

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

**ATIKSU ARITMA TESİSİ KONTROLÜNDE YAPAY
BAĞIŞIKLIK SİSTEMİNİN KULLANILMASI**

DOKTORA TEZİ

Cengiz SERTKAYA

Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM MÜHENDİSLİĞİ

Enstitü Bilim Dalı : BİLİŞİM TEKNOLOJİLERİ

Tez Danışmanı : Yrd. Doç. Dr. Nilüfer YURTAY

Nisan 2016

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ATIKSU ARITMA TESİSİ KONTROLÜNDE YAPAY
BAĞIŞIKLIK SİSTEMİNİN KULLANILMASI

DOKTORA TEZİ

Cengiz SERTKAYA

Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM MÜHENDİSLİĞİ
Enstitü Bilim Dalı : BİLİŞİM TEKNOLOJİLERİ

Bu tez 25/04/2016 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile kabul edilmiştir.

Yrd. Doç. Dr.
Nilüfer YURTAY
Jüri Başkanı



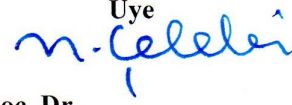
Prof. Dr.
Nevcihan DURU
Üye



Prof. Dr.
Saim ÖZDEMİR
Üye



Doç. Dr.
Numan ÇELEBİ
Üye



Doç. Dr.
Ayhan ŞAMANDAR
Üye



BEYAN

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

Cengiz SERTKAYA



29.04.2016

TEŐEKKÜR

Doktora alıőmam boyunca bana destek ve yardımlarını esirgemeyen tez danıőmanım Sayın Yrd. Do. Dr. Nilüfer YURTAY'a, tez alıőmalarımın her aőamasında bana destek olan Sayın Prof. Dr. Nejat YUMUŐAK ve Prof. Dr. Saim ÖZDEMİR hocalarıma en derin saygı ve teőekkürlerimi sunarım.

Atıksu arıtma sistemleri ile ilgili bilgileri paylaşarak projeye destek saėlayan ve yardımlarını esirgemeyen deėerli hocam Do. Dr. Gülsüm YILMAZ'a teőekkür ederim.

Herzaman ve her konuda yanımda olan, maddi ve manevi destek olan aileme teőekkür ediyor, merhum dedem Polat SERTKAYA'yı saygı ve minnetle anıyorum.

Ayrıca bu alıőmanın maddi açıdan desteklenmesine olanak saėlayan Tübitak Bilim İnsanı Destekleme Programları(BİDEB) Başkanlığına (2233-Doktora Öğrencileri İçin Yurtii Araőtırma Burs Programı) teőekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER.....	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	vii
TABLolar LİSTESİ	ix
ÖZET.....	x
SUMMARY	xi

BÖLÜM 1.

GİRİŞ	1
1.1. Tezin Gerekçesi.....	1
1.2. Tezin Amaç ve Kapsamı.....	4
1.3. Literatür Araştırması.....	4
1.4. Tezin Organizasyonu	16

BÖLÜM 2.

ATIKSU ARITMA TESİSLERİ	18
2.1. Atıksu Arıtma Prosesleri	19
2.2. Atıksu Karakteristiği.....	22
2.3. Atıksu Arıtma Parametreleri	24

BÖLÜM 3.

DOĞAL VE YAPAY BAĞIŞIKLIK SİSTEMLERİ	25
3.1. Doğal Bağışıklık Sistemi.....	25
3.2. Yapay Bağışıklık Sistemi.....	29
3.3. YBS Algoritmaları	30

3.3.1. Negatif seçim algoritması.....	30
3.3.2. Yapay bağışıklık ağı algoritması.....	31
3.3.3. Dendritik hücre algoritması.....	33
3.3.4. Klonal seçim algoritması.....	35

BÖLÜM 4.

YAPAY BAĞIŞIKLIK SİSTEMİ İLE ATIKSU ARITMA TESİS KONTROLÜ UYGULAMASI.....	38
4.1. Veri Prosesleri	38
4.2. Klonal Seçim Prensibine Dayalı YBS Algoritması	44
4.3. AAT Modellerinin Oluşturulması	48
4.4. Veritabanı Mimarisi	52
4.5. Kullanıcı Arayüzleri.....	55
4.6. Simülasyon Sonuçları	59

BÖLÜM 5.

SONUÇLAR VE ÖNERİLER.....	69
KAYNAKLAR	73
ÖZGEÇMİŞ.....	85

SİMGELER VE KISALTMALAR LİSTESİ

AAT	: Atıksu arıtma tesisi
Ab	: Antikor (Antibody)
Ag	: Antijen (Antigen)
AKM	: Askıda katı madde
ANFIS	: Adaptif sinirsel bulanık çıkarım sistemi (adaptive neuro fuzzy inference system)
ASM	: Aktif çamur modeli (active sludge model)
BOİ	: Biyolojik oksijen ihtiyacı
C	: Yapay bağışıklık klon antikor popülasyonu
COND	: İletkenlik (conductivity)
DHA	: Dendritik hücre algoritması
FNN	: Bulanık YSA
FRSRBFNN	: Bulanık kümeli RBFNN (fuzzy rough sets RBFNN)
Fuzzy	: Bulanık mantık (fuzzy logic)
GA	: Genetik algoritma
GPS-X	: Atıksu arıtma simülör programı
HCl	: Hidroklorik asit
IAWQ	: Uluslararası su kalitesi birliđi (International Association of Water Quality)
K-NN	: K-en yakın komşu algoritması (k-nearest neighbors algorithm)
KOİ	: Kimyasal oksijen ihtiyacı
Korr	: Korelasyon
KSA	: Klonal seçim algoritması
MAPE	: Ortalama oransal hata (mean absolute percentage error)
MCAV	: Anomali katsayısı (mature context antigen value)
MLP	: Çok katmanlı algılayıcı (multilayer perceptron)

NFS	: Bulanık YSA (neural fuzzy system)
NH4-N	: Amonyum azotu
NSA	: Negatif seçim algoritması
OKH	: Ortalama karesel hata
P	: Yapay bağışıklık antikor popülasyonu
PCA	: Temel bileşen analizi (principal component analysis)
pH	: Çözeltinin asitlik veya bazlık derecesi
PID	: Katsayı integral türev kontrolcüsü (proportional integral derivate controller)
PLC	: Programlanabilir mantıksal denetleyici (Programmable logic controller)
PNN	: Probabilistik YSA (probabilistic neural network)
PSO	: Parçacık sürü optimizasyonu (particle swarm optimization)
PYSA	: PCA'lı YSA
R	: Korelasyon katsayısı
R2	: Determinasyon katsayısı
RBFINN	: Radyal temel fonksiyonlu YSA (radial basis function neural network)
RHONN	: Yinelemeli yüksek öncelikli YSA
RMSE	: Ortalama karesel hata karekökü (root mean square deviation)
RNN	: Yinelemeli YSA (recurrent neural network)
SCADA	: Merkezi denetleme kontrol ve veri toplama sistemi (supervisory control and data acquisition)
SCNN	: Kendi kendini düzenleyen YSA (self convolutional neural network)
SED	: Tortu (sediments)
SOM	: Öz düzenleyici haritalar (self organizing map)
SORBFNN	: Kendi kendini besleyen radial fonksiyon tabanlı YSA (self organizing radial basis function neural network)
SS	: Askıda katı madde (suspended solid)
SSV	: Uçucu askıda katı madde (volatile suspended solids)
SVN	: Destek vektör makinesi (support vector machine)

TAKM	: Toplam askıda katı madde
TKN	: Kjeldahl nitrojen
UAKM	: Uçucu askıda katı madde
UCI	: Kaliforniya Irvine Üniversitesi (University of California Irvine)
WPD	: Dalgacık paket ayrıştırma (wavelet packet decomposition)
YBS	: Yapay bağışıklık sistemi
YSA	: Yapay sinir ağları

ŞEKİLLER LİSTESİ

Şekil 1.1. Türkiye’deki atıksu arıtma tesislerinin dağılımı	2
Şekil 1.2. Arı algoritması	8
Şekil 1.3. Hybrid YSA-mekanistik modeller	11
Şekil 1.4. GPS-X atıksu simülatörü	14
Şekil 2.1. Türkiye’deki atıksu arıtma tesislerinin proseslere göre dağılımı	19
Şekil 2.2. Tesislerde uygulanan atıksu arıtma prosesleri	19
Şekil 3.1. İnsan vücudundaki bağışıklık sistemi koruma mekanizması	25
Şekil 3.2. Lenfositin üretildiği doku ve organlar	26
Şekil 3.3. Antikor yapısı ve antijen tanıma	27
Şekil 3.4. Bağışıklık sisteminde klonal prensibin çalışma mekanizması.....	28
Şekil 3.5. Bağışıklık sisteminde negatif seçim teorisi çalışma prensibi	28
Şekil 3.6. YBS negatif seçim algoritması akış diyagramı	31
Şekil 3.7. YBS ağı örnek gösterimi	32
Şekil 3.8. Dendritik hücre algoritması	34
Şekil 3.9. Klonal seçim algoritması	36
Şekil 4.1. Uygulama geliştirme adımları	38
Şekil 4.2. Veri kümesi özellik değer dağılım grafikleri	40
Şekil 4.3. Klonal seçim prensibine dayalı YBS algoritması adımları	45
Şekil 4.4. Örnek mutasyon işlemi	47
Şekil 4.5. AAT modelleri	50
Şekil 4.6. Sistem mimarisi	53
Şekil 4.7. Veritabanı mimarisi	55
Şekil 4.8. Model tanımlama ekranı	56
Şekil 4.9. Model test ekranı	57
Şekil 4.10. Model sonuç geçmişi ekranı	57
Şekil 4.11. Tasarım ayarları araç kutusu	58

Şekil 4.12. Simülâtör arayüzünde tanımlanmış atıksu arıtma tesisi	59
Şekil 4.13. YBS model1 için başarı değerleri	60
Şekil 4.14. YBS model2 için başarı değerleri	62
Şekil 4.15. YBS model3 için başarı değerleri	63
Şekil 4.16. YBS model4 için başarı değerleri	64

TABLULAR LİSTESİ

Tablo 1.1. ANFIS model performansları	10
Tablo 1.2. YSA kontrollör parametreleri	12
Tablo 1.3. YSA kontrollör sonuçları	12
Tablo 1.4. AAT üzerine son 10 yılda yapılan diğer yapay zeka çalışmaları	15
Tablo 2.1. Tesis bölümlerinde ölçülen parametreler	24
Tablo 4.1. UCI veri kümesi özellikleri	39
Tablo 4.2. Veri kümesi özelliklerinin değer analizleri	43
Tablo 4.3. YBS sistem parametreleri	46
Tablo 4.4. YBS model1 giriş ve çıkış parametreleri arası korelasyon sonuçları.....	51
Tablo 4.5. YBS model2 giriş ve çıkış parametreleri arası korelasyon sonuçları.....	51
Tablo 4.6. YBS model3 giriş ve çıkış parametreleri arası korelasyon sonuçları.....	51
Tablo 4.7. YBS model4 giriş ve çıkış parametreleri arası korelasyon sonuçları	52
Tablo 4.8. YBS model1 için genel başarı değerleri	66
Tablo 4.9. YBS model2 için genel başarı değerleri	67
Tablo 4.10. YBS model3 için genel başarı değerleri	67
Tablo 4.11. YBS model4 için genel başarı değerleri	67
Tablo 4.12. PYBS model1 için genel başarı değerleri	67
Tablo 4.13. PYBS model2 için genel başarı değerleri	67
Tablo 4.14. PYBS model3 için genel başarı değerleri	68
Tablo 4.15. PYBS model4 için genel başarı değerleri	68
Tablo 5.1. YBS, PYBS ve Dügenci [20] çalışma sonuçları karşılaştırması	70

ÖZET

Anahtar kelimeler: Atıksu Arıtma Tesisi, Yapay Bağışıklık Sistemi, Simülasyon

Su, tüm canlıların yaşam koşullarını belirleyen temel öğelerdendir ve canlıların yaşaması için hayati öneme sahiptir. En küçük canlı organizmadan en büyük canlı varlığa kadar, bütün biyolojik yaşamı ve bütün insan faaliyetlerini ayakta tutan sudur. Kullanılan sular, evsel ve endüstriyel atıklarla kirlenmektedir. Bu atıkların arıtılmadan su yataklarına verilmesi ile de doğal su kaynakları kullanılamaz hale gelmektedir. Atıksuların arıtılarak çevreye verdiği zararları ortadan kaldırmak amacıyla atıksu arıtma tesisleri kurulmaktadır.

Atıksu arıtma tesislerinin deşarj standartlarını yakalayabilmesi ve tesis devamlılığının sağlanması önemlidir. Bu nedenle tesis yönetim parametrelerinin izlenmesi ve kontrolü gereklidir. Ancak bu parametreler deęişken ve linear olmayan oldukça kompleks bir proses yapısına sahiptir. Bu durum klasik matematiksel yöntemler ile modellenmesini mümkün kılmamaktadır. Bu nedenle öğrenebilen bir sistemin tesis proseslerine uygulanması gereklidir.

Bu tez çalışmasında bir atıksu arıtma tesisinin proses simülasyonları bir yapay zeka teknolojisi olan yapay bağışıklık sistemi kullanılarak yeni bir çalışma olarak ele alınmıştır. Tesis geneli ve herbir proses bölümü için giriş parametrelerinden çıkış parametrelerinin tahmin edilmesi için simülator sistemi geliştirilmiştir. Aynı zamanda geliştirilen modeller, tesis işleyişini optimum düzeyde tutmaya yönelik, yöneticiye karar desteęi sağlayacak bir sistem olarak da kullanılabilir.

CONTROL OF WASTEWATER TREATMENT PLANT USING ARTIFICIAL IMMUNE SYSTEM

SUMMARY

Keywords: Wastewater Treatment Plant, Artificial Immune System, Simulation

Water, is the basic element that determines the conditions of life and has vital importance for living things. From the largest to the smallest living organisms, all biological life and human activities need water. Used water is wasted by domestic and industrial wastes. Discharging of these wastes without cleaning is also wasting the surrounding surface water resources and makes it unusable. Wastewater treatment plants are building in order to eliminate the damage of wastewater to the environment.

Waste water treatment plant needs to capture discharge standarts and also ensuring continuity of plant activities. Therefore, it is necessary to monitor and control the facility management parameters. However, these parameters may vary and have non-linear complex process structure behaviour. That makes impossible modelling by classical mathematical methods. For this reason, it is necessary to implement of a learnable system into wastewater plant processes.

In this thesis, process simulations of a wastewater treatment plant are performed as a new study with an artificial intelligence method which is called Artificial Immune System. Output parameters were estimated for each plant parts and for general plant over input parameters. Proposed models can also be used to provide decision support for plant manager to keep plant functionalities at optimum level.

BÖLÜM 1. GİRİŞ

1.1. Tezin Gerekçesi

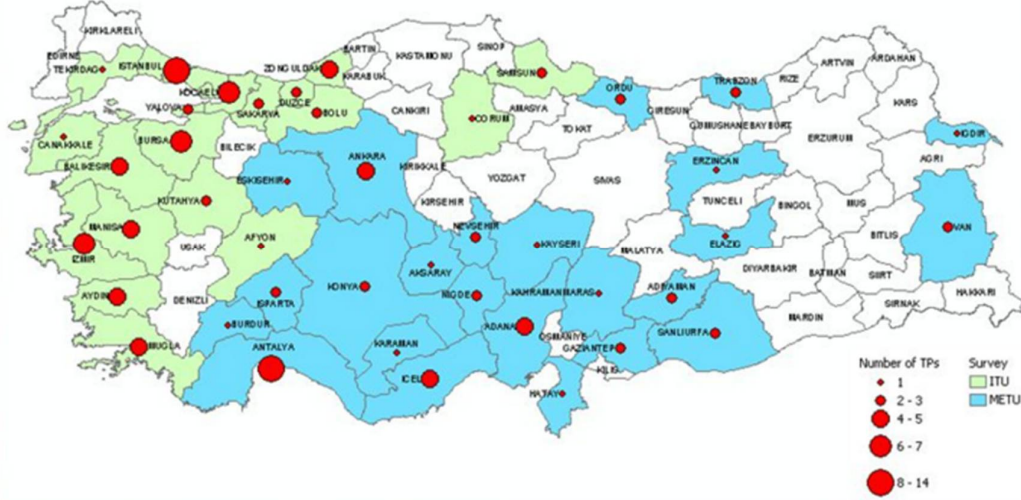
Su, canlı yaşamı için temel bir ihtiyaçtır. Özellikle ekonomik kalkınma, çevre sağlığı, gıda üretimi ve enerji üretimi gibi pek çok hayati faaliyetin gerçekleşmesi için gereklidir. Su ihtiyacının devamlı artmasına karşın dünyada bulunan suların ancak %3'ü kullanılabilir durumdadır.

Su, su kaynaklarından temin edilir ve kullanımının ardından kirletici ve zararlı maddelerden oluşan atıksu olarak tekrar doğaya geri verilirler. Atıksuların temizlenmeden doğaya verilmesi durumunda, doğal su kaynaklarının kirlenmesine sebep olmakta ve sonrasında bu kirliliğin etkisi ile doğal yaşam da geri dönülemez etkilere maruz kalmaktadır.

Hızlı sanayileşme ve kentlere göçlerin artması ile oluşan nüfus artışının bir sonucu olarak, doğanın özümseyebileceğinin üzerinde atıksu üretimi ortaya çıkmıştır. Hem endüstriyel hem de kentsel atıksular çeşitlenmiş ve hacim olarak da artış göstermiştir. Kirliliğin etkisinin önlenmesi için atıksuların denetimi, çevreye zarar vermeyecek şekilde doğal ortama deşarjı için çok sayıda yasa ve yönetmelik çıkarılmıştır.

Türk İstatistik Kurumu (TUIK), 2010 verilerine göre Türkiye'de kanalizasyon sistemi ile toplanan toplam 3,58 milyar metreküp atık suyun %48,6'sı akarsulara, %41,8'i denizlere, geri kalan bölümü ise göller ve diğer su kaynaklarına deşarj edilmiştir [1]. Kentsel ve sanayi faaliyetler sonucunda ortaya çıkan atıksuların miktarının bu denli fazla miktarda oluşu nedeniyle, su kaynaklarına deşarjı ile su kaynakları kirlenerek kullanılmaz hale gelmekte ve yarattığı çevre kirliliği nedeniyle de doğal yaşamı tehdit etmektedir. Bu durum atıksuyun su kaynaklarına deşarj

işleminde önce temizlenmesi zorunluluğunu doğurmaktadır. Atıksudaki kirliliğin bertaraf edilmesi amacıyla atıksu arıtma tesisleri (AAT) kurulmaktadır. Türkiye’de atıksu arıtma tesisleri dağılımı Şekil 1.1’de verilmektedir [2].



Şekil 1.1. Türkiye’deki atıksu arıtma tesislerinin dağılımı [2]

Atıksu arıtma tesislerinde, atıksuyun arıtılması için fiziksel, biyolojik ve kimyasal işlemler, kontrollü bir ortamda ve uygun şartlarda gerçekleştirilir. Bu prosesler kontrol altında tutularak, gerekli müdahalelerle doğadaki reaksiyonlar hızlandırılır ve atıksu arıtımında kullanılmış olur. Buna karşılık her proses için arıtma sırasında kontrol edilmesi gereken birçok parametre vardır. Bu parametrelerin elde edilmesi çoğunlukla laboratuvar analizleri sonucunda gerçekleştiğinden, analiz sonuçlarının elde edilmesi bazı parametreler (örneğin KOİ) için saatler ve bazıları (örneğin BOİ) içinse günler sürmektedir. Ancak atıksu arıtma işlemi anlık kontrol edilmesi ve parametrelerinin devamlı kontrol edilerek, sistemin optimum şekilde atıksu temizliği yapabilmek için ayarlanmasını zorunlu tutmaktadır. Aksi durumda yapılan atıksu temizliği yeterli düzeyde olamayacağı gibi tesis kullanım maliyetlerini de arttırmaktadır.

Atıksu arıtma tesislerinden daha yüksek kalitede arıtılmış atıksuya olan talebin dikkate alınmasıyla, gün geçtikçe artan sıkı deşarj standartlarından dolayı, bu tesislerin daha verimli işletilmesi ve kontrol edilmesi gerekmektedir. Atıksu arıtımı

oldukça kompleks ve dinamik bir yapıyı bünyesinde barındırdığından, arıtma sistemini devamlı olarak izleyen, tesis yöneticisine karar desteği sağlayacak ve arıtma prosesi dinamiklerinin modelleyen yaklaşımlara ihtiyaç bulunmaktadır. Bu ihtiyacı karşılamak adına yapay zeka sistemleri kullanılabilir.

Literatür incelemesi sonucunda elde edilen bilgiler ışığında, günümüze kadar yapılmış çalışmalarda, yapay zeka teknikleri kullanılarak geliştirilmiş tesis giriş değerlerinden çıkış değerlerinin ve iç proses dinamiklerinin tahmin edildiği, sistem performansının ölçüldüğü ve bu değerlere göre karar desteği sağlayacak çalışmalarının azlığı dikkat çekmektedir. Ayrıca çalışmaların çoğunlukla yapay sinir ağı (YSA) algoritması ve türevleriyle yapıldığı dikkat çekmektedir. Bu nedenle diğer yapay zeka yaklaşımlarının da atıksu arıtma probleminde kullanılması ve sonuçların karşılaştırılması önemlidir.

Bu tez kapsamında ele alınan yapay bağışıklık sistemi (YBS) algoritması, atıksu arıtma sistemin modellenmesi, parametrelerinin önceden tahmin edilmesi ve tesis yöneticisine karar desteği sağlaması planlanmıştır.

Yapay bağışıklık sistemi, insan vücudundaki doğal bağışıklık sisteminin çalışma prensiplerine göre oluşturulmuştur. Bağışıklık sistemi kendi özel hücreleri ile vücuda giren yabancı hücreleri tanır ve onları etkisiz hale getirir. YBS'nin doğal bağışıklık sisteminden esinlenilerek elde ettiği tanıma, çeşitlilik, öğrenme, hafıza, dağıtılmış algılama, kendi kendini düzenleme, eşik değeri mekanizması gibi yetenekleri sayesinde diğer yapay zeka algoritmalarına göre avantajlı yönleri bulunmaktadır.

Yapay bağışıklık sistemleri, son yıllarda hayatın birçok alanında uygulanmış ve oldukça başarılı sonuçlar elde edilmiştir. Atıksu tesis modellemesi gibi dinamik değişkenlere sahip ve matematiksel formülasyonu kurulamayan bir problemin çözümünde de bu teknolojiden yararlanılabilir.

1.2. Tezin Amaç ve Kapsamı

Bu tez çalışmasında atıksu arıtma tesisinin proses similasyonu bir yapay zeka teknolojisi olan yapay bağışıklık sistemi kullanılarak yeni bir çalışma olarak ele alınmıştır. Simulatör gerçek bir tesisin çalışma yapısını ve kurallarını aynen uygulamaktadır. Tesis bölümlerinde, bölüm giriş parametrelerinden yola çıkarak, çıkış parametrelerinin tahmin edilmesi ve elde edilen bilgiler ışığında tesis işleyişini optimum düzeyde tutmaya çalışmaya yönelik yöneticiye karar desteği de sağlamaktadır.

1.3. Literatür Araştırması

Atıksu arıtma tesisinde tesis yönetiminin gidişatı, belirli aralıklarla ölçülen parametre değerlerinden hesaplanarak bulunur. Bu parametreler okadar önemlidir ki tesisin performansı, arıtma işlemi yaptığı atıksudaki başarısı ve atıksu arıtmanın tesise olan maliyetleri bu parametreler üzerinden bulunurlar. Bu parametrelerin bazılarını anlık olarak erişebilirken, bazılarını da laboratuvar analizleri sonucunda elde edilmektedir. Bu durumda anlık olarak tesisin gidişatı ve performansı hakkında bilgi vermek zordur. Mühendisliğin bu tür bir soruna yaklaşımı 2 şekildedir. Bunlardan ilki anlık olarak elde edilebilen parametrelerden, elde edilmesi uzun süre alan diğer parametreleri tahmin etmek ikincisi de henüz girişte sahip olunan parametreler üzerinden, çıkışta elde edilecek diğer parametrelerin tahminini önceden gerçekleştirmektir. Bunun için parametreler arasındaki gizli ilişki ortaya çıkarılmaya çalışılır. Hiç şüphesiz bu durum yapay zeka teknolojilerinin yabancı olmadığı bir konudur. Literatür çalışmaları incelendiğinde atıksu arıtmada üzerinde durulan ve yapay zeka sistemleri ile çözülebilen temel problemleri aktif çamur proseslerinin iyileştirilmesi, pH nötralizasyon süreçleri, sistem üzerinde işleyişi sağlayan elektronik sistemin izlenmesi, kontrol edilmesi veya yöneticiye bu anlamda karar desteği sağlamak, tesis yönetiminde kullanılan endüstriyel çözüm uygulamalarının yapay zeka teknikleri ile iyileştirilmesi, online ölçülebilen tesis parametrelerinden yola çıkarak online ölçülemeyen parametreler arasında ilişkiyi ortaya çıkarabilmek, tesis parametreleri ile tesis verimliliğini anlık olarak ölçebilmek ve tesisin giriş

parametreleri kullanılarak çıkış parametrelerinin tahmin edilmesi olarak sınıflanabilir.

Atıksu arıtma prosesleri ve özellikle bu proseslerden aktif çamur sistemleri en yaygın olarak kullanılanlar arasındadır. Evsel ve endüstriyel atıksu arıtma tesisleri giriş debileri ve atıksu karakterizasyonu açısından büyük değişimler gösterirler. Bu değişimlerden dolayı, bir evsel atıksu arıtma tesisinden sağlanan bilgi ve tecrübenin başka bir evsel atıksu arıtma tesisinde kullanılması çok zor olmaktadır. Ayrıca, evsel atıksu arıtma tesislerinin işletilmesinde birçok değişkenin (lineer olmayan ve zamanla değişken) göz önünde bulundurulması gerekmektedir. Bu değişkenlerden bazıları yerinde ölçülebilmesine rağmen bazı değişkenlerin laboratuvarlarda ölçülmesi gerekmektedir. Bu sebeplerden dolayı, bu tesislerin işletilmesinde bir sorunla karşılaşıldığında bu sorunların aşılması çok kolay olmamakta ve sorunun aşılmasına yardımcı olacak araçlara gereksinim duyulmaktadır.

