

**YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**AKTİF ÇAMUR SİSTEMLERİNİN DİNAMİK
SİMÜLASYONU: İSTANBUL'DA TUZLA ve
PAŞAKÖY EVSEL ATIKSU ARITMA TESİSLERİNİN
İNCELENMESİ**

Çevre Müh. Ömer Engin DENİZCİ

**FBE Çevre Mühendisliği Anabilim Dalı Çevre Mühendisliği Programında
Hazırlanan**

YÜKSEK LİSANS TEZİ

Tez Danışmanı : Yrd.Doç.Dr. Arslan SARAL

İSTANBUL, 2009

**YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**AKTİF ÇAMUR SİSTEMLERİNİN DİNAMİK
SİMÜLASYONU: İSTANBUL'DA TUZLA ve
PAŞAKÖY EVSEL ATIKSU ARITMA TESİSLERİNİN
İNCELENMESİ**

Çevre Müh. Ömer Engin DENİZCİ

**FBE Çevre Mühendisliği Anabilim Dalı Çevre Mühendisliği Programında
Hazırlanan**

YÜKSEK LİSANS TEZİ

Tez Danışmanı : Yrd.Doç.Dr. Arslan SARAL

İSTANBUL, 2009

SİMGE LİSTESİ

S0	giriş BOİ veya KOİ konsantrasyonu,
θ	havalandırma tankında bekleme süresi
X	havalandırma tankında ki uçucu askıda katı madde konsantrasyonu
E	proses etkinliği
θC	havalandırma tankının hacmine bağlı ortalama hücre bekleme süresi
V	havalandırma tankı hacmi
X	havalandırma tankındaki uçucu askıda katı madde konsantrasyonu
Qw	atık çamur debisi
Xw	atıksudaki uçucu askıda katı madde konsantrasyonu
Qe	çıkış debisi
Xe	çıkış suyundaki uçucu askıda katı madde konsantrasyonu
Xt	sistemdeki uçucu askıda katı maddelerin toplam kütlesi
Y	Kütle katsayısı
q	spesifik substrat tüketim hızı
kd	mikroorganizma ölüm hızı
$\Pi(\theta X)$	θ parametresinin, x örnekleri üretilmiş modeli,
$L(\theta X)$	olasılık fonksiyonu,
$\Pi(\theta)$	geçmiş olasılıkların yoğunluk fonksiyonu,
Y_{t+1}	t+1 periyodundaki tahmin
St	t süresi sonunda serilerin sezonsal olmayan sadeleştirilmiş ölçü
bt	t periyodu için sadeleştirme trendi
I_{t-L+1}	t+1 periyodu için sadeleştirilmiş sezonsal olan indeks
YH	Heterotforların azalması
f'D	Çökelmeye neden olan biokütle
İN/XB	Biokütlede KOİ başına içerilen N oranı
İN/XD	Çökeltide KOİ başına içerilen N oranı
YA	Ototrofların azalması
μH	Heterotroflar için maksimum büyüme hızı
KS	Heterotroflar için yarı doyumluk oranı
KOH	Heterotroflar için Oksijen yarı doyumluk oranı
KNO	Heterotroflar için Nitrat yarı doyumluk oranı
bLH	Heterotroflar için çökeltme katsayısı
ηg	Anoksik biokütle oluşması koşullarında μH için düzeltme faktörü
ηh	Anoksik hidroliz için düzelme faktörü
ka	Amonyak oluşum hızı
kh	Maksimum spesifik hidroliz hızı
Kx	Yavaş parçalanabilir substratın hidrolizi için yarılanma hızı
μA	Ototroflar için maksimum büyüme hızı
KNH	Ototroflar için amonyak azotunun yarılanma hızı
KOA	Ototroflar için oksijen yarılanma hızı
bLA	Ototroflar için çökeltme katsayısı
ys(i)	i verisinin yumuşatılmış değerini,
N	komşu veri sayısını,
2N+1	kullanılacak açıklık (span) değerini,
x	Yumuşatılan yanıt değeri ile ilişkilendirilmiş öngörü verisini,
xi	Aralık değeri ile tanımlı, x verisine en yakın komşu verileri,
d(x)	x verisi ile en uzak öngörü verisi arasındaki yatay uzaklık değerini,

r_i	Regresyon yumuşatma işleminden sonra elde edilen i noktasındaki verinin kalıntısı
MAD	Kalıntı verilerin ortalama standart sapması, $MAD = \text{median}(r)$,
X_t	Normalize veri değerini,
x_t	Gerçek veri değerini,
$x_{\max}$	Veri setindeki en büyük değeri,
$x_{\min}$	Veri setindeki en küçük değeri,

KISALTMA LİSTESİ

ASM1	Activated Sludge Model 1
ASM2	Activated Sludge Model 2
ASM3	Activated Sludge Model 3
İSKİ	İstanbul Su ve Kanalizasyon İdaresi
IAWQ	Uluslar arası Su Kalite Örgütü
PAAT	Paşaköy Atıksu Arıtma Tesisi
TAAT	Tuzla Atıksu Arıtma Tesisi
YSA	Yapay Sinir Ağı

ŞEKİL LİSTESİ

	Sayfa
Şekil 3.1 Organik karbonun atık su içinde ki karakterizasyonu	10
Şekil 3.2 Azotlu bileşikler atık su içindeki karakterizasyonu.....	11
Şekil 3.3 Tuzla atıksu arıtma tesisi, 2007 yılı tesis giriş-çıkış sıcaklık değişim grafiği.....	14
Şekil 4.1. Tipik yapay sinir ağı (YSA) yapısı.....	19
Şekil 4.2 Tek girişli nöron modeli	20
Şekil 4.3 FIR filtre ağırlıklı dinamik hücre modeli	24
Şekil 4.4 FIR filtre olarak tasarlanan ağırlıklar	25
Şekil 4.5 RC- dinamik bir hücre modeli	25
Şekil 4.6 İleri beslemeli 3 katmanlı YSA	26
Şekil 4.7 Geri Beslemeli İki Katmanlı YSA.....	27
Şekil 4.8 YGKI yapay sinir ağı.....	28
Şekil 4.9 Bellek hücreli yapay sinir ağı ve bellekli bir hücrenin yapısı	29
Şekil 4.10 Radyal tabanlı fonksiyon ağı	30
Şekil 4.11 Fonksiyonel link ağı	32
Şekil 4.12 Çağrışimli Bellek Ağları.....	33
Şekil 4.13 Modül yapay sinir ağları.....	34
Şekil 4.14 Doyumlu doğrusal aktivasyon fonksiyonu	35
Şekil 4.15 Sigmoid (tanh) aktivasyon fonksiyonu	36
Şekil 4.16 Eşik aktivasyon fonksiyonu.....	37
Şekil 5.1 Paşaköy atıksu arıtma tesisi vaziyet planı uydu görüntüsü	41
Şekil 5.2 Tuzla atıksu arıtma tesisi vaziyet planı uydu görüntüsü.....	43
Şekil 7.1 Giriş-Çıkış veri setinin 6 yumuşatma metoduna uygulanmasından elde edilen ilk cevap seti	58
Şekil 7.2 Yumuşatılmış 6 cevap setinin tekrar yumuşatılması ile elde edilen ikinci cevap seti	59
Şekil 7.3 sLow02 cevap setinin polinom fonksiyonu ve sinüs fonk. toplamına göre eğri uydurma grafiği	59
Şekil 7.4 sRlow02 cevap setinin polinom fonksiyonu ve sinüs fonk. toplamına göre eğri uydurma grafiği	60
Şekil 7.5 Yumuşatılmış cevap setlerinin uygulandığı yapay sinir ağı yapısı	60
Şekil 7.6a Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları.....	61
Şekil 7.6b Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları.....	61
Şekil 7.6c Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları.....	61
Şekil 7.6d Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları.....	61
Şekil 7.6e Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları.....	61
Şekil 7.6f Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları.....	61
Şekil 7.6g Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları.....	62
Şekil 7.6h Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları.....	62
Şekil 7.6i Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları.....	62
Şekil 7.6j Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları.....	62
Şekil 7.6k Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları.....	62
Şekil 7.6l Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları.....	62
Şekil 7.7 TAAT (a) ve PAAT (b) yıllık giriş-çıkış KOİ değeri değişimi	63
Şekil 7.8 TAAT (a) ve PAAT (b) yıllık giriş-çıkış BOİ ₅ değeri değişimi	64
Şekil 7.9 TAAT (a) ve PAAT (b) yıllık giriş-çıkış NH ₄ -N değeri değişimi.....	64
Şekil 7.10 TAAT (a) ve PAAT (b) yıllık sıcaklık (°C) değeri değişimi.....	64
Şekil 7.11 TAAT için AKM parametresinin YSA modeli eğitim sonuçları	66

Şekil 7.12	TAAT için AKM parametresi YSA model sonuçlarının, gerçek sonuçlar ile karşılaştırılması	66
Şekil 7.13	TAAT için BOİ parametresinin YSA modeli eğitim sonuçları.....	67
Şekil 7.14	TAAT için BOİ parametresi YSA model sonuçlarının, gerçek sonuçlar ile karşılaştırılması	67
Şekil 7.15	TAAT için KOİ parametresinin YSA modeli eğitim sonuçları	68
Şekil 7.16	TAAT için KOİ parametresi YSA model sonuçlarının, gerçek sonuçlar ile karşılaştırılması	68
Şekil 7.17	PAAT için BOİ parametresinin YSA modeli eğitim sonuçları.....	69
Şekil 7.18	PAAT için BOİ parametresi YSA model sonuçlarının, gerçek sonuçlar ile karşılaştırılması	69
Şekil 7.19	PAAT için KOİ parametresinin YSA modeli eğitim sonuçları.....	70
Şekil 7.20	PAAT için KOİ parametresi YSA model sonuçlarının, gerçek sonuçlar ile karşılaştırılması	70
Şekil 7.21	PAAT için YSA giriş verisi BOİ+T ile elde $\mu_{H,max}$ sonuçlarının, ASM1 model ile elde edilen $\mu_{H,max}$ sonuçları ile karşılaştırılması.....	72
Şekil 7.22	PAAT için YSA giriş verisi BOİ+T ile elde b_{LH} sonuçlarının, ASM1 model ile elde edilen b_{LH} sonuçları ile karşılaştırılması.....	72
Şekil 7.23	TAAT için YSA giriş verisi KOİ+T ile elde $\mu_{H,max}$ sonuçlarının, ASM1 model ile elde edilen $\mu_{H,max}$ sonuçları ile karşılaştırılması.....	73
Şekil 7.24	TAAT için YSA giriş verisi KOİ+T ile elde b_{LH} sonuçlarının, ASM1 model ile elde edilen b_{LH} sonuçları ile karşılaştırılması.....	73
Şekil 7.25	TAAT için KOİ etki analizi	75
Şekil 7.26	TAAT BOİ ₅ etki analizi	76
Şekil 7.27	PAAT için KOİ etki analizi	76
Şekil 7.28	PAAT için BOİ ₅ etki analizi	76

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 3.1 Aktif çamur model no 1 matrisi	9
Çizelge 3.2 ASM1 stokiyometrik – kinetik parametre değerleri	13
Çizelge 5.1 Paşaköy arıtma tesisi giriş suyu parametre değerleri	42
Çizelge 5.2 Tuzla arıtma tesisi giriş suyu parametre değerleri	44
Çizelge 6.1 Parametre-katsayı korelasyonu	48
Çizelge 7.1 Giriş-Çıkış cevap setlerinin eğri uydurma metotlarına etkileri	58
Çizelge 7.2 Yapay sinir ağının cevap setlerine göre karşılaştırmalı performans ve regresyon değerleri	63
Çizelge 7.3 YSA modelleri eğitim ve simülasyon sonuçları	71
Çizelge 7.4 YSA ve ASM1 modelden elde edilen b_{LH} ve $\mu_{H,max}$ katsayılarının karşılaştırılması	74
Çizelge 7.5 Ön çökeltim sonrası evsel atık suyun tipik karakteristiği	75

ÖNSÖZ

Yüksek lisans eğitimim için, beni cesaretlendiren, maddi ve manevi tüm desteklerini eksiksiz sunan, lütuf sahibinin bana bahsettiği sevgili babam Bahattin DENİZCİ' ye, annem Neriman DENİZCİ' ye ve kız kardeşim Esra DENİZCİ' ye teşekkür ederim.

Tez çalışmasına başladığım dönemde, kendisi üniversiteden ayrılmadan önce ilk tez danışmanım olan Sayın Ertan ARSLANKAYA' ya, desteklerinden dolayı teşekkür ederim. Çalışmanın kalan kısmında tez danışmanım olarak görev alan, değerli öğretim görevlisi Sayın Arslan SARAL' a destekleri için teşekkür ederim.

Çalışmam süresince hiçbir desteğini esirgemeyen Proses mühendislik ailesine, sevgili dostum Will Dwinell' a yapay sinir ağları konusunda bana destek olduğu için teşekkür ederim.

Bütün bu güzel nimetleri bana sunan sonsuz lütuf sahibine şükürler olsun.

AKTİF ÇAMUR SİSTEMLERİNİN DİNAMİK SİMÜLASYONU: İSTANBUL'DA TUZLA ve PAŞAKÖY EVSEL ATIKSU ARITMA TESİSLERİNİN İNÇLENMESİ

Ömer Engin DENİZCİ
Çevre Mühendisi, Yüksek Lisans Tezi

Aktif çamur prosesi için geliştirilmiş mevcut modeller, temel biyokinetik denklemlerin kullanılması ile oluşturulmuş, deterministik modellerdir. Bu modellerin kalibrasyonları fazlasıyla zaman alıcı ve dinamik simülasyon uygulamaları bir hayli karmaşıktır. Yapay sinir ağı tekniği ise, kullanım kolaylığı ve hızlı sonuç vermesi gibi avantajları nedeniyle son yıllarda dinamik simülasyon uygulamalarında başarıyla kullanılmaktadır.

Bu tez çalışmasında, aktif çamur prosesinin dinamik simülasyonu için, yapay sinir ağı tekniği kullanılmıştır. İstanbul'da yer alan Tuzla (TAAT) ve Paşaköy (PAAT) evsel atıksu arıtma tesisleri, pilot tesis olarak belirlenmiştir. Yapay sinir ağı modelinde, arıtma tesislerinin laboratuvarından elde edilen günlük ölçüm sonuçları kullanılmıştır. Modelden elde edilen sonuçlar, Aktif Çamur Model No:1 (ASM1) ile hesaplanan sonuçlarla karşılaştırılmıştır.

Bu çalışmada geliştirilen yapay sinir ağı modelinin, tesislerin mevcut davranışına yakınlık oranı, farklı parametrelere göre %55-80 arasında hesaplanmıştır. Ortalama başarısının yaklaşık %70 olduğu tespit edilmiştir. Ayrıca ASM1 modeli ile kolektif çalıştırılması ile elde edilen kinetik katsayılar, tesislerde ki aktif çamur proseslerinin veriminin izlenmesi ve kontrolü açısından oldukça önemlidir. Aktif çamur prosesinin temel ölçüm parametreleri ile korelasyon içinde olan bu katsayılar, deneysel sonuçların modelde çalıştırılması ile kolayca öngörülmesi olarak elde edilebilmektedir.

Geliştirilen modelin, hem Tuzla atıksu arıtma tesisi hem de Paşaköy atıksu arıtma tesisi için, modelde çalışılan KOİ, BOİ ve AKM parametrelere ait geleceğe yönelik tahminsel öngörülerin oluşturulması amacıyla kullanılabilmesi mümkündür. Böylece, her iki arıtma tesisi için, bu model, çeşitli durumlarda önceden bazı yorumların yapılabilmesine, hatta aktif çamur prosesine önceden müdahaleye olanak sağlamaktadır.

Anahtar Kelimeler: Atıksu arıtma, Aktif çamur, Dinamik simülasyon, Yapay sinir ağı, Aktif çamur model 1.

JÜRİ:

1. Yrd.Doç.Dr. Arslan SARAL
2. Prof.Dr. Ferruh ERTÜRK
3. Yrd. Doç.Dr. Osman Atilla ARIKAN

Kabul tarihi:/....../2009
Sayfa Sayısı:

DYNAMIC SIMULATION of ACTIVATED SLUDGE SYSTEMS: ANALYSIS of TUZLA and PAŞAKÖY DOMESTICAL WASTEWATER TREATMENT PLANTS in ISTANBUL

Ömer Engin DENİZCİ
Environmental Engineering, M.S. Thesis

Enhanced current models for activated sludge process are deterministic in character which has been derived from the bio-kinetic equations. Calibrating these models is extremely time-consuming and their applications of dynamic simulations are quite complicated. Recently artificial intelligence technique was successfully used in the field of dynamic simulations due to being user friendly and time-saving.

In this thesis, artificial intelligence technique was used for dynamic simulation of activated sludge process. Tuzla (TAAT) and Paşaköy (PAAT) domestic wastewater treatment plants in Istanbul were determined as pilot plants. Daily measurement results from laboratories of plants were used in the artificial intelligence network. Results acquired from model were compared with other results calculated from Activated sludge model no:1 (ASM1).

Proximity of the developed model to the current behavior of the treatment plants was calculated between % 55-80 depending on different parameters. Mean achievement was calculated approximately %70. Furthermore, kinetic coefficients acquired from ASM1 are highly important in order to obtain and control to the activated sludge in treatment plants. Coefficients, under good correlation with fundamental parameters of activated sludge process, can be predicted easily by this model that was used with experimental results.

The model developed can be used to predict the COD, BOD and SS for both Tuzla and Paşaköy wastewater treatment plants. Thus, this model can be used for the pre-assessment of the two plants interfere the active sludge process if necessary.

Keywords: Wastewater treatment, Activated sludge, Dynamic simulation, artificial neural network, ASM1

JÜRİ:

1. Yrd.Doç.Dr. Arslan SARAL
2. Prof.Dr. Ferruh ERTÜRK
3. Yrd. Doç.Dr. Osman Atilla ARIKAN

Kabul tarihi:/....../2009
Sayfa Sayısı:

1.GİRİŞ

Atıksu arıtma tesislerinin karmaşık fiziksel, kimyasal ve biyolojik prosesler içermesiyle, bir çok kentsel atıksu arıtma tesislerinde ki proseslerin başarısı geçmiş çalışmalara ve tesis işletmecilerinin deneyimlerine bağlıdır. Bu tür tesislerde ki ileri kontrol teknolojilerinin kullanılması, güvenilir veri kontrol cihazlarının eksikliğinden dolayı yavaş gelişim seyretmektedir. Ancak son yıllarda, atıksu arıtma tesislerinde gerçek zamanlı kontrol konusu hakkında yapılan çalışmalar ve konu ile ilgili bilgisayar altyapılı gelişmelerin artması, bu konunun önemini arttırmıştır. Buna etki eden faktörlerin başında uyulması zorunlu deşarj kriterleri, arıtılmamış veya kısmen arıtılmış atıksuların yüzeysel sulara olan etkileri, bilgisayarlı sensör sistemlerine yapılan yatırımlar ve geliştirilmeleri ve uzun dönem maliyet etkinliği konuları yer almaktadır. Böylece arıtma tesislerinde maliyeti azaltıcı, güvenilir, kararlı çalışan ve otomatik sistemlerin temininin gerekliliği artmaktadır.

Bugün mevcut atıksu arıtma tesislerinde ki kontrol stratejileri ve kullanılan teknolojiler tamamen tesis bazlı ve teknolojinin tesise uygulanabilir düzeyine bağlıdır. Birçok eski tesis kontrol ekipmanı barındırmamaktadır. Bu tesislerde genellikle operatör deneyimi ön plandadır. Bazı yeni tesisler ise geniş bir yelpazede gerçek zamanlı kontrol ve izleme ekipmanları ile donatılmıştır. Bu tür tesislerde işletme stratejileri genellikle lokal kontrollere uygulanan, havalandırma havuzundaki çözünmüş oksijene verilen hava akımının etkisi gibi klasik kontrol algoritmalarıdır. Bu nedenle son yıllarda araştırmacılar, gerçek zamanlı kontrolü amaçlayan, atıksu arıtma tesislerinin dinamik modellemeleri üzerinde çalışmaya başlamıştır. Bu çalışmalar arasında en büyük payı aktif çamur prosesi almıştır.

Gerçek zamanlı kontrol sistemi ekipmanları; ölçüm sensörleri, doğrulayıcı regülatörler, kontrol ve ayar ekipmanları ve bunların arasındaki iletişim hatlarından oluşmaktadır. Gerçek zamanlı sistemlerde kontrol ekipmanları, ölçüm cihazından aldıkları sinyalleri doğru proses işleyişine yönelten ve bunları sistemde doğrulayan regülatörlere ileten bir çeşit dinamik model kullanmaktadır.

Bir sistemin dinamik davranışının başarılı bir şekilde kontrol edilebilmesi; prosesin mevcut durumunun izlenmesi ve aksaklıklara tepkisinin gözlemlenmesine, gözlemlerde giriş ve çıkış verilerinin iyi yorumlanmasına, müdahale kapasitesine bağlıdır. Atıksu arıtma

tesislerinde efektif gerçek zamanlı kontrol yapılabilmesi için, sisteme girişlerin ve girişlere alınan cevapların dinamik olarak modellenmesi gerekir.

