



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

ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI

**YÜZEYSEL SULARDA BENZEN MİKROKİRLETİCİSİNİN TESPİTİ
VE MODELLENMESİ: ORHANELİ ÇAYI ÖRNEĞİ**

DOKTORA TEZİ

Özgül ÇİMEN MESUTOĞLU

DANIŞMAN

Dr. Öğretim Üyesi Oğuzhan GÖK

AKSARAY, 2020

Aksaray Üniversitesi Fen Bilimleri Enstitüsü'nün 152311201 numaralı Doktora öğrencisi Özgül ÇİMEN MESUTOĞLU tarafından hazırlanan “YÜZEYSEL SULARDA BENZEN MİKROKİRLETİCİSİNİN TESPİTİ VE MODELLENMESİ: ORHANELİ ÇAYI ÖRNEĞİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Çevre Mühendisliği Anabilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğretim Üyesi Oğuzhan GÖK

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum

Üye: Prof. Dr. Hatim ELHATİP

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Üye: Doç. Dr. İlkay ÖZAYTEKİN

Konya Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Üye: Doç. Dr. Hakan ÇELEBİ

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Üye: Dr. Öğretim Üyesi Sezen KÜÇÜKÇONGAR

Konya Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Tez Savunma Tarihi: 24/06/2020

Jüri tarafından kabul edilen bu tezin Doktora Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....


Doç. Dr. Mehmet Ali HINIS

Fen Bilimleri Enstitüsü Müdürü

DOĞRULUK BEYANI

Doktora tezi olarak sunduğum bu çalışmayı, akademik kurallara ve bilimsel etik, ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın yazdığımı, yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, çalışmamda kullandığım verilerin orijinalliğini ve her türlü intihalden uzak olduğunu beyan ederim.

Enstitü tarafından belli bir zamana bağlı olmaksızın, tezimle ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacağımı bildiririm.


Özgül ÇİMEN MESUTOĞLU

TEŞEKKÜR

Doktora eğitimime ilk başladığım andan itibaren bütün eğitimim boyunca özveriyle bilgisini, sabrını ve insani ilgisini esirgemeyen, bana yol gösteren tez danışmanım Sayın Dr. Öğr. Üyesi Oğuzhan GÖK'e teşekkürlerimi sunarım.

Tez çalışmam boyunca yardımlarını esirgemeyen ve değerli görüşleri ile çalışmama katkılar sağlayan kıymetli hocalarım Doç. Dr. Hakan Çelebi ve Dr. Öğr. Üyesi Sezen KÜÇÜKÇONGAR'a teşekkürlerimi sunarım.

2211/C Yurt İçi Öncelikli Alanlar Doktora Burs Programı kapsamında sağladığı destekten ötürü TÜBİTAK-Bilim İnsanı Destek Programları Başkanlığı (BİDEB) birimine teşekkürlerimi sunarım.

Veri paylaşımı ve gerekli izinler konusunda desteklerini esirgemeyen Meteoroloji Genel Müdürlüğü ve Devlet Su İşleri 3. Bölge Müdürlüğü'ne çok teşekkür ederim.

Çalışmalarım sırasında bana yardımcı olan ve desteklerini esirgemeyen arkadaşlarım Doç. Dr. Alper ALVER ve Dr. Öğretim Üyesi Emine BAŞTÜRK'e teşekkürlerimi sunarım.

Arazi çalışmalarım boyunca bana yardımcı olan Sayın Maden Yüksek Mühendisi Meriç KAYA'ya teşekkür ederim.

Hayatım boyunca sevgi ve ilgilerini üzerimden hiç eksik etmeyen, beni her konuda maddi ve manevi olarak sonuna kadar destekleyen, beni bugünlere getiren annem Şengül ÇİMEN ve babam Mustafa Kemal ÇİMEN'e en içten teşekkürlerimi ve sevgilerimi sunarım.

Her mutlulukta ve zorlukta yanımda olan, akademik hayatım boyunca her sıkıntımı dinleyen ve yardımlarını esirgemeyen, çok sevdiğim manevi ailem ve can arkadaşlarım olan Sayın Nihan ERMiŞ PALALIOĞLU ve Ziraat Yüksek Mühendisi Ayşe Nur BASAR'a sonsuz sevgi ve teşekkürlerimi sunarım.

Ve son olarak da varlığıyla bana huzur veren, tüm çalışmalarım boyunca beni hiç yalnız bırakmayan, her konuda destekleyen ve yardımcı olan, benimle sabahlayan, cesaret veren meslektaşım, can yoldaşım ve eşim Dr. Mehmet MESUTOĞLU'na tüm kalbimle teşekkür eder, sevgilerimi sunarım.

Özgül ÇİMEN MESUTOĞLU

AKSARAY, 2020

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
ÖZET.....	iii
ABSTRACT	iv
ŞEKİLLER DİZİNİ	v
ÇİZELGELER DİZİNİ	vi
SİMGELER VE KISALTMALAR	vii
1. GİRİŞ.....	1
1.1 Çalışmanın Amacı ve Önemi	3
2. KAYNAK ARAŞTIRMASI.....	6
2.1 Mikrokirleticiler	6
2.2 İstatistiksel Çalışma.....	13
2.3 Temel Bileşen Analizi	14
2.4 Yapay Sinir Ağları.....	15
2.4.1 YSA'nın üstünlükleri.....	16
2.4.2 YSA'nın yapısı	18
2.4.3 YSA'nın elemanları	20
2.4.4 YSA'nın sınıflandırılması.....	28
2.4.5 Yapay sinir ağı kullanımının avantaj ve dezavantajları.....	30
2.5 Literatür Özeti	32
3. MALZEME VE YÖNTEM	38
3.1 Çalışma Alanı	38
3.2 Veri Toplama ve Analiz Yöntemi	44
3.2.1 Kullanılan kimyasallar.....	45
3.2.2 Analitik metotlar	45
3.3 İstatistiksel Yöntem.....	49
3.4 Temel Bileşen Analizi Uygulaması.....	50
3.5 Yapay Sinir Ağları ile Modelleme Çalışması.....	50
3.5.1 Veri seti.....	50
4. ARAŞTIRMA BULGULARI VE TARTIŞMA.....	53
4.1 Çalışma Alanının Meteorolojik Verileri.....	53
4.2 Çalışma Alanının Fiziksel ve Kimyasal Özellikleri	55
4.3 Orhaneli Çayı Boyunca Elde Edilen Benzen Sonuçları	58
4.4 YSA'daki Bileşenlerin İstatistiksel Açından Değerlendirilmesi.....	65
4.5 Temel Bileşen Analizi Sonuçlarının Değerlendirilmesi.....	66
4.6 Orhaneli Çayı'ndaki Değişkenlerin Korelasyon Analizi.....	71
4.7 Orhaneli Çayı'ndaki Benzen Konsantrasyonlarının YSA Model Sonuçları ...	72
5. SONUÇ VE ÖNERİLER.....	83
KAYNAKLAR.....	87
ÖZGEÇMİŞ.....	98

DOKTORA TEZİ

YÜZEYSEL SULARDA BENZEN MİKROKİRLETİCİSİNİN TESPİTİ VE MODELLENMESİ: ORHANELİ ÇAYI ÖRNEĞİ

Özgül ÇİMEN MESUTOĞLU

**Aksaray Üniversitesi
Fen Bilimleri Enstitüsü
Çevre Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğr. Üyesi Oğuzhan GÖK

ÖZET

Öncelikli mikrokirleticiler, günümüzde gittikçe artan konsantrasyonları ve su ortamlarındaki dirençli yapıları sebebiyle önemli bir araştırma konusudur. Özellikle, madencilik faaliyetleri, termik santrallerin yaygınlaşması, motorlu taşıtların kullanımının artması ve sanayinin gelişmesi ile öncelikli mikrokirletici varlığına neden olan kaynaklar gün geçtikçe artmaktadır.

Bu çalışmada sanayi ve madencilik faaliyetlerinin yoğun olarak yapıldığı, termik santrallerin bulunduğu bir bölgede bulunan Orhaneli Çayı'nda öncelikli mikrokirleticilerden olan benzen kirleticisinin 12 ay boyunca izlemesi yapılmıştır.

Modelleme çalışmasında yapay sinir ağları kullanılarak benzen mikrokirleticisinin tahmin modeli yapılmış olup; meteorolojik, bazı fiziksel ve kimyasal parametrelerin benzen konsantrasyonları üzerine olan etkileri incelenmiştir. Yapay sinir ağları yapısı, bir girdi katmanı, bir gizli katman ve bir de çıktı katmanından oluşmaktadır. Temel bileşen analizi uygulamasından sonra yapay sinir ağları girdi parametreleri olarak yağış, sıcaklık, nem, pH, debi, çözünmüş oksijen, iletkenlik, toplam organik karbon ve toplam azot kullanılmıştır. Ağ oluşturulurken 11 farklı geri yayılım algoritması kendi içerisinde ortalama karesel hata değerleri ile karşılaştırılmış ve Levenberg – Marquardt algoritması en iyi eğitim algoritması olarak belirlenmiştir. Seçilen eğitim algoritması için üretilen benzen konsantrasyonu tahmininde gizli katmanda kullanılacak optimize nöron sayısı 6 olarak bulunmuştur. Optimize edilen üç katmanlı yapay sinir ağları modeli (9:6:1) için korelasyon katsayısı (R^2) 0.9889 olarak elde edilmiştir.

Yapılan çalışma sonucunda açıkça görülmektedir ki, yapay sinir ağları tabanlı model sonuçlarının yüzeysel sulardaki benzen konsantrasyonu için kullanımı oldukça uygundur.

Anahtar Kelimeler: Benzen, Modelleme, Orhaneli Çayı, Öncelikli Mikrokirleticiler.

Haziran, 2020; 100 sayfa

PhD. THESIS

DETERMINATION AND MODELING OF BENZENE MICROPOLLUTANT IN SURFACE WATERS: ORHANELİ RIVER STUDY

Özgül ÇİMEN MESUTOĞLU

**Aksaray University
Graduate School of Natural and Applied Sciences
Department of Environmental Engineering**

Supervisor: Dr. Oğuzhan GÖK

ABSTRACT

Priority micro-pollutants are an important research topic today due to their increasing concentration and their resistant structure in water environments. Particularly, mining activities, the widespread of thermal power plants, the increase in the use of motor vehicles and the development of the industry, the resources that cause the priority micro-pollutant existence are increasing day by day.

In this study, benzene pollutant, which is one of the primary micro-pollutants, was monitored for 12 months. Orhaneli river, which is located in an area where industrial and mining activities are carried out intensely and where thermal power plants are located, has been chosen as the study area.

In the modeling study, an estimation model of the benzene pollutant was made using artificial neural networks; the effects of meteorological, some physical and chemical parameters on benzene concentrations were investigated. Artificial neural networks structure consists of an input layer, a hidden layer and an output layer. After basic component analysis application, artificial neural networks are used as input parameters, precipitation, temperature, humidity, pH, flow rate, dissolved oxygen, conductivity, total organic carbon and total nitrogen. While creating the network, 11 different back propagation algorithms were compared with mean square error values and Levenberg - Marquardt algorithm was determined as the best training algorithm. In the estimation of benzene concentration produced for the selected training algorithm, the number of optimized neurons to be used in the hidden layer was found to be 6. The correlation coefficient (R^2) for the optimized three-layer artificial neural network model (9:6:1) was obtained as 0.9889.

As a result of the study, it can be clearly seen that the results of artificial neural network based models are quite suitable for the concentration of benzene in surface waters.

Keywords: Benzene, Modeling, Orhaneli River, Priority Micropollutant.

June, 2020; 100 pages

ŞEKİLLER DİZİNİ

Şekil 1.1. Mikrokirlletici kaynakları.....	2
Şekil 2.1. Benzen için faz diyagramı.....	9
Şekil 2.2. Biyolojik sinir hücresi.....	16
Şekil 2.3. YSA modeli.....	19
Şekil 2.4. YSA elemanlarının yapısı.....	20
Şekil 2.5. Basamak (step) transfer fonksiyonu.....	24
Şekil 2.6. Doğrusal (Linear) fonksiyon ve türevi.....	24
Şekil 2.7. Sigmoid fonksiyonu ve türevi.....	25
Şekil 2.8. Hiperbolik tanjant fonksiyonu ve türevi.....	25
Şekil 2.9. ReLU fonksiyonu ve türevi.....	26
Şekil 2.10. Sızıntı ReLU fonksiyonu ve türevi.....	26
Şekil 2.11. Swish fonksiyonu ve türevi.....	27
Şekil 2.12. İleri ve geri beslemeli ağ topolojisi.....	29
Şekil 3.1. Orhaneli Çayı'nın konumu.....	38
Şekil 3.2. Orhaneli Çayı su yolu gösterimi.....	39
Şekil 3.3. Ölçüm noktaları arası kuş uçuşu mesafe cetveli (km)	40
Şekil 3.4. Numune alma noktalarından görüntüler.....	40
Şekil 3.5. Benzen analizinde kullanılan Shimadzu GC QP2010 Plus/MS.....	46
Şekil 3.6. BIOSAN Multi RS-24 programlanabilir rotatör.....	47
Şekil 3.7. Benzen kalibrasyon grafiği.....	48
Şekil 3.8. Benzen analizine ait bir kromatogram ve karakteristik iyonları (m/z)....	49
Şekil 3.9. Kullanılan YSA modelinin topolojik yapısı.....	51
Şekil 4.1. 2018 yılı aylık ortalama (a) sıcaklık, (b) yağış miktarları ve (c) nem....	54
Şekil 4.2. Orhaneli Çayı çözünmüş oksijen, iletkenlik, pH, debi, toplam azot ve toplam organik karbon ölçümleri.....	56
Şekil 4.3. Orhaneli Çayı'ndaki benzen konsantrasyonlarının harita üzerinde gösterimi.....	58
Şekil 4.4. Ocak, Şubat ve Aralık aylarına ait benzen konsantrasyonları.....	59
Şekil 4.5. Mart, Nisan ve Mayıs aylarına ait benzen konsantrasyonları.....	60
Şekil 4.6. Haziran, Temmuz ve Ağustos ayına ait benzen konsantrasyonları.....	61
Şekil 4.7. Eylül, Ekim ve Kasım aylarına ait benzen konsantrasyonları.....	62
Şekil 4.8. Benzen konsantrasyonlarının (a) kurak ve (b) yağışlı mevsimler için dağılımı.....	63
Şekil 4.9. Faktör analizi.....	66
Şekil 4.10. Her bir TB için açıklanan varyans oranları ve Varimax rotasyonu matrisi ile olası kaynakları.....	67
Şekil 4.11. (a) TB1, (b) TB2 ve (c) TB3 için bileşen özdeğerleri.....	69
Şekil 4.12. YSA modeline nöron sayısının etkisi.....	75
Şekil 4.13. YSA ağ yapısı.....	76
Şekil 4.14. YSA analizi sonucu (a) eğitim, (b) validasyon, (c) test ve (d) genel R korelasyon değerleri.....	77
Şekil 4.15. YSA modelinin eğitim, validasyon ve test hataları.....	78
Şekil 4.16. Gizli ve çıktı katmanları için ağırlık ve bias katsayıları	79
Şekil 4.17. YSA tahmini ve model çıktısı olan benzen konsantrasyonlarının ölçüm noktalarına göre karşılaştırılması	79
Şekil 4.18. YSA tahmini ve ölçülen benzen değerlerinin karşılaştırılması.....	80

ÇİZELGELER DİZİNİ

Çizelge 2.1. Uçucu organik bileşikler.....	7
Çizelge 2.2. Benzenin fizikokimyasal özellikleri.....	9
Çizelge 2.3. Benzenin içme ve çevresel sulardaki ulusal ve uluslararası sınır değerler.....	11
Çizelge 2.4. 2013/39/EU Direktifi ile belirlenen 45 öncelikli kirletici madde ve ÇKS değerleri.....	12
Çizelge 2.5. Toplama fonksiyonları.....	22
Çizelge 2.6. Aktivasyon fonksiyonlarının matematiksel ifadeleri.....	23
Çizelge 3.1. Laboratuvar çalışmalarından kullanılan kimyasal malzemeler.....	45
Çizelge 3.2. Ölçüm metotları	45
Çizelge 3.3. Benzen için GC/MS koşulları.....	47
Çizelge 3.4. Benzen için geri kazanım yüzdeleri ve LOD/LOQ değerleri.....	47
Çizelge 4.1. Tek faktörlü ANOVA sonuçları.....	65
Çizelge 4.2. Bileşenlerin puan katsayı matrisi.....	70
Çizelge 4.3. Bileşenlerin gerçek ağırlık ve varyans değerleri.....	71
Çizelge 4.4. Pearson korelasyon matrisi.....	72
Çizelge 4.5. Geri yayılım algoritmalarının değerlendirilmesi.....	74


SİMGELER VE KISALTMALAR

AB	Avrupa Birliđi
ABD	Amerika Birleşik Devletleri
ANOVA	Varyans Analizi
ATSDR	Toksik Maddeler ve Hastalık Kayıt Ajansı
BOİ₅	Biyokimyasal Oksijen İhtiyacı
BTEX	Benzen, Toluen, Etilbenzen, Ksilen
ÇKS	Çevre Kalite Standartları
US EPA	Amerika Birleşik Devletleri Çevre Koruma Ajansı
GC	Gaz Kromatografisi
IARC	Uluslararası Kanser Araştırmaları Ajansı
MS	Kütle Spektroskopisi
MW	Mega Watt
P	Parametre
PAH	Poliaromatik Hidrokarbonlar
SÇD	Su Çerçeve Direktifi
TBA	Temel Bileşen Analizi
TS	Türk Standartları
YSA	Yapay Sinir Ağları
WHO	Dünya Sağlık Örgütü
°C	Santigrat Derece
µg	Mikrogram
ng	Nanogram

1. GİRİŞ

Dünyada insan nüfusunun hızla artması ile birlikte, şehirleşme ve sanayileşme faaliyetleri de gün geçtikçe artmaktadır. Bu faaliyetlerin artmasına paralel olarak gittikçe büyüyen bir enerji ihtiyacı oluşmaktadır (Grigoratos ve Martini, 2014; Uysal, 2019; Vieira vd., 2020). Gelişmekte olan ülkeler arasında yer alan ülkemizin artan enerji ihtiyacına bağlı olarak, çeşitli enerji üretim tesislerine ihtiyaç duyulmaktadır. Diğer yöntemlere kıyasla enerji bakımından dışa bağımlılığı azaltması ve daha ekonomik olmasından dolayı, tüm çevresel etkilerine rağmen termik santrallerde halen yakıt olarak kömür kullanılmaktadır. Kömür kullanımı sebebiyle çevresel ortamlar zarar görmektedir (Kürklü, 2019).

Son yıllarda, toplum sağlığını ve çevre güvenliğini etkileyen kirleticilerin izlenmesi giderek önem kazanmaktadır (Mohácsi vd., 2001; Jiang vd., 2013; Salar-García vd., 2017). Bu kirleticiler arasında önemli bir yeri mikrokirleticiler oluşturmaktadır. Mikrokirletici: Belirli koşullar altında insan aktivitesi ile çevre ortamına yayılan, toksik ve istenmeyen etkilerinin insan ve su yaşamını etkilediği, bu su kaynaklarının kalite ve değerini düşüren maddedir. Mikrokirleticiler; zehirli kirleticiler, eser kirleticiler, dirençli kirleticiler ve öncelikli kirleticiler gibi isimlerle her ülkede farklı olarak tanımlanmaktadırlar (Knipe ve Watts, 1993; Martínez vd., 2013; Glaser vd., 2019; Üstün Odabaşı, 2019). Mikrokirleticilerin kaynakları, teknik ve çevresel önemde geniş farklılıklar gösterirken kaynakların tanımlanması mikrokirleticilerin kontrolünde kolaylıklar sağlamaktadır. Mikrokirletici kaynakları, noktasal kaynaklar ve noktasal olmayan (yayılı) kaynaklar olarak ayrılmaktadır. Mikrokirleticiler, noktasal ve yayılı kaynakların yanı sıra ara kaynaklarla da suya karışmaktadırlar. Bu ara kaynaklara örnek olarak içme suyu dağıtımı ve arıtımı örnek verilebilir (Li vd., 2016). Dezenfeksiyon sonrası oluşan yan ürünler içme suyunu kontamine etmektedir. Dezenfektan olarak klor kullanımı, kloroform ve diğer bromo ve kloro haloformların oluşumunun nedenidir. Brom iyonlarını içeren içme sularının ozonlanması da bromoform ve bromohidrin gibi bromlu organik bileşiklerin suya karışmasına neden olmaktadır (Hoffer ve Shuker, 2000). Yukarıda bahsedilen hem noktasal hem noktasal olmayan kaynaklarla suyu kontamine eden pek çok mikrokirleticinin yüzeysel sulara karışırken izlediği yollar Şekil 1.1’de gösterilmiştir.



Şekil 1.1. Mikrokirletici kaynakları.

Çevre ve insan vücudu üzerinde ciddi etkileri olduğu bilinen mikrokirleticilerden olan Uçucu Organik Bileşikler (UOB) (Uragami vd., 2016); bilinen veya muhtemel kanserojenler olmakla birlikte, toksik ve mutajenik etkilere sahiptirler (Chan vd., 2002). Sudaki UOB'lerin üç temel kaynağı; doğal olarak meydana gelen organik maddelerin parçalanması, evsel ve endüstriyel faaliyetler, su arıtımı ve taşınımı boyunca meydana gelen reaksiyonlardır (Almeida ve Boas, 2004). Su ortamında en çok bulunabilecek bilinen UOB'ler arasında, BTEX (benzen, toluen, etilbenzen ve ksilen) klorlu benzen, diklorometan (DCM), kloroeten (vinilklorit), trikloroetilen, tetrakloroetilen ve karbon tetraklorit sayılabilir. Bu bileşikler denizlere, yer altı sularına ve içme suyu kaynaklarına endüstriyel deşarjlar, petrol türevi yakıtların tam yanmaması ve petrol türevlerinin çevresel alanlara sızması gibi yollarla bulaşmakta, doğal çevre ve canlı hayatı açısından risk oluşturmaktadırlar (Niri vd., 2008; Pecoraino vd., 2008; Radwan vd., 2019). UOB'lerden olan Benzen, çok düşük konsantrasyonlarda kanserojen etkileri nedeniyle literatürdeki en çok çalışılan uçucu organik kirleticilerden biridir (EPA, 1998; Lahlou vd., 2013). Benzen, kimyasal ve petrokimyasal atıksularda sıklıkla rastlanan tipik toksik uçucu organik bileşiktir (Lin ve Huang, 1999) ve ayrıca, monosiklik aromatik hidrokarbon olup, çevre ortamındaki varlığı genellikle yakıtların eksik yanmasından kaynaklanmaktadır (López-Blanco, vd., 2016). Amerika Birleşik Devletleri Çevre Koruma Ajansı (US EPA)'na göre

benzen için içme suyu için limit değeri 5 µg/L'dir (Sarafray-Yazdi, vd., 2008). Benzen, Amerika Çevre Koruma Ajansı (U.S. Environmental Protection Agency) tarafından öncelikli kirleticiler arasında listelenir ve tehlikeli maddelerin öncelik listesindeki ilk 100 kimyasal arasında yer almaktadır (Jechalke vd., 2010; Khodaei, vd., 2017).

1.1 Çalışmanın Amacı ve Önemi

Ülkemizde yüzeysel su kaynaklarında bulunan mikrokirleticiler, endüstriyel faaliyet gösteren bölgelere yakın su kaynaklarının ve tarım arazilerinin kullanımını kısıtlayan önemli bir unsurdur. Yapılan çalışmalar bu mikrokirleticilerin dirençli yapılarından dolayı sularda ve toprakta varlığını devam ettirdiğini işaret etmektedir. Bu nedenle su kaynaklarının ve tarım arazilerinin kullanımında bu kirleticilerin kontrolü önemli bir araştırma konusudur.

Avrupa Birliği, “öncelikli” ve “öncelikli tehlikeli” olarak tanımlanan kirleticiler için Su Çerçeve Direktifi'nde (URL-1) belirtilen Çevresel Kalite Standartları'na uyulmasını, bunlar dışındaki kirleticiler (spesifik kirleticiler) için ise her ülkenin kendi içerisinde belirlediği Çevresel Kalite Standartları'na (YSKY, 2012) uymasını istemektedir. Sularda Çevresel Kalite Standartları ile belirlenmiş olan öncelikli 33 adet kirletici mutlak suretle izlenmesi gereken mikrokirleticilerdir (Deblonde vd., 2011). Bu konuda ülkemiz açısından bu kirleticilerin Su Çerçeve Direktifi'nde belirtilmiş olan periyotlarda su ortamlarında izlenmesi ve aynı zamanda Çevresel Kalite Standartları'nda tanımlanmış olan değerlerinin altında kalmasının sağlanması gerekmektedir. Tüm kirletici parametrelerin birlikte kontrol edilmesi, Su Çerçeve Direktifi'ne uyum çalışmalarında iyi kalitede suların temini açısından da önem arz etmektedir. Bu nedenle kirleticilerin kontrolü ve tespiti büyük önem taşımaktadır.

Avrupa ülkeleri son yıllarda öncelikli kirletici listesinde bulunan kirleticiler üzerinde yoğunlaşarak akademik çalışmalarını bu konuya yönlendirmişlerdir. Ülkemizde de son yıllarda bu konu üzerine çalışmalar yapılmaya başlanmıştır. Ülkemizde tarım arazilerinin ıslahı ve su kirliliği kontrolü hedeflerine yönelik olarak bu mikrokirleticilerin izlenmesi ve kısıtlanması gerekmektedir. Bu kirleticilerin izlenilmesi ve kontrolüne yönelik ülkemizde var olan altyapı çok sınırlıdır. Avrupa Birliği Su Çerçeve Direktifi gerekliliklerinin yerine getirilmesi amacıyla gerek insan

gerekse laboratuvar altyapısının güçlendirilmesi gerekmektedir. Benzen miktarının tespiti ve model çalışmaları ile tahmin edilmesi ve yorumlanması Çevre Kalite Standartları'nın belirlenmesi açısından büyük önem taşımaktadır.

Bu çalışmada, Bursa-Kütahya bölgesinde bulunan Orhaneli Çayı, çalışma alanı olarak belirlenmiştir. Çalışma alanı içerisinde, Türkiye'nin en önemli termik santrallerinden olan üç adet tesis bulunmaktadır. Bu tesisler 50-350 MW aralığında kurulu güce sahiptir. Bu enerji üretim tesislerinde hammadde olarak linyit kömürü kullanılmaktadır. Dolayısıyla madensel işletmeler de çalışma bölgesi içerisinde yer almaktadır.

