

**ARITMA PROSESLERİNİN YAPAY ZEKA VE  
ÇOKLU İSTATİSTİKSEL YÖNTEMLER İLE MODELLENMESİ**

**Gökhan CİVELEKOĞLU**

**DOKTORA TEZİ  
ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI  
ISPARTA – 2006**

**ARITMA PROSESLERİNİN YAPAY ZEKA VE ÇOKLU  
İSTATİSTİKSEL YÖNTEMLER İLE MODELLENMESİ**

**Gökhan CİVELEKOĞLU**

**Danışman  
Doç.Dr. Mehmet KİTİŞ**

**İkinci Danışman  
Doç.Dr. Özer ÇINAR**

**DOKTORA TEZİ  
ÇEVRE MÜHENDİSLİĞİ BÖLÜMÜ  
ISPARTA – 2006**

**T.C.  
SÜLEYMAN DEMİREL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

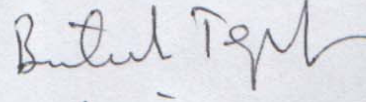

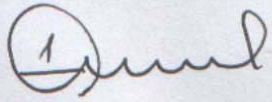
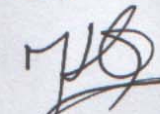
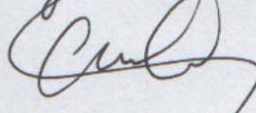
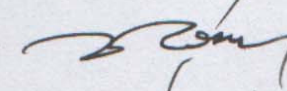
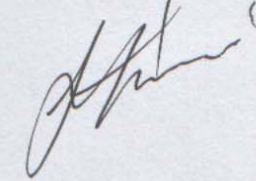
**ARITMA PROSESLERİNİN YAPAY ZEKA VE ÇOKLU  
İSTATİSTİKSEL YÖNTEMLER İLE MODELLENMESİ**

**Gökhan CİVELEKOĞLU**

**DOKTORA TEZİ  
ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI  
ISPARTA – 2006**

Fen Bilimleri Müdürlüğüne

Bu çalışma jürimiz tarafından ÇEVRE MÜHENDİSLİĞİ ANABİLİMDALI'nda DOKTORA TEZİ olarak kabul edilmiştir.

Başkan : Prof. Dr. Bülent TOPKAYA   
Üye : Prof. Dr. S. Nilay KESKİN   
Üye : Prof. Dr. M. Erol KESKİN   
Üye : Doç. Dr. Mehmet KİTİŞ   
Üye : Doç. Dr. Özer ÇINAR   
Üye : Yrd. Doç. Dr. İsmail TOSUN   
Üye : Yrd. Doç. Dr. Serdal TERZİ 

**ONAY**

Bu tez 26/07/2006 tarihinde yapılan tez savunma sınavı sonucunda, yukarıdaki jüri üyeleri tarafından kabul edilmiştir.

...../...../200

**Prof. Dr. Fatma GÖKTEPE**  
**Enstitü Müdürü**

**İÇİNDEKİLER**

İÇİNDEKİLER .....	i
ÖZET.....	iii
ABSTRACT .....	v
ÖNSÖZ ve TEŞEKKÜR.....	vii
SİMGELER (KISALTMALAR) DİZİNİ .....	viii
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ .....	xv
1. GİRİŞ .....	1
1.1. Motivasyon.....	1
1.2. Amaç .....	2
1.3. Kapsam.....	2
2. KAYNAK BİLGİSİ .....	5
2.1. Matematiksel Modelleme Yaklaşımları .....	5
2.1.1. Aktif Çamur Modelleri.....	5
2.1.1.1. Giriş.....	5
2.1.1.2. ASM No.1 .....	7
2.1.1.3. ASM No.3 .....	13
2.1.2. Çoklu İstatistiksel Modelleme Teknikleri.....	19
2.1.2.1. Giriş.....	19
2.1.2.2. Temel Bileşenler Analizi (PCA).....	20
2.1.2.3. Çoklu Lineer Regresyon (MLR) Analizi .....	22
2.1.3. Yapay Zeka Modelleme Teknikleri .....	25
2.1.3.1. Giriş.....	25
2.1.3.2. Bulanık Mantık (FL) .....	27
2.1.3.3. Yapay Sinir Ağları (ANN).....	33

2.1.3.4. Adaptif Ağ Temelli Bulanık Çıkarım Sistemi (ANFIS) .....	45
3. MATERYAL ve METOT .....	49
3.1. Modellerin Tasarımı ve Çalıştırılması .....	49
3.1.1. PCA Metodu .....	49
3.1.2. MLR Metodu.....	50
3.1.3. ANN Metodu.....	51
3.1.4. ANFIS Metodu.....	52
3.1.5. Aktif Çamur 1 ve 3 (ASM1 ve ASM3) Modelleri .....	55
3.1.5.1. Hassasiyet Analizleri.....	57
3.1.5.2. Parametre Tahmini .....	58
3.1.5.3. Kalibrasyon .....	59
3.1.5.4. Doğrulama.....	59
4. BULGULAR.....	60
4.1. İçme Suyu Arıtımında Ozonlama Sonucu Bromat Oluşumunun Çoklu Regresyon Analizi ve Yapay Sinir Ağları ile Modellenmesi.....	60
4.2. Endüstriyel Atıksu Arıtma Tesisinde Karbon ve Azot Gideriminin Temel Bileşenler Analizi ve Adaptif Ağ Temelli Bulanık Çıkarım Sistemi ile Modellenmesi.....	83
4.3. Kentsel Atıksu Arıtma Tesisi Performansının Yapay Zeka Yöntemleri ile Modellenmesi.....	102
4.4. Evsel Atıksu Arıtma Tesisinde Karbon Gideriminin Yapay Sinir Ağları ve Adaptif Ağ Temelli Bulanık Çıkarım Sistemi ile Modellenmesi .....	109
4.5. Evsel Atıksu Arıtma Tesisinde Karbon ve Azot Gideriminin Adaptif Ağ Temelli Bulanık Çıkarım Sistemi ve ASM Yaklaşımı ile Modellenmesi .....	124
5. TARTIŞMA ve SONUÇ.....	144
6. KAYNAKLAR .....	148
ÖZGEÇMİŞ .....	155

## ÖZET

### Arıtma Proseslerinin Yapay Zeka ve Çoklu İstatistiksel Yöntemler ile Modellenmesi

Gökhan CİVELEKOĞLU

İster eş zamanlı isterse gecikmeli (off line) olarak ölçülsün, elde edilen verilerin arıtma tesislerinin izleme ve kontrolü amacıyla kullanılabilmesi için güvenilir ve sistematik değerlendirilme metotlarına ihtiyaç bulunmaktadır. Bu amaçla tez kapsamında, arıtma proseslerine ait geçmişte elde edilen veriler yapay zeka metotları (yapay sinir ağları, ANN ve adaptif ağ temelli bulanık çıkarım sistemi, ANFIS) ve çoklu istatistiksel yöntemler (temel bileşenler analizi, PCA ve çoklu lineer regresyon, MLR) ile değerlendirilerek modellenmiştir. Ayrıca, Uluslararası Su Birliği (IWA) tarafından geliştirilen aktif çamur prosesi modelleri (ASM1 ve ASM3) uygulanarak mekanistik ASM model yaklaşımları ile bir yapay zeka yöntemi (ANFIS) karşılaştırılmış ve tartışılmıştır. Bu kapsamlarda, verileri kullanılan ve modellenen arıtma tesisleri su kalitelerine ve arıtma amaçlarına göre geniş bir spektrumda seçilmiştir. Çalışılan arıtma tesisleri ve bu tesislerde modellenen kirletici parametreleri; evsel ve kentsel atıksu arıtma tesislerinde (toplam 3 farklı tesis) kimyasal oksijen ihtiyacı (KOİ), amonyum azotu ( $\text{NH}_4\text{-N}$ ) ve nitrat azotu ( $\text{NO}_3\text{-N}$ ), bir endüstriyel atıksu arıtma tesisinde KOİ, amonyum azotu ve toplam azot (TN), ve ozonlama uygulayan bir içme suyu arıtma tesisinde bromat iyonunu ( $\text{BrO}_3^-$ ) içermektedir.

Çoklu istatistiksel yaklaşımlar içerisinde yer alan PCA, özellikle değişkenler arasındaki ilişkilerin tam olarak tespit edilemediği kompleks arıtma sistemlerinin analiz edilerek daha küçük boyutta temsil edilebilmesine imkan tanımıştır. Benzer şekilde çoklu istatistiksel yaklaşımlardan bir olan MLR metodunun, değişkenlerin lineer ilişkiye sahip olduğu bilinen arıtma sistemlerini etkili bir şekilde tanımladığı tespit edilmiştir. Aynı arıtma prosesi içerisinde kullanılan yapay zeka yöntemlerinin ise çoklu istatistiksel yöntemlere nazaran, daha güvenilir ve hassas sonuçlar verdiği gözlenmiştir.

Atıksu arıtma tesislerinde aerobik biyolojik oksidasyonun ve tesis performansının değerlendirilmesi aşamasında da ANFIS, ANN ve ASM modelleri ayrı ayrı oluşturulmuş ve karşılaştırılmıştır. ASM modelleri içerisinde ASM3 yaklaşımı, ASM1 yaklaşımına nazaran daha iyi sonuçlar vermiştir. Fakat ASM model yaklaşımları atıksu arıtma

tesisine ait deęişkenleri mekanistik olarak oldukça iyi tanımlayabilmekle birlikte, seçilen hedef deęişkenlerin tahmininde oldukça zayıf kalmıştır. ANFIS ve ANN model mimarilerinin ise atıksu arıtma tesisi performansının ve aerobik biyolojik oksidasyonunun, girdi ve çıktı deęişken bazlı deęerlendirmesinde oldukça güçlü olduęu sonucuna varılmıştır. Ayrıca çalışma kapsamında deęerlendirilen yapay zeka yöntemleri içerisinde yer alan ANFIS yaklaşımının eğitim algoritması yanında nümerik gruplandırma ve kural koyma gibi gelişmiş veri analiz metotlarını barındırmasından ötürü tahmin kapasitesinin ANN yaklaşımından daha iyi olduęu tespit edilmiştir.

Sonuç olarak tez kapsamında ele alınan yapay zeka metotlarının, arıtma proseslerine ait sebep-sonuç ilişkilerini çok iyi bir şekilde tanımladıęı, bu nedenle kompleks proseslerin izlenmesi, kontrolü ve otomasyonunda kullanılabilirlik potansiyelinin bulunduęu tespit edilmiştir.

**Anahtar Kelimeler:** ANFIS, ASM, atıksu arıtma, bromat, MLR, modelleme, PCA, yapay zeka



## ABSTRACT

### **The Modeling of Treatment Processes with Artificial Intelligence and Multistatistical Methods**

**Gökhan CİVELEKOĞLU**

Whether the data is obtained on-line or off-line, reliable and systematic methods are necessary to evaluate and use the data for treatment plant monitoring and control. In this context, artificial intelligence (AI) methods (including artificial neural networks, ANN and adaptive network based fuzzy inference system, ANFIS) and multi-variate statistical techniques (including principal component analysis, PCA and multi-linear regression, MLR) were employed in this dissertation to model treatment plant performance. Historical treatment plant data was used for such modeling efforts. Furthermore, the mechanistic activated sludge models (ASM1 and ASM3) developed by the International Water Association (IWA) were used and the performances of such models were compared side-by-side with those obtained from ANFIS modeling. In an effort to investigate the applicability of AI and multivariate statistical techniques on estimating the performances of treatment processes with a wide spectrum, a total of five different full-scale water and wastewater treatment plants were selected. These plants and their effluent parameters selected for estimation by models include an industrial (sugar production factory) wastewater treatment plant (COD,  $\text{NH}_4\text{-N}$  and TN), two municipal wastewater treatment plants (COD), a domestic wastewater treatment plant (COD,  $\text{NH}_4\text{-N}$  and  $\text{NO}_3\text{-N}$ ), and a water treatment plant employing ozonation ( $\text{BrO}_3^-$ ). Separate models were developed for each plant using its historical data.

PCA results indicated that it is a useful technique for complex treatment systems in which, the interactions among variables are not fully understood, and that it is effective in representing the system with reduced model dimensions. On the other hand, MLR method was found to be very successful in defining treatment systems containing linear interactions among variables. Artificial intelligence methods, however, provided more reliable and sensitive predictions than those obtained by multi-variate statistical methods (PCA and MLR) for each treatment plant studied.

ANFIS, ANN and ASM models were developed separately for the prediction of treatment performance of aerobic biological stages in wastewater treatment plants. It was

found that ASM3 models provided more realistic results than ASM1. Although both of the mechanistic ASM models well-defined the variables in the treatment plants, they could not sufficiently predict the target effluent parameters. On the other hand, ANFIS and ANN model architectures well-defined both the variables and the relations among input and output variables. Furthermore, it was found that prediction capability of ANFIS approach was better than ANN mainly due to the fact that it contains training algorithm, data clustering and rule based modeling structure.

Results overall indicated that artificial intelligence approaches employed in this dissertation are very successful in evaluating treatment performances and predicting effluent parameters for all water and wastewater treatment plants studied. Therefore, such model algorithms appear to have full-scale application potentials for monitoring, on-line control and automation of complex processes in treatment plants.

**Keywords:** ANFIS, artificial intelligence, ASM, bromate, MLR, modeling, PCA, wastewater treatment

## ÖNSÖZ ve TEŞEKKÜR

Bu çalışma, Süleyman Demirel Üniversitesi Mühendislik Mimarlık Fakültesi Çevre Mühendisliği Bölümü Öğretim Üyesi Doç.Dr. Mehmet KİTİŞ yönetiminde hazırlanarak, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsüne Doktora Tezi olarak sunulmuştur. Bu tez, 1155-D-05 nolu Doktora Tez Projesi kapsamında Süleyman Demirel Üniversitesi Araştırma Projeleri Yönetim Birimince desteklenmiştir.

Doktora tez konusunun tespitinden tamamlanması aşamasına kadar geçen süre içerisinde sabrını ve yardımını esirgemeyen danışmanım Doç.Dr. Mehmet KİTİŞ'e, görüş ve fikirleri ile tezin olgunlaşmasında katkıda bulunan eş danışmanım Doç.Dr. Özer ÇINAR'a, ayrıca Prof.Dr. M.Erol KESKİN ve Dr. Altunay PERENDECİ'ye, tez izleme komitesinde yer alarak bana yön veren Prof.Dr. Bülent TOPKAYA ve Prof.Dr. S.Nilay KESKİN'e, bilgi ve deneyimlerini aktarmaktan çekinmeyen Girit Teknik Üniversitesi öğretim üyesi Prof.Dr. Evan DIAMADOPOULOS'a, doktora programı süresince sevgi ve desteği ile her zaman yanımda olan eşime ve tüm aile fertlerime içtenlikle teşekkür ederim.

## SİMGELER (KISALTMALAR) DİZİNİ

AAT	: Atıksu Arıtma Tesisi (Wastewater Treatment Plant, WWTP)
AÇP	: Aktif Çamur Prosesi (Activated Sludge Process)
AKM	: Askıda Katı Madde (mg/L)
ANAMET	: Anaerobic Methane Production (Anaerobik Metan Üretimi)
ANFIS	: Adaptive Network Based Fuzzy Inference System (Adaptif Ağ Temelli Bulanık Çıkarım Sistemi)
ANN	: Artificial Neural Network (Yapay Sinir Ağları)
APHA	: American Public Health Association (Amerikan Halk Sağlığı Kuruluşu)
ARIMA	: Autoregressive Integrated Moving Average (Oto regresif Bütünleşik Hareketli Ortalama )
ASM	: Activated Sludge Models (Aktif Çamur Modelleri)
BOİ	: Biyokimyasal Oksijen İhtiyacı (mg/L)
COST	: European Co-operation in the Field of Scientific and Technical Research (Avrupa Bilimsel ve Teknik Araştırmalar İşbirliği)
ÇO	: Çözünmüş Oksijen (Dissolved Oxygen) (mg/L)
ÇOK	: Çözünmüş Organik Karbon (mg/L)
DYÜ	: Dezenfeksiyon Yan Ürünleri
FIS	: Fuzzy Inference System (Bulanık Çıkarım Sistemi)
FL	: Fuzzy Logic (Bulanık Mantık)
GA	: Genetik Algoritma (Genetic Algorithms)
IWA	: International Water Association (Uluslararası Su Birliği)
KOİ	: Kimyasal Oksijen İhtiyacı (mg/L)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Hata)
MLR	: Multiple Linear Regression (Çoklu Lineer Regresyon)
MLSS	: Mixed Liquor Suspended Solids (Havalandırma Havuzunda Askıda Katı Madde) (mg/L)
MLVSS	: Mixed Liquor Volatile Suspended Solids (Havalandırma Havuzunda Uçuşu Askıda Katı Madde) (mg/L)
NH <sub>3</sub> -N	: Amonyak azotu (mg/L)

NH <sub>4</sub> -N	: Amonyum azotu (mg/L)
NO <sub>3</sub> -N	: Nitrat azotu (mg/L)
PC	: Principal Component (Temel Bileşen)
PCA	: Principal Component Analysis (Temel Bileşenler Analizi)
PHA	: Poli-hidroksi-alkanatlar
PLS	: Partial Least Squares (Kısmi En Küçük Kareler Yöntemi)
RMSE	: Root Mean Square Error (Ortalama Karesel Hata Karakökü)
SRT	: Sludge Retention Time (Çamur Yaşı) (gün)
SVD	: Single Value Decomposition (Tekli Veri Ayırıştırması)
TKM	: Toplam Katı Madde (mg/L)
TN	: Toplam azot (mg/L)
UKM	: Uçucu Askıda Katı Madde (mg/L)
USEPA	: United States Environmental Protection Agency (Amerikan Çevre Koruma Örgütü)
VIF	: Variance Inflation Factor (Varyans Etki Faktörü)
YZ	: Yapay Zeka (Artificial Intelligence)
ZE	: Zeki Etmenler
$b_A$	: ototrofik biyokütlenin bozunma sabiti (1/gün)
$b_{ANO}/b_{HNO}$	: ototrofik/heterotrofik bakterilerin içsel solunum sabiti (1/gün)
$b_H$	: hetotrofik biyokütlenin bozunma sabiti (1/gün)
$b_{STOO_2}/b_{STONO}$	: hücre içinde depolanmış KOİ aerobik/ anoksik içsel solunum sabiti (1/gün)
$f_P$	: partiküler ürün oluşturan biyokütle fraksiyonu (-)
$f_{SI}$	: hidroliz sırasında açığa çıkan $S_I$ miktarı (-)
$f_{XI}$	: biyokütle bozunması sırasında açığa çıkan parçalanamayan KOİ oranı (-)
$F/M$	: Food / Microorganism (Substrat / mikroorganizma)
$i_{NBM}$	: biyokütlerdeki azot miktarı (mg N/mg KOİ, mg N/mg TSS)
$i_{NSI}$	: $S_I$ içerisindeki azot miktarı (mg N/mg KOİ)
$i_{NSS}$	: $S_S$ içerisindeki azot miktarı (mg N/mg KOİ)

$i_{NXI}$	: $X_I$ içerisindeki azot miktarı (mg N/mg KOİ)
$i_{NXS}$	: $X_S$ içerisindeki azot miktarı (mg N/mg KOİ)
$i_{TSSBM}$	: biyokütlerdeki TSS/KOİ oranı (mg TKM/mg KOİ)
$i_{TSSXS}$	: $X_S$ içerisindeki TSS/KOİ oranı (mg TKM/mg KOİ)
$i_{TSSXI}$	: $X_I$ içerisindeki TSS/KOİ oranı (mg TKM/mg KOİ)
$i_{XB}$	: biyokütlerdeki azotun KOİ'ye oranı (mg N/mg KOİ)
$i_{XP}$	: biyokütlerden oluşan ürünlerde azotun KOİ'ye oranı (mg N/mg KOİ)
$k_A$	: amonifikasyon oranı (1/gün)
$k_h$	: maksimum spesifik hidroliz hızı (mg KOİ/mg KOİ.gün)
$k_{STO}$	: hücre içi KOİ depolama hızı (1/gün)
$K_{NH}$	: ototrofik biyokütle için amonyak yarı doygunluk sabiti (mg NH <sub>3</sub> /L)
$K_{NO}$	: denitrifiye edici hetotrofik biyokütlenin nitrat yarı doygunluk sabiti (mg (NO <sub>3</sub> )/L)
$K_{NOX}$	: NO <sub>x</sub> yarılanma sabiti (mg N/L)
$K_{OA}$	: ototrofik biyokütle için oksijen yarı doygunluk sabiti (mg O <sub>2</sub> /L)
$K_{OH}$	: hetotrofik biyokütlenin oksijen yarı doygunluk sabiti (mg O <sub>2</sub> /L)
$K_S$	: hetotrofik biyokütlenin yarı doygunluk sabiti (mg KOİ/L)
$K_{STO}$	: hücre içinde depolanmış KOİ yarılanma sabiti (mg KOİ/L)
$K_X$	: biyolojik olarak yavaş ayrışan substratın hidrolizi için yarı doygunluk sabiti (mg KOİ/mg KOİ)
$Q$	: su veya atıksu debisi (m <sup>3</sup> /gün)
$R$	: korelasyon katsayısı
$R^2$	: tespit katsayısı
$S_{ALK}$	: molar alkalinite konsantrasyonu (mol/L)
$S_I$	: çözünmüş inert organik madde (mg KOİ/L)
$S_{N2}$	: N <sub>2</sub> konsantrasyonu (mg N/L)
$S_{ND}$	: biyolojik olarak parçalanabilen çözünmüş organik azot (mg N/L)
$S_{NH}$	: amonyum ve amonyak azotu (mg N/L)

$S_{NO}$	: nitrat ve nitrit azotu (mg N/L)
$S_{NOX}$	: $NO_3^- + NO_2^-$ konsantrasyonu (mg N/mg L)
$S_O$	: oksijen (negatif KOİ) (mg KOİ/L)
$S_S$	: hazır olarak parçalanabilen organik substrat (mg KOİ/L)
$X_{BA}$	: aktif ototrofik biyokütle (mg KOİ/L)
$X_{BH}$	: aktif heterotrofik biyokütle (mg KOİ/L)
$X_I$	: partiküler inert organik madde (mg KOİ/L)
$X_{ND}$	: biyolojik olarak parçalanabilen partiküler organik azot (mg N/L)
$X_P$	: biyokütle bozunmasından oluşan partiküler ürünler (mg KOİ/L)
$X_S$	: yavaş olarak parçalanabilen organik substrat (mg KOİ/L)
$X_{STO}$	: hücre içinde depolanan substrat (KOİ) konsantrasyonu (mg KOİ/mg L)
$X_{TSS}$	: toplam askıda katı madde konsantrasyonu (mg TKM/mg L)
$X^2$	: Ki-kare katsayısı
$Y_A$	: ototrofik biyokütle ürünü (mg KOİ/mg N)
$Y_H$	: heterotrofik biyokütle ürünü (mg KOİ/mg KOİ)
$Y_{HNO}$	: anoksik heterotrofik biyokütle ürünü (mg TKM/mg BOİ)
$Y_{STONO}$	: hücre içinde depolanan substratın (KOİ) anoksik biyokütle dönüşüm oranı
$Y_{STOO2}$	: hücre içinde depolanan substratın (KOİ) anoksik biyokütle dönüşüm oranı
$\eta_g$	: anoksik şartlarda $\hat{\mu}_H$ için düzeltme faktörü (-)
$\eta_h$	: anoksik şartlarda hidroliz için düzeltme faktörü (-)
$\hat{\mu}_A$	: ototrofik biyokütlenin maksimum spesifik çoğalma katsayısı (1/gün)
$\hat{\mu}_H$	: heterotrofik biyokütlenin maksimum spesifik çoğalma katsayısı (1/gün)

## ŞEKİLLER DİZİNİ

Şekil 2.1. ASM1 ve ASM3 modellerindeki ototrofik ve heterotrofik biyokütle için substrat dengesi (Gujer vd., 1999) .....	14
Şekil 2.2. Temel bileşenler analizinde X matrisinin proses ve gürültü alt uzayına ayrışması .....	20
Şekil 2.3. Temel bileşenlerin veri dağılımı diyagramında kesişimi.....	21
Şekil 2.4. Bulanık Çıkarım Sistemi (Jang, 1993).....	32
Şekil 2.5. p girdili n çıktılı bir yapay nöronun blok diyagram gösterimi (A) ve detaylı gösterimi (B) .....	35
Şekil 2.6. Bir yapay sinir ağı.....	38
Şekil 2.7. Tip 3 bulanık çıkarım sistemi (A) ve eşdeğer ANFIS mimarisi (B).....	46
Şekil 4.1. Bromat oluşumu modelinde PCA sonucu elde edilen bileşenlere ait tanımlanmış yüzdesel özdeğerler (eigenvalues).....	74
Şekil 4.2. Bromat oluşumu modelinde üç temel bileşene ait yük vektörlerinin dağılım diyagramı.....	75
Şekil 4.3. Bromat oluşumu çalışmasında ANN#1 (A) ve ANN#2 (B) model mimarileri .....	78
Şekil 4.4. Tüm sular için ölçülen ve tahmin edilen bromat konsantrasyonları (A) ile model performansları (B:ANN#1; C:ANN#2).....	81
Şekil 4.5. Ereğli Şeker Fabrikası AAT proses akış diyagramı.....	86
Şekil 4.6. Ereğli Şeker Fabrikası AAT’de PCA analizi öncesi geliştirilen KOİ (A), NH <sub>4</sub> -N (B) ve TN (C) modellerinin eğitim ve test hata diyagramları .....	91



Şekil 4.7. Model çalışmasında temel bileşenlerin fonksiyonu cinsinden tanımlanan proses varyans oranı (A) ile KOİ (B), NH <sub>4</sub> -N ve TN (C) modellerine ait yük vektörleri .....	94
Şekil 4.8. PCA sonrası geliştirilen KOİ (A), NH <sub>4</sub> -N (B) ve TN (C) modellerine ait eğitim ve test hata dağılımları .....	98
Şekil 4.9. KOİ (A), NH <sub>4</sub> -N (B) ve TN (C) modellerinin test aşamalarında ölçülen ve tahmin edilen hedef çıktı değişkenlerine ait dağılım diyagramı .....	100
Şekil 4.10. ANN ve ANFIS modellerinde KOİ çıkış değişkeni için hata barı diyagramı.....	106
Şekil 4.11. ANN ve ANFIS modellerinde KOİ çıkış değişkeninin tahmin edilen ve ölçülen değerlerinin zamanla değişimi.....	107
Şekil 4.12. Hanya atıksu arıtma tesisi proses akış diyagramı .....	110
Şekil 4.13. Verilerin PCA temel bileşen yük faktörleri .....	116
Şekil 4.14. Ölçülen KOİ değerlerinin ANN ve ANN+PCA model teknikleri ile tahmin edilmesinin eğitim (A) ve test (B) aşamalarında karşılaştırılması .....	120
Şekil 4.15. Ölçülen KOİ değerlerinin ANFIS ve ANFIS+PCA model teknikleri ile tahmin edilmesinin eğitim (A) ve test (B) aşamalarında karşılaştırılması .....	121
Şekil 4.16. Ölçülen ve tahmin edilen KOİ parametresinin ANN (A) ve ANFIS (B) modeli test aşamasındaki veri dağılımları .....	122
Şekil 4.17. Pelham atıksu arıtma tesisi proses akış diyagramı.....	127
Şekil 4.18. ASM1 ve ASM3 model yaklaşımlarında tesis organik karbon (A), amonyak azotu (B) ve nitrat azotu (C) çıktı değerlerinin kalibrasyon sonuçları .....	134

- Şekil 4.19. ASM1 ve ASM3 model yaklaşımlarında tesis organik karbon (A), amonyak azotu (B) ve nitrat azotu (C) çıktı değerlerinin test (doğrulama) sonuçları ..... 136
- Şekil 4.20. ANFIS modelleriyle eğitim ve test aşaması için KOİ (A, B), NH<sub>3</sub>-N (C, D) ve NO<sub>3</sub>-N (E, F) çıktı değişkenlerinin (tesis çıkış) tahmin edilen değerleri ile ölçülen değerlerinin zamanla değişimleri ..... 142

## ÇİZELGELER DİZİNİ

Çizelge 1.1. Tez kapsamı ve model yaklaşımları.....	4
Çizelge 2.1. ASM1 modellerinde prosese ait kinetik ve stokiyometrik ifadeler (Henze vd., 2000) .....	9
Çizelge 2.2. ASM3 modelinde prosese ait kinetik ve stokiyometrik ifadeler (Henze vd., 2000) .....	15
Çizelge 2.3. Biyolojik sinir sistemi ile ANN'lerin benzer özellikleri.....	35
Çizelge 4.1. Literatürde geliştirilen Bromat ( $\text{BrO}_3^-$ ) Modelleri .....	62
Çizelge 4.2. Yeraltısuyu numunelerinin fizikokimyasal karakteristikleri ve ozonlama koşulları (Tyrovola, 2001) .....	65
Çizelge 4.3. MLR modelleri ve performans değerleri .....	70
Çizelge 4.4. Bromat model değişkenlerine ait korelasyon matrisi.....	73
Çizelge 4.5. Ereğli AAT karbon ve azot giderim modellerinde kullanılan atıksu karakteristikleri .....	87
Çizelge 4.6. ANFIS modellerinde kullanılan girdi ve çıktı parametreleri arasındaki korelasyon ilişkisi .....	92
Çizelge 4.7. PCA sonrası seçilen girdi veri matrisi ile gerçekleştirilen ANFIS model performansları .....	96
Çizelge 4.8. Tuzla Kentsel AAT modellemesinde kullanılan atıksu verileri.....	104
Çizelge 4.9. ANN ve ANFIS modelleri için kullanılan Hanya atıksu arıtma tesisi verileri .....	111
Çizelge 4.10. Hedef çıktı parametresinin belirlenebilmesi amacıyla yönelik veri analiz metotları .....	114

Çizelge 4.11. Girdi veri matrisinde temel bileşenler olarak ifade edilen proses değişken dağılımları .....	115
Çizelge 4.12. Pelham Atıksu Arıtma Tesisi atıksu karakteristikleri (1998-2002) ...	126
Çizelge 4.13. ASM1 ve ASM3 modellerinde kullanılan stokiyometrik ve kinetik ifadelerin başlangıç değerleri (T=20°C).....	129
Çizelge 4.14. ASM1 ve ASM3 model yaklaşımlarında gerçekleştirilen hassasiyet analizi sonuçları .....	131
Çizelge 4.15. ASM1 ve ASM3 model yaklaşımlarında parametre tahmin sonuçları .....	132
Çizelge 4.16. ASM1 ve ASM3 model yaklaşımları ile elde edilen kalibrasyon ve test performans değerleri .....	137
Çizelge 4.17. KOİ, NH <sub>3</sub> -N ve NO <sub>3</sub> -N modellerine ait performans sonuçları .....	143

## 1. GİRİŞ

### 1.1. Motivasyon

Bir çok endüstriyel uygulamada prosesin güvenilir olarak izlenmesi ve kontrol edilmesi en az proses sonunda daha kaliteli ürün elde etmek kadar ekonomik değere sahiptir (Rosen, 2001). Petrokimya ve ilaç endüstrisi gibi kilit öneme sahip seri prosesleri barındıran tesislerde istatistiksel analizler ve çoklu kontrol yöntemleri ile zeki otomatik kontrol mekanizmaları kullanılmaya başlanmıştır. Her ne kadar izleme ve kontrol yöntemleri, endüstriyel uygulamalarda daha yaygın olarak gözlenirse de kirlilik problemlerinin arttığı ve çevre koruma yasalarının sıkılaştırdığı kurallar çerçevesinde çevre mühendisliği proseslerinin kontrolünde de bu yönde yenilikçi yaklaşımlara ihtiyaç duyulmaktadır. Özellikle atıksu arıtma tesisleri (AAT) gibi hem yatırım, hem işletme ve bakım maliyetleri çok yüksek olan ve bir çok kompleks prosesi içinde barındıran sistemlerin mutlaka akılcı yaklaşımlar ile izlenmesi ve kontrol edilmesi gerekmektedir.

Mekanistik olarak adlandırılan ve arıtma proseslerinin tanımlanması ile statik ya da dinamik olarak simülasyonunda kullanılan matematiksel modeller, tespit edilmesi gereken değişken ve sabit parametre sayısının oldukça fazla olmasından dolayı izleme ve kontrol amaçlı uygulamalarda verimli sonuçlar veremeyebilmektedir. Bu gibi durumlarda, kompleks sebep sonuç ilişkilerini insan beynindeki kuramsal yaklaşımlarla tanımlayabilen, uyarlanabilir ve esnek modelleme algoritmaları kullanılabilir (Teppola vd., 1997; Corte's vd., 2000; Tay ve Zhang, 2000). Bu uyarlanabilir algoritmalar yapay zeka yöntemleri olarak tanımlanmaktadır ve özellikle son 20 yılda mühendislik alanında yaygın bir uygulama alanı bulmuştur (Gernaey, 2004). Çevre mühendisliğinde ise yapay zeka uygulamaları oldukça sınırlı olmakla birlikte son yıllarda önemini artırmaktadır.

Yapay zeka, çoklu istatistiksel yöntemler, veri madenciliği gibi kavramlar gelişmeye açık, yenilikçi ve modern bilimsel yöntemler olarak adlandırılmaktadır. Çevre mühendisliği disiplininde özellikle arıtma proseslerinin bu tür yöntemler ile

değerlendirilmesi ve modellenmesinin proses izleme ve kontrol yaklaşımlarında yeni açılımlar getireceği düşünülmektedir.

## **1.2. Amaç**

Bu çalışmanın temel amacı yapay zeka ve çoklu istatistiksel yöntemlerin arıtma proseslerinin izlenmesi ve kontrolü aşamasında uygulanabilirliğinin araştırılması ve uyarlanabilirlik potansiyelinin ortaya konulmasıdır. Bu amaçtan yola çıkılarak arıtma prosesleri ve bu proseslerde eş zamanlı (on-line) ya da gecikmeli (off-line) olarak ölçülen değişkenler dikkate alınarak farklı model metodolojileri ile uyarlanabilir yaklaşımlar geliştirilmiştir.

Bu kapsamda çoklu regresyon analizi, temel bileşenler analizi gibi çoklu istatistiksel yöntemler ile yapay sinir ağları ve adaptif ağ temelli bulanık çıkarım sistemlerini içeren yapay zeka yöntemleri kullanılmıştır. Atıksu arıtma tesislerindeki aktif çamur prosesi için tasarlanmış olan ASM [activated sludge models, (aktif çamur modelleri)] modellerinden karbon ve azot giderimini tanımlayan ASM1 ve ASM3 modelleri kendi içerisinde ve adaptif ağ temelli bulanık çıkarım sistemi ile karşılaştırmalı olarak değerlendirilmiştir.

Model yaklaşımları ayrıntılı olarak açıklanmış ve uygulama nedenleri açıkça ifade edilmiştir. Elde edilen sonuçlarla uygulamaya yönelik, kabul gören ve kompleks arıtma proseslerinde kullanılacak pratik değerlendirme araçları oluşturulmaya çalışılmıştır.

## **1.3. Kapsam**

Tez kapsamında ele alınan modern bilimsel değerlendirme yöntemleri daha çok atıksu arıtma tesislerinin veya aktif çamur prosesinin modellenmesi aşamasında kullanılmıştır. Bu bağlamda sadece aerobik biyolojik arıtma tesisleri ele alınmış ve anaerobik proseslere ait performans modellemesi tez kapsamı içerisinde değerlendirilmemiştir.

Aerobik AAT atıksu karakterizasyonuna göre evsel, kentsel ve endüstriyel olmak üzere üç kısımda incelenmiştir. Aerobik atıksu arıtma tesislerinde gerçekleştirilen modelleme çalışmaları ise iki kısımda incelenmiştir. Birinci kısımda aerobik biyolojik oksidasyon prosesi, prosese ait girdi ve çıktı değişkenleri ile değerlendirilmiş, diğer aşamada ise AAT performansı, tesisteki tüm üniteler dikkate alınarak oluşturulan girdi ve çıktı değişkenli modelleme yaklaşımları ile değerlendirilmiştir. Her iki yaklaşımda da sadece karbon giderimi ya da hem karbon hem de azot giderimi birlikte değerlendirilmiştir.

Mekanistik bir model yaklaşımı olan ASM1 ve ASM3 modelleri ise sadece bir evsel AAT verileri ile birlikte değerlendirilmiştir. Bunun nedeni diğer evsel ve kentsel AAT proseslerinde karbon gideriminin yanında azot gideriminin olmaması, diğer AAT örneğinin ise kentsel atıksu arıtan ardışık (anaerobik+aerobik) sistemden oluşmasıdır. Bu çalışmada kullanılan ASM model yaklaşımları hem tesisdeki aerobik karbon ve azot gideriminin modellenmesinde hem de ANFIS [adaptive network based fuzzy inference system (adaptif ağ temelli bulanık çıkarım sistemi)] modeli ile karşılaştırma yapmak amacı ile kullanılmıştır.

Çoklu istatistiksel metotlar, aerobik biyolojik arıtma tesislerinin modellenmesi aşamasında, veri değerlendirme ve eleme ile temsil edici model matrisi oluşturma amacına yönelik olarak kullanılmıştır. Çalışma kapsamında, proses mekaniğini temsil edici değişken tespitinde PCA [principal component analysis, (temel bileşenler analizi)] metodu uygulanmıştır. PCA metodu temel olarak, ölçülen değişken sayısı ile ifade edilen yüksek boyutlu model matrisinin, istatistiksel olarak daha küçük boyutlu model matrisine dönüştürülmesini amaçlamaktadır.

İçme suyu arıtımında dezenfeksiyon yan ürünü oluşumunun modellenmesinde de hem çoklu istatistiksel metotlar hem de yapay zeka yöntemi birlikte kullanılmıştır. Bu kapsamda temel bileşenler analizi ile proses netleştirilmiştir. Proses içerisinde ölçülen hedef değişkenin (bağımlı değişken), ölçülen diğer değişkenlerle (bağımsız değişkenler) arasındaki ilişkinin lineer (doğrusal) istatistiksel metotlarla

modellenmesi aşamasında da MLR [multi linear regression, (çoklu regresyon)] analizi uygulanmıştır. Çoklu regresyon analizi ile de aralarında doğrusal ilişki bulunan proses değişkenleri logaritmik transformasyon ile üstel güç fonksiyonları şeklinde tanımlanmıştır. Yapay sinir ağları (YSA) da prosesin modellenmesi ve çoklu istatistiksel yöntemler ile karşılaştırılması amacı ile yapılandırılmıştır. MLR modelleme tekniği, AAT değişkenleri arasında mevcut olan yüksek derecede doğrusal olmayan ilişkiler göz önünde bulundurularak, AAT modellemesinde kullanılmamıştır.

Tez kapsamında gerçekleştirilen çalışmaların temel amacı ve kullanılan model yaklaşımları Çizelge 1.1’de verilmiştir.

Çizelge 1.1. Tez kapsamı ve model yaklaşımları

Bulgular Bölüm No.	Amaç	Model Yaklaşımı	Oluşturulan Toplam Model Sayısı
4.1	İçme suyunda bromat konsantrasyonu tespiti	PCA, MLR, YSA	8
4.2	Endüstriyel AAT’de karbon ve azot gideriminin tespiti	PCA, ANFIS	6
4.3	Kentsel AAT performansının tespiti	YSA, ANFIS	2
4.4	Evsel AAT’de karbon gideriminin tespiti	PCA, YSA, ANFIS	4
4.5	Evsel AAT’de karbon ve azot gideriminin tespiti	ASM1, ASM3, ANFIS	9

Elde edilen model sonuçlarının arıtma proseslerinin eş zamanlı otomatik kontrolü ve denetlenmesi aşamasında kullanılması ve bununla ilgili yazılım ve elektro-mekanik donanımların oluşturulması konuları tez kapsamı içerisinde yer almamaktadır.



## **2. KAYNAK BİLGİSİ**

### **2.1. Matematiksel Modelleme Yaklaşımları**

#### **2.1.1. Aktif Çamur Modelleri**

##### **2.1.1.1. Giriş**

Günümüzde arıtılmış atıksu kalitesi ile ilgili getirilen standartlar, sınırlamalar ve ekonomik faktörler atıksuların arıtılmasını kompleks bir endüstri haline dönüştürmüştür. Son yıllarda fiziksel, kimyasal ve biyolojik birçok etkili arıtma teknolojileri geliştirilmekte ve verimli arıtma proseslerinin tasarımları gerçekleştirilmektedir. Uygulama ve işletme aşamasında, tasarım kısmında olduğu kadar proses içerisindeki önemli parametrelerin (debi, organik madde konsantrasyonları vb.) doğru olarak ölçülebilmesi atıksu arıtma sistemlerinin verimli olarak işletilebilmesinde önemlidir (Zavareh, 2003).

Atıksuların biyolojik olarak arıtılmaları 19. yüzyılın sonlarına dayanmaktadır (Dold ve Marais, 1986; Orhon ve Artan, 1994). Biyolojik arıtma ilk olarak 20. yüzyılın başlarında geliştirilen damlatmalı filtre ve biyolojik yatak ile başlamıştır (Hammer, 1996). Aynı yüzyıl içerisinde atıksuların ilave havalandırma ile biyolojik olarak çok daha iyi arıtıldığı fark edilmiş ve geliştirilen prosesin adına “aktif çamur prosesi” adı verilmiştir. Aktif çamur prosesi biyolojik atıksu arıtma metotları içerisinde en çok kullanılan tekniktir. Bu proseste atıksu içerisindeki organik maddeler ortamda askıda bulunan bakteri biyokütlesi tarafından uzaklaştırılmaktadır. Bir atıksu arıtma tesisinde spesifik tasarım gerçekleştirilirse karbonlu organikler yanında biyolojik olarak azot ve fosfor da giderilebilmektedir. Bununla birlikte, aktif çamur prosesi biyolojik doğası sebebiyle birçok farklı mekanizmayı bünyesinde barındırmaktadır. Dolayısıyla biyolojik atıksu arıtma sisteminin verimli olarak işletilebilmesi için bu mekanizmaların tanımlanması ve matematiksel olarak modellenmesi gerekmektedir.

Matematiksel modelleme bir sistemin statik ve dinamik davranışlarının deneysel aşamalara başvurmadan ya da minimum deney ve gözlem ağı ışığında, daha pratik, daha masrafsız ve zamandan tasarruf ederek tespit edilmesini sağlayan bir mühendislik aracıdır. Matematiksel modeller tasarım, araştırma, proses kontrolü, tahmin, performans analizi ve eğitim gibi bir çok amaç için kullanılabilir (Jeppsson, 1996).

Modeller yukarıda belirtildiği üzere mekanistik olarak bir sistem ya da prosesi tanımlamaya yönelik olabileceği gibi, istatistiksel metotlarla da ifade edilebilmektedir. Bu metotta mekanistik yaklaşımda olduğu gibi sistemin iç dinamikleri ile değil, sistemi etkileyen girdi ve sistemi terk eden çıktı parametreleri ile ilgilenilmektedir. Bu bölümde, aktif çamur prosesinin mekanistik olarak modellenmesi ele alınacaktır.

Geçmişten günümüze kadar mekanistik modeller, tasarıma ait kısmi diferansiyel eşitlikleri, bakteriyel çoğalma kinetikleri ve kütle dengesi gibi statik veya dinamik matematiksel yaklaşımlarla ifade edilmektedir. Bu modeller Lawrence ve McCarty Modeli (1970), Goodman ve Englands Modeli (1974) ve IWA (International Water Association) modelleridir (ASM1- Henze vd., 1987; ASM2- Henze vd., 1995; ASM3- Gujer vd., 1999).

Uluslararası Su Kirliliği ve Kontrolü Birliği (IWAPRC), bugünkü adıyla IWA, 1983 yılında biyolojik atıksu arıtma sistemlerinin tasarımı ve işletilmesi için pratik ve uygulanabilir modeller oluşturulması amacıyla bir araştırma grubu oluşturmuştur. Araştırma grubunun gerçekleştirdiği çalışmalar sonucu ilk olarak, aktif çamur sistemlerinde oksidasyon, nitrifikasyon ve denitrifikasyon performanslarını gerçekçi olarak tahmin edilmesine imkan tanıyan ASM1 (activated sludge model no.1) modeli geliştirilmiştir.

### 2.1.1.2. ASM No.1

Model grubu ASM1 modelini karbon oksidasyonu, nitrifikasyon ve denitrifikasyon proseslerinin aynı/sabit biyokütle akımıyla (single sludge) gerçekleştirdiği arıtma tesisleri için tasarlanmıştır. ASM1 modeli 13 bileşen, 8 proses kinetiği ve 19 parametre içermektedir.

Daha önceki modellerdeki düzgün substrat sınıflandırmasının tersine ASM1 modelinde substrat farklı tiplerde sınıflandırılmıştır. Modelde biyolojik olarak parçalanmayan organik maddelerin sistemi değişmeden terk ettiği kabul edilmektedir. İnerit olarak adlandırılan bu organik fraksiyon, çözülmüş ve partiküler olmak üzere iki formda değerlendirilmektedir (McKinney ve Ooten, 1969). İnerit çözülmüş organik madde sistemi değişmeden girdiği konsantrasyon değerinde terk etmekte, inerit organik partiküler madde ise atık aktif çamur ile birlikte sistemi terk etmektedir. Biyolojik olarak parçalanabilen organik madde de biyolojik olarak kolay (hazır) parçalanabilen ve yavaş parçalanabilen organik maddeler olmak üzere iki farklı formda değerlendirilmektedir. Bu yaklaşım, fiziksel ayırmada değil biyolojik proseste değerlendirilmektedir (Ekama vd., 1986). Biyolojik olarak kolay parçalanabilen organik maddeler direkt olarak mikroorganizmalar tarafından biyosentez mekanizması çerçevesinde absorbe edilmektedir. Biyolojik olarak yavaş parçalanabilen organik maddeler ise hidroliz mekanizması ile biyolojik olarak kolay parçalanabilen formlara dönüştürülmekte ve bakteri bünyesine alınmaktadır. Bakterilerin çoğalması hem aerobik hem de anoksik ortamda olabilmektedir.

Model içerisinde biyokütle (bakteriler) heterotrof ve ototrof olmak üzere iki kategoride ele alınmaktadır. Heterotrof bakteriler hem aerobik hem de anoksik ortamda kolay olarak parçalanabilen organik maddeleri karbon ve enerji kaynağı olarak kullanmakta ve çoğalmaktadır. Heterotroflar anoksik ortamda nitrat azotunu elektron alıcısı olarak kullanmakta, ototrof bakteriler ise aerobik ortamda enerjilerini amonyağın oksidasyonundan sağlayarak çoğalmaktadırlar. Bu sınıflandırma, daha detaylı nitrifikasyon ve denitrifikasyon tanımının yapılmasına da imkan tanımaktadır.

Organik substrat içerisindeki elektron ekvivalentleri ile bağlantıyı sağladığı için model içerisinde organik madde KOİ (kimyasal oksijen ihtiyacı) ile temsil edilmiştir (Gaudy ve Gaudy, 1971). Aktif çamur modellerinde sistem içerisindeki elektronlar tam anlamıyla tanımlanamadığı için kütle (elektron) dengesi sisteme giren KOİ, sistemden deşarj edilen KOİ, sistemi atık çamur olarak terk eden KOİ ve sistem içerisindeki karbonlu kimyasal oksijen ihtiyacı arasında yapılmaktadır.

Biyokütle, mikroorganizmaların bozulması (içsel solunum, ölüm ve ayrışma) mekanizması ile azalmaktadır. ASM1 modelinde bozunma, biyokütlenin biyolojik olarak yavaş parçalanabilen partiküler organik ürünlere dönüşümü sırasında meydana gelmektedir. Bu ürünler daha sonra gerçekleşecek biyolojik ataklara karşı tepkisizdir.

