

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

**YÜKSEK LİSANS TEZİ**

**ASİDİK MADEN SIZINTI SULARINI (AMS) ARITAN AKIŞKAN YATAKLI  
REAKTÖR PERFORMANSLARININ YAPAY SİNİR AĞLARI (YSA) İLE  
MODELENMESİ**

**Belgin BABAR**

**ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI**

**ŞANLIURFA  
2011**



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

**YÜKSEK LİSANS TEZİ**

**ASİDİK MADEN SIZINTI SULARINI (AMS) ARITAN AKIŞKAN YATAKLI  
REAKTÖR PERFORMANSLARININ YAPAY SİNİR AĞLARI (YSA) İLE  
MODELLENMESİ**

**Belgin BABAR**

**ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI**

**ŞANLIURFA  
2011**

Yrd. Doç. Dr. Dilek ATASOY danışmanlığında, Belgin BABAR'ın hazırladığı "Asidik Maden Sızıntı Sularını (AMS) Arıtan Akışkan Yataklı Reaktör Performanslarının Yapay Sinir Ağları (YSA) İle Modellenmesi" konulu bu çalışma 03/02/2011 tarihinde aşağıdaki jüri tarafından Çevre Mühendisliği Anabilim Dalı'nda Yüksek Lisans tezi olarak kabul edilmiştir.

Danışman: Yrd. Doç. Dr. Dilek ATASOY

Üye : Doç. Dr. Erkan ŞAHINKAYA

Üye : Doç. Dr. Ahmet KILIÇ

**Bu tezin Çevre Mühendisliği Anabilim Dalında Yapıldığını ve Enstitümüz Kurallarına Göre Düzenlendiğini Onaylarım.**



**Bu Çalışma HÜBAK ve TÜBİTAK Tarafından Desteklenmiştir.  
Proje No: 108Y036**

**Not:** Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, Şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5486 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

## İÇİNDEKİLER

	Sayfa No
ÖZ	i
ABSTRACT	ii
TEŞEKKÜR	iii
ŞEKİLLER DİZİNİ	iv
ÇİZELGELER DİZİNİ	viii
SİMGELER DİZİNİ	ix
1. GİRİŞ	1
1.1. Yapay Sinir Ağlarının (YSA) Tanıtılması	3
1.2. Asidik Maden Sızıntı Sularının Arıtımı	8
1.2.1. Aktif arıtma	8
1.2.2. Pasif arıtma	9
1.3. Akışkan Yataklı Reaktörler ve AMS Arıtımı	11
2. ÖNCEKİ ÇALIŞMALAR	15
2.1. İstanbul ili Ozon Konsantrasyonlarının Yapay Sinir Ağları İle Tahmini	15
2.2. Adapazarı Kentsel Atıksu Arıtma Tesisi Çıkış Suyu Parametreleri ve Verim Değerlerinin Yapay Sinir Ağları ile Tahmini	17
2.3. Denizli (Merkez) Atıksu Arıtma Tesisi Performansının Yapay Sinir Ağları Kullanılarak Modellenmesi	18
2.4. Harran Ovasında Yer Altı Sularında Nitratın Yapay Sinir Ağları İle Tahmini	19
2.5. Çinko İçeren Atıksuların Tam Karışımlı Sülfidojenik Tank Reaktörde (CSTR) Arıtım Performansının YSA ile Modellenmesi	20
3. MATERYAL VE YÖNTEM	24
3.1. Sülfidojenik Yukarı Akışlı Akışkan Yataklı Reaktör (R1)	24
3.2. Sülfidojenik Aşağı Akışlı Akışkan Yataklı Reaktör (R2)	27
3.3. Sülfidojenik Aşağı Akışlı Akışkan Yataklı Reaktör (R3)	28
3.4. Çalışmada Kullanılan YSA'nın Yapısının Belirlenmesi	31
3.5. YSA Giriş ve Çıkış Parametrelerinin Seçilmesi	32
3.6. Backpropagation Algoritmasının Seçilmesi	32
3.7. En İyi Nöron Sayısının Seçilmesi	33
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	34
4.1. Yukarı Akışlı Akışkan Yataklı Reaktör ( R1) Çıkış Değerlerinin YSA İle Tahmin Edilmesi	34
4.1.1. Çıkış sülfat değerlerinin tahmin edilmesi	38
4.1.2. Çıkış KOİ değerlerinin tahmin edilmesi	43
4.1.3. Çıkış alkalinite değerlerinin tahmin edilmesi	47
4.1.4. Çıkış sülfür değerlerinin tahmin edilmesi	51
4.2. Aşağı Akışlı Akışkan Yataklı Reaktör ( R2) Çıkış Değerlerinin YSA İle Tahmin Edilmesi	55
4.2.1. Çıkış sülfat değerlerinin tahmin edilmesi	60
4.2.2. Çıkış KOİ değerlerinin tahmin edilmesi	64
4.2.3. Çıkış alkalinite değerlerinin tahmin edilmesi	68

4.2.4. Çıkış sülfür değerlerinin tahmin edilmesi	72
4.3. Aşağı Akışlı Akışkan Yataklı Reaktör ( R3) Çıkış Değerlerinin YSA İle Tahmin Edilmesi	77
4.3.1. Çıkış sülfat değerlerinin tahmin edilmesi	82
4.3.2. Çıkış KOİ değerlerinin tahmin edilmesi	86
4.3.3. Çıkış alkalinite değerlerinin tahmin edilmesi	90
4.3.4. Çıkış sülfür değerlerinin tahmin edilmesi	94
5. SONUÇLAR ve ÖNERİLER	99
KAYNAKLAR	103
ÖZGEÇMİŞ	105
ÖZET	106
SUMMARY	108

## ÖZ

### Yüksek Lisans Tezi

## ASİDİK MADEN SIZINTI SULARINI (AMS) ARITAN AKIŞKAN YATAKLI REAKTÖR PERFORMANSLARININ YAPAY SİNİR AĞLARI (YSA) İLE MODELLENMESİ

Belgin BABAR

Harran Üniversitesi  
Fen Bilimleri Enstitüsü  
Çevre Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. Dilek ATASOY

Yıl: 2011, Sayfa: 118

Bu çalışmada, Asidik Maden Sızıntı Sularının arıtımında, akışkan yataklı reaktör performanslarının yapay sinir ağları ile modellenmesi amaçlanmaktadır. Bu kapsamda, TÜBİTAK desteği ile yürütülen bir proje ile işletilen yukarı ve aşağı akışlı akışkan yataklı reaktörlerden alınan belirli giriş ve çıkış atıksu verileri kullanılmıştır. Yapay sinir Ağları esasına göre çalışan Matlab 7.6 Bilgisayar programı aracılığı ile modellemeler yapılmış ve reaktör performanslarının tahmin edilmesine çalışılmıştır. Bu çalışmada, AMS arıtan akışkan yataklı reaktörler için “işletim süresi, giriş pH, çıkış pH, giriş sülfat, giriş kimyasal oksijen ihtiyacı (KOİ) ve giriş metal” olmak üzere toplam 6 input parametresini kullanarak; “çıkış sülfat, çıkış KOİ, çıkış alkalinite ve çıkış sülfür” konsantrasyonlarının YSA ile tahmini yapılmıştır. Bu amaçla, 2 senaryo üzerinde çalışılmıştır. İlkinde çıkış pH değeri input parametreleri içerisinde yer alırken (Senaryo-1); ikinci senaryoda (Senaryo-2) çıkış pH değeri input parametreleri arasından çıkarılarak YSA ile reaktör performansının modellenmesi araştırılmıştır. Senaryo-2 ile, AMS arıtımı amaçlı kullanılacak olan bir reaktör henüz kurulmadan performansının tahmin edilmesi hedeflenmiştir. YSA ile akışkan yataklı reaktör performansının modellenmesi çalışmasında; işletim süresi giriş parametreleri arasında yer almıştır. Bunun nedeni ise, reaktör işletimi süresince bakteriyel komünitenin değişmesi ve böylece yeni işletim şartlarına adapte olmasıdır. Dolayısıyla, işletim süresinin giriş parametreleri arasına alınmasıyla, aklımasyon ve kültür farklılıklarından doğan değişimlerin de modellemeye dahil edilebileceği düşünülmüştür.

**ANAHTAR KELİMELER:** Asidik maden sızıntı suları, sülfat indirgeyen bakteriler, akışkan yataklı reaktör, yapay sinir ağları, modelleme

## **ABSTRACT**

**MSs Thesis**

### **ARTIFICIAL NEURAL NETWORK (ANN) MODELING OF THE PERFORMANCE OF FLUIDIZED BED REACTOR IN THE TREATMENT OF THE ACIDIC MINE DRAINAGE WATER (AMD)**

**Belgin BABAR**

**Harran University  
Graduate School of Natural and Applied Sciences  
Department of Environmental Engineering**

**Supervisor: Assist. Prof. Dr. Dilek ATASOY  
Year: 2011, Page: 118**

The aim of the study is the Artificial Neural Network Modeling of the fluidized bed reactor (FBR) performance for the treatment of acidic mine drainage (AMD) water. The parameters of influent and effluent wastewater from upflow and downflow fluidized bed reactors which were operating with TÜBİTAK project were used for input and output data. The artificial neural network models for the reactor performance were done with Matlab 7.6 computer program. Operating time, influent pH, effluent pH, influent sulfate, influent COD and influent metal were used as input data. Sulfate, COD, alkalinity and sulphur concentrations in the effluent were predicted by ANN. For this purpose, two scenarios were worked on to modeling of the reactor performances: The effluent pH was participated in the input parameters for the first scenario while the effluent pH was removed from the input parameters for the second scenario. The determination of a non-constructed reactor performance was analysed in the second scenario. The operating time was incorporated to the input parameters in ANN modeling of FBR. This is because, the bacterial community changed during the operating period and adapted to the new operating conditions. Therefore, it was thought that the variation from the acclimation and culture diversity can be regarded in the ANN modeling with the incorporation of the operating time to input parameters.

**KEY WORDS:** Acidic mine drainage, sulfate reducing bacteria, fluidized bed reactor, artificial neural network, modeling.



## TEŐEKKÜR

Tez alıőmam sűresince bilgi, deneyim, emek ve yardımlarını esirgemeyen danıőman hocam Sayın Yrd. Do. Dr. Dilek ATASOY'a, tez alıőmam sűresince bilgilerinden ok fazla yararlandıėım Do. Dr. Erkan ŐAHİNKAYA, Öğr. Gör. M. İsmail GŪRSOY' a ve hayatım boyunca benden maddi manevi yardımlarını esirgemeyen aileme teőekkűrű bir bor bilirim.

Ayrıca alıőmaya maddi desteklerinden dolayı Harran Ūniversitesi'ne ve TŪBİTAK'a teőekkűrlerimi sunarım.

## ŞEKİLLER DİZİNİ

	<b>Sayfa No</b>	
Şekil 1.1	Yapay Sinir Ağı Modeli	7
Şekil 1.2.	Tek kademeli sülfat indirgeme ve metal çöktürme (a) geri devirsiz, (b) geri devirli	12
Şekil 1.3.	Sülfat indirgeme ve metal çöktürme için su geridevirli ve gaz geridevirli (b) iki kademeli yaklaşım.	13
Şekil 1.4.	Yukarı akışlı (A) ve aşağı akışlı (B) Akışkan Yataklı Reaktörlerin şematik gösterimi.	14
Şekil 2.1.	İstanbul İli Ozon Konsantrasyonu Tahmini İçin Optimum Model Mimarisi	16
Şekil 2.2	Eğitim Seti için Tahmin Edilen İle Ölçülen Ozon Konsantrasyonlarının Karşılaştırılması	16
Şekil 2.3.	Test Seti için Tahmin Edilen İle Ölçülen Ozon Konsantrasyonlarının Karşılaştırılması	16
Şekil 2.4	BOİ Çıkış Değerleri İle Tahmin Değerlerinin Karşılaştırılması	18
Şekil 2.5.	YSA – İstenen Sonuçların BOİ Test Seti İçin $x = y$ Grafiği Üzerinde Gösterimi	18
Şekil 2.6.	A= çıkış verileri T=hedeflenen veriler	19
Şekil 2.7.	Ölçülen ve YSA ile tahmin edilen nitrat konsantrasyonları	20
Şekil.2.8	CSTR çıkış parametrelerinin tahmini için kullanılan YSA ağ modeli	21
Şekil.2.9.	Sülfat (A), KOİ (B), Asetat (C) ve Çinko (D) giderim performansı. Çizgiler ve noktalar sırasıyla giriş ve çıkış konsantrasyonlarını; kesikli çizgiler ise YSA tahmin modellemesini göstermektedir. Asetat giriş konsantrasyonu, etanolün asetata oksidasyonu esas alınarak hesaplanmıştır	22
Şekil 3.1.	Çalışmada kullanılan yukarı akışlı akışkan yataklı reaktör	25
Şekil 3.2.	AAZR1'in şematik gösterimi ve fotoğrafı	28
Şekil 3.3.	AAZR2'in şematik gösterimi ve fotoğrafı	29
Şekil 4.1.	Senaryo-1'e göre Reaktör-1 çıkış sülfat tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	40
Şekil 4.2.	Senaryo-1'e göre (Reaktör -1) çıkış sülfat için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	41
Şekil 4.3.	Senaryo-2'ye göre Reaktör-1 çıkış sülfat tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	42
Şekil 4.4.	Senaryo-2'e göre (Reaktör -1) çıkış sülfat için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	43
Şekil 4. 5.	Senaryo-1'e göre Reaktör-1 çıkış KOİ tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	44
Şekil 4.6.	Senaryo-1'e göre (Reaktör -1) çıkış KOİ için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	45
Şekil 4.7.	Senaryo-2'ye göre Reaktör-1 çıkış KOİ tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	46
Şekil 4.8.	Senaryo-2'ye göre (Reaktör 1) çıkış KOİ için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	47
Şekil 4.9.	Senaryo-1'e göre Reaktör-1 çıkış alkalinite tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	48

Şekil 4.10.	Senaryo-1'e göre Reaktör -1 çıkış alkalinite için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	49
Şekil 4.11.	Senaryo-2'ye göre Reaktör-1 çıkış alkalinite tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	50
Şekil 4.12.	Senaryo-2'ye göre Reaktör-1 çıkış alkalinite için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	51
Şekil 4.13.	Senaryo-1'e göre Reaktör-1 çıkış sülfür tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	52
Şekil 4.14.	Senaryo-1'e göre (Reaktör -1) çıkış sülfür için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	53
Şekil 4.15.	Senaryo-2'ye göre Reaktör-1 çıkış sülfür tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	54
Şekil 4.16.	Senaryo-2'ye göre (Reaktör -1) çıkış sülfür için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	55
Şekil 4.17.	Senaryo-1'e göre Reaktör-2 çıkış sülfat tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	61
Şekil 4.18.	Senaryo-1'e göre (Reaktör-2) çıkış sülfat için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	62
Şekil 4.19.	Senaryo-2'ye göre Reaktör-2 çıkış sülfat tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	63
Şekil 4.20.	Senaryo-2'ye göre (Reaktör-2) çıkış sülfat için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	64
Şekil 4.21.	Senaryo-1'e göre Reaktör-2 çıkış KOİ tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	65
Şekil 4.22.	Senaryo-1'e göre (Reaktör-2) çıkış KOİ için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	66
Şekil 4.23.	Senaryo-2'ye göre Reaktör-2 çıkış KOİ tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	67
Şekil 4.24.	Senaryo-2'ye göre (Reaktör-2) çıkış KOİ için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	68
Şekil 4.25.	Senaryo-1'e göre Reaktör-2 çıkış alkalinite tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	69
Şekil 4.26.	Senaryo-1'e göre (Reaktör-2) çıkış alkalinite için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	70
Şekil 4.27.	Senaryo-2'ye göre (Reaktör-2) çıkış alkalinite tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	71
Şekil 4.28.	Senaryo-2'ye göre (Reaktör-2) çıkış alkalinite için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	72

Şekil 4.29.	Senaryo-1'e göre (Reaktör-2) çıkış sülfür tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	73
Şekil 4.30.	Senaryo-1'e göre (Reaktör-2) çıkış sülfür için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	74
Şekil 4.31.	Senaryo-2'ye göre (Reaktör-2) çıkış sülfür tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	75
Şekil 4.32.	Senaryo-2'ye göre (Reaktör-2) çıkış sülfür için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	76
Şekil 4.33.	Senaryo-1'e göre (Reaktör-3) çıkış sülfat tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	83
Şekil 4.34.	Senaryo-1'e göre (Reaktör-3) çıkış sülfat için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	84
Şekil 4.35.	Senaryo-2'ye göre (Reaktör-3) çıkış sülfat tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	85
Şekil 4.36.	Senaryo-1'e göre (Reaktör-3) çıkış sülfat için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	86
Şekil 4.37.	Senaryo-1'e göre (Reaktör-3) çıkış KOİ tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	87
Şekil 4.38.	Senaryo-1'e göre (Reaktör-3) çıkış KOİ için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	88
Şekil 4.39.	Senaryo-2'ye göre (Reaktör-3) çıkış KOİ tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	89
Şekil 4.40.	Senaryo-2'ye göre (Reaktör-3) çıkış KOİ için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	90
Şekil 4.41.	Senaryo-1'e göre (Reaktör-3) çıkış alkalinite tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	91
Şekil 4.42.	Senaryo-1'e göre (Reaktör-3) çıkış alkalinite için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	92
Şekil 4.43.	Senaryo-2'ye göre (Reaktör-3) çıkış alkalinite tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve tüm veriler (all) için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	93
Şekil 4.44.	Senaryo-2'ye göre (Reaktör-3) çıkış alkalinite için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	94
Şekil 4.45.	Senaryo-1'e göre (Reaktör-3) çıkış sülfür tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	95
Şekil 4.46.	Senaryo-1'e göre (Reaktör-3) çıkış sülfür için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	96

Şekil 4.47.	Senaryo-2'ye göre (Reaktör-3) çıkış sülfür tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)	97
Şekil 4.48.	Senaryo-2'ye göre (Reaktör-3) çıkış sülfür için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması	98

## ÇİZELGELER DİZİNİ

	<b>Sayfa No</b>
Çizelge 3.1.	R1 için periyodik olarak işletme koşulları 25
Çizelge 3.2.	R2 için periyodik olarak işletme koşulları 28
Çizelge 3.3.	R3 için periyodik olarak işletme koşulları 29
Çizelge 3.4.	YSA ile Yukarı ve Aşağı Akışlı AYR performanslarının belirlenmesinde kullanılan senaryolar ve çıkış parametreleri 32
Çizelge 4.1.	Senaryo-1'e göre Reaktör-1 çıkış değerleri için çeşitli öğrenme algoritmalarının kıyaslanması (nöron 20) 35
Çizelge 4.2.	Senaryo 1'e göre her bir out-put parametresi ( Reaktör-1) için farklı nöron sayılarından elde edilen tahminlerin kıyaslanması 36
Çizelge 4.3.	Senaryo-2'ye göre Reaktör-1 çıkış değerleri için çeşitli öğrenme algoritmalarının kıyaslanması (nöron 20) 37
Çizelge 4.4.	Senaryo-2'ye göre her bir out-put parametresi (Reaktör-1) için farklı nöron sayılarından elde edilen tahminlerin kıyaslanması 38
Çizelge 4.5.	Senaryo-1'e göre Reaktör-2 çıkış değerleri için çeşitli öğrenme algoritmalarının değerlendirilmesi (nöron 20) 56
Çizelge 4.6.	Senaryo-1'e göre her bir out-put parametresi (Reaktör-2) için farklı nöron sayılarından elde edilen tahminlerin kıyaslanması 57
Çizelge 4.7.	Senaryo-2'ye göre Reaktör-2 çıkış değerleri için çeşitli öğrenme algoritmalarının değerlendirilmesi ( nöron 20) 58
Çizelge 4.8.	Senaryo-2'ye göre her bir out-put parametresi (Reaktör-2) için farklı nöron sayılarından elde edilen tahminlerin kıyaslanması 59
Çizelge 4.9.	Senaryo-1'e göre Reaktör-3 çıkış değerleri için çeşitli öğrenme algoritmalarının değerlendirilmesi ( nöron 20 ) 78
Çizelge 4.10.	Senaryo-1'e göre her bir out-put parametresi (Reaktör-3) için farklı nöron sayılarından elde edilen tahminlerin kıyaslanması 79
Çizelge 4.11.	Senaryo-2'ye göre Reaktör-3 çıkış değerleri için çeşitli öğrenme algoritmalarının değerlendirilmesi ( nöron 20 ) 80
Çizelge 4.12.	Senaryo-2'ye göre her bir out-put parametresi (Reaktör-3) için farklı nöron sayılarından elde edilen tahminlerin kıyaslanması 81

## SİMGELER DİZİNİ

AMS	Asidik Maden Sızıntısı
SİB	Sülfat İndirgeyen Bakteri
YSA	Yapay Sinir Ağları
KOI	Kimyasal Oksijen İhtiyacı
AYR	Akışkan Yataklı Reaktör
HCl	Hidroklorik asit

## 1.GİRİŞ

Asidik maden sızıntı suları (AMS), bir maden işletmesinin çalışması boyunca ve kapatılması sonrasında sülfürlü cevherler (örneğin pirit) ile suyun ve oksijenin temas halinde bulunmasıyla meydana gelen bir dizi kompleks jeo-kimyasal ve mikrobiyal reaksiyonlar sonucunda oluşmaktadır. Sonuçta oluşan su, genel olarak yüksek asidite (düşük pH) ve yüksek konsantrasyonda çözülmüş metalleri (Cu, Fe, Pb vb.) içermektedir (Costello, 2003; Tsukamoto vd. 2004; Ridge ve Seif, 2005; Akcil ve Koldas, 2006). Yüksek konsantrasyonlarda sülfat ve metal içeren asidik maden sızıntı suları (AMS) oldukça düşük konsantrasyonlarda organik madde içermektedir. AMS sularının biyolojik yollarla arıtılması, hem ekonomik hem de yüksek verimli olmasından dolayı uygulanabilir bir alternatiftir. AMS'de bulunan sülfat, organik madde ilavesiyle, anaerobik şartlarda indirgenerek H<sub>2</sub>S'e dönüşür. Ayrıca, AMS'de bulunan metaller üretilen H<sub>2</sub>S ile reaksiyona girerek oldukça kararlı bir çökelti oluştururlar. İlave olarak, organik maddenin varlığında sülfat indirgenmesi sırasında oluşan bikarbonat alkalinitesi, pH değerinin nötral değerlere kadar ulaşmasını sağlayabilmektedir. Organik madde ilavesiyle, gerek sülfat ve metal giderimi, gerekse pH nötralizasyonunun tek bir reaktörde gerçekleştirilebilmesi bu suların arıtımında önemli avantajlar sağlamaktadır. Asidik maden sızıntı suları asidik karakterde olup pH değeri genellikle 5'in altındadır. Çünkü başlıca oksitlenme tepkimeleri ürünleri arasında sülfat ve proton iyonları bulunmaktadır. Sızıntı suları sülfürik asit içermektedir. Beraberinde metal, ağır metal konsantrasyonu yüksek olabilir. Bunların haricinde, yüksek konsantrasyonlarda askıda katı, çözülmüş katının yanı sıra düşük pH ile organik madde eksikliği bu suların belirgin özellikleridir.