Atıksu arıtma tesisleri giriş parametrelerinin yukarıda bahsedildiği üzere büyük değişimler göstermesi, bu tesislerin optimum performansta işletilmesini zorlaştırmaktadır. Bu atıksu arıtma tesislerinin optimum işletilmesi amacıyla özellikle son 10-15 yılda çeşitli araçlar geliştirilmeye çalışılmaktadır. Bu araçlardan şu anda en yaygın olarak kullanılanı, matematiksel olarak geliştirilmiş ve matris şeklinde düzenlenmiş diferansiyel denklemlerden oluşan aktif çamur modelleridir. 1987 yılından itibaren uluslararası su kalitesi birliği (IAWQ) aracılığıyla aktif çamur model 1 (ASM1) [3], aktif çamur model 2 (ASM2) [4] ve aktif çamur model 3 (ASM3) [5] modelleri geliştirilmesine rağmen, bu modellerin halen bazı zayıf noktaları ve dezavantajları bulunmaktadır. Örneğin, bu modeller aktif çamur proseslerindeki sebep sonuç ilişkilerini çok iyi temsil edemedikleri gibi çok spesifik, çok sayıda ve ölçülmesi genellikle çok kolay olmayan giriş parametrelerine gerek duymaktadır [6]. Diğer ve daha önemli bir dezavantaj da, aktif çamur modelleri sadece aktif çamur içeren arıtma tesisleri için kullanılabilir. Bu nedenle, geliştirilen matematiksel modellere alternatif olarak veya matematiksel modellerin başarımı arttırmak amacıyla çeşitli yapay zeka teknikleri kullanılmaya başlanmıştır.

Atıksu arıtma üzerine geliştirilen ilk yapay zeka modellerinde, çoğunlukla aktif çamur modellerinde, atıksu çıkış değerlerinin tahmin edilmeye çalışıldığı çalışmalar görülmektedir. Ağırlıklı olarak ölçümü zaman alan biyolojik oksijen ihtiyacı (BOİ) ve kimyasal oksijen ihtiyacı (KOİ) parametreleri ile az sayıda çıkış parametresinin tahmini üzerine yapılan çalışmalardır. Aktif çamur yapısı kullanan bir atıksu arıtma sisteminde KOİ çıkış parametresini tahmin etmek amacıyla 1999 yılında yapılan çalışmada, bulanık yapay sinir ağı (FNN) modeli oluşturulmuştur [7]. Aktif çamur modelinin KOİ çıkış değerini elde etmek amacıyla yapılan başka bir çalışmada, yinelemeli bulanık yapay sinir ağı modeli (RFNN) oluşturulmuş, 0,68mg/l hata oranıyla başarılı bir sonuç elde edilmiştir [8]. Yine KOİ parametre tahmini için geliştirilen FNN modellerinde başarılı sonuçlar elde edilmiştir [6, 9, 10].

Atıksu arıtımında hiç kuşkusuz önemli adımlardan biri de, doğaya deşarj işlemi yapılmadan önce atık suyun uygun pH (çözeltinin asitlik veya bazlık derecesi) aralığına getirilmesidir. pH değeri tahmini için yapılan 2009 yılındaki çalışmada, başlangıç pH değerine karşılık, çıkış pH değerini bulmak için bir YSA modeli geliştirilmiştir. Model geri yayımlı 2 girişli (pH öncesi ve HCl (hidroklorik asit) dozajlama değeri), 1 adet gizli katmanı (139 adet nöronlu) olan sigmoid fonksiyonlu bir modeldir. İterasyon sayısı 100 ve öğrenme eşik değeri 0,001 olarak seçilmiş ve sonuç olarak hata oranları üzerinden %0,004 ifadesiyle başarılı bir model olduğu belirtilmiştir. Çalışma sonunda benzer çalışmalarla karşılaştırılması gerektiği ve geri yayılım dışında başka metodlarında kullanılması gerekliliği önerilmiştir [11]. pH düzenleme için doğrudan kontrollörlerin kontrol edildiği zeki sistem çalışmaları da literatürde yer almaktadır. Başarımı görebilmek adına, çalışmalar öncelikle MATLAB Simulink gibi yazılımsal ortamlarda gerçekleştirilmiştir. Sonrasında prosesin doğrudan kontrolünde bir klasik kontrol tekniği olan, PID (katsayı-integral-türev) gibi kontrol teknikleri kullanılmıştır [12, 13, 14, 15].

ASM modellerinin yaygın olarak kullanıldığı dönemlerde, ASM2 modeli proses dinamikleri olan nitrojen ve fosfor tahmini yapmak amacıyla YSA modeli önerilerinin yapıldığı çalışmalar bulunmaktadır [16].

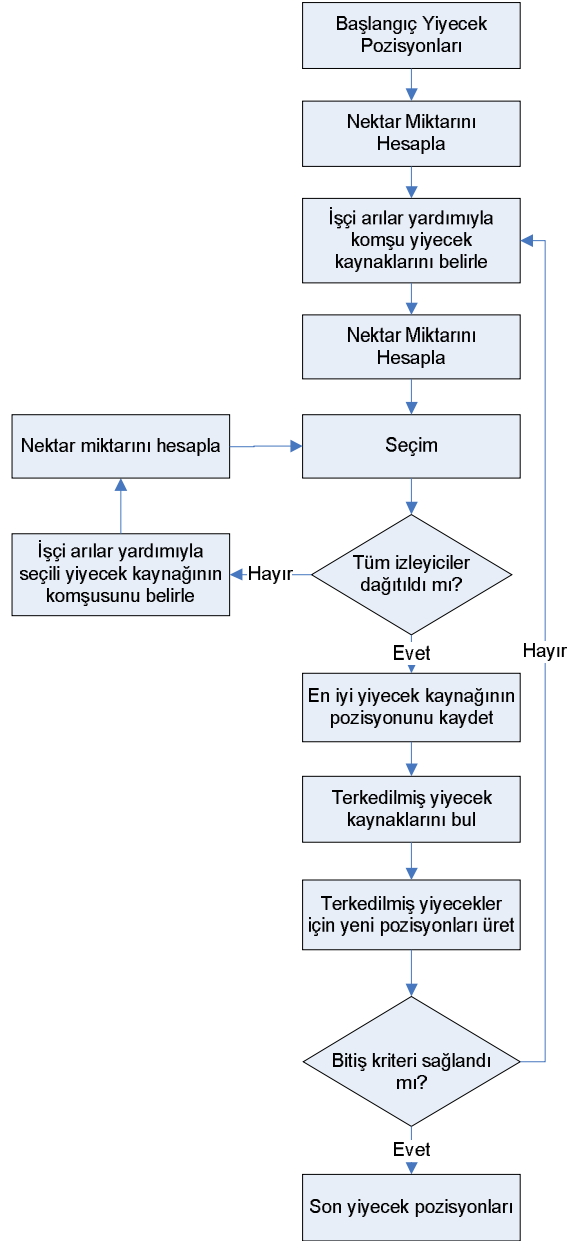
Literatürde tesise gelen atıksu miktarı (debi) tahmini üzerine çalışmalar da yer almaktadır. Geliştirilen YSA yapısı 3 katmanlı, sigmoid aktivasyon fonksiyonlu bir yapıdır. Tahmin için kullanılan veri kümesi içerisinde giriş olarak zaman, mevcut debi ve her saat için ortalama debi kullanılmıştır. Gizli katmanları 44, 25, 11 şeklinde olan 3 farklı YSA yapısı oluşturulmuştur [17].

Tahmin edilmeye çalışılan daha fazla sayıda parametrenin olduğu literatür çalışmaları da bulunmaktadır. 2010 yılında yapılan tez çalışmasında KOİçıkış, UAKMçıkış, TKMçıkış özelliklerinin belirlenmeye çalışıldığı ve giriş olarak KOİgiriş, TKMgiriş, UAKMgiriş, sıcaklık parametreleri çeşitli varyasyonlar ile YSA sistemine giriş olarak verilen modeller oluşturulmuştur. En iyi modelde KOİçıkış için $R^2=0,93$, TKMçıkış için $R^2=0,99$, UAKMçıkış için $R^2=0,97$ olarak belirlenmiştir. Dikkati çeken önemli sonuç, sıcaklık parametresinin giriş olarak alındığı modellerin başarımının en yüksek olduğudur. Karşılaştırma yaptığı başka bir çalışmada kullanılmış olan 18 girdi sayısına karşılık, bu çalışmada maksimum 4 adet girdi ile %99'a varan 4 model performansı elde edilmiştir [18].

Çoklu parametre tahmini yapılan diğer bir çalışmada, atıksu arıtma parametrelerinden KOİ, kjeldahl nitrojen (TKN) ve debi değerleri 3 farklı YSA modeliyle (MLP çokkatmanlı algılayıcı, geri yayımlı ve radyal basis fonksiyonlu YSA) kurulmuştur. Herbir tahmin parametresi için 13 ayrı YSA yapısı ayrı giriş parametreleri ile oluşturulmuştur. Giriş parametreleri KOİ, KOİ (k-1), KOİ (k-2), KOİ (k-3), ay, sıcaklık, yağmur, rüzgar olarak belirlenmiştir. PLC sistem kullanılarak SCADA sistemi üzerinden de veriler alınmaya çalışılmıştır. Sql server veritabanına atılmış veriler üzerinden çalışma MATLAB Simulink üzerinde gerçekleştirilmiştir. Regreasyon analizi ile sonuçlar değerlendirilmiştir. Yapılan implementasyon sonucunda real time olarak KOİ, TKN ve debi değerleri tahmin edilmiştir [19].

Yeni yapay zeka yaklaşımlarının ortaya çıkması ile birlikte atıksu arıtma tesisleri üzerine uygulamaları da yapılmıştır. 2006 yılında yapılan çalışmada arı algoritması YSA'nın eğitim methodu olarak kullanılmıştır ve ilk olarak ADASU Karaman atıksu arıtma tesisi verileri üzerine uygulanmıştır. Elde edilen sonuçlar neticesinde AAT

parametre tahmininde kullanılabileceği ortaya konmuştur. Aynı çalışmada UCI (Kaliforniya Irvine Üniversitesi) verileri de kullanılarak tüm çıkış parametrelerinin tahmini için genel modeller oluşturulmuştur. Model sonuçlarına göre YSA %85, genetik algoritma (GA) %80, arı algoritması %86 oranında başarı elde etmiştir [20]. Arı algoritmasının akış diyagramı Şekil 1.2’de verilmiştir.



Şekil 1.2. Arı algoritması [21]

Diğer bir çalışmada, Pelham atıksu arıtma tesisi işletme verileri kullanarak yapay sinir ağları tekniklerinden olan kohonen özörgütleme harita ağı yapısıyla, aktif çamur prosesindeki değişkenlerin kendi içindeki ilişki ve tepkileri incelenmiş ve proseslerin sistem davranışı analiz edilmiştir. Çalışmada kullanılan yapay sinir ağı metodunun daha verimli çalışabilmesi için ham veriler ilk önce lineer olarak her parametrenin varyansları 1 olacak şekilde normalize edilmiştir. Normalize edilmiş arıtma tesisi işletme verilerine, kohonen özörgütleme harita ağı, MATLAB yazılımı SOM Toolbox ile birlikte kullanılarak uygulanmıştır. Normalize edilmiş değerlerle çalıştırılan ağın çıktıları denormalize edilerek sunulmuştur. Yapılan değerlendirmeye göre, biyolojik reaktördeki pH'ın düşüklüğü ve yüksek çamur yaşının, çıkış BOİ, TAKM ve fekal koliform sayısının yüksek olması gibi bazı problemlere yol açabileceği tespit edilmiştir [22].

Atıksu arıtmada birçok parametre var olduğundan, bazı çalışmalarda parametre sayısını azaltmak ve etkin parametreleri bulmak amacıyla bileşen analizi methodları kullanılmıştır. Bir kağıt endüstrisi atıksu arıtma tesisinde BOİ çıkış parametresinin tahmin edilebilmesi için yapılan çalışmada, temel bileşen analizi (PCA) gerçekleştirilmiş ve BOİ belirlemede etkili parametreler tespit edilmiştir. Analiz sonucunda giriş ve çıkış debileri, giriş ve çıkış KOİ ve giriş BOİ değerleri kullanılmıştır. Çalışmada PCA'nın etkisini görebilmek amacıyla PCA'lı YSA (PYSA), standart YSA ayrı ayrı uygulanmış ve sonuçları karşılaştırılmıştır. Sonuçta PYSA daha başarılı olmuştur [10]. Diğer bir çalışmada biyolojik arıtma sisteminin sadece aerobik kısmının değerlendirilmiş, KOİ çıktı, NH₄-N çıktı ve TN çıktı parametrelerinin tahmine yönelik, herbiri için ayrı ayrı ANFIS modelleri oluşturulmuştur. Bu modellerde çıkış parametreleri için kullanılacak giriş parametreleri PCA analizi sonuçlarına göre belirlenmiştir. Model performansları korelasyon katsayısı (R), ortalama karesel hata karekökü (RMSE) ve ortalama oransal hata (MAPE) ile tespit edilmiştir. Elde edilen ANFIS model sonuçları Tablo 1.1'de gösterilmektedir [23].

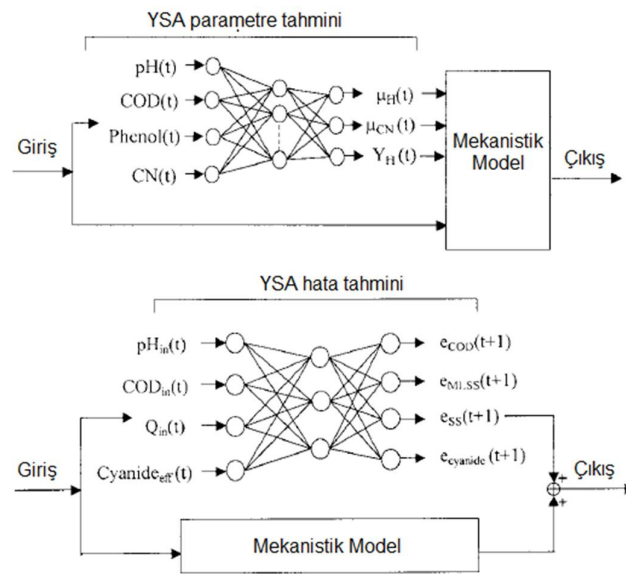
Tablo 1.1. ANFIS model performansları [23]

Model	Girdiler	Çıktıları	Kural Sayısı	Eğitim Sonuçları		Test Sonuçları	
				RMSE	R	RMSE	R
KOİ	Q_{girdi}	$KOİ_{çikti}$	2	8,23	0,99	7,90	0,98
	$KOİ_{girdi}$						
	$KOİ_{dn}$						
	pH						
NH_4N	Q_{girdi}	$NH_4N_{çikti}$	2	0,27	1,00	1,30	0,99
	$KOİ_{girdi}$						
	$KOİ_{dn}$						
	pH						
	TN_{girdi}						
	NH_4N_{girdi}						
	NH_4N_{dn}						
NH_4N_{nit}							
TN	Q_{girdi}	$TN_{çikti}$	2	3,84	0,99	4,21	0,99
	$KOİ_{girdi}$						
	$KOİ_{dn}$						
	pH						
	TN_{girdi}						
	NH_4N_{girdi}						
	NH_4N_{dn}						
NH_4N_{nit}							
	TN_{dn}						

Çalışmaların birçoğu giriş ve çıkış arasındaki ilişkiyi ararken, iç bölümlerdeki parametre gidişatını kontrol etmemektedir. İç proseslerin takip edilmesinin önemini savunan bir çalışmada atıksu arıtma tesisi 2 parçalı, fiziksel ve biyolojik arıtma olarak ele alınmış ve ilk kısımda BOİ, pH, SS, KOİ, debi parametreleri üzerinde ikinci kısım ise nitrojen ve fosfor parametreleri üzerine modellenmiştir. Oluşturulan yapay sinir ağı modelleri, YSA1 modeli 9 giriş 5 çıkıştan, YSA2 ise 10 giriş ve 9 çıkıştan oluşmaktadır. 234 verinin normalizasyon işlemi uygulandıktan sonra 182'si eğitim 52'si test için kullanılmıştır. YSA yapılarında sigmoid ve lineer fonksiyonların etkileri ayrı ayrı incelenmiş, sigmoid fonksiyonların kullanıldığı

modellerin başarımının lineer fonksiyon kullananlara göre daha iyi olduğu görülmüştür [24].

Yapılan çalışmalarda hibrid yaklaşımlar da dikkat çekmektedir. Atıksu arıtmada hibrid yaklaşım, mekanistik yaklaşımın bir yapay zeka metodu ile birlikte kullanımı veya birden fazla yapay zeka yaklaşımının birarada kullanılması ile oluşturulmaktadır. Yapılan bir hibrid çalışmada, YSA, bilinmeyen değerlerin olduğu ve non lineer olan mekanistik model kısımlarında kullanılmıştır. YSA, paralel ve seri olmak üzere mekanistik modele eklenerek 2 ayrı hibrid model oluşturulmuştur. Seri hibrid yapısında YSA bilinmeyen proses değerlerini üretmesi için, paralel yapıda ise mekanistik modele hata düzeltme katkısını sağlaması için kullanılmıştır. Bu birleşim mekanistik ve YSA avantajlarını bir arada toplamaktadır. Çalışmada tek başına YSA, YSA'lı hibrid modeller (seri ve paralel) ve tek başına mekanistik model ayrı ayrı da kıyaslanmış, sırasıyla $R^2=0,82-0,80-0,95-0,71$ değerleri elde edilmiştir. Sonuçlara göre paralel hibrid yapısı en başarılı model olmuştur. Seri model bilinmeyen proses değerlerini ürettiği için işi en zor olan model olmasına rağmen, yine de klasik mekanistik modelden daha başarılıdır [25]. Oluşturulan hibrid modeller Şekil 1.3'de gösterilmektedir.



Şekil 1.3. Hibrid YSA-mekanistik modeller [25]

Diğer bir çalışmada RNN modeli biyolojik arıtma proses kontrolörleri üzerinde 3 farklı şekilde dolaylı, tersine model ve direk adaptif sinir kontrolü olarak kullanılmıştır. Kontrolörlerin görevi belirlenen optimum şartlar altında sistemin sürekliliğini sağlamaya çalışmaktır. Bunun için nonlinear proses dinamikleri, reaksiyon kinetik değerleri ve bilinmeyen ve muhtemelen zaman değişkenli proses parametreleri ile yapmaya çalışır. Bu parametreler ve modelin elde ettiği sonuçlar Tablo 1.2 ve 1.3'te verilmektedir. Dolaylı modelin en başarılı model olduğu sonucuna varılmıştır [26].

Tablo 1.2. YSA kontrollör parametreleri [26]

Parametre	Açıklaması
C_d	Bozulma oranı parametresi
$F_{in}(t)$	Giriş debisi
$F_R(t)$	Geri dönüş debisi
k_{ref}	Referans orantılık faktörü
$n(t)$	Ölçüm gürültüsü
$q(t)$	Havuz giriş-çıkış oranı
S_{in}	Giriş substrat konsantrasyonu
$S(t)$	Substrat konsantrasyonu
T_m	Sensör zaman sabiti
$Y(t)$	Verim katsayısı
V	Biyoreaktör hacmi
$X(t)$	Biyokütle konsantrasyonu
X_m	Ölçülen biyokütle konsantrasyonu
$X_R(t)$	Geri dönüş akıntısındaki biyokütle konsantrasyonu
X_{ref}	X_R için referans sinyali
μ_t	Özel büyüme oranı

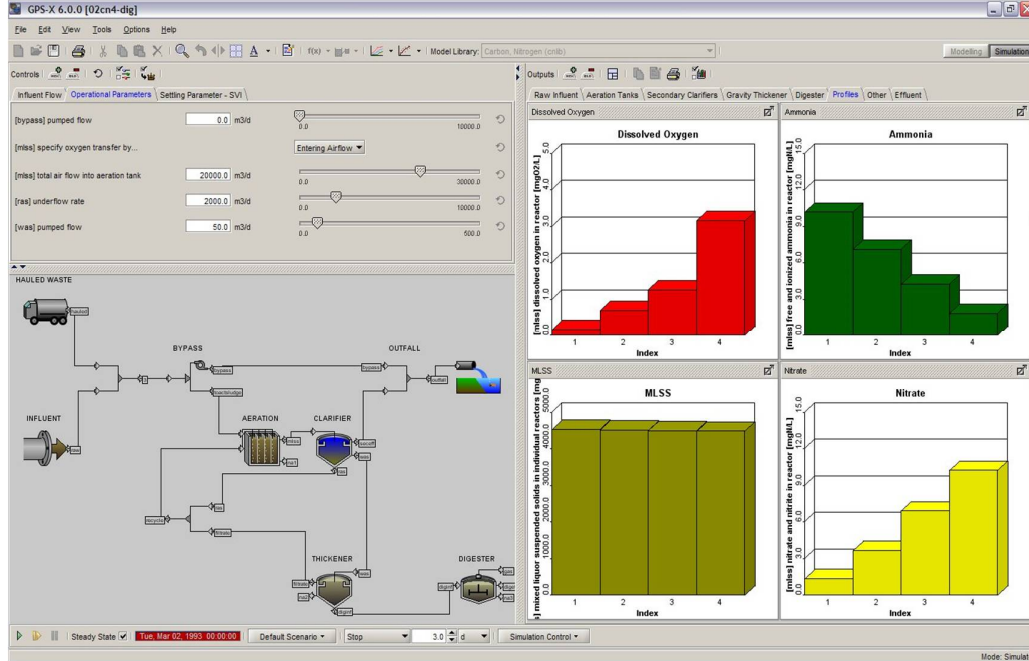
Tablo 1.3. YSA kontroller sonuçları [26]

Kontrol yapısı	OKH (%)
Dolaylı adaptif yinelemeli YSA kontrol	1,2
Tersine tesis modeli için adaptif YSA kontrol	1,4
Direkt adaptif YSA kontrol	2
Adaptif λ -takip kontrol	2,4

Atıksu arıtma proseslerinde biyoreaktörlerin modellenmesi üzerine çalışmalar da bulunmaktadır. 2007 yılında yapılan çalışmada, biyoreaktör prosesleri (denitrifikasyon, büyüme kinetikleri gibi) için matematiksel modelleri oluşturulmuş ve YSA ile kontrollör yapısına adaptif olarak entegre edilmiştir. Kontrol edilen ifadeler, substrat, biyolojik kütle değişimi ve çıkış ifadeleridir. Simülasyon sonuçları bu tür bir problemde YSA yapısının kullanılabilceğini göstermiştir [27].

YSA algoritmasının kullanıldığı başka bir çalışmada yinelemeli yüksek öncelikli YSA (RHONN) anaerobik atıksu arıtım prosesinde kullanılmıştır. Sistemin amacı biyolojik reaktördeki biyolojik kütle miktarını tahmin edebilmek ve belirlenen bir değer civarında tutmaya çalışmaktır. Anaerobik proses yüksek miktarda organik madde yüklemesi olan arıtma tesislerinde tercih edilmektedir. Sistem belirleyicisi olarak KOİ, biogaz ve pH değerleri ölçülmüştür. Geliştirilen sisteme göre bir neuro sistem gözlemcisi sistemdeki parametreleri denetleyerek, yapılacak işlem türünü anahtarlamaaktadır. İşlem türleri olan biokütle ve substrat değerlerini güncellemektir. Sistem kullanılan parametreler ile test edilmiş ve yüksek başarı elde edilmiştir [28].

Atıksu arıtma üzerine yapılan çalışmalarda hiç şüphesiz en büyük sorun sistemin çalışması için gerekli veri kümesinin elde edilmesidir. Bunun için uzun süren saha çalışmaları ve analizler gerektiğinden, bazı araştırmacılar gerçeğe yakın basit operasyonel data üreten simülatör programlardan yararlanmışlardır. Örneğin GPS-X adı verilen atıksu arıtma simülatör programı bu amaçla kullanılmıştır. Yapılan çalışmada, KOİ ve amonyak gibi parametrelerin tahmin edilmesi için YSA modeli geliştirilmiştir. Uygulama verileri GPS-X simülatör programından elde edilmiştir. YSA yapısı olarak da klasik MLP ve erken durdurmalı MLP yapıları tercih edilmiştir [29]. Şekil 1.4’de GPS-X simülatör programı arayüzü gösterilmektedir.



Şekil 1.4. GPS-X atıksu simülatörü [30]

Kentsel atıksu tesislerinin yanı sıra endüstriyel atıksu tesisleri için de çalışmalar yapılmıştır. 2000 yılında yapılan çalışmada, endüstriyel atıksuyun giriş karakterizasyonu analiz edilerek optimum düzeyde artımın yapılabilmesi için bir YSA modeli oluşturulmuştur [31]. Diğer bir çalışmada tesis BOİ değeri YSA ile tahmin edilmeye çalışılmıştır. Kullanılan datasetinde 6 değişik endüstrinin BOİ giriş ve çıkış değerleri yer almaktadır. 2 farklı YSA (BP sigmoid ve danışmanlı öğrenme hiperbolik tanjant transfer fonksiyonlu) modeli kullanılmıştır. İki model sonuçları da determinasyon katsayısı (R^2) ve ortalama karesel hata (OKH) ile incelenmiştir. İlk model başarı oranı %87 ile en başarılı model olmuştur [32].

Günümüzde atıksu arıtma tesislerinde kullanılan mekanik ve bilgisayar tabanlı sistemler, tüm tesis işleyişinin karmaşıklığını azaltmak ve kontrolünü kolaylaştırabilmek amacıyla kullanılmaktadır. Sağladıkları yönetim paneli sayesinde tesis yönetimi ofis içerisinden makinelerin yanına gitmeye gerek kalmadan yapılabilmektedir. Ayrıca bu sistemler sayesinde tesiste ölçülen parametreler kayıt altına alınabilmektedir. Sözet bu amaçla geliştirilmiş bir sistemdir. Ancak sistemin karar verme ve veriler üzerinde yorum yapma yetisinin olmaması nedeniyle bazı

yapay zeka tekniklerinin bu ihtiyacı karşılamaya dönük kullanılması amaçlanmıştır. Bu sayede daha efektif bir tesis yönetimi sağlanabilecektir [33]. Atıksu arıtma tesisleri için literatürde önerilmiş başka uzman sistem çözümleri de bulunmaktadır [34, 35, 36, 37].

Literatürde yeralan atıksu arıtma tesis parametre tahminleri üzerine yapılan diğer çalışmalar ve çalışmalarda kullanılan yapay zeka yaklaşımları Tablo 1.4’de verilmiştir.

