



T.C.
NİĞDE ÖMER HALİSDEMİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ATIKSU ARITMA TESİSİ ÇÜRÜTÜCÜ ÜNİTESİ BİYOGAZ ÜRETİM TAHMİN
SİSTEMİ

NAZIM ÖZİNCE

Ağustos 2019

T.C.
NİĞDE ÖMER HALİSDEMİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

ATIKSU ARITMA TESİSİ ÇÜRÜTÜCÜ ÜNİTESİ BİYOGAZ ÜRETİM TAHMİN
SİSTEMİ

NAZIM ÖZİNCE

Yüksek Lisans Tezi

Danışman

Dr.Öğr.Üyesi Mehmet Kürşat YALÇIN

Ağustos 2019

Nazım ÖZİNCE tarafından **Dr. Öğr. Üyesi Mehmet Kürşat YALÇIN** danışmanlığında hazırlanan “**ATIKSU ARITMA TESİSİ ÇÜRÜTÜCÜ ÜNİTESİ BİYOGAZ ÜRETİM TAHMİN SİSTEMİ**” adlı bu çalışma jürimiz tarafından Niğde Ömer Halisdemir Üniversitesi Fen Bilimleri Enstitüsü **Elektrik-Elektronik Mühendisliği** Ana Bilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan : Dr. Öğr. Üyesi Cabbar Veysel BAYSAL Çukurova Üniversitesi



Üye : Dr. Öğr. Üyesi İlyas KACAR Niğde Ömer Halisdemir Üniversitesi



Üye : Dr. Öğr. Üyesi Mehmet Kürşat YALÇIN Niğde Ömer Halisdemir Üniversitesi



ONAY:

Bu tez, Fen Bilimleri Enstitüsü Yönetim Kurulunca belirlenmiş olan yukarıdaki jüri üyeleri tarafından/....../20.... tarihinde uygun görülmüş ve Enstitü Yönetim Kurulu’nun/....../20.... tarih ve sayılı kararıyla kabul edilmiştir.

...../...../20...

Doç. Dr. Murat BARUT
MÜDÜR

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin bilimsel ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Nazım ÖZİNCE



ÖZET

ATIKSU ARITMA TESİSİ ÇÜRÜTÜCÜ ÜNİTESİ BİYOGAZ ÜRETİM TAHMİN SİSTEMİ

ÖZİNCE, Nazım

Niğde Ömer Halisdemir Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Danışman : Dr. Öğr. Üyesi Mehmet Kürşat YALÇIN

Ağustos 2019, 55 sayfa

Bu tez çalışması kapsamında Kayseri İleri Biyolojik Atık Su Arıtma Tesisinde bulunan Çürütücü Ünitesinde üretilen biyogazın gelecek günlerdeki üretim miktarı tahmin edilmeye çalışılmıştır. 1 Nisan 2017 ile 11 Nisan 2019 tarihleri arasındaki biyogaz üretim miktarı verileri kullanılarak MATLAB yazılım programında *NARNET* modeli ile yapay sinir ağları oluşturulmuştur. *NARNET* modelinde *nöron* ve gecikme (*delay*) sayıları değiştirilerek çok sayıda ağ oluşturulmuş, eğitilmiş ve farklı çalışma bölgelerinde başarı ölçütünü geçen 22 adet ağ kaydedilmiştir. Bu ağlara gelecek günlerdeki biyogaz üretim miktarı tahminleri yaptırılarak gerçek değerlerle karşılaştırılmıştır. Tez kapsamında başarılı ağların oluşturulmuş ve eğitilmiş olması biyogaz üretim miktarı ile ilgili tesiste yapılacak iş ve işlemlerde planlama yapılabilmesini sağlayacaktır.

Anahtar Sözcükler: Atık Su Arıtma Tesisi, Çürütücü Ünitesi, Biyogaz, MATLAB, Yapay Sinir Ağları, NARNET, Nöron, Delay

SUMMARY

WASTEWATER TREATMENT PLANT DIGESTIVE UNIT BIOGAS PRODUCTION ESTIMATION SYSTEM

ÖZİNCE, Nazım

Niğde Ömer Halisdemir University

Graduate School of Natural and Applied Science

Department of Electrical-Electronics Engineering

Supervisor : Assistant Professor Mehmet Kürşat YALÇIN

August 2019, 55 pages

In this thesis, the amount of biogas production in the Digestive Unit in Kayseri Advanced Biological Waste Water Treatment Plant is predicted for the following days using previous data. Artificial neural networks are created with *NARNET* model in *MATLAB* software program using biogas production amount data between April 1, 2017 and April 11, 2019. In the *NARNET* model, many networks are created by changing the number of *neurons* and *delays*, and totally 22 networks satisfying the success criteria are recorded. Using these networks the biogas production amounts are estimated for the following days and compared with the actual values. The establishment of successful networks within the scope of this thesis will enable the planning of the work and operations to be performed in the facility related to the amount of biogas production.

Keywords: Waste Water Treatment Plant, Digestive Unit, Biogas, MATLAB, Artificial neural networks, NARNET, Neuron, Delay

ÖN SÖZ

Tez çalışmam boyunca bilgi ve tecrübesiyle tıkanıđım her noktada önümü açan, ilgi ve alakasını hiçbir zaman esirgemeyen değerli danışmanım Sayın Dr. Öğr. Üyesi Mehmet Kürşat YALÇIN'a, bana aktardıkları akademik ve hayat tecrübeleri ile hem şahsi gelişmeme hem de tezimin oluşturulmasında katkılarından dolayı Sayın Dr. Öğr. Üyesi Cabbar Veysel BAYSAL ve Sayın Dr. Öğr. Üyesi İlyas KACAR hocalarıma sonsuz teşekkürlerimi sunuyorum.

Tez çalışmam boyunca sabrı, fedakârlığı ve desteğıyle sürekli yanımda olan sevgili eşim Sevilay ÖZİNCE'ye, aklıma geldikleri zaman bütün yorgunluğumu alan hayatımın anlamları ikiz kızlarım Miray ve Simay ÖZİNCE'ye, her zaman arkamda olduğunu hissettiren annem Rabiye ÖZİNCE'ye, babam Rasim ÖZİNCE'ye, kız kardeşim Canan ÖZİNCE'ye çok teşekkür ediyorum.

İÇİNDEKİLER

ÖZET	iv
SUMMARY	v
ÖN SÖZ	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
SİMGE VE KISALTMALAR	xii
BÖLÜM I	
GİRİŞ	1
BÖLÜM II	
LİTERATÜR	3
BÖLÜM III	
KAYSERİ İLERİ BİYOLOJİK ATIK SU ARITMA TESİSİ	9
3.1. Çürütücü Ünitesi	11
3.2. Biyogaz Üretimi	13
3.2.1. Hidroliz Safhası	14
3.2.2. Asit Üretimi Safhası (Asidojenez)	14
3.2.3. Asetat Üretimi Safhası (Asetojenez)	14
3.2.4. Metan Üretimi Safhası (Metanojenez)	14
BÖLÜM IV	
METODOLOJİ VE YÖNTEM	16
4.1. Yapay Sinir Ağları	17
4.1.1. Yapay Sinir Ağı Yapısı	17
4.1.2. Ağ Yapılarına Göre Yapay Sinir Ağı Modelleri	20
4.1.3. Yapay Sinir Ağlarının Öğrenme Şekilleri	21
4.2. Levenberg-Marquardt algoritması	24

4.3.	Verilerin Elde Edilmesi	26
4.3.1.	Verilerin Eğitime Hazır Hale Getirilmesi	28
4.4.	Veriler İle Ağ (Network) Oluşturulması.....	32
BÖLÜM V		
BULGULAR.....		35
BÖLÜM V		
SONUÇLAR VE GELECEK ÇALIŞMALAR		52
KAYNAKLAR		53
ÖZGEÇMİŞ		55



ÇİZELGELER DİZİNİ

Çizelge 3.1. Metan oluşum reaksiyonları	15
Çizelge 5.1. YSA'ların eğitiminde kullanılan verilerin paylaşılması	35
Çizelge 5.2. Kaydedilen ağların gün bazında tahmin başarıları	36
Çizelge 5.3. 7 günlük tahmin yapan ağların nöron ve gecikme (<i>delay</i>) sayıları	41
Çizelge 5.4. 14 günlük tahmin yapan ağların nöron ve gecikme (<i>delay</i>) sayıları	41
Çizelge 5.5. 7 günlük tahmin yapan 8 nöron 36 gecikmeli (<i>delay</i>) ağın başarı durumu	42
Çizelge 5.6. 7 günlük tahmin yapan 5 nöron 62 gecikmeli (<i>delay</i>) ağın başarı durumu	43
Çizelge 5.7. 7 günlük tahmin yapan 12 nöron 66 gecikmeli (<i>delay</i>) ağın başarı durumu	44
Çizelge 5.8. 14 günlük tahmin yapan 28 nöron 6 gecikmeli (<i>delay</i>) ağın başarı durumu	45
Çizelge 5.9. 14 günlük tahmin yapan 8 nöron 66 gecikmeli (<i>delay</i>) ağın başarı durumu	46
Çizelge 5.10. 14 günlük tahmin yapan 31 nöron 20 gecikmeli (<i>delay</i>) ağın başarı durumu	47
Çizelge 5.11. 14 günlük tahmin yapan 28 nöron 6 gecikmeli (<i>delay</i>) ağın başarı durumu	48
Çizelge 5.12. 7 günlük tahmin yapan 5 nöron 59 gecikmeli (<i>delay</i>) ağın başarı durumu	49
Çizelge 5.13. 14 günlük tahmin yapan 25 nöron 8 gecikmeli (<i>delay</i>) ağın başarı durumu	50
Çizelge 5.14. 14 günlük tahmin yapan 9 nöron 29 gecikmeli (<i>delay</i>) ağın başarı durumu	51

ŞEKİLLER DİZİNİ

Şekil 2.1. NAR modelinin akış şeması.....	5
Şekil 3.1. Tesisten bir görünüm.....	9
Şekil 3.2. Akış şeması	10
Şekil 3.3. SCADA sistemi tesis genel görünümü.....	11
Şekil 3.4. Çürütücü tankı ve gaz depolama balonları	12
Şekil 3.5. Anaerobik fermentasyon safhaları	13
Şekil 4.1. NAR modelinin blok diyagramı.....	16
Şekil 4.2. Yapay sinir ağı yapısı.....	18
Şekil 4.3. Lineer fonksiyonun grafiksel gösterimi	19
Şekil 4.4. Sigmoid fonksiyonun grafiksel gösterimi	20
Şekil 4.5. Hiperbolik tanjant fonksiyonun grafiksel gösterimi.....	20
Şekil 4.6. İleri beslemeli yapay sinir ağı	21
Şekil 4.7. Geri beslemeli yapay sinir ağı.....	21
Şekil 4.8. SCADA raporlama sistemi ana ekranı	27
Şekil 4.9. 2017 yılının 4. ayına ait rapordaki 194 verinin bir kısmı.....	28
Şekil 4.10. 1 nolu gaz depolama balonu verilerinin MATLAB'a aktarılmış ilk hali	29
Şekil 4.11. Günlük biyogaz üretim verileri	30
Şekil 4.12. Günlük biyogaz üretim verilerinin alt alta yazılmış hali.....	30
Şekil 4.13. Günlük biyogaz üretim verileri grafiği (gereksiz biyogaz üretim verileri dâhil).....	31
Şekil 4.14. Günlük biyogaz üretim verileri grafiği (gereksiz biyogaz üretim verileri çıkarılmış).....	32
Şekil 4.15. Örnek olarak oluşturulmuş 5 gecikme (delay), 6 nöronlu ağı blok diyagramı	33
Şekil 4.16. Örnek olarak oluşturulmuş 5 gecikme (delay), 6 nöronlu kapalı çevrim (closed loop) ağı blok diyagramı	34
Şekil 5.1. 15 nöron 47 gecikme değerine sahip ağı blok diyagramı.....	37
Şekil 5.2. 15 nöron 47 gecikme değerine sahip ağı algoritması	37

Şekil 5.3. 15 nöron 47 gecikme değerine sahip ağın işlem bilgileri.....	37
Şekil 5.4. 15 nöron 47 gecikme değerine sahip ağın performansı.....	38
Şekil 5.5. 15 nöron 47 gecikme değerine sahip ağın hata grafiği.....	38
Şekil 5.6. 15 nöron 47 gecikme değerine sahip ağın eğitim grafiği	39
Şekil 5.7. 15 nöron 47 gecikme değerine sahip ağın doğrulama grafiği	39
Şekil 5.8. 15 nöron 47 gecikme değerine sahip ağın test grafiği.....	40
Şekil 5.9. 15 nöron 47 gecikme değerine sahip ağın genel grafiği.....	40
Şekil 5.10. Ağın başarılı tahmin değeri ve gerçek değer grafiği	42
Şekil 5.11. Ağın başarılı tahmin değeri ve gerçek değer grafiği	43
Şekil 5.12. Ağın başarılı tahmin değeri ve gerçek değer grafiği	44
Şekil 5.13. Ağın başarılı tahmin değeri ve gerçek değer grafiği	45
Şekil 5.14. Ağın başarılı tahmin değeri ve gerçek değer grafiği	46
Şekil 5.15. Ağın başarılı tahmin değeri ve gerçek değer grafiği	47
Şekil 5.16. Ağın başarılı tahmin değeri ve gerçek değer grafiği	48
Şekil 5.17. Ağın başarısız tahmin değeri ve gerçek değer grafiği.....	49
Şekil 5.18. Ağın başarısız tahmin değeri ve gerçek değer grafiği.....	50
Şekil 5.19. Ağın başarısız tahmin değeri ve gerçek değer grafiği.....	51

SİMGE VE KISALTMALAR

Kısaltmalar	Açıklama
MATLAB	Matrix Laboratory
NARX	Nonlinear Autoregressive with External Input
NAR	Nonlinear Autoregressive
KİBAAT	Kayseri İleri Biyolojik Atık su Arıtma Tesis
CHP	Combined Heat and Power Unit (Birleştirilmiş Isı ve Güç Ünitesi)
PLC	Programmable Logic Controller
UAKM	Uçucu Askıda Katı Madde

Simgeler	Açıklama
m ³	Metreküp
kW	Kilowatt
MW	Megawatt
m	Metre
mm	Milimetre
PH	Power of Hydrogen
CO ₂	Karbondioksit
H ₂	Hidrojen
°C	Santigrat Derece
H ₂ S	Hidrojen Sülfür
CH ₄	Metan

BÖLÜM I

GİRİŞ

Atık su arıtma tesislerinin önemi su kıtlığının giderek daha çok hissedilmeye başladığı günümüzde evde ve endüstride kullanılmış olan atık suların ilgili yönetmelik standartlarına uygun olarak, herhangi bir çevre problemi oluşturmayacak şekilde arıtılarak; tarımsal sulama, endüstri, yer altı sularını besleme, hayvan suyu ihtiyacını karşılama gibi maksatlarla tekrar kullanımında önemli rol oynaması sebebiyle giderek artmaktadır. Atık su arıtma tesisleri sadece atık suları arıtmakla kalmaz aynı zamanda süreç boyunca elde edilen çamurun Çürütücü Ünitesinde gerçekleşen belirli işlemler sonucunda yenilenebilir enerji kaynakları kapsamında değerlendirilen biyokütleyle dâhil olan biyogaz üretimi de gerçekleştirir. Elde edilen biyogaz Kayseri İleri Biyolojik Atık su Arıtma Tesisinde bulunan iki adet Isı ve Güç Ünitesinde yakılarak elektrik enerjisine çevrilir ve tesisin elektrik enerjisi ihtiyacının yaklaşık %28'i karşılanır.

