşturulan 9-7-1 YSA modeli.....	102
Şekil 4.96. Sölöz Fe parametresi R^2 grafiği	102
Şekil 4.97. Sölöz Mn parametresi için oluşturulan 6-4-1 YSA modeli	103
Şekil 4.98. Sölöz Mn parametresi R^2 grafiği.....	103
Şekil 4.99. Sölöz Cu parametresi için oluşturulan 6-4-1 YSA modeli	104
Şekil 4.100. Sölöz Cu parametresi R^2 grafiği	104
Şekil 4.101. Sölöz Pb parametresi için oluşturulan 6-4-1 YSA modeli.....	105
Şekil 4.102. Sölöz Pb parametresi R^2 grafiği.....	105
Şekil 4.103. Sölöz Sb parametresi için oluşturulan 9-7-1 YSA modeli.....	106
Şekil 4.104. Sölöz Sb parametresi R^2 grafiği.....	106
Şekil 4.105. Sölöz Al parametresi için oluşturulan 5-3-1 YSA modeli.....	108
Şekil 4.106. Sölöz Al parametresi R^2 grafiği	108
Şekil 4.107. Sölöz B parametresi için oluşturulan 5-3-1 YSA modeli	109
Şekil 4.108. Sölöz B parametresi R^2 grafiği	109
Şekil 4.109. Sölöz Cr parametresi için oluşturulan 6-4-1 YSA modeli.....	110
Şekil 4.110. Sölöz Cr parametresi R^2 grafiği	110
Şekil 4.111. Sölöz Cd parametresi için oluşturulan 6-4-1 YSA modeli	111

Şekil 4.112. Sölöz Cd parametresi R^2 grafiği	111
Şekil 4.113. Sölöz Ni parametresi için oluşturulan 6-4-1 YSA modeli	112
Şekil 4.114. Sölöz Ni parametresi R^2 grafiği	112
Şekil 4.115. Sölöz Zn parametresi için oluşturulan 6-4-1 YSA modeli.....	113
Şekil 4.116. Sölöz Zn parametresi R^2 grafiği.....	113
Şekil 4.117. Sölöz Se parametresi için oluşturulan 9-7-1 YSA modeli	114
Şekil 4.118. Sölöz Se parametresi R^2 grafiği	114
Şekil 4.119. Sölöz Ag parametresi için oluşturulan 9-7-1 YSA modeli	115
Şekil 4.120. Sölöz Ag parametresi R^2 grafiği	115
Şekil 4.121. Karasu bağımsız değişken grafiği	118
Şekil 4.122. Olukdere bağımsız değişken grafiği	119
Şekil 4.123. Kırandere bağımsız değişken grafiği	120
Şekil 4.124. Sölöz bağımsız değişken grafiği	121

TABLÖLAR LİSTESİ

Tablo 2.1. Yapay sinir sisteminin biyolojik sinir sisteminde karşılıkları	10
Tablo 3.1. 2015-2021 yılları Karasu ölçüm sonuçları ortalamaları	36
Tablo 3.2. 2015-2021 yılları Olukdere ölçüm sonuçları ortalamaları.....	37
Tablo 3.3. 2015-2021 yılları Kırandere ölçüm sonuçları ortalamaları.....	38
Tablo 3.4. 2015-2021 yılları Sölöz Deresi ölçüm sonuçları ortalamaları	38
Tablo 3.5. 2015-2021 yılları Karsak Deresi ölçüm sonuçları ortalamaları.....	39
Tablo 4.1. Karasu verilerinin YSA performans değerleri özet tablosu.....	59
Tablo 4.2. Olukdere verilerinin YSA performans değerleri özet tablosu	79
Tablo 4.3. Kırandere verilerinin YSA performans değerleri özet tablosu	98
Tablo 4.4. Sölöz verilerinin YSA performans değerleri özet tablosu	117

ÖZET

Anahtar kelimeler:İznik Gölü, su kalitesi, ağır metal parametresi, yapay sinir ağları

Bu çalışma da 2015-2021 yılları için İznik Gölü'ndeki 4 giriş Karasu, Kırandere, Olukdere, Sölöz ve 1 çıkış noktası olmak üzere Karsak Deresi'nden su kalite parametre ölçümleri alınmıştır. pH, iletkenlik, sıcaklık, biyolojik oksijen ihtiyacı, kimyasal oksijen ihtiyacı, çözünmüş oksijen ve renk içeren fizikokimyasal parametrelerin ağır metaller Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag üzerindeki etkisi incelenmiştir. Ağır metalleri tahmin etmek için çeşitli denemeler yapılarak model çalışmaları için bir yapay sinir ağı (YSA) kullanılmıştır. Model olarak, IBM SPSS istatistik 23 yazılımı kullanılmıştır. Ağır metal değerlerinin performans değerlendirmesinde hata miktarını değerlendirmek için hata kareleri toplamı (SSE) ve belirleme katsayısı (R^2) kullanılmıştır. Sonuçlar, belirleme katsayısının çoğunlukla 1'e yakın olduğunu göstermiştir ve YSA analizi, ağır metal parametrelerinin kirlilik tahmininin gerçekleşebileceğini göstermiştir. Böylece, YSA modelinin göldeki ağır metal kirliliğini tanımlamak için etkin bir şekilde kullanılabilecek bir tahmin aracı olduğu görülmüştür.

EVALUATION OF HEAVY METAL PARAMETERS OF LAKE IZNIK BY ARTIFICIAL NEURAL NETWORKS

SUMMARY


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

In this study, water quality parameter measurements were taken 4 starting point from İznik lake which are Karasu, Kirandere, Olukdere, Sölöz and 1 outpoint which is Karsak Stream in the 2015 to 2021. The effects on heavy metals Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag on pH, conductivity, temperature, biological oxygen need, chemical oxygen need, dissolved oxygen and colorful physicochemical parameters. Various attempts were made to predict heavy metals and an artificial neural network (ANN) was used 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 heavy metal values. The results showed that the coefficient of determination was mostly close to 1 and the ANN analysis showed that the pollution estimation of heavy metal parameters could be realized. Thus, it has been seen that the ANN model is an estimation tool that can be used effectively to describe heavy metal pollution in the lake.

BÖLÜM 1. GİRİŞ

Marmara Bölgesinde yer alan, doğu-batı yönünde bir uzanım gösteren, kuzey-güney yönlü birçok çöküntü alanları mevcuttur. Bu çöküntüler dağ ve platolarla birbirinden ayrılmışlardır (Ardel,1943). İznik Gölü havzası da bu çöküntü alanlarından biri olmaktadır. Kuzeyinde Samanlı Dağları yer almaktadır ve güneyinde Gürle-Avdan dağları bulunur. İznik Gölü bu iki dağ arasında yer alır. Türkiye'nin beşinci büyük gölü olan İznik Gölü havzanın taban kısmındadır. Havzanın içinde yer aldığı doğrultuya paralel olarak doğu-batı yönünde bir uzanış sergilemektedir (Akbulak, 2006).

Gölün yer aldığı havzada Şekil 1.1.'de görüldüğü gibi çok fazla büyük küçük karışık dereler yer almaktadır. Derelerin boyları çoğunlukla kısa ve mevsimlik akarsu özelliğinde bulunmaktadır. Havzanın yüzeybilim yapısından kaynaklı gölün kuzey-güney bölgesinde yer alan derelerin boyları kısa olup kuzey güney yönünde akmakta iken gölün doğu-batısındaki dereler ise daha uzun boylu olup doğu-batı yönünde akmaktadırlar (Garipoğlu ve Uzun, 2019).



Şekil 1.1. İznik Gölü Havzası hidrografi haritası (Garipoğlu ve Uzun, 2019).

İznik Gölü Havzası'nda yer alan, Kocadere (Sölöz Deresi), Kuru Dere (Derbent Deresi), Karasu Deresi, Olukderesi, Kıranderesi, Karsak Deresi gölün en önemli dereleridir (Garipoğlu ve Uzun 2019).

İznik ilçesinde, gölün doğusunda yer alıp büyük bir alanının sit alanı kapsamında yer almasından dolayı inşaata açık olmaması ve sit alanı dışında kalan alanlarında tarım arazisi olması sebebiyle sanayi alanı bulunmamaktadır. Orhangazi, İznik Gölü'nün batısında yer alıp yerleşim alanındaki insanların geçimlerini sağladığı sanayi, hayvancılık, tarım gibi temel ekonomik faaliyetleri oluştururken İznik'te halk çoğunlukla zeytincilik, meyve-sebze üretimi ve diğer sulu tarım ürünleri ile geçimini sağlamaktadır (Garipoğlu ve Uzun 2019). İznik ilçesi ve Orhangazi ilçesinde tarımda kullanılmaya uygun sırasıyla 13.100 hektar ve 6.454 hektar olmak üzere toplamda sulanabilir 19.554 hektar tarım arazisi yer almaktadır (Anonim, 2021).

Su kalitesi parametrelerinin modellenmesi, herhangi bir su sisteminin analizinde çok önemli bir husustur. Su kaynağının uygun yönetimi için yüzey suyu kalitesinin tahmin edilmesi gereklidir. Böylece kirliliği izin verilen sınırlar içinde tutmak için yeterli önlem alınabilir. Gelecekteki olayların doğru tahmini, optimum su kaynakları yönetiminin en önemli hususlarındandır. Yapay sinir ağı, diğer klasik modelleme teknikleriyle karşılaştırıldığında giriş ve çıkış verileri arasındaki karmaşık doğrusal olmayan ilişkileri tanımlayabilen esnek matematiksel yapıya sahip bir tekniktir (Najah ve ark., 2013).

Bu çalışma da, Bursa Büyükşehir Belediyesi Bursa Su ve Kanalizasyon İdaresi (BUSKİ) Genel Müdürlüğü'nden veriler alınmış olup İznik Gölü' ne ait ağır metal parametrelerinin (Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag) yapay sinir ağı (YSA) programında değerlendirilmesi amaçlanmıştır. Veriler 5 gözlem noktasından alınmıştır. 4 giriş (Sölöz, Olukdere, Kıranderesi, Karasu) 1 çıkış noktası (Karsak Deresi) olmak üzere pH, iletkenlik, sıcaklık, çözünmüş oksijen, biyolojik oksijen ihtiyacı, kimyasal oksijen ihtiyacı, renk parametreleri kullanılarak YSA temelli modeller oluşturmak amaçlanmıştır.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

2.1. İznik Gölü

Bursa ili sınırları içerisinde yer alan İznik Gölü, Marmara Denizi'nin güneydoğu bölgesinde bulunmaktadır. Marmara bölgesinde yer alan en büyük tatlı su gölü özelliğindedir. İznik Gölü, Kuzey Anadolu Fay Zonu'nun orta kolu üzerinde doğu batı yönünde oluşmuştur. Gölün derinliği kuzeyden güneye doğru çoğalmaktadır (Meriç ve ark., 2009). Gölün çevresi 92 km uzunluğunda olup 304,18 km² 'lik yüzölçümüne sahiptir. Derinliği -70 m. seviyesine kadar inmekte ve göl yüzeyi deniz seviyesinden 80 m daha yüksektedir. İznik Gölü, tektonik bir yapıya sahiptir ve bu özelliğinden dolayı gölün güney kısmı fay hattına karşılık etmektedir. Gölün en derin alanı güney kısmında yer alır (Garipoğlu ve Uzun, 2019).

Taşkınları önleyebilmek ve göl sularını kontrol edebilmek için gölün batı tarafında setler kurulmuştur. Bölgede kavaklıklar oluşturulmuş ve kurulan seddin gerisindeki 416 hektarlık sulak alan kurutulmuştur (Meşeli, 2010).

Yazları fazla sıcak olan kışları ise ılık bir geçiş iklimine sahip olup gölün bulunduğu havzanın yıllık ortalama sıcaklığı 14°C–16°C arasında değişmektedir. Göl çevresinden dağlık bölgelere doğru gidildiğinde sıcaklık değeri azalma göstermektedir. En yüksek sıcaklık değeri temmuz ve ağustos aylarında ortalama olarak 25°C görülürken, en düşük sıcaklık ocak ayında ortalama olarak 5°C izlenmektedir. Yağışlar gölü besleyen önemli kaynaklardan biridir. İlkbahar ve kış aylarında çoğunluk olarak yağmur şeklinde havzaya düşerken, dağlık bölgelere çıkıldıkça yağış miktarı artıp kar yağışı şeklinde düşüş göstermektedir. Göl etrafına yıllık ortalama 500 mm–800 mm arasında yağış düşerken gölün doğusunda yer alan İznik bölgesinde bu miktar 528 mm civarında görülürken, gölün batısına doğru giderek artmakta olup gölün batısında yer alan Orhangazi bölgesinde 775 mm'ye kadar çıkmaktadır. Devlet Su İşleri tarafından yaptırılan analizlere göre; İznik Gölü suyu ortalama 8.5 pH değerine sahiptir.

Kalsiyum karbonat değeri oldukça yüksek olup, fosfat ve azot değerleri bakımından zengindir (Meşeli, 2010).

2.2. İznik Gölü Su Kalitesi

Gölden ve gölü besleyen derelerden, gölün etrafında yaşayan halk meyve, sebze, zeytincilik ve sulu tarım üretimini gerçekleştirebilmek için su çekme işlemi yapmaktadırlar. Tarım için zirai ilaç ve gübre kullanımı çok fazla mevcuttur. Bu kullanım sonucunda havzanın tabanını oluşturan İznik Gölü'ne yağışlardan kaynaklanan yüzeysel yıkanmalarla sürekli dökülerek kirlilik oluşturmaktadırlar. Tarım için kullanılan alet ve ekipmanlar üreticiler doğrultusunda göl ve gölü besleyen dereler ile yıkanıp tekrar kaynağına akıtılır. Gölün batısında yer alan Orhangazi ilçesi ise, sanayi tesislerinin katı atıklarını göle boşaltarak kirliliğin diğer bir unsurunu yaratmaktadır. Gölde kirlilik yaratan bir unsur da ambalaj atıklarıdır. Gölün etrafında vakit geçiren ziyaretçilerden sonra kıyı hattında aşırı bir ambalaj atığı yığını bulunmakta ve çiftçiler tarafından tarımda kullanılan zirai ilaç ve gübre ambalajları ise hiçbir özen gösterilmeden gelişi güzel bir şekilde çevreye veya su kaynaklarına atılmaktadır (Meşeli, 2010; Garipoğlu ve Uzun, 2019; Anonim, 2021). İznik Gölü, derelerden, tarımdan, aşırı sulamadan, kentleşmeden ve kıyı boyunca endüstriyel faaliyetlerden ve atmosferik birikimden elde edilen girdilere atfedilen yüklerdeki artışa bağlı olarak kademeli olarak bozulmaktadır (Ünlü ve Alpar, 2016).

Çevredeki ağır metal kontaminasyonu, canlı organizmalar için potansiyel riskleri ve tehlikeleri nedeniyle birincil küresel bir endişe kaynağıdır. Ağır metaller, jeolojik ayrışma ve biyolojik ayrışma gibi doğal süreçlerle ve ayrıca madencilik, endüstriyel üretim, fosil yakıtların yakılması, yoğun tarım, gübre kullanımı, çimento üretimi, atık dökümü, kanalizasyon arıtma tesisleri, kentsel akış ve atmosferi, toprakları ve su kütlelerini kirleten diğer birçok faaliyet gibi insan faaliyetleri ile tortulara salınmaktadır (Han ve ark., 2011).

Ağır metaller su kirliliğini oluşturan unsurlardan birisidir. Yüzeysel ve yeraltı sularına ağır metaller doğal kaynakların yanı sıra artış gösteren kentsel, endüstriyel, jeotermal gibi antropojenik baskılarla da ulaşmaktadır. Ca, K, Na, Fe, Zn, Co, Cu, Ni ve Mn gibi ağır metallerin birçoğu C, N, P gibi önemli yaşamsal faaliyetler için gerekmektedir.

Ayrıca, canlılar için ağır metallerin sucul ortamlarda yüksek konsantrasyonlarda bulunması tehlike teşkil etmektedir (Dereli, 2017).

Ağır metaller, gerekli olan veya olmayan metaller ve metaloidlerdir. Her ikisi de yüksek konsantrasyonlarda organizmalar için toksiktir ve birikimleri sudaki organizmaların sağlığını tehdit eder (Green ve ark., 2008). (Şekil 2.1.). (Biney ve ark., 1994;Malik ve ark.,2014;Sarkar ve ark.,2016;Jana ve ark., 2017;Zaidi ve Pal, 2017;Sarkar ve Shekhar,2018). Co, Cu, Fe, Ni ve Zn gibi bu metallerden bazıları eser miktarda su ortamı için gereklidir. Biyokimyasal bir rol oynarlar ve su bitkileri, hayvanlar ve mikroorganizmalardaki yaşam süreçleri için besin olarak gereklidirler. Ancak yüksek konsantrasyonlarda bu eser metaller toksik hale gelir. Cd, Hg ve Pb gibi diğer metaller toksiktir ve bilinen hiçbir biyolojik işlevi yoktur (Talab ve ark., 2016).

Nehir ekosistemlerinin kirlenmesi ciddi bir çevre sorunu haline gelmiştir. Bu, dünya çapında endüstriyel büyümenin ve insan yapımı faaliyetlerin hızlanmasının normal bir sonucudur (Arefin ve ark., 2016).

Metaller	Kaynak	Etkileri
Al (mg/l)	Alüminyum üretim endüstrisi, boksit madenciliği, pigmentler ve boyalar, gübreler ve tekstil	Alzheimer hastalığı, anemi, osteomalazi, glukoz intoleransı, kalp durması ve meme kanseri
As (mg/l)	Yarı iletkenler, odun koruyucular, madencilik ve eritme kömür santralleri, herbisitler, volkanlar, petrol rafineri, hayvan yemi katkı maddeleri	Ensefalopati, Siyah ayak hastalığı, eldiven çorap sendromu, iletim bloğu, QT uzaması
B (mg/l)	Endüstriyel hava emisyonları, gübre ve herbisit uygulamaları, endüstriyel ve kentsel atıklar, cam üretimi, seramik ve kozmetik endüstrileri	İnsanda yüksek Bor alımı merkezi sinir sistemini doğrudan etkiler ve mide bulantısı, kramplar, kasılmalar, koma gibi semptomlar
Cd (mg/l)	Jeojenik kaynaklar antropojenik faaliyetler metal eritme ve rafineri, fosil yakıt yakma, fosfatlı gübrelerin uygulanması, kanalizasyon çamuru.	Hepatik, Pulmoner, Testis hasarı, Böbrek ve kemik hasarı
Cr (mg/l)	Elektrokaplama endüstrisi, çamur, katı atık, tabakhaneler, pigmentler ve boyalar, gübreler ve tekstil	Gastrointestinal, Hepatik, Renal, Nöronal Hasar
Cu (mg/l)	Elektrokaplama endüstrisi, madencilik, eritme, rafineri, pigmentler ve boyalar, Alaşımlar ve satıcılar, biyositler, gübreler ve yakıt	Wilson Hastalığı, Menkes Hastalığı, Baş Ağrısı, Bulantı, Kusma İshali ve Böbrek Arızası
Fe (mg/l)	Demir, çelik ve diğer metalurji endüstrileri, pigmentler, boyalar, tekstil, rafineriler, yakıt, madencilik atıkları, gübreler, herbisit ve demir boruların korozyonu	Diyabet, hemokromatoz, mide problemleri, bulantı, ishal, kusma, gastrointestinal sisteme zarar verme ve karaciğer veya beyin hasarı
Pb (mg/l)	Metal ömürlü cevherlerin madenciliği ve eritilmesi, kurşunlu benzinin yakılması, belediye kanalizasyonu, Pb bakımından zenginleştirilmiş endüstriyel atıklar, boyalar	Teratojenite, Hemoglobin sentezini inhibe eder, Böbrek disfonksiyonu, Eklem ve üreme sistemi
Mn (mg/l)	Piller diğer elektrik, pigmentler ve boyalar, alaşımlar ve lehimler, biyositler, cam, gübreler, yakıt ve rafineriler	Sinir sistemi manganez kaynaklı Parkinsonizm, ruh hali değişiklikleri, kısa süreli hafıza kaybı ve yavaşlamış reaksiyon süresinde toksisite. Anemi, iştahsızlık, yavaşlamış büyüme ve üreme sorunları.
Ni (mg/l)	Volkanik patlamalar, toprak dolgusu, orman yangını, okyanusta kabarcık patlaması ve gaz değişimi, toprakların ve jeolojik malzemelerin ayrışması	İmmünomodülatör ve immünotoksin, Üreme toksini sınıf II, Böbrek hasarı ve Frank hematüri, Hemoglobin HB seviyesini azaltır ve Nörotoksin
Se (mg/l)	Kömür madenciliği, petrol rafineri, fosil yakıtların yanması, cam imalat endüstrisi, kimyasal sentez (örneğin, vernik, pigment formülasyonu)	Kanser, saç ve tırnak kaybı; karaciğer ve böbrek hasarı ve sinir ve kardiyovasküler sistemlerin hasarı
Zn (mg/l)	Elektrokaplama, eritme ve rafineri, madencilik, biyositler, piller ve diğer elektrik, pigmentler ve boyalar, gübreler ve rafineriler	Kusma, İshal, Ikterus (sarılık), Karaciğer ve Böbrek Hasarı

Şekil 2.1. Bazı ağır metallerin kaynakları ve etkileri

2.3. Yapay Sinir Ağları (YSA)

2.3.1. Yapay zeka

Yapay zeka kavramı bir bilgisayarın veya bir makinenin genel anlamda insana sahip nitelikler başta olmak üzere anlama, geçmişteki deneyimlerinden öğrenme, genelleme, çözüm yolu bulma gibi belli mantık süreçlerine özgü sorumlulukları yerine getirme yeteneği olarak tanımlanmıştır (Nabiyev, 2012).