Tablo 1.4. AAT üzerine son 10 yılda yapılan diğer yapay zeka çalışmaları

Yıl	Kaynak	Kullanılan Algoritma
2006	Fuente [38]	Fuzzy
2006	Tabatabaei [39]	SVN
2006	Liu [40]	PNN
2007	Chen [41]	YSA hibrid Fuzzy
2007	CAO [42]	NFS
2008	Moral [43]	YSA
2008	Dellana [44]	YSA
2008	Aguado [45]	Çok değişkenli istatistiksel yaklaşımlar
2008	Hanbay [46]	WPD ve YSA
2009	Mingzhi [47]	ANFIS
2009	Sadrzadeh [48]	Fuzzy
2009	Mingzhi [49]	NFS
2010	Turkdoğan [50]	Fuzzy
2010	Waewsak [51]	ANFIS
2010	Gibert [52]	Veri Madenciliği
2010	Liang [53]	FRSRBFNN
2010	Shi [54]	YSA
2010	Luolong [55]	RBFNN
2010	Yel [56]	Fuzzy
2011	Zhao [57]	Makine Öğrenmesi
2011	West [58]	YSA
2011	Turan [59]	YSA
2011	Feng [60]	Karar Destek Sistemi
2011	Khataee [61]	YSA
2011	Yetilmezsoy [62]	ANFIS
2011	Madaeni [63]	Fuzzy, GA
2011	Wan [64]	ANFIS
2011	Luolong [65]	NFS
2011	Zhi-ming [66]	GA
2011	Kern [67]	SOM

Tablo 1.4. (Devamı)

Yıl	Kaynak	Kullanılan Algoritma
2012	Dürrenmatt [68]	SOM
2012	Olmo [69]	Karar Destek Sistemi
2012	Behera [70]	YSA
2012	Han [71]	RBF
2013	Li [72]	Bayes Ağı
2013	Verma [73]	Veri madenciliği
2013	Liukkonen [74]	Uzman sistem
2013	Kocijan [75]	Örüntü tanıma
2013	Noori [76]	ANFIS
2013	Ye [77]	YSA
2014	Ay [78]	YSA ve ANFIS
2014	Seshan [79]	SVN
2014	Badrnezhad [80]	Hibrit YSA ve GA
2014	Chamberlain [81]	Karar Destek sistemi
2014	Han [82]	SORBFNN
2014	Goldar [83]	YSA
2014	Kern [84]	Makine Öğrenmesi
2015	Yan [85]	GA
2015	Ghaedi [86]	Hibrid YSA ve PSO
2015	Massana [87]	Makine Öğrenmesi
2015	Carvajal [88]	YSA
2015	Liu [89]	YSA
2015	Tao [90]	NFS
2015	Kordkandi [91]	YSA
2016	Li [92]	FFN, SCNN

1.4. Tezin Organizasyonu

Bu tez çalışmasının bölümleri aşağıdaki şekilde organize edilmiştir.

Birinci bölümde, tez çalışmasının amacı ve kapsamı, literatürdeki mevcut çalışmalar ile literature yapacağı katkılardan bahsedilmektedir.

İkinci bölümde, atıksu arıtma tesisleri, tesis prosesleri ve tesiste ölçülen özellikler hakkında bilgi verilmektedir.

Üçüncü bölümde, biyolojik bağışıklık sistemi hakkında genel bir bilgilendirme yapılmış olup, temel bileşenleri ve çalışma mekanizması hakkında bilgi verilmiştir. Yine aynı bölümde doğal bağışıklık sisteminden esinlenilerek üretilen YBS yapıları ve çalışma prensipleri detaylı olarak anlatılmıştır.

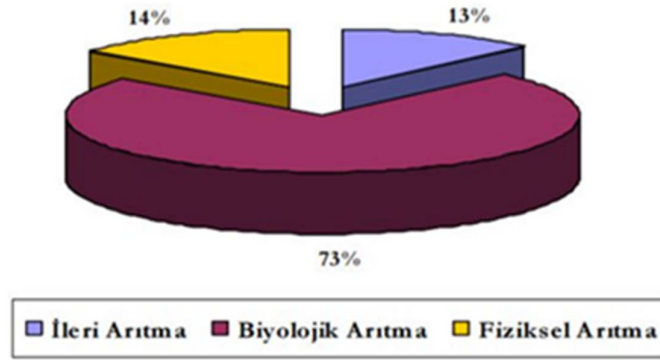
Dördüncü bölümde, geliştirilen atıksu arıtma tesisi YBS simülasyon sistemi hakkında bilgileri içermektedir. Sistemin geliştirilmesi sürecinde yer alan veri üzerinde yapılan işlemler, algoritma geliştirme süreçleri, veritabanı altyapısı ve kullanıcı arayüzleri ayrıntılı bir şekilde açıklanmaktadır. Bölüm sonunda modellerin simülasyon sonuçları verilmektedir.

Beşinci bölümde ise tez çalışması ile ilgili genel sonuçlar ve önerilere yer verilmektedir.

BÖLÜM 2. ATIKSU ARITMA TESİSLERİ

Evsel, endüstriyel faaliyetler veya diğer kullanımlar sonucu kirlenmiş ve özelliklerini yitirmiş sular, atıksu olarak isimlendirilir. Suyun kullanımlar sonucunda yitirmiş olduğu fiziksel ve kimyasal özelliklerini kısmen geri kazandırarak, deşarj edildikleri alıcı ortamın fiziksel, kimyasal ve ekolojik özelliklerini bozmayacak hale getirebilmek için, arıtma tesislerinde fiziksel, biyolojik ve kimyasal arıtma proseslerinin biri veya birkaçına tabii tutulmaktadır.


Atıksuyun karakteristiği (niteliği), atıksu arıtma tesisinde uygulanması gereken arıtma işlemlerini belirlemektedir. Atıksu içerisinde askıda bulunan ve yerçekimi etkisiyle kendiliğinden çökebilen maddelerin atıksudan arıtılması için fiziksel arıtma tesisi, çözünmüş organik maddelerin bakteriyel faaliyetler sonucunda arıtılması için biyolojik arıtma tesisi, bu yöntemlerle arıtılamayan ve kimyasal müdahalenin gerektiği atıksular için ise kimyasal arıtma tesisi kurulmaktadır. Fiziksel, biyolojik ve kimyasal işlemlerin birbiri ardına gelecek şekilde kullanılmasıyla daha kompleks tesisler de kurulabilmektedir. Dünya’da atıksuların arıtılmasının ardından tekrar kullanma ihtiyacı olan bölgelerde bu üç prosesin birarada kullanıldığı ileri arıtma tesisleri kurulmaktadır. 2010 TUİK verilerine göre Türkiye’deki arıtma tesislerinin kullandıkları proseslere göre dağılımı Şekil 2.1’de gösterilmektedir [1].



Şekil 2.1. Türkiye'deki atıksu arıtma tesislerinin proseslere göre dağılımı [1]

2.1. Atıksu Arıtma Prosesleri

Atıksu arıtma tesislerinde temelde 3 tür arıtma prosesi uygulanmaktadır. Bunlar; fiziksel (birincil), biyolojik ve kimyasal (ileri) arıtma prosesleridir. Bu proseslere ek olarak oluşan çamurun tesisten uzaklaştırılması için bir çamur arıtma prosesi de uygulanabilmektedir. Tesislerde uygulanan atıksu arıtma prosesleri Şekil 2.2'de gösterilmektedir [93].



Şekil 2.2. Tesislerde uygulanan atıksu arıtma prosesleri [93]

Fiziksel arıtma, atıksudaki yüzer halde bulunan ve kendiliğinden çökebilen maddelerin atıksudan uzaklaştırılması amacıyla yapılır. Aynı zamanda tesisteki diğer bölümlerin çalışmasını bozabilen taş, kum, çakıl gibi katı maddelerin atıksudan uzaklaştırılmasını sağlamaktadır. Fiziksel proses için kullanılan tesis ekipmanları aşağıdaki gibidir [94].

1. Izgaralar ve elekler: Atıksudan uzaklaştırılmadıkları takdirde, arıtma tesisinin sonraki ünitelerinde tıkanmalara sebep olabilecek büyüklükteki katı maddelerin ayrılması için kullanılır [94].
2. Kum tutucular: Atıksuda bulunan kum çakıl gibi kolayca çökebilen maddelerin pompalar, kanallar ve diğer bölümlerde tıkanmalara neden olacağından, kum tutucular yardımıyla atıksudan uzaklaştırılır [94].
3. Atıksu terfi üniteleri: Atıksuyun debi kaybetmesi üzerine yük kaybını telafi etmek amacıyla kullanılan pompa uniteleridir [94].
4. Öğütücüler: Atıksudaki kaba taneli katıların parçalanmasını sağlamaktadır [94].
5. Yağ tutucular: Genellikle endüstriyel atıksu arıtma tesislerinde kurulan ünitelerdir. Kentsel arıtma tesislerinde ön çökeltme birimlerine kurulan yağ sıyırıcı üniteler kullanılmaktadır. Yağ, yoğunluğu sudan az olduğu için su yüzeyinde bir tabaka halinde yer alır. Yağın, atıksu içerisine oksijen transferini kısıtladığı ve çökmesi gereken taneleri tutarak çökmeyi engellediği için uzaklaştırılması son derece önemlidir [94].
6. Ön çökeltme havuzları: Kaba katı maddelerin birçoğu diğer bölümlerde tutulduktan sonra, organik askıda olan yüksek kirletici özelliğe sahip maddelerin atıksudan uzaklaştırılması gereklidir. Atıksu, çökeltme havuzlarında bekletilerek çökebilen katı maddelerin suyun dibine çökerek uzaklaştırılması sağlanır [94].

Fiziksel arıtma sonrasında ikinci kademe (biyolojik) arıtma uygulanmaktadır. Biyolojik arıtma ortamda oksijen varlığına bağlı, havalı (aerobik) ve havasız (anaerobik) olarak, mikroorganizmaların sistemdeki durumuna göre askıda ve sabit film (biyofilm) prosesleri olarak da sınıflandırılmaktadır. Atıksudaki DBO'nun giderimi, çökmeyen kolloidal katıların pıhtılaştırılması gibi görevleri bulunan

biyolojik arıtma ünitelerinde, arıtma işlemi mikroorganizmalar tarafından gerçekleştirilir. Doğadaki biyolojik döngüler (örneğin nitrifikasyon) tesis ortamında gerçekleştirilir ve mikroorganizmaların sudaki atık maddeleri besin olarak kullanmaları sağlanır. Mikroorganizmaların özgül ağırlığı bu maddelerle beslenerek artar ve atıksudan çökerek ayrılırlar. Mikroorganizmalar atıksudan uzaklaştırıldığında arıtım gerçekleşmiş olmaktadır [95].

Mikroorganizmaların hayati fonksiyonlarını yerine getirip yeni hücre sentezi yapabilmek için,

1. Enerji kaynağına,
2. Karbon,
3. Azot,
4. Fosfor,
5. Sülfür,
6. Potasyum gibi elementlere ihtiyaç duymaktadır [95].

Bu bölümde kullanılan arıtma üniteleri [94]:

1. Biyolojik filtreler: Üzerinde mikroorganizmaların biyofilm halinde büyüdüğü filtrelerdir.
2. Aktif çamur ve modifikasyonları: Havalı biyolojik arıtma içinde geniş kullanım alanı bulunmaktadır. Daha çok büyük tesislerde kullanılır. Bu işlem sonrasında çözünmüş organik madde, çökebilene biyokütleyle dönüştürülür ve son çökeltme tankında çamur olarak tutulmaktadır.
3. Stabilizasyon havuzları ve modifikasyonları: Bu arıtma yönteminde atıksular ön arıtma ünitelerinden geçirildikten sonra havuzlara alınır. Temel prensip, sisteme dışarıdan enerji verilmeden doğal ortamda arıtımın gerçekleştirilmesidir. Stabilizasyon havuzları anaerobik, fakültatif ve olgunlaşma şeklinde 3 kademeli olarak yapılır. Stabilizasyon havuzları organik madde giderme, alg üretimi ve oksijen temini, koliform giderme ve nütrient madde giderme amaçları ile biyolojik arıtma ünitesi olarak dünyada yaygın bir şekilde kullanılmaktadır.

4. Anaerobik sistemler: Oksijenin olmadığı ortamda faaliyet gösteren biyolojik arıtma sistemleridir.

Kimyasal arıtım (ileri arıtma), arıtma tesislerinde ileri düzey arıtma gerçekleştirmek için kullanılmaktadır. Karıştırma ünitelerinde, atıksuyun içerisine çeşitli kimyasal maddelerin eklenerek, atıksu kirleticilerinin kimyasal reaksiyona girmesi sağlanır. Reaksiyona giren kirleticilerin çökmesi ile atıksudan uzaklaştırılır ve arıtma işlemi gerçekleşmiş olur [96].

2.2. Atıksu Karakteristiği

Atıksu kaynağı genellikle evsel veya endüstriyel olarak sınıflandırılır. Atıksuyun kaynağı atıksuyun fiziksel, biyolojik ve kimyasal özelliklerini ve dolayısı ile uygulanması gereken arıtma sürecini de doğrudan etkilemektedir.

Atıksu arıtma, atıksuyun sahip olduğu bu karakteristik özelliklerine göre belirlenir. Atıksu karakteristiğini oluşturan özellikler, ölçüm noktalarındaki sensörler üzerinden veya laboratuvar deneyleri ile ölçülmektedir. Atıksu özelliklerinin belirlenmesi ile tesisin işletme stratejisi belirlenir ve tesis kontrol altında tutulur [94].

Fiziksel özellikler:

1. Sıcaklık: Atıksuyun termal sıcaklık derecesini göstermektedir.
2. Renk: Atıksudaki askıda veya çözülmüş durumda olan maddelerin varlığına bağlı olarak atıksuyun sahip olduğu rengi belirler.
3. Koku: Atıksuyun özelliklerine dair yararlı bilgiler vermektedir. Evsel ve endüstriyel atıksuların kendine özgü kokuya sahiptir.
4. Bulanıklık: Bu ölçümler ile özellikle askıda katı madde içeriği tahmin edilebilmektedir.
5. Debi: Atıksu tesisine gelen atıksuyun debisi mevsimsel şartlara, günlük zaman dilimlerine bağlı olarak salınım göstermektedir.

6. İletkenlik: Atıksudaki çözülmüş madde miktarının bir göstergesidir. Atıksu içerisindeki madde yoğunluğuna bağlı olarak belirli bir iletkenlik düzeyine sahiptir.
7. Çökebilirlik: Bu özelliğe göre belirli bir süre bekletme veya çeşitli boyutlarda filtrelerden geçirilerek, atıksudaki katı maddeler için arıtma stratejisi oluşturmamıza yardımcı olmaktadır.

Biyolojik özellikler, atıksudaki mikroorganizma varlığını belirlemek amacı ile yapılan analizler ile elde edilmektedir. Bu özellikler [94]:

1. Bakteriler: Atıksu içerisinde yoğun miktarda görülen mikroorganizmalardır. Biyolojik arıtma sonucunda büyük miktarı elimine edilse bile yine de atıksu deşarj suyunda bile fazla miktarda bulunmaktadır.
2. Virüsler: Atıksuda bakterilere kıyasla daha az miktarda bulunurlar. Ancak virüslerin belirlenmesi oldukça zor ve zaman alıcı işlemlerin yapılmasını gerektirir.

Kimyasal özellikler, kimyasal analizler sonucunda elde edilmektedir. Analizler sonucunda üzerinde çalışılan unsurun konsantrasyonu belirlenmektedir. Bu özellikler [94]:

1. pH: Atıksu hidrojen iyonu konsantrasyonudur. Atıksu prosesleri pH düzeyine oldukça duyarlıdır.
2. Alkalinite: Atıksuyun asitleri nötralize etme kapasitesinin ölçüsüdür.
3. Katılar: Atıksuda askıda veya çözülmüş halde bulunan katıların ölçüsüdür. Katılar; uçucu, askıda, çözülmüş ve toplam olmak üzere çeşitli şekillerde takip edilirler.
4. BOI: Atıksuyun stabilizasyonu için gerekli olan oksijen ihtiyacıdır. Ölçüm 5 gün boyunca 20 derece sabit sıcaklıkta yapılarak elde edilmektedir.
5. KOI: Atıksuyun kimyasal açıdan ihtiyaç duyduğu oksijen miktarıdır. 3-4 saatlik testler sonucunda elde edilmektedir.
6. Azot: Atıksu içerisinde 4 ayrı formda (organik azot, amonyak, nitrit ve nitrat) bulunan azot miktarı ölçülmektedir.

7. Fosfor: Azot gibi deęişik formlarda bulunmaktadır. Özellikle biyolojik prosesler için gerekli bir elementtir.
8. Klor: Yüksek reaksiyon kapasitesi sebebi ile ölçülen bir parametredir.
9. Sülfür: Düşük seviyede varlığı bile canlı yaşamı için oldukça tehlikelidir.
10. Yağ ve Gres: Bu maddeler alıcı ortam yüzeyini kaplayarak dolayısı ile oksijen transferini engellediđi için dikkat edilen bir parametredir.
11. Diğer parametreler: Tesisin kurulduđu bölgede atıksuyun sahip olabileceđi diğer kimyasal özelliklere göre ayrıca ölçülen başka parametreler de bulunmaktadır. Bu maddeler; ağır metaller, siyanür, fenoller gibi diğer kimyasallardır.

2.3. Atıksu Arıtma Parametreleri

Atıksu arıtma tesisi kontrolünde kullanılan parametrelerin ölçümleri belirli aralıklarla genel olarak tesisin giriş, biyolojik arıtma, çamur arıtma ve tesis çıkışı bölümlerinde gerçekleştirilmektedir. İlgili tesis bölümlerinde ölçülen parametreler Tablo 2.1’de gösterilmektedir.

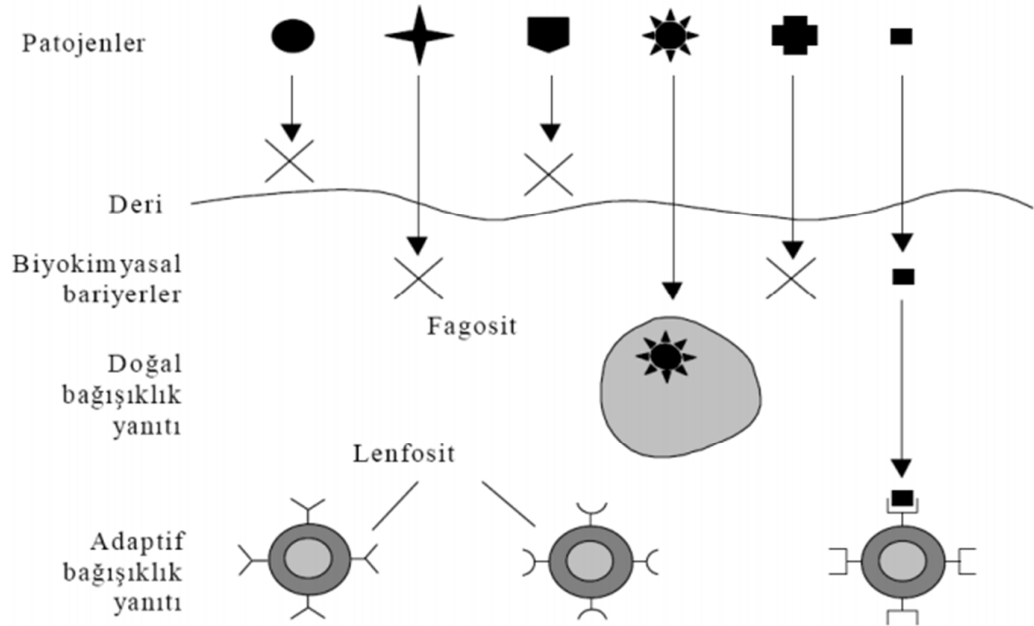
Tablo 2.1. Tesis bölümlerinde ölçülen parametreler [94]

Tesis Giriş	Biyolojik Arıtma	Çamur Arıtma	Tesis Çıkışı
Sıcaklık	Sıcaklık	Geri Devir Çamuru Miktarı	Sıcaklık
pH	pH	Atık Çamur Miktarı	pH
Debi	TAKM	Organik Madde	AKM
TAKM	AKM	İnorganik Madde	BOI
AKM	UAKM	Toplam Katı Madde	KOI
UAKM	Çamur Hacmi		NH4-N
BOI	Çamur İndeksi		NO3-N
KOI	Organik Madde		Fosfor
NH4-N	İnorganik Madde		Organik Madde
NO3-N			İnorganik Madde
Fosfor			
Organik Madde			
İnorganik Madde			

BÖLÜM 3. DOĞAL VE YAPAY BAĞIŞIKLIK SİSTEMLERİ

3.1. Doğal Bağışıklık Sistemi

Bağışıklık sistemi insan vücudunun hastalıklara karşı savunma mekanizmasını oluşturan karmaşık bir sistemdir. Dış ortamdan gelen tüm patojenlere (yabancı, zararlı maddeler, virüsler, bakteriler ve diğer parazitler) ve enfeksiyonlara karşı kendini koruma mekanizmasıdır. Koruma mekanizması çok katmanlı, değişik seviyelere yayılmış formlarda savunma yapılarına sahiptir [97]. İnsan vücudu için bu katmanlar Şekil 3.1’de gösterilmektedir.



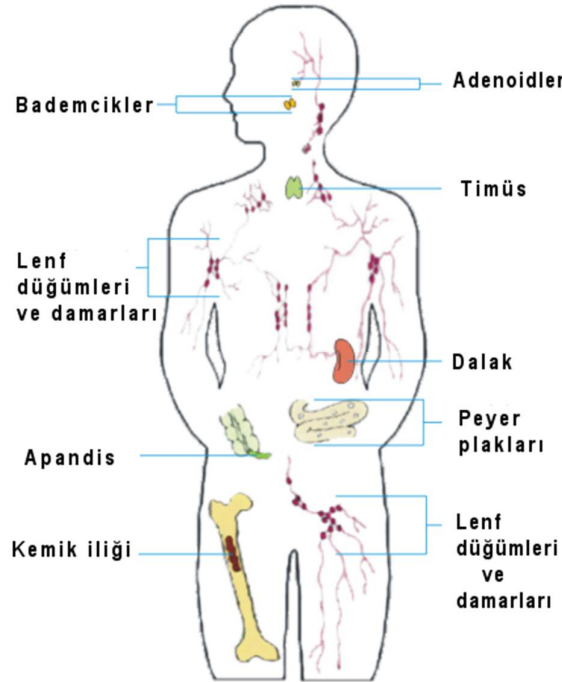
Şekil 3.1. İnsan vücudundaki bağışıklık sistemi koruma mekanizması [97]

Bağışıklık sisteminde tanınmayan her madde veya hücreye genel olarak antijen adı verilmektedir [98]. Savunma mekanizmasının içerisinde bulunan hücreler, dokular ve moleküllerin tamamı bağışıklık sisteminin parçalarıdır. Bu parçalar birarada çalışarak

antijenleri bulur ve bağışıklık cevabı denilen tepkiyi yaratırlar. Bu tepki neticesinde antijenler engellenir veya yok edilir [99, 100].


Doğal bağışıklık sistemini, tanıma işlemini gerçekleştirirken 2 temel mekanizmayı kullanır. Bunlar doğuştan veya sonradan edinilen (adaptif) bağışıklıktır. Doğuştan bağışıklık çoğunlukla bilinen antijenler için çalışırken, adaptif bağışıklık ise doğuştan bağışıklığın tanıyamadığı diğer durumlara karşı canlıyı korumak için devreye girmektedir [101, 102].

Doğuştan bağışıklık canlının doğumunda varolan ve bağışıklık sisteminin oluşturulması için temel bilgileri içerir. Ancak tek başına canlıyı tam olarak korumak için yeterli değildir. Adaptif bağışıklık ise bu ihtiyacı karşılamak adına kullanılır. Adaptif bağışıklık her antijene özgü ayrı hücreler oluşturur, bu hücreleri antijen ile her karşılaştığında geliştirir ve değiştirir. Antijene özgü bu hücreler çoğunluğu kemik iliğinde üretilen lenfositler, yani B ve T tipi beyaz kan hücreleridir [103]. İnsan vücudunda yer alan lenfositin üretildiği doku ve organlar Şekil 3.2’de görülmektedir.



Şekil 3.2. Lenfositin üretildiği doku ve organlar [104]


Bağıışıklık sistemi verdiđi cevabın ardından bu antijene duyarlı hücreleri saklar. Bu hücreler hafıza hücreleri olarak isimlendirilirler. Benzer bir durumla tekrar karşılaşılmaması halinde bu hafıza hücrelerinden yararlanır, bu sayede bağıışıklık sistemi daha hızlı ve güçlü bir şekilde bağıışıklık cevabını oluşturur. Bağıışıklık kazanma hafıza hücrelerinin oluşumu ile gerçekleşmiştir [105]. Bağıışıklık hüresinin antikor yapısı ve antijen tanıma işlemi örnek olarak Şekil 3.3'te gösterilmektedir.



Şekil 3.3. Antikor yapısı ve antijen tanıma [101]

Adaptif bağıışıklığın çalışma prensipleri açıklanırken farklı teoriler oluşturulmuştur:


1. Klonal seçim teorisi: Klonal prensibin çalışma mekanizması Şekil 3.4'de gösterilmektedir.



Şekil 3.4. Bağışıklık sisteminde klonal prensibin çalışma mekanizması [106]

Antijen karşı oluşturulan adaptif yanıt için antijen ile eşleşen antikorlara sahip B hücresi aktive edilir ve çoğalmaya başlar. Sonrasında hafıza ve plazma hücrelerine ayırır. Plazma hücrelerinden antijene özgü savaşabilmesi için antikor hücreleri oluşturulur ve çoğaltılır. Ayrıca hafıza hücreleri ile ikincil bir adaptif bağışıklık cevabı daha oluşturulur [101].

2. Negatif seçim teorisi: Kemik iliğinde üretilen T hücrelerinin timüste geçirdiği evredir. Canlıya ait hücrelerle eşleşmeyen T hücreleri kemik iliğinden dışarı serbest bırakılırken geriye kalan T hücreleri yok edilirler. Yok edilen hücreler canlının kendi öz hücrelerini patojen olarak algılama kapasitesinde olan hücrelerdir. Bu nedenle yok edilmelidirler. Aksi halde T hücreleri canlının kendisini bir tehdit olarak algılar [101]. Negatif seçim teorisi çalışma prensibi Şekil 3.5’de gösterilmektedir.



Şekil 3.5. Bağışıklık sisteminde negatif seçim teorisi çalışma prensibi [101]

3. Baęışık aę teorisi: Bu teori birbirine baęlantılı B hücrelerinin antijen tanıma sırasında oluřturdukları aę yapısına dayanır. Aę üzerindeki her B hücresi baęlantı noktaları üzerinden aęın stabil bir řekilde kurulabilmesi için baęlanırlar. B hücrelerinden en yüksek afinite deęeri sahip hücreleri arasında gerekleřir. Afinite antijen ile B hücresinin ürettięi antikoru birbirine olan ekimi (tanıma gücü) olarak tanımlanır [101].
4. Dendritik hücre teorisi: Dendritik hücreler, dıř evre ile temas halinde bulunan dokularda yer almaktadır. Genellikle deride, burunda, akcięerlerde, midede ve baęırsaklarda bulunurlar. Antijeni daha vücuda veya organın hücresine girmeden önce yakalamak için tasarlanmıřtır. Dendritik hücrelerin öncelikli görevi antijeni erken farketmek olduęundan, henüz uyarılmamıř T hücrelerini uyararak primer baęışıklık cevabının oluřmasını saęlamaktadır [107].

3.2. Yapay Baęışıklık Sistemi

İnsan vücudunda birçok sistem modellenerek bilgisayar algoritmaları řeklinde problem özümleri için kullanılmıřtır. Baęışıklık sisteminin 1960'lı yıllardan itibaren işlevsellięi ve sınırları keřfedilmeye başlanmıřtır. Sistemin keřfedilmeye başlanması ile birlikte öncelikle arařtırmacılar bu sistemin alıřma prensipleri irdelemeye alıřmıřlardır. Baęışıklık sisteminin nasıl alıřtıęına dair somut bilgilerin elde edilmesi 1990'lı yılları bulmuřtur [108].