Orhaneli Çayı boyunca çevresel kirliliğin öngörüldüğü yüzeysel sular içerisinde olduğu düşünülmüştür. Bu bağlamda çay üzerinde yer alan yerleşim yerlerinden kaynaklı kirlilik, madencilik ve endüstriyel faaliyetler bu kirliliğe önemli katkı sağlamaktadır. Bu sebeplerden dolayı çalışma bu alan üzerinde gerçekleştirilmiştir. Ön çalışmalarda; Orhaneli Çayı ile ilgili olarak mikrokirleticilerin varlığı tespit edilmiştir. Bu kirleticiler içerisinde insan ve çevre sağlığı açısından oldukça önemli olan ve bu kaynaktan çok yüksek konsantrasyonlarda bulunan benzen kirleticisi üzerine çalışılmıştır. Ayrıca, birden fazla termik santralin bu bölgede bulunması, yoğun olarak yeraltı ve yerüstü kömür madenciliği faaliyetlerinin yürütülmesi, benzenin hedef kirletici olarak seçilmesi açısından önemli olan faktörlerdendir.

Çevresel ve meteorolojik şartların seçilen öncelikli mikrokirletici üzerine etkisini belirlemek için dört mevsim ile yağışlı ve kurak mevsimlerin takibi yapılmıştır. Bunun için örnek noktaları nüfus yoğunluğu ve termik santrallerin dağılımı göz önüne alınarak belirlenmiştir.

Tehlikeli ve toksik mikrokirleticiler içerisinde yer alan benzenin bilinen basit matematiksel eşitliklerden oluşan modeller yerine, daha karmaşık olan ve güvenli sonuçlar veren yapay zekâ tabanlı modellerin kullanılması amaçlanmıştır.

Son yıllarda yapay sinir ağları, bulanık mantık ve sinirsel bulanık mantık vb. ile geliştirilmiş bilgi işlem teknolojilerinin kullanımı oldukça önemli bir yere sahiptir. Yapay sinir ağları ile modellenmesi zor olan kirleticilerin tahmin edilmesinde başarılı

sonular elde edilmektedir. Mühendislik alanında kullanılan yapay sinir ağılarının temel amacı zaman, maliyet ve iş gücünün azaltılarak istenilen sonuç tahminlerinin oluşturulmasıdır.

Yüzeysel bir su kaynağı olan Orhaneli ayı, öncelikli mikrokirletici olarak seçilen benzen ile ilgili herhangi bir akademik çalışma bulunmamaktadır. Bu öncelikli mikrokirleticinin çevre ve insan sağlığı açısından oldukça tehlikeli olması çalışmanın önemini arttırmaktadır. Yeraltı kömür madenciliğı çalışmalarının yoğun olarak yapıldığı ve termik santrallerin bulunduğu Orhaneli ayı’nda bu faaliyet alanlarına yakın noktalardaki yüzeysel su ortamındaki benzen konsantrasyonlarının tespiti amaçlanmıştır.

Diğer bir amaç ise, Orhaneli ayı üzerinde yapılan bu çalışma ile literatüre, Su ereve Direktifi içerisinde tanımlanan Çevresel Kalite Standartları’na katkı sağlaması ve gelecekte yapılması planlanan çalışmalara referans teşkil etmesidir.

2. KAYNAK ARAŞTIRMASI

2.1 Mikrokirleticiler

Mikrokirleticiler, insan faaliyetleri sonucu çevre ortamlarına verilen, kararlı, toksik ve biyoakümülyasyon gibi özellikleri bünyesinde barındıran, çok düşük miktarlarda bile canlı hayatına zarar veren organik ya da inorganik maddelerdir. Mikrokirleticiler ismi farklı ülke mevzuatlarında eser kirleticiler, öncelikli kirleticiler, toksik kirleticiler ve çözünmeye dirençli kirleticiler olarak değişebilmektedir. Sucul ortamlarda ng/L veya µg/L seviyesinde bulunmasına rağmen orada bulunan canlı hayatı ve insan sağlığı açısından ciddi riskler oluşturmaktadırlar (Schwarzenbach vd., 2006; Bolong vd., 2009; Wille vd., 2012; Manda vd., 2014; Meffe ve Bustamante, 2014; Qi vd., 2014). Bu nedenle su ortamlarında mikrokirletici miktarının artması, çevresel açıdan dünya çapında endişeye sebep olmaktadır (Luo vd., 2014; Wanda vd., 2017). Mikrokirletici kaynaklarından en önemlileri arasında endüstriyel gelişmeler, tarımsal faaliyetler, kişisel bakım ürünlerinin kullanımının artması, farmasötik maddeler ve gün geçtikçe artan enerji ihtiyacını karşılamak için enerji üretim çalışmaları (petrol temini ve kullanımı, termik santraller, vb.) bulunmaktadır (Liu vd., 2008). Bu faaliyetler sonucu su ortamlarına karışan mikrokirleticiler sucul çevre açısından bir tehdit oluşturmaktadır (Jiang vd., 2013a; Palas vd., 2017; Yang vd., 2017).

Dünyada ve ülkemizde klasik su ve atıksu arıtma tesislerinde fiziksel parametreler ile biyolojik olarak parçalanabilen organik maddelerin giderimi yapılmaktadır. Biyolojik arıtmada parçalanamayan ya da bir yüzeyde tutunarak giderilmesi pek mümkün olmayan bu kirleticiler, atıksu arıtma tesislerinden giderimi yapılamadan alıcı ortamlara deşarj edilmektedir (Luo vd., 2014; Yang vd., 2017; Gruchlik vd., 2018).

Mikrokirleticiler olarak tanımlanan pek çok kirletici türü bulunmaktadır. Bu türler içerisinde organik bileşiklerden kaynaklanan kirliliğin önemli bir kısmını uçucu organik bileşikler (UOB) oluşturmaktadır. Dünya Sağlık Örgütü (WHO, 1986) tarafından kaynama noktasının 50 °C – 100 °C ile 240 °C – 260 °C aralığında olan organik bileşikler olarak tanımlanmaktadır ve yüzlerce farklı türü bulunmaktadır (Sözen vd., 2017). Karbon atomu sayısı 12 ya da daha az olan, normalde sıvı ya da katı olsa bile, düşük sıcaklıklarda gaz durumuna geçebilen kirleticiler olarak da

tanımlanmaktadır. Genel olarak uçucu organik kirleticiler ve dahil olduğu gruplar Çizelge 2.1’de gösterilmektedir.

Çizelge 2.1. Uçucu organik bileşikler (Darçın ve Balanlı, 2018).

Organik Bileşik	Grup Adı	Sık Karşılaşılan Kirleticiler
UOB	Alifatik Hidrokarbonlar	Metan, etan, propan, bütan pentan, heksan, heptan, oktan, nonan, sikloheksan, isobütan, isopenten, n-tridekan, dekan, dodekan, undekan
	Aromatik Hidrokarbonlar - Tek Halkalı	Benzen, etilbenzen, dietilbenzen, trimetilbenzen, dimetil-etilbenzen, toluen, ksilenler, stiren, etil toluen
	Aromatik Hidrokarbonlar - Çok Halkalı	Naftalin, fenantren, benzo[a]piren, DDT, dieldrin, permetrin, benz[a]antrasen
	Halojenli Hidrokarbonlar	Kloroform, diklorometan (metilen klorür), trikloroetilen, tetrakloroetilen, p-dikolorobenzen (1,4-diklorobenzen), metil bromit, vinil bromit, benzil klorit, 1,1,1-trikloroetan (metil kloroform), karbon tetraklorit
	Aminler	2-naftilamin, 4-aminobifenil
	Alkoller	N-bütıl alkol, 1-dodekanol, fenol, metil alkol (metanol), etil alkol (etanol), nonanol, isopropil alkol (isopropanol), propargil alkol, 2-etil-1-heksanol
	Eterler	Etil eter
	Aldehitler	Dekanal, nonanal, formaldehit, propenal (akrolein), asetaldehit, furfural, heksanal
	Ketonlar	Aseton, metil etil keton (2-butanon)
	Terpenler	A-pinen, β-pinen, limonen, isopren
	Esterler	Etil asetat, 1-heksil butanoat
	Glikol Eterler	2-etoks etanol
	Organik asitler	Asetik asit, propanoik asit, heksanoik asit, pentanoik asit
	Kükürt içeren bileşikler	Karbon disülfıt
	Diğer bileşikler	1,3-butadien, nitrosaminler

UOB'lerin gerek insan sađlıđı gerekse evre sađlıđı aısından onemi gn getike artmaktadır (Yılmaz Civan vd., 2012; Tsai, W.T., 2016). UOB'ler toksikolojik etkileri, fiziksel ve kimyasal zellikleri nedeniyle insan sađlıđı zerinde onemli sađlık etkileri oluřtururken, uuculuk ve toksisiteleri sebebiyle de evre ortamlarında onemli kirleticiler sınıfındadırlar (Moliner-Martínez, vd., 2013; Wu vd., 2019).


Sudaki organik bileřiklerin  temel kaynađı; dođal olarak meydana gelen organik maddelerin paralanması, evsel ve endstriyel faaliyetler, su arıtımı ve tařınıımı boyunca meydana gelen reaksiyonlardır (Almeida ve Boas, 2004; Xu vd., 2017; Yang et al., 2018). Su ortamında en ok bulunabilecek bilinen UOB'ler arasında, benzen, toluen, etilbenzen ve ksilen (BTEx), diklorometan (DCM), kloroeten (vinilklorit), trikloroetilen, tetrakloroetilen ve karbon tetraklorit sayılabilir.


Bu bileřikler denizlere, yer altı sularına ve ime suyu kaynaklarına endstriyel deřarjlar, petrol trevi yakıtların tam yanmaması ve petrol trevlerinin evresel alanlara sızması gibi yollarla bulařmakta, dođal evre ve canlı hayatı aısından risk oluřturmaktadırlar (Lykke vd., 1979; Niri vd., 2008; Cesarino vd., 2013).

Benzen, aromatik hidrokarbonlar olarak adlandırılan organik bileřikler sınıfının en basit yesidir. Benzen renksiz, alevlenebilen ve sıvı halde bulunan bir maddedir. Benzenin molekler forml C_6H_6 'dır (izelge 2.2). Yksek buharlařma basıncına (20°C'de 9.95 kPa) oda sıcaklıđında ulařması sebebiyle ok hızlı olarak buharlařabilir. Benzenin en yaygın trevleri, toluen (metil benzen), ksilen (dimetil benzen), anilin, stiren ve eter'dir. Benzen ve trevleri; petroln sentezlenmesi, alifatik hidrokarbon grubundaki kimyasalların yksek ısı ve basın altında aromatize edilmesi ve kmr katranı distilasyonu ile ortaya ıkmaktadırlar (URL-2).

Benzen, kimyasal ve petrokimyasal atıksularda sıklıkla rastlanan tipik toksik uucu organik bileřiktir (Lin and Huang, 1999; Almeida vd., 2006; Sarafraz-Yazdi, vd., 2008; Erickson vd., 2014). Benzen, belirli bir kararlılık gsteren doymamıř bir hidrokarbondur ve genellikle yer deđiřtirme tepkimeleri verir. Benzen iin faz diyagramı řekil 2.1'de verilmiřtir.

Çizelge 2.2. Benzenin fizikokimyasal özellikleri (URL-3).

Yapısı	
Moleküler formülü	C ₆ H ₆
Erime noktası (°C)	5.5
Kaynama noktası (°C)	80.1
Yoğunluğu (g/cm ³)	0.87
Moleküler kütlesi (g/mol)	78.11
Moleküler geometrisi	Trigonal planar
Isı sığası (C) (J/mol*K)	134.8



Şekil 2.1. Benzen için faz diyagramı.

Şekil 2.1'deki benzen için faz diyagramı, sıcaklık ve basınçtaki değişikliklerle faz davranışını gösterir. Buradaki üçlü nokta, benzenin üç fazının (gaz, sıvı ve katı) termodinamik dengede bir arada var olduğu sıcaklık ve basınçtır. Kritik nokta ise basınç arttığında veya ısı eklendiğinde maddenin durumunda değişiklik olmayan noktadır. Benzen standart koşullarda sıvıdır. Isıtıldığında gaz haline gelir ve

soğutulduğunda katı hale gelir. Kritik nokta ile üçlü nokta arasındaki eğri, basınçta değişikliklerle benzen kaynama noktasını gösterir. Ayrıca sıcaklıktaki değişikliklerle doyma basıncını gösterir.

Benzen, çok sayıda aromatik hidrokarbonun da ana maddesidir. Pek çok endüstriyel faaliyet sonucunda su ortamlarına benzen salınımı gerçekleşmektedir. Endüstri tesislerinde (ilaç, boya, plastik vb.) geniş bir kullanım alanına sahiptir. Yaygın olarak kullanılmasının iki önemli sebebi; fiziksel özelliklerinin uygun olması ve yerini alabilecek kimyasal maddelere oranla çok daha ucuz olmasıdır (ATSDR, 2007a). Çözücü olarak kullanımı ise, matbaacılıkta boyaları eritme, kutu ve karton imalatında yapıştırma işlemi, kuru temizleme, matbaacılıkta boya eritme, çanta ve ayakkabı imalatında yapıştırma, otomobil boyalarını eritme, madeni ekipmanları temizleme gibi alanlarda sıkça görülmektedir. Boya sanayiinde, boyaları seyreltmek için kullanılan tiner içerisinde de benzen bulunmaktadır. Enerji bakımında yüksek değere sahip olan benzen, doğrudan ya da benzine karıştırılarak yakıt olarak da kullanılmaktadır. Amerika Birleşik Devletleri'nde kullanılan benzinin içeriğinde %30-50 arasında farklı aromatik bileşikler bulunduğundan, yaklaşık %2-3 oranında benzen, bulunduğu bilinmektedir. Kimya ve ilaç sanayisinde sentez yoluyla bazı kimyasal maddeleri üretmek amacıyla kullanılmakta olup, genellikle üretilen benzen miktarının yaklaşık olarak yarısının stiren üretiminde kullanıldığı kayıtlara geçmiştir. Yeraltı ve yerüstü kömür madenciliği faaliyetlerinde kömürün yıkanması ve enerji üretim tesisi olan termik santrallerin faaliyetleri sonucunda benzen konsantrasyonları çevre ortamlarında hızla artmaktadır (Tözün ve Ünsal, 2008; Duan ve Li, 2017).

Benzen, US EPA tarafından öncelikli kirleticiler arasında listelenir ve tehlikeli maddelerin öncelik listesindeki ilk 100 kimyasal arasında yer almaktadır (Khodaei, vd., 2017; Ahmed vd., 2019). Çevreye yayılımında ana kaynak endüstriyel proseslerdir ve monosiklik aromatik hidrokarbon olan benzenin çevre ortamındaki varlığı, genellikle yakıtların (kömür, benzin vs.) eksik yanmasından kaynaklanmaktadır (Torabian vd., 2010; Weisel, 2010; López-Blanco, vd., 2016). Ayrıca orman yangınları ve volkanik hareketler doğal benzen kaynaklarındandır. Su ve toprak ortamlarında bulunan benzen hava ortamına karıştıktan sonra birkaç gün içerisinde diğer kimyasallara bozunmaktadır. Yağmur ve kar yağışıyla birlikte benzen tekrardan toprak ve su ortamlarına taşınmaktadır. Su ve toprak içerisinde hava ortamına göre daha yavaş

bozunan benzen kolaylıkla yeraltı sularına karışabilmektedir (ATSDR, 2007a).

Benzen vücuda girdiğinde baş dönmesi, bilinç kaybı, bağışıklık sisteminde bozulmalar, uyku hali gibi etkilerinin yanı, kemik iliğine etki etmesi sonucu anemi ve lösemiye sebep olabilmektedir. Kan hücrelerini yok etmesi sebebi ile kanserojen madde sınıfındadır (Zhang vd., 2015; Chang vd., 2017; Gjesteland vd., 2019). Uluslararası kuruluşlar tarafından da insanlar için kanserojen olarak sınıflandırılan benzen, IARC için Grup 1 (IARC, 2014); US EPA için ise Grup A (EPA, 2009a) kategorisinde yer almaktadır. Benzenin de içerisinde bulunduğu UOB'lerin içme ve çevresel sulardaki standartları genellikle 98/83/EC sayılı Avrupa Birliği İçme Suyu Direktifi (EU, 1998) veya uluslararası (WHO ve US EPA gibi) ya da ulusal standartlardaki sınır değerlere göre belirlenmektedir (WHO, 1993; EPA, 2009). Ülkemizde yerüstü su kaynaklarındaki öncelikli kirleticiler ve bu sular için çevresel kalite standartlarını belirleyen “Yerüstü Su Kalitesi Yönetmeliği (YSKY)” ile insani tüketim amaçlı kullanılan sular için gerekli kalite standartlarını, içme ve kullanma amacıyla kullanılan bu suların teknik ve hijyenik olarak uygunluğunun sağlanması için detaylı olarak usul ve esasları içeren “İnsani Tüketim Amaçlı Sular Hakkında Yönetmelik (İTASHY)” bulunmaktadır (İTASHY, 2005; YSKY, 2012). Bu kapsamda Çizelge 2.3'te içme ve çevresel sularda benzen kirleticisinin sınır değerleri verilmiştir.

Çizelge 2.3. Benzenin içme ve çevresel sulardaki ulusal ve uluslararası sınır değerleri (Güzel vd., 2018).

UOB	İçme Suyu				Çevresel Su			
	İTASHY (µg/L)	WHO (µg/L)	EU (µg/L)	US EPA (µg/L)	YSKY (µg/L)		EU (µg/L)	
					Kıyı ve Geçiş Suları	Nehirler ve Göller	İç Yüzey Sular	Diğer Yüzey Sular
Benzen	1	10	1	5	8	10	10	8

YSKY'nin eklerinde bulunan öncelikli kirletici listesi Ek-2 Çizelge 2.4'te verilmiştir. Bu liste 2013/39/EU sayılı Avrupa Birliği Direktifi'nde (URL-1) listelenen 45 öncelikli madde ve çevresel kalite standartlarını içermektedir.

Çizelge 2.4. 2013/39/EU Direktifi ile belirlenen 45 öncelikli kirletici madde ve ÇKS değerleri (URL-1).

No	Madde Adı	CAS Numarası	YO-ÇKS* Nehir/Göl (µg/L)	MAK-ÇKS* Nehir/Göl (µg/L)	YO-ÇKS* Kıyı ve Geçiş Suları (µg/L)	MAK-ÇKS* Kıyı ve Geçiş Suları (µg/L)
*YO-ÇKS: Yıllık ortalama çevresel kalite standardı; MAK-ÇKS: Maksimum izin verilerbilir çevresel kalite standardı.						
1	Alaklor	15972-60-8	0.3	0.7	0.3	0.7
2	Antrasen	120-12-7	0.1	0.4	0.1	0.4
3	Atrazin	1912-24-9	0.6	2.0	0.6	2.0
4	Benzen	71-43-2	8	50	8	50
5	Bromlu Difeniller	32534-81-9	-	0.14	-	0.14
6	Kadmiyum ve Bileşikleri	7440-43-9	<0.08 (Sınıf 1) 0.08 (Sınıf 2) 0.09 (Sınıf 3) 0.15 (Sınıf 4) 0.25 (Sınıf 5)	<0.45 (Sınıf 1) 0.45 (Sınıf 2) 0.6 (Sınıf 3) 0.9 (Sınıf 4) 1.5 (Sınıf 5)	0.2	<0.45 (Sınıf 1) 0.45 (Sınıf 2) 0.6 (Sınıf 3) 0.9 (Sınıf 4) 1.5 (Sınıf 5)
7	C10-13 Kloroalkanlar	85535-84-8	0.4	1.4	0.4	1.4
8	Klofenvinfos	470-90-6	0.1	0.3	0.1	0.3
9	Klorpirifos (Klorpirifos-etil)	2921-88-2	0.03	0.1	0.03	0.1
10	1,2-dikloroktan	107-06-2	10	-	10	-
11	Diklorometan	75-09-2	20	-	20	-
12	Di(2-etilhekzil)ftalat (DEHP)	117-81-7	1.3	-	1.3	-
13	Diuron	330-54-1	0.2	1.8	0.2	1.8
14	Endosulfan	115-29-7	0.005	0.01	0.0005	0.004
15	Floranten	206-44-0	0.0063	0.12	0.0063	0.12
16	Hekzakloro-benzen	118-74-1	-	0.05	-	0.05
17	Hekzakloro-bütadien	87-68-3	-	0.6	-	0.6
18	Hekzakloro-sikloheksan	608-73-1	0.02	0.04	0.002	0.02
19	Isoproturon	34123-59-6	0.3	1.0	0.3	1.0
20	Kurşun ve bileşikleri	7439-92-1	1.2	14	1.3	14
21	Cıva ve bileşikleri	7439-97-6	-	0.07	-	0.07
22	Naftalin	91-20-3	2	130	2	130
23	Nikel ve bileşikleri	7440-02-0	4	34	8.6	34
24	Nonilfenoller (4-Nonilfenol)	84852-15-3	0.3	2	0.3	2
25	Oktilfenol ((4-1,1'-3,3'-tetrametilbütıl)-fenol)	140-66-9	0.1	-	0.01	-
26	Pentakloro-benzen	608-93-5	0.007	-	0.0007	-
27	Pentakloro-fenol	87-86-5	0.4	1.0	0.4	1.0
28	Poliaromatik hidrokarbonlar (PAH)		-	-	-	-
	Benzo(a)piren	50-32-8	1.7x10 ⁻⁴	0.27	1.7x10 ⁻⁴	0.27
	Benzo(b)floranten	205-99-2	-	0.017	-	0.017
	Benzo(k)floranten	207-08-9	-	0.017	-	0.017
	Benzo(g,h,i)perilen	191-24-2	-	8.2x10 ⁻³	-	8.2x10 ⁻⁴
	Indeno(1,2,3-cd)piren	193-39-5	-	-	-	-
29	Simazin	122-34-9	1	4	1	4
30	Tributılkalay bileşikleri (Tributılkalay-katyonu)	36643-28-4	0.0002	0.0015	0.0002	0.0015
31	Trikloro-benzenler	12002-48-1	0.4	-	0.4	-
32	Trikloro-metan	67-66-3	2.5	-	2.5	-

Çizelge 2.4 (devam). 2013/39/EU Direktifi ile belirlenen 45 öncelikli kirletici madde ve ÇKS değerleri (URL-1).

33	Trifluralin	1582-09-8	0.03	-	0.03	-
34	Dikofol	115-32-2	1.3×10^{-3}	-	3.2×10^{-5}	-
35	Perflorooktan sülfonik asit ve türevleri (PFOS)	1763-23-1	6.5×10^{-4}	36	1.3×10^{-4}	7.2
36	Kinoksifen	124495-18-7	0.15	2.7	0.015	0.54
37	Dioksinler ve dioksin benzeri bileşikler		-	-	-	-
38	Aklonifen	74070-46-5	0.12	0.12	0.012	0.012
39	Bifenoks	42576-02-3	0.012	0.04	0.0012	0.004
40	Sibutrin	28159-98-0	0.0025	0.016	0.0025	0.016
41	Sipermetrin	52315-07-8	8×10^{-5}	6×10^{-4}	8×10^{-6}	6×10^{-5}
42	Diklorvos	62-73-7	6×10^{-4}	7×10^{-4}	6×10^{-5}	7×10^{-5}
43	Hekzabromosiklodekanlar (HBCDD)		0.0016	0.5	0.0008	0.05
44	Heptaklor ve heptaklor epoksit	76-448/1024-57-3	2×10^{-7}	3×10^{-4}	1×10^{-8}	3×10^{-5}
45	Terbutrin	886-50-0	0.065	0.34	0.0065	0.034

Çizelge 2.4’te verilen 45 öncelikli mikrokirleticilerden biri olan benzen için nehir ve göllerde izin verilen maksimum değer 50 µg/L iken; yıllık ortalama değer 10 µg/L ‘dir. Kıyı ve geçiş sularında yıllık ortalama ve maksimum izin verilebilir çevresel kalite standardı sırasıyla; 8 ve 50 µg/L olarak belirlenmiştir. Avrupa Birliği Direktifi’nde ÇKS’lere uyum sürecinde belirlenmiş olan bu değerler dikkate alınmaktadır.

2.2 İstatistiksel Çalışma

İstatistiksel bir analiz metodu olan ANOVA, analiz edilecek olan bağımsız değişkenlerin üç ya da daha fazla sayıda olduğunda, birbirleri arasında istatistiksel farklılıkların olup olmadığını gösteren, ilişkilerini ortaya çıkaran ve tanımlayan istatistiksel bir analiz metodudur (Biga vd., 2016; Efe ve Çanga, 2017). Temel olarak ANOVA, gruplar arasındaki değişkenlik durumunu (farklılaşmayı-varyansı), grupların içerisindeki faktörler arasındaki değişkenliğe (farklılaşmaya-varyansa) oranlar. Bu analizin amacı, faktörler arasındaki farklılığın, gruplar arasındakinden küçük olup olmadığını tespit etmektir (URL-4). Böylelikle analizi etkileyen faktör veya faktörlerin etkisinin ortaya çıkartılmaktadır. ANOVA testinin uygulanması için bazı ön şartların oluşturulması gerekmektedir. Bunlardan bir tanesi de grupların varyanslarının homojenliğinin sağlanmasıdır. Homojenlik, Levene istatistiği olan *P* değerlerinin sonuçlarına göre değerlendirilmektedir. İstatistiksel olarak sonuçların

anlamalı olduğunu P değerinin 0.05'e eşit veya küçük olması durumunda söyleyebiliriz. Bu seviye benzer istatistiksel analizlerde yaygın olarak kullanılmaktadır (Radic vd., 2018; Demirarslan ve Doğruparmak, 2019).