Gerçek kişiliğe sahip olan insanlar ya da tüzel kişiliğe sahip olan şirketler sürekli olarak gelecek planları yapmakta ve bu planları uygulamaya çalışmaktadır. İnsanların gelişimi şirketlerin ise sürekliliğinin devamı, büyüme hedefleri için yaptıkları gelecek planlarında tahmin sistemi büyük önem arz etmektedir. Gelecek zamanla ilgili tahmin yapabilmek (*forecast*) günlük hayatımızda sağlıktan ekonomiye, turizmden otomotive, politikadan giyime kadar her alanda karşımıza çıkmaktadır. Yapılan çalışmalardan bazıları “Yapay Zekâ Modelleriyle Tam Ölçekli Çamur Çürütme Reaktörlerinden Elde Edilen Biyogaz Üretiminin Tahmini: Yapay Sinir Ağları Ve Fuzzy Logic Uygulamaları”(Karakaya, 2012), “2030 yılında Türkiye’de yeşil enerji kullanım oranlarının tahmin edilmesi”(Gökay, 2019), “Sağlık sektöründe talep tahmini” (Dedeoğlu, 2019), “Borsa İstanbul’un tahminlenmesi”(Erkartal, 2018), “Bir yer altı kömür madeni için risk değerlendirmesi ve kaza tahmini”(Mevsim, 2018) isimli akademik çalışmalardır.

Bu tez çalışması kapsamında Kayseri İleri Biyolojik Atık su Arıtma Tesisinde bulunan Çürütücü Ünitesinde üretilen, iki adet birleştirilmiş Isı ve Güç ünitesinde yakılarak elektrik enerjisine ve ısı enerjisine dönüştürülen biyogazın gelecek günlerdeki üretimi daha önce yapılan çalışmalardan da yararlanılarak Yapay Sinir Ağları ile tahmin edebilmeye çalışılmıştır. Biyogazın gelecek günlerdeki üretimini tahmin edebilmek

bakım onarım planlamalarına yardımcı olabilecek, yöneticilerin müdahale alanını genişletecek, mevcut tesis yenileme amortismanları hakkında bilgi verebilecek ve nihayetinde benzer kurulacak tesislere örnek olabilecektir.



BÖLÜM II

LİTERATÜR

Tahmin yapısına göre çeşitli algoritmalar mevcut olup, bu algoritmalar elde bulunan verilerle sınırlı olarak tahmin etme (predict), elde bulunan verileri de kullanarak gelecek zamanla ilgili tahmin etme (forecast) olarak ikiye ayrılabilir. Tahmin zaman periyoduna göre genel olarak uzun (5-20 yıl), orta (1-5 yıl) ve kısa (1 yıldan az) vadeli olmak üzere üç kategoride sınıflandırılabilir. Yapısına ve periyoduna göre farklılık gösteren tahmin yöntemleri genel olarak Sezgisel (Subjektif) ve Sayısal (Objektif) olmak üzere ikiye ayrılır. Sezgisel tahmin yöntemlere örnek olarak anket yöntemi, delphi tekniği yöntemi, yönetici görüşünü esas alan yöntemleri sayabiliriz. Sayısal yöntemlere örnek olarak ise yapay sinir ağları, genetik algoritma, zaman serileri analizi, regresyon (en küçük kareler) yöntemi, üstel düzeltme yöntemi, aritmetik ortalama yöntemi gibi yöntemleri sayabiliriz.

Zaman serileri analizinde üzerinde çalışma yapılan değişkenin zaman içerisindeki sıralı ölçümlerinin bütünü ele alınarak gerçek değerlerin anlaşılması ve ilgili değişkenin gelecek zamandaki değerlerinin doğru bir şekilde tahmin (*forecast*) edilmesi hedeflenir. Zaman serileri genel olarak dört faktörden oluşur:

1. Trend Faktörü: Zaman serileri değişkeninin uzun dönemde gösterdiği düşme ve yükselme eğilimlerinde gösterdiği kararlı durumu ifade eder.
2. Mevsim Faktörü: Zaman serileri değişkeni mevsimlere göre farklılık gösterebilir. Mevsimsel olarak değişmeyi ifade eder.
3. Çevrimsel Faktör: Zaman serileri değişkeninin mevsimsel faktörden farklı olarak kısa veya uzun dönemsel olarak değişimini ifade eder.
4. Düzensiz Faktör: Diğer faktörler gibi belli olmayan hata faktörü gibi de düşünülebilecek faktördür.

Zaman serileri değişkenini oluşturan faktörler toplama şeklinde ifade edilebilir:

$$y(t) = T(t) + S(t) + C(t) + I(t) \quad (1.1)$$

Zaman serileri değişkenini oluşturan faktörler çarpma şeklinde de ifade edilebilir:

$$y(t) = T(t) \times S(t) \times C(t) \times I(t) \quad (1.2)$$

Zaman serileri temel olarak iki model üzerine kurulur. Bunlar Otoregresif (*AutoRegressive-AR*) model ve Hareketli Ortalama (*Moving Average-MA*) modelidir.

1. Otoregresif (*AutoRegressive-AR*) Model:

Bu model genel olarak $AR(p)$ şekilde ifade edilir. AR modelinde zaman serisi değişkeninin şimdiki değeri, değişkenin önceki değerlerinin doğrusal bir fonksiyonu ile sabit bir terimin toplamından elde edilir.

$$y_t = a_1 \times y_{(t-1)} + a_2 \times y_{(t-2)} \dots + a_p \times y_{(t-p)} + X \quad (1.3)$$

$AR(p)$ modeli formülüzasyonunda a değerleri, değişkenin şimdiki değerinin p zaman önceki değeri ile korelasyonunu ifade eder. X değeri ise sabit terimdir. Biyogaz üretim tahmini biyogazın geçmiş günlerdeki verileri kullanılarak yapıldığı için AR modeli kullanılmıştır.

2. Hareketli Ortalama (*Moving Average-MA*) Model

Bu model genel olarak $MA(q)$ şekilde ifade edilir. MA modelinde zaman serisi değişkeninin şimdiki değeri değişkenin gecikmeli hata teriminde etkilenir.

$$y_t = e_t + a_1 \times e_{(t-1)} + a_2 \times e_{(t-2)} \dots + a_p \times e_{(t-p)} \quad (1.4)$$

$MA(p)$ modeli formülüzasyonunda e değerleri p zaman önceki hata değerleri olup a değerleri ise değişkenin şimdiki değerinin p zaman önceki hata değeri ile korelasyonunu ifade eder.

Temel olarak bu iki modeli kullanan zaman serileri analizinde daha etkili ve daha kullanışlı olduğu için bu iki modelin birleştirilmesiyle *ARMA*, *ARIMA*, *SARIMA* gibi modeller türetilmiştir.

Lineer olmayan sistemler için gelecek değerlerinin tahmin edilebilmesi için zaman serileri analizinden olan Otoregresif (*AutoRegressive-AR*) model üç kategoride sınıflandırılmıştır. İlki harici giriş verisi ve hedef verisinin geçmiş değerlerinin kullanılarak hedef değeri üretilen *NARX* (*Nonlinear Autoregressive with External Input*) modeli; diğeri hedef verilerinin geçmiş değerleri bulunmadığı zaman kullanılan, sadece giriş verilerinin geçmiş değerlerinden hedef değerler üretilen *Nonlinear Input-Output*


modeli; üçüncüsü ise hedef değerlerinin geçmiş değerlerinin giriş olarak kullanılarak hedef değerler üreten *NAR (Nonlinear Autoregressive)* modelidir.

NAR modelinde kullanılan formül aşağıdaki gibidir:

d değeri y serisinin geçmiş değerleri olmak üzere;

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-d)) \quad (1.5)$$

Akış şeması ise Şekil 3.'te belirtildiği gibidir.



Şekil 2.1. *NAR* modelinin akış şeması

Yüksel'in yaptığı yüksek lisans tez çalışmasında internet ağı trafiği isabetli bir şekilde tahmin edilmeye çalışılmıştır. Tahmin yapılırken kullanılan modeller Çok Katmanlı Algılayıcı ve Zaman Serileri Analizi bir arada kullanılarak *MATLAB* programında yazılım geliştirilmesiyle elde edilmiş ve ağı eğitmek için *NAR* kullanılmıştır. Tahmin yapılırken kapalı çevrim ile *forecast* ve açık çevrim ile *predict* olmak üzere iki ayrı tahmin modeli kullanılmıştır. Eğitim fonksiyonu olarak *Scaled Conjugate Gradient* algoritması seçilmiştir. Oluşturulan tahmin modellerinin değerlendirilmesinde Ortalama Mutlak Hata Yüzdesi (*Mean Absolute Percentage Error, MAPE*) değerleri baz alınmıştır. Yapay sinir ağı yapısında gizli katman 1,2 ve 3 olarak seçilmiştir. Nöron sayısı birden ona kadar seçilmiştir. Gecikme zamanı ise kullanılacak modele göre birden 168'e kadar değişmiştir. Elde edilen sonuçlar incelendiğinde aynı şartlarda eğitilen yapay sinir ağlarından 1 gizli katmanlı ağın daha az ortalama mutlak hata yüzdesine sahip olduğu görülmüştür. Yapılan literatür taraması neticesinde gizli katman sayısı 1 olarak eğitilen ağların daha yüksek gizli katman sayısına göre başarılı olduğu çalışmalar göz önüne alınarak bu tez kapsamında da gizli katman sayısı 1 olarak alınmıştır.

Gümüş yaptığı akademik çalışmada yazılım tanımlı ağlarda tıkanıklık tahminini yapay sinir ağları ile yapmıştır. Yapay Sinir Ağı oluşturmak için *OMNET++* programı

kullanılmış olup ağı eğitim için *NARX*, *NAR* ve doğrusal olmayan ileri beslemeli model olmak üzere üç farklı eğitim metodu kullanılmıştır. Yapay Sinir Ağı eğitim fonksiyonu olarak hızlı hesaplanabilir ve kararlı olması sebebiyle *Levenberg–Marquardt* algoritması kullanılmıştır. Ağda kullanılacak veriler 0-1 aralığına indirgenmiştir. Oluşturulan tahmin modellerinin değerlendirilmesinde Ortalama Kare Hatası (*Mean-squared error, MSE*) değerleri baz alınmıştır. Gizli katman sayısı 1, 2, 5, 10 ve 15 alınmıştır. Gecikme zamanı ise 2 olarak seçilmiştir. Eğitilen ağların karşılaştırılması yapıldığında en iyi performansın *NARX* modeli ile elde edildiği, daha sonra *NAR* modeli ile elde edildiği, son olarak ise doğrusal olmayan ileri beslemeli model ile elde edildiği tespit edilmiştir. Gizli katman sayısı azaltılarak yüksek başarı elde edildiği sonucuna ulaşılmıştır.

Butekin Yaşar Üniversitesi kampüsünde bulunan Y Blok binasının kısa dönem yük tahminini Yapay Sinir Ağları kullanarak yapmıştır. Yapay Sinir Ağı oluşturmak için *MATLAB* programı kullanılmış olup ağı eğitim için kapalı çevrim ve açık çevrim *NARX* modelleri kullanılmıştır. Yapay Sinir Ağı eğitim fonksiyonu olarak *Levenberg–Marquardt* ve *Bayesian Regularization* algoritmaları kullanılmıştır. Ağda kullanılacak veriler 0-1 aralığına indirgenmiştir. Oluşturulan tahmin modellerinin değerlendirilmesinde Ortalama Kare Hatası (*Mean-squared error, MSE*) değerleri baz alınmıştır. Gizli katman sayısı 1 olarak seçilmiştir. Harici giriş gecikme zamanı 10 olarak, diğer giriş gecikme zamanı ise 2 olarak seçilmiştir. Nöron sayısı 10 ve 15 seçilmiştir. Oluşturulan ağların karşılaştırılması yapıldığında en iyi performansa sahip *Levenberg–Marquardt* algoritmasının 10 nörona sahip olduğu ve kapalı çevrim oluşturulduğu tespit edilmiştir. Giriş verisinin artırılmasıyla yapay sinir ağı performansının arttığı sonucuna ulaşılmıştır.

Karakaya yaptığı yüksek lisans tez çalışmasında Çürütücü Ünitesinden elde edilen biyogaz üretim tahminini Yapay Sinir Ağları ve *fuzzy logic* uygulamaları ile yapmış ve tahmin modelleri arasında karşılaştırma yapmıştır. Yapay Sinir Ağı oluşturmak için *MATLAB* programı kullanılmış ve 11 eğitim fonksiyonu algoritması ile de ağı eğitilmiştir. 11 eğitim fonksiyonunun karşılaştırılması neticesinde *Scaled Conjugate Gradient* algoritması seçilmiştir. Oluşturulan tahmin modellerinin değerlendirilmesinde Ortalama Kare Hatası (*Mean-squared error, MSE*) değerleri baz alınmıştır. Gizli katman sayısı 1 olarak seçilmiştir. Nöron sayısı ikiden başlayarak on beşe kadar sıralı

olarak seçilmiş, daha sonra 20, 25, 30 ve 35 olarak seçilmiştir. En iyi performansı veren nöron sayısı 14 olarak tespit edilmiştir. Oluşturulan yapay sinir ağlarının tahminleri sonucunda elde edilen en iyi performansa sahip yapay sinir ağının determinasyon katsayısı değeri 0,6496 olarak elde edilmiştir. Çalışma kapsamında biyogaz üretim tahmini için en iyi model 0,8765 determinasyon katsayısı değeri ile *fuzzy logic* olmuştur. Çoklu regresyon modeli ise 0,5665 determinasyon katsayısı değeri ile yapay sinir ağlarından sonra üçüncü olan tahmin modelidir.

Temizel yaptığı yüksek lisans tez çalışmasında yukarı akışlı havasız çamur reaktör sisteminden elde edilen biyogaz ve metan üretimlerini Yapay Sinir Ağları ile tahmin etmiş ve bu sonuçları *non-lineer regresyon* model sonuçları ile karşılaştırmıştır. Yapay Sinir Ağı oluşturmak için *MATLAB* programı kullanılmış ve 11 eğitim fonksiyonu algoritması ile de ağ eğitilmiştir. 11 eğitim fonksiyonunun karşılaştırılması neticesinde en iyi performansa sahip *Levenberg–Marquardt* ile *Scaled Conjugate Gradient* algoritmaları arasında yeniden regresyon analizi yapılarak *Scaled Conjugate Gradient* algoritması seçilmiştir. Oluşturulan tahmin modellerinin değerlendirilmesinde Ortalama Kare Hatası (*Mean-squared error, MSE*) değerleri baz alınmıştır. Gizli katman sayısı 1 olarak seçilmiştir. Nöron sayısı ikiden başlayarak on ikiye kadar sıralı olarak seçilmiş, daha sonra 15 olarak seçilmiştir. Biyogaz tahmininde en iyi performansı veren nöron sayısı 9 olarak tespit edilmiştir. 9 nöron ile oluşturulan yapay sinir ağının tahmini sonucunda elde edilen determinasyon katsayısı değeri 0,935 olmuştur. Yapay sinir ağlarından farklı olarak tahmin yapan *non-lineer regresyon* modelinde ise determinasyon katsayısı değeri 0,919 olmuştur. Tahmin sonuçları değerlendirildiğinde biyogaz üretim miktarı tahmininde yapay sinir ağlarının *non-lineer regresyon* modelinden çok daha iyi sonuçlar verdiği anlaşılmıştır.