Eğer bir maden işletmesinde AMS oluşması potansiyeli varsa ve gereken tedbirler alınmazsa, AMS'nin gelişimiyle bazı çevresel etkilerle karşı karşıya kalınması doğaldır. Etki altına girmesi beklenen alıcı ortamlar ise yüzey suları yeraltı suları ve göllerdir. Asidik maden sızıntı suları yüzey akıntıları, yağmur suları, sızma ve süzülme yoluyla taşınarak nehirlere, göllere ve yeraltı su sistemlerine karışabilir. Böylelikle, su kalitesi değişime maruz kalır, kirlenme gerçekleşir. Bu bağlamda, alıcı ortamlarla bağlantılı ekosistemler etki altına girebilir. Neticede, türlerin yok olması,



besin zincirinin basitleşmesi ve ekolojik duyarlılığın azalması görülebilir. AMS'lerin kirlilik kontrolü; bu suların oluşumu ve taşınımının önlemesinin yanı sıra bu suların toplanması ve arıtımı ile de sağlanabilir (Geldenhuis ve Bell 1998; Johnson 2000). Sudaki asitliğin, metallerin ve sülfatın arıtımında kullanılan birçok fiziko-kimyasal ve biyolojik teknik mevcuttur (Lanouette 1977; Peters ve ark. 1985; Johnson 2000; Hao 2000).

Bu çalışmada, Asidik Maden Sızıntı Sularının arıtımında, akışkan yataklı reaktör performanslarının yapay sinir ağları (YSA) ile modellenmesi amaçlanmaktadır. Bu kapsamda 108Y036 nolu Tübitak Projesi kapsamında işletilen yukarı ve aşağı akışlı akışkan yataklı reaktörlerden alınan belirli giriş ve çıkış atıksu verileri kullanılacaktır. Yapay sinir ağları esasına göre çalışan Matlab 7,6 Bilgisayar programı aracılığı ile modellemeler yapılacak ve reaktör performanslarının tahmin edilmesine çalışılacaktır. Bu çalışmada, AMS arıtan akışkan yataklı reaktörler için “işletim süresi, giriş pH, çıkış pH, giriş sülfat, giriş kimyasal oksijen ihtiyacı (KOİ) ve giriş metal” olmak üzere toplam 6 input parametresini kullanarak; “çıkış sülfat, çıkış KOİ, çıkış alkalinite ve çıkış sülfür” konsantrasyonlarının YSA ile tahmin edilmesi hedeflenmektedir. Bu amaçla, 2 senaryo üzerinde çalışılacaktır. İlkinde çıkış pH değeri input parametreleri içerisinde yer alırken (Senaryo-1); ikinci senaryoda (Senaryo-2) çıkış pH değeri input parametreleri arasından çıkarılarak YSA ile reaktör performansının modellenmesi araştırılacaktır. Senaryo-2 ile AMS arıtımı amaçlı kullanılacak olan bir reaktör henüz kurulmadan performansının tahmin edilmesi hedeflenmektedir. YSA ile akışkan yataklı reaktör performansının modellenmesi çalışmasında; işletim süresi giriş parametreleri arasında yer alacaktır. Bunun sebebi ise, reaktör işletimi süresince bakteriyel komünite değişmekte ve böylece yeni işletim şartlarına adapte olmaktadır. Dolayısıyla, işletim süresinin giriş parametrelerinin arasında yer almasıyla, aklimasyon ve kültür farklılıklarından doğan değişimlerin de modellemeye dâhil edilebileceği düşünülmektedir.

### 1.1. Yapay Sinir Ağlarının (YSA) Tanıtılması

Son yıllarda bilgisayar bilimlerinde yaşanan teknolojik gelişmeler, neredeyse takip edilemeyecek bir hızda ilerlemektedir. Bu ilerleme, insanoğlunun da yaratıcılığını ve sınır tanımazlığını arttırmış, daha önce hiç hayal bile edilemeyen yeni gelişmelerin doğmasına neden olmuştur. Bu gelişmelerden bir tanesi de Yapay Zekâ'dır. Yapay sinir ağının genel bir tanımı yapılması gerekirse, Yapay Sinir Ağı, insan beyninin çalışma ve düşünebilme yeteneğinden yola çıkılarak oluşturulmuş bir bilgi işlem teknolojisidir. Yapay Sinir Ağları (YSA)'da, Yapay Zekâ biliminin altında araştırmacıların çok yoğun ilgi gösterdikleri bir araştırma alanıdır. YSA'ların örnekler ile öğrenebilme ve genelleme yapabilme özellikleri onlara çok esnek ve güçlü araçlar olma özelliği sağlamaktadır.

Yapay sinir ağlarının dayandığı ilk hesaplama modelini temelleri 1940'ların başında araştırmalarına başlayan W.S. McCulloch ve W.A. Pitts'in, 1943 yılında yayınladıkları bir makaleyle atılmış olmuştur. Daha sonra 1954 yılında B.G. Farley ve W.A. Clark tarafından bir ağ içerisinde uyarılara tepki veren, uyarılara adapte olabilen model oluşturulmuştur. 1960 yılı ise ilk neural bilgisayarın ortaya çıkış yılıdır. 1963 yılında basit modellerin ilk eksiklikleri fark edilmiş, ancak başarılı sonuçların alınması 1970 ve 1980'lerde termodinamikteki teorik yapıların doğrusal olmayan ağların geliştirilmesinde kullanılmasına kadar gecikmiştir. 1985 yapay sinir ağlarının oldukça tanındığı, yoğun araştırmaların başladığı yıl olmuştur.

Yapay sinir ağları, birçok alanda problem çözme, tahmin etme ve modelleme çalışmalarında kullanılmaktadır. Yapay sinir ağlarının kullanıldığı alanlardan biri de kimyasal ve biyolojik sistemlerin modellenmesidir. Bu tip modellerin normal matematiksel modellerle tanımlanmaya çalışılmasında, birçok katsayının belirlenmesi ve birçok kabulün yapılması gerekmekte olup, kimi zaman elde edilen sonuçlar doğruluktan çok uzakta olabilmektedir. Dolayısıyla, birçok belirsizliğin olduğu bu gibi sistemlerin modellenmesinde yapay sinir ağları güvenilir ve uygulaması kolay bir alternatif model olarak karşımıza çıkmaktadır.

Yapay sinir ağları, kurulumuna bağlı olarak çeşitli şekillerde sınıflandırılabilir (Mjalli ve ark.2007);

- Tek ve çok katmanlı ( single and multi layer ) ileri beslemeli (feedforward) ağlar
- Geri beslemeli ağlar
- Yinelenen ya da döngülü (recurrent ) ağlar
- Kişisel olarak organize edilmiş (self-organized ) ağlar.

En çok kullanılan ağ tipi ileri beslemeli ağlardır. Burada sistem bir girdi (input), bir çıktı (output ) ve en az bir tane de gizli (hidden ) katmandan meydana gelir. İleri beslemeli terimi, girdi verisinden, çıktı verimini hesaplamak için izlenen yolu tarif etmektedir. Bu ağ sisteminde nöronlar arasındaki bağlantıda bir döngü olmayıp, sürekli ileri doğru bir yol izlenmektedir. Nöronlar, giriş verilerine birer ağırlık fonksiyonu ekleyerek toplar ve belirli aktivasyon fonksiyonları kullanarak çıktıları hesaplar.

YSA'larda bilgi saklama, verilen eğitim özelliğini kullanarak eğitim örnekleri ile yapılır. Sinirsel hesaplama, algoritmik programlamaya bir seçenek oluşturan, temel olarak yeni ve farklı bir bilgi işleme olayıdır. Uygulama imkânının olduğu her yerde, tamamen yeni bilgi işleme yetenekleri geliştirebilir. Bu sayede de geliştirme harcamaları ile geliştirme süresi büyük ölçüde azalır. Bir yapay sinir ağı girdi setindeki değişiklikleri değerlendirerek öğrenir ve buna bir çıktı üretir. Öğrenme işlemi benzer girdi setleri için aynı çıktıyı üretecek bir öğrenme algoritması ile gerçekleşir. Öğrenme setindeki girdilerin istatistiksel özelliklerinin çıkarılarak benzer girdilerin gruplandırılmasını sağlayan bir işlemdir.

Geleneksel bilgisayar uygulamalarının geliştirilmesinde karşılaşılan durum, bilgisayarın belli bilgisayar dilleri aracılığıyla ve kesin yazım algoritmalarına uygun ifadelerle programlanmasıdır. Bu oldukça zaman alan, uyumluluk konusunda zayıf, teknik personel gerektiren, çoğu zaman pahalı olan bir süreçtir. Oysa biyolojik temele dayalı yapay zekâ teknolojilerinden biri olan yapay sinir ağlarının geliştirilmesinde programlama, yerini büyük ölçüde "eğitime" bırakmaktadır. Proses

elemanlarının bağlantı ağırlık değerlerinin belirlenmesi işlemine “ağın eğitilmesi” denir. Yapay sinir ağının eğitilmesinde kullanılan girdi ve çıktı dizileri çiftinden oluşan verilerin tümüne "eğitim seti" adı verilir.

Yapay sinir ağı öğrenme sürecinde, gerçek hayattaki problem alanına ilişkin veri ve sonuçlardan, bir başka deyişle örneklerden yararlanır. Gerçek hayattaki problem alanına ilişkin değişkenler yapay sinir ağının girdi dizisini, bu değişkenlerle elde edilmiş gerçek hayata ilişkin sonuçlar ise yapay sinir ağının ulaşması gereken hedef çıktıların dizisini oluşturur. Öğrenme süresinde, seçilen öğrenme yaklaşıma göre ağırlıklar değiştirilir. Ağırlık değişimi, öğrenmeyi ifade eder. YSA’da ağırlık değişimi yoksa öğrenme işlemi de durmuştur. Başlangıçta bu ağırlık değerleri rastgele atanır. YSA’lar kendilerine örnekler gösterildikçe, bu ağırlık değerlerini değiştirirler. Amaç, ağa gösterilen örnekler için doğru çıktıları üretecek ağırlık değerlerini bulmaktır. Ağın doğru ağırlık değerlerine ulaşması örneklerin temsil ettiği olay hakkında, genellemeler yapabilme yeteneğine kavuşması demektir. Bu genelleştirme özelliğine kavuşması işlemine, “ağın öğrenmesi” denir.

Yapay sinir ağının öğrenme sürecinde temel olarak üç adım bulunmaktadır.

- Çıktıları hesaplamak,
- Çıktıları hedef çıktılarla karşılaştırmak ve hatayı hesaplamak,
- Ağırlıkları değiştirerek süreci tekrarlamak.

Eğitim süreci sonucunda yapay sinir ağında hesaplanan hatanın kabul edilebilir bir hata oranına inmesi beklenir. Ancak hata kareleri ortalamasının düşmesi her zaman için yapay sinir ağının genellemeye (generalization) ulaştığını göstermez. Yapay sinir ağının gerçek amacı girdi-çıkıtı örnekleri için genellemeye ulaşmaktadır.

En uygun öğrenme seviyesi, öğrenme fonksiyonunun önceden amaçlanan bir değere ulaşması ile sağlanamayabilir. Uygulamalarda eğitim süreci boyunca performans fonksiyonunun izlenmesi ile birlikte sık sık genelleme testlerinin gerçekleştirilmesi yolu ile en uygun öğrenme seviyesi elde edilebilir. Eğer en uygun

öğrenme seviyesine, performans fonksiyonunun öngörülerinden önce ulaşılmış ise eğitim süresi daha erken dönemlerde de sona erdirilebilir.

YSA sistemlerinin problemi öğrenme başarısı, gerçekleştirilen testlerle sınanmalıdır. Yapay sinir ağı geliştirme sürecinde veriler ikiye ayrılır; bir bölümü ağın eğitilmesi için kullanılır ve eğitim seti adını alır, diğer bölümü ise ağın eğitim verileri dışındaki performansını ölçmede kullanılır ve “test seti” olarak adlandırılır.


Eğitim ve test setleriyle ilgili temel sorun, yeterli eğitim ve test verisinin miktarının ne olduğudur. Sınırsız sayıda verinin bulunabildiği durumlarda, yapay sinir ağı mümkün olan en çok veriyle eğitilmelidir. Eğitim verisinin yeterli olup olmadığı konusunda emin olmanın yolu; eğitim verisinin miktarının artırılmasının, ağın performansında bir değişiklik yaratmadığını takip etmektir. Ancak bunun mümkün olmadığı durumlarda yapay sinir ağının eğitim ve test verileri üzerindeki performansının yakın olması da verilerin sayıca yeterli olduğuna ilişkin bir gösterge olarak kabul edilebilir.

Katmanların birbiriyle değişik biçimlerde bağlanmaları değişik ağ mimarilerini doğurur. YSA lar üç katmandan oluşur. Bu katmanlar sırası ile:

- Girdi katmanı
- Ara Katman
- Çıktı Katmanıdır.

Girdi katmanındaki proses elemanları dış dünyadan bilgileri alarak ara katmanlara transfer ederler. Bazı ağlarda girdi katmanında herhangi bir bilgi işleme olmaz. Girdi katmanından gelen bilgiler işlenerek çıktı katmanına gönderilirler. Bu bilgilerin işlenmesi ara katmanlarda gerçekleştirilir. Bir ağ içinde birden fazla ara katman olabilir.

Çıktı katmanındaki proses elemanları ara katmandan gelen bilgileri işleyerek ağın girdi katmanından sunulan girdi seti için üretmesi gereken çıktıyı üretirler. Üretilen çıktı dış dünyaya gönderilir.



Şekil 1.1. Yapay Sinir Ağı Modeli

YSA sistemi, basit işletim elemanı olan nöronların birbirine farklı ağırlık vektörleri ile bağlanması ile oluşur. Nöronlar belli bir sayıda giriş (input) verisi alarak bunlara belirli ağırlık vektörleri verip toplar ve transfer fonksiyonlarını kullanarak tek bir çıkış verir (Strik vd. 2005). Öğrenmenin başlangıcında, output ile hedef verisi arasındaki fark fazla olabilmekte ve öğrenme devam ettikçe çıkış verileri daha uyumlu değerlere ulaşmaktadır. Back-propagation algoritması giriş ve buna karşı gelen çıktı vektörünü kullanarak öğrenmeyi gerçekleştirir. Farklı back-Propagation algoritmaları olup bunların içinden sisteme en uygun olanının seçilmesi gerekmektedir.

Yapılan çalışmada izlenecek adımlar aşağıda belirtilmiş ve ayrıntılı olarak açıklanmıştır.

1. Verilerin toplanması, değerlendirilmesi ve reaktöre ait hangi parametrelerin tahmin edilmesi gerektiğinin kararlaştırılması.
2. En uygun tahmin için hangi parametrelerin giriş parametresi olarak kullanılacağını belirlemesi.

3. 12 adet Backpropagation algoritmasından (öğrenme algoritması) hangilerinin tahmin edilecek parametreler için uygun olduğunun belirlenmesi.
4. Gizli katmana ait nöron sayısının tahmin edilen her bir parametre için optimize edilmesi.

## 1.2. Asidik Maden Sızıntı Sularının Arıtımı

AMS'nin gideriminde en uygun yöntem, AMS'yi kaynağında önlemek ve/veya kontrol etmektir. Maden artığındaki nötralle edici minerallerin oranının artırılması ve/veya sülfürlü mineraller ile su ve oksijenin temasının kesilmesi ile AMS'nin oluşumu önlenir. Eğer AMS'nin meydana gelmesi engellenemezse, AMS'nin çevreye etkilerini en aza indirmek veya ortadan kaldırmak için kimyasal ve/veya biyolojik bir proses uygulanmalıdır. Böylece meydana gelen asit etkisiz hale getirilir ve metaller uzaklaştırılır veya su standartlarına uygun, kabul edilebilir seviyelere düşürülür. AMS arıtımında aşağıda açıklanan iki tip arıtım sisteminden yararlanılmaktadır.

### 1.2.1. Aktif arıtma

Asidik maden sızıntı sularının aktif bir yöntemle arıtılması, bazik bir kimyasal madde yardımıyla pH'ın nötrleştirilmesi ve metallerin çöktürülmek suretiyle sistemden uzaklaştırılmasıdır. Kimyasal nötralizasyon ve metalleri hidroksit olarak çöktürmek en yaygın kullanılan AMS arıtım prosesidir (Lanouette 1977; Peters ve ark. 1985; Veeken ve Rulkens 2003).

Asidik ortamda çözülmüş halde bulunan metal iyonları, pH yükseldiğinde toksik anlamda daha az tehlikeli metal karmaşıklarına dönüşmektedir. Sonrasında çözünmez nitelik kazanıp çökelmektedirler. Buna göre arıtma dört temel aşamadan oluşmaktadır; nötrleştirme, havalandırma, çöktürme ve bertaraf; arıtılmış suyun boşaltılması (Ackman, Kleinmann, 1984). Kimyasal ilavesiyle gerçekleştirilen aktif

arıtma asitliğin giderilmesinde ve metallerin uzaklaştırılmasında etkin olmasına karşın; sürekliliğin getirdiği yüksek maliyet, uzun yıllara yayılan mesuliyet, devamlı bakım ihtiyacı ve malzeme tedariki işletmecileri yeni arayışlara itmiştir. Bunun sonucunda pasif arıtma sistemleri doğmuştur

Tichy ve ark. (1998) ile Garcia ve ark. (2001), yüksek miktarda kimyasal madde sarfiyatı, yetersiz sülfat arıtımı ve bertaraf edilme zorunluluğu olan yüksek hacimde çamur oluşumunun bu metodun en önemli dezavantajları olduğunu belirtmişlerdir. Ancak bununla birlikte; sistemin metallerin sülfür ile çöktürülmesi, hidroksit çökeleklerine göre çok daha düşük çıkış metal konsantrasyonu elde edilebilmesi, daha iyi yoğunlaşabilen çamur üretimi ve çöktürülen metallerin geri kazanılabilir olması gibi oldukça önemli avantajları bulunmaktadır. (Whang ve ark. 1982; Peters ve ark. 1985; Boonstra ve ark. 1999; Jalalı ve Baldwin 2000; Veeken ve Rulkens 2003). Dışardan sülfür bileşikleri ekleyerek, metallerin çöktürülmesi yüksek kimyasal sarfiyatına sebep olacağından, AMS arıtımında yaygın olarak kullanılmamaktadır (Lanouette 1977; Van Houten ve ark. 1995).

Günümüzde AMS arıtımı uygulamalarında biyolojik işlemler geliştirilmektedir. Bu işlem; sülfat indirgeyen bakterilerin (SİB) ürünü olan hidrojen sülfür'ün metallerle çökelek oluşturması sırasında mikrobiyal metabolizma tarafından üretilen bikarbonat alkalinitesi ile suyun asitliğin giderilmesini temel almaktadır (Dvorak ve ark. 1992; Christensen ve ark. 1996). Biyolojik olarak sülfat giderimindeki verim, SİB'ler için karbon ve elektron kaynağı temin edilerek arttırılabilir. Sulak alanlarda, reaktif bariyerlerde ve biyoreaktör uygulamalarında AMS arıtımı SİB'ler ile gerçekleştirilebilir.

### 1.2.2. Pasif arıtma

Çeşitli pasif yöntemler, geleneksel yöntemlerden daha baskın işlemlerdir. Pasif yöntemler; yerinde gerçekleştirilen, en az bakım masrafı gerektiren ve doğal prosesler kullanılarak suyun veya katının muamele edilmesi olarak düşünülebilir (Hedin vd. 1994; Younger vd., 2002). Uygulanan yeni teknolojilerin birçoğu temelde



aynı yönteme dayanmaktadır. Geçirgen biyoreaktif bariyerler, biyoreaktörler ve sulak alan teknolojileri maden drenajının giderilmesinde alkali malzemeleri ve sülfat indirgeyici bakterileri kullanabilmektedir. Bu tür teknolojilerin farkı, inşasında ve bu prosese giren suyun kaynağındadır. Örneğin, geçirgen biyoreaktif bariyerler, bir yüzey-altı reaksiyon bölümüne sahiptir. Bu yöntemde yeraltı suyu, doğal akışı ile akarken muamele edilmektedir ve bazı durumlarda reaksiyon bölümüne suyun akışını yönlendirmek için duvarlar geçirimsiz olarak yapılmaktadır. Genellikle reaktif ortam, sülfat indirgeyici bakterilerin geliştiği organik maddeden mikroorganizmalar, metallerin ve sülfatların indirgenmesinin yanı sıra diğer alkali üretim prosesleri boyunca AMS'nin gideriminde rol oynamaktadır. Ayrıca bu mikroorganizmalar, gerekli elektron alıcı ve vericilerinin bulunabilirliğine, kimyasal bileşime ve maden artık ortamındaki sıcaklık ve pH şartlarına bağlı olarak her bir proseste AMS'nin nötralizasyonuna katkıda bulunabilirler (Kuyucak, 2002). Desulphovibrio sp. gibi sülfat indirgeyici bakteriler olarak adlandırılan bir grup bakteri, AMS'nda bulunan sülfatı ( $SO_4^{2-}$ ) sülfüre ( $S^{2-}$ ) dönüştürebilmekte, anoksik ve indirgeyici şartlar altında bir elektron vericisi olarak sülfatı kullanarak organik karbon (besin) kaynağının varlığında bikarbonatı ( $HCO_3^-$ ) oluşturabilmektedir (Dvorak vd., 1992; Kolmert ve Johnson, 2001; Luptakova ve Kusnierova, 2005). Sülfat indirgemede ilk olarak  $HS^-$  oluşmakta ve  $HS^-$ , serbest hidrojen iyonu ile reaksiyona girerek hidrojen sülfürü ( $H_2S$ ) meydana getirmektedir. Daha sonra hidrojen sülfür metallerle reaksiyona girerek, çözünmeyen metal komplekslerini oluşturmakta ve böylece metallerin uzaklaştırılması gerçekleşmektedir. Ortaya çıkan bikarbonat, ortamın bazlılığının (pH vs.) artışına neden olmaktadır. Manganez ve demir indirgemesi, nötralizasyon prosesine önemli katkıda bulunabilmektedir.

Pasif biyolojik giderim sistemlerinin kimyasal yöntemlere göre oldukça avantajlı tarafları olmasına karşın, bu sistemler uygulanacak alanın şartları ile sınırlanmaktadır. Bu sistemlerin performansı yüksek derecede sıcaklığa bağlıdır. Düşük sıcaklıklarda sistemin performansı düşmektedir. Ayrıca bu sistemlerin performansı, muamele edilen suyun kimyasal bileşimine ve akış hızına bağlı olarak sınırlanmaktadır.

Sistemin boyutu, yapının basitliği, asitli suyun kimyasal bileşimini ve gerekli besinlerin miktarı ve bulunabilirliği prosesin maliyetini belirlemektedir. Bu yüzden, bu sistemlerde organik madde veya besin olarak o bölgede bulunabilir malzemelerin kullanımı önerilmektedir.

### 1.3. Akışkan Yataklı Reaktörler ve AMS Arıtımı

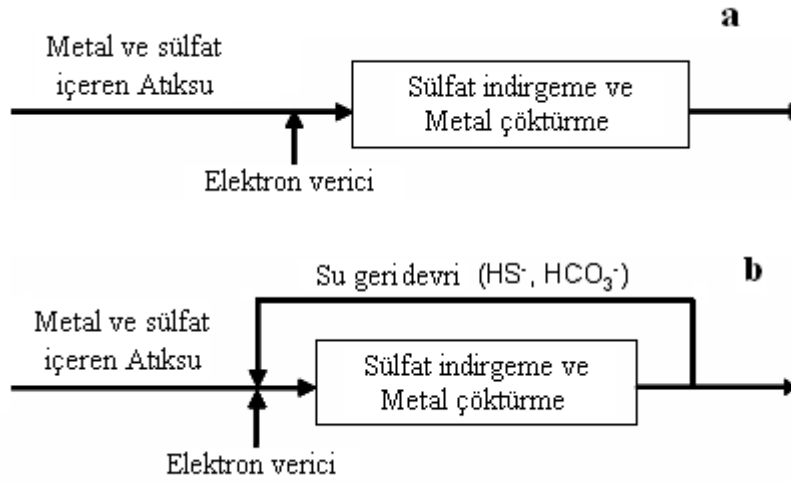
Sülfat indirgeyen bakteri (SİB)'lerin AMS arıtımında kullanılarak metallerin geri kazanımı nispeten yeni bir metot olup, geleneksel yöntemlere kıyasla avantajlı oluşu, bu yöntemi AMS arıtımında ciddi bir alternatif haline getirmiştir. AMS'de bulunan sülfat; organik madde ilavesiyle, anaerobik şartlarda SİB'lerin aktiviteleri sonucu indirgenerek H<sub>2</sub>S'e dönüşür (Denklem 1). AMS'de bulunan metaller üretilen H<sub>2</sub>S ile reaksiyona girerek oldukça kararlı bir çökelti oluşturur (Denklem 2). İlave olarak, organik maddenin sülfat varlığında indirgenmesi sırasında oluşan bikarbonat alkalinitesi (Denklem 1), pH değerinin nötral değerlere kadar ulaşmasını sağlayabilmektedir. Organik madde ilavesiyle; sülfat ve metal giderimi, pH nötralizasyonu ve metal geri kazanım avantajlarından dolayı, SİB'lerin AMS arıtımında yakın zamanda çok daha yaygın olarak kullanılması beklenmektedir.