Karasız bir sistemde giriş ve çıkışlar arasında bağlantı kurabilmek için dinamik modeller kurulmalıdır. Proses kontrol terminolojisinde, bir sistem için dinamik model oluşturmak, sistemin tanımlanması ile ilgilidir. Sistem tanımlama, model için kullanılacak ilgili dataların yorumlanması demektir. Sistem tanımlamanın prosedürü; deneysel tasarıma, model tipi ve yapısının seçimine, model parametresi değerlerinin kestirilebilmesine ve kalibre edilmiş modelin doğrulanması ile ilişkilidir. Model tanımlanabilirliği ve deneysel dizayn birbirine bağlıdır. Tanımlanamayan bir model yapısı ise giriş ve çıkış vektörlerinin tanımlanıp belirlenmesi ile tanımlanabilir halde getirilir. Dinamik sistemi temsil eden model tipinin seçimi, gerçek zamanlı kontrol sistemi için oldukça önemlidir. Bu model kontrol amacı için basit ve anlaşılır olmalıdır. Çünkü karmaşık sistemler, özellikle biyolojik arıtmada, basit sistemlere göre otomasyon zorluklarına sebep olurlar.

Proses içindeki değişkenlerin çok sayıda etkileşimleri, atıksuyun karakterizasyonu, akısı ve konsantrasyonunda ki dinamik değişimler, aktif çamur reaktörlerini fiziksel, kimyasal ve biyolojik yönden karmaşık hale getirir. Bu bağlamda matematiksel modelleme ve bilgisayar simülasyonu, aktif çamur reaktörlerinin performans kabiliyeti, gelişimleri ve tasarımına bağlı potansiyel kazanımlar sağlayabilir. Mevcut matematik modellerin başında, diğerlerine göre, gerçeğe yakın veya potansiyel gerçeklik ifade eden ham öngörüler sunan modeller gelmektedir. Örneğin aktif çamur 1 modeli (AÇM1), karbon oksidasyonu, nitrifikasyon ve denitrifikasyonu da içeren, bağlı büyüme sistemlerinde biyolojik prosesleri tanımlayan bir çerçeve tanımlamaktadır. Aktif çamur 2 modeli (AÇM2) fosfor giderimini de içermektedir.

Aktif çamur proseslerinin modellenmesinde yeni bir yaklaşım yapay sinir ağlarıdır (YSA). Bu tür modeller insan sinir ağlarından esinlenerek tasarlanmıştır. Bir beyin gibi başarılı çalışmıyor olsa da, yapay sinir ağları doğrusal olmayan problemlerin modellenmesinde kısmen başarılı sonuçlar vermektedir. Otomatik kontrolle oluşturulmuş atıksu arıtma tesislerinin kontrol prosesleri yüksek deneyim gerektirmektedir. YSA'lar bu soruna bir çözüm olabilir. Bu nedenle YSA'lar sadece modelin geliştirilmesi aşamasında sıklıkla ölçüme ihtiyaç duyar. Bu ölçüm periyodu, geliştirilecek YSA modelinin tanımlanması için gereklidir. YSA modelinin geliştirilmesinden sonra, ölçüm periyotlarının sıklığı azaltılabilir, böylece modelin cevapları ile gerçek verilerin karşılaştırılması sağlanır. YSA

modellerin kalibrasyonu white-box modellere göre daha az parametre kullanmasından dolayı daha basittir. Ölçülen veriler, cevaptan gelen verilerle farklılık göstermeye başladığı zaman, model yeni verilerle tekrar eğitilir.

Bu tezin amacı yeni bir yapay sinir ağı modeli geliştirerek, mevcut sistemle birbirine yakın sonuçlar veren bir öngörü sistemi oluşturmaktır. Bunu gerçekleştirmek için seçilen çıkış parametrelerine öngörü sonuçlarını oluşturacak çeşitli giriş işletme parametreleri kullanılmıştır. Bu parametreler İstanbul Tuzla evsel atıksu arıtma tesisi (TAAT) ve Paşaköy evsel atıksu arıtma tesislerine (PAAT) ait geçmiş verilerdir. Yapay sinir ağı modelinden elde edilen sonuçlar aktif çamur model 1 (Activated Sludge Model1-ASM1) ile karşılaştırılmıştır.

2. AKTİF ÇAMUR PROSESİ


Atıksu arıtma prosesleri genellikle iki ayrı kategoride toplanmaktadır; birincisi aktif çamur sistemleri gibi askıda büyüme prosesleri, ikincisi biofilm sistemleri gibi bağlı büyüme prosesleri (Grady vd.,1999). Aktif çamur proses karakteristiği, atıksu içinde askıda büyüyen mikroorganizmaların, organik kirleticileri parçalayıp tüketmeleri şeklindedir. Aktif çamur prosesi hem teorik hem de uygulamada yaklaşık 100 yıldır geliştirilmektedir (Grady,1999, Metcalf&Eddy,1991). Atıksu arıtma tesisleri de çoğunlukla aktif çamur prosesi ile işletilmektedir.

2.1 Proses Tanımı


Temelde, aktif çamur prosesleri, havalandırma tankı, çökeltim, biokütle geri devri ve atık biokütle giderimi içerirler. Genelde sürekli veya kesikli olarak işletilen aktif çamur prosesi, karbon oksidasyonu, nitrifikasyon – denitrifikasyon ve fosfor giderim süreçlerini içerecek şekilde aerobik veya anoksik olabilmektedir. Arıtılmış atık sudan aktif biokütle sıklıkla çökeltim süreci ile alınırken bazen flotasyon veya membran filtrasyonu da uygulanabilir.

Biyolojik olarak parçalanabilen substrat, biokütlenin içsel solunumu ile enerjiye dönüştürülür. Daha spesifik olarak, içsel solunum metabolik bir aktivite olup, organik veya inorganik bileşikler elektron verici ve O_2 , NO_2 , NO_3 , SO_4 gibi inorganik bileşikler ise elektron temel alıcı olarak ortamda bulunurlar. Eğer temel elektron alıcı O_2 ise bu tür prosesler aerobik olarak tanımlanır. Biokütle organik substrat içindeki moleküler arası enerjiyi Adenozin Tri Fosfatın (ATP) güçlü fosfat bağlarına dönüştürür. Bu enerji hücre içinde büyüme ve yeni ürünlerin oluşumu için kullanılır (Spanjers vd.,1998). Reaktör içinde bakteriler, substratı aşağıdaki stokiometrik denklemlere göre hem içsel solunum ile parçalar hem de oksidasyon ve sentez yapar.

Oksidasyon ve Sentez



İçsel Solunum



2.2 Proses Analizi

Uzun yıllar süren çalışmalar neticesinde, aktif çamur prosesinin kontrolü ve dizaynı için hem ampirik hem de rasyonel formüller geliştirilmiştir. Genel olarak; besin/mikroorganizma (F/M) oranı ve ortalama hücre bekleme süresi θ_c şeklinde iki ayrı kanaat yaygındır (Metcalf & Eddy, 1991).

Besin / mikroorganizma oranı (F/M), (2.3) eşitliğindeki gibi ifade edilir:

$$F / M = \frac{S_0}{\theta X} \quad (2.3)$$

Burada;

S_0 = giriş BOİ veya KOİ konsantrasyonu, g/m³, mg/L, kg/m³, mg/dm³, L/V

θ = havalandırma tankında bekleme süresi

X = havalandırma tankında ki uçucu askıda katı madde konsantrasyonu, g/m³, /L, kg/m³, mg/dm³, L/V

F/M oranı ile spesifik fayda oranı (U) arasındaki ilişki ise (2.4) eşitliğindeki gibidir.

$$U = \frac{(F / M)E}{100} \quad (2.4)$$

Burada ;

E = proses verimi, %

(2.3)'de ki F/M oranını, (2.4) eşitliğinde yerine yazarsak aşağıdaki denklemi elde ederiz.

$$U = \frac{S_0 - S}{\theta X} \quad (2.5)$$

Reaktör hacmine bağlı ortalama hücre bekleme süresini iki şekilde ifade etmek mümkündür. Bunlardan birincisi havalandırma tankının hacmine göre verilen ifadedir.

$$\theta_c = \frac{VX}{Q_w X_w + Q_e X_e} \quad (2.6)$$

Burada ;

θ_c = havalandırma tankının hacmine bağlı ortalama hücre bekleme süresi, gün

V = havalandırma tankı hacmi, m³

X = havalandırma tankındaki uçucu askıda katı madde konsantrasyonu, g/m³

Q_w = atık çamur debisi, m³/gün

X_w = atıksudaki uçucu askıda katı madde konsantrasyonu, g/m³

Q_e = çıkış debisi, m³/gün

X_e = çıkış suyundaki uçucu askıda katı madde konsantrasyonu, g/m³

İkinci ifade ise toplam sistem hacmine göredir.

$$\theta_{CT} = \frac{X_t}{Q_w X_w + Q_e X_e} \quad (2.7)$$

Burada;

X_t = sistemdeki uçucu askıda katı maddelerin toplam kütlesi, g

Yukarıda tanımlanan sistem de biokütle için kütle dengesi, (2.8) eşitliğindeki gibidir (Tchobanoglous ve Burton, 1991).

$$\frac{dX}{dt} V_r = QX_o - (Q_w X + Q_e X_e) + V_r (r'_g) \quad (2.8)$$

Burada r'_g , sistemdeki mikroorganizmanın net büyüme hızıdır.

Çıkış suyunda hücre konsantrasyonunu sıfır kabul eder ve sistemin kararlı çalıştığını düşünürsek (2.8) eşitliğini aşağıdaki gibi sadeleştirmemiz mümkündür (Tchobanoglous ve Burton, 1991).

$$\frac{1}{\theta_c} = Yq - k_d \quad (2.9)$$

Burada;

Y = kütle katsayısı, M/M (Kütle / Kütle)

q = spesifik substrat tüketim hızı, 1/T (1 / Zaman)

k_d = mikroorganizma ölüm hızı, 1/T (1 / Zaman)

3. AKTİF ÇAMUR MODELLERİ

Aktif çamur prosesleri, klasik, geliştirilmiş havalandırma, oksijen transferi vb... formlarda farklı modellerin modifikasyonlarını içermektedir. Literatürde, aktif çamur modelleri ile ilgili, zaman serisi, istatistiksel, stokastik, deterministik ve mekanistik incelemeleri bulunmaktadır. Sistem davranışının anlaşılabilmesi için daha çok deterministik ve mekanistik modeller üzerinde çalışılmıştır. Deterministik modeller, reaksiyon mekanizmasını tanımlayan denklemlerde ki giriş ve çıkış verileri arasında direk bağlantı kurar. 90'lı yıllardan sonra aktif çamur sistemi, karbon oksidasyonu, nitrifikasyon ve denitrifikasyon prosesleri üzerine modellenmeye başlandı. Henze vd.'nin 1987 yılında yapılan modelleme çalışmaları ile uluslar arası su kalite örgütü'nün (IAWQ) yayınlarında toplanarak aktif çamur model 1 (ASM1) formülize edilmiştir. Bu çalışma gelecek yıllarda yapılan çalışmalara da (ASM2 ve ASM3) temel niteliğindedir.

3.1 Deterministik ASM1, ASM2 ve ASM3 Modelleri

Henze ve diğer bilim adamları, aktif çamur proseslerinin matematik modellenmesi üzerine çalışmışlardır ve 1987 yılında IAWQ Activated Sludge Model 1 (ASM1) ismiyle bir model yayınlamışlardır. Bu model aktif çamurda, heterotrof mikroorganizmaların aerobik ve anoksik büyümesi, ototrof mikroorganizmaların aerobik büyümesi, heterotrof ve ototrof mikroorganizmaların ölümleri ve organik madde ve organik azotun hidrolizi proseslerini içerir.


Bu model, tanımlanmış proses öğeleri ve proses hızı ile ilişkilendirilmiş kinetik ve stokiyometrik katsayıları içeren ifadelerle Çizelge 3.1'de verilmiştir. Bütün öğeler kimyasal oksijen ihtiyacı (KOİ) biriminden ifade edilmiştir.

ASM1 ilk olarak aktif çamur prosesinde oksijen ve azotun elektron alıcı olarak kabul edildiği, atık su arıtma tesislerinde ki organik bileşiklerin ve azotun arıtılması üzerinde geliştirilmiştir. Organik madde konsantrasyonunun ölçülmesi için KOİ seçilmiştir. Modelde, organik karbon bileşikleri ve azot bileşikleri, biyolojik olarak parçalanabilirlikleri ve çözünübilirlikleri üzerinde fraksiyonlarına ayrılmaktadır (Gernaey vd.,2004).

Çizelge 3.1 Aktif çamur model no 1 (ASM1) matrisi (Henze vd.,1987)

Parametre →	S_I	S_S	X_I	X_S	X_{BH}	X_{BA}	X_P	S_O	S_{NO}	S_{NH}	S_{ND}	X_{ND}	S_{ALK}	Proses Hızı (P_j)
Proses														
1.Heterotrofik biyokütlein aerobik büyümesi		$-\frac{1}{Y_H}$			1			$\frac{1-Y_H}{Y_H}$		$-i_{XB}$			$-\frac{i_{XB}}{14}$	$\mu_{maxH} \frac{S_S}{K_S + S_S} \frac{S_O}{K_{OH} + S_O} X_{BH}$
2.Heterotrofik biyokütlein anoksik büyümesi		$-\frac{1}{Y_H}$			1					$-i_{XB}$			$\frac{1-Y_H}{14 \cdot 2.86 Y_H}$ $-\frac{i_{XB}}{14}$	$\eta_g \mu_{maxH} \frac{S_S}{K_S + S_S} \frac{K_{OH}}{K_{OH} + S_O}$ $\frac{S_{NO}}{K_{NO} + S_{NO}} X_{BH}$
3.Ötotrofik biyokütlein aerobik büyümesi						1		$-\frac{4.57 - Y_A}{Y_A}$	$-\frac{1}{Y_A}$	$-i_{XB} - \frac{1}{Y_A}$			$\frac{2}{14 Y_A} \frac{i_{XB}}{14}$	$\mu_{maxA} \frac{S_{NH}}{K_{NH} + S_{NH}} \frac{S_O}{K_{OA} + S_O} X_{BA}$
4.Heterotrofik biyokütlein ayrışması				$1-f_p$	-1		f_p					$i_{XB} - f_p i_{XB}$		$b_H X_{BH}$
5.Ötotrofik biyokütlein ayrışması				$1-f_p$		-1	f_p					$i_{XB} - f_p i_{XB}$		$b_A X_{BA}$
6.Çözünbilir organik azotun nitrifikasyonu										1	-1		$\frac{1}{14}$	$k_a S_{ND} X_{BH}$
7.Yavaş parçalanabilen biyokütlein hidrolizi		1		-1										$k_h \frac{X_S / X_{BH}}{K_X + X_S / X_{BH}} X_{BH}$ $\left[\frac{S_O}{K_{OH} + S_O} + \eta_h \frac{K_{OH}}{K_{OH} + S_O} \frac{S_{NO}}{K_{NO} + S_{NO}} \right]$
8.Organik azotun hidrolizi											1	-1		$\rho_7 (X_{ND} / X_S)$


Temel olarak ASM1 modeli 8 proses ve 13 parametreden oluşur (Henze vd.,1987). Bütün öğeler, çözünebilir olanlar (S) ve partiküler olanlar (X) şeklinde iki sınıfa ayrılmıştır. Aktif çamur içinde bulunun organik içerik, özellikle de organik karbon, biyolojik olarak parçalanabilirlik durumu ve biokütlede ki durumuna göre Şekil 3.1’de gösterilmiştir. Biyolojik olarak parçalanabilen organik içerik ise ileride hızlı ve yavaş parçalanabilir olarak 2 kısma ayrılacaktır. Hızlı biyolojik olarak parçalanabilen içerik, mikroorganizma tarafından enerji ve sentez için kullanılan substrat olarak, yavaş biyolojik olarak parçalanabilen içerik ise kompleks substrat olarak tanımlanmaktadır (Grady vd.,1999).



Şekil 3.1 Organik karbonun atık su içinde ki karakterizasyonu (Jeppson vd., 1993, Petersen vd., 2003)

Aktif biokütle heterotrofik ve ototrofik olarak ikiye ayrılır. Nütrientlerin atık su ortamından uzaklaştırılması için, denitrifikasyon yapamayan heterotroflar, yapabilen heterotroflar ve nitrifikasyon gerçekleştirebilen ototroflar olarak önemli 3 farklı mikroorganizma grubu tanımlanmıştır (Henze vd.,1992).

Toplam Khejdal azotunun (TKN) tespiti için Şekil 3.2’de, atık su içindeki azotlu bileşikler, amonyak, organik azot ve aktif biokütlede ki azot olarak 3 gruba ayrıldığı gösterilmektedir.



Şekil 3.2 Azotlu bileşikler atık su içindeki karakterizasyonu (Jeppson vd., 1993)

ASM 1 için temel teşkil eden, atık su arıtma tesislerinde ki 8 dinamik prosesin açıklaması aşağıda yapılmıştır.

1. Heterotrofların aerobik büyümesi : Organik içeriğin giderilmesi ve yeni hücrelerin oluşmasında temel etkindir. Hücreler, enerji ihtiyacı için hızlı parçalanabilen substratı tüketir. Bu proses alkaliniteadaki değişimle ilişkilendirilir.
2. Heterotrofların anoksik büyümesi : Bazı heterotrofik mikroorganizmalar, oksijen eksikliğinde, elektron alıcı olarak nitratı, substrat olarak ta çözünmüş biyolojik olarak parçalanabilir maddeleri kullanabilir. Bu proses heterotrofik biokütle oluşumunu ve denitrifikasyonu kontrol eder.
3. Ototrofların aerobik büyümesi : Nitrifikasyon ile amonyak nitrata dönüşür. Ototrofik mikroorganizma sayısı ve oksijen ihtiyacı artar. Amonyak hücre sentezinde azot kaynağı olarak kullanılır. Bu proses alkaliniteye etki eder.
4. Heterotrofların etkinliğinin zayıflaması : Bu safhada mikroorganizma faaliyeti azalır ve ölümler gerçekleşir. Hiçbir organik madde kullanılmaz ve elektron alıcısı yoktur.
5. Ototrofların etkinliğinin zayıflaması : Bu proseste, heterotrofların etkinliğinin azalmasında ki gibi işler.

6. Çözünmüş organik azotun amonyağa dönüşmesi : Biyolojik olarak parçalanabilen organik azot, aktif heterotroflarla amonyağa dönüştürülür. Proseste hidrojen iyonu tüketilmesi nedeniyle alkalinite değişir.
7. Partikül organik maddenin hidrolizi : Bu proses yavaş biyolojik olarak parçalanabilen organik maddenin, hızlı parçalanabilen organik maddelere dönüşümü prosesidir. Anoksik şartlarda, bir düzeltme faktörü katsayısı (n_h) ile hidroliz hızında ki azalma tanımlanmıştır. Bu durumda anaerobik ortamda hidroliz hızı sıfır olarak kabul edilmektedir.
8. Partikül organik azotun hidrolizi : Son proses, partikül organik azotun (X_{NS}), çözünmüş, biyolojik olarak parçalanabilir organik azota (S_{NS}) dönüşmesi prosesidir. Bu hız yavaş biyolojik olarak parçalanabilir organik maddenin hidroliz hızının bir parçası olarak kabul edilir.

ASM 1 modelindeki 13 farklı prosese ait parametrenin sembolleri, birim ve tipik değerleri Çizelge 3.2’de gösterilmiştir. Bu model parametrelerinin değerlerini bulabilmek için iki farklı yol izlenebilir. Birincisi, deneyler ile elde edilen doğrudan ölçüm sonuçlarıdır ki birçok çalışma deney tasarımlarını bu prosedür ile oluşturmuştur (Kabouris vd.,1996, Grady vd.,1999). Diğer bir yöntem ise, arıtma tesisine özel ASM1 parametrelerinin kalibrasyonunu oluşturmaktır. En uygun model sonuçları ise, simüle edilmiş sonuçların ve gerçek ölçüm sonuçlarının karşılaştırmalı performansları izlenerek oluşturulabilir (Daigger vd., 1995, Melcer, 1999).

Biyolojik fosfor giderimini içeren ilk model ASM2 modelidir (Henze vd.,1995). Bu model ve ASM1 deki prosesler, geliştirilerek biyolojik fosfor giderimini de tanımlanmıştır. Yine kimyasal fosfor giderimi de çökeltme ile ASM2 içinde tanımlanmıştır. Model henüz biyolojik fosfor giderimini tam olarak içermemektedir (Gernaey vd., 2004). Yinede ASM2, proses dinamiklerinin anlaşılmasında karmaşık gibi görünse de, başarılı bir model kabul edilmektedir. 17 hız denklemi, 17 değişken ve 46 stokiyometrik ve kinetik parametre içermektedir. Sonuç olarak ASM2, gerçekte ölçümü zor olan bazı proses kinetiklerinin tespitinde ve modellerin kalibrasyonunda oldukça başarılı kabul edilmiştir (Henze vd.,1995).


Biyolojik azot giderimi, ilk olarak ASM3 modeli ile tanımlanmıştır. ASM3 modeli, ASM2 modelinde ki gibi ASM1 modeli geliştirilerek oluşturulmuştur.