Bu teknoloji günden güne gelişim göstermektedir. Çoğunluk olarak günlük hayatta var olmaktadır. Yeni ürünler ortaya çıkarmaktadır. Yapay zeka teknolojisi otomasyon sistemleri ile kuşatılarak, bilgisayar sistemlerinin karar verme mekanizmasından yararlanılmaktadır.

Yapay zeka teknolojileri; yapay sinir ağları, genetik algoritmalar, uzman sistemler bulanık önermeler mantığı olarak incelenebilir.

Yapay zeka teknolojileri insanlara günlük hayatta bir çok avantaj sağlar ve yararlı ürünlerin oluşmalarına katkıda bulunur. Bu teknolojilerden yapay sinir ağları bilgisayarların öğrenmesini sağlamaktadır (Öztemel, 2003).

2.3.2. Yapay sinir ağları

Yapay zeka konusunu anlayabilmek için kapsamlı bir araştırma yapmak gerekmektedir. Modern insanlığın en büyük düşlerinden biri olan yapay zeka üzerine birçok filmler çekilip, kitaplar yazılmıştır. Yapay zeka üzerinde en fazla çalışma ve araştırma yapılan konu yapay sinir ağlarıdır. İnsan beyninin yapısı baz alınarak geliştirilmiş bir ağ programıdır. Anlaşıldığı üzere; bütün insan davranışlarının (öğrenme, hatırlama, düşünme gibi) zemininde sinir hücreleri yer almaktadır (Ergezer ve ark., 2003).

İklim ve çevre araştırmalarında çok değişkenli zaman serisi analizi her zaman çok büyük miktarda verinin işlenmesini gerektirir. Yapay sinir ağları birçok zor ve zorlu problemlerin üstesinden gelmek için güçlü bir araçtır ve iklim değişikliği


mekanizmasını arařtırmak ve iklim deęiřiklięi eęilimini tahmin etmek iin yaygın olarak kullanılmaktadır. Bařlıca avantajı, yapay sinir aęlarının, iklim verilerinde gizlenmiř bazı bilinmeyen bilgileri ıkarmasalar da tam olarak kullanmasıdır (Zhou ve ark., 2002).

Yapay sinir aęları, 1980’li yılların sonlarından itibaren kullanılmaya bařlanmıřtır. Zaman serilerine iliřkin tahminler yrtmek iin kullanılan aę yntemlerindendir. Gnmzde birden fazla alanda ngrmleme teknięi olduka fazla bir řekilde kullanılmaktadır. Yapay sinir aęları kolay bir řekilde insan beyninin alıřma fonksiyon yntemini kendine uygulamaktadır. Bu anlamda YSA’ları yapay zeka teknolojileri iinde nem teřkil etmektedir. Yapay sinir aęlarının genelleme yapabilme, sınırsız sayıda deęiřkenle alıřabilme, veriden ęrenebilme gibi ok nemli birok nitelięi iinde barındırma zellięi vardır. Bu zellikleri sebebiyle YSA’lar birden fazla nemli avantajlar saęlamaktadır. Yapay sinir aęları ngr modellemesi alanında ok geniř bir řekilde bulunmaktadır. Aynı zamanda dięer birok alanda da yer almaktadır (Ataseven, 2013).

YSA’lar insan beyninin niteliklerine benzer bir řekilde, iliřkilendirme, sınıflandırma, optimizasyon, ęrenme, genelleme, zellik belirleme gibi birok alanda sekin bir řekilde kullanılmaktadır (ztemel, 2003).

2.3.3. Biyolojik sinir sistemi

Biyolojik sinir sistemi, merkezi sinir aęının (beyin) yer aldıęı srekli olarak merkezinde bilgiyi alan, doęru karar veren, yorum getiren  katmanlı bir sistematik halinde tanımlanmaktadır. Receptorler (alıcı sinir) dıř etkenlerden ya da organizma ierisinden uyarılar alırlar. Aldıkları bu uyarıları beyine bilgi ulařtıran elektriksel sinyallere dnřtrrler. Beyinin rettięi elektriksel darbeleri effectorler (tepki sinirleri) ise organizma ıktısı olarak elveriřli reaksiyonlara dnřtrmektedir. řekil 2.2.’ de grlmektedir.



Şekil 2.2. Biyolojik sinir sisteminin blok gösterimi (Fırat ve ark. 2004).

Beyindeki sinir ağlarının yapısından esinlenerek ortaya çıkarılan yapay sinir ağları yapay olarak tasarımı yapılmış bir ağ sistemidir. Bu sinir ağları deneyimle elde ettikleri bilgileri daha sonra kullanabilmek isterler. Bunun içinde bu bilgileri saklayabilmek adına basit işlemci elemanlarını (nöron) ve birbirleri arasında paralel bağlantılarını (sinaps) oluştururlar (Kulkarni, 1994).


İki özellik açısından beyine benzemektedirler. Aynı beyin de olduğu gibi sinir ağları da bilgilerin çevreden alınıp bir öğrenme sürecinden geçirilerek elde edilmesine dayanmaktadır. Diğer benzerlik ise sinaptik bağlar olarak bilinen nöronlar arasındaki bağlantı gücü sayesinde bu bilgilerin saklanmasıdır (Haykırı, 1999).

Sinir ağı yapısı ele alınarak akson, dentrit, sinaps ve hücre gövdesi adı verilen tüm yapılar incelenmiş olup daha sonrasında yapay sinir ağlarının model yapısı kurgulanmıştır. Gerçek bir biyolojik hücre ile aynı temel işlevlerinin görevini üstlenmesi istenmiş olup model üzerine çalışmalar bu şekilde yürütülmüştür (Fausett ve Elwasif, 1994).

2.3.4. Yapay sinir ağı hücresi

Yapay sinir ağlar bir noktada biyolojik sinir ağının matematiksel bir modelidir. Birbirleri ile fonksiyonel bir ilişki halindedir. Şekil 2.3.'te yapay sinir ağının en temel elamanı olan bir nöronun yapısı görülmektedir (Kalogirou, 1999).

Nöron olarak adlandırılan basit bir yapıdan meydana gelirler. Sinyaller sayesinde nöronlar arasındaki bağlantıları iletirler. Nöronlar arasında her bir bağlantı belirli bir ağırlık değerine sahip olup, her nöronun bir çıktısı ve girdisi bulunmaktadır. Ve bu girdilerin aktivasyon fonksiyonundan geçirilmesi gerekmektedir (Hamzaçebi, 2011). Tablo 2.1.'de biyolojik sinir sisteminin yapay sinir sistemindeki karşılıkları görülmektedir.



Şekil 2.3. Yapay bir nöronun yapısı (Kalogirou, 1999)

Tablo 2.1. Yapay sinir sisteminin biyolojik sinir sisteminde karşılıkları (Öztürk ve ark. 2018).

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

2.3.4.1. Girdiler

Girdiler ($x_1, x_2, \dots, x_n$) dış dünyadan veri alan yapay sinir ağlarının elemanlarıdır. Verileri bir sonraki adıma dönüştürmekten başka işlevleri yoktur. Yani girdiler veriler üzerinde herhangi bir matematiksel işlem yapmazlar ve sadece verici olarak çalışırlar. Girdiler, ağıdın dış dünyası ile ilgili olan YSA'ların iki unsurundan biridir. Bir nöronun sınırsız sayıda girdisi olabilir, ancak her nöronun yalnızca bir çıktısı olmalıdır (Çelik, 2008).

2.3.4.2. Ağırlıklar

Ağırlıklar ($w_1, w_2, \dots, w_n$) başlı başına matematiksel nöronun ve genel olarak yapay sinir ağının en önemli unsurlarıdır. Çünkü ağ tarafından öğrenilen veriler ağırlıklar üzerinde depolanır. YSA'lar ağırlıkları değiştirerek öğrenme işlevlerini gerçekleştirebilirler (Çelik, 2008).

2.3.4.3. Toplama işlevi

Toplama fonksiyonu, dış dünyadan gelen tüm verilerin ve ilgili ağırlıkların toplamından sorumludur. Toplama fonksiyonları, yapay sinir ağlarında en çok kullanılan fonksiyondur. Ancak, sürecin toplama fonksiyonu olması gerektiği konusunda herhangi bir kısıtlama yoktur (Çelik, 2008).

2.3.4.4. Aktivasyon fonksiyonu

Aktivasyon (transfer) fonksiyonu, gelen ağırlıklı girdinin aktivasyonundan ve nihai çıktı değerinin belirlenmesinden sorumludur. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu olarak kullanılabilecek fonksiyonlar problem tipine göre değişmektedir. Hangi tür aktivasyon fonksiyonunun kullanılması gerektiğine dair evrensel bir formül yoktur (Öztemel, 2006). Aktivasyon fonksiyonlarında en çok sigmoid ve hiperbolik tanjant fonksiyonları kullanılmaktadır (Saraç, 2004).

2.3.4.5. Çıkış fonksiyonu

Çıkış fonksiyonu, aktivasyon fonksiyonunun çıkış değerinin ağın son çıkış değeri olarak dış dünyaya veya giriş değerleri olarak diğer bağlı nöronlara aktarılmasından sorumludur.

Yapay sinir nöronları bir araya gelerek yapay sinir ağını oluşturur. Genelde üç katmanda bir araya gelirler ve her katmanda paralel olarak YSA'yı oluştururlar (Açıkalın, 2007).


2.3.5. Yapay sinir ağlarında genel yapı

Yapay sinir ağı, yapay sinir hücrelerinin birbirlerine bağlanması sonucu oluşur. Genel yapı ileri beslemeli bir ağ yapısında giriş, ara katman (gizli katman) ve çıkış katmanı olarak üç katman yapısı şeklinde bulunur. Ara katman sayısı istenilen durumlarda yükseltilebilmektedir. Şekil 2.4.'de üç katmanlı bir ağ yapısı gösterilmiştir. Giriş katmanı gizli katmanı ve çıkış katmanı bulunan bir örnek ağ modelidir.

Giriş katmanı; veriler bu katmanda ağı girilir. Veriler işlenmeden bir sonraki adım olan ara katmana aktarılmaktadır.

Ara (gizli) katman; bu katmanda hücre sayısı probleme göre değişebilir özelliğindedir, giriş katmanındaki verileri uygun fonksiyonlarla geliştirerek çıkış katmanına ulaştırır.

Çıkış katmanı; ara (gizli) katmandan alınan veri, bu katmanda ağıın kullanıldığı fonksiyonda işlenip çıktıyı oluşturur (Kılıç, 2015).



Şekil 2.4. Yapay sinir ağları genel mimarisi (Kılıç, 2015).

2.3.6. Yapay sinir ağlarının genel özellikleri

Yapay sinir ağlarının diğer yöntemlerden farklılıkları genel olarak aşağıdaki gibi sıralanmıştır (Simpson, 1990;Seven, 1993).

Hata Toleransı: Klasik metotlar da bir elemanı yerinden çıkarmak o sistemin çalışabilmesini engellemektedir. Ağ yapısında sahip olunan bilginin bütün bağlantılara yayılımını sinir ağlarında ki paralel yapı sağlamaktadır. Bundan dolayı hücrelerin nötr hale gelmesi, bazı bağlantıların doğru çalışmaması ağın bilgiyi doğru üretebilmesini önemli bir şekilde etkilememektedir. Aynı zamanda ağların hatayı tolere etme kabiliyeti klasik metotlara göre yüksek olmaktadır.

Uyarlanabilirlik: Ağırlıkların yeniden oluşturulabilmesi belirli bir problemi çözmek için eğitilmiş olan ağın, problemde meydana gelen değişikliklere göre tekrardan eğitilebilir olması ve aynı zamanda farklı durumlara uyarlanabilmesi yapay sinir ağlarında avantaj sağlamaktadır.

Paralellik: İşlemler, rutin bilgi işlem yöntemlerinin hemen hemen hepsinde seri bir düzen içerisinde bulunmaktadır. Öncelikli olarak bu düzen hız sorununa sebebiyet vermektedir. Bir beyin yapısına göre bilgisayarlar çok hızlı çalışmaktadırlar. Ama ikisi kıyaslandığında toplam hız baz alındığında beyin bu konuda bilgisayarları geçmektedir. İşlemler yapay sinir ağlarında doğrusal değildirler. Ve bu tüm ağa yayılmış durumdadır. Zaman bağımlılığı da aynı katmanlar içerisinde yer almamaktadır. Bu vaziyet, hızını çok arttırmakta olup tüm sistemin eş zamanlı çalışabilmesini sağlamaktadır. Bu sayede doğrusal olmayan karmaşık sorunların da çözümlenmesini mümkün kılmaktadır.

Öğrenebilirlik: Hazır bilgi işlem sistemleri ağırlık ya da verileri yenileyememekte olup belirli bir algoritma kapsamında çalışmaktadır. Tam tanımlı olmayan problemler de bu vaziyette çözüme kavuşamamaktadır. Önceden sisteme girilen veriler ağlarda kullanılarak ağırlıkların tespit edilmesini sağlamaktadır. Bununla beraber her uygulanan farklı bir çalışma da bu durumda öğrenme işlemi yenilenebilir bir yapıda olmaktadır. Önceden ağırlıkların ve bağlantıların verilememesi amaca uygun olacak bir çalışma da sorun teşkil etmektedir. Fakat örneklerle kendini eğitebilmesi ve gerekli

verileri oluşturabilmesi yapay sinir ağlarının bu özellikleri sayesinde bu sorunu ortadan kaldırmaktadır.

Gerçekleme Kolaylığı: Karışık fonksiyonlar basit fonksiyonlar yerine kullanılabilir.

Donanım ve Hız: Paralel yapısı sayesinde bilgiyi çok hızlı işleme kabiliyetindedirler.

Genelleme: Eğitim sırasında ve sonrasında karşılaşılmayan test örnekleri bulunan ağlar bunları değerlendirir. Daha sonrasında istenilen tepkileri üretebilir. Örnek verilirse, karakter tanımlandığı esnada bozuk karakter girişinde doğru karakterleri elde etmek mümkündür.

Yerel Bilgi İşleme: Problemlerin tamamıyla ilgilenmeyip kısımlarına parça parça odaklanılması ve görev paylaşımı ile çok zor ve karışık problemler yapay sinir ağlarında çözülebilir kılınmaktadır.

2.3.7. Yapay sinir ağlarının uygulama alanları

Optimizasyon: Bir optimizasyon problemi ağı girilip, örnek kümeyle ait ilk verilerin girilme işleminden sonra çözüme ait değişkenler kümesi çıktı verileri olarak alınabilmektedir.

Tahmin: Ağlara girişi sağlanan verilerden belli bir sonuç elde etmek için kullanılmaktadır. Talep tahmini, gelecek tahmini gibi.

Yapay Zeka: Görüntü, ses tanımlama gibi alanlar için kullanılabilir.

Örnek Eşleştirme: Sinir ağlarına girişi yapılan örneğin cinsine uygun örnek tipi seçilebilir.

Gürültü Uzaklaştırma: Gereksiz veriler bu özellik sayesinde uzaklaştırılır ve yeni girdi kümeleri elde edilebilir.

Örnek Tamamlama: Bu sistemlere eğer eksik bir örnek ağa girilmesi takdirinde eksik kalan kısımlar bu ağ tarafından bitirilip daha sonrasında örnek çıktı verisi olarak alınabilir.

Sınıflandırma: Ağdan bir örnek verisi geçirilip, karşılık olarak çıkış verisi olarak bir örnek sınıfı belirtilir.

Üretim: Analizler ve kalite kontrol ile model kurma, geliştirme ve mevcut otomasyon sistemini ilerletmek mümkün olabilmektedir.

Finansman ve Yatırım: Stok analizi, kredi analizi gibi durumların modellenmesinde kullanılabilir.

Tıp: Genetik örnekleme, kan örnekleme haritalarının oluşturulması, hastalıkların belirlenmesi gibi işlemler için kullanılabilir.

Kontrol: Giriş verilerine ait üretilen sonuçlar ile mevcut duruma uygun sonuçlar arasında kıyas yapılabilir.

Bilim ve Mühendislik: Çok değişkenli eğri uyumları, iklim modellemesi, doğrusal olmayan model, karmaşık problemlerin çözümü konularında uygulamalar var olmaktadır. Regresyon ve istatistik testlerinin yetersiz kaldığı birçok konu da kullanılabilir (Haykin, 1999).

2.3.8. Yapay sinir ağlarında öğrenme

Yapay sinir ağları zaman içinde öğrenebilmektedir. Bu özellikleri sayesinde uyarlayıcı nitelik taşımaktadırlar. Yani, sinir ağları problem çözme yeteneklerini geçmiş deneyimlerine dayanarak geliştirirler. Sinir ağlarındaki bu durum “öğrenme” olarak nitelendirilmektedir. Öğrenme; istenilen çıktı verilerini elde edebilmek hedefi ile bağlantıların ağırlıklarının belirlenme kısmıdır (Adıyaman, 2007).

Sinir ağlarında bilgiler, ağdaki bağlantı ağırlıklarında depolanır. Öğrenme hali ağlarda sinirler arasındaki ağırlıkların değiştirilmesi ile gerçekleşir. Bunun sonucunda sinirler


arasında bulunan uzantılar üzerindeki ağırlıkları belirli bir sistem ile sürekli olarak değiştirebilen ağlar eğitilebilir bir hale getirilir. Öğrenebilen ağlar sisteme verilen bir girişin hangi sınıfa ait olduğuna karar verir veya yeni oluşmuş şekilleri tanıyabilir. Düzgünler arasındaki ağırlıkların, düğümlerdeki etkinlik ya da aktarım işlevlerinin değişkenlerinin ayarlanmasıyla yapay sinir ağlarında öğrenme gerçekleşmektedir (Elmas, 2003).

2.3.9. Yapay sinir ağlarının öğrenme algoritmaları

YSA uygulamalarının ilk etabı genel olarak öğrenmedir. Yapay sinir ağlarında öğrenme ağırlıklarının ayarlanma süreci olmaktadır. Bu algoritmalar üç kategori de düşünülebilir. Bunlar eğitici, eğitici ve pekiştirmeli öğrenme olarak isimlendirilir.

2.3.9.1. Eğitici (gözetimli) öğrenme


Bu algoritma için (Şekil 2.5.) ağırlıklar verilen bir girişe karşılık gelen gerçek ve istenilen çıkış değerleri arasındaki fark kullanılarak ayarlanmaktadır. Bu öğrenme metodunda istenilen değeri sağlayacak bir eğitici modeline ihtiyaç duyulmaktadır. Bu algoritmaya örnek olarak delta kuralı ve öğrenen vektör kuvantalama (LVQ) verilebilir. Hatanın geriye yayılma algoritması kolaylığı sebebi ile çok fazla kullanılan öğrenme algoritması niteliğindedir. Fakat yavaş öğrenme hızı gibi bazı dezavantajları olmaktadır (Linkens ve ark., 1996).



Şekil 2.5. Eğitici öğrenme yöntemi (Adıyaman, 2007).

2.3.9.2. Eđiticisiz (gözetimsiz) öğrenme


Bu algoritma da (Şekil 2.6.) çıkış değerlerinin bilinmesine gerek duyulmamaktadır. Eđitme sırasında sadece giriş değerleri uygulansa yeterlidir. YSA ağırlıkları benzer nitelikteki girişler aynı grupta sınıflanacak şekilde ayarlanmaktadır. Bu metoda örnek olarak Khonen, uyarlamalı rezonans teori ağıları verilebilir (Zalama ve ark., 1995).