Asılı büyüyen (Moosa ve ark. 2002, 2005; Şahinkaya 2009) ve bağlı büyüyen (Steed ve ark. 2000; Kaksonen ve ark. 2003; Şahinkaya ve ark. 2007; Hoa 2007) biyoproseslerin sülfat indirgemedede verimli bir şekilde kullanılabilceği literatürde çeşitli çalışmalarda gösterilmiştir. Ancak, biyofilm reaktörlerin asılı büyüyen reaktörlere göre daha düşük hidrolik bekleme zamanlarında daha yüksek sülfat giderim verimi sağlayabildikleri bilinmektedir. Örneğin Kaksonen ve ark. (2003)b, akışkan yataklı reaktörde 35 °C'de yaptıkları çalışmada günlük 600 mg/L çinko ve 300 mg/L demirin tamamen çöktildiğini göstermişlerdir. Ancak, biyofilm reaktörlerde metal birikimi metalin geri kazanımını zorlaştırmaktadır.

Metal içeren atıksuların çözünmüş organik karbon miktarı çok düşüktür ( <10 mg/L) (Johnson 2000). Bu sebeple, sülfatı indirgeyip biyolojik olarak H<sub>2</sub>S üretebilmek için atıksuya uygun karbon ve elektron kaynağı eklemek gerekmektedir. SİB'ler laktat, format, asetat, etanol ve hidrojen gibi düşük moleküler ağırlıklı birkaç besini kullanırlar. Bazı SİB'ler organik besinleri tamamen CO<sub>2</sub>'e oksitlerken, bazıları sadece asetata kadar oksitlerler. Laktat birçok SİB için iyi bir besin kaynağı olup, sülfat ve metal içeren atıksuların arıtımı için biyoreaktör uygulamalarında kullanılabilir (Kaksonen ve ark. 2003b).

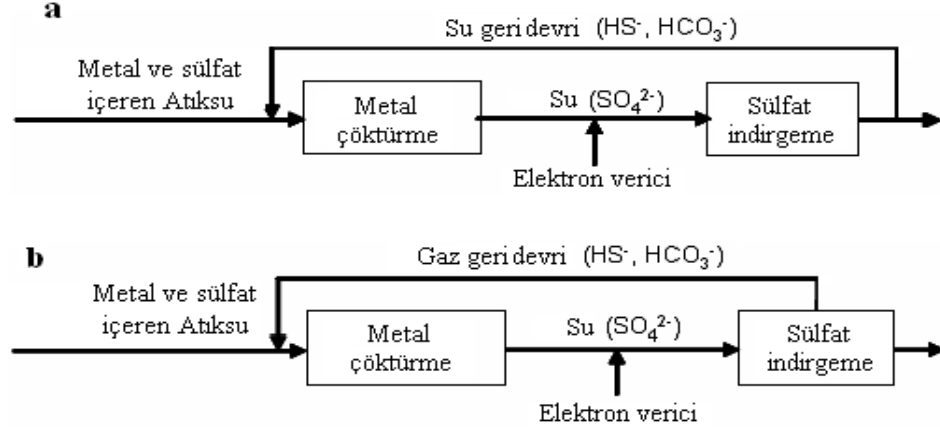
Literatürde, SİB'ler ile metal arıtımına yönelik çalışmalarda, genellikle tek-kademeli sistemler (Şekil 1.1.) kullanılmıştır. Bu sistemlerde sülfat indirgeme ve metal çöktürme aynı reaktörde gerçekleşmekte olup, hem metal geri kazanımı zor olmakta hem de çöken metallere dolayı SİB'lerin aktivitesi düşmektedir.



Şekil 1.2. Tek kademeli sülfat indirgeme ve metal çöktürme (a) geri devirsiz, (b) geri devirli sistemler


Tek kademeli sistemlerde, metal çökelekleri biyoreaktörden geri kazanım amacıyla uzaklaştırılırken, aynı zamanda biyokütle de sistemden uzaklaştırılmakta ve sistem verimi olumsuz yönde etkilenebilmektedir. Yapılan çalışmada asıl amacın metal geri kazanımı olması nedeniyle; sülfat indirgeme ve metal çöktürme basamaklarının ayrı olduğu iki kademeli sistemler (Şekil 1.2.) kullanılacaktır.

Böylece, hem metal geri kazanımı kolaylaşacak hem de metal çökeleklerinden dolayı, SİB'lerin aktivitelerinin düşmesi engellenecektir.



Şekil 1.3. Sülfat indirgeme ve metal çöktürme için su geridevirli ve gaz geridevirli (b) iki kademeli yaklaşım

Bu reaktörde, sudan daha hafif bir taşıyıcı malzeme kullanılarak; suyun aşağı yönlü akışı ile taşıyıcı malzeme akışkan hale getirilecektir. Aşağı akışlı akışkan yataklı reaktörde, AMS arıtımı ve metal geri kazanım verimi yukarı akışlı akışkan yataklı reaktörün kullanıldığı iki-kademeli sistem ile kıyaslanacaktır. Bu reaktörde, metal-sülfür çökelekleri reaktör tabanına doğru çöker ve gaz-katı-sıvı ayırıcısına ulaşarak, metaller reaktörden ayrılır. Böylece, çöken metaller, biyokütle gidermeksizin reaktörden uzaklaştırılmış olur.



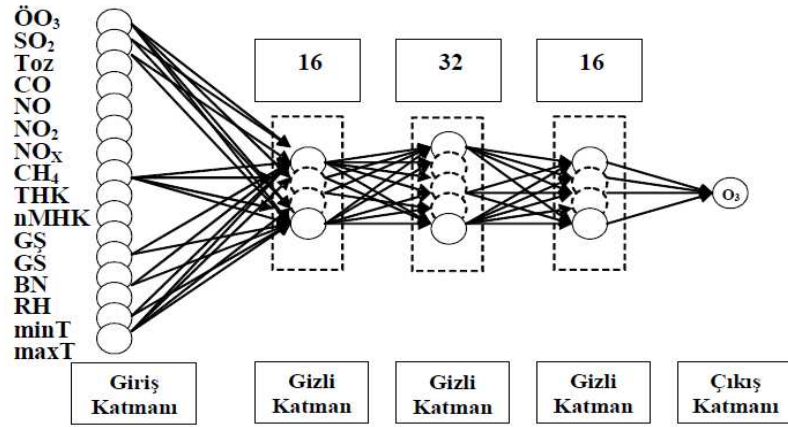
Şekil 1.4. Yukarı akışlı (A) (Sahinkaya vd., 2007a) ve aşağı akışlı (B) (Celis-Garcia vd., 2007) Akışkan Yataklı Reaktörlerin şematik gösterimi

## **2. ÖNCEKİ ÇALIŞMALAR**

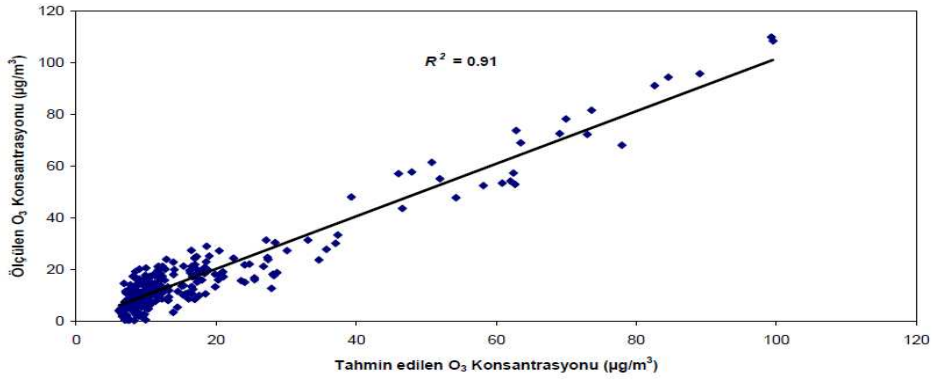
Çevre Mühendisliğinin değişik alanlarında Yapay Sinir Ağları (YSA) kullanılarak birçok çalışma yapılmıştır. Bu tez kapsamında ve tezin uygulanması sürecinde de yararlanılan çalışmaların kısa bir özeti, aşağıda kronolojik olarak verilmiştir.

### **2.1. İstanbul ili Ozon Konsantrasyonlarının Yapay Sinir Ağları İle Tahmini**

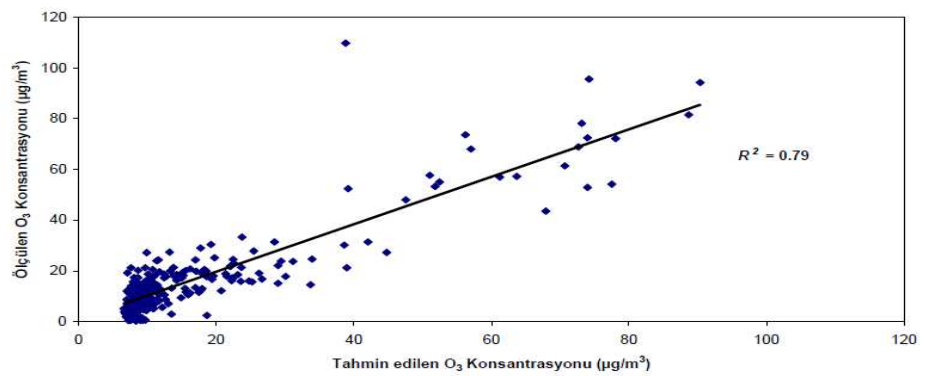
Özcan ve ark., (2006), kirletici ve meteorolojik parametreler kullanarak, YSA yaklaşımı ile İstanbul ili için troposferik ozon konsantrasyonlarını modellemişlerdir. Ozon tahmininde kullanılan parametrelerin yaklaşık 2 yıllık (2004-2005) değişimleri dikkate alınmış ve çok çeşitli model mimarileri farklı model parametreleri ile denenmiştir. En iyi model performansı, 3 gizli katman (16, 32 ve 16 hücreden oluşan) ve öğrenme oranı 0,3 olarak belirlenmiş model denemesinden elde edilmiştir. Bu model mimarisi ve öğrenme oranı ile hesaplanan belirtme katsayıları eğitim ve test veri setleri için sırasıyla 0.91 ve 0.79'dur. Literatürdeki çalışmalar incelendiğinde  $R^2=0.79$ 'un İstanbul için elde edilmiş olan önceki bazı değerlerden daha yüksek olduğu görülmüştür. Sonuçta, YSA modelleme tekniği troposferik ozon konsantrasyonlarının tahmininde başarı ile uygulanmıştır (Tecer ve ark. 2003).



Şekil 2.1. İstanbul İli Ozon Konsantrasyonu Tahmini İçin Optimum Model Mimarisi ( Kabaca, M., Gerger, V., Yetkin, S., Sofuoğlu, S., İnal, F., 2007)



Şekil 2.2. Eğitim Seti için Tahmin Edilen İle Ölçülen Ozon Konsantrasyonlarının Karşılaştırılması ( Kabaca, M., Gerger, V., Yetkin, S., Sofuoğlu, S., İnal, F., 2007)



Şekil 2.3. Test Seti için Tahmin Edilen İle Ölçülen Ozon Konsantrasyonlarının Karşılaştırılması ( Kabaca, M., Gerger, V., Yetkin, S., Sofuoğlu, S., İnal, F., 2007)

## 2.2. Adapazarı Kentsel Atıksu Arıtma Tesisi Çıkış Suyu Parametreleri ve Verim Değerlerinin Yapay Sinir Ağları ile Tahmini

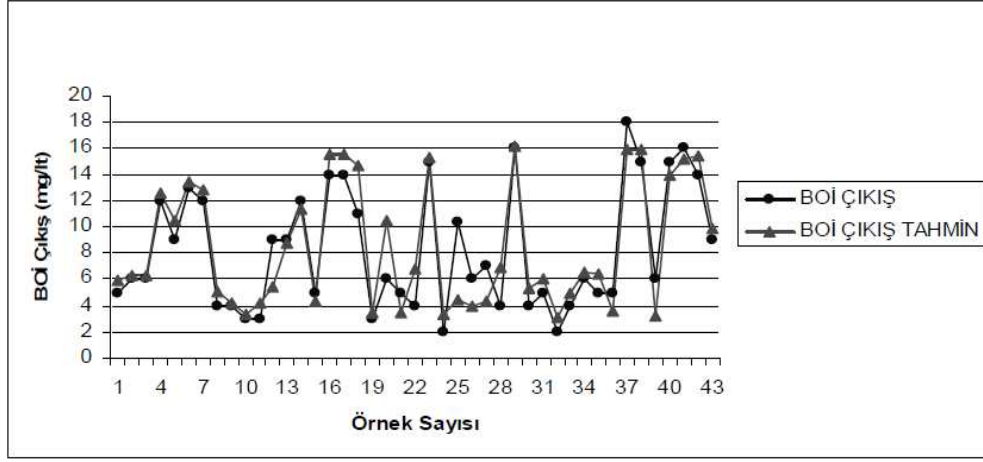
Atık su arıtma tesisleri giriş parametrelerinin büyük değişimler göstermesi, bu tesislerin optimum performansta işletilmesini zorlaştırmaktadır. Bu atık su arıtma tesislerinin optimum işletilmesi amacıyla özellikle son 10-15 yılda çeşitli araçlar geliştirilmeye çalışılmaktadır. Bu araçlardan şu anda en yaygın olarak kullanılanı, matematiksel olarak geliştirilmiş ve matris şeklinde düzenlenmiş diferansiyel denklemlerden oluşan aktif çamur modelleridir. 1987 yılından itibaren IAWQ (International Association of Water Quality) organizasyonu aracılığıyla Aktif Çamur modelleri geliştirilmesine rağmen bu modellerin halen bazı zayıf noktaları ve dezavantajları bulunmaktadır. Bu nedenle, geliştirilen bu matematik modellere alternatif olarak, arıtma tesislerinde son yıllarda daha genel olarak kullanım alanı olan ve sinir ağlarını temel alan yapay zeka teknikleri kullanılmaya başlanmış ve başarılı sonuçlar alınmıştır ( Cınar, O. Yılmaz, A. 2005).

Bu çalışmanın ( Cınar, O., Yılmaz, A., 2005) amacı, Adapazarı kentsel atık su arıtma tesisi verileri (Anonim, 2006) kullanılarak yapay sinir ağları (YSA) modeliyle BOİ, KOİ ve AKM çıkış değerlerini tahmin etmektir. Girdi olarak atık su sıcaklığı, pH, ortalama debi, KOİ giriş, AKM giriş ve BOİ giriş değerleri kullanılarak BOİ, KOİ ve AKM çıkış değerleri için modeller oluşturulmuş ve yaklaşık değerlere ulaşılmıştır. Yapılan çalışmalar sonucunda Adapazarı Kentsel Atık su Arıtma Tesisi verileri kullanılarak oluşturulan modellerden Çok Katmanlı Algılayıcı (CKA) modeli gerçek verilere oldukça iyi bir sonuçla uyum sağlamıştır. Verim formülü kullanılarak gerçek değerler ve programın bulduğu tahmini değerler için verim ayrı ayrı hesaplanmıştır.

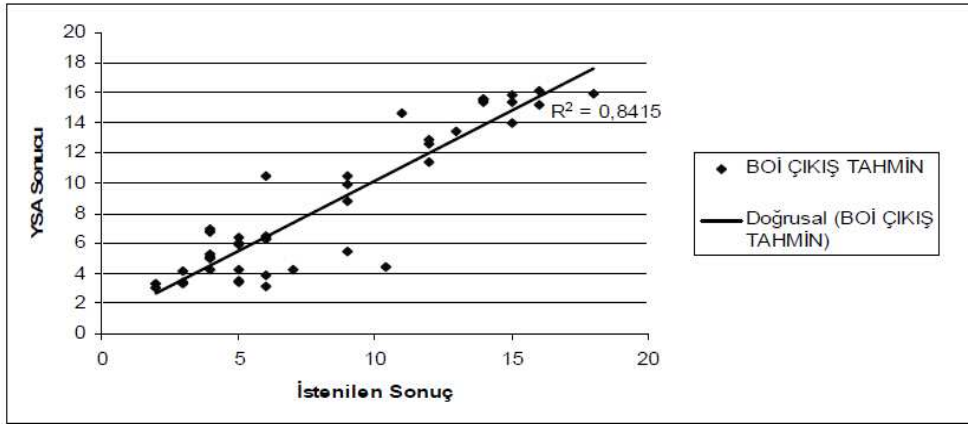
BOİ değerleri 5 günlük analiz sürecinde ölçülmüş olduğu için, yeterli veri sağlamak amacıyla 3 yıllık değerler kullanılmıştır. 2004, 2005 ve 2006 verilerinden elde edilen 123 verinin 80 adedi eğitim setinde, 43 adedi ise test setinde kullanılmıştır. Yapılan çalışmalarda optimum sonuca 65533 iterasyon değeri sonunda, iki gizli katman ve bir katmanda uç değerinde yedi işlem elemanı kullanılarak ulaşılmıştır. Grafiklerde karşılaştırılması yapılan YSA ile bulunan



tahmini (teorik) ve gerçek (deneysel) verim değerlerinin birbiriyle uyum içerisinde olduğu görülmüştür.



Şekil 2.4. BOİ Çıkış Değerleri İle Tahmin Değerlerinin Karşılaştırılması (Açıkalın, S., İleri, R. Keleş, R., 2006)



Şekil 2.5. YSA – İstenen Sonuçların BOİ Test Seti İçin x = y Grafiği Üzerinde Gösterimi (Açıkalın, S., İleri, R. Keleş, R., 2006)


### 2.3. Denizli (Merkez) Atıksu Arıtma Tesisi Performansının Yapay Sinir Ağları Kullanılarak Modellenmesi

Bu çalışmada (Pulcu Yıldız, 2009), Denizli ( Merkez) Atıksu Arıtma Tesisi (DMAA) performansı ayrıntılı olarak incelenerek, yapay sinir ağlarıyla ( YSA ) modelleme çalışmaları yapılmıştır. DMAA aktif çamur ünitesine sahip olup, tesis

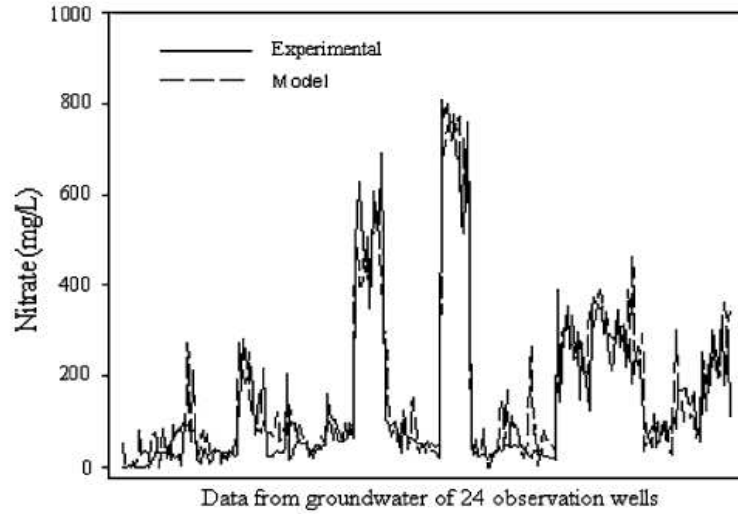
giriş ve çıkışında rutin olarak pH, sıcaklık, iletkenlik, biyokimyasal oksijen ihtiyacı (BOİ), kimyasal oksijen ihtiyacı ( KOİ ), toplam azot ve toplam fosfor analizleri yapılmıştır. Ayrıca, aktif çamur havalandırma havuzunda rutin olarak çözünmüş oksijen, askıda katı madde ( AKM ) ve çamur hacim indeksi ( ÇHİ ) ölçümleri yapılmıştır. Tesis çıkış KOİ, BOİ, toplam azot, toplam fosfat ve havalandırma havuzu ÇHİ değerleri YSA kullanılarak modellenmiştir. Her bir parametre için ilk olarak YSA giriş parametreleri belirlenmiştir. İkinci aşamada ise 12 öğrenme algoritması içinden en iyisi belirlenmiştir. Üçüncü aşamada ise, nöron sayısı optimize edilerek modellenen her bir parametre için en iyi YSA yapısı belirlenmiştir. YSA modellemesi ile oldukça iyi sonuçlar alınmış olup, çıkış KOİ, BOİ, toplam azot, toplam fosfat ve havalandırma havuzu ÇHİ parametreleri için ölçülen ve tahmin edilen parametreler arasındaki korelasyon katsayıları sırasıyla; 0.901, 0.832, 0.737, 0.751 ve 0.84 olarak bulunmuştur.

#### 2.4. Harran Ovasında Yer Altı Sularında Nitratın Yapay Sinir Ağları İle Tahmini

Bu çalışmada (Yesilnacar ve ark. 2008), Harran ovasında yer altı sularında nitrat tahmini için YSA modeli kullanılmıştır. Nitrat konsantrasyonunun tahmini için kolay ölçülebilen; sıcaklık, pH, iletkenlik, yer altı suyu seviyesi, gibi değerler kullanılmıştır. Nitrat konsantrasyonunun tahmini için Harran Ovasında belirlenen 24 gözlem kuyusundan numuneler alınmıştır.



Şekil 2.6.A= çıkış verileri T=hedeflenen veriler (Yesilnacar, M.I., ve ark., 2007)

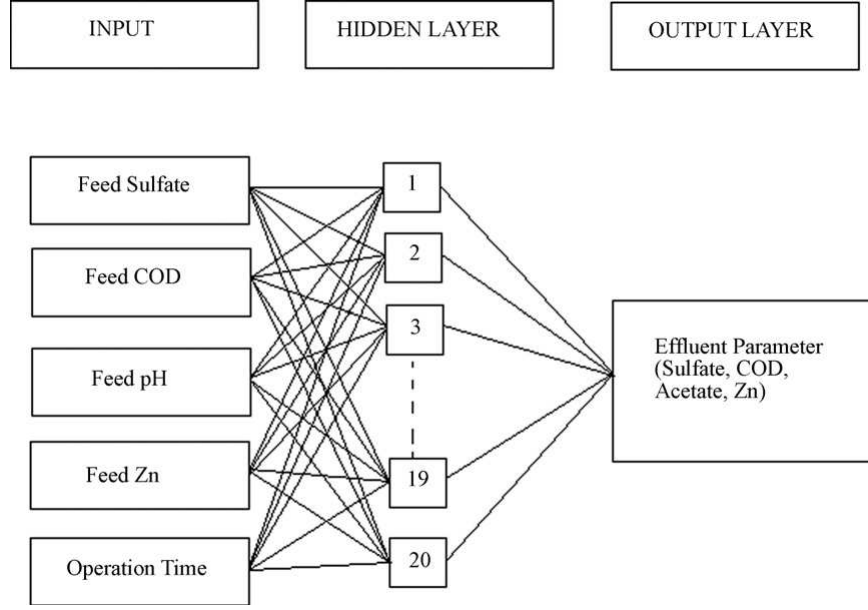


Şekil 2.7. Ölçülen ve YSA ile tahmin edilen nitrat konsantrasyonları (Yesilnacar, M.I., ve ark., 2007)

Bu çalışmada Harran Ovasındaki yer altı sularında YSA ile nitrat konsantrasyonu tahmini yapılmış ve yapılan çalışmalar sonucunda giriş parametresi olarak kullanılan veriler eşliğinde çıkış nitrat konsantrasyonu bulunmuştur. Yapılan çalışmada 12 adet BP algoritması arasından LM algoritması kullanılmış. Sonuç olarak YSA ile tahmin edilen nitrat konsantrasyonu ile ölçülen nitrat konsantrasyon değerlerinin birbirine çok yakın olduğu görülmüştür.