Çizelge 3.2 Nötr pH'da, 10° ve 20° C de evsel atıksu arıtma tesisleri için tipik ASM1 stokiyometrik – kinetik parametre değerleri (Henze vd., 1986, Grady vd., 1999)

Sembol	Tanımı	Birimi	ASM 1 Modelindeki Tipik Değeri	
Stokiyometrik katsayılar			20 °C	10 °C
Y_H	Heterotforların azalması	Oluşan mg KOİ / giderilen mg KOİ	0.67	0.67
f_D	Çökelmeye neden olan biokütle	mg Çökelen KOİ / mg Biokütle KOİ	0.08	0.08
$I_{N/XB}$	Biokütlede KOİ başına içerilen N oranı	mg N / aktif biokütledeki mg KOİ	0.086	0.086
$I_{N/XD}$	Çökeltide KOİ başına içerilen N oranı	mg N / aktif çökeltideki mg KOİ	0.06	0.06
Y_A	Ototrofların azalması	Oluşan mg KOİ / oksitlenmiş mg N	0.24	0.24
Kinetik katsayılar			20 °C	10 °C
μ_H	Heterotroflar için maksimum büyüme hızı	sa ⁻¹	0.25	0.125
K_S	Heterotroflar için yarı doygunluk oranı	mg / L (KOİ)	20.0	20.0
K_{OH}	Heterotroflar için Oksijen yarı doygunluk oranı	mg / L (O ₂)	0.20	0.20
K_{NO}	Heterotroflar için Nitrat yarı doygunluk oranı	mg / L (N)	0.50	0.50
b_{LH}	Heterotroflar için çökeltme katsayısı	sa ⁻¹	0.026	0.0083
η_g	Anoksik biokütle oluşması koşullarında μ_H için düzeltme faktörü	Birimsiz	0.8	0.8
η_h	Anoksik hidroliz için düzeltme faktörü	Birimsiz	0.4	0.4
k_a	Amonyak oluşum hızı	L / mg biokütle. sa	0.0033	0.0017
k_h	Maksimum spesifik hidroliz hızı	mg KOİ / mg biokütle.sa	0.125	0.042
K_x	Yavaş parçalanabilir substratın hidrolizi için yarılanma hızı	mg KOİ / mg biokütle	0.03	0.01
μ_A	Ototroflar için maksimum büyüme hızı	sa ⁻¹	0.033	0.013
K_{NH}	Ototroflar için amonyak azotunun yarılanma hızı	mg / L (N)	1.0	1.0
K_{OA}	Ototroflar için oksijen yarılanma hızı	mg / L (O ₂)	0.4	0.4
b_{LA}	Ototroflar için çökeltme katsayısı	sa ⁻¹	0.005	0.005

Çizelge incelendiğinde, tüm stokiyometrik parametrelerin değerleri, sıcaklığa bağlı olarak değişim göstermemektedir. Buna rağmen, bazı kinetik parametreler sıcaklığa bağlı olarak değişmektedir.

Yukarıda belirtilen aralıklar dâhilinde bu çalışmada modellenen ASM1 yazılımında, μ_H , b_{LH} , k_a , k_h , K_x , ve μ_A katsayılarına belirtilen aralıklarda değerler verilmiştir. Elde edilen bulgular, bu çalışmanın sonuçlar bölümünde anlatılmıştır.



Şekil 3.3 Tuzla atıksu arıtma tesisi, 2007 yılı tesis giriş-çıkış sıcaklık değişim grafiği

3.2 İstatistiksel Teoriler ve Metotlar

3.2.1 Monte Carlo Metodu

Monte Carlo (MC) metodu, olası mümkün sonuçları, bir grup tesadüfi değişkenler yardımıyla, bir prosesi simüle ederek, bunu zamanın değişik periyotlarında defalarca tekrarlayarak ve sonuçları analiz ederek tespit eden istatistiksel bir metottur. MC analizi bu çalışmada, yapay sinir ağında kullanılacak verileri değerlendirmek ve arıtma tesisinde beklenmedik durumları karakterize etmek için kullanılmıştır. Çalışmada tesadüfen seçili veriler altında hem modeldeki beklenmedik durumlar tahmin edilmeye çalışılmış hem de buna giriş faktörlerinin etkisi araştırılmıştır. Beklenmedik durumlar analiz metotlarından diğerlerine göre MC metodu daha basit ve anlaşılması daha kolay bir metottur.

Monte Carlo metodu, sistem çıkışlarının beklenmedik durum analizlerinde ve sistem girişlerinin duyarlılığının, model parametrelerinin ve dizayn, işletme parametrelerinin analizinde sık kullanılan bir metottur. Literatürde, atık su arıtma tesislerinin verimliliğini değerlendiren bazı çalışmalar yer almaktadır. MC metodu ile yapılmış bir çalışmada termodinamik dataların, kimyasal proses dizaynı ve simülasyonu üzerine beklenmedik durumlarının etkisi incelenmiştir (Vasquez vd.,1999). Bu etkiler, dörtgensel olasılık dağılımları olan sistematik hatalar ve normal olasılık dağılımları olan tesadüfi hatalar olarak tanımlanmıştır. Dörtgensel olasılık, fonksiyonun verilen aralıklarda tüm değerlerini kapsayacak şekilde tanımlanan bir dikdörtgendir.

MC metodunun potansiyel kullanım alanları arasında güvenlik faktörü belirlenmesi, proses model optimizasyonu ve deneysel dizayn yer almaktadır. Başka bir çalışmada, tam ölçekli bir oksidasyon hendeğine MC metodu uygulanmıştır (Abusam vd., 2002). Oksidasyon hendeğinin arıtma tesisi içinde gözlemlenen beklenmedik durumları, giriş parametresi değerlerini, giriş yüklerini, önceki durumların değerlerini, simülasyon modellerini ve su sıcaklığının mevsimler değişimini kapsamaktadır. Yapılan çalışmalar neticesinde, giriş yüklerinde ki ve parametrelerinin değerlerinde ki beklenmedik durumlar, arıtma tesislerinde ki performans sapmalarını etkileyen en önemli faktörler arasında göstermektedir.

Başka bir çalışmada, ASM1 modeli üzerine MC simülasyonu uygulanmıştır (Rousseau vd., 2001). Bu çalışmada 300 MC simülasyonu çalıştırılmıştır. Parametreler, üçgensel veya düzleştirilmiş normal dağılımlar olarak kabul edilmiştir. Genellikle, 300 çalışma kabul edilebilir bir çalışma için az bir sayı olduğu öngörülmektedir (Huo J.,2005).

GPS-X ismiyle bilinen aktif çamur prosesi modelleme yazılımı ile ASM1 modeline MC simülasyonu uygulanmıştır (Magbanua, 2004). Çalışmada katı bekletme süresinin arttırılması ile beklenmedik durumların azaltılabileceği öngörülmüştür. Ayrıca hidrolik bekleme süresinin, tesis performansındaki beklenmedik durumlara etkisinde önemli bir rol oynamadığı gözlemlenmiştir.

3.2.2 Bayesian Metodu

Bayesian metodu, belirsizlik taşıyan herhangi bir durumun modelinin oluşturularak, bu durumla ilgili evrensel doğrular ve gerçekçi gözlemler ışığında belli sonuçlar üretilmesini sağlar. Genel olarak (3.1) ifadesindeki gibi formüle edilir.

$$\pi(\theta|x) = \frac{L(\theta|x) \times \pi(\theta)}{\int [L(\theta|x) \times \pi(\theta)] d\theta} \quad (3.1)$$

Burada;

$\Pi(\theta x)$	=	θ parametresinin, x örnekleri üretilmiş modeli,
$L(\theta x)$	=	olasılık fonksiyonu,
$\Pi(\theta)$	=	geçmiş olasılıkların yoğunluk fonksiyonu,
$\int [L(\theta x) \times \pi(\theta)] d\theta$	=	normalleştirme faktörü veya sabit olarak tanımlanır.

İlgili parametreler için uygun geçmiş dağılımları seçmek, bayesian metodunun bir zorluğudur. Bu nedenle literatürde sıklıkla kullanılan, 3 farklı geçmiş dağılım yolu izlendiği görülmektedir.

- Herhangi bir boyutta ve herhangi bir değerdeki gözlem için aynı standart dağılım ailesine ait, doğal öncelikli çiftler. Bunlar; kullanılabilir öncelikleri, referans önceliklerini ve bilgisel öncelikleri kapsar.

- Parametre hakkında az veya hiçbir bilgi olmayan belirsiz öncelikler. Genellikle uygunsuz öncelikler veya bilgisel olmayan öncelikler olarak tanımlanır.
- Son seçenek, veri tabanlı önceliklerdir. Yayınlanmış veya ölçülmüş kaynakları içerir.

Bayesian metodu, mevcut veriler ışığında daha tutarlı parametre dağılımlarının oluşturulmasında genellikle kullanılan bir yöntemdir. Basit normal dağılımlar üreten varyans veya ortalama analizlerinden ziyade bayesian metodu, farklı potansiyel dağılımlar arasından en uygun olanını seçer ve bulur.

3.2.3 Zaman serisi modeller

Zaman değişkeniyle ilişkili bir değişken hakkında, elde edilen gözlem değerlerini zamana göre sıralanmış olarak gösteren serilere, “zaman serisi” denir. Bu tanım genel bir tanımdır. Zaman serilerini konu alan pek çok çalışmada, serilerin gözlem değerlerinin eşit aralıklı zaman noktalarında elde edilmiş olduğu görülmektedir. Eşit aralıklı zaman noktaları (başka bir ifadeyle zaman değişkeninin sıkları), günler (günlük hava sıcaklığında olduğu gibi), aylar (aylık satış miktarlarında olduğu gibi) ve yıllar (yıllık ihracat tutarlarında olduğu gibi) olabilir. Zaman serisi çözümlemelerinde zaman değişkeninin sıkları genellikle $t = 1, 2, \dots, n$ ile ifade edilmektedir. Buna göre bir zaman serisi, eşit aralıklı $t = 1, 2, \dots, n$ zaman noktalarında Y değişkeniyle ilgili elde edilen $y_1, y_2, \dots, y_t, \dots, y_n$ gözlem değerlerini zamana göre sıralanmış olarak gösteren seri olarak tanımlanır.

Zaman serisi modeller iki kategoriye ayrılır. Birincisi diğer farklı değişkenlerden etkilenmeyen, değişkenin sadece zamanın bir fonksiyonu olduğu tek değişkenli zaman serisi modelidir. İkincisi ise değişkenlerin arasından korelasyon bulunan, çok değişkenli zaman serisi modelidir. Tek değişkenli zaman serisi modelleri arasında eksponansiyel sadeleştirme (ES), otomatik regresyon içeren harekeli ortalama (ARIMA) yer alır. Çok değişkenli zaman serisi modelleri arasında ise zaman serilerinin çoklu regresyonu ve dinamik regresyon (DR) yer alır.

Eksponansiyel sadeleştirme (ES) metodu, eksponansiyel ağırlıklı hareketli ortalamaları kapsayan zaman serilerini konu alır. 3 tip ES metodu vardır; basit ES, Holt’un iki parametrelili ES metodu ve Winter’in üç parametrelili ES metodu (De Lurgio, 1998). Basit ES metodu (3.2) eşitliğindeki gibi ifade edilir.

$$F_t = \alpha A_{t-1} + (1 - \alpha)F_{t-1} \quad (3.2)$$

Burada F_t , t periyodu için eksponansiyel olarak sadeleştirilmiş tahmin, A_{t-1} , önceki periyot için gerçek değer, F_{t-1} , önceki periyot için eksponansiyel olarak sadeleştirilmiş tahmin ve α sadeleştirme katsayısıdır.

Winter'in sadeleştirme metodu ise, Holt'un sadeleştirme metodunun bir uzantısıdır. Bu metoda üçüncü bir parametre eklenmesiyle oluşturulmuştur. Bu nedenle bu metot Holt-Winter metodu olarak ta geçmektedir. Bu metot (3.3) eşitliğindeki gibi ifade edilmektedir.

$$Y_{t+1} = (S_t + b_t)I_{t-L+1} + e_{t+1} \quad (3.3)$$

Burada Y_{t+1} , $t+1$ periyodunda ki tahmin, S_t , t süresi sonunda serilerin sezonsal olmayan sadeleştirilmiş ölçüsü, b_t , t periyodu için sadeleştirme trendi, I_{t-L+1} , $t+1$ periyodu için sadeleştirilmiş sezonsal olan indeks ve e_{t+1} , $t+1$ periyodunun hatası olarak ifade edilmektedir.

Zaman serisi modeller atıksu arıtma tesislerinin performanslarının değerlendirilmesinde kullanılmıştır. Yapılan bir çalışmada 1-5 günlük bir periyotta bir atıksu arıtma tesisinden çıkan arıtılmış suyun tahmin modellemesi yapılmıştır. Bu modelde biyolojik oksijen ihtiyacı (BOİ) ve askıda katı madde (SS) konsantrasyonu izlenmiştir. Eksponansiyel ağırlıklı hareketli ortalama formunda olan bu zaman serisi modeli, log transform bağımlı ve bağımsız değişkenler arasındaki birincil farkına odaklı bir modeldir. Bu model, çıkış suyundaki değişimleri, hareketli ortalamanın mevcut düzeyi ile ilgili olarak yorumlar ve bu değişimin bağımsız değişkenlerin hareketli ortalaması ve mevcut düzeyi arasında ki farkın lineer bir fonksiyonu olduğunu söylemektedir (Berthouex vd.,1996).

4. YAPAY SİNİR AĞLARI VE MATEMATİKSEL MODELLEME

Beynin üstün özellikleri, bilim adamlarını üzerinde çalışmaya zorlamış ve beyin nöröfiziksel yapısından esinlenerek matematiksel modeli çıkarılmaya çalışılmıştır. Beynin bütün davranışlarını tam olarak modelleyebilmek için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesi ile çeşitli yapay hücre ve ağ modelleri geliştirilmiştir. Böylece Yapay Sinir Ağları (YSA) olarak adlandırılan, yeni ve günümüz bilgisayarlarının algoritmik hesaplama yönteminden farklı bir bilim alanı ortaya çıkmıştır. Yapay sinir ağları; yapısı, bilgi işleme yöntemindeki farklılık ve uygulama alanları nedeniyle çeşitli bilim dallarının da kapsam alanına girmektedir.


Genel anlamda YSA, beyin bir işlevi yerine getirme yöntemini modellemek için tasarlanan bir sistem olarak tanımlanabilir. YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasından oluşur ve genellikle katmanlar şeklinde düzenlenir. Donanım olarak elektronik devrelerle yada bilgisayarlarda yazılım olarak gerçekleştirilebilir. Beynin bilgi işleme yöntemine uygun olarak YSA, bir öğrenme sürecinden sonra bilgiyi toplama, hücreler arasındaki bağlantı ağırlıkları ile bu bilgiyi saklama ve genelleme yeteneğine sahip paralel dağılmış bir işlemcidir. Öğrenme süreci, arzu edilen amaca ulaşmak için YSA ağırlıklarının yenilenmesini sağlayan öğrenme algoritmalarını ihtiva eder.

Sinir ağları (Şekil 4.1), nöron ismi verilen hesaplama elemanlarının paralel bir şekilde çalışmasından meydana gelir. Bu elemanlar biyolojik sinir sistemlerinden esinlenerek tasarlanmıştır. Belirli bir fonksiyonu gerçekleştirmek için bir sinir ağını, elemanlar arasındaki bağlantıların (ağırlıkların) değerlerini ayarlayarak eğitebiliriz.



Şekil 4.1 Tipik yapay sinir ağı (YSA) yapısı

Basit bir yapay nöron, bir ya da birden çok skaler girişe ve bir çıkışa sahip olan bir hesaplama elemanıdır. Tek girişli nöron modeli Şekil 4.2 de verilmiştir.



Şekil 4.2 Tek girişli nöron modeli

Burada, p : nöronun girişi olan skaler değeri, w : p girişi ile nöron arasındaki ağırlık değerini, b : nöronun bias değerini, f : transfer fonksiyonunu, a : nöronun çıkışını belirtmektedir. p girişi önce w ağırlığı ile çarpılır. Ardından b bias değeri ile toplanır ve transfer fonksiyonundan geçirilerek a çıkışı hesaplanır. Transfer fonksiyonu doğrusal ya da doğrusal olmayan türevlenebilir bir fonksiyondur. İşte bu basit nöron modelinde, giriş ile çıkış arasında basit bir matematiksel bağıntı kurulmuştur. Fakat nöronun arzu edilen çıkışı verebilmesi için w ve b ağırlık değerlerinin optimum olacak şekilde ayarlanması gerekmektedir.

Genelde, sinir ağları eğitilerek belirli bir girişe karşılık verilen arzu edilen çıkışı elde ederler. Bu durum aşağıdaki şekilde verilmiştir. Ağın çıkışı arzu edilen hedefe ulaşıncaya kadar çıkış ile hedef karşılaştırılarak ağın eğitimi (ağırlık değerlerinin ayarlanması) gerçekleştirilir. En basit tanımıyla yapay sinir ağları, bilinen en iyi eğri uydurma tekniklerinden birisidir.

YSA' nın hesaplama ve bilgi işleme gücünü, paralel dağılmış yapısından, öğrenebilme ve genelleme yeteneğinden aldığı söylenebilir. Genelleme, eğitim yada öğrenme sürecinde karşılaşılmayan girişler için de YSA' nın uygun tepkileri üretmesi olarak tanımlanır. Bu üstün özellikleri, YSA' nın karmaşık problemleri çözebilme yeteneğini gösterir. Günümüzde birçok bilim alanında YSA, aşağıdaki özellikleri nedeniyle etkin olmuş ve uygulama yeri bulmuştur (H. Demuth, vd., 2006). Yapay sinir ağlarının başlıca özellikleri şunlardır.

- Doğrusal Olmama

YSA' nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur.

- Öğrenme

YSA' nın arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. YSA' nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez yada tasarlanamaz. Bu nedenle YSA, istenen davranışı gösterecek şekilde ilgilendiği problemde aldığı eğitim örneklerini kullanarak problemi öğrenmelidir.

- Genelleme

YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakterleri verebilir yada bir sistemin eğitilmiş YSA modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir.

- Uyarlanabilirlik

YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.

- Hata Toleransı

YSA, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağıdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA nın bazı bağlantılarının hatta bazı

hücrelerinin etkisiz hale gelmesi, ağın doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.

- Donanım ve Hız

YSA, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda arzu edilir.

- Analiz ve Tasarım Kolaylığı

YSA'nın temel işlem elemanı olan hücrenin yapısı ve modeli, bütün YSA yapılarında yaklaşık aynıdır. Dolayısıyla, YSA'nın farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan YSA'ları benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin YSA ile çözümünde önemli bir kolaylık getirmektedir (G.Dreyfus,2005).

4.1 Yapay Sinir Ağlarının Kullanım Alanları

Son yıllarda YSA'ları, özellikle günümüze kadar çözümü güç ve karmaşık olan ya da ekonomik olmayan çok farklı alanlardaki problemlerin çözümüne uygulanmış ve genellikle başarılı sonuçlar alınabilmektedir. YSA'ları çok farklı alanlara uygulanabildiğinden bütün uygulama alanlarını burada sıralamak zor olmakla birlikte genel bir sınıflandırma ile YSA'nın uygulama alanları aşağıdaki gibi 6 grup içerisinde toplanabilir.

- Arıza Analizi ve Tespiti

Bir sistemin, cihazın ya da elemanın düzenli (doğru) çalışma şeklini öğrenen bir YSA yardımıyla bu sistemlerde meydana gelebilecek arızaların tanımlanma olanağı vardır. Bu amaçla YSA; elektrik makinelerinin, uçakların ya da bileşenlerinin, entegre devrelerin v.s. arıza analizinde kullanılmıştır.

- Tıp Alanında

EEG ve ECG gibi tıbbi sinyallerin analizi, kanserli hücrelerin analizi, protez tasarımı, transplantasyon zamanlarının optimizasyonu ve hastanelerde giderlerin optimizasyonu v.s gibi uygulama yeri bulmuştur.

- Savunma Sanayi

Silahların otomasyonu ve hedef izleme, nesneleri/görüntüleri ayırma ve tanıma, yeni algılayıcı tasarımı ve gürültü önleme v.s gibi alanlara uygulanmıştır.

- Haberleşme

Görüntü ve veri sıkıştırma, otomatik bilgi sunma servisleri, konuşmaların gerçek zamanda çevirisi v.s gibi alanlarda uygulama örnekleri vardır.

- Üretim

Üretim sistemlerinin optimizasyonu, ürün analizi ve tasarımı, ürünlerin (entegre, kağıt, kaynak v.s.) kalite analizi ve kontrolü, planlama ve yönetim analizi v.s. alanlarına uygulanmıştır.

- Otomasyon ve Kontrol

Uçaklarda otomatik pilot sistemi otomasyonu, ulaşım araçlarında otomatik yol bulma/gösterme, robot sistemlerin kontrolü, doğrusal olmayan sistem modelleme ve kontrolü, elektrikli sürücü sistemlerin kontrolü v.s. gibi yaygın bir uygulama yeri bulmuştur.


4.2 Dinamik Hücre Modelleri

Yapay hücre modeli, x girişlerinden y çıkışlarına doğrusal olmayan statik bir dönüşümü gerçekleştirir. Görüntü tanıma ve sınıflandırma uygulamalarında statik hücre yada YSA modelleri uygun olmakla birlikte sistem modelleme ve denetimi gibi dinamik problemlerin çözümünde dinamik hücre yada YSA yapılarının kullanılması gereklidir. Dinamik YSA yapıları çeşitli şekillerde elde edilebilir. Ancak, dinamik bir hücre genel olarak 2 şekilde oluşturulabilir.

a-) Hücrenin ağırlıkları dinamik bir model (bir filtre) olarak seçilebilir.

b-) Hücrenin net girdisi dinamik bir modelden (bir filtre) geçirilebilir.

Filtre ağırlıklı dinamik (FIR) hücre modelinde, hücre ağırlıkları sabit seçilmek yerine bir filtre olarak modellenerek hücrenin dinamik davranışı sağlanabilir. Böylece, herhangi bir ağırlığın dinamik davranışı, zamanın bir fonksiyonu olan ani darbe cevabı ile tanımlanabilir. Her bir hücre ağırlığının FIR filtre olarak modellendiği ayrık zamanlı hücre yapısı Şekil 4.3’de verilmiştir.