Akkurt yaptığı akademik çalışmada İstanbul'un doğalgaz tüketimini tahmin etmeye çalışmıştır. Tahmin sistemi için zaman serileri analizini kullanmıştır. Üssel yumuşatma, *Winters'*, *Box-Jenkins*, *ARIMA*, *SARIMA* gibi metotları kullanılmıştır. Bu metotların içinde en iyi performansa sahip olan *Winters'* metodu olduğu tespit edilmiştir.

Oluşturulan yapay sinir ağlarının tahmin başarısını ölçen metotların biri de Ortalama Mutlak Hata Oranıdır (*Mean Absolute Percentage Error, MAPE*). Ortalama Mutlak Hata Oranı ile ilgili Dünya genelinde kesin kabul görmüş değerler olmamakla birlikte akademik çalışmalarda geçen genel olarak kabul gören değerler bulunmaktadır. Lewis

Ortalama Mutlak Hata Oranı %10 altında olan tahmin modellerini “çok iyi”, %10-%20 arasında kalan tahmin modellerini “iyi”, %20-%50 arası olan modelleri kabul edilebilir, %50 ve üzerinde olan tahmin modellerini ise “hatalı” olarak kategorize etmiştir. Benzer şekilde Witt ve Witt Ortalama Mutlak Hata Oranı %10 altında olan tahmin modellerini “yüksek doğruluk” dereceli olarak, %10-%20 arasında kalan tahmin modellerini “doğru” dereceli olarak kategorize etmiştir. Bu tez çalışması kapsamında da oluşturulan yapay sinir ağlarının yaptığı biyogaz üretim tahmin modellerinin Ortalama Mutlak Hata Oranı %10 olarak alınmıştır.



BÖLÜM III


KAYSERİ İLERİ BİYOLOJİK ATIK SU ARITMA TESİSİ

Yapımı 2002 yılında tamamlanarak devreye alınan Kayseri İleri Biyolojik Atık su Arıtma Tesisi (KİBAAT) 2018 yılı adrese dayalı nüfus sayımına göre 1.389.680 kişinin yaşadığı Kayseri ilinin yaklaşık %85'ine hizmet etmektedir. Kanalizasyon sistemi ile toplanan atık sular ve yağmur toplama sistemi ile toplanan yağmur suları cazibe yoluyla arıtma tesisine gelip burada Çevre ve Şehircilik Bakanlığının belirlediği deşarj standartlarında arıtılarak çevreye zarar vermeyecek şekilde alıcı ortama (Kızılırmak nehri) deşarj edilmektedir. Bu tesiste atık su arıtmak için kullanılan prosese uzun havalandırmalı aktif çamur sistemi denilmektedir. Çeşitli işlemlerden geçirilen atık suda bulunan günlük yaklaşık 18 ton kum, 7 ton ızgara atığı tesisin girişinde tutularak alıcı ortama deşarj edilmemektedir. Tesiste oluşan ham çamur belirli şartlar altında Çürütücü Sisteminde bekletilerek günlük 6.000 ile 8.000 m³ aralığında biyogaz elde edilmektedir. Üretilen bu biyogaz her biri 408 kW güce sahip iki adet Birleştirilmiş Isı ve Güç Ünitelerinde (CHP) yakılarak günlük 10 MW ile 12 MW aralığında elektrik enerjisi üretmekte, ayrıca biyogazın yanması sonucu 24 saat sıcak su elde edilip hem ısınma ihtiyacında hem de bireysel ihtiyaçlarda kullanılmaktadır. Tesisteki ünitelerde işlemlerden geçirilen atık sudan günlük yaklaşık 350 ton arıtma çamuru çıkmaktadır. Yüzde 18-20 seviyesinde susuzlaştırılmış olan bu çamur depolama tesislerinde depolanarak alıcı ortama deşarj edilmemekte, doğa korunmaktadır.




Şekil 3.1. Tesisten bir görünüm

KİBAAT genel hatlarıyla çamur yolu, atık su arıtma yolu ve SCADA kısımlarından oluşmaktadır. Atık su arıtma yolunda tesise giren atık su ilk kademe ızgaralardan geçirilerek yaklaşık olarak 12 metre yüksekliğe çıkarılır. Ardından ızgara binasında bulunan ızgaralar vasıtasıyla içinde bulunan tesise ve doğaya zarar verebilecek ızgara atıkları toplanır. Atık su kum ve yağ tutucu ünitesine yönlendirilerek burada muhteviyatında bulunan kum taneleri ve yağlardan arındırılır. Ön çökeltme tanklarında dinlendirilen atık su bakterilerin ilk yaşam alanı olan bio-fosfor tankına yönlendirilir. Buradan asıl arıtımın yapıldığı 8 adet havalandırma tankına cazibe yoluyla gönderilen atık su en son safhada son çökeltme tanklarında dinlendirilerek alıcı ortama deşarj edilir ve atık su yolu tamamlanmış olur. Çamur yolunda ise ön çökeltme tanklarından çekilen ham çamur ön çamur yoğunlaştırıcıda bekletilerek hedeflenen kuruluğa gelmesi sağlanır. Ardından çürütücü ünitesine gönderilen çamur burada belirli şartlar altında bekletilerek biyogaz üretilir. Çürütücü ünitesinden çıkan çamur son yoğunlaştırma tankında bekletilerek hedeflenen kuruluğa gelmesi sağlanır. Susuzlaştırma ünitesinde geri devir pompa istasyonundan gelen çamurla karıştırılır. Polielektrolit eklenerek belt filtrelere gönderilen çamur yüzde 18-20 kuruluğa getirilerek düzenli depolama tesislerinde çevreye zarar vermeyecek şekilde saklanır ve çamur yolu tamamlanmış olur.



Şekil 3.2. Akış şeması

SCADA kısmında tesiste bulunan bütün ekipmanlardan gelen sinyaller plc'ler vasıtasıyla bölgesel olarak 4 merkez istasyonda toplanır. Buradaki veriler ana sunucu olarak görev yapan bilgisayarlara aktarılıp tesis SCADA sistemi üzerinde izlenir ve yönlendirilir. Ayrıca 4 merkez istasyonda bulunan bilgisayarlar sayesinde, ünite operatörleri hem SCADA üzerinden hem de doğrudan müdahale ile tesisi yönetebilmektedir. Sunucuda depolanan bilgiler sayesinde kurulduğu günden günümüze kadar olan zamandaki bilgiler raporlama edilip geçmişe yönelik bilgilere erişilebilmektedir.



Şekil 3.3. SCADA sistemi tesis genel görünümü

3.1. Çürütücü Ünitesi

Yüksekliği 33 m, çapı 21 m olan çürütücü tankın dışı çürütme sürecine etki etmemesi için yalıtımlı olarak inşa edilmiştir. Tabanı çamurun yönlendirilebilmesi için 45° eğime sahip konik biçimindedir. Tavanı da tıpkı tabanı gibi çürütücü tankında üretilen gazın toplanabilmesi için 45° eğime sahip konik biçimindedir. Tankın toplam hacmi 6.750 m³ tür. Tankın içinin kontrol edilebilmesi için 1 adet zemin seviyesinde, 1 adet tankın üstünde olmak üzere 2 adet baca vardır. Çürütücü tankının ortasında bulunan ve zeminine kadar uzanan çamur karıştırıcısı sayesinde ideal bir karıştırma sağlanarak

çürütme işlemine katkıda bulunulur. Çürütme işlemi sırasında meydana gelen köpüğün giderilmesi için köpük söndürme sistemi vardır. İçindeki çamurun sıcaklığını ölçen 2 adet sıcaklık probu, çamurun seviyesini ölçen seviye sensörü, meydana gelen köpüğün varlığını denetleyen 2 adet kapasitif seviye sensörleri, içindeki çamurun asit baz dengesini ölçen PH metre cihazları ile donatılmıştır. Tankın kapasitesini aşmaması veya diğer meydana gelebilecek problemler için ham çamurun taşarak tankın belirli bir seviyesinde kalmasını sağlayan taşkın yapısı vardır.


Ön çamur yoğunlaştırıcıdan gönderilen ham çamur önce uygun sıcaklığa getirilmesi için ısı eşanjöründen geçirilir. Burada 40° ye kadar ısıtılan ham çamur ile çürütücü tankından gelen beklemiş çamur karıştırılarak çürütücü tankına basılır. Anaerobik fermentasyon sağlanması için hazırlanan uygun koşullarda 20 gün bekletilen çamur son çamur yoğunlaştırma tankına aktarılır. İşlem süresince çıkan süzöntü suyu giriş venturi kanalına gönderilir. Çürütücü tankında üretilen gaz ise önce filtrelerden geçirilerek her birinin hacmi 3.000 m³ olan 2 adet biyogaz depolama balonlarında depolanır. Daha sonra bu gaz her birinin elektrik enerji üretim kapasite 408 kW olan 2 adet Birleştirilmiş ısı ve güç (CHP) ünitelerinde yakılarak elektrik enerjisi elde edilir. Biyogazın CHP lerde yakılmasıyla aynı zamanda ısıda elde edilir. Bu ısı sıcak su için kullanılarak tesiste 24 saat sıcak su sağlanır ve kışın ısıtma olarak kullanılır. CHP ünitelerinde yakılamayan biyogaz miktarı gaz depolama balonlarında saklanabilecek miktarı geçtiğinde ise gaz yakma bacaları vasıtasıyla bertaraf edilir.



Şekil 3.4. Çürütücü tankı ve gaz depolama balonları (Atıksu arıtma dronla çekim, 2018)

3.2. Biyogaz Üretimi

Çürütücü tankta gerçekleşen ham çamurdan biyogaz elde edilmesi işlemi anaerobik fermantasyon sürecidir. Anaerobik fermantasyon süreci genel olarak asidojenik safha ve metanojenik safha olmak üzere 2 safha halinde düşünülse de hidroliz, asit üretimi, asetat üretimi ve metan üretimi olmak üzere 4 safhada gerçekleşir. Her bir safhada farklı türdeki mikroorganizmaların birinin bıraktığı yerden diğerinin devam etmesi sonucunda metan üretimi gerçekleşir.



Şekil 3.5. Anaerobik fermantasyon safhaları (Ekici K.,2018)

3.2.1. Hidroliz Safhası

Anaerobik fermentasyon sürecinin ilk safhası olan hidroliz safhasında vibrio, peptococcus gibi hidrolitik bakterilerin salgıladığı hücre dışı enzimler sayesinde kompleks partiküler maddeler düşük molekül ağırlıklı çözünen bileşiklere dönüştürülür. Bir başka deyişle proteinler aminoasitlere, karbonhidratlar çözünür mono veya disakkaritlere ve lipidler uzun zincirli yağ asitlerine ve/veya gliserine dönüştürülür (Zeki Ö.,2017). Anaerobik fermentasyon sürecinin en yavaş gerçekleşen aşamalarında biri olan hidroliz safhası hız sınırlayıcı safhalardan biridir. Hidroliz safhasın etkileyen en önemli faktörler ise pH, sıcaklık, hidroliz ara ürünlerinin ortamda birikmesi ve organik maddenin partikül boyut dağılımıdır (Balaban, 2009).

3.2.2. Asit Üretimi Safhası (Asidojeniz)

Hidroliz aşamasında oluşan çözünmüş bileşikler, asit üreten (fermantasyon) bakteriler tarafından hücre içine alınır ve asetat, propiyonat, bütirat, karbondioksit ve hidrojen gibi ara ürünlere (uçucu asitlere) dönüştürülür. Asidojenik safhada Clostridium, Bakteroides, Ruminococcus, Lactobacillus, Streptococcus, Presudomonas, Micrococcus, Bacillus ve Escherichia gibi farklı türlerde bakteri türü rol alır. Bu bakteri grubunun bazı türleri fakültatif anaerobtur ve ortama girebilecek serbest oksijeni tüketerek oksijene karşı hassas olan metanojenlerin korunmasına da yardımcı olurlar (Zeki Ö.,2017).

3.2.3. Asetat Üretimi Safhası (Asetojenez)

Anaerobik fermentasyon sürecinin bu safhasında ise asetat karbondioksit ve hidrojene dönüştürülür. Bu safhayı gerçekleştiren bakterilerden bazıları Acetobakterium, Pelobakter ve Butribakterium dur.

3.2.4. Metan Üretimi Safhası (Metanojeniz)

Anaerobik fermentasyon sürecinin bir diğer hız sınırlayıcı safhası metanojeniz safhasıdır. Metanojeniz safhası söz konusu olduğunda, çürütme işlemleri ve sonucunda gaz üretimi hızlı bir şekilde sıcaklık değişimlerine tepki gösterir. Özellikle metan üreten bakteriler daha uzun süren değişikliklere karşı oldukça duyarlı tepkiler göstermektedir. Sıcaklıktaki kısa süreli değişimler, başlangıçtaki sıcaklık çabucak geri kazanılıyorsa çürütmeyi o kadar fazla etkilemez. Esas olarak geniş miktardaki soğuk çamur kümelerinin sebep olduğu şok yükler, soğuk yuvaların olmasını

desteklemektedir. Böyle soğuk çamur kümeleri düzenli proses işleyişiyle ancak çok yavaş bir şekilde bütünleşebilmektedir.

Şimdilik hem yuvarlak hem de çubuk şekilli dört grup metanojenik bakteri bilinmektedir. Onların bulunduğu ortam sıcaklığı 33°C ile 38°C arasındadır. Bu mezofilik çürüme olarak bilinen ve genellikle 30°C ve 40°C arasında çalıştırılan bir sistemdir. Bu sistemde bakteriler CO₂ ve H₂ kullanımıyla metan oluştururlar.

Çürütücü içeriğinin yoğunluğu organizmaların ve besinlerin düzgün ve iyi dağılımına olanak vermelidir ancak zayıf olmamalıdır. Yaklaşık % 2 ile 3 kuru madde bakterinin yeterli büyüme yüzeyi sağlaması için gereklidir. Katı madde içeriği aynı zamanda faal bakteri kısmını da göstermektedir. Gün ışığı bakterilerin faaliyetlerini yavaşlatır ve eğer uzun sürerse gaz üretiminin azalmasına ya da durmasına sebep olur.

Bakterilerin pozitif gelişimi için pH'ı 7 ve 7.5 arasında değişen hafifçe alkali bir ortama gereksinin duyulmaktadır.

Ortamdaki hidrojen sülfid ve klor, bakterilere temel olarak zarar vermektedir. Organik asit oranı (asetik asit olarak hesaplanır) 500 ile 1000 mg/l arasında olmalıdır. Analitik belirleme her zaman aynı metodu izlemelidir. 2.000 mg'ı geçen asit oranı bakterilerin faaliyetini engeller ve önemli oranda gaz üretimini azaltır. Bakterinin hücre bölünmesi yoluyla çoğalması da aynı zamanda büyük oranda etkilenir.

