

T.C.  
YILDIZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

MELAS ATIK SULARININ ARITIMINDA YUKARI AKIŞLI HAVASIZ ÇAMUR  
YATAKLI REAKTÖR (YAHÇYR) SİSTEMİNDEN ELDE EDİLEN BİYOGAZ VE  
METAN ÜRETİMLERİNİN YAPAY SINIR AĞLARI İLE MODELLENMESİ

İLKNUR TEMİZEL

YÜKSEK LİSANS TEZİ  
ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI  
ÇEVRE MÜHENDİSLİĞİ PROGRAMI

DANIŞMAN  
YRD. DOÇ. DR. KAAAN YETİLMEZSOY

İSTANBUL, 2012

**T.C.**  
**YILDIZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**MELAS ATIK SULARININ ARITIMINDA YUKARI AKIŞLI HAVASIZ ÇAMUR  
YATAKLI REAKTÖR (YAHÇYR) SİSTEMİNDEN ELDE EDİLEN BİYOGAZ VE  
METAN ÜRETİMLERİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ**

İlknur TEMİZEL tarafından hazırlanan tez çalışması 04.01.2012 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Çevre Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

**Tez Danışmanı**

Yrd. Doç. Dr. Kaan YETİLMEZSOY  
Yıldız Teknik Üniversitesi

**Eş Danışman**

Yrd. Doç. Dr. İlder TURKDOĞAN AYDINOL  
Yıldız Teknik Üniversitesi

**Jüri Üyeleri**

Doç. Dr. Mehmet ÇAKMAKÇI  
Yıldız Teknik Üniversitesi

Doç. Dr. Neşe TÜFEKÇİ  
İstanbul Üniversitesi

Doç. Dr. Güleda ENGİN  
Gebze Yüksek Teknoloji Enstitüsü

## ÖNSÖZ

---

Çalışmamın bütün aşamalarını titizlikle takip edip beni yönlendiren, bana emek veren, bilgi ve deneyimlerinden yararlandığım değerli danışman hocam Sayın Yrd. Doç. Dr. Kaan YETİLMEZSOY'a, yardımlarından ve manevi desteğinden dolayı Sayın Yrd. Doç. Dr. İlter TÜRKDOĞAN AYDINOL'a teşekkür ve sonsuz şükranlarımı sunarım.

Bu tezi yapabilmem için gerekli eğitim altyapısını sağlayan ancak kısa bir süre önce aramızdan ayrılmış olan, geç tanışıp erken veda ettiğim eski Bölüm Başkanımız Rahmetli Prof. Dr. Ferruh ERTÜRK'e şükranlarımı arz ederim.

Göstermiş oldukları ilgi ve katkılardan dolayı Yıldız Teknik Üniversitesi Çevre Mühendisliği Bölümü'nün saygıdeğer Öğretim Üyelerine ve Araştırma Görevlilerine teşekkür ederim.

Hayatımı borçlu olduğum, beni yetiştiren, bana emek veren, benden sevgi ve şevkatlerini hiç esirgemeyen sevgili aileme, çalışmayı hazırlamam sırasında gösterdiği anlayış ve manevi desteğinden dolayı değerli arkadaşım Jeofizik Mühendisi Salih Görkem YAZAR'a sonsuz teşekkürlerimi sunarım.

Çalışmalarım sırasında yardımlarına ihtiyacım olduğu her an desteklerini benden esirgemeyen, teknik bilgilerine çok güvendiğim değerli arkadaşlarım Çevre Yüksek Mühendisi Kübra ULUCAN ve Çevre Mühendisi M. İberia AYDIN'a minnettarlığımı tekrardan sunarken, yoğun çalışmalarım sırasında her an yanımda olup benden hiçbir zaman sevgilerini ve desteklerini esirgemeyen kıymetli arkadaşlarım Feyza Betül AYDIN, Büşra AKOĞLU, Muhammed Sabri BİLGİLİ ve Marco CAMPAGNA'ya teşekkürü bir borç bilirim.

Aralık, 2011

İlknur TEMİZEL

## İÇİNDEKİLER

---

	Sayfa
SİMGE LİSTESİ .....	vii
KISALTMA LİSTESİ .....	viii
ŞEKİL LİSTESİ.....	ix
ÇİZELGE LİSTESİ .....	x
ÖZET.....	xii
ABSTRACT .....	xiv
BÖLÜM 1 .....	1
GİRİŞ.....	1
1.1    Literatür Özeti .....	1
1.2    Tezin Amacı .....	2
1.3    Bulgular .....	4
BÖLÜM 2 .....	6
MELAS ATIKSULARININ ARITILABİLİRLİĞİ KONUSUNDA YAPILAN ÇALIŞMALAR .....	6
2.1    Melas Maddesinin Genel Karakterizasyonu .....	8
BÖLÜM 3 .....	13
YAPAY SİNİR AĞLARI .....	13
3.1    Yapay Sinir Ağlarının Genel Özellikleri .....	14
3.2    YSA'ların Avantaj ve Dezavantajları .....	15
3.3    Nöronun Biyolojik Yapısı ve Nöron Modelleri .....	17
3.4    Yapay Sinir Hücresinin Yapısı .....	19
3.4.1    Girdiler .....	20
3.4.2    Ağırlıklar .....	20
3.4.3    Birleştirme Fonksiyonu .....	20
3.4.4    Transfer (Aktivasyon) Fonksiyonu.....	20
3.4.5    Çıktılar .....	22

3.5	Yapay Sinir Ağlarının Yapısı .....	22
3.5.1	Giriş Tabakası .....	23
3.5.2	Gizli Tabaka .....	23
3.5.3	Çıkış Tabakası .....	24
3.6	Yapay Sinir Ağlarının Sınıflandırılması.....	25
3.6.1	Yapılarına Göre Yapay Sinir Ağları.....	25
3.6.1.1	İleri Beslemeli Yapay Sinir Ağları .....	25
3.6.1.2	Geri Beslemeli Yapay Sinir Ağları .....	25
3.6.2	Öğrenme Algoritmalarına Göre Yapay Sinir Ağları .....	26
3.6.2.1	Danışmanlı Öğrenme.....	26
3.6.2.2	Danışmansız Öğrenme .....	27
3.6.2.3	Destekleyici Öğrenme .....	27
3.6.3	Öğrenme Zamanlarına Göre Yapay Sinir Ağları .....	27
3.6.3.1	Statik Öğrenme .....	27
3.6.3.2	Dinamik Öğrenme .....	28
3.7	Yapay Sinir Ağlarının Çevre Mühendisliğinde Uygulamaları.....	28
3.7.1	Yapay Sinir Ağlarının Atık Yönetiminde Uygulamaları .....	28
3.7.1.1	Su ve Atıksu Arıtımı .....	28
3.7.1.2	Hava Kirliliği.....	31
BÖLÜM 4 .....		34
MATERİYAL VE METOT .....		34
4.1	Yapay Sinir Ağları Çalışmasında Kullanılan Veri Seti Temini ve İşletme Koşulları.....	34
4.2	Model Değişkenlerinin Tanıtımı.....	37
4.2.1	Organik Yükleme Oranı (OYO, $p_1$ ) .....	37
4.2.2	Alkalinite ( $p_2, p_6$ ) .....	38
4.2.3	pH ( $p_3, p_7$ ).....	39
4.2.4	Sıcaklık ( $p_4$ ).....	39
4.2.5	Uçucu Yağ Asidi ( $p_8$ ) .....	41
4.2.6	Kimyasal Oksijen İhtiyacı (KOİ, $p_5$ ) .....	41
4.2.7	Biyogaz ve Metan Üretimi ( $t_1, t_2$ ).....	42
4.3	Model Datasının Tanımlayıcı İstatistiksel Analizi.....	43
4.4	Veri Setinin Eğitim, Validasyon ve Test Setlerine Bölünmesi .....	43
4.5	Temel Bileşen Analizi (PCA, Principal Component Analysis) .....	44
4.6	Geri Yayılım Algoritmasının (BP) Seçimi.....	45
4.7	Yapay Sinir Ağları Yapısının Optimizasyonu .....	46
4.8	Hassasiyet Analizi .....	47
4.9	Lineer – Non-lineer Çalışma .....	47
4.10	Tahmin sonuçlarının İstatistiksel Analizi.....	48
BÖLÜM 5 .....		51
SONUÇLAR VE ÖNERİLER .....		51
5.1	Geri Yayılım Algoritmasının Seçilmesi.....	51
5.1.1	Biyogaz Tahmini İçin Geri Yayılım Algoritmasının Seçimi .....	51
5.1.2	Metan Tahmini İçin Geri Yayılım Algoritmasının Seçimi .....	54

5.2	Sinir Ağları Yapısının Optimizasyonu .....	56
5.2.1	Biyogaz Tahmini Aşamasının Optimizasyonu .....	56
5.2.2	Metan Tahmini Aşamasının Optimizasyonu .....	58
5.3	Hassasiyet Analizi .....	60
5.3.1	Biyogaz Üretim Tahmininde Hassasiyet Analizi .....	60
5.3.2	Metan Üretim Tahmininde Hassasiyet Analizi.....	63
5.4	Lineer/Non-lineer Çalışma Sonuçları .....	65
5.4.1	Biyogaz Üretim Tahmini İçin Lineer-Non-lineer Çalışma .....	65
5.4.2	Metan Üretim Tahmini İçin Lineer-Non-lineer Çalışma.....	70
5.5	Tahmin Sonuçlarının İstatistiksel Analizi.....	73
5.5.1	Biyogaz Tahmin Sonuçlarının İstatistiksel Analizi .....	74
5.5.2	Metan Tahmin Sonuçlarının İstatistiksel Analizi.....	76
BÖLÜM 6	.....	78
SONUÇ, YORUM VE ÖNERİLER	.....	78
KAYNAKLAR	.....	81
EK-A	.....	87
DENEYSEL VERİLER	.....	87
EK-B	.....	93
YSA TESTING VERİ SETİ	.....	93
EK-C	.....	95
TESTING VERİ SETİNİN YSA'DA BİYOGAZ TAHMİN SONUCUNUN UYUM ÇİZELGELERİ	95	
EK-D	.....	96
TESTING VERİ SETİNİN YSA'DA METAN TAHMİN SONUCUNUN UYUM ÇİZELGELERİ	96	
EK-E	.....	97
DATAFIT® TESTING VERİ SETİ	.....	97
EK-F	.....	99
TESTING VERİ SETİNİN DATAFIT®'TE BİYOGAZ TAHMİN SONUCUNUN UYUM ÇİZELGELERİ	.....	99
EK-G	.....	100
TESTING VERİ SETİNİN DATAFIT®'TE METAN TAHMİN SONUCUNUN UYUM ÇİZELGELERİ	.....	100
ÖZGEÇMİŞ	.....	101

## SİMGE LİSTESİ

---

$R^2$	Determinasyon Katsayısı
$R_a^2$	Ayarlanmış Çoklu Determinasyon Katsayısı
R	Korelasyon Katsayısı
MAE	Ortalama Mutlak Hata
RMSE	Ortalama Karesel Hata Karekökü
$RMSE_s$	Sistemik RMSE
$RMSE_u$	Sistemik Olmayan RMSE
MSE	Ortalama Karesel Hata
IA	Uyum İndeksi
FA2	İki Faktörü
FV	Fraksiyonel Varyans
PSE	Sistemik Hata Oranı
SEE	Tahmindeki Standart Hata
SR	Hataların Toplamı
AR	Ortalama Bakiye Hata
RSS	Hataların Kareleri Toplamı
NNI	Uygulanan Non- Lineer İterasyon Sayısı
$Y_a$	DeneySEL Veri
$Y_p$	Tahmin Deęeri
n	Gözlem Sayısı
p	Çoklu Regresyon Modelindeki Deęişken Sayısı
C°	Celcius Sıcaklık Birimi

## KISALTMA LİSTESİ

---

YAHÇYR	Yukarı Akışlı Havasız Çamur Yataklı Reaktör
YSA	Yapay Sinir Ağları
TKOİ	Toplam Kimyasal Oksijen İhtiyacı
UASB	Upflow Anaerobic Sludge Blanket ( Yukarı Akışlı Çamur Yatağı)
MFC	Microbial Fuel Cell ( Mikrobiyal Yakıt Hücresi)
BAF	Biological Air Filter (Biyolojik Hava Filtresi)
MP	Melanoidin Pigmenti
BOİ <sub>5</sub>	Biyolojik Oksijen İhtiyacı
TKN	Toplam Kjeldahl Azotu
BP-ANN	Back-Propagation Artificial Neural Network (Geri Beslemeli Yapay Sinir Ağları)
NN-LEAP	Neural Network Leachate Flow Rate Prediction (Yapay Sinir Ağı Esaslı Sızıntı Suyu Debisi Tahmini)
GRNN	General Regression Neural Network (Genel Regresyon Sinir Ağı)
FBR	Akışkan Yataklı Reaktör
OBD	Optimum Gövde Çapı
MLP	Çok Katmanlı Algılayıcı
HRT	Hidrolik Bekletme Süresi
OYO	Organik Yükleme Oranı
UKM	Uçucu Katı Madde
UYA	Uçucu Yağ Asidi
KOİ	Kimyasal Oksijen İhtiyacı
TBA	Temel Bileşen Analizi (PCA, Principal Component Analysis)
BP	Geri Yayılım Algoritması



## ŞEKİL LİSTESİ

---

	Sayfa
Şekil 3.1	Basit Bir Nöronun Yapısı [27] ..... 18
Şekil 3.2	Yapay nöronun genel yapısı [29] ..... 18
Şekil 3.3	Yapay Nöronun Detaylı Yapısı [29] ..... 19
Şekil 3.4	En çok kullanılan transfer fonksiyonları [29] ..... 21
Şekil 3.5	Transfer fonksiyonunun çalışma yapısı [29] ..... 22
Şekil 3.6	YSA'nın Genel Yapısı [29] ..... 23
Şekil 3.7	Gizli Tabakası Tek Katmanlı YSA [27] ..... 24
Şekil 3.8	Gizli Tabakası Çok Katmanlı YSA [29] ..... 24
Şekil 3.9	İleri Beslemeli ve Geri Beslemeli Ağ Yapıları [29] ..... 26
Şekil 4.1	Melas atıksularının arıtılmasında kullanılan YAHÇYR sistemi [47]..... 37
Şekil 4.2	Metanojenlerin reaktif aktivitelerinin (R) pH ile değişimi [55]..... 39
Şekil 4.3	Sıcaklığın gaz üretimine etkisi [57]..... 40
Şekil 4.4	Havasız arıtmada dikkate alınan sıcaklık değerleri [55]..... 41
Şekil 4.5	Temel Bileşen Analiz (PCA) Şeması [63]..... 45
Şekil 5.1	YSA Modelinde Biyogaz Performans Grafiği ..... 53
Şekil 5.2	YSA'da Biyogaz Tahmininin Tüm Alt Setlerinin MATLAB® Ekranındaki Grafikleri ..... 54
Şekil 5.3	YSA Modelin'de Metan Performans Grafiği..... 55
Şekil 5.4	YSA'da Metan Tahmininin Tüm Alt Setlerinin Grafiği..... 56
Şekil 5.5	Biyogaz Tahmin Aşamasında MSE Değerlerine Karşılık Gelen Nöron Değerleri ..... 57
Şekil 5.6	YSA İşlem Şeması ..... 60
Şekil 5.7	Biyogaz için 2'li kombinasyondan başlayarak MSE-Korelasyon grafiği ..... 62
Şekil 5.8	Metan için 2'li kombinasyondan başlayarak MSE-Korelasyon grafiği ..... 64

## ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2.1	Melasın genel özellikleri [19] ..... 10
Çizelge 2.2	Melas içeriği [19]..... 10
Çizelge 2.3	Şeker pancarı melasının bileşimi [25] ..... 11
Çizelge 2.4	Melasın Kimyasal Özellikleri [26] ..... 11
Çizelge 3.1	Bilgisayar ve insan beyni arasındaki çalışma sistemlerinin karşılaştırılması ..... 13
Çizelge 3.2	Yapay Sinir Ağlarının Mimarisi ve Yapı Elemanları [28] ..... 17
Çizelge 4.1	Atık ve hammadde kaynaklarına göre biyogaz ve metan oranları [62] 42
Çizelge 4.2	Bu çalışmada göz önüne alınan performans indikatörleri ve matematiksel ifadeleri ..... 49
Çizelge 5.1	10 Nöronlu Hidden Layerda 11 Geri Yayılım Algoritmasının Biyogaz Tahmini İçin Karşılaştırılması..... 52
Çizelge 5.2	Trainlm ve Trainscg geri yayılım algoritmalarının detaylı karşılaştırılması ..... 53
Çizelge 5.3	10 Nöronlu Hidden Layerda 11 Geri Yayılım Algoritmasının Metan Tahmini İçin Karşılaştırılması ..... 55
Çizelge 5.4	Biyogaz Tahmini İçin optimum Nöron Sayısı ..... 57
Çizelge 5.5	Metan Tahmini İçin Optimum Nöron Sayısı..... 58
Çizelge 5.6	Biyogaz üretiminin tahmininde girdi değişkenlerinin optimum model performansına katkıları..... 61
Çizelge 5.7	Biyogaz Üretim Tahmin Değişkenlerinin MSE Azalma Yüzdeleri..... 62
Çizelge 5.8	Metan üretiminin tahmininde girdi değişkenlerinin optimum model performansına katkıları..... 63
Çizelge 5.9	Metan Üretim Tahmin Değişkenlerinin MSE Azalma Yüzdeleri..... 64
Çizelge 5.10	Biyogaz üretiminin tahmininde DataFit® ile elde edilen çoklu regresyon modelleri ve regresyon analizinde hesaplanan bazı istatistiksel değerler..... 67
Çizelge 5.11	Biyogaz üretiminin tahmininde deneysel sonuçlarla en iyi uyum sağlayan çoklu regresyon modelinin (eksponansiyel model) katsayıları ve modele ait bazı istatistiksel sonuçlar ..... 68
Çizelge 5.12	Biyogaz üretiminin tahmininde deneysel sonuçlarla en iyi uyum sağlayan çoklu regresyon modeli (eksponansiyel model) için tanımlayıcı bakiye hataların istatistikleri..... 69
Çizelge 5.13	Metan üretiminin tahmininde DataFit® ile elde edilen çoklu regresyon modelleri ve regresyon analizinde hesaplanan bazı istatistiksel değerler..... 71

Çizelge 5.14	Metan üretiminin tahmininde deneysel sonuçlarla en iyi uyum sağlayan çoklu regresyon modelinin (eksponansiyel model) katsayıları ve modele ait bazı istatistiksel sonuçlar .....	72
Çizelge 5.15	Metan üretiminin tahmininde deneysel sonuçlarla en iyi uyum sağlayan çoklu regresyon modeli (eksponansiyel model) için tanımlayıcı bakiye hataların istatistikleri .....	73
Çizelge 5.16	Biyogaz üretimi tahmininde optimum tahmin modelleri tahmin sonuçlarının validasyonu/verifikasyonu .....	75
Çizelge 5.17	Metan üretiminin tahmininde optimum tahmin modelleri tahmin sonuçlarının validasyonu/verifikasyonu .....	77

**MELAS ATIK SULARININ ARITIMINDA YUKARI AKIŞLI HAVASIZ ÇAMUR YATAKLI REAKTÖR (YAHÇYR) SİSTEMİNDEN ELDE EDİLEN BİYOĞAZ VE METAN ÜRETİMLERİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ**

İlknur TEMİZEL

Çevre Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Yrd. Doç. Dr. Kaan YETİLMEZSOY

Eş Danışman: Yrd. Doç. Dr. İlder TURKDOĞAN AYDINOL

Pilot ölçekli mezofilik yukarı akışlı çamur yataklı (UASB) reaktör sistemde arıtılan melas atık suyu çıkışından sırasıyla biyogaz ve metan üretim oranları, iki adet üç katmanlı yapay sinir ağı (YSA) modeli (8:9:1 ve 8:12:1) ile tahmin edilmiştir.

Yapay zeka esaslı bu yaklaşımda, hacimsel organik yükleme oranı (OLR), işletme sıcaklığı, giriş ve çıkış alkalinitesi, giriş ve çıkış pH, giriş KOİ ve uçucu yağ aside olmak üzere sekiz girdi değişkeni ile modelleme yapılmıştır.

YSA tabanlı gerçekleştirilen bu çalışmada MATLAB® V7.0 programı kullanılmıştır. Geri yayılım (BP) algoritmasının eğitiminden sonra temel bileşen analizi (PCA) yapılarak, YSA modeli biyogaz ve metan üretim oranlarını deneysel veri setinden yola çıkarak tahmin etmiş ve model sonuçlarının korelasyon katsayıları sırasıyla 0.967 ve 0.961 olarak elde edilerek biyogaz ve metan için tatmin edici sonuçlar bulunmuştur.

Bu YSA çalışmasında 11 farklı geri yayılım algoritması arasından scaled conjugate gradient algoritması en iyi algoritma olarak seçilmiştir. Biyogaz ve metan tahminleri sırasında gizli tabaka'da kullanılacak optimize nöron sayıları sırası ile 9 ve 12 olarak bulunmuştur.

YSA tarafından tahmin edilen sonuçlar, aynı veri seti için elde edilen 2 adet eksponansiyel non-lineer regresyon analiz sonucu ile karşılaştırılmıştır. Yapılan çalışma sonucunda açıkça görülmektedir ki, non-lineer regresyon model sonuçları ile YSA tabanlı model sonuçlarının karşılaştırılmasında YSA model sonuçları biyogaz ve metan için daha uygundur.

**Anahtar Kelimeler:** Melas atıksuyu, yukarı akışlı havasız çamur yataklı reaktör (UASB), yapay sinir ağları, modelleme, regresyon modeli, biyogaz, metan

**ARTIFICIAL NEURAL NETWORK-BASED MODELING TO PREDICT BIOGAS AND METHANE PRODUCTION RATES IN A PILOT-SCALE MESOPHILIC UP-FLOW ANAEROBIC SLUDGE BLANKET (UASB) REACTOR TREATING MOLASSES WASTEWATER**

İlknur TEMİZEL

Department of Environmental Engineering

MSc. Thesis

Advisor: Assist. Prof. Dr. Kaan YETİLMEZSOY

Co-Advisor: Assist. Prof. Dr. İltar TURKDOĞAN AYDINOL

Two three-layer artificial neural network (ANN) models (8:9:1 and 8:12:1) were respectively developed to predict biogas and methane production rates in a pilot-scale mesophilic up-flow anaerobic sludge blanket (UASB) reactor treating molasses wastewater.

Eight input variables such as volumetric organic loading rate (OLR), operating temperature, influent and effluent alkalinity, influent and effluent pH, effluent COD and volatile fatty acids (VFA) concentrations were modelled by the use of an artificial intelligence-based approach.

In the study, proposed ANN-based models were created by using MATLAB® V7.0 software program. After backpropagation (BP) training combined with principal component analysis (PCA), the ANN models predicted biogas and methane production rates based on the experimental data, and all the predictions were proved to be satisfactory with correlation coefficients of about 0.967 and 0.961 for biogas and methane, respectively.

In the ANN study, the scaled conjugate gradient algorithm was found as the best of 11 BP algorithms. The numbers of neurons in the hidden layer were optimized as 9 and 12

for the ANN models in estimation of biogas and methane production rates, respectively.

The ANN predicted results were also compared with the outputs of two exponential non-linear regression models derived in this study. Findings of this study clearly indicated that, compared to non-linear regression models, the proposed ANN-based models produced smaller deviations and exhibited a superior predictive performance on forecasting of both biogas and methane production rates. Both ANN outputs and linear/non-linear study results were compared and advantages and further developments were evaluated.

**Key words:** Molasses wastewater, up-flow anaerobic sludge blanket (UASB), artificial neural network, modeling, regression model, biogas, methane

### GİRİŞ

Ülkemizde uzun yıllardan beri özellikle İç Anadolu Bölgesi başta olmak üzere şeker pancarı ve şeker kamışı hammaddelerinden şeker üretimi gerçekleştirilmektedir. Ancak, ülkemiz ekolojisi şeker kamışı tarımına uygun olmadığından dolayı şeker üretimi şeker pancarı üzerinden gerçekleştirilmektedir. Şeker pancarı tarımı ve şeker fabrikaları ülkemize Cumhuriyet Dönemi ile birlikte girmiş olmaktadır. Ülkemizde ilk şeker fabrikası 1925 yılında Uşak'ta kurulmuş olup, ilk şeker üretimi 2006 yılında gerçekleştirilmiştir. Ülkemiz sınırları içerisinde üretilen şeker miktarının gereksinimlerin üzerinde çıkması ve stokların artması neticesinde önemli sorunlar yaşanmıştır. Ancak, 1998 yılında üretilen şeker pancarı miktarına yönelik kota uygulaması kararı ile de bu soruna çözüm bulunarak ülkemizde şeker üretimi ve arzında istikrar sağlanmıştır [1].

#### 1.1 Literatür Özeti

Gıda endüstrisi, ülkemizde olduğu gibi dünya çapında da en büyük sektörlerden biridir. Özellikle şeker endüstrisi, gerek insan beslenmesi ve sağlığı üzerindeki etkileri gerekse de sektörel ve endüstriyel açıdan ülke ekonomilerine sağladığı katkılardan dolayı ülkemiz ve dünya çapında gıda endüstrisi içerisinde bir adım öne çıkmaktadır. Şeker endüstrisi, her ne kadar diğer endüstri kollarına nazaran çevreye zarar vermeyen bir sektör olarak düşünülse de, söz konusu prosesin dikkatli ve özenli tasarlanmaması durumunda ciddi bir organik kirlilik meydana gelebilmektedir.

Hammadde olarak melas maddesini kullanan şeker fabrikalarında uygun arıtma yapılmadığı takdirde yüzeysel sularda ciddi derecede kirlilik gözlemlenebilmektedir.



Ayrıca, melas atık sularının sahip olduğu asidik karakterizasyon ve yüksek konsantrasyonda mineral tuzlar içermesinden dolayı, kontrolsüz olarak deşarj edildiği bölgelerde kötü kokuya neden olmakta ve içerdiği melanoidin pigmenti sebebiyle de sucul ortamda koyu bir renk oluşturmaktadır.

Ülkemiz nüfusu orantılı olarak yiyecek ve içecek sektörüne olan talep artışı dikkate alındığında, melas atık sularının son yıllarda en önemli ve en ciddi problemler arasında yer alabileceği tahmin edilmektedir. Yukarıda belirtilen sebeplerden dolayı, yüksek oranda kirletici içeriğine sahip olan melas atık suyunun alıcı ortama verilmesinden önce mutlaka uygun yöntemlerle arıtılması gerekmektedir.

Literatürde, melas atıksularının arıtılmasına yönelik gerçekleştirilen güncel çalışmalar genel olarak incelendiğinde, bu çalışmaların çoğunun fizikokimyasal esaslı olduğu ve daha ziyade renk ve organik madde giderimi konularıyla sınırlandırıldığı görülmektedir. Özellikle, son yıllarda evsel atık sular dâhil olmak üzere, gıda işleme ve kâğıt endüstrisi atık suları ve hayvansal atıklar gibi organik içerikli pek çok atık ve atık sular hem havasız (anaerobik) olarak arıtılmakta, hem de biyogaz üretimiyle yenilenebilir enerji kaynağı olarak kullanılmaktadır [2]. Bu maksatla, yüksek bir organik madde potansiyeline sahip melas atık sularının anaerobik sistemlerde arıtılmasının, çevre kirliliğinin kontrolü ve yenilenebilir enerji kaynaklarının geliştirilmesi açısından oldukça önemli potansiyel faydalar sağlayacağı düşünülmektedir.

## **1.2 Tezin Amacı**

Ülkemiz nüfusunun artması ve şüphesiz ki artmaya devam edecek olması, gıda sektörüne ve dolayısıyla da şeker endüstrisine olacak talebin artacağı yönünde bir izlenim vermektedir. İhtiyaç dahilinde üretilen şekerin bir yan ürünü olan melas ve proses sonucu açığa çıkan atıksuların alıcı ortama deşarj edilmesi öncesinde muhakkak uygun bir arıtma sisteminden geçirilmesi zorunlu olduğundan, konu ile ilgili arıtılabilirlik çalışmaları son yıllarda hız kazanmıştır.

Literatür dâhilinde şimdiye kadar yapılan çalışmaların daha çok renk ve organik madde giderimi gibi fizikokimyasal alanlarda kısıtlandığı görülmektedir. Yüksek organik içeriğe

sahip melas atık sularının özellikle havasız (anaerobik) sistemlerle gideriminin sağlanmasının, konuya faydalı bir çözüm getirebileceği ve bu alandaki literatür boşluğunun doldurulmasına önemli bir katkı sağlayacağı düşünülmektedir.

Cammerer vd. [3] aminoasitlerle oligomer ve polimer yapıda olan karbonhidratlardan meydana gelen ve model olarak seçilen melanoidinlerin kimyasal olarak parçalanması üzerinde çalışmışlardır. Kim vd. [4], glukoz-glisinden hazırlanmış model melanoidinlerin ozon gazı uygulaması ile parçalanması ve renk giderimi üzerinde çalışmışlardır. Araştırmacılar, -10°C'de 10 ve 90 dakika ozon uygulamışlar ve 10 dakikada %84, 90 dakikada ise %97 oranında renk giderimi sağlandığını gözlemişlerdir. Çalışmada, ozonlama yapıldıktan 40 dakika sonra melanoidinlerin molekül ağırlığının azaldığını tespit edilmiştir. Bunun yanında, bazı anaerobik ve aerobik bakteri türlerinin melanoidin pigmentini parçalayıp kullanma özelliklerinin olduğu belirlenmiştir [5]. Literatürde; *Lactobacillus hilgardii* W-NS, *Bacillus sp* [6], [7], asetojenik bakteri *BP103* ile [8], *Pseudomonas aeruginosa* PA01, *Stenotophomonas maltophila* ile *Proteus mirabilis* [9], gibi mikroorganizmalarla melanoidinin giderimi konusunda çalışmaların yapıldığı görülmektedir.