ASM1 içerisinde azot bileşeni, biyolojik olarak parçalanabilen ve parçalanamayan olmak üzere iki kategoride değerlendirilmektedir. Biyolojik olarak parçalanamayan kısım çözünmüş ve partiküler form şeklinde değerlendirilmekle birlikte çözünmüş kısım ihmal edilmektedir. Biyolojik olarak parçalanabilen azot ise amonyak azotu, çözünmüş organik azot ve partiküler organik azot olmak üzere üç formda değerlendirilmektedir. Heterotrofik bakteriler, çözünmüş organik azotu amonyak azotu formuna dönüştürmekte (amonifikasyon) ve amonyak azotu heterotrof bakterilerin çoğalması için azot kaynağı olarak kullanılmaktadır. Amonyak azotu aynı zamanda ototrofik nitrifikasyon bakterilerinin çoğalmasında enerji kaynağı olarak kullanılmaktadır.

ASM1 modelinde temel notasyonlar, partiküler substrat (X), çözünmüş organik substrat (S) ve alt indisleri, biyokütle (B), organik substrat (S) ve oksijen (O) şeklinde kullanılmaktadır. ASM1 modelinde karbon oksidasyonu, nitrifikasyon ve denitrifikasyon aşamalarına ait proses kinetikleri ve stokiyometrik ifadeler Çizelge 2.1'de verilmiştir.

Çizelge 2.1. ASM1 modelinde prosese ait kinetik ve stokiyometrik ifadeler (Henze vd., 2002)

Bileşen	i	1	2	3	4	5	6	7	8	9
j	Proses	$S_I$	$S_S$	$X_I$	$X_S$	$X_{B,H}$	$X_{B,A}$	$X_P$	$S_O$	$S_{NO}$
1	Heterotrofların aerobik çoğalması		$-\frac{1}{Y_H}$			1			$-\frac{1-Y_H}{Y_H}$	
2	Heterotrofların anoksik çoğalması		$-\frac{1}{Y_H}$			1			$-\frac{1-Y_H}{2.86Y_H}$	
3	Ototrofların aerobik çoğalması						1		$-\frac{4.57}{Y_A} + 1$	$\frac{1}{Y_A}$
4	Heterotrofların bozunması				$1-f_p$	-1		$f_p$		
5	Ototrofların bozunması				$1-f_p$		-1	$f_p$		
6	Çözünmüş organik azotun amonifikasyonu									
7	Organiklerin hidrolizi		1		-1					
8	Organik azotun hidrolizi									
Gözlenen dönüşüm oranı [ $ML^{-3}T^{-1}$ ]		$r_i = \sum_j v_{ij} \cdot \rho_j$								

Çizelge 2.1. (devam)

10	11	12	13	Proses oranı, $\rho_j$ , [ $ML^{-3}T^{-1}$ ]
$S_{NH}$	$S_{ND}$	$X_{ND}$	$S_{ALK}$	
$-i_{XB}$			$-\frac{i_{XB}}{14}$	$\hat{\mu}_H \left( \frac{S_s}{K_s + S_s} \right) \left( \frac{S_o}{K_{OH} + S_o} \right) X_{B,H}$
$-i_{XB}$			$\frac{1-Y_H}{14 \cdot 2.86Y_H} - \frac{i_{XB}}{14}$	$\hat{\mu}_H \left( \frac{S_s}{K_s + S_s} \right) \left( \frac{S_o}{K_{OH} + S_o} \right) \cdot \left( \frac{S_{NO}}{K_{NO} + S_{NO}} \right) \eta_g X_{B,H}$
$-i_{XB} - \frac{1}{Y_A}$			$-\frac{i_{XB}}{14} - \frac{1}{7Y_A}$	$\hat{\mu}_A \left( \frac{S_{NH}}{K_{NH} + S_{NH}} \right) \left( \frac{S_o}{K_{O,A} + S_o} \right) X_{B,A}$
		$i_{XB} - f_p i_{XP}$		$b_H X_{B,H}$
		$i_{XB} - f_p i_{XP}$		$b_A X_{B,A}$
1	-1	$\frac{1}{14}$		$k_A S_{ND} X_{B,H}$

				$k_H \frac{X_s / X_{B,H}}{K_X + (X_s / X_{B,H})} \left[ \left( \frac{S_o}{K_{OH} + S_o} \right) + \eta_h \left( \frac{K_{OH}}{K_{OH} + S_o} \right) \left( \frac{S_{NO}}{K_{NO} + S_{NO}} \right) \right] X_{B,H}$
	1	-1		$\rho_7 (X_{ND} / X_s)$
$r_i = \sum_j v_{ij} \cdot \rho_j$				

Çizelge 2.1'deki bileşenler aşağıda ifade edilmiştir:

$S_I$  = çözülmüş inert organik madde [M (KOİ) L<sup>-3</sup>]

$S_S$  = kolay (hızlı) parçalanabilen organik madde [M (KOİ) L<sup>-3</sup>]

$X_I$  = partiküler inert organik madde [M (KOİ) L<sup>-3</sup>]

$X_S$  = yavaş parçalanabilen organik madde [M (KOİ) L<sup>-3</sup>]

$X_{BH}$  = aktif heterotrofik biyokütle [M (KOİ) L<sup>-3</sup>]

$X_{BA}$  = aktif ototrofik biyokütle [M (KOİ) L<sup>-3</sup>]

$X_P$  = biyokütle bozunmasından oluşan partiküler ürünler [M (KOİ) L<sup>-3</sup>]

$S_O$  = oksijen (negatif KOİ) [M (-KOİ) L<sup>-3</sup>]

$S_{NO}$  = nitrat ve nitrit azotu [M (N) L<sup>-3</sup>]

$S_{NH}$  = amonyum ve amonyak azotu [M (N) L<sup>-3</sup>]

$S_{ND}$  = biyolojik olarak parçalanabilen çözülmüş organik azot [M (N) L<sup>-3</sup>]

$X_{ND}$  = biyolojik olarak parçalanabilen partiküler organik azot [M (N) L<sup>-3</sup>]

$S_{ALK}$  = molar alkalinite konsantrasyonu [mol L<sup>-1</sup>]

Modeldeki stokiyometrik ifadeler de aşağıda belirtilmiştir:

$Y_A$  = ototrofik biyokütle ürünü [M (KOİ) / M (N)]

$Y_H$  = heterotrofik biyokütle ürünü [M (KOİ) / M (KOİ)]

$f_P$  = partiküler ürün oluşturan biyokütle fraksiyonu (-)

$i_{XB}$  = biyokütledeki azotun KOİ'ye oranı [M (N) / M (KOİ)]

$i_{XP}$  = biyokütleden oluşan ürünlerde azotun KOİ'ye oranı [M (N) / M (KOİ)]

Modeldeki kinetik parametreler aşağıda ifade edilmiştir:

$\hat{\mu}_H$  = hetotrofik biyokütlenin maksimum spesifik çoğalma katsayısı ( $T^{-1}$ )

$K_S$  = hetotrofik biyokütlenin yarı doyumluk sabiti [M (KOİ)  $L^{-3}$ ]

$K_{OH}$  = hetotrofik biyokütlenin oksijen yarı doyumluk sabiti [M ( $O_2$ )  $L^{-3}$ ]

$K_{NO}$  = denitrifiye edici hetotrofik biyokütlenin nitrat yarı doyumluk sabiti  
[M ( $NO_3$ )  $L^{-3}$ ]

$b_H$  = hetotrofik biyokütlenin bozunma sabiti ( $T^{-1}$ )

$b_A$  = ototrofik biyokütlenin bozunma sabiti ( $T^{-1}$ )

$\eta_g$  = anoksik şartlarda  $\hat{\mu}_H$  için düzeltme faktörü (-)

$\eta_h$  = anoksik şartlarda hidroliz için düzeltme faktörü (-)

$k_h$  = maksimum spesifik hidroliz hızı [M (KOİ) / M (KOİ)  $T^{-1}$ ]

$K_X$  = biyolojik olarak yavaş ayrılan substratın hidrolizi için yarı doyumluk sabiti  
[M (KOİ) / M (KOİ)]

$\hat{\mu}_A$  = ototrofik biyokütlenin maksimum spesifik çoğalma katsayısı ( $T^{-1}$ )

$K_{NH}$  = ototrofik biyokütle için amonyak yarı doyumluk sabiti [M ( $NH_3$ )  $L^{-3}$ ]

$K_{OA}$  = ototrofik biyokütle için oksijen yarı doyumluk sabiti [M ( $O_2$ )  $L^{-3}$ ]

$k_A$  = amonifikasyon oranı [ $L^3$  / M (KOİ)  $T^{-1}$ ]

Matrisin oluşturulması için ilk yapılacak adım sistem içerisindeki biyolojik proseslerin tanımlanmasıdır. Bileşenler tanımlandıktan sonra  $i$  indeksi bütün bileşenlere,  $j$  indeksi ise her prosese uygulanmaktadır. Modelde daha sonra stokiyometrik ve kinetik parametreler tanımlanmıştır. Kinetik eşitlikler için Monod-Herbert modeli kullanılmıştır.  $\rho$ , proses katsayısı ve  $v_{ij}$  ise stokiyometrik katsayıları ifade etmektedir (Henze vd., 1987).

Farklı parametrelerin değer aralıkları dikkate alındığında bazı parametrelerin atıksu karakteristiğine göre farklılık gösterdiği ve eğer ölçülmemiş ise aralıklar dahilinde

kabul edilebileceği belirtilmektedir. Bu parametreler  $Y_A$ ,  $f_P$ ,  $i_{XB}$ ,  $i_{XP}$ ,  $b_A$ ,  $K_{OH}$ ,  $K_{OA}$  ve  $K_{NO}$  'dir ve bu parametrelere ait önatımlı değerler güvenle kullanılabilir (Henze vd., 1987; 1997). Weijers ve Vanrolleghem (1997) ASM1 modelinde farklı parametrelere ait gerçekleştirdikleri hassasiyet analizlerinde aşağıdaki iki önemli sonuca ulaşmışlardır (Zavareh, 2003):

- ASM1 modelinde güvenilir bir hassasiyet analizi gerçekleştirmek için öncelikle optimal parametrelerin seçilmesi gerekmektedir. Çünkü farklı parametre setleri için farklı hassasiyet analizlerinin yapılması gerekmektedir.
- Parametre tahmini gerçekleştirilmeden önce parametre sayısının azaltılması gerekmektedir. ASM1 modeli içerisinde bir çok parametreyi tahmin etmek mümkün olmakla birlikte yüksek sayıda parametrenin tahmin edilmeye çalışılması gerçekçi bir yaklaşım olarak ifade edilmemektedir.

Ayrıca ASM1 ile gerçekleştirilen model çalışmalarının karşılaştırılmasında hassasiyet analizi ile ilgili net ve tek bir ifade yoktur. Diğer önemli bir nokta da reaktörlerin aynı SRT (çamur yaşı) ve organik yükte işletilse bile biyokütlenin farklı konfigürasyonlarda çoğalmasından ötürü farklı  $\hat{\mu}_H$  ve  $K_S$  değerlerine sahip olmalarıdır.



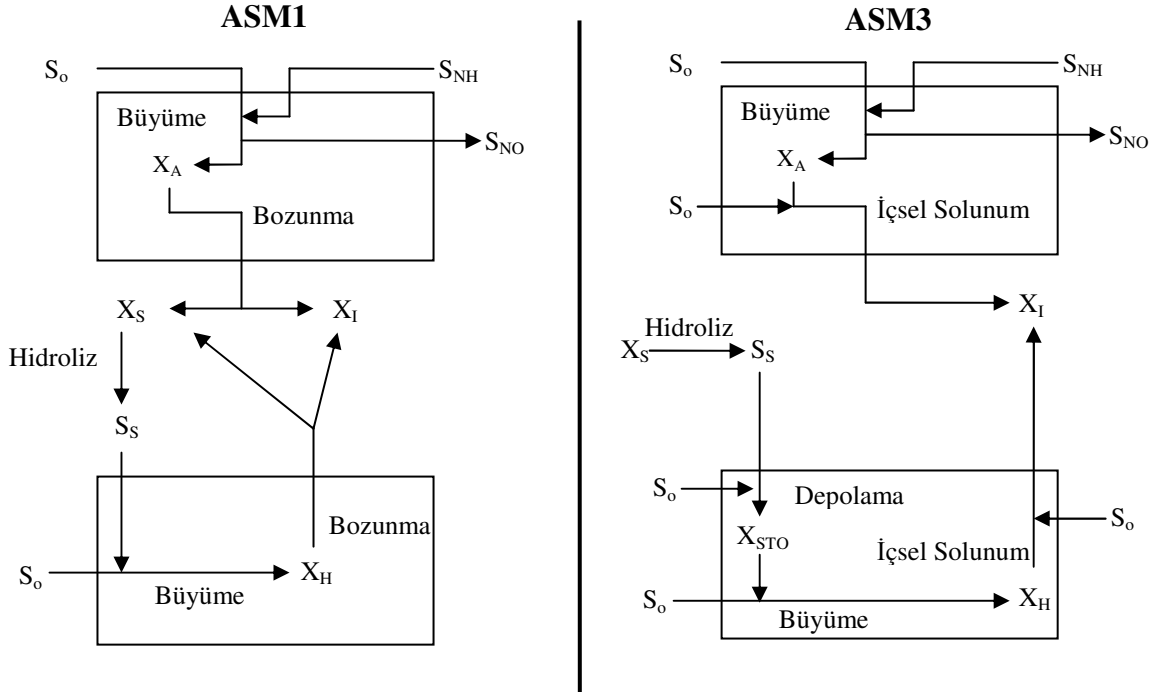
### 2.1.1.3. ASM No.3

ASM3 modeli (activated sludge model no.3) Gujer vd. (1999) tarafından aşağıdaki nedenler göz önüne alınarak önerilmiştir:

- ASM1 modeli heterotrofik mikroorganizmalar için azot ve alkalinite kısıtlamalarını ifade etmekte yetersiz kalmaktadır;
- ASM1 modeli içerisindeki biyolojik olarak ayrışabilen ve partiküler formdaki organik azotun ölçülmesi oldukça güçtür;
- Pratikte, amonifikasyon kinetiğine ait spesifik veriler ölçülememektedir;
- ASM1 modeli inert partiküler organik maddeyi orijinine göre atıksuyun karakterinden ve prostedeki biyokütle bozunmasından geldiğini kabul etmektedir. Fakat bu iki farklı fraksiyonu gerçekte ölçebilmek mümkün değildir;
- Heterotrof mikroorganizmalar tarafından oksijen tüketiminin ve denitrifikasyonun tespit edilmesi sırasında hidroliz mekanizması hakimdir. Fakat bu proses için kinetik parametrelerin tespit edilmesi oldukça güçtür;
- Aktif çamur sistemlerinde gözlenen poli-hidroksi-alkanatların (PHA) depolanma prosesi, ASM1 modelinde ele alınmamıştır;
- ASM1 modelinde nitrifikasyon bakterilerinin aerobik ve anoksik koşullardaki bozunma prosesi ayırt edilmemiştir. Bu durum yüksek SRT değerleri ve yüksek anoksik reaktör hacimleri dikkate alındığında maksimum nitrifikasyon hızlarının elde edilmesine neden olmaktadır;
- ASM1 modelinde reaktörde direkt olarak gözlenebilen MLSS miktarından bahsedilmemektedir.

ASM3 modeli (Gujer vd., 1999), ASM1 modeline benzer olarak atıksu arıtma tesislerinde biyolojik olarak azot giderimi esasına göre kurulmuştur. Ayrıca ASM3 modeli, ASM1 içerisindeki bazı problemlerin giderilmesi ile standart bir yaklaşım halini almıştır (Gujer vd., 1999). İki model arasındaki en büyük fark, ASM3'ün depolanan polimerlerin heterotrofik aktif çamur dönüşümündeki önemini barındırmasıdır. ASM3 modelinde parçalanmaya hazır bütün substratın ( $S_s$ ) hücre

bileşenleri ( $X_{STO}$ ) tarafından alınarak, çoğalma amaçlı depolandığı kabul edilir (Şekil 2.1).



Şekil 2.1. ASM1 ve ASM3 modellerindeki ototrofik ve heterotrofik biyokütle için substrat dengesi (Gujer vd., 1999)

Dolayısıyla heterotrofik biyokütle, içsel hücre yapısı ile modellenmektedir. İki model arasındaki bir diğer fark, ASM3'ün ASM1'e göre daha kolay kalibre edilebilmesidir. Sonuç olarak her iki model de biyolojik arıtma proseslerinin dinamik davranışını modellemede etkili olabilmekle birlikte, biyolojik olarak kolay parçalanmış substrat miktarı fazla olan atıksularda (endüstriyel atıksular) veya tank içerisinde yeterince havalandırılmayan bölgelerde ASM3 modeli daha iyi sonuç vermektedir (Koch vd., 2000).

Bahsedilen eksiklikler ve organik maddenin depolanmasına ait deneysel kanıtlar, aktif çamur modeli çalışma grubunun ASM3 modelini önermelerine neden olmuştur. ASM3 modeli 13 bileşen, 12 proses kinetiği ve 36 parametre içermektedir. ASM3 modeli matrisi ve sembol tanımları Çizelge 2.2.'de verilmiştir.

Çizelge 2.2. ASM3 modelinde prosese ait kinetik ve stokiyometrik ifadeler (Henze vd., 2002)

Bileşen	i	1	2	3	4	5
j	Proses	$S_O$	$S_I$	$S_S$	$S_{NH}$	$S_{N_2}$
1	Hidroliz		$f_{SI}$	$1 - f_{SI}$	$i_{NXS} - f_{SI}i_{NSI}$ $-(1 - f_{SI})i_{NSS}$	
2	KOİ'nin aerobik olarak depolanması	$-1 + Y_{STO O_2}$		-1	$i_{NSS}$	
3	KOİ'nin anoksik olarak depolanması			-1	$i_{NSS}$	$\frac{1 - Y_{STO N_2}}{2.86}$
4	Heterotrofların aerobik çoğalması	$1 - \frac{1}{Y_H}$			$-i_{NBM}$	
5	Heterotrofların anoksik çoğalması				$-i_{NBM}$	$-\frac{1 - 1/Y_{HNO}}{2.86}$
6	Heterotrofların aerobik içsel solunumu	$f_{XI} - 1$			$i_{NBM} - f_{XI}i_{NXI}$	
7	Heterotrofların anoksik içsel solunumu				$i_{NBM} - f_{XI}i_{NXI}$	$\frac{1 - f_{XI}}{2.86}$
8	Depolanmış organiklerin aerobik solunumu	-1				
9	Depolanmış organiklerin anoksik solunumu					$\frac{1}{2.86}$
10	Ototrofların aerobik çoğalması	$-\frac{4.57 - Y_A}{Y_A}$			$-\frac{1}{Y_A} - i_{NBM}$	
11	Ototrofların aerobik içsel solunumu	$f_{XI} - 1$			$i_{NBM} - f_{XI}i_{NXI}$	
12	Ototrofların anoksik içsel solunumu				$i_{NBM} - f_{XI}i_{NXI}$	$\frac{1 - f_{XI}}{2.86}$

Çizelge 2.2. (devam)

6 $S_{NOX}$	7 $S_{ALK}$	8 $X_I$	9 $X_S$
	$\frac{i_{NSS} - f_{SI} - (1 - f_{SI})i_{NSS}}{14}$		-1
	$\frac{i_{NSS}}{14}$		
$-\frac{1 - Y_{STONO}}{2.86} 1$	$\frac{i_{NSS}}{14} + \frac{1 - Y_{STONO}}{14 \cdot 2.86}$		
	$-\frac{i_{NBM}}{14}$		
$\frac{1 - 1/Y_{HNO}}{2.86}$	$-\frac{i_{NBM}}{14} - \frac{1 - 1/Y_{HNO}}{14 \cdot 2.86}$		
	$\frac{i_{NBM} - f_{XI}i_{NXI}}{14}$	$f_{XI}$	
$-\frac{1 - f_{XI}}{2.86}$	$\frac{i_{NBM} - f_{XI}i_{NXI}}{14} + \frac{1 - f_{XI}}{14 \cdot 2.86}$	$f_{XI}$	
$-\frac{1}{2.86}$	$\frac{1}{14 \cdot 2.86}$		
$\frac{1}{Y_A}$	$-\frac{i_{NBM}}{14}$		
	$\frac{i_{NBM} - f_{XI}i_{NSI}}{14}$	$f_{XI}$	
$\frac{1 - f_{XI}}{2.86}$	$\frac{i_{NBM} - f_{XI}i_{NSI}}{14} + \frac{1 - f_{XI}}{14 \cdot 2.86}$	$f_{XI}$	

Çizelge 2.2. (devam)

10 $X_H$	11 $X_{STO}$	12 $X_A$	13 $X_{TSS}$	Proses oranı, $\rho_j$ , [ML <sup>-3</sup> T <sup>-1</sup> ]
			$-i_{TSSXS}$	$k_h \left[ \frac{X_s / X_h}{K_X + (X_s / X_H)} \right] X_H$
	$Y_{STO2}$		$0.6Y_{STO2}$	$k_{STO} \left( \frac{S_s}{K_s + S_s} \right) \left( \frac{S_o}{K_{OH} + S_o} \right) X_H$
	$Y_{STONO}$		$0.6Y_{STONO}$	$\eta_g k_{STO} \left( \frac{S_s}{K_s + S_s} \right) \left( \frac{S_o}{K_{OH} + S_o} \right) \left( \frac{S_{NOX}}{K_{NOX} + S_{NOX}} \right) X_H$
1	$-\frac{1}{Y_H}$		$i_{TSSBM} - \frac{0.6}{Y_H}$	$\mu_H \left( \frac{S_o}{K_{OH} + S_o} \right) \left( \frac{S_{NH}}{K_{NH} + S_{NH}} \right) \left( \frac{S_{ALK}}{K_{ALKH} + S_{ALK}} \right) \cdot \left[ \frac{X_{STO} / X_H}{K_{STO} + (X_{STO} / X_H)} \right] X_H$
1	$-\frac{1}{Y_{NO}}$		$i_{TSSBM} - \frac{0.6}{Y_{HNO}}$	$\mu_H \eta_g \left( \frac{K_{OH}}{K_{OH} + S_o} \right) \left( \frac{S_{NH}}{K_{NH} + S_{NH}} \right) \left( \frac{S_{ALK}}{K_{ALKH} + S_{ALK}} \right) \cdot \left( \frac{S_{NOX}}{K_{NOX} + S_{NOX}} \right) \left[ \frac{X_{STO} / X_H}{K_{STO} + (X_{STO} / X_H)} \right] X_H$
-1			$f_{XI} i_{TSSXI} - i_{TSSBM}$	$b_H \left( \frac{S_o}{K_{OH} + S_o} \right) X_H$
-1			$f_{XI} i_{TSSXI} - i_{TSSBM}$	$b_{HNO} \left( \frac{K_{OH}}{K_{OH} + S_o} \right) \left( \frac{S_{NOX}}{K_{NOX} + S_{NOX}} \right) X_H$
	-1		-0.6	$b_{STO2} \left( \frac{S_o}{K_{OH} + S_o} \right) X_{STO}$ , $b_{STO2} > b_H$
	-1		-0.6	$b_{STONO} \left( \frac{K_{OH}}{K_{OH} + S_o} \right) \left( \frac{S_{NOX}}{K_{NOX} + S_{NOX}} \right) X_{STO}$ , $b_{STONO} > b_{HNO}$
		1	$i_{TSSBM}$	$\mu_A \left( \frac{S_o}{K_{OH} + S_o} \right) \left( \frac{S_{NH}}{K_{NHA} + S_{NH}} \right) \left( \frac{S_{ALK}}{K_{ALKA} + S_{ALK}} \right) X_A$
		-1	$f_{XI} i_{TSSXI} - i_{TSSBM}$	$b_A \left( \frac{S_o}{K_{OA} + S_o} \right) X_A$
		-1	$f_{XI} i_{TSSXI} - i_{TSSBM}$	$b_{ANO} \left( \frac{K_{OA}}{K_{OA} + S_o} \right) \left( \frac{K_{NOX}}{K_{NOX} + S_{NOX}} \right)$

ASM1 yaklaşımından farklı olarak Çizelge 2.2'de yer alan bileşenler aşağıda ifade edilmiştir:

$S_{N_2}$  = N<sub>2</sub> konsantrasyonu [M (N) L<sup>-3</sup>]

$S_{NOX}$  = NO<sub>3</sub><sup>-</sup> + NO<sub>2</sub><sup>-</sup> konsantrasyonu [M (N) L<sup>-3</sup>]

$X_{STO}$  = hücre içinde depolanan substrat (KOİ) konsantrasyonu [M (KOİ) L<sup>-3</sup>]

$X_{TSS}$  = toplam askıda katı madde konsantrasyonu [M (TSS) L<sup>-3</sup>]

ASM3 modeline ilave edilen stokiyometrik ifadeler aşağıda belirtilmiştir:

$Y_{STO2}$  = hücre içinde depolanan substratın (KOİ) anoksik biyokütle dönüşüm oranı

$Y_{STONO}$  = hücre içinde depolanan substratın (KOİ) anoksik biyokütle dönüşüm oranı

$Y_{HNO}$  = anoksik heterotrofik biyokütle ürünü [-, M (TSS) / M (BOİ)]

$f_{XI}$  = biyokütle bozunması sırasında açığa çıkan parçalanamayan KOİ oranı (-)

$f_{SI}$  = hidroliz sırasında açığa çıkan  $S_I$  miktarı (-)

$i_{NSS}$  =  $S_S$  içerisindeki azot miktarı [M (N) / M (KOİ)]

$i_{NXS}$  =  $X_S$  içerisindeki azot miktarı [M (N) / M (KOİ)]

$i_{NSI}$  =  $S_I$  içerisindeki azot miktarı [M (N) / M (KOİ)]

$i_{NXI}$  =  $X_I$  içerisindeki azot miktarı [M (N) / M (KOİ)]

$i_{NBM}$  = biyokütlerdeki azot miktarı [M (N) / M (KOİ), M (N) / M (TSS)]

$i_{TSSBM}$  = biyokütlerdeki TSS/KOİ oranı [M (TSS) / M (KOİ)]

$i_{TSSXS}$  =  $X_S$  içerisindeki TSS/KOİ oranı [M (TSS) / M (KOİ)]

$i_{TSSXI}$  =  $X_I$  içerisindeki TSS/KOİ oranı [M (TSS) / M (KOİ)]

ASM3 modeline ilave edilen kinetik parametreler aşağıda ifade edilmiştir:

$k_{STO}$  = hücre içi KOİ depolama hızı [T<sup>-1</sup>]

$K_{NOX}$  = NO<sub>x</sub> yarılanma sabiti [M (N) L<sup>-3</sup>]

$K_{STO}$  = hücre içinde depolanmış KOİ yarılanma sabiti [M (KOİ) L<sup>-3</sup>]

$b_{STO2}/b_{STONO}$  = hücre içinde depolanmış KOİ aerobik/ anoksik içsel solunum sabiti [T<sup>-1</sup>]

$b_{ANO}/b_{HNO}$  =ototrofik/heterotrofik bakterilerin içsel solunum sabiti [ $T^{-1}$ ]

## 2.1.2. Çoklu İstatistiksel Modelleme Teknikleri

### 2.1.2.1. Giriş

Çoklu istatistiksel proses kontrolü, projeksiyon metotları olarak adlandırılan tekniklerden oluşmaktadır (Davis vd., 1996). Projeksiyon metotlarının temel amacı, ölçülen değişken sayısı ile ifade edilen yüksek boyutlu uzayın, model yardımıyla daha küçük boyutlu uzay haline getirilmesini sağlamaktır. Model uzayı, “pseudo değişkenleri” olarak adlandırılan orjinal değişkenlerin doğrusal kombinasyonunun temel bileşenler veya gizli değişkenler haline getirilmiş halidir (Rosen, 2001). Projeksiyon metodunun tanımlanması ise ölçülen değişkenler içerisinde yer alan veri setini en iyi belirleyen gerçek pseudo değişkenlerini tespit etmeye bağlıdır. Bu nedenle ilişkilendirilmiş veriler, zor olmamakla birlikte projeksiyon metotlarının kullanılması için bir gerekliliktir.

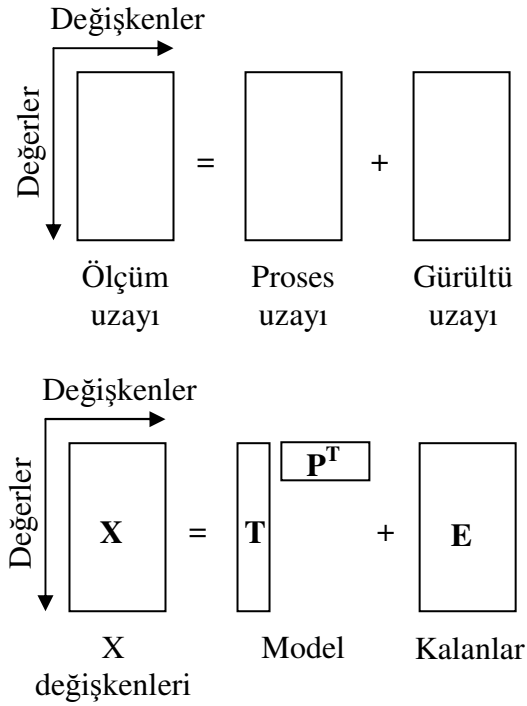
Çoklu lineer regresyon (MLR) analizi gibi metotlar, model içerisinde değerlendirilen hedef değişkenin, birden fazla girdi değişkeni ile doğrusal olarak belirlenmesine imkan tanımakla birlikte çoklu istatistiksel metotlarının başında çoklu bileşenler analizi (principle component analysis, PCA) gelmektedir. PCA ilk olarak Pearson (1991) tarafından, uzaydaki noktalara en yakın doğru veya düzlemleri tespit etmeyi sağlayan bir metot olarak tanımlanmıştır. Çoklu regresyon analizlerinden biri de kısmi en küçük kareler yöntemidir (partial least squares, PLS). Bu analiz de PCA metoduna oldukça yakın yaklaşımları içermektedir.

Çoklu istatistik metotları ekonometrik, fizikometrik ve kemometrik alanda oldukça sık olarak kullanılmakla birlikte, günümüzde proses izleme alanında da kullanılmaya başlanmıştır. Literatürdeki gelişimlere paralel olarak, PCA metodunun farklı terminolojiler kazanmasını da sağlamaktadır. Bu nedenle PCA, araştırma alanına göre aynı zamanda tekli veri ayrıştırılması (singular value decomposition, SVD), Karhuen-Loéve yayılımı, eigenvektör analizi, karakterisitik vektör analizi ve

Hotelling dönüşümü gibi farklı terminolojik tanımlar kapsamında değerlendirilebilmektedir.

### 2.1.2.2. Temel Bileşenler Analizi (PCA)

Matematiksel terminolojide temel bileşenler, proses değişken verilerine ait kovaryans ve korelasyon matrisinin SVD metoduyla ayrıştırılması sonucu elde edilmektedir. Bu işlem ile gerçek (rastlantısal olmayan) değişkenlerin proses uzayı (alt uzayı) tanımlanmış olmaktadır. Alt uzayın tamamlayıcısı olan gürültü alt uzayı ise ideal olarak sadece gürültü içermektedir (Şekil 2.2).

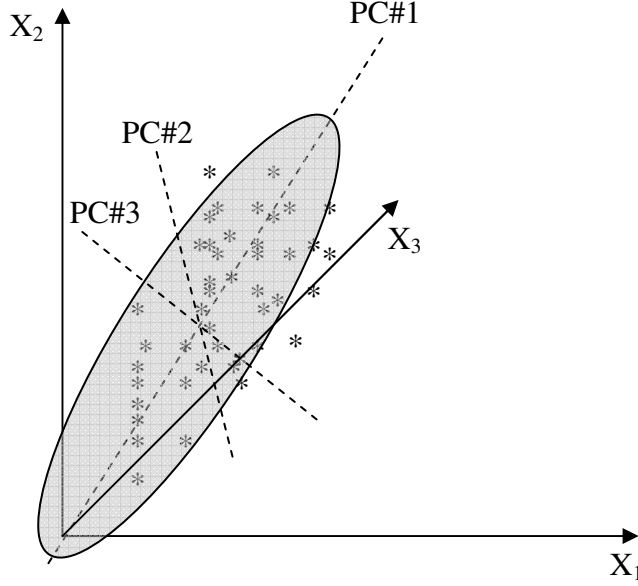


Şekil 2.2. Temel bileşenler analizinde X matrisinin proses ve gürültü alt uzayına ayrışması

Temel Bileşenler Analizi'nin tanımlanmasındaki diğer bir alternatif tanım da bu analizin, ölçülen değişken uzayının en büyük değişkeni yönünde üst üste binen bileşen (doğru) olduğu şeklindedir. Bu tanımdan yola çıkarak analiz içinde



tanımlanan diğer temel bileşenlerin de aynı yöntemle birbirilerine dik (ortogonal) konumlandıkları bir uzay içerisinde buldukları belirtilebilir. Bu yöntem içerisinde temel bileşenlerin tanımlanması sistematik değişken kalmayınca kadar devam etmektedir (Şekil 2.3).



Şekil 2.3. Temel bileşenlerin veri dağılımı diyagramında kesişimi

PCA, matris formunda aşağıdaki gibi yazılabilmektedir:

$$X = TP^T + E \quad (2.1)$$

Yukarıdaki eşitlikte  $X$ ,  $[m \times n]$  formu ve boyutundaki orjinal veri matrisini,  $T$ , temel bileşene ait skorları  $[n \times a]$ ,  $P$ , yükleri  $[n \times a]$  ve  $E$  ise modelde kalan kısmı (ya da gürültü alt uzayını) ifade etmektedir. Eğer  $a = n$  ise  $E=0$  olmaktadır. Bu durum bütün değişken yönlerinin tanımlandığı anlamını taşımaktadır (gürültü alt uzayı yoktur). Eğer  $a < n$  ise orjinal değişkenlerden daha az temel bileşen tanımlanmıştır ve bu durumda  $E$  ifadesi  $TP^T$  matrisinin toplamı ile ifade edilmeyen değişimi belirtmektedir. Genel olarak  $a \ll n$  durumu endüstriyel ölçekli proses kontrolünde daha gerçekçi bir yaklaşım olmaktadır.

Veri ayrıştırılması işleminde ilk olarak değişkenler ortalamaları merkezli ifade edilmekte ve daha sonra değişkenler bu merkez etrafında normalize edilmektedir. Normalizasyon işlemi, değişkenlerin farklı nümerik aralıklara ve birimlere sahip olması sebebiyle temel bileşenler analizinde bir arada değerlendirilmesi için gerçekleştirilmektedir. Bazı durumlarda (değişkenler aynı birime sahip) bu ön işleme gerek kalmamakla birlikte herhangi bir hataya neden olmamak için normalizasyon işlemi sabit bir işlem olarak gerçekleştirilmektedir (Benko, 2004).

Temel bileşenler analizi kullanılarak proses izlemesinin gerçekleştirilmesinde, prosesin normal işletme koşullarını temsil eden veri seti ve dolayısıyla proses alt uzayı tanımlanmış olmaktadır. Bu tanımlama gerçekleştirildikten sonra işletme sırasında elde edilen yeni veriler sırasıyla proses alt uzayı ve gürültü alt uzayında değerlendirilmektedir. Değerlendirilen verilerdeki sapmalar ve dağılımlar bir çok farklı yöntemlerle tespit edilebilmektedir. Karesel hata değerleri ile de model değişkenleri test edilmekte ve model performansı değerlendirilebilmektedir. Eğer mevcut işletim verileri ile zayıf model sonuçları elde edilirse, normal işletme koşullarından sapma olduğu ortaya çıkmaktadır. Hotelling  $T^2$  değeri de temel bileşen skorlarının tespit edilmesinde ve modeldeki sapma ve değişimlerin tespit edilmesinde oldukça önemlidir. Bunun yanında temel bileşenler analizinde normal işletme koşullarında sapma gerçekleştiğinde, geri dönülerek sapmaya neden olan değişkenler tespit edilerek izole edilebilmektedir (Rosen ve Olsson, 1998).

PCA metodunun performansını belirlemek ve performansını değerlendirmedeki en önemli nokta, prosesi temsil eden temel bileşenleri tespit etmek ve buna göre değerlendirme yapmaktır. Bu noktada ise deneyim ve proses bilgisi öncelikli hale gelmektedir. Bu noktada da karar verme meknizmasını kuvvetlendiren farklı metotlar uygulanmaktadır (Qin ve Dunia, 2000).

### **2.1.2.3. Çoklu Lineer Regresyon (MLR) Analizi**

Lineer regresyon analizi, tanımlanan  $X$  ve  $Y$  veri setleri arasındaki ilişkiyi belirlemek için kullanılan istatistiksel bir yöntemdir. Eğer tanımlanan veri setleri

arasındaki ilişki doğrusal ise, veriler grafik üzerinde gösterildiğinde kesişime noktalarından geçen çizgi de doğrusal olacaktır. Bu ilişki doğrusal korelasyon olarak adlandırılmakta ve  $y = mx + b$  şeklinde ifade edilmektedir. Bu eşitlikteki  $m$  ve  $b$ , sırasıyla, doğrusal çizginin eğimini ve  $Y$  eksenindeki kesişim sabitini ifade etmektedir (Berthouex ve Brown, 2002).

Tanımlanan bir veri seti içerisinde  $(x_i, y_i)$   $n$  adet veri noktasında  $m$  ve  $b$  katsayıları aşağıdaki eşitliklerle ifade edilebilmektedir:

$$m = \frac{n \cdot \sum_i^n (x \cdot y) - \sum_i^n x \cdot \sum_i^n y}{n \cdot \sum_i^n (x^2) - \left( \sum_i^n x \right)^2} \quad (2.2)$$

$$b = \frac{\sum_i^n y - m \cdot \sum_i^n x}{n} \quad (2.3)$$

Regresyon analizinde  $X$  ve  $Y$  veri setleri arasındaki doğrusal ilişkinin güvenilirliğini korelasyon katsayısı ( $R$ ) ile belirlemek de mümkündür. Korelasyon katsayısının 1'e eşit olması  $X$  ve  $Y$  arasındaki ilişkinin tam olarak anlamıyla doğrusal olduğunu göstermektedir. Korelasyon katsayısı ne kadar 1'e yakınsa iki parametre arasındaki doğrusal ilişki o kadar kuvvetlenmektedir. Tam tersi durumda ise tanımlanan  $y = mx + b$  doğrusal denkleminin güvenilirliği azalmaktadır.

Tanımlanan bir veri seti içerisinde  $(x_i, y_i)$   $n$  adet veri noktasında korelasyon katsayısı ( $R$ ), aşağıdaki eşitlik yardımıyla ifade edilebilmektedir:

$$R = \frac{n \cdot \sum_i^n (x \cdot y) - \sum_i^n x \cdot \sum_i^n y}{\sqrt{\left[ n \cdot \sum_i^n (x^2) - \left( \sum_i^n (x) \right)^2 \right] \cdot \left[ n \cdot \sum_i^n (y^2) - \left( \sum_i^n (y) \right)^2 \right]}} \quad (2.4)$$

Basit lineer regresyonda tek bir bağımsız değişken ( $X$ ) ile tek bağımlı değişken ( $Y$ ) tahmin edilebilmektedir. Çoklu lineer regresyon analizi de benzer hesap yöntemleri ile birden fazla bağımsız değişkenin ( $X_1, \dots, X_n$ ) tek bağımsız değişken ( $Y$ ) ile olan doğrusal ilişkisi tespit edilebilmektedir. Fakat, çoklu lineer regresyon analizinde birden çok bağımsız değişken olduğu için regresyon doğrusu iki boyutlu bir düzlemde grafiksel olarak gösterilememektedir. MLR analizine ait genel matematiksel ifade aşağıda verilmiştir:

$$y = m_1x_1 + m_2x_2 + m_3x_3 + \dots + m_nx_n + b \quad (2.5)$$

MLR denkleminde her bir bağımsız değişken ( $X_i$ ), bağımlı değişken ( $Y$ ) ile belirli bir doğrusal korelasyona sahiptir. Bu tür korelasyona kısmi korelasyon olarak adlandırılmaktadır.

Regresyon analizinde  $X$  ve  $Y$  değişkenleri arasındaki doğrusal ilişki belirlenirken, ölçülen değerler ve bu değerler arasından geçirilen doğru arasındaki değişime fark değeri adı verilmektedir. Eğer  $X$  ve  $Y$  değişkenleri arasında herhangi bir doğrusal ilişki yok ise orijinal varyansın fark değer varyansına oranı birdir. Eğer bu ilişki çok iyi bir şekilde tanımlanmışsa varyans oranı sıfır olarak ifade edilmektedir. Çoğu zaman verilerin varyans oranı belirtilen sıfır ve bir değerleri arasında bulunmaktadır. Bir sayısından varyans oranının çıkartılması ile de  $R^2$  veya saptama katsayısı elde edilmektedir. Eğer  $R^2$  değeri bire ne kadar yakınsa, değişken varyansının büyük bir kısmının MLR modeli ile ifade edilebildiği ortaya çıkmaktadır.

Regresyon analizinde  $R^2$  değerinin kara kökü alınırsa elde edilen  $R$  parametresine korelasyon katsayısı adı verilmektedir. Korelasyon katsayısı ise -1 ile +1 değerleri arasında değerlendirilmektedir. Eğer katsayı değeri negatif ise, bağımsız değişkenler ile bağımlı değişken arasındaki ilişkide negatiftir. Bu önermenin tersi de doğrudur. Korelasyon katsayısı sıfır ya da sıfıra yakın bir değer ise değişkenler arası ilişkiden bahsetmek mümkün değildir.

Çoklu regresyon analizinde ölçülen ve tahmin edilen değerler arasındaki farkın normal dağılıma uyduğu kabul edilmektedir. Her ne kadar uygulanan bazı istatistiksel testler (F istatistiği gibi) bu yaklaşıma uygun olmayan sonuçlar verse de, fark değerlerine ait normal dağılım histogramlarının oluşturularak yaklaşımın görsel olarak da test edilmesi gerekli görülmektedir.

Regresyon eşitliklerindeki değişkenlere ait katsayıların ( $m_1, \dots, m_n$ ) aldığı negatif ve pozitif değerler, bağımlı değişken arasındaki ilişkinin bir ifadesidir. Eğer MLR model eşitliğindeki herhangi bir değişkene ait katsayı negatif ise, bağımlı değişken ile arasında negatif bir ilişkiden bahsedilebilmektedir. Bu ifadelerin mekanistik olarak daha etkili bir şekilde belirlenebilmesi için değişkenler güç fonksiyonları şeklinde ve logaritmik dönüşüm yapılarak ifade edilebilmektedir. Bu durumda (2.5) eşitliği aşağıdaki formu almaktadır:

$$y = (x_1)^{m_1} \cdot (x_2)^{m_2} \cdot (x_3)^{m_3} \cdot \dots \cdot (x_n)^{m_n} \cdot e^b \quad (2.6)$$

Yukarıdaki eşitliğin elde edilmesi için ilk olarak bağımsız değişkenlerin logaritmik değerleri alınmaktadır. Daha sonra değişkenlere ait katsayılar üstel olarak ifade edilmekte ve değişkenler birbirileri ile çarpılmaktadır. Eşitlik 2.6'dan da görüleceği üzere, regresyon sabiti  $b$  ' de üstel formda ifade edilmektedir.

### 2.1.3. Yapay Zeka Modelleme Teknikleri

#### 2.1.3.1. Giriş

Zeka, anlama ve kavrama yeteneği olarak tanımlanabilir. Bir şeyi anlama, kavram veya önemini anlama olarak da ifade edilen zeka bireysel bilgi birikimi ve deneyimlerle ilişkilidir (Perendeci, 2004).

Genel olarak zeka; çevreyi algılama, karar verme ve hareketleri kontrol etme yeteneğidir. Birçok bilim adamı ilgi alanlarına göre zekayı farklı şekillerde tanımlamışlardır. Bu tanımlardan bazıları;

- İyi akıl yürütme, hüküm verme ve kendini iyileştirme kapasitesi,
- Soyut düşünebilme kapasitesi,
- Algılama, sorgulama ve yaratıcılık,
- Gayeli davranma, mantıklı düşünme ve çevresiyle ilişkilerinde etkili olma kapasitesi,
- Düşüncesini yeni durumlara bilinçli olarak uydurabilme yeteneği,
- Çevreye uygun tepkilerde bulunabilme,
- Öğrenme, problem çözme, yeni ürünler ortaya çıkarma ve iletişim kurma kapasitesi şeklindedir (Sağiroğlu vd., 2003).

Zekanın, iyileştirilebilir, geliştirilebilir ve değiştirilebilir olduğu ve çeşitli yollarla sergilenebildiği, gerçek hayat durumlarından veya koşullarından soyutlanamayacağı da belirtilmiştir. Gardner (1993), insan beyninin farklı bölümlerden oluştuğu ve her bir bölümün özel işlevlere sahip olduğu fikrini ortaya atmış ve zekayı, değişen dünya şartlarında yaşamak ve değişimlere uyum sağlamak amacıyla her insanda kendine özgü bulunan yetenekler ve beceriler bütünü olarak, topluma faydalı şeyler yapabilme kapasitesi olarak tanımlamıştır.

Yapay zeka (YZ, Artificial Intelligence, AI); zeka ve düşünme gerektiren işlemlerin bilgisayarlar tarafından yapılmasını sağlayacak araştırmaların yapılması ve yeni yöntemlerin geliştirilmesi kapsamında çalışan bilim dalıdır (Russell and Norvig, 1995). Yapay zeka; düşünme, anlama, kavrama, yorumlama ve öğrenme yapılarının programlamayla taklit edilerek problemlerin çözümüne uygulanması” olarak ifade edilebilir. Daha geniş olarak YZ;

- Bilgisayarların bilgi edinme, algılama, görme, düşünme ve karar verme gibi insan zekasına özgü kapasitelerle donatılması bilimi,
- İnsanların düşünüş sürecini, çeşitli makineler ve yöntemler kullanarak taklit etme,
- İnsanın düşünme yapısını anlama, bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliştirmeye çalışma,
- Programlanmış bir bilgisayarın düşünme girişimi olarak da tarif edilmektedir.

Özetle YZ, “insanın düşünme, anlama, kavrama, iletişim kurma, yorumlama ve öğrenme yapılarını anlayarak benzerlerini ortaya çıkaracak yeni yaklaşımların bilgisayar yardımıyla geliştirilmesi ve insanlığın hizmetine sunulabilmesi” olarak tanımlanabilir. Ancak, bazı konularda bilgisayarların hiçbir zaman insan seviyesine çıkamayacağı kabul edilerek insanın elektromekanik versiyonlarını yaratmaya çalışmak yerine insanlığa faydalı olmayı amaçlayan araç, gereç ve yaklaşımlar yaratmaya çalışmak daha doğrudur (Sağiroğlu vd., 2003).

Yapay zeka araştırmalarının ana amacı insan bilgi işleme prensiplerinin anlaşılması ve biyolojik sinir sisteminin çalışma mekanizmalarının çözülmesidir. Bu mekanizmaların araştırılmasında ve geliştirilmesinde bilgisayarlar önemli yer tutmaktadır. Bilgisayarlar, işlemci hızı ve sahip oldukları hafıza elemanı ve hızı ile değerlendirilirken, yapay zeka hesaplama gücü, kullanılan yol ve yöntemler ile hafıza olmak üzere üç ana başlık altında karşılaştırılmaktadır. İnsan beynindeki nöronların kimyasal olarak birbirine bağlanma potansiyeli hesaplama gücü olarak ifade edilir. Yapay zeka donanımı işlem kapasitesine, başka bir deyişle işlemci hızına karşılık geldiğinden hesaplama gücünü arttırmaktadır. Karşılaşılan problemlerde algılama ve çözebilme gibi eylemler için kullanılan yol ve yöntemler, insan psikolojisinde çözümlene metodolojisine ve prensiplerine karşılık gelmektedir. Öğrenilen bilgiyi tutan hafızanın kapasitesi ve güvenilirliği insan belleği ile ifade edilirken, yapay zeka sisteminde bilgisayar hafızasına karşılık gelmektedir (Sağiroğlu vd., 2003).

Yapay zeka teknikleri; yapay sinir ağları, bulanık mantık, sezgisel algoritmalar (genetik algoritmalar, tabu arama, karınca algoritması, ısıt işlemler, bağıklık sistemi gibi), uzman sistemler ve belirtilen tekniklerin hibrit uygulamaları (ANFIS) şeklinde gruplandırılmaktadırlar (Sağiroğlu vd., 2003).