Baęışıklık sisteminin sınırlarının belirginleřmeye başlamasının ardından, aynı yapay sinir aęları ve genetik algoritmalarda olduęu gibi doęadan örneklenerek yeni bir sezgisel yöntem olan yapay baęışıklık sistemi (YBS) ortaya çıkmıřtır [108]. İnsanda varolan savunma mekanizmasının modellenerek oluřturulduęu bu yöntem, genel amaçlı bir yöntem olarak geliřtirildięinden, optimizasyon, sınıflandırma, kümeleme, örüntü tanıma gibi birçok kompleks mühendislik probleminin özümünde kullanılabilecek yapıdadır. İlk YBS modeli Forrest tarafından 1996 yılında oluřturulmuř ve bilgisayar virüslerinin tanınması için uygulanmıřtır [109].

YBS'nin, genetik algoritmalarla benzerlikleri olan bir yapıya sahiptir. Her ikisinde de çözüm uzayının kodlanması, bir uygunluk fonksiyonunun belirlenmesi, mutasyon işlemi gibi ortak işlemleri bulunmaktadır. Temel farklılıkları YBS'de çaprazlama operatörünün olmaması ve lokal optimumlara daha hızlı yönelebilmesi ancak global optimuma genetik algoritma kadar yakınsayamayabilmesidir [108].

YBS, diğer yandan yapay sinir ağlarına da benzerlikleri bulunan bir algoritmadır. En temel benzerliği hafıza ve öğrenme özelliklerine sahip olmasıdır. Oluşturabileceği çok sayıda ve farklı özellikte hücre sayesinde geniş bir arama uzayında çözüm arayabilmektedir. Her iki algoritma içerisinde eşik değer tanımı yer almaktadır. Bu benzerliklere rağmen YBS'nin sahip olduğu mutasyon işlevi sayesinde YSA'daki gibi lokal minimumlara takılma ihtimali çok daha az olması YBS'nin önemli avantajlarından [108].

YBS avantajlarıyla adından söz ettirmeye başlamış ve yeni YBS algoritmaları oluşturulmaya başlanmıştır. Bir sonraki alt bölümlerde algoritmalar hakkında detaylı bilgi verilmektedir.

3.3. YBS Algoritmaları

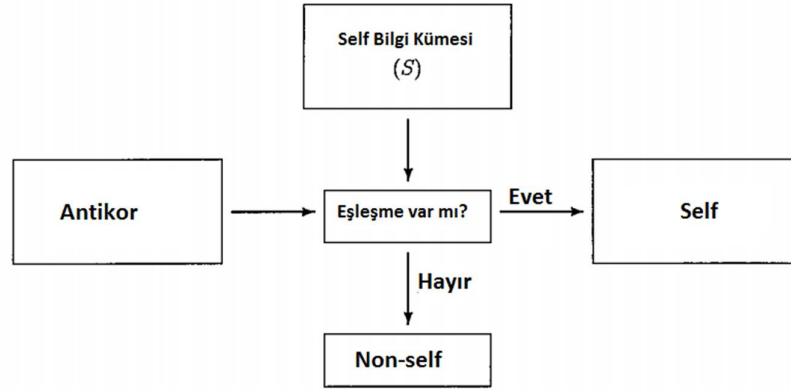
Hesaplama ve teorik bağışıklık bilimi kavramlarının netleşmesinin bir sonucu olarak bağışıklık sistemini örnekleyen, karmaşık ve gelişmiş YBS algoritmaları ortaya çıkmıştır. Bağışıklık sisteminden ilham alınarak geliştirilen YBS algoritmaları, ilk olarak temel YBS mekanizmaları olan klonal seçim, negatif seçim, bağışıklık ağ ve dendritik hücre tabanlı yaklaşımlardır [101, 110].

3.3.1. Negatif seçim algoritması

Negatif seçim algoritması (NSA), doğal bağışıklık sisteminde yeralan negatif seçim mekanizmasından ilham alınarak oluşturulmuştur. Timusta T-hücrelerinin seçimini öngören negatif seçim mekanizmasının ilk teorik modeli Perelson tarafından 1993'te yapılmıştır. Oluşturulan model T hücrelerinin seçimi için detaylı bilgilere sahip

olduğu gibi vücudun kendisine ait olmayan antijenleri tanımada nasıl kullanılabileceği de belirtilmiştir [111].

NSA temel olarak sınıflandırma ve örüntü tanıma problemlerinde kullanılmak üzere tasarlanmıştır. Örnek negatif seçim çalışma prensibi Şekil 3.6'da gösterilmektedir [112].



Şekil 3.6. YBS negatif seçim algoritması akış diyagramı [112]

Negatif seçim tabanlı algoritmalar birçok farklı uygulama alanında kullanılmıştır. Forrest tarafından negatif seçim algoritması matematiksel olarak anormallik tespiti için kullanılmıştır [112]. Ayara ve diğerleri yaptığı çalışmada negative seçim algoritmasında mutasyon işlemini tanımlamıştır [113]. Gonzalez ve Cannady anormallik tespiti için self-adaptif negatif seçim modelini önermiştir [114]. Igawa ve Ohashi, ANSC adında bir sınıflandırma modeli önermiştir. Bu çalışmada negatif seçim ve klonal seçim prensipleri entegre kullanılmış, negatif seçimin tek başına sınıflandırma problemlerinde kullanılması durumunda yaşanan sorunlar, klonal seçim metodu ile aşılmıştır [115]. Negatif seçim prensibinin kullanıldığı birçok farklı çalışma da bulunmaktadır [116, 117, 118].


3.3.2. Yapay bağışıklık ağı algoritması

Yapay bağışıklık ağı algoritması (YBSNet) edinilmiş bağışıklık sisteminde yeralan bağışıklık ağı teorisinden esinlenerek oluşturulmuştur. İlk olarak bağışıklık ağı teorisi

temelleri 1974 yılında Jerne tarafından ortaya çıkarılmıştır. Bu çalışmanın ardından bu teorinin detaylarının açıklandığı araştırmalar yapılmış, çeşitli teorik modeller üretilmiştir [119,120]. Ağ teorisinin matematiksel modellenmesi de Dasgupta tarafından gerçekleştirilmiştir [121]. Bu dönemden itibaren araştırmacılar değişik yaklaşımlar ile yapay bağışıklık ağı algoritmasının gelişmesine katkı sağlamışlardır.

Timmis ve diğerlerinin önerdiği AINE isimli modeli veri analizi amacı ile oluşturulmuş bir modeldir. Bu modelde B hücrelerinin ifadesinde ARB ve NAT yaklaşımları kullanılmıştır [122]. Timmis ve Neal in önerdiği ağ modelinde RLAIS yaklaşımı benimsenmiştir [123]. Castro ve Zuben geliştirdikleri modelde, ağ algoritması ile negatif seçim ve klonal seçim algoritmalarını birlikte kullanmışlardır [124]. Kümeleme problemi için ağ temelli algoritma modeli Li ve diğerleri tarafından geliştirilmiştir [125].

Bağışıklık ağı sürecinin amacı antijene daha az benzeyen (düşük benzerliğe sahip olan) antikor hücreleri bastırarak, yüksek benzerliğe sahip antikorların oluşturduğu bir ağ yaratmaktır. Bu ilke, ağ yapısını daha stabil hale getirerek, dış uyarılara (antijenlere) karşı yine stabil bir tepki vermek içindir. Şekil 3.7’de örnek bir YBSNet gösterimi bulunmaktadır.



Şekil 3.7. YBS ağı örnek gösterimi [126]

YBSNet ağırlıklandırılmış geçiş yolları ve düğümlerinden oluşan bir grafi. Düğümler olarak hücreleri göstermektedir. Benzer nitelikli hücreleri birarada ağ yapısı şeklinde bulunmasını sağlamak amacıyla da yolları bulunmaktadır. Yolların

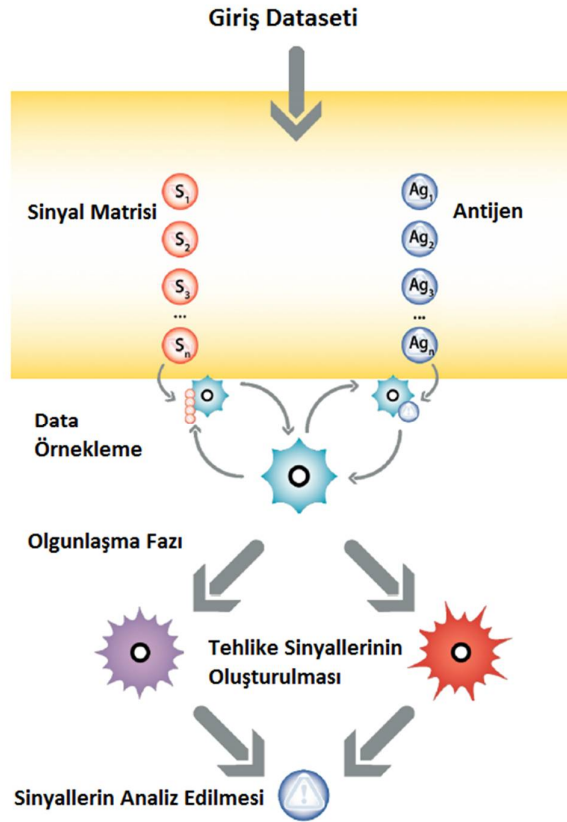
ağırlıkları hücre bağlantısının gücünü göstermektedir. Bilgi ağ üzerinde hücrelere dağıtılmış şekildedir. Ağın büyümesi için temelinde klonal seçim prensibi kullanılır ve benzerlik ölçümü ile gerçekleşen başkalaşım (mutasyon-değişim) ile öğrenme sağlanır. YBSNet algoritma adımları aşağıdaki gibidir [126].

1. S = antijen kümesini oluştur, nt = ağ benzerlik eşik değeri, ct = klonal havuz eşik değeri, h = klonlama sayısı değerlerini tanımla.
2. Başlangıç antikor popülasyonunu oluştur (N).
3. S içerisindeki her antijen için 4 ile 9 arasındaki adımları işlet.
4. N içerisindeki her birey için benzerlikleri tanımla.
5. N içerisindeki her alt küme için yüksek benzerliğe sahip bireyleri klonla.
6. Klonlanan bireyleri mutasyona uğrat ve C klon setine dahil et.
7. C klon setindeki bireyler için antijene benzerliği ct den düşük olan bireyleri yok et.
8. C bireylerinin birbirleri arasındaki benzerlikleri hesapla ve benzerlik değeri ct den düşük olanları yok et. Geriye kalan C setindeki bireyleri N kümesine dahil et.
9. N setindeki her grup bireyin birbiri arasındaki benzerlik değerini hesapla ve nt eşik değerinden düşük olanları N setinden çıkar.
10. S içerisindeki antijenler ile N setindeki bireyleri karşılaştır ve sınıflandır.

3.3.3. Dendritik hücre algoritması

Dendritik hücre algoritması (DHA) bağışıklık sisteminde bulunan dendritik hücrelerden esinlenilerek oluşturulmuştur. DHA yapısı gereği çok boyutlu işlem yapmak için tasarlanmıştır [127].

DHA bir sınıflandırma algoritması değildir ancak filtreleme ve sıralama özelliklerini paylaşarak ürettiği sinyaller ile sınıflandırmaya yardımcı olur. Algoritmanın çalışma akışı Şekil 3.8'de gösterilmektedir [127].



Şekil 3.8. Dendritik hücre algoritması [127]

DHA hücreleri antijenden aldıkları farklı sinyaller neticesinde farklı tecrübelerle sahiptir. Antijeni analiz edebilmek için bu farklı tecrübelerin ortalama olarak biraraya toplanması için bir DHA popülasyonu oluşturulur. Popülasyondaki her birey biraraya gelerek antijeni etiketlemek adına bir anomaly katsayısı (MCAV) değeri oluşturmaya yardımcı olur. MCAV bir anomaly olasılığı değeridir ve 0 ile 1 arasında bir değer alır. 1'e doğru yaklaşması anomaly olasılığının yüksek olduğunu göstermektedir [127].

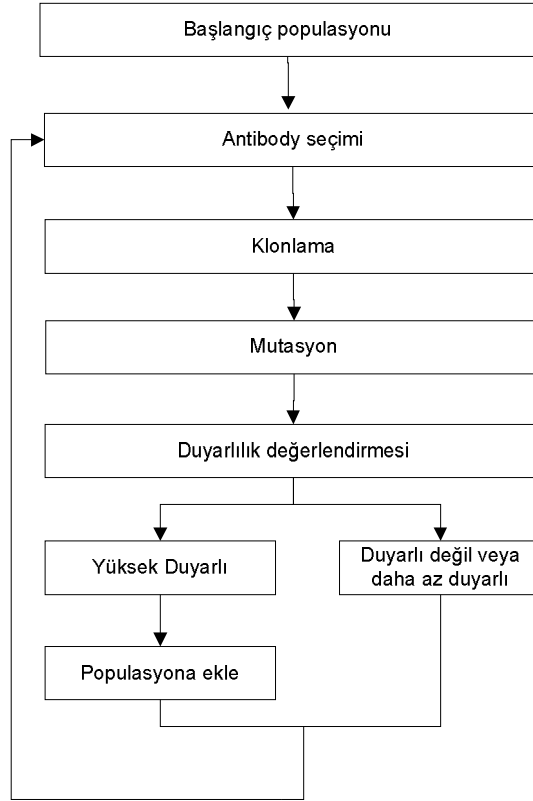
DHA algoritması, veri filtreleme yöntemi olarak anormallik tespiti problemleri için kullanılmaktadır. Algoritma tekli ayrık ve kategorilenmiş girişler üzerinden verilen iki sinyal tipini üzerinde çalışmak üzere oluşturulmuştur. Bu sinyaller tehlikeli ve güvenli gibi iki olasılıklı sinyallerdir [127].

3.3.4. Klonal seçim algoritması

Klonal seçim prensibi çalışmaları ilk olarak 1978'de Burnett tarafından yapılan çalışma ile başlamıştır. Bu çalışma ile benzerlik metrikleri ilk kez matematiksel olarak ifade edilmiştir [128].

Klonal seçim algoritması (KSA) adaptif bağışıklığın antijenleri yok etme sistemini modellemeye çalışır. Kullanım alanı çoğunlukla optimizasyon problemleri için olsa da örüntü tanıma, değer yakınsama problemleri için de uygun modeller yaratmaya elverişlidir. Birçok farklı problem tipi için kullanılan algoritmanın, sürekli değişen ortamlarda tahmin problemi çözümünde performansının son derece yüksek olduğu bilinmektedir [106, 107].

Klonal seçimde modellemeyi gerçekleştirirken antijeni tanıma duyarlılığı geliştirilmeye çalışılır. Bunun için antijeni tanıyan hücrelerin seçilerek çoğalması (klonlama) ve ardından çoğalan hücrelerin antijeni tanıma duyarlılıklarının artırılması için mutasyon işleminden yararlanılır. Bu sayede antijeni daha iyi tanıyan bağışık hücre popülasyonu elde edilmiş olur [129, 130]. Klonal seçim algoritmasının blok diagramı Şekil 3.9'da verilmiştir [106].



Şekil 3.9. Klonal seçim algoritması [106]

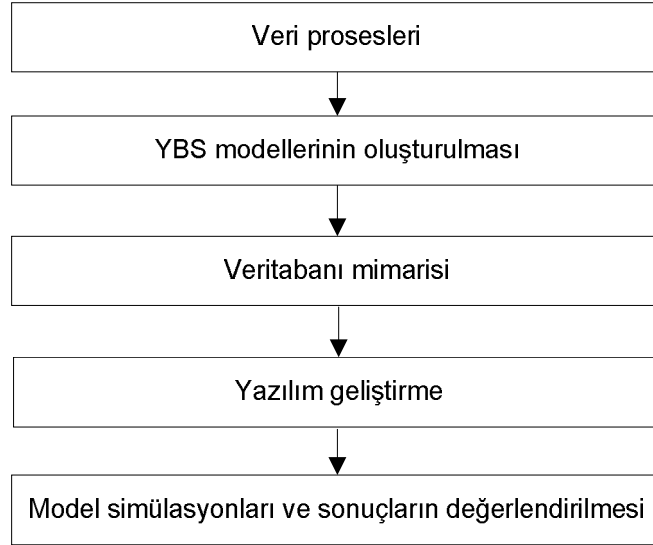
Algoritmanın çalışma adımları şu şekildedir [106]:

1. Sistemin başlangıçta sahip olduğu hafıza hücrelerinden başlangıç antikor popülasyonu (P) oluşturulur.
2. Antikorlardan antijene en çok benzeyen n tanesi seçilir.
3. Seçilen en iyi birey antikorlardan antijene duyarlılıklarına göre klonlanarak çoğaltılırlar ve klon popülasyonu (C) oluşturulur. Klonlama sonucunda duyarlılığı daha yüksek bireyler sayıca çoğalmış olur.
4. Klonlamanın ardından oluşan bireyler mutasyon işlemine tabi tutulur. Mutasyon işleminin amacı duyarlılığı yüksek bireyleri farklılaştırarak antijene daha çok eşleşen bireyler ortaya çıkarmaktır. Mutasyon sonucu oluşan yeni bireyler arasından duyarlılık ölçümü ile kontrol edilir. Mutasyon rastgele genler arasında yapıldığı için türetilen yeni bireylerin istenmeyen bireyler olma ihtimali de vardır.

5. Türetilen bireylerin arasından d adet duyarlı hücre seçilir ve P popülasyonundaki çeşitliliği arttırabilmek için popülasyona eklenir. Daha az duyarlı hücrelerden bir kısmı istenirse P popülasyonundan çıkarılabilir. Algoritmada düşük duyarlığa sahip bireylerin çıkarılma ihtimali daha fazladır.
6. Algoritma bitiş kriteri sağlanıncaya kadar, 2 ile 5 arası adımlar tekrarlanır. Algoritma bitişi, maksimum iterasyon sayısına ulaşıldığında veya yeni bireyler artık türetilmediğinde sonlanacak şekilde ayarlanabilir.

BÖLÜM 4. YAPAY BAĞIŞIKLIK SİSTEMİ İLE ATIKSU ARITMA TESİS KONTROLÜ UYGULAMASI

YBS klonal seçim tabanlı simülatör uygulaması geliştirilirken 4 adımlı bir çalışma sistemi uygulanmıştır. Birinci adımda geliştirilen sistem için veri sağlanmıştır. İkinci adımda veri incelenmiş ve analizler yapılmıştır. Üçüncü adımda YBS modelleri oluşturulmuştur. Dördüncü adımda modeller simüle edilmiş ve elde edilen sonuçlar yorumlanmıştır. Uygulama geliştirilirken uygulanan adımlar Şekil 4.1’de görülmektedir.



Şekil 4.1. Uygulama geliştirme adımları

4.1. Veri Prosesleri

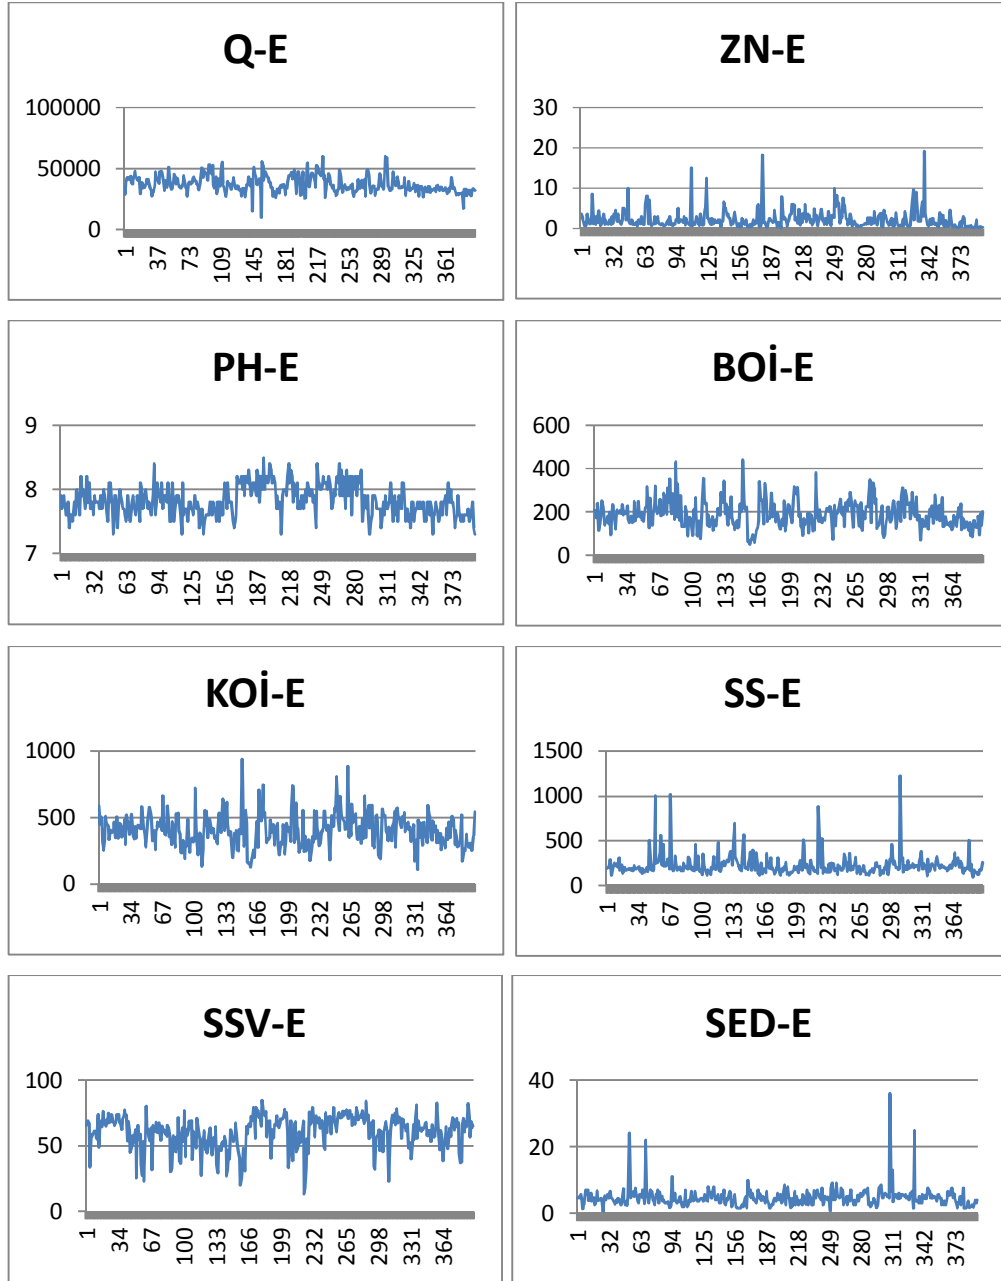
Sistemin çalışması için kullanılan veri kümesi, Kalifornia Irvine Üniversitesi'nin oluşturmuş olduğu, araştırmacıların kullanımına açık olan, makine öğrenmesi veritabanından (UCI) elde edilmiştir [131]. Veri kümesi 527 günlük atıksu arıtma tesisi ölçüm verisini içermektedir. Veri kümesinde 38 adet özellik yer almaktadır. Bu

özelliklerden 9 tanesi performans değerlendirme amacıyla hesaplanan değerler olduğundan veri kümesinden çıkarılmıştır. Geriye kalan 29 adet özellik kullanılmıştır. Bu özellikler hakkında bilgiler Tablo 4.1’de yer almaktadır.