Anaerobik arıtma sistemleri hidrodinamik şartlara, işletme koşullarına ve reaktör türlerine bağlı olarak oldukça kompleks bir davranış sergilemektedir. Bu açıdan anaerobik arıtma sistemleri pH, sıcaklık, alkalinite, uçucu yağ asitleri gibi temel fizikokimyasal parametrelerin yanında, proseste biyokütle aktivitesinin bir göstergesi olan biyogaz ve metan üretimleri açısından sürekli izlenmesi gereken biyolojik proseslerdir. Ancak, anaerobik arıtma sistemleri giriş pH değeri, organik ve hidrolik yükleme oranları, toksik madde konsantrasyonu, şok yüklemeler gibi birçok proses şartından kolayca etkilenmekte olduğundan, prosesten sağlanacak biyogaz ve metan üretimleri de uygulanan proses koşullarına ve girdilerine oldukça bağımlılık göstermektedir. Bu maksatla, çok sayıda sistem faktörünün arasındaki bu kompleks ve non-lineer ilişkinin prosesi temsil edici bir yapay zekâ esaslı tahmin modeli ile araştırılmasına yönelik modelleme çalışmalarının, değişen proses şartlarının daha hızlı ve daha hassas analizi açısından oldukça önemli olduğu düşünülmektedir [10].

Her ne kadar anaerobik arıtma prosesleri biyokimyasal açıdan oldukça kapsamlı olarak incelenmiş olsa dâhi, literatürde proses parametreleri arasındaki ilişkileri matematiksel modeller ile araştıran çalışmaların yetersiz olduğu görülmektedir. Literatürdeki bu boşluk göz önüne alındığında, karakutu tahmin modellemesi alanında en çok uygulanan yapay zekâ modellerinden olan yapay sinir ağları (YSA) esaslı modelleme tekniği ile anaerobik proseslerin entegre edilmesi konusundaki araştırmalar, bu çalışmanın esasını teşkil etmektedir.

### **1.3 Bulgular**

Bu çalışmada, melas atıksularının arıtımında Yukarı Akışlı Havasız Çamur Yataklı Reaktör (YAHÇYR) sisteminden elde edilen potansiyel biyogaz ve metan üretimlerinin iyi eğitilmiş bir YSA modeli ile tahminine yönelik olarak MATLAB® yazılım programı ile bilgisayar esaslı bir araştırma yapılmıştır. Söz konusu YSA modelinin başarılı bir tahmin performansı göstermesi durumunda, farklı proses şartları ve giriş parametrelerindeki salınımlar için biyogaz ve metan üretimlerinin hızlı bir tahmini yapılabilecek ve böylece prosesin stabilitesi etkileyebilecek muhtemel hataların önceden tespiti sağlanabilecektir. Bunun yanında, başarılı bir model performansı ile prosesin işletme maliyetinin düşürülmesi gibi potansiyel faydaların, pilot ölçekli sistemden sanayi ölçekli sisteme geçiş aşamasında YSA ile tahmin modelleme tekniğinin kullanılmasını teşvik edeceği düşünülmektedir.

Bu çalışma kapsamında, YAHÇYR sisteminde melas atıksularının arıtılması sonucu elde edilen metan ve biyogaz üretimlerinin yapay sinir ağları ile modellenmesi çalışılmış olup, şu alt adımlar izlenmiştir:

- Melas atıksularının arıtımında kullanılan YAHÇYR sisteminden elde edilen deneysel bulgular ve sistemin özellikleri incelenmiştir.
- YAHÇYR sisteminden elde edilen deneysel bulgular ve literatürdeki veriler ışığında, bu çalışmada uygulanan YSA modelinin potansiyel girdi ve çıktı değişkenleri değerlendirilmiş ve çok sayıda farklı girdi-çıkı denemeleri yapılarak en uygun girdi-çıkı yapısı seçilmiştir.

- Bir önceki kademede belirlenen girdi-çıkı yapıları ile çok sayıda farklı eğitim algoritmasının (*training algorithm*) mukayesesi yapılmış ve en uygun eğitim algoritması belirlenmiştir.
- En uygun eğitim algoritması için farklı aktivasyon ve transfer fonksiyonlarının kombinasyonları ele alınmış ve böylece en uygun model yapısı belirlenmiştir.
- Seçilen aktivasyon ve transfer fonksiyonları için ele alınan en iyi eğitim algoritmasının kendi içinde ortalama karesel hata (*mean squared error, MSE*) esaslı bir hata analizi yapılmış ve YSA modelinin gizli katmanındaki (hidden layer) optimum neuron sayısı belirlenmiştir.
- Önceki kademeler doğrultusunda bu çalışmada uygulanan en uygun YSA modelinden elde edilen tahmin neticeleri ile deneysel bulgular çok sayıda istatistiksel parametre için mukayese edilmiş ve tahmin sonuçlarının validasyonu/verifikasyonu yapılmıştır.
- YSA modelini teşkil eden her bir girdi değişkeninin seçilen çıktılar üzerindeki etkisini belirlemek amacıyla bir hassasiyet analizi (*sensitivity analysis*) çalışması yapılmıştır.
- Çalışma kapsamında ayrıca DataFit® yazılım programı ile bir non-lineer modelleme çalışması gerçekleştirilmiş ve önerilen tahmin modellerin kendi içinde ayrıca bir mukayesesi de yapılmıştır.

---

### MELAS ATIKSULARININ ARITILABİLİRLİĞİ KONUSUNDA YAPILAN ÇALIŞMALAR

Çevre yönetmeliklerinin daha sıkı olması ve çevresel uyumun önem kazanmasından dolayı fermentasyon ve yemek endüstrilerinde çevre ile ilgili konular önem kazanmıştır. Bu ve benzeri nedenlerden ötürü melas suyu çıkış kalitesini yükseltebilmek amacıyla birkaç farklı metod sunulmuştur.

Sirianuntapiboon ve Prongtong'un [11] yürütmüş olduğu bir çalışma da melas atıksuyundan, biyolojik ve kimyasal prosesleri birleştirerek renk giderimi gerçekleştirilmiştir. Çalışma neticesinde ise renk içeriğinin koagülantlar (CaO ve FeCl<sub>3</sub>) ile giderildiği saptanmıştır. Ancak renk giderim verimini koagülasyon adımın da arttırmak adına, çalışmacılar tarafından melas atıksuyuna ön arıtma olarak çamur eklemesi yapılarak ya da yapılmayarak 96 saat boyunca havalandırma yapılması tavsiye edilmektedir.

Pena ve arkadaşları [12] tarafından yürütülen bir diğer çalışmada ise renk giderimi biyolojik olarak ön arıtılmış melas atıksuyunun ozon ile kimyasal oksidasyon uygulanması şeklindedir. Çalışma sonucunda ozonlama işleminin renk giderimi için etkili ancak organik madde gideriminde daha az etkili olduğu gözlemlenmiştir. Çalışmacıların raporları doğrultusunda, ozon dozajına bağlı olarak 30 dk'lık reaksiyon zamanının da, renk gideriminin % 71'den %93'e, TKOİ gideriminin %15'ten %25'e ulaştığı gözlemlenmiştir.

Zhang ve arkadaşlarının [13] çalışmasında ise; UASB-MFC-BAF (yukarı akışlı anaerobik çamur yataklı reaktör- mikrobiyal yakıt hücresi – biyolojik havalandırmalı filtre) entegre sistemleri kullanılarak eş zamanlı bioelektrik üretimi ve yüksek güçte melas atıksuyu arıtımı gerçekleştirilmiştir. Çalışma sonucunda TKOİ, sülfat, ve renk giderim verimleri sırasıyla %53.2, %52.7, %41.1 olarak elde edilmiştir.

Sirianunatapiboon ve Prasertsong [14], tarafından yapılan çalışma ise; melas atık suyunun asetojenik *BP103* bakterisi ile ardışık yataklı reaktörde arıtılması üzerinedir. BP103 bakterisi çalışmada melas atıksuyu ve melanoidin pigmenti (MP) için absorbent olarak kullanılmıştır. Araştırmalar sonucunda TKOİ, BOİ<sub>5</sub>, TKN (toplam Kjeldahl azotu) ve MP giderim oranları sırasıyla %65.2, %82.8, %32.1 ve %50.2 ortalama değerlerini göstermiştir.

Liang vd. [15] tarafından gerçekleştirilen bir başka çalışmada ise laboratuvar ölçekli bir sistemde melas atıksuyu nihai arıtımında koagülasyon/flokülasyon prosesi gerçekleştirilmiştir. Çalışma sonucunda, ferrik kloridin biyolojik olarak arıtılan melas atıksuyundan giderimi en etkili madde olduğu sonucuna varılmış ve sırasıyla renk ve TKOİ giderim verimlerinin 98% ve 89% değerinde olduğu belirlenmiştir.

Son olarak Sohsalam ve Sirianunatapiboon [16], yüzey akışlı ıslak alan sisteminde *Cyperus involucratus*, *Typha augustifolia* ve *Thalia dealbata* ile çalışmışlardır. Sistemde çalışılan organik yükleme oranı 612 ve 1213 kg BOİ<sub>5</sub>/ha-gün arasındadır. Üzerinde çalışılan yüzey akışlı ıslak alan sisteminden elde edilen maksimum askıda katı madde, BOİ, TKOİ, toplam fosfor, amonyum nitrojen, nitrat nitrojen ve melas pigmentleri giderim verimleri sırasıyla; %90-93, %88-89, %67, %70-76, %77-82, %94-95 ve %72-77 olarak en düşük organik yükleme oranı (612 kg BOİ<sub>5</sub>/ha-gün) ile çalışıldığında elde edilmiştir.

Melas atıksuyu ile yapılmış olan çalışmaların çoğunluğu renk giderimi üzerine olup, havasız arıtma gibi farklı kategorilerde yapılan çalışmaların yetersiz olduğu gözlenmiştir. Özellikle, melas atıksuları üzerine yapılan çalışmaların yapay sinir ağları ile modellenmesi yönünde literatürde spesifik bir çalışma yapılmadığı görülmüştür. Bu tez

çalışmasıyla söz konusu literatür boşluğunun doldurulması yönünde önemli katkılar sağlandığı düşünülmektedir.

## **2.1 Melas Maddesinin Genel Karakterizasyonu**

Şeker ihtiyacının nüfus ile doğru orantılı olarak artması ve bu talebin ülke sınırları içerisinde karşılanabilmesi sonucunda, melas atıksuyu ülkemizdeki çevre sorunları arasında yerini almıştır. Arz-talep sonucu sektörden oluşan bu atıkların ve atıksuların, Avrupa Birliği Uyum Yasa Tasarısı doğrultusunda gelen yeni yönetmelikler neticesinde, alıcı ortama istenilen sınır değerlerinde deşarj edilmesi zorunlu hale gelmiştir. Ülkemizdeki şeker üretimine bakıldığında; 2000 yılı 763,000 ton olan melas üretimi, 2003 yılında 520,000 tona düşmüş, 2004–2005 kampanya döneminde ise azami 600,000 ton civarında tahmin edilmiştir [17].

Amasya Şeker Fabrikası' nın 54. pancar alım kampanyasında, 100 bin 985 dekar alan da ekilen ve şeker fabrikasına teslim edilen 367 bin 619 ton şeker pancarından 329 bin tonu işlenirken, kampanyanın sürdüğü 71 günlük zaman içinde 37 bin 400 ton şeker üretimi, 149 bin 730 ton yaş küspe üretimi, 15 bin 600 ton melas üretimi yapılmıştır. 2009-2010 yılı içerisinde Çorum şeker fabrikası 419 bin şeker pancarı işleneceğini belirterek, 62 bin ton kristal şeker, 110 bin ton yaş pancar posası ve 19 bin ton melas üretimi planlandığını belirtmiştir [18].

Kamış ve pancar şekeri fabrikalarında, sakkarozun kristal halde elde edilmesi için yapılan kademeli işlemlerin en sonunda geriye kalan ve koyu kahve renkli ortalama %50 şeker ihtiva eden yüksek viskoziteli (kıvamlı) şuruba melas denmektedir.

Pratik tanımıyla melas, şeker üretim prosesi neticesinde içerisinden artık daha fazla sakaroz kristalize edilmesi masraf ve zaman ekonomisi açısından verimli olmayan bir kalıntıdır.

Koyu renkli ve kıvamlı bir madde olan melasın kuru madde miktarı yere ve yönteme göre çok az değişmesine rağmen ortalama %77-82 dolayında ve içerdiği şeker miktarı da %50'dir [19].

Sorghum şurubu olarak da bilinen melasın çoğu Küba, Brezilya ve Hindistan gibi sıcak iklimli ülkelerde yetişen şeker kamışından elde edilir. Pancar melası ise daha çok ılıman iklime sahiptir ve Amerika, Almanya, Fransa ve diğer ülkelerde üretilir. Melasın kalitesi, şeker kamışı ya da şeker pancarının olgunluk seviyesine, ekstrakte edilen şekerin miktarına ve ekstraksiyon metoduna bağlıdır [19].

Şeker fabrikalarında, şeker pancarından kristal şeker elde edilirken hasat şekli, depolama şartları ve şeker elde etme yöntemine bağlı olarak kristallendirilemeyen en son şurup şeklinde yaklaşık %4 oranında melas kalır [20].

Melas maddesi genel olarak; hayvancılık (düşük sakkaroz oranlı melas), kömür sanayi, gübre yapımı, yem üretimi, alkol üretimi ve maya üretiminde de kullanılmaktadır.

Tüm bu kullanım alanlarının yanı sıra melas, çeşitli mikro organizmalar kullanılarak aerobik ve anaerobik fermantasyonla protein ve çeşitli kimyasal maddelerin (formik asit, asetik asit, sitrik asit, glukonik asit, glukarik asit, okzalik asit, aseton, glikoz vs.) üretiminde ilaç sanayinde (antibiyotikler), döküm kaplamada bağlayıcı madde ve pürüzsüz yüzey çıkarmada da kullanılmaktadır [21].

Melasın bileşimi; inorganik maddeler, su, şeker ve şeker dışı organik maddelerden oluşan kompleks bir karışımdır. Melas, ortalama %75-80 kuru madde ve bu kuru maddenin %48-52'si toplam şeker ve %25-28'i şeker dışı maddelerden oluşur. Melasta şeker olarak başlıca sakkaroz bulunur. Şeker dışı maddeler hücre gelişimini ve fermantasyonu uyarıcı ve baskılayıcı maddelerden oluşur. Ticari amaçla kullanılan melasta toplam şeker %47'den daha az, pH değeri 6.8'den aşağı olmamalı ve SO<sub>2</sub> içeriği %0.15'i geçmemelidir [22].

Büyük bir bölümü betain maddesinden oluşan melastaki toplam azot miktarı %1.2-2.4 arasında bulunmaktadır [23]. Melasta nitrat %0.8 ve nitrit %0.03'ten fazla olmamalıdır. Melasların uçucu asitleri (asetik asit, bütirik asit) toplam olarak %0.1-0.3'ten fazla olmamalı, eğer uçucu asit miktarı %0.35-1.0 arası ise melas ön işlemlere (asitlendirme ve kaynatma) tabi tutulmalıdır. %0.005'ten fazla bütirik asit mayayı olumsuz yönde etkilemekte ve %1 mertebesindeki bütirik asit ise fermentasyonu tamamen durdurmaktadır. Ülkemizdeki şeker fabrikalarında elde edilen melaslar, genelde bu



olumlu miktarları içermektedirler. Melasta, sadece uçucu asitlerin miktarları fazla olup, inorganik fosfor miktarı düşüktür. Fermantasyon esnasında bu olumsuz durumları düzeltmek için melas önce asitlendirilir ve daha sonra kaynatılır. Böylece, uçucu asitler uzaklaştırılmış olur. Fermantasyondan önce de ortama inorganik fosfor kaynağı olan maddeler ilâve edilerek de fosfor eksikliği tamamlanmalıdır [24]. Melas maddesinin genel karakterizasyonu Çizelge 2.1-2.4'te verilmiştir.

Çizelge 2.1 Melasın genel özellikleri [19]

Parametre	Özellik
Tad ve koku	Tatlı, kendine has keskin kokusu olmalı
Renk ve yapı	Koyu kahverengi pekmez kıvamında, yarı akışkan viskoz sıvı
Görünüm	Homojen renk ve görünüşte olmalı
Dökme yoğunluk	En az 1.0 gr/cm <sup>3</sup>
Polarizasyon	En az %46
Briks	%81-87
Safiyet	%55-65
pH	7 ve üzeri

Çizelge 2.2 Melas içeriği [19]

Parametre	Değer
Protein	%4,0
Kuru madde miktarı	%72,0
Kalsiyum	%0,9
Fosfor	%0,1
Potasyum	%2,5

Çizelge 2.3 Şeker pancarı melasının bileşimi [25]

Parametre	Değer
Kuru madde	%85
Polar şeker	%50
Arılık	%58,8
Şeker dışı madde/100 Kuru madde	41,2
Azotlu şeker dışı madde	%14
Azotsuz şeker dışı madde	%16
Kül	% 11,2

Çizelge 2.4 Melasın Kimyasal Özellikleri [26]

Özellikler	Miktar
Kuru maddesi %, en az	77,0
Sakaroza %, en az	48,0
Özgül ağırlık, en az g/cm <sup>3</sup>	1,2
Ham kül %, en çok	12,0
İnvert şeker %, en çok	0,60
Arsenik mg/kg, en çok	1,0
Bakır mg/kg, en çok	18,0
Çinko mg/kg, en çok	100,0
Demir mg/kg, en çok	100,0
Kalay mg/kg, en çok	100,0
Kurşun mg/kg, en çok	2,0

Melasın yem sanayinde kullanımı da görülmektedir. Bu kullanım alanının başlıca nedeni, melasın yüksek enerji kaynağı olmasıdır. İçeriğinde şeker ve azot, protein, vitamin vb. organik maddelerce zengin melas hayvan beslenmesinde kullanılan değerli

bir sanayi hammaddesidir. Şeker fabrikalarının iki önemli yan ürünü olan melas ve küspe, belirli oranlarda karıştırılarak yine değerli bir hayvan yemi olan “melaslı kuru küspe” elde edilir. Ülkemizde halen 8 şeker fabrikasında küspe kurutma tesisi mevcuttur. Bunun yanı sıra melas, hayvan yeminde lezzeti arttırmakta, tat olarak acı besin bileşenlerinin alımını kolaylaştırmakta, toz ve toprak miktarını azaltarak iyi bir karışım sağlamak ve maliyeti düşürmektedir.

## BÖLÜM 3

### YAPAY SİNİR AĞLARI

Yapay sinir ağları (YSA), insan beyninin en önemli özelliklerinden olan öğrenme yolu vasıtası ile yeni bilgiler türetebilme, bu yeni bilgileri oluşturabilme ve keşfedebilme gibi yetenekleri, herhangi bir yardım almadan otomatik olarak gerçekleştirebilen yani tüm canlılarda bulunan sinir sisteminin çalışmasını elektronik ortama taşımayı hedef haline getiren bir bilgisayar programıdır. Yapay sinir ağları insanlarda olduğu gibi öğrenme, hatırlama ve öğrenilmiş olunan bilgilerin güncellenmesi gibi yeteneklere sahip olabilecek şekilde tasarlanmıştır.

Öğrenme, hatırlama ve güncelleme gibi yeteneklere sahip olunması istenilen yapay sinir ağları üzerinde ki ilk çalışmalar insan beyninden esinlenerek gerçekleştirildiği için öncelikle insan beynini oluşturan nöronların modellenmesi ve bilgisayar sistemlerinde uygulanması şeklinde çalışmalar yapılmıştır. Bu konuda ki çalışmaların ardından bilgisayar sistemlerinin de zamanla gelişme göstermesi üzerine yapay sinir ağları ile yapılan çalışmaların kapsamı ve kullanılabilirliği gelişmiştir.

Çizelge 3.1 Bilgisayar ve insan beyni arasındaki çalışma sistemlerinin karşılaştırılması

BİLGİSAYAR	İNSAN BEYİNİ
Sayısal	Analog
Seri	Paralel
Komut kümeli	Bilgiye Adapte Olma
Yanlış Hesaplamalar Sonucu Etkiler	Birimlerin Ana İşlemlere Etkisi Azdır
Giriş Verilerindeki Hatalar Sonucu Etkiler	Giriş Verilerindeki Hatalara Herzaman Duyarlı Değildir

### 3.1 Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağları genel olarak canlı beyninin yapısını bilgisayar ortamında simule ederek aşağıdaki işlemleri gerçekleştirebilir:

- Öğrenme
- İlişkilendirme
- Sınıflandırma
- Genelleme
- Tahmin
- Özellik belirleme
- Optimizasyon [27]

YSA'larda sistemin paralelliği ve toplamsal işlevin yapısal olarak dağılımı söz konusudur. YSA'lar birçok nörondan meydana gelir ve bu nöronlar eş zamanlı olarak çalışarak karmaşık işlevleri yerine getirir. Diğer bir deyişle karmaşık işlevler birçok nöronun eş zamanlı çalışması ile meydana getirilir. Süreç içerisinde bu nöronlardan herhangi biri işlevini yitirse dahi sistem güven sınırları içerisinde çalışmasına devam edebilir.

Bir diğer özellik ise genelleme yeteneği, diğer bir deyişle ağ yapısının, eğitim esnasında kullanılan nümerik bilgilerden eşleştirmeyi betimleyen kaba özellikleri çıkarması ve böylelikle eğitim sırasında kullanılmayan girdiler için de, anlamlı yanıtlar üretebilmesidir.

Ayrıca ağ fonksiyonları non-lineer olabilmektedir. Yapı üzerinde dağılmış belli tipteki non-lineer alt birimler özellikle, istenen eşleştirmenin denetim ya da tanımlama işlemlerinde olduğu gibi non-lineer olması durumunda işlevin doğru biçimde yerine getirilebilmesini matematiksel olarak olası kılarlar.

Sayısal ortamda tasarlanan YSA'ların, donanımsal gerçekleştirilebilirlikleri söz konusudur. Bu özellik belkide YSA'ların günlük hayatta daha da fazla yaşamımızın içine gireceğinin (girebileceğinin) göstergesidir [28].

### 3.2 YSA'ların Avantaj ve Dezavantajları

YSA'lar işlevleri gereği bilgisayarların öğrenmesini sağlamaktadırlar. Söz konusu durumlara hâkim olarak, olaylara mantıklı bir açıdan yaklaşp en uygun kararı verebilmektedirler.

Sahip olunan bilgileri, sistemleri yapısındaki çok çeşitli veri işleme metotları ile çalıştırdıkları için geleneksel metotlara nazaran çok daha az bakiye hata oluştururlar.

Kullanılan ya da elde edilen bilgilerin tamamı sistemde saklanmaktadır. Geleneksel programlardaki veri tabanı ya da dosyalama düzeneklerinden ziyade ağ bağlantılarında muhafaza edilir. Nöronların bir kaçının işlevini yitirmiş olması durumunda anlamlı bilgilerin kaybolması durumu söz konusu değildir.

Sisteme tanıtılan örnekler, YSA'nın örnekleri ağa tanıtılarak istenen çıktılar doğrultusunda ağın eğitilmiş olması ile sonuçlanmaktadır. Sistemin başarılı olması seçilen veri setiyle alakalı olup, sisteme iyi tanıtılmaması durumunda elde edilen çıkış verilerinin de yanlış olmasına yol açabilir.

YSA'lar sisteme tanıtılan veri setleri ile eğitimleri sırasında tanıtılan örneklendirmelerden genellemeler çıkararak yeni örnekler hakkında bilgi üretebilirler.

YSA'ların algılamaya yönelik olaylarda ki başarıları, yapılan çalışmalar dâhilinde kanıtlanmıştır.

Sisteme tanıtılan örnekler halinde verilen örüntüler YSA'lar tarafından diğer örnekler ile ilişkilendirilebilir ve yeni örneklendirmelerinde hangi sete ne şekilde dâhil olabileceği konusunda karar verebilme yetileri mevcuttur.

Sistemin on-line olarak öğrenebilme ve kendilerini eğitebilme yetenekleri mevcuttur. Eksik bilgi ile çalışabilmekte ve çıktı üretebilmektedirler. Bu ve benzeri durumlarda performans kaybı yaşanmaz. Ancak performans kaybının önemi eksik bilgiye göre değişiklik gösterir. Sisteme tanıtılan veri setinde ki unsurların önem dereceleri de eğitim sırasında tanıtılır.

YSA'ları eksik bilgi ve veri kaybında dahi çalışabilmeleri, hatalara karşı toleransını gösterir.

YSA'lar zamanla ağlar da oluşabilecek problemlerden dolayı yavaş ve göreceli bir bozulmaya uğrarlar. Bu bozulma dereceli bir şekilde (graceful degradation) gerçekleşir. Sistemde birden çökme gerçekleşmez.

YSA'ların sahip olduğu bağlantıların tek başına bir anlamı yoktur. Sistemde bilgiler ağa dağıtılmış bir şekildedir ve hücrelerin bağlantı, ağırlık dereceleri o ağın bilgisini göstermektedir.

Bu kısma kadar avantajlarından bahsedilen YSA'ların dezavantajlarına bakacak olursak;

Bu sistemlerin en önemli sorunu donanım gereksinimidir. YSA'lar paralel işlem yapabilme yeteneğine sahiptir ve bu yüzden paralel çalışan işlemciler ile performans gösterirler.

YSA'larda uygun veri setinin belirlenebilmesi için herhangi bir kural yoktur. Uygun olan ağ yapısının bulunması deneyim ve deneme yanılma yolları ile belirlenebilmektedir.

YSA'ların öğrenme katsayısı, hücre sayısı ve katman sayısı gibi parametrelerin belirlenmesinde belirli kurallar yoktur. Belirli kuralların olmaması ile birlikte her bir veri seti için farklı yaklaşımlar söz konusu olabilir.

Sisteme öğretilmesi gereken durumun gösterilmesi de bazı sorunlara yol açabilmektedir. YSA'lar nümerik bilgilerle çalışmakta ve sisteme veriler tanıtılmadan önce hepsinin nümerik değerlere çevrilmesi gerekmektedir. Bu esnada oluşabilecek aksilikler sistemin verimini etkilemekte bu da doğrudan kullanıcının kabiliyetine bağlı olmaktadır.

YSA'lar da problemlerin çözümü sonrasında gerçekleşen olayların nasıl ve neden olduğu ile ilgili bilgi edinilemediğinden, sistemin davranışlarının açıklanması konusunda sıkıntılar yaşanmaktadır.

Geleneksel algoritmalar ile YSA'ların mukayesesi ile ilgili birkaç madde Çizelge 3.2'de gösterilmiştir.

Çizelge 3.2 Yapay Sinir Ağlarının Mimarisi ve Yapı Elemanları [28]

Geleneksel Algoritmalar	Yapay Sinir Ağları
Çıktılar, koyulan kurallara girişlerin uygulanması ile elde edilir.	Öğrenme esnasında giriş çıkış bilgileri verilerek, kurallar koyulur.
Hesaplama; merkezi, eş zamanlı ve ardışıktır.	Hesaplama; toplu, eş zamansız ve öğrenmeden sonra paraleldir.
Bellek paketlenmiş ve hazır bilgi depolanmıştır.	Bellek ayrılmış ve ağa yayılmıştır. Dâhildir.
Hata toleransı yoktur.	Hata toleransı vardır.
Nisbeten hızlıdır.	Yavaş ve donanıma bağımlıdır.
Bilgiler ve algoritmalar kesindir.	Deneyimden yararlanır.

Yapay sinir ağları insanların biyolojik sinir sistemi yapısından yola çıkılarak geliştirilen bir sistem olduğu için yapay sinir ağlarının çalışmasını anlayabilmek adına öncelikle biyolojik sinir sisteminin yapısına bakmak gerekir. Biyolojik sinir sisteminin yapı taşı olan sinir hücreleri nöronlar, yapay sinir ağlarının da yapı taşıdır [27], [28], [29].

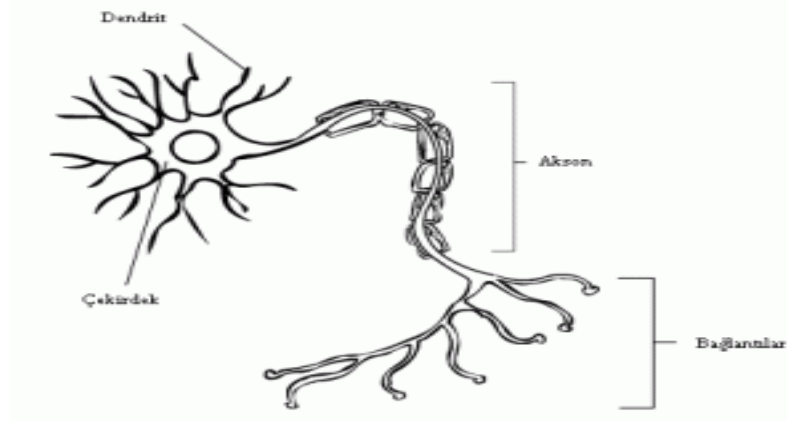
### 3.3 Nöronun Biyolojik Yapısı ve Nöron Modelleri

İnsanlar da elde edilen bilgilerin işleme olayı beyin de gerçekleşmektedir. Cerebral Cortex denilen "beyin" sahip olunan en karmaşık sinir ağlarına sahiptir. Sinir sisteminin en basit yapısı nöronlardır. Beyinde yaklaşık olarak  $10^{10}$  sinir hücresi vardır ve hücre başına bağlantı sayısı ise  $10^4$  mertebesindedir. Beynin sahip olduğu çalışma frekansı 100 Hz olup, fiziksel boyutları ise 1.3 kg ve  $0.15 \text{ m}^2$  dir. Vücudun değişik yerleri ile bilgi alışverişi yapan ise nöron hücresidir.