Şekil 2.6. Eđiticisiz öğrenme yöntemi (Adıyaman, 2007).

2.3.9.3. Pekiştirmeli (destekleyici) öğrenme

Bu öğrenme algoritması (Şekil 2.7.) eđiticili öğrenmenin alternatif bir modelidir. Belirli çıkışları sağlamak üzere bir eđitici kullanmak yerine, verilen girişe karşı düşen sayıl bir performans ölçütünü sağlayacak şekilde belirlenir. En belirgin özelliđi çıkışların istenilen değerlerine gerek duyulmamasıdır (Anderson, 1989).



Şekil 2.7. Destekleyici öğrenme yöntemi (Masters, 1993).


2.3.10. Yapay sinir ağı modelleri

Yapay sinir ağı modelleri;

Tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli yapay sinir ağları, geri beslemeli yapay sinir ağları, radyal tabanlı yapay sinir ağları olarak incelenebilir.

2.3.10.1. Tek katmanlı algılayıcılar

Bu ağ yapısına sahip algılayıcılar sadece girdi ve çıktıdan oluşmaktadır (Şekil 2.8.). Bu ağlarda çıktı fonksiyonu doğrusal olmaktadır. Çıktılar 1 ise birinci sınıfa, -1 ise ikinci sınıfa tekabül etmektedir (Öztemel, 2006).




Şekil 2.8. Tek katmanlı algılayıcı (Öztemel, 2006).

2.3.10.2. Çok katmanlı algılayıcılar (geriye yayılım)

Çok katmanlı algılayıcılar (Şekil 2.9.); doğrusal olmayan yapıya sahip aktivasyon fonksiyonu bulunan birden fazla nöronun bağlandığı yapıya denir. Çok katmanlı algılayıcılar bazı metotların etkisiz kalması üzerine ortaya çıkmıştır (Öztürk ve ark. 2018).

Çok katmanlı algılayıcı modeli mühendislik problemlerinin birçoğuna çözüm üretebilecek bir sistemdedir. Öncelikli olarak sınıflandırma, tanıma ve genellemeyi yapmayı gerektiren problemlerin çözümünde uygulanmaktadır (Adıyaman, 2007).




Şekil 2.9. Çok katmanlı algılayıcı modeli (Adıyaman, 2007).

2.3.10.3. İleri beslemeli yapay sinir ağları

Bu ağlarda düzenli bir yapı mevcuttur. Nöronlar girişten çıkışa kadar olan süreçte sistematik bir haldedir. Tek bir katman yapısından sadece kendinden sonraki katman yapısında bağ yer alır. Bu sinir ağında girişe gelen bilgiler hiçbir değişikliğe uğramadan ara katmandaki hücrelere verilmektedir (Şekil 2.10.). Daha sonra


sistematik bir şekilde çıkış katmanına iletilir ve burada işlenmesi sağlanır. Son olarak dış ortama aktarma işlemi meydana getirilir (Öztürk ve ark., 2018).



Şekil 2.10. İleri beslemeli ağ yapısı (Öztürk ve ark., 2018).

2.3.10.4. Geri beslemeli yapay sinir ağları


Bu ağ yönteminde (Şekil 2.11.), ileri beslemeli ağlardan farklı olarak tek nöron çıktısı kendinden sonra gelmekte olan nöron katmanına girdi olarak verilmez. Kendi katmanında bulunan herhangi bir nörona ya da kendinden önceki katmana girdi olarak sabitlenebilmektedir. Bu özelliği ile bu ağlar doğrusal olmayan bir yapıya sahiptirler. Bağlantılar bağlantı şekillerine göre kullanılmış olan aynı yapay sinir ağıyla farklı özellikte ve yapıda geri beslemeli YSA elde edebilmektedir (Doğan, 2016).



Şekil 2.11. Geri beslemeli ağ yapısı (Doğan, 2016).

2.3.10.5. Radyal tabanlı yapay sinir ağları

Bu yapay sinir ağları yöntemi ileri beslemeli YSA yapısına benzemektedir. 3 katmandan oluşur. Fakat farklı olarak giriş katmandan ara katmana geçiş kısmı doğrusal olmayan sabit bir dönüşümdür. Ara katmandan çıkış katmanına geçiş ise doğrusal ve uyarlamalı bir şekilde gerçekleşmektedir (Şekil 2.12.) (Öcal, 2007).



Şekil 2.12. Radyal tabanlı fonksiyon ağı (Öcal, 2007).

2.3.11. Yapay sinir ağlarının avantajları

- Nitelikleri ve yapıları sayesinde yapay sinir ağlarının birçok önemli avantajları bulunmaktadır. Klasik metotlarla açıkça görülemeyen problemleri çözmek zor olmaktadır. Yapay sinir ağları ile bu sorunları çözmek mümkün olabilmektedir. Eksik bilgi ile çalışabilme, örneklerden öğrenebilme nitelikleri ile yapay sinir ağları örnekler yardımı ile kendi kendine öğrenmeyi gerçekleştirmektedir. Yapay sinir ağlarının avantajları aşağıdaki gibi sıralanabilir (Sarı, 2016):
- YSA'lar diğer klasik hesaplama metotlarına göre problemi çözme esnasında zamanı daha iyi kullanırlar.
- Bu ağlar örnekler yardımı ile öğrenirler ve kendilerini geliştirirler. Yapay sinir ağlarının bir problemi öğrenebilmesi için giriş verileri ile çıkış verilerinin karşılık sağlaması ya da sadece giriş verilerinin sağlanabilmesi gereklidir.

Yeterli miktarda örnek içermelidir. Yapay sinir ağlarına tanımlanmış olan öğrenme kümesi yapısına uygun düzenlenmiş olması gerekmektedir.

- Doğrusal olmayan bir yapıya sahip olmaları sebebi ile gerçek hayattaki problemleri çok daha iyi çözebilmeyi sağlarlar.
- YSA’lar değişken bir ortam içerisinde esneklik özelliğine sahip olurlar.
- Yapay sinir ağları sınıflandırma, ilişkilendirme, genelleme, şekil tanıma hususlarında çok sağlam bir yöntem olmaktadır. Eğitim süreci akabinde bu ağ eğitim hücresi dışındaki çıktılar için de çıkış verileri üretebilmektedir. Bu çıkışlar test verileri ile test edilirler. Bu çıkış değerlerinin hata değerleri kabul edilebilir seviye de yer alırsa, yapay sinir ağları genelleme yapabilme özelliğinde olmaktadır.
- Sistemde bazı farklılıklar olursa ya da yeni bilgiler ortaya çıkarsa bu durumda yapay sinir ağları tekrardan eğitilebilme özelliğine sahiptirler.
- Belirsiz bilgileri işleyebilir ve eksik bilgi ile çalışabilirler.
- Ağın farklı bir kümesinin bozulması ağın tamamını etkilememektedir. Bunun sebebi yapay sinir ağ sisteminin hata toleransına sahip olmasıdır. Ancak bozuk olan ağın hücre performansına göre, ağın performansında azalma gerçekleşebilmektedir.
- Paralel çalışabilme yapıları sayesinde yapay sinir ağları gerçek zamanlı olarak kullanımları daha basit olmaktadır.

2.4. Yapay Sinir Ağlarında Su Kalitesinin Ağır Metaller Bakımından İzlenmesi

Endüstri ve sanayi atıklarında meydana gelen kirliliğin artışındaki en büyük sebepler hızlı nüfus artışı ve yaşam standartlarının gelişmesidir. Bu yüzden bu kirliliklerin göl, nehir gibi alıcı ortamlara ulaşması su kalitesinde bozulmalar ve içilebilir kullanılabilir sularda azalmaları meydana getirmektedir (Akın ve Akın, 2007).

Ağır metal kirlilikleri endüstriyel ve tarımsal faaliyetlerinin çok olmasından kaynaklı meydana gelmektedir (Kahvecioğlu ve ark., 2009). Ağır metal kirliliklerinin gideriminde bir takım yöntemlerin kullanıldığı bilinmektedir. Bunlara birkaç örnek verilmek istenirse de koagülasyon, kimyasal çöktürme, flokülasyon, membran işlemleri gibi yöntemlerdir (Kaewsarn, 2002). Fakat ağır metaller kullanılan bu yöntemlerle çok iyi giderilemeyebilir. Bu teknikler pahalı yöntemlerdir. Çok fazla ekipman, takip cihazı gerektirmektedir. Diğer dezavantajları da belirtilecek olursa enerji ihtiyacı fazla olup, farklı atık ürünler oluşturabilmektedir (Hussein ve ark., 2004).

Ağır metal konsantrasyonları ve diğer çevresel endeksler sürekli olarak kapsamlı bir şekilde izlenmelidir. Su ortamlarında ağır metallerin davranışını ve ilişkili risklerini anlamak; bununla birlikte, düzenli ve entegre izlemenin zaman alıcı olduğu tekrarlanmalıdır. Maliyetli ve entegre izleme sistemleri genellikle hem ağır metalleri hem de diğer ilgili çevresel faktörleri hesaba katacak endekslerden yoksundur (Lu ve ark., 2019). Ancak su kaynaklarında kirlilik düzeylerinin doğrudan ölçüm yöntemleri kullanılarak izlenmesi çok fazla iş gücü, ekipman ve zaman gerektirmektedir. Su kaynaklarının iyi yönetimi için su kirliliği iyi tanımlanmalı, izlenmeli ve modellenmelidir. Modelleme, su kalitesi izleme maliyetini azaltmak için alternatif bir çözümdür. Genel olarak, modeller tarafından üretilen tahminler, kirlletici konsantrasyonlarının sınırlı örnekleme bilgisine dayanmaktadır (Nhantumbo ve ark., 2018).

Bu modellerden biri, yapay sinir ağlarıdır (YSA). Bu metot önceden bilinen verileri kullanıp olayların tahmin edilmesini sağlamaktadır (Eyupoglu ve ark., 2010). Klasik metotlara oranla çok iyi sonuçlar verdiği görülmüştür. YSA doğrusal olmayan bir yapıya sahip olup bu zaman serilerinde de başarı göstermiştir. Bunun sonucunda da iyi bir tahmin aracı unsuru olmasını sağlamıştır (Hamzaçeişeribi ve Kutay, 2004). Bu yöntemin çevre mühendisliği bünyesinde yer alan konuları için de birden fazla alanda çalışmalar yapılmasını sağladığı görülmektedir (Eyupoglu ve ark., 2010).

2.5. Türkiye’de ve Dünya’da Su Kaynaklarında Su Kalitesinin Yapay Sinir Ağları ile Tahmin Çalışmaları

Yapılan bir çalışmada, KOİ konsantrasyonlarının ileri biyolojik atıksu arıtma tesislerinde tahmini için YSA modelini kullanmış olup yaptıkları bu çalışma ile, yapay sinir ağının gelecek vaadeden bir model olduğunu ortaya çıkarmışlardır (Türkmenler ve ark., 2014).

Başka bir çalışmada, çözülmüş oksijen değişimi için yaptıkları çalışmayı Kızılırmak Nehri’nin verilerini baz alarak yürütmüşlerdir. Yapay sinir ağları kullanarak tahmin yürütme çalışması yapmışlardır (Özkan ve ark., 2006).

Bu çalışma da, yapay sinir ağları kullanarak su kalitesi parametreleri için az sayılarda veriler kullanıp çözülmüş oksijen değerinin tahminini gerçekleştirmişlerdir. Model performans kriterleri olarak R^2 değerleri kullanılmış olup kullanılan giriş verileri NO_2-N , NO_3-N , BOİ, debi ve sıcaklıktır. İleri beslemeli yapay sinir ağları ile en iyi tahmin gerçekleştiği görülmüştür. Bu çalışma sayesinde yapay sinir ağlarının nehir kirliliklerini tahmin etmesinde önceden bu sorunu çözme de faydalı olunacağı görülmüştür (Sengorur ve ark., 2005).

Doğan ve ark., (2016), yaptıkları çalışma için, Van Gölü günlük su seviyelerini kullanmışlardır. Burada tahmin yürütme işlemi için radyal tabanlı sinir ağları ve ileri geri besleme sinir ağları kullanılmıştır. Küresel ısınma sebebiyle Van Gölü’ndeki su seviyesinin sürekli olarak belirli zaman aralıkları ile değişim gösterdiğini görmüşlerdir. Günlük su seviyeleri ve buna bağlı gözlenen değerlerin yapay sinir ağlarına göre uygun olduğunu fark etmişlerdir. Çıktı sonuçları, korelasyon katsayısı ve ortalama karesel hata değerleri kullanılarak karşılaştırılma yapılmıştır.

Yapılan başka bir çalışma da, Orta Karadeniz Kıyı şeridi deniz ve ırmak sedimanlarında ağır metal verileri baz alınmıştır. 3 adet tahmin ağını kullanmışlardır. Bu ağlar çoklu değişkenli polinomal regresyon, çok katmanlı algılayıcı ağ modeli, çoklu değişkenli lineer regresyondur. Çalışmada ki modellerin çalışabilmesi için belirli yıllar arasına 5 çeşit noktadan alınan sediman örneklerine ait değerlere bakılmıştır. Her bir veriye ait ağır metal konsantrasyonun tahmin edilmesi için

çalışmada kullanılmış olan üç modelin performans karşılaştırmaları gerçekleştirilmiştir. Bakılan bu parametrelerde regresyon analizleri yapılmıştır. Parametreler bağımsız değişken olarak kabul edilmiştir ve uygulanan modeller arasında en verimli sonucun çoklu değişkenli model ile doğru tahmin edildiği görülmüştür (İşeri ve Arıman, 2019).

Erdem, (2021) yılında yaptığı çalışmada, Ankara’da yer alan 2 atıksu arıtma tesisi içinde bulunan çinko giderim tahminini YSA ile belirlemişlerdir. Bu çalışma da atıksularda çok fazla bulunan çinkonun arıtım sonrası belirlenen değere getirilmesi için bir çalışma yapılmıştır. YSA ile modelleme çalışmasında giriş değerleri için 5 adet parametreye bakılmış olup çıkış değeri olarak 1 parametre belirlenmiştir. Levenberg–Marquardt ileri besleme algoritması kullanılıp veri için eğitim yapılmıştır. Deneysel çıktılar eğitim, validasyon ve test olarak sonuçlanmıştır. Çalışmada giriş parametreleri için farklı değerler alınarak sistemde o şekilde denenmiş ve sisteme ait değer sonuçları belirlenerek elde edilen sonuçlar kıyaslanmıştır. Çalışma sonucunda deneysel ve model tahmini çıkış akımındaki Zn konsantrasyon değerleri kıyaslanıldığında, YSA ile sistemin gayet iyi bir çözüm üretebileceği sonucuna varılmıştır.

Lefkoşa kentinde oluşan su krizini çözebilmek için yapay sinir ağları kullanılmıştır. Su talebi tahmin çalışması yürütülmüştür. Üç adet öğrenme algoritması kullanılmıştır (Gradient-descent, Levenberg-Marquardt, Radyal tabanlı). Bu üç metot için kıyaslanmalar yapılmıştır. Levenberg-Marquardt modelinin diğer metotlara göre en doğru tahmin çalışması yaptığını görmüşlerdir (Adamowski ve Karapataki, 2012).

Hindistan’da nehirde yapılan bir çalışmada, sekiz gözlem noktasını inceleyerek su kalitesi verilerinin 10 yıl boyunca aylık takibini yapmışlardır. Biyolojik oksijen ihtiyacı ve çözünmüş oksijen su kalitesi parametrelerini yapay sinir ağları ile modellemek istediklerinden bu çalışmayı gerçekleştirmişlerdir. Modellemede 11 çeşit su kalitesi parametresini incelemişlerdir. (R^2) değeri performans kriteri olarak kullanılmıştır. Katsayısı değerleri, ÇO ve biyolojik oksijen ihtiyacı için uygun sonuçlarda bulmuşlardır. Bu çalışma sayesinde yapay sinir ağlarının nehir su kalitesi modellemeleri için klasik metodlarına karşı önemli bir çözüm olduğu sonucuna varmışlardır (Singh ve ark., 2009).

Maier ve ark., (1996) bu çalışma da, su kalitesi parametrelerini tahmin etmenin uygun bir yolu olarak yapay sinir ağlarının (YSA) kullanımını sunmaktadır. Murray Nehri'ndeki tuzluluğu günler öncesinden tahmin etmek için YSA yöntemlerinin kullanıldığı bir vaka çalışması sunulmuştur. Murray'deki yüksek tuzluluk seviyelerinin Adelaide'deki su kullanıcılarına yılda 22 milyon ABD doları zarar verdiği tahmin edildiği görülmüştür. Önceki çalışmalar, Murray'den pompalamanın optimal bir şekilde planlanması durumunda, Adelaide'ye sağlanan suyun ortalama tuzluluğunun yaklaşık %10 azaltılabileceğini göstermiştir. Bu sonucun, birkaç hafta önceden tuzluluk tahminlerini gösterebileceği kanısına varılmıştır. Elde edilen sonuçların tahminlilik oranlarının umut verici olduğu görülmüştür.

Swietlicka ve ark., (2017) yılında, Polonya'nın Lublin Eyaletinde, göl ve nehir çökeltilerinde ki Ba, Ag, As, Ca, Cd, Co, Cr, Cu, Fe, Hg, Mg, Mn, Ni, P, Pb, S, Sr, TOC (toplam organik karbon), V ve Zn içerikleri değerlendirilmiştir. Yapay sinir ağları daha sonra verileri tanıma ve sınıflandırma yetenekleri açısından incelenmiştir. İstatistiksel model olarak çok katmanlı algılayıcı kullanılmıştır. Oluşturulan modeller, rezervuar kullanım alanı sınıflandırmasında vakaların %74'ünde, su kütlesi tipinde ise %100 doğru cevap verebilmiştir.

Lu ve ark., (2019) tarafından, Çin'in Taihu Bölgesi'ndeki bir içme suyu kaynağı üzerinde, yeraltı suyunun fizikokimyasal parametreleri ve ağır metal konsantrasyonları ölçülmüştür. Çalışma kapsamında gerçekleştirilen modellemede destek vektör makinesi (DVM) ve yapay sinir ağları (YSA) modelleri kullanılmıştır. Duyarlılık analizi, simüle edilmiş ağır metal konsantrasyonlarının pH'a en duyarlı olduğunu göstermiştir. Hem YSA hem de DVM hızlı simülasyon modelleri, Nash-Sutcliffe verimlilik katsayıları $>0,8$ en fazla olan partikül ağır metal konsantrasyonlarını iyi bir şekilde simüle etmiştir.

Bu çalışmada, Kuzey Tayvan-Feitsui Rezervuarındaki ÇO konsantrasyonunu tahmin etmek için geri yayılım sinir ağı ve uyarlanabilir sinir tabanlı bulanık çıkarım sistemi yaklaşımları ve çoklu doğrusal regresyon yani MLR modelini içeren iki yapay sinir ağı (YSA) modeli geliştirilmiştir. Sinir ağının girdi değişkenleri su sıcaklığı, pH, iletkenlik, bulanıklık, askıda katı maddeler, toplam sertlik, toplam alkalilik ve amonyum azotu olarak belirlenmiştir. Model performansı, ortalama mutlak hata,

ortalama karekök hata, ve ölçülen ve modelle simüle edilen ÇO değerlerinden hesaplanan korelasyon katsayısı ile değerlendirilmiştir. Performans kriterleri açısından geri yayılım sinir ağı ve bulanık çıkarım sistemi modelleri karşılaştırıldığında, bulanık çıkarım modeli, ÇO değerlerini tahmin etmede geri yayılım modelinden daha iyidir. Çalışma sonuçları, özellikle bulanık çıkarım sistemi modelini kullanan sinir ağının, ÇO konsantrasyonlarını uygun bir doğrulukla tahmin edebildiğini ve sinir ağının Tayvan'da rezervuar yönetimi için değerli bir araç olduğunu öne sürdüğünü göstermektedir (Chen ve Liu, 2014).