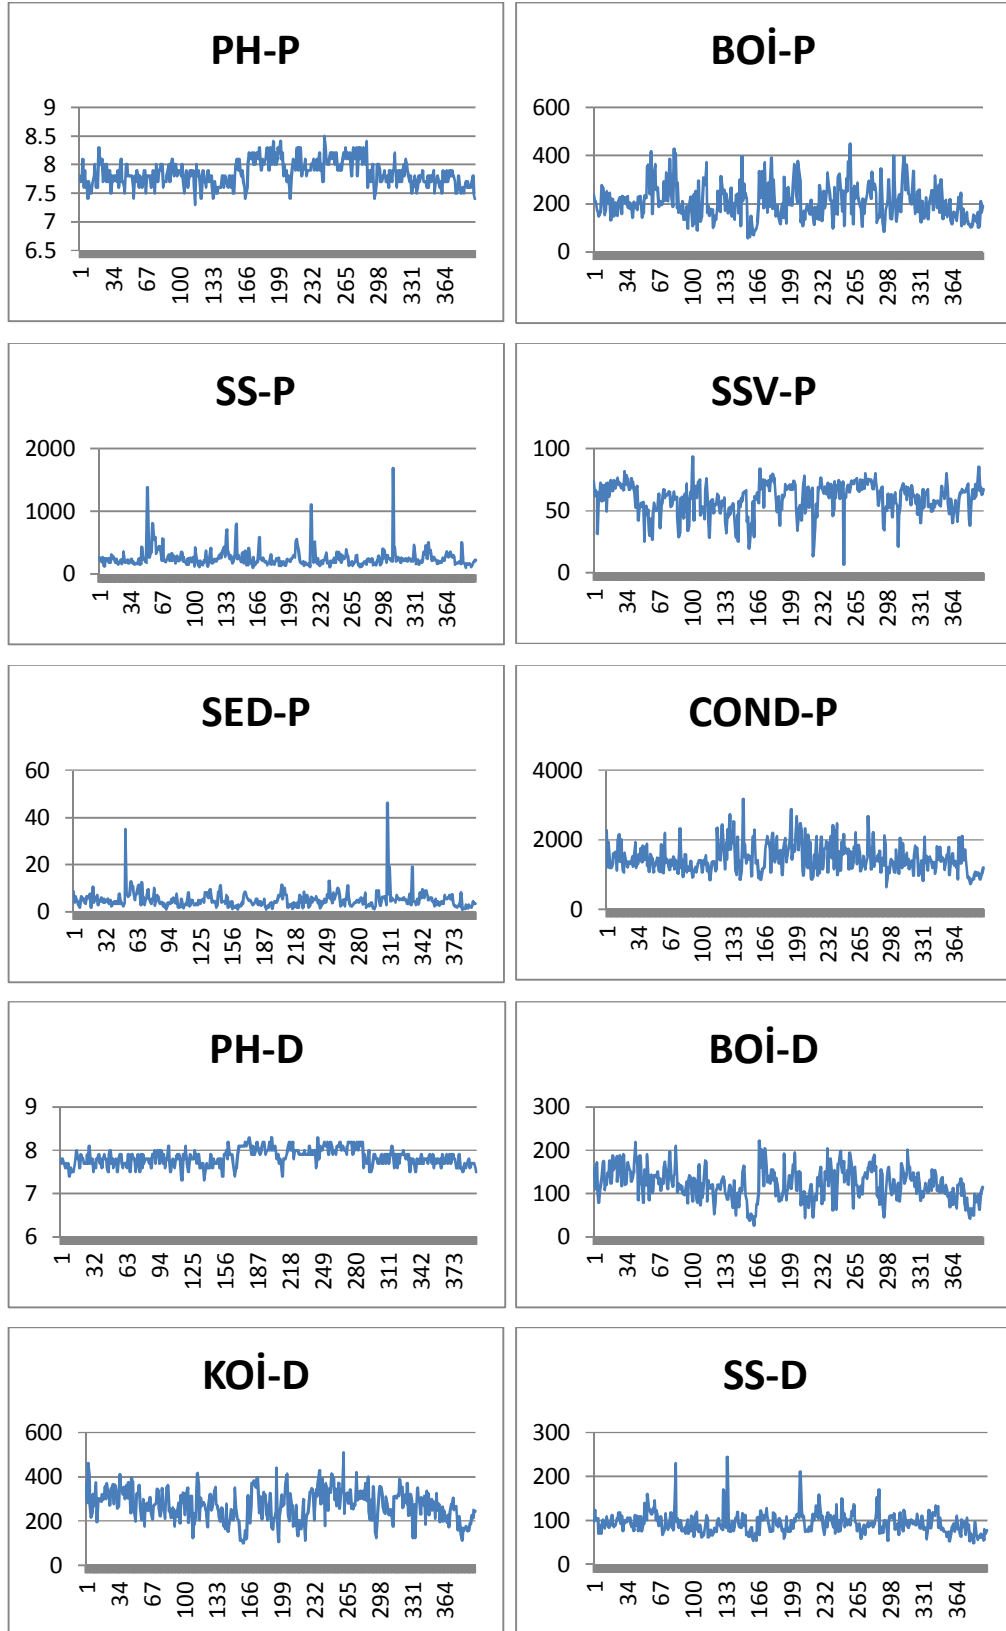
Tablo 4.1. UCI veri kümesi özellikleri [131]

No	Özellik	Açıklama	Min.	Maks.	Ortalama	S. Sapma
1	Q-E	AAT giriş debisi	10050	60081	37343,95	6803,90
2	ZN-E	AAT giriş çinko değeri	0,1	19,1	2,24	2,30
3	PH-E	AAT giriş pH değeri	7,3	8,5	7,82	0,24
4	BOİ-E	AAT girişi BOİ değeri	48	438	188,88	61,10
5	KOİ-E	AAT girişi KOİ değeri	105	941	403,64	119,34
6	SS-E	AAT girişi SS değeri	98	1228	225,67	116,34
7	SSV-E	AAT girişi SSV değeri	13,2	84,8	60,86	12,57
8	SED-E	AAT girişi tortu değeri	0,4	36	4,64	2,87
9	COND-E	AAT girişi iletkenlik değeri	651	3230	1462,50	393,01
10	PH-P	Ön çökeltme girişi pH değeri	7,3	8,5	7,85	0,22
11	BOİ-P	Ön çökeltme girişi BOİ değeri	59	449	207,85	71,60
12	SS-P	Ön çökeltme girişi SS değeri	104	1692	255,59	145,16
13	SSV-P	Ön çökeltme girişi SSV değeri	7,1	93,5	59,80	12,69
14	SED-P	Ön çökeltme girişi SED değeri	1	46	5,07	3,52
15	COND-P	Ön çökeltme girişi COND değeri	646	3170	1477,92	398,32
16	PH-D	Son çökeltme girişi pH değeri	7,3	8,3	7,83	0,19
17	BOİ-D	Son çökeltme girişi BOİ değeri	26	223	122,37	36,65
18	KOİ-D	Son çökeltme girişi KOİ değeri	100	511	273,03	71,33
19	SS-D	Son çökeltme girişi SS değeri	49	244	93,68	23,41
20	SSV-D	Son çökeltme girişi SSV değeri	23,8	100	72,82	10,33
21	SED-D	Son çökeltme girişi SED değeri	0	3,5	0,41	0,37
22	COND-D	Son çökeltme girişi COND değeri	85	3690	1470,96	400,14
23	PH-S	AAT çıkışı pH değeri	7,1	8,1	7,72	0,15
24	BOİ-S	AAT çıkışı BOİ değeri	5	320	19,70	18,17
25	KOİ-S	AAT çıkışı KOİ değeri	9	350	84,75	36,07
26	SS-S	AAT çıkışı SS değeri	6	238	21,63	16,32
27	SSV-S	AAT çıkışı SSV madde	29,2	100	79,84	9,20
28	SED-S	AAT çıkışı SED değeri	0	3,5	0,04	0,22
29	COND-S	AAT çıkışı COND değeri	683	3950	1475,22	383,80

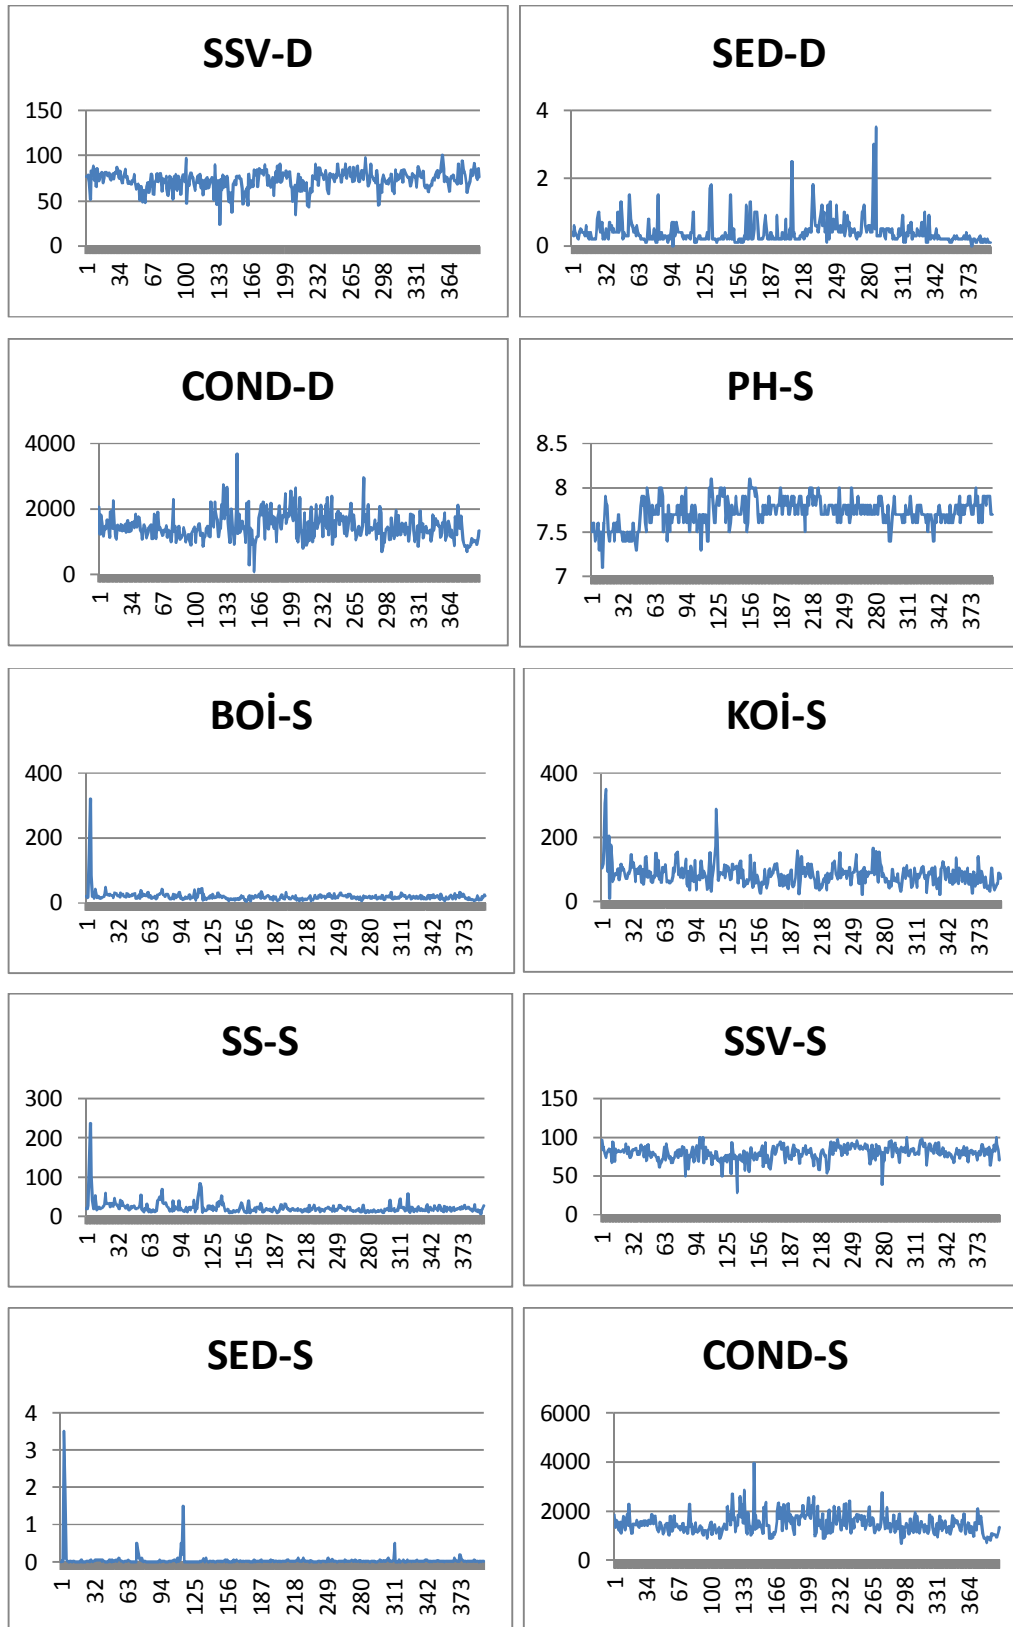
Veri kümesi içerisinde ölçülmediği için boş bırakılan değerler bulunmaktadır. Bu değerler veri kümesinden çıkarılmıştır. Bu işlem sonucunda, 527 adet veriden geriye 395 adet veri kalmıştır. Geriye kalan veri kümesi için özelliklerin değer dağılımı grafikleri Şekil 4.2’de verilmektedir.



Şekil 4.2. Veri kümesi özellik değer dağılım grafikleri



Şekil 4.2. (Devamı)



Şekil 4.2. (Devamı)

Değer dağılımları uzman eşliğinde incelenmiş ve çati noktaları yorumlanmıştır. İnceleme sonucunda ölçüm hatalarından kaynaklı olabileceği muhtemel değerler gözlemlenmiştir. Bu tür değerler sistemin hatalı eğitimine sebep olabileceğinden veri kümesinden çıkarılması faydalıdır [132]. Bu değerlendirme sonucunda uzman görüşüyle 6 adet veri veri kümesinden çıkarılmıştır. Geriye kalan 389 adet veri ile çalışmaya devam edilmiştir. Yeni veri kümesindeki özelliklerin bilgileri Tablo 4.2’de gösterilmektedir.

Tablo 4.2. Veri kümesi özelliklerinin değer analizleri

No	Özellik	Açıklama	Min.	Maks.	Ortalama	S. Sapma
1	Q-E	AAT giriş debisi	10050	60081	37303.59	6800.09
2	ZN-E	AAT giriş çinko değeri	0.1	19.1	2.25	2.32
3	PH-E	AAT giriş pH değeri	7.3	8.5	7.82	0.24
4	BOİ-E	AAT girişi BOİ değeri	48	438	188.85	61.34
5	KOİ-E	AAT girişi KOİ değeri	105	941	404.10	119.65
6	SS-E	AAT girişi SS değeri	98	1016	219.36	91.83
7	SSV-E	AAT girişi uçucu askıda katı madde	17.8	84.8	61.21	12.06
8	SED-E	AAT girişi tortu değeri	0.4	25	4.51	2.20
9	COND-E	AAT girişi iletkenlik değeri	651	3230	1462.87	394.44
10	PH-P	Ön çökeltme girişi pH değeri	7.3	8.5	7.85	0.22
11	BOİ-P	Ön çökeltme girişi BOİ değeri	59	449	207.77	71.53
12	SS-P	Ön çökeltme girişi SS değeri	104	804	247.28	103.92
13	SSV-P	Ön çökeltme girişi SSV değeri	7.1	93.5	60.13	12.17
14	SED-P	Ön çökeltme girişi tortu madde değeri	1	19	4.89	2.44
15	COND-P	Ön çökeltme girişi iletkenlik değeri	646	3170	1479.09	399.92
16	PH-D	Son çökeltme girişi pH değeri	7.3	8.3	7.83	0.19
17	BOİ-D	Son çökeltme girişi BOİ değeri	26	223	122.30	36.49
18	KOİ-D	Son çökeltme girişi KOİ değeri	100	511	272.84	70.82
19	SS-D	Son çökeltme girişi SS değeri	49	244	93.43	23.42
20	SSV-D	Son çökeltme girişi SSV değeri	23.8	100	72.97	10.24
21	SED-D	Son çökeltme girişi SED değeri	0	3.5	0.41	0.37
22	COND-D	Son çökeltme girişi iletkenliği	85	3690	1470.98	401.89
23	PH-S	AAT çıkışı pH değeri	7.1	8.1	7.72	0.15
24	BOİ-S	AAT çıkışı biyolojik oksijen ihtiyacı	5	84	18.56	7.38
25	KOİ-S	AAT çıkışı kimyasal oksijen ihtiyacı	9	287	83.35	31.05
26	SS-S	AAT çıkışı askıda katı madde değeri	6	104	20.69	10.53
27	SSV-S	AAT çıkışı uçucu askıda katı madde	29.2	100	79.85	9.26
28	SED-S	AAT çıkışı tortu değeri	0	0.5	0.02	0.05
29	COND-S	AAT çıkışı iletkenlik değeri	683	3950	1475.52	385.46

Değer aralıkları incelendiğinde özelliklerin birbirinden çok farklı aralıklarda olduğu görülmektedir. Örneğin giriş debisi (Q-E) değeri 10050 ile 60081 arasında değişirken, giriş pH (PH-E) değeri 7,3 ile 8,5 arasında değişmektedir. Birimler arasındaki bu farklılığı ortadan kaldırarak standart hale getirmek ve lokal optimum takılma ihtimalini azaltmak amacıyla normalizasyon işlemi yapay zeka algoritmalarında yaygın olarak uygulanmaktadır [133]. Normalizasyon işlemi ile özellik değerleri 0-1 arasında yayılmaktadır. Kullanılan normalizasyon formülü aşağıda (Denklem 4.1) gösterilmiştir.

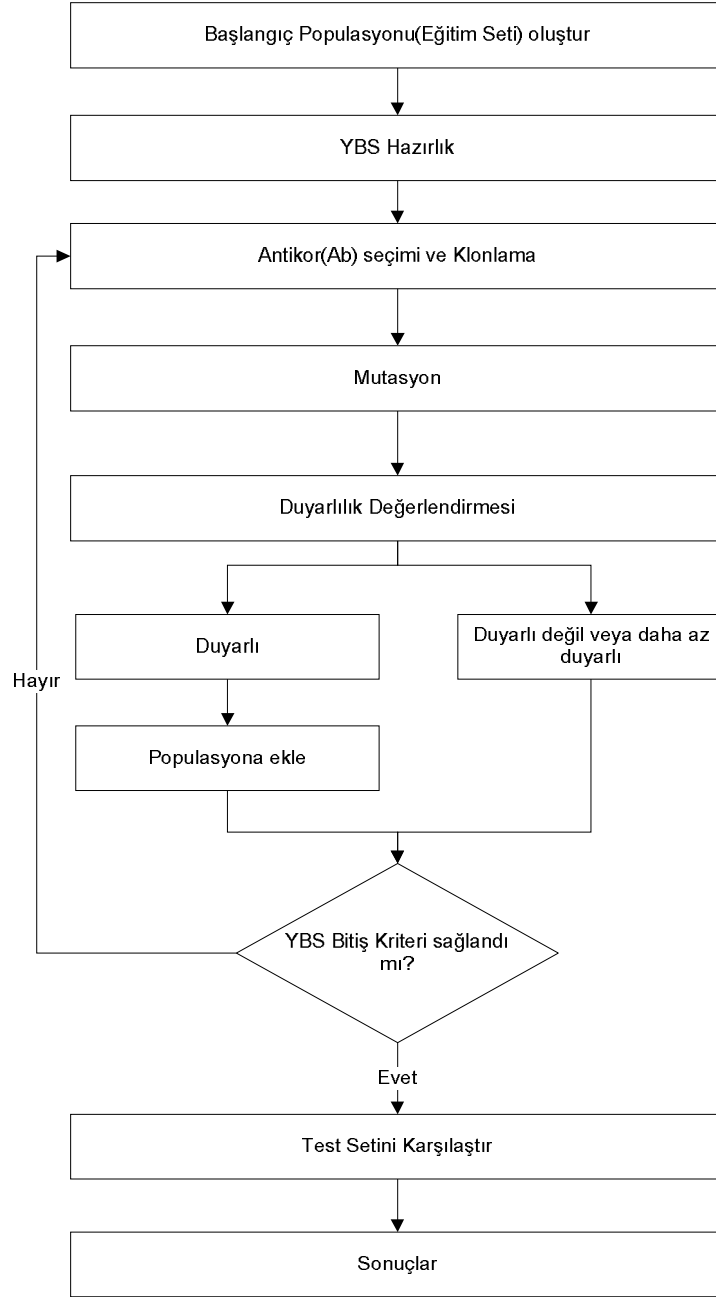
$$N(x_i) = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (4.1)$$

Burada x_i orjinal özellik değerini, $N(x_i)$ normalizasyon sonucu hesaplanan değeri, x_{\max} özelliğin en yüksek değerini, x_{\min} ise özelliğin en küçük değerini ifade etmektedir.

Normalizasyon işlemi ile birlikte veri üzerinde yapılması gereken hazırlık işlemleri tamamlanmıştır.

4.2. Klonal Seçim Prensibine Dayalı YBS Algoritması

Klonal seçim prensibinin tanımından yola çıkarak YBS algoritması adımları Şekil 4.3'de gösterildiği gibi tasarlanmıştır.



Şekil 4.3. Klonal seçim prensibine dayalı YBS algoritması adımları

YBS algoritmasını çalıştırabilmek için ön hazırlık aşamasında antijenin (A_g), antikorun (Ab), antikor populasyonunun (P) matematiksel olarak ifade edilmesi gereklidir. A_g ve Ab tek boyutlu özellik dizisi şeklinde gösterilebilir.

$$A_g = \{ a_1, a_2, a_3, \dots a_k \}$$

$$A_b = \{ a_1, a_2, a_3, \dots a_k \}$$

Burada a özellik değerini, k ise özellik sayısını göstermektedir.

Antikor popülasyonu (P) herbir elemanı antikor olan tek boyutlu bir dizi şeklinde ifade edilir.

$$P = \{ Ab_1, Ab_2, Ab_3, \dots Ab_n \}$$

Burada n antikor sayısını ifade etmektedir.

Hazırlık aşamasında YBS'nin çalışması için sistem parametre değerlerinin de belirlenmesi gereklidir. Parametrelerin belirlenmesi için literatürde bir öneri veya yöntem bulunmamaktadır. Genellikle problem özgü bir biçimde rastgele seçilmişlerdir. Bu nedenle çalışmada deneme yanılma yolu ile belirlenmiştir. Bu çalışmada YBS sistemin ihtiyaç duyduğu parametre değerleri, fonksiyonları ve eğitim bitiş kriterleri Tablo 4.3'te gösterildiği şekilde belirlenmiştir.

Tablo 4.3. YBS sistem parametreleri

Parametre	Değeri
Mutasyon yapılacak gen sayısı	2
Benzerlik ölçüsü	Öklid fonksiyonu
Eğitim bitiş kriterleri	Mutasyon sonucu P popülasyonunun aynı kalması veya maksimum iterasyon sayısına ulaşılması
Eşik değer	0,50

Yüksek benzerlik değerine sahip antikorların seçimi için benzerlik hesaplarının yapılması gereklidir. Benzerlik hesabı için kullanılacak formül doğrudan özellik verisi ile ilgilidir. Örneğin özellik değeri 2'li sistemde yeralan 0 veya 1 değerlerine sahip olabiliyorsa, Hamming veya Manhattan mesafe ölçüm formülleri benzerlik hesabı için kullanılabilir. Ancak özellik şuan ki atıksu verisi gibi 10'luk sistemde değere sahipse öklid mesafesi hesabı kullanılmaktadır. Bu çalışmada kullanılan öklid formülü aşağıdaki denklemde (Denklem 4.2) gösterilmektedir.

$$\text{Öklid } (Ag, Ab) = \sqrt{\sum_{i=1}^n (Ag_i - Ab_i)^2} \quad (4.2)$$

Burada n özellik sayısını, Ag_i antijenin i nolu özellik değerini, Ab_i ise antikorun i nolu özellik değerini ifade etmektedir.

Öklid mesafesi ne kadar fazla ise benzerlik okadar azdır. Bu nedenle benzerlik ölçümü için formül aşağıdaki denklem (Denklem 4.3) haline getirilir.

$$\text{Benzerlik}(Ab) = 1 - \text{Öklid } (Ag, Ab) \quad (4.3)$$

Benzerlik değerlerinin hesaplanmasının ardından, yüksek benzerlik değerlerine sahip antikorlar klonlanarak çoğaltılır. Bu sayede benzerliği yüksek antikorlarla dolu geçici bir popülasyon (C) oluşturulur. Ardından yüksek benzerlik değerlerine sahip iki antikor C popülasyonundan rastgele seçilir ve aralarında mutasyon işlemi gerçekleştirilir. Buradaki amaç antikorlar arasında gen (özellik) değişimi yaparak çeşitliliği arttırmaktır. Bunun için antikorlar arasından rastgele 2 tanesi seçilerek en azından 2 rastgele özelliği yer değiştirilir ve yeni bir antikor türetilir. Yapılan örnek mutasyon işlemi Şekil 4.4'te görülmektedir:

	Özellikler					
	Q-E	ZN-E	PH-E	SS-E	SSV-E	COND-E
Birinci Antikor	0,50	0,18	0,43	0,08	0,73	0,69
İkinci Antikor	0,54	0,07	0,50	0,07	0,72	0,57
Yeni Antikor	0,54	0,18	0,50	0,07	0,72	0,69

Şekil 4.4. Örnek mutasyon işlemi

Burada ikinci antikorun ZN-E ve COND-E özellikleri birinci antikordan alınarak ikinci antikorun aynı özellikleri ile yer değiştirilmiştir. Bu sayede birinci ve ikinci antikordan farklı yeni bir antikor türetilmiştir.

Mutasyon işleminde değiştirilecek özellik sayısı YBS algoritmasının başlangıcında belirlenmesi gereken bir parametredir. Literatürde bu sayının seçilmesi ile ilgili bir öneri veya yöntem bulunmadığından, denemeler sonucunda, çalışmada en iyi sonucu verdiği için 2 olarak seçilmiştir.

Mutasyon işlemi ile oluşan yeni antikor benzerlik değerlendirmesine tabi tutulur. Bunun amacı üretilen yeni antikorun antijene benzerliği daha yüksek ise mevcut antikor popülasyonuna (P) dahil edilir. Eğer aksi durum söz konusu ve benzerliği daha az bir antikor türetilmiş ise yeni antikor hatalı bir üretimdir. Bu durumda popülasyona dahil edilmez ve yok edilir.

YBS algoritmasının eğitimi, popülasyona dahil edilen yeni bir antikor olmayıncaya veya belirlenen maksimum iterasyon sayısına ulaşınca kadar devam etmektedir. Hangi bitiş kriterine ilk önce ulaşırsa, diğer kriterin sağlanması beklenmeden eğitim işlemi sonlandırılır.

Eğitilmiş YBS sistemi daha önce görmediği yeni test verilerini tanımlamak için hazırdır. Bu adımda test verileri (antijenler) ile YBS eğitimi sonucu oluşan antikor popülasyonu (P) elemanları olan antikorlar karşılaştırılmalıdır. Tanıma işleminde istenirse benzerlik ölçüsü formülü kullanılabileceği gibi k en yakın komşu algoritması (K-NN) gibi yardımcı bir algoritmadan da faydalanılabilir. Bu çalışmada test işlemi için benzerlik formülü tercih edilmiştir. Benzerlik formülüne ek olarak bir eşik değer kontrolü eklenmiştir. Eşik değer kabul edilen minimum benzerlik değerini ifade etmektedir. Bu kontrol ile eğer benzerlik, eşik değerden daha az ise bu antikorun sistem tarafından benzer olarak kabul edilmesinin önüne geçebilmek istenmektedir. Eşik değer kontrolü için öklid formülü kullanılmıştır.

4.3. AAT Modellerinin Oluşturulması

AAT bölüm modelleri oluşturulurken temel husus, veri kümesinde hangi AAT bölümlerinde ölçümlerin yapıldığıdır. Ölçüm yapılan noktalar AAT girişi, fiziksel

arıtma çıkışı, havalandırma çıkışı ve tesis çıkışıdır. Bu durumda oluşturulabilir 4 farklı modelden bahsedilebilir. Bu modeller aşağıdaki gibidir.

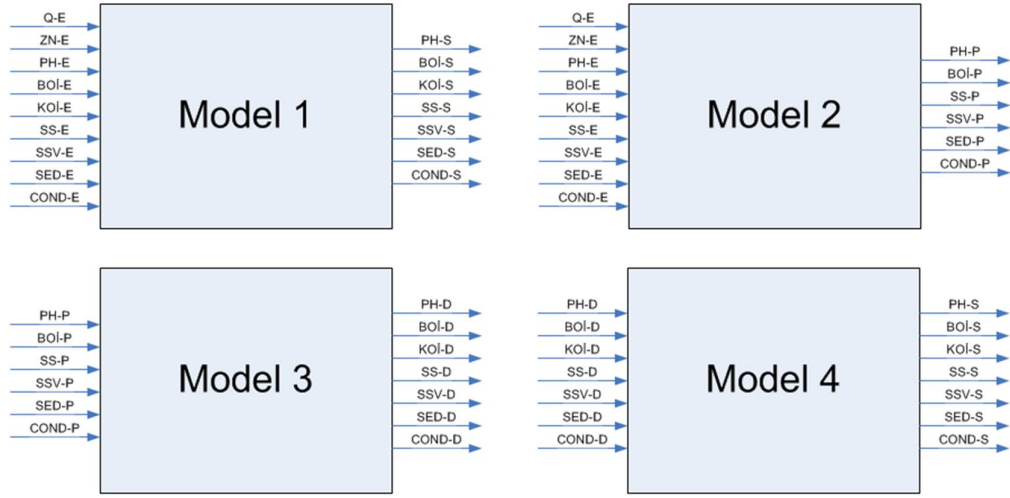
Model 1: AAT girişi ve AAT çıkışı arasında kurulan genel modeldir. Atıksu arıtma tesisine gelen ham atıksuyun, tesisin tüm bölümlerinden geçerek, tüm prosesleri uygulanmasının ardından AAT çıkışında sahip olacağı atıksu karakteristiğini tahmin etmek amacıyla oluşturulmuştur.

Model 2: AAT girişi ve tesis fiziksel arıtma bölümünün çıkışı arasında kurulan modeldir. Atıksu arıtma tesisine gelen atıksuyun fiziksel arıtma sonucunda sahip olacağı atıksu karakteristiğini tahmin etmeye yönelik kurulmuştur.

Model 3: Biyolojik arıtma bölümünün girişi olan ön çöktürme havuzu ile yine aynı bölümün çıkışı olan havalandırma havuzu çıkışı arasında kurulan modeldir. Bölümler birbirine sıralı olarak bağlandığı için ön çöktürme havuzu girişi aynı zamanda fiziksel arıtma bölümünün çıkışıdır. Bu nedenle model 2'nin çıkışı model 3 için giriştir.