Şekil 4.3 FIR filtre ağırlıklı dinamik hücre modeli

Şekil 4.3 de verilen dinamik hücrenin matematiksel modeli denklem 4.1 deki gibi yazılabilir.


$$y(k) = \sum_{i=1}^n \sum_{j=1}^L W_j(L) \cdot x_i(k-L) + b \quad (4.1)$$

Burada L- filtrenin sonlu bellek (gecikme) sayısı olarak tanımlanır ve ağırlıkların gerçekleştirdiği işlevler, sadece birinci hücre girişi için ayrık zamanda Şekil 4.4’de verilen blok şema ile gösterilebilir.



Şekil 4.4 FIR filtre olarak tasarlanan ağırlıklar

RC-Dinamik Hücre Modelinde, diğer bir dinamik hücre modeli, ağırlıkların dinamik bir model olarak seçilmesi yerine hücrenin net girdisinin doğrusal bir dinamik modelden (filtreden) geçirildiği hücre modelidir. Filtrenin seçimi farklı olabilmekle birlikte genellikle birinci dereceden bir filtre (RC filtre) kullanılır. Bu durumda filtrenin ani darbe cevabı $h_0(k)$ ya göre hücre modeli Şekil 4.5’de ki gibi çizilebilir (D.Graupe, 2007).




Şekil 4.5 RC- dinamik bir hücre modeli

4.3 Yapay Sinir Ağı Çeşitleri

Yapay sinir ağları, hücrelerin birbirleri ile çeşitli şekillerde bağlanmalarından oluşur. Hücre çıkışları, ağırlıklar üzerinden diğer hücrelere ya da kendisine giriş olarak bağlanabilir ve bağlantılarda gecikme birimi de kullanılabilir. Hücrelerin bağlantı şekillerine, öğrenme kurallarına ve aktivasyon fonksiyonlarına göre çeşitli YSA yapıları geliştirilmiştir. Bu bölümde, çeşitli problemlerin çözümünde kullanılan ve kabul görmüş bazı YSA yapıları ayrıntısına girmeksizin genel özellikleri ile tanıtılacaktır.

4.3.1 İleri Beslemeli Yapay Sinir Ağları (İBYSA)

İleri beslemeli YSA' da, hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan orta (gizli) katmandaki hücelere iletir. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir. Bu yapısı ile ileri beslemeli ağlar doğrusal olmayan statik bir işlevi gerçekleştirir. İleri beslemeli 3 katmanlı YSA' nın, orta katmanında yeterli sayıda hücre olmak kaydıyla, herhangi bir sürekli fonksiyonu istenilen doğrulukta yaklaştırabileceği gösterilmiştir. En çok bilinen geriye yayılım öğrenme algoritması, bu tip YSA'ların eğitiminde etkin olarak kullanılmakta ve bazen bu ağlara geriye yayılım ağları da denmektedir. Şekil 4.6'da giriş, orta ve çıkış katmanı olmak üzere 3 katmanlı ileri beslemeli YSA yapısı verilmiştir (Matlab, 2006).




Şekil 4.6 İleri beslemeli 3 katmanlı YSA.

Herhangi bir problemi çözmek amacıyla kullanılan YSA da, katman sayısı ve orta katmandaki hücre sayısı gibi kesin belirlenememiş bilgilere rağmen nesne tanıma ve sinyal işleme gibi alanların yanı sıra ileri beslemeli YSA, sistemlerin tanınması ve denetiminde de yaygın olarak kullanılmaktadır.

4.3.2 Geri Beslemeli Yapay Sinir Ağları (GBYSA)

Geri beslemeli YSA' da, en az bir hücrenin çıkışı kendisine ya da diğer hücelere giriş olarak verilir ve genellikle geri besleme bir geciktirme elemanı üzerinden yapılır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu yapısı ile geri beslemeli YSA , doğrusal olmayan dinamik bir davranış gösterir. Dolayısıyla, geri beslemenin yapılış şekline göre farklı yapıda ve davranışta geri beslemeli YSA yapıları elde edilebilir. Bu nedenle, bu bölümde bazı geri beslemeli YSA yapılarında örnekler verilecektir. Şekil 4.7'de iki katmanlı ve çıkışlarından giriş katmanına geri beslemeli bir YSA yapısı görülmektedir (Matlab, 2006).




Şekil 4.7 Geri Beslemeli İki Katmanlı YSA.

Şekil 4.7'de verilen geri beslemeli YSA da giriş vektörü, r adet dış giriş ve p adet gecikmiş ağ çıkışlarından oluşmaktadır. Buna göre YSA' nın giriş vektörü aşağıdaki gibi yazılabilir.

Geri beslemeli YSA'ları; hücreler arası ya da katmanlar arası geri besleme yapılış şekline göre farklı isimlerle adlandırılır. Genellikle derecesi bilinmeyen dinamik sistemlerin tanımlanmasında kullanılan diğer bir YSA yapısı, gizli katman hücrelerinde öz geri beslemenin


kullanıldığı ve yöresel geri-küresel ileri beslemeli (YGKI) olarak söylenen Şekil 4.8’de verilen YSA’dır.



Şekil 4.8 YGKI yapay sinir ağı.

4.3.3 Bellek Hücreli YSA Yapıları (BHYSYA)

Doğrusal olmayan sistemlerin tanınması ve denetiminde, katmanlı YSA yapıları etkin olarak kullanılmaktadır. YSA ile sistem tanımlamada, doğru model yapısının seçilebilmesi ve model girişlerinin belirlenebilmesi için sistemin giriş ve çıkışının gecikme derecelerinin bilinmesi gerekir. Sistemin derecesinin doğru belirlenememesi, modelde temsil edilemeyen dinamikler nedeniyle kararlı ve değişen dinamik şartlarda doğru bir model elde edilmesini etkiler. Bu nedenle, geri beslemeli YSA yapıları kullanılarak sistemin derecesine ihtiyaç duymayan tanı modelleri geliştirilmiştir. Şekil 4.9’da Bellek Hücreli Yapay Sinir Ağları (BHYSYA) olarak söylenen ve ağdaki her bir hücre için bir bellek hücresinin kullanıldığı katmanlı-geri beslemeli bir ağ yapısı verilmiştir.



Şekil 4.9 Bellek hücreli yapay sinir ağı ve bellekli bir hücrenin yapısı.

BHYSAN’ da her bir ağı hücrelerine ait olan bellek hücresi, bir ağırlık (b_j) üzerinden öz geri besleme girişine ve başka bir ağırlık üzerinden (a_j) ait olduğu hücrenin gecikmiş girişine göre bir çıkış üretir. Çıkış katmanında ise genellikle sadece öz geri besleme kullanılır. Buna göre BHYSAN’ ın matematiksel ifadesi aşağıdaki gibi yazılabilir (Matlab, 2006).

$$x_i^b(k) = w_j^a x_i(k-1) + w_j^b x_i^b(k-1) \quad (4.2)$$

$$v_j(k) = \sum_{i=1}^a \{W_j^a x_i(k) + W_j^b x_i^b(k)\} \quad (4.3)$$

$$o_j(k) = \varphi(v_j(k)) \quad (4.4)$$


$$o_j^b(k) = \theta_j^a o_j(k-1) + \theta_j^b o_j^b(k-1) \quad (4.5)$$

$$y(k) = \sum_{j=1}^a \{\theta_j^a o_j(k) + \theta_j^b o_j^b(k)\} + \theta y(k-1) \quad (4.6)$$

BHYSAN’ ın doğrusal olmayan bir sistemi modelleme ve denetim yeteneği, sadece sistemin o an ki giriş ve bir önceki çıkış verileri model girişi alınarak incelenmiş ve tatmin edici sonuçlar alındığı gösterilmiştir. İleri beslemeli katmanlı YSA’ nın sadece gizli katmanında bellek hücreleri kullanılarak bellek hücresinin, ait olduğu hücre çıkışının geçmişteki örneklerini giriş olarak aldığı ve zaman gecikmeli YSA olarak söylenen geri beslemeli ağı yapıları da incelenmiştir.

4.3.4 Radyal Tabanlı Fonksiyon Ağları (RTFA)

Katmanlı YSA' nın tasarımında eğitici geriye yayılım öğrenme algoritması bir en iyileme uygulamasıdır. Radyal tabanlı fonksiyon ağı tasarımı ise çok boyutlu uzayda eğri uydurma yaklaşımıdır ve bu nedenle RTFA' nın eğitimi, çok boyutlu uzayda eğitim verilerine en uygun bir yüzeyi bulma problemine dönüşür. RTFA' nın genellemesi ise test verilerini interpolate etmek amacıyla, eğitim sırasında bulunan çok boyutlu yüzeyin kullanılmasına eşdeğerdir. Radyal tabanlı fonksiyonlar, sayısal analizde çok değişkenli interpolasyon problemlerinin çözümünde kullanılmış ve YSA' nın gelişmesi ile birlikte bu fonksiyonlardan YSA tasarımında yararlanılmıştır. RTFA, ileri beslemeli YSA yapılarına benzer şekilde giriş, orta ve çıkış katmanından oluşur ancak (Şekil 4.10), giriş katmanından orta katmana dönüşüm, radyal tabanlı aktivasyon fonksiyonları ile doğrusal olmayan sabit bir dönüşümdür. Orta katmandan çıkış katmanına ise uyarlamalı ve doğrusal bir dönüşüm gerçekleştirilir.



Şekil. 4.10 Radyal tabanlı fonksiyon ağı

Eğri uydurma teorisi, herhangi birçok değişkenli ve sürekli $f(x)$ fonksiyonunu yaklaştırma ya da interpolate etme problemi ile ilgilidir. İnterpolasyon problemi, $k=1,2,...,N$ için x_k – veri noktası ve d_k -gerçek değerler olmak üzere $F(x_k)=d_k$ interpolasyon koşulunu sağlayan $F()$ fonksiyonunun bulunması olarak tanımlanır. Radyal tabanlı fonksiyonlarla doğrusal $F()$ (4.7) eşitliğindeki gibi tanımlanır (Matlab, 2006).

$$F(x) = \sum_{k=1}^n W_k \phi_k(\|x - x_k\|) \quad (4.7)$$

Burada $\phi(\cdot)$ - doğrusal olmayan radyal tabanlı fonksiyonu, $\|\cdot\|$ - genellikle standart Öklid uzaklığıdır. Bilinen veri noktaları, radyal tabanlı fonksiyonların merkezleri olarak söylenir. RTFA'nın genel yapısında veri örneği kadar orta katman hücrelerine ve ağırlığa gerek duyulduğundan genel çözümü yakınsayan en iyi çözüm aranır. $M < N$ olmak üzere RTFA çıkışı,

$$F(x) = \sum_{i=1}^n W_i \phi_i(\|x - c_i\|) \quad (4.8)$$

Burada c_i – veri noktalarından belirlenecek olan radyal tabanlı fonksiyonların merkez vektörleridir. RTFA'da orta katman aktivasyon fonksiyonu genellikle standart öklit uzaklıklarını üstsel fonksiyondan geçiren gaussian fonksiyonudur ve aşağıdaki gibi tanımlanır.


$$\phi_i(\|x - c_i\|) = e^{-\frac{1}{2}\|x - c_i\|^2} \quad (4.9)$$

RTFA'da uyarlanabilecek serbest parametreler; merkez vektörleri, radyal fonksiyonların genişliği ve çıkış katman ağırlıklarıdır. Çıkış katmanı doğrusal olduğundan ağırlıklar, eğim düşme yada doğrusal en iyileme yöntemleri ile kolayca bulunabilir. Merkezler, girişler arasından rastgele ve sabit olarak seçilebilmekle birlikte RTFA'nın performansını iyileştirmek amacıyla merkez vektörlerinin ve genişliğin uyarlanması için çeşitli yöntemler geliştirilmiştir. Merkez vektörleri, eğim düşme yöntemine göre eğitici öğrenme algoritması ile uyarlanarak, dik en küçük kareler yöntemi ile, yada kendiliğinden düzenlemeli yöntemle giriş örneklerinden öbekleme yapılarak belirlenebilir.

4.3.5 Fonksiyonel Link Ağları (FLA)

Katmanlı YSA, orta katmandaki doğrusal olmayan aktivasyon fonksiyonları nedeniyle doğrusal olmayan öğrenme algoritmaları ile eğitilmelidir. Bu durum, öğrenme hızını yavaşlatır ve fonksiyon yaklaşımında yöresel en aza ulaşılabilir. Bu sorunlar, ağ girişlerini önce doğrusal olmayan bir dönüşümle genişlettikten sonra doğrusal çıkış katmanlı ağ yapıları ile giderilebilir. Şekil 4.11'de verilen ve Fonksiyonel Link Ağları (FLA) olarak bilinen ağlar iyi bir fonksiyon yaklaştırma performansına sahiptir. Bu yönüyle FL ağları, merkezleri ve

genişliği sabit tutulan RTFA' na benzer ancak, FLA' da orta katmanın görevi ve aktivasyon fonksiyonları farklıdır (Matlab, 2006).



Şekil 4.11 Fonksiyonel link ağı


FLA' da ağ çıkışı, orta katmanda genişletilmiş ağ girişlerinin doğrusal toplamıdır ve FLA'nın eğitimi yalnızca çıkış katman ağırlıklarının ayarlanmasına gereksinim duyar. FLA'nın fonksiyon yaklaşırma performansı, ağ girişlerinin yeterince genişletilmesine bağlıdır. Yeterince yüksek dereceden aktivasyon fonksiyonu içeren FLA' nın, herhangi bir doğrusal olmayan sürekli fonksiyonu arzu edilen doğrulukta yaklaşılabileceği belirlenmiştir. Ancak, ağ girişleri arttıkça orta katman aktivasyon fonksiyonları büyük boyutlara ulaşacak ve ağın gerçekleştirilmesi güç olacaktır. Örneğin, 20 girişli bir ağ için 3.dereceden polinomsal açılımla 1270 adet genişletilmiş giriş oluşur. Bu nedenle, arzu edilen doğruluğu sağlayacak şekilde en iyiye yakın bir alt model seçimine gereksinim duyulur. RTFA' na benzer şekilde çeşitli yöntemlerin yanı sıra dik en küçük kareler yöntemi FLA' da alt model seçiminde etkin olarak kullanılır.

4.3.6 Çağrışımli Bellek Ağları (ÇBA)

Çağrışımli sistemler, belirli giriş vektörlerini belirli çıkış vektörlerine dönüştüren ya da ilişkilendiren sistemler olarak tanımlanır. Dolayısıyla çağrışımli bellek ağları, eğitim sürecinde ağa verilen eğitim örneklerini ağırlıkları aracılığı ile saklar yada ezberler ve hatırlama yada genelleme sürecinde ise saklanmış örneklerin gürültülü versiyonları da ağa verilmiş olsa doğru örnekleri verebilir. Bu yönü ile ÇBA' ları kodlayıcılar ve kod çözücülere benzer işlevleri yerine getirirler ve beynin yapısal karakteristikleri yerine işlevsel özelliklerini

benzeştiren ağ yapısı olarak söylenebilir. ÇBA' ları genellikle örüntü tanıma ve eldeki eksik verilerden doğru verileri ortaya çıkarma gibi uygulamalarda yaygın olarak kullanılır.

Şekil 4.12'de çağrışımlı bir bellek ağının yapısı görülmektedir. Burada, x -giriş vektörü, y - çıkış vektörü ve M -bellek matrisidir. Genel olarak Şekil 4.12'de verilen çağrışımlı bellek ağı, n adet vektör ilişkilendirmesi sağlayabilir ancak gerçekte, saklanabilecek vektör sayısı giriş vektör boyutundan daha azdır örneğin $m < n$ gibi (Matlab, 2006).




Şekil 4.12 Çağrışımlı Bellek Ağları

ÇBA' ları, sistem modelleme ve denetimi amacıyla da kullanılabilir. Bu tür ÇBA' ları, 3 katmanlı YSA yapısına benzer ancak girişler normalize edilmek üzere giriş katmanından orta katmana farklı doğrusal olmayan fonksiyonlarla bir dönüşüm gerçekleştirirler. ÇBA' nın performansı, ağ girişlerinden orta katman taban fonksiyonlarına gerçekleştirilen doğrusal olmayan dönüşüme bağlıdır. Orta katmandan çıkış katmanına ise doğrusal bir dönüşüm vardır. Bu nedenle, ÇBA tasarımında, ağ giriş uzayını normalize eden n boyutlu bir bölümlendirme yapısı belirlenmelidir. Girişleri normalize etme, her bir girişin en azını ve en çoğunu belirleyerek bu aralığı ağın duyarlılığına göre bölümlere ayırma işlemi olarak kısaca tanımlanabilir. Bölümlendirme yapısının tasarımı, ÇBA'nın modelleme yeteneği, bellek gereksinimi ve öğrenme hızını etkiler (Matlab, 2006).

4.3.7 Modül Yapay Sinir Ağları (MYSA)

Modül YSA' ları, çok sayıda YSA yapısının birleşiminden oluşur aşağıdaki gibi tanımlanır. Eğer, bir ağın yapması gereken işlemler birbirleriyle de haberleşmeksizin iki yada daha fazla modüle (alt yapıya) ayrılabilirse bu ağlar modül YSA' ları olarak söylenir (Şekil 4.13).



Şekil 4.13 Modül yapay sinir ağları

Modüllerin çıkışları, modüllerden bilgi geri beslenmemek üzere bir birleştirme birimi ile birleştirilir ve birleştirme birimi;

- a-) Modül YSA çıkışını elde etmek için modül çıkışlarının nasıl birleştirilmesi gerektiğini,
- b-) Hangi eğitim örneklerini hangi modülün öğreneceğini kararlaştırmalıdır.

Bu nedenle modül YSA' nın, böl ve yönet esasına göre çalıştığı söylenebilir ve böylece karmaşık problemler daha basit alt bileşenlerine ayrılarak çözülebilir ve sonuçta çözümler birleştirilebilir. Örneğin, süreksiz fonksiyonların tek bir YSA ile yaklaştırılması, özellikle süreksizlik noktalarında arzu edilen sonucu vermez. Böyle bir fonksiyonun süreksizlik noktaları arasındaki her bir bölgesi ayrı bir YSA modülü ile yaklaştırılarak sonuç fonksiyon, modül çıkışlarının birleşimi olarak alınabilir. Bu nedenle de, modül YSA' larının eğitiminde genellikle hem eğiticili hem de eğiticişiz öğrenme algoritmalarını birlikte kullanmak gerekir.


4.4 Aktivasyon Fonksiyonları

Hücre modellerinde, hücrenin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonları sabit parametrelili yada uyarlanabilir parametrelili seçilebilir. Aşağıda, hücre modellerinde yaygın olarak kullanılan çeşitli aktivasyon fonksiyonları tanıtılmıştır.

4.4.1 Doğrusal ve Doyumlu-Doğrusal Aktivasyon Fonksiyonu

Doğrusal bir problemi çözmek amacıyla kullanılan doğrusal hücre ve YSA' da ya da genellikle katmanlı YSA' nın çıkış katmanında kullanılan doğrusal fonksiyon, hücrenin net girdisini doğrudan hücre çıkışı olarak verir. Doğrusal aktivasyon fonksiyonu matematiksel olarak $y=v$ şeklinde tanımlanabilir. Doyumlu doğrusal aktivasyon fonksiyonu ise aktif çalışma bölgesinde doğrusaldır ve hücrenin net girdisinin belirli bir değerinden sonra hücre çıkışını doyuma götürür. Doyumlu doğrusal aktivasyon fonksiyonunun (4.10) eşitliğinde matematiksel tanımı, Şekil 4.14'de ise grafiği görülmektedir.

$$y = \begin{cases} 1 & v > 1 \\ v & -1 < v < 1 \\ -1 & v < -1 \end{cases} \quad (4.10)$$




Şekil 4.14 Doyumlu doğrusal aktivasyon fonksiyonu

4.4.1.1 Sigmoid Aktivasyon Fonksiyonu

Şekil 4.15’de grafiği verilen çift yönlü sigmoid (tanh) fonksiyonu, türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması nedeniyle doğrusal olmayan problemlerin çözümünde kullanılan YSA’larında tercih edilir. Çift yönlü sigmoid fonksiyonun tanımı (4.11) eşitliğinde ve tek yönlü sigmoid fonksiyonunun matematiksel ifadesi ise (4.12) eşitliğinde verilmiştir.

$$\varphi(v) = a \frac{1 - e^{-bv}}{1 + e^{-bv}} \quad (4.11)$$

$$\varphi(v) = a \frac{1}{1 + e^{-bv}} \quad (4.12)$$




Şekil 4.15 Sigmoid (tanh) aktivasyon fonksiyonu.

Sigmoid fonksiyonlarında a ve b katsayıları genellikle birim olarak alınır ancak, YSA’ nın eğitiminde öğrenme oranını hızlandırıcı etkilerinin olduğu ve en uygun değerleri ise $a=1.716$, $b=2/3$ olarak belirlenmiştir. Ayrıca, a ve b katsayılarının YSA’ nın eğitim sürecinde uyarlanmasıyla sabit katsayılı fonksiyona göre daha iyi bir performans elde edilebilmektedir.

4.4.1.2 Eşik Aktivasyon Fonksiyonu

McCulloch-Pitts modeli olarak bilinen eşik aktivasyon fonksiyonlu hücreler, mantıksal çıkış verir ve sınıflandırıcı ağlarda tercih edilir. Şekil 4.16 Perceptron (Algılayıcı) olarak söylenen eşik fonksiyonlu hücrelerin matematiksel modeli aşağıdaki gibi tanımlanabilir.