Biyolojik sinir sistemlerinin temel elemanı olan nöronlar 4 bölümde oluşmakta olup, bunlar sırası ile; dendrit, akson, çekirdek ve bağlantılardır. Dendritler sinir hücrelerinin ucunda yer alıp, ağaç kökü gibi bir görüntüye sahiptirler. Dendritler temel olarak bağlı oldukları nöron veya duyu organlarından aldıkları sinyalleri çekirdeğe iletme görevini

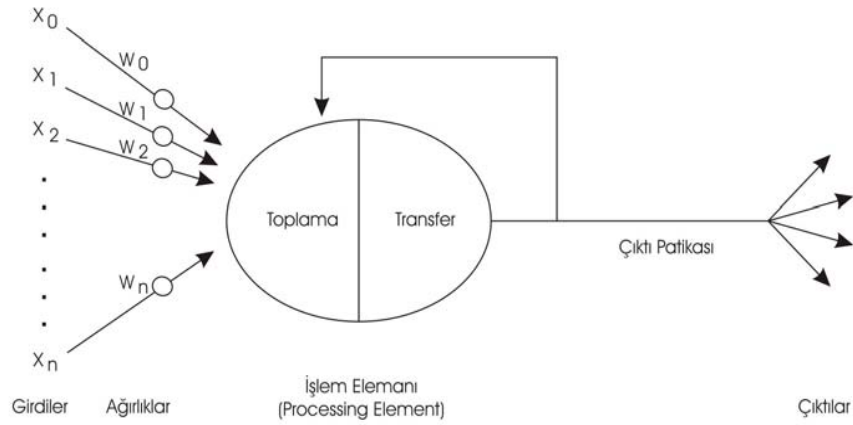


gerçekleştirirler. Çekirdek de dendrit vasıtasıyla gelen sinyalleri bir araya toplayıp aksonlara iletir. Toplanan tüm bu sinyaller akson vasıtası ile işlenerek nöronun diğer ucunda bulunan bağlantılara gönderilir ve bu bağlantılar üretilmiş olunan bu yeni sinyalleri bir diğer nörona ileterek görevini tamamlamış olur. Şekil 3.1’de basit bir nöronun yapısına ilişkin resim verilmiştir.



Şekil 3.1 Basit Bir Nöronun Yapısı [27]

Yapay sinir ağlarının, insan sinir sisteminden esinlenerek yapıldığından bahsetmiştik. Nöronların yapısı ve sistematığı ile ilgili verilen bu bilgiler doğrultusunda yapay sinir ağlarında basit bir nöronun işleyişi Şekil 3.2’de ki gibidir.



Şekil 3.2 Yapay nöronun genel yapısı [29]

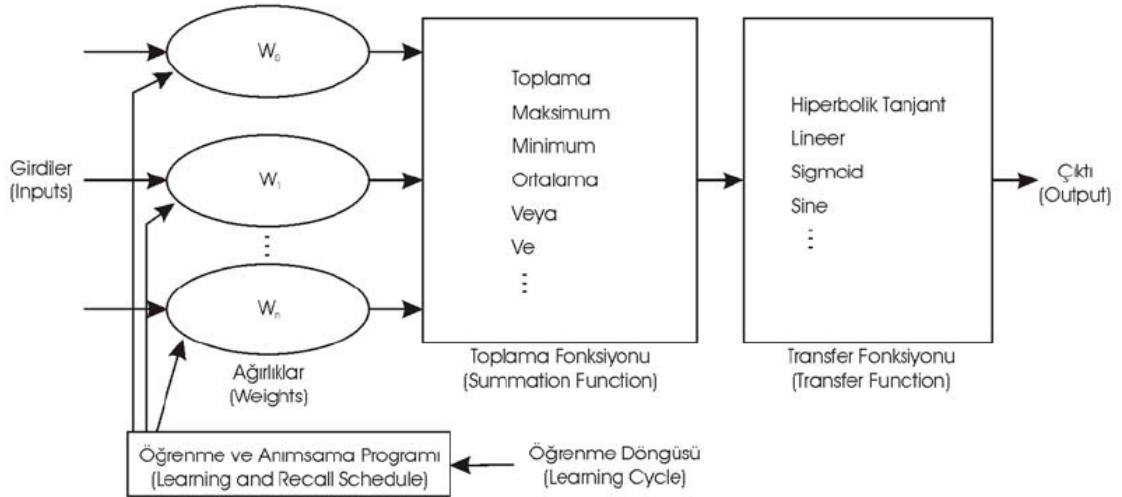
### 3.4 Yapay Sinir Hücresinin Yapısı

Önceki başlıklarda açıklandığı üzere yapay sinir hücreleri biyolojik sinir hücrelerinin yapısı ile benzerlik gösterebilmektedir ve nöronlar sinir sisteminde olduğu gibi aralarında bağ kurarak yapay sinir ağlarını oluşturabilmektedirler. Sinir sisteminde gerçekleşen giriş sinyallerinin alınması, alınan sinyallerin toplanıp işlenmesi ve çıktıların iletilmesi şeklindeki faaliyetler yapay sinir ağlarında da gerçekleşmektedir [27], [28], [29].

Bir yapay sinir hücresi 5 bölümden oluşmaktadır;

- Girdiler (inputs)
- Ağırlıklar
- Birleştirme fonksiyonu
- Aktivasyon fonksiyonu
- Çıktılar (outputs)

Bu bölümlerin detaylı gösterimi ile birlikte yapay sinir ağı akım şeması Şekil 3.3'te gösterilmiştir.



Şekil 3.3 Yapay Nöronun Detaylı Yapısı [29]

### 3.4.1 Girdiler

Yapay sinir ağlarına dışarıdan verilen bilgilerdir. Nöronlar tarafından alınan bilgiler biyolojik sinir hücrelerinde olduğu gibi bir araya gelebilmek üzere nöron çekirdeğine gönderilirler.

### 3.4.2 Ağırlıklar

Ağırlıklar, hücreler arasındaki bağlantıların sayısal değerini belirtmektedir. Bir hücre üzerine gelen bilginin sistem içerisindeki değerini ve hücre üzerindeki etkisini gösterir. Yapay sinir hücresine gelen bilgiler nöronlar üzerinden çekirdeğe ulaşmadan önce sahip oldukları bağlantıların ağırlık değeri ile çarpılarak çekirdeğe iletilir. Bu şekilde giriş verilerinin elde edilmek istenen çıktı değerine olan etkisi ayarlanabilir. Bu ağırlık değerleri pozitif, negatif veya sıfır olabilir. Ağırlık değeri sıfır olan giriş verilerinin çıkış üzerinde herhangi bir etkisi olmamaktadır.

### 3.4.3 Birleştirme Fonksiyonu

Birleştirme fonksiyonu, nöronlara gelen net bilgilerin hesaplanmasını sağlayan fonksiyondur. Yapay sinir hücreleri sahip oldukları ağırlıklarla çarpılarak gelen girdileri toplayıp hücrelerin kendilerine ait net girdisini hesaplayan bir fonksiyondur. Birleştirme fonksiyonun toplama fonksiyonu olarak da literatürde karşımıza çıkabilmektedir. Denklem 3.1'de görülen eşitlik birleştirme fonksiyonuna örnektir.

$$NET = \sum_{i=1}^N X_i W_i \quad (3.1)$$

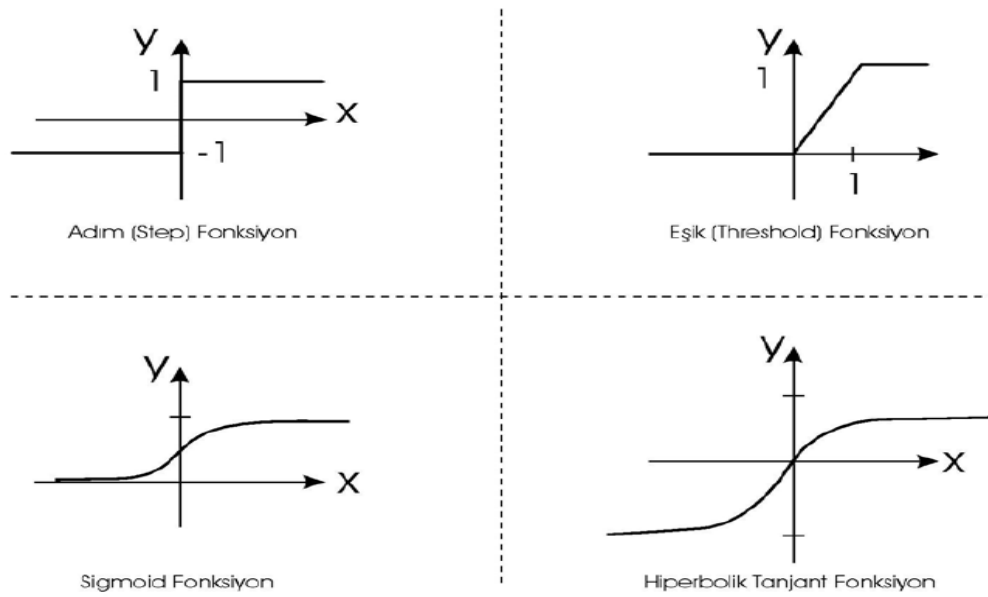
### 3.4.4 Transfer (Aktivasyon) Fonksiyonu

Yapay sinir ağlarında, birleştirme (toplama) fonksiyonundan çıkan net toplam'ın sistemden elde edilmek istenen çıktı verilerini oluşturmasından önce transfer fonksiyonuna iletilmesi gerekmektedir. Transfer fonksiyonu genel olarak doğrusal olmayan fonksiyonlar arasından seçilir. Yapay sinir ağlarının doğrusal olmama özelliği transfer fonksiyonlarının doğrusal olmamasından kaynaklanmaktadır. Doğrusal olan

fonksiyonların seçilmemesinin sebebi ise doğrusal fonksiyonlarda çıktı'nın girdi ile doğru orantılı olmasıdır. Bu durum, ilk YSA denemelerinin başarısızlıkla sonuçlanmasına sebep olmuştur [30].

Transfer fonksiyonları seçiminde dikkat edilmesi gereken bir diğer konu ise seçilen fonksiyonun türevinin kolay hesaplanabilir olmasıdır. Özellikle geri beslemeli ağlarda aktivasyon fonksiyonunun türevi de görev aldığı için hesaplamaların kullanılabilir olmasından dolayı, hesaplaması kolay bir fonksiyonun seçilmesi gerekmektedir.

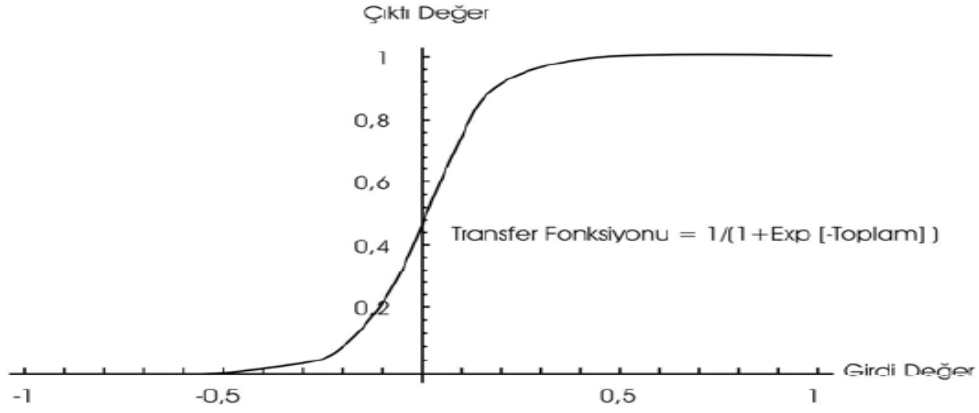
Genellikle kullanılan transfer fonksiyonları eşik, sigmoid, hiperbolik tanjant vb. fonksiyonlardır. Bu fonksiyonlar arasında en çok kullanılanlar Şekil 3.5'de örneklendirilmiştir.



Şekil 3.4 En çok kullanılan transfer fonksiyonları [29]

Transfer fonksiyonundan elde edilen sonuç genelde işlem elemanının çıktısı olur. Transfer fonksiyonunun çalışma yapısı Şekil 3.5'te sigmoid fonksiyon kullanılarak örneklendirilmiştir. Sigmoid transfer fonksiyonu, toplama fonksiyonundan gelen ve Şekil 3.5'te gösterilen değerleri alır ve sıfır (0) ile bir (1) arasında bir değere dönüştürür. Sıfır (0) ile bir (1) arasındaki bu değer, transfer fonksiyonunun ve dolayısıyla işlem

elemanının çıktısıdır. Elde edilen bu çıktı sonuç şeklinde dış ortama veya yeni bir girdi olarak başka bir nörona iletilir.




Şekil 3.5 Transfer fonksiyonunun çalışma yapısı [29]

#### 3.4.5 Çıktılar

Transfer fonksiyonundan elde edilen değerler nöronların çıktı (output) değerini belirtmektedir. Bu değer yapay sinir ağ sisteminin genel çıktısı olarak kullanılabilir ya da sistem içerisinde tekrardan başka bir giriş (input) değeri olarakta kullanılabilir. Çıktı değerleri bir ya da daha fazla sayıda olabilir.

#### 3.5 Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları yapısı, yapay sinir hücrelerinin birbirine bağlanması ile oluşum gösteren yapılardır. Bu sistemde nöronların birbiri ile etkileşime geçtiği ve bağlantı kurduğu 3 ana bölüm bulunmaktadır. Bu bölümler; giriş, ara ve çıkış katmanları olarak adlandırılmakta ve yapay sinir ağlarının yapısını oluşturmaktadır. Şekil 3.7'de YSA'nın genel yapısı şematize edilmiştir ve bu katmanlar alt konu başlıklarında sırasıyla incelenmiştir.



Şekil 3.6 YSA'nın Genel Yapısı [29]

### 3.5.1 Giriş Tabakası

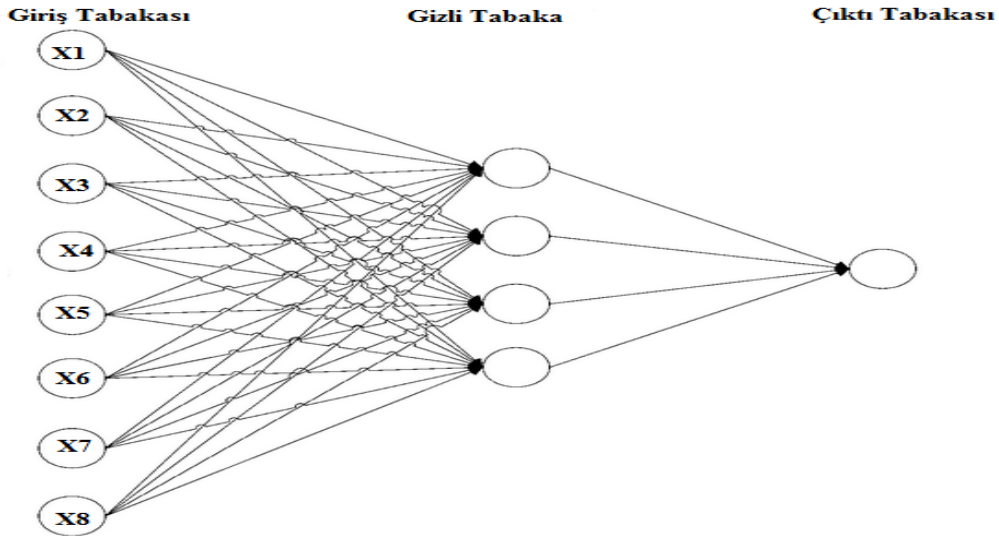
Yapay sinir ağlarında tüm işlemlerin başlatılabilmesi için giriş tabakasında kullanılmak istenen veri setinin sisteme girişinin yapıldığı, tanıtıldığı katmandır. Bu katmanda sisteme tanıtılmak istenildiği giriş değeri kadar nöron bulunur ve tüm bu nöronlar herhangi bir işleme uğramadan bir sonraki katmadan iletilir.

### 3.5.2 Gizli Tabaka


Giriş katmanında sisteme tanıtılan veri setinden çıkan bilgiler bu katmana gelir. Ara katman sayısı yapay sinir ağları arasında değişkenlik gösterebilir. Bazı yapay sinir ağlarında ara katman bulunmazken bazı sistemlerde 1, bazılarında ise çoklu katmanlar gözlenebilir. Ara katmanda bulunan nöron sayıları sistemde giriş yapan verilerin sayısı ya da sistemden elde edilmek istenen çıkış verisi sayısından bağımsızdır. Birden fazla ara katmana sahip olan yapay sinir ağlarında bu katmanların sahip oldukları nöron sayıları da değişkenlik gösterebilir. Ara katmanların ve bu katmanlardaki nöronların sayısının artması hesaplama karmaşıklığına ve işlem süresini arttırmasına rağmen yapay sinir ağlarının daha karmaşık problemlerin çözümünde de kullanılabilmesini sağlar.

Yapay sinir ağlarında sisteme girilen veri seti ve sistemden elde edilen çıkış değerleri bilinmektedir ancak bu iki katman arasında bulunan gizli tabakada gerçekleştirilen

işlemler bilinmediği için bu tabaka gizli tabaka ismini almıştır. Şekil 3.8’de tek katmanlı bir gizli tabakaya sahip yapay sinir ağı görülmekte iken şekil 3.9’da görülen yapay sinir ağında gizli tabakasında1’den fazla katmana sahip olan bir sistem görülmektedir.



Şekil 3.7 Gizli Tabakası Tek Katmanlı YSA [27]



Şekil 3.8 Gizli Tabakası Çok Katmanlı YSA [29]

### 3.5.3 Çıkış Tabakası

Çıktı tabakası yapay sinir ağlarındaki son tabaka olup, girdi katmanında sisteme tanıtılan veri setinden gelen bilgileri işleyerek karşılığında çıktıları üreten tabakadır. Bu katmanda üretilen çıkış verileri direk olarak kullanılabilir ya da geri beslemeli ağlarda

çıktı tabakasından elde edilen veriler kullanılarak ağ için yeni ağırlık deęerleri hesaplanabilir.

### **3.6 Yapay Sinir Ağlarının Sınıflandırılması**

Yapay sinir ağları işleyiş olarak birbirine benzemesine rağmen, ağın mimarisi, öğrenme yöntemi ve bağlantı yapıları gibi kriterler'den ötürü farklılık gösterebilmektedir. Genel olarak YSA'lar üç ana kritere göre sınıflandırılmaktadır.

Yapay sinir ağları genel olarak şu başlıklar altında sınıflandırılmaktadır;

1. Yapılarına göre
2. Öğrenme algoritmalarına göre
3. Öğrenme zamanına göre

#### **3.6.1 Yapılarına Göre Yapay Sinir Ağları**

Yapay sinir ağları sahip oldukları nöronların birbirine bağlandıkları şekillere göre ileri ve geri beslemeli olarak ikiye ayrılırlar. Yapılarına göre yapay sinir ağları ilerleyen alt başlıklarda irdelenmiştir.

##### **3.6.1.1 İleri Beslemeli Yapay Sinir Ağları**

İleri beslemeli yapay sinir ağların da işlem elemanları arasındaki bağlantılar bir döngü oluşturmaz ve bu ağlar giriş verisine genellikle hızlı bir şekilde karşılık üretirler. Nöronlar girişten çıkışa doğru düzenli katmanlar şeklinde olup bir katmandan sadece kendinden sonraki katmanlara bağ bulunmaktadır. Yapay sinir ağına gelen bilgiler giriş katmanına daha sonra sırasıyla ara katmanlardan ve çıkış katmanından işlenerek geçer ve daha sonra çıkış verisi elde edilir.


##### **3.6.1.2 Geri Beslemeli Yapay Sinir Ağları**

Geri beslemeli yapay sinir ağlarında bağlantılar döngüsel biçimde yer alırlar. Geri beslemeli ağların ileri beslemeli ağlardan farkı, bir nöronun çıktısının sadece kendinden sonra gelen nöron katmanına girdi olarak verilmeyip ayrıca kendinden önceki



katmanda veya kendi katmanında bulunan herhangi bir nörona da girdi olarak tanıtılabilmesidir.

Geri beslemeli yapay sinir ağları, sahip oldukları döngü sebebiyle girdinin karşılığını yavaş bir şekilde oluştururlar. Bu yüzden, bu tür ağların eğitime süreci daha uzun olmaktadır [27], [29]. Şekil 3.10'da yapay sinir ağlarında iler ve geri beslemeli ağ yapılarının şematizesi gösterilmektedir.



Şekil 3.9 İleri Beslemeli ve Geri Beslemeli Ağ Yapıları [29]

### 3.6.2 Öğrenme Algoritmalarına Göre Yapay Sinir Ağları

Yapay sinir ağlarının Sisteme tanıtılan giriş verilerine göre çıktı üretebilmesinin yolu ağın öğrenme kapasitesi ile alakalıdır. Bu öğrenme işleminin de birden fazla yöntemi vardır. Yapay sinir ağları öğrenme algoritmalarına göre danışmanlı, danışmansız ve takviyeli öğrenme olarak üçe ayrılır.

#### 3.6.2.1 Danışmanlı Öğrenme

Yapay sinir ağlarında danışmanlı öğrenme de sisteme tanıtılan giriş değerlerinden elde edilmesi hedeflenen çıkış verileri de sisteme tanıtılır. Ağ tanıtılan bu giriş verileri için istenen sonucu bulabilmek amacıyla kendi ağırlık atamalarını günceller. Ağ'dan elde edilen çıktılar ile bulunması istenilen değerler arasındaki hata payı hesaplanarak, ağın bu hata payına göre yeni ağırlık ataması gerçekleşir.

Hata payı hesaplaması ise, sistemden elde edilen tüm çıktılar ile bulunulması beklenen çıktılar arasındaki fark hesaplanıp, bu farka göre tüm nöronlara düşen hata payı bulunur. Bu işlem ardından her nöron kendisine gelen ağırlıkları güncelleyerek işleme devam eder.

Bu işlem, istenilen verilere en yakın değer elde edilene kadar devam eder [27], [29].

### **3.6.2.2 Danışmansız Öğrenme**

Yapay sinir ağlarında danışmansız öğrenme işlemi sisteme sadece örnek verilerin tanıtılması ile gerçekleştirilir. Sisteme herhangi bir çıktı bilgisi verilmediği için sistem girişte tanıtılan veriler doğrultusunda her bir veriyi kendi arasında sınıflandırarak kendi kurallarını oluşturur. Son olarak ağ bağlantı ağırlıklarını aynı özellikte olan dokuları ayırabilecek şekilde düzenleyerek öğrenme işlemi tamamlar[27], [29].

### **3.6.2.3 Destekleyici Öğrenme**

Destekleyici öğrenme yaklaşımında, sistem ağın her bir iterasyon sonucunda elde ettiği verileri iyi ya da kötü olarak kategorize etmesiyle gerçekleşir. Bu veriler doğrultusunda ağ kendini yeniden düzenler ve bu şekilde ağ kendini elde ettiği bu bilgiler ile hem eğiterek hemde işlemlerden çıkardığı sonuçlar ile döngüyü devam ettirerek sürekli bir işleme tabi tutar [27], [29].

## **3.6.3 Öğrenme Zamanlarına Göre Yapay Sinir Ağları**

### **3.6.3.1 Statik Öğrenme**

Yapay sinir ağlarında statik öğrenme kuralı ile çalışan sistemler de ağ kullanılmadan önce eğitimi gerçekleştirilmektedir. Eğitim tamamlandıktan sonra ağ istenildiği gibi kullanılabilir. Ancak kullanım sırasında ağ üzerindeki ağırlık atamalarında herhangi bir değişiklik yapılamaz.

### **3.6.3.2 Dinamik Öğrenme**

Yapay sinir ağlarında dinamik öğrenme kuralı, sistemin çalışmakta olduğu süre boyunca öğrenmesini öngörerek tasarlanmış olduğu öğrenme şeklidir. Ağ'da sinir eğitim aşaması bittikten sonra da, daha sonra ki kullanımlarda elde edilen çıktı verilerinin onaylanmasına göre ağırlıklar değiştirilerek çalışmalar devam ettirilir.

## **3.7 Yapay Sinir Ağlarının Çevre Mühendisliğinde Uygulamaları**

Çevre Mühendisliği alanında yapılan çalışmaların yapay zeka ile desteklenmesi son yılların popüler konuları arasında yer almaktadır. Yapılan geniş kapsamlı araştırmalar sonucunda çevre mühendisliği alanında gerçekleştirilen çalışmalar içerisinde, yapay zeka ile tahmin modellemesi yapılan çalışmaların %55.7'si su ve atıksu alanında, %30.8'i hava kirliliği alanında ve %13.5'i de katı atıklar alanında ortaya çıkan sorunların çözülümü yönündedir [31]. İlerleyen konu başlıklarında bu konularda gerçekleştirilen en güncel çalışmalar özetlenmiştir.

### **3.7.1 Yapay Sinir Ağlarının Atık Yönetiminde Uygulamaları**

Kentsel atık yönetim sistemlerinde, atıkların düzgün bir şekilde depolanması ve bu alanların dizaynı ile planlaması için atık miktarına yönelik kesin bilgiler gerekmektedir. Ancak üretilen atığın miktarının tahmin edilmesi parametrelerin çeşitli sebeplerden ötürü farklılık göstermesinden ötürü doğru bir şekilde öngörülememektedir. Zade ve Noori [32 ], Mashhad'da üretilen atığın miktarı ile ilgili, ileri beslemeli yapay sinir ağları ile bir model geliştirmişlerdir. Jahandideh vd. [33], yapay sinir ağları ve çoklu lineer regresyon analizi tahmin modellerini kullanarak, hastane atıklarının toplam miktarını tahmin etmiş ve atıkları keskin, bulaşıcı ve genel olarak sınıflandırabilmişlerdir. Yapay sinir ağları ve diğer modeller atık yönetimi ve arıtımı gibi konularda yapılan çalışmalarda son zamanlarda fazlasıyla ihtiyaç duyulan bir konu haline gelmiştir.

#### **3.7.1.1 Su ve Atıksu Arıtımı**

Yabunaka vd. [34], yeni bir uygulama olan BP-ANN modeli ile Japonya da'ki Kasumigaura Gölün'de oluşan yosun miktarını tahmin etmişlerdir. Elde edilen sonuçlar

doğrultusunda YSA modelinin seçilen su kalitesi parametreleri ile oluşum gösteren alg'ler arasındaki ilişkiyi iyi bir şekilde kavrayıp bu doğrultuda etkili bir sonuç verdiğini görülmüştür.

Karul vd. [35], 3 katmanlı Levenberg-Marquardt ileri beslemeli algoritma kullanarak, Keban Barajı rezervuarı, Mogan ve Eymir göllerinde ötrofikasyon prosesi için tahminde bulunmuşlardır. Keban Barajı'nın karışık ve alışılmışın dışında olan doğal yapısına rağmen ölçülen ve tahmin edilen değerler arasında iyi bir korelasyon katsayısı elde etmişlerdir. Mogan ve Eymir gölleri için ise, ölçülen ve yapay sinir ağları tarafından tahmin edilen değerler arasındaki uyum max. R = 0.95'lik korelasyon katsayısı ile iyi bir sonuç göstermiştir. Yapılan bu model çalışması ile YSA modellerinin çok kompleks yapıda ki ya da non-lineer davranışlar gösteren veriler ile de uygun sonuçlar gösterebileceği kanıtlanmıştır.

Hamed vd. [36], Mısır'da bulunan ve ortalama 1 milyon m<sup>3</sup>/gün'lük debiye sahip olan, Kahire atıksu arıtma tesisinde YSA temelli 2 model geliştirerek tesisin performansını tahmin etmeye çalışmışlardır. Çalışma kapsamında 10 ay boyunca arıtma tesisinin farklı aşamalarında BOİ ve askıda katı madde konsantrasyonlarını kayıt altında tutmuşlardır. Çalışma sonucunda YSA modeli atıksu arıtma tesisi performansını tahmin etmede etkili ve güçlü bir sistem olduğu belirlenmiştir.

Onkal-Engin vd. [37] tarafından yapılan bir başka çalışmada ise YSA modeli BP algoritması ile kokulu kanalizasyon örneklerinin, BOİ değerleri ile ilişkilendirilmesi amaçlanmıştır. Sonuç olarak YSA modelinin atıksu arıtma tesisinin farklı bölgelerinden toplanan örneklerin sınıflandırılmasında başarılı olduğunu görülmüştür.

YSA ile yapılan bir başka çalışma ise Yetilmezsoy ve Sapci-Zengin [38] tarafından gerçekleştirilmiştir. Çalışmada seyreltilmiş pamuk endüstrisi atıksuyunun, yukarı akışlı anaerobik çamur yataklı reaktörde işletimi sırasında KOİ giderim verimi tahmin edilmeye çalışılmıştır. YSA modelinde 3 katmanlı (9:12:1) model uygulanmış ve tanjant sigmoid (tansig) transfer fonksiyonu ile gizli katmanda 12 nöron ile çalışılmıştır. Elde edilen sonuçlarda YSA modelinin KOİ giderim verimlerini hassas ve etkili bir şekilde

tahmin ettiđi ve 9 farklı parametre ile yapılan alıřmada 0.83'lük tatmin edici bir korelasyon elde edildiđi grlmřtr.

Karaca ve zkaya [39] tarafından ynetilen bir alıřmada, Yapay Sinir Ađları – Sızıntı Suyu Debisi Tahmini (NN-LEAP) isimli alıřmada YSA modeli kullanılarak, kentsel katı atık deponi sahasında oluřan gnlk sızıntı debisinin kontrol amalanmıřtır. Katı atık deponi sahasında ki sızıntı suyu debisini yaklaşık olarak  $R = 0.95$ 'lik bir korelasyon katsayısı ve 0.00168'lik bir ortalama karesel hata (MSE) ile tahmin etmiřtir. alıřma sonucunda YSA ile yapılan bu modellemenin atık deponi sahasında ki sızıntı suyu debisinin kontrol ve gnlk deřarj miktarını iyi bir řekilde tahmin ettiđini grlmřtr.