2.3 Temel Bileşen Analizi

Temel Bileşen Analizi (TBA), verilerin boyutunu azaltma, tahminde bulunma ve bazı analizler için veri setini görüntülemek amaçlarıyla yaygın olarak kullanılmaktadır. TBA, orjinal p değişkeninin varyans yapısını, sayısını azaltarak ve bu değişkenlerin doğrusal bileşenleri olan yeni değişkenlerle ifade etme yöntemidir (Rocha ve Palma, 2019). Başka bir deyişle, birbiriyle ilişkisi olan çok sayıda değişkenden meydana gelen bir veri setinin boyutlarını içerisindeki değişim korunarak daha küçük boyuta indirgenmesini sağlayan bir dönüşüm tekniğidir (Yazar vd., 2009). Ayrıca, çevresel verilerin çok değişkenli istatistiksel analizinde kullanılan en popüler yöntemdir (Platikanov vd., 2019). TBA, trendleri ve kalıpları koruyarak yüksek boyutlu verideki karmaşıklığı basitleştirir. Bunu, verileri özelliklerine göre işlev gören daha az boyuta dönüştürerek yapmaktadır (Lever vd., 2017). Aralarında korelasyon bulunan p sayıda değişkenin ifade ettiği yapıyı, aralarında korelasyon olmayan ve orjinal değişken sayısından daha az sayıda ($p > k$) doğrusal bileşenleri olan değişkenlerle açıklanma yöntemine dayanmaktadır. Veri matrisinde bulunan p değişkeninin doğrusal bileşenlerini tespit etmek için korelasyon ya da kovaryans matrisinin özvektörleri ve özdeğerleri kullanılır (Jolliffe ve Cadima, 2016). Eğer değişkenlerin varyansları aynı birimdeyse varyans-kovaryans matrisi, değilse korelasyon matrisi kullanılır. p boyutlu uzayın gerçek boyutu TBA analizi ile belirlenir. Bu gerçek boyuta temel bileşenler adı verilir. Temel bileşenlerin en önemli üç özelliği arasında; korelasyonsuz olması, ilk sıradaki temel bileşenin toplam değişkenliği en çok ifade eden değişken olması ve ikinci temel bileşenin ise geri kalan değişkenliği en fazla açıklayan değişken olması yer almaktadır (URL-5).

Modelleme çalışmalarında girdi olarak verilen parametrelerin çıktı parametresine katkısı özdeğerler ile belirlenir (Mavukkandy vd., 2014). Böylelikle parametre ağırlıkları belirlendikten sonra kullanılan modeller daha tutarlı ve daha gerçekçi sonuçlar vermektedir. Fazla veri karmaşıklığından ve zamandan tasarruf sağlanması ile yaygın kullanım alanına sahiptir. TBA tarafından belirlenen ortak bileşenler

(bağımsız parametreler) birbiriyle ilişkili olmadığından, bağımsız parametreler arasındaki olası bir çoklu bağlantı probleminden kaçınılır (Alver ve Kazan, 2020).


2.4 Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan beyninin çalışma prensibi temel alınarak geliştirilmiş olan bir bilgi işlem teknolojisidir (Turhan vd., 2013). YSA ile insan beynindeki sinir hücrelerinin (nöronlar) birleşiminden oluşan basit biyolojik sinir sistemi taklit edilmektedir. Bu nöronlar farklı şekillerde birbirlerine bağlanarak sinir ağı oluştururlar (Yesilnacar vd., 2008; Babar, 2011; Terzi ve Baykal, 2012). Sinir ağları öğrenme, hafızada tutma ve datalar arasındaki ilişkiyi meydana çıkarma özelliğini sahiptirler. Bunun anlamı, insana özgü bir özellik olan düşünme ve gözlemleme ile problemlere çözüm üretme yeteneğine YSA'lar da sahiptir (Zhao vd., 2011). İnsanların düşünme ve gözlemleme yetenekleri ile problemlere çözüm üretebilmesinin en önemli nedeni, insan beyninin deneyimleyerek yani yaşayarak öğrenebilmesidir. YSA'lar insan beyninin doğal olarak yapabildiği yeni bilgiler öğrenme, öğrendiği bu bilgiler ışığında yorum yapabilme ve yeni bilgiler oluşturabilme gibi özellikleri hiçbir yardım almadan yapabilmek amacıyla geliştirilmiş olan bilgisayar sistemleridir (URL-6).

Ayrıca eklemek gerekirse, insan beyni içerisinde yaklaşık olarak 10^{11} adet nöronun varlığından söz edilmektedir. Bilgisayar sistemlerine bu sayı ile modelleme yapılması henüz mümkün değildir. Fakat günümüz itibarıyla insan beyni ile yarışma kapasitesine sahip olmasalar bile, YSA'lar yapısal olmaları ve hassasiyet ile çalışmaları sebebiyle pek çok alanda kullanılarak başarılı sonuçlar vermektedirler (Öztemel, 2012; Soltoggio vd., 2018).

YSA, biyolojik sinir ağlarından modellenmiş oldukları için, öncelikle biyolojik sinir sisteminin yapısına bakılarak onun çalışma sisteminin anlaşılması gerekmektedir. Biyolojik sinir ağı, sinir hücrelerinin (nöronların) bir araya gelmesinden meydana gelir. Şekil 2.2'de gösterildiği gibi, tipik bir sinir hücresi 4 ana bölmeden oluşmaktadır. Bunlar, soma adı verilen hücre gövdesi, bir ucunda bir grup liflere benzeyen ve bağlı bulunduğu sinir hücresinden veya diğer organlardan bilgiler (sinyaller) getiren “dendrit” bağlantı elemanları, bir ucu sinir hücresine bağlı olup diğer ucunda snapsler bulunan

ve hücrede toplanan sinyalleri snapslere aktaran “aksonlar”, aksonlardan aldığı sinyali yeni bir sinir hücresine aktaran “snaps”lerdir.



Şekil 2.2. Biyolojik sinir hücresi (URL-7).

Bir biyolojik sinir hücresinin model alınarak oluşturulan yapay sinir hücreleri de girdi katmanı, çıktı katmanı, gizli katman, aktivasyon fonksiyonu olmak üzere dört ana bölümden meydana gelmektedir.

2.4.1 YSA’nın üstünlükleri

YSA’lar, biyolojik sinir ağlarının yapısı ve çalışma prensibinden esinlenerek ortaya çıkartılmıştır. Bu nedenle biyolojik sinir sisteminin sahip olduğu üstünlüklere de sahiptir.

2.4.1.1 Doğrusal olmama

YSA’lar tahmin yapmak için kullanıldığında özellikle doğrusal olmayan problemlerde istatistiki hesaplama yöntemlerine kıyasla daha doğru ve kolay bir şekilde sonuç vermektedirler. YSA’da bulunan nöronların doğrusal olmaması ve aynı zamanda doğrusal olmayan sonuçlar vermesi sebebiyle ağ da doğrusal değildir. Ağın bu özelliği sebebiyle YSA’lar doğrusal olmayan karmaşık problemlerin çözümünde yaygın olarak kullanılmaktadır.

2.4.1.2 Paralellik

YSA'lar, mevcut problem çözme algoritmalarından farklı olarak paralel çalışma yapısına oldukça uygundur. Hızlı bir şekilde problem çözebilme yeteneği bu özelliği ile ortaya çıkmıştır.

2.4.1.3 Hata toleransı

Klasik bilgisayar algoritmalarında, yerinden alınan herhangi bir işlem elemanı, algoritmayı etkisiz bir hale sokar. Ancak YSA'larda bir elemanda oluşan hasar, sistemin genel performansında ciddi bir eksikliğe yol açmaz. YSA'ların paralel olarak çalışması, hız avantajı ile birlikte yüksek hata imkânı da sağlamaktadır. YSA, çok sayıda nöronun farklı şekillerde bağlanmasıyla meydana geldiğinden paralel bir yapıya sahiptir. Ağın sahip olduğu bir bilgi ağıdaki tüm bağlantılara dağılmaktadır. Bu nedenle, bazı yerlerde meydana gelen aksaklıklar, ağın doğru sonuç üretmesini önemli ölçüde etkilemez. Diğer tahmin yapan algoritmalar göre hatayı tolere etme yetenekleri oldukça yüksektir.

2.4.1.4 Öğrenebilirlik

Klasik algoritmaların büyük bir çoğunluğu, oluşturulan eşitliklerin hesaplanması ile aynı girdi değerleri için aynı çıktıları üretmektedirler. YSA'lar bu lineer algoritmaların aksine programlara öğrenme yeteneği kazandırmışlardır. Klasik algoritmalarda sadece net olarak tanımlı bir çözüm yolu bulunan problemler çözümlenebilirken, YSA sayesinde çözüm yöntemi hakkında bilgi verilmeden çözümleme yapılabilir. YSA'nın aynı tipte problemleri çözümleyebilmesi için gereken tek şey bir örnek girdi için sonuçların bulunmasıdır.

2.4.1.5 Genelleme

YSA'lar çalışılan probleme göre eğitildikten sonra öğretilmeyen durumlar için de cevap verebilmektedir. YSA öğrendiklerinden yola çıkarak öğrenmediklerine ulaşabilmektedir.

2.4.1.6 Uyarlanabilirlik

YSA çözmeye çalıştığı probleme göre kendi kendini düzelterek ağırlıklarını belirler. Karmaşık bir problemi çözmek için eğitilmiş olan YSA, herhangi bir başka problemi çözmek için de rahatlıkla kullanılabilir. Bu konuda gereken tek şey yeni problemin girdi ve çıktıları parametreleri ile ağıın tekrar eğitilmesidir.

2.4.1.7 Hız

YSA'lar paralel yapıda olmaları sebebiyle problem çözmede oldukça hızlı bir şekilde sonuca ulaşma yeteneğine sahiptir. Ayrıca bu özelliğinden dolayı bilgisayar donanımı üzerinde de rahatlıkla gerçekleştirilebilir.

2.4.1.8 Analiz ve tasarım kolaylığı

YSA'ların temel yapı taşı olan yapay sinir yapısı bütün YSA'larda aynıdır. Bundan dolayı yapay sinir hücresinin tasarımından sonra bu temel eleman ile YSA'lar kolaylıkla oluşturulabilir. YSA'ların temel yapısının da aynı olmasından dolayı her türlü problemin çözümünde kullanılabilmeye imkân sağlar (Öztemel, 2012).


2.4.2 YSA'nın yapısı

YSA'lar insan yapısındaki biyolojik sinir sisteminden esinlenilerek oluşturulmuştur. Biyolojik sinir sisteminde bulunan nöronlar, birbirleri ile iletişimlerini sinapslar sayesinde gerçekleştirirler. Bir nöron işlediği bilgiyi aksonu ile başka bir nörona gönderir. Bu doğal yapıyı taklit eden yapay sinir hücreleri de dışarıdan gelen bilgiyi toplama fonksiyonu yardımı ile toplayarak aktivasyon fonksiyonundan geçirir ve çıktıyı oluşturur. Üretilen çıktı ağıın bağlantısı üzerinden başka bir yapay sinir hücresine (proses elemanına) gönderilir. Farklı yapılarda toplama ve aktivasyon fonksiyonları kullanılmaktadır. YSA'ları birbirine bağlayan ise ağırlık değerleridir. Birbirine paralel olan proses elemanları 3 katman olarak bir ağı yapısını oluşturur. Bunlar;

- Girdi katmanı
- Gizli (Ara) katman
- Çıktı katmanı

Ağa verilen bilgiler girdi katmanı sayesinde ağa ulaşır. Gizli katman ya da katmanlarda işlenerek çıktı katmanına ulaşır. Ağa verilen bilgilerin işlenmesi, ağdaki ağırlık değerleri kullanılarak bu bilgilerin çıktıya dönüştürülmesidir. Doğru çıktıların oluşturulabilmesi için ağırlık değerlerinin doğru olması gerekmektedir. Doğru ağırlık değerlerinin bulunması, ağın eğitilmesi olarak tanımlanmaktadır. Ağırlık değerleri ilk olarak rastgele verilir. Ağın eğitilmesi sırasında ağa verilen her örnek ile ağdaki öğrenme kuralına göre ağırlık değerleri güncellenir. Her bir örnek ile ağdaki ağırlıklar değişir ve en doğru sonuç için ağırlık değerleri elde edilmeye çalışılır. Bu aşama, eğitim setindeki her girdi değeri için doğru çıktı değeri üretinceye kadar devam eder. Bu aşamadan sonra test veri setindeki değerler ağa verilerek doğru sonuç verip vermediği görülür. Doğru cevaplar verildiğinde ise ağ eğitilmiş kabul edilir. Bu ağırlıkların her birinin ne anlama geldiği bilinmemektedir. Bu nedenle YSA'lara **“kara kutu”** deyiimi yaygın olarak kullanılmaktadır. Ağırlık değerlerinin tek tek anlamlarının bilinmemesi ile birlikte, YSA'nın girdi değerleri ile oluşturduğu çıktı değerleri bu ağırlıklar kullanılarak ortaya çıkmaktadır. Böylelikle YSA'nın zekasının bu ağırlık değerlerinde gizli olduğu söylenebilir.


Ağın bir problemi çözmeyi öğrenmesi o problem için en doğru YSA modelinin seçilmesi ile mümkün olmaktadır. Şimdiye kadar çok sayıda YSA modeli geliştirilmiştir. YSA modelinin şekilsel gösterimi Şekil 2.3'te verilmiştir.



Şekil 2.3. YSA modeli.

2.4.3 YSA'nın elemanları

YSA hücresinin nöron modeli, biyolojik bir sinir hücresine göre çok daha basit bir yapıya sahiptir (Şekil 2.4). YSA, birbirlerine kademeli olarak bağlı ve beraber çalışabilen nöronlardan meydana gelmektedir.



Şekil 2.4. YSA elemanlarının yapısı.

En küçük ve temel bilgi işleme birimi olan nöronlar, bir veya birden fazla girdi alarak tek bir çıktı değeri verirler. Bir YSA hücresi girdi, ağırlık, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere 5 temel bileşenden oluşmaktadır (Yusri vd., 2018). Diğer nöronlardan gelen ya da dış ortamdan alınan girdi, YSA'daki ağırlıklarla çarpılarak diğer nörona bağlanır. Ağırlıklarla çarpılıp toplama fonksiyonu ile hesaplanan net girdi, aktivasyon fonksiyonundan geçirilmesiyle net çıktı elde edilir. Böylelikle nöron çıkışı da hesaplanmış olmaktadır.

2.4.3.1 Girdiler

YSA hücrelerini eğitmek amacıyla dış ortamdan verilen ya da başka bir yapay sinir hücresinden gelen bilgidir. Ağın eğitimi için kullanılan datalar, giriş katmanında nöron sayısını belirler.

2.4.3.2 Ağırlıklar

Ağırlıklar, hücreler arası bağlantının sayısal ifadesidir ve YSA hücresine gelen bilgilerin değerini ve hücreye olan etkisinin sayısal ifadesini gösterirler. Her girdinin

kendine özgü bir ağırlığı vardır ve devamlı değişkendir. Ağırlıklar, öğrenme eylemi sırasında girdi ve çıktı arasındaki ilişkiyi yakalayabilmek için pozitif, negatif ve sıfır olarak değişebilmektedirler. Ağırlık değerinin küçük ya da büyük olması, o ağırlığın önemli olduğunu göstermemektedir.

2.4.3.3 Toplama fonksiyonu

Toplama fonksiyonu, girdiler ile ağırlıkların çarpılarak nörona gelen girdilerin birleştirilmesi sonucu YSA hücresinin net girdi değerini hesaplayan fonksiyondur. Girdi ve ağırlıklar için bütünleştirme yapan pek çok toplama fonksiyonu mevcuttur. Ancak genellikle, girdi ve ağırlık değerinin çarpılması ile elde edilen değer aktivasyon fonksiyonuna gönderilir (Öztemel, 2012). Toplama fonksiyonunun yaygın olarak kullanılan pek çok çeşidi bulunmaktadır. Bu fonksiyon çeşidine karar vermek için herhangi bir formül bulunmadığından, hangi çeşidin kullanacağına deneme yanılma yolu ile karar verilmektedir. Yaygın olarak kullanılan toplama fonksiyonları Çizelge 2.5'te verilmiştir.

Çizelge 2.5. Toplama fonksiyonları.

Fonksiyon Adı	Fonksiyon Formülü	Açıklama
Toplam	$Net = \sum_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbirleriyle toplanarak Net girdi değeri hesaplanır.
Çarpım	$Net = \prod_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleriyle çarpılarak Net girdi hesaplanır.
Maksimum	$Net_i = Max(X_i * W_i)$	n adet girdi içinden ağırlıklar girdiler ile çarpıldıktan sonra içlerinden en büyüğü Net girdi olarak kabul edilir.
Minimum	$Net_i = Min(X_i * W_i)$	n adet girdi içinden ağırlıklar girdiler ile çarpıldıktan sonra içlerinden en küçüğü Net girdi olarak kabul edilir.
Çoğunluk	$Net = \sum_{i=1}^N Sgn(X_i * W_i)$	n adet girdi içinden ağırlıklar girdiler ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi kabul edilir.
Kümülatif Toplam	$Net = Net(eski) + \sum_{i=1}^N (X_i * W_i)$	Hücreye gelen bilgiler ağırlıklı olarak toplanır. Daha önce hücreye gelen bilgilere yeni hesaplanan girdi değerleri eklenerek hücrenin Net girdisi hesaplanır.

2.4.3.4 Aktivasyon fonksiyonu


Aktivasyon fonksiyonunda girdi olarak, toplama fonksiyonunun çıktı değeri kullanılır. Hücreye iletilen net girdi değerini işleyerek, üretilecek çıktıyı belirler. Genellikle bu fonksiyon, doğrusal olmayan bir fonksiyondur. Ayrıca, ağda bulunan tüm nöronların aynı aktivasyon fonksiyonunda olması gerekli değildir. Aktivasyon fonksiyonu seçilirken, ağ içerisindeki değerler ve yapısal özellikleri önemlidir. Örneğin; değerlerin hepsi 0-1 aralığında ise, sigmoid fonksiyonunun kullanılması uygun olacaktır. Yaygın olarak kullanılan aktivasyon fonksiyonları aşağıda verilmiştir. Ayrıca bu fonksiyonların matematiksel ifadeleri Çizelge 2.6’da gösterilmektedir.

Çizelge 2.6. Aktivasyon fonksiyonlarının matematiksel ifadeleri (URL-8).

AKTİVASYON FONKSİYONU	DENKLEM	ARALIK
Doğrusal Fonksiyon	$f(x) = x$	$(-\infty, \infty)$
Basamak Fonksiyonu	$f(x) = \begin{cases} 0 & \text{ için } x < 0 \\ 1 & \text{ için } x \geq 0 \end{cases}$	$\{0, 1\}$
Sigmoid Fonksiyonu	$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$	$(0, 1)$
Hiperbolik Tanjant Fonksiyonu	$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$(-1, 1)$
ReLU	$f(x) = \begin{cases} 0 & \text{ için } x < 0 \\ x & \text{ için } x \geq 0 \end{cases}$	$[0, \infty)$
Leaky (Sızıntı) ReLU	$f(x) = \begin{cases} 0.01 & \text{ için } x < 0 \\ x & \text{ için } x \geq 0 \end{cases}$	$(-\infty, \infty)$
Swish Fonksiyonu	$f(x) = 2x\sigma(\beta x)$ $\quad \beta = 0 \text{ için } f(x) = x$ $\quad \beta \rightarrow \infty \text{ için } f(x) = 2\max(0, x)$	$(-\infty, \infty)$

Basamak (Step) Fonksiyonu


İkili değer alan bir fonksiyondur ve ikili sınıflayıcı olarak kullanılır. Bu yüzden genellikle çıkış katmanlarında tercih edilir. Gizli katmanlarda türevi öğrenme değeri temsil etmediği için kullanılması tavsiye edilmez ve bu amaçla kullanıldığına rastlamak pek mümkün değildir (Şekil 2.5).



Şekil 2.5. Basamak (step) transfer fonksiyonu.

Doğrusal (Linear) Transfer Fonksiyonu


Doğrusal transfer fonksiyonunda çıktı değeri girdi değerine eşittir (Şekil 2.6). Doğrusal problemlerin çözümünde etkili olarak kullanılmaktadır. Aynı girdi değerler için hep aynı çıktı değerlerini üretmesi onun geniş yelpazede kullanılamayacağını göstermektedir.



Şekil 2.6. Doğrusal (Linear) fonksiyon ve türevi.

Sigmoid Fonksiyonu


Sürekli ve türevi alınabilir bir fonksiyon olan sigmoid fonksiyonunun doğrusal olmayışı sebebiyle YSA uygulamalarında çok sık kullanılmaktadır (Şekil 2.7). Bu fonksiyonda girdi değerlerinin her biri için 0 ile 1 aralığında çıktı değeri üretilmektedir.



Şekil 2.7. Sigmoid fonksiyonu ve türevi.

Hiperbolik Tanjant Sigmoid (TanSig) Transfer Fonksiyonu


Bu fonksiyon sigmoid fonksiyonuna benzer bir fonksiyondur (Şekil 2.8). Sigmoid fonksiyonunda çıkış değerleri 0 ile 1 arasında değişirken, hiperbolik tanjant fonksiyonunda -1 ile 1 arasında değişmektedir.



Şekil 2.8. Hiperbolik tanjant fonksiyonu ve türevi.

ReLU (Rectified Linear Unit/Doğrultulmuş Doğrusal Birim) Fonksiyonu


Fonksiyonda negatif değerler sıfır ile değiştirilir. Böylelikle ağ daha hızlı çalışmaktadır. Bu özelliğinden dolayı çokça tercih edilmektedir. Ancak negatif bölgede sıfır değerini alması bu değerlerinin türevinin de sıfır olması demektir. Yani bu bölgede öğrenme gerçekleşmemektedir (Şekil 2.9).



Şekil 2.9. ReLU fonksiyonu ve türevi.

Sızıntı (Leaky) ReLU Fonksiyonu

Bu fonksiyon ReLU'daki negatif değerlerin yok olmasını engellemek için geliştirilmiştir. Eksi bölgede bulunan sızıntıya 0.01 değeri verilmiştir. Sıfıra yakın ancak sıfır olmayan bu değer sayesinde ağı öğrenmesi negatif bölge için de sağlanmış olmaktadır (Şekil 2.10).




Şekil 2.10. Sızıntı ReLU fonksiyonu ve türevi.

Softmax Fonksiyonu

Sigmoid fonksiyonuna benzer olması sebebiyle sınıflandırma durumunda kullanıldığında oldukça iyi sonuçlar vermektedir. 0 ile 1 aralığında değerler oluşturarak, girdi parametresinin belirli bir sınıfa ait olma olasılığını belirler. Yani yorumlama yeteneğini olasılıksal metotla gerçekleştirir. Genellikle çıkış fonksiyonunda kullanılmaktadır.

Swish (A Self-Gated/Kendinden Geçitli) Fonksiyonu

ReLU'dan farklı olarak negatif bölgede değer almaktadır. Aldığı bu değerler doğrusal değildir. Bu fonksiyonda girdi değerleri ile sigmoid fonksiyonunun çarpımını çıktı olarak üretilmektedir (Şekil 2.11).



Şekil 2.11. Swish fonksiyonu ve türevi.

2.4.3.5 Çıktılar

Aktivasyon fonksiyonundan çıkan değer, nöronun çıktı değeridir. Nöronların çok sayıda girdi değeri olabilirken, tek bir çıktı değeri vardır. Bu çıktı değeri istenirse ağıın içerisindeki başka bir nörona girdi olarak kullanılabileceği gibi modelin son çıktı değeri olarak da kullanılabilir.

2.4.4 YSA'nın sınıflandırılması

YSA'lar işleyiş olarak aynı gözüktüğü de öğrenme yöntemi, ağ mimarisi ve bağlantı yapıları gibi özelliklerinden dolayı farklılık gösterebilmektedir. YSA'lar genel olarak üç ana kritere göre sınıflandırılmaktadır. Bunlar;

- Yapılarına göre,
- Öğrenme zamanına göre,
- Öğrenme algoritmalarına göre

2.4.4.1 YSA'ların yapılarına göre sınıflandırılması


Yapay sinir hücreleri tek başınayken problem çözümünde başarısız olurken, iki ya da daha fazla yapay sinir hücresinin bir araya gelmesiyle YSA oluşmaktadır. YSA'lar karmaşık problemlerin çözümünde oldukça yeteneklidirler. Birbirlerinden ayrı yapay sinir hücrelerinin birbirlerine bağlanma şekline “*Topoloji*” adı verilmektedir. Bağlantının yapılma şekline göre pek çok farklı topoloji olmasına rağmen genellikle ileri beslemeli ve geri beslemeli olarak ikiye ayrılmaktadır (Krenker vd., 2011; Arı ve Berberler, 2017). Şekil z’de ileri ve geri beslemeli ağ topolojisi şematize edilmiştir.

İleri beslemeli yapay sinir ağları

İleri beslemeli YSA'larda işlem elemanları arasındaki bağlantılar bir döngü oluşturmaz ve bu ağlar genellikle giriş verisine çok hızlı karşılık üretirler. Nöronlar girişten çıkışa doğru düzenli katmanlar şeklindedir ve bir katmandan sadece kendinden sonraki katmanlara bağ bulunmaktadır. Bir YSA'ya gelen veri sırasıyla; giriş, ara katmanlar ve çıkış katmanlarından geçer ve çıkış veri elde edilir.

Geri beslemeli yapay sinir ağları

Geri beslemeli YSA'larda bağlantılar döngüsel olarak çalışırlar. İleri beslemeli YSA'lardan farkı, bir nöronun çıktısının sadece kendinden sonra gelen nörona girdi olarak verilmeyip kendinden önce gelen nörona da girdi olarak tanıtılabilmesidir. Döngüsel süreç ile çalışıklarından girdi parametresini çıktıya dönüştürmeleri zaman alır. Bu nedenle de öğrenme süreleri daha uzundur (URL-9). İleri ve geri beslemeli ağ topolojisi Şekil 2.12’de görülmektedir.



Şekil 2.12. İleri ve geri beslemeli ağ topolojisi.

2.4.4.2 YSA'ların öğrenme algoritmalarına göre sınıflandırılması

YSA'ların, nörona verilen girdilere göre çıktı üretebilmesi, ağın öğrenebilme yeteneği sebebiyle olmaktadır. Öğrenme işleminin danışmanlı, danışmansız ve takviyeli öğrenme olmak üzere üç yolu vardır.

Danışmanlı Öğrenme: Ağa verilen girdi değerleri ile birlikte çıktı değerleri de verilir. Ağ, girdiler için istenen çıktı değerlerini verebilmek için sürekli olarak ağırlıklarını günceller. Ağdaki çıktılar ile gerçek çıktılar arasındaki hata oranları hesaplanarak ağdaki yeni ağırlık değerleri bu hata oranlarına göre yeniden belirlenir. Ağın tüm çıktıları ile gerçek çıktı değerleri arasındaki fark hesaplanarak her bir nörona düşen hata payı hesaplanır. Bu hata paylarına göre her nöron kendi ağırlık değerlerini günceller.