Şekil 4.16 Eşik aktivasyon fonksiyonu

4.5 Literatürde, Aktif Çamur Tesislerine Uygulanan, Yapay Sinir Ağları Kullanılarak Yapılmış Geçmiş Çalışmalar

Aktif Çamur Prosesi, endüstriyel ve evsel arıtma tesislerinde genellikle ikincil arıtım ünitesi olarak yer almaktadır. Böyle bir prosesin efektif kontrolünün yapılabilmesi için, hem biyolojik reaktörün hem de son çökeltim tankının dinamiklerinin asgari düzeyde simüle edilebilmesi gerekir. Yapay sinir ağları, bu kontrolün sağlanmasında, mekanistik yaklaşımlarda ki karmaşık matematiksel yapılara ihtiyaç duymadan, modelin tahmin kapasitesini arttırmaktadır. Siyah kutu modeli (Black Box Model, Cote vd., 1995) çalışmasında elde edilen sonuçlarda, deneysel yapıda, mekanistik modelin kapsayamadığı dinamik bir davranışın bulunduğu ve yapay sinir ağı modelinin bu davranışa daha uygun sonuçlar verdiği saptanmıştır.

Arıtma tesisi prosesinin kontrol edilebilmesi için, yapay sinir ağı ile parça analizi ilkesi (PCA) birleştirilerek bir sanal sensör (PCA+YSA) üzerinde çalışılmıştır (Choi ve Park, 2001). YSA modelinin geliştirilmesi için, günlük periyotlarla, 113 boyunca giriş atık suyunun kalitesi ölçülmüştür. Çok değişkenli regresyon, parçalı regresyon, yapay sinir ağı ve “PCA+YSA” gibi 4 farklı metot birbirleri ile karşılaştırılmıştır. Tahmin edilmesi istenilen çıkış parametresi olarak TKN seçilmiştir ve farklı 11 parametre giriş parametresi olarak belirlenmiştir. Elde edilen sonuçlarda uygulanan performans kriteri ortalama standart sapma (RMSE) metoduna göre tespit edilmiştir. Buna göre sadece yapay sinir ağları 66.50, YSA+PCA 13.82 sapma göstererek, hibrit modelin avantajı kanıtlanmıştır.

Bir başka çalışmada, eğitim prosesi süresince, giriş atık suyun debisi ve pH en önemli iki parametre olarak gösterilmiştir. Böylece, YSA’nın, değişkeler yoluyla tanımlanan daha iyi bir işletme şartı sağlayabileceği sonucuna varılmıştır. YSA, sistemdeki karışıklıkların önüne geçilebilmesi için gerekli tahminleri yapabilen ve çıkıştaki dalgalanmaları en aza indiren bir kontrol mekanizması olarak tanımlanmıştır (Gontarski vd., 2000).

Zeng ve arkadaşları, ana arıtma prosesi koagülasyon olan bir kağıt endüstrisi atık su arıtma tesisi için bir model üzerinde çalışmıştır. Bunun için, çok katmanlı geri yayımlı bir YSA kullanmıştır. Kirletici giderim oranları ile koagülasyon da kullanılan kimyasal madde arasındaki doğrusal olmayan ilişkiyi incelemiştir. Modelin eğitiminde gradyent azaltım

algoritmasını seçilmiştir. Geliştirilen bu modelin tesisin kontrolü için kullanılabileceğini ve geleceğe yönelik makul tahminlerin yapılabileceği sonucuna varılmıştır (Zeng vd., 2004).

Bir diğer çalışma, 1 milyon metreküp günlük debisi ile Mısır büyük atık su arıtma tesisi üzerinde yapılan bir model çalışmasıdır. YSA modelini oluşturmak için tesisin geriye dönük verileri kullanılmıştır. Biyolojik oksijen ihtiyacı ve askıda katı maddenin modellenmesi üzerinde çalışılmıştır. 10 aylık gözlemlenen veriler, arıtma tesisinin laboratuvar sonuçlarından alınmıştır. Her değişken için iki ayrı YSA modeli oluşturulmuştur. Bu modeller yüksek randıman göstermiş ve arıtma tesisleri için geleceğe yönelik tahminlerin değerlendirilmesi için YSA'nın önemli bir rol üstlendiği sonucuna varılmıştır (Hamed vd., 2004).

5. İSTANBUL TUZLA ve PAŞAKÖY ATIKSU ARITMA TESİSLERİ

5.1 Genel Bakış

İstanbul su ve kanalizasyon idaresi (İSKİ), İstanbul'un içmesuyu ihtiyacını karşılayan projeler ürettiği gibi, hem endüstriyel hem de evsel atıksuların alıcı ortamları kirletmeden arıtılması ile ilgili projeleri de üretmektedir. Bu çalışmada İstanbul'da ki iki arıtma tesisi incelenmiştir: Paşaköy atıksu arıtma tesisi (PAAT) ve Tuzla atıksu arıtma tesisi (TAAT). Bu tesislere ait detaylı bilgiler, bu bölümün ilerleyen başlıkları altında yer almaktadır.


5.2 Paşaköy Atıksu Arıtma Tesisi (PAAT)

Ömerli Barajı; İstanbul'un su kaynakları arasında çok önemli bir yere sahiptir. Ömerli Havzasında yer alan ve yetersiz altyapıya sahip, kontrolsüz kentleşmenin etkilerinden baraj gölünü korumak ve gelecekte de bu su kaynağından verimli olarak yararlanabilmek gayesiyle, Paşaköy İleri Biyolojik Atıksu Arıtma Tesisi kurulmuştur.

Ömerli su havzasında Sarıgazi, Samandıra, Sultanbeyli, Alemdağ, Yenidoğan ve Sultançiftliği yerleşim bölgelerinde oluşan ve Ömerli Barajı'na dökülen atıksuları arıtmaktadır. Atıksular, ileri biyolojik arıtma sistemiyle ve mevcut alıcı ortam dışarı standartlarına uygun kalitede arıtılarak, yapılmakta olan tünel vasıtasıyla Riva Deresi ile Karadeniz'e verilmektedir ve böylece baraja kirleticilerin girişi önlenmektedir.

5.2.1 Tesis Hidrolik Parametreleri ve Giriş Suyu Özellikleri

Arıtma tesisi, nihai kapasitede 1.065.000 kişilik bir nüfustan kaynaklanan ve 500.000 m³/gün debiye sahip atıksuları arıtmaktadır. Tesis bu safhada, 250.000 kişilik atıksu yüküne göre inşa edilmiştir. Tesisin kurulu olduğu alan 507.000 m²'dir. İleri biyolojik atıksu tasfiye işlemi, atıksuda bulunan karbonun yanı sıra, su kaynaklarında kirliliğe yol açan azot, fosfor gibi besin maddelerinin de giderilmesini sağlamaktadır (İSKİ, 2009).



Şekil 5.1 Paşaköy atıksu arıtma tesisi vaziyet planı uydu görüntüsü (1.Giriş yapısı, 2. Blower odası, 3. Izgara-kum tutucu, 4. Parşal savağı, 5. Çamur keki depolama, 6. Çamur susuzlaştırma, 7. Süzüntü pompa ist., 8. Çamur depolama, 9. DAF ünitesi, 10. Biyolojik fosfor tankları, 11. Proses tankları, 12. Blower binası, 13. DAF geri devir, 14. Son çökeltim)

İnce ızgara ve kum tutucudan gelen atıksu, geri devir çamuruyla karışarak biyolojik fosfor ünitesine girmektedir. Bu ünite 2700 m³ lük 3 havuz seri olarak çalışmaktadır ve havuzların toplam hacmi 8100 m³'tür. AKM, her havuda bulunan muz tipi 2 yavaş karıştırıcı ile askıda tutulmaktadır. Biyolojik fosfor giderme ünitesi; biyolojik arıtmada anaerobik (havasız) ortam şartları sağlanmaktadır. Bu tanklarda mikroorganizma bünyesinde bulunan fosforun daha sonra havalandırma havuzlarında (çok daha fazlasını almak üzere) salınması yani suya verilmesi işlemini gerçekleştirmektedir.

Havalandırma havuzları aerobik, anoksik kısımları bulunan seri olarak bağlı 4 havuzdan oluşmaktadır ve bu tankların toplam hacmi 40.000 m³'tür. Havalandırma havuzları, ikişerli konumda da çalıştırılabilir. Bu durumda nitrifikasyonun devam etmesini sağlamak için geri kalan kanallar havalandırılmaktadır. AKM'nin çökmesini önlemek, hava kabarcıklarının yolunu uzatarak havalandırma verimini arttırmak ve homojen karışım sağlamak üzere, kanat açıklığı 2500 mm olan muz tipi karıştırıcılar monte edilmiştir. 4 kanalın her birine, havalandırma için ince kabarcıklı seramik difüzörler yerleştirilmiştir. Difüzörlere hava, blower binasında bulunan 3 adet blower tarafından temin edilmektedir. Her kanala verilecek hava miktarı vana ile ayarlanarak, tanklardaki çözünmüş oksijen seviyesi önceden belirlenmiş seviyede tutulmaktadır. Havalandırma havuzlarından gelen atıksu, sürgülü kapaklara sahip bir dağıtım yapısına gelerek her biri 4500 m³ hacme sahip 4 adet, 42 m çapında ve 3.2 m

derinliğinde dairesel çöktürme tankına verilir. Son çöktürme havuzundan, geri terfi merkezine gelen çamur, biyolojik fosfor ünitesine basılarak sisteme geri devredilmektedir. Nihai debide %80 geri devir oranı sağlanmaktadır (İSKİ, 2009).

Çizelge 5.1 Paşaköy arıtma tesisi giriş suyu parametre değerleri (İSKİ, 2004)

Parametre	Birim	Minimum	Maksimum	Ortalama	Standart Sapma
Debi	m ³ /gün				
pH	-	6.8	7.7	7.3	0.37
Sıcaklık Atıksu	°C	5.8	23.3	16.6	4.89
KOİ	mg/l	50	992	448	176.8
BOİ	mg/l	25	610	245	102.5
TKN	mg/l	3.6	79	45.3	17.7
TP	mg/l	0.2	13	5.1	2.35

5.3 Tuzla atıksu arıtma tesisi (TAAT)

Hizmet alanı Gebze, Darıca, Çayırova, Tuzla, Pendik, Kartal ve kısmen Maltepe bölgeleridir. Bu yerleşim alanlarından gelen atıksular 4.5 m çapa kadar tünel ve kolektör hatları ile toplanarak arıtma tesisine ulaşmaktadır. TAAT, 1998 yılında hizmete sunulmuştur. Tesis biyolojik arıtma ve deniz deşarjı olarak işletmeye alınmıştır. 4.5 milyon nüfusa göre planlanan tesis de ileri biyolojik arıtma üniteleri içinde alanlar ayrılmıştır.

Tesisin proje kapasitesi 150.000 m³/gün olarak hesaplanmıştır. Günlük ortalama 230.000 m³ atıksuyu arıtabilmektedir (İSKİ, 2009).

5.3.1 Tesis Hidrolik Parametreleri ve Giriş Suyu Özellikleri

Tuzla Sahil Tüneli ve Kemiklidere Tuzla Tüneli ile Pendik ve Tuzla yönlerinden gelen atıksular giriş yapısında iki noktadan tesise girer. Atıksular ilk olarak içerisindeki kaba maddelerin pompa ve diğer teçhizatlara zarar vermesini önlemek için taş tutucu ve kaba ızgaradan geçirilir. Kaba ızgaradan geçen atıksular -8,47 kotundan, kapasitesi 5275 m/saat 1465 lt/sn) olan pompalarla +12,86 kotuna terfi edilir.



Şekil 5.2 Tuzla atıksu arıtma tesisi vaziyet planı uydu görüntüsü (1.Giriş yapısı ve ızgaralar, 2. Kum tutucu, 3. Ön çökeltim tankları, 4. Havalandırma tankları, 5. Son çökeltim tankları, 6. Çamur yüzdürme, 7. Çamur çürütücü, 8. Çamur susuzlaştırma, 9. Blower ünitesi, 10. Çamur yoğunlaştırma tankları)

Terfi edilen atıksular çubuk aralığı 1 cm olan toplam 3 adet ince ızgaradan geçirilir. Iızgaralar 3 m genişliğinde olup yatayla 75° açı yapacak şekilde monte edilmiştir. 2 adet kum tutucu bulunmaktadır ve havuzların toplam kapasitesi 385 m^3 tür. Kum tutuculardaki bekleme süresi 4 dakikadır. Buradan çıkan sular ön çöktürme tanklarına alınır. Toplam kapasitesi 2682 m^3 olan 4 adet ön çökeltim havuzu bulunmaktadır. Havuzların boyu 60m, eni 15m ve derinliği 3m dir. Buradan çıkan sular havalandırma havuzlarına alınır. 1500 m^3 lük 4 adet havalandırma havuzu bulunmaktadır. Havuzların boyu 80m, eni 15m ve derinliği 5m dir. Havalandırma havuzundan çıkan atıksular, son çökeltim tankına iletilir. 4adet son çökeltim tankı bulunmaktadır.

Çizelge 5.2 Tuzla arıtma tesisi giriş suyu parametre değerleri (İSKİ, 2007)

Parametre	Birim	Minimum	Maksimum	Ortalama	Standart Sapma
Debi	m ³ /gün				
pH	-	6.49	9.07	7.74	0.24
Sıcaklık Atıksu	°C	0	28.8	16.8	5.86
O ₂ çözünmüş	mg/l	0.13	24.8	2.4	1.58
AKM	mg/l	246	2520	914	385.7
KOİ	mg/l	252	3350	993	370.1
BOİ	mg/l	50	1100	508	171.9

5.4 ASM1 Modelinin Tesis Şartlarına Kalibrasyonu

ASM1 modelinin giriş parametreleri; giriş debisi ve 13 ayrı bileşen içermektedir. Modelde kullanılacak bu 13 bileşen için, tesislerin aktif çamur proseslerinde herhangi bir ölçüm yapılmamıştır. Bu nedenle, rutin ölçümleri yapılan KOİ, BOİ, NH₄-N gibi verilerden, bir metot yardımıyla 13 bileşenin elde edilmesi gerekmektedir. Bu çalışmada, Grady vd.'nin (1999), önerdiği bir çevrim metodu kullanılmıştır. Bu metot, AKM, BOİ₅ ve amonyak azotu ölçümleri kullanılarak, ASM1 modelinin 13 giriş bileşeninin hesaplanmasına imkân sağlamaktadır. Bölüm 3.1'de de ifade edildiği gibi, KOİ, 4 ayrı tamamlayıcı unsurun bir bileşimidir ve bunlar;

- Biyolojik olarak parçalanabilen ve partikül haldeki KOİ (X_{SO})
- Biyolojik olarak parçalanabilen ve çözünmüş haldeki KOİ (S_{SO})
- Partikül haldeki inert KOİ (X_{IO})
- Çözünmüş haldeki inert KOİ (S_{IO})

dır.

Daha önce tanımlanmış olan çevrim metodunda belirtilen ampirik formüller, aşağıda özetlenmiştir:

$$TKOİ=2.1*BOİ_5$$

$$KOİ_{BO}=1.71* BOİ_5$$

$$UAKM=0.75*AKM$$

$$TKN=1.74*S_{NHO}$$

$$\begin{aligned}
KOI_{IO} &= TKOI - KOI_{BO} \\
X_{IO} &= 0.56 * UAKM \\
S_{IO} &= KOI_{IO} - X_{IO} \\
S_{SO} &= 0.35 * KOI_{BO} \\
X_{SO} &= KOI_{BO} - S_{SO} \\
ON_{TO} &= S_{NSO} + S_{NIO} + X_{NSO} + X_{NIO} \\
X_{NIO} &= 0.06 * X_{IO} \\
S_{NIO} &= 1.5 \text{ mg/l} \\
S_{NSO} &= (S_{NSO} + X_{NSO}) * [(S_{SO}) / (S_{SO} + X_{SO})]
\end{aligned} \tag{5.1}$$

Burada; AKM askıda katı madde, UAKM uçucu askıda katı madde, ON_{TO} toplam organik azot ve TKN toplam Kjeldahl azotu anlamına gelmektedir.

Bu metot kullanılarak oluşturulan giriş parametre değerlerinin bazıları negatif çıkabilir. Negatif çıkan değerlerin model içinde kullanılabilmesi iki yol ile mümkün olmaktadır. Bunlardan birincisi, negatif olan değer bileşeninin ihmal edilebilir olduğu, değer sıfır olabileceği ya da sıfıra yakın çok küçük bir değer (örneğin 0.001) kullanılabileceği düşünülebilir. Diğeri ise, ampirik formüllerdeki katsayıların küçük miktarlarda değiştirilebilmesidir.

(5.1) eşitliğinde tanımlanan parametreler giriş verisi için kullanılacak parametrelerdi. Çıkış için kullanılacak parametreler için yine deneysel verilerden oluşturulmuş ampirik formüller bulunmaktadır (Grady vd.,1999).

$$\begin{aligned}
TKN &= S_{NHE} + S_{NSE} + X_{NSE} \\
BOI_5 &= f_{bod} * (S_{SE} + X_{SE} + X_{BHE} + X_{BAE}) \\
TKOI &= S_{IE} + S_{SE} + [(X_{SE} + X_{BHE} + X_{BAE} + X_{IE} + X_{DE}) = XKOI] \\
UAKM &= XKOI / icv \\
AKM &= UAKM / ivt
\end{aligned} \tag{5.2}$$

6. MATERYAL ve METOT

Çalışmada incelenecek her iki arıtma tesisi için, en az 1 yıllık, günlük ölçüm periyodunda analiz edilen, parametre ölçüm sonuçlarının dökümü elde edilmiştir. Günlük ölçüm sonuçları incelenerek, parametrelere ait eksik veriler Monte Carlo simülasyonu ile tamamlanmıştır. İki farklı tesiste yapılan günlük ölçümlerden sadece bazıları ortak parametreleri içermektedir. Dolayısıyla bu ortak parametreler tespit edilmiş ve çalışma bu parametrelerin ölçüm sonuçları üzerinden devam ettirilmiştir. Bu parametrelerin günlük analiz sonuçları üzerinden, kabaca yapay sinir ağı (YSA) modeli ile denemeler yapılmış ve ham verilerin YSA modeline göstereceği cevapların etkinliği tespit edilmiştir. Kaba modelden elde edilen sonuçların etkinliğinin düşük olduğu tespit edilmiştir. Bu nedenle parametrelerin ham ölçüm değerleri farklı metotlar ile yumuşatılmıştır. Elde edilen yumuşatılmış veriler yeniden kabaca YSA modelde kullanılmış ve hangi yumuşatma metodundan elde edilen veri setinin, gerçek modelde kullanılacağı tespit edilmiştir. Bir sonraki aşamada, gerçek YSA modelin tespiti için, farklı algoritmalar ve eğitim fonksiyonları ile denemeler yapılmıştır. Test modellerinin sonuçları incelenerek, çalışmada kullanılacak gerçek YSA model tespit edilmiştir. Her iki tesis için, aynı parametrelere ait farklı veri setleri, gerçek YSA üzerinde çalıştırılarak, tesislere ait model sonuçları oluşturulmuş ve incelenmiştir.

YSA modelin etkinliğinin tespit edilmesi amacıyla, ASM1 modeli ile YSA model karşılaştırılmıştır. Bu karşılaştırmada, ASM1 modelinde kullanılan farklı stokiometrik katsayılar üzerinden kıyaslamalar yapılmıştır. Bu katsayılar, hem YSA modelde, farklı giriş parametrelerinden elde edildiği gibi hem de ASM1 modelinden elde edilmiştir. Her iki modelden elde edilen katsayılar birbirleri ile karşılaştırılmıştır.

Yapay sinir ağı modeli, hem PAAT hem de TAAT'nin aktif çamur sisteminin giriş-çıkış verileri ile eğitilmiştir. Doğru modelin tespit edilmesi ve geriye yönelik verilerin arşivlenmesi, bir model çalışmasının en hassas noktasıdır. YSA modelinin etkinliği ve doğruluğu, her iki tesisin verilerinin modelde test edilmesi ile ölçülmüştür. Bu ölçümler esnasında test ve kalibrasyon dahil 250 den fazla model denemesi Matlab'ın "Neural Network Tool" modülü ile gerçekleştirilmiştir. Her denemenin sonuçlarının ayrı ayrı incelenmesi uzun zaman almıştır. Bununla beraber, ASM1 modeli ile YSA modelinin çapraz karşılaştırmaları da yapılmıştır. Bunun için ASM1 modeline ait ampirik formüllerin iteratif yöntemle çözümüne dayanan program modülleri Matlab programında yazıldı. YSA modelinde

kullanılan tesis giriři test verilerinden elde edilen, tahminsel ıkıř verileri ASM1 modelinde giriř parametresi olarak kullanılmıřtır.

Her iki arıtma tesisinin YSA modelden elde edilen ıkıř verileri, tesislerin gerek ıkıř verileri ile karřılařtırılmıřtır. Ancak, tesislerde llen parametrelerin eřitlilięi birbirlerinden farklı olduęu tespit edilmiřtir. Bu parametrelerin, YSA modelde kullanılmak iin gerekli hassasiyete yeteri kadar sahip olmadıęı biliniyordu. Dolayısıyla, yapılan karřılařtırmalar biyolojik oksijen ihtiyaı (BOİ), kimyasal oksijen ihtiyaı (KOİ) ve askıda katı madde (AKM) parametreleri arasında sınırlandırılmıřtır.