### **2.1.3.2. Bulanık Mantık (FL)**

Bazı sistemlerde modelleme doğru şekilde yapılsa bile elde edilen modelin denetleyici tasarımında kullanımı karmaşık problemlere ve oldukça yüksek maliyete neden olabilir. Bu nedenle, bazı denetim algoritmalarının belirsiz, doğru olmayan, iyi

tanımlanmamış, zamanla deęişen ve karmaşık sistemlere uygulanması mümkün olmayabilir. Bu durumda ya hiç çözüm üretilememekte ya da elde edilen denetleyicinin performansı yeterince iyi olmamaktadır (Perendeci, 2004).

Bu gibi durumlarda genellikle bir uzman kişinin bilgi ve deneyimlerinden yararlanılma yoluna gidilir. Uzman kişi az, çok, pek az, pek çok, biraz az, biraz çok gibi günlük hayatta sıkça kullanılan dilsel niteleyiciler doğrultusunda bir denetim gerçekleştirir. Bu dilsel ifadeler doğru bir şekilde bilgisayara aktarılırsa hem uzman kişiye ihtiyaç kalmamakta hem de uzman kişiler arasındaki denetim farkını ortadan kaldırmaktadır. Böylece denetim mekanizması esnek bir yapıya kavuşmaktadır. Temeli insanın herhangi bir sistemi denetlemedeki düşünce ve sezgilerine baęlı davranışının benzetimine dayanmaktadır. Dolayısıyla bir insan bir sistemi bulunduğu gerçek durumdan istenilen duruma götürmek için sezgilerine ve deneyimlerine baęlı olarak bir denetim stratejisi uygulayarak amaca ulaşmaktadır. Bulanık mantık bu tür mantık ilişkileri üzerine kurulmuştur.

Bulanık mantık yaklaşımı, makinelere insanların özel verilerini işleyebilme ve onların deneyimlerinden ve önsözlerinden yararlanarak çalışabilme yeteneğini verir. Bu yeteneęi kazandırırken sayısal ifadeler yerine sembolik ifadeler kullanır. Bu sembolik ifadelerin makinelere aktarılması matematiksel bir temele dayanır. Bu matematiksel temel bulanık mantık kümeler kuramı ve buna dayanan bulanık mantıktır. Dilsel ifadelerin bilgisayara aktarılması matematiksel bir temele dayanmaktadır. Bu matematiksel temel, bulanık kümeler kuramı ve bulanık mantık olarak adlandırılır. Bulanık mantık bilinen klasik mantık gibi (0,1) olmak üzere iki seviyeli deęil, [0,1] aralığında çok seviyeli işlemleri ifade etmektedir.

Bu konudaki ilk ciddi adım 1965 yılında Lotfi A. Zadeh tarafından yayınlanan bir makalede bulanık mantık veya bulanık küme kuramı adı altında ortaya konulmuştur. Zadeh (1965) çalışmasında, insan düşüncesinin büyük çoğunluğunun bulanık olduğunu, kesin olmadığını belirtmiştir. Bu yüzden 0 ve 1 ile temsil edilen Boolean mantık bu düşünce sistemini yeterli bir şekilde ifade edememektedir. İnsan mantığı, açık-kapalı, sıcak-soęuk, 0 ve 1 gibi deęişkenlerden oluşan kesin ifadelerin yanı sıra az açık, az kapalı, serin, ılık gibi ara deęerleri de göz önüne almaktadır. Bu nedenle



bulanık mantık klasik mantığın aksine iki seviyeli değil, çok seviyeli işlemleri kullanmaktadır (Perendeci, 2004).

Bulanık mantığın genel özellikleri Zadeh (1965) tarafından şu şekilde ifade edilmiştir;

- Bulanık mantıkta, kesin değerlere dayanan düşünme yerine, yaklaşık düşünme kullanılır,
- Bulanık mantıkta her şey  $[0,1]$  aralığında belirli bir derece ile gösterilir,
- Bulanık mantıkta bilgi; büyük, küçük, çok az gibi dilsel ifadeler şeklindedir,
- Bulanık çıkarım işlemi dilsel ifadeler arasında tanımlanan kurallar ile yapılır,
- Her mantıksal sistem bulanık olarak ifade edilebilir,
- Bulanık mantık matematiksel modeli çok zor elde edilen sistemler için çok uygundur.

Bulanık mantık işlemleri problemin analiz edilmesi ve tanımlanması, kümelerin ve mantıksal ilişkilerin oluşturulması, mevcut bilgilerin bulanık kümelere dönüştürülmesi ve modelin yorumlanması aşamalarından oluşmaktadır. Sistemin her bir girdi ve çıktı değişkenleri için üyelik işlevi tanımlanmalıdır. Üyelik işlevinin sayısı sistemin davranışına bağlı olmakla birlikte, aynı zamanda tasarımcının seçimine de bağlıdır (Elmas, 2003a).

Bulanık mantık kuramının insan düşünüş tarzına çok yakın olması en büyük üstünlüğünü oluşturmaktadır. Bulanık mantık yaklaşımı matematiksel modele ihtiyaç duymadığından, matematiksel modeli iyi tanımlanamamış, zamanla değişen ve doğrusal olmayan sistemler başarılı uygulama alanlarıdır. Bulanık mantık yaklaşımında işaretlerin bir ön işlemeye tabii tutulmaları ve geniş bir alana yayılmış değerlerin az sayıda üyelik değerlerine indirgenmeleri uygulamaların daha hızlı bir şekilde sonuca ulaşmasını sağlamaktadır. Sistemlerin kararlılık, gözlemlenebilirlik ve denetlenebilirlik analizlerinin yapılmasında ispatlanmış kesin bir yöntemin olmayışı bulanık mantığın temel dezavantajıdır. En önemli ve sürekli belirtilen dezavantaj ise; üyelik işlevlerinin ayarlanmasının uzun zaman alması ve öğrenme yeteneği olmamasıdır (Elmas, 2003a)

Bir bulanık küme, bir kümeye ait olan bir elementin derecesini ifade eder. Bu sebeple, bir bulanık kümenin karakteristik fonksiyonunun verilen bir kümede elementin üyelik derecesini belirten  $0$  ile  $1$  arasında bir değer almasına izin verilir. Eğer  $X$ ,  $x$ 'den jenerik olarak gösterilen nesnelerin koleksiyonu ise, daha sonra  $X$ 'deki bir bulanık küme;  $A$ , sıralanmış çiftlerin bir kümesi olarak tanımlanır;

$$A = \{(x, \mu_A(x) \mid x \in X\} \quad (2.7)$$

$\mu_A(x)$ , üyelik boşluğu  $M$ 'e  $M=[0,1]$   $X$ 'i haritalayan  $A$ 'daki  $x$ 'in üyelik fonksiyonu (Membership Function, MF) olarak isimlendirilir.  $M$ ,  $0$  ve  $1$  olmak üzere sadece iki nokta içerdiğinde,  $A$  bulanık olmayandır (ham) ve  $\mu_A$  bir ham kümenin karakteristik fonksiyonuna benzerdir (Jang, 1993).

Bulanık mantık sisteminin temeli, üyelik işlevlerinden ortaya çıkan dilsel değişkenlerin oluşturduğu girdileri karar verme sürecinde kullanmaktır. Bu değişkenler, dilsel “Eğer- ise” kurallarının ön şartları tarafından birbirleriyle eşleşir. Her bir kuralın sonucu, girdilerin üyelik derecelerinden bulanıksızlaştırma (durulaştırma) metoduyla sayısal bir değer elde edilmesiyle belirlenir (Elmas, 2003a).

Üyelik işlevlerinde genel olarak gerçek sayılar kullanılır. Bu işlevler  $[0,1]$  aralığında üyelik derecesine sahiptir (Elmas, 2003a). Pratikte üyelik işlevleri denetlenecek sistemin durumuna göre uygulayıcı tarafından yamuk, üçgen, çan eğrisi, Gaussian1, Gaussian 2, psigma, dsigma, pi, sigma, gibi çok değişik şekillerde seçilebilir.

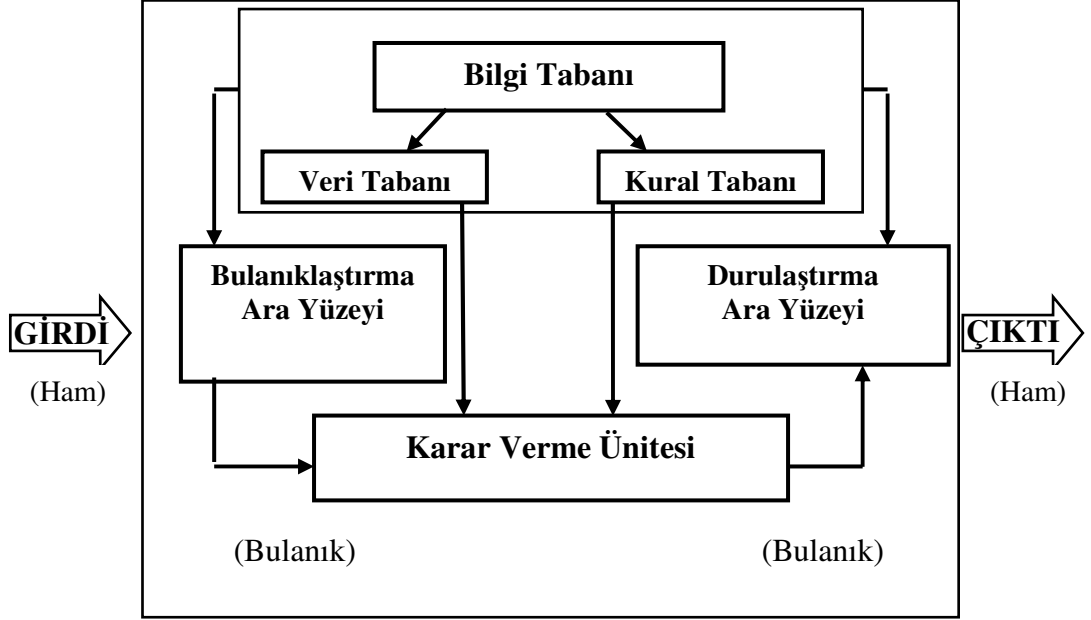
Bulanık küme klasik ve keskin kümedeki açık/kapalı, soğuk/sıcak gibi ikili denetim değişkenlerinden oluşan keskin dünyayı az açık/az kapalı, serin/ılık, biraz hızlı/biraz yavaş gibi yumuşak (soft) niteleyicilerle gerçek dünyaya benzettir. Yani klasik kümelerdeki gibi bir değişken, verilen kümenin ya elemanı ya da elemanı değildir yaklaşımının tersine her değişken verilen kümede belirli bir üyelik derecesine sahiptir (Elmas, 2003a).

Bulanık eğer- daha sonra kuralları veya bulanık koşul durumları, *EĞER A, DAHA SONRA B* formunun ifadeleridir. Burada A ve B bulanık kümenin etiketleridir. Kısa formlarından dolayı bulanık eğer-daha sonra kuralları, kesin olmayan ve belirsizliklerin çevresinde karar vermek için insan yeteneğinde önemli rol oynayan kesin olmayan modları yakalamak için sıklıkla uygulanır. Basit bir gerçeği tanımlamak için bir örnek verilebilir;

Takagi ve Sugeno tarafından önerilen diğer form bulanık eğer-daha sonra kuralı, sadece dayanak noktası bölümünü içeren bulanık setlere sahiptir. Takagi ve Sugeno'nun bulanık eğer-daha sonra kuralı kullanılarak, objelerin hareketindeki direnç kuvveti aşağıdaki şekilde tanımlanabilir;

Her iki tip bulanık eğer-daha sonra kuralı yaygın olarak hem modellemede hem de kontrolde kullanılmaktadır. Dil etiketleri ve üyelik fonksiyonlarının kullanılmasıyla, bir bulanık eğer-daha sonra kuralı insan tarafından kullanılan bir “parmak hesabı” (rule of thumb) ruhunu kolayca yakalayabilir. Diğer bir açıdan; dayanak noktası bölümündeki niteleyiciler nedeniyle, her bulanık eğer-daha sonra kuralı incelenmekte olan sistemin bir bölgesel tanımlaması olarak görülebilir. Bulanık eğer-daha sonra kuralları bulanık çıkarım sisteminin merkez bölümünü oluşturmakta, bir bulanık tabanlı kurallar sistemi bulanık denetimcisi olarak yaygın şekilde kullanılmaktadır (Jang, 1993).

Bulanık çıkarım sistemleri, bulanık kural temelli sistemler (Fuzzy-Rule-Based Systems), bulanık modeller (Fuzzy Models), bulanık birleşmeli hafızalar (FAM, Fuzzy Associative Memories) veya denetimci olarak kullanıldığında bulanık kontrolcüler (Fuzzy Controllers) olarak bilinmektedirler. Şekil 2.4'de Bulanık çıkarım sisteminin akış şeması verilmiştir.



Şekil 2.4. Bulanık Çıkarım Sistemi (Jang, 1993)

Temel olarak, Şekil 2.4'de görülen bir bulanık çıkarım sistemi beş fonksiyonel bloktan oluşur;

- Kural tabanı: Birkaç bulanık eğer - ise kuralını içerir.
- Veri tabanı: Bulanık kurallarında kullanılan bulanık setlerin üyelik fonksiyonlarını tanımlar.
- Bulanıklaştırma ara yüzeyi: Ham girişleri dil bilimsel değerler ile eşleşen derecelere dönüştürür.
- Karar verme ünitesi: Kurallardaki çıkarım işlemlerini gerçekleştirir.
- Durulaştırma ara yüzeyi: Bulanık çıkarım sonuçlarını ham çıktılara dönüştürür.

Bulanık çıkarım sistemleri tarafından gerçekleştirilen “bulanık akıllı düşünmedeki” adımlar (bulanık eğer-daha sonra kurallarına dayanan çıkarım işlemleri) şunlardır (Jang, 1993);

1. Dayanak noktası bölümündeki her bir dilbilim etiketinin üyelik değerlerinin sağlanması için (veya uyuşabilirlik oranlarının) üyelik fonksiyonları ile giriş değişkenlerinin karşılaştırılması (bu aşama genellikle bulanıklaştırma olarak isimlendirilir).
2. Her bir kuralın ağırlık gücünü elde etmek için dayanak noktası bölümündeki üyelik değerlerinin birleştirilmesi (spesifik T-norm işlemcisi, genellikle çarpma veya min. yoluyla).
3. Ağırlık gücüne dayanan her bir kuralın niteliklendirilmiş sonucunun (bulanık veya ham) üretilmesi.
4. Ham bir çıktı üretmek için niteliklendirilmiş sonuçların biraraya getirilmesi (bu aşama genellikle durulaştırma olarak isimlendirilir).

Geçmişte bir çok bulanık akıllı düşünme tipi önerilmiştir. Bulanık akıllı düşünme tipine dayanan ve bulanık eğer-daha sonra kuralları uygulanan bulanık çıkarım sistemlerinin bir çoğu Tip 1, Tip 2 ve Tip 3 olarak üç tipe ayrılabilir. Fakat teorik olarak, hangi tip bulanık çıkarım sistemi tipinin diğerlerinden daha iyi olduğu konusunda bir kanıt bulunmamaktadır. Bir tipin seçimi temelde kullanıcının tercihine ve uygulamaya bağlıdır (Jang, 1993; Perendeci, 2004).

### **2.1.3.3. Yapay Sinir Ağları (ANN)**

İnsan beyni bilinen en gizemli ve karmaşık hesaplayıcıdır. Yapay sinir ağları (ANN), insan beyninin işleyişini taklit ederek yeni sistem oluşturmaya çalışan yaklaşımlardır. İstisnasız tüm ANN yapılarının esin kaynağı biyolojik sinir ağlarının işleyiş yöntemidir.

Yapay sinir ağları, sisteme ilişkin tek veya çoklu parametrelere bağlı olarak tanımlanan girdi verileri ile sistemin yine tek veya çoklu parametrelere bağlı olarak tanımlanabilen çıktıları arasında ilişki kurabilme yeteneğine sahiptir (Sağiroğlu vd., 2003).

Basit tanımıyla yapay sinir ağıları, birçok basit işlemci elemandan oluşan yapılardır. Bu elemanlar farklı formda ifade edilebilen nümerik verileri taşıyan “bağlantılar” veya “ağırlıklar” ile birbirlerine bağlıdırlar. ANN’deki gelişmelerin ana kaynağı, beynin rutin olarak gerçekleştirdiği karmaşık hesaplamaları yapabilen yapay belki de zeki davranış sergileyen sistemlerin yapılabileceği ümididir. ANN yapılarına göre farklı öğrenme yaklaşımı kullanır ve bu yaklaşımlara göre ağırlıklar değiştirilir. Ağırlıkların değişimi öğrenmeyi ifade eder. ANN’de ağırlık değişimi yok ise öğrenme işlemi de sona ermiştir (Perendeci, 2004).

Yapay sinir ağıları, yerel bir hafıza yapısı tanımlayan ve birbirleri ile çeşitli şekillerde bağlantılı olan veri işleme elemanlarının dağıtılmış veriyi geliştirebildikleri paralel yapılardır. Genel olarak, matematiksel modelleri oluşturulamayan veya matematiksel modelleri çok zor tanımlanabilen problemlerin çözümü için kullanılır. Veri işleme veya işlemci elemanların (nöronların) bir ağ yapısı tanımlayacak şekilde birbirlerine bağlanmaları fikri beyin hücrelerinin birbiriyle olan bağlantılardan esinlenerek gerçekleştirilmiştir (Sağiroğlu vd., 2003) .

Beyin; öğrenebilir, sonuçlar çıkartabilir, genelleme yapabilir, soyut ve somut kavramları açıklayabilir, bilgi depolayabilir, ilişkilendirebilir, mevcut bilgilerden yeni sonuçlar çıkarabilir, problem çözebilir ve farklı çözüm önerileri getirebilir. Beynin bütünleşmiş bir çalışma yapısı vardır.

Kısaca belirtmek gerekirse, beyne bağlı olarak çalışan reseptör olarak adlandırılan alıcı sinirler veri toplamakla görevlidir. Bu sinirler algıladıkları tüm verileri bilgi içeren elektriksel sinyallere dönüştürerek beyne iletirler. Beyin veri işleme süreci sonunda aldığı kararları elektriksel sinyallere dönüştürür. Söz konusu sinyaller efektör olarak adlandırılan tepki sinirleri tarafından uygun tepkilere dönüştürülmek üzere organlara iletilir (Sağiroğlu vd., 2003).


ANN’ler insan beyninin aktivitesi örnek alınarak geliştirilmeye çalışılmıştır ve aralarında yapısal olarak benzerlikler vardır. Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. ANN’ler birbirine bağlı doğrusal ve/veya doğrusal olmayan birçok elemandan oluşurlar. Biyolojik sinir

sistemi ile yapay sinir sistemi arasındaki benzerlikler Çizelge 2.3'de verilmiştir (Sağiroğlu vd., 2003).


Çizelge 2.3. Biyolojik sinir sistemi ile ANN'lerin benzer özellikleri

Biyolojik Sinir Sistemi	Yapay Sinir Ağlar
Nöron	Yapay Nöron (İşlemci Eleman)
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Bir yapay nöron temel olarak girdiler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıktı olmak üzere beş kısımdan oluşmaktadır. Şekil 2.5'de p girdili n çıktılı bir yapay nöronun blok diyagram gösterimi (A) ve detaylı açılımı (B) verilmiştir (Öztemel, 2003; Sağiroğlu vd., 2003).



(A)



(B)

Şekil 2.5. p girdili, n çıktılı bir yapay nöronun blok diyagram gösterimi (A) ve detaylı gösterimi (B)

Bu şekilde;  $x$  girdileri,  $y$  çıktısı,  $F$  fonksiyonu,  $p$  nöron girdi sayısını,  $n$  çıktı sayısını  $w$  ise ağırlıkları ifade etmektedir.

Girdiler: Bir yapay sinir hücresine (proses elemanına) dış dünyadan gelen bilgilerdir. Bunlar ağırlık öğrenmesi istenen örnekler tarafından belirlenir. Yapay sinir hücresine dış dünyadan olduğu gibi başka hücrelerden veya kendi kendisinden de bilgiler gelebilir.

Girdiler  $p$  elemanlı sütun vektörü olarak gösterilmektedir;

$$X = [x_1 \dots x_p]^T \quad (2.8)$$

Ağırlıklar: Ağırlıklar bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Ağırlıklar, girdi ile toplama noktaları arasındaki bağlantılara karşılık gelir. Ağırlıkların büyük ya da küçük olması önemli veya önemsiz olduğu anlamına gelmez. Sinapslar, ağırlıklar olarak adlandırılan ayarlanabilir parametreler ile karakterize edilirler. Ağırlıklar,  $p$  elemanlı satır vektörü olarak düzenlenir.

$$W = [w_1 \dots w_p] \quad (2.9)$$

Toplama fonksiyonu: Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. En yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece ağa gelen net girdi bulunmuş olur.

Sinapslardan ve dendritlerden geçen girdi işaretleri, toplam post-sinaptik aktiviteyi tanımlayan aktivasyon potansiyeli olarak toplanır. Aktivasyon potansiyeli girdi işaretlerinin ve ağırlıklarının doğrusal toplamı olarak şekillenmiştir. Yani, ağırlıklar ile girdi vektörlerinin çarpımıdır.

Bu çarpım;



$$v = \sum_{i=1}^p w_i x_i = xw = [w_1 w_2 \dots w_p] \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_p \end{bmatrix} = wx^T \quad (2.10)$$

ile ifade edilir. Literatürde yapılan araştırmalarda toplama fonksiyonu olarak değişik formüller kullanılmaktadır.

**Aktivasyon fonksiyonu:** Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Aktivasyon potansiyeli, çıktı işaretini üreten bir aktivasyon fonksiyonundan  $F(\cdot)$  geçirilir ve çıktı değeri 2.11 eşitliğinde ifade edilen fonksiyondan elde edilmektedir.

$$y = F(v) \quad (2.11)$$

Aktivasyon fonksiyonu, aktivasyon potansiyelini çıktı işaretinin standart değerleri için normalize eden bir fonksiyondur. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu olarak da çıktıyı hesaplamak için değişik formüller kullanılmaktadır.

Yaygın olarak kullanılan çok katmanlı algılayıcı (Multilayer Perceptrons) modelinde genellikle aktivasyon fonksiyonu olarak sigmoid fonksiyon kullanılmaktadır. Çıktı değerlerine sigmoid bir aktivasyon değeri uygulanırsa, sonuçta çıktı değeri 2.12 eşitliği ile tespit edilmektedir.

$$y = F(v) = \frac{1}{1 + e^{-v}} \quad (2.12)$$


**Çıktılar:** Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Bir işlemci elemanın çıktı değeri diğer işlemci elemanlarına girdi veya ağırlık çıktı değeri olabilir. Üretilen çıktı dış dünyaya da gönderilebilir.

Yapay sinir hücreleri bir araya gelerek yapay sinir ağlarını oluştururlar. Sinir hücrelerinin bir araya gelmesi rastgele olmaz. Genel olarak hücreler üç katman halinde ve her katman içinde paralel şekilde bir araya gelerek ağı oluştururlar (Öztemel, 2003). Bu katmanlar aşağıda belirtilmiştir;

**Girdi katmanı:** Bu katmandaki proses elemanları dış dünyadan bilgileri alarak ara katmanlara transfer etmekle sorumludurlar. Bazı ağlarda bilgi katmanında herhangi bir bilgi işleme olmaz.

**Ara katmanlar:** Girdi katmanından gelen bilgiler işlenerek çıktı katmanına gönderilir. Bilgilerin işlenmesi ara katmanlarda gerçekleştirilir. Bir ağ içinde birden fazla ara katman bulunabilir.

**Çıktı katmanı:** Bu katmandaki proses elemanları ara katmandan gelen bilgileri işleyerek ağın girdi katmanından sunulan girdi seti için üretilmesi gereken çıktıyı üretirler. Şekil 2.6'da bu üç katmanın her birinde bulunan proses elemanları ve katmanlar arası ilişkiler bir yapay sinir ağı olarak verilmiştir.



Şekil 2.6. Bir yapay sinir ağı

Şekildeki yuvarlaklar proses elemanlarını göstermektedir. Her katmanda birbirine paralel elemanlar söz konusudur. Proses elemanlarını birbirine bağlayan çizgiler ise ağın bağlantılarını göstermektedir. Proses elemanları ve bağlantıları yapay sinir ağını oluştururlar. Bu bağlantıların ağırlık değerleri öğrenme sırasında belirlenmektedir.

Yapay sinir ağlarının genel çalışma prensibi, bir girdi setini alarak onları çıktı setine çevirmek olarak açıklanabilir. Bunun için ağın kendisine gösterilen girdiler için doğru çıktıları üretecek hale gelmesi (yani eğitilmesi) gerekmektedir. Ağa sunulacak girdiler öncelikle bir vektör haline getirilir, bu vektör ağa gönderilir ve ağ bu vektör için gerekli çıktı vektörünü üretir. Ağın parametre değerleri doğru çıktıyı üretecek şekilde düzenlenir. Bir yapay sinir ağı, herhangi bir girdi vektörünü nasıl dönüştürdüğü konusunda bir bilgi vermez. Mühendislik açısından bakıldığında yapay sinir ağları “kara kutu” gibi görülebilir. Kara kutu, dışarıdan bilgileri alıp, dışarıya ürettiği çıktıları vermektedir. İçeride ne olduğu ise bilinmemektedir. Diğer bir deyişle yapay sinir ağının sonuçları nasıl oluşturduğunu açıklama yeteneği yoktur. Bu durum ağa olan güveni sarsmakla birlikte başarılı uygulamalar yapay sinir ağlarına olan ilgiyi sürekli artırmaktadır (Öztemel, 2003).

Yapay sinir ağlarında proses elemanlarının bağlantılarının ağırlık değerlerinin belirlenmesi işlemine “ağın eğitilmesi” denir. Başlangıçta bu ağırlık değerleri rastgele olarak atanır. Yapay sinir ağları kendilerine örnekler sunuldukça bu ağırlık değerlerini değiştirirler. Amaç ağa sunulan örnekler için doğru çıktıları üretecek ağırlık değerlerini bulmaktır. Örnekler ağa defalarca sunulurken en doğru ağırlık değerleri bulunmaya çalışılır. Ağın doğru ağırlık değerlerine ulaşması örneklerin temsil ettiği olay hakkında genellemeler yapabilme yeteneğine kavuşması demektir. Bu genelleştirme özelliğine kavuşması işlemine “*ağın öğrenmesi*” denir. Ağırlıkların değerlerinin değiştirilmesi belirli kurallara göre yürütülmektedir. Bu kurallara “*öğrenme kuralları*” denir. Kullanılan öğrenme stratejisine göre değişik öğrenme kuralları geliştirilmiştir.

Yapay sinir ağlarında öğrenme olayının iki aşaması vardır. Birinci aşamada ağa sunulan örnek için ağın üreteceği çıktı belirlenir. Bu çıktı değerinin doğruluk derecesine göre iki aşamada ağın bağlantılarının sahip olduğu ağırlıklar değiştirilir.

Ağın çıktısının belirlenmesi ve ağırlıkların değiştirilmesi öğrenme kuralına bağlı olarak farklı şekillerde olmaktadır.

Ağın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini (performansını) ölçmek için yapılan denemelere ise “*ağın test edilmesi*” denilmektedir. Test etmek için ağın öğrenme sırasında görmediği örnekler kullanılır. Test etme sırasında ağın ağırlık değerleri değiştirilemez. Test örnekleri ağa sunulur. Ağ eğitim sırasında belirlenen bağlantı ağırlıklarını kullanarak görmediği bu örnekler için çıktılar üretir. Elde edilen çıktılarının doğruluk değerleri ağın öğrenmesi hakkında bilgiler verir. Sonuçlar ne kadar iyi olursa eğitimin performansı da o kadar iyi demektir. Eğitimde kullanılan örnek setine “*eğitim seti*”, test için kullanılan sete ise “*test seti*” adı verilmektedir. Yapay sinir ağlarının bu şekilde bilinen örneklerden belirli bilgileri çıkartarak bilinmeyen örnekler hakkında yorumlar yapabilme (genelleme yapabilme) yeteneğine “*adaptif öğrenme*” denir (Öztemel, 2003).

ANN’ler genel olarak birbirleri ile bağlantılı işlemci birimlerden veya diğer bir ifade ile nöronlar veya işlemci elemanlardan oluşurlar. Nöronlar arasındaki bağlantıların yapısı ağın yapısını belirler. İstenilen hedefe ulaşmak için bağlantıların nasıl değiştirileceği, öğrenme algoritması tarafından belirlenir. Kullanılan öğrenme kuralına göre, hatayı sıfıra indirecek şekilde ağın ağırlıkları değiştirilir. ANN’ler yapılarına ve öğrenme algoritmalarına göre sınıflandırılırlar (Elmas, 2003b).

Yapay sinir ağları yapılarına göre ileri beslemeli ağ (Feedforward Network) ve geri beslemeli ağ (Feedback Network) ağlar olmak üzere iki farklı yapıda incelenmektedir.

İleri beslemeli bir ağda işlemci elemanlar genellikle katmanlara ayrılmışlardır. İşaretler, girdi katmanından çıktı katmanına doğru tek yönlü bağlantılarla iletilir. İşlemci elemanlar, bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. İleri beslemeli ağlara örnek olarak çok katmanlı perseptronlar (Multilayered Perceptrons, MLP) ve öğrenme vektör nicelendirmesi ağı (Learning Vector Quantization Network, LVQ) ağları verilebilir. Bu ağlar statik ağlar olarak da bilinir (Elmas, 2003b; Öztemel, 2003; Sağiroğlu vd. 2003).

Bir geri beslemeli sinir ağı, çıktı ve ara katman çıktılarının, girdi birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girdiler hem ileri yönde hem de geri yönde aktarılmış olur. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıktı hem o andaki hem de önceki girdileri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundur. Bu ağlara örnek olarak Hopfield, Elman ve Jordan ağları verilebilir (Elmas, 2003b; Öztemel, 2003; Sağıroğlu vd. 2003).

Yapay sinir ağları gibi örneklerden öğrenen sistemlerde değişik öğrenme stratejileri kullanılmaktadır. Öğrenmeyi gerçekleştirecek olan sistem ve kullanılan öğrenme algoritması bu stratejilere bağlı olarak değişmektedir. Bu öğrenme algoritmalarının çoğunluğu matematik tabanlı olup ağırlıkların güncelleştirilmesi için kullanılır. Öğrenme işlemi çok parametrelili, karmaşık ve matematiksel olarak ifade edilmesi zor bir işlemdir. Literatürde mevcut öğrenme algoritmalarının bir çoğu Hebb, Delta, Kohonen ve Hopfield olmak üzere dört farklı öğrenme kuralından esinlenerek geliştirilmiştir. Genel olarak üç öğrenme algoritmasının uygulandığı görülmektedir

Danışmanlı öğrenme (supervised learning) stratejisinde öğrenen sistemin olayı öğrenebilmesi için bir danışman (öğretici) yardımcı olmaktadır. Danışman sisteme öğrenilmesi istenen olay ile ilgili örnekleri girdi/çıkıtı seti olarak verir. Yani her örnek için hem girdiler hem de o girdiler karşılığında oluşturulması gereken çıktılar sisteme sunulurlar. Sistemin görevi girdileri öğreticinin belirlediği çıktılara haritalamaktır. Bu sayede olayın girdileri ile çıktıları arasındaki ilişkiler öğrenilmektedir. Çok katmanlı algılayıcı ağı (Multilayer Perceptrons Network) bu stratejiyi kullanan ağlara örnek olarak verilebilir (Sağıroğlu vd., 2003). Tez kapsamında gerçekleştirilen ANN ve ANFIS çalışmalarında danışmanlı öğrenme kullanılmıştır.

Danışmansız öğrenme (unsupervised learning) stratejisinde ise sistemin öğrenmesine yardımcı olan herhangi bir öğretici yoktur. Sisteme sadece girdi değerleri gösterilir. Örneklerdeki parametreler arasındaki ilişkileri sistemin kendi kendisine öğrenmesi beklenir. Bu öğrenme algoritmalarında istenilen çıktı değerinin bilinmesine gerek yoktur. Uygulanan girdiye göre, bu girdi verileri arasındaki matematiksel ilişkilere

göre bağlantı ağırlıkları ayarlanır. Aynı özellikleri gösteren türlerde (patterns) aynı çıktılar, farklı çıktılarda ise yeni çıktılar oluşturulur. ART (Uyarlanabilir Rezonans Ağı, Adaptive Resonance Theory) SOM (Özörgütlemeli Harita Ağı, Self Organizing Map) öğrenme kuralları danışmansız öğrenmeye örnek olarak verilebilir (Sağıroğlu vd., 2003).

Takviyeli öğrenme (reinforcement learning) stratejisinde öğrenen sisteme bir öğretici yardımcı olur. Fakat öğretici her girdi seti için olması gereken (üretilmesi gereken) çıktı setini sisteme göstermek yerine sistemin kendisine gösterilen girdilere karşılık çıktısını üretmesini bekler ve üretilen çıktının doğru veya yanlış olduğunu gösteren bir sinyal üretir. Sistem öğreticiden gelen bu sinyali dikkate alarak öğrenme sürecini devam ettirir. LVQ (Öğrenme Vektör Nicelendirmesi Ağı, Learning Vector Quantization Network) bu stratejiyi kullanan sisteme örnek olarak verilebilir (Sağıroğlu vd., 2003).

Yukarıda anlatılan stratejilerden birkaçını birlikte kullanarak öğrenme gerçekleştiren ağlar da mevcuttur. Bu stratejiler karma stratejiler olarak bilinir. RBN (Radyal Tabanlı Yapay Sinir Ağları, Radyal Basis Neural Network) ve PBNN (Olasılık Tabanlı Yapay Sinir Ağları, Probabilistic Basis Neural Network) gibi ağlar örnek olarak verilebilir.

Yapay sinir ağı gibi öğrenen sistemlerde öğrenme, yukarıda anlatılan stratejilerden hangisi uygulanırsa uygulansın bazı kurallara göre gerçekleşmektedir (Sağıroğlu vd., 2003). Bu kurallar çevrimdışı öğrenme kuralları ve çevrimiçi öğrenme kuralları olmak üzere iki kısımda incelenmektedir.

Ağların çoğu için çevrimdışı çalışma modu kullanılır. Bu yaklaşımda ağ farklı bir ortamda eğitilir. Eğitim sonucu elde edilen ağırlıklar ile ağın yapısı daha sonra eş zamanlı (on-line) uygulamalarda kullanılır. Çevrimdışı öğrenme kuralına dayalı öğrenen sistemler kullanıma alınmadan önce örnekler üzerinden eğitilirler. Bu kuralları kullanan sistemler eğitildikten sonra gerçek hayatta kullanıma alındığından artık öğrenme olmamaktadır. Sistemin öğrenmesi gereken yeni bilgiler söz konusu olduğunda sistem kullanımdan çıkarılmakta ve çevrim dışı olarak yeniden

eđitilmektedir. Eđitim tamamlanınca sistem tekrar kullanıma alınmaktadır (Sađırođlu vd., 2003). Tez kapsamında gerekleřtirilen ANN ve ANFIS alıřmalarında evrimdışı renme alıřma modu kullanılmıřtır.

Bu kurallara gre renen sistemler gerek zamanda alıřırken bir taraftan fonksiyonlarını yerine getirmekte diđer taraftan ise renmeye devam etmektedir. evrimii veya gerek zamanlı renmede, sistem zerinde bir renme algoritması ve bu yapıyı destekleyen donanım ve yazılımlar mevcuttur. Bu yaklařım daha ok farklı uygulamaların yođun olarak kullanıldıđı ve retilecek sistemin devamlı farklı davranıřlar sergilediđi durumlarda kullanılır (Sađırođlu vd., 2003).

Yapay sinir ađlarının karakteristik zellikleri uygulanan ađ modeline gre deđiřmektedir. Bütün modeller iin geerli olan genel karakteristikler ařađdaki gibi sıralanabilir;

- Yapay sinir ađları makine renmesini gerekleřtirirler,
- Programları, alıřma řekli bilinen programlama yntemlerine benzememektedir,
- Bilgi saklanır,
- Yapay sinir ađları rnekleri kullanarak renirler,
- Yapay sinir ađlarının gvenle alıřtırılabilmesi iin nce eđitilmeleri ve performanslarının test edilmesi gerekmektedir,
- Grlmemiř rnekler hakkında bilgi retebilirler,
- Algılamaya ynelik olaylarda kullanılabilirler,
- řekil iliřkilendirme (rnt) ve sınıflandırma yapabilirler,
- rnt tanımlama gerekleřtirebilirler,
- Kendi kendini organize etme ve renebilme yetenekleri vardır,
- Eksik bilgi ile alıřabilmektedirler,
- Hata toleransına sahiptirler,
- Belirsiz, tam olmayan bilgileri iřleyebilmektedirler,
- Tedrici bozulma gsterirler,
- Dađınık belleđe sahiptirler,

- Sadece sayısal bilgiler ile çalışabilmektedirler.

Yapay sinir ağları klasik sistemlere göre aşağıda verilen üstünlüklere sahiptir.

- Doğrusal olmama,
- Öğrenme,
- Genelleme yapma,
- Adaptasyon,
- Veri işleme,
- Hataya ve gürültüye karşı duyarlılık ve tolerans,
- Donanım,
- Hazır paket programlar.

ANN uygulamaları temel olarak tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama ve veri filtreleme olarak sınıflandırılabilir:

- Tahmin (Prediction): Uygulanan girdi değerlerinden bazı çıktı değerleri bulunmaya çalışılır.
- Sınıflandırma (Classification): Girdi değerleri kullanılarak sınıflandırma yapılır.
- Veri ilişkilendirme (Data Association): Sınıflandırmaya benzer bir yaklaşım gibi görünse de ilave olarak hatalı olan veriyi tanımlar.
- Veri yorumlama (Data Conceptualization): Girdi verisinde mevcut gruplar arasındaki ilişkileri analiz etme işlemidir.
- Veri filtreleme (Data Filtering): Girdi sinyalleri içerisindeki uygun olmayan verilerin ayıklanmasını sağlar.

ANN'ler elektrik ve elektronik mühendisliği, sistem kontrol mühendisliği, bilgisayar mühendisliği, kimya mühendisliği, inşaat ve yapı mühendisliği, imalat ve makine mühendisliği, harita mühendisliği ve uygulamalarında problemlerin çözümünde yaygın olarak kullanılmaktadırlar (Elmas, 2003b; Öztemel, 2003; Sağiroğlu vd. 2003).



#### 2.1.3.4. Adaptif Ağ Temelli Bulanık Çıkarım Sistemi (ANFIS)

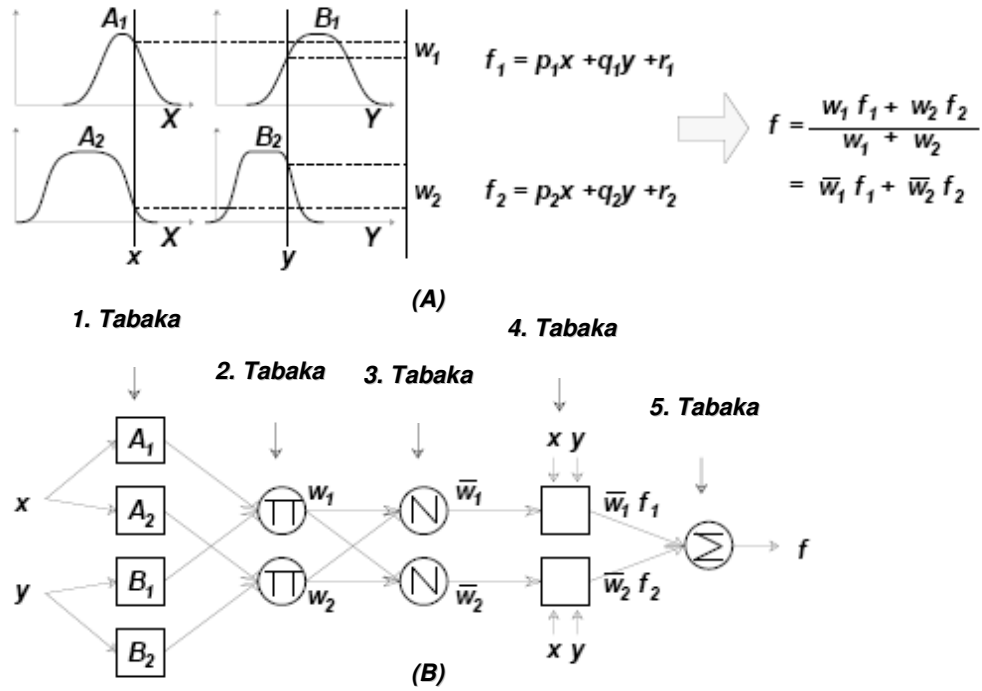
Uyarlamalı sinir ağlarının fonksiyonel olarak bulanık çıkarım sistemlerine eşdeğer olduğu hibrit yapıya ANFIS (adaptive network fuzzy inference system-adaptif ağ temelli bulanık çıkarım sistemi) adı verilmektedir. ANFIS mimarisi aynı zamanda hibrit öğrenim algoritmasının uygulandığı bir yapay zeka modelleme tekniğidir (Jang, 1993).

ANFIS modelleme tekniğinin basitleştirerek ifade edilmesi adına bulanık çıkarım sistemi  $x$  ve  $y$  olmak üzere iki girdili ve tek çıktılı ( $z$ ) olarak değerlendirilmiştir. Aynı zamanda kural tabanının aşağıda ifade edildiği gibi Takagi ve Sugeno tip iki adet eğer-ise kurallarını içerdiği kabul edilmiştir:

$$\text{Kural 1: Eğer } x, A_1 \text{ ve } y, B_1 \text{ ise } f_1 = p_1x + q_1y + r_1 \quad (2.13)$$

$$\text{Kural 2: Eğer } x, A_2 \text{ ve } y, B_2 \text{ ise } f_2 = p_2x + q_2y + r_2 \quad (2.14)$$

olarak ifade edilmektedir. Tip 3 bulanık çıkarımı ve ilgili eşdeğer ANFIS mimarisi (tip 3 ANFIS) sırasıyla Şekil 2.7(a) ve Şekil 2.7(b)'de verilmiştir.



Şekil 2.7. Tip 3 bulanık çıkarım sistemi (A) ve eşdeğer ANFIS mimarisi (B)

Aynı tabakada verilen nöron fonksiyonları aşağıda belirtildiği üzere benzer fonksiyon ailesinin üyesi olarak ifade edilmiştir.

1. Tabaka: Bu tabakadaki tüm nöronlar  $(i)$  karesel fonksiyon olarak tanımlanmıştır.

$$Q_i^1 = \mu_{A_i}(x) \quad (2.15)$$

Bu eşitlikte  $x$ ,  $i$  nöronundaki girdi,  $A_i$  ise nöron fonksiyonu ile ifade edilen dilsel (küçük, geniş vb.) tanımları içermektedir. Diğer bir deyişle  $Q_i^1$  ifadesi  $A_i$  ifadesinin üyelik fonksiyonudur. Genel olarak  $\mu_{A_i}(x)$  genelleştirilmiş bir çan fonksiyonu (2.16) olarak minimum sıfır ve maksimum bir değerini alacak şekilde ya da gauss fonksiyonu (2.17) şeklinde seçilmiştir.

$$\mu_{A_i}(x) = \frac{1}{1 + \left[ \left( \frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (2.16)$$

$$\mu_{A_i}(x) = \exp \left[ - \left( \frac{x - c_i}{a_i} \right)^2 \right] \quad (2.17)$$

Yukarıdaki eşitliklerde geçen  $a_i$ ,  $b_i$  ve  $c_i$  değerleri parametre setlerini oluşturmaktadır. Bu parametrelere ait değerlerin değişmesi ile çan fonksiyonu ya da gauss fonksiyonu değişmekte ve  $A_i$  dilsel tanımına ait üyelik fonksiyonları farklı formlar almaktadır. Bu tabakada bahsedilen parametre seti mesnet parametreleri olarak adlandırılmaktadır.

2. Tabaka: Bu tabakadaki tüm nöronlar, gelen sinyalleri çarparak diğer tabakaya ileten ve  $\pi$  sembolü ile ifade edilmiştir.

$$w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y), \quad i = 1, 2 \quad (2.18)$$

Bu tabakada çıktı olarak üretilen bütün nöronlar bir kuralın tetikleyici gücü olarak tanımlanmaktadır.

3. Tabaka: bu tabakada bütün nöronlar genel olarak N şeklinde adlandırılmıştır.  $i$  nöronunda, bu nörona ait kuralın tetikleyici gücü, diğer tüm kuralların tetikleyici güçleri toplamına bölünmektedir.

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (2.19)$$

Bu tabakanın çıktı nöronlarına normalize edilmiş tetikleyici güçler adı verilmektedir.

4. Tabaka: Bu tabakadaki tüm nöronlar ( $i$ ) karesel fonksiyon olarak tanımlanmıştır.

$$Q_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (2.20)$$

Yukarıda tanımlanan denklemde  $\bar{w}_i$ , 3. tabakanın çıktısı,  $p_i$ ,  $q_i$  ve  $r_i$  değerleri ise parametre setlerini oluşturmaktadır. Bu tabakada bahsedilen parametre seti, sonuç parametreleri olarak adlandırılmaktadır.

5. Tabaka: Bu tabakadaki tüm nöronlar, gelen bütün sinyalleri toplayarak tek bir sonuç veren  $\Sigma$  sembolü ile ifade edilmiştir.

$$Q_i^5 = \text{toplam çıktı} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (2.21)$$

Yukarıda beş tabaka ile ifade edilen ve bu çalışmada kullanılan ANFIS mimari yapısı tip 3 olarak adlandırılan bulanık çıkarım sistemine dayanmaktadır. Bu mimari dışında tip 1 ve tip 2 olarak adlandırılan ANFIS mimarileri de bulanık mantık ve yapay sinir ağlarının bir arada kullanıldığı hibrit modelleme mimarileri olarak karşımıza çıkmaktadır.

### 3. MATERYAL VE METOT

#### 3.1. Modellerin Tasarımı ve Çalıştırılması

##### 3.1.1. PCA Metodu

Temel Bileşenler Analizi (PCA) metodu, model veri matrisinin boyutsal olarak azaltılması amacıyla sık olarak kullanılan bir istatistiksel analizdir. PCA metodunun temel işlevi, veri setinin temsil edici değişkenleri, bu değişkenlere ait veri noktaları arasındaki doğrusal korelasyonu tanımlamayı ifade etmektedir. Metot, bu yöntem sonucunda “temel bileşenler” olarak adlandırılan yeni bir değişken veri seti oluşturmaktadır. Her bir temel bileşen, orijinal verilerin doğrusal kombinasyonunu ifade etmektedir. Ayrıca bütün temel bileşen eksenleri birbirine dikey (ortogonal) olarak tanımlanmakta ve bu sayede gereksiz bilgiler ayıklanmaktadır. Bu nedenle temel bileşenlere ait veriler de eksen uzayında birbirine dik olarak tanımlanmakta ve karesel matris olarak ifade edilmektedir. Bu amaçla, bir dönüştürme yaparak noktaların sahip oldukları toplam varyansın ilk eksen boyunca değişmemesi sağlanarak, birbirine dik yeni eksenler elde edilmektedir.

PCA kapsamında veriler, istatistiksel bir yazılım olan SPSS 9.0 programında bulunan faktör analiz aracı kullanılarak değerlendirilmiştir. PCA metodu ile istatistiksel değerlendirmede ilk olarak faktör analizi gerçekleştirilmiştir. Bu nedenle ilk olarak değişkenlerin korelasyon matrisi belirlenmiştir. Temel bileşenler yaklaşımı bütün değişkenlerdeki maksimum varyansı tanımlayacak faktörü hesaplamaktadır. Geriye kalan maksimum miktardaki varyansı tanımlamak için de ikinci faktör hesaplanmaktadır. Gerçekleştirilen çalışmalarda bu durum, değişkenlerdeki toplam varyans tanımlanıncaya kadar devam ettirilmiştir.