Danışmansız Öğrenme: Ağa öğrenme esnasında yalnızca örnek girdi değerleri verilmektedir. Verilen girdi değerlerine göre ağ kendi kurallarını oluşturur. Ağ, her verilen örneği kendi içerisinde sınıflandıracak şekilde kendine özgü kurallar oluşturur. Ağ, bağlantı ağırlık değerlerinden aynı özellikte olan kısımlarını ayırt edebilecek şekilde güncelleyerek öğrenme işlemini bitirir.

Destekleyici Öğrenme: Ağın her bir iterasyonu sonucunda ulaştığı sonuç değerinin iyi ya da kötü olup olmadığı hakkında bilgi verilir. Ağ, elde edilen bu bilgiler ile kendini tekrardan düzenler. Böylelikle ağ hem öğrenip hem sonuç üreterek çalışmaya devam eder.

Örneğin, satranç oynayabilen bir YSA, hamlenin iyi ya da kötü olduğunu o an ayırt edemez ancak yine de o hamleyi yapar. Oyun bittiğinde YSA oyunu kazanmış ise hamlelerinin iyi olduğu sonucuna varır. Bir dahaki oyunlar da bu hamlelerin iyi olduğunu varsayarak oynayacaktır (Bayır, 2006).

2.4.4.3 Yapay sinir ağlarının öğrenme zamanına göre sınıflandırılması

YSA'lar öğrenme zamanına göre ikiye ayrılırlar. Bunlar;

Statik Öğrenme: Bu kural ile çalışan YSA'lar öncelikle eğitilmelidir. Ağ eğitildikten sonra kullanılabilir. Fakat ağ üzerindeki ağırlıklarda hiçbir değişiklik yapılamaz.

Dinamik Öğrenme: Bu kural YSA'nın çalıştırıldığı her an öğrenmeye devam etmesi mantığı ile tasarlanmıştır. Eğitim aşaması bitirildikten sonra ağ kullanılırken çıktı değerlerine göre kendi ağırlıklarını değiştirerek çalışmaya devam eder.

2.4.5 Yapay sinir ağı kullanımının avantaj ve dezavantajları

YSA'lar işlevleri gereği bilgisayarların öğrenmesini sağlamaktadırlar. Söz konusu durumlara hâkim olarak, olaylara mantıklı bir açıdan yaklaşıp en uygun kararı verebilmektedirler. Sahip olunan bilgileri, sistemleri yapısındaki çok çeşitli veri işleme metotları ile çalıştırdıkları için geleneksel metotlara nazaran çok daha az bakiye hata oluştururlar. Kullanılan ya da elde edilen bilgilerin tamamı sistemde saklanmaktadır. Geleneksel programlardaki veri tabanı ya da dosyalama düzeneklerinden ziyade ağ bağlantılarında muhafaza edilir. Nöronların birkaçının işlevini yitirmiş olması durumunda anlamlı bilgilerin kaybolması durumu söz konusu değildir. Sisteme

tanıtılan örnekler, YSA'nın örnekleri ağı tanıtarak istenen çıktılar doğrultusunda ağı eğitilmiş olması ile sonuçlanmaktadır. Sistemin başarılı olması seçilen veri setiyle alakalı olup, sisteme iyi tanıtılmaması durumunda elde edilen çıkış verilerinin de yanlış olmasına yol açabilir. YSA'lar sisteme tanıtılan veri setleri ile eğitimleri sırasında tanıtılan örneklendirmelerden genellemeler çıkararak yeni örnekler hakkında bilgi üretebilirler. YSA'ların algılamaya yönelik olaylarda ki başarıları, yapılan çalışmalar dâhilinde kanıtlanmıştır. Sisteme tanıtılan örnekler halinde verilen örüntüler YSA'lar tarafından diğer örnekler ile ilişkilendirilebilir ve yeni örneklendirmelerinde hangi sete ne şekilde dâhil olabileceği konusunda karar verebilme yetileri mevcuttur. Sistemin online olarak öğrenebilme ve kendilerini eğitebilme yetenekleri mevcuttur. Eksik bilgi ile çalışabilmekte ve çıktı üretebilmektedirler. Bu ve benzeri durumlarda performans kaybı yaşanmaz. Ancak performans kaybının önemi eksik bilgiye göre değişiklik gösterir. Sisteme tanıtılan veri setinde ki unsurların önem dereceleri de eğitim sırasında tanıtılır. YSA'ların eksik bilgi ve veri kaybında dahi çalışabilmeleri, hatalara karşı toleransını gösterir. YSA'lar zamanla ağlar da oluşabilecek problemlerden dolayı yavaş ve göreceli bir bozulmaya uğrarlar. Bu bozulma dereceli bir şekilde (graceful degradation) gerçekleşir. Sistemde birden çökme gerçekleşmez. YSA'ların sahip olduğu bağlantıların tek başına bir anlamı yoktur. Sistemde bilgiler ağı dağıtılmış bir şekildedir ve hücrelerin bağlantı, ağırlık dereceleri o ağı bilgisini göstermektedir (Öztemel, 2012).

Bu sistemlerin en önemli dezavantajı donanım gereksinimidir. YSA'lar paralel işlem yapabilme yeteneğine sahiptir ve bu yüzden paralel çalışan işlemciler ile performans gösterirler. YSA'larda uygun veri setinin belirlenebilmesi için herhangi bir kural yoktur. Uygun olan ağ yapısı kişinin bu konudaki deneyimi ve çözülecek olan problem ile gerçekleştirilen deneme yanılma döngüsü ile belirlenebilmektedir. YSA'larda kullanılan hücre sayısı, öğrenme katsayısı ve gizli katman sayısı gibi parametrelerin belirlenmesinde kesin bir kural yoktur. Belirli kuralların olmaması ile birlikte her bir veri seti için farklı yaklaşımlar söz konusu olabilir.^[1]_{SEP}Sisteme öğretilmesi gereken durumun gösterilmesi de bazı sorunlara yol açabilmektedir. YSA'lar nümerik bilgilerle çalışmakta ve sisteme veriler tanıtılmadan önce hepsinin nümerik değerlere çevrilmesi gerekmektedir. Bu esnada oluşabilecek aksilikler sistemin verimini etkilemekte bu da doğrudan kullanıcının kabiliyetine bağlı olmaktadır. YSA'lar da

problemlerin çözümü sonrasında gerçekleşen olayların nasıl ve neden olduğu ile ilgili bilgi edinilemediğinden, sistemin davranışlarının açıklanması konusunda sıkıntılar yaşanmaktadır (Gönül vd., 2015).

2.5 Literatür Özeti

Bu bölümde bugüne kadar yapılmış olan literatürlerden elde edilmiş derlemeler yer almaktadır. Çevresel matrislerde çalışma konusu ile ilgili çalışmalar değerlendirilmiştir.

Fırat ve Güngör, (2004) Büyük Menderes Havzası'nda bulunan bir gözlem istasyonundan alınan verileri ile akarsular tarafından taşınan askı maddesi miktarını ileri beslemeli yapay sinir ağları ile tespit etmişlerdir. Akarsuyun debisini girdi, askı madde miktarı verisini ise çıktı parametresi olarak kullanmışlardır. Yapılan modelleme çalışması sonucunda gerçek değerler ile tahmin değerlerinin tutarlı olduğunu görmüşlerdir.

Pecoraino vd., (2008) Sicilya'da yeraltı sularında UOB izlemesi gerçekleştirmişlerdir. 2004-2005 yılları arasında 324 noktadan numuneler alınarak yapılan çalışmada, aralarında benzenin de bulunduğu 13 adet UOB izlemesi yapmışlardır. Petrol endüstrilerinin yoğun olduğu bölgede en yüksek benzen konsantrasyonlarını tespit etmişlerdir. Ayrıca, endüstriyel emisyonların ve araç egzozlarındaki eksik yanmanın da benzen miktarında artışa neden olduğunu eklemişlerdir.

Ülke vd., (2010) YSA modelinde günlük yağış ve akım verilerini girdi parametresi olarak kullanarak askıda katı madde yükünü tahmin etmişlerdir. Demirköprü Barajı için yapılan bu çalışmada toplam askıda katı madde için gerçek veriler ile model tahmin değerleri karşılaştırıldığında %10'dan daha az bir fark ortaya çıkmıştır. Böylelikle YSA modelinin bu çalışma için uygun olduğu sonucuna varmışlardır.

Elmolla vd., (2010) fenton prosesi ile sulardan antibiyotiklerin arıtımını tahmin edebilmek için YSA modelini kullanmışlardır. Gizli katmanda 14 nöron ve tanjant sigmoid transfer fonksiyonu ile eğitim algoritması olarak Levenberg–Marquardt geri yayılım algoritması seçilmiştir. Bu sonuçlar doğrultusunda, YSA'nın Fenton sürecinin

davranışını etkili bir şekilde tahmin edebileceği ve simüle edebileceği sonucuna varmışlardır.

Song vd., (2010) Çin’de bulunan Chanzhi yüzeysel su kaynağında sürekli ölçümü yapılan su kalite parametrelerinden sıcaklık, pH, toplam sertlik, çözülmüş oksijen, BOİ₅, nitrat ve amonyum azotu parametrelerine ait verileri temin etmişlerdir. Yılın 12 ayı içerisinde Mayıs, Ağustos ve Ekim aylarında yapılan ölçüm sonuçları ile kalan diğer aylar için YSA modeli ile tahmin çalışması gerçekleştirmişlerdir. Çalışma sonucunda YSA tahmini sonucunda elde edilen değerler ile ölçüm değerleri arasında %10’dan daha az hata payı olduğunu belirtmişlerdir.

Eren ve Turp, (2011) YSA modeli ile sızıntı suyundan nikel iyonlarının gideriminin tahmini ile ilgili çalışma yapmışlardır. YSA model yapısında girdi parametresi olarak başlangıç nikel konsantrasyonu, temas süresi ve adsorbent miktarını; çıktı parametresi olarak da nikel iyonlarının giderim verimini seçmişlerdir. Çalışılan ağ yapısında öğrenme algoritması olarak Levenberg–Marquardt geri yayılım algoritmasını kullanarak tek gizli katmanda 10 adet nöron ile çalışmışlardır. YSA modelinde R korelasyon katsayısını 0.99 olarak elde etmişlerdir. R korelasyon katsayısının 0.99 olması, modelin bu çalışma konusunda çok iyi bir tahmin yeteneğine sahip olduğunu göstermektedir.

Özdemir vd., (2011) YSA ve çoklu lineer regresyon (MLR) modelleri ile sulardan Sodyum Dodesil Benzen Sülfonat (SDBS)’ın adsorpsiyon yöntemi ile giderim veriminin tahmin çalışmasını gerçekleştirmişlerdir. Bağımsız değişkenlerden olan pH, adsorban dozu, sıcaklık, çalkalama periyodu ve çalkalama hızını model yapısında girdi parametresi olarak, bağımlı değişken olan SDBS’nin giderim verimini ise çıktı parametresi olarak belirlemişlerdir. Çalışmada, %8’lik Bakır klorür ve %10’luk Çinko klorür ile muamele edilmiş Polianilin adsorbent olarak kullanılmıştır. Model çalışmasında YSA için R korelasyon katsayılarını %8’lik Bakır klorür için %98, %10’luk Çinko klorür için ise %94 olarak elde etmişlerdir. MLR modelinde de yüksek korelasyonlu sonuçlar elde etmelerine rağmen YSA’nın bu çalışma için daha uygun bir model olduğunu belirtmişlerdir.

Subaşı ve Ersü, (2012) atıksu arıtma performansını tahmin edebilmek için YSA model yapısını kullanmışlardır. Model ağ yapısında girdi olarak, giriş ve çıkış olmak üzere KOİ, toplam katı madde, uçucu askıda katı madde ve sıcaklık parametrelerini seçmişlerdir. YSA modelinden %98'lik bir R korelasyon katsayısı elde etmişlerdir. Bu sonuca göre, literatürde belirtilen diğer modellere ek olarak YSA'nın da arazi ölçekli evsel atıksu arıtma tesisleri için kullanılabilir olduğunu ortaya koymuşlardır.

Altinkum, (2013) atmosferik ortamdaki UOB'lerin varlığına meteorolojik parametrelerin etkisini incelemek için YSA model yapısını kullanmıştır. YSA'da aralarında benzenin de bulunduğu 33 adet farklı UOB türü için ayrı ayrı model oluşturarak sonuçları değerlendirmiştir. Model sonuçlarında R korelasyon katsayısı 0.547 ile 0.818 arasında değişmektedir. Benzen için R korelasyon katsayısını 0.74 olarak rapor ederek, bu sonuçlar doğrultusunda YSA modelinin atmosferik ortamdaki UOB'lerin modellenmesinde başarılı olduğunu söylemektedir.

Meffe ve Bustamante, (2014) İtalya'daki yüzeysel su kaynaklarından Po, Arno ve Tiber nehirleri ile Milan, Bari, Roma ve Palermo'daki yeraltı sularında sularda pestisit, yasa dışı ilaçlar, farmasötikler, östrojen ve endüstriyel kirleticiler araştırması yapmışlardır. Bu çalışma 1997-2013 yılları arasındaki sonuçları içermektedir. Çalışma sonucunda 16 pestisit, 15 parmasötik, 13 endüstriyel kirletici, 7 östrojen ve 2 yasa dışı ilaç tespit edilmiştir. Benzen konsantrasyonu petrol endüstrisi yakınlarındaki noktalarda çok yüksek konsantrasyonlarda, mesafe ile birlikte diğer noktalarda düşük konsantrasyonlarda sonuçlar olduğu rapor edilmiştir.

Tahbaoub vd., (2014) Ürdün'de bulunan içme suyu kaynaklarından Zarqa Nehri ve bu nehir üzerinde bulunan üç adet barajdan Nisan-Ağustos 2010 tarihleri aralığında yüzeysel su örnekleri almışlardır. Örneklerde yarı uçucu organik kirletici tespitinde bulunan 55 adet kirleticinin izlemesini gerçekleştirmişlerdir. Kirletici değerleri kısa vadede uluslararası limit değerlerin altında kalmış olup, uzun vadede izlemenin yapılmasını önermektedirler.

Borshi vd., (2016) Arnavutluk'un Durres şehri Adriatik denizi kıyısında bulunan liman ve plaj civarından alınan 18 su numunesinde PAH ve BTEX analizleri gerçekleştirmişlerdir. Örnek alınan noktalarda BTEX kirleticileri içerisinde en

yüksek konsantrasyona sahip olan kirleticiyi benzen olarak belirtmişlerdir. BTEX'in tespit edildiği noktalardaki benzen sonuçları 13.4, 10.5, 8.5, 5.8, 0.2 ve 0.01 mg/L olarak kaydedilmiştir. Deniz suyu içerisindeki PAH ve BTEX konsantrasyonunun, yakınlarda bulunan petrol endüstrisi, deniz taşımacılığı, otomobil emisyonları gibi nedenlerden kaynaklandığını belirtmişlerdir.

Li vd., (2016) Çin'de bulunan Liaodong Yarımadası'nda mikrokirletici tespiti yapmışlardır. 5 adet kırsal bölgede bulunan 13 tane içme suyu temini yapılan kuyudan numuneler alınarak mikrokirletici taraması gerçekleştirilmiştir. Sonuç olarak 80 adet mikrokirletici tespit ederek, sağlık riskleri açısından değerlendirmişlerdir.

Masih vd., (2016) Hindistan'ın Gorakhpur şehrinde hava ortamındaki BTEX konsantrasyonları ile ilgili çalışma yapmışlardır. Ekim 2014-Kasım 2015 tarihleri arasında aylık olarak örneklemeler yaparak; yerleşim yeri, endüstriyel faaliyet alanı, yol kenarı ve tarımsal alanı temsil edecek noktalar seçmişlerdir. Elde ettikleri sonuçları yaz, kış ve muson mevsimleri olarak 3 bölümde incelemişlerdir. BTEX bileşenlerinin tümünde kış mevsiminde ve endüstriyel faaliyet gösteren alanda en yüksek konsantrasyonlarla karşılaştıklarını rapor etmişlerdir.

Arkoç vd., (2016) sodyum absorpsiyon oranı (SAR) değerinin tahmininde YSA model yapısını kullanmışlardır. 18 adet su kuyusundan 1 yıl boyunca aylık periyotlarla numuneler alınmış olup, pH, toplam sertlik, sıcaklık, klorür, iletkenlik ve toplam çözünmüş katı madde miktarını YSA girdi parametresi olarak kullanmışlardır. YSA model tahmini ile ölçülen değerler arasındaki R korelasyon katsayısını 0.885 olarak elde etmişlerdir. Bu çalışma ile yeraltı sularının daha kolay ve ucuz olarak izlenilmesinin mümkün olduğunu belirtmektedirler.

Senthil Kumar vd., (2017) Hindistan'ın Madurai bölgesindeki petrol yatakları ve yerleşim yerleri civarından 100 adet yeraltı suyu numunesi alarak benzen analizi yapmışlardır. Ocak, Şubat ve Mart aylarındaki ortalama benzen değerleri sırasıyla; 0.1 mg/L, 0.138 mg/L ve 0.06 mg/L olarak kaydetmişlerdir. Ayrıca, benzenin çocuklarda kanser riski yetişkinlere kıyasla 7 kat daha fazla olduğu sonucuna varmışlardır. ArcGIS programı ile bölgeye ait benzen haritaları oluşturmuşlardır.

Ürdün’de içme suyu temini yapılan Zarqa Nehri’nde bulunan 3 adet su rezervuarında Tahboub vd., (2017) yarı-uçucu organik bileşiklerin izlenmesi hakkında çalışmışlardır. Nisan-Ağustos 2010 ayları arasında aylık olarak alınan örneklerde 55 adet yarı-uçucu organik kirleticinin analizlerini gerçekleştirmişlerdir. Çalışma sonucunda, Ürdün’de yarı-uçucu organik kirleticilerin yüzey suyunun kirlenmesinde kabul edilebilir uluslararası sınırlar içinde olduğunu, ancak uzun vadeli izleme programlarının uygulanması gerektiğini ortaya koymuşlardır.

Su kalitesini ve öncelikli mikrokirleticilerin oluşumunu kontrol eden başlıca hidrokimyasal prosesleri belirlemek için Wanda vd., (2017) tarafından izleme çalışması yapılmıştır. Haziran 2014 - Nisan 2016 tarihleri arasında Kuzey Afrika’daki Mpumalanga, Gauteng ve Kuzey Batı bölgelerinde bulunan 44 su kaynağından iki aylık periyotlarda su numuneleri toplamışlardır. EMP’lerin oluşum ve taşınımlarında hidrokimyasal faktörlerin etkisini ortaya çıkarmak için hidrokimyasal modeller (Geochemist's Workbench, pH-REdox-Equilibrium ve Surfer) kullanmışlardır.

Hong vd., (2018) Çin ‘in Shenzhen bölgesinde bulunan 16 adet asfalt yol yüzeyinden kuru ve ıslak vakum ile alınan örneklerde benzen, toluen, etilbenzen ve ksilen ölçümleri yapmışlardır. Bu ölçümleri 2017 yılının kış mevsiminde gerçekleştirmişlerdir. Yapılan ölçümler sonucunda YSA ile modelleme yapılarak, insan sağlığı açısından risk haritası oluşturmuşlardır.

Piersanti vd., (2018) İtalya’nın merkezinde bulunan Kuzey Torrevaldaliga’daki kömürle çalışan termik santralden kaynaklanan atmosferik emisyonların insan ve canlı hayatının üzerindeki kanserojen ve toksik sağlık etkilerini araştırmışlardır. Benzenin de içerisinde bulunduğu pek çok tehlikeli kirletici incelemesini yaptıklarında sadece termik santral değil, diğer sanayi ve şehir kaynakları da hesaplama katıldığında önlem alınması gereken miktarların görüldüğünü tespit etmişlerdir.


García-Alba vd., (2019) İspanya’nın kuzeybatısında bulunan Eo Haliç’indeki suyun yüzme suyu olarak değerlendirilebilmesi için *Escherichia coli* (*E. Coli*) analizlerini gerçekleştirmişlerdir. Çalışmada maddi ve zaman olarak kâr sağlamak amacıyla su ortamındaki *E. Coli* miktarını tahmin etmek amacıyla YSA model yapısını

kullanmışlardır. Çalışma sonucunda R korelasyon katsayısını 0.83 olarak rapor etmişlerdir.

Bir diğer YSA çalışmasında Wang ve Deng, 2019 kuzey Meksika Körfezi'ndeki kıyı sularında Fekal koliform bakteri sayısını belirlemek için tahmin yöntemini kullanmışlardır. YSA ağ yapısında 1 adet gizli katmanda 12 adet nöron ile çalışmışlardır. Girdi parametresi olarak rüzgâr, tuzluluk, gelgit, su sıcaklığı, yağış ve güneş radyasyonu kullanılmıştır. İstiridye hasatının yapıldığı bu kıyı sularında 2001-2011 yılları arasında ıstiridyelerdeki fekal koliform bakteri sayısı verileri YSA modelinde kullanılmıştır. Model sonucunda elde ettikleri R korelasyon katsayısı 0.7421 olarak rapor etmişlerdir. YSA modelinin fekal olarak kirlenmiş ıstiridyelerin hasat ve tüketimini azaltmayı mümkün kıldığını ve böylece ıstiridye tüketicileri için sağlık riskini büyük ölçüde azalttığını belirtmişlerdir.

Alver ve Kazan, (2020) Mayıs 2018 - Şubat 2019 arasında 10 ay boyunca tam ölçekli membran filtrasyon ünitesinde arıtılan suda, 44 adet su kalite parametresi izlemesi yapmışlardır. Bu parametreler model girdisi olarak kullanılmadan önce PCA ile model girdi sayısını aralarındaki ilişkiye göre gruplandırarak azaltmışlardır. Elde edilen sonuçlar YSA ile modellenmiştir. Oluşturdukları YSA modelinin de MSE (ortalama karesel hata) değeri 0.00293 iken, R^2 değerini %98.758 olarak rapor etmişlerdir.

Orhaneli Çayı üzerinde yapılan çalışma alanı içerisinde 2 adet ilçe, 1 adet belde, 7 adet köy ve 5 adet mahalle bulunmaktadır. Bu yerleşim yerlerindeki toplam nüfus 96228 kişi olarak kaydedilmiştir. Bölge içerisinde yoğun olarak çalışan 3 adet termik santral ve yeraltı linyit kömürü işletmeleri bulunmaktadır.



Şekil 3.2. Orhaneli Çayı su yolu gösterimi.

Numune noktaları seçiminde yukarıda bahsi geçen nüfus, termik santraller ve yeraltı kömür işletmeleri göz önüne alınarak seçilmiştir. Bunun için Orhaneli Çayı boyunca 9 adet numune alma noktası belirlenmiştir. Bu numune alma noktaları Orhaneli Çayı'nın en çok kirleticiye maruz kaldığı bölgelerdir. Ayrıca bazı numune alma noktaları ise nüfusun yoğun olduğu yerleşim yerlerini kapsamaktadır. Buna ilaveten Orhaneli Çayı üzerinde tarımsal sulamanın etkin olduğu alanların bulunması da bu noktaların oluşturulmasında etkili olmuştur. Numune noktaları arası kuş uçuşu mesafeler Şekil 3.3'te gösterilmektedir.

Numune Alma Noktaları		Ö1	Ö2	Ö3	Ö4	Ö5	Ö6	Ö7	Ö8	Ö9
Tavşanlı İlçesi 1	Ö1									
Tavşanlı İlçesi 2	Ö2	2,78								
Tunçbilek Beldesi 1	Ö3	7,27	4,83							
Tunçbilek Beldesi 2	Ö4	9,45	7,03	2,20						
Tunçbilek Beldesi 3	Ö5	9,52	7,15	2,33	0,31					
Tunçbilek Beldesi 4	Ö6	10,55	8,38	3,67	1,85	1,56				
Orhaneli İlçesi 1	Ö7	61,74	58,97	55,71	54,21	54,34	54,49			
Orhaneli İlçesi 2	Ö8	69,29	66,56	63,48	62,05	62,20	62,41	8,24		
Orhaneli İlçesi 3	Ö9	70,47	67,74	64,75	63,35	63,52	63,76	9,93	1,91	

Şekil 3.3. Ölçüm noktaları arası kuş uçuşu mesafe cetveli (km).

Orhaneli Çayı boyunca numune alınan noktalardan elde edilen görüntüler Şekil 3.4’te gösterilmektedir.



Şekil 3.4. Numune alma noktalarından görüntüler.



Şekil 3.4 (devam). Numune alma noktalarından görüntüler.



Ö4




Ö5



Şekil 3.4 (devam). Numune alma noktalarından görüntüler.




Ö6



Ö7



Şekil 3.4 (devam). Numune alma noktalarından görüntüler.



Şekil 3.4 (devam). Numune alma noktalarından görüntüler.

3.2 Veri Toplama ve Analiz Yöntemi

Orhaneli Çayı'ndan aylık olarak toplanan su örnekleri, ISO 5667-6'ya göre alınmıştır. Numune alma sırasında temiz polietilen kapaklı cam şişeler kullanılmıştır. Şişe

numune alınacak nehir suyuyla tercihen doğrudan doldurulmuştur. Alınan numunelerin, akarsuyun kıyısı veya yatağının bulandırılmasıyla kirlenmesinden kaçınmak için dikkat edilmiştir. Nehir kıyısından bir teleskopik numune alma çubuğu ile numune alma şişeleri veya kapları direk olarak nehre daldırılarak yüzeyden 20-25 cm aşağısından alınmıştır. Örnekler araziden laboratuvara gelinceye kadar +4 °C’de ve karanlık ortamda muhafaza edilmiştir. 24 saat içerisinde laboratuvara getirilerek ekstraksiyon işlemi tamamlanmıştır.

3.2.1 Kullanılan kimyasallar

Laboratuvardaki analizler sırasında kullanılan kimyasal malzemeler, özellikleri ve kullanım amaçları detaylı olarak Çizelge 3.1’de verilmiştir.

Çizelge 3.1. Laboratuvar çalışmalarından kullanılan kimyasal malzemeler.