Çizelge 3.1. Metan oluşum reaksiyonları (Zeki Ö.,2017)


Substrat	Reaksiyon	Kullanılabilir enerji ΔG° kJ/mol CH ₄
H ₂	$4H_2 + HCO_3^- + H^+ \rightarrow CH_4 + 3H_2O$	-135.6
Format	$4HCOO^- + H_2O + H^+ \rightarrow CH_4 + 3HCO_3^-$	130
Asetat	$CH_3COO^- + H_2O \rightarrow CH_4 + HCO_3^-$	-31
Metanol	$4CH_3OH \rightarrow 3CH_4 + HCO_3^- + H_2O$	-106.6

BÖLÜM IV

METODOLOJİ VE YÖNTEM

Bu tez çalışması kapsamında geçmiş günlerde üretilen gaz değerleri *MATLAB* programının zaman serileri analizlerinden biri olan *NAR* modelinde giriş verisi olarak kullanılarak yapay sinir ağları oluşturulmuş, bu ağlar vasıtasıyla *future based* kısa vadeli tahminler (*forecast*) yapılmış, elde edilen değerler gerçek verilerle karşılaştırılarak oluşturulan yapay sinir ağları test edilmiştir.

Tez çalışması kapsamında biyogaz üretim tahmini biyogazın geçmiş günlerdeki verileri kullanılarak yapıldığı ve biyogaz üretiminin lineer olmayan bir yapıya sahip olduğu için *NAR* modeli kullanılmıştır. *NAR* modelinin seçilmesindeki bir diğer etken ise Literatür bölümünde birkaçı anlatılan akademik çalışmalardan anlaşılacağı üzere zaman serileri analizinde *NAR* modelinin diğerlerine göre tahmin başarısının yüksek olmasıdır.



Şekil 4.1. *NAR* modelinin blok diyagramı

Şekil 4.1.'de blok diyagramı verilen *NAR* modeli 1 gizli katmanlı modeldir. Seçilecek gizli katman sayısına göre gizli katman bloğu artar. *D* ile gösterilen ifade gecikme (*delay*) değeridir. Seçilecek *D* değerine göre çıkış değerinin o kadar önceki değerleri giriş olarak sisteme verilir. *N* gizli katmanda bulunan nöron sayısıdır. Seçilecek nöron sayısına göre yapay sinir ağı eğitilir. Gizli katman bloğunda çalışmaya göre belirlenmiş aktivasyon fonksiyonu yer almaktadır. Bu blok diyagramında gizli katmanda bulunan aktivasyon fonksiyonu lineer fonksiyondur.

NAR modeli ile zaman serileri analizini uygulayabileceğimiz çok kullanılan tahmin yöntemlerinden biri olan ve bu tez çalışması kapsamında da kullanılan Yapay Sinir Ağları insan beyni çalışmasını taklit eder. Her zaman tıp biliminin ilgisini çeken insan

beyni mükemmel bir yapıda olup her geçen gün yeni bir özelliği keşfedilmektedir. İnsanların büyük bir kısmının bilgisi beynimizin kimyasal tepkimeler ve elektrik akımları ile çalışıyor olmasıdır. Doğru bir tespit olan bu işlemleri beynimizin, bilim adamları tarafından henüz kesinleştirilemese de 100 milyar sinir hücresi ile yaptığı tahmin edilmekte ve bu sayı insana göre değişebilmektedir. Beynin çalışması genel olarak 3 aşamadan oluşur:


1. Bilgi girişi,
2. Sentezleme ve karşılaştırma,
3. Bilgi çıkışı ve eylem.

4.1. Yapay Sinir Ağları

Tıpkı insan beyninde olduğu gibi bir yapay sinir ağı nöronu diğer nörondan sinyalleri alır, bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkarır. 1940’larda temeli atılan yapay sinir ağları asıl sıçramasını 1970’li yıllarda yapmış olup bilgisayarlarında gelişmesiyle birlikte günümüze kadar birçok aşama kaydetmiş ve *Artificial Bee Colony* isimli algoritma geliştiren Prof. Dr. Derviş Karaboğa gibi Türk bilim insanlarının da katkısıyla gelişmeye devam etmektedir.

4.1.1. Yapay Sinir Ağı Yapısı

Şekil 4.2.’de yapısı gösterilen yapay sinir ağı 5 bileşenden oluşur. Bunlar girdi değerleri, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkış değerleridir. Giriş değerlerinin her biri bir bağlantı ağırlığıyla çarpılır. Nöronlar giriş bilgilerini ağırlandırdıktan sonra doğrusal olarak toplar ve eşik bu bilgiyi doğrusal veya doğrusal olmayan bir fonksiyonda işleyerek çıktı bilgisine dönüştürür.



Şekil 4.2. Yapay sinir ağı yapısı (Keskenler ve Keskenler, 2017)

Girdi Değerleri: Yapay sinir ağına ilk gelen bilgilerdir. Şekil 1.2.'de $X_1, X_2, \dots, X_m$ ile gösterilen bu bilgiler dış ortamdan gelebilir, başka bir yapay sinir ağından gelebilir veya kendi yapay sinir ağından gelebilir. Tez çalışmasında kullanılan girdi değerleri biyogaz üretim değerlerinin geçmiş günlerdeki üretim miktarlarıdır.

Ağırlıklar: Beynimizdeki sinir hücrelerinde sinapslar hangi görevi yapıyorsa yapay sinir ağında da ağırlıklar aynı görevi yapar. Ağırlıklar girdi değerlerinin çıktı üzerindeki önemi ve etkisini belirleyen katsayılardır. Şekil 1.2.'de $W_1, W_2, \dots, W_m$ ile gösterilen ağırlıklar pozitif, sıfır veya negatif değerlerini alabilirler. Sıfır değerini aldığı zaman çıktıya bir etkisinin olmadığı anlaşılmaktadır. Pozitif veya negatif değer alması durumunda ise değerın büyüklüğüne göre çıktı üzerindeki etki dereceleri yüksek veya az olur.

Toplama Fonksiyonu: Beynimizdeki sinir hücrelerinde hücre gövdesinin yaptığı işi yapay sinir ağında toplama fonksiyonu yapar. Yapay sinir ağına gelen bilgilerin ağırlıklandırıldıktan sonra hepsinin toplanarak eşik değerinde eklenmesiyle ağa giren net bilgiyi hesaplar. Çarpım, toplam, minimum, maksimum gibi çeşitleri olan toplama fonksiyonunun en yaygın kullanılanı ağırlıklı toplam fonksiyondur.


$$net = \sum_{i=1}^m X_i \times W_i + b \quad (4.1)$$

Aktivasyon Fonksiyonu: Toplama fonksiyonunda elde edilen sinir ağına gelen net bilginin bazı fonksiyonlar yoluyla işlenerek mevcut girdi değerlerine karşı üretilecek

çıktıyı belirler. Çeşitli aktivasyon fonksiyonları mevcut olup bunlardan bazıları şu şekildedir:

Lineer Fonksiyon: Bu fonksiyonun formülü (4.2)'de verildiği gibidir. Tez çalışması sırasında biyogaz üretim miktarı değerleri yüksek olduğu için 0-1 aralığına indirgeme yapılmamış, tahmin edilen değerin direk olarak çıkış olarak yansıtıldığı lineer fonksiyon kullanılmıştır.


$$f(net) = net \quad (4.2)$$



Şekil 4.3. Lineer fonksiyonun grafiksel gösterimi

Sigmoid Fonksiyon: Bu fonksiyonun formülü (4.3)'de verildiği gibidir.


$$f(net) = \frac{1}{1+e^{-net}} \quad (4.3)$$



Şekil 4.4. Sigmoid fonksiyonun grafiksel gösterimi (Butekin, 2019)

Hiperbolik Tanjant Fonksiyon: Bu fonksiyonun formülü (4.4)'de verildiği gibidir.

$$f(net) = \frac{e^{net} + e^{-net}}{e^{net} - e^{-net}} \quad (4.4)$$




Şekil 4.5. Hiperbolik tanjant fonksiyonun grafiksel gösterimi (Butekin, 2019)

Çıktı Değerleri: Girdi değerlerinin aktivasyon fonksiyonundan geçirildikten sonra elde edilen değerlerdir. Aktivasyon fonksiyonu sonucunda bir çıktı olabileceği gibi birden fazla çıktı da olabilir.


4.1.2. Ağ Yapılarına Göre Yapay Sinir Ağı Modelleri

Yapay sinir ağının işlem akışına göre ikiye ayrılırlar. İlki ileri beslemeli yapay sinir ağıdır. Bu ağ yapısında işlemler ileri yönde ilerler. Bir girdi katmanı, en az bir gizli katman ve bir çıktı katmanından oluşur.



Şekil 4.6. İleri beslemeli yapay sinir ağı (Şahin, 2019)

İkinci ağ yapısı geri beslemeli yapay sinir ağıdır. Bu ağ yapısında giriş katmanı, gizli katman ve çıkış katmanı olduğunu varsayarsak çıkış katmanından gizli katmana veya gizli katmandan giriş katmanına bilgi aktırabilir. Böylelikle giriş katmanındaki değişikliklere ağ kendini hazırlamış olur. Bu ağlara aynı zamanda dinamik yapay sinir ağı da denilmektedir. Tez kapsamında oluşturulan yapay sinir ağı da geri beslemeli yapay sinir ağıdır.



Şekil 4.7. Geri beslemeli yapay sinir ağı (Şahin, 2019)

4.1.3. Yapay Sinir Ağlarının Öğrenme Şekilleri

Yapay sinir ağlarının en önemli özelliği öğrenebilmeleridir. Öğrenme stratejileri kullanan yapay sinir ağlarında öğrenme gerçekleştikten sonra iyi öğrenip öğrenemediği ağın bilmediği girdi değerleri kullanılarak ürettiği değer ile gerçek değerın kıyaslanması sonucu belirlenir. Her bir öğrenme işleminde ağırlık katsayıları değişir ve istenilen öğrenme gerçekleştirilmeye çalışılır. Öğrenme stratejisinden biri olan danışmansız (*unsupervised*) öğrenmede giriş değerleri ağa verilir fakat çıkış değerleri verilmez. Bu öğrenmenin başarılı olup olmadığı ürettiği çıkış ile gerçek çıkışın karşılaştırılması

sonucu elde edilir. Bu öğrenme stratejisinde ağırlıklandırma ağı tarafından kendi işlemlerine göre yapılır. Diğer öğrenme şekli olan danışmanlı (*supervised*) öğrenmede hem giriş değerleri hem de çıkış değerleri ağı verilir. Giriş verileri ile ağı öğrenme gerçekleştirir ve doğruluğunu test etmek için çıkış verileriyle karşılaştırır. Çıkış hedef değerlerine ulaşılan kadar öğrenme tekrarlanır. Her bir öğrenme safhasında giriş değerleri tekrar ağırlıklandırılarak çıkış hedef değerine ulaşılmaya çalışılır. Tez kapsamında biyogaz üretim değerlerinin geçmiş günlerdeki üretim miktarı değerleri giriş olarak, mevcut günlerdeki değeri ise çıkış değeri olarak verildiği için danışmanlı öğrenme gerçekleştirilmiştir. Danışmanlı öğrenme şekline benzer olan takviyeli (*reinforcement*) öğrenmede ise giriş değerler verilir, çıkış değerleri verilmez fakat öğrenme sonucunda üretilen değer doğruluğu konusunda bilgi verilir. Bu bilgileri kullanan takviyeli öğrenme stratejisi giriş değerlerini tekrar ağırlıklandırarak hedef çıkış değeri üretmeye çalışır.

Yapay sinir ağlarının tüm ağı modellerine göre özelliklerini aşağıdaki gibi sıralayabiliriz (Öztemel, 2012):

- Öğrenme işlemlerini örneklerle gerçekleştirirler.
- Kendi kendine öğrenebilme yetenekleri vardır.
- Makine öğrenmesi gerçekleştirirler.
- Çalıştırılmadan önce eğitilmeleri gerekmektedir.
- Bilgileri saklama özellikleri vardır.
- Hataya karşı duyarlıdırlar, eksik bilgilerle de çalışabilirler.
- Belirsiz bilgileri işleyebilirler.
- Algılama içeren olaylarda kullanılabilirler.
- Doğrusal değildirler.

Yapay sinir ağlarının avantajları ve dezavantajları kısaca özetlenecek olursa (Öztemel, 2012);

Avantajları

- Yapay sinir ağları makine öğrenmesi gerçekleştirebilirler. Olayları öğrenerek benzer olaylar karşısında mantıklı kararlar verebilirler.

- Bilgi işleme yöntemleri geleneksel programlamadan farklıdır. Bu nedenle geleneksel programlamanın getirdiği birçok olumsuzluk ortadan kaldırılabilir.
- Geleneksel programlamada olduğu gibi bilgiler veri tabanları ya da dosyalarda belli bir düzende tutulmayıp ağın tamamına yayılarak değerler ile ölçülen ağ bağlantılarında saklanmaktadır. Nöronlardan bazılarının işlevini yitirmesi anlamlı bilginin kaybolmasına neden olmaz.
- Yapay Sinir Ağlarının öğrenebilmesi için örneklerin belirlenmesi, bu örneklerin ağa gösterilerek istenen çıktılara göre ağın eğitilmesi gerekmektedir. Ağın başarısı, seçilen örnekler ile doğru orantılıdır, ağa olay bütün yönleri ile gösterilemezse ağ yanlış çıktılar üretebilir.
- Daha önce görülmemiş örnekler hakkında bilgi üretebilirler. Yapay Sinir Ağları eğitimleri sırasında kendilerine verilen örneklerden genellemeler çıkarırlar ve bu genellemeler ile yeni örnekler hakkında bilgi üretebilirler.
- Yapay Sinir Ağlarının en başarılı oldukları alanlar algılamaya yönelik uygulama alanlarıdır.
- Örüntü (*pattern*) ilişkilendirme ve sınıflandırma yapabilirler. Yapay Sinir Ağları kendilerine örnekler halinde verilen örüntüleri kendisi veya diğerleri ile ilişkilendirebilir. Ayrıca kendisine verilen örneklerin kümelenebilmesi ile bir sonraki verinin hangi kümeye dâhil olacağını karar verilmesi konusunda kullanılabilirler.
- Örüntü tamamlama yapabilirler. Ağa eksik bilgileri içeren örüntüler verildiğinde eksik bilgilerin tamamlanması konusunda başarılıdırlar.
- Kendi kendine öğrenebilme ve organize etme yetenekleri vardır.
- Eksik bilgi ile çalışabilirler. Geleneksel sistemlerin aksine Yapay Sinir Ağları eğitildikten sonra veriler eksik bilgi içerse dahi çıktı üretebilirler. Bu durum bir performans kaybına yol açmaz.
- Yapay Sinir Ağlarının eksik bilgilerle çalışabilmeleri ve bazı hücreleri bozulsa dahi çalışabilmeleri, onları hatalara karşı toleranslı yapar.
- Yapay Sinir Ağları tarafından üretilen bir ağ zaman içerisinde yavaş ve göreceli bir bozulmaya uğrar. Ağlar problemin ortaya çıktığı anda bozulmazlar.
- Yapay Sinir Ağlarında bilgi ağa dağıtılmış bir şekilde tutulur. Hücrelerin bağlantı ve ağırlık dereceleri, ağın bilgisini gösterir. Bu nedenle tek bir bağlantının kendi başına anlamı yoktur.