Farklı parametrelerin giriř seti varyasyonları oluřturularak, YSA modeldeki ıkıř sonularına etkileri incelenmiřtir. 1 yıllık veriler iin yapılan bu alıřmada, her bir giriř veri setinde ortalama 360 veri bulunmaktadır. Bir eęitim fonksiyonu iin, 3 farklı nron sayısı ile yapılan 31 denemede, toplam giriř-ıkıř veri sayısı yaklaşık 22.300'dr. Sadece 3 farklı eęitim fonksiyonu iin toplam 66.700 civarında verinin tasnifi yapılmıřtır.

YSA modelinin ve ayrıca ASM1 modelinin, kullanılan giriř verileri aısından mevsimsel olarak 4 kısıma ayrılarak incelenmesi dřnlmřtr. Bunun nedeni ise, izelge 3.2'de belirtilen ASM1 modelindeki bazı kinetik parametrelerin sıcaklıęa ve dolayısıyla mevsime baęlı deęiřim gstermesidir. Verilerin, mevsimsel YSA eęitimi iin sayıca yetersiz olması, yapılan denemelerin beklenen sonucu vermemesinden dolayı, bu sonulara alıřmanın bu blmnde yer verilmemiřtir. Yine veri eksiklięi nedeniyle, ASM1 model iin tm kinetik katsayıların tespitinden ziyade, birbirleri ile ilgili parametrelere ait kinetik katsayıların tespiti zerinde durulmuřtur. Bunun iin 2005 yılında, Jinseng Huo'nun doktora tezinde yayınlanmış "parametre-katsayı korelasyonu" izelgesinden (izelge 6.1) yararlanılmıřtır. izelgede, ASM1 modelinin, AKM, BOİ ve KOİ parametreleri ile korelasyon halindeki kinetik katsayıları yer almaktadır. Parantez iindeki artı iřareti, katsayının, parametre ile doęru orantılı iliřkisi olduęunu ifade etmektedir.

Çizelge 6.1 Parametre-katsayı korelasyonu (Huo, 2005)

Parametre	No.1	No.2	No.3	No.4
BOİ ₅	$b_{LH} (-)$	$Y_H (+)$	$\mu_{H,max} (-)$	$K_S (+)$
AKM	$b_{LH} (-)$	$Y_H (+)$	-	-
KOİ	$Y_H (+)$	$b_{LH} (-)$	$\mu_{H,max} (-)$	$K_S (+)$
TKN	$b_{LH} (+)$	$K_{NH} (+)$	$\mu_{H,max} (-)$	-

Çizelge 6.1 incelendiğinde, beş kinetik katsayının, parametreler ile korelasyon halinde olduğu görülmektedir. Bu çalışmada, Çizelge 3.2’de sıcaklığa göre değişim göstermeyen K_S , Y_H ve K_{NH} katsayılarının sabit olduğu kabul edilerek sırasıyla; 20, 0.67 ve 1 değerleri alınmıştır. b_{LH} ve $\mu_{H,max}$ katsayıları ise ASM1 model yardımı ile tespit edilmiştir. ASM1 modelden her iki tesis için ayrı ayrı elde edilen ilk 100 katsayı verisi ile eğitilen YSA modeli, b_{LH} ve $\mu_{H,max}$ katsayılarının tespiti için kullanılmıştır. AKM, KOİ, BOİ ve sıcaklık parametreleri giriş verisi olarak kullanılarak, b_{LH} ve $\mu_{H,max}$ katsayıları YSA modelden tespit edilmiştir.

ASM1 modelinin, tesislere uygulanması için, tesislerden elde edilen ham gerçek ölçüm sonuçları kullanılmıştır. Ölçüm sonuçlarının, ASM1 parametrelerine uyarlanması için Matlab programında bir algoritma oluşturulmuş ve kodları yazılmıştır. Denklem 5.1 ve 5.2’deki ampirik formüller kullanılarak, tesislerin gerçek giriş-çıkış verilerinden elde edilen, ASM1 modelinin senelik giriş-çıkış veri seti oluşturulmuştur. Buradan hareketle, (5.1) eşitliğinden elde edilen ASM1 parametreleri, Çizelge 3.1’deki gerçek ASM1 modeli ampirik formülleri ile çözümlenerek, proseslere ait bileşenlere ulaşılmıştır.

6.1 Dinamik Simülasyon için Nümerik Algoritma

Statik simülasyon ile dinamik simülasyon arasında ki; fark birinci dereceden diferansiyel denklemlerin sıfır olmamasıdır. Diferansiyel denklemlerin çözümünde genelde Runge-Kutta metodu kullanılır. Sayısal analizde Runge-Kutta yöntemleri, adi diferansiyel denklemlerin çözüm yaklaşımları için kapalı ve açık yinelemeli yöntemler ailesinin önemli bir tipidir. Bu yöntem 1900'lü yıllarda C. Runge ve M.W. Kutta adlı matematikçiler tarafından geliştirilmiştir.

4. dereceden klasik Runge-Kutta Yöntemi:

"RK4" veya "Runge-Kutta yöntemi" olarak adlandırılan Runge-Kutta yöntemleri ailesinin bu üyesi sıkça kullanılır.

Aşağıdaki gibi tanımlanan bir başlangıç değer problemini ele alalım.

$$y' = f(t, y), \quad y(t_0) = y_0 \quad (6.1)$$

ve bu problem için RK4 yöntemi aşağıdaki denklemlerle verilir.

$$y_{n+1} = y_n + \frac{h}{6}(k_1 + 2k_2 + 2k_3 + k_4) \quad (6.2)$$

Burada;

$$k_1 = f(t_n, y_n) \quad (6.3)$$

$$k_2 = f\left(t_n + \frac{h}{2}, y_n + \frac{k_1}{2}\right) \quad (6.4)$$

$$k_3 = f\left(t_n + \frac{h}{2}, y_n + \frac{k_2}{2}\right) \quad (6.5)$$

$$k_4 = f(t_n + h, y_n + k_3) \quad (6.6)$$

Böylece bir sonraki y_{n+1} değeri o anki y_n değerine h aralığının büyüklüğüyle tahmini eğimin çarpımının eklenmesiyle elde edilir. Bu eğim, eğimlerin ağırlıklı ortalamasıdır:

- k_1 aralığın başlangıcındaki eğimdir.
- k_2 aralığın orta noktasındaki eğimdir. Bu k_2 eğimi, Euler Yöntemi kullanılarak y 'nin $t_n+h/2$ noktasındaki değerinden elde edilir.
- k_3 yine orta noktadaki eğimdir. Ama bu sefer y değeri k_2 eğiminden elde edilir.
- k_4 aralığın sonundaki eğimdir ve y değeri k_3 eğimi kullanılarak bulunur.

Monte Carlo için halihazırda bulunan birkaç bilgisayar programı vardır. Bunlardan MATLAB® GARCH modülü, güçlü tümleşik algoritması ve kullanışlı grafik fonksiyonları ile diğerlerine göre avantajlıdır. Bu modül genellikle finanssal zaman serisi modelleme çalışmaları ve Monte Carlo simülasyonu oluşturmak için kullanılmaktadır.

Kabul edilen başlangıç koşulları, dinamik simülasyonun ilk zamanlarında, simülasyon tahminleri üzerinde aşırı tesirlerde bulunabilir. Arıtma tesisinin kademe değişikliğine vereceği tepkinin, giriş şartlarında biraz zaman aldığı da (3 yada 4 SRT kadar) bilinmektedir (Grady vd.,1999). Bu durumların yanı sıra, bu çalışmada, dinamik simülasyonun başlangıç değerleri için, kararlı hal işletme değerleri alınmıştır. Böylece başlangıç koşullarının simülasyon üzerindeki etkileri azaltılarak, daha kısa zamanda, gerçek işletme koşullarının elde edilmesi sağlanmıştır. Arıtma tesisi günlük giriş verileri tekrarlanmak suretiyle kullanılarak, test simülasyonu 66 gün için oluşturulmuştur.

6.1.1 Geriye Yayılım Tabanlı Toplu Gradyent Azaltım Algoritması (Backpropagation)

Tek katmanlı sinir ağlarının kullanım alanlarının dar kapsamlı olması, 1970’lerde yapay sinir ağlarına olan ilginin azalmasına neden oldu. Bu konuda birçok araştırmacı, çok katmanlı yapay sinir ağlarının eğitilmesi ile ilgili etkili bir metodu, birbirlerinden bağımsız bir olarak buldular. “Backpropagation” olarak isimlendiren geriye yayılım algoritmasının, farklı birçok problemin çözümünde kullanılması, yapay sinir ağlarının kullanışlı bir yöntem olmasında etkili olmuştur. Basit olarak geriye yayılım algoritmasının temel prensibi şöyle özetlenebilir.

İleri beslemeli (feed-forward) bir ağ boyunca, her bir giriş birimi (X_i), birer giriş sinyali kabul eder. Alınan her sinyal, gizli birimlere ($Z_1, Z_2, \dots, Z_n$) yayınlanır. Gizli birimler, her bir sinyale ait etkinleştirmeyi (activation) hesaplar ve bu sinyalleri (z_j) çıkış birimine iletir. Çıkış birimi (Y_k), bu sinyallerin etkinleştirilmesini (y_k) hesaplar ve ağın cevap formuna iletir. Bu işlemler giriş örneklerinin tamamına uygulanır.

Yapay sinir ağının eğitilmesi esnasında, her çıkış birimi, hesapladığı etkinleştirmeyi (y_k), ona ait hedef değeri (t_k) ile karşılaştırır. Karşılaştırma işleminde her birim için ilgili hatayı tespit eder ve bulur. Bulunan hataların değerini temel alarak, δ_k katsayıları hesaplanır. δ_k , çıkış biriminden (Y_k) önceki tüm katman birimlerine, ilgili hataları dağıtmak için kullanılır. Aynı zamanda bu katsayılar, çıkış katmanı ve gizli katman arasında kalan ağırlık (w_{ij}) değerlerinin güncellenmesinde de kullanılır. Basit olarak, δ_k , her bir gizli birim (Z_j) için hesaplanır.

δ faktörlerinin tamamı tespit edildikten sonra, bütün katmanların ağırlık değerleri aynı anda ayarlanır. Ağırlık değerlerinin (w_{ij}) ayarlanması, δ_j faktörüne ve giriş biriminin etkinleştirme değerine (x_i) dayanır.

Geriye yayılım algoritması (backpropagation algorithm) aşağıdaki adımlar izlenerek oluşturulmuştur.

1. Ağırlık değerlerinin başlatılması
2. Durma kriteri yanlışken, 3-10 maddeleri arasını uygula
3. Her bir eğitim çifti için, 4-9 maddeleri arasını uygula

İler Besleme (Feed-forward) :

4. Her giriş birimi ($X_1, X_2, \dots, X_n$) giriş sinyali (x_i) alır ve bu sinyalleri kendinden sonraki katmana (Gizli katman) iletir.
5. Her gizli birim ($Z_1, Z_2, \dots, Z_p$), kendine ait ağırlıklı giriş sinyallerini toplar,

$$z_{in_j} = V_{0j} + \sum_{i=1}^n x_i v_{ij}, \text{ çıkış sinyalini hesaplamak için etkinleştirme fonksiyonunu}$$

çalıştırır. Oluşan çıkış sinyallerini kendinden sonraki birime (çıkış katmanı) iletir.

6. Her çıkış birimi ($Y_1, Y_2, \dots, Y_m$), kendine ait ağırlıklı giriş sinyallerini toplar,

$$y_{in_k} = w_{0k} + \sum_{j=1}^p z_j w_{jk}, \text{ buna bağlı olarak çıkış sinyali üretir.}$$

Geriye yayılım hatası (Backpropagation Error) :

7. Her çıkış birimi ($Y_1, Y_2, \dots, Y_m$), eğitim giriş verilerine karşılık gelen, hedef verileri kabul eder. Sonra hata katsayılarını δ_k hesaplar. Sonrada ağırlık düzeltme katsayılarını hesaplar ve altındaki katmana iletir.
8. Her gizli birim ($Z_1, Z_2, \dots, Z_p$), girişler arasındaki farkları toplar, ve bunlardan, etkinleştirme hata katsayılarını, ağırlık düzeltme katsayılarını, sapma (bias) düzeltme katsayılarını hesaplar.

Ağırlık ve sapmaların güncelleştirilmesi:

9. Her çıkış birimi ($Y_1, Y_2, \dots, Y_m$), kendi sapma ve ağırlıklarını günceller. Aynı güncellemeyi her gizli birim de yapar.
10. Test durdurma koşulları

6.2 Verilere Ait Zaman Serisi Analizi

Hem Paşaköy arıtma tesisi hem de Tuzla arıtma tesisinden elde edilen verilerde, hafta sonlarına ait bazı günlerde ve tatil günlerinde eksik veriler bulunmaktadır. İstatistiksel modelin doğru olarak uygulanabilmesi için eksik verilerin bazı tahmin metotları ile hesaplanması gerekmektedir. Ayrıca tesislerden elde edilen verilerin gürültü (noisy) büyüklüklerine bağlı dağılım analizine tabi tutulması gerekmektedir. Böylelikle yumuşatılmış verilerin özellikleri ortaya koyularak, zaman serisinin dağılımının modele uygunluğu artırılmış olmaktadır. Her iki işlem için logaritmik metotlar bulunmaktadır.

Hareketli ortalama filtresi (HOF – Moving average filtering) olarak bilinen yumuşatma yöntemi, bir veriyi, kendisine komşu olan diğer verilerin ortalamasını kullanarak yumuşatır. Matematiksel olarak (4.18) eşitliğindeki gibi ifade edilir.

$$y_s(i) = \frac{1}{2N+1} (y(i+N) + y(i+N-1) + \dots + y(i-N)) \quad (6.7)$$

Burada;

$y_s(i)$: i verisinin yumuşatılmış değerini,

N : komşu veri sayısını,

$2N+1$: kullanılacak açıklık (span) değerini,

ifade eder.

Doğrusal regresyon metodu ile yumuşatmayı temel kabul eden iki ayrı filtreleme ve yumuşatma yöntemi bulunmaktadır. “Lowess” ve “Loess” olarak adlandırılan her iki yöntem, lokal olarak ağırlıkları belirlenmiş verilerin doğrusal regresyon kullanarak yumuşatılması prensibine dayanır. Lokal regresyon yumuşatma yönteminin (LRY) işlem sırası aşağıdaki gibidir:

- i. Aralıktaki her veri noktası için regresyon ağırlıkları (4.19) eşitliğindeki gibi hesaplanır.

$$w_i = \left(1 - \left| \frac{(x - x_i)^3}{d(x)} \right| \right)^3 \quad (6.8)$$

Burada;

- x : Yumuşatılan yanıt değeri ile ilişkilendirilmiş öngörü verisini,
 x_i : Aralık değeri ile tanımlı, x verisine en yakın komşu verileri,
 $d(x)$: x verisi ile en uzak öngörü verisi arasındaki yatay uzaklık değerini,

ifade eder.

- ii. Ağırlıklı doğrusal en küçük kareler regresyonu uygulanır. Lowess için 1. derece polinom denklemi, Loess için 2. derece polinom denklemi kullanılır.
 iii. İlgili öngörü verisine bağlı olarak, ağırlıklı regresyon tarafından, yumuşatılmış veriler hesaplanır.

Eğer veri seti aykırı değerler içeriyorsa, yumuşatılan veriler çarpıtılmış olabilir. Bu durumun üstesinden gelebilmek için, aykırı verilerin ters etkilerinin tesiri altında kalmayan dayanıklı yumuşatma yöntemi (DYY - Robust) kullanılmalıdır. DYY aşağıda belirtilen adımları takip eder:

- i. LRYM için yukarıda belirtilen adımlardan gerekli kalıntı veriler bulunur.
 ii. Aralık değeri içindeki her veri noktası için dayanıklı ağırlıklar, (4.20) eşitliği ile hesaplanır.

$$w_i = \begin{cases} (1 - (r_i / 6MAD)^2)^2 & |r_i| < 6MAD \\ 0 & |r_i| \geq 6MAD \end{cases} \quad (6.9)$$

Burada;

r_i : Regresyon yumuşatma işleminden sonra elde edilen i noktasındaki verinin kalıntı verisini,

MAD : Kalıntı verilerin ortalama standart sapması, $MAD = \text{median}(r)$,

olarak ifade edilir.

- iii. Dayanıklı ağırlıklar kullanılarak tekrar yumuşatma yapılır. Son yumuşatılmış veriler, hem doğrusal regresyonun ağırlıkları hem de dayanıklı ağırlıklar kullanılarak hesaplanır.
- iv. 5 iterasyon tamamlanana kadar önceki iki adım tekrarlanır.

Bu yöntemler ile elde edilen veri setlerinden hangisinin yapay sinir ağına daha başarılı olacağını tespit etmek için, yapay sinir ağı, yumuşatılmış her üç veri setiyle eğitime tabi tutulmuştur. Bunun için Tuzla ve Paşaköy arıtma tesislerine ait giriş askıda katı madde ve çıkış askıda katı madde verileri kullanılmıştır. Ocak ayından itibaren ilk 100 değer, veri seti olarak seçilmiştir. Veri setinde yer alan giriş ve çıkış değerlerine, yumuşatma uygulamadan önce normalizasyon işlemi uygulanmıştır.

Normalizasyon, yapay sinir ağına kullanılacak giriş ve çıkış verilerinin, eğitim fonksiyonuna cevap verebilmesi için $[-1 \ +1]$ veya $[0 \ 1]$ aralığında yeniden hesaplanıp, değerlendirilmesi olarak tanımlanmaktadır.

$[0 \ 1]$ aralığı için;

$$X_t = \frac{x_t - x_{\min}}{x_{\max} - x_{\min}} \quad (6.10)$$

$[-1 \ +1]$ aralığı için;

$$X_t = 2 \times \frac{x_t - x_{\min}}{x_{\max} - x_{\min}} - 1 \quad (6.11)$$

Burada;

X_t : Normalize veri değerini,

x_t : Gerçek veri değerini,

$x_{\max}$: Veri setindeki en büyük değeri,

$x_{\min}$: Veri setindeki en küçük değeri,

ifade eder.

7. BULGULAR

7.1 Veri setlerinin zaman serisi analizi ve veri yumuřatma uygulamaları


$[-1 +1]$ aralıęında normalize edilen verilerin korelasyon katsayısı düşük olduęu için, bu alıřmada $[0 1]$ aralıęında normalize edilen askıda katı madde giriř-ıkıř verileri kullanılmıřtır (izelge 7.1).

Giriř-ıkıř veri setinin, farklı yumuřatma fonksiyonlarına gre elde edilen cevaplarının etkisi, eřitli eęri uydurma metotları ile llmelidir. Bunun için Matlab programının eęri uydurma modl olan “curve fitting toolbox” kullanılmıřtır (cftool). Giriř-ıkıř veri seti, 6 yumuřatma metodu ile yumuřatılmıřtır (řekil 7.1). Her yumuřatma iřlemi 2. kez gerekleřtirilerek, ikinci cevap veri seti de oluřturulmuřtur (řekil 7.2). Bu iřlem, bir veya iki kere yumuřatılan veri setlerinden hangilerinin cevap setinin daha yksek tutarlılık saęlayacaęını tespit etmek amacıyla uygulanmıřtır.


Her giriř-ıkıř veri seti, 6 deęiřik yumuřatma fonksiyonuna (Moving average, Lowess, Loess, Saitzky-Golay, Robust Lowess, Robust Loess) tabi tutulmuřtur. Elde edilen her iki cevap setine, yksek dereceden sins fonksiyonlarının toplamı ve polinom fonksiyonları ile elde edilen eęri uydurma yntemleri uygulanmıřtır. Cevap setlerinin etkinlikleri korelasyon katsayısı (R^2) ve karesel hata kare kk (RMSE) deęerleri ile llmř ve izelge 7.1’de karřılařtırmalı olarak verilmiřtir.

Çizelge 7.1 Giriş-Çıkış cevap setlerinin eğri uydurma metotlarına etkileri (s:smooth, Low: Lowess, Loe: Loess, R: Robust SAG: Savitzky-Golay, MAV: Moving Average)

	9. Derece Polinom Fonksiyonu		8. Derece Sinüs Fonksiyonlarının Toplamı	
	R-kare	RMSE	R-kare	RMSE
Norm	0.313	0.163	0.402	0.166
sMAV1	0.684	0.067	0.879	0.045
sMAV2	0.739	0.056	0.917	0.034
sLOW1	0.498	0.114	0.602	0.110
sLOW2	0.926	0.026	0.996	0.007
sLOE1	0.378	0.137	0.555	0.126
sLOE2	0.862	0.044	0.973	0.021
sSAG1	0.437	0.122	0.555	0.118
sSAG2	0.459	0.117	0.666	0.100
sRLOW1	0.375	0.113	0.741	0.079
sRLOW2	0.921	0.018	0.987	0.008
sRLOE1	0.375	0.136	0.602	0.118
sRLOE2	0.873	0.037	0.973	0.018




Şekil 7.1 Giriş-Çıkış veri setinin 6 yumuşatma metoduna uygulanmasından elde edilen ilk cevap seti (sag: Savitzky-Golay, rlow: Robust Lowess, rloe: Robust Loess)




Şekil 7.2 Yumuşatılmış 6 cevap setinin tekrar yumuşatılması ile elde edilen ikinci cevap seti
(sag: Savitzky-Golay, rlow: Robust Lowess, rloe: Robust Loess)

Çizelge 7.1 incelendiğinde, ikinci Lowess (sLow02) yumuşatma metodunun en iyi birinci cevap setini (Şekil 7.3) ve ikinci Robust Lowess (sRlow02) metodunun da en iyi ikinci cevap setini (Şekil 7.4) oluşturduğu görülmektedir.