### 2.5. Çinko İçeren Atıksuların Tam Karışımli Sülfidojenik Tank Reaktörde (CSTR) Arıtım Performansının YSA ile modellenmesi

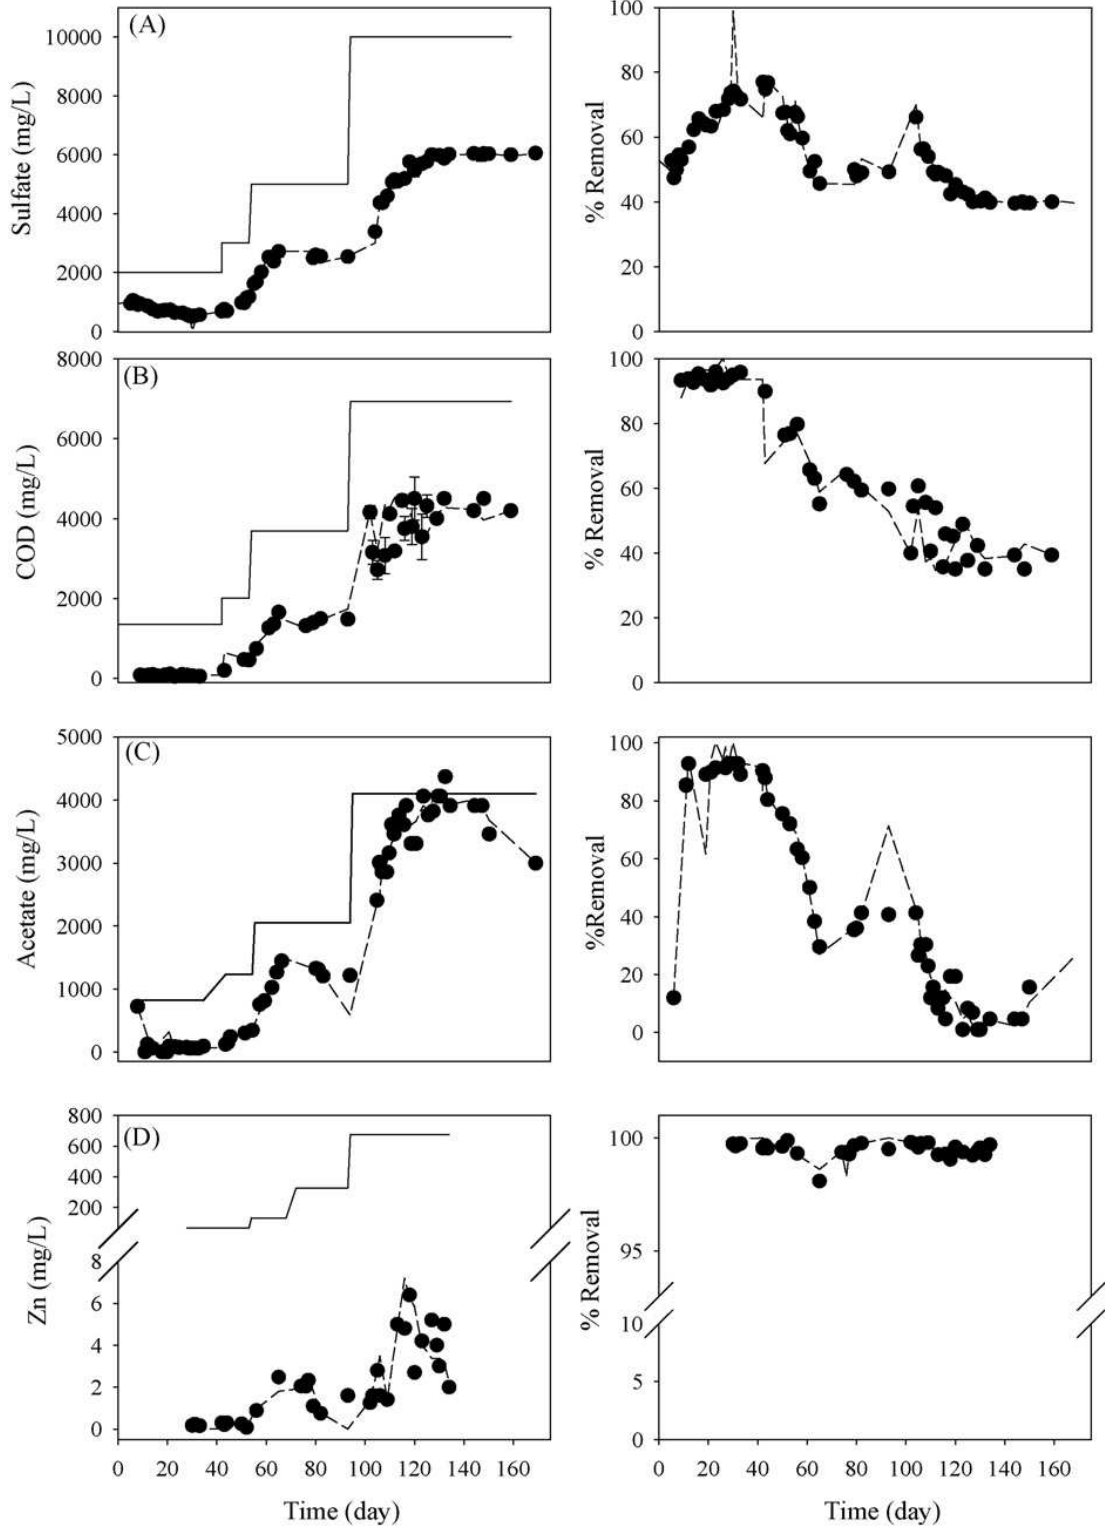
Bu çalışmada Sahinkaya (2009) tarafından (65- 677 mg/l) çinko ve (2- 10 mg/l) sülfat içerikli atıksuyun mezofilik (35 °C) şartlardaki CSTR'deki sülfidojenik arıtımı çalışılmıştır. Sülfat indirgeyen bakteriler için karbon ve elektron kaynağı olarak ortama elektron eklenmiştir. 2 g/l besin eklenmesi halinde sülfat giderimi % 70 iken; 10 gr/l besin eklenmesi durumunda sülfat giderim % 40' a düşmüştür. Çinko sülfür oluşumu nedeniyle % 99'un üzerinde çinko giderimi sağlanmıştır. Çalışmada yapay sinir ağları kullanılarak tahmin edilen değerler ile ölçülen değerlerin performans değerlendirilmesi yapılmaya çalışılmıştır. Modelleme için (Şekil 2.8.) çift katmanlı ağ modeli kullanılmıştır.



Şekil.2.8. CSTR çıkış parametrelerinin tahmini için kullanılan YSA ağ modeli  
( Şahinkaya, E., 2008)

Modelleme çalışması için; giriş sülfat, giriş KOİ, giriş pH, giriş çinko ve işletme zamanı olarak toplam 6 adet input parametresi kullanılmıştır. Kullanılan bu input parametreleri yardımı ile çıkış sülfat, KOİ, asetat ve Zn output parametreleri olarak tahmin edilmeye çalışılmıştır.

Yapılan çalışmalar sırasında elde edilen veriler training, validation ve test olmak üzere 3 bölümde kullanılmıştır. MSE değerleri kıyaslanarak 12 adet back propagation algoritması arasından en iyisi seçilmeye çalışılmış ve en iyi algoritma olarak trainlm bulunmuştur. En iyi algoritmanın seçilmesinden sonra en iyi nöron numarasının tespiti yapılmış KOİ, sülfat ve asetat için nöron numarası 20, çinko için ise 40 olarak bulunmuştur.



Şekil.2.9. Sülfat (A), KOİ (B), Asetat (C) ve Çinko (D) giderim performansı. Çizgiler ve noktalar sırasıyla giriş ve çıkış konsantrasyonlarını; kesikli çizgiler ise YSA tahmin modellemesini göstermektedir. Asetat giriş konsantrasyonu, etanolün asetata oksidasyonu esas alınarak hesaplanmıştır( Şahinkaya, E., 2008)

Yapılan tüm çalışmalar sonrasındaki R değerleri sülfat asetat KOİ ve çinko için sırası ile (Şekil.2.10.) 0.998, 0.993, 0.976 ve 0.827 olarak bulunmuştur. Bu sonuçlardan da anlaşılıyor ki tahmin edilen ve ölçülen değerler arasında çok büyük benzerlik olup modelleme çalışması oldukça iyi sonuç vermiştir.

### **3. MATERYAL VE YÖNTEM**

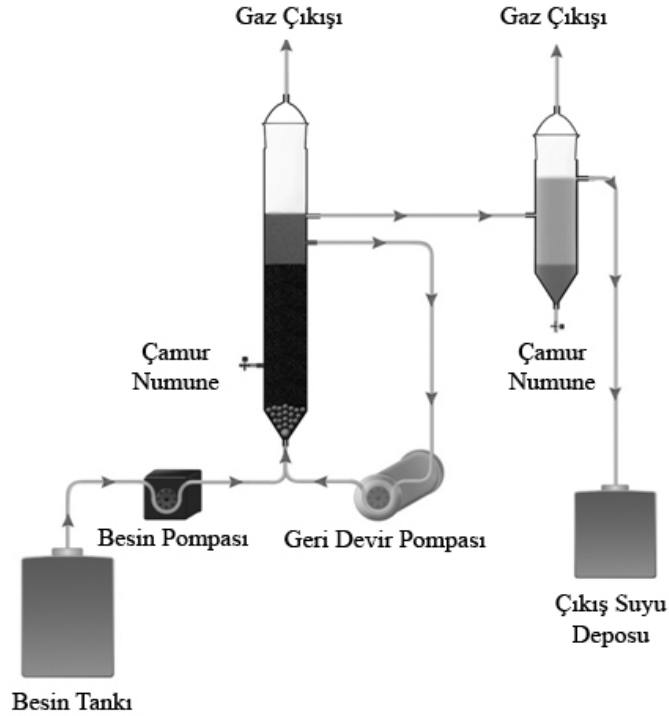
AMS arıtımı yapılan laboratuvar ölçekli 3 çeşit sülfidojenik akışkan yataklı reaktör sistemleri tanıtılmıştır.

#### **3.1. Sülfidojenik Yukarı Akışlı Akışkan Yataklı Reaktör (R1)**

Bu çalışmada, evsel nitelikli atıksu arıtma tesisindeki anaerobik çürütücünün çıkışından aşılanmış laboratuvar ölçekli bir akışkan yataklı reaktör (AYR) (Şekil 3.1.) kullanılmıştır. AYR sıcaklık kontrollü bir odada 35 °C`de işletilmiştir. Biyokütle taşıyıcısı olarak zeolit (0,5-1 mm partikül boyutlarında) kullanılmıştır. Taşıyıcı yatak akışkanlığı yüksek geri devirde yaklaşık %15–20 civarında olup, aktif akışkan yatak hacmi yaklaşık 300 mL`dir. AYR reaktör değişik konsantrasyonlarda laktat ve sülfatın bulunduğu (Çizelge 3.1.), çeşitli nütrientler (Bayrakdar ve ark. 2009) içeren sentetik atıksu ile beslenmiştir. SİB`ler için elektron ve karbon kaynağı olarak laktat kullanılmıştır. KOİ/sülfat oranı 0.67 ve 1.0 arasında değişmiştir (periyot 5-7). Besin çözeltisi buzdolabında 4 °C`de tutulmuştur. KOİ giderimi, sülfat indirgeme, Cu ve Zn`de çökme giriş besininde gözlemlenmemiştir.

Çizelge 3.1. R1 için periyodik olarak işletme koşulları

Parametreler	Periyotlar									
	1	2	3	4	5	6	7	8	9	10
Günler	0-15	15-60	60-88	88-110	110-150	150-180	180-208	208-220	220-239	239-250
Besin Sülfat Konsantrasyonu (mg/L)	1000	2000	2000	2000	2000	2000	2000	2000	2000	2000
Besin Laktat Konsantrasyonu (mg KOİ/L)	670	1340	1340	1340	1340	1700	2000	1700	1700	2000
Hidrolik Bekletme Süresi, HRT (saat)	12	12	12	12	12	12	12	24	24	24
Besin pH	7	6-7	5,5	5	5	5	5	4	3,5-4	2-2,5
KOİ/SO <sub>4</sub>	0,67	0,67	0,67	0,67	0,67	0,85	1	0,85	0,85	0,85
Besin Cu Konsantrasyonu (mg/L)	-	-	12,5-50	75	100	100	100	100	150	150
Besin Zn Konsantrasyonu (mg/L)	-	-	12,5-50	75	100	100	100	100	150	150



Şekil 3.1. Çalışmada kullanılan yukarı akışlı akışkan yataklı reaktör



Sülfidojenik akışkan yataklı reaktör (AYR)'ün 250 gün boyunca farklı besin pH'ları ve çeşitli sülfat, laktat ve metal yüklemelerindeki performansı değerlendirilmiştir (Çizelge 3.1.), Reaktör ilk olarak SİB'lerin gelişmesi için 1000-2000 mg/L  $SO_4^{2-}$  içeren, metalsiz ve alkali bir çözelti ile beslenmiştir (Periyot 1, 0-45 gün arası). Daha sonra, giriş pH'sı azaltılarak ve metal yüklemeleri arttırılarak reaktör performansı değerlendirilmiştir (Çizelge 3.1.), 5. ve 7. periyotlar arasında ise KOİ/sülfat oranının reaktör performansı üzerindeki etkisi değerlendirilmiştir. Reaktör giriş ve çıkışlarından haftada 3-4 kez numune alınarak pH, alkalinite, toplam uçucu yağ asidi (UYA), kimyasal oksijen ihtiyacı (KOİ), sülfat, çözünmüş sülfür, çözünebilir ve toplam metal (Zn ve Cu) deneyleri yapılmıştır. Numuneler geri devir hattından alınarak analizler yapılmıştır.

Sülfat, çözünmüş sülfür, çözünmüş metal (Zn ve Cu) ve KOİ ölçümleri için alınan numuneler Hettich Rotofix 32 cihazı kullanılarak 4000 rpm'de 10 dakika santrifüj edilmiştir. Toplam sülfür ölçümü CORD-RUWISCH (1985) tarafından tanımlanan metot doğrultusunda, Shimadzu UV-1601 Spectrophotometer cihazı kullanılarak spektrofotometrik yöntem ile yapılmıştır. Sülfat ölçümü için turbidimetrik bir metot kullanılmıştır. KOİ ve alkalinite ölçümleri standart metotlara uygun olarak yapılmıştır. KOİ ölçümlerinden önce numunelerin pH'sı konsantre  $H_2SO_4$  kullanılarak pH=2 seviyesinin altına düşürülmüştür ve numunelerin içinden 5 dakika boyunca  $N_2$  gazı geçirilerek numunelerdeki  $H_2S$  giderilmiştir. Toplam uçucu yağ asidi (UYA) ölçümleri Alvarez ve ark. (2007) tarafından tanımlanan yöntem doğrultusunda ölçülmüştür. HCl ilave edilmiş numunelerin asetat ölçümleri için 30 m x 0.25 mm (ID) x 0.50  $\mu m$  (film) FFAP kapiler kolon ve alev iyonlaştırıcı dedektör içeren bir gaz kromatografisi (Varian 3900GC) kullanılmıştır. Çözünmüş Zn ve Cu ölçümleri için numuneler 0.45  $\mu m$  polyethersulfone membran şırınga filtreler ile süzöldükten sonra konsantre HCl ile pH= 2'nin altına düşürülmüştür. Toplam Zn ve Cu ölçümleri için numuneler önce konsantre HCl ile asitlenerek Zn ve Cu partikülleri çözünmüş hale getirilmiş, daha sonra numuneler 0.45  $\mu m$  filtrelerden geçirilerek biyokütle ve diğer partiküller giderilmiştir. Metal konsantrasyonları atomik absorpsiyon spektrofotometre (Varian AA 140) cihazı kullanılarak ölçülmüştür. Panalytical Axios-Advanced dalga boyu dağıtıcılı X-ışını floresansı spektrofotometre

(XRF) kullanılarak reaktör işletme süresinin sonunda (245. gün) reaktörden alınan çamur örneklerinin elemental kompozisyonuna bakılmıştır. Bu ölçüm için Erciyes Üniversitesi, Merkezi Laboratuvar'ından hizmet alımı yapılmıştır.

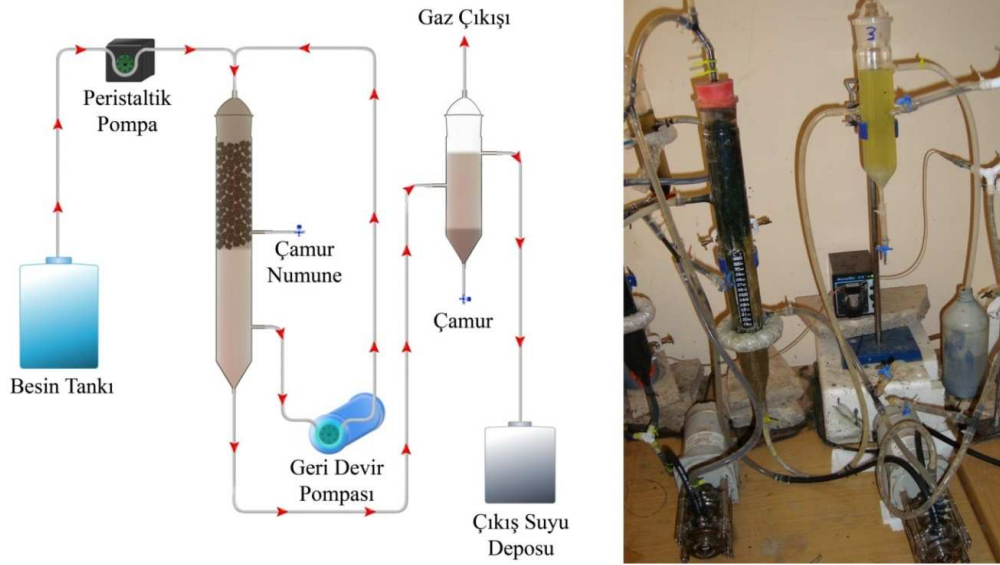
Bütün ölçümler en az iki paralel olacak şekilde yapılmıştır.

### **3.2. Sülfidojenik Aşağı Akışlı Akışkan Yataklı Reaktör (R2)**

Aşağı akışlı AYR'lerde, taşıyıcı malzeme sudan hafif olduğu için suyun üst kısmında yüzer ve sıvının aşağı yönde geri devredilmesiyle taşıyıcı malzeme akışkan hale getirilir (Celis-Garcia ve ark. 2007). Bu çalışmada aşağı akışlı AYR ile AMS arıtım performansı ilk kez incelenmiş ve metal geri kazanımı çalışılmıştır. R2'de taşıyıcı malzeme olarak, hammaddesi polieter olan sünger kullanılmıştır. Polieter süngerler ortalama 1 cm'lik büyüklüklerde kesilmiş olup, reaktör içerisindeki aktif biyokütle için taşıyıcı ortam oluşturmaktadır. Reaktör 5 cm çapında, 40 cm uzunluğunda cam malzemedendir yapılmıştır (Şekil 3.2.). Reaktörün tamamı su ile dolu olup, hacmi 1 L'dir. Ayrıca reaktör çıkışında hacmi 250 ml olan çökeltme tankı mevcuttur. Reaktöre beslenen sentetik atıksu debisi 670 ml/gün'dür. Reaktördeki taşıyıcı malzeme hacmini esas alarak hesaplanan hidrolik bekleme süresi (HRT) 12 saattir. Reaktörde elektron ve karbon kaynağı olarak laktat kullanılmıştır. AAYR1'in, 200 gün süresince işletilmesi sırasında 8 farklı işletme koşulu oluşturulmuştur (Çizelge 3.2.).

Çizelge 3.2. R2 için periyodik olarak işletme koşulları

Parametre	PERİYOTLAR							
	1	2	3	4	5	6	7	8
Günler	0-14	15-59	60-87	88-110	110-149	150-179	180-196	197-200
Giriş Sülfat (mg/L)	1000	2000	2000	2000	2000	2000	2000	2000
Giriş Laktat (mg KOİ/L)	670	1340	1340	1340	1340	1700	2000	2500
Giriş pH	7	6	5,5	5	5	5	5	5
KOİ/Sülfat	0,67	0,67	0,67	0,67	0,67	0,85	1	1,25
Giriş Metal Çinko + Bakır (mg/L)	-	-	25 – 100	150	200	200	200	200



Şekil 3.2. AAYR-1'in şematik gösterimi ve fotoğrafı

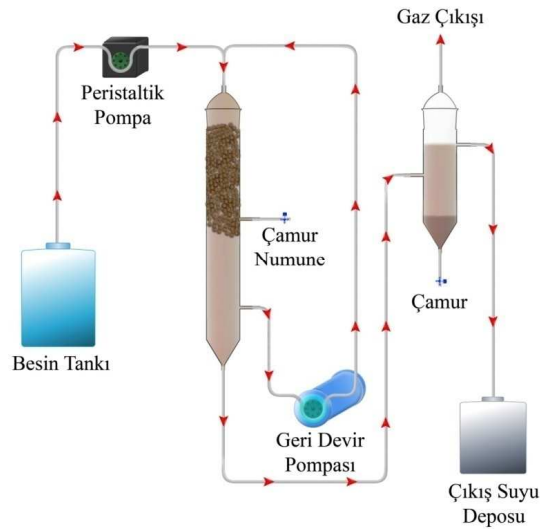
### 3.3. Sülfidojenik Aşağı Akışlı Akışkan Yataklı Reaktör (R3)

R3'de taşıyıcı malzeme olarak, hammaddesi poliüretan olan köpük kullanılmıştır. Poliüretan köpükler ortalama 5 mm'lik büyüklüklerde olup, reaktör içerisindeki aktif biyokütle için taşıyıcı ortam oluşturmaktadır. Reaktör 5 cm çapında, 40 cm uzunluğunda cam malzemeden yapılmıştır (Şekil 3.3.). Reaktörün tamamı su ile dolu olup, hacmi 1 L'dir. Ayrıca reaktör çıkışında hacmi 250 ml olan

çökeltme tankı mevcuttur. Reaktör debisi 540 ml/gün olan sentetik atıksu ile beslenmiştir. Taşıyıcı malzeme hacmini esas alarak hesaplanan hidrolik bekleme süresi (HRT) 16 saattir. Reaktörde elektron ve karbon kaynağı olarak laktat kullanılmıştır. AAYR2’de 200 gün süresince işletilmesi sırasında 8 farklı işletme koşulu oluşturulmuştur (Çizelge 3.3.).