Dezavantajları

- Yapay Sinir Ağlarının en önemli sorunu donanım bağımlı olmalarıdır. Yapay Sinir Ağlarının en önemli özelliği olan paralel işlem yapabilme yeteneği, paralel çalışan işlemciler ile performans gösterir.
- Yapay Sinir Ağlarında probleme uygun ağ yapısının belirlenmesi için geliştirilmiş bir kural yoktur. Uygun ağ yapısı deneyim ve deneme yanılma yoluyla belirlenmektedir.
- Yapay Sinir Ağlarında öğrenme katsayısı, hücre sayısı, katman sayısı gibi parametrelerin belirlenmesinde belirli bir kural yoktur. Bu değerlerin belirlenmesi için belirli bir standart olmamakla birlikte her problem için farklı bir yaklaşım söz konusu olabilmektedir.
- Öğrenilecek problemin ağı gösterimi önemli bir problemdir. Yapay Sinir Ağları nümerik bilgilerle çalışabilmektedir. Problemler Yapay Sinir Ağlarına tanıtılmadan önce nümerik değerlere çevrilmek zorundadırlar. Burada belirlenecek gösterim mekanizması ağın performansını doğrudan etkileyeceği için kullanıcı buna dikkat etmek zorundadır.
- Ağın eğitiminin ne zaman bitirilmesi gerektiğine ilişkin belli bir yöntem yoktur. Ağın örnekler üzerindeki hatasının belirli bir değerin altına indirilmesi eğitimin tamamlandığı anlamına gelmektedir. Burada en uygun değer veren bir mekanizma henüz yoktur.
- Yapay Sinir Ağları bir probleme çözüm ürettiği zaman, bunun neden ve nasıl olduğuna ilişkin bir ipucu vermemesi Yapay Sinir Ağlarının en önemli sorunudur. Bu durum ağı olan güveni azaltıcı bir unsurdur.

Yapay sinir ağları ile yapılan birkaç örneği Literatür bölümünde de verilen akademik çalışmalara bakıldığı zaman eğitim metodu olarak *Levenberg–Marquardt* algoritmasının başarılı bir tahmin performansı sergilediği görülmektedir. Bu tez çalışması kapsamında da yapay sinir ağları oluşturulurken hızlı yapısı, az zaman harcaması, yüksek başarı performansı ve ani düşüş ve yükselişlere karşı kararlı bir yapıya sahip olan *Levenberg–Marquardt* algoritması kullanılmıştır.

4.2. Levenberg-Marquardt algoritması

Levenberg-Marquardt algoritması geri yayılım ile en küçük kareler metodunu kullanır. Algoritmanın amacı hesapladığı hata değerine göre nöron ağırlıklarını güncellemek ve

sonuç olarak en küçük hata değerini yakalamaktır. İleri beslemeli ağlarda en hızlı öğrenme metodu olduğu kabul edilmektedir. *Levenberg-Marquardt* algoritması Hessian matrisini hesaplamak zorunda kalmaması ile ikinci dereceden eğitim hızına yaklaşır. Performans fonksiyonunda Hessian matrisi formül (4.5)'te belirtildiği gibi hesaplanır.

$$H(t) = J^t(t) \times J(t) + \mu I \quad (4.5)$$

Formül (4.5)'te J Jacobien matrisini, t iterasyon sayısını, μ Marquardt parametresini, I ise birim matrisi ifade etmektedir. Formülde verilen Jacobien matrisi hata değerine göre oluşan ağırlıkların birinci türevlerinden oluşur.

$$J(t) = \partial e(t) \div \partial w(t-1) \quad (4.6)$$

Formül (4.6)'da e(t) ifadesi ağ hata vektörünü, w(t) ifadesi ağırlık matrisini belirtir.

Gradient hesabında ise formül (4.7) kullanılır.

$$g(t) = J^t(t) \times e(t) \quad (4.7)$$

Bu formüllerden yola çıkılarak oluşturulan algoritma ağırlıkları ise Formül (4.8)'de ifade edilmiştir.

$$w(t+1) = w(t) - [H(t)]^{-1} \times g(t) \quad (4.8)$$

Formül (4.5)'te verilen Marquardt parametresi (μ) büyük olduğunda gradient değeri küçük bir adım ile azalmaktadır. Buradaki amaç Newton metodu en az hata değerine doğru ve hızlı bir şekilde ulaşmayı hedeflediği için Newton metoduna hızlı bir şekilde geçiş yapabilmektir. Newton ve steepest descent algoritmalarından türetilerek güncelleştirilen *Levenberg-Marquardt* algoritması formül (4.9)'da verilmiştir.

$$\Delta w(t) = (J^t \times J + \mu I)^{-1} \times J^t \times e \quad (4.9)$$

Formül (4.9)'da verilen ifadelere bakacak olursak; w ağırlık vektörünü, J Jacobien matrisini ifade edip (PxM)xN boyutundadır, μ ayarlanabilen Marquardt parametresini, I birim matrisini, e hata vektörünü ifade edip (PxM)xI boyutundadır. N ağırlık sayısı, M çıkış sayısı, P ise eğitim örnek sayısıdır. Marquardt parametresi (μ) çok küçükse Newton metodu gibi, çok büyükse steepest descent metodu gibi davranır. Bu durum için bir formül uyarlanacak olursa formül (4.10) elde edilir.


$$\mu(n) = \begin{cases} \mu(n-1) \times k & E(n) > E(n-1) \\ \mu(n-1) \div k & E(n) \leq E(n-1) \end{cases} \quad (4.10)$$

Formül (4.10)'da belirtilen ifadelerden E uygunluk değerini ifade etmekte olup k ise sabit sayıdır.

Levenberg-Marquardt algoritmasının işlem aşamaları şu şekilde gerçekleşir. İlk önce nöron ağırlıklarının uygunluk değeri hesaplanır. İkinci aşamada Marquardt parametresi (μ) küçük bir değer seçilir. Üçüncü aşamada Marquardt parametresine (μ) bağlı formül ile yeni ağırlık vektörü oluşturulur ve uygunluk değeri hesaplanır. Dördüncü aşamada yeni hesaplanan uygunluk değeri bir önceki uygunluk değerinden büyükse Marquardt parametresi (μ) k sabit sayısı ile çarpılarak artırılır, küçükse Marquardt parametresi (μ) k sabit sayısına bölünerek azaltılır. Son aşamada ise nöron ağırlıkları Marquardt parametresine (μ) bağlı formül ile güncelleştirilir ve üçüncü aşamaya geri dönlür. Bu işlemler eğitilen ağda belirtilen parametreler yakalanana kadar devam eder.

4.3. Verilerin Elde Edilmesi

Kayseri İleri Biyolojik Atık Su Arıtma Tesisi 24 saat esasına göre çalışmakta olup sahada bulunan ekipmanlardan gelen bilgiler ilk kurulduğu günden bugüne kadar 1 tanesi ana sunucu, 1 tanesi yedek sunucu olmak üzere 2 tane sunucuda saklanmaktadır. Sunucularda saklanan bilgiler SCADA Raporlama Sistemi tarafından çekilerek *Microsoft Office* programlarından biri olan *Excel* programına aktarılmaktadır. Raporlama sisteminde çekilecek verilerin günlük, haftalık, aylık, yıllık olarak çekilebilme seçenekleri mevcuttur.



Şekil 4.8. SCADA raporlama sistemi ana ekranı

Bu tez çalışması kapsamında SCADA Raporlama Sisteminden en küçük ortak zaman gün olduğu için biyogaz üretimi verilerinin günlük değerleri çekilmiştir. SCADA Raporlama Sisteminden *Excel* programına debi miktarından hava sıcaklığına, UAKM değerinden havalandırıcı ünitesi basınçlarına, gaz depolama balonlarındaki biyogaz miktarından Birleştirilmiş Isı ve Güç Ünitelerinde üretilen elektrik enerjisine kadar günlük 194 farklı veri aktarılmaktadır.

1	2	A	FH	FI	FJ	FK	FL	FM	FN
1		04/2017							
2		Tanım		Enerji Üretimi				SUS	
3		tip	CHP Odası metan analizörü	CHP1	CHP2	Toplam CHP	Spesifik Enerji Üretimi	Katı Madde Konsantrasyonu	
4		P&I kodu	809.MQ.01					66.2.MQ.02	66.2.MF.11
5		birim	% LEL	kWh	kWh	kWh	kWh/ton	g/l	m²
6		kolon no	163	164	165	166	167	168	169
7	1		0	0	9.520	9.520	584	3,00	926,4
8	2		0	0	9.432	9.432	662	3,00	954,3
9	3		0	0	9.687	9.687	638	3,00	975,9
10	4		0	0	9.517	9.517	690	3,00	1.029,4
11	5		0	0	9.574	9.574	1.060	22,02	874,6
12	6		0	0	9.547	9.547	1.324	4,03	991,8
13	7		0	0	9.536	9.536	977	3,00	1.035,1
14	8		0	0	9.448	9.448	723	3,00	960,1
15	9		0	0	9.568	9.568	758	3,00	1.003,4
16	10		0	0	9.517	9.517	1.743	3,00	1.010,2
17	11		0	159	8.542	8.701	2.824	3,00	1.012,6
18	12		0	5.408	1.560	6.967	791	3,00	1.007,3
19	13		0	12	7.316	7.329	1.048	3,00	1.030,7
20	14		0	402	5.047	5.449	735	3,00	1.040,3
21	15		0	3.283	175	3.457	497	3,00	1.062,8
22	16		0	2.759	6.100	8.859	1.174	3,04	1.052,2
23	17		0	2.478	6.925	9.403	628	3,00	1.068,3
24	18		0	9.586	1.363	10.949	833	0,71	1.027,2
25	19		0	7.789	3.616	11.406	963	0,00	934,4
26	20		0	9.165	8.721	17.886	1.575	0,00	920,7
27	21		0	3.510	8.993	12.502	1.285	0,00	1.002,8
28	22		0	9.639	5.510	15.149	1.426	0,00	1.006,1
29	23		0	9.632	3.706	13.338	1.273	0,00	1.012,3
30	24		0	9.530	4.412	13.942	1.328	0,00	789,0
31	25		0	9.394	3.144	12.538	1.202	0,00	0,0
32	26		0	9.653	6.419	16.073	1.079	0,00	0,0
33	27		0	9.642	5.641	15.284	1.673	0,00	0,0
34	28		0	9.560	5.859	15.420	1.373	0,00	0,0
35	29		0	6.803	3.090	9.892	820	0,00	0,0
36	30		0	8.244	6.530	14.774	1.028	0,00	0,0

Şekil 4.9. 2017 yılının 4. ayına ait rapordaki 194 verinin bir kısmı

Çürütücü Ünitesinde üretilen biyogazın depolandığı gaz depolama balonlarının yapımı 2017 yılının Nisan ayında biterek devreye alındığı için bu ay itibariyle sunucuda değerler tutulmaktadır. Tez çalışması kapsamında 2017 yılının Nisan ayı 1. günü ile 2019 yılının Nisan ayı 11. günü arasındaki 741 günlük veriler her ay ayrı olacak şekilde SCADA Raporlama Sisteminden Excel programına aktarılmıştır.

4.3.1. Verilerin Eğitime Hazır Hale Getirilmesi

MATLAB programında eğitim gerçekleştirebilmek için ilk önce elimizde bulunan 24 ayrı Excel dosyasındaki 741 günlük verinin MATLAB programında bulunan Excel okuma komutu ile aktarımı gerçekleştirilmiştir. Bu tez çalışması kapsamında biyogaz üretiminin tahmini yapıldığı için biyogaz üretim miktarlarında kullanacağımız 1 nolu Gaz depolama balonu içindeki biyogaz miktarı, 2 nolu Gaz depolama balonu içindeki biyogaz miktarı ve birleştirilmiş ısı ve güç ünitesi biyogaz giriş debisi verileri toplam

194 farklı veri içinden kendi bulundukları sütun numaraları kullanılarak *MATLAB* programına aktarılmış ve ihtiyacımız olmayan veriler elenmiştir.

balon_1_seviye													
31x24 double													
1	12	13	14	15	16	17	18	19	20	21	22	23	24
1 47.3270	2.3876e+03	1.7856e+03	2.0359e+03	2.6163e+03	2.6207e+03	2.1706e+03	2.8456e+03	2.0186e+03	2.2006e+03	2.0066e+03	2.4601e+03	2.3408e+03	2.2476e+03
2 0	1.2581e+03	1.7650e+03	2.0928e+03	2.3740e+03	2.6660e+03	2.0818e+03	2.8159e+03	2.0408e+03	2.3979e+03	2.1957e+03	2.2493e+03	2.3061e+03	2.0635e+03
3 0	525.7278	2.0364e+03	1.8112e+03	2.1605e+03	2.6507e+03	2.0560e+03	2.6301e+03	2.3456e+03	2.2038e+03	2.2886e+03	2.6447e+03	2.5449e+03	2.4617e+03
4 17e+03	496.0989	1.5780e+03	1.9840e+03	2.0758e+03	2.6545e+03	2.0941e+03	2.7717e+03	2.3875e+03	2.6367e+03	2.3533e+03	2.7218e+03	2.4107e+03	2.6032e+03
5 59e+03	964.1777	1.3738e+03	2.2722e+03	2.4391e+03	2.6681e+03	2.0104e+03	2.7968e+03	2.3878e+03	2.5823e+03	2.0767e+03	2.3941e+03	2.4557e+03	2.4202e+03
6 0	2.5243e+03	1.6200e+03	2.4038e+03	2.0770e+03	2.6851e+03	1.8139e+03	2.6880e+03	2.4084e+03	2.5781e+03	2.0149e+03	2.5841e+03	2.4341e+03	2.5770e+03
7 0	3000	1.8660e+03	2.3134e+03	2.0241e+03	2.6918e+03	2.2095e+03	2.6941e+03	2.1943e+03	2.5485e+03	1.9587e+03	2.6234e+03	2.3942e+03	2.4045e+03
8 50e+03	1.9491e+03	1.9053e+03	2.2602e+03	2.5120e+03	2.6769e+03	2.2490e+03	2.6540e+03	1.7011e+03	1.9646e+03	1.8635e+03	2.5995e+03	2.4082e+03	2.4333e+03
9 42e+03	2.2864e+03	2.3745e+03	2.3820e+03	2.2068e+03	2.6645e+03	2.0500e+03	2.2040e+03	1.8023e+03	2.3652e+03	1.8749e+03	2.3387e+03	1.8179e+03	2.6182e+03
10 56e+03	2.4325e+03	2.2446e+03	0	2.1920e+03	2.6675e+03	2.0698e+03	2.1302e+03	1.8031e+03	2.4365e+03	2.0389e+03	2.5010e+03	2.5783e+03	2.6659e+03
11 36e+03	2.8255e+03	2.0411e+03	0	2.1274e+03	2.6753e+03	2.2947e+03	1.8112e+03	1.8046e+03	2.5601e+03	2.0988e+03	2.1544e+03	2.4795e+03	2.4669e+03
12 56e+03	2.6993e+03	1.5016e+03	1.3757e+03	0	2.1960e+03	2.2442e+03	2.3452e+03	1.7959e+03	2.2385e+03	2.4487e+03	2.5961e+03	2.6155e+03	0
13 55e+03	2.7543e+03	1.8596e+03	2.0377e+03	2.5827e+03	1.8595e+03	2.0437e+03	1.9002e+03	2.1405e+03	1.9862e+03	2.0976e+03	2.2910e+03	2.4826e+03	0
14 47e+03	2.7943e+03	1.6618e+03	2.1039e+03	2.3218e+03	1.6701e+03	2.1007e+03	2.3570e+03	2.0299e+03	2.1442e+03	1.8226e+03	2.6142e+03	2.3647e+03	1.4788e+03
15 04e+03	2.6166e+03	1.9469e+03	1.5567e+03	2.1981e+03	1.5889e+03	2.2043e+03	1.7689e+03	0	2.3108e+03	2.4015e+03	2.1845e+03	2.0874e+03	1.9762e+03
16 38e+03	2.0420e+03	2.1066e+03	2.0564e+03	2.5198e+03	1.5830e+03	2.1335e+03	2.2485e+03	0	2.5491e+03	2.0537e+03	2.3551e+03	2.3144e+03	2.6695e+03
17 30e+03	1.5623e+03	2.1233e+03	2.0060e+03	2.5399e+03	1.5286e+03	2.6396e+03	2.1634e+03	0	2.3798e+03	1.8626e+03	2.5365e+03	1.9089e+03	2.6402e+03
18 53e+03	1.8191e+03	2.2411e+03	2.1348e+03	2.5464e+03	1.7792e+03	2.1324e+03	1.8008e+03	0	2.1921e+03	2.2398e+03	2.2570e+03	1.8702e+03	2.6102e+03
19 79e+03	1.6243e+03	2.2234e+03	2.1736e+03	1.3280e+03	1.3488e+03	2.2761e+03	1.1006e+03	0	2.4155e+03	2.3065e+03	2.0965e+03	1.8483e+03	2.6154e+03
20 59e+03	1.8738e+03	1.8917e+03	2.2511e+03	2.0212e+03	2.0167e+03	2.1176e+03	2.0568e+03	0	1.9312e+03	2.3813e+03	2.0016e+03	2.1238e+03	2.4195e+03
21 42e+03	2.0229e+03	1.9399e+03	2.1965e+03	1.2029e+03	1.9415e+03	2.4037e+03	1.9386e+03	0	2.5065e+03	2.3281e+03	2.4566e+03	2.3831e+03	2.7137e+03
22 00e+03	1.7072e+03	2.4055e+03	2.3368e+03	1.4377e+03	2.0698e+03	2.0951e+03	2.0869e+03	0	2.5090e+03	1.8862e+03	2.4718e+03	2.5798e+03	2.7063e+03