Şekil 7.3 sLow02 cevap setinin polinom fonksiyonu ve sinüs fonk. toplamına göre eğri
uydurma grafiği



Şekil 7.4 sRlow02 cevap setinin polinom fonksiyonu ve sinüs fonk. toplamına göre eğri uydurma grafiği


7.2 Yapay sinir ağı modelinin geliştirilmesi üzerine yapılan uygulamalar

Yumuşatma metotlarından elde edilen cevap setlerinin performansları, bir yapay sinir ağına izlenmiştir. Yapay sinir ağı (Şekil 4.22), 2 katmandan oluşturulmuştur. İleri beslemeli, geriye yayımlı (Feed-Forward Backpropagation) ağı eğitim algoritması Levenberg-Marquardt (trainlm) tır. 10 nöronlu birinci katmanın transfer fonksiyonu tanjant sigmoid (tansig), 1 nöronlu ikinci katmanın transfer fonksiyonu da tansig'dir.




Şekil 7.5 Yumuşatılmış cevap setlerinin uygulandığı yapay sinir ağı yapısı (Matlab 2009a)


Yapay sinir ağının cevap setlerine göre performansları (Şekil 7.6), regresyon (R) değerleri ile Çizelge 7.2'de karşılaştırmalı olarak sunulmuştur.




(a) sMAV1 için




(b) sMAV2 için




(c) sLOW1 için




(d) sLOW2 için




(e) sLOE1 için




(f) sLOE2 için




(g) sSAG1 için




(h) sSAG2 için




(i) sRLOW1 için



(j) sRLOW2 için



(k) sRLOE1 için



(l) sRLOE2 için

Şekil 7.6 Yapay sinir ağının yumuşatılmış cevap setlerine göre performansları


Çizelgeye göre, birinci cevap setinden en iyi sonucu regresyonal olarak, hareketli ortalama (MAV) ve düzeltilmiş lowess (RLOW) ile yumuşatılan sMAV1 ve sRLOW1 setleri vermiştir. Fakat sMOV1 seti ile çalıştırılan ağın performansı sıfıra daha yakındır. İkinci cevap setinden hem regresyonal hem de ağ performansı olarak en iyi sonucu, lowess algoritması ile yumuşatılan sLOW2 cevap seti vermiştir.

Çizelge 7.2 Yapay sinir ağının cevap setlerine göre karşılaştırmalı performans ve regresyon değerleri


Cevap Seti	Epoch	Ağ Performans	R
sMAV1	10	0.00942	0.792
sMAV2	10	0.000784	0.931
sLOW1	15	0.01	0.760
sLOW2	12	0.000068	0.987
sLOE1	14	0.0183	0.356
sLOE2	140	0.000381	0.949
sSAG1	12	0.0396	0.297
sSAG2	7	0.012	0.733
sRLOW1	10	0.011	0.799
sRLOW2	10	0.000104	0.986
sRLOE1	11	0.0072	0.608
sRLOE2	5	0.0341	0.211

7.3 Veri setlerinin, yapay sinir ağı modeline ve ASM1 modeline uygulanması


Şekil 7.7, 7.8, 7.9 ve 7.10'de PAAT ve TAAT ye ait ön çökeltim havuzu girişi ve son çökeltim havuzu çıkışı KOİ, BOİ₅, NH₄-N ve sıcaklık değişim grafiklerine yer verilmiştir.




Şekil 7.7 TAAT (a) ve PAAT (b) yıllık giriş-çıkış KOİ değeri değişimi




(a)




(b)

Şekil 7.8 TAAT (a) ve PAAT (b) yıllık giriş-çıkış BOI_5 değeri değişimi


(a)



(b)

Şekil 7.9 TAAT (a) ve PAAT (b) yıllık giriş-çıkış NH_4-N değeri değişimi

(a)




(b)

Şekil 7.10 TAAT (a) ve PAAT (b) yıllık sıcaklık ($^{\circ}C$) değeri değişimi


YSA modelde, giriş parametrelerinin, çıkış sonucuna etkisini ölçebilmek için etki analizi çalışması yapılmıştır. Bu analizde, TAAT için, KOİ, BOİ₅, NH₄-N ve sıcaklık değerleri farklı kombinasyonlarda giriş değeri olarak kullanılmıştır. Çıkış sonucu olarak KOİ, BOİ₅ ve NH₄-N gözlemlenmiştir. Yapılan ilk çalışmalarda YSA modellerin nöron sayıları 25-50 arasında seçilmiştir. Bu hali ile modellerin çıkış değerleri, gerçek çıkış değerleri ile karşılaştırıldığında, R² değerlerinin 0.35-0.40 aralığında olduğu gözlemlenmiştir. Bu sonuçların tatmin edici olmadığı belirlenmiştir. Bu nedenle nöron sayıları kademeli olarak arttırılmıştır. Buna paralel olarak, başka çalışmalarda en çok kullanılan farklı eğitim fonksiyonları incelenip, kullanılmıştır. Böylece bu çalışma için en uygun eğitim fonksiyonu araştırılmıştır. Sonuçlara ait özet tablolara Ek.1’de yer verilmiştir.

Elde edilen sonuçlarda EK1 incelendiğinde, en uygun eğitim fonksiyonunun traingda olduğu gözlemlenmiştir. En uygun nöron sayısı için, genellikle nöron sayısının artışı ile R² nin arttığı tespit edilmiştir. Böylece spesifik modeller çalıştırılırken, nöron sayısı 100-200 arasında seçilmiştir.


Şekil 7.12, 7.14, 7.16, 7.18 ve 7.20’de, TAAT ve PAAT için 1 senelik periyotta BOİ, KOİ ve AKM parametrelerine ait tesis gerçek çıkış değerleri ile YSA modelinden elde edilen tahminsel çıkış verilerine grafiksel olarak yer verilmiştir. Şekil 7.11, 7.13, 7.15, 7.17 ve 7.19’da ise oluşturulan modellerin, eğitim, doğrulama, test ve genel eğilimlerinin başarımlarına yer verilmiştir.




Şekil 7.11 TAAT için AKM parametresinin YSA modeli eğitim sonuçları




Şekil 7.12 TAAT için AKM parametresi YSA model sonuçlarının, gerçek sonuçlar ile karşılaştırılması $R^2: 0.632$




Şekil 7.13 TAAT için BOİ parametresinin YSA modeli eğitim sonuçları




Şekil 7.14 TAAT için BOİ parametresi YSA model sonuçlarının, gerçek sonuçlar ile karşılaştırılması R^2 : 0.608




Şekil 7.15 TAAT için KOİ parametresinin YSA modeli eğitim sonuçları




Şekil 7.16 TAAT için KOİ parametresi YSA model sonuçlarının, gerçek sonuçlar ile karşılaştırılması R^2 : 0.843




Şekil 7.17 PAAT için BOİ parametresinin YSA modeli eğitim sonuçları



Şekil 7.18 PAAT için BOİ parametresi YSA model sonuçlarının, gerçek sonuçlar ile karşılaştırılması R^2 : 0.807



Şekil 7.19 PAAT için KOİ parametresinin YSA modeli eğitim sonuçları




Şekil 7.20 PAAT için KOİ parametresi YSA model sonuçlarının, gerçek sonuçlar ile karşılaştırılması R^2 : 0.478

Buna göre modellerin eğitimi sırasında en iyi sonuç, TAAT'nin AKM parametresinde elde edilmiştir. Fakat simülasyon açısından en iyi sonuç ise PAAT'nin BOİ₅ parametresinde elde edilmiştir. Genel olarak bakıldığında, modellerin simülasyon başarıları %60'ın üzerinde gerçekleşmiştir. Fakat neredeyse bütün simülasyon başarımları, eğitim başarımlarının altında olduğu gözlemlenmiştir. Özellikle farklı tesislerin aynı parametrelere karşı simülasyon sonuçları oldukça farklılık gösterdiği tespit edilmiştir. BOİ parametresi için TAAT de elde edilen R^2 sonuç 0.608 iken, PAAT de 0.807 olarak hesaplanmıştır. Bunun aksine, KOİ parametresi için TAAT de elde edilen R^2 sonuç 0.84 iken, PAAT de 0.47 olarak hesaplanmıştır. PAAT'nin, bu sonucu ile %68 lık genel başarımlar ortalamasının da altında olduğu tespit edilmiştir. Bu sonuçlara ait özet tabloya, Çizelge 7.3'de yer verilmiştir.


Çizelge 7.3 YSA modelleri eğitim ve simülasyon sonuçları

Parametre	TAAT		PAAT	
	Genel R	R^2	Genel R	R^2
AKM	0.909	0.632	-	-
BOİ ₅	0.678	0.608	0.722	0.807
KOİ	0.841	0.843	0.569	0.478

Çizelge 6.1 incelendiğinde, beş kinetik katsayının, parametreler ile korelasyon halinde olduğu görülmektedir. b_{LH} ve $\mu_{H,max}$ katsayılarının, her iki model için senelik periyottaki değişimine Şekil 7.21, 7.22, 7.23 ve 7.24'de yer verilmiştir.




Şekil 7.21 PAAT için YSA giriş verisi BOİ+T ile elde $\mu_{H,max}$ sonuçlarının, ASM1 model ile elde edilen $\mu_{H,max}$ sonuçları ile karşılaştırılması R^2 : 0.824




Şekil 7.22 PAAT için YSA giriş verisi BOİ+T ile elde b_{LH} sonuçlarının, ASM1 model ile elde edilen b_{LH} sonuçları ile karşılaştırılması R^2 : 0.786

YSA modellerden, PAAT için, b_{LH} ve $\mu_{H,max}$ katsayılarına ait, ASM1 modelden elde edilen katsayı sonuçlarına en yakın sonucu, her iki katsayı için BOİ+T giriş verisi ile eğitilen model vermiştir. Çizelge 7.3’de görüldüğü üzere, BOİ parametresine yine en iyi YSA model sonucunu veren PAAT olmuştur. Bu iki durum birbiri ile paralellik gösterdiği tespit edilmiştir.



Şekil 7.23 TAAT için YSA giriş verisi KOİ+T ile elde $\mu_{H,max}$ sonuçlarının, ASM1 model ile elde edilen $\mu_{H,max}$ sonuçları ile karşılaştırılması R^2 : 0.768



Şekil 7.24 TAAT için YSA giriş verisi KOİ+T ile elde b_{LH} sonuçlarının, ASM1 model ile elde edilen b_{LH} sonuçları ile karşılaştırılması R^2 : 0.821

YSA modellerden, TAAT için, b_{LH} ve $\mu_{H,max}$ katsayılarına ait, ASM1 modelden elde edilen katsayı sonuçlarına en yakın sonucu, her iki katsayı için KOİ+T giriş verisi ile eğitilen model vermiştir. Çizelge 7.3’de görüldüğü üzere, KOİ parametresine yine en iyi YSA model sonucunu veren TAAT olmuştur. Bu iki durum birbiri ile paralellik gösterdiği tespit edilmiştir.

PAAT için, ortalama değerlere bakıldığında; ASM1 modelinden elde edilen kinetik katsayıların ortalaması $\mu_{H,max}$ için 0.20, b_{LH} için 0.021 civarında hesaplanmıştır. YSA modelinden elde edilen ortalamalar ise, $\mu_{H,max}$ için 0.25, b_{LH} için 0.024 olarak hesaplanmıştır. TAAT için bakıldığında; ASM1 modelinden elde edilen kinetik katsayıların ortalaması $\mu_{H,max}$ için 0.21, b_{LH} için 0.021 olarak hesaplanmıştır. YSA modelinden elde edilen ortalamalar ise, $\mu_{H,max}$ için 0.24, b_{LH} için 0.026 olarak hesaplanmıştır. Bu değerler, Çizelge 3.2’de belirtilen, atıksu arıtma tesisleri için tipik ASM1 stokiyometrik – kinetik parametre değerleri arasında kaldığı tespit edilmiştir.

ASM1 modelden her iki tesis için ayrı ayrı elde edilen ilk 100 katsayı verisi ile eğitilen YSA modelinden elde edilmiş b_{LH} ve $\mu_{H,max}$ katsayılarının, ASM1 modelden elde edilen sonuçlar ile karşılaştırılmasına Çizelge 7.4’de yer verilmiştir.

Çizelge 7.4 YSA ve ASM1 modelden elde edilen b_{LH} ve $\mu_{H,max}$ katsayılarının karşılaştırılması
(T: Sıcaklık, °C)


YSA Giriş Verisi	TAAT		PAAT	
	$R^2 b_{LH}$	$R^2 \mu_{H,max}$	$R^2 b_{LH}$	$R^2 \mu_{H,max}$
AKM	0.714	0.626	-	-
BOİ ₅	0.657	0.688	0.741	0.772
KOİ	0.723	0.707	0.603	0.622
BOİ ₅ +T	0.710	0.733	0.786	0.824
KOİ+T	0.821	0.768	0.688	0.657
KOİ+ BOİ ₅	0.586	0.563	0.591	0.639
KOİ+ BOİ ₅ +T	0.635	0.604	0.602	0.658

Çizelge 7.5’de ASM1 model çalışmasında kullanılan bileşenler için, model algoritmasında ki değerlere yer verilmiştir.

Çizelge 7.5 Ön çökeltim sonrası evsel atık suyun tipik karakteristiği (*: Grady vd., 1999)
(- olan bileşenler için tipik giriş değerleri kullanıldı)


Sembol	Birim	*Tipik Giriş değeri	PAAT için ASM1 model Ortalama değeri	TAAT için ASM1 model Ortalama değeri
X_I	mg/L KOİ	40	-	-
X_S	mg/L KOİ	160	137.44	166.87
X_{BH}	mg/L KOİ	96	79.51	84.82
X_{BA}	mg/L KOİ	10	6.24	13.06
X_D	mg/L KOİ	0	0.10	0.10
S_I	mg/L KOİ	40	-	-
S_S	mg/L KOİ	64	72.09	70.08
S_{NO}	mg/L N	1	-	-
S_{NH}	mg/L N	12.5	-	-
S_{NS}	mg/L N	10.1	-	-
X_{NS}	mg/L N	18.28	-	-
S_{ALK}	mM/L	6	-	-

YSA modelde, tesislere bağlı olarak, BOI_5 , KOİ ve Sıcaklık (T) giriş parametrelerinin, çıkış parametreleri üzerine etkileri incelenmiştir. Şekil 7.25, 7.26'da TAAT, Şekil 7.27 ve 7.28'de PAAT için elde edilen etki analizi grafikleri yer almaktadır. Etkisi incelenecek olan parametre, modele maksimum-minimum değerleri arasında girilerek, çıkış parametresinin değişimi gözlenmiştir. Diğer parametrelerin yıllık ortalama değerleri alınmış, sabit değer olarak modele girilmiştir.




Şekil 7.25 TAAT için KOİ etki analizi

(BOI_5 girişort = 500 (sabit), T_{ort} = 14 (sabit) $KOI_{giriş-maks}$ = 2210, $KOI_{giriş-min}$ = 260)




Şekil 7.26 TAAT BOİ₅ etki analizi

(KOİ_{girişort} = 990 (sabit), T_{ort} = 14 (sabit) BOİ₅ giriş-maks = 1100, BOİ₅ giriş-min = 100)



Şekil 7.27 PAAT için KOİ etki analizi

(BOİ_{girişort} = 279 (sabit), T_{ort} = 16.6 (sabit) KOİ giriş-maks = 780, KOİ giriş-min = 120)



Şekil 7.28 PAAT için BOİ₅ etki analizi

(KOİ_{girişort} = 500 (sabit), T_{ort} = 16.6 (sabit) BOİ₅ giriş-maks = 2210, BOİ₅ giriş-min = 260)

Etki analizine ait yukarıdaki şekiller incelendiğinde, her iki arıtma tesisinde de, giriş değerinin artışı ile çıkış değerinin arttığı belirlenmiştir. Artış hızlarının bazı parametrelerde logaritmik, bazı parametrelerde ise doğrusala yakın eğilimde olduğu gözlemlenmiştir.

8. SONUÇLAR ve ÖNERİLER

Bu çalışmada, aktif çamur sisteminin dinamik olarak simüle edilebilirliği çalışılmıştır. Yapay sinir ağı ile aktif çamur sisteminin modellenmesi ve bu modelin, ASM1 modeli ile hibritleştirilmesi üzerine denemeler yapılmıştır. Bunun için, mevcut iki ayrı evsel biyolojik atıksu arıtma tesisi incelenmiştir. Tesislerin aktif çamur proseslerinin giriş-çıkış değerlerinden elde edilen günlük ölçümler temel alınmıştır. Bir yapay sinir ağı geliştirilerek, buradan hareketle tesislerin bazı parametrelerine ait çıkış değerleri için geleceğe yönelik tahmin modeli oluşturulmuştur.

Bu çalışma için oluşturulan yapay sinir ağı modelinin, her iki arıtma tesisi dikkate alındığında, farklı parametrelere göre %55-80 arasında başarı oranının olduğu ve ortalama başarısının yaklaşık %70 olduğu tespit edilmiştir. Ortalama başarı yüzdesi dikkate alındığında, literatürdeki benzer çalışmalara yakın bir başarı ortalaması elde edilmiştir. Model veriminin artırılmasında, verilerin tesislerdeki ölçüm aşaması büyük önem taşımaktadır.

Arıtma tesislerinden, çeşitli parametrelere ait elde edilen günlük ölçüm sonuçlarının yapay sinir ağları ile oluşturulmuş modellerde kullanılabilmesi için, bu sonuçların çeşitli yöntemlerle yumuşatılması gerekmektedir. Parametre ölçüm değerlerinin, arıtma tesisi karakteristiğini, model içine yansıtabilmesi için, tesislerde yapılan analizlerin de son derece hassas olması gerekmektedir. Bir gün içinde yapılan analizlerin sonuçlarının, bir önceki gün sonuçları ile yorumlanması, tesis dinamiklerinin tespit edilebilmesi açısından önem taşımaktadır.

Bu çalışmada ortaya konulan modelin, hem Tuzla atıksu arıtma tesisi hem de Paşaköy atıksu arıtma tesisi için, modelde çalışılan KOİ, BOİ ve AKM parametrelere ait geleceğe yönelik tahminsel öngörülerin oluşturulması amacıyla kullanılabilmesi mümkündür. Böylece, her iki arıtma tesisi için, bu model, çeşitli durumlarda önceden bazı yorumların yapılabilmesine, hatta aktif çamur prosesine önceden müdahaleye olanak sağlamaktadır.

Yapay sinir ağı modelinin, bilim adamlarınca kabul görmüş bir model olan ASM1 modeli ile kolektif çalıştırılması ile elde edilen kinetik katsayılar, tesisler deki aktif çamur proseslerinin veriminin izlenmesi ve kontrolü açısından oldukça önemlidir. Aktif çamur prosesinin temel ölçüm parametreleri ile korelasyon içinde olan bu katsayılar, parametre

analiz sonuçlarının hassas olarak ölçölüp, modelde çalıştırılması ile kolayca öngörüsöl olarak elde edilebilmektedir. Bu duruma olanak sağlaması açısından geliştirilen yapay sinir ağı modeli, tesislerde ki aktif çamur proseslerinin dinamiklerinin izlenmesine kolaylık getirmektedir.

Model başarısının arttırılması amacıyla, aktif çamur ünitelerinde gün içi saatlik ölçümler yapılabilir. Bu ölçüm verilerinin yapay sinir ağı eğitiminde kullanılması ile, modelin başarısına pozitif bir katkı sağlanabilir. Dinamik simölasyonda, zaman serisi aşamalarının sıklaştırılması ile model verimi arttırılabilir. Ancak yeni veriler ile beraber tüm diğör verilerin tasnifinin uzun zaman almaması açısından, ölçüm-değerlendirme işlemlerinin otomatik kontrol ile yapılması, zamandan tasarruf sağlayacaktır.

KAYNAKLAR

- Abusam, A.; Keesman, K.J. ve Spanjers, H. (2002) "Estimation of Uncertainties in the Performance Indices of an Oxidation Ditch Benchmark", *Journal of Chemical Technology and Biotechnology*, 77 (9): 1058-1067.
- Berthouex, P.M. ve Box, G.E. (1996) "Time Series Models for Forecasting Wastewater Treatment Plant Performance", *Water Research*, 30 (8): 1865-1875.
- Choi, D., Park, H. (2001) "A Hybrid Artificial Neural Network as a Software Sensor for Optimal Control of a Wastewater Treatment Process." *Water Research* 35.16 3959-3967.
- Côte, M., Grandjean, B.P.A., Lessard, P., Thibault, J. (1995) "Dynamic Modelling of the Activated Sludge Process: Improving Prediction using Neural Networks." *Water Research* 29.4: 995-1004.
- Daigger, G.T. ve Nolasco, D. (1995) "Evaluation and Design of Full-scale Wastewater Treatment Plants Using Biological Process Models", *Water Science and Technology*, 31(2), 245-255.
- DeLurgio S.A., (1998) "Forecasting Principles and Applications, Mcgraw-Hill International Editions." ISBN 0-07-115998-3
- Gernaey, K.V., van Loosdrecht, M.C.M., Henze, M., Lind, M., Jørgensen, S.B. (2004) "Activated Sludge wastewater treatment plant modelling and simulation: state of the art.", *Environmental Modelling & Software* 19 763-783.
- Gontarski, C.A., Rodrigues, P.R., Mori, M., Prenem, L.F., (2000) "Simulation of an Industrial Wastewater Treatment Plant using Artificial Neural Networks." *Computers and Chemical Engineering* 24 1719-1723.
- Grady, C.P.L., Jr.; Daigger, G.T. ve Lim, H.C. (1999) "Biological Wastewater Treatment (2nd Edition)", Marcel Dekker, Inc. New York, NY.
- Hamed, M. M., Khalafallah, M. G., Hassanien E. A (2004). "Prediction of wastewater treatment plant performance using artificial neural networks" *Environmental Modelling & Software* (19) 919-928.
- Henze, M.; Grady, C.P.L., Jr; Gujer, W.; Marais, G.v.R. and Matsuo, T. (1986) "Activated Sludge Model No. 1". International Association on Water Pollution Research and Control, London, England.
- Henze, M.; Gujer, W.; Mino, T.; Matsuo, T.; Wentzel, M.C. ve Marais, G.v.R. (1995) "Activated Sludge Model No. 2". International Association on Water Quality Science Technology Report No. 3, London, England.
- Henze, M., Leslie Grady, C.P., Gujer Jr, W., Marais, G.V.R., Matsuo, T. (1987) "A General Model For Single-Sludge Wastewater Treatment Systems." *Water Research* 505-515.