Benzer konularda yapılan alıřmalardan birinde ise Al-Mutari vd. [40], YSA temelli bir model kullanarak, stabilizasyon prosesi ve ıkıř atık suyunun biyolojik aktivitesi iliřkilendirilmeye alıřılmıř (Hawalli Atıksu arıtma tesisi, Kuveyt) ve BP ve genel regresyon analiz algoritmaları ile mikrofauna trlerinin dađılımını incelenmiřtir. Bu alıřma da, verilerin stabilizasyon prosesinde ki mikrofauna dađılımını YSA kullanılarak modellenmiřtir ve ıkıř atıksu deđerinin biyolojik aktivitesi tahmin edilmeye alıřılmıřtır. alıřmacılar sistemin yapısını geri dađımlı yapay sinir ađları (BPNN) kullanarak 4 adımda modellemiřlerdir. alıřmanın optimizasyon kısmında, geri dađımlı YSA modeli ile optimum yapıyı bulabilmek iin sistem 6 farklı řekilde eđitilerek alıřtırılmıřtır. alıřma sonucunda genetik uyarlamalı genel regresyon sinir ađlarının (GRNN) kullanımının alıřma iin daha avantajlı ve uygun bir model olduđu tespit edilmiřtir.

zkaya vd. [41] tarafından yapılan bir bařka alıřmada, YSA modeli ile İstanbul Sarıyer'de bulunan Odayeri dzenli p depolama sahasın'a kurulan arazi lekli biyoreaktrlerden elde edilen gaz ierisinde ki metan paralanmasını tahmin etmeye alıřmıřlardır. alıřmadan alınan sonularda YSA modelinin kayda deđer bir lde ( $R=0.96$ ) metan paralanmasını tahmin ettiđini ve sisteme eř zamanlı etki eden oklu faktrlerin anlařılması ynnde de iyi sonular gsterdiđi belirtilmiřtir.

zkaya vd.'nin [42] bir bařka alıřmasında akıřkan yataklı reaktrde (FBR) biyolojik  $Fe^{+2}$  oksidasyonunun performansı ve biyoyıkama sırasında biriken  $Fe^{+3}$  kontrol, geri

beslemeli yapay sinir ağı ile tahmin edilmeye çalışılmıştır. Çalışma sonucunda ölçülen ve YSA tarafından tahmin edilen konsantrasyon değerlerinin birbiriyle uyum gösterdiği görülmüştür.

İncelenilmiş olunan çalışmalardan görüldüğü üzere su ve atıksu arıtımında YSA modelleri başarıyla uygulanabilmektedir. Ek olarak bu modellerin uygulanabilirliği kolay olup, çoklu değişkenlerin kullanıldığı sistemlerde nonlineer ilişkilerin belirtilmesine ihtiyaç yoktur ve su ve atıksu ortamlarında kompleks biyokimyasal reaksiyonları tanımlayabilmektedir [31].

### **3.7.1.2 Hava Kirliliği**

Hava kirliliği son 10 yıl içerisinde dünyanın birçok ülkesinde en önemli ve kritik çevre kirliliklerinden biri haline gelmiştir. Populasyon artışı, hızlı endüstriyelleşme, araç trafiğinin yoğunluğu, evsel ısınma, elektrik üretimi, antropojenik aktiviteler ve doğal kaynaklar gibi sebeplerden ötürü yüksek seviyelere ulaşan hava kirliliği yaşam kalitesini etkilemektedir. Özellikle bazı bölgelerde havadaki kirlilik konsantrasyonunun artması sonucu, solunum yolları ile ilgili akut ve kronik hastalıklar baş göstermiştir. Bu hastalıklar arasında, kardiyovasküler hastalıklar, bronkospazm, akciğer ödemi, pnömoni, akut bronşit hastalıkları ve akciğer kanseri yer almaktadır. Son yıllarda halkın sağlığına bu denli zarar veren çevre problemlerinden ötürü bu sorunla mücadele edilmesi önem kazanmıştır [31].

Hava kirliliği konusunda matematiksel modellerin önem arz etmesi hem dizayn ve işletimi açısından hemde büyük boyutlandırma değerlerinde çalışabilmek açısından avantaj sağlamaktadır. Bu dataları kullanarak, hava kirliliği kontrol ve uyarı modelleri geliştirilmesinin yanı sıra gelecek emisyon senaryoları ile ilgili tahminlerde de bulunulabilir [31].

Akkoyunlu ve arkadaşlarının [43], yaptığı bir çalışmada hava kirliliğinin daha sağlam, güvenilir ve kaliteli yollarla kontrolü için yapay zekâ esaslı modeller gibi dinamik tekniklere ihtiyaç olduğu belirtilmiştir. Bu tür modellerle, anahtar parametrelerin

kesinleştirilmesi ve çoklu girdiler ile çıktılar arasında varolan non-lineer ilişkilerin tahmin edilmesi gerçekleştirilebilmektedir.

Son 10 yılda hava kirliliği üzerine yapılan çalışmaların çoğunda YSA tabanlı tahmin modelleri etkili bir şekilde kullanılmaya başlanmıştır. Bu araştırmalarda, çalışmacıların çoğu farklı türlerde YSA modelleri denemişlerdir ve sonuçlar çoklu regresyon analizi ile öngörülen değerler ile kıyaslanmıştır. Örneğin Yetilmezsoy tarafından yapılan bir çalışmada [44], hava siklonlarda optimum gövde çapının (OBD) hesaplanmasında, gaz debisi, partikül yoğunluğu, sıcaklık,  $K_a$  ve  $K_b$  olarak adlandırılan siklon dizaynında önem arz eden 2 farklı parametre de seçilerek, 5 farklı değişken ve 505 farklı yapay senaryo ile tahmin edilmeye çalışıldığı yapay sinir ağları modeli ve yeni bir empirik model denenmiştir. Çalışma sonucunda elde edilen optimum çap, ampirik model çalışmasında 1.3 cm, yapay sinir ağları çalışmasında ise 0.0022 cm olarak tahmin edilmiştir. İki çalışmada da kullanılabilir sonuçlar elde edilmiş olup, YSA modelinin daha pratik, hızlı ve uygulanabilir olduğu görülmüş ve optimum gövde çapı tahmininde daha iyi bir tahmin yaptığı tespit edilmiştir.

Agirre-Basurko vd. [45], 2 adet çoklu katmanlı geri yayımlı (MLP) model ve bir adet'te çoklu lineer regresyon analiz modeli ile İspanya, Bilbao'da ki ozon ( $O_3$ ) ve azotdioksit ( $N_2O$ ) seviyelerini tahmin etmeye çalışmışlardır. Yapılan çalışmada, trafik'te yer alan değişkenler modeli geliştirebilmek adına kullanılmıştır. Sonuçlar MLP tabanlı modelin, çoklu lineer regresyon analizi modeline kıyasla, kirletici konsantrasyonunu daha üstün bir performansla tahmin ettiğini göstermiştir.

Hava kirliliği temelli bir başka çalışmada, Nunnari vd. [46], çeşitli stokastik teknikler ile bir noktada ki  $SO_2$  konsantrasyonlarını YSA, fuzzy logic ve bazı genel teknikler ile ölçerek karşılaştırmasını gerçekleştirmiştir. YSA modelinin bazı kritik bölümlerde daha iyi bir tahmin yapması neticesinde, hava kalite kontrolünde uyarıcı sistem olarak YSA yaklaşımını modelin uygulama olarak kullanılmasını tavsiye etmişlerdir.

Çeşitli meteorolojik koşullar altında gerçekleşen atmosferik kirliliklerin yayılım ve taşınım mekanizmaları karmaşık olmasına rağmen, hava kirliliği kontrolünün kontrol altına alınması ile ilgili çalışmalarda tahmin modelleri ile yapılan çalışmalara devam

edilmektedir. Yapay zekâ temelli gerekleřtirilen alıřmaların uygun bir řekilde dizaynı ve hesaplanması gerekleřtirilebilirirse, bu yntemlerin hava kalite ynetimi ve hava kirlilięinin kontrol gibineme arz eden konulardaneme bir rol oynayabileceęi dřnlmřtr [31].

řimdiye kadar bahsedilen bu alıřmaların haricinde, yapay zekâ temelli teknikler ile hava kirlilięi alanında kontrol, kirlilik giderimi gibi alıřmalar yapılmaya devam edilmektedir [31].



### MATERYAL VE METOT

#### 4.1 Yapay Sinir Ağları Çalışmasında Kullanılan Veri Seti Temini ve İşletme Koşulları

Bu tez kapsamında, melas atıksularının arıtımının gerçekleştirildiği yukarı akışlı havasız çamur yataklı reaktör (YAHÇYR) sisteminden elde edilen potansiyel biyogaz ve metan üretimlerinin iyi eğitilmiş bir YSA modeli ile tahminine yönelik bilgisayar esaslı bir çalışma gerçekleştirilmiştir. YSA modelleme çalışmasında kullanılan veri seti, Türkdöğ-an-Aydıno-l ve Yetilmezsoy [47] tarafından, pilot ölçekli bir YAHÇYR sisteminde gerçekleştirilen deneysel çalışmadan temin edilmiştir.

Kararlı hal şartlarındaki deneysel veri setinin alındığı önceki çalışmada; melas atıksuyu Adapazarı'nda bulunan bir şeker fabrikasından temin edilmiş olup, deney öncesi substrat dekompozisyonunu minimize etmek için +4°C'lik buzdolabında depolanmıştır. Hammadde olarak kullanılan melas atıksuyunun içeriği (g/kg melas) sırasıyla; toplam kimyasal oksijen ihtiyacı (TKOİ) : 800-900 , amonyum nitrojen (NH<sub>3</sub>-N): 25-80 , oksijen 4-8, K<sup>+</sup>: 40-60 ve Na<sup>+</sup>: 150-200 şeklindedir. Diğer melas bileşenlerinin yüzdesel ağırlık oranları (%) ise sırasıyla; sakkaroz: 50, betain: 5.5, K<sub>2</sub>O: 4.7 ve diğerleri ise: 39.8 olarak belirlenmiştir [47].

YAHÇYR sisteminin besleme suyu önceden belirlenen miktarda melas suyunun istenilen miktarda musluk suyu ile seyreltilmesi ile hazırlanmıştır (1:10-1:3 kat). Besi kültürünün ortama uyum sağlamasından sonra , seyreltme oranı 1:10'dan 1:3'e düşürülmüştür. Organik yükleme oranı ise yükselmiş (2'den 17 kg TKOİ/ m<sup>3</sup> -gün ) ve reaktörün farklı besleme oranlarına karşı gösterdiği dayanıklılık üzerine çalışma yapılmıştır [47].

Melas atık suyunun kısmen asidik karakterizasyon göstermesiyle [13], besleme atıksuyunun pH değeri kademeli olarak  $\text{NaHCO}_3$  (Merck Kimyasal corp.) eklemesiyle ayarlanması Gohil ve Nakhla [48] tarafından yapılan çalışma ile benzerlik göstermektedir. Optimum anaerobik mikrobiyal büyüme için gerekli makro ve mikro besin içeren çözeltiler aşağıdaki bileşenler ile hazırlanmış ve eklenen yüksek organik yükleme koşulları ile 1 mL / L günlük besleme yapılmıştır [49]: 5 g/L  $\text{MgSO}_4 \cdot 7\text{H}_2\text{O}$ , 6 g/L  $\text{FeCl}_2 \cdot 6\text{H}_2\text{O}$ , 10 g/L  $\text{CoCl}_2 \cdot 6\text{H}_2\text{O}$ , 1 mg/L  $\text{H}_3\text{BO}_3$ , 1 mg/L  $\text{ZnSO}_4 \cdot 7\text{H}_2\text{O}$ , 1 mg/L  $\text{CuSO}_4 \cdot 5\text{H}_2\text{O}$ , 100 mg/L  $\text{MnCl}_2 \cdot 6\text{H}_2\text{O}$ , 1 mg/L  $(\text{NH}_4)_6\text{Mo}_{24} \cdot 4\text{H}_2\text{O}$ , 585 mg/L  $\text{Al}_2(\text{SO}_4)_3 \cdot 18\text{H}_2\text{O}$ , ve 1 g/L  $\text{Na}_2\text{SiO}_3 \cdot 9\text{H}_2\text{O}$  [47].

Melas atıksuyu farklı organik ve hidrolik yükleme koşulları altında anaerobik olarak pilot ölçekli YAHÇYR reaktörde arıtılmıştır. Sistemin iç çapı, toplam uzunluğu ve toplam tank kapasitesi sırasıyla 20 cm, 190 cm ve 90 L'dir. Reaktörün tüm parçaları ANSI 316 paslanmaz çelikten yapılmıştır. Reaktör 20 cm uzunluğunda konik tabana ve işletim sırasında tıkanma durumundan kaçınmak için 1.0 cm çapında besleme giriş borusuna sahiptir. Çıkış savağı reaktörün en üstünde (1.85) olup, çıkış bağlantı borusu ile çıkış suyu toplama tankına iletilmektedir. Reaktör, sistemin alt kısmından başlayarak 0.30, 0.45, 0.60, 0.75 ve 0.90 metre mesafelerinde 5 adet numune alma noktası ile donanımlandırılmıştır. Her bir örnek alma noktasının çapı yaklaşık 1.5 cm'dir. [47].

Biyogaz reaktörün baş kısmından gaz toplama sistemi ile toplanmıştır. Gaz toplama ve ölçme sistemi; gaz-katı-sıvı ayrıştırıcı (15 cm çapındaki ters çevrilmiş hunilerden yapılmıştır), gaz toplama boruları, cam su toplama kabı hidrojen sülfür ( $\text{H}_2\text{S}$ ) sıyrıcı ve ıslak-tip gaz metre kullanılmıştır. Reaktör'ün mezofilik şartlarını ( $35.2 \pm 0.7^\circ\text{C}$ ) koruyabilmek adına bir diğer reaktörde bulunan, Fisher Isotemp 2100 (Fisher Company, Pittsburgh) dalgıç sirkülatörü ile sıcak suyun reaktördeki sirkülasyonu sağlanmıştır. Isıtılan su ceketten reaktörün etrafını ve cam yünü çevreleyerek izolasyon materyali olarakta [47].

Sisteme beslenen farklı atıksu debisi değerlerine dayanılarak (40.5-165.1 L/gün), reaktör yarı-sürekli besleme modunda (saatte 2 kere, 15 dk) atıksu pompalanarak ve günlük çıkış örnekleri toplanarak işletilmiştir. Pilot ölçekli reaktör, 2 yıllık süre içerisinde çeşitli organik ve hidrolik yükleme oranları ile işletilmiştir. Giriş ve çıkış


örneklendirmeleri, kararlı hale geçildiği zaman uygulanmıştır. Beslemede, hedeflenen farklı hidrolik bekleme süreleri (HRT) peristaltik pompa (ColeParmer, Masterflex®) kullanılarak elde edilmiştir [47].

Reaktör içerisindeki sıvı fazın akışkanlığına göre, atıksu beslemesinde uygun giriş hızı sağlanmıştır. Reaktör beslemesi sırasında, besleme tankı cam bir çubuk ile belli aralıklarla karıştırılarak askıda katı maddelerin çökmesi engellenmiş ve bu şekilde besleme çözeltisinin homojenliği sağlanmıştır [47].

Çürütme prosesinin verimini arttırmak için reaktör Kartonsan Fabrikası'na ait Anaerobik Arıtma Tesisi'nden (Çorlu, İstanbul, Türkiye) alınan anaerobik çamur (çalışma hacminin yaklaşık %25'i) ile aşılanmıştır. Deney düzeneğinin ayrıntılı şeması Şekil 4.1'de gösterilmiştir [47].

Giriş ve çıkış pH değerleri pH metre (Thermo Orion 210) ile ölçülmüştür. Toplam Kimyasal Oksijen İhtiyacı (TKOİ), Uçucu Yağ Asitleri (UYA) ve alkalinite analizleri Standart Metodlar'da (1995) belirtilen prosedürlere göre yürütülmüştür [47].

Reaktör içerisindeki biyogaz üretim miktarı sürekli olarak davul tipi Ritter ıslak-tip gazmetre (Ritter Apparatebau GmbH & Co.) ile ölçülmüş ve biyogazın kompozisyonu portatif Orsat cihazı ile belirlenmiştir. Sistemin stabilitesi ve atıksu numunelerinin izlenmesi Yıldız Teknik Üniversitesi, İnşaat Mühendisliği laboratuvarlarında gerçekleştirilmiştir [47].



Şekil 4.1 Melas atıksularının arıtılmasında kullanılan YAÇYR sistemi [47]

## 4.2 Model Değişkenlerinin Tanıtımı

Bu çalışma kapsamında, günlük biyogaz ve metan üretimlerinin YSA tekniği ile modellenmesinde, spesifik model girdileri (organik yükleme oranı, YAÇYR sistemi çıkış KOİ konsantrasyonu, alkalinite, sıcaklık, giriş ve çıkış pH değerleri, YAÇYR sistemi çıkış uçucu yağ asidi (UYA) konsantrasyonu) seçilmiş ve bunların YSA modelinin yapısına dâhil edilme gerekçeleri alt başlıklarda izah edilmiştir.

### 4.2.1 Organik Yükleme Oranı (OYO, $p_1$ )

Organik yükleme oranı (OYO), birim hacim ( $m^3$ ) biyoreaktörlere günlük olarak beslenen organik madde miktarı (genelde KOİ veya uçucu katı maddelerin (UKM) türünden) olarak tarif edilir.

Anaerobik arıtmada bakteriler, organik yükleme hızına karşı oldukça hassastırlar. Anaerobik arıtma esnasında, istenen arıtma performansını elde edebilmek maksadıyla optimum organik yükleme hızı korunmalıdır. Organik yükleme hızı yüksek olduğunda biyoreaktör içinde asit birikmesi olur ve pH düşer. pH'ın düşmesi, metanojenik bakterilerin faaliyetlerini olumsuz yönde etkiler. Bu da gaz üretim hızını düşürür ve hatta durdurur. Benzer şekilde, organik besleme hızı düştüğü zaman gaz üretim hızı da düşer [50].

Organik yükleme oranı, anaerobik sistem karakteristiğini ve mikrobiyal ekolojiyi etkileyen en önemli parametredir. Bu parametre, reaktörün işletme karakteristiğini, bakteriyel kütle ve hacimsel ortamdaki aktiviteyi önemli ölçüde etkilemektedir. Organik yükleme oranı aynı zamanda anaerobik arıtma sistemindeki biyolojik dönüştürme kapasitesinin bir ölçüsüdür [51]. OYO değeri kullanılan teknolojiye ve arıtılan atıksuya göre değişiklik göstermektedir [52]. Çeşitli anaerobik reaktör konfigürasyonları esas alındığında, OYO değerlerinin 0.6 – 86.4 kg KOİ/m<sup>3</sup>-gün gibi geniş aralıkta melas atıksularından giderildiği görülmektedir [53].

#### **4.2.2 Alkalinite (p<sub>2</sub>, p<sub>6</sub>)**

Bir atıksuyun alkalinitesi, o suyun asitleri nötrale edebilme kapasitesi olarak tanımlanır. Alkalinite, pH değerlerine karşı suların gösterdiği direncin bir ölçüsü olması nedeni ile incelenen atıksuyun tampon kapasitesini yansıtmaktadır [54].


Ayrıca, alkalinite sıvıların pH değişimlerine olan dayanma kabiliyeti olarak da açıklanabilmektedir. Alkalinite, sıvı ortamlara asit ilavesi yapıldığında karbonatların hidroksit iyonlarına katkı sağlamasını sağlar ve bu durum asitleri nötrale eder. Bu şekilde gerçekleşen olaya alkalitenin tampon etkisi adı verilmektedir [47].

Alkalinite, sadece pH düzenlemede değil, metan üretiminde CO<sub>2</sub> tamponlayıcı bir özellik de sağlamaktadır. Genel olarak, alkalinite ilavesinde bakteriyel aktiviteyi bozmadan dengeyi istenen eşitlik değerine yavaşça kaydıran tek kimyasal olan sodyum bikarbonat kullanılmaktadır [47].

#### 4.2.3 pH (p<sub>3</sub>, p<sub>7</sub>)

pH, bir çözeltinin asit veya baz olma özelliğinin şiddetini gösteren bir terim olup çözeltide bulunan H<sup>+</sup> iyonu konsantrasyonunu ve daha kesin bir ifade ile hidrojen iyonunun aktivitesini göstermektedir.

Anaerobik arıtmada optimum pH değerleri 5.5 ve 8.5 arasındadır. Metan bakterileri pH değerlerine karşı hassasiyet göstermektedirler. Metan bakterileri için pH aralığı 6.5 ile 7.8 arasında iken asit üretici bakterilerin optimum pH aralığı 5.5 ve 6 arasındadır. Bu durum, neden bazı tesis tasarımlarının hidroliz/ asidifikasyon ve asetat/metan oluşumu şeklinde iki aşamalı olarak yapılmasının en önemli sebebidir [47]. Şekil 3.2’de metanojenlerin reaktif aktivitelerinin (R) pH ile değişimi gösterilmiştir.



Şekil 4.2 Metanojenlerin reaktif aktivitelerinin (R) pH ile değişimi [55]

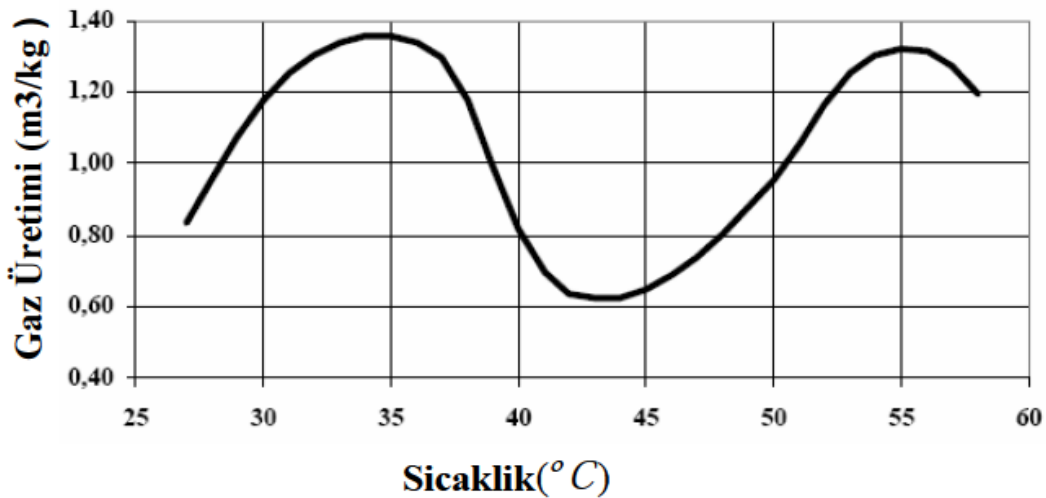
Anaerobik arıtmada asitojenik grup pH bakımından birçok özel durumu içerir. Asidifikasyon en iyi pH > 4.5 değerinde gerçekleşmektedir. Şekil 2.2’den de görüldüğü gibi, asetojen ve metanojen prosesleri ise yaklaşım olarak 6.5-8.0 arasındaki pH değerlerinde en iyi performanslarını göstermektedir [56].

#### 4.2.4 Sıcaklık (p<sub>4</sub>)


Anaerobik sistemde mikroorganizmaların büyüme oranlarında, yaşam sürelerinde ve reaksiyonların hızında sıcaklık çok önemli bir parametredir. Tüm bakteri gurupları farklı

sıcaklıklarda büyürler. Metanojenik proste (hidrolizden metanojene dönüşüm kademeleri) 5-65°C'de faaliyet gösterdikleri bilinmektedir [56].

Ortamın sıcaklığı artırıldığında biyokimyasal reaksiyon hızlanmaktadır. Bu nedenle, sıcaklık arttırıldığında hücrelerin büyümeleri de hızlanır. Fakat büyük yapıda ki proteinlerin nükleik asitlerin veya yağların fonksiyonlarını yitirdiği bir sıcaklık limiti vardır. Aynı zamanda büyümeleri için minimum bir sıcaklık değeri vardır. Genellikle organizmalar 30-40°C sıcaklık değerleri arasında büyürler. Ancak, değer değişikliklerine göre temelde dört grupta toplanırlar. Mezofilik mikroorganizmaların optimal büyüme sıcaklıkları 20 ile 50°C arasındadır. Psikofilik bakteriler ise 15°C'den düşük bir sıcaklıklarda faaliyet göstermektedirler. Termofilik bakteriler ise 50°C'nin üstünde çok iyi bir büyüme sağlarlar. Bazı bakteriler ise 75°C'nin üzerindeki sıcaklıklarda büyüdüklerinden dolayı bunlara da aşırı termofilik bakteriler adı verilir. Şekil 3.3 ve 3.4'te sıcaklığın gaz üretimi ve proses hızı üzerine etkileri gösterilmiştir.



Şekil 4.3 Sıcaklığın gaz üretimine etkisi [57]



Şekil 4.4 Havasız arıtmada dikkate alınan sıcaklık değerleri [55]

#### 4.2.5 Uçucu Yağ Asidi ( $p_8$ )

Havasız arıtmada uçucu yağ asit (UYA) konsantrasyonundaki önemli değişiklikler, reaktördeki asidojenik ve metanojenik popülasyonlar arasındaki stabilitenin bozulmasına sebep olmaktadır [58]. Reaktörde UYA konsantrasyonundaki artış sebebiyle pH değeri düşmektedir. Bu durumun uzun süreli devam etmesi halinde ise metanojenik popülasyon inhibe olmakta, asidojenik bakteriler reaktör içerisinde baskın popülasyon olmaktadır. Ancak reaktörde yeterli tamponlama kapasitesi bulunması halinde metanojenik popülasyon üzerindeki zararlı etkiler ortadan kalkmaktadır [59]. Sistemde UYA konsantrasyonunun artması doğrudan KOİ giderimini azalttığından, etkin bir arıtma verimi ve metan üretimi açısından reaktördeki UYA konsantrasyonunun mutlaka kontrol edilmesi gerekmektedir [2].

#### 4.2.6 Kimyasal Oksijen İhtiyacı (KOİ, $p_5$ )

KOİ, evsel ve endüstriyel atıksuların kirlilik derecesini belirlemede kullanılan önemli bir parametre olup, kimyasal oksidasyonda maddenin biyolojik olarak ayrışıp ayrışmadığına ve ayrışma hızına bakılmaksızın bütün organik maddelerin oksitlenebilme kapasitesini temsil etmektedir. Kimyasal oksijen ihtiyacı çevre kirlenmesinde en çok kullanılan parametrelerden biri olup, atıksuların bünyesindeki organik maddelerin miktarını, kimyasal oksidasyonları için gerekli oksijen miktarı cinsinden belirlenebilmesi ile elde edilebilen bir metottur. Yöntem birkaç istisna dışında tüm organik maddelerin, kuvvetli oksitleyicilerle asit ortamlarda oksitlenebilecekleri esasına dayanmaktadır [60].



#### 4.2.7 Biyogaz ve Metan Üretimi ( $t_1$ , $t_2$ )

Biyogaz eldesi temel olarak organik maddelerin ayrıştırılmasına dayandığı için temel substrat kaynağı olarak bitkisel atıklar ya da hayvansal gübreler kullanılabilir. Kullanılan hayvansal gübrelerin biyogaza dönüşüm sırasında fermante olarak daha yararlı hale geçmesi sebebiyle dünyada temel materyal olarak kullanılmaktadır [61].

Çizelge 4.1 Atık ve hammadde kaynaklarına göre biyogaz ve metan oranları [62]

ATIK KAYNAĞI	Biyogaz Verimi (L/kg)	Metan Oranı (Hacimsel %'si)
Siğır Gübresi	90-310	65
Kanatlı Gübresi	310-620	60
Domuz Gübresi	340-550	65-70
Buğday Samanı	200-300	50-60
Çavdar Samanı	200-300	59
Arpa Samanı	290-310	59
Mısır Sapları ve Artıkları	380-460	59
Keten & Kenevir	360	59
Çimen	280-550	70
Sebze Artıkları	330-360	Değişken
Ziraat Artıkları	310-430	60-70
Yerfıstığı Kabuğu	365	-
Dökülmüş Ağaç Yaprakları	210-290	58
Algler	420-500	63
Atıksu Çamuru	310-800	65-80

Herhangi bir anaerobik sistemde, prosesin verimliliği genel olarak biyogaz veya metan üretim oranı ile temsil edilmektedir. Biyogaz reaktörleri işletiminde dikkat edilmesi gereken en önemli adım, atık içerisinde bulunan organik maddelerin biyolojik

parçalanması sonucu oluşan metan üretiminin maksimize olabilmesi için sürekli olarak kontrolünün yapılmasıdır. Biyogaz ürünleri ve metan içeriğinin azalması anaerobik çürütücü sistemlerde kararsız proses koşullarının potansiyel indikatörleridir. Sistemin kararlılığı metan içeriğinin dikkatli bir şekilde kontrolüyle sağlanabilmektedir. Gaz üretim oranı, anaerobik biyokütle aktivitesinin önemli bir ölçüsü olarak ifade edilebilir [47].

### **4.3 Model Datasının Tanımlayıcı İstatiksel Analizi**

Yapılan çalışma da, 8 girdi (input) ve 2 çıktı (output) değerlerini kapsayan toplamda 137 adet kararlı hal verisini içeren deney sonuçları kullanılmıştır. Girdi parametreleri olarak organik yükleme oranı, alkalinite (giriş ve çıkış), pH (giriş ve çıkış), sıcaklık, YAHÇYR sistemi çıkış KOİ ve uçucu yağ asidi konsantrasyonları; çıktı parametreleri olarak da metan ve biyogaz üretim miktarları kullanılmıştır.

### **4.4 Veri Setinin Eğitim, Validasyon ve Test Setlerine Bölünmesi**

YSA'da kullanılan veri setinin eğitim, validasyon ve test alt setlerine bölünmesinde kullanıcı tarafından çalıştırılan MATLAB® esaslı algoritma kullanılmıştır. Veri seti sisteme tanıtıldıktan sonra program tarafından belirlenen alt setlere rastgele veri atanması yapılmış olup, validasyon ve test alt setlerine eşit sayıda, eğitim alt setine ise bu iki grubun iki katı kadar veri sağlanmıştır.

Rastgele yerleştirmeler neticesinde alt setlere program tarafından atanan veri sayısı;

- Eğitim alt setinde 69
- Validasyon alt setinde 34
- Test alt setinde 34'dür.

Yapılan çalışmalarda veriler girdi (p) ve çıktı ya da hedef (t) matrislerine ayrılmıştır. Kullanılan veriler her bir bölümün çalışma alanına rastgele bir şekilde seçilerek yerleştirilmiştir. Eğitim seti, ağ içerisindeki çoğunluğu temsil edebilecek şekilde bir çift girdi/hedef veriyi eğiterek iyi bir tahmin sonucu elde etmeye olanak sağlar. YSA'nın bu özelliği elde edilen yeni çıktı verisinin, doğru çıktı verisi ile benzerliğe sahip olmasını

sağlar. Eğitim fonksiyonu hesaplamalar için bir döngü oluşturmaktadır. Eğitim fonksiyonu her bir döngüde girdilerin dizilimini, çıktı değerlerinin hesaplanmasını, her bir girdi vektörü ve dizili girdiler arasında temsil edilen vektör için hata oranı ve ağa adaptasyon olunumunu gerçekleştirir [63].