PCA analizinde ikinci adım eigenvektörleri (özvektörler) ve eigendeğerlerinin (özdeğerler) hesaplanmasıdır. Bu hesaplama,  $n \times n$  boyutlu bir vektörün  $n \times 1$  vektörü

ile çarpılması sonucu oluşan değeri sağlayan sıfırdan farklı  $x$  vektörüne eigenvektör, skaler çarpanına ise eigendeğerleri adı verilmektedir. Her bir temel bileşen için tanımlanan bu değerlerin kümülatif toplamı hesaplanan varyansın %70'lik kısmını tanımladığında, işleme son verilmiş ve değerlendirilecek temel bileşen sayısı hesaplanmıştır. Çalışma kapsamında eigendeğerlerine ait yük faktörleri grafiksel olarak değerlendirildiği için maksimum 3 temel bileşen dikkate alınmıştır.

Grafiğe geçirilen temel bileşenlerde değişkenlere ait tanımlanan yük faktörleri, birbirine olan yakınlık, uzaklık, kesişim, fiziksel ve mekanistik anlamları ile değerlendirilerek, veri matrisinin azaltılarak, temsil edici şekle dönüştürülmesi sağlamıştır.

### **3.1.2. MLR Metodu**

Çoklu Regresyon (MLR) metodu, doğrusal bir sistem ya da proses içerisindeki girdi ve çıktı parametreleri arasındaki nicel ilişkiyi kuran ve bu ilişkide hangi parametrelerin daha etkili olduğunu belirlemeye yardımcı olan çoklu bir istatistiksel analiz metodudur. MLR analizi, özellikle deneysel çalışmaların değerlendirilmesi ve ampirik model ya da modeller şeklinde ifade edilmesine imkan tanıyan bir metottur.

MLR kapsamında veriler, istatistiksel bir yazılım olan SPSS 9.0 programında bulunan regresyon analiz aracı kullanılarak değerlendirilmiştir. Çalışma kapsamında ilk olarak deneysel parametreler içerisinde tahmin edilecek hedef parametre bağımlı değişken olarak, diğer parametreler ise bağımsız değişkenler olarak tanımlanmıştır. Daha sonra model değişkenlerine ait veriler logaritmik olarak ifade edilmiş ve çoklu lineer regresyon analizine tabi tutulmuştur. Çalışmada lineer regresyon analizinde tanımlanan sabit değer, logaritmik transformasyon ile önce katsayı haline getirilmiş, daha sonra da değişkenlere ait üstel regresyon sabitleri bu katsayıya göre normalize edilmiştir. Bu nedenle ampirik matematiksel ifadelerde regresyon sabiti bulunmamaktadır.

Çoklu regresyon analizi ile ifade edilen doğrusal modellerin performansı ortalama karesel hata karekökü (RMSE), ortalama oransal hata (MAPE) ve regresyon katsayıları ( $R^2$ ) ile değerlendirilmiştir. Bunun yanında F istatistiği uygulanarak, tekli varyans analizi ile değişkenlerin serbestlik derecesi tespit edilmiştir. Ayrıca modelin regresyon analiz performansını olumsuz etkileyen collinearity (doğrudaşlık, aynı doğru üzerinde kesişme) ilişkisi de araştırılmıştır.

### 3.1.3. ANN Metodu

Yapay sinir ağları (ANN) metodu, sisteme ilişkin tek veya çoklu parametrelere bağlı olarak tanımlanan girdi verileri ile sistemin yine tek veya çoklu parametrelere bağlı olarak tanımlanabilen çıktıları arasında ilişki kurabilme yeteneğine sahip olan bir yapay zeka algoritmasıdır.

ANN modelleri genel olarak 3 bağımsız katmandan oluşmaktadır. Bunlar girdi, gizli ve çıktı katmanlarıdır. Her katman bir çok nöron içerebilmekte ve her nöron katman içerisinde belirli ve benzer bir işlem mantığı çerçevesinde hareket etmektedir. Nöronlar arasından bilgi bir takım seri işlemler ile transfer edilmektedir. ANN modellerinde girdi ve çıktı katmanları tek olmakla birlikte, model birden fazla gizli katmanından oluşabilmektedir.

Çalışma kapsamında MATLAB R14 yazılımı içerisinde bulunan Neural Network aracı kullanılmıştır ve en iyi simülasyonu gerçekleştirmek amacıyla bir çok farklı ANN mimarisi denenmiştir. Bir çok farklı yapının denenmesinin temel amacı minimum eğitim hatasını elde etmeye çalışmaktır. Her bir ANN model mimarisi ileri beslemeli geri yayımlı algoritmaya göre tasarlanmıştır. Aktivasyon (transfer) fonksiyonu olarak da “tanh” (tanjant hiperbolik) eğitim fonksiyonu seçilmiştir.

ANN model yaklaşımında proses elemanları (nöron) arasındaki bağlantılara ait ağırlık değerlerinin belirlenmesi işlemine ağırlık eğitimi adı verilmektedir. Bu aşamada ağırlık gösterilen örneğe göre ağırlık çıktıları oluşturması ve bu çıktıların

doğruluk derecesine göre ağırlıkların değiştirilmesi işlemleri gerçekleştirilmektedir. Çalışma kapsamında ANN mimarisinde bağlantı ağırlıkları ayarlanmamış, ağın kendi kendine verilen örneği öğrenmesi sağlanmıştır. Bu aşamada 100 ila 500 aralığında iterasyon adımı seçilmiştir. Eğitim aşamasında kullanılacak veri setinin büyüklüğü hakkında literatürde net bir ifade bulunmamakla birlikte, toplam verinin en az yarısının eğitim aşamasında kullanılması genel bir yaklaşım olarak kabul görmektedir. ANN modelinin hedef çıktı değişkenini iyi tahmin edebilmesi, ağın iyi eğitilmesi direkt olarak ilişkili olduğu belirtilmektedir. Bu nedenle çalışma kapsamında kullanılan eğitim veri seti, toplam veri setinin %70-%80'i arasında seçilmiştir.

Ağın eğitimi tamamlandıktan sonra performansının ölçülmesi için gerçekleştirilen işlemlere de ağın doğrulanması ya da test edilmesi adı verilmektedir. Bu aşamada ağın öğrenme aşamasında görmediği örneklerin kullanılması gerekmektedir. Aynı zamanda bu aşamada ağın bağlantı ağırlıkları değiştirilmemekte ve eğitim sırasında tespit edilen ağırlıklar kullanılmaktadır. Elde edilen sonuçlar ağın öğrenmesi hakkında da bilgi vermektedir. Ölçülen ve tahmin edilen sonuçlar birbirine ne kadar yakın olursa eğitim performansı da o kadar iyi demektir. Çalışma kapsamında kullanılan test veri seti, toplam veri setinin %20-%30'u arasından seçilmiştir.

ANN modellerinin performansları ölçülen ve tahmin edilen değerler arasındaki ilişkilerin tanımlanması ile tespit edilmiştir. Bu amaçla ortalama karesel hata (RMSE), ortalama oransal hata (MAPE) ve  $R^2$  kriterleri temel alınmıştır.

#### **3.1.4. ANFIS Metodu**

Adaptif Ağ Temelli Bulanık Çıkarım Sistemi (ANFIS) metodu uyarlamalı sinir ağlarının fonksiyonel olarak bulanık çıkarım sistemlerine eşdeğer olduğu ve hibrit öğrenim algoritmasının uygulandığı bir yapay zeka algoritmasıdır. ANFIS mimarisinin temel ve en güçlü özelliği, adaptif denetim yapısı ile kompleks doğrusal olmayan sistemleri tanımlayabilmesidir.



ANFIS algoritması, ANN yaklaşımının öğrenme gücü ile bulanık mantık yaklaşımının kural tabanlı sonuç çıkarma mekanizmalarının avantajlarını içermektedir. ANFIS algoritmasında ilk olarak daha önceden belirlenen girdi ve çıktı değişkenlerine ait veriler sınıflandırılmakta ya da bölünmektedir. Çalışma kapsamında ele alınan değişkenlere ait veriler eksiltmeli sınıflandırma (subtractive clustering) yöntemi ile sınıflandırılmıştır. Veri sınıflandırmasının en önemli avantajı, bulanık mantıktaki üyelik fonksiyonlarının ve kuralların otomatik olarak belirlenmesidir.

Atıksu atırma tesisleri gibi oldukça kompleks yapıların modellenmesinde tek başına bir bulanık mantık sisteminin kullanılması kuralların eksik tanımlanması açısından değerlendirildiğinde dezavantajdır. Çünkü otomatik olarak tespit edilmeyen kurallar, tam anlamıyla ifade edilememiş bir model mimarisinin ortaya çıkmasına neden olacaktır. Bu nedenle ANFIS algoritmasında eksiltmeli sınıflandırma yöntemi kullanılmış ve tanımlanan sınıf merkezi ve komşu sınıf sınırlarına göre bulanık mantık kural tabanı oluşturulmuştur.

ANFIS algoritması içerisinde üyelik fonksiyonları Sugeno tip bulanık çıkarım sistemi uygulayarak tespit edilmiştir. Bu aşamada hedef çıktı değişkenine ait üyelik fonksiyonu doğrusal şekilde ifade edilmiş, girdi değişkenlerine ait üyelik fonksiyonu olarak da Gauss fonksiyonu kullanılmıştır. Sugeno tip bulanık çıkarım sistemi yapısal olarak tek bir hedef çıktı değişkeninin tahmininde kullanıldığı için, bütün ANFIS modelleri tek hedef çıktı değişkeni ile ifade edilmiştir.

ANFIS algoritması MATLAB R14 yazılımı içerisinde bulunan Bulanık Mantık aracı yardımıyla çalıştırılmıştır. Seçilen model parametreleri farklı birimlere sahip olduklarından sınır değerleri *xbounds* fonksiyonu ile normalize edilmiştir. Dolayısıyla bu fonksiyon ile her bir girdi ve çıktı değişkeni için muhtemel minimum ve maksimum değerleri belirlenmiş olmaktadır.

Normalizasyon adımını prototip ANFIS yapısının elde edilmesi aşaması izlemiştir. Bu aşamada verilerin sınıflandırılması ve kuralların oluşturulması ile algoritma tarafından prototip bir bulanık çıkarım model yapısı oluşturulmaktadır. Bu yapı temel olarak alınmış ve adaptif ağ mimarisi ile eğitilerek ANFIS model sonuçları elde edilmiştir.

ANFIS model yaklaşımında da ANN model yaklaşımına benzer olarak ağ bağlantı ağırlıkları ayarlanmamış, ağın kendi kendine verilen örneği öğrenmesi sağlanmıştır. Bu aşamada 100 ila 500 aralığında iterasyon adımı seçilmiştir. Çalışma kapsamında kullanılan eğitim veri seti ise, toplam veri setinin %70-%80'i arasından seçilmiştir.

Ağın eğitimi tamamlandıktan sonra performansının ölçülmesi için gerçekleştirilen işlemlere de ağın doğrulanması ya da test edilmesi adı verilmektedir. Bu aşamada ağın öğrenme aşamasında görmediği örneklerin kullanılması gerekmektedir. Aynı zamanda bu aşamada ağın bağlantı ağırlıkları değiştirilmemekte ve eğitim sırasında tespit edilen ağırlıklar kullanılmaktadır. Elde edilen sonuçlar ağın öğrenmesi hakkında da bilgi vermektedir. Ölçülen ve tahmin edilen sonuçlar birbirine ne kadar yakın olursa eğitim performansı da o kadar iyi demektir. Çalışma kapsamında kullanılan test veri seti, toplam veri setinin %20-%30'u arasından seçilmiştir.

ANFIS modellerinin performansları ölçülen ve tahmin edilen değerler arasındaki ilişkilerin tanımlanması ile tespit edilmiştir. Bu amaçla ortalama karesel hatanın karekökü (RMSE), ortalama oransal hata (MAPE) ve korelasyon katsayısı (R) kriterleri temel alınmıştır. RMSE hata değeri ise aşağıdaki eşitlik yardımıyla hesaplanmıştır:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - y_i)^2}{N}} \quad (3.1)$$

Yukarıdaki denklemde  $x_i$  ve  $y_i$  sırasıyla ölçülen ve tahmin edilen verileri,  $N$  ise gözlenen veri sayısını ifade etmektedir.

### 3.1.5. Aktif Çamur 1 ve 3 (ASM1 ve ASM3) Modelleri

Aktif çamur modelleri (ASM) birçok stokiyometrik ve kinetik katsayıları içeren ve aktif çamur prosesini tanımlayan kompleks matematiksel ifadeler bütünüdür. ASM1 modeli aktif çamur prosesinde karbon ve azot giderim mekanizmalarını tanımlamakta, ASM3 ise ASM1 modelinden farklı olarak içsel solunum ve biyokimyasal depolamayı substratın değerlendirilmesinde temel mekanizmalar olarak geçerli kılmaktadır. ASM2 modeli ise biyolojik fosfor giderim mekanizmasını tanımlayan mekanistik bir model olmakla birlikte bu çalışma kapsamında fosfor giderimi değerlendirmeye alınmadığı için kullanılmamıştır.

Çalışma kapsamında ASM1 ve ASM3 modelleri kullanılarak, mevcut aktif çamur sisteminin modellenmesi amaçlanmıştır. ASM1 modeli 13 değişken ve 8 proses içermekte, ASM3 modeli ise 13 değişken ve 12 proses içermektedir. Her iki model için mevcut kinetik ve stokiyometrik sabitler de dikkate alındığında, oluşturulan diferansiyel denklemlerin çözülebilmesi ve sistemin uygun bir şekilde karakterize edilebilmesi için bir simülasyon yazılımına ihtiyaç duyulmaktadır. Bu amaçla çalışma kapsamında AQUASIM 2.0 yazılımı kullanılmıştır. AQUASIM 2.0 yazılımı sucül sistemlerin tanımlanması ve tasarlanması ve dinamik olarak modellenmesi aşamalarında kullanılmaktadır. Aynı zamanda yazılım model değerlendirme, hassasiyet analizi ve parametre tahmini gibi önemli alt araçları bünyesinde barındırmaktadır. Model yaklaşımında aktif çamur prosesini tanımlayan kısmi diferansiyel eşitlikler ilk olarak sonlu farklar metodu ile nümerik olarak ifade edilmekte ve matematiksel iterasyon teknikleri ile dinamik (zamana bağlı) olarak çözülmektedir (Reichert, 1998).

Çalışmada, aktif çamur sistemi tanımlanmadan önce atıksu arıtma tesisinden elde edilen ham veriler, ASM modellerinde tanımlanan formlara dönüştürülmüştür. Tesise ait ham azot ( $\text{NH}_4\text{-N}$ ,  $\text{NO}_3\text{-N}$  ve organik-N) verileri direkt olarak ASM modellerinde kullanılmış,  $\text{KOİ}$  substrat değerleri ise aşağıda belirtilen şekilde fraksiyonlarına ayrılmıştır:

$$\text{Toplam KOİ} = S_s + S_I + X_I + X_s \quad (3.2)$$

Eşitliğin sağ tarafında kalan ifadeler sırasıyla biyolojik olarak kolay ayrışabilen çözülmüş substrat ( $S_s$ ), inert çözülmüş substrat ( $S_I$ ), inert partiküler substrat ( $X_I$ ) ve biyolojik olarak yavaş ayrışabilen partiküler substrat ( $X_s$ ) olarak tanımlanmaktadır.

Toplam KOİ değerini 3.2 no'lu eşitlik yardımıyla fraksiyonlarına ayırma işleminde kabul gören bazı yaklaşımlar (Daigger ve Grady, 1995, Grady vd., 1999) bulunmakla birlikte, yaklaşımların çoğunda belirtilen metodolojilerde ölçülmesi gerekli parametrelerin mevcut tesiste ölçülmemesi nedeni ile KOİ fraksiyonları daha pratik bir yöntemle tespit edilmiştir. Bu yöntemde, Henze vd., (1987) tarafından farklı coğrafik alanlarda tanımlanan ham evsel atıksuyundaki tipik KOİ fraksiyonları oransal olarak ifade edilmiştir. Buna göre hesaplama kolaylığı açısından çalışma kapsamında ele alınan atıksu arıtma tesisi girişinde ölçülen toplam KOİ değerinin %20'si  $S_s$ , %5'i  $S_I$ , %62'si  $X_s$  ve kalan %13'lük kısım da  $X_I$  olarak tanımlanmıştır.

Ardından aerobik ve anoksik bölgeler tespit edilerek, hedef atıksu arıtma prosesini temsil edici reaktör konfigürasyonu tanımlanmıştır. Daha sonra tesis girişinde ölçülen ya da hesaplanan azot ve karbon fraksiyonları ile aktif çamur prosesine ait kinetik parametrelerinin tipik değerleri ve bulunabilecekleri değer aralıkları modele girdi olarak verilmiştir. Bu aşamadan sonra ASM1 ve ASM3 modelleri için hassasiyet analizleri ve kinetik parametre tahminleri ve doğrulama gerçekleştirilmiştir.

ASM1 ve ASM3 modellerine ait veri yapısı oluşturulurken, karşılaştırma yapılabilmesi amacıyla ANFIS model yaklaşımında kullanılan veri sayısı ASM modellerinde de aynen kullanılmıştır. Dolayısıyla AQUASIM 2.0 yazılımında karbon ve azot fraksiyonları gerçek liste değişkenleri (real list variables) olarak adlandırılmış ve modelde değerler günlük olarak tanımlanmıştır. Modelin simülasyon süresi de tanımlanan gün süresince gerçekleştirilmiştir.

### 3.1.5.1. Hassasiyet Analizleri

Hassasiyet analizleri model parametrelerinin tanımlanması ve hangi parametrenin proses içerisinde daha etkili olduğunun belirlenmesi aşamasında kullanılmaktadır. Bu amaçla AQUASIM 2.0 yazılımı içerisindeki hassasiyet analizi aracı kullanılmıştır. Bu yazılım, model içerisinde tanımlanan her parametre için doğrusal hassasiyet analizi gerçekleştirebilmektedir. Yazılım dört farklı hassasiyet fonksiyonu barındırmaktadır. Eğer  $y$ , AQUASIM 2.0 tarafından hesaplanan rastgele bir parametre ve  $p$ , bir model parametresi ise, bahsedilen dört hassasiyet fonksiyonu aşağıdaki gibi tanımlanabilmektedir:

- 1) Mutlak-Mutlak Fonksiyonu, 3.3 no'lu eşitlik ile ifade edilmekte olup, birim  $p$  değişiminde  $y$ 'nin mutlak değişimini hesaplamaktadır.

$$\delta_{y,p}^{a,a} = \frac{\partial y}{\partial p} \quad (3.3)$$

- 2) Göreceli-Mutlak Fonksiyon, eşitliği 3.4 no'lu eşitlik ile ifade edilmekte ve birim  $p$  değişiminde  $y$  değerinin göreceli değişimini tanımlamaktadır.

$$\delta_{y,p}^{r,a} = \frac{\frac{\partial y}{\partial p}}{y} \quad (3.4)$$

- 3) Mutlak-Göreceli Fonksiyon, 3.5 no'lu eşitlik ile ifade edilmekte olup,  $p$  değerinin %100 değişimine karşılık  $y$  değerinin mutlak değişimini hesaplamaktadır.

$$\delta_{y,p}^{a,r} = p \frac{\partial y}{\partial p} \quad (3.5)$$

- 4) Göreceli-Göreceli Fonksiyon ise 3.6 no'lu eşitlik ile ifade edilmekte ve p değerinin %100 değişimine karşılık y değerinin göreceli değişimini hesaplamaktadır.

$$\delta_{y,p}^{r,r} = \frac{p \frac{\partial y}{\partial p}}{y} \quad (3.6)$$

Çalışma kapsamında göreceli-göreceli hassasiyet fonksiyonu kullanılmıştır. Bunun en önemli nedeni boyutsuz olmasıdır. Böylece birbirinden farklı model değişkenlerinin genel bir ifade üzerindeki etkileri daha iyi anlaşılabilir. ASM1 ve ASM3 modellerinde gerçekleştirilen hassasiyet analizleri sonucu, çalışma kapsamında ele alınan aktif çamur prosesinde tespit edilen en etkili ve önemli kinetik parametreler daha sonraki adımda tahmin edilmişlerdir.

### 3.1.5.2. Parametre Tahmini

Bir aktif çamur prosesinde kinetik katsayılar; atıksu kompozisyonuna, reaktör tasarımına, biyolojik çeşitliliğe, pH ve çözülmüş oksijen gibi birçok fiziksel ve biyokimyasal faktöre bağlı olarak değişiklik gösterebilmektedir. Dolayısıyla çalışma kapsamında tipik olarak tanımlanan kinetik parametrelerin, hedef atıksu arıtma prosesine göre tekrar düzenlenmesi gerekmektedir.

AQUASIM 2.0 yazılımı, ASM modeli içerisinde sabit olarak tanımlanan kinetik parametreleri tahmin edebilmektedir. Yazılım, ölçülen (tipik kinetik değerler) ve model tarafından hesaplanan sabit değerler arasındaki ağırlıklı türevlerin karesel toplamını ( $X^2$ ) minimize etmeye çalışmaktadır. Bahsedilen karesel toplam ki-kare (chi-square) olarak tanımlanmakta ve aşağıdaki şekilde ifade edilmektedir:

$$X^2 = \frac{\sum (\hat{y}_i - y_i)^2}{\sigma^2} \quad (3.7)$$

Bu eşitlikte  $\sigma$ , veriye ait standart sapmayı,  $\hat{y}_i$ , model parametrelerine [ $p=(p_1, p_2, \dots, p_m)$ ] ait bir fonksiyonu ifade etmektedir. ASM modellerinde (ASM1 ve ASM3), ki-kare ifadeleri nümerik olarak minimize edilmiştir. Bu aşamada  $p_{i,\min} \leq p_i \leq p_{i,\max}$  şartı temel olarak kullanılmıştır.

### 3.1.5.3. Kalibrasyon

Çalışma kapsamında sabit kinetik parametrelerin tahmin edilmesini takiben ASM modellerinin kalibrasyonu gerçekleştirilmiştir. Bu aşamada ANFIS modeli ile karşılaştırma yapabilmek için toplam veri setinin %70'i kalibrasyon için ayrılmıştır. Bu aşamada, parametre tahmini ile değiştirilen kinetik ifadeler kalibrasyonun kilit noktasını oluşturmuştur. Çünkü artık kinetik ifadeler, atıksu arıtma tesisindeki tanımlanan temsil edici aktif çamur sistemine göre tahmin edilmiştir. AQUASIM 2.0 yazılımı daha önceden tespit edilen simülasyon zamanına (%70'lik veri sayısına eşdeğer gün) göre çalıştırılmıştır.

### 3.1.5.4. Doğrulama

Kalibrasyon aşamasını takiben, toplam veri setinin %30'luk kısmıyla modelin doğrulama (test) işlemi gerçekleştirilmiştir. Bu işlemin kalibrasyon aşamasından tek farkı simülasyon zamanının değişmesidir. Bu nedenle model simülasyon zamanı %30'luk veri sayısına eşdeğer güne göre çalıştırılmıştır.

## 4. BULGULAR

Tez kapsamında gerçekleştirilen çalışmaların bulguları toplam 5 bölüm altında toplanmıştır. Her bölümde kısaca çalışmanın teorik altyapısı ve amacı tanımlanarak, elde edilen bulgular değerlendirilmiştir.

### 4.1. İçme Suyu Arıtımında Ozonlama Sonucu Bromat Oluşumunun Çoklu Regresyon Analizi ve Yapay Sinir Ağları ile Modellenmesi

İçme sularının dezenfeksiyonunda uygulanan en etkin yöntemlerden bir tanesi ozonlamadır. Ozon; bakteriler, virüsler ve protozoalar dahil çok geniş bir yelpazedeki patojenlere karşı etkili bir dezenfektan olsa da, sulardaki çeşitli maddelerle (doğal organik maddeler, bromür iyonu, vs) kimyasal reaksiyonları sonucu toksik veya karsinojen özellikte dezenfeksiyon yan ürünleri (DYÜ) oluşturabilmektedir (Glaze vd., 1993; Siddiqui ve Amy, 1993; von Gunten ve Hoigne, 1994; USEPA, 1999).

Bromat ( $\text{BrO}_3^-$ ) iyonu, sulardaki bromür ( $\text{Br}^-$ ) iyonunun moleküler ozon ( $\text{O}_3$ ) ile kompleks reaksiyonları sonucu oluşmaktadır. Bu kompleks reaksiyon mekanizmalarında hipobromik asit, bromlu organikler ve bromaminler gibi diğer yan ürünler de meydana gelebilmektedir (von Gunten ve Oliveras, 1998; Westerhoff vd., 1998a; USEPA, 1999; Kim vd., 2004). Ozonlama sonucu oluşan DYÜ'lerden insan sağlığı açısından en önemlilerinden bir tanesi bromat iyonudur (Glaze vd., 1993; Amy vd., 1994; Ozekin vd., 1998; von Gunten, 2003). Bazı hayvanlar üzerinde yapılan deneyler sonucu bromat iyonunun gen yapısında farklılaşmalara neden olduğu ve bu yüzden insanlar üzerinde potansiyel genotoksik ve karsinojen etkilerinin bulunması ihtimali göz önüne alınarak, Amerikan Çevre Koruma Teşkilatı (USEPA) ve Avrupa Birliği (EC) tarafından içme suyundaki maksimum bromat kirliliği konsantrasyonu (MCL)  $10 \mu\text{g/L}$  olarak belirlenmiştir (Kurokawa vd., 1990; USEPA, 1999; McDorman vd., 2005).



Bromat ve diğler bromürlü DYÜ oluşumlarına etkisi olan temel parametreler öncelikle ham sudaki bromür konsantrasyonu, doğal organik madde miktar ve türleri (toplam organik karbon-TOK cinsinden), ozon/bromür ve TOK/bromür oranları, uygulanan ozon dozu ve ozon temas süresi, amonyak konsantrasyonu, pH ve alkalinitedir (Symons vd., 1987; Glaze vd., 1993; Krasner vd., 1993; Pinkernell ve von Gunten, 2001; von Gunten, 2003; Koscielna, 2004; Legube vd., 2004).

Ozonlanmış sularda oluşan bromatın tahminine yönelik bazı kinetik, mekanistik veya ampirik modeller geliştirilmiştir (Song vd., 1996a,b; Grguric ve Coston, 1998; Westerhoff vd., 1998b; Pinkernell ve von Gunten; 2001; Hassan vd., 2003; Legube vd., 2004; Sadiq ve Rodriguez, 2004a,b; Sohn vd., 2004). Çizelge 4.1'den de görüleceğı üzere geliştirilen birçok model, içerdiği değışkenlerin logaritmik transformasyon ile tanımlandığı çoklu regresyon analizleri ile ifade edilmiştir. Bunun yanında çoklu regresyon analizleri ile birinci ve ikinci dereceden kinetik katsayıların tahmin edildiğı modeller de mevcuttur (Sadiq ve Rodriguez, 2004a). Ham sudaki birçok su kalite parametresinin birbirleri ile olan kompleks etkileşimi bu tür modellerin etkinliğinin büyük farklılıklar göstermesine neden olmaktadır. Çünkü sudaki farklı etkileşimler bromat oluşumundaki kompleks reaksiyon zincirini etkilemektedir. Bu nedenle içme suyu arıtımında bromat oluşumunun etkili olarak tahmin edilmesi oldukça güçtür.

Yapay Sinir Ağları (ANN) metodu son yıllarda çevresel araştırma ve uygulamalarda özellikle su ve hava kalitesi izleme ve kontrolüne yönelik olarak sıkça kullanılmaya başlanmıştır (Baxter vd., 1999; Choi ve Park, 2001; Legube vd., 2004; Perendeci vd., 2004; Çinar, 2005). ANN, aynı zamanda bromat oluşumunun modellenmesinde de çoklu regresyon analizi ile birlikte kullanılmış ve bu metot ile karşılaştırıldığında oldukça iyi sonuçlar verdiği gözlemiştir (Legube vd., 2004). ANN metodu herhangi bir kompleks matamatiksel formülasyon ya da algoritmaya gerek duymadan kavramları, geçmiş veriler içerisinde elde edebilmesi bu metodun diğler metotlara göre avantajıdır (Jain vd., 1996).

Çizelge 4.1. Literatürde geliştirilen Bromat ( $\text{BrO}_3^-$ ) modelleri

Kaynak	Veri kaynağı	N	R <sup>2</sup>	Birim	Bromat oluşum modelleri	
Ozekin, 1994	Laboratuvar	303	0.73	$\mu\text{g/L}$	$1.55 \cdot 10^{-6} (\text{ÇOK})^{-1.26} (\text{pH})^{5.82} (\text{O}_3)^{1.57} (\text{Br}^-)^{0.73} (t)^{0.28}$	
Ozekin vd., 1998					20°C'den farklı sıcaklıklar için bromat konsantrasyonu aşağıdaki eşitlikle bulunabilir $[\text{BrO}_3^-] = [\text{BrO}_3^-]_{20\text{C}} (1.035)^{T-20}$	
Siddiqui vd., 1994	Laboratuvar	54	0.88	$\mu\text{g/L}$	$1.5 \cdot 10^{-3} (\text{ÇOK})^{-0.74} (\text{pH})^{-2.26} (\text{O}_3)^{0.64} (\text{Br}^-)^{0.61} (\theta)^{2.03}$	
		22	0.64			$1.5 (\text{ÇOK})^{-0.75} (\text{pH})^{-2.25} (\pi+1)^{1.31} (\text{Br}^-)^{0.60}$
		173	0.68			$0.26 (\text{ÇOK})^{0.86} (\text{pH})^{3.27} (\text{ÇO}_3)^{0.22} (\text{Br}^-)^{0.67} (t+1)^{0.25}$ (0<t<1 sa)
Song vd., 1996a,b	Arazi	119-239	0.87-0.97	$\mu\text{g/L}$	Bromür, ÇOK, amonyak, ozon dozu, inorganik karbon ve temas süresinin fonksiyonu olan bromatın tahmini için 13 farklı lineer regresyon modeli (her bir su kaynağı için)	
Hassan vd., 2003	von Gunten ve Oliveras (1998) ve Song vd., (1996a,b)	NR	0.77-0.99	$\mu\text{mol/L}$	Bromat oluşumu için TFG modelindeki ara ürünlerdeki 72 adet ozon ayrışma, •OH tüketimi ve Br <sup>-</sup> oksidasyon reaksiyon katsayıları	
Legube vd., 2004	Laboratuvar	204	0.93-0.99	$\mu\text{g/L}$	Bromür, ÇOK, amonyak, alkalinite, pH, sıcaklık ve Cl <sup>-</sup> 'nin fonksiyonu olan bromatın tahmini için 4 farklı çoklu lineer regresyon modeli (her bir su kaynağı için 3 tane, tüm sular için 1 tane)	
		184	0.98 (bütün numunelerde)	$\mu\text{g/L}$	Aynı değişkenlerle 4 farklı ANN modeli (her bir su kaynağı için 3 tane, tüm sular için 1 tane)	
Tyrovola ve Diamadopoulos, 2005	Laboratuvar	65	0.67-0.95	$\mu\text{g/L}$	Bromür, pH, iletkenlik, ozon dozu ve ozon temas süresinin fonksiyonu olan bromatın tahmini için 7 farklı çoklu regresyon modeli (her bir su kaynağı için 3 tane, tüm sular için 1 tane)	

Mevcut çalışma (Doktora çalışması, Bulgular 4.1)	Tyrovola, 2001	65	0.84	μg/L	$(\text{NH}_3\text{-N})^{-0.15} \cdot (\text{ÇOK})^{-0.26} \cdot (\text{Alk})^{0.45} \cdot \text{pH}^{-0.44} \cdot (\text{Cl}^-)^{-0.14} \cdot (\text{O}_3)^{0.63} \cdot t^{0.54}$
		65	0.84		$(\text{NH}_3\text{-N})^{-0.14} \cdot (\text{ÇOK})^{-0.22} \cdot (\text{Alk})^{0.42} \cdot \text{pH}^{-0.30} \cdot (\text{O}_3)^{0.63} \cdot t^{0.54}$
		65	0.15		$(\text{Br}^-)^{-1.74} \cdot (\text{bulanıklık})^{-0.31} \cdot (\text{ilet})^{2.11}$
		65	0.12		$(\text{Br}^-)^{0.78} \cdot (\text{Cl}^-)^{0.75} \cdot (\text{ilet})^{-1.19}$
		65	0.77		$(\text{Br}^-)^{0.47} \cdot (\text{O}_3)^{0.62} \cdot t^{0.51}$
		65	0.76		$(\text{ilet})^{0.46} \cdot (\text{O}_3)^{0.62} \cdot t^{0.50}$
		65	0.96-0.97		Bromür, klorür, ÇOK, amonyak, alkalinite, pH, iletkenlik, bulanıklık, ozon dozu ve ozon temas süresinin fonksiyonu olan bromatın tahmini için 2 farklı ANN modeli (tüm sular için)

N=Veri sayısı, ÇOK=çözünmüş organik karbon (mg/L); O<sub>3</sub>=uygulanan ozon dozu (mg/L); pH=ozonlamadaki pH değeri; Br<sup>-</sup>=bromür iyonu konsantrasyonu (mg/L); t=temas süresi (dk); ÇO<sub>3</sub>=çözünmüş ozon konsantrasyonu (mg/L); Alk=alkalinite (mg/L); ilet=iletkenlik (μS/cm); π=perokson oranı (H<sub>2</sub>O<sub>2</sub>/O<sub>3</sub>); ve θ=ozonlama sıcaklığı (°C), Ct=Ozona maruz kalma süresi (mg/L.dk)

Yeraltı suları, özellikle tatlı su kaynaklarının kısıtlı olduğu ada benzeri coğrafyalarda temel içme ve kullanma kaynağı olarak göze çarpmaktadır. Özellikle turistik adalarda, yaz aylarında baş gösteren yüksek su ihtiyacını karşılamak için deniz kıyısına yakın bölgelerdeki kuyulardan yüksek miktarda tatlı su çekilmektedir. Bu durum, deniz suyunun tatlı su kaynaklarına girişim yapmasına neden olmakta ve böylece tatlı su içerisindeki bromür konsantrasyonu da artış göstermektedir. Ticari şişe suyu üretim tesislerinde, suda tat bırakmadığı ve güçlü bir dezenfektan olduğu için ozonla dezenfeksiyon metodu tercih edilmektedir. Fakat yukarıda belirtilen bromür konsantrasyonundaki artış nedeni ile yeraltı kuyularından elde ettikleri suyu ozonla dezenfeksiyon işlemine tabi tutan şişe suyu üreticileri büyük problemlerle karşı karşıya kalmaktadır. Çünkü çekilen tatlı sulara deniz suyu girişi olduğu ve deniz suyu içerisinde de yüksek miktarda bromür bulunmasından ötürü, ozonlama işlemi sonucu yüksek konsantrasyonlarda bromat oluşmaktadır (Mitrakas ve Simeonidis, 2003; Tyrovola ve Diamadopoulos, 2005). Bununla birlikte bromatın ölçümü pahalı ve özel analitik yöntemler gerektirmesinden dolayı, küçük çaplı su şirketleri bromat oluşumunun izlenmesi ve kontrolünde büyük zorluklar yaşamaktadır.

Tezin birinci bölümünün temel amacı çabuk ve pratik olarak ölçülebilen ham su kalite değişkenleri veya işletme parametreleri ile oluşturulacak modeller ile ozonla dezenfekte edilmiş şişe sularında bromat konsantrasyonunun belirlenmesidir. Bu kapsamda çoklu regresyon analizi ve yapay sinir ağları kullanılmıştır. Çalışmada temel bileşenler analizi ile model girdi parametrelerinin azaltılmasına çalışılmıştır.

Bromat oluşumu için gerçekleştirilen modelleme çalışmasında kullanılan veriler Tyrovola (2001)'den alınmıştır. Kaynak çalışmada, Girit adasının kuzey batısında yer alan beş yeraltı suyu kuyusundan alınan numuneler laboratuvar ortamında, yarı sürekli bir reaktörde, oda sıcaklığında (20-23 °C), farklı temas sürelerinde (0, 2, 5, 10, 15, 30, 60 dk), farklı ozon dozlarına (0.5, 2, 3, 3.5 mg/L) maruz bırakılmıştır. Daha sonra oluşan bromat analiz edilmiştir. Çalışmada ozonlama sırasında hiçbir pH tampon çözeltisi kullanılmamıştır. Tüm su numunelerinde uygulanan ozon dozu ve

temas süresi sırasıyla 0.5-3.5 mg/L ile 0-60 dk arasında değişmektedir. Su numunelerinin fizikokimyasal karakteristikleri Çizelge 4.2’de özetlenmiştir.

Çizelge 4.2. Yeraltısu numunelerinin fizikokimyasal karakteristikleri ve ozonlama koşulları (Tyrovola, 2001).

Model		1 <sup>a</sup>	2	3	4	5
Değişken No.	Yeraltı suyu No.					
X1	NH <sub>3</sub> -N (mg/L)	MKL <sup>b</sup>	MKL	0.019	0.016	MKL
X2	ÇOK (mg/L)	0.60	1.40	0.50	0.68	0.54
X3	Alkalinite (mg/L)	122	117	115	246	135
X4	Bulanıklık (NTU)	0.15	0.60	0.23	0.06	0.16
X5	İletkenlik (µS/cm)	334	1280	1950	3940	3800
X6	pH	8.07	7.10	7.24	7.17	7.13
X7	Br <sup>-</sup> (µg/L)	161	598	1472	3844	4084
X8	Cl <sup>-</sup> (mg/L)	16	253	463	1047	1170
X9	Ozon dozu (mg/L)		0.5, 2, 3, 3.5			
X10	Temas süresi (dk)		0, 2, 5, 10, 15, 30, 60			
Y	BrO <sub>3</sub> <sup>-</sup> (µg/L)	25.18	45.45	83.95	216.63	241.50

<sup>a</sup> Farklı ozon dozları ve temas sürelerinde her bir numune için 13 analiz gerçekleştirilmiştir (toplam veri sayısı=13 analiz\*5 numune=65) ve bütün değerler analitik ölçümlerin ortalaması olarak ifade edilmiştir.

<sup>b</sup> Minimum kantifikasyon limitinin (MKL) altında (<0.01 mg/L)

Çizelge 4.2’den de görüleceği üzere 2 ve 3 numaralı yeraltı suyu numuneleri, deniz suyu girişiminden mevsimlik olarak etkilenen kireçtaşı akiferini temsil etmektedir. 4 ve 5 numaralı numuneler ise deniz suyu girişiminden yıl boyunca etkilenen yeraltı suyu kaynağını temsil etmektedir. Tüm yeraltı suyu kaynakları, tipik tatlı su kaynakları ile karşılaştırıldıklarında, orta dereceden, çok yüksek derecelere (3, 4 ve 5 numaralı kaynaklar) kadar bromür konsantrasyonu içermektedir. İletkenlik ölçümleri baz alındığında 1 numaralı kaynak dışındaki yeraltı suyu numuneleri hafif tuzlu su olarak nitelendirilebilir. Çizelge 4.2’den de açıkça görüleceği üzere deniz suyu girişiminin etkisi 1 no’lu kaynaktan 5 no’lu kaynağa doğru artmaktadır. Çözünmüş

organik karbon (ÇOK) ölçümleri, çalışılan yeraltı sularının organik madde içeriği açısından tipik korunan yeraltı suyu grubuna girdiğini göstermektedir. Benzer olarak tüm yeraltı suyu kaynaklarında çok düşük amonyak konsantrasyonları ölçülmüştür. Detaylı deneysel çalışmalar ve analitik ölçümler Tyrovola (2001) ve Tyrovola ve Diamadopoulos (2005) çalışmalarında bulunabilir. Laboratuvar çalışmaları ile elde edilen tüm su kalitesi, ozonlama ve bromat konsantrasyon verileri, MATLAB R14 yazılımı içerisinde bulunan ANN ve istatistiksel araçlar ile modellenmiştir. PCA ve MLR kapsamında ise veriler, istatistiksel bir yazılım olan SPSS 9.0 programında bulunan faktör analiz aracı ve regresyon analiz aracı kullanılarak değerlendirilmiştir.

Bu çalışmada en iyi benzetimi gerçekleştirmek için bir çok ANN mimarisi denenmiştir. Modellerin eğitilmesi aşamasında 100 ila 500 arasında iterasyon adımı kullanılmıştır. ANN yapısı ileri beslemeli geri yayımlı algoritma ile tanjant hiperbolik (tanh) eğitim aktivasyon (transfer) fonksiyonuna göre tasarlanmıştır. İki farklı ve birbirinden bağımsız modelleme çalışmasında farklı ozon dozunda ve temas süresinde ölçülen bromat konsantrasyonlarını içeren 65 deneysel veri kullanılmıştır. ANN model eğitim aşamasında veri setinin yaklaşık %75'i (49) kullanılmıştır. Eğitilen sinir ağının test edilmesi aşamasında ise veri setinin kalan yaklaşık %25'lik (16) kısmı kullanılmıştır. ANN eğitim ve test aşamasında kullanılan veriler rastgele olarak seçilmiştir.

MLR ve ANN modellerinin performansı, ölçülen ve tahmin edilen veriler arasındaki ortalama karesel hata karekökü (RMSE), ortalama oransal hata (MAPE) ve regresyon katsayısı ( $R^2$ ) ile değerlendirilmiştir. Çalışmada  $R^2$  katsayısı, literatür sonuçları (Çizelge 4.1) ile karşılaştırma yapabilmek amacıyla kullanılmıştır. Regresyon katsayıları, lineer regresyon analizi ile, RMSE ve MAPE değerleri ise aşağıdaki eşitlikler yardımıyla belirlenmiştir:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - y_i)^2}{N}} \quad (4.1)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|x_i - y_i|}{x_i} \cdot 100\% \quad (4.2)$$

Denklemden  $x_i$  ve  $y_i$ , sırasıyla ölçülen ve tahmin edilen verileri,  $N$  ise toplam veri sayısını ifade etmektedir.

Bromat oluşumunu tanımlamak için toplam 6 adet ampirik MLR modeli kurulmuştur. MLR modellerinde, 5 su kaynağına ait bütün deneysel veriler kullanılmıştır. Her yeraltı suyu kaynağı için, farklı ozon dozu ve temas süresinde uygulanan ozonla dezenfeksiyon işlemi sonunda bromat konsantrasyonları ölçülmüştür. Ayrıca bu iki deneysel değişkenin yanında, ÇOK, NH<sub>3</sub>-N, alkalinite, bromür, klorür, pH, bulanıklık ve iletkenlik gibi ham su kalite parametreleri de MLR modellerinde bağımsız değişken olarak değerlendirilmiştir. Her bir yeraltı suyu kaynağından tek defada örnekleme gerçekleştirildiği için ham su kalite parametrelerine ait regresyon katsayısı sıfırdır. Bu yüzden MLR analizi, her kaynak için ayrı değil, tüm kaynaklara ait verilerin bir araya getirilmesi ile gerçekleştirilmiştir. Her bir yeraltı suyu kaynağı için gerçekleştirilen MLR modelleri daha önceki yayınlarda bulunmaktadır (Tyrovolas ve Diamadopoulos, 2005).

MLR modellerinin regresyon katsayıları ve ortalama karesel hataya bağlı performansları Çizelge 4.3'de verilmiştir. İlk MLR modelinde ham su kalite parametreleri (NH<sub>3</sub>-N, ÇOK, alkalinite, bulanıklık, iletkenlik, pH, Br<sup>-</sup>, Cl<sup>-</sup>) ve deney değişkenleri (uygulanan ozon dozu ve temas süresi) ele alınmıştır. İfade edilen değişkenlere ait korelasyon matrisi Çizelge 4.4'de verilmiştir. Tüm model değişkenleri, regresyon katsayılarının belirlenmesi için logaritmik forma dönüştürülmüştür. Song vd. (1996a,b) bromat oluşumunu, bağımsız değişkenler olarak adlandırılan su karakteristikleri ve işletme parametrelerinin güç fonksiyonu olarak aşağıdaki şekilde ifade etmiştir.

$$[BrO_3^-] = e^{b_0} [Br^-]^{b_1} [ÇOK]^{b_2} [NH_3 - N]^{b_3} [doz]^{b_4} pH^{b_5} [alkalinite]^{b_6} (süre)^{b_7} \quad (4.3)$$

Denkleimde ÇOK, NH<sub>3</sub>-N ve uygulanan ozon dozu mg/L; başlangıç bromür konsantrasyonu µg/L; alkalinite mg/L CaCO<sub>3</sub>; ozon temas süresi ise dk birimindedir. *b0-b7* ampirik regresyon katsayılarını ifade etmektedir. Bu çalışmada tüm değişkenlere ait regresyon katsayıları  $e^{b0}$  a göre standardize edilmiştir. Bu yüzden MLR denklemlerinde bu sabit ifade yer almamaktadır.

İlk olarak, ölçülen bütün parametreler (Çizelge 4.2) kullanılarak bromat oluşumu MLR analizi ile tahmin edilmeye çalışılmıştır. Bulanıklık, iletkenlik ve bromür değişkenleri %95'lik güven aralığı ve F ihtimal istatistik değerinin (P>0.05) dışında kaldığı için hesap algoritması tarafından model#1'den çıkartılmıştır.

Çizelge 4.3'den de görüleceği üzere ilk MLR modelinin bromat oluşumunu oldukça iyi tanımladığı gözlenmektedir ( $R^2=0.84$ ). İlk MLR modeli uygulanan ozon dozu, temas süresi ve alkalinite değişkenlerine ait regresyon katsayılarının pozitif değer almasından ötürü kimyasal olarak da tutarlılık göstermektedir. Bu da adı geçen değişkenlerin değeri arttıkça, bromat oluşumunun da artacağını ifade etmektedir. Benzer olarak ÇOK ve amonyak konsantrasyonlarına ait negatif regresyon katsayıları da ilk MLR modelinin kimyasal olarak tutarlı olduğunu göstermektedir. Çünkü bromür iyonu içeren suda amonyum bulunması ve bu durumda ozonlama işleminin yapılması ile bromaminler oluşmakta ve bu durum da bromat ve organik yan ürün oluşumunu azaltmaktadır (USEPA, 1999). Ayrıca, artan ÇOK değerleri de diğer organik yan ürünlerin daha fazla oluşmasından dolayı bromat konsantrasyonunda düşüşe neden olmaktadır. Bununla birlikte ilk MLR modelinde pH değişkenine ait regresyon sabiti kimyasal olarak zıtlık oluşturmaktadır. Çünkü ozonla dezenfeksiyon esnasında bromat oluşumu, asidik pH larda kontrol edilebilmektedir. Düşük pH larda hipobromür iyonu oluşmamakta, hipobromik asit baskın hale geçmektedir. Alkali pH şartlarında ise ozon, hipobromür iyonunu oksitleyerek direkt reaksiyonlarla bromat iyonu oluşumuna neden olmaktadır (Krasner vd., 1993; Siddiqui ve Amy, 1993; USEPA, 1999). Ayrıca, alkali pH koşullarında ozonun ayrışması hidroksil radikallerin (OH) oluşmasına ve dolaylı radikal reaksiyonlarla bromat oluşumuna sebebiyet vermektedir. MLR#1 modeli, pH ve bromat arasındaki negatif korelasyonun kimyasal olarak doğru olmamasına rağmen, genel olarak bromat



oluşumunu yeterli derecede tahmin edebilmiştir. Bu noktada, MLR#1 modelinde 10 girdi parametresinin değerlendirildiği, dolayısıyla da girdi ve çıktı değişkenleri arasındaki kompleks ilişkinin artması sonucu bu tür sonuçlar elde edilebileceği konusuna dikkat edilmelidir. Benzer gözlemler literatürde de belirtilmiştir (Siddiqui vd., 1994; Legube vd., 2004).