Huo, J.; Seaandr, W.L.; Robinson, R.B. ve Cox, C.D. (2005) "Application of Time Series Models to Analyze and Forecast the Influent Components of Wastewater Treatment Plants (WWTPs)", EWRI '05 World Water & Environmental Resources Congress, Anchorage, Alaska, May 15-19, 2005.

İSKİ, İstanbul Su ve Kanalizasyon İdaresi, (2004), "Paşaköy atıksu arıtma tesisi faaliyet raporu", İstanbul

İSKİ, İstanbul Su ve Kanalizasyon İdaresi, (2007), "Tuzla atıksu arıtma tesisi faaliyet raporu", İstanbul

İSKİ, İstanbul Su ve Kanalizasyon İdaresi, (2009), <http://www.iski.gov.tr>

Jeppsson, U., ve Olsson, G. (1993), "Reduced order models for on-line parameter identification of the activated sludge process." Water Sci. Technol. 28(11/12), 173-183

Kabouris, J.C. ve Georgakakos, A. P. (1996) "Parameter and State Estimation of the Activated Sludge Process-I. Model Development", Water Research, 30(12), 2853-2865.

Magbanua, B.S. (2004) "Probability Modeling of Activated Sludge Systems: Strategies for Reducing Process Uncertainty", EWRI '04 World Water & Environmental Resources Congress, Salt Lake City, Utah, June 27-July 1, 2004.

Matlab R2009, (2009), The Mathworks INC., Matlab User Manual

Matlab R14, (2006), The Mathworks INC., Matlab User Manual

Melcer, H. (1999) "Full Scale Experience with Biological Process Models- Calibration" Issues, Water Science Technology, 39(1), 245-252.

Metcalf ve Eddy, Inc. (1991) "Wastewater Engineering: Treatment, Disposal, and Reuse" , (Revised by Tchobanoglous, G.; and Burton F.L.), McGraw Hill, New York, NY.

Petersen B., Gernaey K., Henze M. ve Vanrolleghem P.A. (2003) "Calibration of activated sludge models: A critical review of experimental designs." In: Biotechnology for the Environment: Wastewater Treatment and Modeling, Waste Gas Handling. Eds. Agathos S.N. and Reineke W., Kluwer Academic Publishers, Dordrecht, The Netherlands. 101-186.

Rousseau, D.; Verdonck, F.; Moerman, O.; Carrette, R.; Thoeye, C.; Meirlaen, J. Ve Vanrolleghem, P.A. (2001) "Development of a Risk Assessment Based Technique for Design/retrofitting of WWTPs", Water Science and Technology, 43(7), 287-294.

Spanjers, H. ve Vanrolleghem, P. (1995) "Respirometry as a Tool for Rapid Characterization of Wastewater and Activated Sludge", Water Science and Technology, 31(2), 105-114.

Tchobanoglous, G.; Burton, F.L ve Stensel, B.H (1991) "Wastewater Engineering: Treatment and Reuse", Metcalf & Eddy, Inc., McGraw Hill

Vasquez, V.R. ve Whiting, W.B. (1999) "Effect of Systematic and Random Errors in Thermodynamic Models on Chemical Process Design and Simulation: A Monte Carlo Approach", *Industrial and Engineering Chemistry Research*, 38, 3036-3045.

Zeng R.J., McMurray S.H., Meyer R.L., Yaun Z. ve Keller J. (2004) "Integration of titrimetric measurement, off-gas analysis and NO_x- biosensors to investigate the complexity of denitrification processes" In proceedings: 2nd IWA conference on Automation in Water Quality Monitoring (AutMoNet2004), April 19-20, Vienna, Austria, pp 53-59.

EK1. Etki analizi sonuçları

TRAININGDA					
Çıkış verisi	Giriş verisi	İlk değer R ²	Sabit giriş verisi	Nöron Sayısı	R ²
BOİ ₅	BOİ+T	0.610	T	100	0.572
				150	0.588
				200	0.601
	KOİ+T	0.754	T	100	0.748
				150	0.766
				200	0.790
	BOİ+KOİ+T	0.627	BOİ	100	0.554
				150	0.582
				200	0.594
	BOİ+KOİ+T		KOİ	100	0.627
				150	0.641
				200	0.655
	BOİ+KOİ+T		T	100	0.478
				150	0.471
				200	0.494
KOİ	BOİ+T	0.721	T	100	0.657
				150	0.687
				200	0.692
	KOİ+T	0.757	T	100	0.686
				150	0.702
				200	0.712
	BOİ+KOİ+T	0.684	BOİ	100	0.559
				150	0.614
				200	0.632
	BOİ+KOİ+T		KOİ	100	0.622
				150	0.634
				200	0.640
	BOİ+KOİ+T		T	100	0.668
				150	0.670
				200	0.670
NH ₄ -N	NH ₄ -N+T	0.687	T	100	0.659
				150	0.667
				200	0.670

TRAINGDM					
Çıkış verisi	Giriş verisi	İlk değer R ²	Sabit giriş verisi	Nöron Sayısı	R ²
BOİ ₅	BOİ+T	0.610	T	100	0.522
				150	0.547
				200	0.558
	KOİ+T	0.754	T	100	0.708
				150	0.715
				200	0.710
	BOİ+KOİ+T	0.627	BOİ	100	0.500
				150	0.479
				200	0.511
	BOİ+KOİ+T		KOİ	100	0.535
				150	0.552
				200	0.548
	BOİ+KOİ+T		T	100	0.588
				150	0.579
				200	0.602
KOİ	BOİ+T	0.721	T	100	0.604
				150	0.614
				200	0.642
	KOİ+T	0.757	T	100	0.634
				150	0.652
				200	0.669
	BOİ+KOİ+T	0.684	BOİ	100	0.487
				150	0.501
				200	0.512
	BOİ+KOİ+T		KOİ	100	0.544
				150	0.571
				200	0.580
	BOİ+KOİ+T		T	100	0.607
				150	0.607
				200	0.615
NH ₄ -N	NH ₄ -N+T	0.687	T	100	0.633
				150	0.630
				200	0.636

TRAINLM					
Çıkış verisi	Giriş verisi	İlk değer R ²	Sabit giriş verisi	Nöron Sayısı	R ²
BOİ ₅	BOİ+T	0.610	T	100	0.534
				150	0.537
				200	0.548
	KOİ+T	0.754	T	100	0.717
				150	0.725
				200	0.718
	BOİ+KOİ+T	0.627	BOİ	100	0.530
				150	0.490
				200	0.511
	BOİ+KOİ+T		KOİ	100	0.525
				150	0.561
				200	0.550
	BOİ+KOİ+T		T	100	0.580
				150	0.580
				200	0.594
KOİ	BOİ+T	0.721	T	100	0.598
				150	0.614
				200	0.632
	KOİ+T	0.757	T	100	0.616
				150	0.632
				200	0.684
	BOİ+KOİ+T	0.684	BOİ	100	0.477
				150	0.501
				200	0.510
	BOİ+KOİ+T		KOİ	100	0.555
				150	0.587
				200	0.580
	BOİ+KOİ+T		T	100	0.600
				150	0.600
				200	0.608
NH ₄ -N	NH ₄ -N+T	0.687	T	100	0.627
				150	0.620
				200	0.644

EK2. Matlab ASM1 model kodları

```
% program_1:simule.m
% asm1 parametreleri, giriş özellikleri ve reaktör koşulları tanımlanmıştır.
% değişkenler, model parametreleri ve giriş özellikleri değerlerinin atanabilmesi için
% vektörize edilmiştir.

function [t, y] = simule(xinit, fa, tc, ndngu);

% değişkenler
% ss          hızlı parçalanabilen substrat, mg koi/l
% xs          yavaş parçalanabilen substrat, mg koi/l
% xbh         heterotrofik kütle, mg/l
% xba         ototrofik kütle, mg/l
% snh         amonyak azotu, mg n/l
% sno         nitrat ve nitrit azotu, mg n/l
% xp          inert partiküller, mg/l
% snd         çözünebilir parçalanabilir organik azot, mg n/l
% xnd         partiküle parçalanabilir organik azot, mg n/l
% salk        alkalinite, mmol/l
% so          çözülmüş oksijen, mg/l
% fa          döngü katsayısı, kullanıcı kontrollü
% tc          döngünün toplam süresi (saat), kullanıcı kontrollü
% xinit       döngünün başlangıcında, değişkenler için kullanılan, başlangıç tahmin vektörü
              kullanıcı kontrollü
% ndngu       sistemin kararlı hale ulaşabilmesi için gerekli döngü sayısı

% çıkış

% t          döngü zaman dilimi (saat)
% y          sistem dinamiği

global lagfaz giris model mnturev

% stokiyometrik katsayılar

ya = 0.24;    % ötotrofik büyüme , mg koi/mg n
yh = 0.67;    % heterotrofik büyüme, mg koi/mg koi
fp = 0.08;    % biyokütle büyüme fraksiyonu
ixb = 0.086;  % biyokütle içindeki azot fraksiyonu, mg n/mg koi
ixp = 0.06;   % bozunma ürünlerindeki azot fraksiyonu, mg n/mg koi

% kinetik katsayılar

uh = 6.0;     % heterotroflar için spesifik büyüme hızı, 1/d
ua = 0.65;    % ototroflar için spesifik büyüme hızı, 1/d
bh = 0.62;    % heterotroflar için ayrışma hızı, 1/d
ba = 0.12;    % ototroflar için ayrışma hızı, 1/d
ng = 0.8;     % anoksik büyüme için düzeltme faktörü
```


nh = 0.7; % hidroliz için düzeltme faktörü
ka = 5.0; % çözülmüş organik azot için amonyaklaşma katsayısı, 1/d
kh = 0.1; % partiküle organik hidroliz hızı, 1/d

% monod yarılanma katsayıları

ks = 5.0; % mg koi/l
koh = 0.1; % mg koi/l
kno = 0.2; % mg n/l
knh = 0.2; % mg n/l
koa = 1.0; % mg koi/l
kalk = 0.1; % mmol/l
kx = 0.15; % mg koi/mg koi
teta = 12; % hidrolik bekleme süresi, saat
r = 15; % ortalama hücre bekleme süresi, gün
model = [ya; yh; fp; ixb; i'xp; ba; uh; ks; koh; kno; bh; ng; nh; kh; kx; ua; knh; koa; ka; kalk; teta, t]
% model vektörü asm1 in parametrelerini içermektedir.
% model simülasyonu için giriş değerleri
ss_mod = 182; % hızlı parçalanabilen substrat, mg koi/l
xs_mod = 69; % yavaş parçalanabilen substrat, mg koi/l
snd_mod = 6.9; % biyolojik parçalanabilen çözülmüş organik azot, mg n/l
xnd_mod = 8.8; % biyolojik parçalanabilen partikül organik azot, mg n/l
snh_mod = 24.1; % amonyak azotu, mg n/l
sno_mod = 0; % nitrat ve nitrit azotu, mg n/l
salk_mod = 4.3; % alkalinite, mmol/l
so_mod = 0; % çözülmüş oksijen, mg koi/l
% bu vektör giriş özelliklerini içermektedir
giris = [ss_mod, xs_mod, snd_mod, xnd_mod, snh_mod, sno_mod, salk_mod, so_mod];
% türev alma için zaman adımı tanımlama
tend = tc/24; % zaman adımının günden saate çevrilmesi
t0 = 0; % giriş zaman değeri 0
tstep = 0.0003; % türev alma zaman değeri: 0.003 gün = 4.32 dakika
mnturev = tstep;
z0 = xinit';
% sistem simülasyonu
if ndngu > 0
func = 'asm1_mod'; % asm1 model yazılımı çağırılıyor
t = [];
y = [];
for precyc = 1 : ndngu
[tcyc, ycyc] = turevci(func, t0, tend, z0, tstep, 0, fa); % türev proseduru çağırılıyor
t = [t 24*tcyc + (precyc-1)*tc];
y = [y, ycyc];
n = length(ycyc);
z0 = ycyc(n,:);
save z0;
end;

```

end;
% program_2: asml_mod.m
% aerobik anoksik aerobik kosullar icin bagintilar formüle edilmiştir.
% sistem kosullarını içeren vektörler, her başlangıç değişkeni için ilgili bağıntıya
% yönlendirilir
% simule.m dosyası içindeki rutin döngüleri çağırır.

function [f] = asml_mod(x,lagfaz,giris,model);

ya = model(1); yh = model(2); fp = model(3); ixb = model(4); ixp = model(5); ba = model(6);
uh = model(7); ks = model(8); koh = model(9); kno = model(10); bh = model(11); ng =
model(12); nh = model(13); kh = model(14); kx = model(15); ua = model(16); knh =
model(17); koa = model(18); ka = model(19); kalk = model(20); theta = model(21); mcrt =
model(22);

ss_inf = giris(1); xs_inf = giris(2); snd_inf = giris(3); xnd_inf = giris(4); snh_inf = giris(5);
sno_mod = giris(6); salk_mod = giris(7); so_mod = giris(8);

% oksijen transfer katsayısının tespiti
q = 0.5;
qq = 24;
soo = 8.5;

kla = 0.0; % havasız,
if lagfaz == 1, % hava ile
kla = (25.8 * q - 3.5) * qq;
end;
ss = x(1); xs = x(2); xbh = x(3); xba = x(4); snh = x(5); sno = x(6); xp = x(7); snd = x(8); xnd
= x(9); salk = x(10); so = x(11);

% sıfırın altındaki her konsantrasyon sıfır kabul edilecek

jneg = find(x < 0);
if jneg > 0;
x(jneg) = zeros(length(jneg),1);
end;

% asml e bağlı proses hızları
% heterotrofik büyüme hızı
r1 = uh*(ss/(ks+ss))-(so/(so+koh))*xbh;
% anoksik heterotrofik büyüme hızı
r2 = uh*(ss/(ks+ss))*(koh/(koh+so))*(sno/(kno+sno))*ng*xbh;
% aerobik otorofik büyüme hızı
r3 = ua*(snh/(snh+knh))*(so/(so+koa))*xba*(salky(salk+kalk));
% heterotrofik ayrışma hızı
r4 = bh * xbh;
% ototrofik ayrışma hızı
r5 = ba * xba;

```

```

% çözünmüş organik azotun amonyaklaşma proses hızı
r6 = ka * snd * xbh;
% bağlı organik bileşiklerin hidroliz hızı
r7 = kh^xs/(kx+(xs/xbh))*((so/(so+koh)+nh*(koh/(koh+so))*(sno/(sno+kno)));
% bağlı azotlu bileşiklerin hidroliz hızı
r8 = r7*(xnd/xs);

% asm1 de bildirilen her değişken için stokiyometrik zaman türevleri
% xbh kütle dengesi (heterotrof)
dxbh = -(xbh/mcrt) + r1 + r2 - r4;
% xba kütle dengesi (ototrof)
dxba = -(xba/mcrt) + r3 - r5;
% xs kütle dengesi (partikül organik substrat)
dxs = (xs_mod/theta) - (xs/mcrt) + (r4+r5)*(1-fp) - r7;
% xnd kütle dengesi (partikül organik azot)
dxnd = (xnd_mod/theta) - (xnd/mcrt) + (r4+r5)*(ixb-fp*ixp) - r8;
% xp kütle dengesi (ayırışma)
dxp = (-xp/mcrt) + (r4+r5)*fp;
% ss kütle dengesi (çözünmüş organik substrat)
dss = ((ss_mod-ss)/theta) - (1/yh)*(r1+r2) + r7;
% snh kütle dengesi (amonyak azotu)
dsnh = ((snh_mod-snh)/theta) - ixb*(r1+r2) - (ixb+1/ya)*r3 + r6;
% sno kütle dengesi (nitrit ve nitrat azotu)
dsno = ((sno_mod-sno)/theta) - ((1-yh)/(2.86*yh))^2 + r3/ya;
% snd kütle dengesi (çözünmüş organik azot)
dsnd = ((snd_mod-snd)/theta) - r6 + r8;
% salk kütle dengesi (alkalinite)
dsalk = ((salk_mod-salk)/theta)-(ixb/14)*rt+((1-yh)/(14*2.86*yh)-ixb/14)*r2-...
(ixb/14+1/(7*ya))*r3 + r6/14;
% oksijen tüketim hızı
our= r1*(1/yh-1) + r3*(4.57/ya-1);
% so kütle dengesi (çözünmüş oksijen)
dso = (so_mod-so)/theta + kla*(soo-so) - our;

f = [dss; dxs; dxbh; dxba; dsnh; dsno; dxp; dsnd; dxnd; dsalk; dso];

% program_3: turevci.m
function [t,y,v] = turevci(func,to,tfinal,yo,dtdef,vflag,fa)
global lagfaz giris model mnturev
lagfaz = 0;
if vflag == 0
dtmax = dtdef;
dtmin = (tfinal-to)/10000;
kt = 0.05;
c = 0.0001;
x = yo;
dt = dtdef;
mnturev = dtdef;

```

```

i = i;
time = t0;
t(i) = time;      % baslangic zamani
y(i,:) = x';
% baslangic zaman adimi icin
[u1] = feval(func,time,x);
[u2] = feval(func,time+dt/2, x+u1*dt/2);
du = u2-u1;
dt = kt*0.5*dt*norm(u1,inf)/(norm(du,inf)+c);
if dt>dtmax,
dt = dtmax;
end;
if dt<dtmin,
dt = dtmin;
end;
while abs(time) < abs(tfinal)
if (time-t0)>(1-fa)*(tfinal-t0),
lagfaz = 1;
end;

if dt<mnturev,
mnturev=dt;
end;
if abs(time + dt) > abs(tfinal),
dt = tfinal - time;
end;
[u1] = feval(func,time,x);
[u2] = feval(func,time+dt/2,x+u1*dt/2);
[u3] = feval(func,time+dt/2,x+u2*dt/2);
[u4] = feval(func,time+dt,x+u3*dt);
x = x + (dt/6)*(u1+2*u2+2*u3+u4);
time = time + dt;
du = u4-u1;
dt = kt*dt*norm(u1,inf)/(norm(du,inf)+c);
if dt>dtmax,
dt = dtmax;
end;
if dt<dtmin,
dt = dtmin;
end;
jneg = find(x < 0);
if jneg>0,
x(jneg) = zeros(length(jneg),1);
end;
i = i + 1;
else
t(i) = time;
y(i,:) = x-;

```

```

end;
mnturev
dtmax = dtdef;
dtmin = (tfinal-t0)/10000;
kt = 0.05;
c = 0.0001;
n = length(yo);
v = eye(n,n);
id = eye(n,n);
x = y0;
dt = dtdef;
time = t0;
i = i;
t(i) = time;      % giris noktasi
y(i,:) = x';
% giris zaman adimi icin
[u1,u1] = feval(func,time,x);
dt = 1/(norm(max(abs(u1)),inf)+c);
if dt>dtmax,
dt = dtmax;
end;
if dt<dtmin,
dt = dtmin;
end;
while abs(time) < abs(tfinal)
if (time-t0)>(1-fa)*(tfinal-t0),
lagfaz = 1;
end;
if abs(time + dt) > abs(tfinal),
dt = tfinal - time;
end;
[u1,u1] = feval(func,time,x);
[u2,u2] = feval(func,time+dt/2,x+urdt/2);
[u3,u3] = feval(func,time+dt/2,x+u2*dt/2);
[u4,u4] = feval(func,time+dt,x+u3*dt);
x = x + (dt/6)*(u1+2*u2+2*u3+u4);
time = time + dt;
dt = 1/(norm(max(abs(u4)),inf)+c);
if dt>dtmax,
dt = dtmax;
end;
if dt<dtmin,
dt = dtmin;
end;
jneg = find(x < 0);
if jneg>0,
x(jneg) = zeros(length(jneg),1);
end;

```

```

% jakobyan analitik çözümü
v= v + (dt/6)*(u1+2*u2+2*u3+u4);
% jakobyan nümerik türev
j2 = u2*(id+(dt/2)*u1);
j3 = u3*(id+(dt/2)*j2);
j4 = u4*(id+(dt)*j3);
tmpv = v;
v= tmpv*( id + (dt/6)*(u1+2*j2+2*j3+j4));
i = i + 1;
t(i) = time;
y(i,:) = x';
end;
end;

```

ÖZGEÇMİŞ

Doğum tarihi 03.08.1982

Doğum yeri İstanbul

Lise 1996-2000

Halide Edip Adıvar Lisesi

Lisans 2000-2005

Uludağ Üniversitesi, Mühendislik Mimarlık Fakültesi
Çevre Mühendisliği Bölümü

Yüksek Lisans 2006-

Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü
Çevre Müh. Anabilim Dalı, Çevre Müh. Programı

Çalıştığı kurumlar

2005-Devam

Proses Mühendislik Arıtma Sistemleri İnş. San ve Tic.
Ltd. Şti.