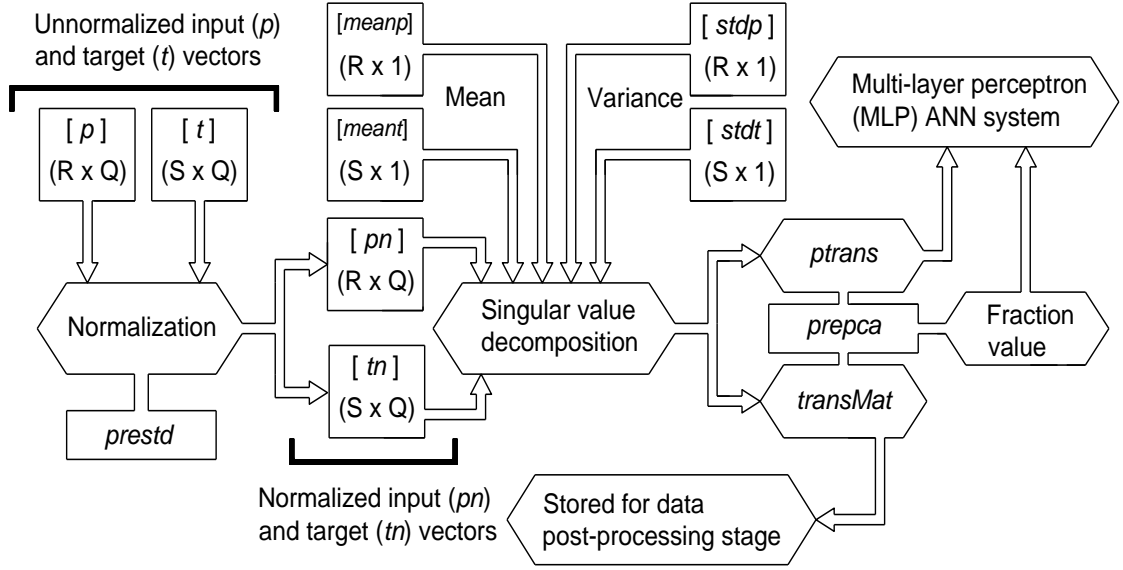
#### 4.5 Temel Bileşen Analizi (PCA, Principal Component Analysis)

Temel bileşen analizinde (TBA) ilk adım veri setini çalışma alanına yüklemektir. Çalışmada,  $p$  ve  $t$  matrislerinde verilen ağın orijinal girdi ve çıktı (hedef) değerleri *prestd* algoritma kodu kullanılarak normalize edilir. Normalize edilmiş girdi ve çıktı'lar (hedef) yani  $p_n$  ve  $t_n$ , sıfır anlamlılık, birim standart sapma ve dağılım kazanırlar. Orijinal girdi ve çıktı'ların (hedef) anlamlılık (meanp, meant) ve standart sapma (stdp, stdt) değerleri ağ eğitilmeden önce tanımlanmaktadır. Daha sonra, girdi vektörlerinin dönüşümünü belirleyen vektörler (*ptrans*) ve temel bileşen dönüşüm matrisleri (*transmat*) belirlenir. Tüm bu vektörler ileri de elde edilecek olunan girdi değerlerinin dönüşümlerinde kullanılmıştır.

Bazı durumlarda, girdi değerlerinin boyutları büyük olabilmekte ancak vektörlerin bileşenleri fazlasıyla birbiri ile ilişki içinde olabilmektedir. Böyle durumlarda girdi vektörlerinin boyutlarını azaltmak ağ için yararlı olmaktadır. Bu prosedürü etkili bir şekilde gerçekleştirebilen sistem temel bileşen analizi olarak adlandırılmaktadır. Mohamad-Saleh ve Holey [64] tarafından elde edilen bulgular doğrultusunda, sisteme tanıtılan veri setindeki değerlerin elimine edilmesi ve kolay şekilde ilişkilendirilmesi tahmin performansını arttırmakta ve çok katmanlı geriye yayımlı algoritmali YSA sistemlerde eğitim zamanını azalttığı tespit edilmiştir. Bunların dışında TBA'nın 3 etkisi bulunmaktadır: (1) girdi vektörlerinin bileşenlerinin analizi, (2) elde edilen sonuçların temel bileşen şeklinde verilmesi (çeşitlilik miktarı fazla olur), (3) veri setinde bulunan ve sisteme en az katkıda bulunan bileşenlerin elimine edilmesidir.

Yukarıda bahsedilen durumlar göz önünde bulundurulduğunda, TBA, her bir bölüme ayrıştırılacak olunan dataların ve parametrelerin, sisteme katkısı göz önüne alınarak etkili şekilde belirlenmesini sağlamaktadır [63].

Şekil 4.5'te, bu çalışmada gerçekleştirilen temel bileşen analizi (PCA) gösterilmiştir.



Şekil 4.5 Temel Bileşen Analiz (PCA) Şeması [63]

#### 4.6 Geri Yayılm Algoritmasının (BP) Seçimi

Geri besleme ağlarının geliştirilmesi, sinir ağlarına olan ilginin yeniden artmasında önemli bir rol oynamıştır. Bir ağı bir fonksiyona yaklaşıncaya kadar eğitmek için girdi vektörleri ve karşılıklı hedef vektörleri kullanılır, girdi vektörleri belirli çıktı vektörleri ile ilişkilendirilir ya da girdi vektörleri uygun bir metot yardımı ile tasnif edilir. Bu genelleme özelliği bir girdi veya hedef eş setleri ile temsil edilen ağı eğitilmesini ve düzgün sonuçlar elde edilmesini mümkün kılar. Son katmandan başlanarak hassaslıklar hesaplanır ve ağı boyunca ilk katmana doğru geriye dönük besleme yapılır [65]. Geri beslemeli ağlar, ortalama karesel hatayı asgari seviyelere düşürmek için belirli bir gradyan metodu kullanan çok katmanlı ileri besleme ağlarıdır ve geri besleme algoritmasının konumu ortalama karesel hatanın gradyanı ile birlikte gradyan metodu sağlar. Kâğıt üzerinde ANN'lar, üç adet katmandan oluşur: girdi katmanı, gizli katman ve çıktı katmanı.

Ma vd. [66] geri besleme ağlarının kullanımının özellikle etkileşimli tahminlere uyarlanmasına uygun hale getiren belirli faydaları olduğunu belirtmiştir:

- Bir yığın halindeki veri setlerini işleyebilir ve tahmin sonuçlarını hızlı bir şekilde elde edebilir.
- Herhangi bir girdi verisinin istenen çıktılarını bilen bir eğitmen yardımı ile eğitebilen bir sistemdir.
- Geri besleme ağlarının çıktıları olasılıklardan oluştuğuna göre, ilişkilerinin bir derecesi olarak değerlendirilebilir.

Bu nedenle, ANN türleri içerisinde geri besleme ağları en basit ve en çok kullanılan ağ modellerinden birisi olarak değerlendirilmektedir [67]. Geri besleme ağlarının öğrenme süreci, veri akışının ileri hesaplaması ve hata sinyallerinin geri beslemesi olmak üzere iki ana iterasyon basamağından oluşur. İleri hesaplama yapılırken, özgün veriler girdi katmanından çıktı katmanına doğru ilerleyerek gizli işleme katmanından ve sadece bir sonraki katmanın nöronlarını etkileyen katman nöronlarından geçerler. Geri besleme ağlarının diğer ağ türlerinden ayrılan temel avantajlarından birisi; çıktı katmanından elde edilen sonuç istenilen değerde değilse, geri besleme süreci başlar ve hata ileri hesaplamasının aksi yönünde ağ boyunca geriye dönük olarak yayılır [67], [68]. Geri beslemedeki hata sinyaline göre ağ bütün katmanları birbirine bağlayan ağı değiştirerek en uygun ağırlık setini arar ve doğru ağ çıktılarını verir [68]. Bu nedenle, bu iki basamağın iterasyon ile yapılması sonucunda ağ çıktısı ile istenen çıktı arasındaki hata delta kuralı kullanılarak azami seviyeye düşürülür [67].

Verilen problemin çözümünde hangi eğitim algoritmasının en hızlı sonucu vereceğini tahmin etmek oldukça güçtür. Bu durum problemin karmaşıklığı ve eğitim setinin içerisindeki verilerin miktarı da dâhil olmak üzere pek çok faktöre bağlıdır [63], [69].

#### **4.7 Yapay Sinir Ağları Yapısının Optimizasyonu**

Almasri ve Kaluarachchi'nin [70] raporuna göre; YSA tabanlı çalışmalarda sinir ağları sisteminin optimizasyonu en önemli adımlardan biridir. Bu işlem sistemin performansı açısından önemli bir role sahiptir. Bu yüzden, optimizasyon işlemleri nöron sayısı ve ortalama hatanın karesi (MSE) değerleri arasında gerçekleştirilmektedir.

YSA'lar gizli katmanlarında bulunan nöron sayılarına karşı hassastır. Çok az nöron sistemde alt seviye uyumsuzluk (underfitting) durumuna sebep olabilmektedir. Bunun aksine, çok fazla nöron da sistemin üst seviye uyumsuzluğuna (overfitting) olmasına sebep olabilmektedir. Ancak bazı durumlarda tüm eğitim verileri sisteme tam bir uyum gösterebilir ancak böyle bir durumda da elde edilen eğrinin çok fazla dalgalanma oluşturduğu tespit edilmiştir. Böyle durumlarda eğitim setindeki hata payı çok küçük olmakta ancak yeni veri seti sisteme tanıtıldığında elde edilen hata payı daha büyük olmuştur. Sinir ağları eğitilmiş örnekleri hafızada tutabilmesine rağmen, yeni verilerin tanıtıldığı durumlarda genelleme yapamamaktadır. Bu durum Bayesian kuralı ile eğitilerek (algoritma kodu, *trainbr*) LMA'nın modifikasyonu ile ya da diğer eğitim tekniklerinden herhangi birinde erken durdurma (early stopping) tekniği ile engellenebilir [63].

#### **4.8 Hassasiyet Analizi**

YSA modellerinde değişkenlerin tahmin modeline olan etki değerini belirleyebilmek amacı ile hassasiyet analizi yapılmaktadır. Hassasiyet analizi yapılırken sisteme tanıtılan girdi verilerinin farklı kombinasyonlarının sistem performansına katkıları incelenerek gerek görüldüğünde her hangi bir etkiye sahip olmayan girdi değerleri elenir [71].

#### **4.9 Lineer – Non-lineer Çalışma**

Bu bölümde, deneysel veriler ayrıca DataFit® bilimsel yazılım (Copyright© 1995-2005 Oakdale Engineering V8.1.69) tarafından değerlendirilmiş ve sonuçları bulanık mantık tahminleri ve deneysel değerler ile karşılaştırılmıştır. Non-lineer regresyon analizinde kullanılan paket programda, Levenberg-Marquardt yöntemi kullanılmıştır. Regresyon modelleri çözüldükçe, elde edilen modeller en uygundan başlayarak kendi içinde otomatik olarak sıralanmıştır. Deneysel veriler, açık veri kaynağı olarak kullanılan Microsoft® Excel veritabanı bağlantısından alınmış ve regresyon analizi gerçekleştirilmiştir. Bununla birlikte *t*-oranları ve karşılık gelen *p* değerleri ile regresyon katsayılarının ve model değişkenlerinin önemi değerlendirilmiştir. Model performansını daha iyi gözlemlemek için için tanımlayıcı istatistiksel hatalar da hesaplanmıştır [72].

#### 4.10 Tahmin sonuçlarının İstatistiksel Analizi

Model sonuçlarının doğrulanması model geliştirme önemli bir parçası olup, görsel ve sayısal yöntemler ile elde edilebilmektedir. Görsel yöntemler, model performansını sezgisel olarak yakalayabilmesine rağmen, sayısal yöntemler, bilimsel bir şekilde model geliştirmek ve karşılaştırmak için çok daha sağlam bir zemin sağlamaktadır [72],[73].

Karşılaştırma amacıyla; determinasyon katsayısı ( $R^2$ ), korelasyon katsayısı ( $R$ ), ortalama mutlak hata (MAE), ortalama karesel hata karekökü (RMSE), sistematik ve sistematik olmayan RMSE (sırasıyla  $RMSE_S$  ve  $RMSE_U$ ), ortalama karesel hata (MSE), uyum indeksi (IA), iki faktörü (FA2), fraksiyonel varyans (FV), sistematik hata oranı (PSE) ve kesişim noktası gözlenen değerler ve modelin tahmin performans değerleri arasında (a) ve eğim (b) ( $y = bx + a$ ) gibi çeşitli istatistiksel göstergeler model performans tahminini tanımlamak için yardımcı araçlar olarak kullanılabilir [47].

Determinasyon katsayısı ( $R^2$ ), tahmin modeli için gözlenen toplam değişimin (total variations) ne kadarının model tarafından açıklanıp açıklanamayacağını belirten ve model performansı hakkında önemli bir bilgi sağlayan bir istatistiksel göstergedir. Ayrıca, RMSE yapay zekâ tabanlı modelleri ile en sık kullanılan göstergelerden biri olup, sistematik ( $RMSE_S$ ) ve sistematik olmayan ( $RMSE_U$ ) RMSE olarak bileşenlerine ayrılabilir.  $RMSE_S$ , modele bağlı hata (lineer sapma) kısmını anlatmaktadır. Bu nedenle, düşük bir değer iyi bir model anlamına gelir.  $RMSE_U$ , model tarafından elde edilemeyen rastgele belirlenen hata bölümünü açıklamaktadır. MAE, sayısal ölçüm sonuçlarının en basit olanıdır. Bu sadece tahmin verileri üzerinden alınan mutlak hataların ortalamasıdır.

Çizelge 4.2 Bu çalışmada göz önüne alınan performans indikatörleri ve matematiksel ifadeleri

Performans indikatörleri	Matematiksel hesaplama <sup>a</sup>
Determinasyon katsayısı ( $R^2$ )	$R^2 = \frac{\left( \sum_{i=1}^n (O_i - O_m)(P_i - P_m) \right)^2}{\sum_{i=1}^n (O_i - O_m)^2 \sum_{i=1}^n (P_i - P_m)^2}$
Korelasyon katsayısı ( $R$ )	$R = \sqrt{\frac{\left( \sum_{i=1}^n (O_i - O_m)(P_i - P_m) \right)^2}{\sum_{i=1}^n (O_i - O_m)^2 \sum_{i=1}^n (P_i - P_m)^2}}$
Ortalama mutlak hata (MAE)	$MAE = \frac{1}{n} \sum_{i=1}^n  P_i - O_i $
Ortalama karesel hatanın karekökü (RMSE)	$RMSE = \left( \frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2 \right)^{0.5}$
Sistemik RMSE (RMSE <sub>S</sub> )	$RMSE_S = \left( \frac{1}{n} \sum_{i=1}^n [P_i_{reg} - O_i]^2 \right)^{0.5}$
Sistemik olmayan RMSE (RMSE <sub>U</sub> )	$RMSE_U = \left( \frac{1}{n} \sum_{i=1}^n [P_i_{reg} - P_i]^2 \right)^{0.5}$
Sistemik hata oranı (PSE)	$PSE = \frac{RMSE_S^2}{RMSE_U^2}$
Uyumluluk indeksi (IA)	$IA = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n ( P_i - O_m  +  O_i - O_m )^2}$
Fraksiyonel varyans (FV)	$FV = 2 \sigma_o - \sigma_p / \sigma_o + \sigma_p$
2'nin faktörü (FA2)	$0.5 \leq FA2 = \frac{1}{n} \sum_{i=1}^n \left( \frac{O_i}{P_i} \right) \leq 2$



Uyum indeksi (IA), 0 - 1 aralığında sınırlı bir boyutsuz bağıl bir ölçü olarak kabul edilir. Bu nedenle, modeller arasında çapraz kıyaslamalar yapmak için idealdir [63]. İkinci faktörü, FA2, 0,5 - 2 aralığında oranı O / P (gözlenen / beklenen) değerleri arasındaki tahmin sonuçlarının yüzdesini verir. FV ise tahmin edilen varyans ve gözlenen varyans arasındaki farkın karşılaştırılması olarak sağlayan başka bir normalizasyon ölçüsüdür [73].

FV = 0 olan bir modelin varyansı gözlenen değerlerin varyansına eşittir. Yukarıda ifade edilen istatistiksel performans indikatörlerine ilişkin detaylı tanımlar ve matematiksel hesaplamalar çeşitli çalışmalarda bulunabilir [63],[72], [74].

### SONUÇLAR VE ÖNERİLER

Bu çalışmada, çıkış değerleri (output) olarak biyogaz ve metan üretimlerine ilişkin tahminler yapıldığı için YSA sistemi bu iki parametre içinde ayrı ayrı sonuçlar vermiştir. YSA'da gerçekleştirilen temel bileşen analizi sonucunda giriş datası olarak sisteme tanıtılan tüm parametrelerin önerilen YSA modeli için önem teşkil etmesi dolayısıyla seçilen girdi değişkenlerinin tamamının model yapısında kullanımı uygun görülmüştür. İlerleyen başlıklarda her iki çıkış parametresi için elde edilen tahmin sonuçları belirtilmiştir.

#### 5.1 Geri Yayılım Algoritmasının Seçilmesi

Geri yayılım algoritması seçiminde model ile uygunluğunun sağlanabilmesi çok önemlidir. Uzun yıllar yapılan çalışmalarda ortaya çıkan çok sayıda eğitim algoritması arasından Çevre Mühendisliği verileri ile uygunluk gösterdiği bilinen algoritmalar arasından en uygunu seçilip model çalıştırılmıştır. İlerleyen alt başlıklar da biyogaz ve metan için geri yayılım algoritmalarının seçimi hakkında detaylı bilgiler verilmiştir.

##### 5.1.1 Biyogaz Tahmini İçin Geri Yayılım Algoritmasının Seçimi

Biyogaz için geri yayılım algoritması seçiminde YSA modeline ait gizli katmanda 10 nöron sayısı seçilerek işlemler yapılmıştır. Sistem için gereken kodlar MATLAB® programına girildikten sonra Çevre Mühendisliği alanında yaygın olarak kullanılan 11 algoritma teker teker denenerek en yüksek korelasyon ve en düşük hata payını veren fonksiyonun seçilimi hedeflenmiştir. Bu algoritmaların sonuçlarının karşılaştırılması çizelge 5.1'de verilmiştir.

Çizelge 5.1 10 Nöronlu Hidden Layerda 11 Geri Yayılım Algoritmasının Biyogaz Tahmini İçin Karşılaştırılması

Fonksiyon	R (korelasyon katsayısı)	MSE	İterasyon Sayısı	En İyi Lineer Denklem
<i>trainrp</i>	0.941	0.083948	12	$Y=0.89X+27$
<i>traincgf</i>	0.939	0.077211	14	$Y=0.87X+28$
<i>traincgp</i>	0.969	0.806710	22	$Y=0.96X+9.6$
<i>traincgb</i>	0.959	0.112100	21	$Y=0.92X+17$
<i>trainlm</i>	0.970	0.101950	9	$Y=0.91X+18$
<b><i>trainscg</i></b>	<b>0.964</b>	<b>0.065163</b>	<b>21</b>	<b><math>Y=0.93X+13</math></b>
<i>trainbfg</i>	0.966	0.082306	19	$Y=0.95X+14$
<i>trainoss</i>	0.963	0.082435	21	$Y=0.94X+11$
<i>traingd</i>	0.953	0.131580	1000	$Y=0.91X+16$
<i>traingdx</i>	0.915	0.193090	53	$Y=0.8X+45$
<i>traingdm</i>	0.597	0.588450	15	$Y=0.49X+110$

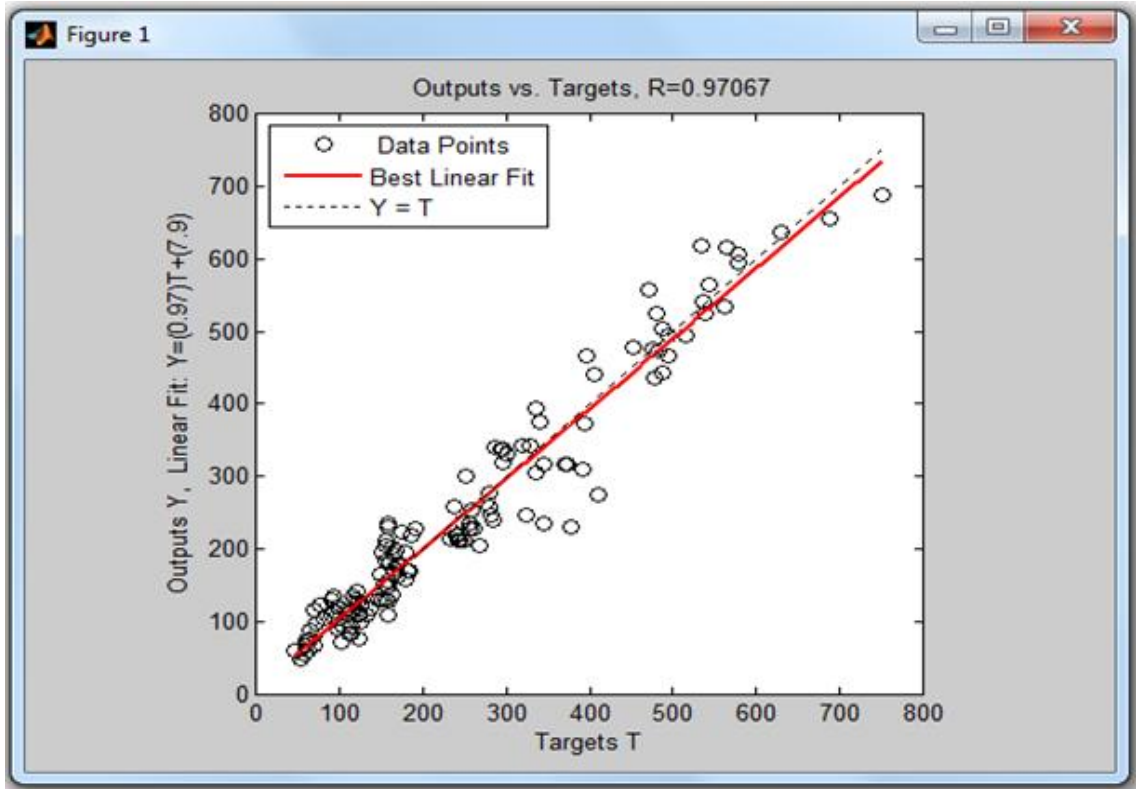
Bu 11 algoritma arasında korelasyon katsayısı en yüksek (0.97) olan Levenberg-Marquardt geri yayılım algoritması ile en düşük ortalama karesel hata (0.065163)'ü (MSE) veren Scaled conjugate gradient geri yayılım algoritması arasında bir seçim yapılması gerektiğinde bu iki geri yayılım algoritması'nın regresyon analizleri yeniden incelenmiştir.

Bu iki algoritma ile ilgili detaylı bilgiler Çizelge 5.2'de gösterilmektedir.


Çizelge 5.2 Trainlm ve Trainscg geri yayılım algoritmalarının detaylı karşılaştırılması

Fonksiyon	YSA Setleri	R	MSE
<i>trainlm</i>	Tüm Regresyon Performansı	0.95894	0.13
	Eğitim	0.99994	
	Validasyon	0.88313	
	Test	0.96452	
<i>trainscg</i>	Tüm Regresyon Performansı	0.9683	<b>0.07</b>
	Eğitim	0.98353	
	Validasyon	0.95143	
	Test	0.95509	

Çizelge 5.2’de belirtilen sayısal bilgilerin program’da gösterimi ise Şekil 5.1 ve 5.2’deki gibidir.



Şekil 5.1 YSA Modelinde Biyogaz Performans Grafiği



Şekil 5.2 YSA'da Biyogaz Tahmininin Tüm Alt Setlerinin MATLAB® Ekranındaki Grafikleri

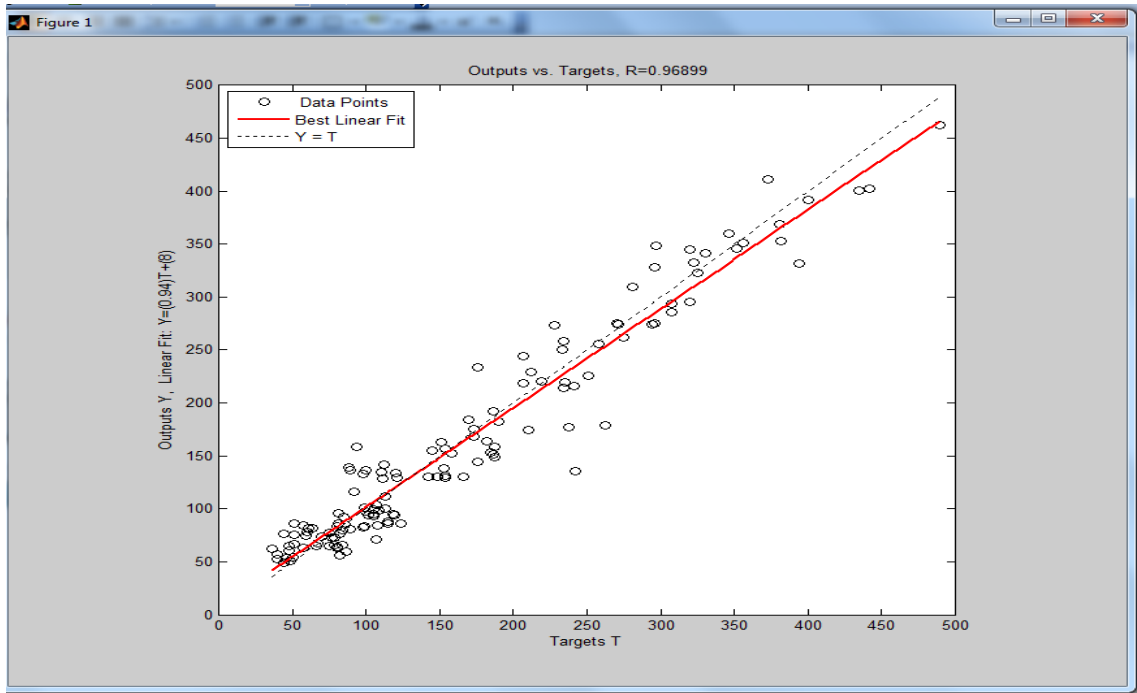
Şekil 5.1 ve 5.2'de görülen regresyon analizi sonuçları *trainscg* algoritmasına ait olup ayrıntılı olarak incelendiğinde *trainlm* algoritmasından daha yüksek korelasyona sahip olduğu ve ortalama karesel hatasının daha düşük olduğu görülmüştür. Ayrıca validasyon, eğitim ve test performansları da genele bakıldığında daha başarılıdır. Belirtilen sebeplerden dolayı biyogaz tahmini için seçilen geri yayılım algoritması Scaled conjugate gradient (*trainscg*) 'dir.

### 5.1.2 Metan Tahmini İçin Geri Yayılım Algoritmasının Seçimi


Metan için geri yayılım algoritması seçiminde 1 hidden layer'da 10 nöron sayısı seçilerek işlemler yapılmıştır. Sistem için gereken kodlar MATLAB®'e girildikten sonra literatürde en yaygın kullanılan 11 eğitim algoritması denenerek en yüksek korelasyon ve en düşük hata payını veren fonksiyonun seçimi hedeflenmiştir. Bu algoritmaların sonuçlarının karşılaştırılması çizelge 5.3'de verilmiştir.

Çizelge 5.3 10 Nöronlu Hidden Layerda 11 Geri Yayımlı Algoritmasının Metan Tahmini İçin Karşılaştırılması

Fonksiyon	R (korelasyon katsayısı)	MSE	İterasyon Sayısı	En İyi Lineer Denklem
<i>trainrp</i>	0.962	0.13234	18	$Y=0.96X+6.1$
<i>traincgf</i>	0.969	0.084566	24	$Y=0.96X+6.8$
<i>traincgp</i>	0.964	0.12586	25	$Y=0.97X+2.2$
<i>traincgb</i>	0.967	0.095984	23	$Y=0.95X+7.1$
<i>trainlm</i>	0.962	0.087656	9	$Y=0.97X+11$
<b><i>trainscg</i></b>	<b>0.974</b>	<b>0.068945</b>	<b>42</b>	<b><math>Y=0.91X+11</math></b>
<i>trainbfg</i>	0.967	0.073375	24	$Y=0.97X+3.6$
<i>trainoss</i>	0.957	0.11942	22	$Y=0.96X+8.9$
<i>traingd</i>	0.967	0.11046	1000	$Y=0.93X+6.5$
<i>traingdx</i>	0.591	0.94466	16	$Y=0.4X+80$
<i>traingdm</i>	0.954	0.15656	1000	$Y=0.91X+11$



Şekil 5.3 YSA Modelin'de Metan Performans Grafiği



Şekil 5.4 YSA'da Metan Tahmininin Tüm Alt Setlerinin Grafiği

Çizelge 5.3'te görülen sonuçlar doğrultusunda algoritmalar arasında en yüksek korelasyon ve en düşük ortalama karesel hata veren algoritma Scaled conjugate gradient algoritmasıdır ve biyogaz tahmininde olduğu gibi metan tahmininde de geri yayılım algoritması olarak Scaled conjugate gradient (*trainscg*) algoritması seçilmiştir.

## 5.2 Sinir Ağları Yapısının Optimizasyonu

Sinir ağlarının optimizasyonu aşamasında hedef, gizli katmanda (hidden layer) bulunan nöron sayısını optimize bir şekilde belirleyebilmektir. Bu amaç doğrultusunda, bu çalışmada gizli katmandaki nöron sayısı 2'den başlatılıp optimize değer bulunana dek arttırılarak işleme devam edilmiştir.

Bu işlem doğrultusunda metan ve biyogaz tahminlerinde hidden layer'da kullanılacak olan optimum nöron sayıları ilerleyen başlıklar da belirlenmiştir.