Çizelge 4.3. MLR modelleri ve performans değerleri

MLR Model No.	Eşitlik	RMSE (µg/L)	MAPE (%)	R <sup>2</sup>
1	$[BrO_3^-] = [NH_3 - N]^{-0.15} \cdot [ÇOK]^{-0.26} \cdot [alkalinite]^{0.45} \cdot pH^{-0.44} \cdot [Cl^-]^{-0.14} \cdot [doz]^{0.63} \cdot (süre)^{0.54}$	9.12	19.14	0.84
2	$[BrO_3^-] = [NH_3 - N]^{-0.14} \cdot [ÇOK]^{-0.22} \cdot [alkalinite]^{0.42} \cdot pH^{-0.30} \cdot [doz]^{0.63} \cdot (süre)^{0.54}$	9.11	19.13	0.84
3	$[BrO_3^-] = [Br^-]_0^{-1.74} \cdot [bulaniklik]^{-0.31} \cdot [iletkenlik]^{2.11}$	13.12	49.12	0.15
4	$[BrO_3^-] = [Br^-]_0^{0.78} \cdot [Cl^-]^{0.75} \cdot [iletkenlik]^{-1.19}$	13.23	49.14	0.12
5 (PCA sonrası)	$[BrO_3^-] = [Br^-]_0^{0.47} \cdot [doz]^{0.62} \cdot (süre)^{0.51}$	10.88	22.99	0.77
6 (PCA sonrası)	$[BrO_3^-] = [iletkenlik]^{0.46} \cdot [doz]^{0.62} \cdot (süre)^{0.50}$	10.94	23.68	0.76

Amonyak, ÇOK, alkalinite, klor ve uygulanan ozon dozu: mg/L; temas süresi: dk.; iletkenlik: µS/cm; bulanıklık (NTU); başlangıç bromür ve bromat konsantrasyonları: µg/L.

MLR hesap algoritması içerisindeki varyans etki faktörü (VIF) analizi sonucu iletkenlik, bromür ve klorür konsantrasyonları arasında çok güçlü bir korelasyon bulunduğu gözlenmiştir (Çizelge 4.4). Gerek bu nedenle gerekse bromat oluşumunu başlangıç bromür konsantrasyonu tetiklediği için MLR model#2’de klorür değişkeni yerine bromür değişkeni kullanılmıştır. Fakat her ne kadar başlangıç bromür konsantrasyonu bromat oluşumunda kritik olarak rol oynasa da MLR yaklaşımındaki F istatistiği olasılık değeri baz alınarak ( $P>0.05$ ), bromür değişkeni algoritma tarafından modelden çıkartılmıştır. İkinci eşitlikte bromür değişkeninin bulunmama nedeni budur. Ayrıca ikinci MLR modeli eşitliği ve sonuçlarının ilk MLR modeli ile benzerlik gösterdiği dikkat çekmektedir.

MLR#2 sonrası iki model yaklaşımı (model#3 ve model#4) model#1 ve model#2 deki analiz problemlerin çıkış nedenlerini nicelik olarak ifade etmeye yöneliktir. Bu amaçla sırasıyla, model#3’de, model#1’de çıkartılan değişkenlerin (bromür, bulanıklık ve iletkenlik) ve model#4’de de birbirileri arasında çok güçlü korelasyon bulunan bromür, klorür ve iletkenlik değişkenlerinin (Çizelge 4.4) MLR model performansına olan etkileri araştırılmıştır. Çizelge 4.3’den de görüleceği üzere MLR#3 modelinin performansı oldukça düşüktür ( $R^2=0.15$ ). Bunun nedeni farklı karakteristikleri tanımlamalarına rağmen başlangıç bromür konsantrasyonu, bulanıklık ve iletkenlik parametrelerinin istatistiksel olarak farklılık içermemesidir ( $P<0.05$ ). Ayrıca başlangıç bromür konsantrasyonuna ait regresyon sabiti işareti kimyasal proses ile uyumlu değildir ve bulanıklık parametresinin bromat oluşumuna etkisine dair literatürde herhangi bir bilgiye rastlanmamıştır. Çizelge 4.4’den görüleceği üzere klorür ve başlangıç bromür konsantrasyonu ile iletkenlik arasında çok yüksek korelasyon bulunmaktadır. Bu üç parametre, MLR analizine tabi tutulduğunda model performans sonuçlarının oldukça kötü olduğu ve iletkenlik regresyon sabitinin bromat oluşum kimyasına ters düştüğü görünmektedir. Bu duruma collinearity (doğrudanlık, aynı doğru üzerinde kesişme) probleminin yol açtığı düşünülmektedir. Doğrudanlık bir regresyon modelinde değişkenlerden bazılarının veya tümünün mükemmel yakın nitelikte doğrusal ilişki içerisinde bulunması anlamını taşımaktadır. Pratik olarak bu durum, aynı etkiyi gösteren değişkenlerin üst üste binerek modelde gereğinden fazla girdi parametresinin

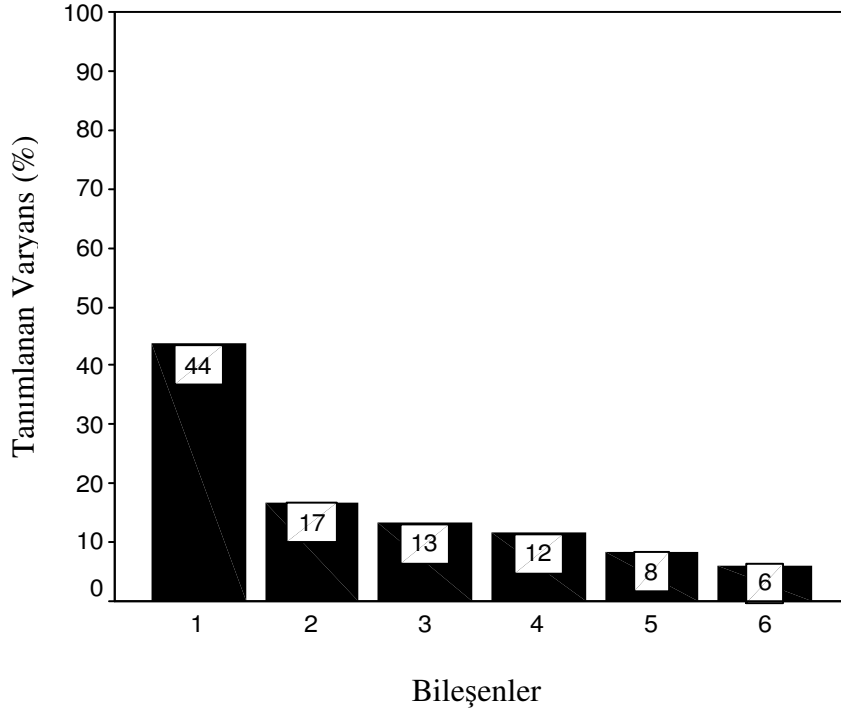
bulunmasına neden olmaktadır. Bu da model gücünü azaltarak, sonucun yorumlanmasını olumsuz yönde etkilemektedir (Montgomery vd., 2001).

Çizelge 4.4. Bromat model değişkenlerine ait korelasyon matrisi

	NH <sub>3</sub> -N	ÇOK	Alkalinite	İletkenlik	pH	Br <sup>-</sup>	Cl <sup>-</sup>	Uygulanan ozon dozu	Temas süresi
NH <sub>3</sub> -N	1.00	-0.38	0.39	0.48	-0.36	0.48	0.46	0.01	-0.01
ÇOK	-0.38	1.00	-0.04	-0.08	-0.28	-0.20	-0.02	0.06	0.07
Alkalinite	0.39	-0.04	1.00	0.57	-0.30	0.59	0.48	-0.10	-0.10
İletkenlik	0.48	-0.08	0.57	1.00	-0.89	<b>0.99</b>	<b>0.99</b>	-0.17	-0.04
pH	-0.36	-0.28	-0.30	-0.89	1.00	-0.83	-0.93	0.12	-0.02
Br <sup>-</sup>	0.48	-0.20	0.59	<b>0.99</b>	-0.83	1.00	<b>0.97</b>	-0.18	-0.06
Cl <sup>-</sup>	0.46	-0.02	0.48	<b>0.99</b>	-0.93	<b>0.97</b>	1.00	-0.15	0.00
Uygulanan ozon dozu	0.01	0.06	-0.10	-0.17	0.12	-0.18	-0.15	1.00	0.07
Temas süresi	-0.01	0.07	-0.10	-0.04	-0.02	-0.06	0.00	0.07	1.00


Koyu değerler yüksek korelasyonu ifade etmektedir.

MLR#5 modeli öncesi, ilk MLR modelindeki 10 deęişkenin aralarındaki iliřkiyi net olarak tanımlamak ve deęişken sayısını azaltmak için temel bileşenler analizi (PCA) uygulanmıştır. PCA sonuçları, üç bileşene ait kümülatif Eigen değerlerinin, hesaplanan varyansın %74'ünü tanımlamaktadır (Şekil 4.1).



Şekil 4.1. Bromat oluşumu modelinde PCA sonucu elde edilen bileşenlere ait tanımlanmış yüzdesel özdeğerler (eigenvalues)

Ayrıca temel bileşenler baz alınarak her bir deęişkene ait katsayılar Şekil 4.2'de üç boyutlu dağılım diyagramında verilmiştir. Bu diyagramda yer alan 10 deęişken, temel bileşen analizinden elde edilen yük faktörleri şeklinde tanımlanmıştır ve ifade edilen faktör değerlerinin 3 temel bileşen içerisinde nasıl dağıldığını göstermektedir. Şekil 4.2'den de görüleceği üzere X5, X7 ve X8 olarak tanımlanan sırasıyla iletkenlik, klorür ve başlangıç bromür konsantrasyonu model deęişkenlerine ait faktör değerleri (yük faktörleri) yaklaşık olarak aynıdır. Benzer olarak Şekil 4.2'de uygulanan ozon dozu ve temas süresi (sırasıyla X9 ve X10) arasında da benzer yük değerleri elde edilmiştir.



Şekil 4.2. Bromat oluşumu modelinde üç temel bileşene ait yük vektörlerinin dağılım diyagramı

Şekil 4.2'deki diğer parametreler (X1, X2, X3, X4 ve X6) ise yukarıda tanımlanan yük bileşen kesişimlerinin dışında kalmaktadır. Dolayısıyla uygulanan ozon dozu ve temas süresi (sırasıyla X9 ve X10), bromat oluşumunda tetikleyici parametreler olduğu için başlangıç bromür konsantrasyonu ile PCA sonrası MLR model#5 içerisinde birlikte değerlendirilmiştir. MLR model#5 bromat oluşumunu ilk MLR modeli kadar olmasa da iyi tahmin etmiştir ( $R^2=0.77$ ). Ayrıca kurulan çoklu regresyon modelinde bütün değişkenlere ait regresyon sabitlerinin işaretleri, kimyasal olarak da tutarlılık göstermektedir.

Son MLR analizi, oluşturulan modellerin pratik kullanım amacı esas alınarak yapılandırılmıştır. Bu aşamda MLR model#2'deki yaklaşıma benzer şekilde Çizelge 4.4'deki korelasyon tablosundan faydalanarak iletkenlik, başlangıç bromür konsantrasyonu ile yer değiştirmiştir. Bunun nedeni, hem iki değişken arasındaki yüksek korelasyon ( $R=0.99$ ), hem de sularda iletkenlik parametresinin ölçümünün

bromüre göre çok daha ucuz ve hızlı olmasıdır. Dolayısıyla MLR model#6 da başlangıç bromür konsantrasyonu, iletkenlik parametresi ile temsil edilmiştir. Gerçekleştirilen analiz sonuçları ve değişkenlere ait regresyon katsayıları, MLR model#5 ile oldukça benzerdir. Bu sonuç aynı zamanda yaklaşımın doğru yapıldığını da kanıtlamaktadır.

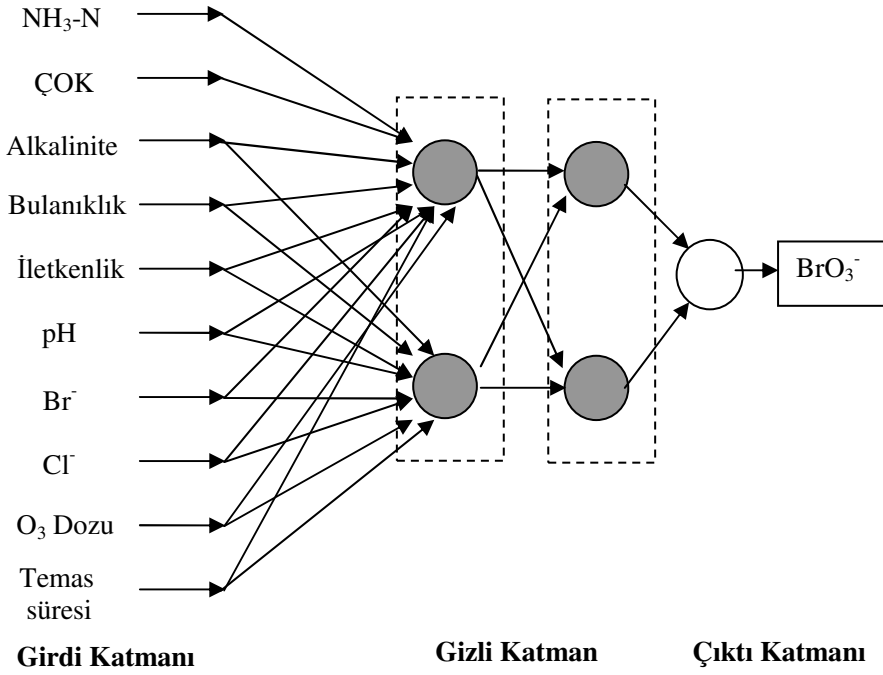
MLR#1 ve MLR#2 modellerinden de anlaşılacağı üzere bazı model değişkenlerine ait regresyon katsayı işaretleri ile bromat oluşum kimyası uyum göstermemektedir. Üçüncü ve dördüncü modeller ise bir ve iki numaralı MLR modellerindeki sorunların nicelik olarak açıklanması amacı ile gerçekleştirilmiştir. Bu nedenle PCA sonrası gerçekleştirilen modelleme çalışmaları (MLR#5 ve 6) daha güvenilir, basit ve anlık olarak ölçülebilen parametreler ile pratik ve kullanışlı modeller oluşturma amacına yönelik olarak gerçekleştirilmiştir. Bu nedenle başlangıç bromür konsantrasyonu, uygulanan ozon dozu, temas süresi ve iletkenlik parametreleri değerlendirmeye alınmıştır. MLR model #5 ve #6'ya ait regresyon katsayıları sırasıyla 0.77 ve 0.76 olarak hesaplanmıştır. Temel bileşenler analizinden hareketle pH, MLR#4 yaklaşımından çıkartılmıştır. Son iki MLR yaklaşımı ilk iki MLR yaklaşımı ile karşılaştırıldığında daha az değişken ile benzer model performanslarının elde edildiği gözükmektedir. Ayrıca, MLR model#6 gibi hızlı ve pratik olarak ölçülebilen parametrelerle kurulan modeller ile firmalarının bromat konsantrasyonunu oldukça ucuz bir maliyetle tahmin edebilecekleri düşünülmektedir.

Lineer regresyon analizinde çıktı parametresi bağımlı değişken, girdi parametreleri ise bağımsız değişken olarak adlandırılmaktadır. Bununla birlikte MLR ile bromat tahmininde pH ve alkalinite gibi bazı girdi değişkenleri kompleks kimyasal etkileşimlerden dolayı tam olarak bağımsız olamayabilmektedir. Değişkenler arası ilişkilerin tam olarak tespit edilemediği ya da kompleks ve doğrusal olmayan (non-linear) etkileşimlerde ANN algoritması uygun bir yaklaşım olarak gözükmektedir. ANN metotları değişkenler arasındaki kompleks etkileşimleri oldukça etkili bir şekilde tanımlayabilmektedir. Bununla birlikte ANN yaklaşımı MLR analizinden farklı olarak, değişkenler arası ilişkileri matematiksel eşitliklerle ifade etmemektedir. ANN yöntemi, geçmiş verileri eğiterek modelin tahmin kapasitesini artıracak bir çok




farklı algoritma kullanabilmektedir. Bu çalışmada çok katmanlı yapay sinir ađ yapısı kullanılarak iki farklı ANN modeli ile tüm sularda ölçülen veriler ışığında bromat oluşumu tahmin edilmeye çalışılmıştır.

İlk ANN ađı (ANN#1) girdi katmanında 10 girdi nöronu, 2 gizli katmanın her birinde 2 nöron ve çıktı katmanında da 1 adet çıktı nöronu içermektedir (Şekil 4.3a). İkinci ANN mimarisi (ANN#2) ise girdi katmanında 3 girdi nöronu, 2 gizli katmanın her birinde 2 nöron ve çıktı katmanında da 1 adet çıktı nöronu içermektedir (Şekil 4.3b).



(A)

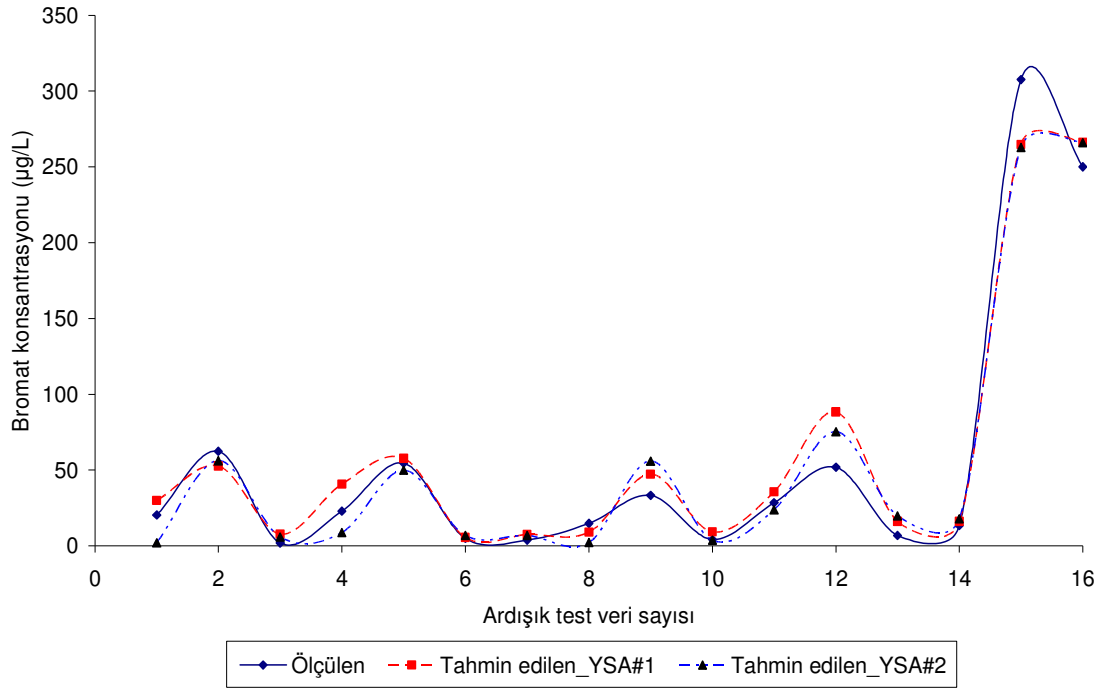


(B)


Şekil 4.3. Bromat oluşumu çalışmasında ANN#1 (A) ve ANN#2 (B) model mimarileri

Daha önce de belirtildiği üzere bromür, klorür ve iletkenlik arasında güçlü bir korelasyon bulunmasına karşın bromür ve iletkenlik parametreleri ANN#1 mimarisinde bir arada değerlendirilmiştir. Bunun nedeni bromür konsantrasyonu ve tuzluluk değerlerinin bromat oluşumundaki önemini değerlendirmektir. Ayrıca dikkat edilecek olursa ANN#1 yaklaşımında MLR model#1 yaklaşımına benzer olarak bütün ölçülen parametrelerin modele dahil edildiği görülebilmektedir.


ANN#2 model mimarisinde basit ve pratik bir model tasarlamak için anlık ölçülebilen parametreler (iletkenlik, uygulanan ozon dozu ve temas süresi) seçilmiştir. ANN model yapısı için temel bileşenler analizi uygulanmamıştır. MLR model#6'daki değişkenler ANN#2 modeli için girdi olarak seçilmiştir. Dolayısıyla ANN yaklaşımında MLR analizleri de dikkate alınarak toplam 2 farklı model tanımlanmıştır. Geri kalan 4 MLR analizi ANN yaklaşımı sırasında dikkate alınmamıştır. Bunun nedeni, sırasıyla MLR model#1 ve #2 ile MLR model#5 ve #6'nın performanslarının yaklaşık olarak aynı olmasıdır. MLR model#3 ve#4 ise kontrol modeli olarak seçildiği için mekanistik yaklaşıma dahil edilmemiştir. Eğitim fazında her iki ANN modeli için 100 iterasyon adımının yeterli olduğu tespit edilmiştir. Eğitim aşamasından sonra test aşaması için ANN#1 ve ANN#2 yaklaşımları için bromat tahmini hata değerleri RMSE ve MAPE olarak sırasıyla 4.06 ve 4.16  $\mu\text{g/L}$  ile %10.72 ve %15.34 şeklinde hesaplanmıştır. Şekil 4.4a tüm sular için ölçülen ve ANN#1 ile ANN#2 model yaklaşımları baz alınarak tahmin edilen bromat konsantrasyonları arasındaki ilişkiyi ifade etmektedir. Her iki ANN modelin performansı sırasıyla Şekil 4.4b ve Şekil 4.4c'de gösterilmiştir. ANN modelleri için hesaplanan RMSE ve  $R^2$  değerleri girdi ve çıktı değişkenleri arasındaki geniş değer aralığı dikkate alındığında oldukça tatmin edici gözükmektedir.



(A)



(B)



(C)

Şekil 4.4. Tüm sular için ölçülen ve tahmin edilen bromat konsantrasyonları (A) ile model performansları (B: ANN#1; C: ANN#2).

Her iki ANN modeli de yüksek  $R^2$  deęerlerine sahiplerse de (ANN model#1 ve model#2 için sırasıyla 0.97 ve 0.96) model#1 yaklaşımının RMSE ve  $R^2$  parametreleri ile deęerlendirildięinde bromat oluşumunu daha iyi tahmin ettięi tespit edilmiştir (Şekil 4.4b ve Şekil 4.4c). Bununla birlikte model#1 içerisindeki bazı girdi parametreleri (ÇOK ve bromür konsantrasyonu gibi) pahalı ve ayrıntılı analitik teknikler gerektirdięinden modelin pratik kullanılışlılığını engelleme potansiyeline sahiptir. Dięer yandan model#2, anlık olarak ölçülebilen pratik girdi parametrelerini (iletkenlik, uygulanan ozon dozu, temas süresi) içermektedir. Böylece yüksek tahmin kapasitesi ve pratiklik açısından deęerlendirildięinde model#2, Girit adasındaki küçük çaplı şişe suyu üreticileri için kullanışlı bir yaklaşım içermektedir.

Tüm sonuçlar deęerlendirildięinde MLR ve ANN modelleme tekniklerinin her ikisi de bromat oluşumunu etkili bir şekilde tahmin edebilmiştir. MLR modellerinde RMSE hata deęeri 9 ile 14  $\mu\text{g/L}$  (%19-%50 MAPE) arasında deęişirken, ANN modelleri için elde edilen hata deęerleri 4.06 ve 4.16  $\mu\text{g/L}$  arasında (%10-%16 MAPE) hesaplanmıştır. Bu da ANN model yaklaşımının bromat tahminlerinde daha başarılı olduğunu göstermektedir.

#### **4.2. Endüstriyel Atıksu Arıtma Tesisinde Karbon ve Azot Gideriminin Temel Bileşenler Analizi ve Adaptif Ağ Temelli Bulanık Çıkarım Sistemi ile Modellenmesi**

Aktif çamur prosesi (AÇP) kentsel ve endüstriyel atıksu arıtma tesislerinde (AAT) en sık kullanılan biyolojik arıtma metodudur. AÇP, biyolojik bileşenlerde, parametre konsantrasyonlarında ve atıksu debisinde oluşan büyük farklılıklardan ötürü kendi içerisinde oldukça dinamik bir yapıya sahiptir. Bu kapsamda, biyolojik proseslerin ve kompleks etkileşimlerin tanımlanması, tahmini ve kontrolü için matematik modellere ve bilgisayar simülasyonlarına ihtiyaç bulunmaktadır (Jeppsson, 1996). Son 20 yıldır arıtma proseslerinde mikrobiyolojik (biyokütle) aktivitelerini tanımlamak için aktif çamur modelleri (ASM1, ASM2, ASM3, TUDP) olarak adlandırılan bazı deterministik yaklaşımlar geliştirilmiştir (Henze vd., 1987; Henze vd., 1995; Gujer vd., 1999; van Veldhuizen vd., 1999; Brdjanovic vd., 2000). Bu matematiksel modellerin içerisindeki yaklaşımlar mühendislik prensiplerini temel aldığı için atıksu arıtma tesislerinde karbonlu ve azotlu substratların konsantrasyonlarının tahmin edilmesi aşamasında oldukça etkili olabilmektedirler (Jeppsson, 1996). Fakat, geliştirilen deterministik modeller çok sayıda kinetik ve stokiyometrik parametreler içerdiklerinden dolayı, sistemin tam olarak tanımlanabilmesi için oldukça fazla sayıda kompleks matematiksel ifadelerin ortaya çıkmasına neden olmaktadır. Bu durum AAT işletmesi açısından değerlendirildiğinde pratik bir yaklaşım olarak değerlendirilmemektedir (Jeppsson, 1996; Tay ve Zhang, 2000).

Atıksu arıtma tesislerinde güvenilir modelleme ve kontrol teknikleri oluşturmanın temel amacı arıtma performansını olabildiğince optimal şartlarda tutmak olmalıdır. Sistemin kompleks ve dinamik yapısı dikkate alındığında tüm prosesin optimizasyonunu sağlayan anlık kontrol stratejilerinin belirlenmesi gerekmektedir (Luccarini vd, 2002). Bu bağlamda atıksu arıtma tesislerindeki prosesler, yapay zeka (YZ) adı verilen modelleme yaklaşımları ile tanımlanmaya başlanmıştır (Häck ve Köhne, 1996; Farza vd., 1998; Acha vd., 1999; Choi ve Park, 2001; Luccarini vd, 2002; Chen vd, 2003; Hamed vd, 2004; Çinar, 2005).


YZ metotları içerisinde yapay sinir ağıları (ANN), genetik algoritma (GA), bulanık mantık (FL), kural temelli sistemler, bilgi temelli sistemler ve bu tekniklerin birlikte değerlendirildiği metotları barındırmaktadır. Adı geçen hibrit uygulamalardan bir tanesi de adaptif ağ temelli bulanık çıkarım sistemidir [adaptive network based fuzzy inference system (ANFIS)]. ANFIS metodu ilk olarak Jang (1993) tarafından birinci derece Sugeno bulanık modeli (Takagi ve Sugeno, 1983, 1985; Sugeno ve Kang, 1986) temel alınarak öne sürülmüştür. ANFIS içerisinde kullanılan ANN çok tabakalı ileri beslemeli ve geri yayımlı ağı kullanmaktadır.

Çalışmada çok değişkenli istatistiksel veri analiz tekniklerinden biri olan temel bileşenler analizi (PCA), SPSS 9.0 programında bulunan faktör analiz aracı yardımıyla model girdi matris boyutunu belirlemek için kullanılmıştır. PCA yüksek boyutlu (parametre sayısı veya veri sayısı olarak) sistemlerde ön değerlendirme metodu olarak kullanılabilir (Jolliffe, 2002).

Tezin ikinci bölümünün temel amacı tam ölçekli bir biyolojik ardışık endüstriyel atıksu arıtma tesisinin aerobik kısmının performansının ANFIS ile değerlendirilmesidir. Çalışmada belirtildiği üzere ardışık biyolojik arıtma sisteminin sadece aerobik kısmı model kapsamında değerlendirilmiştir. Bunun sebebi, aynı tesisin anaerobik kısmının daha önce ANFIS metodu ile değerlendirilmiş (Perendeci, 2004) olmasıdır. Ayrıca ilgili literatür incelendiğinde aerobik biyolojik oksidasyonun ANFIS ile modellenmesine dair bir çalışmaya rastlanmamıştır. Bunun yanında endüstriyel atıksu arıtma tesisindeki nihai çıkış suyu kalitesi, aerobik prosesinde gerçekleştirilecek optimum kontrol stratejileri ile doğrudan bağlantılı bulunmaktadır. Tüm bu nedenlerden ötürü  $KO_2$ ,  $NH_4-N$  ve  $TN$  olmak üzere 3 farklı ve birbirinden bağımsız ANFIS modeli geliştirilmiştir. Bu modellerde  $KO_2_{çıktı}$ ,  $NH_4-N_{çıktı}$  ve  $TN_{çıktı}$  parametreleri, atıksu arıtma tesisindeki karbon ve azotun tahmin edilebilmesi için çıktı parametreleri olarak belirlenmiştir. Belirlenen çıktı parametrelerini tahmin edecek girdi değişken matrisi oluşturulduktan sonra kurulan 3 bağımsız model ANFIS algoritması ile değerlendirilmiştir.



Modelleme çalışması için Konya (Ereğli) Endüstriyel Şeker Fabrikası Atıksu Arıtma Tesisi seçilmiş ve tesisden işletim verileri elde edilmiştir. Tesis, sırasıyla anaerobik ve aerobik ardışık prosesler ile ANAMET (Anaerobic Methane Production) tipinde işletilmektedir (Şekil 4.5). Anaerobik ünite tam karışimli hidroliz ve anaerobik tanklar ile lamella tipi çökeltim tankını içermektedir. Aerobik kısım ise aktif çamur prosesi ve son çökeltim tankından oluşmaktadır. Aktif çamur prosesi, iç içe geçmiş tam karışimli ve pre-denitrifikasyon prensibine göre işletilen nitrifikasyon/denitrifikasyon tanklarını içermektedir. Üç ayrı modelin geliştirilmesinde kullanılan veriler atıksu arıtma sistemi içerisinde anlık olarak ölçülen (on-line) ve laboratuvar analizleri (off-line) ile belirlenen değişkenlerden elde edilmiştir.



1. Bruckner çökeltim tankı çıkışı
2. Fabrika atıksuyu
3. Rafineri atıksuyu
4. Dengeleme tankı
5. Hidroliz tankı
6. Biyogaz hattı
7. Çamur geri devir hattı
8. Anaerobik reaktör
9. Lamella çökeltim tankı
10. Çamur geri devir hattı

11. Fazla çamur hattı
12. Denitrifikasyon tankı
13. Nitrifikasyon tankı
14. Çamur geri devir hattı
15. Son çökeltim tankı
16. Fazla çamur hattı
17. Çamur kurutma yatağı
18. Çıkış/deşarj

Şekil 4.5. Ereğli Şeker Fabrikası AAT proses akış diyagramı

Daha önceden oluşturulan ANFIS algoritması hazır bulunduğu için ilk olarak uygun girdi ve çıktı parametrelerinin belirlenmesi amaçlanmıştır. Bir modelde girdi değişkenlerinin belirlenmesi önemli bilgi birikimini gerekli kılmaktadır. ANFIS modelleri için girdi ve çıktı parametreleri günlük olarak belirlenen değişkenler arasından seçilmiştir. Bu işlem gerçekleştirilirken ölçülmeyen ya da kayıp veriler değişken matrisinden çıkartılmıştır. Oluşturulan nihai model veri matrisi 2002-2003 yılı şeker üretim kampanyasına ait 183 günlük ardışık verileri içermektedir. Model için seçilen parametrelere ait temel istatistiksel değerler ve Şekil 4.5’de verilen parametrelerin ölçüm noktaları Çizelge 4.5’de tanımlanmıştır.

ANFIS algoritması MATLAB R14 (MathWorks, Inc.) yazılımı içerisinde bulunan Fuzzy Logic aracı yardımıyla çalıştırılmıştır. Seçilen model parametreleri farklı birimlere sahip olduklarından sınır değerleri *xbounds* fonksiyonu ile normalize edilmiştir. Dolayısıyla bu fonksiyon ile her bir girdi ve çıktı değişkeni için muhtemel minimum ve maksimum değerleri belirlenmiş olmaktadır. Her üç bağımsız ANFIS modeli için toplam veri sayısının yaklaşık %60’ı (110 veri) eğitim aşamasında kalan %40’lık kısım da (73 veri) modelin test edilmesi (doğrulanması) aşamasında kullanılmıştır. Eğitim ve test verileri, oluşturulan matris içerisinde gelişigüzel belirlenmiştir.

Çizelge 4.5. Ereğli AAT karbon ve azot giderim modellerinde kullanılan atıksu karakteristikleri

Atıksu parametreleri	Minimum	Ortalama	Maksimum
$Q_{girdi}$ ( $m^3/gün$ )	484	3290	4856
$Q_{geri\ döngü}$ ( $m^3/gün$ )	30	3578	5663
$Q_{fazla}$ ( $m^3/gün$ )	0	145	600
$KOİ_{girdi}$ (mg/L)	92	202	416
$KOİ_{dn}$ (mg/L)	48	110	364
$KOİ_{çıktı}$ (mg/L)	40	100	300
pH	7.3	7.7	8.2
$TAKM_{nit}$ (mg/L)	316	8555	16100
$UAKM_{nit}$ (mg/L)	175	3256	8850
$NH_4-N_{girdi}$ (mg/L)	10	39	147

NH <sub>4</sub> -N <sub>dn</sub> (mg/L)	0	12	139
NH <sub>4</sub> -N <sub>nit</sub> (mg/L)	0	12	163
NH <sub>4</sub> -N <sub>çikti</sub> (mg/L)	0	11	131
TN <sub>girdi</sub> (mg/L)	16	50	128
TN <sub>çikti</sub> (mg/L)	4	30	177
TN <sub>dn</sub> (mg/L)	4	28	172

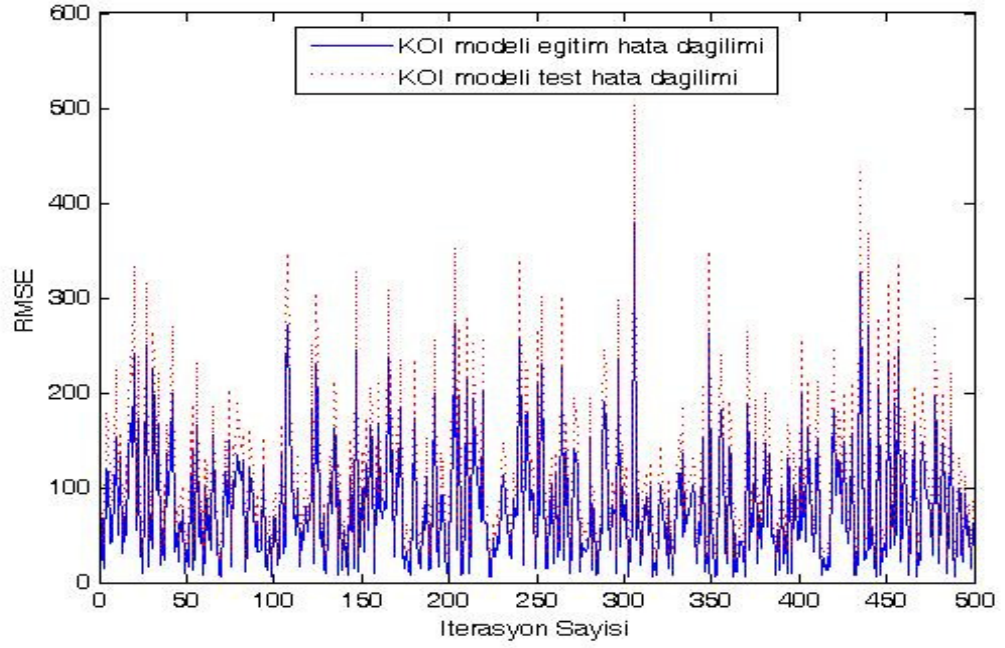
Q: Atıksu ve çamur akış debileri, TAKM: Toplam Askıda Katı Madde, UAKM: Uçucu Askıda Katı Madde, NH<sub>4</sub>-N: Amonyum Azotu, TN: Toplam Azot

ANFIS algoritması her zaman ilk olarak bir prototip (başlangıç) bulanık çıkarım sistemi (FIS) oluşturmakta ve o prototipin eğitilmesi ile sonuçlar elde edilmektedir. Bu çalışmada başlangıç bulanık çıkarım sisteminin oluşturulması için verilerin ait olduğu gruplar ve sayıları belirlenmiş ve bu işlem eksiltmeli gruplandırma algoritması (subtractive clustering algorithm) ile gerçekleştirilmiştir. Daha sonra başlangıç FIS, ANFIS algoritması ile optimize edilmiştir. Çalışmada kullanılan veri gruplandırma algoritması *genfis2* fonksiyonu ile ifade edilmekte ve içerisinde veri grubunun etki merkezini belirleyen *radii* vektörü ve bazı opsiyonel fonksiyonları barındırmaktadır. Bu fonksiyonlardan biri de *quashfactor* dır. Bu fonksiyon da veri grubuna ait etki merkezinin yarıçapının belirli aralıklar içerisinde bulunan rakamlarla çarparak veri grubu merkezine olan komşuluğu tespit etmektedir. Her üç ANFIS modeli için de başlangıç veri grubu yarıçapı ve veri grubu komşuluk faktörü sırasıyla 0.5 ve 1.25 olarak belirlenmiştir. Bu rakamlar aynı zamanda belirtilen vektörel fonksiyonların ANFIS algoritmasındaki orijinal değerleridir. Bu değerler çalışma kapsamında belirli aralıklarla farklılaştırılarak, fonksiyonlardaki değişimin ANFIS model performansına etkisi değerlendirilmiştir.

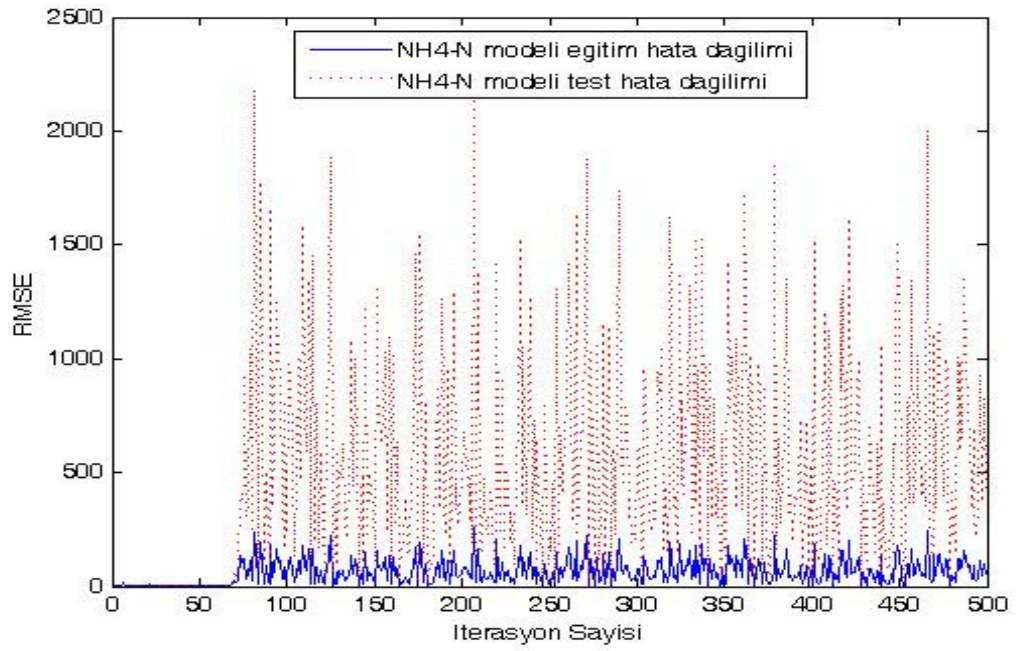
Eğitilen ANFIS modelleri daha sonra belirlenen doğrulama veri seti ile test edilmiştir. Model performansları gerek eğitim gerekse test veri seti için korelasyon katsayısı (R), ortalama karesel hata karekökü (RMSE) ve ortalama oransal hata (MAPE) ile tespit edilmiştir.

Çalışma kapsamında kurulan ANFIS modellerinin tümünde birinci derece Sugeno bulanık mantık çıkarım sistemi kullanıldığı için hepsinde tek bir çıktı bulunmaktadır.

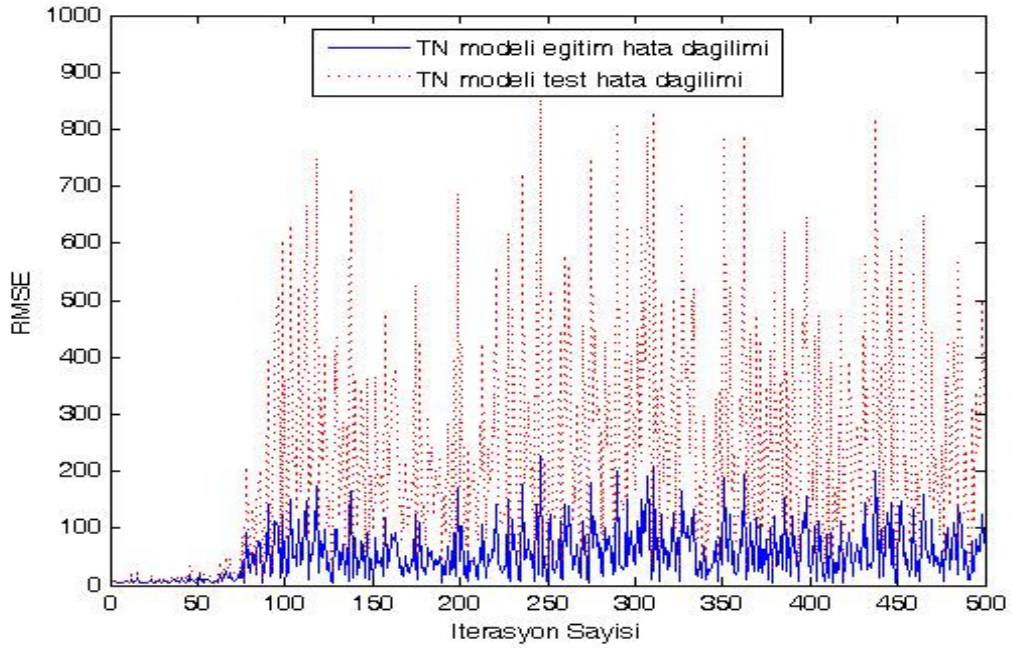
Kurulan ANFIS modellerin hepsi hedef çıktı değerlerinin etkili olarak tahmin edilebilmesi için bir çok iterasyon adımıyla eğitilmiştir (maksimum 500 iterasyon). Eğitim ve test aşamalarına ait hata dağılımları eğitim algoritması çalışırken hesaplanmıştır. Şekil 4.6'dan da görüleceği üzere eğitim sırasında RMSE değerleri stabil halde değildir ve sürekli değişmektedir. Her üç model için gerçekleştirilen ilk sonuçlarda KOİ, NH<sub>4</sub>-N ve TN modelleri için RMSE ve MAPE hata değerleri sırasıyla (23.5 mg/L, %14.3), (1.5 mg/L, %47.1) ve (5.7 mg/L, %20.2) olarak hesaplanmıştır. Her ne kadar model doğrulama aşamasında R katsayıları oldukça yüksekse de (KOİ, NH<sub>4</sub>-N ve TN modelleri için sırasıyla 0.93, 0.99, 0.98), bu durum hata değerleri ile birlikte değerlendirildiğinde etkili bir tahmin yapılamadığını göstermektedir İlk aşamada elde edilen yüksek RMSE ve MAPE hata değerleri dikkate alınarak çalışmada ANFIS modellerinin performansının artırılmasına odaklanılmıştır.



(A)



(B)



(C)

Şekil 4.6. Ereğli Şeker Fabrikası AAT’de PCA analizi öncesi geliştirilen KOİ (A), NH<sub>4</sub>-N (B) ve TN (C) modellerinin eğitim ve test hata diyagramları

Herhangi bir tahmin amaçlı kurulan modelde, model girdilerini doğru saptamak kritik öneme sahiptir. Bu nedenle her bir ANFIS modeli için mevcut girdi değişkenleri ile çıktı değişkenleri arasındaki korelasyon katsayıları hesaplanmıştır. Çizelge 4.6’dan da görüleceği üzere AAT işletimi ele alındığında kurulan modellerdeki hedef değişkenler (KOİ<sub>çıktı</sub>, NH<sub>4</sub>-N<sub>çıktı</sub>, TN<sub>çıktı</sub>), atıksu ve çamur akış debileri ( $Q_{girdi}$ ,  $Q_{geri\ devir}$ ,  $Q_{fazla}$ ) ile sistemdeki çamur miktarı (TAKM ve UAKM) dışındaki girdi parametreleri ile pozitif doğrusal ilişkiye sahiptir. Belirtilen girdi değişkenlerinin model çıktıları ile ters orantılı doğrusal ilişkisi, tesisteki debi değerlerinin ve çamur miktarının artması ile artırılmış sudaki KOİ, NH<sub>4</sub>-N ve TN konsantrasyonlarının azalacağı anlamını taşımaktadır. Fakat tesis giriş atıksuyu debisi ( $Q_{girdi}$ ) artarken, reaktördeki hidrolik bekletme süresi azalacağından biyolojik proses için geçen süre azalmakta ve bu durum çıkış kalite parametreleri (KOİ, NH<sub>4</sub>-N ve TN) değerlerinin artmasına neden olmaktadır. Dolayısıyla bu noktada istatistiksel sonuçlarla biyolojik proses sonuçları uygunluk göstermemektedir. Bu duruma, endüstrinin üretim periyodu boyunca kaydedilen atıksu debisindeki yüksek salınımların neden olduğu sanılmaktadır.