Kimyasal Madde	% Saflık	Firma	CAS No	Kimyasal Formülü
Metil Tert-Bütil Eter	≥%99.8	Sigma Aldrich	1634-04-4	(CH ₃) ₃ COCH ₃
Benzen	CRM	Restek	71-43-2	C ₆ H ₆
Sodyum Hidroksit	≥%98.0	Sigma Aldrich	1310-73-2	NaOH
Asetik Asit	≥%99.0	Merck	64-19-7	CH ₃ COOH
Helyum	≥%99.9	Linde	7440-59-7	He
Metanol	≥%99.9	Merck	67-56-1	CH ₃ OH

3.2.2 Analitik metotlar

Toplanan su örneklerinde yapılan analizlerin her birinin hangi metotla yapıldığı, aşağıda yer alan Çizelge 3.2’de verilmiştir.

Çizelge 3.2. Ölçüm metotları.

Parametre	Metot
pH	SM 4500 H ⁺
İletkenlik (µS/cm)	TS 9748 EN 27888
Çözünmüş Oksijen (mg O ₂ /L)	TS 6288 EN ISO 8467
Toplam Organik Karbon (mg/L)	SM 5310 B
Toplam Azot (mg/L)	ASTM D8083

Su örneklerinde pH ölçümü göre SM 4500 H⁺ metoduna göre ISOLAB marka portatif ölçüm cihazı ile gerçekleştirilmiştir. pH metre probu her kullanımdan önce saf su ile iyice temizlenmiş ve ardından standart pH çözeltileri (pH=4, 7 ve 10) yardımıyla doğrulaması yapılmıştır. İletkenlik ölçümü de ISOLAB marka portatif ölçüm cihazı ile, çözülmüş oksijen ölçümü ise Hach Lange marka HQ 30D flexi model arazi tipi cihaz ile gerçekleştirilmiştir. Toplam Organik Karbon ve Toplam Azot ölçümleri Shimadzu TOC-TN cihazı kullanılarak SM 5310B ve ASTM D8083 metotları ile yapılmıştır.

Benzen analizi, örneklerin sıvı-sıvı ekstraksiyon metodu ile Restek-Rxi 5Sil MS (30m*0.25mm*0.10µm) kapiler kolonu donanımlı Shimadzu GC QP2010 Plus/MS (Şekil 3.5) cihazında gerçekleştirilmiştir. 6 mL örnek ile 3 mL MTBE çözücüsü 2 saat boyunca cam baloncuk ilave edilmiş cam şişe içerisinde BIOSAN Multi RS-24 (Şekil 3.6) programlanabilir rotatör yardımıyla çalkalanmış ve faz ayrımı gerçekleştikten sonra 2 mL'lik viallere aktarılmıştır.



Şekil 3.5. Benzen analizinde kullanılan Shimadzu GC QP2010 Plus/MS.



Şekil 3.6. BIOSAN Multi RS-24 programlanabilir rotatör.

Benzen analizleri için Shimadzu GC QP2010 Plus/MS cihazında kullanılan işletme şartları Çizelge 3.3'te ve çoklu analizler sonucunda elde edilen dedeksiyon limiti ve geri kazanım yüzdeleri Çizelge 3.4'te sunulmuştur.


Çizelge 3.3. Benzen için GC/MS koşulları.

Cihaz	Shimadzu GC QP2010 Plus / MS		
Kolon	Rxi 5Sil-MS (30m*0.25mm*0.1µm)		
Enjeksiyon	Enjeksiyon sıcaklığı 220 °C; 2 mm düz kuvars astar; enjeksiyon hacmi 2 µL; Splitless enjeksiyon @ 5mL/dk MTBE için		
GC Programı	30 °C	0 dk.	
	5 °C/dk.	60 °C	0 dk.
	10 °C/dk.	200 °C	0 dk.
	12 °C/dk.	320 °C	10 dk.
Dedektör	MS; dedektör sıcaklığı 220 °C, interfaz sıcaklığı 320 °C, çözücü kesme süresi 2.5 dk.		
Taşıyıcı Gaz	Helyum (UHP), taşıyıcı gaz başlangıç hızı (45 °C) 35 cm/sn.		

Çizelge 3.4. Benzen için geri kazanım yüzdeleri ve LOD/LOQ değerleri.


Bileşen	Ortalama Süre (dk)	Geri Kazanım (%) (n=10)	LOD (µg/L)	LOQ (µg/L)
Benzen	4.62	92.7 ± 0.4	1.426	4.752

GC/MS'te benzen analizi için kullanılan kalibrasyon eğrisi Şekil 3.7'de verilmiştir. Hazırlanan eğri 1-500 µg/L konsantrasyon aralığında 7 noktalı olarak hazırlanmıştır. Geri kazanım çalışması 100 µg/L'lik standart üzerinde gerçekleştirilmiştir.



Şekil 3.7. Benzen kalibrasyon grafiği.

Şekil 3.7'de verilen kalibrasyon eğrisi benzen analizinde kullanılmıştır. Düşük ve yüksek konsantrasyonlardaki benzen miktarlarını da ölçebilmek için daha hassas bir kalibrasyon eğrisi hazırlanmıştır. Analizlerde ön çalışmalar sonucunda yüksek benzen konsantrasyonlarının da görülmesi nedeniyle, numuneler ikiyeşerli olarak cihaza verilmiştir. Bunlar, orijinal ve iki kat seyreltilmiş örneklerdir. Böylelikle düşük ve yüksek benzen konsantrasyonları da tespit edilmiştir. GC-MS cihazında yapılan benzen analizlerinden elde edilen bir kromotogram ve benzenin karakteristik iyonları (m/z) Şekil 3.8'de verilmiştir.



Şekil 3.8. Benzen analizine ait bir kromotogram ve karakteristik iyonları (m/z).

Şekil 3.8’de GC-MS cihazında analizi gerçekleştirilen benzen mikrokirleticisine ait bir kromotogram ve benzen karakteristik iyonlarının bulunduğu görüntüler bulunmaktadır. Benzen için m/z değerleri 77, 78 ve 79 olarak görülmektedir. Ayrıca, benzen piki 4.62 dakikada çıkmıştır.

3.3 İstatistiksel Yöntem

İstatistiki çalışma için, ANOVA metodu kullanılmıştır. ANOVA metodu ile varyans analizi, seçilen parametreler ile Benzen arasındaki ilişkiyi bulmak için kullanılmıştır. ANOVA analizi Excel 2019’da gerçekleştirilmiştir. Varyans analizi sonucuna göre numune alma noktaları ve termik santral arası mesafe ile mevsimsel farkın benzen konsantrasyonunda daha etkili olduğu sonucuna ulaşılmıştır. Bu yöntemle, her

faktörün hedef parametresi üzerindeki kuadratik ve etkileşimli etkilerinin istatistiksel önemi, Fischer (F-testi) testi %95 güven aralığında uygulanarak belirlenmiştir.

3.4 Temel Bileşen Analizi Uygulaması

TBA analizinde SPSS 25.0 yazılım programı kullanılmıştır. TBA analizi için Meteoroloji Genel Müdürlüğü'nden temin edilen nem, sıcaklık ve yağış parametreleri ile çözünmüş oksijen, iletkenlik, debi, toplam organik karbon ve toplam azot değerleri kullanılmıştır. YSA'ya verilecek olan girdilerin gruplandırılarak daha anlamlı hale gelmesi sağlanmıştır.

3.5 Yapay Sinir Ağları ile Modelleme Çalışması


3.5.1 Veri seti

Çok büyük veya küçük ağırlıklar nedeniyle sayısal taşmaları önlemek için giriş ve çıkış verileri (Benzen, toplam organik karbon, toplam azot pH, debi, iletkenlik, çözünmüş oksijen, sıcaklık, nem ve yağış) 0 ile 1 arasında normalleştirilmiştir. Uygulanan normalizasyon denklemi, Eşitlik 3.1'deki gibidir:

$$x_{norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (3.1)$$

Burada: x_{norm} normalleştirilmiş değer, x_i orijinal değer, x_{max} ve x_{min} sırasıyla maksimum ve minimum değerlerdir, bu nedenle normalleştirilmiş veriler 0 ile 1 arasındadır.

Model için kullanılan verilerin %70'i eğitim için, %15'i validasyon ve geriye kalan %15'i ise test için ayrılmıştır. YSA oluştururken MATLAB 2019b kullanılmıştır. Analizde kullanılan YSA modelinin topolojik yapısı, girdi ve çıktı parametreleri ile birlikte Şekil 3.9'da gösterilmektedir.



Şekil 3.9. Kullanılan YSA modelinin topolojik yapısı.

YSA modeli, giriş katmanında 3, çıkış katmanında 1 nörondan oluşmaktadır. Gizli katmanda (saklı katman) 1 adet katman kullanılmıştır. Gizli katmandaki nöron sayısı ise 1 ile 20 arasında çalıştırılarak hata performansları (MSE, Mean Square Error) karşılaştırılmıştır. Bu konu ile ilgili net bir kural olmadığından her model için kullanılacak olan nöron sayısı ağıın mimarisine ve girdi-çıkı parametrelerinin yapısına bağlı olarak değişmektedir. Bu nedenle deneme gizli katmandaki nöron sayısı deneme yanılma yöntemiyle seçilmiştir.

Yapay sinir ağında bulunan ara bağlantı nöronlarına ait ağırlık değeri Eşitlik 3.2'deki gibi hesaplanmaktadır.

$$W_{ix}^m = W_{ix}^{m-1} + W_{ix}^m = W_{ix}^{m-1} + \eta \times \delta_x^n \times A_i^{n-1} \quad (3.2)$$

Burada; W_{ix} bağlantı ağırlığı, η öğrenme oranı, δ_x^n hata sinyali, A_i^{n-1} bağlantı ağırlığı ile ilişkili alt katmanın çıkış değeridir. Toplama fonksiyonu, ağıdaki ilk adım olan tüm

girdilerin ağırlıklı toplamını hesaplamak için kullanılmaktadır. Bu fonksiyon Eşitlik 3.3'te verilmiştir.

$$f(x) = \sum_{i=1}^n (W_{ix} + a_i) \quad (3.3)$$

Bu çalışmada gizli katmanda aktivasyon fonksiyonu olarak hiperbolik tanjant sigmoid transfer fonksiyonu, tüm çıkış katmanı için ise lineer transfer fonksiyonu kullanılmıştır. YSA yapısı, gerçek değer ve YSA çıktı değeri arasındaki farkın minimize edilmesi ve R korelasyon katsayısının (R^2) maksimize edilmesi ile ayarlanır. Kullanılan denklemler Eşitlik 3.4 ve 3.5'te görülmektedir.

$$MSE = \frac{1}{N} \sum_{t=1}^N (Y_t - \hat{Y}_t)^2 \quad (3.4)$$

$$R^2 = 1 - \frac{\sum_{t=1}^N (Y_t - \hat{Y}_t)^2}{\sum_{t=1}^N (\hat{Y}_t)^2} \quad (3.5)$$


Mühendislik alanında yaygın olarak kullanılan 11 farklı geri yayılım algoritması seçilerek birbirleriyle kıyaslanmıştır. Çalışmanın bu aşamasında nöron sayısı 10 olarak sabit tutulup, geri yayılım algoritmaları denenmiştir. Elde edilen R korelasyon katsayıları ve MSE değerleri göz önünde bulundurularak model için en iyi algoritma seçimi gerçekleştirilmiştir.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu çalışma iki kısımdan oluşmaktadır. Çalışmanın ilk kısmında, Orhaneli Çayı'nda belirlenen noktalardan alınan su numunelerinde benzen analizleri, ikinci kısmında ise tek yönlü ANOVA ve TBA analizleri yapılarak, YSA ile benzen kirliliği modellenmiştir.

4.1 Çalışma Alanının Meteorolojik Verileri

Çalışma alanı ile ilgili meteorolojik veriler Meteoroloji Genel Müdürlüğü'nün 17704 (Tavşanlı) ve 18083 (Orhaneli) istasyonlarından temin edilmiştir. YSA modelinde girdi parametresi olarak kullanılan sıcaklık, yağış ve nem miktarlarının aylık ortalama değerleri detaylı olarak Şekil 4.1'de verilmiştir. Orhaneli ve Tavşanlı istasyonlarından elde edilen ortalama sıcaklık verilerine göre en yüksek hava sıcaklığı Temmuz ve Ağustos aylarında 22-24 °C aralığında; en düşük hava sıcaklığı ise Aralık ve Ocak aylarında 2-7 °C arasında değişmektedir. Yağış miktarlarında aylara göre salınımlar görülmekte olup, en yüksek yağış miktarı Mayıs ve Haziran aylarında, 2-5 kg/m² aralığında gerçekleşmiştir. En düşük yağışlı aylar ise Temmuz-Eylül arasında kaydedilmiştir. Bu istasyonlar için ortalama nem miktarı %50-90 aralığında değişmektedir.




Şekil 4.1. 2018 yılı aylık ortalama (a) sıcaklık, (b) yağış miktarları ve (c) nem.

4.2 Çalışma Alanının Fiziksel ve Kimyasal Özellikleri


Orhaneli Çayı boyunca belirlenmiş olan numune alma noktalarında ölçümü yapılan pH, iletkenlik ve çözülmüş oksijen parametrelerinin sonuçları Şekil 4.2’de; debi, toplam organik karbon ve toplam azot parametrelerinin sonuçları detaylı olarak verilmiştir. Bu analizler her bir numune alma noktası için aylık periyotlarda gerçekleştirilmiştir.

Orhaneli Çayı’nda belirlenen ölçüm noktalarından alınan su numunelerinde pH, iletkenlik, çözülmüş oksijen, toplam organik karbon ve toplam azot parametrelerinin analizleri gerçekleştirilmiştir. Şekil 4.2’de görülen pH parametresi 4-9 arasında değişmektedir. Ölçüm noktalarında aylık olarak değişimine bakıldığında, aylara göre birbirine yakın sonuçlar ile karşılaşmıştır. Çözülmüş oksijen değerleri 1.5 ile 11 mg/L arasında değişmekte olup; Temmuz, Ağustos ve Eylül aylarında sıcaklığın artmasıyla birlikte en düşük değerleri görülmektedir. İletkenlik parametresi aylara göre ele alındığında Şubat-Haziran arasında 140-480 $\mu\text{S}/\text{cm}$ aralığındayken; Temmuz-Ocak arasında 420-860 $\mu\text{S}/\text{cm}$ aralığında değerler görülmektedir. İletkenlik parametresi ile benzen arasında pozitif yönlü bir korelasyon mevcuttur. Su ortamında benzen varlığında iletkenlik değerlerinde de artış görülmektedir. Fakat bu durum mevcut su ortamında bulunan diğer kirleticiler ve fiziksel-kimyasal parametrelere göre değişkenlik gösterebilmektedir (Craig, 1998). Debi parametresinde aylara göre 10-80 m^3/s arasında değişen geniş bir aralık görülmektedir (Şekil 4.2). Bölgenin yağışlı dönemleri göz önüne alındığında debi salınımı kış-ilkbahar mevsimlerinde oldukça yüksek, yaz-sonbahar mevsimlerinde ise en düşük seviyelerde ölçümler elde edilmiştir. Orhaneli Çayı yaklaşık olarak 20-80 m^3/s arasında bir debiye sahiptir. Tüm bu debi salınımları çalışmada yer alan fiziksel parametreler, organik kirlilik ve benzen sonuçlarını da etkilemektedir. Suyun debisi arttıkça kirletici madde olan benzen parametresinin konsantrasyonunun azalması beklenir. Ancak, suya kirletici deşarjı ya da bunun gibi durumlar oluşursa bu durum değişiklik gösterebilmektedir. Toplam organik karbon ve toplam azot parametreleri için ilkbahar ve yaz aylarındaki konsantrasyonlar sırasıyla; 10-35 mg/L ve 0.01-3 mg/L aralığındadır. Sonbahar ve kış aylarında ise toplam organik karbon 70-100 mg/L; toplam azot 0.1-9 mg/L aralığındaki konsantrasyonlar tespit edilmiştir. TOK ve benzen arasında ise doğru orantılı olan bir

ilişki bulunmaktadır. Su ortamında benzen miktarındaki artış, TOK konsantrasyonunda da artışa sebep olmaktadır (Özdemir, 2018).




Şekil 4.2. Orhaneli Çayı çözülmüş oksijen, iletkenlik, pH, debi, toplam azot ve toplam organik karbon ölçümleri.



Şekil 4.2 (devam). Orhaneli Çayı çözünmüş oksijen, iletkenlik, pH, debi, toplam azot ve toplam organik karbon ölçümleri.


4.3 Orhaneli Çayı Boyunca Elde Edilen Benzen Sonuçları

Çalışmada, Ocak-Aralık 2018 boyunca aylık olarak 9 noktadan numuneler alınmıştır. Uygun numune alam ve saklama koşulları sağlanarak Aksaray Üniversitesi Çevre Mühendisliği Analiz Laboratuvarı'nda benzen analizleri yapılmıştır. Ölçülen benzen konsantrasyonlarının harita üzerinde gösterimi Şekil 4.3'te görülmektedir. Mevsimsel olarak benzen konsantrasyonlarının detaylı gösterimi Şekil 4.4-4.7 arasında verilmiştir.




Şekil 4.3. Orhaneli Çayı'ndaki benzen konsantrasyonlarının harita üzerinde gösterimi.

Şekil 4.3'te görüldüğü gibi Orhaneli Çayı boyunca ölçüm yapılan noktalarda ortalama değerlere bakılarak en yüksek benzen konsantrasyonları ile Ö4 ve Ö5 noktalarında elde edilmiştir. Haritada bu noktalardan sonra gelen Ö6 noktasında 500-700 µg/L aralığında değerler ölçülmüştür. En düşük konsantrasyonlar ise <100 µg/L seviyesinde ilk numune alma noktası olan Ö1 noktasında ölçülmüştür. Ö3, Ö8 ve Ö9 noktalarında ise 300-500 µg/L aralığında benzen konsantrasyonları bulunmuştur. Ö2 noktasında ise ortalama olarak 100-300 µg/L konsantrasyon aralığında sonuçlar elde edilmiştir.




Şekil 4.4. Ocak, Şubat ve Aralık aylarına ait benzen konsantrasyonları.

Aralık, Ocak ve Şubat aylarına ait benzen konsantrasyonları Şekil 4.4’de verilmiştir. Grafikte görüldüğü gibi Ö4, Ö5 ve Ö6 noktalarında 760-980 µg/L aralığında diğer noktalara oranla daha yüksek benzen konsantrasyonları ölçülmüştür. İlk ölçüm noktası olan Ö1’de Ocak, Şubat ve Aralık ayları için sırasıyla; 75, 73 ve 77 µg/L benzen konsantrasyonu tespit edilmiştir. Bu noktada diğerlerine göre daha düşük benzen konsantrasyonları ile karşılaşılmasının sebebi, endüstriyel alanların bu noktadan sonra başlaması ve akarsuyun akış yönünün Ö1’den Ö9’a doğru olduğu düşünülmektedir.




Şekil 4.5. Mart, Nisan ve Mayıs aylarına ait benzen konsantrasyonları.

Şekil 4.5’de Mart, Nisan ve Mayıs aylarına ait benzen konsantrasyonları bulunmaktadır. İlkbahar aylarında yapılan ölçümlerde 65-950 $\mu\text{g/L}$ gibi geniş aralıkta benzen konsantrasyonları görülmektedir. Kış aylarına göre nispeten daha düşük benzen konsantrasyonları ile karşılaşmıştır. Bunun nedeni, kış aylarında ısınmadan kaynaklı enerji ihtiyacının daha fazla olmasıdır. Ölçüm noktaları arasında yine Ö4, Ö5 ve Ö6 noktalarında kış aylarında olduğu gibi en yüksek benzen konsantrasyonları görülmektedir. Mart, Nisan ve Mayıs ayları için Ö6 noktasında 580-760 $\mu\text{g/L}$ aralığında benzen konsantrasyonu görülürken; bu aralık Ö7 noktasında 200-300 $\mu\text{g/L}$ ’dir. Ö6 - Ö7 noktaları arasında akarsu yakınında herhangi bir endüstriyel faaliyet ya da yerleşim yeri bulunmadığından ve mesafenin de fazla olması benzen konsantrasyonundaki azalmanın sebebi olabilir.




Şekil 4.6. Haziran, Temmuz ve Ağustos ayına ait benzen konsantrasyonları.

Haziran, Temmuz ve Ağustos aylarında ölçülen benzen konsantrasyonları Şekil 4.6’da görülmektedir. Yaz aylarında benzen konsantrasyonları 50 ila 630 µg/L arasında değişmektedir. Haziran, Temmuz ve Ağustos aylarında tüm ölçüm noktalarında birbirine çok yakın benzen konsantrasyonları ölçülmüştür. Örneğin, Ö2 noktasında Haziran ayında benzen konsantrasyonu yaklaşık 210 µg/L iken, Temmuz ve Ağustos aylarında sırasıyla 200 ve 230 µg/L’dir. Bu aylarda da diğer mevsimlerde olduğu gibi Ö4, Ö5 ve Ö6 noktalarında en yüksek benzen konsantrasyonları ile karşılaşmıştır. Isınmadan kaynaklı benzen salınımı yok denecek kadar az olduğundan tüm ölçüm noktalarında bir miktar azalma gözlemlenmiştir. Ancak endüstriyel faaliyetler ile araç trafiğinin devam etmesi sebebiyle sudaki benzen varlığını korumaktadır.



Şekil 4.7. Eylül, Ekim ve Kasım aylarına ait benzen konsantrasyonları.

Şekil 4.7’de Eylül, Ekim ve Kasım aylarına ait benzen konsantrasyonları verilmiştir. Yılın diğer aylarına göre farklı konsantrasyonlara rastlanmamıştır. Ö4 noktasında Eylül ayında 500 µg/L benzen konsantrasyonu ölçülürken, Kasım ayında bu değer yaklaşık 800 µg/L olmuştur. Endüstriyel faaliyetlerin artması, termik santrallerin çalışmaya devam etmesi ve ısınma amacıyla kömür ve benzeri kaynakların kullanılması nedeniyle bu sonuçlarla karşılaşmıştır. Diğer ölçüm noktaları için de aynı artış Şekil 4.7’de açıkça görülmektedir. Tüm çalışma boyunca endüstriyel faaliyetlerin yoğun olduğu alanların yakınında bulunan noktalarda yüksek benzen konsantrasyonları görülmüştür. Benzen konsantrasyonlarının kurak ve yağışlı mevsimler için dağılımı detaylı olarak Şekil 4.8’de verilmiştir.



Şekil 4.8. Benzen konsantrasyonlarının (a) kurak ve (b) yağışlı mevsimler için dağılımı.

Şekil 4.8’de görüldüğü gibi Haziran, Temmuz, Ağustos, Eylül ve Ekim ayları kurak mevsim olarak, yılın geri kalan ayları ise yağışlı mevsim olarak belirlenmiştir (URL-10; URL-11). Yağışlı mevsim için benzen konsantrasyonlarının kurak mevsime oranla genel olarak daha yüksek seviyede olduğu görülmektedir. Ö6 noktasında kurak mevsim için benzen konsantrasyonları 416-511 $\mu\text{g/L}$ aralığında iken; yağışlı

mevsimde bu aralık 539-789 µg/L seviyesine yükselmiştir. Diğer örnekleme noktaları için de benzer sonuçların elde edildiği görülmektedir. Yağışlı mevsim olarak görülen aylarda hava sıcaklığının da nispeten daha düşük olması benzen konsantrasyonundaki artışa etki etmektedir (Masih vd., 2016). Ayrıca yağışların artmasıyla hava ortamındaki benzenin su ortamına geçişi de mümkün olmaktadır.

Literatürde yapılmış olan birçok çalışma, bu çalışmadaki sonuçlara paralellik göstermektedir. Sicilya’da 2004-2005 yılları arasında Pecoraino vd., (2008) yeraltı suyunda aralarında benzenin de bulunduğu 13 adet UOB izlemesi yapmışlardır. 324 noktadan numuneler alınarak yapılan çalışmadaki benzen konsantrasyonları 0.01 ile 15 µg/L arasında değişmekte olduğunu ve petrol endüstrisinin yoğun olduğu bölgede en yüksek benzen konsantrasyonlarının bulunduğunu tespit etmişlerdir. Ayrıca, endüstriyel emisyonların ve araç egzozlarındaki eksik yanmanın da benzen miktarında artışa neden olduğunu eklemişlerdir. Adriyatik denizi kıyısında Borshi vd., (2016) PAH ve BTEX kirleticilerinin belirlenmesi amacıyla bir çalışma yapmışlardır. 18 noktadan aldıkları deniz suyu örneklerinde toplam BTEX konsantrasyonu maksimum 13.4 mg/L, minimum ise 0.01 mg/L olarak ölçmüşlerdir. Bu değerler oldukça yüksektir. Bu çalışmada Arnavutluk’ta bulunan 2 adet liman ve 1 adet sahil kıyısında benzen konsantrasyonunun yüksek çıkmasının sebebinin petrol endüstrisi nedeniyle sulara petrolün karışması olduğunu tespit etmişlerdir. Bu tespitle birlikte yapmış olduğumuz çalışma sonuçları ile paralellik göstermektedir. Ayrıca; kış aylarında ısınmadan kaynaklanan enerji ihtiyacının da artması nedeniyle evsel ve endüstriyel amaçlarla tüketilen kömür miktarları artmaktadır. Bu durum benzen konsantrasyonlarındaki artışı bir diğer sebebi olarak açıklanabilir. Meffe ve Bustamante, (2014) İtalya’da bazı yüzeysel ve yeraltı sularında 1997-2013 yılları arasında öncelikli mikrokirleticiler ile ilgili yapılmış çalışmaları içeren bir derleme çalışması ortaya koymuşlardır. Bu çalışmada, yeraltı suyunda öncelikli mikrokirleticilerden olan benzenin oldukça yüksek miktarda bulunduğunu bildirmişlerdir. Bu maksimum konsantrasyon 15×10^6 ng/L’dir. Bu tür yüksek benzen konsantrasyonlarının petrokimya sanayi faaliyetlerinin bir sonucu olarak bir akiferde tespit edildiğini söylemektedirler. Maré vd., (2014) de hava ortamında bulunan BTEX bileşenlerine, konutlarda yakılan yakıtlar ve trafikteki motorlu taşıtlardan kaynaklanan emisyonların sebep olduğunu vurgulamışlardır. Yine BTEX bileşenleri ile Masih vd.,

(2016)'nin yaptıkları çalışmada endüstriyel, konut, yol kenarı ve tarımsal alanlarda mevsimsel olarak izlemesini yapmışlardır. Çalışma sonucunda kış aylarında ve endüstriyel faaliyet gösteren alandan alınan örneklerde BTEX konsantrasyonlarının en yüksek seviyede olduğunu rapor etmişlerdir. Liu vd., (2020) Çin'in Lanzhou şehrinde yeraltı su kalitesini sıfırlandırmak için UOB'lerden 17 tanesinin ölçümlerini gerçekleştirmişlerdir. Bunlar içerisinde öncelikli mikrokirleticilerden olan benzen de bulunmaktadır. Yaptıkları çalışma sonucunda kalite sınıfları açısından yüksek UOB konsantrasyonları ile karşılaşmışlardır. Ayrıca, benzen konsantrasyonlarının 10 µg/L'den daha yüksek olduğunu ve yeraltı suyu kalite sınıflarından Sınıf III'ün sınır değerini (10 µg/L) aştığını rapor etmişlerdir.