Şekil 4.10. 1 nolu gaz depolama balonu verilerinin MATLAB'a aktarılmış ilk hali

Günlük üretilen biyogaz miktarı; o gün 1 nolu Gaz depolama balonu içindeki biyogaz miktarı ile 2 nolu Gaz depolama balonu içindeki biyogaz miktarı ve birleştirilmiş ısı ve güç ünitesine giren biyogaz miktarı toplamından, bir önceki günün 1 nolu Gaz depolama balonu içindeki biyogaz miktarı ile 2 nolu Gaz depolama balonu içindeki biyogaz miktarının toplamından çıkarılması suretiyle elde edilir.

$$\begin{aligned} \text{Mevcut Gün Biyogaz Miktarı} &= \text{Gaz Depolama Balonu 1} + \\ &\text{Gaz Depolama Balonu 2} + \text{Birleştirilmiş Isı ve Güç Ünitesi biyogaz giriş debisi} \\ (4.11) \end{aligned}$$

$$\begin{aligned} \text{Bir Önceki Gün Biyogaz Miktarı} &= \text{Gaz Depolama Balonu 1} + \\ &\text{Gaz Depolama Balonu 2} \end{aligned} \quad (4.12)$$

$$\begin{aligned} \text{Günlük Üretilen Biyogaz Miktarı} &= \text{Mevcut Gün Biyogaz Miktarı} - \\ &\text{Bir Önceki Gün Biyogaz Miktarı} \end{aligned} \quad (4.13)$$

günlük_uretilen_gaz																							
31x24 double																							
1	7	8	9	10	11	12	13	14	15	16	17	18	19										
1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	1.935e+03	6.7148e+03	6.5990e+03	6.0098e+03	4.6304e+03	9.9085e+03	6.3196e+03	6.8008e+03	1.0014e+04	7.6830e+03	6.8514e+03	5.2604e+03	5.4654e+03	0	0	0	0	0	0	0	0	0	0
3	9.296e+03	6.9102e+03	7.2399e+03	6.3550e+03	5.0806e+03	8.5744e+03	5.8407e+03	8.6838e+03	7.2729e+03	9.8323e+03	6.0053e+03	4.8512e+03	6.0758e+03	0	0	0	0	0	0	0	0	0	0
4	8.163e+03	5.7102e+03	5.7691e+03	7.1020e+03	7.0436e+03	7.7777e+03	5.3724e+03	8.7337e+03	6.3162e+03	8.7738e+03	6.3270e+03	5.3958e+03	7.2055e+03	0	0	0	0	0	0	0	0	0	0
5	3.317e+03	8.3822e+03	7.0201e+03	6.6685e+03	6.6371e+03	4.9925e+03	6.7041e+03	7.6728e+03	7.4260e+03	7.6682e+03	6.4980e+03	5.1619e+03	6.0348e+03	0	0	0	0	0	0	0	0	0	0
6	1.840e+03	7.0171e+03	7.4735e+03	6.5585e+03	-4.4498e+03	5.8754e+03	6.5435e+03	8.7096e+03	6.9075e+03	7.8564e+03	6.4486e+03	5.0328e+03	5.5555e+03	0	0	0	0	0	0	0	0	0	0
7	8.512e+03	5.7138e+03	5.9663e+03	6.4539e+03	0	5.2944e+03	6.7210e+03	1.0134e+04	6.3208e+03	7.8146e+03	6.1092e+03	5.1862e+03	6.9407e+03	0	0	0	0	0	0	0	0	0	0
8	3.851e+03	5.6668e+03	7.1492e+03	5.9370e+03	1.0347e+04	3.9608e+03	6.0720e+03	9.9556e+03	6.9478e+03	7.2440e+03	7.2681e+03	4.9917e+03	5.6892e+03	0	0	0	0	0	0	0	0	0	0
9	7.563e+03	7.3068e+03	6.8132e+03	6.1218e+03	6.2201e+03	5.0066e+03	7.1848e+03	8.3314e+03	1.1111e+04	6.2203e+03	7.7417e+03	6.5480e+03	7.3102e+03	0	0	0	0	0	0	0	0	0	0
10	7.959e+03	9.0560e+03	7.7718e+03	6.2559e+03	6.2152e+03	6.2043e+03	8.4408e+03	-4.5632e+03	8.8709e+03	7.6901e+03	6.3862e+03	4.0288e+03	6.9227e+03	0	0	0	0	0	0	0	0	0	0
11	3.064e+03	7.9060e+03	6.0244e+03	5.9015e+03	6.0930e+03	5.9316e+03	8.9494e+03	0	8.1353e+03	8.7181e+03	6.9084e+03	4.2002e+03	6.5454e+03	0	0	0	0	0	0	0	0	0	0
12	2.431e+03	8.0785e+03	8.3597e+03	6.4179e+03	6.3711e+03	8.2442e+03	5.9235e+03	1.1779e+04	-4.7544e+03	7.9237e+03	6.7562e+03	7.1937e+03	6.8074e+03	0	0	0	0	0	0	0	0	0	0
13	3.548e+03	7.0361e+03	7.1352e+03	5.6410e+03	6.4051e+03	1.0091e+04	9.0617e+03	7.7629e+03	1.2696e+04	7.7260e+03	5.8272e+03	5.5619e+03	6.3968e+03	0	0	0	0	0	0	0	0	0	0
14	9.838e+03	6.0636e+03	6.5258e+03	5.4214e+03	7.3390e+03	9.2287e+03	6.6617e+03	7.2496e+03	7.5894e+03	7.6268e+03	5.8266e+03	6.9176e+03	5.9011e+03	0	0	0	0	0	0	0	0	0	0
15	7.311e+03	7.9043e+03	7.2064e+03	4.8511e+03	6.2741e+03	9.0160e+03	8.1879e+03	6.9134e+03	7.0223e+03	7.7094e+03	5.3735e+03	8.1931e+03	-3.9844e+03	0	0	0	0	0	0	0	0	0	0
16	4.932e+03	6.3377e+03	6.5126e+03	7.2628e+03	6.9457e+03	6.7761e+03	7.2200e+03	6.1148e+03	8.8407e+03	7.7595e+03	8.1585e+03	5.9305e+03	0	0	0	0	0	0	0	0	0	0	0
17	2.183e+03	7.5715e+03	6.5361e+03	5.9340e+03	6.5855e+03	7.1691e+03	6.6805e+03	9.0056e+03	8.9317e+03	7.1967e+03	9.6304e+03	6.6364e+03	0	0	0	0	0	0	0	0	0	0	0
18	6.851e+03	6.8777e+03	5.9719e+03	5.7105e+03	6.6457e+03	7.9631e+03	7.8293e+03	7.7004e+03	8.3634e+03	6.5551e+03	8.4057e+03	6.2592e+03	0	0	0	0	0	0	0	0	0	0	0
19	4.939e+03	6.9911e+03	5.4474e+03	5.4518e+03	6.5971e+03	8.3798e+03	7.4376e+03	8.7416e+03	6.0368e+03	6.6928e+03	7.3127e+03	1.8613e+03	0	0	0	0	0	0	0	0	0	0	0
20	9.616e+03	6.8300e+03	6.7076e+03	5.9640e+03	8.1356e+03	7.8511e+03	8.1426e+03	8.6696e+03	6.3834e+03	6.8026e+03	6.7136e+03	4.7114e+03	0	0	0	0	0	0	0	0	0	0	0
21	4.846e+04	7.0178e+03	5.9216e+03	7.4185e+03	8.1542e+03	6.9798e+03	6.9884e+03	8.0519e+03	7.5302e+03	6.3417e+03	6.6277e+03	6.4533e+03	0	0	0	0	0	0	0	0	0	0	0
22	6.774e+03	3.3030e+03	4.9368e+03	7.0822e+03	8.7636e+03	6.3468e+03	5.6143e+03	7.7396e+03	7.0136e+03	7.0385e+03	7.4593e+03	4.9658e+03	0	0	0	0	0	0	0	0	0	0	0


Şekil 4.11. Günlük biyogaz üretim verileri

Formül (4.11), (4.12) ve (4.13) adımları uygulanarak elde edilip Şekil 4.11’de gösterilen 24 farklı sütunda bulunan günlük gaz üretim miktarları tek giriş olarak işlem görebilmesi için alt alta yazdırılmıştır.

tüm_günlük_uretilen_gaz			
744x1 double			
	1	2	3
634	6.3259e+03		
635	6.4840e+03		
636	6.1654e+03		
637	6.0015e+03		
638	6.1947e+03		
639	6.5427e+03		
640	6.8350e+03		
641	7.0682e+03		
642	6.6354e+03		
643	5.7465e+03		
644	5.9165e+03		
645	5.6241e+03		
646	5.7228e+03		
647	6.9179e+03		
648	6.6308e+03		
649	7.4109e+03		
650	7.1180e+03		
651	-4.1897e+03		
652	0		
653	5.3942e+03		


Şekil 4.12. Günlük biyogaz üretim verilerinin alt alta yazılmış hali

Şekil 4.12’de de görüleceği üzere bazı veriler negatif bazıları sıfır bazılarıysa günlük üretilebilecek biyogaz miktarının üzerinde çıkmaktadır. Verilerinin tamamını kullanmak mümkün olmadığı için gereksiz olan verilerin çıkarılması için günlük gaz üretim miktarlarının orta (*median*) değeri hesaplanmıştır. Hesaplanan orta (*median*) değeri 6.323 çıkmıştır. Her ne kadar tesis yapılırken biyogaz üretim miktarı 7.982 m³ olarak hesaplanmışsa da, geçen yıllar boyunca biyogaz üretim miktarı 9.500 m³ değerlerine çıktığı için orta (*median*) hata oranı % 50 seçilmiştir. Hata oranı yüzde % 50’nin altında veya üstünde olan güne denk gelen satırlar tespit edilmiş ve bu satırlar çıkarılmıştır. Böylelikle günlük üretilen gaz verileri *MATLAB* programında yapay sinir ağı oluşturmak için uygun hale getirilmiştir.



Şekil 4.13. Günlük biyogaz üretim verileri grafiği (gereksiz biyogaz üretim verileri dâhil)

1 Nisan 2017 tarihi ile 11 Nisan 2019 tarihi arasındaki 741 günlük biyogaz üretim verisi orta (*median*) işlemi uygulandıktan sonra elimizde 635 günlük yapay sinir ağlarına uygulanabilecek veri kalmıştır.



Şekil 4.14. Günlük biyogaz üretim verileri grafiği (gereksiz biyogaz üretim verileri çıkarılmış)

4.4. Veriler İle Ağ (Network) Oluşturulması

Eğitime hazır hale getirilen günlük biyogaz üretim verileri *NARNET*'te eğitime tabii tutulmadan önce *NARNET* bulunan bazı parametrelerin ayarlanması gerekmektedir. *NARNET*'in yapısına bakıldığı zaman belirleyebileceğimiz parametreler gizli katman (*hidden layer*) sayısı, gecikme (*delay*), nöron sayısı ve eğitim fonksiyonudur (*training function*). Bu parametrelerin belirlenmesi bir sonraki bölümde anlatılmıştır. Elimizdeki veriler kullanılarak *NARNET* modeliyle bu tez çalışmasındaki ağ oluşturulma aşamaları şu şekildedir:

İlk önce elimizde bulunan veri demetini ağ eğitime uygun hale getirmek için hücre (cell) şekline dönüştürülmüştür.

```
T = mat2cell((biyogaz(1:veri))',1,[ones(1,veri)])
```

Daha sonra nöron ve gecikme (*delay*) sayıları girilerek *NAR* modellenli ağ oluşturulmuştur.


```
net = narnet(1:D,N)
```

Zaman serisine sahip olan veriler ağ eğitime hazır hale getirilmiştir.

```
[Xs,Xi,Ai,Ts] = preparets(net,{}, {},T)
```

Daha önce oluşturulan *NAR* modellenli ağ eğitimi gerçekleştirilmiştir.

```
net = train(net,Xs,Ts,Xi,Ai)
```




Şekil 4.15. Örnek olarak oluşturulmuş 5 gecikme (*delay*), 6 nöronlu ağın blok diyagramı

Elde edilen ağ daha iyi tahmin sonuçları vermesi için kapalı çevrim (*closed loop*) ağa çevrilmiştir.

```
[Y,Xf,Af] = net(Xs,Xi,Ai)
```

```
[netc,Xic,Aic] = closeloop(net,Xf,Af)
```



Şekil 4.16. Örnek olarak oluşturulmuş 5 gecikme (delay), 6 nöronlu kapalı çevrim (closed loop) ağı blok diyagramı

Oluşturulan NAR modelli ağ kapalı çevrim (*closed loop*) ağ yapısı oluşturulduktan sonra istediğimiz sayıda gelecek tahmini yapılabilir.

```
y2 = netc(cell(0,tahmini_istenen_gun_sayisi),Xic,Aic)
```

Bu tez kapsamında y2 eşitliği ile eğitilen ağlara 7 günlük ve 14 günlük tahmin yaptırılmıştır. Ağı hata oranı formül 4.14'teki hesaplamaya göre belirlenmiştir.

$$\text{Hata Oranı} = (\text{Gerçek biyogaz üretim miktarı} - \text{Ağın tahmin ettiği biyogaz üretim miktarı}) \div \text{Gerçek biyogaz üretim miktarı} \quad (4.14)$$

7 ve 14 günlük tahmin yapıldıktan sonraki devam eden günlerde veri değerlerine yeni gelen 7 ve 14 günlük veriler eklenmiş, yeni veri setiyle ağ oluşturulurken izlenen adımlar izlenmiş ve ağlara yeni tahminler yaptırılmıştır. Böylelikle 7 günlük tahmin yapan ağlara birbirini izleyen 8 hafta, 14 günlük tahmin yapan ağlara ise birbirini izleyen 4 hafta biyogaz üretim tahmini yaptırılmıştır.