Çizelge 3.3. R3 için periyodik olarak işletme koşulları

Parametre	PERİYOTLAR							
	1	2	3	4	5	6	7	8
Günler	0-14	15-59	60-87	88-110	110-149	150-179	180-196	197-200
Giriş Sülfat (mg/L)	1000	2000	2000	2000	2000	2000	2000	2000
Giriş Laktat (mg KOİ /L)	670	1340	1340	1340	1340	1700	2000	2500
KOİ/Sülfat	0,67	0,67	0,67	0,67	0,67	0,85	1	1,25
Giriş pH	7	6	5,5	5	5	5	5	5
Giriş Metal Çinko + Bakır (mg/L)	-	-	25 – 100	150	200	200	200	200



Şekil 3.3. AAYR-2'in şematik gösterimi ve fotoğrafı

Çalışma boyunca pH, giriş metal konsantrasyonları ve KOİ/SO<sub>4</sub> oranları farklı değerlerde çalışılmıştır (Çizelge 3.2. ve Çizelge 3.3.). Reaktörler ilk 15 gün boyunca 1000 mg/L sülfat ve 670 mg/L KOİ içeren, metalsiz sentetik atıksu ile beslenmiş ve SİB'lerin gelişmelerini arttırmak amacıyla 15.-60. günler arasında 2000 mg/L sülfat ve 1340 mg/L KOİ içeren sentetik atıksu ile beslemeye devam edilmiştir. 60. Gün itibariyle bakterilerin ortamdaki gelişmesine bağlı olarak sentetik atıksuya farklı zamanlarda 25, 50, 100, 150 ve 200 mg/L Cu ve Zn karışımı ilave edilmiştir. Tüm çalışma boyunca reaktöre eklenen Cu ve Zn konsantrasyonları eşittir. Yani reaktörde toplam metal konsantrasyonu 100 mg/L ise; bunun 50 mg/L si Zn, 50 mg/L si de Cu'dur. Reaktörlerden haftada 3-4 kez numuneler alınarak deneyler yapılmıştır.

Reaktörlerden; sülfür, sülfat, KOİ, alkalinite ve uçucu yağ asidi deneylerini gerçekleştirmek amacıyla günde toplam 40 ml numune ağzı kapalı cam tüplere alınmıştır. Alınan numunelerde öncelikle sülfürün uçmasını engellemek amacıyla, NaOH ile numunelerin pH'sı 10 seviyesine getirilmiştir. Reaktörlerden alınan numuneler 4000 rpm'de 10 dakika santrifüj edilmiştir (Alkalinite ve UYA deneyleri hariç). Sülfat ölçümü için standart metotlarda verilen bulanıklık yöntemi ve iyon kromatografisi kullanılmıştır. Toplam uçucu yağ asidi ölçümü için Alvarez ve ark. (2007) tarafından tavsiye edilen metot kullanılmıştır. KOİ ve alkalinite ölçümü için yine standart metotlardaki yöntemler kullanılmıştır. KOİ ölçümünden önce, numunelerin pH değeri 2'nin altına düşürülerek, numunelerin içerisinden N<sub>2</sub> gazı geçirilmiştir. Böylece numunelerde bulunan sülfür uzaklaştırılmıştır. Çözünmüş çinko ve bakır ölçümlerinde ise; numuneler ilk olarak 0.45 µm gözenek çapına sahip filtrelerden geçirilmiş ve daha sonra HCl asit ile pH=2'nin altına düşürülmüştür. Toplam çinko ve bakır ölçümlerinde ise; numuneler önce HCl ile asitlenmiş ve pH'sı 2'nin altına düşürülmüş, daha sonra 0,45 µm gözenek çapına sahip filtrelerden geçirilmiştir. Çözünmüş metal konsantrasyonları atomik absorpsiyon spektrofotometre (Varian AA 140) cihazı kullanılarak ölçülmüştür. pH ölçümleri, proje kapsamında alımı yapılan HACH (Sension 156) marka pH metre kullanılarak yapılmıştır.

### 3.2. Çalışmada Kullanılan YSA'nın Yapısının Belirlenmesi

Bu çalışmada, akışkan yataklı reaktör performanslarının yapay sinir ağları ile modellenmesi gerçekleştirilmiştir. AMS arıtan yukarı akışlı akışkan yataklı reaktör (R1) ile aşağı akışlı akışkan yataklı reaktörler (R2 ve R3) için “işletme süresi, giriş pH, çıkış pH, giriş sülfat, giriş kimyasal oksijen ihtiyacı (KOİ) ve giriş metal” olmak üzere toplam 6 input parametresini kullanarak; “çıkış sülfat, çıkış KOİ, çıkış alkalinite ve çıkış sülfür” konsantrasyonları YSA ile tahmin edilmeye çalışılmıştır. Bu amaçla, 2 senaryo üzerinde çalışılmıştır (Çizelge 3.4.). İlkinde çıkış pH değeri input parametreleri içerisinde yer alırken (Senaryo-1); ikinci senaryoda (Senaryo-2) çıkış pH değeri input parametreleri arasından çıkarılmış ve YSA ile reaktör performansları modellenmiştir. Senaryo-2 ile, AMS arıtımı amaçlı kullanılacak olan bir reaktör henüz kurulmadan performansının tahmin edilmesi hedeflenmektedir.

YSA ile yukarı akışlı AYR performansının modellenmesinde işletim süresi giriş parametreleri arasında yer almıştır. Bunun sebebi ise, reaktör işletimi süresince bakteriyel komünite değişmekte ve böylece yeni işletim şartlarına adapte olmaktadır. Dolayısıyla, işletim süresinin giriş parametrelerinin arasında yer almasıyla, aklımasyon ve kültür değişimlerinden doğan değişimler modellemeye dahil edilmiş olabilir.

Çalışmada ilk olarak her bir parametre tahmini için optimum YSA yapısının belirlenmesi hedeflenmiştir. Bu amaçla, ilk olarak öğrenme algoritması optimizasyonu yapılmış olup, nöron sayısı 20’de sabit tutulmuştur. Nöron sayısının optimizasyonunda ise, en iyi sonucu veren öğrenme algoritması kullanılarak, farklı nöron sayılarında elde edilen sonuçlar karşılaştırılmış ve optimum nöron sayısına karar verilmiştir.

Çizelge 3.4. YSA ile Yukarı ve Aşağı Akışlı AYR performanslarının belirlenmesinde kullanılan senaryolar ve çıkış parametreleri

Giriş (input parametreleri)		Çıkış Parametreleri
Senaryo-1	Senaryo-2	
İşletme süresi (gün)	İşletme süresi (gün)	Çıkış Sülfat (mg/L)
Giriş pH	Giriş pH	Çıkış KOİ (mg/L)
Giriş KOİ (mg/L)	Giriş KOİ (mg/L)	Çıkış alkalinite (mg/L)
Giriş sülfat (mg/L)	Giriş sülfat (mg/L)	Çıkış sülfür (mg/L)
Giriş metal (mg/L)	Giriş metal (mg/L)	
Çıkış pH		

### 3.3. YSA Giriş ve Çıkış Parametrelerinin Seçilmesi

Reaktörlerden elde edilen günlük veriler kullanılacaktır. Elde edilen veriler değerlendirilerek, tahmini yapılacak çıkış parametrelerine karar verilecektir. Tahmin edilecek çıkış parametrelerinin belirlenmesi oldukça önemlidir. Giriş parametresi seçerken dikkat edilecek hususlar; parametrenin kolay ölçülebilir olması hatta mümkünse online olarak prop ile ölçümünün gerçekleştirilebilmesidir. Kolay ölçülmesinin yanında doğru ölçüm yapılabilmesi ve reaktör çıkış parametrelerinin tahmininde iyi sonuç vermesi önemlidir. Bu kıstaslar göz önüne alınarak, farklı parametreler giriş verisi olarak kullanılarak modelleme işlemi yapılacaktır. Bu aşamada YSA yapısı sabit tutularak sadece giriş parametreleri değiştirilecek ve elde edilen en uygun sonuca göre giriş parametrelerine karar verilecektir.

### 3.4. Backpropagation Algoritmasının Seçilmesi

Bu çalışmada 12 farklı back-propagation algoritması seçilerek birbiriyle kıyaslanacaktır. İlk aşamada nöron sayısı 20 olarak sabit tutulup back-propagation algoritmaları değiştirilecektir. Elde edilen sonuçlar neticesinde en iyi algoritma seçilecektir.

### **3.5. En İyi Nöron Sayısının Seçilmesi**

İkinci aşamada ise bulunan en iyi algoritma sabit tutulup nöron sayıları 3, 5, 10, 30 ve 40 olmak üzere tek tek denenerek en iyi nöron sayısı tespit edilecektir. En iyi algoritma ve nöron sayısı belirlenirken R değerleri dikkate alınacaktır. Bu değerleri içerisinde en yüksek olan en iyi sonuç olarak değerlendirilecektir.



## 4.ARAŞTIRMA BULGULARI VE TARTIŞMA

### 4.1. Yukarı Akışlı Akışkan Yataklı Reaktör (R1) Çıkış Değerlerinin YSA ile Tahmin Edilmesi

Bu kısımda, AMS arıtan yukarı akışlı akışkan yataklı reaktör (R1) den elde edilen veriler olan; “işletme süresi, giriş pH, çıkış pH, giriş sülfat, giriş kimyasal oksijen ihtiyacı (KOİ) ve giriş metal” olmak üzere toplam 6 input parametresi kullanılarak; “çıkış sülfat, çıkış KOİ, çıkış alkalinite ve çıkış sülfür” konsantrasyonları YSA ile tahmin edilmeye çalışılmıştır. Bu amaçla, 2 senaryo üzerinde çalışılmıştır (Çizelge 4.1, Çizelge 4.2, Çizelge 4.3, Çizelge 4.4). İlkinde çıkış pH değeri input parametreleri içerisinde yer alırken (Senaryo-1); ikinci senaryoda (Senaryo-2) çıkış pH değeri input parametreleri arasından çıkarılmış ve YSA ile reaktör performansının modellenmesine çalışılmıştır. Senaryo-2 ile AMS arıtımı amaçlı kullanılacak olan bir reaktör henüz kurulmadan performansının tahmin edilmesi hedeflenmektedir.

Çizelge 4.1. Senaryo-1'e göre Reaktör-1 çıkış değerleri için çeşitli öğrenme algoritmalarının kıyaslanması (nöron 20)

BP Algoritm		Trainlm	Traincgp	Traingd	Trainгда	Traingdх	Trainrp	Trainscg	Trainoss	Traincgf	Trainbfg	Traingdm	Traincgb
Sülfat	T-R	0.99	0.42	0.95	0.93	0.93	0.98	0.97	0.70	0.02	0.42	0.46	0.09
	V- R	0.86	0.91	0.92	0.87	0.87	0.94	0.93	0.92	0.96	0.90	0.59	0.92
	Tt-R	0.92	0.83	0.88	0.86	0.86	0.91	0.88	0.90	0.90	0.85	0.15	0.91
	A-R	0.94	0.54	0.91	0.89	0.89	0.94	0.93	0.69	0.45	0.55	0.41	0.31
KOl	T-R	0.99	0.60	0.97	0.96	0.71	0.98	0.97	0.01	0.40	0.55	0.55	0.37
	V- R	0.85	0.82	0.84	0.87	0.67	0.86	0.84	0.85	0.84	0.85	0.54	0.81
	Tt-R	0.93	0.91	0.94	0.95	0.43	0.92	0.93	0.93	0.94	0.95	0.14	0.90
	A-R	0.95	0.47	0.93	0.94	0.62	0.94	0.93	0.36	0.59	0.01	0.36	0.15
Alkalinite	T-R	0.99	0.15	0.95	0.96	0.98	0.99	0.96	0.32	0.27	0.49	0.15	0.47
	V- R	0.89	0.95	0.88	0.91	0.94	0.94	0.91	0.91	0.94	0.87	0.11	0.95
	Tt-R	0.92	0.95	0.95	0.94	0.93	0.96	0.82	0.93	0.93	0.92	0.03	0.90
	A-R	0.94	0.22	0.93	0.94	0.95	0.97	0.92	0.49	0.30	0.10	0.08	0.41
Sülfür	T-R	1	0.05	0.95	0.94	97	0.99	0.97	0.73	0.45	0.56	95	0.09
	V- R	0.87	0.90	0.91	0.91	0.88	0.95	0.89	0.91	0.90	0.93	0.91	0.91
	Tt-R	0.88	0.90	0.90	0.86	0.91	0.96	0.90	0.92	0.94	0.95	0.92	0.90
	A-R	0.94	0.23	0.92	0.92	0.94	0.98	0.93	0.45	0.12	0.68	0.93	0.22

Çizelge 4.2. Senaryo 1'e göre her bir out-put parametresi ( Reaktör-1) için farklı nöron sayılarında elde edilen tahminlerin kıyaslanması

Nöron sayısı		3	5	10	20	30	40
Sülfat (trainrp)	T-R	0.94	0.96	0.99	0.98	0.99	0.99
	V- R	0.91	0.90	0.85	0.94	0.84	0.78
	Tt-R	0.91	0.86	0.90	0.91	0.80	0.72
	A-R	0.92	0.91	0.93	0.94	0.90	0.85
Koi (trainlm)	T-R	0.95	0.94	0.98	0.99	1	0.99
	V- R	0.82	0.79	0.84	0.85	0.89	0.86
	Tt-R	0.89	0.91	0.91	0.93	0.91	0.94
	A-R	0.90	0.89	0.93	0.95	0.95	0.94
Alkalinite (trainrp)	T-R	0.95	0.98	0.97	0.99	0.99	0.99
	V- R	0.91	0.93	0.95	0.94	0.92	0.93
	Tt-R	0.90	0.94	0.95	0.96	0.93	0.92
	A-R	0.92	0.95	0.96	0.97	0.96	0.96
Sülfür (trainrp)	T-R	0.93	0.96	0.98	0.99	0.99	0.95
	V-R	0.91	0.89	0.94	0.95	0.92	0.91
	Tt-R	0.84	0.94	0.94	0.96	0.90	0.92
	A-R	0.90	0.94	0.96	0.98	0.95	0.94

Çizelge 4.3.Senaryo-2'ye göre Reaktör-1 çıkış değerleri için çeşitli öğrenme algoritmalarının kıyaslanması (nöron 20)

BP Algorithms		Trainlm	Traincgp	Traingd	Traingda	Trainidx	Trainrp	Trainscg	Trainoss	Traincgf	Trainbfg	Traingdm	Traincgb
Sülfat	T-R	0.99	0.23	0.90	0.92	0.85	0.96	0.96	0.22	0.33	0.52	0.14	0.54
	V- R	0.90	0.94	0.83	0.85	0.80	0.89	0.90	0.91	0.92	0.89	0.14	0.82
	Tt-R	0.81	0.80	0.81	0.79	0.67	0.84	0.83	0.89	0.82	0.87	0.42	0.71
	A-R	0.92	0.30	0.86	0.86	0.79	0.91	0.91	0.39	0.18	0.91	0.22	0.02
KOİ	T-R	1	0.35	0.98	0.98	0.99	0.99	0.99	0.14	0.36	0.05	0.66	0.05
	V- R	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.99	0.62	0.99
	Tt-R	0.94	0.94	0.94	0.92	0.93	0.96	0.94	0.93	0.94	0.94	0.69	0.95
	A-R	0.98	0.16	0.98	0.97	0.97	0.98	0.98	0.18	0.56	0.58	0.61	0.53
Alkalinite	T-R	0.99	0.22	0.95	0.96	0.97	0.98	0.98	0.53	0.30	0.12	0.95	0.62
	V- R	0.95	0.96	0.94	0.94	0.95	0.97	0.96	0.94	0.95	0.95	0.94	0.95
	Tt-R	0.96	0.95	0.92	0.94	0.92	0.96	0.91	0.93	0.94	0.95	0.92	0.94
	A-R	0.97	0.29	0.94	0.94	0.95	0.97	0.96	0.67	0.27	0.18	0.94	0.08
Sülfür	T-R	1	0.19	0.94	0.95	0.98	0.98	0.98	0.32	0.08	0.73	0.19	0.56
	V- R	0.87	0.94	0.88	0.92	0.92	0.93	0.92	0.94	0.89	0.92	0.09	0.85
	Tt-R	0.88	0.90	0.90	0.90	0.95	0.93	0.90	0.92	0.78	0.93	0.06	0.89
	A-R	0.94	0.15	0.92	0.92	0.96	0.96	0.95	0.47	0.27	0.44	0.06	0.02

Çizelge 4.4. Senaryo-2'ye göre her bir out-put parametresi (Reaktör-1) için farklı nöron sayılarında elde edilen tahminlerin kıyaslanması

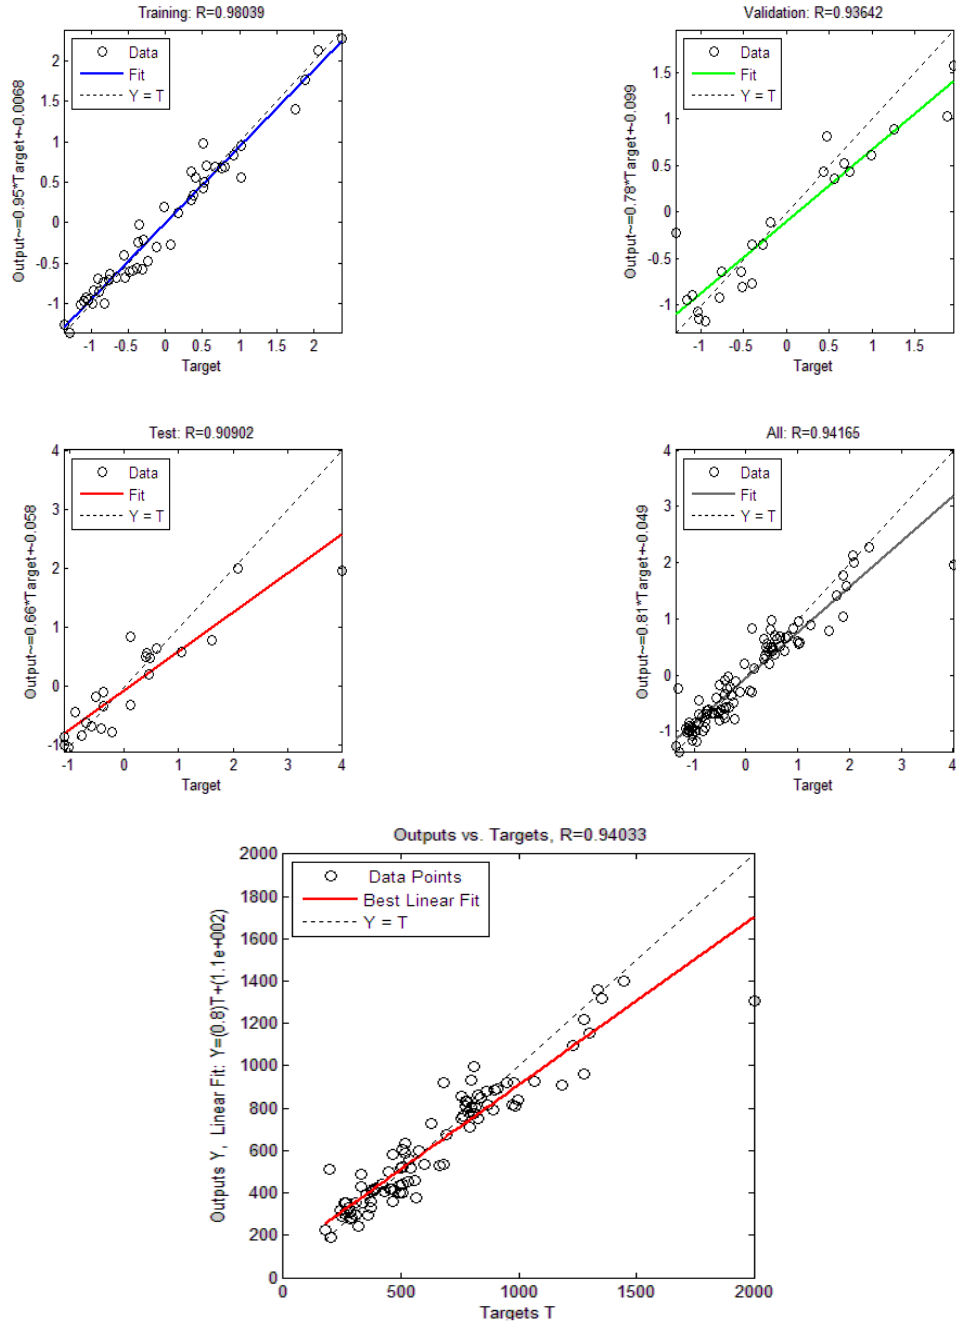
Nöron sayısı		3	5	10	20	30	40
Sülfat (trainlm)	T-R	0.95	0.98	0.99	0.99	0.99	0.99
	V-R	0.70	0.91	0.97	0.90	0.92	0.92
	Tt-R	0.63	0.87	0.88	0.81	0.66	0.78
	A-R	0.81	0.93	0.95	0.92	0.89	0.92
KOİ (trainrp)	T-R	0.92	0.96	0.97	0.99	0.99	0.99
	V-R	0.85	0.92	0.93	0.95	0.94	0.92
	Tt-R	0.90	0.93	0.93	0.95	0.93	0.94
	A-R	0.90	0.94	0.95	0.97	0.96	0.96
Alkalinite (trainlm)	T-R	0.42	0.47	0.98	0.98	0.99	0.98
	V-R	0.42	0.69	0.93	0.92	0.96	0.92
	Tt-R	0.35	0.12	0.95	0.91	0.97	0.96
	A-R	0.31	0.42	0.96	0.96	0.98	0.96
Sülfür (traingdx)	T-R	0.42	0.47	0.98	0.98	0.98	0.98
	V-R	0.42	0.69	0.93	0.92	0.95	0.92
	Tt-R	0.35	0.12	0.95	0.95	0.96	0.96
	A-R	0.31	0.42	0.96	0.96	0.97	0.96

#### 4.1.1. Çıkış sülfat değerlerinin tahmin edilmesi

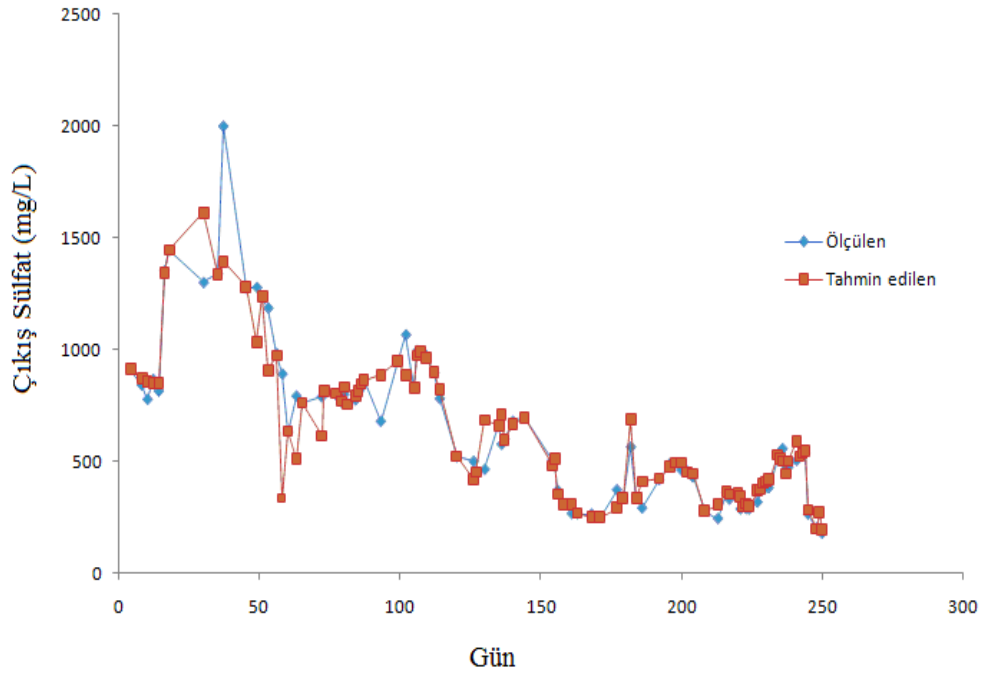
Öncelikle senaryo-1 için (çıkış pH'nın input olarak kullanılması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Yapılan

karşılaştırmalar sonucunda Çizelge 4.1.'den de görüldüğü üzere çıkış sülfat tahmininde en iyi öğrenme algoritması trainrp olarak tespit edilmiştir.