4.4 YSA'daki Bileşenlerin İstatistiksel Açıdan Değerlendirilmesi

İstatistiksel çalışmada, tek faktörlü ANOVA metodu ile varyans analizi, seçilen parametreler ile benzen arasındaki ilişkiyi bulmak için kullanılmıştır. TBA ve YSA için kullanılacak olan verilerin numune alma noktaları arası mesafe ve mevsim hedef alınarak kullanılacağına, tek faktörlü ANOVA varyans analizi ile karar verilmiştir (Çizelge 4.1).

Çizelge 4.1. Tek faktörlü ANOVA sonuçları.


	Mesafe		Mevsim	
	<i>P</i> -değeri	F ölçütü	<i>P</i> -değeri	F ölçütü
Çözünmüş Oksijen	2.99084E-31		0.147513868	
İletkenlik	1.11575E-11		1.83729E-07	
pH	0.946702134		6.95712E-54	
Debi	0.00031342		0.646868657	
Nem	1.21951E-05	2.033294	9.30623E-15	1.889801
Sıcaklık	0.99999817		2.52739E-89	
Yağış	0.655843514		0.000145547	
Toplam Organik Karbon	0.999812592		6.36366E-41	
Toplam Azot	0.51730155		1.98723E-34	
Benzen	2.29163E-34		0.387573509	

Çizelge 4.1'e göre benzenin *P*-değeri numune alma noktalarına göre analiz edildiğinde 2.29163E-34 olarak hesaplanmıştır. Ayrıca, mesafe arasındaki fark istatistiksel olarak anlamlı çıkmıştır ($P < 0.05$) (Minareci vd., 2018). Bu modelin çok düşük olasılık

değerine ($P<0.0001$) sahip olması modelin %95 güven seviyesinde önemli olduğunu göstermektedir (Davarnejad vd., 2014). Bu değer ne kadar küçükse model o denli güvenlidir sonucuna varılmaktadır. Bu nedenle TBA ve YSA analizlerinde mesafe değerleri temel alınarak gerçekleştirilmiştir.


4.5 Temel Bileşen Analizi Sonuçlarının Değerlendirilmesi

TBA analizi YSA modeline girdi olarak verilen değişken sayısını azalmak ve veri setindeki sapmayı minimize etmek amaçlarıyla kullanılmaktadır (Granato vd., 2018). Çoklu girişi olan çalışmalarda parametre sayısından daha az sayıda dominant faktör bulunduğu esasına dayanmaktadır. Bu faktörler deneysel olarak analiz edilemez ve sensörlerle de tespit edilemedikleri için bunlara gizli faktörler adı verilmektedir (Platikanov vd., 2019). TBA tekniğinde çevresel faktörler, mutlak faktör yükleri ve ana bileşenler arasındaki varyansa göre seçilmektedir (Primpas vd., 2010). Yapılan çalışmada veri setindeki parametreler arasındaki ilişkileri belirleyerek ve tüm verileri temsil edebilecek bileşenleri tanımlayarak veri sayısını azaltmak amacıyla TBA kullanılmıştır. Ayrıca, TBA analizinde her parametre için bileşen puanları hesaplanmıştır. TBA analizinde, ilk olarak bileşenler tanımlanmış ve Şekil 4.9’da gösterilmiştir.



Şekil 4.9. Faktör analizi.


Şekil 4.9’da görüldüğü gibi, toplam 3 temel bileşen değişkenlerin toplam varyansının %100’ünü açıklayabilen 1’in üzerinde özdeğere sahiptir. Bu süreçte, Kaiser’in (Kaiser, 1960) kuralına göre orijinal değişkenler normalize edildiğinden, her değişkenin ortalaması 0 ve varyans 1’dir. Toplam varyansın tek bir değişkene göre daha az tanımlayıcı özelliği olduğundan, 1’den daha düşük bir özdeğere sahip bileşenler seçilmemiştir. Böylece toplam girdi sayısı 9’dan 3’e düşürülmüştür. Bu bileşenlerin yorumlanmasını kolaylaştırmak amacıyla Varimax bileşen rotasyonu gerçekleştirilmiştir. Bu yöntem ile herhangi bir bileşen üzerinde daha fazla ağırlığa (etkiye) sahip parametreleri belirleyerek bileşenlerin yorumlanmasını kolaylaştırırken, herhangi bir bilgi kaybı engellenmiş olur. Varimax rotasyonu sonuçları Şekil 4.10’da gösterilmektedir.



Bileşen	TB1	TB2	TB3
Nem	0.990	0.084	0.019
Sıcaklık	0.990	0.084	0.019
pH	0.981	-0.103	-0.068
Yağış	0.968	0.077	-0.172
Çözülmüş Oksijen	0.942	-0.163	-0.049
İletkenlik	0.259	0.893	0.033
Toplam Azot	-0.0405	0.836	0.216
Toplam Organik Karbon	0.234	0.250	0.913
Debi	0.511	0.042	-0.814
Toplam	4.871	1.729	1.727
% Varyans	59.649	21.826	12.873
% Toplam	59.649	81.475	94.348

Şekil 4.10. Her bir TB için açıklanan varyans oranları ve Varimax rotasyonu matrisi ile olası kaynakları.

Şekil 4.10'da görüldüğü gibi bileşenlerle ilişkili parametreler, 0.45'ten büyük olan bileşen yükleri dikkate alınarak belirlenmiştir (Tabachnick ve Fidell, 2001; Tezbaşaran ve Gelbal, 2018). Öngörülen birinci temel bileşen (TB1) içerisinde, nem, sıcaklık, pH, yağış ve çözünmüş oksijen parametreleri bileşen yük sırasına göre gruplandırılmıştır. Bu nedenle birinci temel bileşen, çalışmamızda göz önüne aldığımız benzer konsantrasyonu değişimini birinci derecede açıklamaktadır. TB1, toplam parametre varyansının %59.649'unu açıklamaktadır. İkinci temel bileşen (TB2), iletkenlik ve toplam azot (TN) parametrelerini içermekte olup, toplam varyansın %21.826'lık kısmını oluşturmaktadır. Son olarak üçüncü temel bileşen (TB3), toplam organik karbon (TOK) ve debi parametrelerini içermektedir. TB3 ise toplam parametre varyansının %12.873'lük kısmını açıklamaktadır. Sonuç olarak TB1, TB2 ve TB3 bileşenleri toplam parametre varyansının %94.348'lik kısmını temsil etmektedir. Girdi bileşenlerinden nem, sıcaklık, pH, yağış, çözünmüş oksijen, iletkenlik, toplam organik karbon ve toplam azot artı(+) yönlü; debi ise eksi(-) yönlü olarak matrisi etkilemektedir. Çingiroğlu (2018), Ergene Nehri'ndeki kirletici kaynakların belirlenmesi ile ilgili kapsamlı bir çalışma gerçekleştirmiştir. Bu çalışma içerisinde kullandığı TBA metodunda ilk üç temel bileşenin tüm datalar için toplam varyansın %50'sini açıkladığını tespit etmiştir.



Şekil 4.11. (a) TB1, (b) TB2 ve (c) TB3 için bileşen özdeğerleri.

Şekil 4.11’de yapılan TBA çalışmasından elde edilen temel bileşenlerin detaylı gösterimi bulunmaktadır. TB1’de içerisinde bulunan nem, sıcaklık pH ve çözünmüş oksijen parametreleri pozitif yönlü olarak sırasıyla; 0.99, 0.99, 0.981, 0.968 ve 0.942 bileşen yükleri ile katkı sağlamaktadırlar. TB2’de bulunan parametreler iletkenlik ve TN’dir. Bileşen üzerindeki katkı yükleri pozitif yönde iletkenlik için 0.893, toplam azot için 0.836’dır. Son olarak TB3 içerisinde bulunan toplam organik karbon parametresi pozitif yönlü olarak 0.913, debi parametresi ise negatif yönde 0.814’lük bir bileşen yüküne sahiptir.

Bir sonraki adımda, her bir numune alma noktasının bileşen skorları belirlenmiş ve skor katsayısı matrisi Çizelge 4.2’de verilmiştir. TBA sonucunda elde edilmiş olan bileşenlerin gerçek ağırlık ve yüzde varyans değerleri ise Çizelge 4.3’te gösterilmektedir.

Çizelge 4.2. Bileşenlerin puan katsayı matrisi.

	TB1	TB2	TB3
Ö1	0.183	-0.111	0.058
Ö2	0.042	0.583	-0.116
Ö3	0.188	-0.068	0.037
Ö4	0.044	0.165	-0.543
Ö5	0.194	0.04	0.066
Ö6	0.194	0.04	0.066
Ö7	0.177	0.07	-0.068
Ö8	0.105	0.003	0.612
Ö9	-0.075	0.521	-0.022

Çizelge 4.2’de tüm verilerin %100 ’ünü temsil eden bileşen puan katsayıları görülmektedir. Buradaki katsayılar YSA modelinde girdi olarak kullanılmıştır. Yapılan TBA analizinde verilerin normalizasyonu da gerçekleştirildiğinden ikinci bir normalizasyon işlemine gerek kalmadan YSA analizi gerçekleştirilmiştir.

Çizelge 4.3. Bileşenlerin gerçek ağırlık ve varyans değerleri.

Bileşen	Başlangıç Özdeğerleri	Parametre	Ağırlık	Toplam Ağırlık	Gerçek Ağırlık	% Varyans
TB1	5.368	Nem	0.990	4.871	1.091	12.849
		Sıcaklık	0.990		1.091	12.849
		pH	0.981		1.081	12.732
		Yağış	0.968		1.067	12.564
		Çözünmüş Oksijen	0.942		1.038	12.226
TB2	1.964	İletkenlik	0.893	1.729	1.014	11.946
		Toplam Azot	0.836		0.950	11.184
TB3	1.159	Toplam Organik Karbon	0.913	1.727	0.613	7.216
		Debi	0.814		0.546	6.434
Toplam					8.491	100

Çizelge 4.3'te bulunan gerçek ağırlık ve varyans değerleri, başlangıç özdeğerler esas alınarak yeniden hesaplama yöntemi ile elde edilmiştir. Tüm verilerin %100'ünü temsil etmektedir. Her bir bileşen içerisindeki parametrelerin kendi içerisinde sudaki benzen konsantrasyonunu hangi oranda etkilediği konusunda bilgi vermektedir.

4.6 Orhaneli Çayı'ndaki Değişkenlerin Korelasyon Analizi

Korelasyonların analizi (Pearson Korelasyon Analizi; SPSS 25.0), izlenen su ortamındaki benzen konsantrasyonları ile diğer analizleri yapılan değişkenler arasındaki ilişki hakkında bilgi edinmeye ve meteorolojik koşullar ile aralarındaki korelasyonları belirlemek amacıyla kullanılmaktadır. Pearson korelasyon analizi sonuçları Çizelge 4.4'te verilmiştir. Pearson korelasyon değerleri -1 ile +1 arasında değişmektedir. Bu aralık içerisindeki -1 ve +1 değerleri çok güçlü negatif ve pozitif korelasyonunu, 0 (sıfır) değeri ise korelasyon olmadığını ifade etmektedir (Abbas vd., 2019). Parametreler arası ilişki pozitif ya da negatif yönde; 0.00 - 0.25 çok zayıf, 0.26 - 0.49 zayıf, 0.50 - 0.69 orta, 0.70 - 0.89 güçlü ve 0.90 - 1.0 çok güçlü olarak belirlenmiştir. Korelasyonu orta, güçlü ve çok güçlü olan değerler çizelgede renklendirilmiştir.

Çizelge 4.4. Pearson korelasyon matrisi.

P/P	Çözünmüş Oksijen	İletkenlik	pH	Debi	Nem	Sıcaklık	Yağış	Toplam Organik Karbon	Toplam Azot
Çözünmüş Oksijen	1								
İletkenlik	0.181	1							
pH	0.961	0.158	1						
Debi	0.459	0.083	0.533	1					
Nem	0.887	0.295	0.955	0.512	1				
Sıcaklık	-0.587	0.295	0.955	0.512	1	1			
Yağış	0.869	0.271	0.948	0.647	0.978	0.978	1		
Toplam Organik Karbon	0.093	0.277	0.123	-0.553	0.283	0.283	0.094	1	
Toplam Azot	-0.576	0.546	-0.481	-0.323	-0.303	-0.303	-0.335	0.319	1

Pozitif yöndeki bir korelasyon, bir değişkenin değerindeki bir artışın, bağımlı değişken üzerinde pozitif bir etkiye sahip olduğunu göstermektedir. Sıcaklık parametresindeki artışın nem parametresinde pozitif yönlü bir artışa sebep olmaktadır. Ayrıca, Ç.O ve TN parametreleri arasında ise korelasyonun -0.576 olması, eksi yönlü orta dereceli bir ilişki olduğunu göstermektedir. Eksi yönlü korelasyonda, bir değişkenin değerinin pozitif yönlü artması, diğer değişkenin azalması (negatif yönlü arttığı) anlamına gelmektedir.

4.7 Orhaneli Çayı'ndaki Benzen Konsantrasyonlarının YSA Model Sonuçları

Orhaneli Çayı'ndaki benzen konsantrasyonunun modellenmesi için YSA kullanılmıştır. Benzen konsantrasyonu çıktı parametresi (bağımlı değişken), TB1, TB2 ve TB3 parametreleri ise girdi parametresi (bağımsız değişken) olarak YSA ağ yapısında kullanılmıştır. YSA modeli, MATLAB (R2019b) programı kullanılarak oluşturulmuştur.

Literatürde başarılı olduğu bildirilen birçok çalışmada ağ yapısı ile ilgili parametrelerin belirlenmesi için standart bir yöntem olmadığı ve tartışılan verilere göre parametre belirlemenin yapılabileceğinden bahsedilmiştir (Chen vd., 2013). Buna göre YSA yapısında kullanılan parametrelerin çoğunluğuna çeşitli denemeler sonucunda karar verilmiştir.

Eğitim, test ve validasyon için veri seti oranları değiştirilerek optimum ağ yapısı üzerinde çalışılmıştır. Veri setinin %70'i eğitim, %15'i validasyon ve %15'i test seti olarak kullanıldığında gerçeğe en yakın tahmin sonucuna ulaşıldığı görülmüştür. Veriler YSA'nın tahmin yeteneğinin geliştirilebilmesi için ağa rastgele şekilde tanıtılmıştır. Epoch sayısı 10000 iterasyon olarak belirlenmiştir (Jha vd., 2014). Epoch sayısının az ya da fazla olması, alt ya da üst seviye uyumsuzlukları ortaya çıkmasına sebep olduğundan oldukça önemlidir. Böyle bir durumda model öğrenmek yerine ezber yapmaktadır ve başarılı sonuçlar elde edilememektedir.

Çok Katmanlı Algılayıcı (ÇKA) ağ yapısında 1 adet gizli katman kullanılmıştır. Literatürde birden fazla gizli katman kullanıldığında modele fazladan genelleme yeteneği katmadığı görülmüştür. Aksi olarak modelin ezberleme eğiliminin artmasıyla birlikte çok uzun hesaplama süreleri gerektirmektedir (Gündoğdu, 2006).


Çözümü istenen problem için model içerisinde hangi eğitim algoritmasının en hızlı sonucu vereceğini tahmin etmek oldukça zordur. Problemin karmaşıklığı, eğitim setinin içerisindeki verilerin sayısı ve daha pek çok faktör bu duruma etki etmektedir (Yetilmezsoy ve Saral, 2007; Akkoyunlu vd., 2010; Kırbaş, 2017). Çevre Mühendisliği alanında yaygın olarak kullanılan 11 geri yayılım algoritmasının her biri için model çalıştırılarak en yüksek korelasyon (R) ve en düşük hata payını (MSE) veren fonksiyon belirlenmiştir. Bu algoritmaların sonuçlarının karşılaştırılması Çizelge 4.5'te verilmiştir.

Çizelge 4.5. Geri yayılım algoritmalarının değerlendirilmesi.

Fonksiyon	R (Eğitim)	R (Validasyon)	R (Test)	R (Tüm)	MSE	İterasyon
<i>trainbfg</i>	0.5779	0.7271	0.1762	0.5478	0.19170	10
<i>trainscg</i>	0.7357	0.8332	0.5941	0.7292	0.11390	9
<i>trainrp</i>	0.7799	0.7795	0.3092	0.6927	0.34280	40
<i>traincgp</i>	0.8439	0.9317	0.8486	0.8592	0.06794	25
<i>traincgf</i>	0.6455	0.9177	0.8428	0.6977	0.08680	15
<i>traincgb</i>	0.7632	0.7421	0.5841	0.7368	0.08690	13
<i>trainoss</i>	0.0452	0.7985	0.2955	0.2098	0.13910	6
<i>traingd</i>	0.3565	0.7141	0.4825	0.4099	0.17399	7
<i>traingdx</i>	0.1553	0.4199	0.3805	0.2202	0.26512	9
<i>traingdm</i>	0.0471	0.2781	0.1573	0.0968	0.67630	9
<i>trainlm</i>	0.9768	0.9545	0.9813	0.9624	0.05478	4


Çizelge 4.5’te verilmiş olan geri yayılım algoritmalarının tümü 1 adet gizli katmanda 10 nöron ile çalıştırılmıştır. R korelasyon katsayısı en yüksek (0.9624) ve en düşük ortalama karesel hatayı (MSE) (0.05478) veren geri yayılım algoritması *trainlm* (Levenberg-Marquardt)’dir. Levenberg – Marquardt algoritması eğitimde sağladığı hız ve kararlılık sayesinde YSA yapılarında sıklıkla kullanılmaktadır (Ghoreishi ve Heidari, 2013; Thambavani ve Kavitha, 2014; Arkoç vd., 2016; Gholizadeh ve Sabzi, 2017). Veriler ağa tanıtılmadan önce ağ üzerinde aynı oranda etki sağlamaları açısından verilere normalizasyon işlemi uygulanmıştır.

YSA’lar modelin gizli katmanında olan nöron sayılarına karşı çok hassastır. Gereğinden fazla nöron bulunması model sisteminde üst seviye uyumsuzluğa (overfitting) sebep olurken, çok az nöron bulunması ise alt seviye uyumsuzluk (underfitting) durumunun oluşmasına sebep olabilmektedir (Badkar vd., 2013). YSA modeli için kullanılacak olan en iyi nöron sayısının belirlenmesi için yapılan çalışmanın sonuçları Şekil 4.12’de görülmektedir.




Şekil 4.12. YSA modeline nöron sayısının etkisi.

Literatürdeki çalışmalar incelendiğinde ağdaki nöron sayısı yeterli olarak artırıldığında model öğrenme setini çok yüksek oranlarda doğru tanıyabilmektedir. Nöron sayısının gereğinden fazla artması ağ yapısının büyümesine neden olduğundan, modelde genellemenin azalması ve ezberlemenin artması kaçılmaz olmaktadır (Ghoreishi ve Heidari, 2013). Bu konuda kesin bir kural ya da sınır olmamakla birlikte, genellikle girdi parametresinin 2 katı kadar belirlenen nöron sayısında en iyi sonuçlar elde edilebilmektedir. Optimum nöron sayısı belirleme çalışmasında iterasyon sayısı sabit tutulmuştur (iterasyon=4). Modelin farklı nöron sayılarında çalıştırılması sonucunda gizli katmanda 6 adet nöron kullanılarak oluşturulan model için sonuçların en uygun olduğu görülmüştür (Şekil 4.12). Tek gizli katmanda 6 nöronla ağ yapısı oluşturulmuştur. Oluşturulan YSA ağ yapısı Şekil 4.13’de görülmektedir.




Şekil 4.13. YSA ağ yapısı.

YSA çalışmalarında ağın öğrenmesi ve gerçeğe en yakın sonuçları vermesi için, oluşturulan ağ yapısı üst üste çalıştırılmaktadır. Ağ, her seferinde bir ortalama karesel hata ve korelasyon katsayısı vermektedir. En az ortalama karesel hata ile en yüksek korelasyon katsayısını veren model sonuçları elde edildiğinde ağın çalışması durdurulur ve ağ kaydedilir. Bu çalışmada en düşük ortalama karesel hata ile en yüksek korelasyon katsayısını veren ağın regresyon sonuçları Şekil 4.14’te verilmiştir.



Şekil 4.14. YSA analizi sonucu (a) eğitim, (b) validasyon, (c) test ve (d) genel R korelasyon değerleri.




Şekil 4.15. YSA modelinin eğitim, validasyon ve test hataları.

Şekil 4.14'te görüldüğü gibi eğitim ve test verileri için 0.998'luk bir R korelasyon katsayısı edilmiştir. Validasyon verileri için ise R korelasyon katsayısı 1 ile mükemmel bir uyum gösterdiği görülmektedir. Modelin eğitiminde kullanılan çok az veri olmasına rağmen, modelin tahminlerinin modelin eğitiminde kullanılmayan verilerle uyuşması nedeniyle model tahminlerinin güvenilir olduğu söylenebilir. YSA sonuçlarına göre, R korelasyon katsayısı değerleri çıktının iyi açıklandığını belirtmektedir. Bu sonuç, YSA modelinin gerçek değerleri tahmin etmek için yeterince iyi olduğunu göstermektedir. Ayrıca, bu değerler YSA kullanan ve başarılı olan birçok çalışmanın korelasyon değeri sonuçlarına benzerdir (Khajeh vd., 2014; Arkoç vd., 2016). Şekil 4.15'te YSA modelinin eğitim, validasyon ve test hataları görülmektedir. En düşük MSE değerinin görüldüğü 4 iterasyonla en iyi model sonucu elde edilmiştir. Devamında artan iterasyonla artık model verilen örnekleri ezberlemeye başlar ve bu durum modelin tahmin kabiliyeti azalmasına neden olmaktadır. YSA modelinin gizli katman ve çıktı katmanı için ağırlık ve bias katsayıları Şekil 4.16'da özetlenmiştir.

Girdi	W_{Girdi}			W_{Gizli}	b_{Girdi}	b_{Gizli}
-0.075	-3.4080	1.8499	-0.0746	4.7878	2.6108	-2.7462
0.194	1.7233	-1.2658	3.4369	6.7849	3.8173	
-0.111	1.4758	1.6365	-0.2770	-0.5306	-0.1835	
0.583	4.4702	1.1346	1.9390	-3.5859	0.6903	
-0.543	8.5510	3.2019	1.6455	-4.0663	-1.2734	
0.612	-3.4888	-1.5507	1.1030	-2.2789	2.1994	


Şekil 4.16. Gizli ve çıktı katmanları için ağırlık ve bias katsayıları.

Uygulanan YSA modelinden elde edilen benzen tahminlerinin uygun olduğu, modelin MSE değeri ve R korelasyon katsayıları ile açıkça görülmektedir. Ancak, verilerin dağılım grafiği, hangi veri noktalarının uygun şekilde eşleştirilemediğini belirlemek için önemlidir. Bu nedenle benzen sonuçlarının YSA ve gerçek veriler için dağılım grafiği Şekil 4.17’de, YSA tahmini ve ölçülen benzen değerlerinin karşılaştırılması ise Şekil 4.18’de verilmiştir.



Şekil 4.17. YSA tahmini ve model çıktısı olan benzen konsantrasyonlarının ölçüm noktalarına göre karşılaştırılması.

Şekil 4.17’de görüldüğü gibi Ö5 ve Ö6 dışındaki tüm noktalar için analiz edilen benzen konsantrasyonları ile YSA modelinden elde edilen tahmin değerleri birebir örtüşmektedir. Ö5 ve Ö6 noktaları için ise sırasıyla; %6 ve %14 hata payıyla sonuç elde edilmiştir. Bu sonuçlar doğrultusunda oluşturulan ağ yapısındaki YSA modelinin geniş yelpazedeki benzen konsantrasyonları için başarılı tahminler yapabildiği görülmektedir. Bu konuda literatürde çeşitli çalışmalar bulunmaktadır.



Şekil 4.18. YSA tahmini ve ölçülen benzen değerlerinin karşılaştırılması.

Şekil 4.18’de verilen YSA tahmini ve ölçülen benzen değerlerinin karşılaştırılmasında görüldüğü gibi YSA tahmin modeli oldukça iyi çalışmaktadır. Değerler karşılaştırıldığında R^2 değeri 0.9778 olarak hesaplanmıştır. Bu korelasyon katsayısı modelin bu çalışma için uygun olduğunu ve benzer çalışmalarda güvenilir bir şekilde kullanılabileceğini göstermektedir.