BÖLÜM V

BULGULAR

Bu tez çalışması kapsamında gizli katman (*hidden layer*) sayısı 1 olarak seçildiği sebepleriyle birlikte daha önceki bölümlerde açıklanmıştır. Yine eğitim fonksiyonu olarak *Levenberg-Marquardt* seçilmiştir ve seçilme sebebi hızı, kararlılığı ve benzer tahmin çalışmalarında gösterdiği başarı olduğu daha önceki bölümlerde de açıklanmıştır. *NAR* modeli ile ağlar (*network*) eğitilirken eğitim (*training*), doğrulama (*validation*) ve test (*testing*) verilerinin yüzde değerleri genel kabul gören değer olan 70-15-15 seçilmiştir ve bu orana göre veriler rastgele olarak ağ tarafından seçilmiştir.

Çizelge 5.1. YSA'ların eğitiminde kullanılan verilerin paylaşılması

	Eğitim (<i>training</i>) verisi	Doğrulama (<i>validation</i>) verisi	Test (<i>testing</i>) verisi	Toplam
Yüzde	%70	%15	%15	%100
Adet	445	95	95	635

Nöron sayısının aralığı belirlenirken hem *NAR* modeli ile yapılan tahmin çalışmaları incelenmiş hem de biyogaz üretim tahmini için yapılan çalışmalar incelenmiştir. Yapılan literatür taraması neticesinde nöron sayısının birden başlayarak belirli bir sayıya kadar sıralı olarak seçildiği, daha sonra atlamalı olarak seçildiği görülmüş olup bu rakam 35 nörona kadar çıkmıştır. Yapılan inceleme neticesinde başarılı olan nöron sayı aralığı 9-14 arasında olduğu tespit edilmiştir. Bu tez çalışması kapsamında ise nöron aralığı biraz daha genişletilmiş ve 5 nörondan başlayarak birer artırımlı olarak 50 nörona kadar *NAR* modelli ağ oluşturulmuştur.

Kullanılan nöron sayıları: 5, 6, 7, ..., 48, 49, 50.

Gecikme (*delay*) sayısı belirlenirken de nöron sayı aralığını belirlenirken olduğu gibi hem *NAR* modeli ile yapılan tahmin çalışmaları incelenmiş hem de biyogaz üretim tahmini için yapılan çalışmalar incelenmiştir. Yapılan literatür taraması neticesinde gecikme (*delay*) sayısı olarak 2'de alınmıştır, 168'de alınmıştır. Gecikme (*delay*) sayısı seçimi noktasında geçerli bir kabul olmayıp yapılan çalışmaya ve oluşturulan ağa göre

değişiklik göstermektedir. Bu tez çalışması kapsamında ise gecikme (*delay*) sayısı belirlenirken ne kadar az gecikme (*delay*) sayısı kullanılırsa o kadar az geçmiş veriye sahip olmamız gerektiğinden 1’den başlanılıp 70’e kadar sıralı olarak belirlenmiştir.

Kullanılan gecikme (delay) sayıları: 1, 2, 3, ..., 68, 69, 70.


Ağlar eğitilmeden önce NAR modeli için gerekli olan parametre aralıkları bu bölümün başında anlatıldığı gibi belirlenmiştir. Daha sonra NAR modeli ile ağlar eğitime başlanmıştır. Nöron ve gecikme (*delay*) sayılarının değişimi ile farklı birçok ağ eğitilmiştir. Bu eğitilen ağlardan 7 günlük tahmin yapabilecek şekilde eğitilenler için 7 günlük tahmin yapması istenmiş, 14 gün tahmin yapabilecek şekilde eğitilenler için 14 günlük tahmin yapması istenmiştir. Başarı kriteri olarak belirlenen %10 yüzdeliği burada devreye girmektedir. Eğitilen ağların tahmin ettiği biyogaz üretim tahmini gerçek değer %10 altında veya üstünde olduğu gün sayısı toplam gün sayısının %90 ve üzerinde ise bu ağ başarılı sayılmış ve devam eden günler için tekrar tahmin yaptırılmak üzere kaydedilmiştir. Başarılı olan ağları çizelge ile açıklayacak olursak;

Çizelge 5.2. Kaydedilen ağların gün bazında tahmin başarıları

Kaydedilen Ağ Türü	$\pm\%10$ 'a kadar hata yaptığı gün sayısı	$\%10$ 'dan fazla hata yaptığı gün sayısı
7 günlük tahmin için eğitilen ağlar	7	0
14 günlük tahmin için eğitilen ağlar	13	1

Başarılı olarak kaydedilen 14 günlük tahmin yapan 15 nöron 47 gecikmeli ağın eğitilme süreci şu şekilde gerçekleşmiştir.

İlk önce bir önceki bölümde veriler kodlar ile giriş verisi ağ eğitime uygun hale getirilmiş, daha sonra nöron sayısı 15 ve gecikme değeri 47 girilerek bir ağ oluşturulmuştur.



Şekil 5.1. 15 nöron 47 gecikme değerine sahip ağı blok diyagramı

Başarı kriterini geçmiş örnek ağlardan biri olan bu ağın veri girişleri rastgele seçilmiştir. Eğitim metodu daha önce de açıklandığı gibi *Levenberg-Marquardt* algoritmasıdır. Ağ eğitilirken performans değerlendirmesi Ortalama Kare Hatasıdır (*Mean-squared error, MSE*).

Algorithms

Data Division: Random (dividerand)
 Training: Levenberg-Marquardt (trainlm)
 Performance: Mean Squared Error (mse)
 Calculations: MEX


Şekil 5.2. 15 nöron 47 gecikme değerine sahip ağı algoritması

9 iterasyonda eğitimini sonlandıran ağ işlem bilgileri şu şekildedir:

Progress				
Epoch:	0	9 iterations	1000	
Time:		0:00:00		
Performance:	1.82e+07	9.78e-19	0.00	
Gradient:	6.87e+07	3.55e-06	1.00e-07	
Mu:	0.00100	0.00100	1.00e+10	
Validation Checks:	0	6	6	


Şekil 5.3. 15 nöron 47 gecikme değerine sahip ağı işlem bilgileri

Bu ağı sahip olduğu performans grafiği şu şekildedir:



Şekil 5.4. 15 nöron 47 gecikme değerine sahip ağın performansı


Bu ağın hata grafiği ise şu şekildedir:




Şekil 5.5. 15 nöron 47 gecikme değerine sahip ağın hata grafiği

Hata grafiğini incelediğimiz zaman çok büyük kısmının ± 700 bandında olduğu görülmektedir. Kayseri İleri Biyolojik Atık su Arıtma Tesisinde üretilen biyogaz miktarının da günlük 7.000-8.000 m³ hatta bazı zamanlar 9.500 m³ değerine çıktığı göz önüne alınırsa bu rakamın hata oranı olarak kabul edilen %10 bandı içinde kaldığı görülmektedir.


Başarılı olarak kaydedilen 15 nöron 47 gecikme değerine sahip ağı eğitimi sürecinde oluşan *regression* grafikleri şu şekildedir:




Şekil 5.6. 15 nöron 47 gecikme değerine sahip ağı eğitim grafiği



Şekil 5.7. 15 nöron 47 gecikme değerine sahip ağı doğrulama grafiği



Şekil 5.8. 15 nöron 47 gecikme değerine sahip ağın test grafiği



Şekil 5.9. 15 nöron 47 gecikme değerine sahip ağın genel grafiği

5-50 arası nöronlar ve 70 değerine kadar gecikme kombinasyonu ile oluşturulan birçok ağ içerisinde başarılı olan 7 günlük tahmin yapabilen toplam ağ sayısı 9, 14 günlük tahmin yapabilen toplam ağ sayısı 13 kaydedilmiş ve çizelge 5.3. ve çizelge 5.4'te gösterilmiştir.

Çizelge 5.3. 7 günlük tahmin yapan ağların nöron ve gecikme (*delay*) sayıları

7 Günlük Tahmin Yapan Ağlar	Nöron Sayısı	Gecikme (<i>delay</i>) Sayısı	Epoch Sayısı
1	5	59	12
2	5	62	15
3	8	36	11
4	9	28	20
5	12	66	10
6	16	23	11
7	25	40	13
8	34	60	7
9	39	64	6

Çizelge 5.4. 14 günlük tahmin yapan ağların nöron ve gecikme (*delay*) sayıları


14 Günlük Tahmin Yapan Ağlar	Nöron Sayısı	Gecikme (<i>delay</i>) Sayısı	Epoch Sayısı
1	8	66	11
2	9	29	13
3	11	25	15
4	15	47	15
5	15	23	18
6	25	8	16
7	26	40	8
8	28	6	10
9	31	20	18
10	34	13	19
11	37	19	15
12	46	6	8
13	48	7	10

Devam eden haftalarda, gerçekleştirilen eğitim sonucu kaydedilen başarılı ağlara kendi tahmin günleri bazında yani 7 günlük tahmin yapabilen ağlar için 7 günlük, 14 günlük tahmin yapabilen ağlar için 14 günlük tahmin yaptırılmış ve gerçek biyogaz üretim değeriyle karşılaştırılarak doğrulukları takip edilmiştir. Devam eden günlerde başarılı tahmin yapan ağlardan bazılarının karşılaştırmalı grafikleri Şekil 5.10, ..., Şekil 5.16 arası, başarısız tahmin yapan ağlardan bazılarının karşılaştırmalı grafikleri Şekil 5.17, Şekil 5.18 ve Şekil 5.19’da gösterilmiştir.

Çizelge 5.5. 7 günlük tahmin yapan 9 nöron 28 gecikmeli (*delay*) ağıın başarı durumu

Gün	Ağın Tahmin Ettiği Biyogaz Üretim Miktarı (m ³)	Gerçek Üretilen Biyogaz Üretim Miktarı (m ³)	Hata Oranı (%)
3 Mayıs	8.794	8.606	-2,19
4 Mayıs	8.421	8.957	5,99
5 Mayıs	8.639	8.463	-2,08
6 Mayıs	8.425	7.864	-7,14
7 Mayıs	8.955	9.076	1,33
8 Mayıs	8.213	8.671	5,28
9 Mayıs	8.729	9.781	10,75

Başarılı tahmin yapan 9 nöron ve 28 gecikmeli (*delay*) ağda, nöron sayısı nispeten az olmasına rağmen tam 4 haftalık yani 28 günlük geçmiş biyogaz üretim verilerinin kullanılması ağın biyogaz üretim yapısını çözüp başarılı tahmin yapmasını sağlamıştır.




Şekil 5.10. Ağın başarılı tahmin değeri ve gerçek değer grafiği

Çizelge 5.6. 7 günlük tahmin yapan 5 nöron 62 gecikmeli (*delay*) ağıın başarı durumu

Gün	Ağın Tahmin Ettiği Biyogaz Üretim Miktarı (m ³)	Gerçek Üretilen Biyogaz Üretim Miktarı (m ³)	Hata Oranı (%)
12 Nisan	7.764	8.306	6,53
13 Nisan	7.935	8.668	8,46
14 Nisan	7.954	8.132	2,19
15 Nisan	7.174	8.223	12,76
16 Nisan	7.634	7.941	3,87
17 Nisan	7.944	7.213	-10,13
18 Nisan	7.674	7.789	1,48

7 günlük tahminde başarılı olan 5 nöron ve 62 gecikmeli (*delay*) ağ nöron sayısının az olmasına rağmen neredeyse 9 haftalık yani 62 günlük geçmiş biyogaz üretim verilerinin kullanılması ağın biyogaz üretim yapısını öğrenmesini sağlamıştır.




Şekil 5.11. Ağın başarılı tahmin değeri ve gerçek değer grafiği

Çizelge 5.7. 7 günlük tahmin yapan 12 nöron 66 gecikmeli (*delay*) ağı'n başarı durumu

Gün	Ağın Tahmin Ettiği Biyogaz Üretim Miktarı (m ³)	Gerçek Üretilen Biyogaz Üretim Miktarı (m ³)	Hata Oranı (%)
24 Mayıs	7.367	7.205	-2,25
25 Mayıs	6.542	7.017	6,77
26 Mayıs	6.519	7.384	11,71
27 Mayıs	7.306	8.194	10,84
28 Mayıs	7.396	7.058	-4,79
29 Mayıs	7.206	7.748	6,99
30 Mayıs	7.286	8.042	9,40

7 günlük tahminde başarılı olan bir diğer ağ 12 nöron ve 66 gecikmeye (*delay*) sahiptir. Yeterli nöron sayısı ve 7 günlük tahmin için küçümsenmeyecek miktar olan 66 günlük geçmiş biyogaz üretim verileri ile eğitilmesi ağı başarılı yapmıştır.




Şekil 5.12. Ağın başarılı tahmin değeri ve gerçek değer grafiği

Çizelge 5.8. 14 günlük tahmin yapan 26 nöron 40 gecikmeli (*delay*) ağı'n başarı durumu

Gün	Ağın Tahmin Ettiği Biyogaz Üretim Miktarı (m ³)	Gerçek Üretilen Biyogaz Üretim Miktarı (m ³)	Hata Oranı (%)
10 Mayıs	8.114	10.112	19,76
11 Mayıs	7.860	7.565	-3,90
12 Mayıs	8.865	8.720	-1,66
13 Mayıs	8.546	7.415	-15,25
14 Mayıs	7.768	8.203	5,30
15 Mayıs	8.648	9.161	5,60
16 Mayıs	8.383	7.730	-8,45
17 Mayıs	7.805	7.882	0,98
18 Mayıs	6.011	7.045	14,68
19 Mayıs	6.911	7.061	2,13
20 Mayıs	8.400	6.960	-20,69
21 Mayıs	7.103	7.925	10,37
22 Mayıs	8.059	7.394	-8,99
23 Mayıs	8.191	7.675	-6,73

14 günlük tahminde başarılı olan 26 nöron ve 40 gecikmeli (*delay*) ağ göstermektedir ki yeterli nöron sayısı ve biyogaz üretim verilerinden yeterli sayıda geçmiş veri kullanılması ağın başarılı biyogaz üretim tahmini yapmasını sağlar.