En iyi öğrenme algoritmasının seçilmesinden sonra, YSA yapısının optimize edilmesi için optimum nöron sayısının bulunması amacıyla çalışmalar yapılmıştır. Öğrenme algoritması trainrp'de sabit tutularak sadece nöron sayısı 3, 5, 10, 30 ve 40 olarak değiştirilmiş ve elde edilen sonuçlar Çizelge 4.2.'de sunulmuştur. Buna göre optimum nöron sayısı trainrp için 20 bulunmuştur. Ölçülen ve tahmin edilen değerler arasında öğrenme, doğrulama ve test grafiklerinde yüksek korelasyon sabitleri ( $R > 0,86$ ) bulunmuştur (Şekil 4.1.). Tüm sonuçları (öğrenme-doğrulama-test) temsil eden (all) R değeri 0.94 olarak belirlenmiştir (Çizelge 4.2.). Elde edilen sonuçların daha iyi yorumlanabilmesi için ölçülen değerler ile tahmin edilen değerler reaktör işletme zamanına göre aynı şekilde (Şekil 4.2.) gösterilmiştir. Şekil'den de görüldüğü gibi çıkış sülfat değerleri optimize edilen YSA ile oldukça iyi bir şekilde tahmin edilebilmiştir.



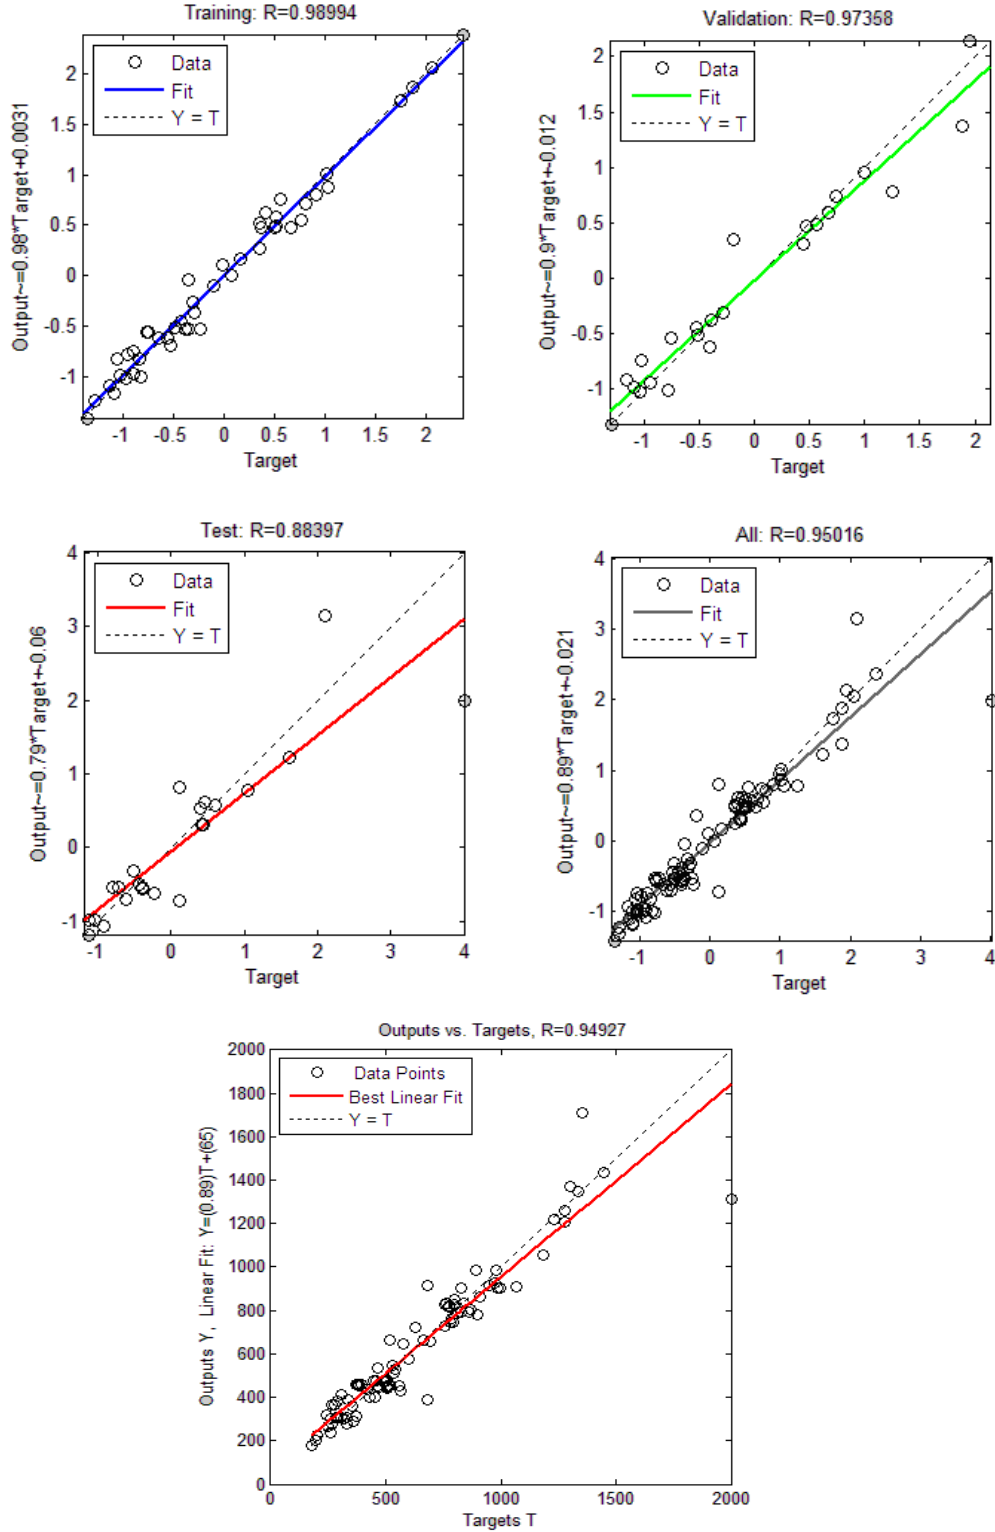
Şekil 4.1. Senaryo-1'e göre Reaktör-1 çıkış sülfat tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)



Şekil 4. 2. Senaryo-1'e göre (Reaktör -1) çıkış Sülfat için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması


Senaryo-2 input verileri, “giriş pH, giriş sülfat, giriş kimyasal oksijen ihtiyacı (KOİ) ve giriş metal” olarak 5 parametreden oluşmuş olup; çıkış pH, bu parametrelere dâhil edilmemiştir. Output parametresi olarak çıkış sülfatın YSA ile tahmini yapılmıştır. Tüm işlemler senaryo-1’de olduğu gibi gerçekleştirilmiştir. Senaryo-2’ye göre, çıkış sülfat için nöron sayısı 20’de sabit tutularak en iyi öğrenme algoritması trainlm olarak bulunmuştur (Çizelge 4.3.). Daha sonra optimum nöron sayısı için denemeler yapılmış ve trainlm algoritması için nöron sayısı 10 olarak belirlenmiştir (Çizelge 4.4.). Şekil 4.3.’ten de görüleceği üzere; training, validation, test ve tüm veriler (all) için R değerleri sırasıyla; 0.99, 0.97, 0.88 ve 0.95 olup oldukça yüksek bulunmuştur.





Şekil 4.3. Senaryo-2'ye göre Reaktör-1 çıkış sülfat tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)

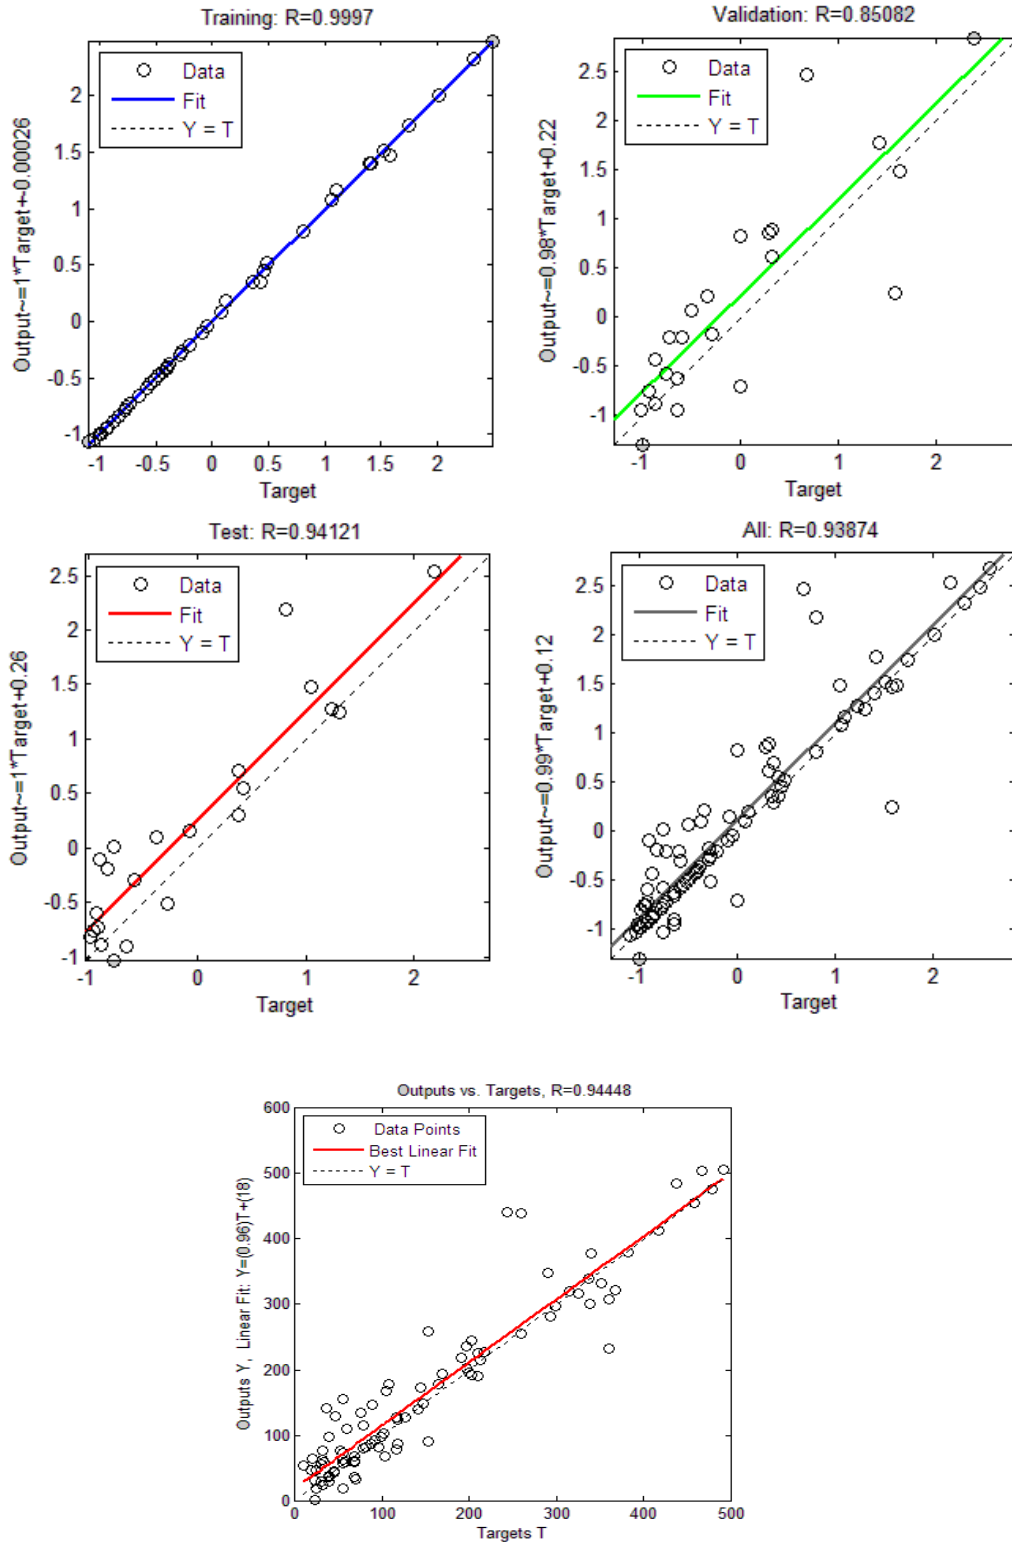
Kıyaslanmanın kolay olabilmesi için Şekil 4.4'te işletme zamanı bazında ölçülen ve tahmin edilen değerler aynı grafikte gösterilmiştir. Şekilden de görüleceği üzere, çıkış pH değeri kullanılmadan da çıkış sülfat değerleri optimize edilen YSA ile başarılı bir şekilde tahmin edilebilmektedir.



Şekil 4.4. Senaryo-2'e göre (Reaktör -1) çıkış Sülfat için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması


#### 4.1.2. Çıkış KOİ değerlerinin tahmin edilmesi

Çıkış KOİ değerlerinin tahmininde Senaryo-1 için (giriş parametrelerine pH'nın dahil edilmesi durumu) nöron sayısı 20'de sabit tutularak en iyi öğrenme algoritması trainlm olarak( R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.85, 0.93 ve 0.95) bulunmuştur (Çizelge 4.1.). Öğrenme algoritması trainlm'de sabit tutularak sadece nöron sayısı değiştirilmiş ve optimum nöron sayısı trainlm için 40 olarak bulunmuştur (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.86, 0.94 ve 0.94) (Çizelge 4.2. ve Şekil 4.5).



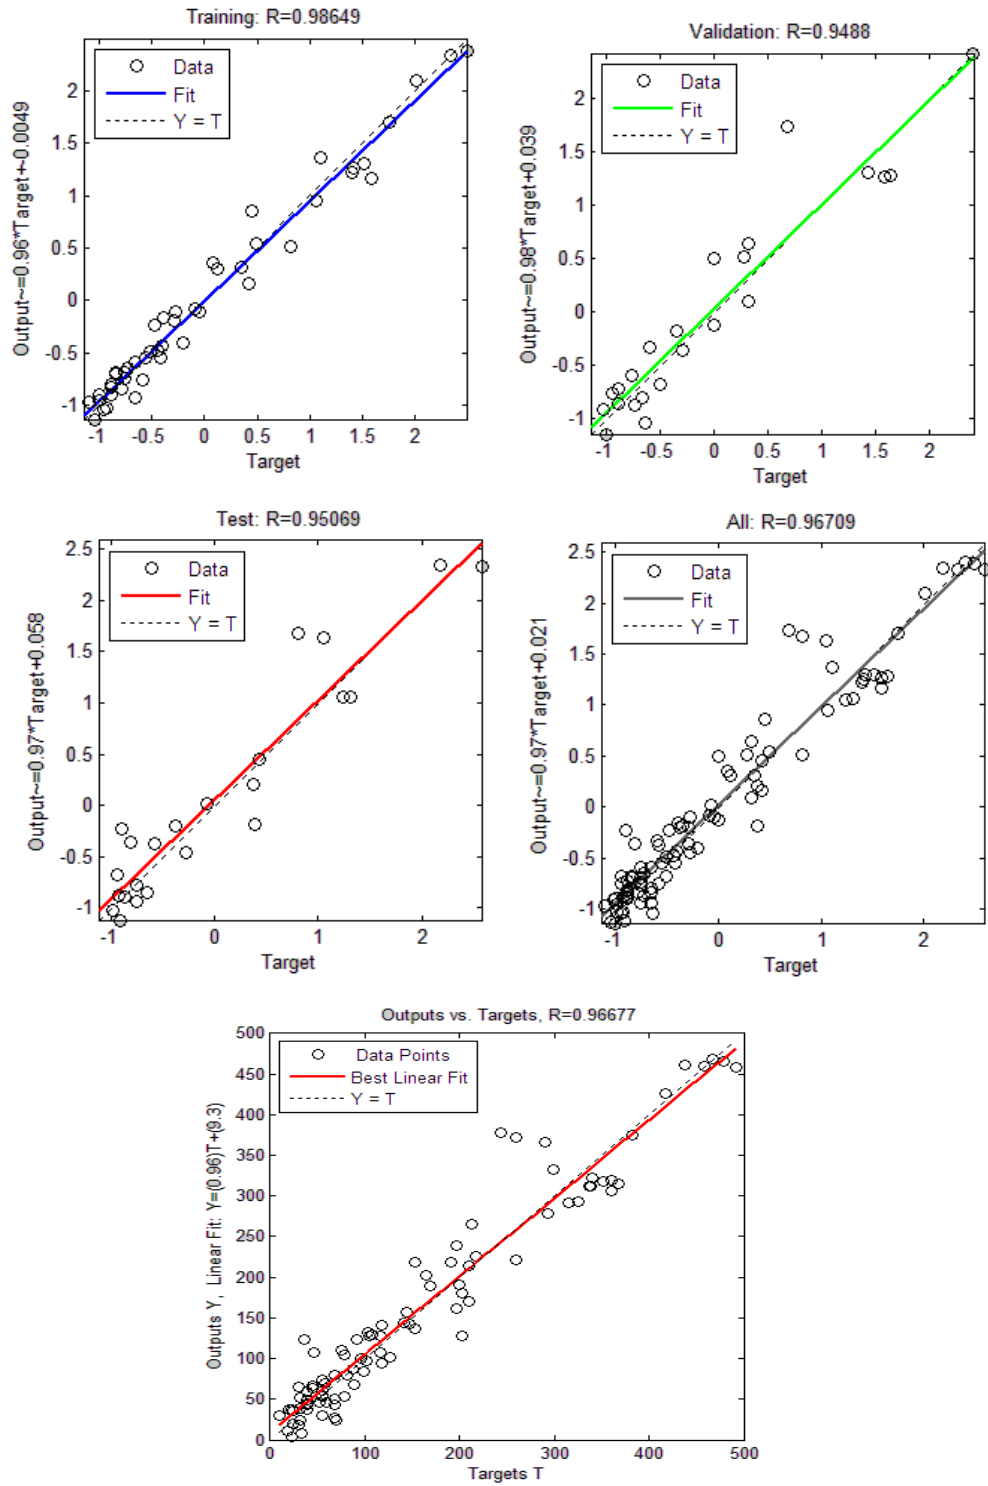
Şekil 4. 5. Senaryo-1'e göre Reaktör-1 çıkış KOİ tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)

Ölçülen ve tahmin edilen verilerin daha iyi kıyaslanabilmesi için işletim süresince ölçülen ve tahmin edilen veriler Şekil 4.6.'da sunulmuştur. Şekilden de görüldüğü üzere, çıkış KOİ değerleri ile tahmin değerleri birbirine çok yakın olup, YSA ile çıkış KOİ değerlerinin gayet başarılı bir şekilde tahmin edilebileceği gösterilmiştir.




Şekil 4.6. Senaryo-1'e göre (Reaktör -1) çıkış KOİ için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

Senaryo-2'ye göre çıkış KOİ tahmini için, çıkış pH input parametreleri arasından çıkarılarak tüm işlemler yinelenmiştir. Nöron sayısı 20'de sabit tutularak, en iyi öğrenme algoritması trainrp olarak bulunmuştur. Trainrp için optimum nöron sayısı ise 20 olarak bulunmuştur. (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.95, 0.95 ve 0.97). Elde edilen korelasyon grafikleri Şekil 4.7'de; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.8'de gösterilmiştir.



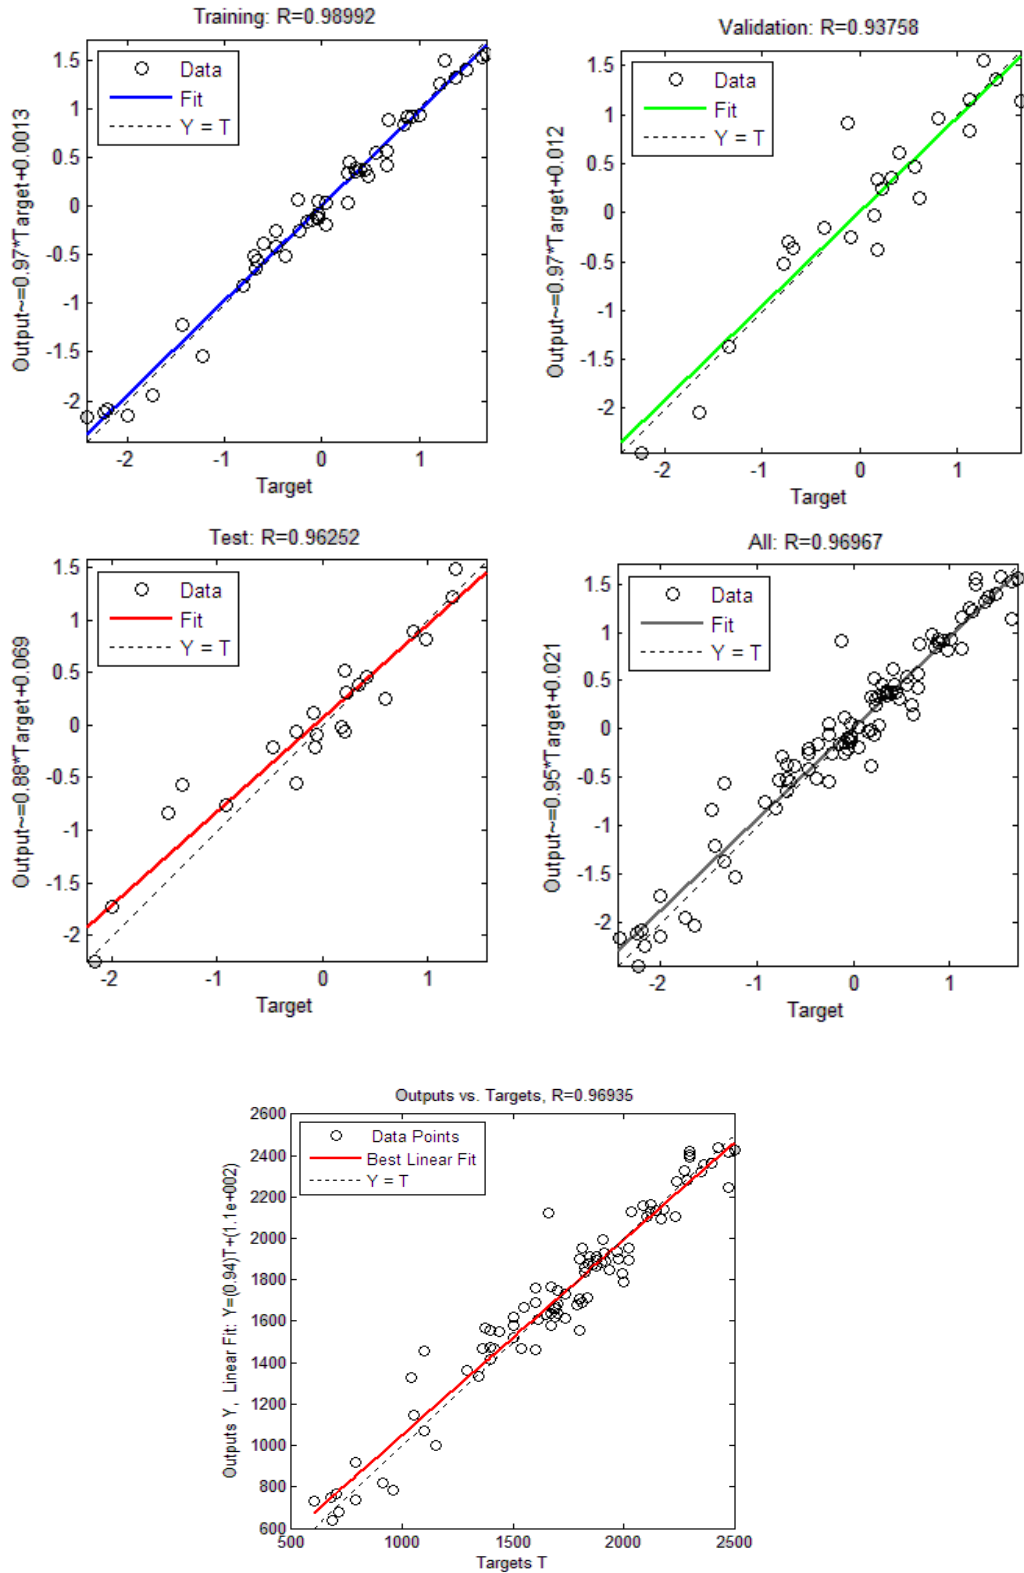
Şekil 4.7. Senaryo-2'ye göre Reaktör-1 çıkış KOİ tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)




Şekil 4.8. Senaryo-2'ye göre (Reaktör 1) çıkış KOİ için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

#### 4.1.3. Çıkış alkalinite değerlerinin tahmin edilmesi

Çıkış alkalinite değerlerinin tahmininde Senaryo-1 için nöron sayısı 20'de sabit tutularak en iyi öğrenme algoritması trainrp olarak bulunmuştur (Çizelge 4.1). Öğrenme algoritması trainrp'de sabit tutularak sadece nöron sayısı değiştirilmiş ve optimum nöron sayısı trainrp için 20 olarak bulunmuştur (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.94, 0.96 ve 0.97) (Çizelge 4.2. ve Şekil 4.9.). Şekil 4.10'dan da görüleceği üzere çıkış alkalinite değerleri oldukça başarılı bir şekilde tahmin edilmiştir.