Bu çalışma, Sosiani Nehri'ndeki kurşun, bakır ve kadmiyumun kirlilik yükünü yapay sinir ağı kullanarak, fiziko-kimyasal parametrelere dayalı olarak tahmin etmeyi amaçlamıştır. Altı numune bölgesinden alınan numunelerde, bulanıklık, elektriksel iletkenlik ve kimyasal oksijen ihtiyacı, florür ve fosfat parametrelerinden oluşan 78 veri seti bakılmıştır. Veri setleri %60 eğitim, %20 test ve %20 bekletme olmak üzere değerlendirilmiştir. Model olarak, IBM SPSS istatistik 20 yazılımını kullanılmış ve performanslar korelasyon katsayısı kullanılarak değerlendirilmiştir. YSA ile fiziksel ve kimyasal parametreler ile Pb, Cu ve Cd için gözlenen korelasyon katsayıları ile nehirdeki Pb, Cu ve Cd kirlilik yükünün tahmin edebildiği görülmüştür (Obiewa ve ark., 2020).

Yüzey suyunun ağır metal kontaminasyonu, en ciddi çevresel tehlikelerden biri olarak kabul edilir. Bu çalışmanın amacı, Gebeng sanayi bölgesi nehirlerinde yüzey sularında bulunan ağır metalin kökenini belirlemektir. Örnekler bir yıl boyunca Tunggak ve Balok nehirleri boyunca on istasyonda toplanmıştır. Malezya ağır metaller standardına göre, Gebeng nehirlerinin yüzey suyu altı ağır metal ile kirlenmiştir: Cd, Co, Cu, Pb, Mn ve Ni. Kaynakları tanımlamak için çok değişkenli bir istatistiksel araç olan SPSS sürüm 22.0 kullanılmıştır. Ağır metaller, kirliliğin antropojenik nedenlerden kaynaklandığını gösteren ana bileşen analizi kullanılarak üç bileşene ayrılırken istasyonlar da, küme analizi kullanılarak üç gruba ayrılmıştır. Genel olarak, bu araştırmanın bulguları, Gebeng nehirlerindeki ağır metal kontaminasyonunu azaltmayı amaçlayan gelecekteki çalışmalarda yararlı olacağı gözlenmiştir (Islam ve ark., 2022).

Sapanca Gölü için yapılan bu çalışmada ise, çözünmüş oksijen (ÇO) konsantrasyonunu tahmin etmek için pH, magnezyum (Mg), sıcaklık, kimyasal oksijen

ihtiyacı (KOİ), ortofosfat (o-PO₄), nitrit azotu (NO₂-N) ve nitrat azotu (NO₃-N) bağımsız parametreler insan beyninin işleyişinin matematiksel bir temsili olan YSA için kullanılmıştır. Başarılı YSA modeli, geleneksel çoklu doğrusal regresyon (MLR) analizine kıyasla daha iyi sonuçlar verdiği görülmüştür. Geliştirilen model IBM SPSS 21.0, gelecekte eksik verileri tamamlamak ve sürdürülebilir çevre yönetimi yoluyla kirliliğin azaltılmasına yönelik karar sürecini desteklemek için tahmin amacıyla kullanılmıştır. Bu çalışma ile Sapanca Gölü'nün ötrofikasyon tehdidi sonucunda YSA ve ötrofikasyon modellerinin çıktıları ile hızlı kentleşme sorununa dikkat çekecek bilimsel altyapıyı oluşturmak amaçlanmıştır (Akıner ve Akıner, 2021).

Bir çalışma da SPPS programının iyi bir tahmin modeli olduğunu kanıtlar niteliğinde bir çalışma yapılmıştır. Bu çalışma da rezervuarlarda sıkça kullanılan bir su kalitesi metriği olan Carlson'un Trofik Durum Endeksi'ni tahmin etmek için bir makine öğrenme yaklaşımı oluşturmaktadır. 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 su yönetimi çalışmalarının planlanmasında desteklemek için kabul edilir düzeyde olduğu görülmüştür. Buna göre, bu çalışma su kalitesi değerlendirmesinde potansiyel kullanım için yeni bir yaklaşım sunmaktadır. 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 varılabilir (Chou ve ark., 2018).

BÖLÜM 3. MATERYAL VE YÖNTEM

3.1. Materyal

Çalışmada İznik Gölü'ne ait su kalite parametre verileri Bursa Büyükşehir Belediyesi Bursa Su ve Kanalizasyon İdaresi (BUSKİ) Genel Müdürlüğü'nden alınmış olup verilerin bir yapay sinir ağı olan IBM SPSS V.23 programında Neural Network modülü kullanılarak analiz sonuçlarının değerlendirilmesi hedeflenmiştir.

pH, iletkenlik, biyolojik oksijen ihtiyacı (BOİ), kimyasal oksijen ihtiyacı (KOİ), sıcaklık, çözünmüş oksijen (ÇO), renk(RES436nm), renk(RES620nm), renk (RES525nm), kalay (Sn), arsenik (As), antimon (Sb), alüminyum (Al), bor (B), krom (Cr), kadminyum (Cd), gümüş (Ag), bakır (Cu), nikel (Ni), kurşun (Pb), demir (Fe), selenyum (Se), çinko (Zn), mangan (Mn) parametrelerinin ölçümleri BUSKİ'den alınarak bu parametrelerden çeşitli model denemeleri yapılarak ağır metal kirliliği tahmin sonuçları elde edilmiştir.

3.2. Yöntem

3.2.1. Çalışılan parametrelerin tanımı

3.2.1.1. pH

pH, su kalitesinin en önemli parametrelerinden biridir (Spellman, 2017). Aşırı yüksek ve düşük pH'lar su kullanımı için zararlı olabilir. Yüksek bir pH, tadı acı hale getirir ve klor dezenfeksiyonunun etkinliğini azaltır, böylece ek klor ihtiyacına neden olur (DeZuane, 1997).

Sudaki oksijen miktarı pH yükseldikçe artar. Düşük pH'lı su, metalleri ve diğer maddeleri paslandırır veya çözer. Kirlilik, suyun pH'ını değiştirebilir, bu da suda yaşayan hayvanlara ve bitkilere zarar verebilir (Apha, 2005).

Kadmiyum, kurşun ve krom gibi ağır metaller yüksek asitli suda (düşük pH) daha kolay çözünür. Bu önemlidir, çünkü birçok ağır metal suda çözündüğünde çok daha toksik hale gelir (DeZuane, 1997).

3.2.1.2. İletkenlik

Suyun elektriksel iletkenliği, bir çözeltinin elektrik akımını taşıma veya iletme kabiliyetinin bir ölçüsüdür (Metcalf ve ark., 2003). Elektrik akımı çözelti içindeki iyonlar tarafından taşındığından, konsantrasyon iyonları artar. İletkenlik; sıcaklık, pH, alkalinite, toplam sertlik, kalsiyum, toplam katılar, toplam çözünmüş katılar ve kimyasal oksijen ihtiyacı, klorür ve suyun demir konsantrasyonu gibi parametrelerle önemli korelasyon gösterir (Gupta ve Paul 2010).

3.2.1.3. Sıcaklık

Su sıcaklığı, suda yaşayan organizmaların büyümesinin yanı sıra kimyasal ve biyolojik aktiviteyi de etkiler (Pawar 2010). Viskozite, çözünürlük, kokular ve kimyasal reaksiyonlar sıcaklıktan etkilenir (Apha, 2005). Böylece sedimantasyon, klorlama prosesleri ve biyolojik oksijen ihtiyacı sıcaklığa bağlıdır (Davis, 2010). Ayrıca suda çözünmüş ağır metallerin biyosorpsiyon sürecini de etkiler (Salman ve ark., 2014).

3.2.1.4. Renk

Organik maddeden çürüyen maddeler, toprak, taş, kaya gibi inorganik maddeler suya renk verir, bu da estetik nedenlerle sakıncalı olabilmektedir (Apha, 2005).

3.2.1.5. Çözünmüş oksijen

Çözünmüş oksijen (ÇO), akarsularda, nehirlerde ve göllerde su kalitesinin en önemli parametrelerinden biri olarak kabul edilir. Su kirliliğinin önemli bir ölçütüdür. Çözünmüş oksijen konsantrasyonu ne kadar yüksek olursa, su kalitesi o kadar iyi olur (Apha, 2005). Oksijen suda az çözünür ve sıcaklığa çok duyarlıdır (Metcalf ve ark., 2003). Gerçek çözünmüş oksijen miktarı suyun basıncına, sıcaklığına ve tuzluluğuna bağlı olarak değişir (Apha, 2005).

3.2.1.6. Biyolojik oksijen ihtiyacı

Biyolojik oksijen ihtiyacı (BOİ), sularda ve atıklarda indirgenmiş maddelerin oksidasyonu sırasında mikroorganizmalar tarafından tüketilen çözünmüş oksijenin bir ölçüsüdür. BOİ, nehirlerdeki ve akarsulardaki çözünmüş oksijen miktarını doğrudan etkiler. BOİ ne kadar büyük olursa, akışta oksijen o kadar hızlı tükenir. Bu, daha yüksek sucul yaşam biçimleri için daha az oksijenin mevcut olduğu anlamına gelir. BOİ kaynakları arasında yapraklar ve odunsu döküntüler, ölü bitki ve hayvanlar, hayvan gübresi, kağıt hamuru ve kağıt fabrika atıkları, atık su arıtma tesislerinden, besi alanlarından ve gıda işleme tesislerinden çıkan atıklar, başarısız septik sistemler, ve kentsel yağmur suyu akışı yer almaktadır. Yüksek BOİ seviyelerine sahip atıkların deşarjı, alıcı su kütlelerinde ciddi çözünmüş oksijen tükenmesi ve balık ölümleri gibi su kalitesi sorunlarına neden olabilir (Penn, 2003).

3.2.1.7. Kimyasal oksijen ihtiyacı

Kimyasal oksijen ihtiyacı (KOİ), çevresel izleme ve çevresel etki değerlendirmelerinde organik su kirleticilerinin nispi içeriğini belirlemek için yaygın olarak kullanılmaktadır. Endüstriyel atık sudaki besinler ve insan faaliyetleriyle deşarj edilen evsel atık sular, su ötrofikasyonuna, alg patlaması felaketlerine, ekolojik fonksiyon kaybına ve diğer sorunlara neden olabilir (Zhao ve ark., 2012). KOİ, su kirliliği derecesi için en iyi göstergelerden biri olarak kabul edilir (Jia ve ark., 2017). Endüstriyel atık su, karmaşık kimyasal bileşenlere sahip olduğundan ve arıtılması, ayrıştırılması ve arıtılması zor olduğundan, evsel atık sulardan daha zararlıdır. Yüksek KOİ'li su genellikle yüksek organik maddeden oluşur; bu nedenle, yüksek KOİ değeri

kirli su anlamına gelir. Bu nedenle, endüstriyel atık sudaki KOİ deşarjının kontrolü, su çevre kirliliğinin önlenmesi ve kontrolünde önemli bir bileşendir (Zhao ve ark., 2012).

3.2.1.8. Ağır metaller

Çok çeşitli inorganik toksik maddeler suda çok küçük veya eser miktarlarda bulunabilir. Eser miktarda dahi olsa halk sağlığı için tehlike oluşturabilirler (Davis, 2010). Bazı toksik maddeler doğal kaynaklardan oluşur, ancak diğerleri endüstriyel faaliyetler ve tehlikeli atıkların uygunsuz yönetimi nedeniyle oluşur (Metcalf ve ark., 2003).

Kadmiyum, krom, kurşun, cıva, gümüş, arsenik, baryum, talyum ve selenyum gibi toksik olan bazı ağır metalleri içerir (Järup, 2003).

Kurşun, arsenik, cıva, krom, nikel, baryum, kadmiyum, kobalt, selenyum, vanadyum gibi kirleticilerin bazıları ppb (milyarda bir parça) aralığında bile çok zararlı, toksik ve zehirlidir. İnsan ve hayvan sağlığı için yararlı olan bazı mineraller, bunların ötesinde toksik olan küçük dozlarda bulunur. Çinko , bakır , demir vb. bu kategoriye girer. Tarım için çinko, bakır, mangan , demir, bor gibi bazı elementler öngörülen miktarlarda faydalıdır (Bhateria ve Jain, 2016).

3.2.2. Ağır metal verilerinin değerlendirilmesi

Su kaynaklarında ağır metal konsantrasyonlarının belirlenmesine yönelik çalışmalar, fizikokimyasal ve çevresel faktörlerin ağır metal konsantrasyonlarını etkileyebileceğini ortaya koymuştur. İznik Gölü'ndeki 2015-2021 yıllarında 5 gözlem noktasından farklı tarihlerde ve farklı adetlerde alınan ölçümlerin her bir yıl için ortalamaları alınıp tahmin modellemesi yapılmıştır. 4 parametre için (Sn,Sb,Se,Ag) bazı yıllarda ölçüm yapılmadığından dolayı programda Se parametresi için 2017-2021 yılları arası, Sn,Sb,Ag parametrelerinin 2018-2021 yılları arasında olan ortalamaları baz alınarak sistem de tahmin çalışmaları yapılmıştır. Dört giriş noktası Sölöz, Olukdere, Karasu, Kırandere ve bir çıkış noktası Karsak Deresi olarak belirlenmiştir. Gözlem noktalarından alınan pH, iletkenlik, BOİ, KOİ, sıcaklık, çözünmüş oksijen, renk(RES436nm), renk(RES620nm) ve renk (RES525nm) parametreleri girdi verileri

olarak Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag parametreleri ise tahmin amaçlı çıktı verileri olarak kullanılmıştır. Literatürde de, ağır metal konsantrasyonlarının tahmini için pH, EC, KOİ, vb. parametreler girdi verisi olarak kullanılmaktadır (Rooki ve ark. 2011; Bayatzadeh Fard ve ark. 2017; Nhantumbo ve ark. 2018; Lu ve ark. al. 2019; Agah ve Soleimanpourmoghadam 2020).

3.2.2.1. YSA modellemesi ve uygulaması

4 gözlem noktası (Karasu, Olukdere, Kırandere ve Sölöz) için tahmin çalışmaları ayrı ayrı yapay sinir ağı programında değerlendirilmiş olup çıktı verisi olarak Karsak Deresi ağır metal parametreleri baz alınmıştır. Program da çeşitli denemeler yapılarak en iyi belirleme katsayısını (R^2) veren modele ulaşmak amaçlanmıştır. Geri yayılım eğitim algoritması kullanan çok katmanlı algılayıcı, IBM SPSS istatistik 23 yazılımı ile benimsenmiştir.

Çok katmanlı yapay sinir ağı kullanılmış olup, gizli katmanlardaki nöronların sayısı 1 ile 7 arasında değişiklik göstermiştir. Gizli katman için, aktivasyon fonksiyonu tanjant hiperbolik tanjant, sigmoid fonksiyonu kullanılmıştır. Döngü sayısı 1000, minimum nispi değişiklik 0.0001 ve hata oranında minimum değişiklik 0.001'dir.

Önyargı(bias), nörona işlevi sola veya sağa kaydırma imkanı veren ve nöronu daha güçlü kılan skaler bir parametredir (Obiewa ve ark., 2020).

Program da test etmek için hata kareleri toplamı (SSE), belirleme katsayısı (R^2) parametreleri kullanılmıştır. Burada, gözlenen ve tahmin edilen modeller arasındaki doğrusal ilişkiyi belirlemek için R^2 kullanılırken, model hatalarını ölçmek için SSE kullanılmıştır.

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) ile verilmiştir.

$$SSE = \sum_{i=1}^n (Sobs - Scal)^2 \quad (3.1)$$

N, tahmin edilen toplam veri kümesi sayısı, Sobs giriş konsantrasyonunun gözlemlenen değeri ve Scal çıkış konsantrasyonu hesaplanan (YSA değeri) değeridir (Obiewa ve ark., 2020).

R^2 değeri 1'e ne kadar yakınsa, bir tahmin modelinin tahmin becerisi o kadar iyi olmaktadır (Denklem 3.2) (Arefinia ve ark., 2020).

$$r = \frac{\sum (Sobs - \bar{Sobs})x(Scal - \bar{Scal})}{\sqrt{(\sum (Sobs - \bar{Sobs})^2 x (\sum (Scal - \bar{Scal})^2)}} \quad (3.2)$$

$\bar{Scal}$, hesaplanan ortalama konsantrasyondur. Simüle edilen ve gözlemlenen veriler arasındaki korelasyonun gücünü karakterize eder. Birliğe yaklaşan r değerleri iyi bir modeli göstermektedir (Obiewa ve ark., 2020).

3.2.3. İznik Gölü giriş çıkış noktalarından alınan numune yerleri

İznik Gölü'nün yağış havzası çok küçük olduğu için gölü besleyen su kaynakları da sayıca çok az sayıdadır. Güneyde Sölöz (Kocadere), kuzeybatıda Olukdere, kuzeydoğuda Karadere (Karasu) ve doğu tarafında bulunan İznik ilçesinin güney kısmında yer alan Kırandere en önemli dereleridir. Ve çalışmada giriş kaynağı olarak kabul edilmiştir. Karsak Deresi gölün tek göl ayağı olup çıkış kaynağı olarak verileri değerlendirilmiştir. Bu akarsulardan numuneler BUSKİ tarafından 2015-2021 yılları arasında alınmıştır. Bahsedilen derelerin konumları (Şekil 3.1.)'de gösterilmiştir.



Şekil 3.1. İznik Gölü uydu görüntüsü

Karasu Deresi İznik Gölü'nün en önemli deresi rolündedir. Hemen hemen 230.3 km²'lik bir alanın sularını biriktirmektedir. Karasu Deresi havzadaki diğer derelere göre taşıdığı su miktarının fazla olma sebebi doğu tarafı yönüne sokulan kolları, yağış miktarı fazla olan dağlık alanın sularını drene ettiğinden dolayı kaynaklanmaktadır. Bu özelliği sebebi ile, debisinde bir düşüş ortaya çıkmaktadır. Fakat yaz aylarında bir kuruma meydana gelmemektedir (Akbulak, 2006).

Sölöz Deresi (Kocadere) İznik Gölü'nün ikinci büyük dere niteliğindedir. Bununla birlikte güney tarafına en fazla yanaşan deresi özelliğindedir (Akbulak, 2006).

Olukdere, İznik Gölü'ne kuzeybatıdan dökülür. Önemli derelerinden bir diğeridir. Olukdere, Orhangazi kuzeybatısındaki bol debili kaynakların suyunu bünyesinde bulundurup, çoğunlukla mevsimlik dere özelliğindeki kollara sahip olmasına rağmen, aşağı çığırında daimi akış gösteren bir dere özelliğindedir (Akbulak, 2006).

Avdan Dağı'nın kuzey aklanından (derelerini aynı göle gönderen bölge) doğan Karanlık Dere, ovada doğudan gelen Ana Dere ile birleşerek Kırandere adını alır ve batıya yönelim göstermektedir (Yazıcı, 2020).

Karsak Deresi, İznik Gölü'nün deşarjını sağlamaktadır. İznik gölü ile Gemlik Körfezi arasında bulunur. Gemlik ilçesinde en çok su taşıyan dere özelliğindedir. Karsak Deresi, göl ve havzasındaki kirliliklere sebebiyet vererek içeriğindeki çok fazla kirlletici kaynağı Gemlik Körfezi'ne götürmektedir (Teksoy, 2019). Bu çalışmada çıkış kaynağı olarak değerlendirilmiştir.

3.2.4. Gözlem noktaları su kalite verileri

Gözlem noktalarına ait 2015-2021 yılları arasında belirli aylarda ölçümü yapılan parametre veri sonuçlarının yıllık ortalamaları için Tablo 3.1., Tablo 3.2., Tablo 3.3., Tablo 3.4. ve Tablo 3.5. oluşturulmuştur.