Şekil 5.13. Ağın başarılı tahmin değeri ve gerçek değer grafiği

Çizelge 5.9. 14 günlük tahmin yapan 8 nöron 66 gecikmeli (*delay*) ağıın başarı durumu

Gün	Ağın Tahmin Ettiği Biyogaz Üretim Miktarı (m ³)	Gerçek Üretilen Biyogaz Üretim Miktarı (m ³)	Hata Oranı (%)
10 Mayıs	7.991	10.112	20,97
11 Mayıs	7.966	7.565	-5,30
12 Mayıs	7.991	8.720	8,36
13 Mayıs	7.121	7.415	3,97
14 Mayıs	7.656	8.203	6,66
15 Mayıs	7.203	9.161	21,37
16 Mayıs	7.203	7.730	6,82
17 Mayıs	7.203	7.882	8,62
18 Mayıs	7.369	7.045	-4,60
19 Mayıs	7.369	7.061	-4,36
20 Mayıs	7.369	6.960	-5,88
21 Mayıs	6.373	7.925	19,58
22 Mayıs	7.129	7.394	3,58
23 Mayıs	6.258	7.675	18,46

14 günlük tahminde başarılı olan 8 nöron ve 66 gecikmeli (*delay*) ağda nöron sayısı az olmasına rağmen 66 günlük geçmiş biyogaz üretim verilerinin kullanılması ağın biyogaz üretim yapısını öğrenmesini ve başarılı tahmin yapmasını sağlamıştır.




Şekil 5.14. Ağın başarılı tahmin değeri ve gerçek değer grafiği

Çizelge 5.10. 14 günlük tahmin yapan 31 nöron 20 gecikmeli (*delay*) ağıın başarı durumu

Gün	Ağın Tahmin Ettiği Biyogaz Üretim Miktarı (m ³)	Gerçek Üretilen Biyogaz Üretim Miktarı (m ³)	Hata Oranı (%)
10 Mayıs	9.006	10.112	10,93
11 Mayıs	7.338	7.565	3,01
12 Mayıs	8.585	8.720	1,55
13 Mayıs	8.103	7.415	-9,28
14 Mayıs	8.175	8.203	0,34
15 Mayıs	7.806	9.161	14,79
16 Mayıs	8.544	7.730	-10,52
17 Mayıs	7.829	7.882	0,67
18 Mayıs	7.388	7.045	-4,87
19 Mayıs	7.985	7.061	-13,09
20 Mayıs	6.861	6.960	1,43
21 Mayıs	7.255	7.925	8,46
22 Mayıs	7.462	7.394	-0,93
23 Mayıs	6.770	7.675	11,79

14 günlük tahminde başarılı olan bir diğer ağ 31 nöron ve 20 gecikmeye (*delay*) sahiptir. Nöron sayısının fazla olması, nispeten az sayılabilecek 20 günlük geçmiş biyogaz üretim verilerini dengelemiş ve ağ başarılı tahmin yapacak şekilde eğitilmiştir.




Şekil 5.15. Ağın başarılı tahmin değeri ve gerçek değer grafiği

Çizelge 5.11. 14 günlük tahmin yapan 48 nöron 7 gecikmeli (*delay*) ağı'n başarı durumu

Gün	Ağın Tahmin Ettiği Biyogaz Üretim Miktarı (m ³)	Gerçek Üretilen Biyogaz Üretim Miktarı (m ³)	Hata Oranı (%)
26 Nisan	8.502	8.138	-4,47
27 Nisan	8.612	7.523	-14,47
28 Nisan	8.833	8.220	-7,45
29 Nisan	7.936	8.409	5,62
30 Nisan	8.668	8.877	2,35
1 Mayıs	8.650	8.977	3,65
2 Mayıs	8.722	9.128	4,45
3 Mayıs	8.785	8.606	-2,07
4 Mayıs	9.072	8.957	-1,29
5 Mayıs	8.975	8.463	-6,05
6 Mayıs	9.353	7.864	-18,94
7 Mayıs	9.294	9.076	-2,40
8 Mayıs	9.183	8.671	-5,90
9 Mayıs	9.436	9.781	3,53

14 günlük tahminde başarılı olan 48 nöron ve 7 gecikmeye (*delay*) sahip ağın geçmiş biyogaz üretim verilerinden 7 günlük verilse bile çok fazla nöron ile eğitilmesi biyogaz üretim yapısını öğrenmesini ve başarılı tahmin yapmasını sağlamıştır.




Şekil 5.16. Ağın başarılı tahmin değeri ve gerçek değer grafiği

Çizelge 5.12. 7 günlük tahmin yapan 5 nöron 59 gecikmeli (*delay*) ağıın başarı durumu

Gün	Ağın Tahmin Ettiği Biyogaz Üretim Miktarı (m ³)	Gerçek Üretilen Biyogaz Üretim Miktarı (m ³)	Hata Oranı (%)
17 Mayıs	9.593	7.882	-21,70
18 Mayıs	8.554	7.045	-21,41
19 Mayıs	9.737	7.061	-37,90
20 Mayıs	10.152	6.960	-45,86
21 Mayıs	10.322	7.925	-30,24
22 Mayıs	10.675	7.394	-44,39
23 Mayıs	10.814	7.675	-40,90

7 günlük tahminde başarısız olan 5 nöron ve 59 gecikmeye (*delay*) sahip ağda nispeten yeterli olan 59 günlük geçmiş biyogaz üretim verileri nöron sayısı az olduğu için ağın biyogaz üretim yapısını öğrenmesinde yeterli olmamış ve sonuçta ağ başarısız olmuştur.




Şekil 5.17. Ağın başarısız tahmin değeri ve gerçek değer grafiği

Çizelge 5.13. 14 günlük tahmin yapan 25 nöron 8 gecikmeli (*delay*) ağı'n başarı durumu

Gün	Ağın Tahmin Ettiği Biyogaz Üretim Miktarı (m ³)	Gerçek Üretilen Biyogaz Üretim Miktarı (m ³)	Hata Oranı (%)
12 Nisan	8.843	8.306	-6,46
13 Nisan	8.805	8.668	-1,58
14 Nisan	8.960	8.132	-10,17
15 Nisan	9.146	8.223	-11,22
16 Nisan	9.735	7.941	-22,60
17 Nisan	9.407	7.213	-30,41
18 Nisan	9.772	7.789	-25,46
19 Nisan	9.764	7.339	-33,05
20 Nisan	9.508	9.098	-4,50
21 Nisan	9.385	8.840	-6,16
22 Nisan	9.366	8.941	-4,75
23 Nisan	8.624	9.199	6,24
24 Nisan	8.697	9.953	12,62
25 Nisan	8.583	7.614	-12,73

14 günlük tahminde 25 nöron ve 8 gecikmeye (*delay*) sahip ağ başarısız olmuştur. Tatmin edici bir değer olan 25 nöron ile eğitilen ağın 14 günlük tahmin yapması için 8 günlük geçmiş biyogaz üretim verilerini kullanması yeterli olmamış, başarısız olmuştur.




Şekil 5.18. Ağın başarısız tahmin değeri ve gerçek değer grafiği

Çizelge 5.14. 14 günlük tahmin yapan 9 nöron 29 gecikmeli (*delay*) ağı'n başarı durumu

Gün	Ağın Tahmin Ettiği Biyogaz Üretim Miktarı (m ³)	Gerçek Üretilen Biyogaz Üretim Miktarı (m ³)	Hata Oranı (%)
24 Mayıs	7.872	7.205	-9,25
25 Mayıs	7.030	7.017	-0,18
26 Mayıs	7.465	7.384	-1,10
27 Mayıs	6.602	8.194	19,43
28 Mayıs	7.418	7.058	-5,10
29 Mayıs	7.681	7.748	0,86
30 Mayıs	6.630	8.042	17,56
31 Mayıs	7.140	7.807	8,54
1 Haziran	7.015	7.808	10,16
2 Haziran	6.891	8.751	21,25
3 Haziran	7.410	8.299	10,72
4 Haziran	7.437	6.349	-17,14
5 Haziran	7.480	4.035	-85,38
6 Haziran	7.382	4.743	-55,63

14 günlük tahminde başarısız diğer bir ağ 9 nöron ve 29 gecikmeye (*delay*) sahiptir. Hem nöron sayısının az olması hem de geçmiş biyogaz üretim verilerinin yeterli miktarda olmaması bu ağı başarısız yapmıştır.



Şekil 5.19. Ağın başarısız tahmin değeri ve gerçek değer grafiği

BÖLÜM V

SONUÇLAR VE GELECEK ÇALIŞMALAR

Tez çalışması kapsamında Kayseri İleri Biyolojik Atık Su Arıtma Tesisinde bulunan Çürütücü ünitesinde üretilen biyogazın geçmiş günlerdeki üretim miktarı verileri kullanılarak gelecek günlerdeki üretim miktarı verileri başarılı bir şekilde tahmin edilmiştir. Daha önceki biyogaz üretim tahmin çalışmalarına kıyasla bu tez kapsamında nöron aralığı daha geniş seçilmiştir, nöron sayısı da buna bağlı olarak daha fazladır. Aynı şekilde gecikme sayısı da fazla seçilmiştir ve eğitilen ağ sayısı daha önceki çalışmalara bakarak daha çoktur. Eğitilen ağlar “çok iyi” dereceli başarı ölçütüne tabi tutularak ağların tahminlerinin daha isabetli olması hedeflenmiştir. Bir önceki ünite de örnek olarak verilen ağ sonuçlarından görüleceği üzere eğitilen ağlardan bazıları %90 üzeri bazıları %85 üzeri başarılı biyogaz üretim miktarı tahmininde bulunmuşlardır.

İlerde yapılacak çalışmalarda biyogaz üretim tahmini yapılırken mevsim gibi harici giriş kullanılıp *NARX* modeli ile yapay sinir ağları oluşturularak mevsimsel tahmin çalışmaları yapılması ile daha başarılı sonuçlar elde edilebilir.

Yine ileride yapılacak tahmin çalışmalarında biyogaz üretimini etkileyen faktörler ile mesela sıcaklık, uçucu katı madde, alkalinite gibi parametrelerin biyogaz üretim miktarı ile korelasyonu ile tahmin modelleri oluşturulması sonucu daha başarılı sonuçlar elde edilebilir.

KAYNAKLAR

Akkurt, M., Zaman Serileri Metotlarıyla Doğalgaz Tüketiminin Tahmini, Yüksek Lisans Tezi, *Fatih Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 2009

“Atıksu arıtma dronla çekim”, *Kayseri Su ve Kanalizasyon İdaresi Genel Müdürlüğü*, hakkib\D:\ELEKTRİK\ Atıksu arıtma dronla çekim.mp4, 2018.

Balaban, Ü., Yemekhane Atıklarının Anaerobik Arıtma Kinetiği, Yüksek Lisans Tezi, *İ.T.Ü. Fen Bilimleri Enstitüsü*, İstanbul, 2009

Butekin, T.Ç., Yapay Sinir Ağları Kullanılarak Yaşar Üniversitesi Yük Tahmini, Yüksek Lisans Tezi, *Yaşar Üniversitesi Fen ve Doğa Bilimleri Enstitüsü*, İzmir, 2019

Çuhadar, M. ve Kayacan C., “Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye’deki Konaklama İşletmeleri Üzerine Bir Deneme”, *Anatolia:Turizm Araştırmaları Dergisi*, cilt 16, sayı 1, s. 29, 2005.

Ekici, K., Kentsel Atık su Arıtma Tesisi Anaerobik Çamur Çürütücülerinin Dinamik Proses Modelleme Yaklaşımı ile Analizi, *İ.T.Ü. Fen Bilimleri Enstitüsü*, İstanbul, s. 6-29, 2018.

Gümüş, F., Yazılım Tanımlı Ağlarda Makine Öğrenme Algoritmaları ile Tıkanıklık Kontrolü, Yüksek Lisans Tezi, *İstanbul Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 2016

Karakaya, K., Yapay Zekâ Modelleriyle Tam Ölçekli Çamur Çürütme Reaktörlerinden Elde Edilen Biyogaz Üretiminin Tahmini: Yapay Yapay Sinir Ağları ve Fuzzy Logic Uygulamaları, Yüksek Lisans Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 2012.

Keskenler, E.F. ve Keskenler M.F., “Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi”, *Takvim-i Vekayi*, cilt 5, sayı 2, s. 8-18, 2017.

Öztemel, E., Yapay Sinir Ağları, *Papatya Yayıncılık*, İstanbul, Ankara, İzmir ve Adana, 2012.

Şahin, M., Sivas İlinin Güneş Işınım Şiddeti ve Rüzgar Hızının Yapay Sinir Ağları ile Tahmin Edilmesi, Yüksek Lisans Tezi, **Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü**, Sivas, 2019

Temizel, İ., Melas Metan Atık Üretimlerinin Sularının Arıtımında Yukarı Akışlı Havasız Çamur Yapay Sinir Ağları İle Modellenmesi Yataklı Reaktör (Yahçyr) Sisteminden Elde Edilen Biyogaz ve Metan Üretimlerinin Yapay Sinir Ağları İle Modellenmesi, Yüksek Lisans Tezi, **Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü**, İstanbul, 2012

Yüksel, M.C., Zaman Serili Çok Katmanlı Algılayıcı ve Zaman Gecikmeleri Kullanılarak Ağ Trafik Tahmini için Yeni Bir Yazılımın Geliştirilmesi, Yüksek Lisans Tezi, **Çukurova Üniversitesi Fen Bilimleri Enstitüsü**, Adana, 2019.

Zeki Ö., Evsel Atıksu Arıtma Tesislerinde Anaerobik Çürütücülerden Çıkan Atık Anaerobik Çamurun İleri Arıtımı ve Değerlendirme Seçenekleri, Doktora Tezi, **Çukurova Üniversitesi Fen Bilimleri Enstitüsü**, Adana, s. 13-21, 2017.

ÖZGEÇMİŞ

Nazım ÖZİNCE 19.05.1986 yılında Kayseri’de doğdu. İlk, orta ve lise eğitimini Kayseri’de bulunan okullarda tamamladı. Lisans eğitimine Atatürk Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği bölümünde başlayıp yatay geçişle geldiği Erciyes Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği bölümünde 2009 yılında lisans eğitimini tamamladı. 2009-2010 yılları arası askerliğini asteğmen olarak tamamladı. 2010 Aralık ayı ile 2012 Şubat ayları arası yapımını YDA Group’un üstlendiği Forum Kayseri şantiyesinde Elektrik Şefi olarak çalıştı. 2012 Aralık ayında Niğde Çevre ve Şehircilik Müdürlüğüne atandı ve Kontrol Mühendisi olarak çalıştı. 2017 yılından itibaren Kayseri Büyükşehir Belediyesi Su ve Kanalizasyon İdaresi Atıksu Arıtma Daire Başkanlığında Elektrik Bakım Onarım Sorumlusu olarak çalışmaktadır. Evli ve 2 çocuk babası olup İngilizce bilmektedir.