Çizelge 4.6. ANFIS modellerinde kullanılan girdi ve çıktı parametreleri arasındaki korelasyon ilişkisi

Çıktı Parametreleri	Girdi Parametreleri						
	$Q_{girdi}$	$KOİ_{girdi}$	$KOİ_{dn}$	pH	$Q_{geri\ devir}$	$Q_{fazla}$	$TAKM_{nit}$
$KOİ_{çikti}$	-0.69	0.62	0.98	0.51	-0.51	-0.32	-0.67
$NH_4-N_{çikti}$	-0.57	0.37	0,83	0.43	-0.48	-0.36	NS
$TN_{çikti}$	-0.47	0.24	0.75	0.31	-0.39	-0.40	NS

Çizelge 4.6. (devam)

Çıktı Parametreleri	Girdi Parametreleri					
	$UAKM_{nit}$	$TN_{girdi}$	$NH_4-N_{girdi}$	$NH_4-N_{dn}$	$NH_4-N_{nit}$	$N-tot_{dn}$
$KOİ_{çikti}$	-0.60	NS	NS	NS	NS	NS
$NH_4-N_{çikti}$	NS	0.74	0.94	0.99	0.99	0.96
$TN_{çikti}$	NS	0.73	0.96	0.96	0.95	0.99

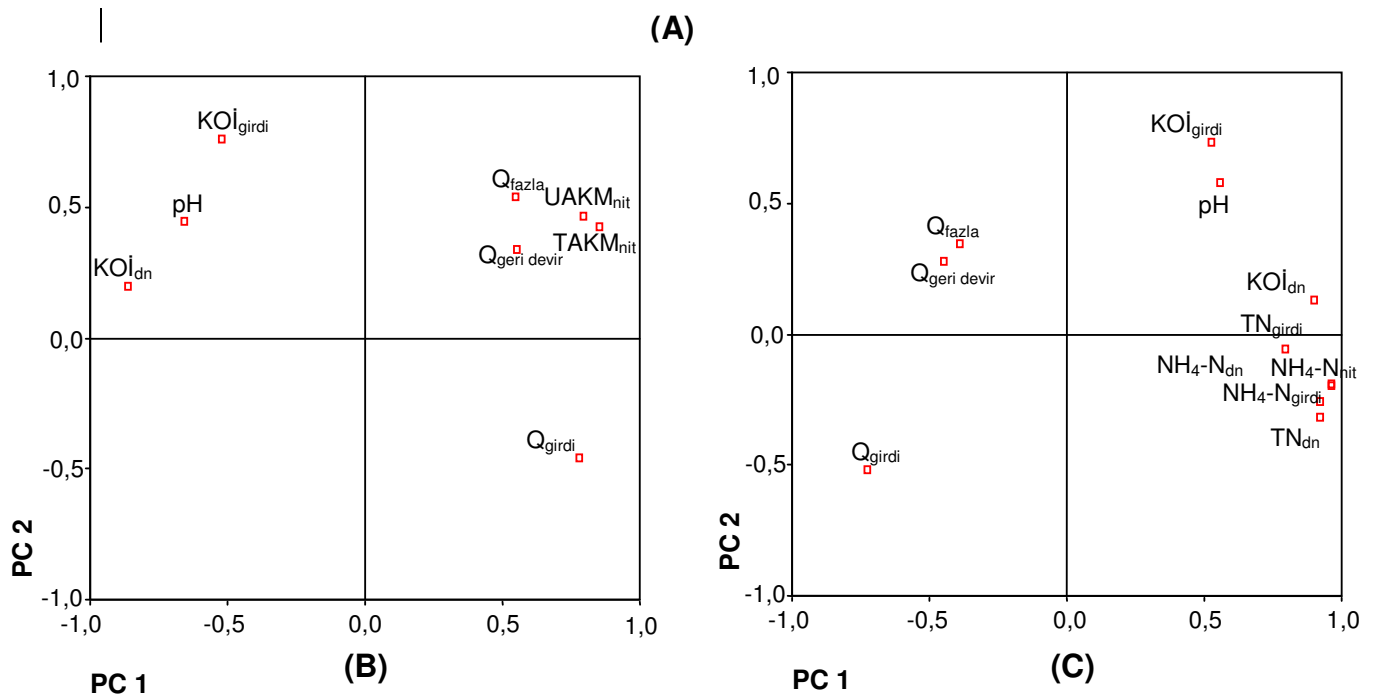

Model girdi ve çıktıları arasındaki ilişkilerin tam olarak belirlenememesinden ötürü mevcut durumu netleştirmek için PCA metodu kullanılmıştır. Tasarlanan 3 model içerisinde  $NH_4-N$  ve  $TN$  modellerinin girdi değişkenleri aynı olmasından ötürü tek girdi matrisi olarak değerlendirilmiştir. Dolayısıyla  $KOİ$  model matrisi ile birlikte 3 model için 2 farklı PCA metodu kullanılmıştır. PCA analizleri girdi değişken sayılarına göre  $KOİ$ ,  $NH_4-N$  ve  $TN$  modelleri için sırasıyla 8 ve 11 bileşen (değişken) ile gerçekleştirilmiştir. Her iki PCA analizinde de ilk iki temel bileşen (PC1 ve PC2)  $KOİ$ ,  $NH_4-N$  ve  $TN$  modelleri için sırasıyla toplam varyansın %73.1 ve %73.3'lük kısmını tanımlamaktadır (Şekil 4.7a). Her iki analiz için ilk iki temel bileşene ait yük faktörleri Şekil 4.7b ve Şekil 4.7c'de tanımlanmıştır. Proses değişkenlerinin temel bileşen yük faktörleri, analiz sonucuna göre gruplaşabilmektedir. Şekil 4.7b'den görüleceği üzere  $Q_{fazla}$ ,  $Q_{geri\ devir}$ ,  $TAKM_{nit}$  ve  $UAKM_{nit}$  değişkenleri benzer yük faktörlerine sahiptir ve birlikte değerlendirilebilir. Benzer olarak PCA analizi içerisinde yük faktörlerine göre,  $NH_4-N_{in}$ ,  $NH_4-N_{nit}$ ,  $NH_4-N_{dn}$ ,  $TN_{girdi}$  ve  $TN_{dn}$  değişkenleri de ayrı bir grup olarak kümelmiştir (Şekil 4.7c). Bu durum, aynı grup içerisinde bulunan değişkenler arasındaki güçlü korelasyonun da bir göstergesidir. Dolayısıyla aynı grup içerisinde birbirine yakın faktör değerleri alan değişkenler, fiziksel olarak da benzer davranışlar gösterebilmektedir. Bu durumda değişkenlerin aldıkları yük faktörlerine göre gruplanması prosesin daha net anlaşılmasını ve gruptan temsili parametrelerin seçilebilmesini sağlamaktadır.



Analiz metodu uygulandıktan sonra PCA sonuçları ve ilk modelin girdi parametrelerine ait korelasyon katsayıları birlikte değerlendirilerek bağımsız üç ANFIS modeli için iki farklı girdi matrisi oluşturulmuştur. Şekil 4.7b’de, PCA değerlendirmesindeki ilk parametre grubunu tesis girişindeki substrat ve diğer atıksu parametrelerinin ( $KOİ_{girdi}$ ,  $KOİ_{dn}$ , pH) oluşturduğu gözlenmiştir. Bu durum nitrifikasyon tankı içerisindeki pH değeri ile tesis girişinde ve denitrifikasyon tankı içerisinde ölçülen  $KOİ$  değerlerinin,  $KOİ$  giderimi ile pozitif ve doğrusal bir korelasyona sahip olduğu anlamını taşımaktadır. Bahsi geçen değişkenler arasındaki ilişki Çizelge 4.6’da hesaplanan korelasyon katsayıları ile de uygunluk göstermektedir.

$KOİ$  model yaklaşımında, tesise giriş debisi ( $Q_{girdi}$ ) haricinde, çıktı parametresi ile negatif korelasyona sahip değişkenler model girdi matrisinden çıkartılmıştır. Tesise giren atıksu debisi atıksu arıtma tesisi performansı değerlendirilirken ihmal edilemeyeceğinden ötürü  $KOİ$  model matrisinden çıkartılmamıştır. Böylece, PCA analizinde tanımlanan ilk değişken grubu ve atıksu debisi  $KOİ$  modeli girdi matrisini oluşturmuştur.

Kurulan ANFIS modellerinde,  $NH_4-N_{çıkıktı}$  ve  $TN_{çıkıktı}$  değişkenlerinin tahmininde aynı girdi matrisi kullanılmasından dolayı, tek bir değişken azaltma yaklaşımı kullanılmıştır. Şekil 4.7c’de belirtildiği üzere on bir girdi değişkeni dört farklı grup oluşturmuştur.  $NH_4-N$  ve  $TN$  modellerinde atıksu ve çamur debileri ( $Q_{girdi}$ ,  $Q_{geri\ devir}$  ve  $Q_{fazla}$ ) dışındaki değişkenler, model çıktı parametreleri ( $NH_4-N_{çıkıktı}$ ,  $TN_{çıkıktı}$ ) ile pozitif korelasyona sahiptir. Bu durum, Çizelge 4.6’da da görüleceği üzere, proses tankları içerisindeki pH, karbon ve azot yüklerinin çıkış parametreleri ile pozitif korelasyona sahip olduklarını göstermektedir.



Şekil 4.7 Model çalışmasında temel bileşenlerin fonksiyonu cinsinden tanımlanan proses varyans oranı (A) ile KOİ (B), NH<sub>4</sub>-N ve TN (C) modellerine ait yük vektörleri

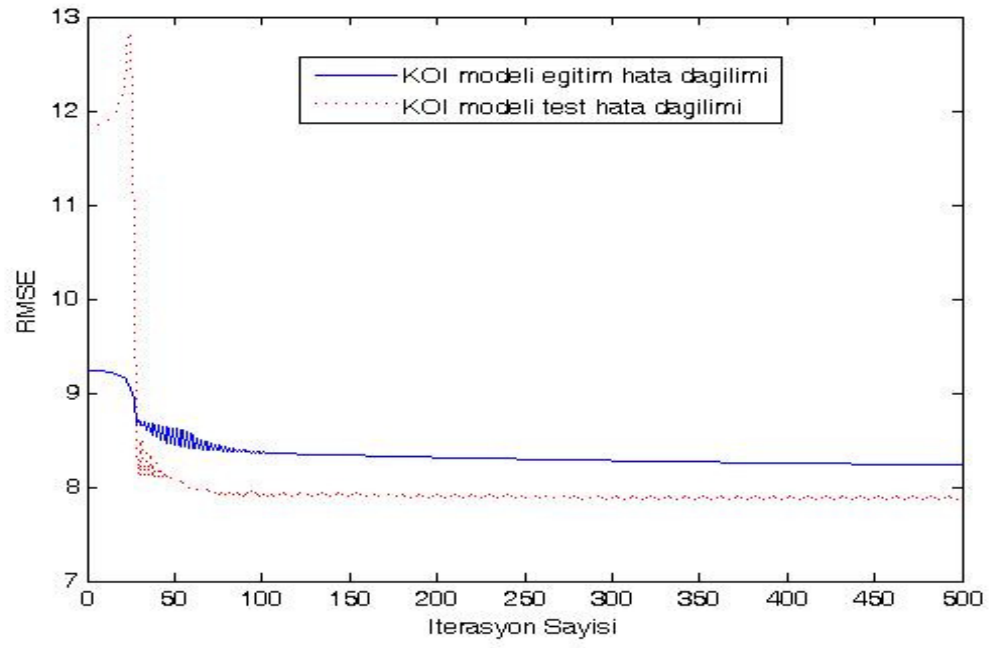
Ayrıca KOİ modelinde olduğu gibi, hedef çıktı parametresi ile negatif korelasyona sahip girdi değişkenleri birlikte değerlendirildiklerinde fazla çamur debisi ( $Q_{\text{fazla}}$ ) ve çamur geri devir debisinin ( $Q_{\text{geri devir}}$ ) biyolojik proses açısından uygun sonuçlar verdikleri gözlenmiştir. Çünkü  $Q_{\text{fazla}}$  maksimum  $600 \text{ m}^3/\text{gün}$  değerindedir. Bu değer maksimum tesis atıksu girişi debisinin %12'sine tekabül etmektedir. Dolayısıyla bir gün içerisinde atıksuyun %88'lik kısmı proseste kalmaktadır. Bu durum oluşan aktif çamurun çoğunun sistem içerisinde kaldığını ve biyolojik prosesin uzun çamur bekletme zamanlarında (SRT, solids retention time) işletildiğini doğrulamaktadır. Sonuç olarak tesisin sabit SRT değerinde işletilebilmesi açısından değerlendirildiğinde  $Q_{\text{geri devir}}$  parametresi,  $Q_{\text{fazla}}$  parametresinden daha önemli duruma gelmektedir. Dolayısıyla Çizelge 4.6.'daki çıkış karbon ve azot konsantrasyonları ile  $Q_{\text{geri devir}}$  arasındaki negatif korelasyonun nedeninin de bu durum olabileceği düşünülmektedir. Netice olarak, bahsi geçen ve çıktı parametreleri ile negatif korelasyona sahip değişkenler,  $\text{NH}_4\text{-N}$  ve TN modeli girdi matrisinden çıkartılmıştır.

PCA ile girdi matris boyutu daraltılan ANFIS modellerine ait seçilen değişkenler ve bu modellere ait eğitim ve test performans değerleri Çizelge 4.7'de verilmiştir. Çizelge 4.7'den de açıkça görüleceği üzere KOİ modeli 4 girdi (ilk değeri: 8), ikinci ve üçüncü ANFIS modelleri ise ( $\text{NH}_4\text{-N}$  ve TN modelleri) 9 girdi değişkeni (ilk değer:11) içermektedir. Yeni geliştirilen modeller ilk önce çalıştırılan modeller ile aynı algoritmaya sahiptir. ANFIS modellerinde eğitim aşaması çok önemli bir yer tuttuğu ve model sonuç performansını direkt olarak etkilediği için, eğitim aşamasına ait RMSE ve R değerleri Çizelge 4.7'de verilmiştir. Önerilen ANFIS modelleri, PCA öncesi kurulan modeller ile karşılaştırıldığında KOİ modeli için test hata değeri RMSE olarak  $22.52 \text{ mg/L}$ ' den  $7.90 \text{ mg/L}$  değerine MAPE olarak da %14.25'den %7.26'ya düşmüştür. Ayrıca yine KOİ modeli için R katsayısı 0.93'den 0.98'e yükselmiştir. Bu durum her ne kadar KOİ çıktı değerinin gerçek sisteme oldukça yakın düzeyde tahmin edilebildiğini gösterse de aynı kabul edilebilir hata değerleri, Çizelge 4.5'deki ortalama değerleri göz önüne alındığında TN ve özellikle  $\text{NH}_4\text{-N}$  modelleri için elde edilememiştir.

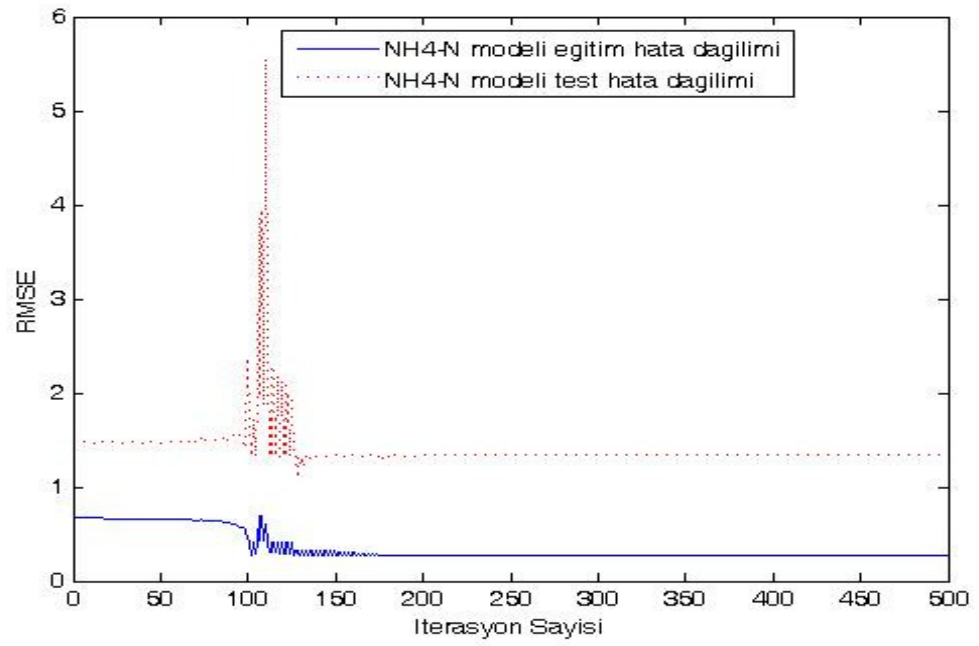
Çizelge 4.7. PCA sonrası seçilen girdi veri matrisi ile gerçekleştirilen ANFIS model performansları

Model	Model Girdileri	Model Çıktıları	Kural Sayısı	Eğitim Sonuçları		Test Sonuçları	
				RMSE (mg/L)	R	RMSE (mg/L)	R
KOİ	Q <sub>girdi</sub> KOİ <sub>girdi</sub> KOİ <sub>dn</sub> pH	KOİ <sub>çıkı</sub>	2	8.23	0.99	7.90	0.98
NH <sub>4</sub> -N	Q <sub>girdi</sub> KOİ <sub>girdi</sub> KOİ <sub>dn</sub> pH TN <sub>girdi</sub> NH <sub>4</sub> -N <sub>girdi</sub> NH <sub>4</sub> -N <sub>dn</sub> NH <sub>4</sub> -N <sub>nit</sub> TN <sub>dn</sub>	NH <sub>4</sub> -N <sub>çıkı</sub>	2	0.27	1.00	1.30	0.99
TN	Q <sub>girdi</sub> KOİ <sub>girdi</sub> KOİ <sub>dn</sub> pH TN <sub>girdi</sub> NH <sub>4</sub> -N <sub>girdi</sub> NH <sub>4</sub> -N <sub>dn</sub> NH <sub>4</sub> -N <sub>nit</sub> TN <sub>dn</sub>	TN <sub>çıkı</sub>	2	3.84	0.99	4.21	0.99

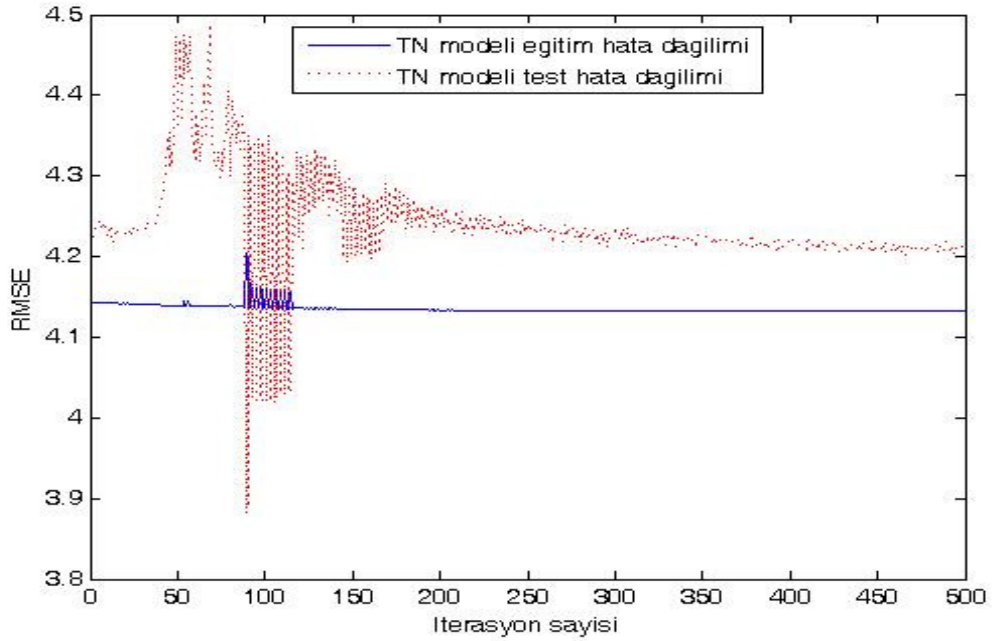
ANFIS modelleri için RMSE olarak ifade edilmiş eğitim ve test hataları, azalma (stabil hale gelme) eğilimi göstermekte ve 200 iterasyon adımından sonra da sabite yakın değerler almaktadır (Şekil 4.8).



(A)



(B)

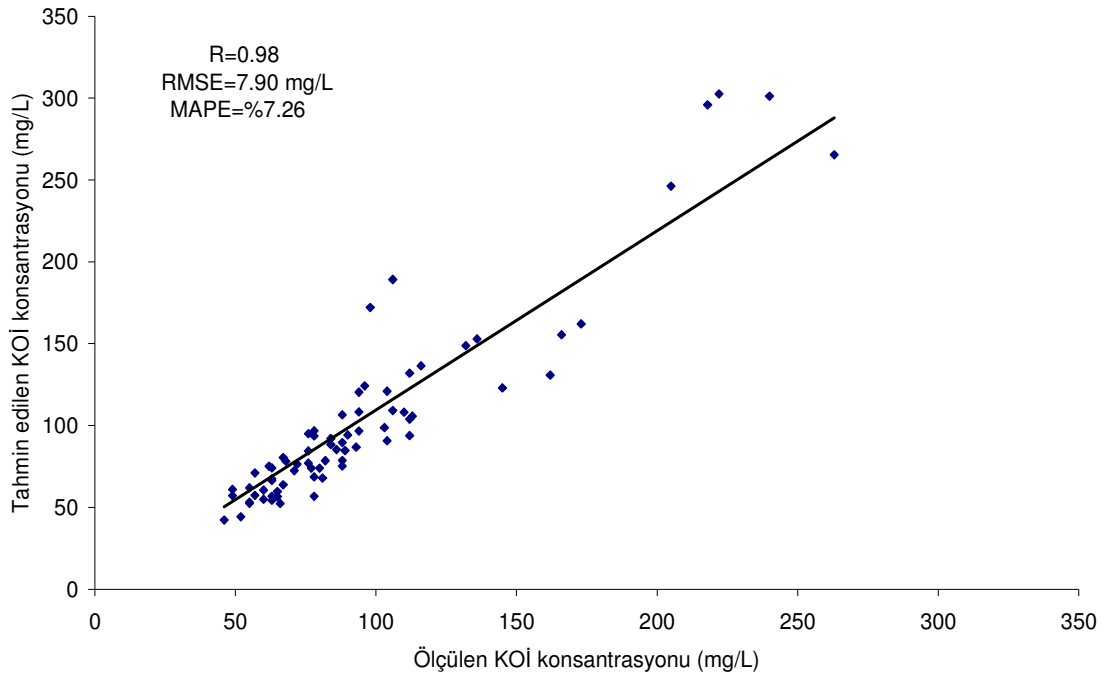


(C)


Şekil 4.8. PCA sonrası geliştirilen KOİ (A),  $\text{NH}_4\text{-N}$  (B) ve TN (C) modellerine ait eğitim ve test hata dağılımları

Daha önce de belirtildiği gibi ilk aşamada kurulan ve çalıştırılan ANFIS modelleri gerek eğitim, gerekse test aşamasında oldukça değişken hata dağılımına sahip olmakla birlikte, bu durum yeni kurulan modellerde tespit edilmemiş, eğitilen ve test edilen modellerin düzgün hata eğilimlerine sahip oldukları gözlenmiştir.


$\text{NH}_4\text{-N}$  modelinde ölçülen ve tahmin edilen test verilerinin %92'lik kısmı 0-1.5 mg/L aralığında bulunmaktadır. Bu nedenle Şekil 4.9'da daha net yorum yapılabilmesi için ölçülen ve tahmin edilen 6 adet  $\text{NH}_4\text{-N}_{\text{çıktı}}$  verisi (>28 mg/L) grafiğe dahil edilmemiştir. Fakat bu 6 veri, grafik üzerinde belirtilen R, RMSE ve MAPE parametrelerinin hesaplanması sırasında kullanılmıştır. Şekil 4.9'dan görüleceği üzere, gelişigüzel seçilen test verileri ile gerçekleştirilen modelleme sonucunda  $\text{NH}_4\text{-N}$  modeli dışında, ölçülen ve tahmin edilen veriler yüksek oranda uygunluk göstermektedir.



(A)



(B)



(C)

Şekil 4.9. KOİ (A), NH<sub>4</sub>-N (B) ve TN (C) modellerinin test aşamalarında ölçülen ve tahmin edilen hedef çıktı değişkenlerine ait dağılım diyagramı

Yukarıda belirtildiği üzere NH<sub>4</sub>-N modeline ait veri setinin diğer ANFIS modellerindeki veri setlerinin aksine belirli ve düşük aralıklarda yoğunlaşması, elde edilen yüksek korelasyona karşın dağınık bir dağılım diyagramı elde edilmesinin nedeni olabileceği düşünülmektedir. Ayrıca, NH<sub>4</sub>-N modelindeki test verilerine ait tahminlerin dağınıklığı, hata oranını da artırmış ve modelin tahmin kapasitesini azaltmıştır. NH<sub>4</sub>-N modelindeki kadar olmamakla birlikte KOİ ve TN modellerinde de ölçülen ve tahmin edilen test verileri arasında kısmi sapmalar gözlenmektedir. Bunun nedeninin de arıtma tesisinde KOİ<sub>çıktı</sub> ve TN<sub>çıktı</sub> konsantrasyonlarında işletme koşullarına göre gerçekleşen farklılıklar ve dalgalanmalar olduğu tahmin edilmektedir.

Bu çalışmanın son aşamasını ANFIS algoritmasının içerisinde bulunan fonksiyon değişkenlerinin model performansına olan etkisinin araştırılması oluşturmaktadır. Sugeno tip sistemler ve bu sistemlere ait uyarlanabilir ağlar çalışma kapsamı da göz önünde bulundurulurken ele alınmamıştır. Daha önce de belirtildiği üzere ANFIS, protatip bir bulanık mantık çıkarım sistemi ile işleme başlamakta ve bu aşamada



eksiltmeli gruplandırma algoritması (*genfis2* fonksiyonu) ile bu çıkarım sistemi içerisindeki veri grupları ve veri grup merkezleri tespit edilmektedir. Ayrıca *genfis2* fonksiyonu başlangıç değerleri 0.5 ve 1.25 olan sırasıyla *radii* ve *quashfactor* vektörleri içermektedir. Belirtilen amaç doğrultusunda, ANFIS model algoritmasındaki *radii* ve *quashfactor* 0.05'lik artışlar ile sırasıyla 0.1-1.0 ve 0.1-1.5 değerleri arasında değiştirilmiştir. Tanımlanan veri aralıkları dışında ANFIS algoritması protatip FIS sistemini oluşturamamaktadır. Bunun nedeni, adaptif ağ içerisindeki toplam ağırlık çarpanının sıfır olması ve algoritmanın birden fazla kural üretememesidir. ANFIS tekniğinde model çözümlemesi için, sistemde en az iki kuralın oluşturulması gerekmektedir. Çalıştırılan tüm ANFIS modellerinde adı geçen algoritma değişken vektörlerinin düşük değerlerinde, bulanık mantık kuralları ters orantılı olarak artmaktadır. Düşük algoritma vektörleri, çok fazla veri grubu oluşmasına, veri grubu merkezlerinin ve birbirileri arasındaki uzaklık (komşuluğun) derecesinin azalmasına dolayısıyla da kural sayısındaki artışa neden olmaktadır. Bu durumun tam tersi de geçerlidir. Bu durum model performanslarını olumsuz olarak etkilemiştir. Ayrıca ANFIS algoritmasında veri gruplandırma fonksiyon vektörlerinin değişimi ile herhangi bir düzgün azalan ya da artan performans değişikliği gözlenmemiştir. Yalnızca, *radii* vektörünün 0.5'ten 0.6'ya yükselmesi ile KOİ modelinde RMSE cinsinden hata %6 oranında azalmış, R katsayısı ise sabit kalmıştır. Sonuç olarak *genfis2* fonksiyonlarına ait başlangıç orijinal değerlerinin bu çalışma kapsamında ANFIS modellerinin performansında düzenli bir değişikliğe neden olmadığı tespit edilmiştir. Fakat bu durum, başka çalışmalar için de benzer şekilde araştırılmalıdır.

Bu çalışma kapsamında modelleme sonuçları, mükemmel derecede olmasa da, ANFIS algoritmasının, atıksu arıtma tesisine ait hedef çıktı parametrelerini, kısmen düşük RMSE ve MAPE hata değerleri ile yüksek R katsayılarında tahmin edebildiğini göstermiştir. Bu durumun, atıksu arıtma tesisi içerisindeki değişken sayısının fazlalığı ve yüksek derecede kompleks yapıya sahip biyolojik aktif çamur prosesi dikkate alındığında oldukça önemli olduğu düşünülmektedir.

### 4.3. Kentsel Atıksu Arıtma Tesisi Performansının Yapay Zeka Yöntemleri ile Modellenmesi

Biyolojik atıksu arıtma tesisleri için geliştirilen matematiksel modeller (ASM1, ASM2, ASM2d, ASM3 ve TUDP), sistem işletimini kontrol ve simüle etmek açısından kullanışlıdır. Bu matematiksel modeller deterministik veya beyaz kutu (white box) modelleri olarak adlandırılmakta ve mühendislik prensipleri doğrultusunda, kütle veya bileşen dengesi eşitliklerinin uygulanması sonucu elde edilen diferansiyel denklemler şeklinde ifade edilmektedir (Hong vd., 2003). Fakat bununla birlikte sistemde, biyolojik mekanizmayı matematiksel olarak tanımlamak kompleks olup, fazla sayıda stokiyometrik ve kinetik parametre değişkenleri sebebiyle çok etkin olamamaktadır. Ayrıca işletilen atıksu arıtma tesislerinde birçok fiziksel ve biyokimyasal parametrelerin analitik ölçümü zor, pahalı ve zaman alıcıdır. Dolayısıyla, biyolojik mekanizmanın tam olarak tanımlanamaması halinde, deterministik modeller geçerliliğini kaybetmekte ya da proses eksik tanımlanmaktadır (Teppola vd., 1997; Mujunen vd., 1998; Gregersen ve Jørgensen, 1999)

Kara kutu (black box) olarak adlandırılan ve sadece sistemdeki girdi-çıkı parametrelerini dikkate alan modellerde ise parametre tahmininde fiziksel, kimyasal ya da biyolojik özellikler dikkate alınmamaktadır. Sistem ya da prosesin geçmiş verilerine dayanarak girdi-çıkı değişkenlerine göre oluşturulan modelleme ve kontrol teknikleri yapay zeka sistemleri olarak adlandırılmaktadır (Hong vd., 2003). Yapay zeka (YZ); düşünme, anlama, kavrama, yorumlama ve öğrenme yapılarının programlamayla taklit edilerek problemlerin çözümüne uygulanması olarak ifade edilebilir. Yapay zeka teknolojileri özetle uzman sistemler, yapay sinir ağları (ANN), genetik algoritmalar (GA), bulanık önermeler mantığı (FL) ve zeki etmenler (ZE) olarak adlandırılmaktadır. Son yıllarda bu teknikler içerisinde en çok yapay sinir ağları ve bulanık önermeler mantığı yöntemleri çevre mühendisliği disiplinde uygulama alanları bulmaktadır (Cortés vd., 2000).

Yapay sinir ağıları, gerçek beyin fonksiyonlarının ürünü olan örnekleri kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı nasıl tepkiler üretebileceğini belirleyebilen bilgisayar sistemleridir (Çınar, 2005). İnsan beyninin fonksiyonel özelliklerine benzer olarak, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadır. Bulanık mantık kavramı, belirsizliklerin anlatımı ve belirsizliklerle çalışabilmeyi mümkün kılan bir matematiksel düzen olarak tanımlanmaktadır (Sugeno ve Kang, 1986). ANN ve FL; dinamik, doğrusal olmayan ve tam olarak karakterize edilememiş sistemlerin tanımlanmasında ve değerlendirilmesinde kullanılan modelleme yaklaşımlarıdır (Perendeci vd., 2004). Bulanık çıkarım sisteminin insan mantığına uyarlanmış belirgin bilgi işleme gücünü ve yapay sinir ağlarının güçlü öğrenme algoritmasını bir arada barındıran hibrit yapıya adaptif ağ temelli bulanık çıkarım sistemi (ANFIS, Adaptive Network based Fuzzy Inference System) adı verilmektedir (Jang, 1993).

Tezin üçüncü bölümünün temel amacı; hem ANN hem de ANFIS model yaklaşımı kullanılarak, atıksu arıtma tesisi aerobik biyolojik sürece ait hedef çıktı değişkeninin, aynı tesise ait geçmiş verilerle tanımlanması ve bu verilerle eğitilmesi ile daha hızlı ve güvenilir olarak tahmin edilmesinin araştırılmasıdır. Çalışma kapsamında esas olarak İstanbul Su ve Kanalizasyon İdaresi (İSKİ) Tuzla Kentsel Atıksu Arıtma Tesisi'ne ait 2003 yılı (1 yıllık) işletim verileri kullanılmıştır. Tesis genel hatları ile bir giriş yapısı, kum tutucu, ön çökeltim tankı, havalandırma tankı ve son çökeltim tankından oluşmakta ve klasik aerobik aktif çamur prosesi ile işletilmektedir. Çalışmada birbirinden bağımsız ANN ve ANFIS model yapıları kurularak, tesis KOİ çıkış değişkeninin tahmin edilmesi hedeflenmiştir. Kurulan KOİ tahmin modelleri için kullanılan tesis atıksu verileri Çizelge 4.8'de sunulmuştur.

Çizelge 4.8. Tuzla Kentsel AAT modellemesinde kullanılan atıksu verileri

Atıksu Parametreleri	Minimum	Ortalama	Maksimum
$Q_{girdi}$ (m <sup>3</sup> /gün)	12780	170048	287100
TAKM <sub>girdi</sub> (mg/L)	90	599	4940
KOI <sub>kum</sub> (mg/L)	110	690	4360
L <sub>KOI</sub> (kg/gün)	11183	110080	637432
İletkenlik <sub>kum</sub> (mS/cm)	2.3	9	15
pH <sub>kum</sub>	4.1	8	9.8
Sıcaklık <sub>kum</sub> (°C)	10	19	27.2
KOI <sub>çıktı</sub> (mg/L)	10	68	97

$Q_{girdi}$ : Atıksu giriş debisi, TAKM<sub>girdi</sub>: Tesis girişindeki toplam askıda katı madde, KOI<sub>kum</sub>: Kum tutucu tankı çıkışı kimyasal oksijen ihtiyacı, L<sub>KOI</sub>: Tesis girişi KOİ yükü

ANFIS ve ANN algoritmaları sırasıyla, MATLAB R14 (MathWorks, Inc.) yazılımı içerisinde bulunan Fuzzy Logic Toolbox ve Artificial Neural Network Toolbox kullanılarak çalıştırılmıştır. ANFIS modelleme çalışmasında, girdi ve çıktı değişkenleri sayısal aralıkları xbounds fonksiyonu ile normalize edilmiştir. ANN modelinde ise girdi ve çıktı değişkenleri aşağıdaki eşitlik kullanılarak normalize edilmiş, sonuç verileri de yine aynı eşitlik kullanılarak gerçek verilere dönüştürülmüştür.

$$x_{i,norm} = \frac{x_i - x_{i,min}}{x_{i,max} - x_{i,min}} \quad (4.4)$$

Eşitlikte  $x_i$ , değişkenin gerçek değerini;  $x_{i,norm}$ , normalize edilmiş veriyi;  $x_{i,max}$  ve  $x_{i,min}$  ise sırasıyla veri setindeki maksimum ve minimum veri değerini ifade etmektedir. Her iki model için eğitim ve test aşamalarında kullanılan veriler veri tabanından rastgele seçilmişlerdir. Tesiste bir yıl boyunca ölçülen işletme parametreleri içerisinde seçilen toplam 167 verinin yaklaşık % 70'i (116) eğitimde, geri kalan % 30'u (51) ise modellerin doğrulanması aşamasında kullanılmıştır. MATLAB R14'de yazılan her iki modele ait script dosyalarının çalıştırılması ile sistem çıktı değişkenleri tahmin edilmiş ve modellerin doğruluğu test verileri ile denetlenmiştir.

ANFIS ve ANN model performansları, ölçülen ve tahmin edilen çıktı değişkenleri arasındaki karesel hata karekökü (RMSE) ve ortalama mutlak hata (MAPE Mean Absolute Percentage Error) ile korelasyon katsayısı (R) hesaplanarak değerlendirilmiştir. Çalışmada kullanılan hata eşitlikleri aşağıda verilmiştir.

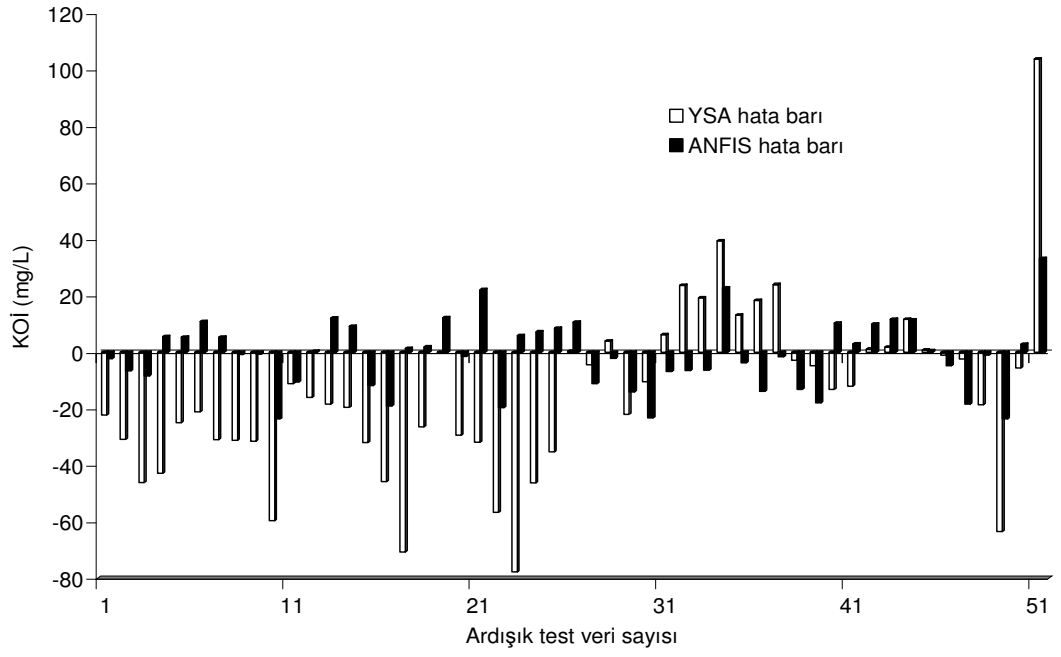
$$RMSE = \sqrt{\frac{\sum_1^N (x_i - y_i)^2}{N}} \quad (4.5)$$

$$RMSE (\%) = \frac{RMSE}{x_{i,ortalama}} \cdot 100 \quad (4.6)$$

$$MAPE (\%) = \frac{1}{N} \cdot \left( \sum_1^N \left[ \left| \frac{x_i - y_i}{x_i} \right| \right] \right) \cdot 100 \quad (4.7)$$


Eşitliklerde tanımlanan  $x_{i,ortalama}$  veri setinin ortalama değerini;  $x_i$  ve  $y_i$  sırasıyla ölçülen ve model sonucunda tahmin edilen çıktı değişkenlerini;  $N$  ise veri adedini göstermektedir.

Kurulan ANN ve ANFIS modellerinde KOİ için elde edilen korelasyon katsayıları sırasıyla 0.85 ve 0.98 olarak tespit edilmiştir. ANN ve ANFIS modellerinde elde edilen RMSE hata değerleri sırasıyla 33.5 mg/L (%19.1) ve 12.3 mg/L (%7.0); MAPE hata değerleri ise yine sırasıyla, %17.1 ve %5.8 olarak hesaplanmıştır. Her iki modelin test verileri üzerinde elde edilen hata değerlerine ait diyagram Şekil 4.10'da verilmiştir.



Şekil 4.10. ANN ve ANFIS modellerinde KOİ çıkış değışkeni için hata barı diyagramı

ANN ve ANFIS modellerinde KOİ çıkış değışkeninin tahmin edilen değeri ile ölçülen değeri zamanla değışimleri Şekil 4.11’de verilmiştir.



Şekil 4.11. ANN ve ANFIS modellerinde KOİ çıkış değişkeninin tahmin edilen ve ölçülen değerlerinin zamanla değişimi

Kurulan ANN ve ANFIS modellerinin doğruluğu, test verileri için elde edilen düşük RMSE ve MAPE hata değerleri ve yüksek korelasyon katsayısı değerleri ile kanıtlanmıştır. Elde edilen sonuçlar, ANFIS algoritmasının girdi ve çıktı değişkenleri arasındaki ilişkiyi daha iyi bir şekilde tanımladığını ve çıktı değişkenlerinin yüksek doğrulukla tahmin edildiğini ortaya koymaktadır.

Tuzla kentsel atıksu arıtma tesisi için gerçekleştirilen modelleme çalışması sonucunda, ANFIS yaklaşımının tesis KOİ giderim performansının değerlendirilmesinde ANN yaklaşımından daha tatmin edici sonuçlar verdiği bulunmuştur. Ayrıca, ANFIS model algoritmasının tesis işletme koşullarını ANN algoritmasına göre daha iyi tanımladığı gözlenmiştir. ANFIS modelleri eş zamanlı tesis kontrollerinde uygulama potansiyeline sahiptir.

Atıksu arıtma tesislerinin yapay zeka yöntemleri ile modellenmesi son yıllarda hız kazanmıştır. Yapay zeka yöntemleri tek başına veya hibrit olarak; tesis içi gerçekleşmesi muhtemel sorunları önceden tahmin etmek veya ortaya çıkan problemlere anında müdahale ederek, karar verme mekanizmasını kuvvetlendirmek

ve maliyetleri minimize etmek için kullanılabilir. Bu yöntemlerle, seçilen hedef değişkenlerin tahmini kolaylıkla yapılabilir.

ANFIS modelleme yaklaşımı ANN metodu ile karşılaştırıldığında kural tabanlı bir eğitim algoritması olduğu için, aerobik atıksu arıtma tesislerinde mevcut sensör, otomasyon sistemleri ve operator deneyimleriyle desteklenerek daha sağlam ve güvenilir denetleyici kontrol sistemlerine dahil edilebilir.



#### **4.4. Evsel Atıksu Arıtma Tesisinde Karbon Gideriminin Yapay Sinir Ağları ve Adaptif Ağ Temelli Bulanık Çıkarım Sistemi ile Modellenmesi**

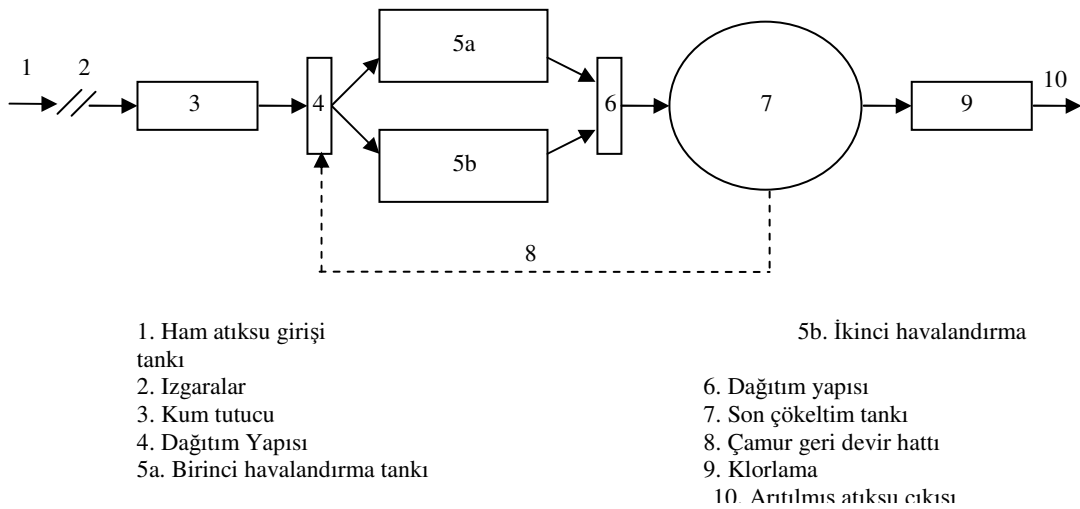
Atıksu arıtma tesislerinin işletilmesi ve tesis içi proses kontrolü, biyolojik aktif çamur prosesindeki kompleks etkileşimler ve zamana bağlı değişken hidrolik koşullar nedeniyle oldukça güçtür. Son yirmi yıldır, arıtma proseslerindeki mikrobiyolojik (biyokütle) aktiviteleri tanımlamaya yönelik olarak aktif çamur kütle dengesi modelleri (ASM1, ASM2, ASM2d, ASM3, ASM3-BioP, TUDP) gibi deterministik yaklaşımlar geliştirilmiştir (Henze vd., 1987; Henze vd., 1995; Gujer vd., 1999; van Veldhuizen vd., 1999; Brdjanovic vd., 2000). Bu matematiksel modellerdeki yaklaşımlar temel mühendislik prensiplerine dayandırıldığı için bu tür modeller, atıksu arıtma tesisleri içerisindeki karbon ve azot giderimini tahmin etmede oldukça etkili olabilmektedir (Gernaey vd., 2004). Bununla birlikte geliştirilen modellerin boyutunun yüksek olması, prosese ait kinetik ve stokiyometrik parametrelerin oldukça fazla olması ve bu parametrelere ait bilgilerin tesis içerisinde spesifik tesis, laboratuvar veya işletim bilgileri ile elde ediliyor olması nedeniyle, modellerin kullanışlığı bir çok pratik uygulama için sınırlı düzeyde kalmaktadır. Ayrıca aktif çamur modelleri, çökeltme gibi diğer arıtma tesisi işlem ya da proseslerine ait yaklaşımları barındırmadığı takdirde genel tesis performansının değerlendirilmesi verimli olamayabilmektedir (Yoo vd., 2003; Gernaey vd., 2004).

Son yıllarda çevre mühendisliği pratik uygulamalarında karar verme mekanizmasına yönelik olarak yapay zeka metotları oldukça sık kullanılmaya başlanmıştır (Rizzoli ve Young, 1997; Olsson ve Newell, 1999; Corte's vd., 2000; Gernaey vd., 2004; Perendeci vd., 2004; Çinar, 2005). Yapay sinir ağları (ANN), genetik algoritma (GA), bulanık mantık (FL), kural tabanlı sistemler, bilgi tabanlı uzman sistemler ve adaptif ağ temelli bulanık çıkarım sistemi (ANFIS) gibi bahsedilen metotların bütünleşik yapı uygulamaları da yapay zeka metotları içerisinde değerlendirilmektedir. ANFIS tipik bir bulanık sinir sistemi olup, beş tabakalı ileri beslemeli ağ ile Takagi-Sugeno (Takagi ve Sugeno 1983, 1985; Sugeno ve Kang 1986) bulanık çıkarım yaklaşımını içeren bir yapay zeka algoritmasıdır. Sistem

içerisindeki ANN kısmında ise ileri beslemeli geri yayımlı algoritma kullanılmaktadır.

Tezin dördüncü bölümünün temel amacı tam ölçekli bir biyolojik atıksu arıtma tesisi performansının ANN ve ANFIS yapay zeka modelleme tekniklerinin temel bileşenler analizi (PCA) kullanılarak karşılaştırmalı olarak değerlendirilmesidir. Bu amaç doğrultusunda tesisteki organik karbon giderimini temsil etmek için KOİ çıktı parametresi, iki model yaklaşımı için de model çıktı değişkeni olarak belirlenmiştir. Temel olarak karbon gideriminin tahmin edilmesi amaçlandığı için, tesis azot girdi ve çıktı parametreleri çalışma kapsamında değerlendirilmemiştir.

Model karakterizasyonu için Yunanistan'ın Girit Adası Hanya Şehri evsel atıksu arıtma tesisi verileri kullanılmıştır. Tesiste karbonlu organik madde ve askıda katı madde gideriminin gerçekleştiği birincil ve ikincil arıtma (aktif çamur prosesi) prosesleri mevcuttur (Şekil 4.12). Ayrıca, tesis verileri göz önünde bulundurularak, amonyum azotunun da nitrifikasyon prosesi ile sistemden uzaklaştırıldığı gözlenmiştir. Fakat daha önce de belirtildiği üzere, tesis içerisinde azot giderimi performansının modellenmesi bu çalışma kapsamında değerlendirilmemiştir.



Şekil 4.12. Hanya atıksu arıtma tesisi proses akış diyagramı

Atıksu arıtma tesisi havalandırma tankı veri kayıtları, atıksu ve çamur kalite parametrelerine ait analitik ölçümleri ile anlık sensör (algılayıcı) sinyallerini (havalandırma tankı içerisinde pH, sıcaklık ve çözünmüş oksijen) içermektedir.

ANN ve ANFIS model yapılarının oluşturulması için ilk olarak günlük ölçülen parametreler içerisinde girdi ve çıktı değişkenleri belirlenmiştir. Bu aşamayı takiben kayıp ya da eksik ölçüm verileri model matrisinden ayıklanmıştır. Elde edilen nihai veri matrisi (girdi ve çıktı) 2001-2003 yılları arasında ölçülen 200 ardışık günlük veriyi içermektedir. Her iki model yapısına ait ölçülen ve hesaplanan model parametrelerinin temel istatistiksel değerleri ile parametre ölçüm noktaları Çizelge 4.9'da verilmiştir.