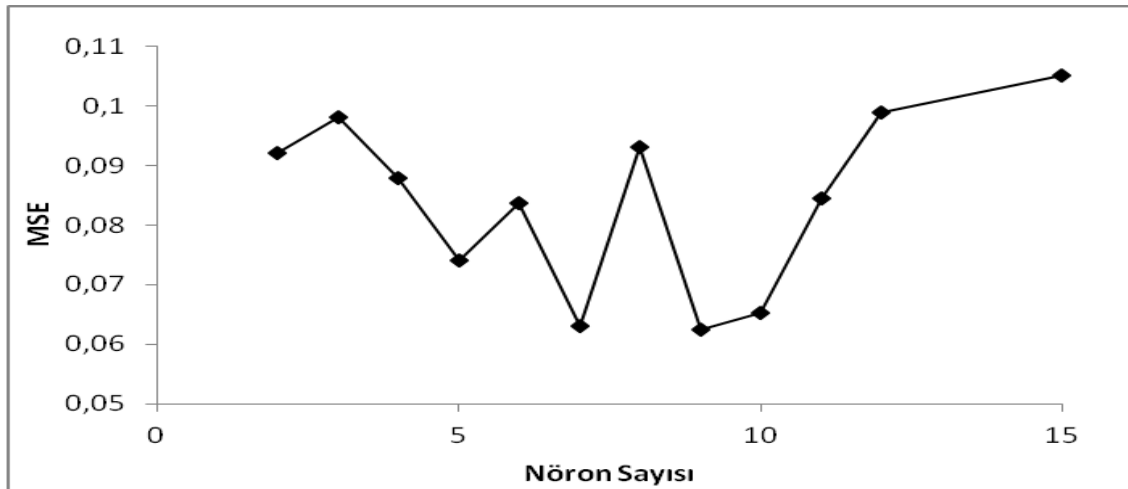
### 5.2.1 Biyogaz Tahmini Aşamasının Optimizasyonu

Biyogaz tahmini aşamasında geri yayılım algoritması olarak *trainscg* algoritması kullanımı uygun bulunmuştur ve bu algoritma ile nöron sayısı en az 2'den başlayarak

optimum nöron sayısını belirlemek amacıyla denemeler gerçekleştirilmiştir. Optimum nöron sayısını bulabilmek amacıyla gerçekleştirilen işlemler Çizelge 5.4'te belirtilmiştir.

Çizelge 5.4 Biyogaz Tahmini İçin optimum Nöron Sayısı

Nöron Sayısı	MSE (Ortalama Karesel Hata)
2	0.092019
3	0.098094
4	0.087874
5	0.074066
6	0.083606
7	0.062983
8	0.093060
9	<b>0.062382</b>
10	0.065163
11	0.084393
12	0.098851
15	0.105140



Şekil 5.5 Biyogaz Tahmin Aşamasında MSE Değerlerine Karşılık Gelen Nöron Değerleri



Çizelge 5.4'te elde edilen veriler doğrultusunda çizilen Grafik 5.1'de görüldüğü üzere biyogaz tahmini sırasında hidden layer'da kullanılan optimum nöron sayısı 9 olarak tespit edilmiştir. Çalışmada, trainscg algoritmasında 9 nöronlu regresyon analiz sonuçları ise;  $R = 0.971$  ve  $Y = 0.97X + 7.9$  olarak elde edilmiştir.

### 5.2.2 Metan Tahmini Aşamasının Optimizasyonu

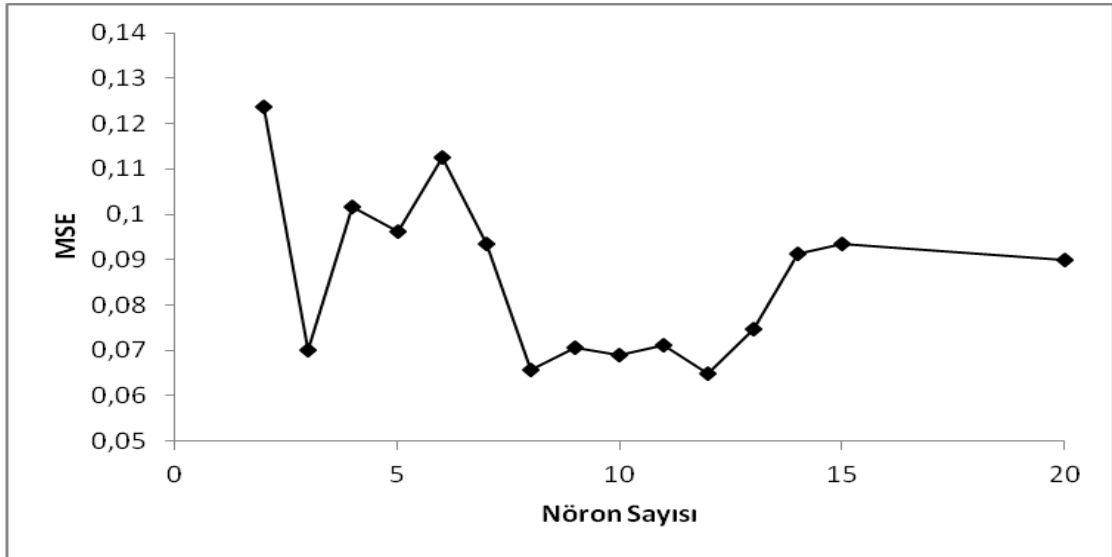
Metan tahmini aşamasında geri yayılım algoritması olarak trainscg algoritması kullanımı uygun bulunmuştur.

Çizelge 5.5 Metan Tahmini İçin Optimum Nöron Sayısı

Nöron Sayısı	MSE (Ortalama Karesel Hata)
2	0.123660
3	0.069976
4	0.101530
5	0.096226
6	0.112590
7	0.093489
8	0.065665
9	0.070555
10	0.068945
11	0.071023
<b>12</b>	<b>0.064884</b>
13	0.074581
14	0.091332
15	0.093501
20	0.090054

Bu algoritma ile nöron sayısı en az 2'den başlayarak optimum nöron sayısını belirlemek amacıyla denemeler gerçekleştirilmiştir. Optimum nöron sayısını bulabilmek amacıyla gerçekleştirilen işlemler Çizelge 5.5'te belirtilmiştir.

Çizelge 5.5'te elde edilen veriler doğrultusunda çizilen Grafik 5.2'de ise metan tahmini sırasında hidden layer'da kullanılan optimum nöron sayısı 12 olarak tespit edilmiştir.




Grafik 5.1 Metan Tahmin Aşamasında MSE Değerlerine Karşılık Gelen Nöron Değerleri

Trainscg algoritmasında 12 nöronlu regresyon analiz sonuçları ise ;

$R = 0.96899$  ve  $Y = 0.94 X + 8$  bulunmuştur.

Bu aşamaya kadar elde edilen bilgiler doğrultusunda bu çalışmada kullanılacak olan YSA sisteminin işleyiş şeması Şekil 5.5'teki gibidir.



Şekil 5.6 YSA İşlem Şeması

### 5.3 Hassasiyet Analizi

Hassasiyet analizi, YSA içerisinde kullanılan verilerin teker teker yada 2'li, 3'lü ve 4'lü vs. şeklindeki kombinasyonlar ile sisteme tanıtılarak parametrelerin modele katkısını ölçebilmeye dayanan bir analizdir. Bu çalışmada girdi değişkenlerinin sayısı verilerimiz 1'den 8'e kadar kombine edilerek hassasiyetleri ölçülmüştür. Alt başlıklarda biyogaz ve metan için ayrı ayrı hassasiyet analiz sonuçları verilmiştir.

#### 5.3.1 Biyogaz Üretim Tahmininde Hassasiyet Analizi


Bu çalışmada tahmin edilmesi hedeflenen biyogaz değerleri için sisteme tanıtılan girdi değişkenlerinin hassasiyet analizi çizelge 5.6'da görülmektedir.

Çizelge 5.6 Biyogaz üretiminin tahmininde girdi değişkenlerinin optimum model performansına katkıları

Kombinasyon	MSE (Ortalama karesel hata)	R	İterasyon sayısı	Gradyan değeri	En iyi lineer eşitlik
$p_1$	$>10^4$	0.934	$>500$	28.84	$Y=0.85X+36$
$p_1 + p_2$	0.10139	0.94	16	0.125	$Y=0.86X+32$
$p_1 + p_2 + p_3$	0.09737	0.941	20	0.120	$Y=0.9X+22$
$p_1 + p_2 + p_3 + p_4$	0.0935	0.959	23	0.0388	$Y=0.94X+13$
$p_1 + p_2 + p_3 + p_4 + p_5$	0.0857	0.96	18	0.108	$Y=0.94X+12$
$p_1 + p_2 + p_3 + p_4 + p_5 + p_6$	0.079	0.97	24	0.048	$Y=0.97X+0.13$
$p_1 + p_2 + p_3 + p_4 + p_5 + p_6 + p_7$	0.0644	0.9705	19	0.0586	$Y=0.95X+15$
<b><math>p_1 + p_2 + p_3 + p_4 + p_5 + p_6 + p_7 + p_8</math></b>	<b>0.062382</b>	<b>0.971</b>	<b>20</b>	<b>0.136</b>	<b><math>Y=0.97X+7.9</math></b>

Modele öncelikle tek değişken tanıtılmış ve ortalama karesel hata payı belirlenmiştir. Bir sonraki aşamada ikinci değişkenin eklenmesi ile ortalama karesel hata payı azalmış ve korelasyon katsayısı artış göstermiştir. Her bir değişken eklendiğinde beklenen sonuç ortalama karesel hatanın düşmesi ve korelasyon katsayısının artış göstermesi yönündedir. Çizelge 5.6'da görüldüğü üzere her bir değişken modele girdiğinde istenilen düşüş ve çıkışlar elde edilmiştir. Hassasiyet analizi sonuçları, sisteme girdi olarak tanıtılan verilerin bir kez daha model için uygun olduğunu göstermiştir.

Şekil 5.7'de ortalama karesel hata değeri azaldıkça, korelasyon katsayısının artışı biyogaz tahmininde elde edilen değerler için gösterilmektedir.



Şekil 5.7 Biyogaz için 2'li kombinasyondan başlayarak MSE-Korelasyon grafiği

Biyogaz tahmini için kullandığımız parametrelerin hassasiyet analizi sonucundan da görüldüğü gibi model için uygun olduğu ve eklenen her bir parametrenin MSE'yi azaltıp korelasyonu arttırdığı tespit edilmiştir. Çizelge 5.7'de, kullanılan değişkenlerin modele eklendiğinde ortalama karesel hata (MSE) değerindeki azalma yüzdeleri verilmiştir.

Çizelge 5.7 Biyogaz Üretim Tahmin Değişkenlerinin MSE Azalma Yüzdeleri

Girdiler	MSE	MSE Azalma Yüzdesi
$p_1+p_2$	0,101390	-
$p_1+p_2+p_3$	0,097370	% 3.96
$p_1+p_2+p_3+p_4$	0,093500	% 7.78
$p_1+p_2+p_3+p_4+p_5$	0,085700	% 15.47
$p_1+p_2+p_3+p_4+p_5+p_6$	0,079000	% 22.08
$p_1+p_2+p_3+p_4+p_5+p_6+p_7$	0,064400	% 36.48
$p_1+p_2+p_3+p_4+p_5+p_6+p_7+p_8$	0,062382	% 38.47

Çizelge 5.7 incelendiğinde  $p_1$  girdisinin hassasiyet analiz sonucunun eklenmediği görülmektedir, çünkü bu değer hesaplanamayacak kadar büyük olmaktadır. Ayrıca  $p_2$  girdisi eklendiğinde ortalama karesel hata değerinin büyük oranda azaldığı Çizelge 5.6'da görülmektedir.

Sonuç olarak Çizelge 5.7'den anlaşılacağı üzere değişkenlerimiz hata payını azaltacak kadar model açısından önem teşkil etmektedir. Biyogaz için hassasiyet analizi sonucunda tüm girdi değişkenlerinin model için uygun olduğu bir kez daha kanıtlanmıştır.

### 5.3.2 Metan Üretim Tahmininde Hassasiyet Analizi

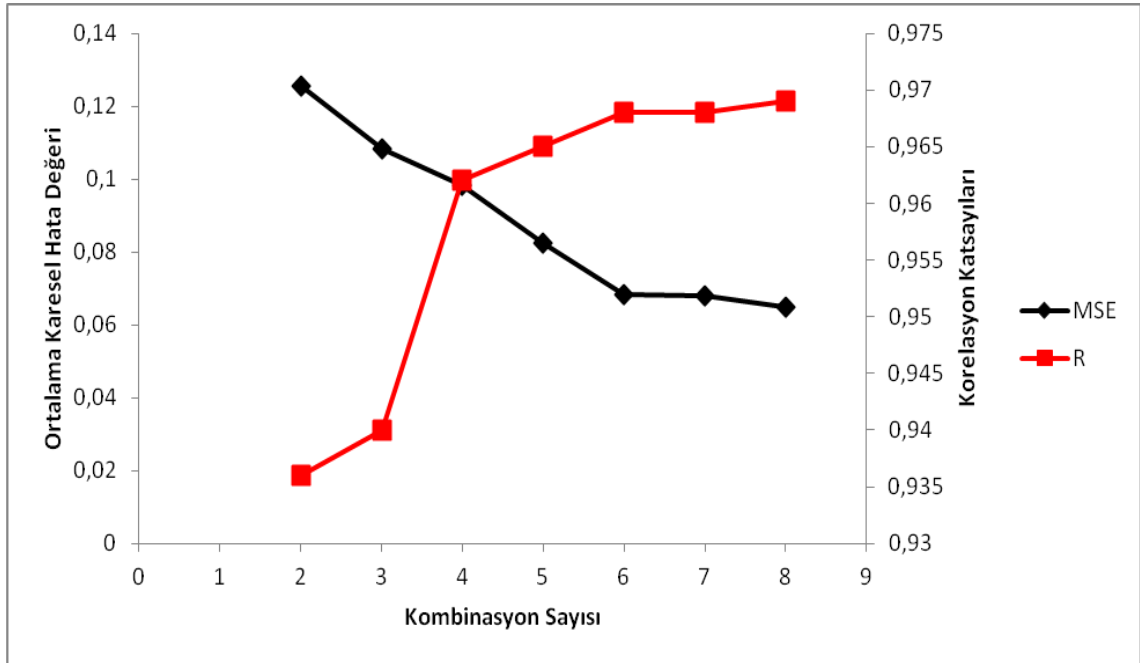
Metan üretim tahmini için yapılan hassasiyet analizinde ki girdi değişkenlerinin sonuçları Çizelge 5.8'de gösterilmektedir.

Çizelge 5.8 Metan üretiminin tahmininde girdi değişkenlerinin optimum model performansına katkıları

Kombinasyon	MSE (Ortalama karesel hata)	R	İterasyon sayısı	Gradyan değeri	En iyi lineer eşitlik
$p_1$	$>10^4$	0.923	>500	2.9623	$Y=0.85X+24$
$p_1 + p_2$	0.12552	0.936	22	0.0654	$Y=0.89X+19$
$p_1 + p_2 + p_3$	0.10821	0.940	24	0.0671	$Y=0.88X+15$
$p_1 + p_2 + p_3 + p_4$	0.0982	0.962	27	0.0389	$Y=0.92X+12$
$p_1 + p_2 + p_3 + p_4 + p_5$	0.0825	0.965	26	0.0722	$Y=0.94X+8.2$
$p_1 + p_2 + p_3 + p_4 + p_5 + p_6$	0.0684	0.968	26	0.0516	$Y=0.92X+11$
$p_1 + p_2 + p_3 + p_4 + p_5 + p_6 + p_7$	0.068	0.968	20	0.0907	$Y=0.94X+9.6$
<b><math>p_1 + p_2 + p_3 + p_4 + p_5 + p_6 + p_7 + p_8</math></b>	<b>0.064884</b>	<b>0.969</b>	<b>24</b>	<b>0.0597</b>	<b><math>Y=0.94X+8</math></b>

Metan tahmininde hassasiyet analizi sonuçları incelendiğinde istenildiği gibi değişkenlerin katkısı arttıkça MSE değeri azalmış ve korelasyon katsayısı artış göstermiştir. Bu sonuçlardan görüldüğü üzere metan tahmini için seçilen girdi verileri,

model için yüksek oranda uygunluk göstermektedir. Grafik 5.4'te ortalama karesel hata değeri azaldıkça, korelasyon katsayısının artışı metan tahmininde elde edilen değerler için gösterilmektedir.



Şekil 5.8 Metan için 2'li kombinasyondan başlayarak MSE-Korelasyon grafiği

Çizelge 5.9 Metan Üretim Tahmin Değişkenlerinin MSE Azalma Yüzdeleri

Girdiler	MSE	MSE Azalma Yüzdesi
$p_1+p_2$	0,125520	-
$p_1+p_2+p_3$	0,108210	% 13,79
$p_1+p_2+p_3+p_4$	0,098200	% 21,76
$p_1+p_2+p_3+p_4+p_5$	0,082500	% 34,27
$p_1+p_2+p_3+p_4+p_5+p_6$	0,068400	% 45,50
$p_1+p_2+p_3+p_4+p_5+p_6+p_7$	0,068000	% 45,82
$p_1+p_2+p_3+p_4+p_5+p_6+p_7+p_8$	0,064884	% 48,31

Çizelge 5.9 metan üretim tahmini için kullanılan değişkenlerin ortalama karesel hata değerlerinin değişkenler analize eklendikçe gerçekleşen azalma yüzdelerini göstermektedir.

Çizelge 5.9'da ki MSE azalma yüzdelerine bakacak olursak, metan üretimi için seçilen girdi verilerinin model için uygun olduğu görülmektedir çünkü analize dahil olan her veri ortalama karesel hata değerini azaltacak niteliktedir.

#### **5.4 Lineer/Non-linear Çalışma Sonuçları**

Çalışmanın bu kısmında YSA tarafından modellenen veri setinin, DataFit® programında da çalıştırılarak kıyaslamalar yapılması hedeflenmiştir. DataFit® programı da YSA gibi yüksek korelasyonlar verebilen bir programdır. YSA tarafından uygunluğu belirlenen model için DataFit® programında elde edilen tahmin sonuçlarının kıyaslaması yapılmak istendiğinden lineer/non-linear esaslı bir çalışma gerçekleştirilmiştir.

Ancak önceden belirtmek gerekirse, konvansiyonel regresyon denklemlerinin YSA'dan daha yüksek değerler veremeyeceği tahmin edilmektedir. YSA modeli yapısı gereği, dinamik verilere (modele tanıtılan yeni verilere) çabuk uyum sağlayabilmektedir. Ancak DataFit®'te bu durum sonucunda yeniden bir denklem kurulma zorunluluğu vardır. Bu gibi dezavantajlarından dolayı DataFit® programında elde edilen sonuçlar uygun gibi görülsede hem bahsedilen sebepten ötürü hem de DataFit® programının sonuç olarak verdiği denklemlerin kompleksliğinden ötürü pratikte uygulanabilirliği YSA'ya göre daha azdır.

İlerleyen alt başlıklarda biyogaz ve metan için yapılan DataFit® çalışmaları sonucu elde edilen değerler sıralanmıştır.

##### **5.4.1 Biyogaz Üretim Tahmini İçin Lineer-Non-linear Çalışma**

DataFit® programında biyogaz tahmini için yapılan çalışma neticesinde program, 1 eksponansiyel ve 2 lineer denklemden oluşan 3 farklı model sonucu vermiştir. Çizelge 5.10'de veri seti için DataFit® tarafından uygun görülen bu denklemler sıralanmaktadır.



Bu çizelgede dikkat edilmesi gereken değerler determinasyon katsayısı ( $R^2$ ) ve ayarlanmış çoklu determinasyon katsayısı ( $R_a^2$ ) sonuçlarıdır. Bu iki parametrenin veri seti için vermiş olduğu sonuçların birbirine yakın olması veri sayısının yeterli olup olmadığını göstermektedir. Çizelge 5.10'de de görüldüğü üzere  $R^2$  ve  $R_a^2$  sonuçları birbiri ile yakın değerlere sahiptir. Bu şekilde seçilmiş olan veri setinin model için yeterli ve uygun olduğu bir kez daha kanıtlanmış olmaktadır.

Çizelge 5.10 Biyogaz üretiminin tahmininde DataFit® ile elde edilen çoklu regresyon modelleri ve regresyon analizinde hesaplanan bazı istatistiksel değerler

Sıra	Model	SEE	SR	AR	RSS	R <sup>2</sup>	R <sub>a</sub> <sup>2</sup>	NNI
1	$\exp(a \cdot x_1 + b \cdot x_2 + c \cdot x_3 + d \cdot x_4 + e \cdot x_5 + f \cdot x_6 + g \cdot x_7 + h \cdot x_8 + i)$	46,93	-246,25	-1,79	281.864,8	0,918	0,913	7
2	$a \cdot x_1 + b \cdot x_2 + c \cdot x_3 + d \cdot x_4 + e \cdot x_5 + f \cdot x_6 + g \cdot x_7 + h \cdot x_8 + i$	48,63	$9,37 \cdot 10^{-11}$	$6,83 \cdot 10^{-13}$	302.718,1	0,912	0,907	1
3	$a \cdot x_1 + b \cdot x_2 + c \cdot x_3 + d \cdot x_4 + e \cdot x_5 + f \cdot x_6 + g \cdot x_7 + h \cdot x_8$	51,85	-30,16	-0,22	896.749,3	0,899	0,894	3

67

SEE: Tahmindeki standart hata

SR: Hataların toplamı

AR: Ortalama bakiye hata

RSS: Hataların kareleri toplamı

R<sup>2</sup>: Determinasyon katsayısı

R<sub>a</sub><sup>2</sup>: Ayarlanmış çoklu determinasyon katsayısı

NNI: Uygulanan non-lineer iterasyon sayısı

Çizelge 5.11 DataFit® tarafından verilen sonuçlar arasında en yüksek korelasyona sahip olan eksponansiyel denklemin katsayılarının ve modele ait bazı istatistiksel verilerin sonuçlarını göstermektedir. Bu çizelge’de t oranı ve p değeri üzerinden model hakkında yorum yapılması mümkündür. Elde edilen sonuçlarda t oranının yüksek ve p değerinin düşük olduğu değişkenler, model için uygun girdiler olduğunu göstermektedir. Çizelge 5.9’a bakıldığında seçilen parametrelerin model için uygun olduğu görülmektedir.

Çizelge 5.11 Biyogaz üretiminin tahmininde deneysel sonuçlarla en iyi uyum sağlayan çoklu regresyon modelinin (eksponansiyel model) katsayıları ve modele ait bazı istatistiksel sonuçlar

Katsayılar ve sabit terim ( <i>i</i> )	Girdi değişkenleri	Standart hata	t oranı	p değeri
$a = 0.098$	$x_1 = \text{Organik yükleme oranı (kg KOİ/m}^3\text{/gün)}$	0,0037	26,29	0,0
$b = 7,78.10^{-7}$	$x_2 = \text{Giriş alkalinite değeri (mg/L CaCO}_3\text{)}$	$5,27.10^{-5}$	0,015	0,988
$c = -2,6.10^{-2}$	$x_3 = \text{Giriş pH değeri}$	$1,91.10^{-2}$	-1,018	0,310
$d = 0,161$	$x_4 = \text{İşletme sıcaklığı (°C)}$	$1,91.10^{-2}$	8,415	0,0
$e = -4,42.10^{-5}$	$x_5 = \text{Çıkış KOİ değeri (mg/L)}$	$5,37.10^{-5}$	-0,824	0,411
$f = 1,196.10^{-4}$	$x_6 = \text{Çıkış alkalinite değeri (mg/L CaCO}_3\text{)}$	$3,66.10^{-5}$	3,272	0,001
$g = 5,86.10^{-2}$	$x_7 = \text{Çıkış pH değeri}$	0,139	0,420	0,675
$h = -2.95,10^{-5}$	$x_8 = \text{Çıkış uçucu yağ asidi (mg CH}_3\text{COOH/L)}$	$3,55.10^{-5}$	-0,832	0,407
$i = -1.539$	Sabit terim	1,061	-1,451	0,149

Çizelge 5.12 biyogaz üretimi için DataFit®'te tahmini yapılan verilerin deneysel sonuçları için en yüksek korelasyonu sağlayan Çizelge 5.10'da ki 1. denklem'in tanımlayıcı bakiye hata istatistiklerini göstermektedir.

Çizelge 5.12 Biyogaz üretiminin tahmininde deneysel sonuçlarla en iyi uyum sağlayan çoklu regresyon modeli (eksponansiyel model) için tanımlayıcı bakiye hataların istatistikleri

Bakiye hata istatistiği	Hesaplama	Regresyon sonuçları
Hata toleransı	$Y_a - Y_p$	$1,10^{-10}$
Hataların toplamı	$\sum_{i=1}^n Y_a - Y_p$	-246,25
Ortalama hata	$\frac{\sum_{i=1}^n Y_a - Y_p}{n}$	-1,797
Hataların toplamı (Mutlak)	$SSE = \sum_{i=1}^n Y_a - Y_p^2$	281.864,79
Tahmindeki standart hata	$\sqrt{\frac{\sum_{i=1}^n Y_a - Y_p^2}{n-p}} = \sqrt{\frac{SSE}{n-p}}$	46,93

$Y_a$ : Deneysel veri

$Y_p$ : Tahmin değeri

n: Gözlem sayısı

p : Çoklu regresyon modelindeki değişken sayısı

#### 5.4.2 Metan Üretim Tahmini İçin Lineer-Non-linear Çalışma

Biyogaz üretim tahmininde yapıldığı gibi metan üretim tahmininde de YSA'dan sonra DataFit® ile veriler işleme alınmıştır. Biyogaz için elde edilen sonuçlarda olduğu gibi DataFit® metan üretim tahmini içinde 1 eksponansiyel ve 2 lineer denklem olmak üzere 3 adet denklem vermiştir. Bu denklemler Çizelge 5.13'de görülmektedir.

Modellerimizin  $R^2$  ve  $R_a^2$  değerleri arasındaki yakınlığa bakılacak olduğunda metan üretimi için sisteme tanıtılan veri sayısı uygun ve yeterli miktardadır.

Çizelge 5.14'de metan üretimi için en uygun modele ait katsayılar ve modeldeki istatistiksel sonuçlar görülmektedir. Elde edilen  $t$  oranı ve  $p$  değerlerine göre, biyogaz üretimi tahmininde olduğu gibi metan üretimi tahmininde de OLR ve işletme sıcaklığı en önemli girdi değişkenleri olarak belirlenmiştir.

Çizelge 5.15 ise metan üretimi için DataFit®'te tahmini yapılan verilerin deneysel sonuçları için en yüksek korelasyonu sağlayan Çizelge 5.13'deki 1. denklemin tanımlayıcı bakiye hata istatistiklerini göstermektedir.

Çizelge 5.13 Metan üretiminin tahmininde DataFit® ile elde edilen çoklu regresyon modelleri ve regresyon analizinde hesaplanan bazı istatistiksel değerler

Sıra	Model	SEE	SR	AR	RSS	R <sup>2</sup>	R <sub>a</sub> <sup>2</sup>	NNI
1	$\exp(a*x_1+b*x_2+c*x_3+d*x_4+e*x_5+f*x_6+g*x_7+h*x_8+i)$	30,42	-164,39	-1,199	118.410,2	0.921	0.916	7
2	$a*x_1+b*x_2+c*x_3+d*x_4+e*x_5+f*x_6+g*x_7+h*x_8+i$	31,72	$2,51.10^{-12}$	$1,84.10^{-12}$	128.752,2	0.914	0.908	3
3	$a*x_1+b*x_2+c*x_3+d*x_4+e*x_5+f*x_6+g*x_7+h*x_8$	34,89	-24,17	-0.176	157.044,5	0.895	0.889	11

71

SEE: Tahmindeki standart hata

SR: Hataların toplamı

AR: Ortalama bakiye hata

RSS: Hataların kareleri toplamı

R<sup>2</sup>: Determinasyon katsayısı

R<sub>a</sub><sup>2</sup>: Ayarlanmış çoklu determinasyon katsayısı

NNI: Uygulanan non-lineer iterasyon sayısı

Çizelge 5.14 Metan üretiminin tahmininde deneysel sonuçlarla en iyi uyum sağlayan çoklu regresyon modelinin (eksponansiyel model) katsayıları ve modele ait bazı istatistiksel sonuçlar

Katsayılar ve sabit terim ( <i>i</i> )	Girdi değişkenleri	Standart hata	<i>t</i> oranı	<i>p</i> değeri
$a = 0,0947$	$x_1 = \text{Organik yükleme oranı (kg KOİ/m}^3\text{/gün)}$	$3,54 \cdot 10^{-3}$	26,73	0.0
$b = 7,34 \cdot 10^{-5}$	$x_2 = \text{Giriş alkalinite değeri (mg/L CaCO}_3\text{)}$	$5,23 \cdot 10^{-5}$	1,405	0.162
$c = -4,76 \cdot 10^{-2}$	$x_3 = \text{Giriş pH değeri}$	0.0251	-1,891	0.060
$d = 0,1405$	$x_4 = \text{İşletme sıcaklığı (}^\circ\text{C)}$	$1,83 \cdot 10^{-2}$	7,69	0.0
$e = -3,491 \cdot 10^{-5}$	$x_5 = \text{Çıkış KOİ değeri (mg/L)}$	$5,475 \cdot 10^{-5}$	-0,638	0.524
$f = 7,526 \cdot 10^{-5}$	$x_6 = \text{Çıkış alkalinite değeri (mg/L CaCO}_3\text{)}$	$3,611 \cdot 10^{-5}$	2,084	0.039
$g = 0.296$	$x_7 = \text{Çıkış pH değeri}$	0.1369	2,1222	0.0357
$h = -7.27 \cdot 10^{-5}$	$x_8 = \text{Çıkış uçucu yağ asidi (mg CH}_3\text{COOH/L)}$	$3,92 \cdot 10^{-5}$	-1,853	0.066
$i = 2,673$	Sabit terim	1,043	-2,564	0.011

Bu çalışma kapsamında gerçekleştirilen non-lineer regresyon analizi neticesinde elde edilen eksponansiyel modeller için Çizelge 5.11 ve Çizelge 5.14'te verilen regresyon değişkenlerine ait *t* oranı değerlerinin pozitif ve negatif değerler aldığı görülmektedir. Hesaplanan *t* oranları, değişkenlere ait etki değerlerinin bunlara karşılık gelen standart hata değerlerine oranı şeklinde elde edilen nümerik değerlerdir. Hesaplanan standart hata değerlerine göre; negatif *t* oranları negatif yani antagonistik etkileri, pozitif *t* oranları ise pozitif yani sinerjistik etkileri göstermektedir. Ancak, bu etkiler seçilen modelin matematiksel yapısına doğrudan bağlılık göstermekte olup, farklı modeller için

aynı deęişken farklı bir etki gösterebilmektedir. Bu nedenle, hesaplanan  $t$  oranlarına göre modele ait bağımsız deęişkenlerin bağımlı deęişkenler (örn: biyogaz ve metan) üzerindeki negatif ya da pozitif etkileri, o hesaplamada göz önüne alınan model için ifade edilmelidir. Esasen, model deęişkenlerinin tahmindeki yüzdesel katkıları ANOVA ile elde edilecek kareler toplamları göre daha net bir şekilde hesap edilebilir.