3.2.4.1. İznik Gölü giriş noktaları ölçümleri

Bu kısım da 2015-2021 yılları Karasu, Olukdere, Kırandere ve Sölöz Deresi'nin su kalite ölçüm sonuçları ortalamaları verilmiştir

Tablo 3.1. 2015-2021 yılları Karasu ölçüm sonuçları ortalamaları

Yıllar	pH	İletkenlik	BOİ	Sıcaklık	ÇO	KOİ	Renk(RES)		
							436nm	620nm	525nm
	–	mS/cm	mg/L	°C	mg/L	mg/L	m ⁻¹	m ⁻¹	m ⁻¹
2015	8,13	302,55	1,65	20,15	10,50	15,00	0,10	0,00	0,00
2016	8,59	583,00	2,86	14,63	11,40	17,50	0,93	0,23	0,33
2017	8,48	379,00	2,00	13,10	10,63	16,40	1,48	0,63	0,95
2018	8,01	437,00	2,00	18,40	9,69	13,25	0,30	0,13	0,15
2019	8,28	1021,50	2,25	13,60	11,14	15,75	0,35	0,13	0,18
2020	8,38	559,00	2,00	15,96	10,53	18,33	0,33	0,10	0,13
2021	8,54	341	2	12,9	10,9	16	0,45	0,10	0,15

Karasu Deresi Tablo 3.1.'de görülen parametreler yıl bazında incelenirse en düşük pH ölçümün 8,01 ile 2018 yılında, en yüksek ölçümün ise 8,59 ile 2016 yılında olduğu görülmektedir. İletkenlik parametresinin 2019 yılında 1021,50 mS/cm ile diğer yıllara oranla bir artış gösterdiği görülmektedir. BOİ parametresi 2,86 mg/l ile 2016 yılında en yüksek değere sahiptir. Sıcaklık parametresi 2015 yılında 20,15 °C ile en yüksek , 2021 yılında 12,9 °C ile en düşük değere sahiptir. ÇO parametresi için en düşük ortalama 9,69 mg/l ile 2018 yılındadır. KOİ parametresi için yıllara bakıldığında artış azalış göstermekte olup en yüksek ortalaması 2020 yılında 18,33 mg/l ile olmuştur. Renk parametresi için bakılacak olursa da RES436nm parametresi 2015 yılında 0,10

m^{-1} iken 2017 yılında $1,48 \text{ m}^{-1}$ pik noktaya ulaşmıştır. RES620nm parametresi 2017 yılında $0,63 \text{ m}^{-1}$ 'dir ve diğer yıllar incelendiği genel olarak ortalama ölçümler birbirine yakın konsantrasyonlara sahiptir. RES525nm parametresi de 2017 yılında $0,95 \text{ m}^{-1}$ olarak görülmekte olup diğer yıllara bakıldığında ortalama ölçümler birbirine yakındır.

Tablo 3.2. 2015-2021 yılları Olukdere ölçüm sonuçları ortalamaları

Yıllar	pH	İletkenlik	BOİ	Sıcaklık	ÇO	KOİ	Renk(RES)		
							436nm m^{-1}	620nm m^{-1}	525nm m^{-1}
2015	8,05	485	2,76	17,16	9,00	10,00	0,40	0,27	0,30
2016	8,15	449	2,30	15,65	9,50	16,00	0,23	0,08	0,10
2017	8,18	478	5,50	15,40	8,65	16,00	0,85	0,40	0,60
2018	8,04	394,50	2,00	15,30	8,24	16,00	0,20	0,10	0,10
2019	7,86	484	3,00	16,20	8,43	12,33	0,23	0,10	0,17
2020	8,44	467	2,00	13,10	9,90	11,00	0,10	0,10	0,10
2021	8,12	524	4,5	16,1	8,35	18	0,35	0,10	0,15

Olukdere için Tablo 3.2.'deki parametreler yıl bazında incelenirse en düşük pH ölçümün 2019 yılında 7,86 olduğu görülmektedir. En yüksek pH değeri 2020 yılında 8,44'tür. İletkenlik parametresi 2018 yılında 394,5 mS/cm ile en düşük ortalama değerine sahiptir. BOİ parametresi 2017 yılı ortalaması 5,5 mg/l 'dir ve diğer yıllara oranla bakıldığında en pik değere ulaşmıştır. 2021 yılında da artış göstermiş olup 4,5 mg/l'dir. Sıcaklık parametresi ortalama ölçümleri genel olarak birbirine yakın değerler olduğu görülmektedir. ÇO parametresi de 8,24 mg/l ile 9,90 mg/l değerleri arasında olup yıl bazlarında ortalamaları yakın değerlere sahip olduğu görülmektedir. KOİ parametresi 2021 yılında 18 mg/l ile en yüksek ortalama değerine, 2015 yılında 10 mg/l ile en düşük ortalama ölçümüne sahiptir. 2016-2018 yılları arasında 16 mg/l ile aynı ortalama değeri olduğu görülmektedir. Renk parametresi için bakılacak olursa da; RES436nm genel olarak birbirine yakın ortalama değerleridir. RES620nm 2018-2021 yılları arasında ortalama ölçüm değerlerinin aynı olduğu görülmektedir. RES525nm için en yüksek ortalama değeri 2017 yılında $0,60 \text{ m}^{-1}$ 'dir.

Tablo 3.3. 2015-2021 yılları Kırandere ölçüm sonuçları ortalamaları

Yıllar	pH	İletkenlik	BOİ	Sıcaklık	ÇO	KOİ	Renk(RES)		
							436nm	620nm	525nm
	–	mS/cm	mg/L	°C	mg/L	mg/L	m ⁻¹	m ⁻¹	m ⁻¹
2015	8,55	610	2,15	22,80	8,67	17,50	0,50	0,00	0,05
2016	8,46	741,25	3,20	16,12	10,82	15,75	0,04	0,03	0,125
2017	8,70	726	2,00	14,90	11,12	18,05	0,78	0,04	0,55
2018	8,46	704,50	2,25	19,08	10,85	14,00	0,45	0,18	0,225
2019	8,01	746,75	2,50	16,25	13,50	16,75	0,25	0,10	0,12
2020	8,80	722,33	2,33	23,65	11,76	22,33	0,36	0,10	0,16
2021	8,49	688	2	8,25	13,3	16	1,05	0,75	0,8

Kırandere için Tablo 3.3.'te bulunan parametreler yıl bazında incelendiğinde pH parametresi 8,80 ortalaması ile 2020 yılında en yüksek değere sahiptir. İletkenlik parametresi için 2016-2020 yılları arasında ortalama ölçüm değerleri genel olarak birbirine yakındır. BOİ parametresi de 2016 yılında 3,20 mg/l ile en yüksek ortalama değerine sahiptir. Diğer yıllarda genellikle ortalama değerleri birbirine yakın ortalamalardır. Sıcaklık parametresi için en düşük ortalama 2021 yılında 8,25 °C'dir. Diğer yıllarda yakın ortalamalara sahiptir. ÇO parametresi 2015 yılında 8,67 mg/l ile en düşük konstrasyon ortalamasına sahip olduğu görülmektedir. KOİ parametresi 22,33 mg/l ile en yüksek konsantrasyon ortalamasına sahiptir. Renk parametreleri için ise RES436nm 2016 yılında diğer yıllara oranla çok düşük bir değere sahiptir ve 2021 yılında ise diğer yıllara oranla da yüksek bir ortalama değeri olduğu görülmektedir. RES620nm en düşük 0 iken en yüksek 0,75 m⁻¹'dir. RES525nm en düşük 0,05 m⁻¹ iken en yüksek 0,8 m⁻¹'dir.

Tablo 3.4. 2015-2021 yılları Sölöz Deresi ölçüm sonuçları ortalamaları

Yıllar	pH	İletkenlik	BOİ	Sıcaklık	ÇO	KOİ	Renk(RES)		
							436nm	620nm	525nm
	–	mS/cm	mg/L	°C	mg/L	mg/L	m ⁻¹	m ⁻¹	m ⁻¹
2015	8,36	484,33	3,33	16,25	10,00	10,00	0,30	0,10	0,20
2016	8,13	560,50	0,57	15,83	8,20	14,00	1,43	0,93	1,15
2017	7,75	581,25	2,75	14,85	7,90	16,75	0,70	0,25	0,33
2018	8,04	541,66	117,66	13,47	7,18	309,00	8,03	3,30	5,17
2019	7,98	576,25	4,33	17,40	7,40	14,50	1,00	0,45	0,60
2020	8,23	520	3,00	10,40	9,75	20,00	0,65	0,20	0,35
2021	8,42	497	2,5	9,65	9,8	16	0,5	0,15	0,25

Sölöz Deresi için Tablo 3.4.'te bulunan parametreler yıl bazı incelendiğinde pH değerleri ortalamaları genel olarak yakın değerlerdedir. İletkenlik parametresi 2017 yılında 581,25 mS/cm ile en yüksek ortalamaya, 2021 yılında 497 mS/cm ile en düşük

ortalama olduğu görülmektedir. BOİ parametresi 117,66 mg/l ile diğer yıllara oranla çok büyük bir artış söz konusu olduğu görülmektedir. Sıcaklık parametresi 2019 yılında 17,40 °C ile en yüksek, 2021 yılında 9,65 °C ile en düşük sıcaklık ortalamasına sahiptir. ÇO parametresi genel olarak 2015-2021 yılları arasında 7,18 mg/l ile 10 mg/l arasında gelmiş olup yakın değerlere sahiptir. KOİ parametresi diğer yıllara oranla 2018 yılında 309 mg/l ortalama sahip olup en yüksek ortalama konsantrasyon değerindedir. Diğer yıllar için incelersek ortalama ölçümleri genel olarak birbirine yakındır. Renk parametresi ise RES436nm, RES620nm, RES525nm için 2018 yılında sırasıyla 8,03 m⁻¹, 3,30 m⁻¹, 5,17 m⁻¹ ortalama değerlerine sahip olup diğer yıllara oranla büyük bir artış gözlemlenmiştir. Genel olarak diğer yıllar için ortalama değerleri birbirine yakındır.

3.2.4.2. İznik Gölü çıkış noktası ölçümü

Bu kısım da 2015-2021 yılları Karsak Deresi su kalitesi ölçüm sonuçları ortalamaları verilmiştir.

Tablo 3.5. 2015-2021 yılları Karsak Deresi ölçüm sonuçları ortalamaları

	Sn	As	Fe	Mn	Cu	Pb	Sb	Al	B	Cr	Cd	Ni	Zn	Se	Ag
Yıllar	mg/L	mg/L	mg/L	mg/L	mg/L	mg/L	mg/L	mg/L	mg/L	mg/L	mg/L	mg/L	mg/L	mg/L	mg/L
2015	-	0,050	1,225	0,050	0,075	0,075	-	1,187	0,078	0,050	0,075	0,075	0,075	-	-
2016	-	0,025	0,348	0,012	0,004	0,010	-	0,560	0,048	0,004	0,004	0,008	0,062	-	-
2017	-	0,015	0,449	0,011	0,003	0,003	-	0,540	0,060	0,008	0,003	0,009	0,006	0,011	-
2018	0,010	0,013	0,049	0,007	0,004	0,004	0,013	0,071	0,060	0,003	0,003	0,007	0,008	0,011	0,003
2019	0,015	0,015	0,242	0,050	0,010	0,010	0,015	0,690	0,050	0,010	0,010	0,015	0,028	0,015	0,010
2020	0,015	0,015	0,361	0,018	0,010	0,010	0,015	0,590	0,040	0,010	0,010	0,015	0,010	0,015	0,010
2021	0,025	0,025	0,200	0,010	0,010	0,025	0,025	0,252	0,071	0,010	0,010	0,025	0,010	0,025	0,017

Karsak Deresi için Tablo 3.5.'te görülen parametreler yıl bazında incelendiğinde Sn parametresi genel olarak yakın ortalama konsantrasyon değerlerine sahiptir. As parametresi 2018 yılında 0,013 mg/l ile en düşük konsantrasyon değerine ve 2015 yılında 0,050 mg/l ile en yüksek ortalama konsantrasyon değerine sahip olduğu

görülmektedir. Fe parametresi 2018 yılında 0,049mg/l ile en düşük konsantrasyon ortalamasına, 2015 yılında 1,225mg/l ile en yüksek ortalama konsantrasyonuna sahiptir. Mn parametresi 2018 yılında 0,007 mg/l ile en düşük ortalama , 2015 ve 2019 yıllarında 0,050 mg/l ile en yüksek ortalama değerlerindedir. Cu parametresi 2016-2021 yılları arasında birbirine yakın ortalama değerlerinde olup, 2015 yılında 0,075 mg/l ile en yüksek ortalama değerine sahiptir. Pb parametresi 2017 yılında 0,003 mg/l ile en düşük ortalama, 2015 yılında 0,075 mg/l ile en yüksek ortalama değildir. Sb parametresi için yıllara bakıldığında ortalama değerler birbirine yakın görülmektedir. Al parametresi 2018 yılında 0,071 mg/l ile en düşük konsantrasyon , 2015 yılında 1,187 mg/l ile en yüksek konsantrasyon ortalamasına sahiptir ve diğer yıllara ortalama ölçümleri birbirine yakın değerler göstermektedir. B parametresi yıl bazında incelenirse birbirlerine yakın değerler halinde artış-azalış göstermektedir. Cr ve Cd parametrelerinin ortalamaları 2016-2021 yılları arasında yakın değerlerdir. İki parametre içinde 2015 yılında diğer yıllara oranla bir artış gözlemlenmiştir. Ni parametresi 2015 yılında 0,075 mg/l ile en yüksek ortalama değerine sahiptir. Diğer yıllardaki ortalamalar birbirlerine yakın bir artış-azalış göstermiştir. Zn parametresi 2015 ve 2016 yıllarında sırasıyla 0,075mg/l, 0,062mg/l olarak görülmektedir. Bu Zn değerleri en yüksek ortalama konsantrasyonlarıdır. Se parametresi ortalama ölçümleri yıllar olarak bakıldığında birbirlerine çok yakın değerler olduğu görülmektedir. Ag parametresi 2021 yılında 0,017 mg/l ile en yüksek konsantrasyon değerine sahipken, 2018 yılında 0,003 mg/l ile en düşük ortalama değerine sahip olduğu görülmektedir.

BÖLÜM 4. ARAŞTIRMA BULGULARI


4.1. Karasu Deresi için Yapılan YSA Modelleri ve R² Grafikleri

Karasu Deresi için veriler programda sisteme yüklenip 7 parametre girdisi pH, iletkenlik, BOİ, KOİ, sıcaklık, çözünmüş oksijen, renk(RES436nm), renk(RES620nm) ve renk (RES525nm) baz alınarak girdi parametreleri üzerinden çeşitli denemeler yapılmıştır. Diğer çalışmalarda, ANN ve ANFIS modelleri ile metal konsantrasyonu tahmininde pH, sıcaklık ve KOİ gibi girdi parametrelerinin tek başına kullanılması yetersiz kalmış; ancak birlikte kullanıldığında model tahminlerinin başarısının önemli ölçüde arttığı belirtilmektedir (Bayatzadeh Fard ve ark., 2017; Nhantumbo ve ark. 2018; Lu ve ark. 2019). Bu üç girdi verisi bazı metallerin tahmininde yeterli model performansı sağlarken, bazı metal tahminlerinde girdi verisi olarak EC, BOİ ve SS değerlerinin eklenmesi model başarısını artırabilir veya azaltabilir olduğu görülmüştür (Ozel ve ark., 2020).


Karsak Deresi çıkış noktasında ki her bir ağır metal için Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag en iyi R² değerini bulmak amaçlanmıştır. Aktivasyon fonksiyonları olarak sigmoid ve hiperbolik tanjant fonksiyonları kullanılmıştır. Gizli katmandaki nöron sayıları 1 ile 7 arasında değişiklik göstermiştir.

Programda oluşturulan YSA mimarileri Şekil 4.1., 4.3., 4.5., 4.7., 4.9., 4.11., 4.13., 4.15., 4.17., 4.19., 4.21., 4.23., 4.25., 4.27., 4.29.'da gösterilmiştir.


Yapılan denemeler sonucunda çıkan R² değerleri grafik olarak Şekil 4.2., 4.4., 4.6., 4.8., 4.10., 4.12., 4.14., 4.16., 4.18., 4.20., 4.22., 4.24., 4.26., 4.28., 4.30.'da verilmiştir.




Şekil 4.1. Karasu SN parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.2. Karasu SN parametresi R^2 grafiği




Şekil 4.3. Karasu As parametresi için oluşturulan 8-7-1 YSA modeli




Şekil 4.4. Karasu As parametresi R^2 grafiği




Şekil 4.5. Karasu Fe parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.6. Karasu Fe parametresi R^2 grafiği




Şekil 4.7. Karasu Mn parametresi için oluşturulan 6-1-1 YSA modeli




Şekil 4.8. Karasu Mn parametresi R^2 grafiği




Şekil 4.9. Karasu Cu parametresi için oluşturulan 5-3-1 YSA modeli




Şekil 4.10. Karasu Cu parametresi R^2 grafiği




Şekil 4.11. Karasu Pb parametresi için oluşturulan 6-3-1 YSA modeli




Şekil 4.12. Karasu Pb parametresi R^2 grafiği




Şekil 4.13. Karasu Sb parametresi için oluşturulan 9-4-1 YSA modeli

Şekil 4.14. Karasu Sb parametresi R^2 grafiği


YSA modelleri için Sn, As, Fe, Mn, Cu, Pb, Sb için korelasyon katsayısı sırasıyla 0.999, 0.985, 0.963, 0.859, 0.987, 0.757, 0.998'dir ve sonuçlar bu çalışma da YSA modelinin kirliliği tahmin edebildiğini ve girdi parametreleri ile iyi ilişki kurulduğu görülmüştür. Benzer çalışma örnekleri de daha önceki çalışmalarda yapılmış olup Obiewa ve ark., (2020)'nın yaptığı çalışmada Sosiani Nehri'ndeki kurşun, bakır ve kadminyumun kirlilik yükünü YSA kullanarak, fiziko-kimyasal parametrelere dayalı olarak tahmin etmişlerdir. Girdi katmanı için bulanıklık, KOİ, iletkenlik, florür ve fosfat parametrelerini çıktı katmanı için ise üç bağımlı değişkeni Pb, Cu ve Cd kullanmışlardır. YSA ile Pb, Cu ve Cd için gözlenen değerler arasındaki R^2 değerleri sırasıyla 0.999, 0.991 ve 0.996 bulmuşlardır ve böylelikle YSA'nın nehirdeki Pb, Cu ve Cd kirlilik yükünü tahmin edebildiğini görmüşlerdir. Bir başka çalışmada da bakır, demir, çinko, manganez, nikel ve kurşun analizleri yapılmış ve sonuçlar YSA'lar ile modellenmiştir. Bartın Nehri'ndeki kirlilik parametrelerinin izlenmesi için en uygun modelin tanımlanması amaçlanmış ve çalışma sonucunda en uygun modeli belirlemişlerdir. Girdi parametreleri olarak sıcaklık, pH, iletkenlik, KOİ, BOİ ve askıda katı madde kullanmışlardır. Çıkan R^2 değerleri çok katmanlı da 0,770 'in üzerinde, radyal tabanlı da 0.773'ün üzerinde ve uyarlanabilir nöro-bulanık çıkarım sistemi modelin de 0.800'ün üzerinde bulmuşlardır. Sonuçlara göre, ağır metal içeriklerinin yapay zeka modelleri ile yaklaşık olarak tahmin edilebileceği sonucuna varılmıştır. Bu çalışma ile nehirlerde ki zararlı ağır metalleri hem hızlı hem de ekonomik olarak tespit etmenin mümkün olabileceği sonucuna ulaşmışlardır (Ozel ve ark., 2020).




Şekil 4.15. Karasu Al parametresi için oluşturulan 9-4-1 YSA modeli




Şekil 4.16. Karasu Al parametresi R^2 grafiği




Şekil 4.17. Karasu B parametresi için oluşturulan 8-7-1 YSA modeli




Şekil 4.18. Karasu B parametresi R^2 grafiği




Şekil 4.19. Karasu Cr parametresi için oluşturulan 8-7-1 YSA modeli




Şekil 4.20. Karasu Cr parametresi R^2 grafiği




Şekil 4.21. Karasu Cd parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.22. Karasu Cd parametresi R^2 grafiği




Şekil 4.23. Karasu Ni parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.24. Karasu Ni parametresi R² grafiği




Şekil 4.25. Karasu Zn parametresi için oluşturulan 8-7-1 YSA modeli




Şekil 4.26. Karasu Ni parametresi R^2 grafiği




Şekil 4.27. Karasu Se parametresi için oluşturulan 8-4-1 YSA modeli



Şekil 4.28. Karasu Se parametresi R^2 grafiği



Şekil 4.29. Karasu Ag parametresi için oluşturulan 9-5-1 YSA modeli



Şekil 4.30. Karasu Ag parametresi R^2 grafiği

YSA modelleri için Al, B, Cr, Cd, Zn, Se, Ag için korelasyon katsayıları sırasıyla 0.636, 0.937, 0.723, 0.902, 0.872, 0.993, 0.986'dır ve sonuçlar bu çalışmanın bulgularıyla kirliliği tahmin edebildiği ve girdi parametreleri ile iyi ilişki kurulduğu görülmüştür. Ni parametresi korelasyon katsayısı 0.447 bulunmuştur ve çok iyi bir ilişki kurulamamıştır. Daha önce yapılan bir diğer çalışmada da Lakan kurşun-çinko madeninin yeraltı sularında, tarihsel madencilik faaliyetlerinden kaynaklanan etkiler nedeniyle yüksek konsantrasyonlarda Fe, Mn, Pb ve Zn bulunmuştur. Bu çalışmada, giriş parametreleri olarak sülfat (SO_4), klorür (Cl) ve toplam çözünmüş katı madde (TÇK) ve çıkış parametreleri olarak Fe, Mn, Pb ve Zn kullanılarak yeraltı sularındaki ağır metal konsantrasyonlarını tahmin etmek için YSA modelleri geliştirilmiştir. Bu amaçla, mevcut yeraltı suyu kalite izleme verileri kullanılarak kirlenme yeraltı suyu kaynakları belirlenmiştir. Toplanan veriler kullanılarak çeşitli modeller eğitilmiş ve test edilmiştir. Tahmin edilen ve ölçülen veriler arasındaki karşılaştırmalar yapılmış olup, en iyi modelin çok çıkışlı uyarlanabilir nöral bulanık çıkarım sistemi olduğu sonucuna varılmıştır. Çıkan R^2 sonuçları Fe, Mn, Pb ve Zn sırası ile 0.99, 0.98, 0.98, 0.99 bulunmuştur. Modelin yeraltı suyundaki ağır metallerin dağılımını yüksek derecede doğruluk ve sağlamlıkla tahmin etme potansiyeline sahip olduğunu göstermiştir (Bayatzadeh Fard ve ark., 2017).