Model 4: AAT ileri arıtma bölümü girişi ile ileri arıtma çıkışı arasında kurulan modeldir. İleri arıtma bölümü girişi aynı zamanda biyolojik arıtma bölümünün çıkışıdır. Benzer şekilde ileri arıtma çıkışı aynı zamanda AAT çıkışını ifade etmektedir.

Modellerin temsil ettiği bölümlerin belirlenmesinin ardından modellerin giriş ve çıkış parametreleri ile genel görünümü Şekil 4.5'teki gibi oluşmaktadır.



Şekil 4.5. AAT modelleri

Her model için giriş ve çıkış parametreleri arasındaki ilişkiyi incelemek son derece faydalıdır. Bu amaçla kullanılan yöntemler, temel bileşen analizi (PCA) olarak isimlendirilmektedir. PCA analizinin amacı giriş ve çıkış parametreleri arasındaki ilişki düzeyinin ortaya çıkarılması ve bu sayede sistemde kullanılan giriş parametre sayısını azaltmaktır. Bu özelliği ile PCA analizi parametre azaltma prosedürü olarak da bilinmektedir [134, 10]. Aynı zamanda daha az giriş parametresi ile çalışacağından algoritmanın performansı da artacaktır [22].

Literatürde kullanılan birçok PCA analizi yöntemi bulunmaktadır. Bu çalışmada bir PCA analizi methodu olan lineer korelasyon kullanılmıştır. Kullanılan korelasyon denklemi aşağıdaki (Denklem 4.4) gibidir.

$$Korr(X, Y) = \frac{E[(X - \mu_x) \times (Y - \mu_y)]}{\sigma_x \sigma_y} \quad (4.4)$$

Burada E korelasyon operatörü, X ve Y iki rastgele değişkeni, μ_x ve μ_y rastgele değişkenler arasındaki beklenen değer operatörü, σ_x ve σ_y ise standart sapma değerini ifade etmektedir. Korelasyon (Korr), X ve Y değişkenleri arasındaki ilişkiyi gösteren sayısal bir değerdir. Bu değer -1 ile 1 arasında bir değer olabilmektedir [135]. Korelasyon değeri 0 olduğunda değişkenlerin arasında bir ilişkinin var

olmadığını, 0 dan uzaklaştıkça daha yüksek bir ilişkinin varlığını göstermektedir. $Korr < 0$ ilişkin negatif (ters yönde) olduğu, $Korr > 1$ olduğunda pozitif (aynı yönde) olduğunu göstermektedir.

Korelasyon hesaplamaları her model için ayrı ayrı yapılmış ve Tablo 4.4, 4.5, 4.6 ve 4.7'de yer alan sonuçlar elde edilmiştir.

Tablo 4.4. YBS Model 1 giriş ve çıkış parametreleri arası korelasyon sonuçları

	PH-S	BOİ-S	KOİ-S	SS-S	SSV-S	SED-S	COND-S
Q-E	0,07	-0,08	-0,08	-0,06	-0,10	-0,08	-0,08
ZN-E	-0,15	0,00	0,05	-0,04	0,11	-0,05	0,08
PH-E	0,35	0,06	0,02	-0,09	0,14	-0,07	0,30
BOİ-E	0,02	0,28	0,29	0,17	-0,02	0,12	0,27
KOİ-E	0,00	0,23	0,34	0,11	0,06	0,07	0,31
SS-E	0,11	0,02	0,00	0,03	-0,21	0,05	0,12
SSV-E	-0,10	0,16	0,18	0,04	0,37	0,03	0,18
SED-E	0,04	0,11	0,09	0,02	0,00	0,07	0,18
COND-E	0,13	0,10	0,20	0,01	-0,01	-0,06	0,91

Tablo 4.5. YBS Model 2 giriş ve çıkış parametreleri arası korelasyon sonuçları

	PH-P	BOİ-P	SS-P	SSV-P	SED-P	COND-P
Q-E	0,17	-0,22	-0,09	-0,28	-0,21	-0,07
ZN-E	0,05	0,05	0,12	-0,12	0,14	0,07
PH-E	0,90	0,20	-0,08	0,26	0,08	0,32
BOİ-E	0,17	0,70	0,20	0,22	0,34	0,28
KOİ-E	0,19	0,56	0,32	0,21	0,51	0,35
SS-E	-0,13	0,14	0,79	-0,51	0,51	0,09
SSV-E	0,28	0,30	-0,47	0,86	-0,03	0,19
SED-E	0,09	0,33	0,41	-0,05	0,74	0,21
COND-E	0,28	0,28	0,13	0,16	0,23	0,97

Tablo 4.6. YBS Model 3 giriş ve çıkış parametreleri arası korelasyon sonuçları

	PH-D	BOİ-D	KOİ-D	SS-D	SSV-D	SED-D	COND-D
PH-P	0,89	0,29	0,31	0,09	0,17	0,22	0,29
BOİ-P	0,21	0,65	0,54	0,42	0,11	0,22	0,32
SS-P	-0,08	0,08	0,04	0,47	-0,45	0,10	0,15
SSV-P	0,21	0,41	0,44	-0,07	0,71	0,12	0,18
SED-P	0,09	0,34	0,34	0,40	-0,06	0,18	0,25
COND-P	0,30	0,37	0,44	0,18	0,10	0,15	0,94

Tablo 4.7. YBS Model 4 giriş ve çıkış parametreleri arası korelasyon sonuçları

	PH-S	BOİ-S	KOİ-S	SS-S	SSV-S	SED-S	COND-S
PH-D	0,53	0,00	0,00	-0,17	0,13	-0,08	0,28
BOİ-D	-0,16	0,40	0,36	0,21	0,16	0,08	0,37
KOİ-D	-0,17	0,36	0,50	0,19	0,19	0,05	0,40
SS-D	-0,02	0,18	0,16	0,13	-0,06	0,06	0,18
SSV-D	-0,11	0,15	0,13	0,05	0,46	0,02	0,11
SED-D	-0,02	0,15	0,07	0,00	0,13	0,07	0,16
COND-D	0,10	0,13	0,25	0,03	0,01	-0,04	0,95

Korelasyon sonuçlarının gösterdiği lineer ilişki seviyesine göre parametre azaltmak için bir eşik değer belirlenmelidir. Eşik değer belirlenmesi için literatürde bir yöntem bulunmamaktadır. Mutlak korelasyon 0-1 arasında olduğuna göre %5'lik minimum korelasyon eşiği belirlenmesi uygun görülmektedir. Buna göre eşik değer 0,05 olarak belirlendiğinde $-0,05 < \text{Korr} < 0,05$ arasındaki ilişkiler ihmal edilebilir. Tablolarda kırmızı işaretlenmiş alanlar eşik değer altında kalan bu ilişkileri göstermektedir.

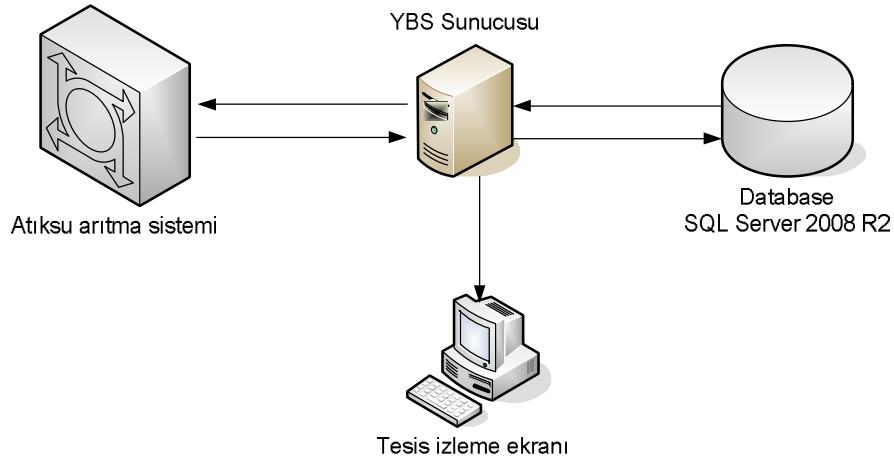
Herbir AAT modeli içerisinde her çıkış parametresi için, bir önceki alt bölümde yer alan YBS Klonal seçim algoritması ayrı ayrı kullanılmıştır. Buna göre örneğin 1 nolu AAT modeli için PH-S çıkış değeri hesaplanırken modelin giriş parametrelerini kullanan bir YBS algoritması olacaktır.

Sistem üzerinde PCA analizinin etkilerini de görebilmek amacıyla hem PCAsız (YBS) hemde PCAlı (PYBS) modeller oluşturulmuş ve performans değerlendirmeleri simülasyon sonuçları alt bölümünde yapılmıştır.

4.4. Veritabanı Mimarisi

YBS sisteminin geçmiş durumların örneklenerek kendini eğitebilmesi ve daha doğru karar verebilmesi için önemlidir. Bu nedenle geçmişe dönük tesis verilerinin bir veritabanında tutulması gereklidir. AAT bölümlerinde ölçülen parametrelerin sayısı ve bu değerlerin çoğunlukla günlük olarak tutulacağı düşünüldüğünde oldukça fazla sayıda verinin bu veritabanında yer alacağını söyleyebiliriz. Bu çok sayıda verinin hızlı ve efektif bir şekilde okunup sorgulanabilmesi için güçlü bir veritabanı yönetim

sistemine ihtiyaç vardır. Bu ihtiyaçları karşılayabilmesi amacıyla veritabanı yönetim sistemi olarak, güvenli ve stabil olan, etkin veri saklama imkanı sağlayan ve query optimizasyonu seçenekleri ile hızlı bir şekilde sorgulamalar yapabileceğimiz bir yapı sağladığından Microsoft SQL Server 2008 R2 versiyonu seçilmiştir. YBS sisteminde işlem gücüne, yoğun veri akışına ve sayıca fazla verinin saklanmasına ihtiyaç duyulmaktadır. Sistemin bir atıksu arıtma tesisine doğrudan uygulanması durumunda kurulması önerilen sistem mimarisi Şekil 4.6’de gösterilmektedir.



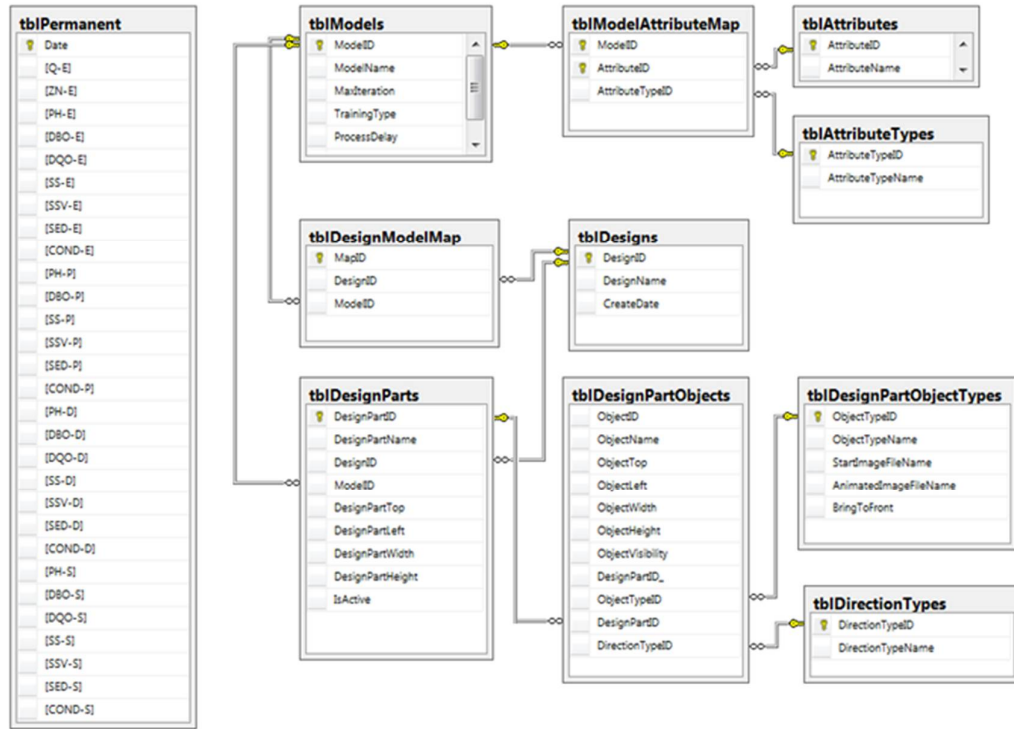
Şekil 4.6. Sistem mimarisi

Veritabanında oluşturulan tablolar aşağıdaki gibidir :

1. Özellikler tablosu (tblAttributes): Uygulama içerisinde kullanacağımız parametrelerin isim ve kodlarının tutulduğu tablodur.
2. Özellikler tipleri tablosu (tblAttributeTypes): Parametre türlerinin belirtildiği tablodur. Uygulama için genel olarak 2 tip parametre bulunmaktadır, bunlar; giriş ve çıkış parametre türleridir.
3. Kalıcı değerler tablosu (tblPermanent): Tüm tesise ait verilerin saklandığı ve YBS algoritmasının çalışırken kullanacağı temel tablodur. YBS karar mekanizmasını bu tablodaki veriler üzerinden işletecektir. Bu amaçla aşağıdaki tablo yapısı oluşturulmuştur. Ayrıca UCI veritabanında bulunan atıksu arıtma tesisine ait veriler, uygulama geliştirme sürecinde kullanılmak üzere bu tabloya aktarılmıştır.

4. Parametre istatistikleri tablosu (tblAttributeStatistics): Parametrelere ait istatistiksel bilgiler bu tabloda günlük olarak tutulacaktır. Bu istatistiksel bilgiler ilgili parametrenin o güne kadar genel veri setinde elde ettiği minimum, maximum ve standart sapma değerleridir.
5. Model tablosu (tblModels): YBS’de oluşturulacak olan modellerin kaydının tutulduğu tablodur.
6. Model özellik ilişkilendirme tablosu (tblModelAttributeMap): Herbir model için kullanılacak giriş ve tahmin edilmek istenen çıkış parametrelerinin ilişkilendirildiği tablodur.
7. Design tablosu (tblDesign): Atıksu tesis tasarımlarının herbiri uygulama açısından bir designdir. Bu sayede birçok farklı tasarım oluşturabilir ve veritabanında saklayabiliriz.
8. Design bölümleri tablosu (tblDesignParts): Gerçekleştirilen herbir design, farklı bölümlerin birleşmesinden oluşmaktadır. Bu yapı atıksu arıtma tesislerinin, tesis bölümlerinden oluşmasına benzemektedir. Herbir bölüm ayrı ayrı tasarlanmaktadır. Ayrıca bölümde kullanılacak olan YBS modeli de ayrı ayrı belirlenebilmektedir.
9. Design bölüm nesneleri tablosu (tblDesignPartObjects): Atıksu arıtma tesislerinde her bir bölümde kullanılan alt birimler, örneğin fiziksel arıtmada bulunan filtreler, kum tutucu ve yağ tutucu birimleri gibi birim bazında tanımlamalar bu tabloda yapılmaktadır.
10. Design bölüm nesne türleri tablosu (tblDesignPartObjectTypes): Tasarımda kullanılan atıksu arıtma tesisine ait bölüm nesneleri bu tabloda tutulmaktadır.
11. Akış yönü tablosu (tblDirectionTypes): Bağlantı birimleri (borular) için su akış yönünü ifade eden tablodur.

Veritabanına ait diyagram görünümü Şekil 4.7’de gösterilmektedir.

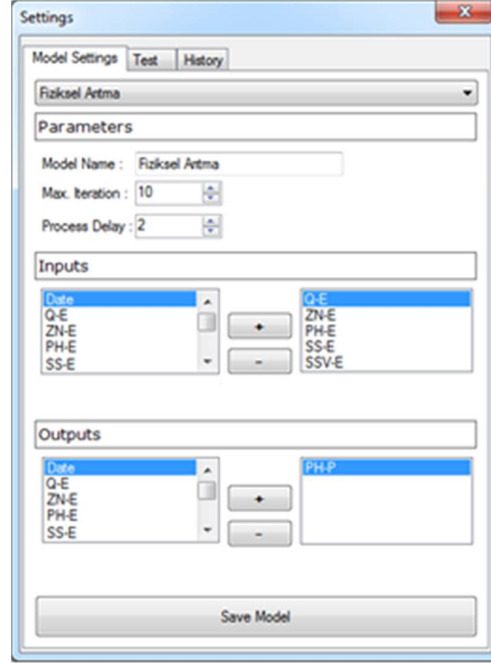


Şekil 4.7. Veritabanı mimarisi

4.5. Kullanıcı Arayüzleri

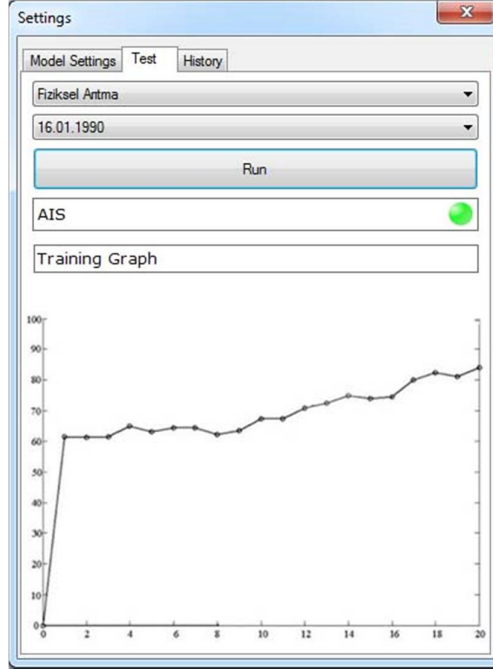
Simülasyon yazılım geliştirme sırasında simülasyon sistemleri araştırmasından elde edilen bilgiler kullanılmıştır. Bu bilgilere ek olarak üzerinde önemle durulan husus dinamik bir arayüz geliştirmektir. Çünkü hedeflenen birçok farklı atıksu arıtma tesisinin tasarlanabileceği genel bir yapı oluşturmaktır. Bu sayede farklı tesisler de kolaylıkla uygulama arayüzünden tanımlanabilecektir. Geliştirilen uygulamanın bölümleri şu şekildedir:

1. Model tanımlama ekranı: YBS modelleri için gerekli tanımlamalar dinamik olarak kullanıcı arayüzünden yapılabilmektedir. YBS çalışma parametresi olan iterasyon sayısı yani öğrenme sırasında gerçekleştirilecek olan maximum iterasyon miktarı bu ekrandan tanımlanmaktadır. Modelde kullanılacak giriş ve çıkış parametre seçimleri de yine bu ekrandan seçilebilmektedir. Model tanımlama ekranı Şekil 4.8’de gösterilmiştir.



Şekil 4.8. Model tanımlama ekranı

2. Model test ekranı: Modeller tanımlandıktan sonra istenirse veritabanında kayıt altına alınmış bir veri üzerinden çalıştırılarak test edilebilir. Bu model başarımını görme şansımız olmaktadır. İstenirse model tanımlama ekranından değerler değiştirilebilir ve model üzerindeki etkileri gözlemlenebilir. Model test ekranı Şekil 4.9’da gösterilmektedir.



Şekil 4.9. Model test ekranı


3. Model arşiv ekranı: Modellerin elde ettiği simülasyon sonuçları geçmişe dönük olarak bu ekrandan izlenebilmektedir. Bu ekran Şekil 4.10'de gösterilmektedir.

The screenshot shows the 'Settings' window with the 'History' tab selected. The 'Fiziksel Artma' dropdown is set to 'PH-P'. The 'History' table displays a list of simulation results with columns for Date, Real Value, Predicted Value, and Success Rate.

Date	Real Value	Predicted Value	Success Rate
01.06.1990	7.80	7.80	100.00
03.05.1990	7.70	7.80	91.00
06.02.1990	8.10	7.90	83.00
07.01.1990	7.80	7.30	58.00
10.05.1990	7.90	7.69	83.00
11.01.1990	7.70	7.50	84.00
11.03.1990	8.10	7.90	83.00
13.03.1990	7.60	7.69	92.00
15.01.1990	7.80	7.80	100.00
15.03.1990	7.60	7.80	83.00
16.01.1990	7.80	7.80	100.00
17.01.1990	7.70	7.80	91.00
18.01.1990	7.90	7.80	92.00
18.03.1990	7.70	8.10	66.00
22.03.1990	7.50	7.60	92.00
23.04.1990	7.90	7.90	100.00

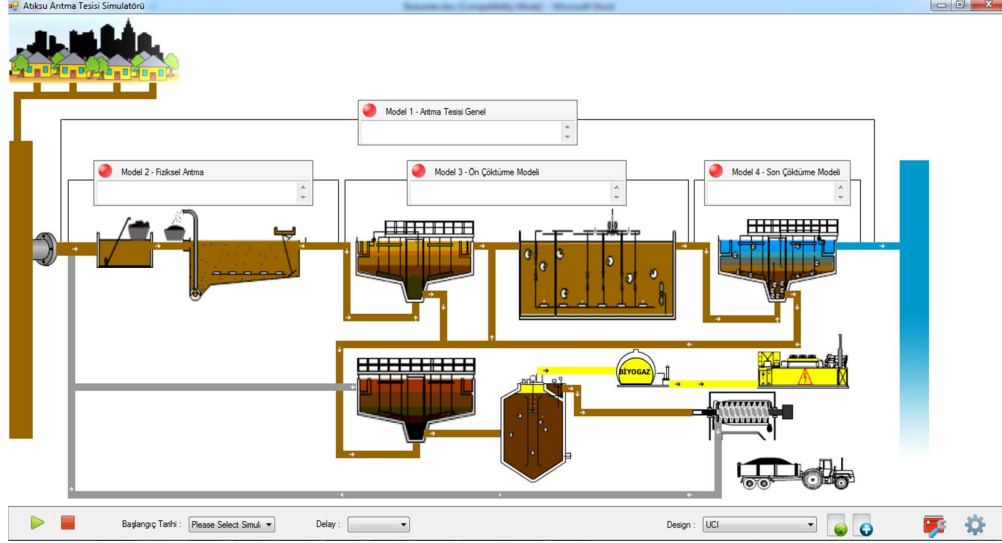
Şekil 4.10. Model sonuç geçmişi ekranı

4. Tasarım ve simülasyon arayüzü: Atıksu arıtma tesisi tasarımının yapıldığı ekrandır. Burada tesis simülatörümüzde olmasını istediğimiz tesis bölümleri ve o bölümlere ait mekanizmaları (nesneleri) koordinatları girerek ekrandaki konumlara yerleştirmektediriz. Bu amaçla tasarım ayarları adlı araç kullanılmaktadır. Tesis tasarımını tamamladığımızda her bir bölümde kullanmak istediğimiz YBS modelini, yine aynı araç kullanılarak seçilmektedir. Bu işlemin ardından sistem simülasyona hazır hale gelmiş olmaktadır. Tasarım ayarları araç kutusu Şekil 4.11’de gösterilmektedir.



Şekil 4.11. Tasarım ayarları araç kutusu

Tasarım arayüzü kullanılmak suretiyle, UCI verilerine uygun olarak tasarlanmış atıksu arıtma tesisi Şekil 4.12’de gösterilmektedir.



Şekil 4.12. Simülasyon arayüzünde tanımlanmış atıksu arıtma tesisi

Simülasyon tasarım ekranının altında bulunan simülasyon başlama verisi (başlangıç tarihi) ve zaman ilerleme değeri (delay) seçilerek başlat tuşuna basılarak simülasyon başlatılmaktadır.

4.6. Simülasyon Sonuçları

Simülasyon yazılımında oluşturulan modeller ile PCA'sız (YBS) ve PCA'lı (PYBS) olmak üzere 2 tür çalışma yapılmıştır. YBS herhangi bir eleme yapmadan modele ait tüm parametrelerinin kullanıldığı, PYBS modelleri ise PCA analizine göre ihmal edilebilir parametrelerin sisteme dahil edilmediği çalışmadır.

Model veri tahminlerinin başarı değerlendirilmesi için aşağıdaki formül (Denklem 4.5) kullanılmıştır.

$$X = \left(1 - \frac{|X_p - X_r|}{X_{max} - X_{min}}\right) * 100 \quad (4.5)$$

Burada X_p parametrenin tahmin değerini, X_r gerçek değeri, X_{max} parametrenin en yüksek değerini, X_{min} ise en düşük değerini ifade etmektedir.


Modellerin genel başarı değerlendirilmesi için ise, başarı değerlerinin ortalaması (Denklem 4.6) ve determinasyon katsayısı (R^2) (Denklem 4.7) denklemleri kullanılmıştır:

$$\text{Başarı}(\%) = \text{Ortalama}(X) \quad (4.6)$$


$$R^2 = \left\{ \frac{1}{n} \times \sum_{i=1}^n [(x_i - \bar{x}) \times (y_i - \bar{y})] / (\sigma_x \times \sigma_y) \right\}^2 \quad (4.7)$$

Burada n tahmin sayısını, x_i gerçek değeri, \bar{x} ortalama değeri, y_i tahmin değerini, \bar{y} tahmin değerleri ortalamasını, σ_x gerçek değerlerin standart sapmasını, σ_y tahmin değerlerinin standart sapma değerini ifade etmektedir.