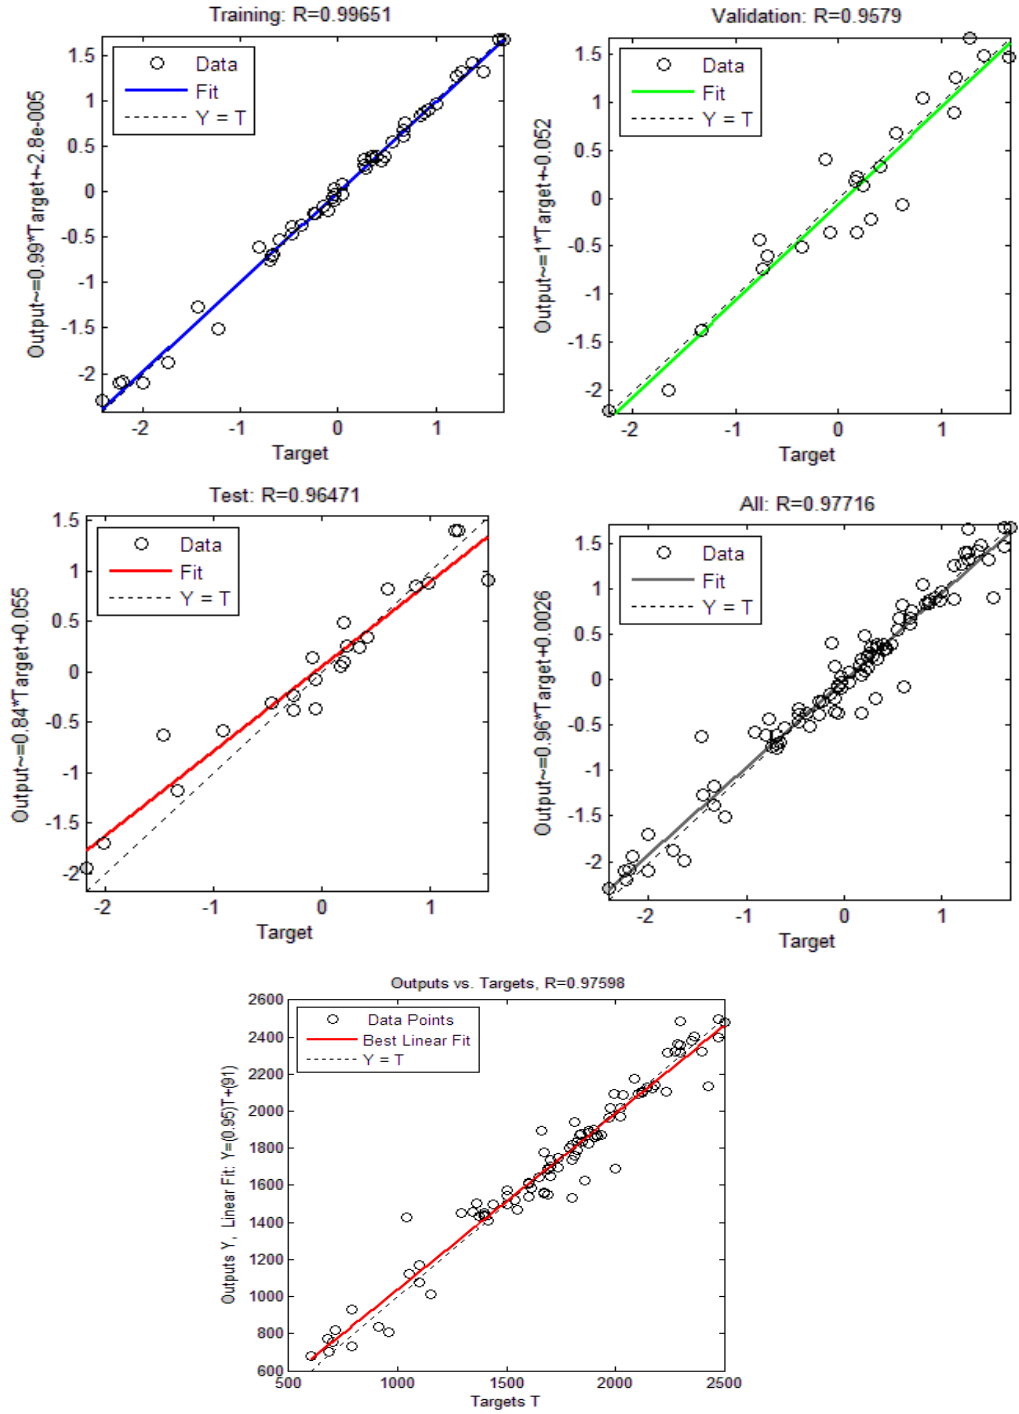
Şekil 4.9. Senaryo-1'e göre Reaktör-1 çıkış alkalinite tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)




Şekil 4.10. Senaryo-1'e göre (Reaktör -1) çıkış alkalinite için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

Senaryo-2'ye göre çıkış alkalinite tahmini için tüm işlemler yinelenmiştir. En iyi öğrenme algoritması nöron sayısı 20'de sabit tutularak trainlm olarak bulunmuştur. Trainlm için optimum nöron sayısı ise 30 şeklinde belirlenmiştir (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.96, 0.97 ve 0.98). Elde edilen korelasyon grafikleri Şekil 4.11.'de; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.12'de gösterilmiştir. Senaryo-2'ye göre de çıkış alkalinite değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.





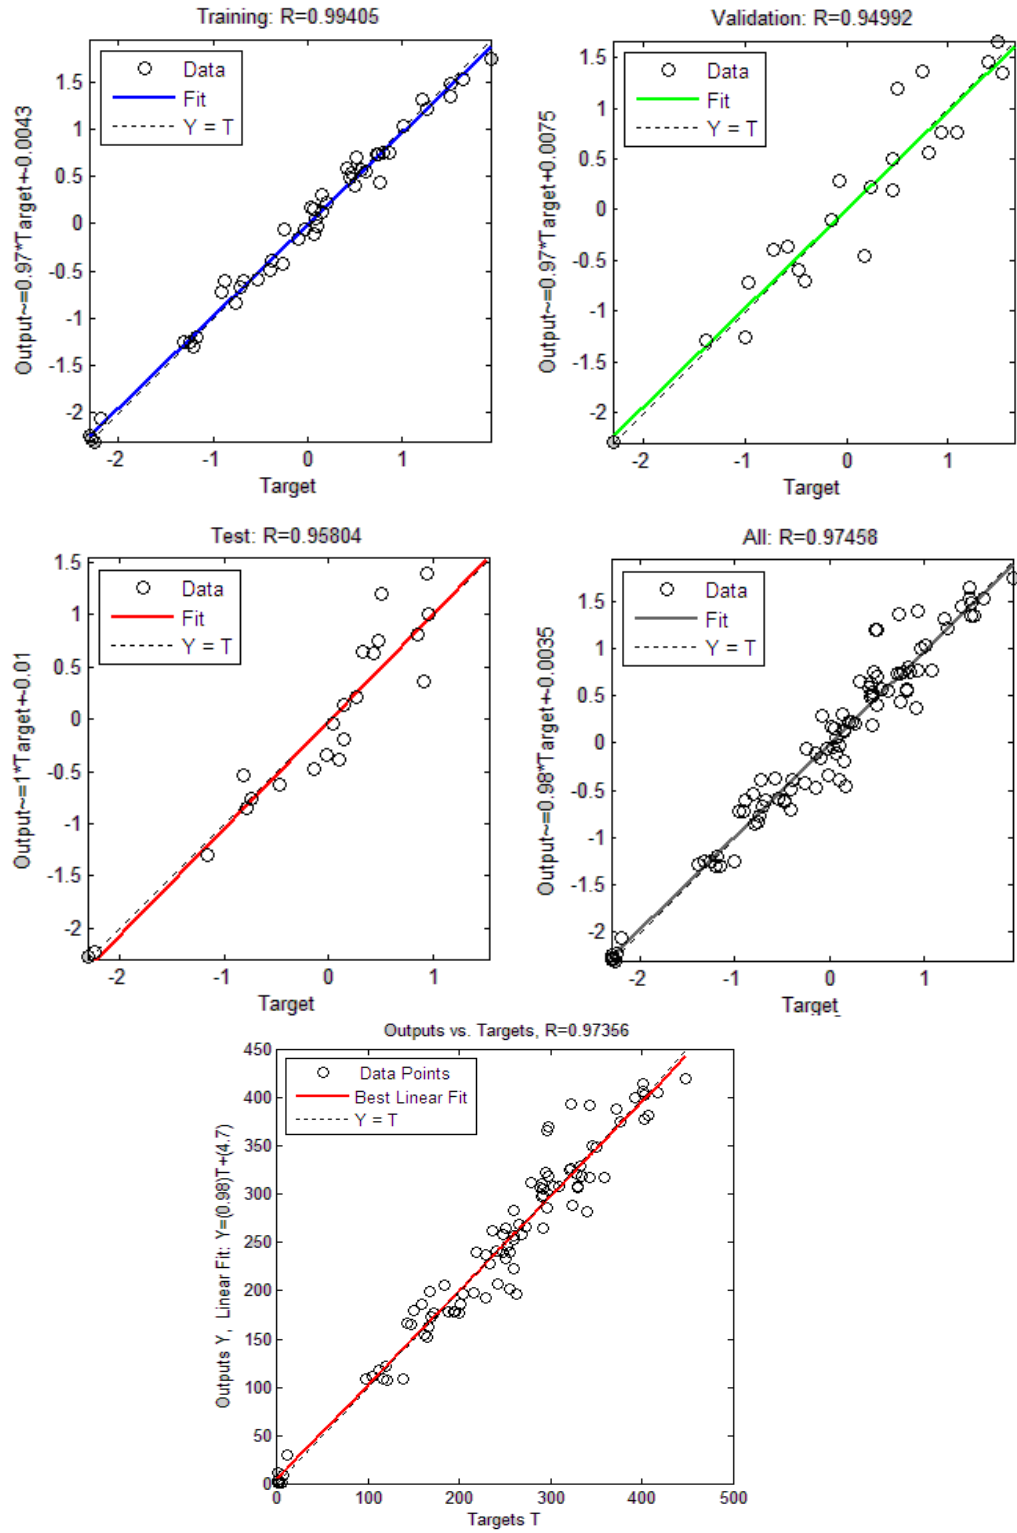
Şekil 4.11. Senaryo-2'ye göre Reaktör-1 çıkış alkalinite tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)




Şekil 4.12. Senaryo-2'ye göre (Reaktör-1) çıkış alkalinite için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

#### 4.1.4. Çıkış sülfür değerlerinin tahmin edilmesi

Çıkış sülfür değerlerinin tahmininde Senaryo-1 için nöron sayısı 20'de sabit tutularak en iyi öğrenme algoritması trainrp olarak bulunmuştur (Çizelge 4.1.). Öğrenme algoritması trainrp'de sabit tutularak sadece nöron sayısı değiştirilmiş ve optimum nöron sayısı trainrp için 20 olarak bulunmuştur (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.95, 0.96 ve 0.98) (Çizelge 4.2. ve şekil 4.13). Şekil 4.14'ten de görüleceği üzere çıkış sülfür değerleri oldukça başarılı bir şekilde tahmin edilmiştir.

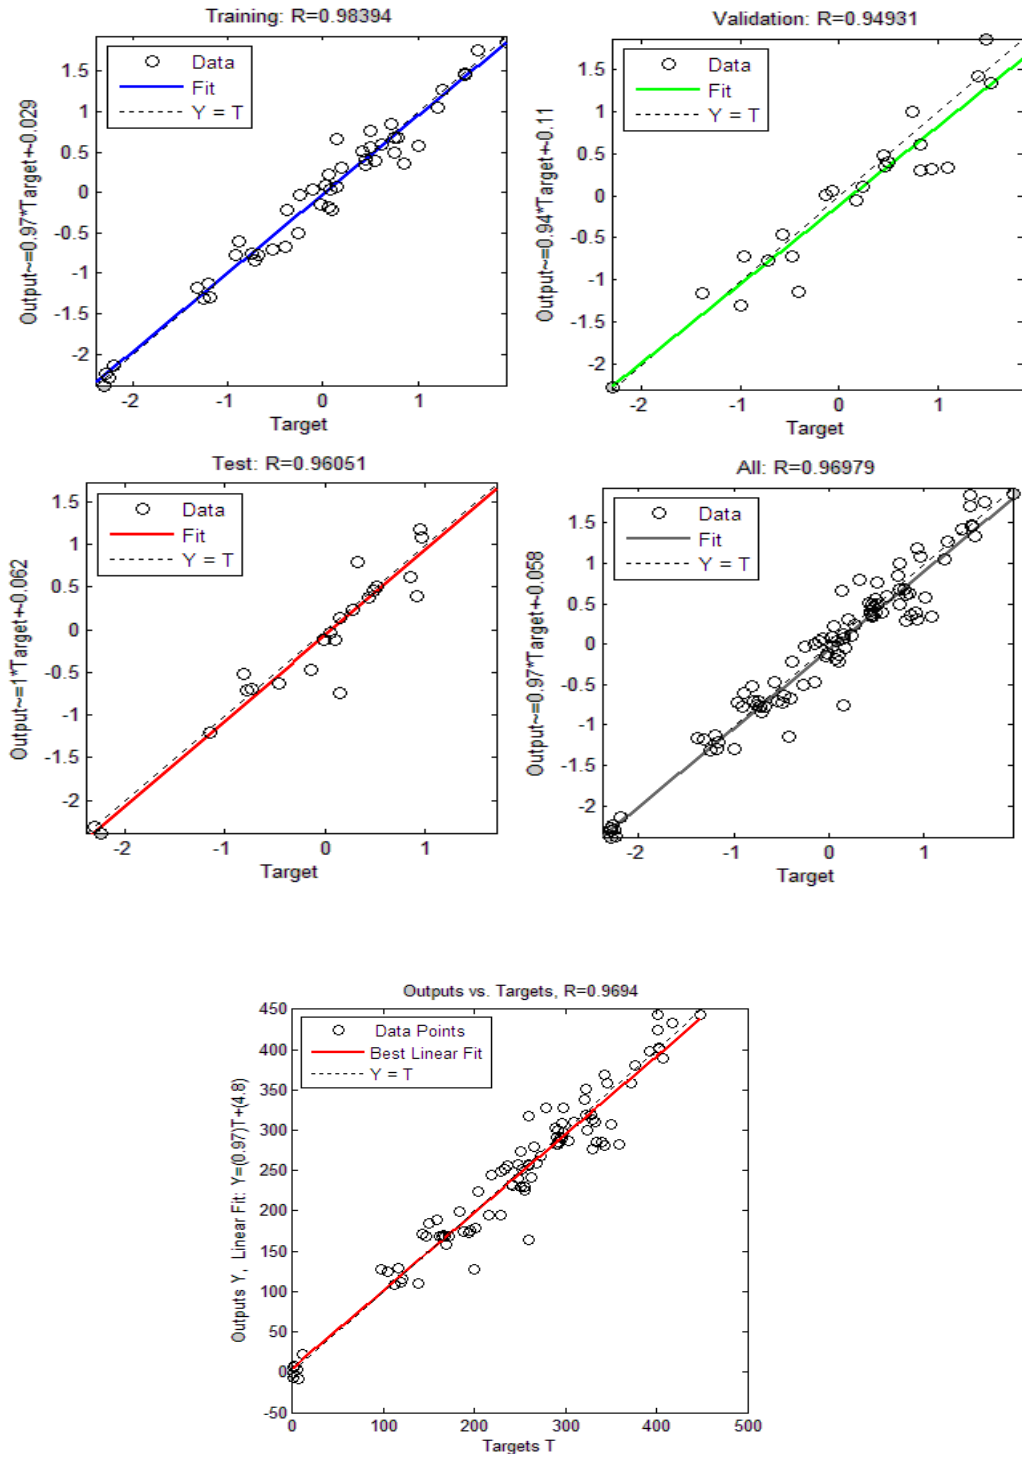


Şekil 4.13. Senaryo-1'e göre Reaktör-1 çıkış sülfür tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)

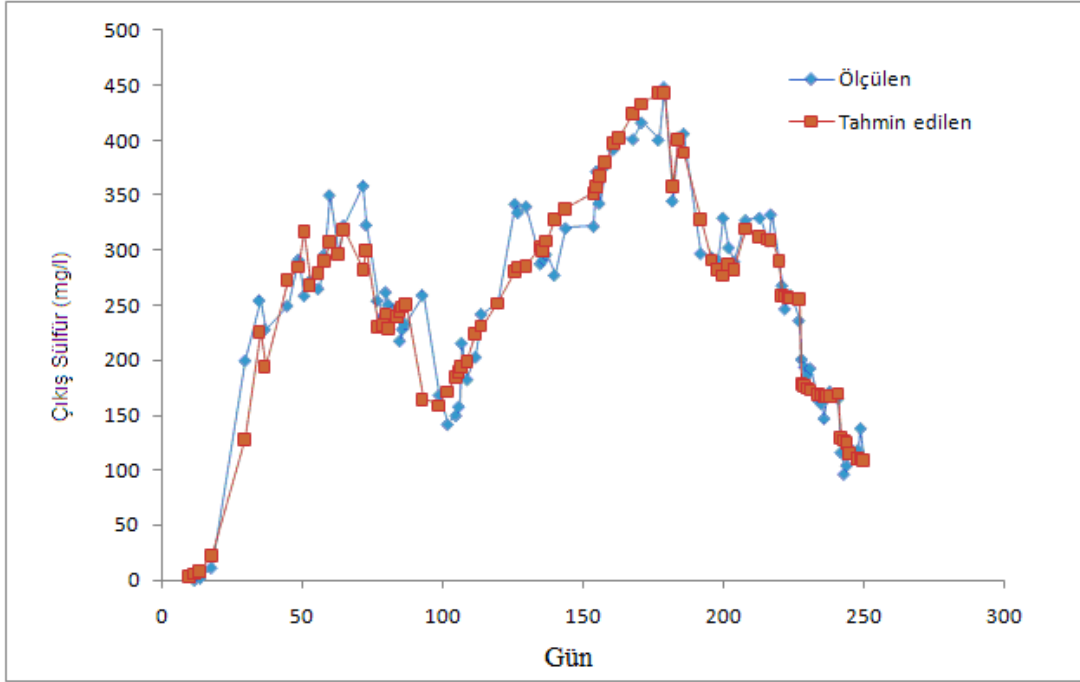


Şekil 4. 14. Senaryo-1'e göre (Reaktör -1) çıkış sülfür için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

Senaryo-2'ye göre çıkış sülfür tahmini için tüm işlemler yinelenmiştir. En iyi öğrenme algoritması nöron sayısı 20'de sabit tutularak traingdx olarak bulunmuştur. Traingdx için optimum nöron sayısı ise 30 olarak belirlenmiştir (R-training, R-validation, R-test ve R-all sırasıyla 0.98, 0.95, 0.96 ve 0.97). Elde edilen korelasyon grafikleri Şekil 4.15'te; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.16'da gösterilmiştir. Senaryo-2'ye göre çıkış sülfür değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir



Şekil 4.15. Senaryo-2'ye göre Reaktör-1 çıkış sülfür tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)



Şekil 4.16. Senaryo-2'ye göre (Reaktör -1) çıkış sülfür için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

#### 4.2. Aşağı Akışlı Akışkan Yataklı Reaktör (R2) Çıkış Değerlerinin YSA ile Tahmin Edilmesi

Bu kısımda yine AMS arıtan aşağı akışlı akışkan yataklı reaktörden (Reaktör 2) elde edilen veriler olan; “işletme süresi, giriş pH, çıkış pH, giriş sülfat, giriş kimyasal oksijen ihtiyacı (KOİ) ve giriş metal” olmak üzere toplam 6 input parametresi kullanılarak; “çıkış sülfat, çıkış KOİ, çıkış alkalinite ve çıkış sülfür” konsantrasyonları YSA ile tahmin edilmeye çalışılmıştır. Bu amaçla, yine 2 senaryo üzerinde çalışılmıştır (Çizelge 4.5, Çizelge 4.6, Çizelge 4.7, Çizelge 4.8). İlkinde çıkış pH değeri input parametreleri içerisinde yer alırken (Senaryo-1); ikinci senaryoda (Senaryo-2) çıkış pH değeri input parametreleri arasından çıkarılmış ve YSA ile reaktör performansının modellenmesine çalışılmıştır.