Çizelge 5.15 Metan üretiminin tahminde deneysel sonuçlarla en iyi uyum saęlayan çoklu regresyon modeli (eksponansiyel model) için tanımlayıcı bakiye hataların istatistikleri

Bakiye hata istatistięi	Hesaplama	Regresyon sonuçları
Hata toleransı	$Y_a - Y_p$	$1.10^{-10}$
Hataların toplamı	$\sum_{i=1}^n Y_a - Y_p$	-164,395
Ortalama hata	$\frac{\sum_{i=1}^n Y_a - Y_p}{n}$	-1,199
Hataların toplamı (Mutlak)	$SSE = \sum_{i=1}^n Y_a - Y_p^2$	118.410,24
Tahmindeki standart hata	$\sqrt{\frac{\sum_{i=1}^n Y_a - Y_p^2}{n-p}} = \sqrt{\frac{SSE}{n-p}}$	30,42

## 5.5 Tahmin Sonuçlarının İstatistiksel Analizi

Yapılan çalışmanın bu bölümünde YSA ve DataFit® ile modellenen veri setinin istatistiksel analiz sonuçları verilmiş olup biyogaz ve metan üretimi için elde edilen tahmin sonuçlarının karşılaştırılması yapılmıştır. Yapılan istatistiksel analizler test dataları üzerinden gerçekleştirilmiştir. İlerleyen alt başlıklarda biyogaz ve metan üretimi için yapılan tahmin sonuçlarının istatistiksel analizlerinin detaylı incelenmesi ve karşılaştırılması yer almaktadır.



### 5.5.1 Biyogaz Tahmin Sonuçlarının İstatistiksel Analizi

Biyogaz tahmin sonuçları için öncelikle YSA ve ardından DataFit® programında istatistiksel analizi gerçekleştirilmiştir. Çizelge 5.16’te optimum tahmin modellerinin sonuçlarının karşılaştırılması görülmektedir.

Çizelge 5.16’dan da görüldüğü üzere YSA tarafından elde edilen optimum model sonucunun determinasyon ve korelasyon katsayıları DataFit® tarafından elde edilen optimum modelden fazladır olup, bu durum YSA’nın çalışma kapsamında göz önüne alınan veri seti için en uygun model olduğunu göstermektedir.

Ortalama mutlak hata (MAE), Ortalama karesel hatanın karekökü (RMSE), Sistemik RMSE (RMSE<sub>s</sub>), Sistemik olmayan RMSE (RMSE<sub>u</sub>) ve sistemik hata oranı (PSE) değerlerine göre YSA tarafından elde edilen modelin sahip olduğu hata sonuçları DataFit® tarafından uygun bulunan modelin hata sonuçlarından daha azdır. Yani YSA tahmin ederken DataFit®’e göre daha az hata yaparak optimum sonuca erişmiştir.

Son olarak uyumluluk indeksi (IA) ve 2’nin faktörü (FA2) değerlerine bakılacak olunursa; bu değerler yukarıda bahsedilen parametreler kadar önem taşımamaktadır. Ancak önerilen modelin doğruluğunu kontrol etmek açısından bakılacak olunursa bu iki değer 1’e yakın olması modelimizin doğruluğunu kanıtlamaktadır. Çizelge 5.16’te de görüldüğü üzere bu iki değerimiz dikkat edilmesi istenilen değere her iki tahmin sonucunda da yakınlık göstermektedir, ancak YSA bu parametrelerde de öne çıkmaktadır.

Çizelge 5.16 Biyogaz üretimi tahmininde optimum tahmin modelleri tahmin sonuçlarının validasyonu/verifikasyonu

Performans indikatörleri	Matematiksel hesaplama	YSA Modeli	Non-lineer regresyon modeli (ekspansiyel model)
Determinasyon katsayısı ( $R^2$ )	$R^2 = \frac{\left( \sum_{i=1}^n (O_i - O_m)(P_i - P_m) \right)^2}{\sum_{i=1}^n (O_i - O_m)^2 \sum_{i=1}^n (P_i - P_m)^2}$	0.935	0.919
Korelasyon katsayısı (R)	$R = \sqrt{\frac{\left( \sum_{i=1}^n (O_i - O_m)(P_i - P_m) \right)^2}{\sum_{i=1}^n (O_i - O_m)^2 \sum_{i=1}^n (P_i - P_m)^2}}$	0.967	0.958
Ortalama mutlak hata (MAE)	$MAE = \frac{1}{n} \sum_{i=1}^n  P_i - O_i $	29.2722	32.0368
Ortalama karesel hatanın karekökü (RMSE)	$RMSE = \left( \frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2 \right)^{0.5}$	41.5818	45.7748
Sistemik RMSE ( $RMSE_S$ )	$RMSE_S = \left( \frac{1}{n} \sum_{i=1}^n [P_i_{reg} - O_i]^2 \right)^{0.5}$	4.805	10.493
Sistemik olmayan RMSE ( $RMSE_U$ )	$RMSE_U = \left( \frac{1}{n} \sum_{i=1}^n [P_i_{reg} - P_i]^2 \right)^{0.5}$	41.304	44.557
Sistemik hata oranı (PSE)	$PSE = \frac{RMSE_S^2}{RMSE_U^2}$	0.0135	0.0555
Uyumluluk indeksi (IA)	$IA = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n ( P_i - O_m  +  O_i - O_m )^2}$	0.983	0.978
Fraksiyonel varyans (FV)	$FV = 2 \sigma_o - \sigma_p / \sigma_o + \sigma_p$	-0.0048	0.02528
2'nin faktörü (FA2)	$0.5 \leq FA2 = \frac{1}{n} \sum_{i=1}^n \left( \frac{O_i}{P_i} \right) \leq 2$	1.0219	0.977

### 5.5.2 Metan Tahmin Sonuçlarının İstatistiksel Analizi

Metan tahmin sonuçları için YSA ve DataFit® programında modelleme yapılmıştır. Çizelge 5.17’de optimum tahmin modellerinin sonuçlarının karşılaştırılması yapılmıştır. Çizelge’den de görüldüğü gibi YSA tarafından elde edilen optimum model sonucunun determinasyon ve korelasyon katsayıları datafit tarafından elde edilen optimum modelden fazladır ki bu durum YSA’nın çalışmada kullanılan veri seti için en uygun model olduğu belirlenmiştir.

Ancak ortalama mutlak hata (MAE), Ortalama karesel hatanın karekökü (RMSE), Sistemik RMSE (RMSE<sub>s</sub>), Sistemik olmayan RMSE (RMSE<sub>u</sub>) ve sistemik hata oranı (PSE) değerlerine bakıldığında YSA ve DataFit®’ten elde edilen değerlerin bazı dalgalanmalara sahip olduğunu ve DataFit® tarafından bazı parametreler için daha iyi sonuçlar tahmin edildiği görülmektedir.

Ancak sadece elde edilen sonuçlardan yola çıkarak metan üretimi tahmininde DataFit® esaslı regresyon modelinin daha uygun olduğu doğrudan söylenemez. Sonuçlardan da görüldüğü üzere DataFit® tarafından veri seti için uygun bulunan modelin pratikte uygulanması zaman kaybına sebep olmaktadır. Ayrıca modele katkıda bulunabilmesi amacıyla modele bir başka değişken eklendiğinde YSA’nın tersine DataFit®’te yeniden bir model kurulması gerekmekte olup, bu durum elde edilen model sonuçlarının güncellemeye pek yatkın olmadığını göstermektedir. Bu sebeplerden ötürü Çizelge 5.17’de DataFit® hata oranlarında YSA’ya göre az bir farkla daha düşük bir sonuç vermiş olmasına rağmen kullanılabilirlik açısından uygun olmadığı için YSA modeli metan tahmin sonuçları için daha uygun bulunmuştur.

Son parametrelerimiz olan uyumluluk indeksi (IA) ve 2’nin faktörü (FA2) değerlerine bakıldığında ise; bu değerlerin hata oranları ya da korelasyon ve determinasyon katsayıları kadar model üzerinde etkisi olmadığı önceden belirtilmiştir. Ancak modelin doğruluğunu kontrol etmek açısından bakılacak olunursa bu iki değerlerin 1’e yakın olması modelin doğruluğunu kanıtlamaktadır. Çizelge 5.17’de de görüldüğü üzere bu iki değerimiz dikkat edilmesi istenilen değere her iki tahmin sonucunda da yakınlık göstermektedir, ancak YSA bu parametrelerde de öne çıkmaktadır.

Çizelge 5.17 Metan üretiminin tahmininde optimum tahmin modelleri tahmin sonuçlarının validasyonu/verifikasyonu

Performans indikatörleri	Matematiksel hesaplama <sup>a</sup>	YSA Modeli	Non-lineer regresyon modeli (eksponansiyel model)
Determinasyon katsayısı ( $R^2$ )	$R^2 = \frac{\left( \sum_{i=1}^n (O_i - O_m)(P_i - P_m) \right)^2}{\sum_{i=1}^n (O_i - O_m)^2 \sum_{i=1}^n (P_i - P_m)^2}$	0.924	0.922
Korelasyon katsayısı (R)	$R = \sqrt{\frac{\left( \sum_{i=1}^n (O_i - O_m)(P_i - P_m) \right)^2}{\sum_{i=1}^n (O_i - O_m)^2 \sum_{i=1}^n (P_i - P_m)^2}}$	0.961	0.960
Ortalama mutlak hata (MAE)	$MAE = \frac{1}{n} \sum_{i=1}^n  P_i - O_i $	23.0142	22.6958
Ortalama karesel hatanın karekökü (RMSE)	$RMSE = \left( \frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2 \right)^{0.5}$	29.555	29.215
Sistemik RMSE ( $RMSE_S$ )	$RMSE_S = \left( \frac{1}{n} \sum_{i=1}^n [P_i_{reg} - O_i]^2 \right)^{0.5}$	8.6829	6.7137
Sistemik olmayan RMSE ( $RMSE_U$ )	$RMSE_U = \left( \frac{1}{n} \sum_{i=1}^n [P_i_{reg} - P_i]^2 \right)^{0.5}$	28.2503	28.434
Sistemik hata oranı (PSE)	$PSE = \frac{RMSE_S^2}{RMSE_U^2}$	0.0945	0.0558
Uyumluluk indeksi (IA)	$IA = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n ( P_i - O_m  +  O_i - O_m )^2}$	0.979	0.979
Fraksiyonel varyans (FV)	$FV = 2 \sigma_o - \sigma_p / \sigma_o + \sigma_p$	0.01591	0.02568
2'nin faktörü (FA2)	$0.5 \leq FA2 = \frac{1}{n} \sum_{i=1}^n \left( \frac{O_i}{P_i} \right) \leq 2$	1.0477	0.9797

### SONUÇ, YORUM VE ÖNERİLER

Bu çalışmada melas atık sularının arıtımında yukarı akışlı havasız çamur yataklı reaktör (YAHÇYR) sistemi kullanılmış ve elde edilen biyogaz ile metan üretimlerinin yapay sinir ağları ile modellenmesi gerçekleştirilmiştir. YSA modelleme çalışmasında kullanılan veri seti, Türkdöğän-Aydınođ ve Yetilmezsoy [47] tarafından, pilot ölçekli bir YAHÇYR sisteminde gerçekleştirilen deneysel çalışmadan temin edilmiştir.

Çalışma kapsamında; temel bileşen analizi (principal component analysis, PCA) yapılmış ve PCA çalışması sonucunda tüm deęişkenlerin modele katkılarından dolayı deęerlendirilmeye alınması gerektięi belirlenmiştir. Model için geri yayılım algoritması (back propagation) seçimi hem biyogaz hemde metan için yapılmıştır. Yapılan işlemler sonucunda biyogaz için, 0.964 korelasyon ( $R$ ) saęlayan *trainscg* geri yayılım algoritması, metan için ise 0.974 korelasyon ( $R$ ) saęlayan yine *trainscg* (scaled conjugate gradient) algoritması seçilmiştir. Yapay sinir ağları sisteminin optimizasyonu aşamasında ise biyogaz ve metan üretimlerinin tahminlerinde gizli tabakalar da (hidden layer) kullanılacak optimum nöron sayısı elde edilmiştir. Optimizasyon sonucunda biyogaz için, 0.062382 ortalama karesel hata (MSE) ile 9 nöron, metan için ise 0.064884 ortalama karesel hata deęeri (MSE) ile 12 nöron ile gizli katmandaki nöron sayıları optimize edilmiştir. Hassasiyet analizi (sensitivity analysis) aşamasına gelindiğinde ise girdi olarak sisteme tanıtılan tüm parametrelerin YSA modeline katkıları belirlenmiş ve katkı yüzdeleri hesaplanmıştır. Biyogaz için yapılan hassasiyet analizinde, ilk veri sisteme girildiğinde ortalama karesel hata (MSE) deęeri  $>10^4$  iken dięer 7 parametre analize katıldıkça ortalama karesel hata deęeri önemli derecede düşüş göstermiş ve son olarak 0.062382 deęerini almıştır. Aynı şekilde, metan için de gerçekleştirilen

hassasiyet analizinde ilk parametre modele tanıtıldığında MSE değeri  $>10^4$  iken tüm parametrelerin analize dahil edilmesi halinde MSE değeri 0.064884'e düşmüştür.

YSA tekniği ile yapay zeka esaslı bir çalışma yapıldıktan sonra, DataFit® ile lineer-non-linear kapsamlı bir çalışma daha gerçekleştirilerek tahmin sonuçlarının kendi içerisinde mukayesesi yapılmıştır. Yapılan non-linear çalışma neticesinde, biyogaz için biri eksponansiyel olmak üzere 3 adet non-linear formülasyon elde edilmiştir. Bu 3 denklem arasından 0.918 değerrindeki korelasyon katsayısı ile eksponansiyel denklem model için uygun bulunmuştur. Metan için non-linear sonuçlara bakıldığında ise sistem biyogazda olduğu gibi 1 tanesi eksponansiyel denklem olmak üzere 3 adet denklemi veri seti için uygun model olarak atamış ve aralarında en yüksek korelasyonu 0.921 değerini veren eksponansiyel denklem en uygun model olarak seçilmiştir.

Ancak DataFit® ile gerçekleştirilen non-linear regresyon analizi neticesinde elde edilen model sonuçları, YSA tarafından elde edilen sonuçlarla kıyaslandığında, biyogaz üretim tahmin sonuçlarında YSA performansının DataFit®'ten çok daha uygun olduğu spesifik istatistiksel analizler doğrultusunda görülmüştür. Metan tahmin sonuçlarında yapılan kıyaslamaya bakıldığında DataFit®'in bazı değerlerinde YSA'dan daha uygun olduğu görülmektedir. Fakat, istatistiksel verilerin uygunluğu dışında modelin günlük hayatta kullanılabilirliği açısından DataFit®'ten elde edilen multi parametreliliği regresyon denklemi YSA modeli kadar kullanışlı olmayıp, güncel veriler karşısında yeniden model kurulması zorunluluğu ve değişen veriler karşısında YSA kadar dinamik olmaması gibi sebeplerden ötürü, metan üretim tahmininde de YSA'nın çok daha avantajlı olduğu görülmüştür.

Gerçekleştirilen bu çalışmada yapay sinir ağlarının dinamik bir yapıya sahip olduğu ve sisteme tanıtılan her tür yeni bilgi için çok kısa zamanda kendini güncelleyebildiği görülmüştür. Yapay sinir ağlarının aksine bu gibi durumlarda konvansiyonel non-linear esaslı regresyon denklemi daha sabit bir yapıya sahip olduğu için yeni veriler karşısında yeni bir model kurulması gerektiğini göstermiştir. DataFit® kompleks ve yüksek mertebeli formülizasyonlara sahip olmasına rağmen, YSA modelleme tekniği bu konuda uygulamada daha avantajlı bir metottur.

Ayrıca çalışma kapsamında, biyogaz ve metan üretimlerinin tahmininde YSA esaslı iki farklı tahmin modeli geliştirilmiştir. Bunun yanında, biyogazdaki metan muhtevasının deneysel olarak sürekli ölçülmesi neticesinde biyogaz esaslı bir YSA modelinden metan üretim tahmininin yapılması da ayrı bir araştırma konusudur. Benzer şekilde, biyogazdaki diğer bileşenlere ait üretim değerleri de elde edilebilir. Ayrıca, geliştirilen tahmin modellerinin pratikteki uygulanabilirliğini arttırmak amacıyla değişken sayısının azaltılması da düşünülebilir. Ancak değişken sayısının azaltılmasında, modelin prosesi temsil edici özelliğinin geri planda kalmamasına özen gösterilmelidir.

Sonuç olarak, gerçekleştirilen bu çalışma ile gerçek ölçekli tesislerde, sisteme dahil olan değişkenlere göre metan ve biyogaz tahminleri önceden yapılabilir ve oluşabilecek muhtemel emisyon miktarları belirlenebilir. Yine aynı şekilde tahmin edilen değerlere bağlı olarak sistemden elde edilebilecek toplam enerji ve kalorifik yanma değerleri hesaplanabilir. Bu gibi avantajlarının yanısıra, tesiste gaz kaynaklı problemlerin önceden tespiti konusunda prosese adapte edilecek YSA esaslı bir uyarı mekanizmasının da gelecekteki çalışmalar için potansiyel bir avantaj sağlayabileceği düşünülmektedir.

Yapılan bu çalışmada, aktivasyon algoritması olarak tanjant hiperbolik sigmoid fonksiyonu (*tansig*) kullanılmıştır. Ancak ilerideki çalışmalarda, aktivasyon algoritması değiştirilerek farklı YSA modelleri için yeni çalışmalar da yapılabilir. Ayrıca, sisteme katkısı olabilecek olan başka proses kaynaklı parametreler de (örn: yukarı akış hızı, reaktördeki katı madde konsantrasyonu, çözünmüş KOİ, KOİ giderim hızı, hidrolik bekletme süresi, vb.) eklenerek yeni YSA modelleri ve bunların tahmin performansına spesifik katkıları bulunabilir. Bunların dışında, bu çalışmada ortaya koyulan avantajlarından ötürü YSA modelleri ile benzer amaçlı tahmin modelleri entegre edilerek farklı yapay zeka esaslı modelleme (örn: neuro-fuzzy modelleri) çalışmaları da gelecekte yapılabilir.

## KAYNAKLAR

- 
- [1] Timetürk Gazetesi, Türkiye’de Şeker Üretimi ve Sorunları, [www.timeturk.com](http://www.timeturk.com), 14 Nisan 2011
- [2] Yetilmezsoy, K., (2008), Tavuk Çiftliği Atıklarının Havasız Çamur Yataklı Reaktörde Arıtılabilirliği, Doktora Tezi, YTÜ, Fen Bilimleri Enstitüsü, İstanbul.
- [3] Cammerer, B., Jalyschkov, V. Ve Kroh, L.W, (2002). "Carbohydrate structures as part of the melanoidin skeleton", International Congress Series, 1245: 269-273
- [4] Kim, S.B., Hayase, F. ve Kato, H., (1985). " Decolorization and degradation products of melanoidins on ozonolysis", Agricultural Biology and Chemistry, 49:785-792.
- [5] Ohmomo, S., Yoshikawa, H., Nozaki, K., Nakajima, A., Daengsubhar, W. Ve Nakamura, I., (1988 b). " Continuous Decolorization of Molassed Wastewater Using Immobilized Lactobacillus Hilgardii Cell", Agricultural and Biological Chemistry, 52:2437-2441.
- [6] Nakajima-Kame, T., Shimomura, M., Nomra, N., Chanpornpong, T. Ve Nakahava, T., (1999). " Decolorization of Molasses Wastewater by Bacillus sp. Under Thermophilic and Anaerobic Conditions", Journal of Bioscience and Bioengineering, 87: 119-121.
- [7] Kumar, P., Chandra, R., (2006). " Decolorization and Detoxification of Synthetic Molasses Melanoidins by Individual and Mixed Cultures of Bacillus spp.", Bioresource Technology, 97 (16): 2096-2012.
- [8] Sirianuntabipoon, S., Phothilangka, P. Ve Ohmomo, S., (2004). " Decolorization of Molasses Wastewater by A Strain No. BP103 of Acetogenic Bacteria", Bioresource Technology, 92: 31-39.
- [9] Mohana, S., Desai, C. Ve Madamwar, D., (2007). " Biodegradation and Decolorization of Anaerobically Treated Distillery Spent Wash By a Novel Bacterial Consortium", Bioresource Technology, 98: 333-339.
- [10] Türkdöğän-Aydınol, F. İ. Ve Yetilmezsoy, K., (2010). " A Fuzzy-Logic-Based Model to Predict Biogas and Methane Production Rates in a Pilot-Scale Mesophilic UASB Reactor Treating Molasses Wastewater", Journal of Hazardous Materials, 182: 460-471.



- [11] Sirianuntapiboon, S. Ve Prongtong, S., (2000). "Removal of Color Substances in Molasses Wastewater by Combined Biological and Chemical Processes", *Thammasat Int. J. Sc. Tech.*, 5: 2.
- [12] Pena, M., Coca. M., Gonzalez, G., Rioja, R. Ve Garcia, M.T., (2003). " Chemical Oxidation of Wastewater From Molasses Fermentation With Ozone", *Chemosphere* 51: 893-900.
- [13] Zhang, B., Zhao, H., Zhou, S., Shi, C., Wang, C. ve Ni, J., (2009). " A Novel UASB-MFC-BAF Integrated System for High Strength Molasses Wastewater Treatment and Bio-Electricity Generation", *Bioresource Technology*, 100: 5687-5693
- [14] Sirianuntapiboon, S. Ve Prasertsong, K., (2008). " Treatment of Molasses Wastewater by Acetogenic Bacteria BP103 in Sequencing Batch Reactor (SBR) System", *Bioresource Technology*, 99: 1806-1815.
- [15] Liang, Z., Wang, Y., Zhou, Y., Liu, H. Ve Wu, Z., (2009). " Variables Affecting Melanoidins Removal From Molasses Wastewater by Coagulation/Flocculation", *Separation and Purification Technology*, 68: 382-389.
- [16] Sohsalam, P. Ve Sirianuntapiboon, S., (2008). " Feasibility of Using Constructed Wetland Treatment for Molasses Wastewater Treatment", *Bioresource Technology*, 99: 5610-5616.
- [17] Türkiye Yem Sanayicileri Birliđi, Biyoyakıt Politakalarının Gıda ve Yem Sanayilerine Katkıları, [www.turkiyeyembir.org.tr](http://www.turkiyeyembir.org.tr), 15 Mayıs 2011.
- [18] Kent Haber Gazetesi, Kaçak Şeker Üretimi Düşüyor, [www.kenthaber.com](http://www.kenthaber.com), 25 Ağustos 2011.
- [19] Türk Şeker Fabrikaları A.Ş., Şeker Fabrikası – Melas, [www.turkseker.gov.tr](http://www.turkseker.gov.tr) , 25 Ağustos 2011.
- [20] Schneider, F., (1971). Şekerin Teknolojisi, Türkiye Şeker Fabrikası A.Ş. Yayını, Ankara.
- [21] Gürel, Ö., (1996). Melastan Fermantasyon Yoluyla Etanol Elde Edilmesi, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- [22] Pamir, M.H., (1978). Teknik ve Endüstriyel Mikrobiyoloji, A. Ü. Ziraat Fakültesi Yayınları, 681, Ankara.
- [23] Fidan, İ. Ve Şahin, İ., (1979). İspirto Teknolojisi ve Damıtık İçkiler, A. Ü. Ziraat Fakültesi, Teksir No:12, Ankara.
- [24] Tayfun, N., (1974). " Melasın Özelliklerinin Fermantasyona Etkisi", *Şeker* 90, 42- 50.
- [25] Kavas, M.F. ve Leblebici, M.J., (2004). Kalite ve İşletme Kontrol Laboratuvarı El Kitabı, Türkiye Şeker Fabrikası A.Ş. Genel Müdürlüğü Yayınları, 224: 261, Ankara.
- [26] DPT, (2001). Sekizinci Beş Yıllık Kalkınma Planı, Ankara.

- [27] Kakıcı, A., (2009). Yapay Sinir Ağlarına Giriş, [www.ahmetkakici.com](http://www.ahmetkakici.com), 18 Ocak 2011.
- [28] Yapay Sinir Ağları, (2010). Yapay Sinir Ağlarına Genel Bakış, [www.yapay-sinir-aglari.uzerine.com](http://www.yapay-sinir-aglari.uzerine.com), 30 Ağustos 2011.
- [29] Yurtoğlu, H., (2005). Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği, Uzmanlık Tezi, Devlet Planlama Teşkilatı, Ankara.
- [30] Minsky, M. L. ve Papert, S. A., (1969). Perceptrons, Cambridge, MA: MIT Press.
- [31] Yetilmezsoy, K., Özkaya, B. Ve Çakmakçı, M., (2011). " Artificial Intelligence-Based Prediction Models For Environmental Engineering", Neural Network World, 193-218.
- [32] Zade, J.G. ve Noori, R., (2008). " Prediction Of Municipal Solid Waste Generation By Use Of Artificial Neural Network: A Case Study Of Mashhad.", International Journal of Environmental Research, 13-22.
- [33] Jahandideh, S., Jahandideh, S., Asadabadi, E.B., Askarian, M., Movamedi. M., Mehdi, M., Hosseini, S. ve Jahandideh, M., (2009). " The Use of Artificial Neural Networks and Multiple Linear Regression to Predict Rate of Medical Waste Generation", Waste Management, 29: 2874-2879.
- [34] Yabanuka. K., Hosomi, M. Ve Murakami, A., (1997). " Novel Application of a Back- Propagation Artificial Neural Network Model Formulated to Predict Algal Bloom", Water Science Technology, 36: 89-97.
- [35] Karul, C., Soyupak, S., Çilesiz, A. F., Akbay, N. Ve Germen, E., (2000). " Case Studies On The Use Of Neural Networks in Eutrophication Modeling", Ecological Modelling, 134: 145-152.
- [36] Hamed, M., Khalafallah, M. G. ve Hassanien, E. A., (2004). " Prediction of Wastewater Treatment Plant Performance Using Artificial Neural Networks", Environmental Modelling Software, 19: 919-928.
- [37] Onkal-Engin, G., Demir, I. Ve Engin, S. N., (2005). " Determination of the Relationship Between Sewage Odour and BOD by Neural Networks", Environmental Modelling Software, 21: 1190-1197.
- [38] Yetilmezsoy, K. Ve Sapci-Zengin, Z., (2009). " Stochastic Modeling Applications for the Prediction of COD Removal Efficiency of UASB Reactors Treating Diluted Real Cotton Textile Wastewater", Stochastic Environmental Researches and Risk Assessment, 23: 13-26.
- [39] Karaca, F. Ve Özkaya, B., (2006). " A Neural Network- Based Model for Controlling Leachate Flow-Rate in a Municipal Solid Waste Landfill Site", Environmental Modelling Software, 21: 1190-1197.
- [40] Al- Mutairi, N., Kartam, N., Koushki, P. Ve Al-Mutairi, M., (2004). " Modelling and Predicting Biological Performance of Contact Stabilization Process Using Neural Networks", Journal of Computing in Civil Engineering, 18: 341-349.

- [41] Özkaya, B., Demir, A. Ve Bilgili, M. S., (2007). " Neural Network Prediction Model for the Methane Fraction in Biogaz from Field-Scale Landfill Bioreactors", *Environmental Modelling Software*, 22: 815-822.
- [42] Özkaya, B., Şahinkaya, E., Nurmi, P., Kaksonen, A. H. Ve Puhakka, J. A., (2008). " Biologically Fe<sup>+2</sup> Oxidizing Fluidized Bed Reactor Performance and Controlling of Fe<sub>2</sub>S<sub>3</sub> Recycle During Heap Bioleaching: An Artificial Neural Network- Based Model", *Bioproc. Biosyst. Eng.*, 31: 111-117.
- [43] Akkoyunlu, A., Yetilmezsoy, K., Erturk, F. Ve Öztemel, E., (2010). " A Neural Network- Based Approach for the Prediction of Urban SO<sub>2</sub> Concentrations in the İstanbul Metropolitan Area", *International J. Environmental Pol.*, 40: 301-321.
- [44] Yetilmezsoy, K., (2006). " Determination of Optimum Body Diameter of Air Cyclones Using a New Empirical Model and a Neural Network Approach", *Environ. Eng. Sci.*, 28: 680-690.
- [45] Agirre- Basurko, E., Ibarra- Berastegi, G. ve Madariaga, I., (2006). " Regression and Multilayer Perceptron- Based Models to Forecast Hourly O<sub>3</sub> and NO<sub>2</sub> Levels in the Bilboa Area", *Environ. Model. Soft.*, 21: 430-446.
- [46] Noori, R., Hoshyaripour, G., Ashrafi, K. Ve Araabi, B. N., (2010). " Uncertainty Analysis of Developed ANN and ANFIS Models in Prediction of Carbon Monoxide Daily Concentrations", *Atmos. Environ.*, 44: 476-482.
- [47] Türkdoğan-Aydınoğlu, F., İ. Ve Yetilmezsoy, K., (2010). " A Fuzzy- Logic- Based Model to Predict Biogas and Methane Production Rates in a Pilot- Scale Mesophilic UASB Reactor Treating Molasses Wastewater", *Journal of Hazardous Materials*, 182: 460-471.
- [48] Gohil, A. Ve Nakhla, G., (2006). " Treatment of Tomato Processing Wastewater by An Upflow Anaerobic Sludge Blanket- Anoxic- Aerobic System", *Bioresour. Technol.*, 97: 2141- 2152.
- [49] Çiler, M., (1985). Design Principles for the Treatment of High- Strength Wastewaters in a UASB System, Doktora Tezi, İstanbul Teknik Üniversitesi, İstanbul.
- [50] Öztürk, M., (2005). Hayvan Gübresinden Biyogaz Üretimi, [www.mozturk.net](http://www.mozturk.net), 26 Temmuz 2011.
- [51] Verma, S., (2002). Anaerobic Digestion of Biodegradable Organics in Municipal Solid Wastes, Yüksek Lisans Tezi, Department of Earth and Environmental Engineering & Applied Science, Columbia University, USA.
- [52] Kanat, G. ve Saral, A., (2009). " Estimation of Biogas Production Rate in a Thermophilic UASB Reactor Using Artificial Neural Networks", *Environ. Model. Assess.*, 14: 607- 614.
- [53] Satyawali, Y. Ve Balakrishnan, M., (2008). " Wastewater Treatment in Molasses- Based Alcohol Distilleries for COD and Color Removal: A Review", *J. Environ. Manage.*, 86: 481- 497.