Karasu da kirlilik, zirai mücadele ilaçlarından kaynaklanmaktadır (Dede, 2009). Bu sebeple gelen kirlilik etmenlerinin bölgede ki tarımsal faaliyetlerin neden olduğu düşünülebilir.

Tablo 4.1.'de Karasu için yapılmış olan tüm ağır metal denemelerinin girdi verileri, ara katman sayısı, aktivasyon fonksiyonu, çıktı verisi, eğitim-test aşamasındaki hata kareleri toplamı (SSE) ve korelasyon katsayısı (R^2) değerleri özet tablo halinde görülmektedir.

Tablo 4.1. Karasu verilerinin YSA performans deęerleri zet tablosu


GİRDİLER	ARA KATMAN	AKTİVASYON FONKSİYONU (ARA KATMAN)	ÇIKTI	EĞİTİM SSE	TEST SSE	R ²
PH,İletkenlik,ÇO, KOİ,BOİ,T	4	Sigmoid	SN	1,43E-05	1,87E-05	0.999
PH,İletkenlik,ÇO, KOİ,T, Renk	7	Hyperbolic tangent	As	0.001	0.001	0.985
PH,İletkenlik,ÇO, KOİ,BOİ,T	4	Hyperbolic tangent	Fe	0.011	1,96E-08	0.963
PH,İletkenlik,ÇO, KOİ,BOİ,T	1	Hyperbolic tangent	Mn	0.007	0.023	0.859
PH,İletkenlik,ÇO, KOİ,T	3	Sigmoid	Cu	0.000	0.003	0.987
PH,İletkenlik,ÇO, KOİ,BOİ,T	3	Hyperbolic tangent	Pb	0.006	0.045	0.757
PH,İletkenlik,ÇO, KOİ,BOİ,T, Renk	4	Hyperbolic tangent	Sb	0.002	0.000	0.998
PH,İletkenlik,ÇO, KOİ,BOİ,T,Renk	4	Hyperbolic tangent	Al	7,72E-06	0.885	0.636
PH,İletkenlik,ÇO, KOİ,T, Renk	7	Hyperbolic tangent	B	0.070	0.102	0.937
PH,İletkenlik,ÇO, KOİ,T, Renk	7	Hyperbolic tangent	Cr	4,58E-06	0.924	0.723
PH,İletkenlik,ÇO, KOİ,BOİ,T	4	Hyperbolic tangent	Cd	0.154	0.114	0.902
PH,İletkenlik,ÇO, KOİ,BOİ,T	4	Sigmoid	Ni	0.085	0.004	0.447
PH,İletkenlik,ÇO, KOİ,T, Renk	7	Sigmoid	Zn	0.000	0.028	0.872
PH,İletkenlik,ÇO, KOİ,T, Renk	4	Hyperbolic tangent	Se	0.015	0.002	0.993
PH,İletkenlik,ÇO, KOİ,BOİ,T, Renk	5	Hyperbolic tangent	Ag	0.041	0.000	0.986

4.2. Olukdere için Yapılan YSA Modelleri ve R^2 Grafikleri


Olukdere için veriler programda sisteme yüklenip 7 parametre girdisi pH, iletkenlik, BOİ, KOİ, sıcaklık, çözünmüş oksijen, renk(RES436nm), renk(RES620nm) ve renk (RES525nm) baz alınarak girdi parametreleri üzerinden çeşitli denemeler yapılmıştır. Karsak Deresi çıkış noktasında ki her bir ağır metal için Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag en iyi R^2 değerini bulmak amaçlanmıştır. Aktivasyon fonksiyonları olarak sigmoid ve hiperbolik tanjant fonksiyonları kullanılmıştır. Gizli katmandaki nöron sayıları 1 ile 7 arasında değişiklik göstermiştir.

Programda oluşturulan YSA mimarileri Şekil 4.31., 4.33., 4.35., 4.37., 4.39., 4.41., 4.43., 4.45., 4.47., 4.49., 4.51., 4.53., 4.55., 4.57., 4.59.'da gösterilmiştir.


Yapılan denemeler sonucunda çıkan R^2 değerleri grafik olarak Şekil 4.32., 4.34., 4.36., 4.38., 4.40., 4.42., 4.44., 4.46., 4.48., 4.50., 4.52., 4.54., 4.56., 4.58., 4.60.'da verilmiştir.




Şekil 4.31. Olukdere SN parametresi için oluşturulan 6-4-1 YSA modeli



Şekil 4.32. Olukdere SN parametresi R^2 grafiği




Şekil 4.33. Olukdere As parametresi için oluşturulan 6-1-1 YSA modeli




Şekil 4.34. Olukdere As parametresi R^2 grafiği




Şekil 4.35. Olukdere Fe parametresi için oluşturulan 9-2-1 YSA modeli




Şekil 4.36. Olukdere Fe parametresi R^2 grafiği




Şekil 4.37. Olukdere Mn parametresi için oluşturulan 9-5-1 YSA modeli



Şekil 4.38. Olukdere Mn parametresi R^2 grafiği




Şekil 4.39. Olukdere Cu parametresi için oluşturulan 9-3-1 YSA modeli




Şekil 4.40. Olukdere Cu parametresi R2 grafiği


Yüksek konsantrasyonlarda bakır iyonunun su kaynaklarına girmesi durumunda; canlı organizmaların enzim aktivitesi etkilenir ve normal organlarının işleyişi bozulur (Sharpley ve ark., 2003). Bakırın insan sağlığı üzerindeki etkileri ile ilgili endişeler, sudaki konsantrasyonlarını sınırlayan çok sayıda kılavuz ve düzenlemeye yol açmıştır. Bakırla ilgili yapılan YSA çalışmalarından biri de Shakeri ve ark., (2013)'nın Sistan-Belucistan'da en önemli içme suyu kaynağı olan bir rezervuarından su numuneleri toplanarak çalışmada Chahnimehl rezervuarının suyundaki Cu konsantrasyonunu tahmin etmek için YSA araştırılmıştır. Giriş değişkenleri elektrik iletkenliği, toplam çözünmüş katılar, sıcaklık ve pH, sudaki Cu konsantrasyonu ise çıktıdır. Korelasyon katsayıları eğitim, doğrulama ve test için sırasıyla 0.9346, 0,8612, 0.9372 bulunmuştur ve böylece tahmin edilen değerlerin doğru olduğunu ve ağ tasarımının uygun olduğunu ve giriş değişkenlerinin Cu konsantrasyonunun tahmini için uygun olduğu görülmüştür. İznik Gölü için oluşturulan YSA modellerinde de Cu değerleri 4 gözlem noktası içinde yüksek gelmiş olup programın doğru tahmin ettiği görülmüştür.




Şekil 4.41. Olukdere Pb parametresi için oluşturulan 6-2-1 YSA modeli



Şekil 4.42. Olukdere Pb parametresi R^2 grafiği




Şekil 4.43. Olukdere Sb parametresi için oluşturulan 6-3-1 YSA modeli




Şekil 4.44. Olukdere Sb parametresi R^2 grafiği


YSA modelleri için Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag için korelasyon katsayıları sırasıyla 0.997, 0.986, 0.810, 0.972, 0.990, 0.922, 0.949, 0.852, 0.743, 1.000, 0.926, 0.997, 0.967, 0.999, 0.884'tür ve sonuçların bu çalışmanın bulgularıyla kirliliği tahmin edebildiğini ve girdi parametreleri ile iyi ilişki kurulduğu görülmüştür. Daha öncelerde yapılan bir çalışma da ise, iklim ve kirlilik koşullarına bağlı olarak tropikal "Malezya" ve kurak "Libya" daki hem kirli hem de kirli olmayan göl su kütlelerinde bulunan ağır metal içeriğindeki değişiklikleri modellemek için radyal temel fonksiyonu sinir ağı algoritmasını kullanmıştır. Çalışma farklı iklim koşulları altında yürütülmüş ve haftalık fizikokimyasal parametre verileri (pH, iletkenlik, sıcaklık, çözünmüş oksijen, toplam çözünmüş katı madde , toplam askıda katı madde, klorür , nitrit, fosfat ve sülfat) ve iklimsel parametrelerin (hava sıcaklığı, nem ve yağış) kayıtları girdi verisi olarak kullanmışlardır. Ağır metaller arasında ise nikel ,kobalt , demir, çinko, bakır , kurşun ve kadminyum yer almaktadır. Üç farklı senaryo değerlendirilmiştir ve bu senaryolardan elde ettikleri performans ölçütlerine göre R^2 değerleri kirli göl için 0.780, kirlenmemiş göl için 0.958, tropikal göl için 0.516, kurak göl için 0.996 bulunmuştur. Genel olarak tüm bu senaryolardan elde edilen sonuçların yüksek düzeyde tahmin doğruluğu gösterdiğini bulmuşlardır (Elzwayie ve ark., 2017).




Şekil 4.45. Olukdere Al parametresi için oluşturulan 9-2-1 YSA modeli




Şekil 4.46. Olukdere Al parametresi R^2 grafiği




Şekil 4.47. Olukdere B parametresi için oluşturulan 6-3-1 YSA modeli




Şekil 4.48. Olukdere B parametresi R^2 grafiği




Şekil 4.49. Olukdere Cr parametresi için oluşturulan 6-5-1 YSA modeli




Şekil 4.50. Olukdere Cr parametresi R^2 grafiği



Şekil 4.51. Olukdere Cd parametresi için oluşturulan 9-7-1 YSA modeli




Şekil 4.52. Olukdere Cd parametresi R^2 grafiği




Hidden layer activation function: Hyperbolic tangent

Output layer activation function: Identity


Şekil 4.53. Olukdere Ni parametresi için oluşturulan 6-3-1 YSA modeli




Şekil 4.54. Olukdere Ni parametresi R^2 grafiği




Şekil 4.55. Olukdere Zn parametresi için oluşturulan 9-7-1 YSA modeli




Şekil 4.56. Olukdere Zn parametresi R^2 grafiği




Şekil 4.57. Olukdere Se parametresi için oluşturulan 9-7-1 YSA modeli



Şekil 4.58. Olukdere Se parametresi R^2 grafiği



Şekil 4.59. Olukdere Ag parametresi için oluşturulan 6-3-1 YSA modeli



Şekil 4.60. Olukdere Ag parametresi R^2 grafiği

Olukludere Orhangazi kasabasına doğrudan sınır olan deredir. Deredeki suyun kalitesi Yalova yolu köprüsüne gelinceye kadar temizdir. Fakat bu noktada bağlanan Orhangazi ve civarındaki yakın yerleşimlerinin kanalizasyonları, Orhangazi Belediyesi Mezbahasının ve Orhangazi'deki sanayi tesislerinin, küçük zeytinyağı fabrikalarının atık suları kaliteyi önemli ölçüde etkilemektedir (Dede, 2009). Endüstriyel ve tarımsal kaynaklar, Song ve ark., (2018) tarafından bildirildiği gibi Cr, Ni ve Zn tarafından tanımlanmıştır. Cr genellikle metal ve kimyasal üretim gibi endüstriyel faaliyetlerden kaynaklanmaktadır. İznik Gölü'nde de son zamanlarda yaşanan endüstriyel gelişme, tarımsal faaliyetler ve göl çevresindeki kentleşme ile birlikte artan nüfus antropojenik stresi arttırmıştır (Budakoğlu, 2000; Ünlü ve ark., 2010). Gölün batı kısmı organize sanayi bölgesidir (Orhangazi); makine üretimi, gıda işleme, zeytinyağı üretimi, tekstil ve paketlenme fabrikaları, metal ve kereste işleme ile bilinir.

Tablo 4.2.'de Olukdere için yapılmış olan tüm ağır metal denemelerinin girdi verileri, ara katman sayısı, aktivasyon fonksiyonu, çıktı verisi, eğitim-test aşamasındaki hata kareleri toplamı (SSE) ve korelasyon katsayısı (R^2) değerleri özet tablo halinde görülmektedir.

Tablo 4.2. Olukdere verilerinin YSA performans deęerleri zet tablosu


GİRDİLER	ARA KATMAN	AKTİVASYON FONKSİYONU (ARA KATMAN)	ÇIKTI	EĞİTİM SSE	TEST SSE	R ²
PH,İletkenlik,ÇO, KOİ,T,BOİ	4	Sigmoid	SN	9,24E-05	4,48E-08	0.997
PH,İletkenlik,ÇO, KOİ,T,BOİ	1	Hyperbolic tangent	As	0.041	7,01E-06	0.986
PH,İletkenlik,ÇO, KOİ,T,BOİ, Renk	2	Hyperbolic tangent	Fe	0.069	0.503	0.810
PH,İletkenlik,ÇO, KOİ,BOİ,T, Renk	5	Hyperbolic tangent	Mn	0.100	1,32E-06	0.972
PH,İletkenlik,ÇO, KOİ,BOİ,T, Renk	3	Hyperbolic tangent	Cu	0.037	0.001	0.990
PH,İletkenlik,ÇO, KOİ,BOİ,T	2	Hyperbolic tangent	Pb	0.245	0.002	0.922
PH,İletkenlik,ÇO, KOİ,BOİ,T	3	Hyperbolic tangent	Sb	0.042	0.22	0.949
PH,İletkenlik,ÇO, KOİ,BOİ,T, Renk	2	Hyperbolic tangent	Al	0.379	0.104	0.852
PH,İletkenlik,ÇO, KOİ,BOİ,T	3	Hyperbolic tangent	B	0.024	0.540	0.743
PH,İletkenlik,ÇO, KOİ,BOİ,T	5	Hyperbolic tangent	Cr	0.002	1,94E-06	1.000
PH,İletkenlik,ÇO, KOİ,BOİ,T, Renk	7	Sigmoid	Cd	0.012	0.000	0.926
PH,İletkenlik,ÇO, KOİ,BOİ,T	3	Hyperbolic tangent	Ni	0.010	1,82E-06	0.997
PH,İletkenlik,ÇO, KOİ,BOİ,T, Renk	7	Sigmoid	Zn	0.003	0.012	0.967
PH,İletkenlik,ÇO, KOİ,BOİ,T, Renk	7	Hyperbolic tangent	Se	0.001	0.000	0.999
PH,İletkenlik,ÇO, KOİ,BOİ,T	3	Hyperbolic tangent	Ag	0.002	0.668	0.884

4.3. Kırandere için Yapılan YSA Modelleri ve R^2 Grafikleri


Kırandere için veriler programda sisteme yüklenip 7 parametre girdisi pH, iletkenlik, BOİ, KOİ, sıcaklık, çözünmüş oksijen, renk(RES436nm), renk(RES620nm) ve renk (RES525nm) baz alınarak girdi parametreleri üzerinden çeşitli denemeler yapılmıştır. Karsak Deresi çıkış noktasında ki her bir ağır metal için Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag en iyi R^2 değerini bulmak amaçlanmıştır. Aktivasyon fonksiyonları olarak sigmoid ve hiperbolik tanjant fonksiyonları kullanılmıştır. Gizli katmandaki nöron sayıları 1 ile 5 arasında değişiklik göstermiştir.

Programda oluşturulan YSA mimarileri Şekil 4.61., 4.63., 4.65., 4.67., 4.69., 4.71., 4.73., 4.75., 4.77., 4.79., 4.81., 4.83., 4.85., 4.87., 4.89.'da gösterilmiştir.


Yapılan denemeler sonucunda çıkan R^2 değerleri grafik olarak Şekil 4.62., 4.64., 4.66., 4.68., 4.70., 4.72., 4.74., 4.76., 4.78., 4.80., 4.82., 4.84., 4.86., 4.88., 4.90.'da verilmiştir. YSA modelleri için Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag için korelasyon katsayısı sırasıyla 0.966, 0.932, 0.993, 0.820, 0.873, 0.989, 1.000, 0.894, 0.835, 0.981, 0.939, 0.988, 0.937, 0.851, 0.977'dir ve sonuçlar bu çalışmanın bulgularıyla iyi ilişkilidir.




Şekil 4.61. Kırandere SN parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.62. Kırandere SN parametresi R^2 grafiği




Şekil 4.63. Kırandere As parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.64. Kırandere As parametresi R^2 grafiği




Şekil 4.65. Kırandere Fe parametresi için oluşturulan 9-4-1 YSA modeli




Şekil 4.66. Kırandere Fe parametresi R^2 grafiği




Şekil 4.67. Kırandere Mn parametresi için oluşturulan 5-1-1 YSA modeli




Şekil 4.68. Kırandere Mn parametresi R^2 grafiği




Şekil 4.69. Kırandere Cu parametresi için oluşturulan 6-2-1 YSA modeli




Şekil 4.70. Kırandere Cu parametresi R^2 grafiği




Şekil 4.71. Kırandere Pb parametresi için oluşturulan 6-1-1 YSA modeli



Şekil 4.72. Kırandere Pb parametresi R^2 grafiği




Şekil 4.73. Kırandere Sb parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.74. Kırandere Sb parametresi R^2 grafiği

Endüstriyel ve tarımsal kaynaklar, yüksek miktarda Pb, Cd, Co, Ni ve Zn ve özellikle pH ile karakterizedir. Bu metaller temel olarak metal işleme/boya ve tarımsal faaliyetler gibi endüstriyel faaliyetlerden ve pestisit kullanımından kaynaklanmaktadır (Mahaffey, 1983;Sakan ve ark., 2011). Bu sebeple girdi verilerinden biri pH seçilmiştir. İznik ve Orhangazi'deki sanayilerden ve gölün etrafındaki tarımda kullanılan zirai ilaç ve gübrelerden gelen kimyasallar kıyı bitkileri ve canlıları öldürmektedir. İznik'ten ve Orhangazi'den gelen azot yükü fazladır (Budakoğlu, 2000). Gübre kullanımı gibi tarımsal faaliyetler genellikle As, Cr, Ni ve Zn'nin ana kaynağıdır (Wang ve ark., 2017). İznik Gölü çevresinde tarımsal faaliyetlerin oldukça fazla olduğu için düşünülürse bu metallerin gölde bulunma sebeplerinin bu faktörler olduğu düşünülebilir.Yüksek konsantrasyonlarda Cd, Pb, As ve Cu içeren azot ve fosfor bazlı gübreler tatlı su sisteminde birikmeye neden olmuştur (Sönmez ve ark., 2008).


İznik Gölü'nün kirlenmesine neden olan bir diğer unsur ise gölün batı kıyılarında İstanbul-Bursa karayolu Orhangazi'den geçmekte ve bu yoğun trafik hava kirliliklerine neden olabilmektedir (Oktem ve ark., 2012). Trafik ve litojenik kaynaklar, karayollarının varlığı ve bölgenin mineral yapısı ile açıklanmaktadır. Bu sebeple de Ni açısından en önemli kirletici kaynaklardır ve akaryakıtın yanmasından ve bu yollardaki fren balatalarından kaynaklanabilmektedir. Diğerleri Al ve Fe toprak yapısından kaynaklanır (Wedepohl, 1991;Berger ve Dallinger, 1993;Duman ve ark., 2007).