Mamasın Barajı’nda Elhatip ve Kömür, (2008) su kalite parametrelerinden olan elektriksel iletkenlik ve çözünmüş oksijen değerlerini tahmin etmek için YSA model yapısını kullanmışlardır. Toplam askıda katı madde, periyot, yağış miktarı, sıcaklık, toplam azot ve örnekleme noktalarını girdi parametresi olarak ağ yapısına tanıtılmıştır. YSA tahmin modeli ile elde edilen sonuçlar ve analiz sonuçları arasında elektriksel

iletkenlik için % 6.46'lık, çözünmüş oksijen için ise %4.72'lik fark olduğunu rapor etmişlerdir. YSA modeli kullanarak nehir suyundaki mevcut katı madde konsantrasyonunun tahmini konusunda çalışma yapan Doğan, (2009) bağımlı değişken (çıktı parametresi) olarak yatak eğimi, akım debisi ve katı madde dane çapını kullanmıştır. Model ağ yapısında en iyi sonucun gizli katmandaki 2 adet nöron ile sağlanması üzerine, 60 adet deney verisi ile ağ yapısını oluşturarak 0.98'lik bir korelasyon katsayısı elde etmiştir. Bu sonuç doğrultusunda girdi ve çıktı parametreleri arasındaki lineer olmayan ilişkiyi açıklayabilmek için YSA model yapısının kullanılabileceğini belirtmiştir. Elmolla vd., (2010) YSA modeli yapısını kullanarak gerçekleştirdikleri fenton prosesinin antibiyotiklerdeki arıtma verimini tahmin çalışmasında R korelasyon katsayısını 0.997 olarak kaydetmişlerdir. Kullandıkları YSA modelinde eğitim algoritması olarak Levenberg–Marquardt geri yayılım algoritmasını seçmişlerdir. MSE değerinin ise 0.000376 olarak bulunması üzerine YSA'nın bu prosesi tahmin etme yeteneğinin olduğunu belirtmişlerdir. Çin'de çeşitli amaçlarla kullanılan Chanzhi yüzeysel su kaynağında yapılan çalışmada Song vd., (2010) su kalite parametrelerinden olan sıcaklık, pH, toplam sertlik, Ç.O, BOİ₅, nitrat ve amonyum azotu verilerini temin etmişlerdir. Mayıs, Ağustos ve Ekim aylarında ölçümü gerçekleştirilen bu parametreler için yılın geri kalan aylarındaki verilerde YSA tahmin modelini kullanmışlardır. Yapılan çalışma sonucunda ölçüm sonuçları ile YSA tahmin sonuçları arasında %10'dan daha az hata payı olduğunu rapor etmişlerdir. Eren ve Turp (2011) sızıntı suyundan nikel iyonlarının giderimini tahmin edebilmek için YSA modelini geliştirmişlerdir. YSA modelinde girdi parametresi olarak başlangıç nikel konsantrasyonu, adsorbent miktarı ve temas süresi parametrelerini; çıkış parametresi olarak da nikel iyonlarının giderim verimini kullanmışlardır. Öğrenme algoritması olarak Levenberg–Marquardt geri yayılım algoritmasının kullanıldığı tek gizli katmana sahip ağ mimarisinde 10 adet nöron ile çalışmışlardır. Geliştirdikleri YSA model yapısı ile Ni(II) iyonlarının giderimi için 0.99'luk bir R korelasyon katsayısı elde etmişlerdir. Bu sonuç doğrultusunda, modelin çok iyi bir tahmin yeteneğine sahip olduğu ve bu amaçla kullanılabileceğini belirtmişlerdir. Özdemir vd., (2011) sulardan Sodyum dodesil benzen sülfonat (SDBS)'in adsorpsiyon yöntemi ile gideriminde tahmin modelleri ile çalışmışlardır. YSA ve çoklu lineer regresyon (MLR) modellerinin kullanıldığı çalışmada pH, adsorban dozu, sıcaklık, çalkalama periyodu ve çalkalama hızı girdi parametresi, SDBS'nin giderim verimi ise çıktı parametresi

olarak belirlenmiştir. Adsorbent olarak %8'lik Bakır klorür ve %10'luk Çinko klorür ile muamele edilmiş Polianilin kullanılmıştır. Her iki adsorbent ile yapılan YSA çalışmasında %8'lik Bakır klorür için %98 ve %10'luk Çinko klorür için ise %94 lük R^2 değeri elde etmişlerdir. MLR modelinde de yüksek korelasyonlu sonuçlar elde etmelerine rağmen YSA'nın bu çalışma için daha uygun bir model olduğunu belirtmişlerdir. Altunkum (2013) çalışmasında YSA kullanarak atmosferik ortamdaki UOB'lerin tahmin modellemesi için meteorolojik parametrelerin etkilerini incelemiştir. 33 adet farklı UOB türü için ayrı ayrı YSA ağı oluşturarak sonuçları değerlendirmiştir. Aralarında benzenin de bulunduğu 33 tür için korelasyon katsayıları 0.547 ile 0.818 arasında değişmektedir. Benzen için R korelasyon katsayısını 0.74 olarak bularak, bu sonuçlar doğrultusunda YSA modelinin atmosferik uçucu organik bileşiklerin modellemesinde başarılı olduğunu söylemektedir. Hosseinzadeh vd. (2018), hava ortamında BTEX konsantrasyonu için tahmin yöntemi olarak YSA'nın diğer tahmin yöntemlerine göre daha doğru sonuçlar verdiğini belirtmişlerdir. İspanya'nın kuzeybatısında bulunan Eo Haliç'i'nde García-Alba vd., (2019) suyun yüzme açısından değerlendirilebilmesi için *Escherichia coli* (E. coli) analizlerini gerçekleştirmişlerdir. Yapılan çalışmada maddi ve zamansal açıdan kâr sağlamak amacıyla E. coli miktarının tahmininde YSA modelini kullanmışlardır. Çalışma sonucunda R korelasyon katsayısını 0.83 olarak rapor etmişlerdir. Wang ve Deng, (2019) kuzey Meksika Körfezi'nde istridye hasatının yapıldığı kıyı sularında fekal koliform bakteri seviyesini belirlemek için YSA model yaklaşımını tercih etmişlerdir. Fekal koliform seviyesinin çıktı parametresi olarak belirlendiği YSA modelinde, girdi parametresi olarak rüzgâr, tuzluluk, gelgit, su sıcaklığı, yağış ve güneş radyasyonu kullanılmıştır. Model yapısında 1 adet gizli katman kullanılmış olup, gizli katman 12 adet nöron içermektedir. 2001-2011 yılları arasında 7 farklı istridye hasat alanına ait fekal koliform miktarı verileri ile YSA model yapısını oluşturmuşlardır. Modelden elde edilen korelasyon katsayısı 0.7421'dir. Çalışma sonucunda YSA modelinin fekal olarak kirlenmiş istridyelerin hasat ve tüketimini azaltmayı mümkün kıldığı ve böylece istridye tüketicileri için sağlık riskini büyük ölçüde azalttığını rapor etmişlerdir.

5. SONUÇ VE ÖNERİLER

Son yıllarda, toplum sağlığını ve çevre güvenliğini etkileyen kirleticilerin izlenmesi giderek önem kazanmaktadır. Ülkemizde de son yıllarda Su Çerçeve Direktifi kapsamında mikrokirleticiler konusunda ciddi izleme çalışmaları yapılmaktadır. Mikrokirleticilerin yüzeysel su kaynaklarında tespit edilerek izlemesinin yapılması oldukça önemli olduğunda bu konuda çalışmalar yapılmıştır.

Teknolojinin gelişmesiyle birlikte işgücü ve maliyetten tasarruf sağlayan bilgisayar tabanlı programların kullanımı da yaygınlaşmaktadır. Bu amaçla kullanılan programlar arasında yapay zekâ temeli modelleme yazılımları başı çekmektedir. Bu sebeplerden, arazi çalışmalarına ek olarak Yapay Sinir Ağları (YSA) ile modelleme çalışmaları gerçekleştirilmiştir.

Bu tez çalışması, madencilik faaliyetlerinin yoğun olarak yapıldığı Kütahya ve Bursa il sınırlarında bulunan önemli bir yüzeysel su kaynağı olan Orhaneli Çayı'ndaki öncelikli mikrokirleticilerden benzen konsantrasyonunun mevcut durumunu ortaya koymaktadır. Ayrıca YSA ile benzen konsantrasyonlarının tahmini için modelleme çalışmaları gerçekleştirilmiştir. YSA çalışmasında kullanılan veri seti, 12 ay boyunca aylık olarak alınan su numuneleri ile yapılan analizler sonucunda oluşturulmuştur.

Orhaneli Çayı'nda tespit edilen benzen konsantrasyonları Şekil 4.4-4.7 arasında detaylı olarak verilmiştir. Orhaneli Çayı debisi için çalışma süresi boyunca oldukça geniş bir aralıkta sonuçlar elde edilmiştir. Özellikle çalışma alanının topoğrafik yapısı sebebi ile kurak-yağışlı dönemlerde debi 10-80 m³/s seviyelerinde ölçülmüştür. İlk ölçüm noktası olan Ö1'de 12 ay boyunca tespit edilen benzen konsantrasyonu 50-85 µg/L arasında değişmektedir. Bu değer YSKY'ye göre müsaade edilen sınır değer 5-8.5 katı arası daha yüksektir. Yıl boyunca yapılan analizlerde benzen konsantrasyonunda büyük değişimler görülmemesinin ve diğer ölçüm noktalarına göre daha düşük benzen konsantrasyonları elde edilmesinin sebebi, endüstriyel alanların bu noktadan sonra başlaması ve akarsuyun akış yönünün Ö1'den Ö9'a doğru olması sebebiyle olabilir. En yüksek benzen konsantrasyonları Ö4, Ö5 ve Ö6 noktalarında tespit edilmiştir. Bu noktalarda yıl içerisinde 400-980 µg/L gibi geniş ve oldukça yüksek bir aralıkta benzen konsantrasyonları tespit edilmiştir. Endüstriyel faaliyetlerin

yoğun olması, termik santrallerin bu bölgede yoğunlaşması ve yerleşim alanlarına yakınlıkları sebebiyle Ö4, Ö5 ve Ö6 ölçüm noktalarında bu yüksek benzen konsantrasyonlarının görüldüğü düşünülmektedir. Ö7 ve Ö8 noktalarında ise yakın çevrelerinde endüstriyel faaliyet ya da yerleşim yeri bulunmadığından diğer noktalara göre daha düşük benzen konsantrasyonları tespit edilmiştir (200-450 µg/L). Ö9 noktasına gelindiğinde 270-550 µg/L aralığında benzen konsantrasyonları ile karşılaşmıştır. İlkbahar ve yaz aylarında kış aylarına göre nispeten daha düşük benzen konsantrasyonları ile karşılaşmıştır. Bunun nedeni, kış aylarında ısınmadan kaynaklı enerji ihtiyacının daha fazla olmasıdır. Ancak termik santraller ve madencilik çalışmaları devam etmesi sebebiyle sudaki benzen varlığını korumaktadır.

Çalışma kapsamında; ANOVA varyans analizi ve TBA analizi yapılmıştır. ANOVA analizi sonucunda elde edilen verilerin mevsimsel olarak değil, numune noktaları temel alınarak YSA çalışmasının yapılması gerektiği anlaşılmıştır. TBA çalışmasında ise tüm değişkenlerin YSA modeline katkısı olması nedeniyle değerlendirmeye girdi olarak alınması gerektiği belirlenmiştir.

Tek faktörlü ANOVA testinde benzenin *P*-değeri noktalar arası numune alma noktalarına göre analiz edildiğinde 2.29163E-34 olarak hesaplanmıştır. Ayrıca, mesafe arasındaki fark istatistiksel olarak anlamlı çıkmıştır ($P<0.05$).

TBA analizi SPSS Versiyon 25 ile çalışmadaki numune alma noktaları (mesafe) temel alınarak analiz gerçekleştirilmiştir. Bu modelin çok düşük olasılık değerine ($P<0.0001$) sahip olması modelin %95 güven seviyesinde önemli olduğunu göstermektedir. Bu değer ne kadar küçükse model o denli güvenlidir sonucuna varılmaktadır. Bu nedenle TBA ve YSA analizinde numune alma noktaları temel alınarak girdi parametreleri oluşturulmuştur.

YSA model çalışması için MATLAB programı kullanılmıştır. YSA uygulaması için bu program içerisinde iki adet seçenek bulunmaktadır. Birincisi MATLAB içerisinde hazır olarak bulunan Neural Network Toolbox uygulaması, ikincisi ise ağ oluşturmadır. Bu çalışmada ağ oluşturarak YSA uygulaması yapılmıştır. Orhaneli Çayı'nda ölçümü yapılan parametrelerden benzen konsantrasyonuna etki edenler belirlenerek veri seti hazırlanmıştır. Uygulamada, verilerin %70'i eğitim, %15'i validasyon ve geriye

kalan %15'i de test aşamasında kullanılmıştır. YSA'nın öğrenme algoritması olarak "Geri yayımlımlı" algoritma, ağ yapısı olarak da "İleri beslemeli ağ" çalışmanın amacına uygun olarak seçilmiştir. Ağ içerisinde tek gizli katman kullanılmıştır.

YSA modelinde aktivasyon fonksiyonu olarak en az hata veren Hiperbolik Tanjant Sigmoid (TanSig) fonksiyonu, birleştirme fonksiyonu olarak da toplama fonksiyonu kullanılmıştır. Ayrıca, öğrenme algoritmaları içerisinde mühendislik çalışmalarında yaygın olarak kullanılan *trainbfg*, *trainscg*, *trainrp*, *traincgp*, *traincgf*, *traincgb*, *trainoss*, *traingd*, *traingdx*, *traingdm* ve *trainlm* fonksiyonları ile denemeler yapılmıştır. Ağ yapısına en uygun olan *trainlm* (Levenberg-Marquardt) algoritması seçilmiş olup, 0.9768 R korelasyon katsayısı elde edilmiştir. Öğrenme oranı (learning rate-lr) belirlemek üzere 0,05-1 aralığında denemeler yapılmış ve öğrenme oranı 0.8 olarak belirlenmiştir. YSA yapısında önemli olan iterasyon sayısının en doğru olarak belirlenebilmesi için 10000 olarak sabitlenmiştir. Modelin 1-20 aralığındaki nöron sayılarında çalıştırılması sonucunda gizli katmanda 6 adet nöron kullanılmasında en yüksek R korelasyon katsayısı (0.9889) ve en düşük MSE değeri (0.000678) elde edilmiştir. YSA yapısında tek gizli katmanda 6 nöronla ağ yapısı oluşturulmuştur.

Oluşturulan ağ yapısının gerçekleştirilen bu çalışmada oldukça iyi çalıştığı, elde edilen R korelasyon katsayısı (0.9889) ve MSE değeri (0.000678) ile ispatlanmıştır. Böylelikle, Orhaneli Çayı'nda yüzeysel su ortamında mevcut olan benzen miktarının YSA modellemesi ile tahmin edilebilirliği mümkün olmuştur. YSA modelinin kullanımının arazi ve laboratuvar çalışmalarındaki zaman ve iş gücünden tasarruf sağlanması, çalışmanın gerçekleştirdiği en büyük katkılardandır.

YSA modeli, yüzeysel su ortamlarındaki mikrokirletici miktarının modellenmesinde eldeki veri setinin miktar ve kalitesine bağlı olarak oldukça iyi sonuçlar verebilmektedir. Çalışma sırasında YSA'nın dinamik bir yapıya sahip olduğu ve sisteme tanıtılan her tür yeni bilgi için kendini çok kısa sürede güncelleyebildiği görülmüştür. YSA model sistemine katkı sağlayabilecek organik ve inorganik parametreler eklenerek yeni model eşitlikleri üretilebilir. Örneklem noktaları ve izleme periyotları artırılarak modelin tahmin yeteneğine katkıda bulunması düşünülmektedir. Ayrıca, kullanılan gizli katman sayısı artırılabilir ve nöron sayısında da uygun değişiklikler yapılabilir. Ancak burada dikkat edilmesi gereken nokta, YSA

tahmin yeteneğinin bozulmamasıdır. Ağın ezberlemesi değil, öğrenmesi üzerine çalışması gerekmektedir. Aksi gerçekleştiğinde ağ düzgün çalışmayacaktır. Bu çalışmada, ortaya koyulan avantajlarından ötürü YSA modeli ile benzer amaçlı tahmin modelleri entegre edilerek, farklı yapay zekâ esaslı modelleme çalışmaları da gelecekte yapılabilir. Yapay zekâ tabanlı farklı matematiksel modeller için kıyaslama yapılabilir.

Ayrıca, Orhaneli Çayı üzerinde gerçekleştirilen bu çalışmada öncelikli mikrokirleticilerden olan benzen kirleticisi ele alınmıştır. Bu çalışma temel alınarak hedef kirletici olarak birden fazla öncelikli mikrokirleticilerin de tespiti ve izlemesi yapılarak daha geniş hedef verileri ortaya konulabilir.

Bu konu ile ilgili olarak bölgede herhangi bir çalışma yapılmamış olmasından dolayı, bundan sonraki çalışmalara referans teşkil ederek yüzeysel su ortamlarındaki öncelikli mikrokirleticiler ve modellenmesi konusundaki çalışmalara katkı sağlaması aşîkardır.

KAYNAKLAR

- Abbas, H., Al-Salloum, Y.A., Elsanadedy, H.M. ve Almusallam, T.H., 2019. ANN models for prediction of residual strength of HSC after exposure to elevated temperature, *Fire Safety Journal*, 106, 13–28.
- Ahmed, N., Ok, Y.S., Jeon, B.H., Kim, J.R., Chae, K.J. ve Oh, S.E., 2019. Assessment of benzene, toluene, ethyl-benzene, and xylene (BTEX) toxicity in soil using sulfur-oxidizing bacterial (SOB) bioassay, *Chemosphere*, 220, 651-657.
- Akkoyunlu, A., Yetilmezsoy, K., Ertürk, F. ve Öztemel, E., 2010. A neural Network-Based Approach for the Prediction of Urban SO₂ Concentrations in İstanbul Metropolitan Area, *International Journal of Environment and Pollution*, 40, 4.
- Almeida, K.C.S., Oikawa, H., Oliveira, J. ve Duarte, C.L., 2006. Degradation of petroleum hydrocarbons in seawater by ionizing radiation, *Journal of Radioanalytical and Nuclear Chemistry*, 270, 1, 93–97.
- Altinkum, N., 2013. Meteorolojik parametrelerin atmosferik uçucu organik bileşikleri üzerine etkisinin yapay sinir ağları ile modellenmesi, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Alver, A. ve Kazan, Z., 2020. Prediction of full-scale filtration plant performance using artificial neural networks based on principal component analysis, *Separation and Purification Technology*, 230, 115868.
- Arkoç, O., Akıncı, T.Ç., ve Nogay, H.S., 2016. Yapay sinir ağları yardımı ile yeraltı suyunda sodyum absorpsiyon oranı (SAR) tahmini: ergene havzası doğu akiferi örneği, *Jeoloji Mühendisliği Dergisi*, 40, 2, 177-188.
- Arı, A. ve Berberler, M.E., 2017. Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı, *Acta Infologica*, 1, 2, 55-73.
- ATSDR, 2007a. Toxicological Profile for Benzene, Atlanta, Public Health Service, US Department of Health and Human Services.
- Badkar, D.S., Pandey, K.S. ve Buvanashakaran, G., 2013. Development of RSM and ANN based models to predict and analyze the effects of process parameters of laser-hardened commercially pure titanium on heat input and tensile strength, *The International Journal of Advanced Manufacturing Technology*, 65, 1319–1338.
- Babar, B., 2011. Asidik maden sızıntı sularını (AMS) arıtan akışkan yataklı reaktör performanslarının yapay sinir ağları (YSA) ile modellenmesi, Yüksek Lisans Tezi, Harran Üniversitesi, Fen Bilimleri Enstitüsü, Şanlıurfa.
- Borshi, X., Nuro, A., Macchiarelli, G. ve Palmerini, M.G., 2016. Determination of PAH and BTEX in water samples of adriatic sea using GC/FID, *International Journal of Current Microbiology and Applied Sciences*, 5, 11, 877-884.

- Carcinogenic effects of benzene: Update, 1998; EPA/60/p-97/001 U.S., Environmental Protection Agency, U.S. Government Printing Office, Washington DC, USA.
- Chang, S.H., Wu, C.H., Wang, R.C. ve Lin, C.W., 2017. Electricity production and benzene removal from groundwater using low-cost mini tubular microbial fuel cells in a monitoring well, *Journal of Environmental Management*, 193, 551-557.
- Chen, M.Y., Fan, M.H., Chen, Y.L. ve Wei, H.M., 2013. Design of experiments on neural network's parameters optimization for time series forecasting in stock markets, *Neural Network World*, 4, 13, 369-393.
- Cıgızoğlu, H.K., 2000. Suspended sediment estimation for rivers using artificial neural networks and sediment rating curves. *Turkish Journal of Engineering Environmental Science*, 26, 27-36.
- Çingiroğlu, F., 2018. Determination of river pollution sources using source apportionment method: Ergene River, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Craig, B., 1998. Predicting the conductivity of water-in-oil solutions as a means to estimate corrosiveness, *Corrosion*, 54, 8, 657-662.
- Darade, S.S. ve Bandela, N.N., 2017. A study and abatement of phenolic content in water from various sampling points in the vicinity of River Patalganga, *Environmental Nanotechnology, Monitoring & Management*, 7, 1-8.
- Darçın, P. ve Balanlı, A., 2018. Yapı ürünlerinden kaynaklanan uçucu organik bileşiklerin yapı biyolojisi açısından irdelenmesi, *Megaron*, 13, 4, 597-607.
- Deblonde, T., Cossu-Leguille, C. ve Hartemann, P., 2011. Emerging pollutants in wastewater: a review of the literature, *International Journal of Hygiene and Environmental Health*, 214, 442-448.
- Demirarslan, K.O. ve Doğruparmak, Ş.Ç., 2019. Maden kaynaklı trafik emisyonlarının dağılımlarının modellenmesi: Artvin örneği, *Artvin Çoruh Üniversitesi Doğal Afetler Uygulama ve Araştırma Merkezi Doğal Afetler ve Çevre Dergisi*, 5, 1, 11-21.
- Doğan, E., 2009. Katı madde konsantrasyonunun yapay sinir ağlarını kullanarak tahmin edilmesi, *İMO Teknik Dergi*, 4567-4582.
- Duan, X. ve Li, Y., 2017. Sources and fates of btex in the general environment and its distribution in coastal cities of China, *Journal of Environmental Science and Public Health*, 1, 2, 86-106.
- Efe, E. ve Çanga, D., 2017. Tek faktörlü çalışmalarda alt grup tasarımı kontrast analizi ve pamuk verilerine uygulanması, *KSÜ Doğa Bilimleri Dergisi*, 20 (Özel Sayı),

- Elhatip, H. ve K  m  r, M.A., 2008. Evaluation of water quality parameters for the Mamasin dam in Aksaray city in the central Anatolian part of Turkey by means of artificial neural networks, *Environmental Geology*, 53, 1157–1164.
- Elmolla, E.S., Chaudhuria, M. ve Eltoukhy, M.M., 2010. The use of artificial neural network (ANN) for modeling of cod removal from antibiotic aqueous solution by the fenton process, *Journal of Hazardous Materials*, 179, 127–134.
- EPA, 2009. Method 524:3: Measurement of Purgeable Organic Compounds in Water by Capillary Column Gas Chromatography/Mass Spectrometry, U.S. Department of Health and Human Service, USA.
- Erickson, T.A., Nijjar, R., Kipper, M.J. ve Lear, K.L., 2014. Characterization of plasma-enhanced teflon AF for sensing benzene, toluene, and xylenes in water with near-IR surface plasmon resonance, *Talanta*, 119, 151–155.
- EU, 1998. The Quality of Water Intended for Human Consumption. Official Journal of the European Communities, Council Directive 98/83/EC.
- Fırat, M. ve G  ng  r, M., 2004. Askı madde konsantrasyonu ve miktarının yapay sinir a  lları ile belirlenmesi, *  MO Teknik Dergi*, 219, 3267-3282.
- Gholizadeh, F. ve Sabzi, F., 2017. Prediction of CO₂ sorption in poly(ionic liquid)s using ANN-GC and ANFIS-GC models, *International Journal of Greenhouse Gas Control*, 63, 95–106.
- Ghoreishi, S.M. ve Heidari, E., 2013. Extraction of Epigallocatechin-3-gallate from green tea via supercritical fluid technology: Neural network modeling and response surface optimization, *Journal of Supercritical Fluids*, 74, 128–136.
- Gjesteland, I., Hollund, B.E., Kirkeleit, J., Daling, P.S., S  rheim, K.R. ve Br  tveit, M., 2019. Determinants of airborne benzene evaporating from fresh crude oils released into seawater, *Marine Pollution Bulletin*, 140, 395–402.
- Glaser, C., Schwientek, M. ve Zarfl, C., 2019. Designing field-based investigations of organic micropollutant fate in rivers, *Environmental Science and Pollution Research*, 26, 28633–28649.
- G  n  l, Y., Ulu,   ., Bucak, A. ve Bilir, A., 2015. Yapay sinir a  lları ve klinik ara  tırmalarda kullanımı, *Genel Tıp Dergisi*, 25, 104-111.
- G  zel, B., Canlı, O. ve   ktem Olgun, E., 2018. Sularda bulunan u  ucu organik bile  şikler ve sa  lı  a etkileri, *Anadolu   niversitesi Bilim ve Teknoloji Dergisi C- Ya  am Bilimleri ve Biyoteknoloji*, 7, 2, 277-290.
- Granato, D., Santos, J.S., Escher, G.B., Ferreira, B.L. ve Maggio, R.M., 2018. Use of

- principal component analysis (PCA) and hierarchical cluster analysis (HCA) for multivariate association between bioactive compounds and functional properties in foods: A critical perspective, *Trends in Food Science & Technology*, 72, 83–90.
- Grigoratos, T. ve Martini, G., 2014. Brake wear particle emissions: a review, *Environmental Science and Pollution Research*, 22, 4, 2491-2504.
- Gruchlik, Y., Linge, K. ve Joll, C., 2018. Removal of organic micropollutants in waste stabilisation ponds: A review, *Journal of Environmental Management*, 206, 202-214.
- Hoffer, M. ve Shuker, L. 2000. ILSI workshop on assessing health risks from environmental exposure to chemicals: the example of drinking water, summary report, *Food and Chemical Toxicology*, 38, 3-12.
- Hong, N., Liu, A., Zhu, P., Zhao, X., Guan, Y., Yang, M. ve Wang, H., 2018. Modelling benzene series pollutants (BTEX) build-up loads on urban roads and their human health risks: implications for stormwater reuse safety, *Ecotoxicology and Environmental Safety*, 164, 234–242.
- Hosseinzadeh, A., Najafpoor, A.A., Jafari, A.J., Jazani, R.K., Baziar, M., Bargozi, H. ve Piranloo, F.G., 2018. Application of response surface methodology and artificial neural network modeling to assess non-thermal plasma efficiency in simultaneous removal of BTEX from waste gases: Effect of operating parameters and prediction performance, *Process Safety and Environmental Protection*, 119, 261–270.
- Ivana Cesarino, I., Cesarino, V., Moraes, F.C., Ferreira, T.C.R., Lanza, M.R.V., Mascaro, L.H. ve Machado, S.A.S., 2013. Electrochemical degradation of benzene in natural water using silver nanoparticle-decorated carbon nanotubes, *Materials Chemistry and Physics*, 141, 304-309.
- Jechalke, S., Vogt, C., Reiche, N., Franchini, A.G., Borsdorf, H., Neu, T.R. ve Richnow, H.H., 2010. Aerated treatment pond technology with biofilm promoting mats for the bioremediation of benzene, MTBE and ammonium contaminated groundwater, *Water Research*, 44, 1785–1796.
- Jiang, J.Q., Zhou, Z., Patibandla, S. ve Shu, X., 2013. Pharmaceutical removal from wastewater by ferrate(VI) and preliminary effluent toxicity assessments by the zebrafish embryo model, *Microchemical Journal*, 110, 239–245.
- Jiang, J.Q., Zhou, Z. ve Sharma, V.K., 2013a. Occurrence, transportation, monitoring and treatment of emerging micro-pollutants in waste water — A review from global views, *Microchemical Journal*, 110, 292–300.
- Jolliffe, I.T. ve Cadima, J., 2016. Principal component analysis: a review and recent developments, *Philosophical Transactions Royal Society A*, 374, 20150202.