Çizelge 4.9. ANN ve ANFIS modelleri için kullanılan Hanya atıksu arıtma tesisi verileri

No	Parametreler	Minimum	Maksimum	Ortalama	Std. Sapma
X <sub>1</sub>	Q <sub>girdi</sub> (m <sup>3</sup> /gün)	13422	19712	16965	1517
X <sub>2</sub>	AKM <sub>kum</sub> (mg/L)	76	970	244	115
X <sub>3</sub>	KOİ <sub>kum</sub> (mg/L)	216	1925	592	179
X <sub>4</sub>	KOİ <sub>aerobik yük</sub> (kg/gün)	3075	29707	10016	2882
X <sub>5</sub>	TAKM <sub>a,b</sub> (mg/L)	3568	9745	6518	1184
X <sub>6</sub>	UAKM <sub>a,b</sub> (mg/L)	2440	7300	4646	843
X <sub>7</sub>	(UAKM/TAKM) <sub>a,b</sub>	0.67	0.76	0.71	0.03
X <sub>8</sub>	TAKM <sub>geri devir</sub> (mg/L)	6640	17190	11093	1929
X <sub>9</sub>	ÇO <sub>a,b</sub> (mg/L)	1.69	6.80	3.55	0.87
X <sub>10</sub>	(F/M) <sub>a,b</sub> (kg KOİ/kg UAKM.gün)	0.07	0.44	0.20	0.06
Y	KOİ <sub>çıktı</sub> (mg/L)	0	170	28	24.08

Q<sub>girdi</sub>: Ham atıksu girişi, AKM<sub>kum</sub>: Kum tutucu çıkışı askıda katı madde konsantrasyonu, KOİ<sub>kum</sub>: Kum tutucu çıkışı kimyasal oksijen ihtiyacı konsantrasyonu, KOİ<sub>aerobik yük</sub>: Kum tutucu çıkışı, havalandırma tankı girişi kimyasal oksijen ihtiyacı yükü (Q<sub>girdi</sub>\*KOİ<sub>kum</sub>), TAKM<sub>a,b</sub>: Birinci ve ikinci havalandırma tankı ortalama toplam askıda katı madde (MLSS) konsantrasyonu, UAKM<sub>a,b</sub>: Birinci ve ikinci havalandırma tankı ortalama uçucu askıda katı madde (MLVSS) konsantrasyonu, (UAKM/TAKM)<sub>a,b</sub>: Birinci ve ikinci havalandırma tankı ortalama organik çamur oranı, TAKM<sub>geri devir</sub>: Geri devir hattı çamur konsantrasyonu, ÇO<sub>a,b</sub>: Birinci ve ikinci havalandırma tankı ortalama çözünmüş oksijen konsantrasyonu, (F/M)<sub>a,b</sub>: Birinci ve ikinci havalandırma tankı ortalama F/M oranı, KOİ<sub>çıktı</sub>: Arıtılmış atıksu çıkışı kimyasal oksijen ihtiyacı konsantrasyonu

Bazı parametreler [( $KOI_{\text{aerobik yük}}$ , ( $UAKM/TAKM$ )<sub>a,b</sub> ve ( $F/M$ )<sub>a,b</sub>] model içerisinde aerobik prosesin daha iyi temsil edilebilmesi için yeniden hesaplanarak model girdi matrisine dahil edilmiştir.  $KOI_{\text{aerobik yük}}$  ve ( $UAKM/TAKM$ )<sub>a,b</sub> parametrelerinin hesaplanmasına ait açıklamalar Çizelge 4.9 altında verilmiştir. ( $F/M$ )<sub>a,b</sub> parametresi ise aşağıdaki eşitlik yardımıyla hesaplanmıştır:

$$(F/M)_{a,b} = \frac{KOI_{\text{aerobik yük}}}{TAKM_{a,b} \cdot V_{\text{aerobik}}} \quad (4.8)$$

Eşitlik 4.8’de ifade edilen  $V_{\text{aerobik}}$  (7900 m<sup>3</sup>) parametresi, birinci ve ikinci havalandırma tankı reaktör hacmini tanımlamaktadır.

ANN ve ANFIS algoritmaları MATLAB R14 (MathWorks Inc.) yazılım içerisinde bulunan “Neural Network” ve “Fuzzy Logic” araçları ile çalıştırılmıştır. Model parametreleri değişken birim yapısına sahip olmalarından dolayı, her iki model için de normalizasyon işlemleri gerçekleştirilmiştir. PCA kapsamında veriler, istatistiksel bir yazılım olan SPSS 9.0 programında bulunan faktör analiz aracı kullanılarak değerlendirilmiştir.

ANN modelinde girdi ve çıktı veri setinin normalizasyonu işleminde belirlenen eğitim veri setinin ortalama ve standart sapma değerleri kullanılmıştır. Bu prosedürde *prestd* fonksiyonu kullanılmıştır. Benzer amaçla fakat farklı bir metot kullanılarak, aynı veri seti ANFIS modeli içerisinde normalizasyon işlemine tabi tutulmuştur. Bu amaçla, ANFIS veri setinde her parametrenin alabileceği olası sınır uç değerleri tahmin edilerek *xbounds* fonksiyonu kullanılarak normalizasyon işlemi tamamlanmıştır. Her iki modelleme çalışmasında da toplam veri adedinin 140 günlük kısmı (%70) eğitim, kalan 60 günlük kısmı da (%30) test aşamalarında kullanılmıştır. Model eğitim ve test veri setleri, toplam veri seti içerisinde rastgele seçilmiştir. ANFIS modelleme yaklaşımında başlangıç bulanık çıkarım sistemi prototipi ile veri gruplarını tespit etmek için eksiltmeli veri gruplandırma yöntemi kullanılmıştır. ANFIS hesap algoritması içerisinde bu yöntem *genfis2* fonksiyonu ile temsil edilmiştir. Daha sonra başlangıç bulanık çıkarım sistemi prototipi algoritma

değişkenleri ile optimize edilmiştir. Tüm veri grupları için yarıçap (cluster radius) 0.5 olarak seçilmiştir.

Derecelendirilen ve optimize edilen model yapıları en iyi eğitim sonucunun elde edilebilmesi için 100 ila 1000 adım arasında iterasyon işlemine tabi tutulmuştur. Daha sonra modeller orijinal veritabanından rastgele olarak seçilen test veri seti ile aynı işleme tabi tutulmuştur. Bu aşamada elde edilen ANN ve ANFIS model tahmin sonuçları, ölçülen orijinal test verileri ile karşılaştırılmıştır. Her iki model için de eğitim ve test aşaması için tahmin performansları hesaplanmıştır. Ölçülen ve model tarafından tahmin edilen veriler arasındaki yakınlık temel alınarak gerçekleştirilen model tahmin performansı hesaplarında korelasyon katsayısı (R), ortalama karesel hata karekökü (RMSE) ve ortalama oransal hata (MAPE) kriterleri kullanılmıştır.

Daha önce de belirtildiği üzere ANN ve ANFIS modelleme yaklaşımları için kullanılan girdi ve çıktı veri matrisi aynıdır (Çizelge 4.9). Bu çalışma için kullanılan veriler günlük olarak ölçülen değerler ile ifade edilmiştir. Bu veriler her ne kadar zaman serileri gibi gözükmele birlikte ARIMA [(Autoregressive Integrated Moving Average), (Oto regresif Bütünleşik Hareketli Ortalama )] ve transfer fonksiyonu gibi zaman serisi metotları ile analiz edilemezler. Bunun en önemli nedeni atıksu arıtma tesisinde alınan numune aralığının (1 gün) zaman olarak çok uzun olmasıdır. Yapay zeka metotlarının tam ölçekli atıksu arıtma tesisi performansının değerlendirilmesi aşamasında karşılaştırılması için üç farklı metot kullanılmıştır. Bu metotlar yapay sinir ağları (ANN), adaptif ağ temelli bulanık çıkarım sistemi (ANFIS) ve temel bileşenler analizidir (PCA). Çalışmada yapay zeka metotlarının tahmin kapasitesinin incelenmesi, girdi matrisinin boyutunun azaltılması ile birlikte değerlendirilmiştir. Çizelge 4.9'dan da görüleceği üzere her iki model yaklaşımı için 11 atıksu kalite parametresi arasından KOİ parametresi (Y) model çıktı değişkeni olarak seçilmiş, geri kalan 10 parametre de ( $X_1-X_{10}$ ) girdi matrisini oluşturmuştur.

Seçilen veri matrisi, PCA metodu uygulanmadan ilk olarak ANN modeli içerisinde değerlendirilmiştir. ANN modelinde gizli katman ve gizli katman içerisinde bulunacak nöron sayıları deneme ve yanılma yoluyla tespit edilmiştir. Bununla

birlikte, ANN modellemesi boyunca gizli katman ve gizli katmana ait nöron sayısının model sonuçlarını önemli oranda etkilemediği gözlenmiştir. Çizelge 4.10'dan da görüleceği üzere 15 nörona sahip tek bir gizli katman yapısı belirlenmiş ve model ağı bir çok iterasyon adımı (maksimum 1000 adım) eğitilmiştir. Bu aşamada 500 adımın iterasyon aralıkları için belirlenen minimum hataya ulaşmada yeterli olduğu tespit edilmiştir. Sonuç model ağı, gerek eğitim aşamasında gerekse test aşamasında tesis çıkış KOİ değerini oldukça iyi tahmin etmektedir. ANN modelinin tahmin performans kriterleri eğitim ve test aşamaları için sırasıyla RMSE 2.23 mg/L ve 2.30 mg/L; MAPE %6.86 ve %7.79; R değeri ise 0.98 ve 0.97 olarak tespit edilmiştir. Hesaplanan korelasyon katsayılarından da anlaşılacağı üzere, ANN modeli ile eğitim ve test aşamalarındaki toplam veri dağılımının %98 oranında tahmin edilebildiği belirlenmiştir.

Çalışmanın ikinci adımını hibrit yapay zeka algoritmasını (neuro-fuzzy algoritması) içeren ANFIS yaklaşımının tahmin kapasitesinin araştırılması oluşturmaktadır. ANN modeline benzer olarak 200 ardışık veri, 147 eğitim verisi ve 60 test verisi olarak ayrılmıştır. Veri yapısını oluşturduktan sonra hibrit yapay zeka algoritması çalıştırılmış ve ANFIS sistemi tarafından otomatik olarak 18 bulanık çıkarım kuralı (FIS kuralı) oluşturulmuştur (Çizelge 4.10). Eğitim prosesinden sonra RMSE, MAPE ve R değerleri sırasıyla 0.45 mg/L, %1.21 ve 0.99 olarak hesaplanmıştır.

Çizelge 4.10 Hedef çıktı parametresinin belirlenebilmesi amacıyla yönelik veri analiz metotları

Metotlar	Metot İçerikleri
ANN	10 girdi, 1 gizli katman (15 nöron) ve 1 çıktı, geri yayımlı algoritma
ANFIS	10 girdi, 18 FIS kuralı ve 1 çıktı, geri yayımlı algoritma
PCA	10 girdi 3 temel bileşene indirilmiştir
ANN+PCA	3 girdi, 1 gizli katman (5 nöron) ve 1 çıktı
ANFIS+PCA	3 girdi, 9 FIS kuralı ve 1 çıktı

Elde edilen yüksek eğitim performans değerlerinin ardından test verileri doğrulama aşamasında kullanılmıştır. Sonuç ANFIS model performansı ise RMSE, MAPE ve R olarak sırasıyla 2.09 mg/L, %6.51 ve 0.97 olarak hesaplanmıştır. Elde edilen bu değerler arasından RMSE değeri için her iki modelin karşılaştırılması yapılacak olursa, 'ANFIS model algoritması ANN hesap algoritmasına göre eğitim aşamasında

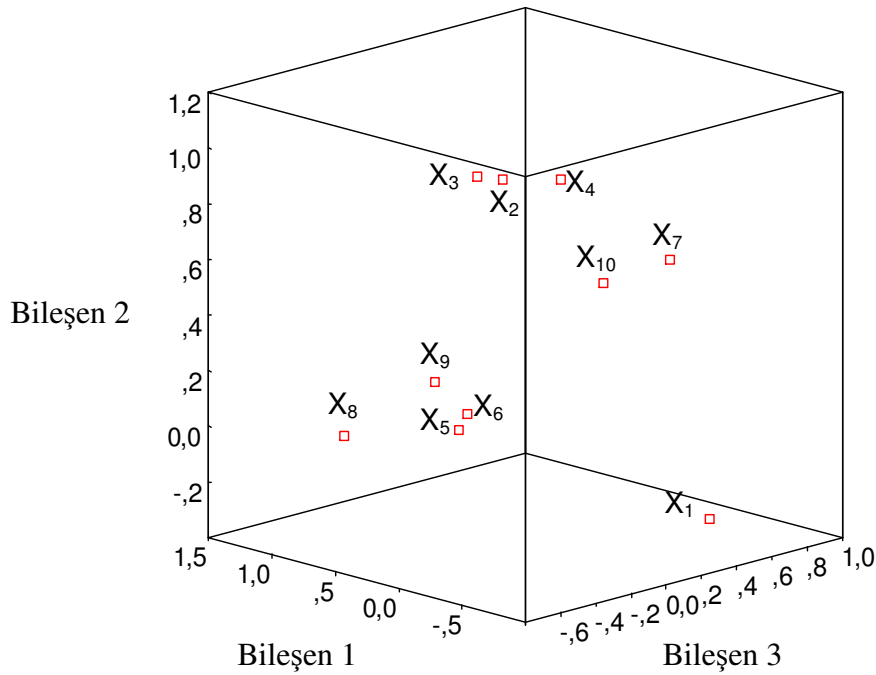
5 kat daha iyi KOİ tahmini yapmıştır' denebilmektedir. ANN ve ANFIS model algoritmalarında test aşamalarındaki RMSE değerleri ise yaklaşık olarak aynıdır. Dolayısıyla biyolojik arıtma sistemindeki parametrelerin kompleks yapısı dikkate alındığında iki model yaklaşımının da oldukça iyi sonuçlar verdiği söylenebilmektedir.

Bir tahmin modelinde bilindiği üzere en kritik noktalardan biri de model girdi parametrelerinin belirlenmesidir. Bu noktada en önemli husus, belirlenen parametrelerin hedef çıktı değişkenini tahmin etmede ne kadar temsil edici olduğudur. Özellikle, atıksu arıtma tesisi gibi bir çok kompleks proses barındıran bütünlük sistemlerde hedef çıktı değişkeninin hızlı ve pratik olarak ölçülebilen parametreler ile tahmini büyük kolaylıklar sağlamaktadır. Bu nedenlerle, Çizelge 4.9'da tespit edilen girdi parametrelerinin azaltılması ve temsil edici boyutunun incelenmesi amacıyla veri analiz yöntemlerinden biri olan PCA metodu çalışmada uygulanmıştır. ANN ve ANFIS modelleri için aynı girdi matrisi kullanıldığı için tek bir PCA yaklaşımı ele alınmıştır. Bu yaklaşım ile Çizelge 4.11'den görüleceği üzere 10 girdi parametresine ait toplam verilerin dağılımının (varyansın) %94'ü 3 temel bileşenle (PC) ifade edilmiştir.

Çizelge 4.11. Girdi veri matrisinde temel bileşenler olarak ifade edilen proses değişken dağılımları

Bileşen	Başlangıç Eigenvalue Değerleri			Karesel Toplamı Alınmış Yük Faktörleri		
	Toplam	Varyans (%)	Kümülatif (%)	Toplam	Varyans (%)	Kümülatif (%)
1	4.78	47.83	47.83	4.78	47.83	47.83
2	3.39	33.94	81.77	3.39	33.94	81.77
3	1.28	12.85	94.62	1.28	12.85	94.62
4	2.76E-01	2.75	97.38			
5	1.63E-01	1.63	99.01			
6	6.09E-02	6.09E-01	99.62			
7	2.69E-02	2.70E-01	99.89			
8	9.65E-03	9.65E-02	99.99			
9	5.30E-04	5.30E-03	99.99			
10	2.53E-04	2.53E-03	100.00			

PCA metodu ile tespit edilen 3 temel bileşene ait yük faktörleri Şekil 4.13'de verilmiştir. Bu şekilden de görüleceği üzere bazı yük faktörleri birbirilerine oldukça yakındır. Ayrıca şekil içerisinde girdi parametreleri, karışıklığa neden olmaması için Çizelge 4.9'da tanımlandıkları üzere “ $X_i$ ” parametresi ile ifade edilmiştir. Şekil 4.13'deki yük faktörlerine (Eigenvalue) göre 10 girdi parametresi 3 farklı grup oluşturmuştur. Şekilde,  $AKM_{kum}$ ,  $KOİ_{kum}$  ve  $KOİ_{erobik}$  yük (sırasıyla  $X_2$ ,  $X_3$  ve  $X_4$ ) parametrelerinin birlikte değerlendirilebilir olduğu gözlenmektedir. Benzer olarak  $(UAKM/TAKM)_{a,b}$ ,  $(F/M)_{a,b}$  (sırasıyla  $X_7$  ve  $X_{10}$ ) ile  $TAKM_{a,b}$ ,  $UAKM_{a,b}$ ,  $TAKM_{geri}$  devir ve  $ÇO_{a,b}$  (sırasıyla  $X_5$ ,  $X_6$ ,  $X_8$  ve  $X_9$ ) parametreleri de kendi aralarında değerlendirilebilmektedir. Parametrelerin kendi arasında gruplanması, aralarında yüksek korelasyon bulunduğunun veya yük faktör dağılımında benzer değerler alacağına bir göstergesidir.



Şekil 4.13. Verilerin PCA temel bileşen yük faktörleri

Proses değişkenlerinin gruplanması aynı zamanda proses davranışının netleştirilmesi ve girdi matrisinin daha temsil edici hale getirilmesi veya basitleştirilmesi



aşamalarında oldukça avantajlı olduğu gözlenmiştir. Şekil 4.13’de görüleceği üzere  $Q_{girdi}$  ( $X_1$ ) değişkeninin diğer 9 parametreden bağımsız bir yük faktörüne sahip olduğu belirlenmiştir. Bu durum, atıksu arıtma tesisi giriş debisi ile diğer ölçülen parametreler arasında istatistiksel olarak herhangi bir ilişki olmadığını göstermektedir.

PCA analizi sonucu ANN ve ANFIS modelleri için değişik girdi matrisleri elde edilmiştir. PCA sonuçları değerlendirilirken  $(UAKM/TAKM)_{a,b}$  ve  $(F/M)_{a,b}$  parametreleri diğer girdi değişkenlerine ve temel tesis işletim bilgilerine bağımlı olarak hesaplandığı göz önünde bulundurularak model girdi matrisinden çıkartılmıştır. Ardından iki PCA grubu arasından iki parametre seçilmiştir. Bu seçim yapılırken değişkenin içinde bulunduğu grubu temsil edebilme ile tesis içerisinde kolay ve pratik olarak ölçülebilme özellikleri göz önünde bulundurulmuştur.

PCA analizi ile elde edilen yük faktörleri değerlendirilirken, gruplar içerisindeki parametreler arasındaki korelasyon da incelenmiştir. Örneğin,  $AKM_{kum}$  ve  $KOI_{kum}$  ile  $AKM_{kum}$  ve  $KOI_{aerobik}$  yük arasındaki korelasyon katsayıları sırasıyla 0.89 ve 0.75 olarak hesaplanmıştır. Bu durum kum tutucu çıkışı  $KOI$  içeriğinin büyük bir kısmının partiküler formda bulunduğunu göstermektedir. Ayrıca  $AKM$  parametresinin ölçümü  $KOI$  parametresine göre hem daha kolay hem de az zaman alıcıdır. Ayrıca  $AKM$  ölçümü kimyasal tüketimi gerektirmeyen analitik prosedürler içermektedir. Bütün bu nedenler göz önünde bulundurularak ilk yük faktörü grubunu temsilen  $AKM_{kum}$  parametresi girdi matrisine dahil edilmiştir. İkinci girdi parametresi, benzer yük faktörlerine sahip bulunan havalandırma tankına ait parametrelerin ( $TAKM_{a,b}$ ,  $UAKM_{a,b}$ ,  $TAKM_{geri\ devir}$ ,  $\dot{C}O_{a,b}$ ) bulunduğu grup içerisinden seçilmiştir. Bu grup içerisinde beklendiği üzere  $TAKM_{a,b}$  ve  $UAKM_{a,b}$  parametreleri arasında yüksek korelasyon bulunmaktadır (yaklaşık 0.99).  $\dot{C}O_{ab}$  parametresinin  $TAKM_{a,b}$  ve  $UAKM_{a,b}$  parametreleri ile korelasyonu ise sırasıyla 0.86 ve 0.87 olarak hesaplanmıştır. Ayrıca  $TAKM_{geri\ devir}$  parametresi de diğer grup parametreleri ile pozitif korelasyona sahiptir. Dolayısıyla bu değerlendirmeler yanında havalandırma tankında anlık olarak ölçülebildiği için  $\dot{C}O_{a,b}$  parametresi, ikinci yük faktörü grubunda yeni temsil edici girdi parametresi olarak belirlenmiştir.

Son olarak  $Q_{girdi}$  parametresi, anlık olarak ölçülebilir olması ve atıksu arıtma tesislerinin işletilmesinde kritik role sahip olması nedeniyle son parametre olarak girdi matrisine dahil edilmiştir. Sonuç olarak  $Q_{girdi}$ ,  $AKM_{kum}$ , ve  $CO_{a,b}$  parametreleri KOİ hedef çıktı değişkenini tahmin etmek üzere tanımlanan yeni girdi matrisi bileşenleri olarak tanımlanmıştır.

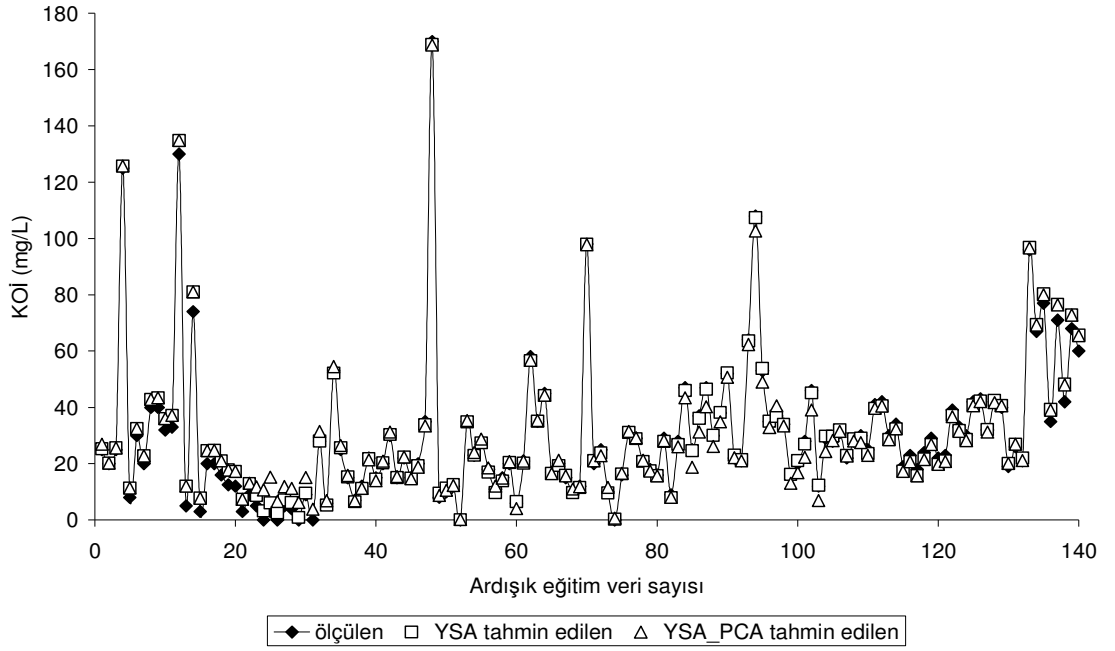
PCA analizi ve yeni girdi matrisinin belirlenmesinden sonra ANN ve ANFIS model performansları eğitim ve test aşamaları için ayrı ayrı hesaplanmıştır. Yukarıda da belirtildiği üzere ANN ve ANFIS modelleri 3 girdi parametresi içermektedir. Her iki model içinde de yeni geliştirilen model yapısında, önceki model yaklaşımlarında kurulan hesap algoritmaları kullanılmıştır. Her iki model yaklaşımında da eğitim prosesi oldukça önemlidir. Bu nedenle ilk olarak modellerin eğitim performansları hesaplanmıştır. Daha sonra eğitilen model yapıları, belirlenen test verileri ile tekrar değerlendirilerek her iki model için nihai KOİ tahmin performansları elde edilmiştir.

Hedef çıktı değişkenini tahmin etmek için, ANN modelinde tek gizli katmanlı (5 nöronlu) yapı kurulmuştur. Model sonucu, RMSE değeri eğitim ve test aşamaları için sırasıyla 2.23 mg/L'den 3.36 mg/L değerine; 2.30 mg/L'den 2.33 mg/L değerine yükselmiştir. Benzer hata yükseliş trendi MAPE parametresi için de geçerlidir. MAPE hata değerinde bir önceki ANN modeline göre eğitim aşamasında %3.56, test aşamasında ise %3.87 artış tespit edilmiştir. Ayrıca ölçülen değerler ile tahmin edilen değerler arasındaki korelasyon katsayısı, eğitim aşamasında bir önceki ANN modeline göre 0.98 değerinden 0.92 değerine; test aşamasında ise 0.97 değerinden 0.93 değerine düşmüştür.


Yeni girdi matrisleri ile aynı değerlendirme kriterleri ANFIS modeli için de uygulanmıştır. ANFIS modelinde eğitim aşaması sonrası sistem tarafından otomatik olarak koyulan kural sayısı 18'den 9'a düşmüştür. Aynı aşamaya ait performans değerleri ise RMSE, MAPE ve R olarak sırasıyla, 1.51 mg/L, %3.91 ve 0.98 olarak hesaplanmıştır. Dolayısıyla PCA analizinden sonra tanımlanan yeni girdi matrisi ile çalıştırılan ANFIS modelinin, orijinal girdi matrisi ile çalıştırılan daha önceki ANFIS modeline nazaran daha düşük eğitim performansına sahip olduğu belirlenmiştir.

Ayrıca yeni ANFIS modelinin test aşamasında bir önceki ANFIS modeli tahmin verileri hata değerlerinde RMSE olarak 0.51 mg/L ve MAPE olarak %1.14 artış gözlenmiştir. Benzer performans düşüşü korelasyon katsayısı değerinde de kendini göstermektedir. Yeni ANFIS modeli korelasyon katsayısı test aşamasında 0.97'den 0.95 değerine gerilemiştir. Her ne kadar PCA analizi sonucu oluşturulan yeni girdi matrisi ile her iki model yaklaşımında performans düşüş gösterse de hem eğitim hem de test aşamaları performansında kritik değişkenlik gözlenmemiştir. Bu durum, seçilen 3 girdi parametresi ile KOİ çıktı değişkeninin orijinal model yapısına oldukça yakın tespit edilebildiğini göstermektedir.

Şekil 4.14 ve Şekil 4.15 sırasıyla ANN ve ANFIS modellerinin temel bileşenler ile eğitim ve test aşamasındaki ölçülen ve tahmin edilen veriler arasındaki ilişkiyi; Şekil 4.16 ise ANN ve ANFIS modelleri test aşamasında ölçülen ve tahmin edilen veriler arasındaki dağılımı ifade etmektedir. Şekil 4.14 ve Şekil 4.15'dan görüleceği üzere ANFIS metodu, eğitim ve test aşamalarında ANN metoduna göre daha iyi tahmin sonuçları vermektedir.




(A)




(B)

Şekil 4.14 Ölçülen KOİ değerlerinin ANN ve ANN+PCA model teknikleri ile tahmin edilmesinin eğitim (A) ve test (B) aşamalarında karşılaştırılması




(A)




(B)

Şekil 4.15. Ölçülen KOİ değerlerinin ANFIS ve ANFIS+PCA model teknikleri ile tahmin edilmesinin eğitim (A) ve test (B) aşamalarında karşılaştırılması



(A)



(B)

Şekil 4.16 Ölçülen ve tahmin edilen KOİ parametresinin ANN (A) ve ANFIS (B) modeli test aşamasındaki veri dağılımları

Ayrıca PCA sonrası ANFIS modeli test aşamasında elde edilen RMSE hata değeri (1.51 mg/L) ortalama hedef çıktı KOİ değişkeninin %5.29'ına isabet etmektedir. Bu oran ANN modelinde %8 dolaylarında hesaplanmıştır. KOİ parametresinin standart titrimetrik ölçüm metodunda, sentetik numuneler için hesaplanan rölatif hata değeri %4.8 ile %5.6 arasında değişmektedir (APHA, 1998). Dolayısıyla, ANFIS modeli ile elde edilen RMSE hata değeri, ANN yaklaşımındaki RMSE değeri ile karşılaştırıldığında ANFIS model sonuçlarının pratik uygulama açısından daha gerçekçi sonuçlar verdiği söylenebilir.

#### 4.5. Evsel Atıksu Arıtma Tesisinde Karbon ve Azot Gideriminin Adaptif Ağ Temelli Bulanık Çıkarım Sistemi ve ASM Yaklaşımı ile Modellenmesi

Evsel atıksu arıtma tesisleri (AAT) bir çok kompleks fiziksel, kimyasal ve biyolojik prosesler içermektedir. Evsel AAT'de aktif çamur prosesi, en yaygın olarak uygulanan biyolojik arıtma metodudur. Bu proses temel olarak atıksu içerisindeki çözülmüş ve partiküler organik maddelerin ortamdaki mikroorganizmalar tarafından biyolojik olarak parçalanması sonucu biyokütle ve enerjiye dönüştürülmesi prensibine dayanmaktadır. Spesifik tasarım ve amaçlar doğrultusunda bir aktif çamur prosesi ile, biyolojik olarak karbon, azot ve fosfor giderimi birlikte gerçekleştirilebilmektedir (Gernaey vd., 2004).

Aktif çamurun biyolojik özelliği nedeniyle önemli proses değişkenleri eş zamanlı olarak izlenememekte ve ortaya çıkan problemlere zamanında müdahale etmek mümkün olamamaktadır. Bu nedenle tesis içi gerçekleşmesi muhtemel sorunları önceden tahmin etmek veya ortaya çıkan problemlere anında müdahale ederek, karar verme mekanizmasını kuvvetlendirmek ve maliyetleri en aza indirmek için iyi yapılandırılmış modellere ihtiyaç vardır.

Günümüzde, AAT performansını tanımlamaya yönelik olarak aktif çamur sürecine dayalı modelleme teknikleri geliştirilmiştir (Gernaey vd., 2004). Bu teknikler "*model-simulasyon tabanlı proses tanımlama*" metodları olarak adlandırılmakta ve farklı koşullar altında sistemi temsil edecek matematiksel yaklaşımları içermektedirler. Günümüzde en çok kullanılan aktif çamur modelleri; Uluslararası Su Birliği (IWA, International Water Association) (Henze vd., 1987; Gujer vd., 1999) ve Delft Teknik Üniversitesi (van Veldhuizen vd., 1999; Brdjanovic vd., 2000) tarafından geliştirilen modellerdir. Çalışma kapsamında Uluslararası Su Birliği tarafından aktif çamur sistemlerinde karbon oksidasyonu, nitrifikasyon ve denitrifikasyon performanslarının tahmin edilmesi aşamalarında kullanılan ASM1 ve ASM3 model yaklaşımları ele alınmıştır.



ASM1 ilk olarak kentsel atıksu arıtma tesislerinde oksijen ve nitrat azotunun elektron alıcısı olarak tüketilmesi ile karbon ve azot gideriminin gerçekleşmesi esasına göre geliştirilmiştir. Model içerisinde KOİ, organik maddenin eşdeğeri olarak tanımlanmıştır. Modelde organik karbon ve azot bileşenleri, biyolojik parçalanmaya ve çözünürlük durumuna göre oldukça az fraksiyonlara ayrılmıştır.

ASM3 modeli (Gujer vd., 1999), ASM1 modeline benzer olarak atıksu arıtma tesislerinde biyolojik olarak azot giderimi esasına göre kurulmuştur. Ayrıca ASM3 modeli, ASM1 içerisindeki bazı problemlerin giderilmesi ile standart bir yaklaşım halini almıştır (Gujer vd., 1999). İki model arasındaki en büyük fark, ASM3'ün depolanan polimerlerin heterotrofik aktif çamur dönüşümündeki önemini barındırmasıdır. ASM3 modelinde parçalanmaya hazır bütün substratın ( $S_s$ ) hücre bileşenleri ( $X_{STO}$ ) tarafından alınarak, çoğalma amaçlı depolandığı kabul edilir (Şekil 2.1). Dolayısıyla heterotrofik biyokütle, içsel hücre yapısı ile modellenmektedir. İki model arasındaki bir diğer fark, ASM3'ün ASM1'e göre daha kolay kalibre edilebilmesidir. Sonuç olarak her iki model de biyolojik arıtma proseslerinin dinamik davranışını modellemede etkili olabilmekle birlikte, biyolojik olarak parçalanmaya hazır substrat miktarı fazla olan atıksularda (endüstriyel atıksular) veya tank içerisinde yeterince havalandırılma yapılmayan bölgelerde ASM3 modeli daha iyi sonuç vermektedir (Koch vd., 2000).

Pratik uygulamalarda bu modellerin (ASM1, ASM2, ASM3 ve TUDP), aktif çamur prosesindeki sebep-sonuç etkileşimlerini çok iyi tanımlayamamaları, belirlenmesi zor olan oldukça fazla sayıda spesifik kinetik parametre içermeleri gibi sebeplerden dolayı, AAT tanımlanması ve kontrolüne yönelik olarak farklı metot arayışlarına gidilmiştir (Teppola vd., 1997; Çinar, 2005).

AAT verilerinin izlenmesi, proses tanımı ve kontrolünde; düşünme, anlama, kavrama, yorumlama ve öğrenme yapılarının programlamayla taklit edilerek problemlerin çözümüne yönelik uygulamalar kapsamında geliştirilen yapay zeka teknikleri (Bulanık Mantık, Yapay Sinir Ağları, Bulanık Sinir Sistemleri, Genetik

Algoritma ve Uzman Sistemler) yeni modelleme yaklaşımları olarak göze çarpmaktadır (Hong vd., 2003).

Bulanık çıkarım sisteminin insan mantığına uyarlanmış belirgin bilgi işleme gücünü ve yapay sinir ağlarının güçlü öğrenme algoritmasını bir arada barındıran hibrit yapıya adaptif ağ temelli bulanık çıkarım sistemi (ANFIS, Adaptive Network based Fuzzy Inference System) adı verilmektedir. İlgili literatür incelendiğinde, Çevre Mühendisliği disiplininde ANFIS modelleme yaklaşımının atıksu arıtım proseslerinde uygulamasının oldukça yeni olduğu görülmektedir.

Tezin beşinci ve son fazının temel amacı ASM ve ANFIS model yaklaşımlarını kullanılarak, bir evsel atıksu arıtma tesisinde biyolojik sürece ait hedef çıktı değişkenlerinin, aynı tesise ait geçmiş verilerle tanımlanması ve bu verilerle eğitilmesi ile daha hızlı ve güvenilir olarak tahmin edilmesinin araştırılmasıdır. Çalışma kapsamında A.B.D. Güney Carolina eyaletinde bulunan Pelham atıksu arıtma tesisine ait 1998-2002 tesis verileri değerlendirilmiştir. Tesise ait atıksu karakteristikleri Çizelge 4.12’de verilmiştir:

Çizelge 4.12. Pelham Atıksu Arıtma Tesisi atıksu karakteristikleri (1998-2002)

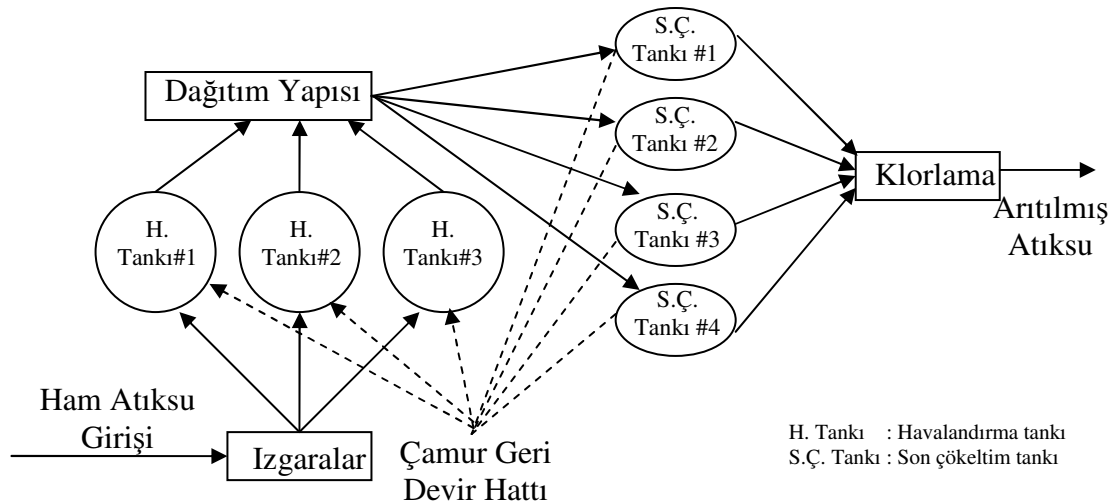
Atıksu Parametreleri	Minimum	Ortalama	Maksimum
$Q_{girdi}$ ( $m^3/gün$ )	12532	21440	28650
$KOİ_{girdi}$ (mg/L)	350	440	570
$TAKM_{girdi}$ (mg/L)	106	189	300
$NH_3-N_{girdi}$ (mg/L)	15	23	75
$pH_{h. tankı}$	6.06	6.70	7.20
$Sıcaklık_{h. tankı}$ ( $^{\circ}C$ )	13.60	19.50	25.60
$ÇO_{h. tankı}$ (mg/L)	1.02	2.80	5.50
$KOİ_{çıkıtı}$ (mg/L)	8	15	26
$NH_3-N_{çıkıtı}$ (mg/L)	0.07	1.12	4.40
$NO_3-N_{çıkıtı}$ (mg/L)	1.25	6.22	10.55

Q: Atıksu Debisi, KOİ: Kimyasal Oksijen İhtiyacı, TAKM: Toplam Askıda Katı Madde,  $NH_3-N$ : Amonyak Azotu,  $NO_3-N$ : Nitrat Azotu, ÇO: Çözünmüş Oksijen

Pelham AAT, Güney Carolina eyaletinde Batı Carolina Bölgesel Kanalizasyon İdaresi (WCRSA) otoritesi altında işletilen ve içerisinde biyolojik karbon ve azot giderim proseslerini barındıran bir atıksu arıtma tesisidir. Pelham AAT proses akış diyagramı Şekil 4.17’de gösterilmiştir.

ASM1 ve ASM3 model yaklaşımları, AQUASIM 2.0 yazılımı kullanılarak simüle edilmiştir. AQUASIM 2.0 yazılımı sucul sistemlerin tanımlanması ve tasarlanması ve dinamik olarak modellenmesi aşamalarında kullanılmaktadır. Aynı zamanda yazılım model değerlendirme, hassasiyet analizi ve parametre tahmini gibi önemli alt araçları bünyesinde barındırmaktadır. Model yaklaşımında aktif çamur sistemini ifade eden kısmi diferansiyel eşitlikler, zamana bağlı olarak (dinamik) nümerik metotlar ile çözülmektedir (Reichert, 1998). AQUASIM 2.0 yazılımı, ASM1 ve ASM3 bileşenlerine göre tekrar düzenlenmiştir.

ANFIS algoritması ise MATLAB R14 (MathWorks Inc.) yazılımı içerisinde bulunan Fuzzy Logic Toolbox kullanılarak çalıştırılmıştır. Modelleme çalışmasında kullanılan girdi ve çıktı değişkenleri sayısal aralıkları algoritma içerisinde bulunan *xbounds* fonksiyonu ile normalize edilmiştir.



Şekil 4.17. Pelham atıksu arıtma tesisi proses akış diyagramı

Pelham AAT Carousel tip havalandırma tanklarına sahiptir ve model içerisinde toplam sekiz adet seri reaktör tam karışimli olarak tanımlanmıştır. Bu tanımlama, COSTWWTP (European Cooperation in the field of Scientific and Technical Research Wastewater Treatment Plant Benchmark) simülasyon referansı (COST Action 624/682) temel alınarak ve hedef tesise uyarlanarak gerçekleştirilmiştir. Bu kapsamda yapılan kabuller aşağıda verilmiştir:

- 8 adet seri tam karışimli biyolojik tank ve 1 adet son çökeltim tankı
- Toplam biyolojik tank hacmi 6300 m<sup>3</sup> (ilk üç tank 1040 m<sup>3</sup>, diğerlerinin her biri 844 m<sup>3</sup> hacme sahip)
- Sabit sıcaklık (20°C) ve nötral pH
- İlk iki tank anoksik (çözünmüş oksijen yok) ve tam karışimli reaktör, diğer tanklardaki ÇO konsantrasyonları 3. 4. ve 5. tanklarda 2.5 mg/L, 6. ve 7. tanklarda 2.0 mg/L ve 8. tankda 1.5 mg/L
- Son üç tankta oksijen doygunluk konsantrasyonu 8 mg O<sub>2</sub>/L
- Son çökeltim tankı hacmi 5700 m<sup>3</sup>
- 5. tankdan 1. tanka %300 geri devir
- Son çökeltim tankından 1. tanka (%100) çamur geri devri (son çökeltim tankında biyolojik reaksiyon olmadığı için, geri devir hattındaki çözünmüş oksijen miktarı 5. tank içerisindeki değer ile aynıdır).

AQUASIM 2.0 yazılımında ASM1 ve ASM3 modellerinin tanımlanması aşamasında kullanılan stokiyometrik ve kinetik ifadeler ve bu ifadelerle ait başlangıç değerler Çizelge 4.13'de verilmiştir.

Çizelge 4.13. ASM1 ve ASM3 modellerinde kullanılan stokiyometrik ve kinetik ifadelerin başlangıç değerleri (T=20°C)

Sembol	Birim	ASM1/ASM3 (Gujer vd., 1999)
<i>Kinetik parametreler</i>		
$k_h$	(gün <sup>-1</sup> )	3.00
$K_X$	(gX <sub>s</sub> .g <sup>-1</sup> X <sub>H</sub> )	1.00
$k_{STO}^*$	(gS <sub>s</sub> .g <sup>-1</sup> X <sub>H</sub> .gün <sup>-1</sup> )	5.00
$\eta_{NO}^*$	-	0.60
$K_{OH}$	gO <sub>2</sub> .m <sup>-3</sup>	0.20
$K_{NOX}^*$	gN.m <sup>-3</sup>	0.50
$K_S$	gKOİ.m <sup>-3</sup>	20.00
$K_{STO}^*$	gX <sub>STO</sub> .g <sup>-1</sup> X <sub>H</sub>	1.00
$\hat{\mu}_H$	gün <sup>-1</sup>	2.00
$K_{NH}$	gN.m <sup>-3</sup>	1.00
$b_H$	gün <sup>-1</sup>	0.20
$b_{HNO}^*$	gün <sup>-1</sup>	0.10
$b_{STOO_2}^*$	gün <sup>-1</sup>	0.20
$b_{STONO}^*$	gün <sup>-1</sup>	0.10
$\hat{\mu}_A$	gün <sup>-1</sup>	1.00
$K_{OA}$	gO <sub>2</sub> .m <sup>-3</sup>	0.50
$b_A$	gün <sup>-1</sup>	0.15
$b_{ANO}^*$	-	0.05
<i>Stokiyometrik parametreler</i>		
$f_{XI}^*$	gX <sub>I</sub> .g <sup>-1</sup> X <sub>H</sub>	0.20
$Y_{STOO_2}^*$	gX <sub>STO</sub> .g <sup>-1</sup> S <sub>s</sub>	0.85
$Y_{STONO}^*$	gX <sub>STO</sub> .g <sup>-1</sup> S <sub>s</sub>	0.80
$Y_H$	gX <sub>H</sub> .g <sup>-1</sup> X <sub>STO</sub>	0.63
$Y_{HNO}^*$	gX <sub>H</sub> .g <sup>-1</sup> X <sub>STO</sub>	0.54
$Y_A$	gCOD.g <sup>-1</sup> N	0.24
$i_{NSI}$	gN.g <sup>-1</sup> KOİ	0.01
$i_{NSS}$	gN.g <sup>-1</sup> KOİ	0.03
$i_{NXI}$	gN.g <sup>-1</sup> KOİ	0.02
$i_{NXS}$	gN.g <sup>-1</sup> KOİ	0.04
$i_{NBM}$	gN/g <sup>-1</sup> KOİ	0.07

\* Yalnızca ASM3 model yaklaşımında kullanılmıştır.

Çizelge 4.13'den de görüleceği üzere, ASM1 ve ASM3 parametreleri arasında farklılıklar göze çarpmaktadır. Bu durumun en önemli nedeni ASM1 modelinde karşılaşılan bazı kısıtlamaların ASM3 modelinde değiştirilmiş olmasıdır (iç solunum, hücre içi substrat depolama vb.).

ASM (ASM1 ve ASM3) ve ANFIS model yaklaşımı için birbirinden bağımsız her üç model için eğitim ve test aşamalarında kullanılan veriler rastgele seçilmişlerdir. Kurulan modellerde seçilen hedef çıkış parametreleri ANFIS model yaklaşımında KOİ, NH<sub>3</sub>-N ve NO<sub>3</sub>-N konsantrasyonu olarak; ASM yaklaşımında ise S<sub>s</sub> (biyolojik olarak parçalanabilen çözünmüş KOİ), S<sub>NO</sub> (çözünmüş nitrit ve nitrat azotu) ve S<sub>NH</sub> (çözünmüş amonyum azotu) konsantrasyonları olarak tanımlanmıştır. Beş yıl boyunca ölçülen AAT işletme parametreleri içerisinde modele esas oluşturmak üzere seçilen toplam 900 verinin % 70'i (630) eğitimde (ASM'deki kalibrasyon eşdeğeri), geri kalan % 30'u (270) ise modelin test edilmesi aşamasında kullanılmıştır.

ASM ve ANFIS model performansları ölçülen ve tahmin edilen çıktı değişkenleri arasındaki karesel hata karekökü (RMSE), ortalama oransal hata (MAPE) ve korelasyon katsayısı (R) hesaplanarak değerlendirilmiştir.

Kurulan ASM1 ve ASM3 modellerinde ilk olarak hassasiyet analizi gerçekleştirilmiştir. Bu analiz model içerisindeki hangi parametre ve sabitlerin daha etkili olduğunu tanımlamaktadır. Hassasiyet analizleri, her iki ASM yaklaşımı için de S<sub>s</sub>, S<sub>NO</sub> ve S<sub>NH</sub> konsantrasyonları esas alınarak bağımsız olarak gerçekleştirilmiştir. Analizde göreceli fonksiyon kullanılmış ve hesaplama sonucu sıfır değer alan parametreler sistem çözümünde dikkate alınmamıştır. Analizde esas alınan parametreye göre hesaplanan hassasiyetler büyükten küçüğe sıralanarak, en önemlileri seçilmiş ve parametre tahmini aşamasında kullanılacak değişkenler olarak tespit edilmiştir. ASM1 ve ASM3 yaklaşımlarında elde edilen hassasiyet analizi sonuçları Çizelge 4.14'de verilmiştir:

Çizelge 4.14. ASM1 ve ASM3 model yaklaşımlarında gerçekleştirilen hassasiyet analizi sonuçları

ASM1			ASM3		
S <sub>s</sub>	S <sub>NH</sub>	S <sub>NO</sub>	S <sub>s</sub>	S <sub>NH</sub>	S <sub>NO</sub>
$\mu_H$	$\mu_A$	$Y_H$	$Y_H$	$\mu_A$	$Y_H$
$b_H$	$K_{NH}$	$\mu_A$	$Y_{STO}$	$b_A$	$K_A$
$Y_H$	$b_A$	$Y_A$	$b_H$	$K_{NH}$	$b_H$
$K_S$	$\mu_H$	$b_A$	$\mu_H$	$\mu_H$	$Y_A$

Çizelge 4.14’de model yaklaşımlarında hesap fonksiyonunun en hassas olduğu ilk 4 parametre verilmiştir. Model yaklaşımlarında hesap fonksiyonunun daha az hassas olduğu parametreler dikkate alınmamıştır. Hassasiyet analizini takiben tespit edilen parametreler, her iki model için de parametre tahminine tabi tutulmuştur.

Bir aktif çamur prosesinde kinetik katsayılar; atıksu kompozisyonuna, reaktör tasarımına, biyolojik çeşitliliğe, pH ve çözülmüş oksijen gibi birçok fiziksel ve biyokimyasal faktöre bağlı olarak değişiklik gösterebilmektedir. Dolayısıyla çalışma kapsamında tipik olarak tanımlanan kinetik parametrelerin, hedef atıksu arıtma prosesine göre tekrar düzenlenmesi gerekmektedir. Bu nedenle ASM modeli içerisinde sabit olarak tanımlanan kinetik parametreler AQUASIM 2.0 yazılımının matematiksel prosedürü kullanılarak tahmin edilmiştir. Yazılım, ölçülen (tipik kinetik değerler) ve model tarafından hesaplanan sabit değerler arasındaki ağırlıklı türevlerin karesel toplamını [ki-kare, ( $X^2$ )] minimize etmeye çalışarak modele girilen parametreleri tahmin etmiştir. Ki-kare ifadesi aşağıdaki şekilde hesaplanmıştır:

$$X^2 = \frac{\sum (\hat{y}_i - y_i)^2}{\sigma^2} \quad (4.9)$$

Bu eşitlikte  $\sigma$ , veriye ait standart sapmayı,  $\hat{y}_i$ , model parametrelerine [ $p=(p_1, p_2, \dots, p_m)$ ] ait bir fonksiyonu ifade etmektedir.