- [54] Ülkü, A., B, (2006). Anaerobik Arıtma Sisteminin Modellenmesi ve Kontrolü, Yüksek Lisans Tezi, Gebze İleri teknoloji Enstitüsü Mühendislik ve Fen Bilimleri Enstitüsü, Gebze.
- [55] Öztürk, İ., (1999). Anaerobik Bioteknoloji ve Atık Arıtımındaki Uygulamaları, Su Vakfı Yayınları.
- [56] Murnleitner, E., (2001). State Detecion and Feedback Control of the Anaerobic Wastewater Treatment Using Fuzzy Logic, Doktora Tezi, Technischen Universitat München.
- [57] Ros, M. Ve Zupancic, G.D., (2003). " Thermophilic Anaerobic Digestion of Waste Activated Sludge", Acte Chim. Slov, 50: 359-374.
- [58] Lahav. O. Ve Loewenthal, R. E., (200). " Rapid communication Measurement of VFA in Anaerobic Digestion: The Five- Point Titration Method Revisited", Water SA, 26: 389- 393.
- [59] Florencio, L., Field, A. Ve Lettinga, G., (1997). " High- Rate Anaerobic Treatment Of Alcoholic Wastewaters", Brazilian Journal of Chemical Engineering, 14(4): 409- 416.
- [60] Samsunlu, A., (2005). Çevre Mühendisliği Kimyası, Birsen Yayınevi.
- [61] Vikipedi Özgür Ansiklopedi, Biyogaz, [www.wikipedia.com](http://www.wikipedia.com), 15 şubat 2011.
- [62] Albiyobir Alternatif Enerji ve Biyodizel Üreticileri Birliği, Biyoyakıtlar, [www.albiyobir.org.tr](http://www.albiyobir.org.tr), 16 Mart 2011.
- [63] Akkoyunlu, A., Yetilmezsoy, K., Ertürk, F. Ve Oztemel, E., (2010). " A neural Network- Based Approach fort he Prediction of Urban SO<sub>2</sub> Concentrations in İstanbul Metropolitan Area", Int. J. Enviroment and Pollution, 40: 4.
- [64] Mohamad- Saleh, J. Ve Hoyle, B. S., (2008). " İmproved Neural Network Performance Using Principal Component Analysis on Matlab", Int., J. The Computer, The İnternet and Management, 16: 1-8.
- [65] Hagan, M. T., Demuth. H. B. Ve Beale, M. H., (1996). Neural Network Design , PWS Publishing Company, Boston, MA.
- [66] Ma, Z., Zhou, C., Lu, L., Ma, Y., Sun, P. Ve Cui, Y., (2007). " Predicting Protein-Protein İnteractions Based on BP Neural Network", İnternational Conference on Bioinformatics and Biomedicine Workshops, (BIBMW), California, USA, 3-7.
- [67] Cai, M., Yin, Y. Ve Xie, M., (2009). " Prediction of Hourly Air Pollutant Concentrations Near Urban Arterials Using Artificial Neural Network Approach", Transport. Res. Part D, 14: 32-41.
- [68] Liu, Z. Ve Meng, X., (2009). " İntegration of İmproved BPNN Algorithm and Multistage Dynamic Fuzzy Judgement and İts Application ESMP Evaluation", J. Computers, 4: 69-76.
- [69] Yetilmezsoy, K. Ve Saral, A. (2007). " Stochastic Modeling Approaches Based on Neural Network and Linear- Nonlinear Regression Techniques fort he

Determination of Single Droplet Collection Efficiency of Countercurrent Spray Towers”, *Environ. Model. Assess*, 12: 13-26.

- [70] Almasri, M. N. Ve Kaluarachchi, J. J., (2005). “ Modular Neural Networks to Predict the Nitrate Distribution in Ground Water Using the Onground Nitrogen Loading and Recharge Data”, *Environ. Model. Soft.*, 18: 388-398.
- [71] Yetilmezsoy, K. Ve Demirel, S., (2007). “ Artificial Neural Network (ANN) Approach for Modeling of Pb (II) Adsorption From Aqueous Solution by Antep Pistachio ( Pistacia Vera L.) Shells”, *Science Direct*, 153: 1288- 1300.
- [72] Yetilmezsoy, K. Ve Sapçı-Zengin, Z., (2007). “ Stochastic Modeling Applications for the Prediction of COD Removal Efficiency of UASB reactors Treating Diluted Real Cotton Textile Wastewater”, *Stoch. Environ. Res. Risk Assess.*, 23: 13- 26.
- [73] Murnleitner, E., Becker, T.M. ve Delgado, A., (2002). “State Detection And Control of Overloads in the Anaerobic Wastewater treatment Using Fuzzy Logic”, *Water Res.*, 36:201-211.
- [74] Metternicht, G. ve Gonzalez, S., (2005). “FUERO: Foundations of a Fuzzy exploratory Model for Soil Erosion Hazard Prediction”, *Environ. Model. Soft.*, 20: 715-728.

## DENEYSEL VERİLER

OLR	Giriş Alkalinite	Giriş pH	Sıcaklık	Çıkış KOİ	Çıkış Alkalinite	Çıkış pH	Çıkış Uçucu Yağ Asidi	Gaz Hacmi	CH <sub>4</sub>
2,062	1060	5,90	35,0	174	1300	6,75	127	59	40
1,953	1020	6,20	34,8	131	1340	6,80	71	62	46
2,072	980	6,20	34,0	218	1400	6,80	113	64	50
2,073	786	5,50	34,9	204	1246	6,70	113	68	48
2,076	884	4,90	35,5	198	1320	6,65	99	65	48
2,139	840	6,50	34,8	174	1500	6,60	282	58	44
2,094	460	4,95	34,5	174	1360	6,65	145	46	36
1,970	580	5,10	35,1	161	1180	6,80	141	52	40
1,955	820	4,90	35,5	131	1360	6,70	126	59	44
2,017	763	4,70	35,6	138	1280	6,75	133	63	49
2,509	920	6,10	34,3	144	1440	6,70	71	102	75
2,471	860	5,90	37,2	109	1720	6,80	76	119	80
2,459	660	5,40	35,8	153	1780	6,70	118	113	79
2,279	360	4,50	34,6	133	1600	6,70	101	123	87
2,356	380	4,45	35,3	272	1240	6,60	80	98	67
2,395	442	4,50	34,3	249	1320	6,70	85	112	80
2,932	360	4,60	33,5	331	1220	6,60	71	75	51

3,163	400	4,50	34,0	384	1200	6,55	339	71	51
3,170	300	4,50	36,4	403	900	6,60	296	81	59
3,226	560	4,80	34,7	384	1380	6,60	282	80	60
3,263	583	4,70	36,0	269	1400	6,60	307	70	51
3,365	300	4,00	35,5	279	1640	6,90	339	110	81
3,252	420	4,10	35,4	186	1640	6,90	141	109	82
3,073	560	4,40	35,4	186	1620	6,80	466	104	80
3,365	520	4,40	35,3	167	1580	6,80	99	100	77
3,043	860	4,20	35,5	93	1660	6,70	71	114	82
3,139	380	4,20	35,7	205	1460	6,80	71	122	98
3,299	1100	6,60	35,4	230	2000	6,80	254	91	57
3,187	1020	6,50	35,1	350	2040	6,75	424	93	66
3,259	440	5,00	34,9	384	1960	6,60	169	89	57
3,208	460	4,80	35,2	298	1820	6,70	198	96	64
3,275	480	4,70	35,1	324	1920	6,70	141	92	61
4,066	460	4,60	34,4	269	1340	6,65	85	123	84
4,127	440	4,50	34,8	384	1340	6,60	212	125	86
4,129	360	4,50	35,0	461	1320	6,60	198	120	80
4,128	480	4,50	34,9	346	1360	6,65	141	124	81
3,993	520	4,50	34,9	254	1380	6,70	71	132	98
5,774	1750	7,10	35,5	335	2550	6,80	184	155	107
5,818	1700	7,00	34,5	329	2600	7,50	198	160	110
5,941	1840	6,00	35,1	310	2700	6,90	113	168	124
5,967	1600	6,10	36,1	503	2680	6,85	127	158	100
6,258	1160	5,10	35,1	348	2600	6,80	353	162	109
6,977	1340	7,40	35,1	707	3060	7,00	127	323	210

7,556	1220	6,90	35,1	428	3240	7,00	141	378	242
7,109	720	5,20	36,6	223	2940	7,10	438	372	234
6,788	480	4,40	35,7	465	2820	7,00	71	410	262
8,641	720	4,50	36,0	391	2540	7,00	240	392	251
10,291	1280	5,80	35,7	561	2820	6,90	311	294	176
10,601	1080	5,20	35,7	484	2920	7,10	141	320	234
9,777	520	4,40	35,4	426	2920	6,95	325	300	219
8,919	1020	4,50	35,5	639	3000	7,00	169	295	212
9,661	980	4,30	35,2	484	2940	6,90	127	287	207
9,419	840	4,60	35,5	707	3060	7,00	141	296	207
14,785	270	4,00	35,5	2914	4600	7,15	1765	538	296
16,456	260	4,00	35,3	2500	4540	6,70	3529	540	270
16,005	240	4,10	34,9	2400	4040	6,90	4471	535	294
15,568	270	4,00	35,0	2020	4340	7,00	2193	562	320
16,281	265	4,20	35,1	2100	4280	7,20	1855	543	320
3,560	520	5,70	34,5	308	1640	6,90	99	121	85
3,757	540	4,90	33,0	249	1380	6,65	113	115	84
3,220	740	4,70	35,5	252	1320	6,60	265	125	75
3,246	620	4,50	35,3	246	1340	6,70	395	113	70
3,262	680	4,50	35,5	294	1440	6,60	169	137	89
4,241	1280	4,90	35,1	304	1260	6,60	99	146	99
4,278	1240	4,70	35,5	315	1300	6,70	748	158	79
4,013	960	4,60	36,0	350	1660	6,70	282	170	119
4,139	1120	4,70	36,0	355	1660	6,80	56	166	113
3,850	1240	4,70	36,1	245	1700	6,90	141	169	115
4,389	320	5,50	35,3	422	1300	6,60	353	159	105



5,255	320	4,40	35,2	468	1280	6,60	282	154	100
4,924	360	4,30	34,9	325	1380	6,55	240	156	105
5,136	346	4,40	35,3	362	1260	6,70	212	152	99
4,950	340	4,40	35,1	398	1380	6,60	169	157	105
5,298	340	4,10	35,1	192	1300	6,50	169	156	100
5,211	300	4,10	34,8	307	1340	6,50	212	162	102
5,338	320	4,10	34,6	384	1330	6,55	99	179	115
5,021	520	4,50	34,0	377	1360	6,60	71	159	108
5,091	1360	4,50	34,5	576	1600	6,70	71	166	118
5,197	1380	4,40	34,7	330	1890	6,65	141	165	107
6,162	540	4,70	35,2	501	2100	6,75	99	242	148
5,933	580	4,60	35,6	483	2180	6,80	71	239	153
6,021	660	4,50	35,3	499	2100	6,75	99	233	142
6,000	520	4,30	34,8	461	2180	6,80	113	245	154
6,095	540	4,40	35,1	420	2140	6,80	71	241	154
8,851	1130	6,50	34,1	542	2500	6,80	184	252	151
7,924	780	5,10	34,8	232	2640	6,95	141	260	166
8,802	560	4,60	35,1	426	2360	6,80	579	258	170
8,730	520	4,60	34,8	155	2180	6,90	198	245	154
9,498	920	5,00	34,6	252	2080	6,85	71	255	158
8,525	1200	4,90	35,4	205	2400	7,10	141	345	238
9,948	1120	5,00	35,6	215	2680	7,00	99	335	241
9,157	1040	5,00	36,3	202	2680	7,15	184	340	258
9,703	1300	4,90	36,4	330	2540	7,00	141	335	228
9,371	1240	5,00	36,0	290	2480	6,90	85	345	235
12,771	1840	5,17	35,4	1499	5080	7,45	420	476	352

13,080	1920	5,88	35,9	1350	4070	7,45	282	488	356
13,070	1840	5,20	35,9	1356	4060	7,40	370	480	346
13,316	1750	5,00	35,7	1420	3950	7,30	282	495	381
13,140	1810	5,10	35,5	1390	4040	7,35	176	483	382
13,894	1920	7,40	35,8	316	2900	6,95	113	405	271
13,215	1940	7,20	35,8	446	3040	7,00	593	487	307
13,484	1180	5,40	36,3	335	3140	6,90	113	515	330
12,935	1340	5,30	35,9	707	3060	7,00	127	495	322
13,263	1220	5,30	35,1	428	3240	7,00	141	479	307
13,714	720	5,20	36,6	223	2940	7,10	438	472	297
15,794	2040	7,70	36,5	467	2620	7,10	353	579	394
16,483	1080	5,50	36,4	357	2600	7,00	184	690	435
15,823	560	4,20	36,1	730	2560	7,05	71	631	442
16,561	860	4,00	36,4	733	3000	7,00	99	753	489
15,444	480	4,00	36,3	476	3040	7,10	85	565	373
8,356	1020	7,40	35,1	288	4260	7,15	99	186	145
8,201	940	6,40	35,5	144	2700	6,80	42	190	112
7,832	480	5,00	34,0	164	1560	6,70	71	182	113
8,652	620	5,00	35,0	384	1400	6,60	155	174	111
7,896	480	5,00	34,9	416	1400	6,75	141	179	120
8,007	560	5,00	34,8	324	1420	6,70	254	183	121
8,620	486	4,50	34,5	330	1380	6,70	254	155	98
9,025	540	4,50	33,1	315	1420	6,70	353	159	92
8,792	520	4,60	34,4	200	1480	6,80	169	149	89
8,939	544	4,40	35,1	325	1440	6,75	254	151	94
9,116	530	4,50	34,8	275	1460	6,60	282	155	88

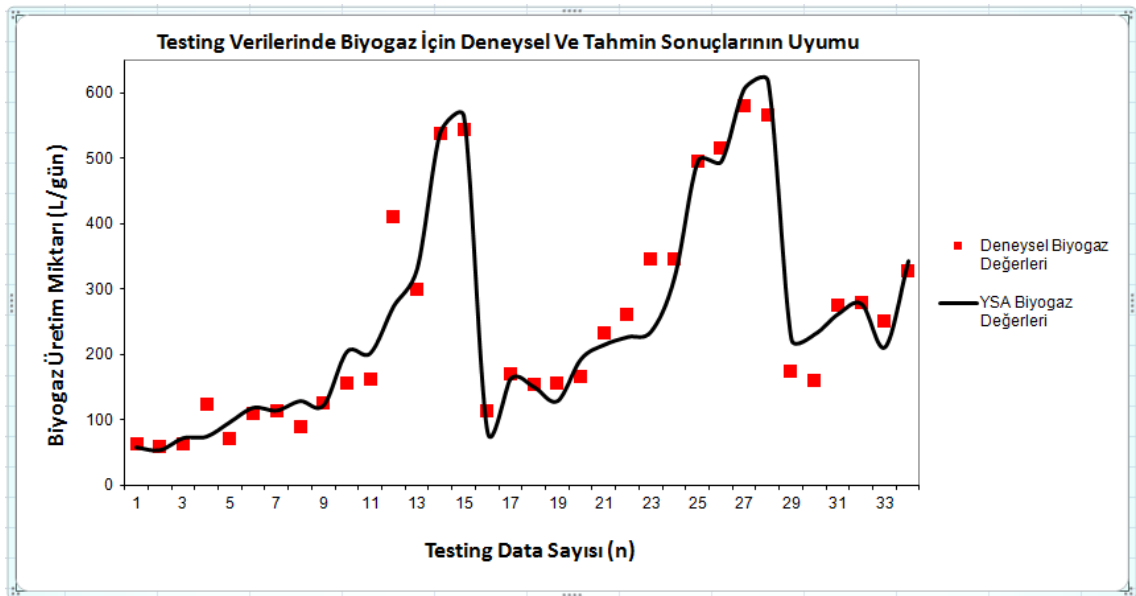
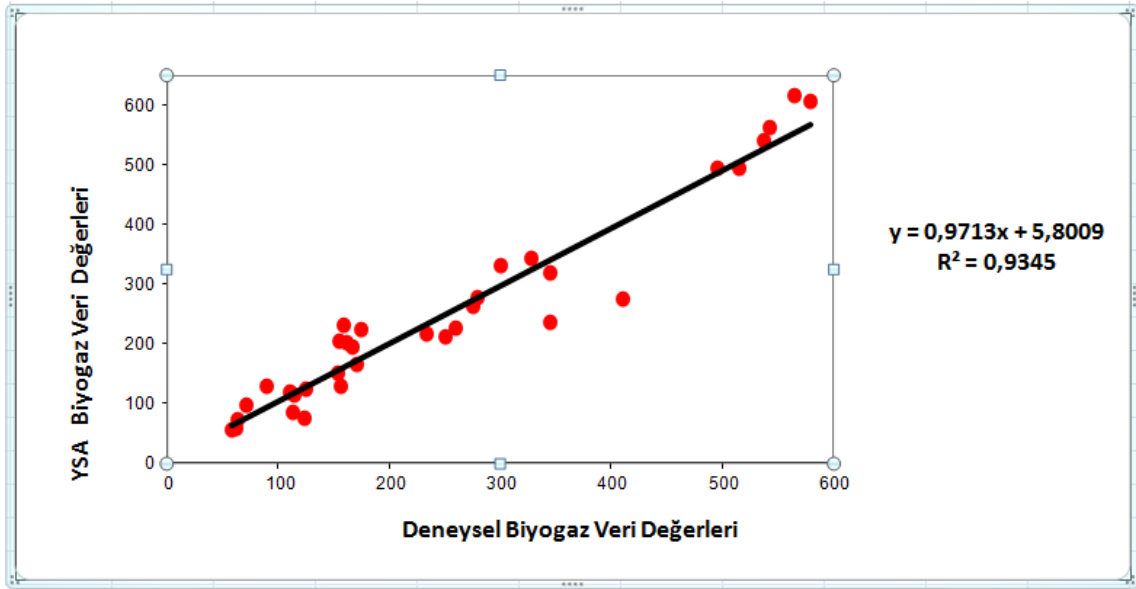
9,738	420	4,70	34,5	576	1340	6,70	282	275	176
9,917	400	4,70	33,8	502	1440	6,80	325	282	186
10,111	435	4,60	34,8	532	1240	6,70	409	284	187
9,990	406	4,50	35,2	561	1320	6,70	339	280	182
10,048	412	4,60	35,2	540	1330	6,60	305	279	187
10,483	620	4,90	35,6	308	1220	6,70	56	237	173
11,324	880	5,30	34,9	300	1300	6,70	367	247	173
10,689	960	5,60	35,2	176	1260	6,80	184	267	190
10,686	860	5,70	34,5	200	1240	6,70	99	250	185
11,353	720	5,50	35,2	225	1300	6,80	141	255	186
12,973	1460	7,70	34,5	264	1240	6,70	212	371	275
13,808	1220	5,65	35,1	374	1860	6,95	56	394	296
14,332	1020	5,30	33,7	352	2160	7,05	153	328	233
15,227	1320	5,60	35,4	276	2180	7,00	99	396	281
14,861	1280	5,55	35,5	396	2380	7,05	141	452	325
23,065	880	4,55	32,5	836	2240	6,90	466	580	400

## YSA TESTING VERİ SETİ

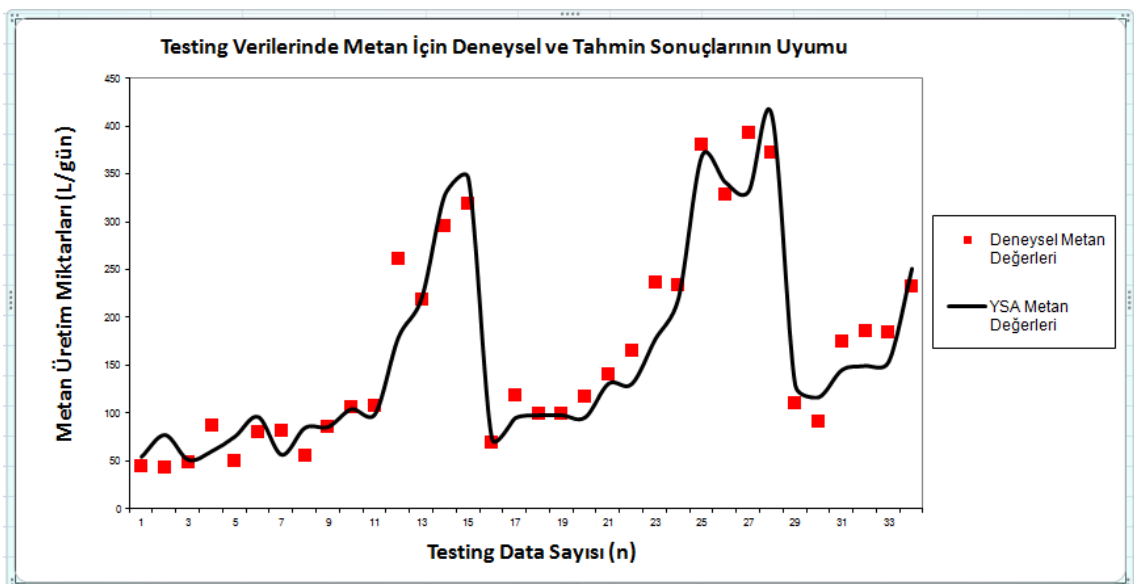
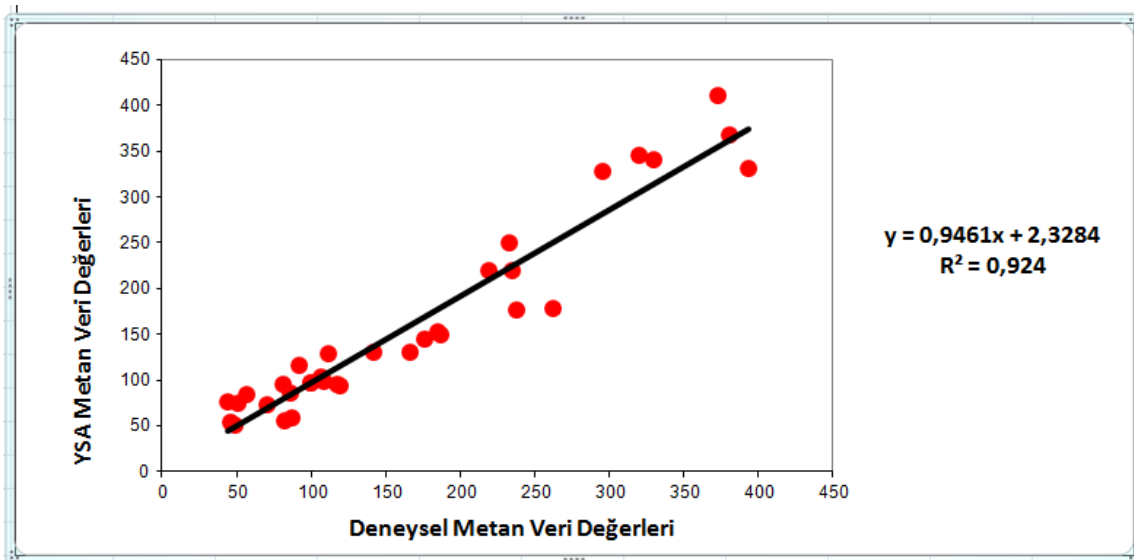
BİYOGAZ DENEY SONUÇLARI	BİYOGAZ MODEL SONUÇLARI	METAN DENEY SONUÇLARI	METAN MODEL SONUÇLARI
62	58,58	45,88	53,82
58	54,12	44,08	76,72
63	72,66	49,14	50,67
123	74,89	87,33	59,53
71	97,04	51,12	75,10
110	119,02	81,40	95,62
114	114,75	82,08	55,96
89	129,10	56,96	84,24
125	122,63	86,25	85,24
155	204,60	106,95	103,84
162	202,34	108,54	98,63
410	274,14	262,40	178,67
300	330,97	219,00	220,20
538	540,95	295,90	328,51
543	563,80	320,37	345,12
113	83,61	70,06	73,53

170	163,64	119,00	94,33
154	150,65	100,10	97,29
156	129,22	99,84	97,40
166	193,26	117,86	95,10
233	215,15	142,13	130,44
260	227,02	166,40	130,11
345	235,30	238,05	176,86
345	317,46	234,60	219,78
495	495,17	381,15	368,74
515	494,83	329,60	341,32
579	607,08	393,72	331,59
565	617,25	372,90	411,07
174	223,28	111,36	128,75
159	231,34	92,22	116,05
275	262,25	176,00	144,75
279	277,38	186,93	149,03
250	211,51	185,00	153,20
328	343,02	232,88	250,80

## TESTING VERİ SETİNİN YSA'DA BİYOGAZ TAHMİN SONUCUNUN UYUM ÇİZELGELERİ



## TESTING VERİ SETİNİN YSA'DA METAN TAHMİN SONUCUNUN UYUM ÇİZELGELERİ





## DATAFIT® TESTING VERİ SETİ

BİYOĞAZ DENEY SONUÇLARI	BİYOĞAZ DATAFIT® SONUÇLARI	METAN DENEY SONUÇLARI	METAN DATAFIT® SONUÇLARI
62	103,34	45,88	72,78
58	104,33	44,08	67,59
63	121,44	49,14	84,29
123	110,57	87,33	74,46
71	101,58	51,12	67,49
110	144,39	81,40	99,37
114	140,20	82,08	96,37
89	129,13	56,96	82,36
125	129,96	86,25	85,90
155	187,47	106,95	125,72
162	194,14	108,54	129,86
410	238,83	262,40	160,22
300	305,81	219,00	199,52
538	543,97	295,90	323,38
543	586,18	320,37	353,18
113	130,08	70,06	87,74
170	162,45	119,00	109,31


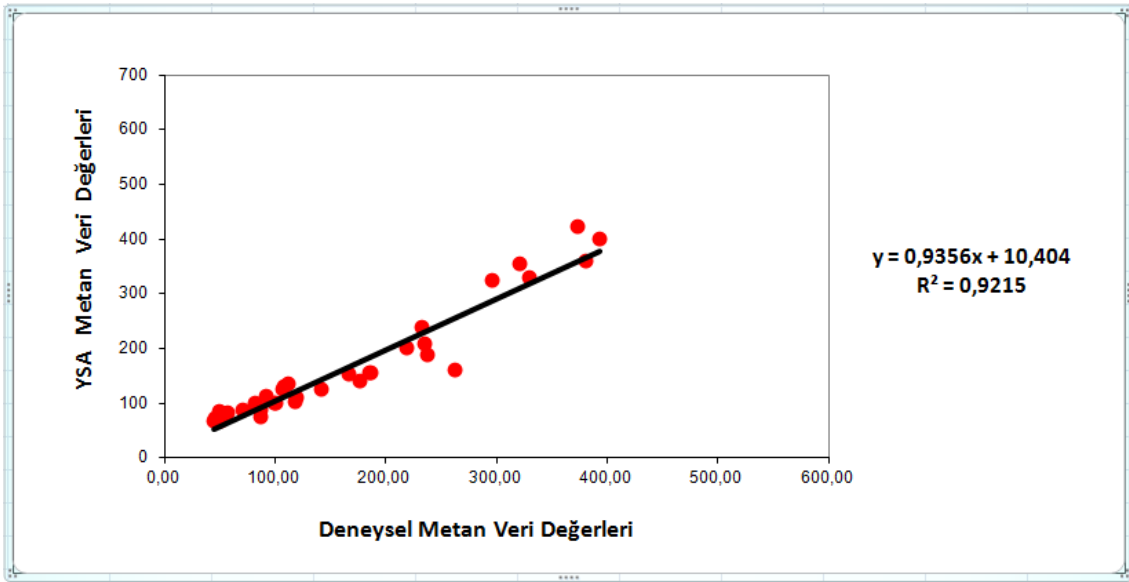


154	153,14	100,10	99,44
156	154,37	99,84	98,99
166	140,69	117,86	101,76
233	186,96	142,13	124,55
260	223,16	166,40	151,57
345	257,22	238,05	186,78
345	305,60	234,60	208,59
495	494,50	381,15	359,42
515	511,96	329,60	328,48
579	586,22	393,72	400,64
565	639,11	372,90	421,60
174	208,04	111,36	135,33
159	161,92	92,22	111,40
275	212,21	176,00	141,04
279	243,93	186,93	156,04
250	229,22	185,00	154,84
328	328,73	232,88	237,38

## TESTING VERİ SETİNİN DATAFIT®'TE BİYOGAZ TAHMİN SONUCUNUN UYUM ÇİZELGELERİ



## TESTING VERİ SETİNİN DATAFIT®TE METAN TAHMİN SONUCUNUN UYUM ÇİZELGELERİ



## ÖZGEÇMİŞ

---

### KİŞİSEL BİLGİLER

**Adı Soyadı** : İlknur TEMİZEL  
**Doğum Tarihi ve Yeri** : 21 Kasım 1987  
**Yabancı Dili** : İngilizce  
**E-posta** : temizelilknur@gmail.com

### ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Yüksek Lisans	Çevre Mühendisliği	Yıldız Teknik Üniversitesi	2012
Lisans	Çevre Mühendisliği	Sakarya Üniversitesi	2009
Lise	Fen Bilimleri	Bağlar Lisesi	2004

### Proje

Proje No	Proje Adı	Proje Tarihi	Görev
109Y269	Mikrobiyal Yakıt Hücresi ile Asit Oluşumu ve Metan Oluşumu Safhasındaki Katı Atık Depolama Alanı Sızıntı Sularından Elektrik Üretimi	Mayıs 2010-Mayıs 2012	Proje Asistanı