- Kaiser, H.F., 1960. The application of electronic computers to factor analysis. *Educational and Psychological Measurement*, 20, 1, 141-151.
- Khajeh, M., Kaykhaii, M., Hashemi, S.H. ve Shakeri, M., 2014. Particle swarm optimization–artificial neural network modeling and optimization of leachable zinc from flour samples by miniaturized homogenous liquid–liquid microextraction, *Journal of Food Composition and Analysis*, 33, 32–38.
- Khodaei, K., Nassery, H. R., Asadi, M.M., Mohammadzadeh, H. ve Mahmoodlu, M.G., 2017. BTEX biodegradation in contaminated groundwater using a novel strain (*Pseudomonas* sp. BTEX-30), *International Biodeterioration & Biodegradation*, 116, 234-242.
- Kırbaş, İ., 2017. İstatistiksel metotlar ve yapay sinir ağları kullanarak kısa dönem çok adımlı rüzgâr hızı tahmini, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22, 1, 24-38.
- Knipe, A.C. ve Watts, W.E., 1993. *Organic Reaction Mechanism*, John Wiley and Sons, New York, USA.
- Lahlou, H., Vilanova, X. ve Correig, X. 2013. Gas phase micro-preconcentrators for benzene monitoring: A review, *Sensors and Actuators B*, 176, 198–210.
- Lever, J., Krzywinski, M. ve Altman, N., 2017. Principal component analysis, *Nature Methods*, 14, 7, 641-642.
- Li, X., Shang, X., Luo, T., Du, X., Wang, Y., Xie, Q., Matsuura, N., Chen, J. ve Kadokami, K., 2016. Screening and health risk of organic micropollutants in rural groundwater of Liaodong Peninsula, China, *Environmental Pollution*, 218, 739-748.
- Liu, Y., Shao, M., Lu, S., Chang, C.C., Wang, J.L. ve Chen, G., 2008. Volatile organic compound (VOC) measurements in the Pearl River Delta (PRD) region, China, *Atmospheric Chemistry Physics*, 8, 1531–1545.
- Liu, Y., Hao, S., Zhao, X., Li, X., Qiao, X., Dionysiou, D.D. ve Zheng, B., 2020. Distribution characteristics and health risk assessment of volatile organic compounds in the groundwater of Lanzhou City, China, *Environmental Geochemical Health*, <https://doi.org/10.1007/s10653-020-00591-6>.
- Luo, Y., Guo, W., Ngo, H.H., Nghiem, L.D., Hai, F.I., Zhang, J., Liang, S. ve Wang, X.C., 2014. A review on the occurrence of micropollutants in the aquatic environment and their fate and removal during wastewater treatment, *Science of the Total Environment*, 473–474, 619–641.
- Lykke, A.W.J., Stewart, B.W., O'connell, P.J. ve Lemesurier, S.M., 1979. Pulmonary responses to atmospheric pollutants. I: an ultrastructural study of fibrosing alveolitis evoked by petrol vapour. *Pathology*, 11, 71-80.

- Manda, B.M.K., Worrell, E. ve Patel, M.K., 2014. Innovative membrane filtration system for micropollutant removal from drinking water e prospective environmental LCA and its integration in business decisions, *Journal of Cleaner Production*, 72, 153-166.
- Marć, M., Zabiegała, B. ve Namieśnik, J., 2014. Application of passive sampling technique in monitoring research on quality of atmospheric air in the area of Tczew, Poland, *International Journal of Environmental Analytical Chemistry*, 94, 2, 151–167.
- Martínez, C., Ramírez, N., Gómez, V., Pocurull, E. ve Borrull, F., 2013. Simultaneous determination of 76 micropollutants in water samples by headspace solid phase microextraction and gas chromatography–mass spectrometry, *Talanta*, 116, 937–945.
- Masih, A., Lall, A.S., Taneja, A. ve Singhvi, R., 2016. Inhalation exposure and related health risks of BTEX in ambient air at different microenvironments of a terai zone in north India, *Atmospheric Environment*, 147, 55-66.
- Mavukkandy, M.O., Karmakar, S., Harikumar, P.J.E.S. ve Research, P., 2014. Assessment and rationalization of water quality monitoring network: a multivariate statistical approach to the Kabbini River (India). *Environmental Science Pollution Research International*, 21, 10045–10066.
- Meffe, R. ve Bustamante, I., 2014. Emerging organic contaminants in surface water and groundwater: A first overview of the situation in Italy, *Science of the Total Environment*, 481, 280–295.
- Minareci, O., Çakır, M. ve Minareci, E., 2018. The Study of Surface Water Quality in Büyük Menderes River (Turkey): Determination of Anionic Detergent, Phosphate, Boron and Some Heavy Metal Contents, *Applied Ecology and Environmental Research*, 16, 4, 5287-5298.
- Mohácsi, A., Bozóki, Z. ve Niessner, R., 2001. Direct diffusion sampling-based photoacoustic cell for in situ and on-line monitoring of benzene and toluene concentrations in water, *Sensors and Actuators B*, 79, 127-131.
- Moliner-Martínez, Y., Herraiz-Hernandez, R., Verdú-Andres, J., Campíns-Falcó, P., Garrido-Palanca, C., Molins-Lagua, C. ve Seco, A., 2013. Study of the influence of temperature and precipitations on the levels of BTEX in natural waters. *Journal of Hazardous Materials*, 263P, 131–138.
- Neale, P.A., Altenburger, R., Aït-Aïssa, S., Brion, F., Busch, W., Umbuzeiro, G. A., Denison, M.S., Pasquier, D.D., Hilscherova, K., Hollert, H., Morales, D.A., Novak, J., Schlichting, R., Seiler, T.B., Serra, H., Shao, Y., Tindall, A.J., Tollefsen, K.E., Williams, T.D. ve Escher, B.I. 2017. Development of a bioanalytical test battery for water quality monitoring: Fingerprinting identified micropollutants and their contribution to effects in surface water, *Water Research*, 123, 734-750.

- Özdemir, U., Özbay, B., Veli, S. ve Zor, S., 2011. Modeling adsorption of sodium dodecyl benzene sulfonate (SDBS) onto polyaniline (PANI) by using multi linear regression and artificial neural networks, *Chemical Engineering Journal* 178, 183–190.
- Özdemir, A., 2018. Usage of tph (total petroleum hydrocarbons) in water analysis for oil and gas exploration: first important results from Turkey, *Süleyman Demirel University Research Article Journal of Engineering Sciences and Design*, 6, 4, 615 – 636.
- Pecoraino, G., Scalici, L., Avellone, G., Ceraulo, L., Favara, R., Candela, E.G., Provenzano, M.C. ve Scaletta, C., 2008. Distribution of volatile organic compounds in Sicilian groundwaters analysed by head space-solid phase micro extraction coupled with gas chromatography mass spectrometry (SPME/GC/MS), *Water Research*, 42, 3563–3577.
- Platikanov, S., Baquero, D., González, S., Martín-Alonso, J., Paraira, M., Cortina, J.L. ve Tauler, R., 2019. Chemometric analysis for river water quality assessment at the intake of drinking water treatment plants, *Science of the Total Environment*, 667, 552–562.
- Primpas, I., Tsirtsis, G., Karydis, M. ve Kokkoris, G.D., 2010. Principal component analysis: development of a multivariate index for assessing eutrophication according to the european water framework directive, *Ecological Indicators*, 10, 178–183.
- Qi, W., Müller, B., Pernet-Coudrier, B., Singer, H., Liu, H., Qu, J. ve Berg, M., 2014. Organic micropollutants in the Yangtze River: Seasonal occurrence and annual loads, *Science of the Total Environment*, 472, 789–799.
- Radic, S., Medunic, G., Kuharic, Z., Roje, V., Maldini, K., Vujcic, V. ve Krivohlavek, A., 2018. The effect of hazardous pollutants from coal combustion activity: Phytotoxicity assessment of aqueous soil extracts, *Chemosphere*, 199, 191-200.
- Radwan, M., Alalm, M.G. ve El-Etriby, H.K., 2019. Application of electro-Fenton process for treatment of water contaminated T with benzene, toluene, and p-xylene (BTX) using affordable electrodes, *Journal of Water Process Engineering*, 31, 100837.
- Rocha, A.C. ve Palma, C., 2019. Source Identification of Polycyclic Aromatic hydrocarbons in soil sediments: application of different methods, *Science of the Total Environment*, 652, 1077–1089.
- Salar-García, M.J., Ortiz-Martínez, V.M, Hernández-Fernández, F.J., de los Ríos, A.P. ve Quesada-Medina, J., 2017. Ionic liquid technology to recover volatile organic compounds (VOCs), *Journal of Hazardous Materials*, 484-499.
- Schwarzenbach, R.P., Escher, B.I., Fenner, K., Hofstetter, T.B., Johnson, C.A., von Gunten, U. ve Wehrli, B., 2006. The challenge of micropollutants in aquatic

systems, Science, 313, 1072-1077.

Senthil Kumar, M, Sivasankar, V. ve Gopalakrishna, G.V.T., 2017. Quantification of benzene in groundwater sources and risk analysis in a popular south indian pilgrimage city – a GIS based approach, Arabian Journal of Chemistry, 10, 2523–2533.

Simantiraki, F. ve Gidakos, E., 2015. Comparative assessment of compost and zeolite utilisation for the simultaneous removal of BTEX, Cd and Zn from the aqueous phase: batch and continuous flow study, Journal of Environmental Management, 159, 218-226.

Soltoggio, A., Stanley, K.O. ve Risi, S., 2018. Born to learn: The inspiration, progress, and future of evolved plastic artificial neural networks, Neural Networks, 108, 48–67.

Song, S., Zheng, X. ve Li, F., 2010. Surface Water quality forecasting based on ANN and GIS for the Chanzhi Reservoir, China, The 2nd International Conference on Information Science and Engineering, Çin, Bildiriler Kitabı, 4094-4097.

Sözen, E., Gündüz, G., Aydemir, D. ve Güngör, E., 2017. Biyokütle kullanımının enerji, çevre, sağlık ve ekonomi açısından değerlendirilmesi, Bartın Orman Fakültesi Dergisi, 19, 1, 148-160.

Sousa, J.C.G., Ribeiro, A.R., Barbosa, M.O., Pereira, M.F.R., Silva, A.M.T., 2018. A review on environmental monitoring of water organic pollutants identified by EU guidelines, Journal of Hazardous Materials, 344, 146–162.

Subaşı, H. ve Ersü, Ç.B., 2012. Yapay sinir ağı ile atıksu arıtma performansının modellenmesi, Ç.Ü Fen ve Mühendislik Bilimleri Dergisi, 28, 3, 110-117.

Tabachnick, E.G. ve Fidell, L.S., 2001. Using Multivariate Statistics, Sixth Edition, Pearson Education Limited, Harlow, United Kingdom.

Tahboub, Y.R., Zaater, M.F. ve Khater, D.F., 2017. Semi-volatile organic pollutants in Jordanian surface water, Arabian Journal of Chemistry, 10, 3318–3323.

T.C. Resmi Gazete, İnsani Tüketim Amaçlı Sular Hakkında Yönetmelik, 25730, 17.02.2005.

T.C. Resmi Gazete, Yerüstü Su Kalitesi Yönetmeliği, 29797, 10.08.2016.

Terzi, Ö. ve Baykal, T., 2012. Akarsulardaki katı madde miktarının yapay sinir ağı ile tahmini: Kızılırmak Nehri örneği. Uluslararası Teknolojik Bilimler Dergisi, 4, 3, 8-14.

Tezbaşaran, E. ve Gelbal, S., 2018. Temel bileşenler analizi ve yapay sinir ağı modellerinin ölçek geliştirme sürecinde kullanılabilirliğinin incelenmesi, Mersin Üniversitesi Eğitim Fakültesi Dergisi, 14, 1, 225-252.

- Thambavani, D.S. ve Kavitha, B., 2014. Prediction and simulations of chromium (VI) ions removal efficiency by riverbed sand adsorbent using artificial neural networks, *International Journal of Engineering Sciences & Research Technology*, 3, 5, 906-913.
- Torabian, A., Kazemian, H., Seifi, L., Bidhendi, G.N., Azimi, A.A. ve Ghadiri, S.K., 2010. Removal of petroleum aromatic hydrocarbons by surfactant-modified natural zeolite: the effect of surfactant, *Clean*, 38, 1, 77-83.
- Tözün, M. ve Ünsal, A., 2008. Benzen ve sağlık etkileri, *TAF Preventive Medicine Bulletin*, 7, 6, 541-546.
- Tsai, W.T., 2016. Toxic volatile organic compounds (VOCs) in the atmospheric environment: regulatory aspects and monitoring in Japan and Korea. *Environments*, 3, 3, 23.
- Turhan, C., Gökçen, G. ve Kazanasmaz, T., 2013. Yapay sinir ağları ile İzmir'deki çok katlı binaların toplam enerji tüketimlerinin tahmin edilmesi, *Tesisat Mühendisliği*, 134, 61-68.
- Uragami, T., Fukuyama, E. ve Miyata, T., 2016. Selective removal of dilute benzene from water by poly(methylmethacrylate)-graft-poly(dimethylsiloxane) membranes containing hydrophobic ionic liquid by pervaporation, *Journal of Membrane Science*, 131-140.
- Uysal, H.L., 2019. Endüstriyel boyahane tesislerinde baca gazı atık ısısının geri kazanım analizi ve bir uygulama, *Yüksek Lisans Tezi*, Balıkesir Üniversitesi, Fen Bilimleri Enstitüsü, Balıkesir.
- Ülke, A., Özkul, S., Tayfur, G. ve Gündoğdu, İ., 2010. Gediz nehri için eksik sediment verilerinin tahmin edilmesi, *VI. Ulusal Hidroloji Kongresi*, 254-264, Denizli.
- Üstün Odabaşı, S., 2019. Mikrokirleticilerin çevresel etkileri ve giderim yöntemlerinin sürdürülebilirlik açısından araştırılması, *Yüksek Lisans Tezi*, Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Samsun.
- Vieira, C.M.S., Mafra, G., Brognoli, R., Richter, P., Rosero-Moreano, M. ve Carasek, E., 2020. A high throughput approach to rotating-disk sorptive extraction (RDSE) using laminar cork for the simultaneous determination of multiclass organic micro-pollutants in aqueous sample by GC-MS. *Talanta*, 208, 120459.
- Vimalkumar, K., Arun, E., Krishna-Kumar, S., Poopal, R.K., Nikhil, N.P., Subramanian, A. ve Babu-Rajendran, R., 2018. Occurrence of triclocarban and benzotriazole ultraviolet stabilizers in water, sediment, and fish from Indian rivers, *Science of the Total Environment* 625, 1351–1360.
- Wang, J. ve Deng, Z., 2019. Modeling and predicting fecal coliform bacteria levels in oyster harvest waters along Louisiana Gulf coast. *Ecological Indicators*, 101, 212–220.

- Wanda, E.M.M., Mamba, B.B. ve Msagati, T.A.M., 2017. Hydrochemical modelling of water quality in terms of emerging micropollutants in Mpumalanga, Gauteng and North West Provinces, *Physics and Chemistry of the Earth*, 100, 143-157.
- Weisel, C.P., 2010. Benzene exposure: An overview of monitoring methods and their findings, *Chemico-Biological Interactions*, 184, 58–66.
- WHO, 1993. Guidelines for Drinking Water Quality, Drinking Water Standards, World Health Organization, Geneva, Switzerland.
- Wille, K., De Brabander, H.F., De Wulf, E., Van Caeter, P., Janssen, C.R. ve Vanhaecke, L., 2012. Coupled chromatographic and mass-spectrometric techniques for the analysis of emerging pollutants in the aquatic environment, *Trends in Analytical Chemistry*, 35, 87-108.
- Wu, C., Liu, W., Jiang, J., Wang, Y., Hou, K. ve Li, H., 2019. An in-source helical membrane inlet single photon ionization time-of-flight T mass spectrometer for automatic monitoring of trace VOCs in water, *Talanta*, 192, 46–51.
- Xu, Z., Huang, X., Nie, W., Chi, X., Xu, Z., Zheng, L., Sun, L. ve Ding, A., 2017. Influence of synoptic condition and holiday effects on VOCs and ozone production in the Yangtze River Delta region, China, *Atmospheric Environment*, 168, 112-124.
- Yang, Yun-Ya, Toor, G.S., Wilson, P.C. ve Williams, C.F., 2017. Micropollutants in groundwater from septic systems: Transformations, transport mechanisms, and human health risk assessment, *Water Research*, 123, 258-267.
- Yang, C., Qian, H., Li, X., Cheng, Y., He, H., Zeng, G. ve Xi, J., 2018. Simultaneous Removal of Multicomponent VOCs in Biofilters, *Trends in Biotechnology*, 36, 673–685.
- Yeşilnacar, M.I., Şahinkaya, E., Naz, M. ve Özkaya, B., 2008. Neural network prediction of nitrate in groundwater of Harran Plain, Turkey, *Environmental Geology*, 56, 19–25.
- Yetilmezsoy, K. ve Saral, A., 2007. Stochastic Modeling Approaches Based on Neural Network and Linear-Nonlinear Regression Techniques for the Determination of Single Droplet Collection Efficiency of Countercurrent Spray Towers, *Environmental Modeling & Assessment*, 12, 13-26.
- Yılmaz Civan, M., Oğuz Kuntasal, Ö. ve Tuncel, G., 2012. Contribution of VOCs to Ozone Formation in Bursa Atmosphere, *Karaelmas Science and Engineering Journal*, 2, 1, 34-40.
- Yusri, I.M., Abdul Majeed, A.P.P., Mamat, R., Ghazali, M.F., Awad, O.I. ve Azmi, W.H., 2018. A review on the application of response surface method and artificial neural network in engine performance and exhaust emissions characteristics in alternative fuel, *Renewable and Sustainable Energy Reviews*,

90, 665–686.

Zhang, Z., Wang, X., Zhang, Y., Lü, S., Huang, Z., Huang, X. ve Wang, Y., 2015. Ambient air benzene at background sites in China's most developed coastal regions: Exposure levels, source implications and health risks, Science of the Total Environment, 511, 792–800.

Zhao, Y., Dong, Z.C. ve Li, Q.H., 2011. ANN based on SFLA for Surface Water Quality Evaluation Model and Its Application, International Conference on Transportation, Mechanical, and Electrical Engineering, Changchun, Bildiriler Kitabı, 1615-1618.

URL1 <<https://eurlex.europa.eu/LexUriServ/LexUriServ.do?uri=OJ:L:2013:226:0001:0017:EN:PDF>>, Erişim Tarihi: 22.10.2019.

URL-2 <<https://www.nkfu.com/benzen-nedir-benzen-ozellikleri-ve-kullanim-alanlari/>>, Erişim Tarihi: 12.07.2019.

URL-3 <<https://www.wikiwand.com/tr/Benzen>>, Erişim Tarihi: 03.04.2019.

URL-4 <<http://www.istatistik.gen.tr/?p=29>>, Erişim Tarihi: 16.10.2019.

URL-5 <<http://www.stat.gen.tr/index.php?istek=sinif&dersid=ist01&konuid>>, Erişim Tarihi: 15.10.2019.

URL-6 <https://tr.wikipedia.org/wiki/Yapay_sinir_ağları>, Erişim Tarihi: 11.04.2019.

URL-7 <<https://auzefalmsstorage.blob.core.windows.net/auzefcontent>>, Erişim Tarihi: 19.09.2019.

URL-8 <<https://medium.com/@ayyucekizrak/derin-öğrenme-için-aktivasyon-fonksiyonlarının-karşılaştırılması-cee17fd1d9cd>>, Erişim Tarihi: 05.11.2019.

URL-9 <<https://medium.com/@ayyucekizrak/şu-kara-kutuyu-açalım-yapay-sinir-ağları-7b65c6a5264a>>, Erişim Tarihi: 13.10.2019.

URL-10 <<https://tr.climate-data.org/asya/tuerkiye/kuetahya/kuetahya-191/>>, Erişim Tarihi: 26.06.2020.

URL-11 <<https://tr.climate-data.org/asya/tuerkiye/bursa/bursa-714886/>>, Erişim Tarihi: 26.06.2020.

ÖZGEÇMİŞ

Adı ve Soyadı : Özgül Çimen Mesutoğlu

Adres : Merkez/AKSARAY

E-posta adresi : ozgulgimen@gmail.com

EĞİTİM BİLGİLERİ (Kurum ve Yıl)

Lisans : Selçuk Üniversitesi, 2007-2012

Yüksek Lisans : Aksaray Üniversitesi, 2013-2014

Doktora : Aksaray Üniversitesi, 2015-Halen

MESLEKİ DENEYİM VE ÖDÜLLERİ

1. BUSKİ İçme Suyu ve Atıksu Arıtma Tesisi / Yaz Stajı (2008)
2. Aksaray Üniversitesi /Araştırma Görevlisi / 2013 - Halen

TEZDEN ÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER

-

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER

Uluslararası Hakemli Dergilerde Yayınlanan Makaleler

1. Gök, O. ve Çimen Mesutoğlu, Ö., 2017. Ağır metallerin giderimi için düşük maliyetli adsorban olarak pirina kullanımı, Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 32, 2, 507-516.
2. Gök, O. ve Çimen Mesutoğlu, Ö., 2016. Application of pistachio shell PSS as low cost adsorbent for the removal of Pb(II) from aqueous solution, International Journal of Ecosystems and Ecology Science, 6, 3, 389-394.

Ulusal Hakemli Dergilerde Yayınlanan Makaleler

1. Gök, O. ve Çimen Mesutoğlu, Ö., 2019. Arsenic removal from water with regional natural material. Journal of the Institute of Science and Technology, 9, 85-90.

3. Gök, O. ve Çimen Mesutoğlu, Ö., 2018. Adsorpsiyon kolon sisteminde pirina kullanılarak ağır metal giderimi. DEU Muhendislik Fakültesi Fen ve Muhendislik, 20, 60, 1000-1009.

Kongrelerde Sunulan Bildiriler

1. Çimen, Ö., Dursun, Ş. ve Mankolli, H., 2013. Selection and suggestions of site type for solid waste incineration systems in Turkey with basis available in Europe, International Conference of Ecosystems, Tiran, Poster.
2. Çimen, Ö., Gök, G., Çelebi, H. ve Gök, O., 2014. The possible environmental impacts of the biosolids in the worldwide, International Conference of Environmental Science and Technology, Antalya, Bildiriler Kitabı, 245-247.
3. Gök, O., Çelebi, H., Gök, G., Özcan, S. ve Çimen, Ö., 2014. İçme suyu arıtımında kompozit demir matrisli sistem kullanımı ile arsenik gideriminde yenilikçi bir yaklaşım, 2. KOP Bölgesel Kalkınma Sempozyumu, Niğde, Bildiriler Kitabı, 321-327.
4. Çimen, Ö., Gök, G., Çelebi, H ve Gök, O., 2014. Renewable Energy Sources Potential for Aksaray city, 2nd Conference on Recycling & Reuse, Bildiriler Kitabı, 45-46.
5. Gök, G., Mesutoğlu, Ö. ve Gök O., 2015. Municipal solid waste management in Aksaray, VI. Türk-Alman Katı Atık Günleri-TAKAG'2015 & Young Reserachers' Forum, İzmir, Poster.
6. Çimen Mesutoğlu, Ö. ve Gök, O., 2016. Removal of Zn(II) from Aqueous solutions by activated olive pomace, 2nd International Conference on Science Ecology and Technology, 319.
7. Gök, O., Çimen Mesutoğlu, Ö., 2016. Application of pistachio shell PSS as low cost adsorbent for the removal of Pb(II) from aqueous solution, 6th International Conference of Ecosystems, 155.
8. Ayturan, Z.C., Kunt, F., Ulusoy, Ç., Dursun, Ş. ve Çimen Mesutoğlu, Ö., 2017. Selçuk üniversitesi yerleşkesi kapalı alanlarda ortam PM2.5 seviyesinin belirlenmesi, VII. Ulusal Hava Kirliliği Kontrolü Sempozyumu, Antalya, Bildiriler Kitabı, 83-89.
9. Dursun, Ş., Ayturan, Z.C., Kunt, F., Ulusoy, Ç. ve Çimen Mesutoğlu, Ö., 2017. Selçuk üniversitesi yerleşkesi açık alanlarda ortam PM2.5 seviyesinin

belirlenmesi, VII. Ulusal Hava Kirliliği ve Kontrolü Sempozyumu, Antalya, Bildiriler Kitabı, 190-202.

10. Mesutoğlu, M. ve Çimen Mesutoğlu, Ö., 2017. A research of the CCS activities in the coal-fired power plants of Turkey and some European countries, International Symposium of Mining and Environment, Bodrum, Bildiriler Kitabı, 299.
11. Çimen Mesutoğlu, Ö., Çelebi, H., Gök, O. ve Koçyiğit, H., 2017. ASÜ kampüs atıksularının karakterizasyonu / characterization of ASÜ campus wastewater. XIII. Congress of Ecology and Environment, 299.
12. Çimen Mesutoğlu, Ö., Çelebi, H. ve Gök, O., 2018. Use of chicken eggshells for adsorption of reactive black-5 from aqueous solution, 10th Eastern European Young Water Professionals Conference, Zagreb, Bildiriler Kitabı, 309-310.
13. Çelebi, H. ve Çimen Mesutoğlu, Ö., 2018. Kirlilik yükü yüksek zeytinyağı endüstrisi atıksularının ekolojik boyutu, 1. Uluslararası İçmesuyu ve Atıksu Sempozyumu, Bildiriler Kitabı, 629-642.