Seçilen parametrelerin her iki ASM yaklaşımı için tahmin edilmiş değerleri Çizelge 4.15’de verilmiştir. Bu değerler ASM1 ve ASM3 modellerinde  $S_s$ ,  $S_{NO}$  ve  $S_{NH}$  çıkış konsantrasyonlarının tahmin edilmesinde ortak olarak kullanılmıştır.


Çizelge 4.15 ASM1 ve ASM3 model yaklaşımlarında parametre tahmin sonuçları

Parametreler	Değer Aralığı (Tipik Değer)*	ASM1	ASM3
$\mu_H$ (gün <sup>-1</sup> )	0.6-13.2 (2.0)	7.26	6.67
$b_H$ (gün <sup>-1</sup> )	0.1-1.5 (0.2)	0.62	0.89
$Y_H$ (g KOİ.g <sup>-1</sup> KOİ)	0.38-0.75 (0.63)	0.41	0.40
$K_S$ (g KOİ.m <sup>-3</sup> )	5-225 (20)	20	9.39
$\mu_A$ (gün <sup>-1</sup> )	0.2-1.0 (1.0)	0.99	0.20
$K_{NH}$ (g NH <sub>3</sub> -N.m <sup>-3</sup> )	1.0	0.85	1.00
$b_A$ (gün <sup>-1</sup> )	0.05-0.2 (0.15)	0.05	0.05
$Y_A$ (g KOİ.g <sup>-1</sup> N)	0.07-0.28 (0.24)	0.25	0.25
$Y_{STO}$ (g X <sub>STO</sub> .g <sup>-1</sup> S <sub>s</sub> )	0.80	-	0.87


\* ASM1 ve ASM3 yaklaşımında 20 °C’deki tipik değerler verilmiştir (Gujer vd., 1999).

Parametrelerin tahmin edilmesini takiben kalibrasyon aşamasına geçilmiştir. Bu aşamada birbirine takip eden ardışık 630 veri, günlük bazda değerlendirilmiştir. Dolayısıyla ASM1 ve ASM3 modellerinin kalibrasyonundaki simülasyon süresi 630 gündür. Ayrıca bu aşamada reaktör konfigürasyonu, reaktör içindeki çözünmüş oksijen konsantrasyonu gibi farklı değişkenler ayarlanarak en iyi model kalibrasyonu elde edilmeye çalışılmıştır.  $S_s$ ,  $S_{NH}$  ve  $S_{NO}$  çıkış konsantrasyonlarının ASM1 ve ASM3 model yaklaşımları kullanılarak AQUASIM 2.0 programında elde kalibrasyon sonuçları sırasıyla Şekil 4.18a, Şekil 4.18b ve Şekil 4.18c’de gösterilmiştir.






(A)



(B)




(C)


Şekil 4.18. ASM1 ve ASM3 model yaklaşımlarında tesis organik karbon (A), amonyak azotu (B) ve nitrat azotu (C) çıktı değerlerinin kalibrasyon sonuçları

Şekil 4.18'den de görüleceği üzere kalibrasyon aşamasında elde edilen model tahmin sonuçları, ölçülen verilerden oldukça uzaktır. Bu sonuçlar, model yazılımı içerisinde proses değişkenleri ile gerçekleştirilebilecek bütün ayarların yapılması sonucu elde edilmiştir.


ANFIS modeli ile karşılaştırma yapılabilmesi açısından hedef çıktı değişkenleri, elde edilebilen en iyi kalibrasyon sonuçlarının alındığı değişken ve sabitler ile test edilmiştir (Şekil 19a, Şekil 19b ve Şekil 19c).



(A)



(B)



(C)

Şekil 4.19. ASM1 ve ASM3 model yaklaşımlarında tesis organik karbon (A), amonyak azotu (B) ve nitrat azotu (C) çıktı değerlerinin test (doğrulama) sonuçları

Şekil 4.19'den de görüldüğü ve beklendiği üzere aktif çamur prosesine ait hedef çıktı değişkenleri çok düşük doğrulukta tahmin edilebilmiştir. ASM1 ve ASM3 model yaklaşımları ile kalibrasyon ve test aşamalarında tahmin edilen  $S_s$ ,  $S_{NH}$  ve  $S_{NO}$  çıktı değerlerine ait performans değerleri Çizelge 4.16'da verilmiştir.

Çizelge 4.16. ASM1 ve ASM3 model yaklaşımları ile elde edilen kalibrasyon ve test performans değerleri

Modeller	ASM1					
	S <sub>S</sub>		S <sub>NH</sub>		S <sub>NO</sub>	
Kriterleri	K	T	K	T	K	T
R	0.09	0.15	0.32	0.09	0.65	0.15
RMSE (mg/L)	1.35	1.29	4.73	6.32	2.45	6.38
MAPE (%)	41.21	40.84	32.11	21.92	23.51	55.43

Çizelge 4.16. (devam)

Modeller	ASM3					
	S <sub>S</sub>		S <sub>NH</sub>		S <sub>NO</sub>	
Kriterleri	K	T	K	T	K	T
R	0.12	0.22	0.43	0.12	0.95	0.22
RMSE (mg/L)	1.33	1.21	2.31	5.45	0.35	5.28
MAPE (%)	39.32	38.17	17.92	20.36	9.45	44.82

K: Kalibrasyon, T: Test

Çizelge 4.16'da görüldüğü üzere ASM3 modeli ASM1 modeline göre daha iyi sonuçlar vermektedir. Özellikle çıkış NO<sub>3</sub>-N konsantrasyonunun model içerisindeki kalibrasyonu ASM3 yaklaşımıyla oldukça iyi tanımlanmıştır (Çizelge 4.16). Fakat modelin test aşamasında benzer performans sonuçları elde edilememiştir. Ayrıca ASM1 ve ASM3 model yaklaşımlarıyla test veri setinde elde edilen en yüksek korelasyon katsayıları sırasıyla 0.15 ve 0.22' dir. Dolayısıyla her iki model yaklaşımı da aktif çamur prosesindeki hedef çıktı değişkenlerinin tahmin edilmesinde oldukça zayıf kalmaktadır.

ASM model yaklaşımlarının tesis çıkışı karbon ve azot parametrelerinin tahmininde başarısız olmasının birçok nedeni bulunmaktadır. Fakat en temel sorunun kalibrasyon aşamasınının tam anlamıyla gerçekleştirilememesinden kaynaklandığı düşünülmektedir. Literatürde ASM model uygulamalarıyla ilgili bir çok yayın bulunmakla birlikte, model kalibrasyonu ile ilgili temel prosedürler farklılık

göstermektedir (Roeleveld ve van Loosdrecht, 2002). Genel olarak bakıldığında ise model kalibrasyonu; atıksu karakterizasyonu, çamur kompozisyon analizleri ile stokiyometrik ve kinetik parametrelerin ölçülmesinden oluşmaktadır (Petersen, 2000; Sin, 2004). Bu nedenle ASM modellerinde belirsizliklerin ortadan kaldırılması için laboratuvar ortamında kesikli şartlarda aerobik ve anoksik respirasyon ve inhibisyon testlerinin gerçekleştirilmesi önerilmektedir (Koch vd., 2000). Çünkü ASM yazılımlarının içerisinde bulunan parametre tahmin prosedürleri kinetik ve stokiyometrik ölçümlerin oldukça geniş aralıklarda salınmasına ve mevcut çalışmada elde edildiği üzere düşük doğrulukta simülasyon sonuçlarının elde edilmesine neden olabilmektedir.


Yukarıda belirtilen faktörler göz önüne alındığında çalışma kapsamında ele alınan 4 yıllık (1998-2002) tesis işletim periyodunda karbon ve azot giderim proseslerine ait model ile tahmin edilen kinetik ve stokiyometrik ifadelerin mevsimsel olarak sabit kalması mümkün değildir. Dolayısıyla bu ifadelerin kesikli laboratuvar şartlarında belirlenmesi gerekmektedir. Fakat her iki ASM yaklaşımında da Pelham AAT'de verilerin alındığı dönem boyunca herhangi bir kinetik ya da stokiyometrik ölçüm verisine rastlanmadığı için bu değişkenler tesis verisine göre matematiksel yöntemler ile tahmin edilerek sabit kabul edilmiştir. Ayrıca bu ölçümlerin maliyetli ve zaman alıcı olmasından ötürü sürekli olarak işletilen tam ölçekli atıksu arıtma tesislerinde gerçekleştirilmesi oldukça güçtür. Bütün bu nedenler birlikte değerlendirildiğinde ASM yaklaşımları ile kurulacak modellerin mutlaka deneysel olarak elde edilen kinetik ve stokiyometrik ifadeler ile desteklenmesi gerektiği düşünülmektedir. Literatürde bu düşüncüyü destekleyecek oldukça fazla miktarda çalışmaya mevcuttur. Ancak ilgili literatür incelendiğinde, yukarıda belirtilen kalibrasyon prosedürlerinin uygulandığı ve başarılı sonuçların elde edildiği belirtilen çalışmaların hiç birinde tahmin performansına ait istatistiksel bir sonuç verilmemiştir. Bu durum mevcut ASM model çalışmasının literatür ile bire bir karşılaştırılmasını zorlaştırmıştır.

ASM model yaklaşımında beklenen sonuçlar elde edilemediği için atıksu arıtma tesisine ait aynı veri setleri kullanılarak aktif çamur prosesi, yapay zeka yöntemleri içerisinde yer alan ANFIS yöntemi ile modellenmiştir. ANFIS algoritmasında MATLAB R14'de yazılan model dosyasının çalıştırılması ile çıkarmalı gruplandırma


yöntemini (subtractive clustering) uygulayan genfis2 fonksiyonu prototip bulanık çıkarım sistemini oluşturmuştur. ANFIS fonksiyonu ile eğitim ve optimizasyon işlemi uygulanmış ve prototip bulanık çıkarım sistemine eşdeğer nitelikte gerçek bulanık çıkarım sistemi elde edilmiştir. Optimize edilen model ile sistem çıktı değişkenleri tahmin edilmiş ve modelin doğruluğu test verileri ile denetlenmiştir.

Her üç modelin eğitimi aşamasında 500 iterasyon adımı uygulanmıştır. KOİ, NH<sub>3</sub>-N ve NO<sub>3</sub>-N değişkenleri için eğitimden sonra hesaplanan RMSE ve MAPE değerleri sırasıyla, 0.66 mg/L, 0.33 mg/L ve 0.25 mg/L ile %3.38, %15.87 ve %4.64 olarak bulunmuştur. Eğitimden sonra test veri seti için KOİ, NH<sub>3</sub>-N ve NO<sub>3</sub>-N değişkenlerine ait RMSE ve MAPE değerleri ise 0.78 mg/L, 0.32 mg/L ve 0.31 mg/L ile %4.20, %19.27 ve %6.03 olarak hesaplanmıştır. Modellemede kullanılan girdi ve çıktı değişkenlerine ait verilerin farklı değer aralıkları göz önüne alındığında, hesaplanan eğitim ve test RMSE değerlerinin tatmin edici düzeyde olduğu görülmektedir.

Kurulan ANFIS modelleriyle eğitim ve test aşaması için KOİ, NH<sub>3</sub>-N ve NO<sub>3</sub>-N çıktı değişkenlerinin (tesis çıkış) tahmin edilen değerleri ile ölçülen değerlerinin zamanla değişimleri sırasıyla Şekil 4.20 (A, B), (C, D) ve (E, F)'de verilmiştir.

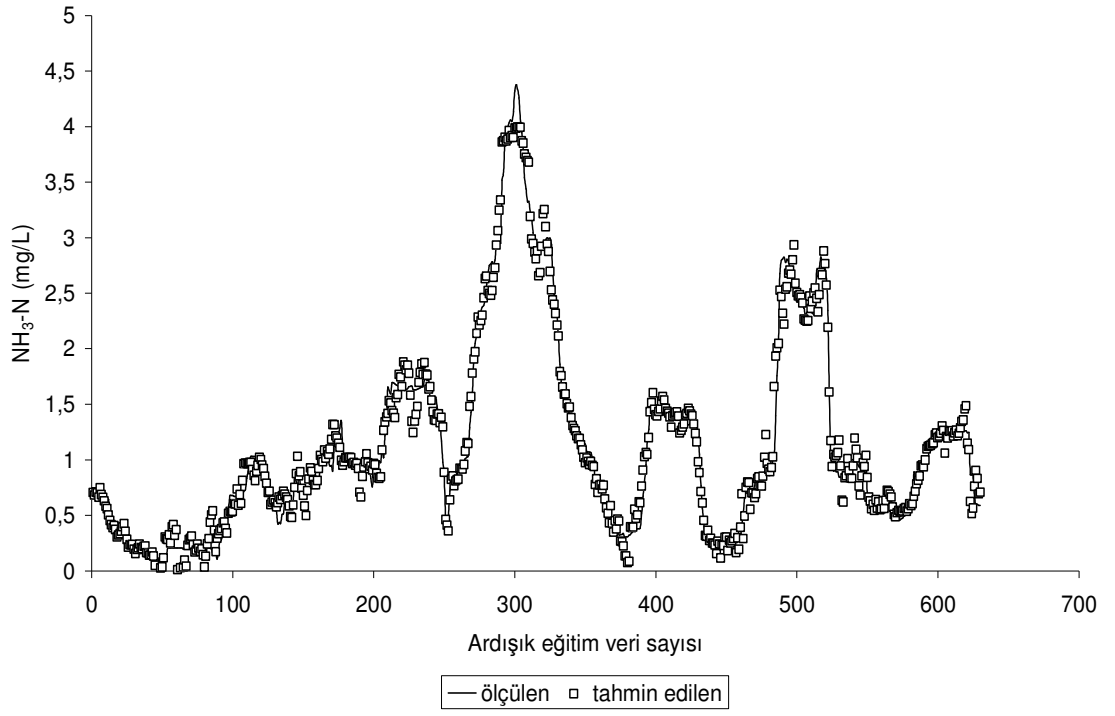


(A)




(B)


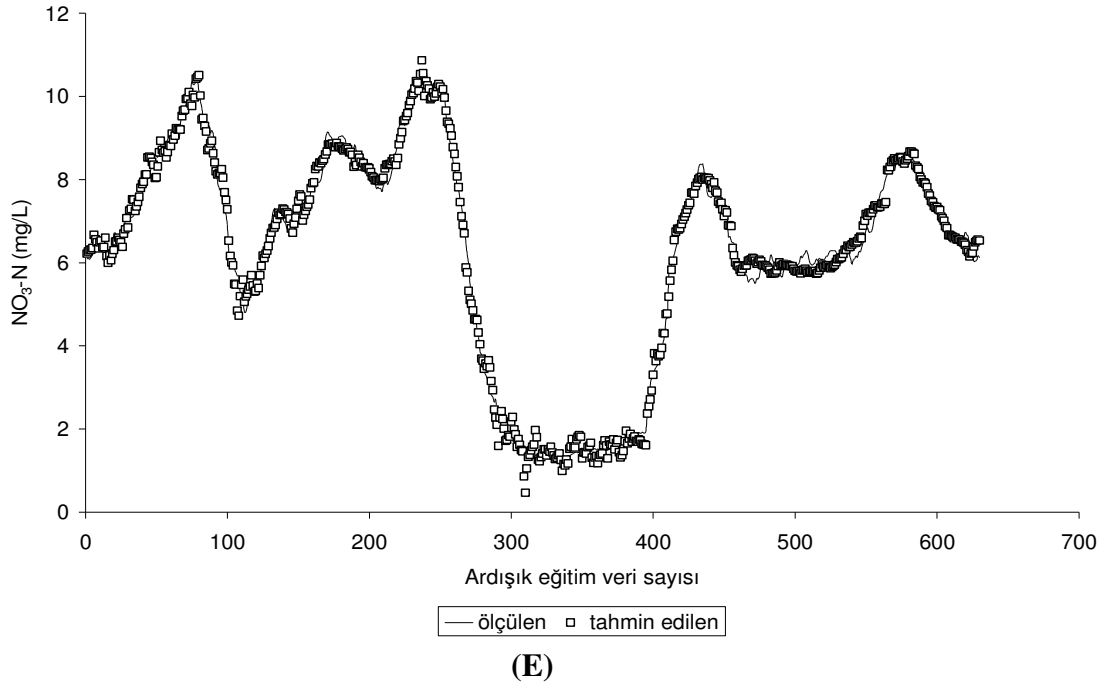




(C)



(D)



Şekil 4.20. ANFIS modelleriyle eğitim ve test aşaması için KOİ (A, B),  $\text{NH}_3\text{-N}$  (C, D) ve  $\text{NO}_3\text{-N}$  (E, F) çıktı değişkenlerinin (tesis çıkışı) tahmin edilen değerleri ile ölçülen değerlerinin zamanla değişimleri

Kurulan üç farklı bağımsız ANFIS modeline ait R ve RMSE değerleri de Çizelge 4.17'de özet olarak verilmiştir. Test seti için elde edilen korelasyon katsayıları KOİ,

NH<sub>3</sub>-N ve NO<sub>3</sub>-N için sırasıyla 0.98, 0.94 ve 0.99 olarak bulunmuştur. Kurulan her üç modelin doğruluğu test verileri için elde edilen düşük RMSE ve yüksek korelasyon katsayısı değerleri ile kanıtlanmıştır. Elde edilen sonuçlar, ANFIS algoritmasının girdi ve çıktı değişkenleri arasındaki ilişkiyi iyi bir şekilde tanımladığını ve çıktı değişkenlerinin yüksek doğrulukla tahmin edildiğini ortaya koymaktadır.

Çizelge 4.17. KOİ, NH<sub>3</sub>-N ve NO<sub>3</sub>-N modellerine ait performans sonuçları

Girdiler	Çıktılar	Eğitim Performansı		Test Performansı	
		RMSE, MAPE	R	RMSE, MAPE	R
Q <sub>girdi</sub> (m <sup>3</sup> /gün)	KOİ <sub>çıkı</sub> (mg/L)	0.66 mg/L	0.98	0.78 mg/L	0.98
KOİ <sub>girdi</sub> (mg/L)		%3.38		%4.20	
TAKM <sub>girdi</sub> (mg/L)	NH <sub>3</sub> -N <sub>çıkı</sub> (mg/L)	0.33 mg/L	0.93	0.32 mg/L	0.94
NH <sub>3</sub> -N <sub>girdi</sub> (mg/L)		%15.87		%19.27	
pH <sub>h. tankı</sub>	NO <sub>3</sub> -N <sub>çıkı</sub> (mg/L)	0.25 mg/L	0.99	0.31 mg/L	0.99
Sıcaklık <sub>h. tankı</sub> (°C)		%4.64		%6.03	
ÇO <sub>h. tankı</sub> (mg/L)					

Yapay zeka yöntemleri tek başına veya hibrit olarak; AAT içi gerçekleşmesi muhtemel sorunları önceden tahmin etmek veya ortaya çıkan problemlere anında müdahale ederek, karar verme mekanizmasını kuvvetlendirmek ve maliyetleri minimize etmek için kullanılabilir. Pelham AAT aerobik biyolojik arıtma süreci için gerçekleştirilen modelleme çalışması sonucunda, ANFIS yaklaşımının tesis performansının değerlendirilmesinde çok iyi sonuçlar verdiği bulunmuştur. Ayrıca, model algoritmasının tesis işletme koşullarını iyi tanımladığı ve eş zamanlı tesis kontrolü için uygulama potansiyelinin yüksek olduğu gözlenmiştir.

## 5. TARTIŞMA ve SONUÇ

Tez kapsamında gerçekleştirilen çalışmalar sonucu elde edilen temel sonuçlar aşağıda tartışılmıştır:

Atıksu arıtma tesislerinin optimal yönetimi için tesis içi kompleks yapıların ve proseslerin farklı yöntemlerle tanımlanması ve tahmin edilmesi gerekmektedir. Atıksu arıtma tesislerinin matematiksel (mekanistik) olarak modellenmesi (tez kapsamında ASM) ile ilgili çalışmalar ve elde edilen tecrübeler oldukça fazla iken, yapay zeka yöntemlerinin (tez kapsamında ANFIS ve ANN) tesis performansının tahmin edilmesinde ve gerçek zamanlı tesis kontrolünde kullanılmasına ilişkin bilgiler literatürde oldukça kısıtlıdır.

Atıksu arıtma tesislerinde yapay zeka sistemlerinin kullanılması doğru veri analiz ve model yaklaşımlarını zorunlu kılmaktadır. Model yapısı ile girdi ve hedef çıktı değişken(ler)i belirlenirken, tesise ait geçmiş verilerin (anlık-nümerik, gecikmeli-nümerik, kalitatif, deneysel, hesap yaklaşımı, vb.) toplanması, düzenlenmesi de oldukça önemlidir. Atıksu arıtma tesislerinin yapay zeka sistemleri ile değerlendirilmesi veya kontrolünün etkili bir şekilde yapılabilmesi için model girdi ve çıktı değişkenlerinin doğru seçilmesi gereklidir.

Tez kapsamında ele alınan ANN ve ANFIS yapay zeka yöntemlerinde mevcut mekanistik model yaklaşımlarına benzer olarak kalibrasyon ve doğrulama (test) aşamaları gerçekleştirilmiştir. Kalibrasyon aşaması yapay zeka yöntemlerinde eğitim aşamasına karşılık gelmektedir. Bu safhanın performansının yüksek olması, doğrulama kısmının da tatmin edici düzeyde başarılı olmasını sağlamaktadır.

Çalışmalarda değerlendirilen arıtma proseslerine ait işletme koşulları oldukça değişken ve etkileşimli olduğundan, değişken sayısını azaltmak ve model boyutunu küçültmek için PCA analizi kullanılmıştır. PCA metodunun temsil edici model parametrelerinin belirlenmesinde oldukça güçlü bir metot olduğu tespit edilmiştir.

ANN model yaklaşımının dezenfeksiyon yan ürünleri oluşumunun (tez kapsamında bromat) modellenmesinde MLR analizine karşı alternatif bir değerlendirme aracı olabileceği tespit edilmiştir. Ayrıca proses içerisinde kolay ölçülebilen işletim parametrelerin seçilmesi ile ANN modelleme yaklaşımı pahalı yöntemlerden farklı olarak bromat konsantrasyonlarının önceden tahmin edilerek izlenmesi ve kontrolüne imkan veren pratik ve kullanışlı bir yaklaşım olabilir.

Arıtma proseslerinde tahmin edilmek istenen hedef çıktı değişkene ait veri dağılımının belirli bir değer etrafında toplanması veya sabit olması durumunda yapay zeka sistemlerinin tahmin kapasitesi ve performansı azalmaktadır. Bu dezavantajın üstesinden gelmek için bütün girdi ve çıktı değişkenlerinin logaritmik dönüşüm ya da başka ekstra normalizasyon metotları ile modele dahil edilmesi gerekmektedir. Bu ise yapay zeka yaklaşımlarının arıtma sistemlerinin kontrolü ve yönetimi aşamasında kullanılmasını kısıtlamaktadır.

Tez kapsamında endüstriyel ve ardışık biyolojik prosesler (anaerobik+aerobik) içeren bir atıksu arıtma tesisinin aerobik biyolojik oksidasyon kısmında, karbon ve azot giderimi performansı, PCA ve ANFIS modelleri ile oldukça iyi bir şekilde tahmin edilmiştir. Aynı modelleme tekniklerinin konvansiyonel aktif çamur prosesindeki karbon giderim performansını da düşük hata değerlerinde, yüksek doğrulukta tahmin edebildiği tespit edilmiştir.

Kurulan ANN ve ANFIS modellerinin doğruluğu, test verileri için elde edilen düşük RMSE ve MAPE hata değerleri ve yüksek korelasyon katsayısı değerleri ile kanıtlanmıştır. Elde edilen sonuçlar, ANN ve ANFIS algoritmasının girdi ve çıktı değişkenleri arasındaki ilişkiyi daha iyi bir şekilde tanımladığını ve çıktı değişkenlerinin yüksek doğrulukla tahmin edildiğini ortaya koymaktadır. Kentsel atıksu arıtma tesisi performansını belirlemek için gerçekleştirilen modelleme çalışması sonucunda ise ANFIS yaklaşımının arıtma performansının değerlendirilmesinde ANN yaklaşımından daha tatmin edici sonuçlar verdiği bulunmuştur. ANFIS model algoritmasının tesis işletme koşullarını ANN algoritmasına göre daha iyi tanımladığı gözlenmiştir.

Tez çalışmasında bir evsel atıksu arıtma tesisinde karbon ve azot giderimi ASM model yaklaşımları (ASM1 ve ASM3) ve ANFIS yapay zeka modelleme tekniği ile birlikte karşılaştırmalı olarak değerlendirilmiştir. Çalışma sonucu ANFIS modelleme yaklaşımının ASM model yaklaşımlarına göre çıkış kalite parametrelerini oldukça iyi tahmin edebildiği gözlenmiştir. ASM yaklaşımının ise, sadece tesise ait geçmiş veriler ışığında değerlendirilmesi sonucu oldukça düşük tahmin performansına sahip olduğu, bu yüzden ASM yaklaşımlarında kinetik ve stokiyometrik parametrelerin mutlaka spesifik ölçüm ve değerlendirme teknikleri ile belirlenerek, modelin desteklenmesi gerektiği tespit edilmiştir.

ANFIS gerek ANN, gerekse ASM metotlarına göre daha iyi bir tahmin performansına sahip olmakla birlikte, aynı zamanda kural tabanlı bir eğitim algoritması olduğu için, ANFIS metodunun atıksu arıtma tesislerinde mevcut sensör, otomasyon sistemleri ve operator deneyimleriyle desteklenerek daha sağlam ve güvenilir denetleyici kontrol sistemlerine dahil edilebileceği gözlenmiştir. Dolayısıyla ANFIS modellerinin eş zamanlı tesis kontrollerinde uygulama potansiyeline sahip olduğu tespit edilmiştir.

ANFIS algoritmasında veri gruplandırma fonksiyon vektörlerinin değişimi ile herhangi bir düzgün azalan ya da artan performans değişikliği gözlenmemiştir. Yalnızca, radii vektörünün 0.5'ten 0.6'ya yükselmesi ile KOİ modelinde RMSE cinsinden hata %6 oranında azalmış, korelasyon katsayısı ise sabit kalmıştır. Sonuç olarak genfis2 fonksiyonlarına ait başlangıç orijinal değerlerinin bu çalışma kapsamında ANFIS modellerinin performansında düzenli bir değişikliğe neden olmadığı tespit edilmiştir. Fakat bu durum, başka çalışmalar için de benzer şekilde araştırılmalıdır.

Tez çalışmalarında ele alınan yapay zeka yöntemlerinin (ANN ve ANFIS), değişkenler arasındaki ilişkinin etkileşimli, kompleks ve doğrusal olmayan arıtma sistemlerinin modellenmesinde oldukça iyi sonuçlar verdiği tespit edilmiştir. Yapay zeka yöntemleri, güçlü eğitim algoritması ile bir çok mühendislik dalındaki süreç ve

işlemin modellenmesinde yaygın olarak kullanılmaya başlanmıştır. Benzer şekilde çevre mühendisliği alanında arıtma süreçlerinin de yapay zeka yöntemleri ile modellenmesi çalışmaları son bir kaç yılda hız kazanmıştır. Yapay zeka yöntemleri tek başına veya hibrit olarak; tesis içi gerçekleşmesi muhtemel sorunları önceden tahmin etmek veya ortaya çıkan problemlere anında müdahale ederek, karar verme mekanizmasını kuvvetlendirmek ve maliyetleri en aza indirmek için kullanılabilir. Bu yöntemlerle, seçilen hedef değişkenlerin tahmini kolaylıkla yapılabilmektedir.

Yapılan tez literatürdeki sayılı çalışmalardan biri olup, literatüre katkılar sağlayacaktır. Örneğin, içme suyu arıtımında ozonlama sonucu oluşan bromat konsantrasyonlarının ANN, MLR ve PCA modelleri ile karşılaştırmalı olarak tahmin edilmesi literatürde ilk defa bu tez kapsamında yapılmıştır. Bir endüstriyel atıksu arıtma tesisinin aerobik biyolojik arıtma sürecinde organik karbon ve azot gideriminin ANFIS ve PCA modelleri ile tahmin edilmesi literatürde bir ilkidir. Benzer şekilde, ASM ve ANFIS modellerinin biyolojik arıtma süreçlerinde bire bir karşılaştırılması ilk defa bu tezde yapılmıştır. Dolayısıyla tez kapsamında arıtma prosesleri gerek proses gerekse performans bazında hem mekanistik, hem de yapay zeka ve çoklu istatistiksel yöntemler ile birlikte karşılaştırmalı olarak değerlendirilmiştir. Tezin çevre mühendisliği alanında gerçekleştirilecek yapay zeka modelleme ve pratik mühendislik uygulama çalışmalarında da bir kaynak oluşturabileceği düşünülmektedir.

## 6. KAYNAKLAR

- Acha, V., Meurens, M., Naveau, H., Dochain, D., Bastin, G., Agathos, S. N., 1999. Model-based estimation of an anaerobic reductive dechlorination process via an attenuated total reflection-Fourier transform infrared sensor. *Water Science and Technology* 40(8), 33-40.
- Amy, G.L., Siddiqui, M., Zhai, W., DeBroux, J., Odem, W., 1994. Survey of bromide in drinking water and impacts on DBP formation. AWWA Research Foundation, Denver, CO.
- APHA, 1998. *Standart Methods for the Examination of Water and Wastewater*, 20th Edition, Washington, DC, USA.
- Baxter, C.W., Stanley, S.J., Zhang, Q., 1999. Development of a full-scale artificial neural network model for the removal of natural organic matter by enhanced coagulation. *Aqua* 48(4), 129-136.
- Benko, M., 2004. Functional principal components analysis, implementation and applications. MS thesis, Humboldt University, Germany.
- Berthouex, P.M., ve Brown, L.C., 2002. *Statistics for Environmental Engineers*, 2nd Edition, Lewis Publishers, Boca Raton, FL, USA, 335 s.
- Brdjanovic, D., van Loosdrecht, MCM., Versteeg, P., Hooijmans, C.M., Alaerts, G.J., Heijnen, J.J., 2000. Modeling COD, N and P removal in a full-scale WWTP Haarlem Waanderpolder. *Water Research* 34, 846-858.
- Chen, W.C., Chang, N.B., Chen, J.C., 2003. Rough set-based hybrid fuzzy-neural controller design for industrial wastewater treatment. *Water Research* 37, 95-107.
- Choi, D.J. ve 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.
- Corté's, U., Sa'nchez-Marre`, M., Ceccaroni, L., Roda, I.R., Poch, M., 2000. Artificial intelligence and environmental decision support systems. *Appl. Intell.* 13, 77-91.
- Çinar, Ö., 2005. New tool for evaluation of performance of wastewater treatment plant: Artificial neural network. *Process Biochemistry* 40(9), 2980-2984.
- Daigger, G. T. ve Grady, C. P. L., 1995. The Use of Models in Biological Process Design,, *Proceedings of 68th Annual WEF Conference & Exposition*, Miami Beach, Florida, USA, 1, 501-510.
- Davis, J.F., Bakshi, B. R., Kosanovich, K. A., Piovoso, M. J., 1996. Process monitoring, data analysis and data interpretation, *AIChE Symposium Series* 92: 1-11.
- Dold, P.L. ve Marais, G.R., 1986. Evaluation of the General Activated Sludge Model Proposed by IWAPRC Task Group, *Water Science and Technology* 18, 63-89.



- Ekama, G.A., Dold, P.L., Marais, G.R., 1986. Procedures for determining influent COD fractions and the maximum specific growth rate of heterotrophs in activated sludge systems, *Water Science and Technology* 18(6), 91-114.
- Elmas, Ç., 2003a. Bulanık Mantık Denetleyiciler, Seçkin Yayıncılık, İstanbul
- Elmas, Ç., 2003b. Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama), Seçkin Yayıncılık, İstanbul.
- Eroğlu, V., 1995. Su Tasviyesi, İTÜ İnşaat Fakültesi Matbaası, İstanbul
- Farza, M., Busawon, K., Hammouri, H., 1998. Simple nonlinear observers for on-line estimation of kinetic rates in bioreactors. *Automatica* 34(3), 301-318.
- Gardner, H., 1993. Multiple Intelligences, The Theory in Praticce, Basic Books, New York, US.
- Gaudy, A.F. ve Gaudy, E.T., 1971. Biological concept for design and operation of the activated sludge process. Environmental Protection Agency Water Pollution Research Series, Report No. 17090, FQJ 09/71
- 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 Modeling and Software* 19, 763-783.
- Glaze, W.H., 1987. The Chemistry of Water Treatment Processes Involving Ozone, Hydrogen Peroxide, and Ultraviolet Radiation, *Ozone Sci. Engrg.* 9(4), 335.
- Glaze, W.H., Weinberg, H.S., Cavanagh, J.E., 1993. Evaluating the formation of brominated DBPs during ozonation. *Journal of American Water Works Association* 85(1), 96.
- Goodman, B.L. ve Englande, A.J. 1974. A Unified Model of the Activated Sludge Process. *J. Water Pollution Control Federation* 46(2), 312-332.
- Grady, C. P. L., Daigger, G. T., Lim. H.C., 1999. *Biological Wastewater Treatment*, 2nd Edition, Marcel Dekker, Inc New York, NY.
- Gregersen, L. ve Jørgensen, S.B., 1999. Supervision of fed-batch fermentations. *Chem. Eng. J.* 75, 69-76.
- Grguric, G. ve Coston, C.J., 1998. Modeling of nitrate and bromate in a seawater aquarium. *Water Research* 32(6), 1759-1768.
- Gujer, W., Henze M., Mino, T., van Loosdrecht, M.C.M., 1999. Activated Sludge Model No.3. *Water Science and Technology* 39(1), 183-193.
- Häck, M. ve Köhne, M. 1996. Estimation of wastewater process parameters using neural networks. *Water Science and Technology* 33(1), 101-115.
- Hamed, M.M., Khalafallah, M.G., Hassanien, E.A., 2004. Prediction of wastewater treatment plant performance using artificial neural networks. *Environmental Modeling & Software* 19, 919-928
- Hammer, M. J., 1986. *Water and wastewater technology*, Prentice Hall, Inc., Englewood Cliffs, New Jersey, USA.

- Hassan, K.Z.A., Bower, K.C., Miller, C.M., 2003. Numerical simulation of bromate formation. *Journal of Environmental Engineering* 129(11), 991-998.
- Henze, M., Grady, C.P.L., Jr., Gujer, W., Marais, G.V.R., Matsuo, T., 1987. Activated Sludge Model No.1. IAWQ Scientific and Technical Report No.1, London, UK.
- Henze, M., Gujer, W., Mino, T., Matsuo, T., Wentzel, M.C.M, Marais, G.V.R., 1995. Activated Sludge Model No.2. IWA Scientific and Technical Report No.3, IWA Publishing, London, UK.
- Henze, M., Harremoës, P., Jansen, J.L.C, Arvin, E., 1997. *Wastewater Treatment: Biological and Chemical Processes*, 2<sup>nd</sup> Edition, Springer Inc.
- Henze, M., Gujer, W., Mino, T., Loosdrecht, M.V., 2002. Activated Sludge Models ASM1, ASM2, ASM2D and ASM3, IWA Scientific and Technical Report No.9, IWA Publishing, London, UK.
- Hong, Y.S.T., Rosen, M.R., Bhamidimarri, R., 2003. Analysis of a municipal wastewater treatment plant using a neural network-based pattern analysis, *Water Research* 37, 1608-1618.
- Jain, A.K., Mao, J.C., Mohiuddin, K.M., 1996. Artificial neural networks: A tutorial. *Computer* 29(3), 31-44.
- Jang, J.S.R., 1993. ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Trans. Sys., Man and Cybernetics* 23(3), 665-685.
- Jeppsson, U., 1996. Modelling Aspects of Wastewater Treatment Processes, PhD Dissertation, Department of Industrial Electrical Engineering and Automation (IEA), Lund Institute of Technology (LTH), Lund, Sweden.
- Jolliffe, I.T., 2002. *Principal Component Analysis*, 2<sup>nd</sup> Ed., Springer, New York, NY.
- Kim, J.H., von Gunten, U., Marinas, B.J., 2004. Simultaneous prediction of *Cryptosporidium parvum* oocyst inactivation and bromate formation during ozonation of synthetic waters. *Environmental Science & Technology* 38(7), 2232-2241.
- Koch, G., Kuhni, M., Gujer, W., Siegrist, H., 2000. Calibration and validation of activated sludge model no.3 for Swiss municipal wastewater. *Water Research* 34, 3580-3590.
- Koscielna, H., 2004. Determination of bromate in drinking water. A review. *Chemia Analityczna* 49(4), 445-457.
- Krasner, S.W., Glaze, W.H., Weinberg, H.S., Daniel, P.A., Najm, I.N., 1993. Formation and control of bromate during ozonation of waters containing bromide. *Journal of American Water Works Association* 1, 73-81.
- Kurokawa, Y., Maekawa, A., Takahashi, M., Hayashi, Y., 1990. Toxicity and carcinogenicity of potassium bromate. *Environ. Health Perspectives* 87, 309-335.
- Lawrence, A.W. ve McCarty, P.L., 1970. Unified Basis for Biological Treatment Design and Operation. *J. Sanitary Engineering Division, ASCE*, 96, SA3, 757-778.

- Legube, B., Parinet, B., Gelinet, K., Berne, F., Croue, J.P., 2004. Modeling of bromate formation by ozonation of surface waters in drinking water treatment. *Water Research* 38(8), 2185-2195.
- Luccarini, L., Porrà E., Spagni, A., Ratini, P., Grilli, S., Longhi, S., Bortone G. 2002. Soft sensors for control of nitrogen and phosphorus removal from wastewaters by neural networks. *Water Science and Technology* 45(4-5), 101-107.
- McDorman, K.S., Pachkowski, B.F., Nakamura, J., Wolf, D.C., Swenberg, J.A., 2005. Oxidative DNA damage from potassium bromate exposure in Long-Evans rats is not enhanced by a mixture of drinking water disinfection by-products. *Chemico-Biological Interactions* 152, 107-117.
- McKinney, R.E., ve Ooten, R.J., 1969. Concepts of complete mixing activated sludge. *Trans. 19<sup>th</sup> Sanitary Engineering Conference, University of Kansas*, pp. 32-59.
- Mitrakas, M., ve Simeonidis, C., 2003. Conditions affecting bromate formation during ozonation of bottled water. *Ozone Science&Engineering* 25(3), 167-175.
- Montgomery, D.C., Peck, E.A., Vinning, G.G. 2001. *Introduction to Linear Regression Analysis*. 3rd edition, John Wiley & Sons, New York, 672 p.
- Mujunen, S.P., Minkkinen, P., Teppola, P., Wirkkala, R.S., 1998. Modeling of activated sludge plants treatment efficiency with PLSR: a process analytical case study, *Chemom. Intell. Lab. Syst.* 41, 83-84.
- Orhon, D. ve Artan, N., 1994. *Modelling of activated sludge systems*, Tech-nomic Publishing Company, Inc., Lancaster, Pennsylvania, USA.
- Olsson, G. ve Newell, B., 1999. *Wastewater Treatment Systems. Modelling, Diagnosis and Control*. IWA Publishing, London, UK.
- Ozegin, K., Westerhoff, P., Amy, G.L., Siddiqui, M.S., 1998. Molecular ozone and radical pathways of bromate formation during ozonation. *J. of Environmental Engineering* 124(5), 456-462.
- Öztemel, E., 2003. *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul.
- Pearson, K. 1991. On lines and planes of closest fit to systems of points in space, *Philos. Mag.* 2, 559–572.
- Perendeci A., 2004. *Şeker Fabrikası Anaerobik Atıksu Arıtım Sisteminin Kararlı Olmayan Koşullarda Modellenmesi Çalışmaları*. Doktora tezi, Hacettepe Üniversitesi Çevre Mühendisliği Bölümü, Ankara.
- Perendeci, A., Arslan, S., Tanyolaç, A., Çelebi, S.S., 2004. The effect of history extension on adaptive-network based fuzzy inference system for a real scale anaerobic wastewater treatment plant. *Proc. of 10<sup>th</sup> World Congress on Anaerobic Digestion*, Aug. 29-Sept. 2, Montreal, Canada, pp. 1392.
- Petersen, B., 2000. *Calibration, identifiability and optimal experimental design of activated sludge models*. Ph.D. Thesis, Ghent University, Faculty of Agricultural and Applied Biological Science, Belgium.

- Pinkernell, U., von Gunten, U., 2001. Bromate minimization during ozonation: mechanistic considerations. *Environmental Science & Technology* 35, 2525-2531.
- Qin, S. J. ve Dunia, R. 2000. Determining the number of principal components for best reconstruction, *J. Process Control* 10(2-3), 245–250.
- Reichert, P. 1998. AQUASIM 2.0-User Manual-Computer Program for the Identification and Simulation of Aquatic Systems, Swiss Federal Institute for Environmental Science and Technology (EAWAG), Dübendorf, Switzerland.
- Rizzoli, A.E. ve Young, W.J., 1997. Delivering environmental decision support systems: software tools and techniques. *Environmental Modeling and Software* 12, 237-249.
- Roeleveld, P.J. ve van Loosdrecht, M.C.M., 2002. Experience with guidelines for wastewater characterisation in The Netherlands, *Wat. Sci. Tech.* 45(6), 77-87.
- Rosen, C. ve Olsson, G. 1998. Disturbance detection in wastewater treatment plants, *Wat. Sci. Tech.* 37(12), 197–205.
- Rosen, C., 2001. A Chemometric Approach to Process Monitoring and Control with Applications to Wastewater Treatment Operation, Lund University, Doktora Tezi.
- Russell, S.J., Norvig, P., 1995. *Artificial Intelligence: A Modern Approach*, Anglewood Cliffs NJ: Prentice-Hall, US.
- Sadiq, R. ve Rodriguez, M.J., 2004a. Disinfection by-products (DBPs) in drinking water and predictive models for their occurrence: a review. *Science of the Total Environment* 321(1-3), 21-46.
- Sadiq, R. ve Rodriguez, M.J., 2004b. Fuzzy synthetic evaluation of disinfection by-products-a risk-based indexing system. *Journal of Environmental Management* 73, 1-13.
- Sağiroğlu, Ş., Beşdok, E., Erler, M., 2003. *Mühendislikte Yapay Zeka Uygulamaları-I, Yapay Sinir Ağları*, Ufuk Yayıncılık, Kayseri, 423 s.
- Siddiqui, M.S. ve Amy, G.L., 1993. Factors affecting DBP formation during ozone-bromide reactions. *J. of American Water Works Association* 1, 63-72.
- Siddiqui, M.S., Amy, G.L, Ozekin, K., Westerhoff, P., 1994. Empirically and theoretically based models for predicting brominated ozonated by-products. *Ozone Sci Eng.* 16, 157-178.
- Sin, G. 2004. *Systematic Calibration of Activated Sludge Models*, Ph.D. Thesis Ghent University, Faculty of Agricultural and Applied Biological Science, Belgium.
- Sohn, J., Amy, G.L, Cho, J.W., Lee, Y., Yoon, Y., 2004. Disinfectant decay and disinfection by-products formation model development: chlorination and ozonation by-products. *Water Research* 38(10), 2461-2478.
- Song, R., Minear, R., Westerhoff, P., Amy, G.L., 1996a. Modeling and risk analysis of bromate formation from ozonation of bromide-containing waters. *Wat. Sci. Tech.* 34(7-8), 79-85.

- Song, R., Donohoe, C., Minear, R., Westerhoff, P., Ozekin, K., Amy, G., 1996b. Empirical modeling of bromate formation during ozonation of bromide-containing waters. *Water Research* 30(5), 1161-1168.
- Sugeno, M., ve Kang, J. T., 1986. Fuzzy modeling and control of multilayer incinerator. *Fuzzy Sets and Systems* 18, 329-346.
- Symons, J.M., Fu, P.L.K., Dressman, R.C., Stevens, A.A., 1987. The influence of bromide ion on organic chlorine and organic bromine formation during free chlorination. *Journal of American Water Works Association* 79(9), 114-118.
- Takagi, T., ve Sugeno, M., 1983. Derivation of fuzzy control rules from human operators actions. *Proc., IFAC Symp. on Fuzzy Information* 55-60.
- Takagi, T., ve Sugeno, M., 1985. Fuzzy identification systems and its application to modeling and control. *IEEE Trans. Sys., Man and Cybernetics* 15, 116-132.
- Tay, J.H., ve Zhang, X., 2000. A fast predicting neural fuzzy model for high-rate anaerobic wastewater treatment systems. *Water Research* 34(11), 2849-2860.
- Teppola, P., Mujunen, S-P., Minkkinen, P., 1997. Partial least squares modeling of an activated sludge plant: a case study, *Chemometrics and Intelligent Laboratory Systems* 38, 198-208.
- Tyrovola, K., 2001. Generation of bromates during ozonation of groundwater in coastal areas (in Greek). MS thesis, Technical University of Crete, Greece.
- Tyrovola, K. ve Diamadopoulos, E., 2005. Bromate formation during ozonation of groundwater in coastal areas in Greece. *Desalination* 176(1-3), 201-209.
- USEPA, 1999. Alternative disinfectants and oxidants guidance manual. Office of Water, EPA 815-R-99-014.
- van Veldhuizen, H.M., van Loosdrecht, M.C.M., Heijnen, J.J., 1999. Modeling biological phosphorus and nitrogen removal in a full scale activated sludge process. *Water Research* 33, 3459-3468.
- von Gunten, U. ve Hoigne, J., 1994. Bromate formation during ozonation of bromide-containing waters: Interaction of ozone and hydroxyl radical reactions. *Environmental Science&Technology* 28, 1234-1242.
- von Gunten, U. ve Oliveras, Y., 1998. Advanced oxidation of bromide-containing waters: bromate formation mechanisms. *Environmental Science&Technology* 32, 63-70.
- von Gunten, U., 2003. Ozonation of drinking water: Part II. Disinfection and by product formation in presence of bromide, iodide or chlorine. *Water Research* 37(7), 1469-1487.
- Yoo, C. K., Vanrolleghem, P. A., Lee, I. B., 2003. Nonlinear modeling and adaptive monitoring with fuzzy and multivariate statistical methods in biological wastewater treatment plant. *Journal of Biotechnology* 105, 135-163.
- Weijers, S.R. ve Vanrolleghem, P.A., 1997. A procedure for selecting best identifiable parameters in calibrating activated sludge no. 1 to full-scale plant data, *Water Science and Technology* 36(5), 69-79

- Westerhoff, P, Song, R., Amy, G.L., Minear, R., 1998a. NOM's role in bromine and bromate formation during ozonation. *Journal of American Water Works Association* 89(2), 82-94.
- Westerhoff, P, Song, R., Amy, G.L., Debroux, J., 1998b. Numerical kinetic models for bromide oxidation to bromine and bromate. *Water Research* 32, 1687-1699.
- Zavareh, H.S., 2003. Evaluation and modeling of a membrane activated sludge system. Yüksek lisans tezi, Department of Civil Engineering, University of Ottawa, Canada.

**ÖZGEÇMİŞ**

Adı Soyadı : Gökhan Civelekoğlu

Doğum Yeri : Isparta

Doğum Yılı : 25.10.1978

Medeni Hali : Evli

**Eğitim ve Akademik Durumu:**

Lise 1992-1996 Gürkan Lisesi (Yabancı Dil Ağırlıklı Lise)

Lisans 1996-2000 İstanbul Teknik Üniversitesi İnşaat Fakültesi Çevre Mühendisliği Bölümü

Yüksek Lisans 2001-2003 Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Çevre Mühendisliği Anabilim Dalı

Yabancı Dil İngilizce

**İş Deneyimi:**

2000-2001 Süleyman Demirel Üniversitesi Rektörlük Bilgi İşlem Daire Başkanlığında Sözleşmeli Personel (Çözümleyici)

2001-2006 Süleyman Demirel Üniversitesi Mühendislik-Mimarlık Fakültesi Çevre Mühendisliği Bölümünde Öğretim Görevlisi