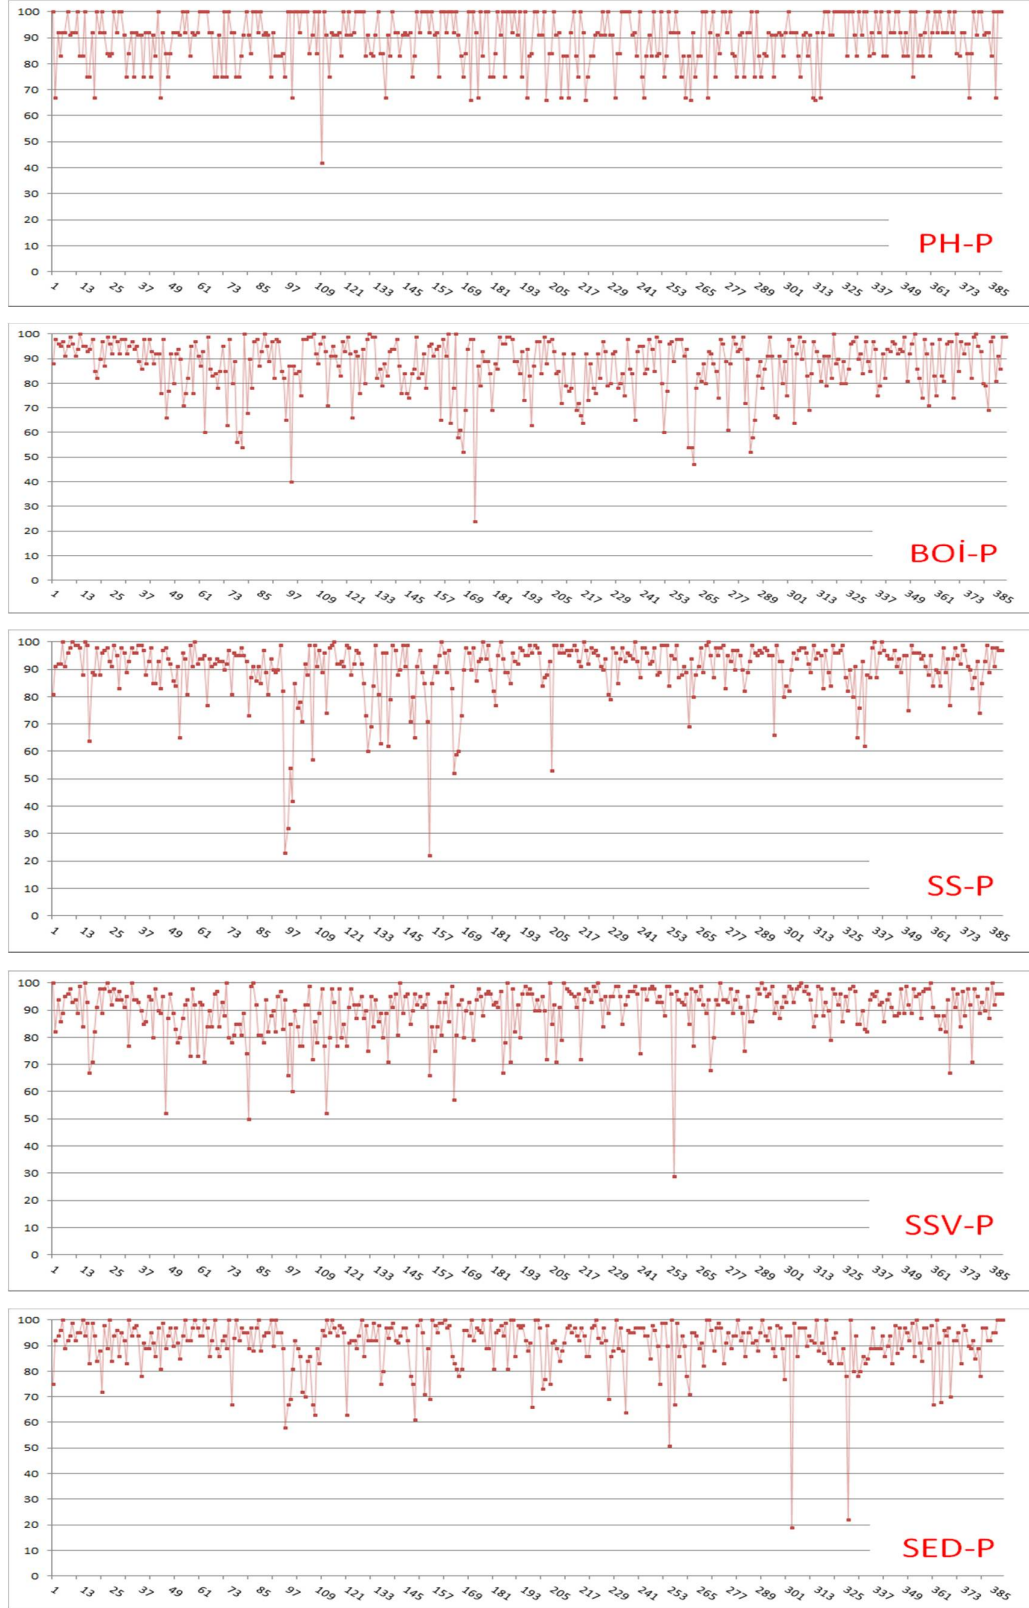
Simülâtörde ilk olarak YBS modelleri simüle edilmiştir. Şekil 4.13, 4.14, 4.15, 4.16'da YBS modellerinin herbir örneği için elde edilen başarı değerleri grafiklerle gösterilmiştir.



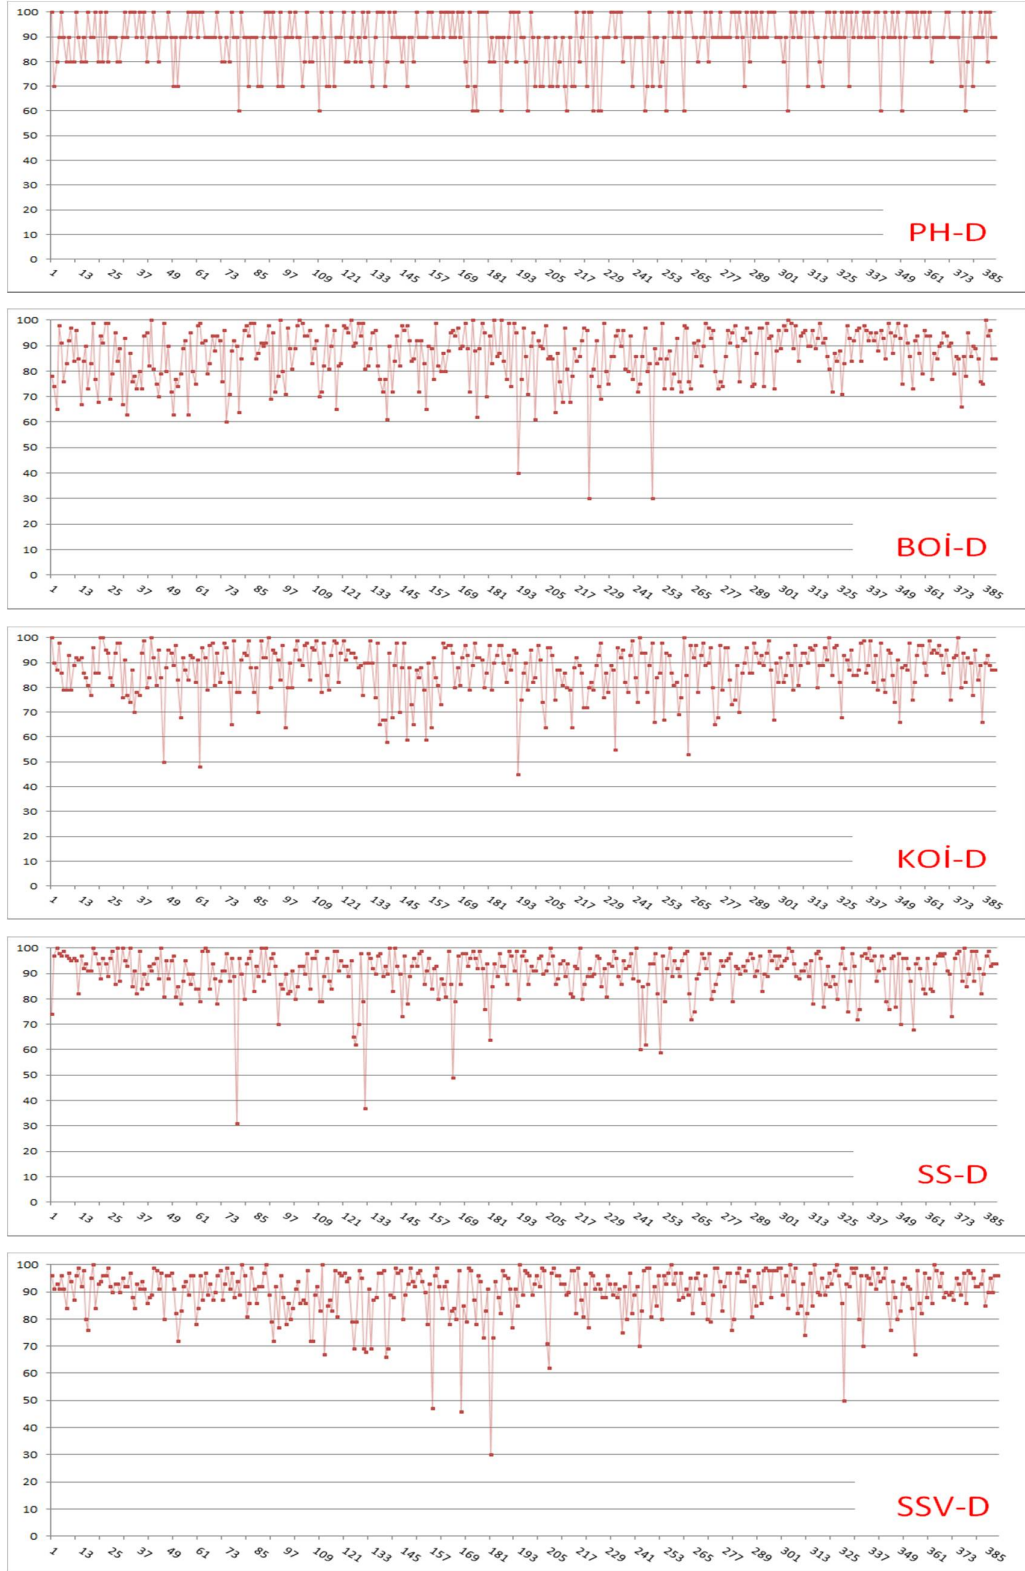
Şekil 4.13. YBS model1 için veri başarı değerleri




Şekil 4.13. (Devamı)




Şekil 4.14. YBS model2 için veri başarı değerleri




Şekil 4.15. YBS model3 için veri başarı değerleri



Şekil 4.15. (Devamı)



Şekil 4.16. YBS model4 için veri başarı değerleri



Şekil 4.16. (Devamı)

YBS modellerin başarı grafikleri incelendiğinde, genel başarının kabul edilebilir aralıkta olduğu görülmektedir. Ancak grafiklerdeki düşük değerler incelenecek olur ise;

1. Model PH-S için %30 ve %20 başarı gösterdiği 8,1 gerçek değeri için tahmin edilen değer sırasıyla 7,4 ve 7,3 'tür. Tüm veri kümesi içerisinde bu değer için örnek sayısı 2'dir yani oldukça azdır. Az örnek sayısına rağmen, sistemin %20 ve %30 başarı oranlarını elde etmesi öğrenmeyi gerçekleştirdiğini ve bu durumlar hakkında kısmen yorum yapabildiğini göstermektedir.
2. Model BOİ-S için %16 lık başarının elde edildiği tarihten 1 gün sonra veri kümesindeki açıklamalara göre ikinci çöktürme tankında sorun gerçekleşmiştir. 3 gün süren bu sorunun 1 gün önceki veri ölçümlerini de etkilemiş olabileceği düşünülmektedir.
3. Model KOİ-S için %32 lik başarının gösterdiği 287 değeri için veri kümesinde sadece 1 örnek yer almaktadır. Örnek sayısının yeterli olmamasına rağmen sistem, 97,96 değerini tahmin ederek kısmen öğrenme gerçekleştirmiştir.
4. Genel olarak diğer model parametreleri için de düşük değerlerin oluşma sebebi çoğunlukla veri kümesinde ilgili veri için yeterli örneğin yer almaması veya veri kümesinde belirtilen tesis problemlerinin bu tarihlere yakın zamanlara denk gelmesi nedeniyle ölçümlerin doğru yapılmaması olarak düşünülmektedir. Sistem bu durumlar için belirli tahmin değerleri üretmiş ve belirli oranlarda öğrenme gerçekleşmiştir.

Modellerin genel başarısı elde edilen veri başarılarının ortalaması ve determinasyon katsayısı şeklinde ifade edilmiştir. Bu formüllere göre genel model başarı oranları herbir parametre için Tablo 4.8, 4.9, 4.10 ve 4.11'de gösterilmektedir.

Tablo 4.8. YBS model için başarı değerleri

	PH-S	BOİ-S	KOİ-S	SS-S	SSV-S	SED-S	COND-S	Genel Başarı
O. Başarı(%)	84,83	90,26	89,24	89,91	87,86	94,77	91,75	89,80
R2	84,77	94,64	91,21	93,39	91,50	93,97	86,14	90,80

Tablo 4.9. YBS model2 için başarı değerleri

	PH-P	BOİ-P	SS-P	SSV-P	SED-P	COND-P	Genel Başarı
O. Başarı(%)	89,39	87,15	90,31	90,02	90,66	89,52	89,51
R2	85,45	86,38	88,52	84,54	86,52	84,30	85,95

Tablo 4.10. YBS model3 için başarı değerleri

	PH-D	BOİ-D	KOİ-D	SS-D	SSV-D	SED-D	COND-D	Genel Başarı
O. Başarı(%)	88,74	86,35	86,98	90,31	89,93	92,34	92,71	89,62
R2	86,72	88,24	82,39	92,30	85,87	95,59	89,90	88,72

Tablo 4.11. YBS model4 için başarı değerleri

	PH-S	BOİ-S	KOİ-S	SS-S	SSV-S	SED-S	COND-S	Genel Başarı
O. Başarı(%)	87,46	90,95	88,59	90,72	88,50	94,46	93,20	90,55
R2	84,40	93,57	87,15	91,35	86,32	90,92	89,72	89,06

YBS modellerinin genel başarı ortalamaları incelendiğinde, en düşük başarı model 1 PH-S parametresi için, en yüksek başarı model 4 SED-S parametresi için elde edilmiştir. Determinasyon katsayısına göre en düşük başarı model 3 KOİ-D parametresi için, en yüksek başarı 95,59 ile model 3 SED-D parametresi için elde edilmiştir.

PYBS model sonuçları Tablo 4.12, 4.13, 4.14, 4.15'deki şekilde elde edilmiştir.

Tablo 4.12. PYBS model1 için başarı değerleri

	PH-S	BOİ-S	KOİ-S	SS-S	SSV-S	SED-S	COND-S	Genel Başarı
O. Başarı(%)	85.10	89.95	88.60	88.31	86.11	93.05	91,75	88,52
R2	83.93	93.67	90.24	92.40	90.52	92.97	86,14	90,62

Tablo 4.13. PYBS model2 için başarı değerleri

	PH-P	BOİ-P	SS-P	SSV-P	SED-P	COND-P	Genel Başarı
O. Başarı(%)	89,39	87,15	90,31	90,02	90,32	89,52	89,45
R2	85,45	86,38	88,52	84,54	84,79	84,30	85,66

Tablo 4.14. PYBS model3 için başarı değerleri

	PH-D	BOİ-D	KOİ-D	SS-D	SSV-D	SED-D	COND-D	Genel Başarı
O. Başarı(%)	88,74	86,35	85,69	90,31	89,93	92,34	92,71	89,44
R2	86,72	88,24	81,57	92,30	85,87	95,59	89,90	88,60

Tablo 4.15. PYBS model4 için başarı değerleri

	PH-S	BOİ-S	KOİ-S	SS-S	SSV-S	SED-S	COND-S	Genel Başarı
O. Başarı(%)	86,52	88,94	87,91	88,32	87,60	92,93	93,20	89,35
R2	82,71	92,63	85,41	88,54	83,61	88,12	89,72	87,25

PCA analizi sonucu giriş parametrelerinin azaltılması gerekmeyen model çıkış parametrelerine örneğin, model1 için; COND-S, model2 için; PH-P, BOİ-P, SS-P, SSV-P, COND-P, model3 için; PH-D, BOİ-D, SS-D, SSV-D, SED-D, COND-D ve model4 için; COND-S parametrelerine yer verilmemiştir. Bu parametreler için başarı, YBS modelleri ile aynı olacağından, YBS model sonuç değerleri aynen alınmış ve kırmızı ile işaretlenmiştir.

PYBS model sonuçları incelendiğinde başarılı olduğu görülmüştür. Aynı zamanda PYBS modelleri için, klasik YBS modelleri üzerinden toplam 27 parametre kaldırılmış olmasına rağmen yine de YBS modellerine yakın sonuçlar elde etmiştir. Bu durumda daha az parametre ile daha hızlı işlem yapabilen, başarılı modellerin kurulabileceği görülmüştür. Benzer şekilde büyük boyutlu veri kümelerinin kullanılması durumunda hızlı sonuç üretmek için YBS modellerine alternatif olarak PYBS modelleri tercih edilebilir.

BÖLÜM 5. SONUÇLAR VE ÖNERİLER

Atıksu arıtma tesisi dinamik bir sistem yapısına sahiptir. Tesis içerisine alınan atıksuyun karakteristik özelliklerine göre tesisin çalışma koşullarını bozmayacak şekilde, gerekli değişikliklerin ivedilikle yapılması gerekir. Aksi durumda tesisin arıtma işlemi performansı, beklenen düzeylerde gerçekleşmeyebilir veya tesis tamamen kapatılarak işletme koşullarının tekrar uygun hale gelmesi için beklenir. Bu tür durumların varlığı atıksu arıtma tesislerinin sürekli olarak kontrol edilmesini ve gereken önlemlerin alınmasını zorunlu tutmaktadır. İnsan kontrolünde olan bu tür sistemlerin mutlaka bilgisayar destekli sistemler ile takip edilmesi, gerektiğinde uyarılarda bulunması ve tesis yöneticisine karar desteği sağlaması gerekir.

Bu tez kapsamında geliştirilen YBS tabanlı atıksu arıtma tesis simülatörü ile online olarak simüle edilmiş kontrolörlerden alınan bilgiler işlenir ve ileriye dair tahminlerde bulunulur. Yapılan tahminler geçmişteki yaşanan durumlar da dikkate alınarak yapılır. Geçmişteki birçok farklı durum göz önüne alındığından büyük miktarda veri, bir insanın düşünce ve algı kapasitesinin çok üzerinde, hızlı bir şekilde işlenerek atıksu bölümlerindeki çıkış değerleri elde edilmiş olur. Elde edilen sonuçlar ile en iyi şekilde arıtma işlemi gerçekleştirilebilmesi ve ortaya çıkabilecek sorunların önceden görülerek bertaraf edilmesinde tesis yöneticisine karar desteği sağlamaktadır.

Sistemin çalışabilmesi için UCI verileri kullanılmıştır. Verilerin ölçüm noktaları esas alınarak, tesis için 4 ayrı model oluşturulmuştur. Model simülasyonları sonucunda yüksek başarı değerleri elde edilmiştir.

PCA analizi kullanılan parametre sayısını azaltmak amacıyla uygulanan, sistemin işlem süresini kısaltarak önemli süre avantajı sağlayan bir yöntemdir. Literatürde birçok alanda kullanıldığı bilinmektedir. Bu nedenle PCAnın atıksu arıtma parametre

tahmini problemine etkileri incelenmek istenmiştir. Analiz sonuçlarına göre oluşturulan PYBS modellerinde, sisteme dahil edilmeyen parametreler olmasına karşın yine de tüm parametrelerin kullanıldığı YBS modellerine çok yakın sonuçlar elde edilmiştir. Bu sayede problemin daha az parametre ile de modellenebileceği başarılı sistemlerin ortaya çıkarılabileceği gösterilmiştir. Ayrıca PCA analizi sonucunda PYBS modellerinde toplam 27 giriş parametresi sisteme alınmadığından, modellerin sonuç üretmek için harcadığı toplam süre, YBS modeline göre ortalama %12 daha az olmuştur. Özellikle büyük boyutlarda veri kümesinin olduğu, bu nedenle klasik YBSnin eğitim için harcadığı sürenin belirgin bir şekilde hissedildiği durumlarda, PYBS modelinin süre avantajı önem kazanacaktır. Bu nedenle büyük veri kümesinin işleme alınacağı durumlarda, sistemin çalışma hızı daha önemli bir faktör olacağından, YBS ile PYBS arasındaki başarı farkı gözardı edilebilir ve daha hızlı olan PYBS modelinin kullanımı tercih edilebilir.

Literatürde UCI atıksu verilerinin kullanıldığı Düğenci [20] çalışmasında, tesis giriş parametreleri üzerinden tesis çıkış parametreleri tahmin edilmiştir. İlgili çalışmada kullanılan metodların başarı değerleri ve bu çalışmada elde edilen sonuçlar Tablo 5.1’de karşılaştırılmaktadır.

Tablo 5.1. YBS, PYBS ve Düğenci [20] çalışma sonuçları karşılaştırması

Metod	Başarı (%)
Regresyon	85,17
Geri yayılım	85,40
GA	86,49
Arı algoritması	87,24
YBS model1	89,80
PYBS model1	88,52

Bu çalışmada geliştirilen YBS ve PYBS modellerinin, Düğenci [20] çalışmasında kullanılan metodlara göre daha başarılı olmuştur. En başarılı model klasik YBS modelidir.

Atıksu arıtma tesislerinde ölçülen parametrelerden BOI parametresinin elde edilmesi normal şartlarda laboratuvar testleri ile sağlanmaktadır ve ortalama 1 hafta içerisinde

elde edilmektedir. Diğer önemli parametrelerden biri olan KOI parametresi 3 saatlik bir test sonucu elde edilebilmektedir. Geliştirilen sistemde bu parametreler birkaç saniye gibi kısa bir zamanda tahmin edilmektedir. Buna göre atıksu arıtmada ortam koşullarının önemli olduğu, biyolojik arıtmayı gerçekleştiren mikroorganizmalar için gerekli önlemler önceden alınabilir. Mikroorganizmaların yaşaması için gerekli oksijen miktarını, eklenmesi veya ortamdan atılması gereken katı madde miktarını belirlemede önemli avantajlar sağlamaktadır.

Atıksu arıtma tesisleri için karşılaşılan en önemli sorun hiç şüphesiz, tesise gelen ani aşırı kirlilik yüküdür. Genellikle bir endüstri kuruluşunun deşarj kurallarına aykırı olarak kanalizasyon hattına verdiği atıklardan veya yoğun yağışın etkisiyle gerçekleşmektedir. Geliştirilen sistem ani değişimlerin izlenmesi ile tesis kararlılığını bozacak bu tür durumların önüne geçilmesi için de kullanılabilir.

Atıksu arıtma tesisleri buldukları bölgenin yaşam koşulları, ortaya çıkan kirlilik türüne göre farklı şekillerde dizayn edilebilir. Benzer şekilde gelişen teknoloji ile birlikte yeni atıksu arıtma tesis yapıları da oluşturulmaktadır. Geliştirdiğimiz YBS tabanlı sistem herhangi bir atıksu arıtma tesisi yapısına uygulanabilir esneklikte dizayn edilmiştir.

Gerçek dünya problemlerinde kullanılan verilerin doğruluğu son derece önemlidir. Bu nedenle veri kümesinin analiz edilmesi ve gerekli görüldüğünde bu verilerin temizlenerek hatalı veriden arındırılması gereklidir. Ancak bu işlemin rastgele değil, bir uzman kontrolünde yapılması son derece önemlidir.

Her yapay zeka yaklaşımında olduğu gibi YBS için de, öğrenmeyi etkileyen parametre değerlerinin ve fonksiyon türlerinin doğru seçilmesi son derece önemlidir. YBS parametreleri maximum iterasyon sayısı, eşik değeri, mutasyon edilen gen sayısı ve affinite fonksiyonudur. Parametre değerleri problemde problemde değişkenlik göstermektedir ve literatürde değerlerin seçimi için herhangi bir yöntem belirtilmemiştir. Bu nedenle yaygın olarak probleme özgü, deneme yanılma yöntemi ile en uygun parametre ve fonksiyonun seçimi yapılmaktadır.

Geliştirilen sistemde ortalama en yüksek başarı durumunu, sistemin çalışma parametrelerinin probleme özgü seçilmesi ile elde edilmiştir. Örneğin maximum iterasyon sayısı öğrenme için geçen süreyi arttırmaktadır. Bu nedenle bu değerin büyük seçilmesi sistemin cevap süresini arttıracığından en fazla 2 değerinde tutulması tercih edilmiştir. Eğer sistem, işlemci gücü daha yüksek bir bilgisayarda çalıştırılırsa, bu sınırlama da ortadan kalkacaktır.

Oluşturulan sistem farklı katmanlara sahip sistemler için de YBS yapısının kullanılabilceğini göstermektedir. Genellikle literatürdeki çalışmalar tek katmanlı (AAT girişinden doğrudan AAT çıkışı) giriş ve çıkış arasında ilişkinin belirlenmeye çalışıldığı araştırmalardır. Bu açıdan çalışmanın, literature önemli katkılar sağlayacağı düşünülmektedir.

YBS algoritmalarının, literatürde yapılmış çalışmalar da dikkate alındığında, diğer mühendislik sahalarında da başarılı sonuçlar elde edebileceği düşünülmektedir.

Daha sonraki yapılacak çalışmalarda YBS, diğer yapay zeka yaklaşımları ile hibrid olarak kullanılabilir. Algoritmaların birlikte kullanımı ile yaklaşımların avantajlı olduğu noktalar bir araya toplanabilir ve sınırlamaları da aşılarak, daha iyi sonuçların elde edildiği çözümlerin oluşturulabileceği düşünülmektedir.

KAYNAKLAR

- [1] TÜİK, <http://www.tuik.gov.tr>, Erişim Tarihi: 01.03.2016.
- [2] Dilek, F.B., Arıtılmış Evsel Atıksuların Tarımsal Sulamada Kullanılması Çalıştayı, Medaware projesi, Ankara, 2005.
- [3] Henze, M. Grady Jr, C.P.L., Gujer, W., Marais, G.R., Matsuo, T., Activated Sludge Model No.1. Iawq Scientific And Technical Report No. 1, Iawq, London, UK, 1987.
- [4] Henze, M., Gujer, W., Takaishi, M., Matsuo, T., Wentzel, M.C., Marais, G.R., Activated Sludge Model No. 2. Iawq Scientific And Technical Report No. 3, Iawq, London, UK, 1995.
- [5] Gujer, W., Henze, M., Mino, T., Loosdrecht, V., Activated Sludge Model No. 3, Water Science And Technology, 39(1): 183-193, 1999.
- [6] Hong, Y.S.T., Bhamidimarri, R., Evolutionary Self-Organising Modelling Of A Municipal Wastewater Treatment Plant, Water Research, 37, 1199-1212, 2003.
- [7] Tomida, S., Hanai, T., Ueda, N., Honda, H., Kobayashi, T., Construction Of Cod Simulation Model For Activated Sludge Process By Fuzzy Neural Network, Journal Of Bioscience And Bioengineering, 88, 215- 220, 1999.
- [8] Tomida, S., Hanai, T., Honda, H., Kobayashi, T., Construction Of Cod Simulation Model For Activated Sludge Process By Recursive Fuzzy Neural Network, Journal Of Chemical Engineering Of Japan, 34, 369-375, 2001.
- [9] Yoshikawa, H., Hanai, T., Tomida, S., Honda, H., Kobayashi, T., Determination Of Operating Conditions In Activated Sludge Process Using Fuzzy Neural Network And Genetic Algorithm, Journal Of Chemical Engineering Of Japan, 34, 1033-1039, 2001.
- [10] Oliveira-Esquerre, K.P., Mori, M., Bruns, R.E., Simulation Of An Industrial Wastewater Treatment Plant Using Artificial Neural Networks And Principal Components Analysis, Brazilian Journal Of Chemical Engineering, 19(4): 365-370, 2002.