Şekil 4.75. Kırandere AI parametresi için oluşturulan 6-2-1 YSA modeli




Şekil 4.76. Kırandere AI parametresi R^2 grafiği




Şekil 4.77. Kırandere B parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.78. Kırandere B parametresi R^2 grafiği




Şekil 4.79. Kırandere Cr parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.80. Kırandere Cr parametresi R^2 grafiği




Şekil 4.81. Kırandere Cd parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.82. Kırandere Cd parametresi R^2 grafiği




Şekil 4.83. Kırandere Ni parametresi için oluşturulan 6-2-1 YSA modeli




Şekil 4.84. Kırandere Ni parametresi R^2 grafiği




Şekil 4.85. Kırandere Zn parametresi için oluşturulan 6-5-1 YSA modeli




Şekil 4.86. Kırandere Zn parametresi R^2 grafiği




Şekil 4.87. Kırandere Se parametresi için oluşturulan 6-4-1 YSA modeli



Şekil 4.88. Kırandere Se parametresi R^2 grafiği



Şekil 4.89. Kırandere Ag parametresi için oluşturulan 5-3-1 YSA modeli



Şekil 4.90. Kırandere Ag parametresi R^2 grafiği

Bir diğerkirlilik unsurlarından birisi ise; göl suyu aynı zamanda sulama için de kullanılıyor ve göl yaz aylarında rekreasyon için popüler bir yerdir. Göl çevresinde, özellikle gölün batı kıyısındaki Orhangazi bölgesinde, sulamalı tarıma uygun 1. sınıf tarım arazilerinin (yerleşime açık) plansız şekilde kötüye kullanılması, İznik Gölü'nün geleceğini tehlikeye atmaktadır (Meşeli, 2010).

İznik Gölü, Orhangazi Sanayi Bölgesi'nin atık suları, İznik ve Osmangazi tankerleri, İznik Marmara Birlik Zeytin İşleme Tesisleri ve Orhangazi'deki İspak sanayi tesisleri tarafından kirletilmektedir. Ayrıca göl, çevresindeki küçük zeytinyağı fabrikaları nedeniyle tehdit altındadır ve göl havzasında kimya, otomotiv, metal ve gıda sanayi sektörleri bulunuyor (WWF, 2011).

Tablo 4.3.'de Kırandere için yapılmış olan tüm ağır metal denemelerinin girdi verileri, ara katman sayısı, aktivasyon fonksiyonu, çıktı verisi, eğitim-test aşamasındaki hata kareleri toplamı (SSE) ve korelasyon katsayısı (R^2) değerleri özet tablo halinde görülmektedir.

Tablo 4.3. Kırandere verilerinin YSA performans değerleri özet tablosu

GİRDİLER	ARA KATMAN	AKTİVASYON FONKSİYONU (ARA KATMAN)	ÇIKTI	EĞİTİM SSE	TEST SSE	R ²
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Sigmoid	SN	0.001	0.000	0.966
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Sigmoid	As	0.007	1,69E-06	0.932
PH,İletkenlik,ÇO, KOİ,BOİ,T, Renk	4	Hyperbolic tangent	Fe	0.001	0.020	0.993
PH,İletkenlik,ÇO,KOİ,T	1	Hyperbolic tangent	Mn	0.054	0.695	0.820
PH,İletkenlik,ÇO,KOİ,BOİ,T	2	Hyperbolic tangent	Cu	0.038	0.192	0.873
PH,İletkenlik,ÇO,KOİ,BOİ,T	1	Hyperbolic tangent	Pb	0.000	0.028	0.989
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Sigmoid	Sb	2,41E-05	2,40E-08	1.000
PH,İletkenlik,ÇO,KOİ,BOİ,T	2	Hyperbolic tangent	Al	0.182	0.074	0.894
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Sigmoid	B	0.002	0.017	0.835
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Sigmoid	Cr	0.002	4,53E-08	0.981
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Sigmoid	Cd	0.004	0.007	0.939
PH,İletkenlik,ÇO,KOİ,BOİ,T	2	Hyperbolic tangent	Ni	0.044	2,17E-05	0.988
PH,İletkenlik,ÇO,KOİ,BOİ,T	5	Hyperbolic tangent	Zn	0.018	7,91E-06	0.937
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Sigmoid	Se	0.002	0.002	0.851
PH,İletkenlik,ÇO,KOİ,T	3	Sigmoid	Ag	0.000	2,74E-06	0.977


4.4. Sölöz için Yapılan YSA Modelleri ve R^2 Grafikleri

Sölöz Deresi için veriler programda sisteme yüklenip 7 parametre girdisi pH, iletkenlik, BOİ, KOİ, sıcaklık, çözünmüş oksijen, renk(RES436nm), renk(RES620nm) ve renk (RES525nm) baz alınarak girdi parametreleri üzerinden çeşitli denemeler yapılmıştır. Karsak Deresi çıkış noktasında ki her bir ağır metal için Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag en iyi R^2 değerini bulmak amaçlanmıştır. Aktivasyon fonksiyonları olarak sigmoid ve hiperbolik tanjant fonksiyonları kullanılmıştır. Gizli katmandaki nöron sayıları 3 ile 7 arasında değişiklik göstermiştir.


Programda oluşturulan YSA mimarileri Şekil 4.91., 4.93., 4.95., 4.97., 4.99., 4.101., 4.103., 4.105., 4.107., 4.109., 4.111., 4.113., 4.115., 4.117., 4.119.'da gösterilmiştir.


Yapılan denemeler sonucunda çıkan R^2 değerleri grafik olarak Şekil 4.92., 4.94., 4.96., 4.98., 4.100., 4.102., 4.104., 4.106., 4.108., 4.110., 4.112., 4.114., 4.116., 4.118., 4.120.'de verilmiştir.

YSA modelleri için Sn, As, Fe, Cu, Pb, Sb, Al, Cr, Cd, Ni, Zn, Se, Ag için korelasyon katsayısı sırasıyla 0.990, 0.844, 0.804, 0.962, 0.995, 0.885, 0.909, 0.989, 0.841, 0.917, 0.759, 0.995, 0.809'dur ve sonuçlar bu çalışmanın bulgularıyla iyi ilişkilidir. Mn parametresi korelasyon katsayısı 0.551 bulunmuştur ve çok iyi bir ilişki kurulamamıştır. B parametresi korelasyon katsayısı 0.304 bulunmuştur ve çok iyi bir ilişki kurulamamıştır





Şekil 4.91. Sölöz SN parametresi için oluşturulan 9-7-1 YSA modeli

Şekil 4.92. Sölöz SN parametresi R^2 grafiği




Şekil 4.93. Sölöz As parametresi için oluşturulan 9-7-1 YSA modeli


Şekil 4.94. Sölöz As parametresi R^2 grafiği




Şekil 4.95. Sölöz Fe parametresi için oluşturulan 9-7-1 YSA modeli




Şekil 4.96. Sölöz Fe parametresi R^2 grafiği




Şekil 4.97. Sölöz Mn parametresi için oluşturulan 6-4-1 YSA modeli


Şekil 4.98. Sölöz Mn parametresi R^2 grafiği




Şekil 4.99. Sölöz Cu parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.100. Sölöz Cu parametresi R^2 grafiği




Şekil 4.101. Sölöz Pb parametresi için oluşturulan 6-4-1 YSA modeli

Şekil 4.102. Sölöz Pb parametresi R^2 grafiği




Şekil 4.103. Sölöz Sb parametresi için oluşturulan 9-7-1 YSA modeli

Şekil 4.104. Sölöz Sb parametresi R^2 grafiği

Kocadere (Sölöz) yağış havzası en büyük olan deredir. Sölöz beldesinin kanalizasyonu buraya deşarj edilmekte olup, Kocadere'nin suyundan yaz sezonu boyunca sulama yapıldığından göle pek fazla su ulaşmamaktadır. Göle karışan atıklardan kaynaklanan aşırı yosunlaşma ve toplu balık ölümleri dikkat çekmektedir (Dede, 2009). İznik Gölü'ndeki kirliliğin nüfus artışıyla orantılı olarak arttığı bilinen bir gerçektir. Göl çevresinde Orhangazi ve İznik'te fosseptiklerin yaygın olarak kullanılması gölün kirliliğinin artmasına neden oluyor. Ayrıca gölün çevresinde 45 köy bulunmakta ve evsel atık sularının kirlilik yükleri gölü etkilemektedir. Ancak kullanılan suyun belirli bir miktarının (genel olarak %70-90) kanalizasyona geri döndüğü düşünülmektedir (Oktem ve ark., 2012).







Hidden layer activation function: Hyperbolic tangent

Output layer activation function: Identity

Şekil 4.105. Sölöz Al parametresi için oluşturulan 5-3-1 YSA modeli




Şekil 4.106. Sölöz Al parametresi R^2 grafiği




Hidden layer activation function: Hyperbolic tangent

Output layer activation function: Identity

Şekil 4.107. Sölöz B parametresi için oluşturulan 5-3-1 YSA modeli




Şekil 4.108. Sölöz B parametresi R^2 grafiği




Hidden layer activation function: Hyperbolic tangent

Output layer activation function: Identity

Şekil 4.109. Sölöz Cr parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.110. Sölöz Cr parametresi R^2 grafiği




Hidden layer activation function: Hyperbolic tangent

Output layer activation function: Identity


Şekil 4.111. Sölöz Cd parametresi için oluşturulan 6-4-1 YSA modeli




Şekil 4.112. Sölöz Cd parametresi R^2 grafiği




Şekil 4.113. Sölöz Ni parametresi için oluşturulan 6-4-1 YSA modeli


Şekil 4.114. Sölöz Ni parametresi R^2 grafiği




Şekil 4.115. Sölöz Zn parametresi için oluşturulan 6-4-1 YSA modeli



Şekil 4.116. Sölöz Zn parametresi R^2 grafiği




Şekil 4.117. Sölöz Se parametresi için oluşturulan 9-7-1 YSA modeli

Şekil 4.118. Sölöz Se parametresi R^2 grafiği



Şekil 4.119. Sölöz Ag parametresi için oluşturulan 9-7-1 YSA modeli

Şekil 4.120. Sölöz Ag parametresi R^2 grafiği

Havzada kirleticileri göle boşaltan noktasal ve noktasal olmayan (yaygın) kirlilik kaynakları mevcuttur (Akkoyunlu ve ark., 2011). İznik Gölü'nün havza alanı, farklı silisiklastik kayalardan oluşmuştur. Çoğunlukla kuvars ve yüksek Si, Ba, Pb ve Th konsantrasyonları içeren, karbonat kayalardan (Ca, Br, Sr ve As konsantrasyonlarında zenginleştirilmiş), karışık tortul kayalardan (daha yüksek Cr, Ni ve Sr), metamorfik kayalardan (kuvarstaki yüksek içerikler ve K, Rb, U ve Sn elementleri), felsik ila orta volkanik kayalar (yüksek Al, Ti, Zr ve Zn içeriği) ve mafik volkanik kayalar (daha yüksek Na, Cu, Mg ve Fe) (Viehberg ve ark., 2012). İznik Gölü'ne en yaygın metal kirletici girdisi, hem doğal hem de antropojenik metalleri taşıyan, kısa ama yakın aralıklı akarsuların taşıdığı asılı partikül yüküdür. Çoğunlukla kıyıya yakın ekosistemleri etkiler (örneğin kentsel akıştan Zn), tortu matrisindeki Pb, Cr, V, Ni, Cd ve Cu konsantrasyonları derin havzalara doğru hafifçe artış göstermektedir. Metal kontaminasyonu için bir başka kaynak, dağınık girdilerden, kentsel ve tarımsal faaliyetlerden kaynaklanan arazi akışıdır. Alt akımların etkisi altında daha derin havzalarda tortu taşınması ve birikmesi ve atmosferik birikim, gölün daha derin kısımlarında biriken en yaygın metal kirleticiler için aktif rol oynar; örneğin Pb, Cr, Zn, Cd ve Cu (Ünlü ve Alpar, 2016). Bu sebeple de İznik Gölü havzasında oluşan bu ağır metallerin takibi kirlilik açısından oldukça önemlidir.

Tablo 4.4.'de Sölöz için yapılmış olan tüm ağır metal denemelerinin girdi verileri, ara katman sayısı, aktivasyon fonksiyonu, çıktı verisi, eğitim-test aşamasındaki hata kareleri toplamı (SSE) ve korelasyon katsayısı (R^2) değerleri özet tablo halinde görülmektedir.


Tablo 4.4. Sölöz verilerinin YSA performans değeri özet tablosu

GİRDİLER	ARA KATMAN	AKTİVASYON FONKSİYONU (ARA KATMAN)	ÇIKTI	EĞİTİM SSE	TEST SSE	R ²
PH,İletkenlik,ÇO,KOİ,BOİ,T,Renk	7	Hyperbolic tangent	SN	0.000	2,63E-08	0.990
PH,İletkenlik,ÇO, KOİ,BOİ,T, Renk	7	Sigmoid	As	0.001	0.066	0.844
PH,İletkenlik,ÇO, KOİ,BOİ,T, Renk	7	Hyperbolic tangent	Fe	0.096	0.369	0.804
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Sigmoid	Mn	0.049	0.046	0.551
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Sigmoid	Cu	0.006	1,87E-08	0.962
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Hyperbolic tangent	Pb	0.001	0.009	0.995
PH,İletkenlik,ÇO,BOİ KOİ,T, Renk	7	Hyperbolic tangent	Sb	6,66E-09	0.324	0.885
PH,İletkenlik,ÇO,KOİ,T	3	Hyperbolic tangent	Al	0.305	0.008	0.909
PH,İletkenlik,ÇO,KOİ,T	3	Hyperbolic tangent	B	1,60E-06	0.144	0,304
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Hyperbolic tangent	Cr	0.003	5,14E-06	0.989
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Hyperbolic tangent	Cd	0.007	0.020	0.841
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Hyperbolic tangent	Ni	0.008	0.004	0.917
PH,İletkenlik,ÇO,KOİ,BOİ,T	4	Hyperbolic tangent	Zn	9,76E-06	0.069	0.759
PH,İletkenlik,ÇO,KOİ,BOİ,T,Renk	7	Hyperbolic tangent	Se	2,08E-07	0.000	0.995
PH,İletkenlik,ÇO,KOİ,BOİ,T,Renk	7	Hyperbolic tangent	Ag	0.011	0.687	0.809

4.5. Bağımsız Değişkenin Önemi


Ağır metallerin kirlilik tahmininde girdi olarak kullanılan parametrelerin etki değerlerini belirlemek için programda testi yapılmıştır.

Bağımsız değişkenin önemi, modelin yüzde olarak ifade edilen bağımlı değişkenleri ne ölçüde tahmin ettiğinin bir ölçüsüdür (Abbas ve ark., 2019).




Şekil 4.121. Karasu bağımsız değişken grafiği

Karasu için en etkili parametrenin iletkenlik olduğu ardından ise BOİ, renk(res525nm), pH, ÇÖ olduğu Şekil 4.121.'de görülmektedir.




Şekil 4.122. Olukdere bağımsız değişken grafiği

Olukdere için en etkili parametrenin KOİ olduğu ardından BOİ ve ÇO olduğu Şekil 4.122.'de görülmektedir.



Şekil 4.123. Kırandere bağımsız değişken grafiği

Kırandere için en etkili parametrenin KOİ olduğu ardından sıcaklık, pH, renk(res436nm), iletkenlik, renk(res620nm) olduğu Şekil 4.123.'de görülmektedir.



Şekil 4.124. Sölöz bağımsız değişken grafiği

Sölöz için en etkili parametrenin sıcaklık olduğu ardından iletkenlik, ÇO, pH, renk(Res436nm) olduğu Şekil 4.124.'de görülmektedir.

BÖLÜM 5. TARTIŞMA VE SONUÇ

Su kalitesinin insan sağlığı üzerindeki önemi iyi bilinmekte ve son yıllarda büyük ilgi görmektedir. Günümüzde akarsular, endüstriyel faaliyetlerin çoğalması ve nüfusun hızla artması nedeniyle yoğun kirliliğe maruz kalmaktadır. Özellikle göllerin kimyasal kirliliği, insan sağlığı ve sucul ekosistemler için en büyük tehditlerden biri olmaktadır. Bu sebeple de sulardaki kirlilik miktarlarının izlenmesi, takibi su kaynaklarının sürdürülebilir kullanımı için büyük önem arz etmektedir. Bununla birlikte, doğrudan gerçekleştirilen ölçümler büyük maliyet, zaman ve işçilik gerektirirken, YSA modellemeleri su kalitesi izleme maliyetini azaltmak için alternatif bir çözüm sunmaktadır. YSA tahmin çalışmaları sayesinde su kirliliği takibinde maliyet ve zamandan oldukça tasarruf etmek mümkündür.

Bu çalışma da, İznik Gölü'ndeki ağır metal parametrelerinin yapay sinir ağı ile tahmin çalışmaları yapılmış ve kirlilik parametrelerinin izlenmesi için en uygun modeller denenmiştir. İstatiksel bir yöntem olan IBM SPSS V.23 programında neural network modülü kullanılarak çalışılmıştır. BUSKİ Genel Müdürlüğünden 2015-2021 yılları arasındaki Karasu, Olukdere, Kırandere, Sölöz için pH, iletkenlik, biyolojik oksijen ihtiyacı, kimyasal oksijen ihtiyacı, çözünmüş oksijen, sıcaklık, renk parametreleri; Karsak Deresi için ise ağır metal parametreleri (Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag) alınmıştır. 4 parametre için (Sn, Sb, Se, Ag) bazı yıllarda ölçüm yapılmadığından dolayı programda Se parametresi için 2017-2021 yılları arası, Sn, Sb, Ag parametrelerinin 2018-2021 yılları baz alınmıştır. Bu parametreler kullanılarak çeşitli denemeler yapılarak YSA temelli bir model oluşturmak amaçlanmıştır. Girdi parametreleri olarak pH, iletkenlik, BOİ, KOİ, ÇO, sıcaklık ve renk parametreleri seçilmiştir. Çıktı parametresi olarak ise her bir ağır metal parametresi programda tek tek baz alınmıştır. 4 gözlem noktası içinde denemeler ayrı ayrı yapılmıştır. 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 7 arasında deęişiklik göstermiştir. Sonuçların performanslarını deęerlendirmek için hata kareleri toplamı (SSE) ve belirleme katsayısı (R^2) kullanılmıştır.

Karasu için oluşturulan YSA modellerinde çıkan R^2 deęerleri Sn, As, Fe, Mn, Cu, Pb, Al, B, Cr, Cd, Ni, Zn, Se, Ag için korelasyon katsayısı sırasıyla 0.999, 0.985, 0.963, 0.859, 0.987, 0.757, 0.998, 0.636, 0.937, 0.723, 0.902, 0.447, 0.872, 0.993, 0.986 bulunmuştur. Olukdere için oluşturulan YSA modellerinde çıkan R^2 deęerleri Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag için korelasyon katsayıları sırasıyla 0.997, 0.986, 0.810, 0.972, 0.990, 0.922, 0.949, 0.852, 0.743, 1.000, 0.926, 0.997, 0.967, 0.999, 0.884 bulunmuştur. Kırandere için oluşturulan YSA modellerinde çıkan R^2 deęerleri Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag için korelasyon katsayısı sırasıyla 0.966, 0.932, 0.993, 0.820, 0.873, 0.989, 1.000, 0.894, 0.835, 0.981, 0.939, 0.988, 0.937, 0.851, 0.977 bulunmuştur. Sölöz için oluşturulan YSA modellerinde çıkan R^2 deęerleri Sn, As, Fe, Mn, Cu, Pb, Sb, Al, B, Cr, Cd, Ni, Zn, Se, Ag için korelasyon katsayısı sırasıyla 0.990, 0.844, 0.804, 0.551, 0.962, 0.995, 0.885, 0.909, 0.304, 0.989, 0.841, 0.917, 0.759, 0.995, 0.809 bulunmuştur. Çıkan R^2 sonuçları çoęunlukla 1'e yakın geldięi için YSA'nın tahmin etme doęruluęunu ispatlar niteliğinde olmuştur. Hata kareleri toplamı (SSE) deęerleri test ve eęitim deęerleri, baz alınan modellerin test ve eęitim sürecinde 0'a yakın deęerler almış olup, tahmin çalışmasında IBM SPSS V.23 modülünün doęru sonuçlar verebildięi görölmüştür. Su kaynaklarının iyi yönetilmesi için göl kirlilięi iyi tanımlanmalı, izlenmeli ve modellenmelidir. YSA modelinin, göldeki ağır metallerin varlıęını tahmin etmek için kullanımı kolay ve uygun maliyetli bir alternatif sunduęu 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.
- Açıklalın, S. 2007. Atıksu arıtma tesisi veriminin yapay sinir ağları ile tahmin edilmesi Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Çevre Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Adamowski, J. F. ve Karapataki, C. (2012). Comparison of multivariate regression and artificial neural networks for peak urban water-demand forecastin: evaluation of different ann learning algorithms. *Journal of Hydrologic Engineering*, 17 (7), 834–836.
- Adıyaman, F. (2007) Talep tahmininde yapay sinir ağlarının kullanılması İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, İstanbul.
- Agah, A., & Soleimanpournoghadam, N. (2020). Design and implementation of heavy metal prediction in acid mine drainage using multi-output adaptive neuro-fuzzy inference systems (ANFIS)-a case study. *International Journal of Mining and Geo-Engineering*, 54(1), 59-64.
- Akbulak, C.(2006) İznik Gölü Depresyonunun Beşeri ve İktisadi Coğrafya Açısından İncelenmesi İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Coğrafya Anabilim Dalı, Doktora Tezi, İstanbul.
- Akın M., Akın G.(2007), Suyun önemi, Türkiye’de su potansiyeli, su havzaları ve su kirliliği, Ankara Üniversitesi Dil ve Tarih-Coğrafya Dergisi, 47(2), 105-118.
- Akiner, M. E., & Akiner, İ. (2021). Water quality analysis of drinking water resource lake Sapanca and suggestions for the solution of the pollution problem in the context of sustainable environment approach. *Sustainability*, 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.
- Anderson, C. W. (1989). Learning to control an inverted pendulum using neural networks. *IEEE Control Systems Magazine*, 9(3), 31-37.
- Anonim (2021), İznik Gölü Sulak Alan Yönetim Planı (2021-2025). Tarım ve Orman Bakanlığı 2. Bölge Müdürlüğü.