- [11] Meenakshipriya, B., Saravanan, K., Sathiyavathi, S., Neural Based pH System in Effluent Treatment Process, *Modern Applied Science*, 3(4): 166-176, 2009.
- [12] Alışkan İ., Gülez K., Cansever G., pH Nötralizasyon Prosesinin Yapay Sinir Ağı ile Kontrolü, *Otomatik Kontrol Ulusal Toplantısı*, Ankara, 100-106, 2006.
- [13] Alışkan İ., Gülez K., Cansever G., pH Sürecinin Lyapunov Tabanlı Lineer Olmayan Denetleyici İle Denetimi, İstanbul, 2008.
- [14] Toyoda, A., Taira, T., A High Level Treatment Of Fluorine Wastewater To Reduce Sludge, *IEEE*, 201-204, 1995.
- [15] Eikens B., Karim, M.N., Saucedo, V., Morris, A.J., Waste Water Neutralization Using A Fuzzy Neural Network Controller, *American Control Conference*, Washington, 1995.
- [16] Zhao, H., Hao, O.J., Mcavoy, T.J., Approaches To Modeling Nutrient Dynamics: Asm2, Simplified Model And Neural Nets, *Water Science And Technology*, 39(1): 227-231, 1999.
- [17] Plonka, L., Miksch, K., Ann-Based Short-Term Wastewater Flow Prediction For Better WWTP Control, *Chemistry and Chemical Technology*, 4(2): 159-162, 2010.
- [18] Subaşı, H., Yapay Sinir Ağı ile Atıksu Arıtma Performansının Modellenmesi, *Yüksek Lisans Tezi*, Adana, 2010.
- [19] Kriger, C., Prediction of the influent wastewater variables using neural network theory, *Cape Peninsula University of Technology*, Doktora Tezi, 2007.
- [20] Düğenci, M., Arı Algoritması'nın Yapay Sinir Ağı Öğrenmesi İçin Kullanımı ve Atıksu Arıtma Tesis Kontrolü Uygulaması, *Sakarya Üniversitesi*, Doktora Tezi, 2007.
- [21] Karaboğa, D., Akay, B., A modified Artificial Bee Colony algorithm for real-parameter optimization, *Information Sciences*, 192, 120-142, 2012.
- [22] Çınar, Ö., Yılmaz, A.S., Yapay Sinir Ağlarının Atıksu Arıtma Tesis İşletimine Uygulanması: Bir Örnek Çalışma, *Ksü Fen Ve Mühendislik Dergisi*, 8(2): 48-52, 2005.
- [23] Civelekoğlu, G., Arıtma Proseslerinin Yapay Zeka Ve Çoklu İstatistiksel Yöntemler İle Modellenmesi, *Süleyman Demirel Üniversitesi*, Doktora Tezi, 2006.

- [24] Tezel, G., Yel, E., Sinan, R.K., Artificial Neural Network (Ann) Model for Domestic Wastewater Treatment Plant Control, BALWOIS 2010, Makedonya, 2010.
- [25] Lee, D.S., Jeon, C.O., Park, J.M., Chang, K.S., Hybrid Neural Network Modeling of a Full-Scale Industrial Wastewater Treatment Process, *Biotechnology and Bioengineering*, 78(6): 670-682, 2002.
- [26] Baruch, I.S., Georgieva, P., Cortes, J.B., Azevedo, S.F., Adaptive Recurrent Neural Network Control of Biological Wastewater Treatment, *International Journal Of Intelligent Systems*, 206, 173-193, 2005.
- [27] Benelmir, O., Filali, S., Modeling and Neural Networks of Bioreactors in Wastewater Treatment Process, *International Journal on Sciences and Techniques of Automatic Control*, 1(1): 109-120, 2007.
- [28] Hernandez, S.C., Sanchez, E.N., Bueno, J.A., Neurofuzzy Control Strategy for an Abattoir Wastewater Treatment Process, 11th International Symposium on Computer Applications in Biotechnology (CAB 2010), Leuven, Belgium, 2010.
- [29] Grieu, S., Traore, A., Polit, M., Colprim, J., Neural networks for estimating wastewater BOD5 and Ammonia from simple on-line operational data, *Computational Engineering in Systems Applications CESA 2003*, Lille, Fransa, 2003.
- [30] <https://www.softwarehamilton.com/2014/01/09/hydromantis-releases-latest-build-of-flagship-product-gps-x>, Erişim Tarihi: 01.03.2016.
- [31] Gontarski, C.A., Rodrigues, P.R., Mori, M., Prenem, L.F., Simulation Of An Industrial Wastewater Treatment Plant Using Artificial Neural Networks, *Computers And Chemical Engineering*, 24, 1719-1723, 2000.
- [32] Vyas, M., Modhera, B., Vyas, V., Sharma, A.K., Performance Forecasting Of Common Effluent Treatment Plant Parameters By Artificial Neural Network, *ARPN Journal of Engineering and Applied Sciences*, 6(1): 38-42, 2011.
- [33] Krovvidy, S., Wee, W.G., Suidan, M., Summers, R.S., Intelligent Sequence Planning For Wastewater Treatment Systems, *IEEE*, 9(6): 15-20, 2004.
- [34] Rossman, L.A., A Hybrid Knowledge-Based/Algorithmic Approach To The Design Of Waste Treatment Systems, Pmc. Asce Sixth Conf. Computing In Civil Engineering, Am. Soc. Of Civil Eng., Newyork, 1989.
- [35] Gall, R.A.B., Patry, G.G., Knowledge- Based System For The Diagnosis Of An Activated Sludge Plant, In *Dynamic Modeling And Expert Systems In Wastewater Engineering*, G. Patry And D. Chapman, Lewis Publishers, Chelsea, 193-240, 1989.

- [36] Chapman, D.T., Patry, G.G., Hill, R.D., Dynamic Modeling And Expert Systems In Wastewater Engineering: Trends, Problems, Needs, In Llydynamic Modeling And Expert Systems In Wastewater Engineering, G. Patry And D. Chapman, Lewis Publishers, Chelsea, 345-370, 1989.
- [37] Spall, J.C., Cristion, J.A., A Neural Network Controller For Systems With Unmodeled Dynamics With Applications To Wastewater Treatment, IEEE, 27(3): 369-375, 1997.
- [38] Fuente, M.J., Robles, C., Casado, O., Syafiie, S., Tadeo, F., Fuzzy control of a neutralization process, Engineering Applications of Artificial Intelligence, 19, 905-914, 2006.
- [39] Tabatabaei, T.S., Farooq, T., Guergachi, A., Krishnan, S., Support Vector Machines Based Approach For Chemical Phosphorus Removal Process In Wastewater Treatment Plant, IEEE CCECE/CCGEL, Ottawa, 318-322, 2006.
- [40] Liu, Z., Wang, X., Lian, X., Wang, Z., Hou, C., A New Process Neural Network Algorithm of Soft Sensor for Time-Varying System, International Conference on Computational Intelligence for Modelling Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'06), 2006.
- [41] Chen, J.C., Chang, N.B., Mining the fuzzy control rules of aeration in a Submerged Biofilm Wastewater Treatment Process, Engineering Applications of Artificial Intelligence, 20, 959-969, 2007.
- [42] Cao, G., Li, M., Mo, C., Simulation of T-S Fuzzy Neural Network to UASB Reactor Shocked by Toxic Loading, International Conference on Computational Intelligence and Security, 2007.
- [43] Moral, H., Aksoy, A., Gökçay, C.F., Modeling of the activated sludge process by using artificial neural networks with automated architecture screening, Computers and Chemical Engineering, 32, 2471-2478, 2008.
- [44] Dellana, S.A., West, D., Predictive modeling for wastewater applications: Linear and nonlinear approaches, Environmental Modelling and Software, 24, 96-106, 2009.
- [45] Aguado, D., Rosen, C., Multivariate statistical monitoring of continuous wastewater treatment plants, Engineering Applications of Artificial Intelligence, 21, 1080-1091, 2008.
- [46] Hanbay, D., Türkoğlu, İ., Demir, Y., Prediction of wastewater treatment plant performance based on wavelet packet decomposition and neural networks, Expert Systems with Applications, 34, 1038-1043, 2008.

- [47] Mingzhi, H., Yongwen, M., Jinquan, W., Yan, W., Simulation of a paper mill wastewater treatment using a fuzzy neural network, *Expert Systems with Applications*, 36, 5064-5070, 2009.
- [48] Sadrzadeh, M., Ghadimi, A., Mohammadi, T., Coupling a mathematical and a fuzzy logic-based model for prediction of zinc ions separation from wastewater using electrodialysis, *Chemical Engineering Journal*, 151, 262-274, 2009.
- [49] Mingzhi, H., Jinquan, W., Yongwen, M., Yan, W., Weijiang, L., Xiaofei, S., Control rules of aeration in a submerged biofilm wastewater treatment process using fuzzy neural networks, *Expert Systems with Applications*, 36, 10428-10437, 2009.
- [50] Türkdoğan Aydınol, F.I., Yetinmezsoy, K., A fuzzy-logic-based model to predict biogas and methane production rates in a pilot-scale mesophilic UASB reactor treating molasses wastewater, *Journal of Hazardous Materials*, 182, 460-471, 2010.
- [51] Waewsak, C., Nopharatana, A., Chaiprasert, P., Neural-fuzzy control system application for monitoring process response and control of anaerobic hybrid reactor in wastewater treatment and biogas production, *Journal of Environmental Sciences*, 22(12): 1883-1890, 2010.
- [52] Gibert, K., Rodriguez-Silva, G., Rodriguez-Roda, I., Knowledge discovery with clustering based on rules by states: A water treatment application, *Environmental Modelling and Software*, 25, 712-723, 2010.
- [53] Liang, J., Luo, F., Yu, R., Xu, Y., Wastewater Effluent Prediction Based on Fuzzy-Rough Sets RBF Neural Networks, *Networking, Sensing and Control (ICNSC)*, Chicago, 2010.
- [54] Shi, X., Qiao, J., Neural Network Predictive Optimal Control for Wastewater Treatment, *International Conference on Intelligent Control and Information Processing*, Çin, 2010.
- [55] Luolong, G., Luofei, Z., Zhenghui, X., Prediction of Wastewater sludge recycle performance using Radial Basis Function Neural Network, 2010 *International Conference on Networking and Information Technology*, 319-321, 2010.
- [56] Yel, E., Yalpir, S., Prediction of primary treatment effluent parameters by Fuzzy Inference System (FIS) approach, *Procedia Computer Science*, 3, 659-665, 2011.
- [57] Zhao, L.J., Yuan, D.C., Chai, T.Y., Tang, J., KPCA and ELM ensemble modeling of wastewater effluent quality indices, *Procedia Engineering*, 15, 5558-5562, 2011.

- [58] West, D., Dellana, S., An empirical analysis of neural network memory structures for basin water quality forecasting, *International Journal of Forecasting*, 27, 777-803, 2011.
- [59] Turan, N.G., Mesci, B., Ozgonenel, O., The use of artificial neural networks (ANN) for modeling of adsorption of Cu(II) from industrial leachate by pumice, *Chemical Engineering Journal*, 171, 1091-1097, 2011.
- [60] Feng, L., Water Treatment Plant Decision Making Using Rough Multiple Classifier Systems, *Procedia Environmental Sciences*, 11, 1419-1423, 2011.
- [61] Khataee, A.R., Dehghan, G., Zarei, M., Ebadi, E., Pourhassan, M., Neural network modeling of biotreatment of triphenylmethane dye solution by a green macroalgae, *Chemical Engineering Research and Design*, 89, 172-178, 2011.
- [62] Yetilmezsoy, K., Fingas, M., Fieldhouse, B., An adaptive neuro-fuzzy approach for modelling of water-in-oil emulsion formation, *Colloids and Surfaces A: Physicochemical and Engineering Aspects*, 389, 50-62, 2011.
- [63] Madaeni, S.S., Kurdian, A.R., Fuzzy modeling and hybrid genetic algorithm optimization of virus removal from water using microfiltration membrane, *Chemical Engineering Research and Design*, 89, 456-470, 2011.
- [64] Wan, J., Huang, M., Ma, Y., Guo, W., Wang, Y., Zhang, H., Li, W., Sun, X., Prediction of effluent quality of a paper mill wastewater treatment using an adaptive network-based fuzzy inference system, *Applied Soft Computing*, 11, 3238-3246, 2011.
- [65] Luolong, Luofei, Zhouliyou, Yehongtao, Xuyuge, Predicting Wastewater Sludge Recycle Performance Based On Fuzzy Neural Network, 2011 International Conference on Networking, Sensing and Control, Hollanda, 2011.
- [66] Zhi-ming, C., Jue, H., Wastewater Treatment Prediction Based on Chaos-GA Optimized LS-SVM, *Control and Decision Conference (CCDC)*, 4013-4016, 2011.
- [67] Kern, P., Oyetoyan, T.D., McLoone, S., Self-Organizing Map based operating regime estimation for state based control of Wastewater Treatment Plants, 2011 International Conference of Soft Computing and Pattern Recognition (SoCPaR), 2011.
- [68] Dürrenmatt, D.J., Gujer, W., Data-driven modeling approaches to support wastewater treatment plant operation, *Environmental Modelling and Software*, 30, 47-56, 2012.

- [69] Olmo, F.H., Llanes, F.H., Gaudioso, E., An emergent approach for the control of wastewater treatment plants by means of reinforcement learning techniques, *Expert Systems with Applications*, 39, 2355-2360, 2012.
- [70] Behera, S.K., Rene, E.R., Park, H.S., Neural network modeling of sorption of pharmaceuticals in engineered floodplain filtration system, *Expert Systems with Applications*, 39, 6052-6060, 2012.
- [71] Han, H.G., Qiao, J.F., Chen, Q.L., Model predictive control of dissolved oxygen concentration based on a self-organizing RBF neural network, *Control Engineering Practice*, 20, 465-476, 2012.
- [72] Li, D., Yang, H.Z., Liang, X.F., Prediction analysis of a wastewater treatment system using a Bayesian network, *Environmental Modelling and Software*, 40, 14-150, 2013.
- [73] Verma, A., Wei, X., Kusiak, A., Predicting the total suspended solids in wastewater: A data-mining approach, *Engineering Applications of Artificial Intelligence*, 26, 1366-1372, 2013.
- [74] Liukkonen, M., Juntunen, P., Laakso, I., Hiltunen, Y., A software platform for process monitoring: Applications to water treatment, *Expert Systems with Applications*, 40, 2631-2639, 2013.
- [75] Kocijan, J., Hvala, N., Sequencing batch-reactor control using Gaussian-process models, *Bioresource Technology*, 137, 340-348, 2013.
- [76] Noori, R., Safavi, S., Shahrokni, S.A.N., A reduced-order adaptive neuro-fuzzy inference system model as a software sensor for rapid estimation of five-day biochemical oxygen demand, *Journal of Hydrology*, 495, 175-185, 2013.
- [77] Ye, Y., Zhuang, Y., The COD Predictive Technique Based on Neural Network, 2013 International Conference on Mechatronic Sciences, Electric Engineering and Computer (MEC), Çin, 2013.
- [78] Ay, M., Kisi, O., Modelling of chemical oxygen demand by using ANNs, ANFIS and k-means clustering techniques, *Journal of Hydrology*, 511, 279-289, 2014.
- [79] Seshan, H., Goyal, M.K., Falk, M.W., Wuertz, S., Support vector regression model of wastewater bioreactor performance using microbial community diversity indices: Effect of stress and bioaugmentation, *Water Research*, 53, 282-296, 2014.

- [80] Badrnezhad, R., Mirza, B., Modeling and optimization of cross-flow ultrafiltration using hybrid neural network-genetic algorithm approach, *Journal of Industrial and Engineering Chemistry*, 20, 528-543, 2014.
- [81] Chamberlain, B.C., Carenini, G., Öberg, G., Poole, D., Taheri, H., A Decision Support System for the Design and Evaluation of Sustainable Wastewater Solutions, *IEEE Transactions On Computers*, 63(1): 129-141, 2014.
- [82] Han, H., Nonlinear Model-Predictive Control for Industrial Processes: An Application to Wastewater Treatment Process, *IEEE Transactions On Industrial Electronics*, 61(4): 1970-1982, 2014.
- [83] Goldar, A., Revollar, S., Lamanna, R., Vega, P., Neural-MPC for N-removal in activated-sludge plants, 2014 European Control Conference (ECC), 808-813, 2014.
- [84] Kern, P., Wolf, C., Gaida, D., Bongards, M., Mcloone, S., COD and NH₄-N Estimation in the Inflow of Wastewater Treatment Plants using Machine Learning Techniques, 2014 IEEE International Conference on Automation Science and Engineering (CASE), Tayvan, 2014.
- [85] Yan, A., Shao, H., Wang, P., A soft-sensing method of dissolved oxygen concentration by group genetic case-based reasoning with integrating group decision making, *Neurocomputing*, 169, 422-429, 2015.
- [86] Ghaedi, M., Ansari, A., Bahari, F., Ghaedi, A.M., Vafaei, A., A hybrid artificial neural network and particle swarm optimization for prediction of removal of hazardous dye brilliant green from aqueous solution using zinc sulfide nanoparticle loaded on activated carbon, *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 137, 1004-1015, 2015.
- [87] Massana, A.C., Donate, M.G., Sanchez, D., Munoz, L.A.B., Muniesa, M., Blanch, A.R., Predicting fecal sources in waters with diverse pollution loads using general and molecular host-specific indicators and applying machine learning methods, *Journal of Environmental Management*, 151, 317-325, 2015.
- [88] Carvajal, G., Roser, D.J., Sisson, S.A., Keegan, A., Khan, S.J., Modelling pathogen log₁₀ reduction values achieved by activated sludge treatment using naïve and semi naïve Bayes network models, *Water Research*, 85, 304-315, 2015.
- [89] Liu, Q., Ibeas, A., Vilanova, R., Neural Network Identification of Wastewater Treatment Plants, 2015 Mediterranean Conference on Control and Automation (MED), İspanya, 2015.

- [90] Tao, F.W., Fei, Q.J., Tang, G.H., Xi, M., Dissolved Oxygen Control System Based on the T-S Fuzzy Neural Network, *Neural Networks (IJCNN)*, 1-7, 2015.
- [91] Kordkandia, S.A., Berardi, L., Comparing new perspective of hybrid approach and conventional kinetic modelling techniques of a submerged biofilm reactor performance, *Biochemical Engineering Journal*, 103, 170-176, 2015.
- [92] Li, F., Qiao, J., Han, H., Yang, C., A self-organizing cascade neural network with random weights for nonlinear system modeling, *Applied Soft Computing*, 42, 184-193, 2016.
- [93] Samsunlu, A., Atık Suların Arıtılması, *Birsen Yayınevi*, 193, 2006.
- [94] Toprak, H., Aktif çamur sürecinin işletilmesi, *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Yayınları*, 2000.
- [95] Toprak, H., Çevre Mühendisliği Ders Notları, <http://web.deu.edu.tr/atiksu/ana58/bolum05.pdf>, Erişim Tarihi: 01.03.2016.
- [96] Tchobanoglous, G., Burton, F.L., Stensel, H.D., *Wastewater Engineering: Treatment and Reuse*, McGraw-Hill, New York, 2003.
- [97] Aydın, İ., Metasezgisel Yöntemler Ders Notları, http://web.firat.edu.tr/iyaydin/bmu579/bmu_579_bolum5.pdf, Erişim Tarihi: 01.03.2016.
- [98] Castro, L., Zuben, F., *Artificial Immune Systems: Part I - Basic Theory and Applications*, TR-DCA, 1999.
- [99] Babayigit, B., Yapay bağışıklık algoritmaları ile lineer anten dizi sentezi, *Doktora Tezi*, Erciyes Üniversitesi, Kayseri, 2007.
- [100] Özşen, S., Biyomedikal sınıflama problemleri için problem tabanlı bir yapay bağışıklık sisteminin geliştirilmesi ve biyomedikal sınıflama problemlerine uygulanması, *Doktora Tezi*, Selçuk Üniversitesi, Konya, 2008.
- [101] Castro, L., Timmis, J., *Artificial Immune Systems as a Novel Soft Computing Paradigm*, *Soft Computing Journal*, 7, 526-544, 2003.
- [102] Timmis, J., Knight, T., Castro, L., Hart, E., An Overview of Artificial Immune Systems, *Computation in Cells and Tissues: Perspectives and Tools for Thought*, *Natural Computation*, 51-86, 2004.
- [103] Al-Enezi, J.R., Abbod, M.F., Alsharhan, S., *Artificial Immune Systems and Models, Algorithms and Applications*, *IJRRAS*, 3(2): 118-131, 2010.

- [104] Wikipedia, Bağışıklık sistemi organları, https://tr.wikipedia.org/wiki/Ba%C4%9F%C4%B1%C5%9F%C4%B1kl%C4%B1k_sistemi, Erişim Tarihi: 01.03.2016.
- [105] Abbas, A.K., Lichtman, A.H., Pillai, S., Temel immünoloji - immune sistemin işlevleri ve bozuklukları, Güneş Tıp Kitabevi, 2015.
- [106] De Castro, L.N., Von Zuben, F.J., The Clonal Selection Algorithm with Engineering Applications, In Workshop Proceedings of GECCO, Las Vegas, USA, 36-37, 2000.
- [107] Yücelbaş, C., Elipsoid Tanıma Çemberli Bir Yapay Bağışıklık Sistemi Tasarımı Ve Sınıflama Problemlerindeki Performans Analizi, Yüksek Lisans Tezi, Konya, 2012.
- [108] Karaboğa, D., Yapay Zeka Optimizasyon Algoritmaları, Nobel Yayıncılık, Ankara, 2006.
- [109] Forrest, S., Dasgupta, D., Novelty Detection in Time Series Data Using Ideas From Immunology, Proceedings of the ISCA'96, 1996.
- [110] Sertkaya, C., Bilgisayar Güvenliğinde Yapay Bağışıklık Sistemi, Yüksek Lisans Tezi, Sakarya Üniversitesi, Sakarya, 2009.
- [111] Perelson, A., Boer, R.D., Kevrekidis, I., Immune network behaviour: from stationary states to limit cycle oscillations, Bulletin of Mathematical Biology, 55(4): 745-780, 1993.
- [112] Forrest, S., Perelson, A., Allen, L., Cherukuri, R., Self-nonsel discrimination in a computer, IEEE Computer Society, 202-209, 1994.
- [113] Ayara, M., Timmis, J., Castro, L.D., Duncan, R., Negative Selection: How to Generate Detectors, International Conference on Artificial Immune Systems, 89-98, 2002.
- [114] Gonzalez, L., Cannady, J., A Self-Adaptive Negative selection approach for anomaly detection, Congress on Evolutionary Computation, IEEE Press, 1561-1568, 2004.
- [115] Igawa, K., Ohashi, H., A Negative Selection Algorithm for Classification and Reduction of the Noise Effect, Applied Soft Computing, 9, 431-438, 2009.
- [116] Zeng, J., Li, T., Liu, X., Liu, C., Peng, L., Sun, F., A Feedback Negative Selection Algorithm to Anomaly Detection, Third International Conference on Natural Computation (ICNC 07), 4, 604-608, 2007.

- [117] Xia, F., Zhu, Y., Gao, Y., Shape-Space Based Negative Selection Algorithm And Its Application On Power Transformer Fault Diagnosis, IEEE International Conference on Robotics and BioInformatics, 2149-2154, 2007.
- [118] Zhengbing, H., Ji, Z., Ping, M., A Novel Anomaly Detection Algorithm Based on Real-Valued Negative Selection System, Workshop on Knowledge Discovery and Data Mining, 499-502, 2008.
- [119] Ishiguro, A., Watanabe, Y., Uchikawa, Y., Fault Diagnosis of Plant System Using Immune Networks, IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MF1'94), 34-42, 1994.
- [120] Hunt, J., Cooke, D., Learning Using an Artificial Immune System, Journal of Network and Computer Applications, 19, 189-212, 1996.
- [121] Dasgupta, D., Ji, Z., Gonzalez, F., Artificial Immune System (AIS) Research in the Last Five Years, The 2003 Congress on Evolutionary Computation, 123-130, 2003.
- [122] Timmis, J., Neal, M., A Resource Limited Artificial immune System for Data Analysis, Knowledge Based Systems, 14(3): 121-130, 2001.
- [123] Timmis, J., Neal, M., Hunt, J., An Artificial Immune System or Data Analysis, Bios Stems, 55, 143-150, 2000.
- [124] Castro, L.D., Zuben, F., An Evolutionary Immune Network for data Clustering, IEEE Brazilian Symposium on Artificial Neural Networks, 84-89, 2000.
- [125] Li, L., Shao-dan, Z., Hong-wen, L., Fen, X., Wen-bo, X., Parameter Optimization of Pharmacokinetics Based on Artificial Immune Network, Applied Mathematics and Mechanics, 29(4): 549-558, 2008.
- [126] Castro, L.N., An Introduction to the Artificial Immune Systems, ICANNGA, Prag, 2001.
- [127] Greensmith, J., Aickelin, U., Artificial Dendritic Cells: Multi-faceted Perspectives, Human-Centric Information Processing Through Granular Modelling, 182, 375-395, 2009.
- [128] Burnet, F.M., Clonal Selection and After, In Theoretical Immunology, Perelson and G. H. Pimbley Jr., 63-85, 1978.
- [129] Ulutaş, B.H., Konak, S.K., A review of clonal selection algorithm and its applications, Artificial Intelligence Review, 36, 117-138, 2011.
- [130] Garrett, S.M., A Paratope is not an Epitope: Implications for Immune Network Models and Clonal Selection, ICARIS-2003, 217-228, 2003.

- [131] <https://archive.ics.uci.edu/ml/datasets/Water+Treatment+Plant>, Erişim Tarihi: 01.03.2016.
- [132] Xingquan, Z., Xindong, W., Qijun, C., Eliminating Class Noise in Large Datasets, International Conference on Machine Learning (ICML), Washington DC, 2003.
- [133] Zhang, T., You, X., Improvement of the Training and Normalization Method of Artificial Neural Network in the Prediction of Indoor Environment, Procedia Engineering, 121, 1245-1251, 2015.
- [134] MacGregor, J.F., Nomikos, P., Monitoring batch processes using multiway principal component analysis, AIChE Journal, 8(40): 1361-1375, 1994.
- [135] Everitt, B.S., Dunn, G., Applied Multivariate Data Analysis, 2nd ed, Londra, Wiley, 2001.

ÖZGEÇMİŞ

Cengiz SERTKAYA, 13.07.1983 tarihinde Ankara'da doğdu. İlkokul eğitimini Etimesgut'ta orta ve lise eğitimini Mamak'ta tamamladı. 2002 yılında Mamak Anadolu Lisesi'nden mezun oldu. 2002 yılında başladığı Sakarya Üniversitesi Bilgisayar Mühendisliği bölümünden 2006 yılında mezun oldu. Aynı yıl Sakarya Üniversitesi, Bilgisayar ve Bilişim Mühendisliği bölümünde yüksek lisans programına başladı ve 2009 yılında mezun oldu. 2007 yılından 2010 yılı sonuna kadar ADASU Genel Müdürlüğü'nde mühendis olarak çalıştı. Bu süre içerisinde yazılım uzmanı, veritabanı yöneticisi, yazılım proje yöneticisi görevlerinde aktif rol aldı. 2011 yılında Erasmus değişim programı ile gittiği Reutlingen Üniversitesi'nde İformatik alanında dersler aldı. 2011 yılı sonunda Türkiye'ye geri dönerek Türkiye Cumhuriyeti Cumhurbaşkanlığı'nda yazılım proje yöneticisi olarak çalıştı. 2012 yılı sonunda Işık Üniversitesi Bilgisayar Mühendisliği bölümünde araştırma görevlisi olarak çalışmaya başladı ve 2014 yılında görevinden ayrıldı. 2014 yılından itibaren freelance olarak çalışmaktadır.