- Ardel, A. (1943). "Marmara Bölgesinin Güneydoğu Havzalarının Morfolojik Karakterleri" Türk Coğrafya Dergisi. Sayı II., s. 160-171, Ankara.
- Arefin, M.T., Rahman, M.M., Wahid-U-Zzaman, M., Kim, J.-E., 2016. Heavy metal contamination in surface water used for irrigation: functional assessment of the Turag River in Bangladesh. *J. Appl. Biol. Chem.* 59, 83–90.
- 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.
- Ataseven, B. (2013). Yapay sinir ağları ile öngörü modellemesi. *Öneri Dergisi*, 10(39), 101-115.
- Awwa, A. w.e.f. (2005). Standard methods for the examination of water and wastewater. APHA WEF AWWA.
- Bayatzadeh Fard, Z., Ghadimi, F., & Fattahi, H. (2017). Use of artificial intelligence techniques to predict distribution of heavy metals in groundwater of Lakan lead-zinc mine in Iran. *Journal of Mining and Environment*, 8(1), 35-48.
- Berger, B., & Dallinger, R. (1993). Terrestrial snails as quantitative indicators of environmental metal pollution. *Environmental monitoring and assessment*, 25(1), 65-84.
- Bhateria, R., & Jain, D. (2016). Water quality assessment of lake water: a review. *Sustainable Water Resources Management*, 2(2), 161-173.
- Biney, C., Amuzu, A.T., Calamari, D., Kaba, N., Mbome, I.L., Naeve, H., Ochumba, P.B. O., Osibanjo, O., Radegonde, V. and Saad, M.A.H. 1994. Review of heavy metals in Review of pollution in the African aquatic environment edited by Davide Calamari, FAO Fisheries Reports No. 471, pp. 7–43
- Budakoğlu, M. (2000). İznik Gölü Hidrojeokimyası ve sonuçların jeostatistik değerlendirmesi (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- Chen, W. B., & Liu, W. C. (2014). Artificial neural network modeling of dissolved oxygen in reservoir. *Environmental monitoring and assessment*, 186(2), 1203-1217.
- Chou, J. S., Ho, C. C., & Hoang, H. S. (2018). Determining quality of water in reservoir using machine learning. *Ecological informatics*, 44, 57-75.
- Çelik, B. (2008). Yapay Sinir Ağları Metodolojisi İle Zaman Serisi Analizi: Teori ve Uygulama (Doctoral dissertation, Marmara Üniversitesi (Turkey)).
- Davis, M. L. (2010). Water and wastewater engineering: design principles and practice. McGraw-Hill Education.
- Dede, A. (2009). İznik göl suyu kalite parametrelerinin yapay sinir ağlarıyla değerlendirilmesi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Bölümü, Yüksek Lisans Tezi.

- Dereli E. M., Ertürk, A., ve Çakmakçı, M., (2017). Yüzeysel Sularda Ağır Metallerin Etkileri ve Ötrofikasyon İle İlişkisi. *Türkiye Dil Bilimleri Dergisi*. 214-230.
- DeZuane, J. (1997). *Handbook of drinking water quality*. John Wiley & Sons.
- Doğan, E., Kocamaz, U., Utkucu, M., Yıldırım, E., 2016. Modelling Daily water level fluctuations of Lake Van (Eastern Turkey) using Artificial Neural Networks. *Fundam. Appl. Limnol.*, 187(3), 177– 189
- Doğan, O. (2016). Uyarlamalı sinirsel bulanık çıkarım sisteminin (ANFIS) talep tahmini için kullanımı ve bir uygulama. *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 31(1), 257-288.
- Duman, F., Aksoy, A., & Demirezen, D. (2007). Seasonal variability of heavy metals in surface sediment of Lake Sapanca, Turkey. *Environmental monitoring and assessment*, 133(1), 277-283.
- Elmas Çetin, (2003), *Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*, Seçkin Yayınları: Ankara.
- Elzwayie, A., El-Shafie, A., Yaseen, Z. M., Afan, H. A., & Allawi, M. F. (2017). RBFNN-based model for heavy metal prediction for different climatic and pollution conditions. *Neural Computing and Applications*, 28(8), 1991-2003.
- Erdem, F. (2021). Atıksulardan Zn Gideriminin Yapay Sinir Ağı (YSA) ile Modellenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (24), 335-342.
- Ergezer, H., Dikmen, M., & Özdemir, E. (2003). Yapay sinir ağları ve tanıma sistemleri. *PiVOLKA*, 2(6), 14-17.
- Eyupoglu, V., Eren, B., Dogan, E. (2010). Prediction of Ionic Cr (VI) Extraction Efficiency in Flat Sheet Supported Liquid Membrane Using Artificial Neural Networks (ANNs). *Int. J. Environ. Res.*, Volume:4, Number:3, 463-470.
- Fausett, L. V., & Elwasif, W. (1994, June). Predicting performance from test scores using backpropagation and counterpropagation. In *Proceedings of 1994 IEEE International Conference on Neural Networks (ICNN'94)* (Vol. 5, pp. 3398-3402). IEEE.
- Fırat, M. (2002). Doğrusal ve kıvrımlı akarsulara yerleştirilen köprü ayakları etrafında meydana gelen oyulma derinliğinin yapay sinir ağları ile belirlenmesi (Doctoral dissertation, Pamukkale Üniversitesi).
- Fırat, M., & Güngör, M. (2004). Askı madde konsantrasyonu ve miktarının yapay sinir ağları ile belirlenmesi. *Teknik Dergi*, 15(73).
- 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.
- Green, S. M., Machin, R., & Cresser, M. S. (2008). Effect of long-term changes in soil chemistry induced by road salt applications on N-transformations in roadside soils. *Environmental pollution*, 152(1), 20-31.

- Gupta, T., & Paul, M. (2013). The seasonal variation in ionic composition of pond water of Lumding, Assam, India. *Current World Environment*, 8(1), 127-131.
- H. Türkmenler, M. Pala, R. Can ve N. Çağlar, «Yapay Sinir Ağı Modeli Kullanılarak İleri Biyolojik Atıksu Arıtma Tesislerinde Kimyasal Oksijen İhtiyacı Çıkış Konsantrasyonlarının Tahmini,» %1 içinde 2nd International Symposium On Environment And Morality, Adıyaman, 2014.
- Hamzaçebi, C. (2011). Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı, Matlab ve Neuro Solutions Uygulamalı. (1. Baskı). Ekin Basım Yayın Dağıtım, Bursa.
- 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).
- Han YM, Cao JJ, Kenna TC, Yan B, Jin ZD, Wu F, An ZS (2011) Distribution and ecotoxicological significance of trace element contamination in a *150 year record of sediments in Lake Chaohu, Eastern China. *J Environ Monit* 13(3):743–752
- Haykır, S., 1999. Neural Networks: A Comprehensive Foundation Second Edition, prentice Hall, New Jersey.
- Hussein, H., Ibrahim, S. F., Kandeel, K., Moawad, H. (2004). Biosorption Of Heavy Metals From Waste Water Using *Pseudomonas* sp., *Electronic Journal of Biotechnology*, Cilt 1, No 7, 38-46.
- Islam, M. S., Khalid, Z. B., Gabar, S. M., & Yahaya, F. M. (2022). Heavy metals pollution sources of the surface water of the Tunggak and Balok river in the Gebeng industrial area, Pahang, Malaysia. *International Journal of Energy and Water Resources*, 1-8.
- İşeri, İ. & Arıman, S. (2019). Sedimandaki Ağır Metal Konsantrasyonunun Çoklu Değişken Regresyon Modelleri ve Çok Katmanlı Algılayıcı Ağ Modeli ile Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (Özel Sayı), 389-397.
- Jana, S., Mahanti, B., Sur, D., 2017. Presence and source of toxic heavy metals in *camellia sinensis* shoot. *Int. J. Pharmaceut. Sci. Res.* 8 (6), 2402–2407 <https://doi.org/10.13040/IJPSR.0975-8232.86.2402-07>.
- Järup, L. (2003). Hazards of heavy metal contamination. *British medical bulletin*, 68(1), 167-182.
- Jia J, Jian H, Xie D, Gu Z, Chen C (2017) Multi-Perspectives' Comparisons and Mitigating Implications for the COD and NH3-N Discharges into the Wastewater from the Industrial Sector of China. *Water* 9:201.
- Kaewsarn, P. (2002). Biosorption Of Copper (II) From Aqueous Solutions By Pre-Treated Biomass Of Marine Algae *Padina* sp., *Chemosphere*, Cilt 47, No 10, 1081-1085.
- Kahvecioğlu, Ö., Kartal G, Güven, A. ve Timur S, 2009. Metallerin Çevresel Etkileri-I, İTÜ, http://www.metalurji.org.tr/dergi/dergi136/d136_4753.pdf (Erişim Tarihi:12 Mart 2011).

- Kalogirou, S. A. (1999). Applications of artificial neural networks in energy systems. *Energy Conversion and Management*, 40(10), 1073-1087.
- Kılıç, G. (2015). Yapay Sinir Ağları ile Yemekhane Günlük Talep Tahmini. Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği, Yüksek Lisans Tezi.
- Kulkarni, A. D. (1994). Artificial neural networks for image understanding. New York: Van Nostrand Reinhold.
- Linkens, D. A., & Nyongesa, H. O. (1996). Learning systems in intelligent control: an appraisal of fuzzy, neural and genetic algorithm control applications. *IEE Proceedings-Control Theory and Applications*, 143(4), 367-386.
- Lu H, Li H, Liu T, Fan Y, Yuan Y, Xie M, Qian X (2019) Simulating heavy metal concentrations in an aquatic environment using artificial intelligence models and physicochemical indexes. *Sci Total Environ* 694:133591
- Mahaffey, K. R. (1983). Sources of lead in the urban environment. *American Journal of Public Health*, 73(12), 1357-1358.
- Maier, H. R., & Dandy, G. C. (1996). The use of artificial neural networks for the prediction of water quality parameters. *Water resources research*, 32(4), 1013-1022.
- Malik, D., Singh, S., Thakur, J., Singh, R.K., Kaur, A., Nijhawan, S., 2014. Heavy metal pollution of the Yamuna River: an introspection. *Int. J. Curr. Microbiol. Appl. Sci.* 3 (10), 856–863.
- Masters, T., 1993. *Practical Neural Network Recipes in C++*, Academic Pres, USA.
- 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. I., Tchobanoglous, G., Burton, FL, Stensel, HD (2003). *Wastewater Engineering: Treatment and Reuse*.
- Nabiyev, V. V. (2012). Yapay Zekâ: İnsan-Bilgisayar Etkileşimi. Baskı Yeri: Seçkin Yayıncılık.
- 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.
- Nhantumbo C, Carvalho F, Uvo C, Larsson R, Larson M (2018) Applicability of a processes-based model and artificial neural networks to estimate the concentration of major ions in rivers. *J Geochem Explor* 193:32–40.

- O. Özkan, C. Kınacı ve Ş. Sağıroğlu, «Çözünmüş Oksijen Değişiminin Yapay Sinir Ağları ile Belirlenmesi: Kızılırmak Nehri Örneği,» İTÜ Mühendislik Dergisi, cilt 5, no. 3, pp. 30-38, 2006.
- OBIEWA, J. O., KARIUKI, 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).
- Oktem, Y. A., Gumus, M., Yilmaz, G. B. (2012): The potential sources of pollution affecting the water quality of Lake Iznik. – *International Journal of Electronics, Mechanical and Mechatronics Engineering* 2(3): 225-232.
- Öcal, Onur. 2007. Yapay sinir ağları algoritması kullanılarak akarsu havzalarında yağış-akış-katı madde ilişkisinin belirlenmesi. Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği, Yüksek Lisans Tezi.
- Öztemel, E. (2003). Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.
- Öztemel, E. (2006). Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Pawar, A. L. (2010). Seasonal variation in physicochemical quality of Lonar Lake water. *Journal of chemical and pharmaceutical research*, 2(4), 225-231.
- Penn, Pauer, Mihelcic (2003) *Environmental and ecological chemistry*, vol 2.
- Rooki, R., Doulati Ardejani, F., Aryafar, A., & Bani Asadi, A. (2011). Prediction of heavy metals in acid mine drainage using artificial neural network from the Shur River of the Sarcheshmeh porphyry copper mine, Southeast Iran. *Environmental earth sciences*, 64(5), 1303-1316.
- Sakan, S., Đorđević, D., Dević, G., Relić, D., Anđelković, I., & Đuričić, J. (2011). A study of trace element contamination in river sediments in Serbia using microwave-assisted aqua regia digestion and multivariate statistical analysis. *Microchemical Journal*, 99(2), 492-502.
- Salman, H. A., Ibrahim, M. I., Tarek, M. M., & Abbas, H. S. (2014). Biosorption of heavy metals: a review. *Journal of Chemical Science and Technology*, 3(4), 74-102.
- Saraç, T. (2004). Artificial Neural Networks. Seminar Project, Gazi University, Industrial Engineering Department, Ankara.
- Sarı, M. Yapay sinir ağları ve bir otomotiv firmasında satış talep tahmini uygulaması, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi, 2016.
- Sarkar, A., Arora, S., Shekhar, S., 2016. Boron in groundwater of National Capital Region Delhi. *J. Water Pollut. Purif. Res.* 3 (2), 30–36.

- Sarkar, A., Shekhar, S., 2018. Iron contamination in the waters of Upper Yamuna basin. *Groundwat. Sustain. Dev.* 7, 421–429. <https://doi.org/10.1016/j.gsd.2017.12.011>.
- Sengorur, B., Dogan, E., Koklu, R. ve Samandar, A. (2005). Dissolved oxygen estimation using artificial neural network for water quality control. *Electronic Letters on Science and Engineering*, 1 (2), 13–16.
- Seven, A., Temmuz 1993. Yapay Sinir Ağları ile Doku Sınıflandırma, Yüksek Lisans Tezi, İ.T.Ü Fen Bilimleri Enstitüsü, İstanbul.
- SHAKERI, A. A., GHOLAMALIZADEH, A. A., & Soltani, J. (2013). Artificial neural network (ann) approach for predicting cu concentration in drinking water of chahnimeh1 reservoir in Sistan-Balochistan, Iran.
- Sharpley A.N., Daniel T., Sims T., Lemunyon J., Stevens R., Parry R., *Agricultural Phosphorus and Eutrophication*, 2nd ed. U.S. Department of Agriculture, Agricultural Research Service, ARS–149, 44 pp. 2003.
- Simpson, P. K., 1990. *Artificial Neural Systems*, Pergamon Pres.
- Singh, K. P., Basant, A., Malik, A. ve Jain, G. (2009). Artificial neural network modeling of the river water quality—a case study. *Ecological Modelling*, 220 (6), 888–895.
- Song, T., Su, X., He, J., Liang, Y., & Zhou, T. (2018). Source apportionment and health risk assessment of heavy metals in agricultural soils in Xinglonggang, Northeastern China. *Human and Ecological Risk Assessment: An International Journal*, 24(2), 509–521.
- Sönmez, İ., Kaplan, M., & Sönmez, S. (2008). Kimyasal gübrelerin çevre kirliliği üzerine etkileri ve çözüm önerileri. *Derim*, 25(2), 24–34.
- Spellman, F. R. (2017). *The drinking water handbook*. CRC Press.
- Swietlicka I, Sujak A, Muszyński S, Świetlicki M (2017) The application of artificial neural networks to the problem of reservoir classification and land use determination on the basis of water sediment composition. *Ecol Indic* 72:759–765
- Talab, S.A., Goher, M.E., Ghannam, H.E., Abdo, M.H., 2016. Chemical compositions and heavy metal contents of *Oreochromis niloticus* from the main irrigated canals (Rayahs) of Nile Delta. *Egypt. J. Aquat. Res.* 42, 23–31.
- TEKSOY, A., KATİP, A., & NALBUR, B. E. (2019). KARSAK DERESİ'NDE SU KALİTESİNİN İZLENMESİ VE GEMLİK KÖRFEZİ'NE ETKİSİNİN DEĞERLENDİRİLMESİ. *Uludağ University Journal of The Faculty of Engineering*, 24(1), 171–180.
- 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.

- Ünlü, S., & Alpar, B. (2016). An assessment of trace element contamination in the freshwater sediments of Lake Iznik (NW Turkey). *Environmental Earth Sciences*, 75(2), 1-14.
- Viehberg FA, U" lgen UB, Damcı E, Franz SO, O" n Akc,er S, Roeser PA, C, ag˘ atay MN, Litt T, Melles M (2012) Seasonal hydrochemical changes and spatial sedimentological variations in Lake Iznik (NW Turkey). *Quat Int* 274:102–111
- Wedepohl, K. H. (1991). The composition of the upper earth's crust and the natural cycles of selected metals. *Metal in natural raw materials, natural resources. Metals and their compounds in the environment. Occurrence, analysis and biological relevance*, 3-17.
- WWF (2011): Protection of Turkey's Wetlands Problems and Solution Suggestions. – World Wildlife Fund Turkey Information Note.
- X. Wang, L. Wuxing, L. Zhen'gao, T. Ying, P. Christie, and P. Yongming, "Effects of long-term fertilizer applications on peanut yield and quality and on plant and soil heavy metal accumulation," *Pedosphere*, 2017.
- Yazıcı, Ö. (2020). İznik-Mekece Arasında Jeomorfolojik Gözlemler . *Anemon Muş Alparslan Üniversitesi Sosyal Bilimler Dergisi* , 8 (1) , 125-138 .
- Zaidi, J., Pal, A., 2017. Review on heavy metal pollution in major lakes of India: Remediation through plants. *Afr. J. Environ. Sci. Technol.* 11 (6), 255–265.
- Zalama, E., Gaudiano, P., & Coronado, J. L. (1995). A real-time, unsupervised neural network for the low-level control of a mobile robot in a nonstationary environment. *Neural networks*, 8(1), 103-123.
- Zhao X, Huang X, Liu Y (2012) Spatial autocorrelation analysis of Chinese inter-provincial industrial chemical oxygen demand discharge. *Int J Environ Res Public Health* 9:2031–2044
- Zhou, Z. H., & Chen, S. F. (2002). Neural network ensemble. *CHINESE JOURNAL OF COMPUTERS-CHINESE EDITION-*, 25(1), 1-8.

ÖZGEÇMİŞ

Adı Soyadı :Deniz KASAPOĞULLARI

ÖĞRENİM DURUMU

Derece	Eğitim Birimi	Mezuniyet Yılı
Yüksek Lisans	Sakarya Üniversitesi / Fen Bilimleri Enstitüsü / Çevre Mühendisliği	Devam ediyor
Lisans	Sakarya Üniversitesi / Mühendislik Fakültesi / Çevre Mühendisliği	2018
Lise	Bursa Cumhuriyet Lisesi	2013

İŞ DENEYİMİ

Yıl	Yer	Görev
2020-2021	Jitpol Poliüretan San. Tic. Ltd. Şti.	Planlama Mühendisi
2019-2020	Netnehir Osgb	İsg Uzmanı

YABANCI DİL

İngilizce