Çizelge 4.5.Senaryo-1'e göre Reaktör-2 çıkış değerleri için çeşitli öğrenme algoritmalarının değerlendirilmesi ( nöron 20 )

BP Algorithms		Trainlm	Traincgp	Traingd	Traingda	Traingdx	Trainrp	Trainscg	Trainoss	Traincgf	Trainbfg	Traingdm	Traincgb
Sülfat	T-R	1	0.56	0.89	0.91	0.97	0.99	0.93	0.04	0.04	0.14	0.11	0.24
	V- R	0.76	0.85	0.87	0.86	0.89	0.90	0.78	0.93	0.82	0.86	0.13	0.83
	Tt-R	0.62	0.67	0.77	0.81	0.92	0.90	0.85	0.90	0.62	0.86	0.21	0.87
	A-R	0.84	0.43	0.85	0.87	0.94	0.95	0.88	0.24	0.03	0.36	0.04	0.44
KOI	T-R	1	0.14	0.95	0.99	0.98	0.99	0.99	0.11	0.23	0.57	0.98	0.62
	V- R	0.98	0.98	0.96	0.99	0.99	0.98	0.99	0.98	0.98	0.98	0.98	0.98
	Tt-R	0.90	0.90	0.86	0.94	0.93	0.94	0.87	0.90	0.95	0.94	0.91	0.92
	A-R	0.97	0.38	0.93	0.97	0.97	0.98	0.97	0.45	0.49	0.67	0.97	0.07
Alkalinite	T-R	1	0.03	0.97	0.97	0.85	0.99	0.98	0.30	0.49	0.55	0.77	0.26
	V- R	0.87	0.94	0.93	0.94	0.81	0.97	0.94	0.95	0.96	0.97	0.69	0.95
	Tt-R	0.68	0.95	0.92	0.96	0.78	0.95	0.95	0.98	0.96	0.95	0.74	0.97
	A-R	0.86	0.30	0.95	0.96	0.82	0.98	0.96	0.12	0.50	0.11	0.54	0.52
Sülfür	T-R	1	0.08	0.96	0.96	0.98	0.99	0.97	0.03	0.14	0.41	0.82	0.33
	V- R	0.80	0.86	0.83	0.80	0.87	0.91	0.87	0.90	0.86	0.86	0.77	0.87
	Tt-R	0.63	0.93	0.91	0.92	0.91	0.94	0.95	0.95	0.92	0.91	0.68	0.92
	A-R	0.83	0.37	0.91	0.91	0.94	0.96	0.94	0.41	0.43	0.53	0.74	0.19

Çizelge 4.6.Senaryo-1'e göre her bir out-put parametresi (Reaktör-2) için farklı nöron sayılarından elde edilen tahminlerin kıyaslanması

Nöron Sayısı		3	5	10	20	30	40
Sülfat (trainrp)	T-R	0.90	0.89	0.92	<b>0.99</b>	0.97	0.98
	V- R	0.89	0.86	0.82	<b>0.90</b>	0.89	0.88
	Tt-R	0.61	0.74	0.70	<b>0.90</b>	0.82	0.88
	A-R	0.82	0.85	0.84	<b>0.95</b>	0.92	0.94
Koi (trainrp)	T-R	<b>0.99</b>	0.98	0.99	0.99	0.99	0.99
	V- R	<b>0.99</b>	0.98	0.98	0.99	0.99	0.97
	Tt-R	<b>0.95</b>	0.94	0.93	0.94	0.93	0.89
	A-R	<b>0.98</b>	0.97	0.97	0.98	0.98	0.96
Alkalinite (trainrp)	T-R	0.97	0.97	<b>0.99</b>	0.99	0.99	0.99
	V- R	0.96	0.94	<b>0.97</b>	0.97	0.93	0.95
	Tt-R	0.95	0.96	<b>0.97</b>	0.95	0.96	0.93
	A-R	0.97	0.96	<b>0.98</b>	0.98	0.96	0.93
Sülfür (trainrp)	T-R	0.94	0.96	0.97	<b>0.99</b>	0.87	0.98
	V-R	0.83	0.86	0.85	<b>0.91</b>	0.87	0.86
	Tt-R	0.90	0.90	0.92	<b>0.94</b>	0.85	0.87
	A-R	0.90	0.93	0.93	<b>0.96</b>	0.91	0.93



Çizelge 4.7. Senaryo-2'ye göre Reaktör-2 çıkış değerleri için çeşitli öğrenme algoritmalarının değerlendirilmesi ( nöron 20)

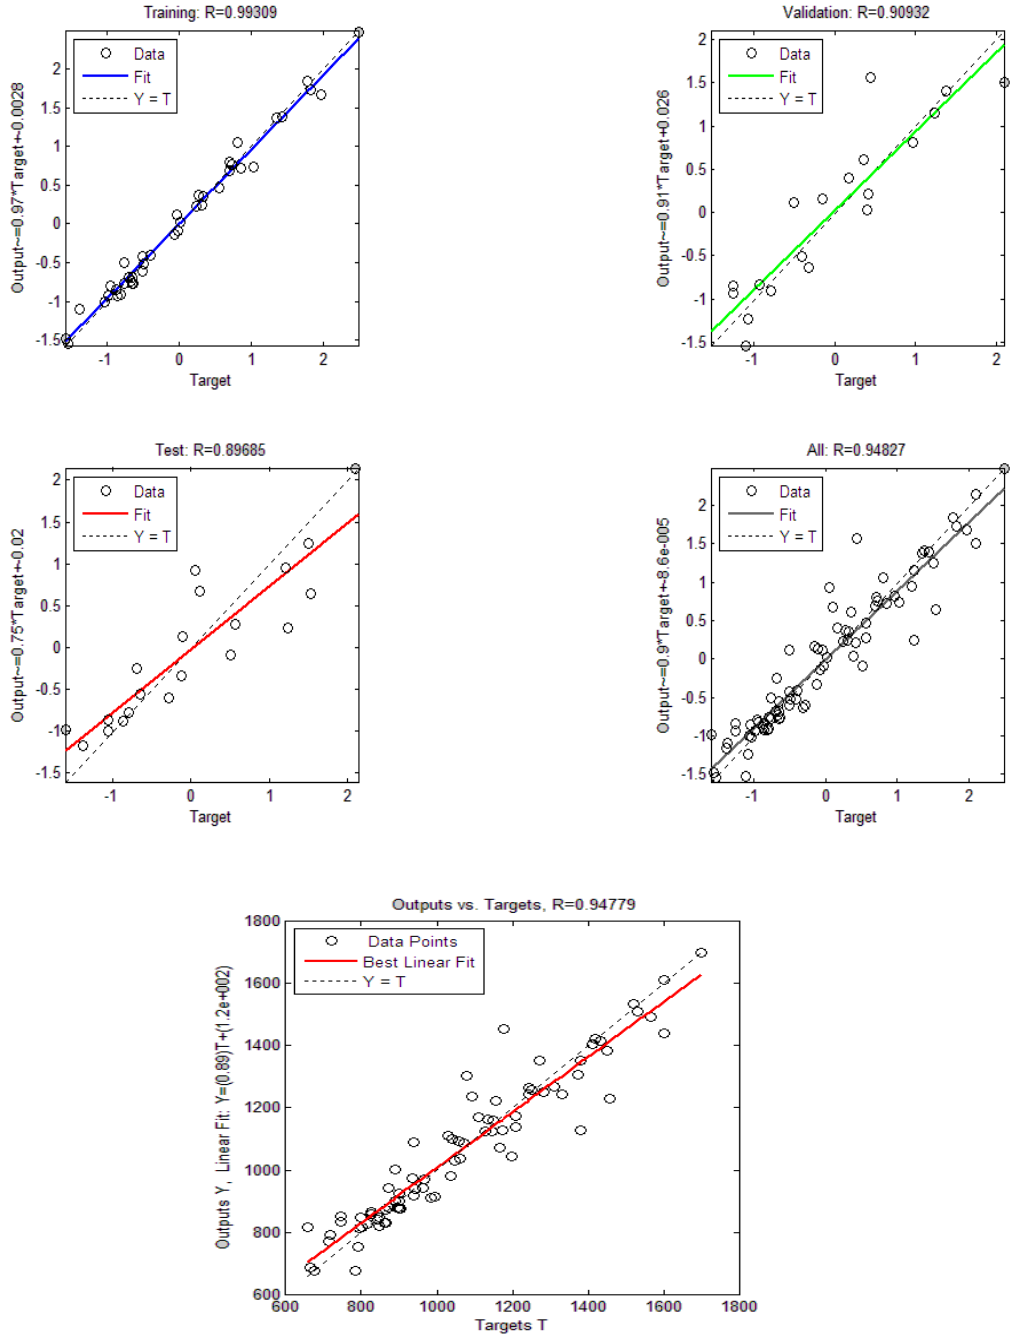
BP Algorithm		Trainlm	Traincgp	Traingd	Trainгда	Traingdх	Trainrp	Trainscg	Trainoss	Traincgf	Trainbfg	Traingdm	Traincgb
Sülfat	T-R	0.99	0.25	0.92	0.89	0.94	0.96	0.96	0.01	0.42	0.41	0.55	0.33
	V- R	0.90	0.83	0.86	0.81	0.88	0.90	0.88	0.82	0.92	0.94	0.59	0.92
	Tt-R	0.81	0.81	0.71	0.78	0.82	0.89	0.86	0.78	0.82	0.87	0.24	0.85
	A-R	0.92	0.24	0.85	0.83	0.89	0.93	0.91	0.35	0.57	0.59	0.44	0.18
KOİ	T-R	0.99	0.51	0.97	0.98	0.39	0.99	0.98	0.45	0.39	0.07	0.86	0.02
	V- R	0.98	0.99	0.98	0.99	0.34	0.99	0.98	0.99	0.98	0.99	0.92	0.99
	Tt-R	0.92	0.93	0.92	0.90	0.11	0.94	0.84	0.95	0.92	0.94	0.53	0.92
	A-R	0.97	0.44	0.96	0.97	0.27	0.98	0.96	0.62	0.26	0.44	0.78	0.49
Alkalinite	T-R	0.99	0.32	0.97	0.96	0.96	0.98	0.98	0.38	0.07	0.52	0.96	0.59
	V- R	0.97	0.95	0.92	0.94	0.95	0.96	0.96	0.96	0.97	0.94	0.93	0.94
	Tt-R	0.94	0.96	0.91	0.94	0.94	0.94	0.94	0.96	0.97	0.96	0.96	0.95
	A-R	0.97	0.38	0.94	0.95	0.95	0.97	0.97	0.46	0.50	0.13	0.95	0.10
Sülfür	T-R	0.99	0.08	0.96	0.97	0.81	0.98	0.97	0.66	0.39	0.55	0.31	0.16
	V- R	0.90	0.83	0.87	0.88	0.74	0.90	0.88	0.88	0.87	0.89	0.35	0.85
	Tt-R	0.92	0.86	0.94	0.92	0.83	0.94	0.94	0.92	0.92	0.95	0.50	0.87
	A-R	0.95	0.30	0.94	0.94	0.79	0.96	0.94	0.73	0.27	0.03	0.31	0.25

Çizelge 4.8. Senaryo-2'ye göre her bir out-put parametresi (Reaktör-2) için farklı nöron sayılarından elde edilen tahminlerin kıyaslanması


Nöron Sayısı		3	5	10	20	30	40
Sülfat (trainrp)	T-R	0.97	0.90	0.92	<b>0.96</b>	0.93	0.99
	V- R	0.88	0.87	0.85	<b>0.90</b>	0.85	0.92
	Tt-R	0.83	0.76	0.83	<b>0.89</b>	0.80	0.79
	A-R	0.91	0.85	0.88	<b>0.93</b>	0.88	0.92
KOl (trainrp)	T-R	0.98	0.98	<b>0.99</b>	0.99	0.98	0.99
	V- R	0.99	0.98	<b>0.99</b>	0.99	0.99	0.99
	Tt-R	0.92	0.91	<b>0.95</b>	0.94	0.92	0.94
	A-R	0.97	0.97	<b>0.98</b>	0.98	0.97	0.98
Alkalinite (trainlm)	T-R	0.97	<b>0.99</b>	0.99	0.99	0.99	0.99
	V- R	0.93	<b>0.98</b>	0.97	0.98	0.97	0.97
	Tt-R	0.92	<b>0.97</b>	0.96	0.94	0.94	0.92
	A-R	0.95	<b>0.98</b>	0.98	0.97	0.98	0.97
Sülfür (trainrp)	T-R	0.96	0.97	0.98	<b>0.98</b>	0.98	0.98
	V-R	0.88	0.86	0.90	<b>0.90</b>	0.89	0.85
	Tt-R	0.90	0.94	0.93	<b>0.94</b>	0.91	0.90
	A-R	0.92	0.94	0.94	<b>0.96</b>	0.94	0.93

#### 4.2.1. Çıkış sülfat değerlerinin tahmin edilmesi

Önelikle senaryo-1 için (çıkış pH değerinin input parametresi olarak kullanılması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.6.'dan da görüldüğü üzere çıkış sülfat tahmininde en iyi öğrenme algoritması trainrp olup nöron sayısı 20 olarak bulunmuştur. (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.90, 0.90 ve 0.95). Elde edilen korelasyon grafikleri Şekil 4.17.'de ölçülen değerler ile tahmin değerlerinin kıyaslanması için reaktör işletme zamanına göre elde edilen grafik ise Şekil 4.18. gösterilmiştir. Senaryo-1'e göre çıkış sülfat değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir

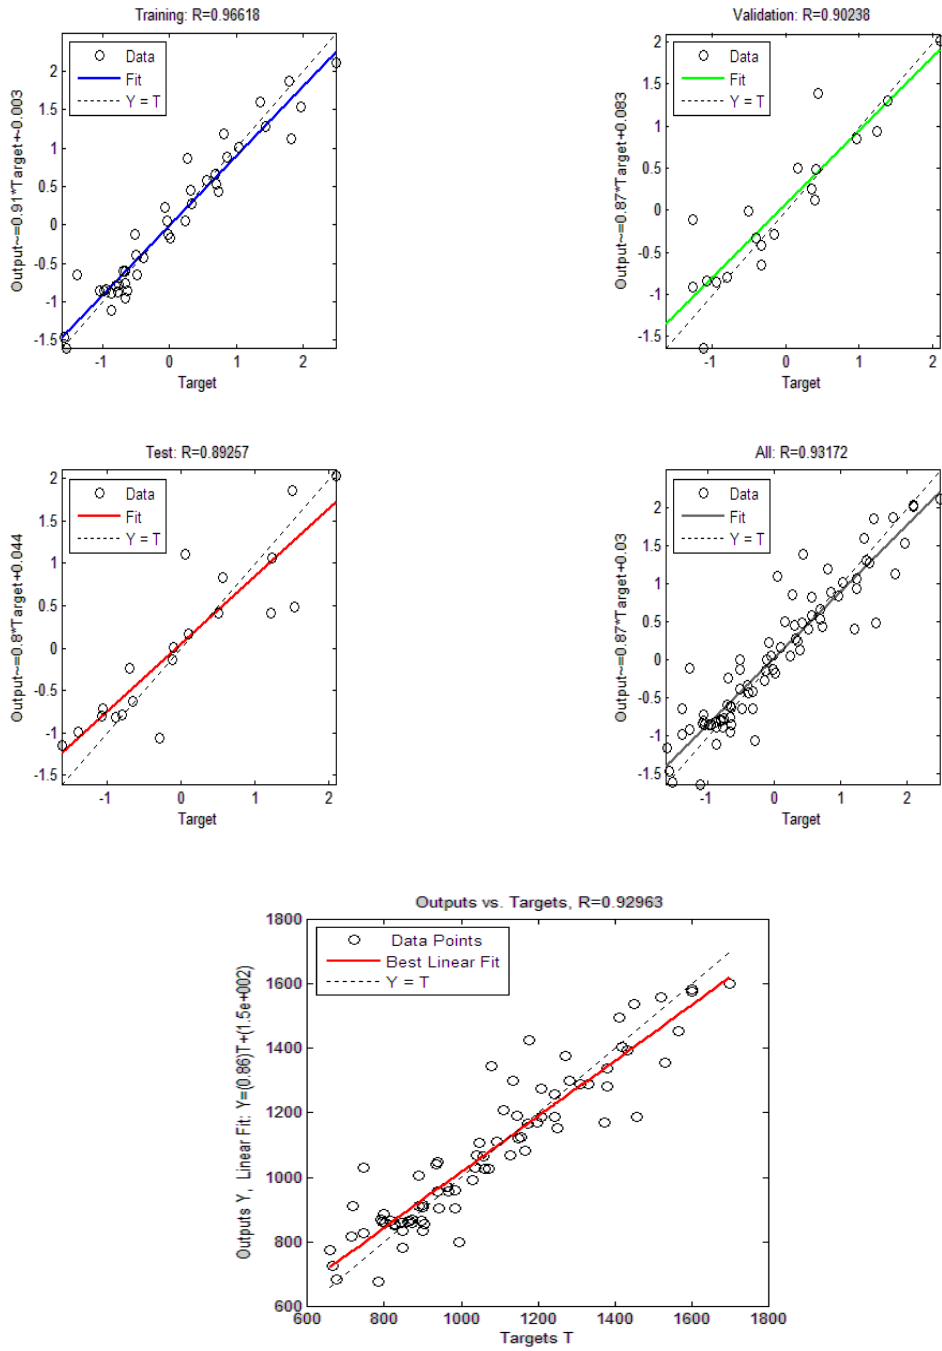


Şekil 4.17.Senaryo-1'e göre Reaktör-2 çıkış sülfat tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)

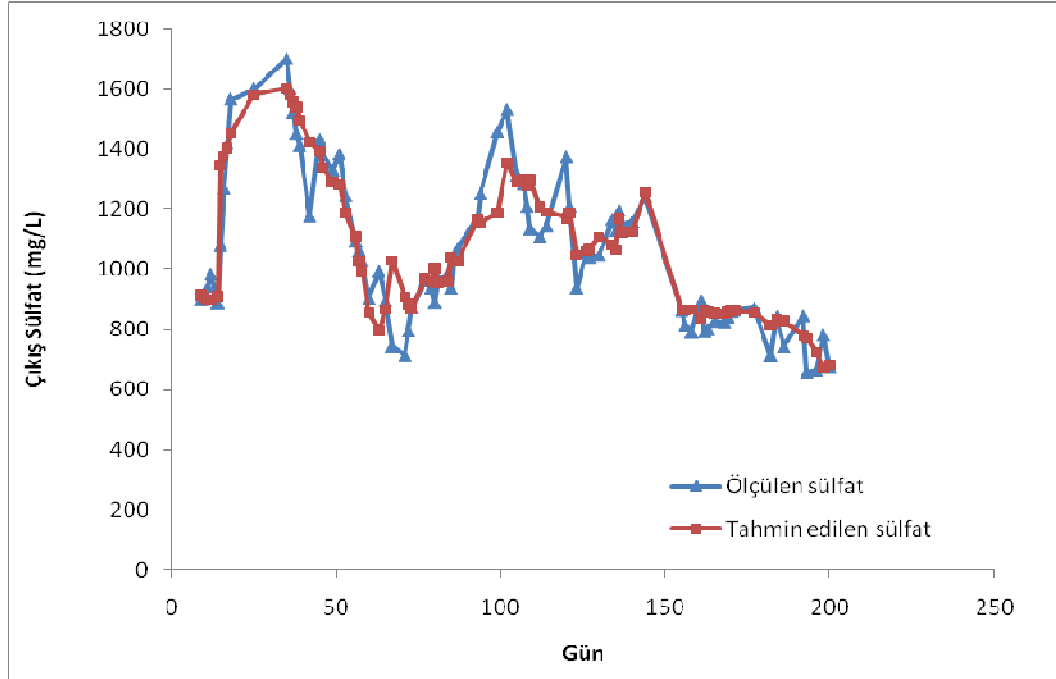


Şekil 4.18. Senaryo-1'e göre (Reaktör-2) çıkış sülfat için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

Senaryo-2 için (çıkış pH değerinin input parametresi olarak kullanılmaması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.7. ve Çizelge 4.8.'den de görüldüğü üzere çıkış sülfat tahmininde en iyi öğrenme algoritması trainrp olup nöron sayısı 20 olarak bulunmuştur. (R-training, R-validation, R-test ve R-all sırasıyla 0.96, 0.90, 0.89 ve 0.93). Elde edilen korelasyon grafikleri Şekil 4.19.'te; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.20.'da gösterilmiştir. Senaryo-2'ye göre çıkış sülfat değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir



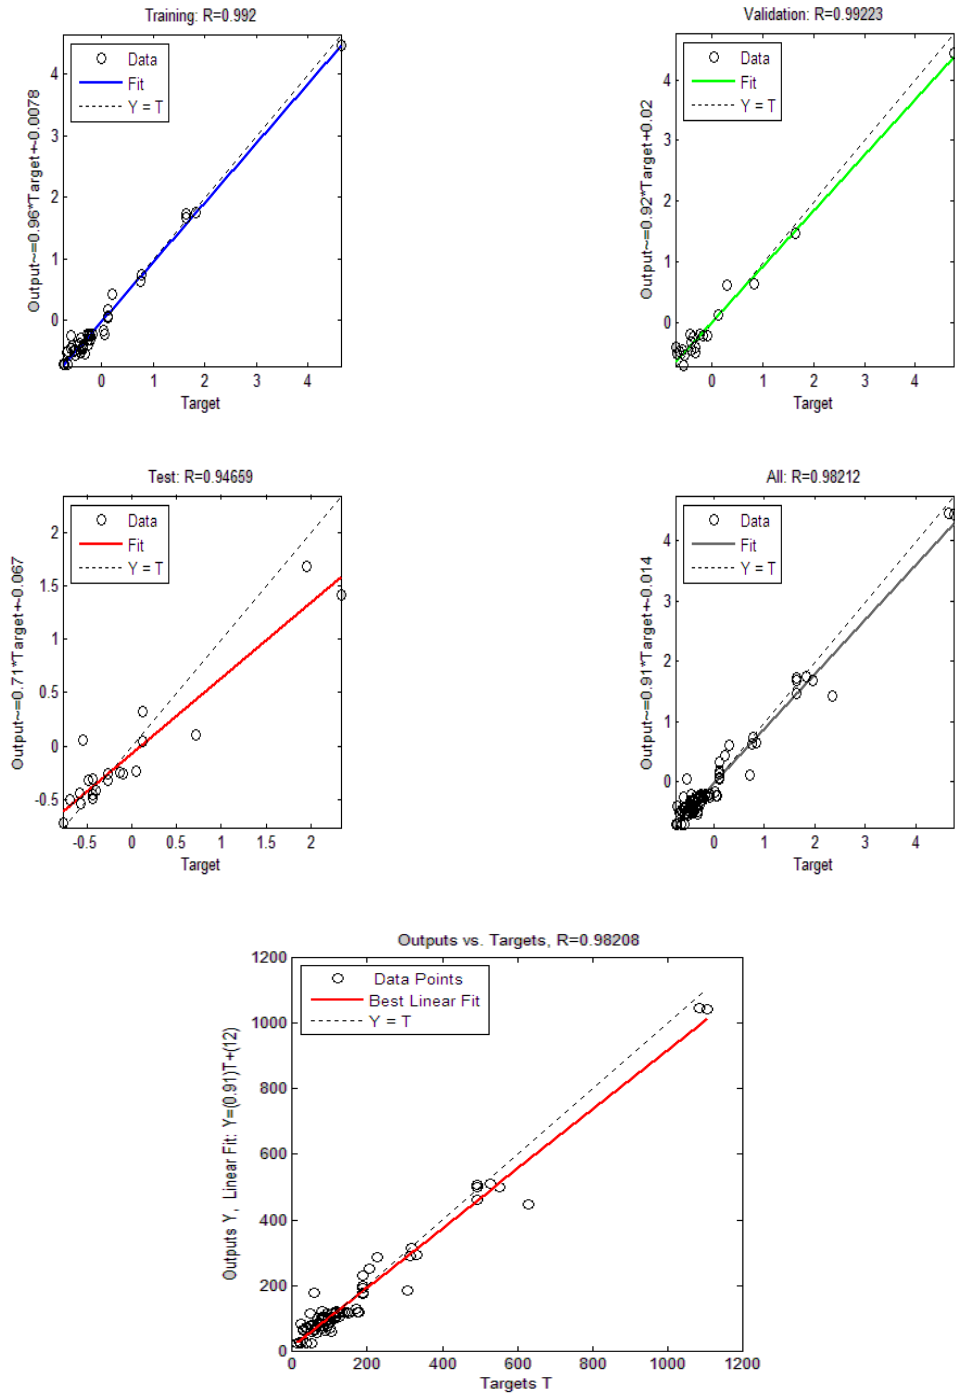
Şekil 4.19. Senaryo-2'ye göre Reaktör-2 çıkış sülfat tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)



Şekil 4.20. Senaryo-2'ye göre (Reaktör-2) çıkış sülfat için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması


#### 4.2.2.Çıkış KOİ değerlerinin tahmin edilmesi

Öncelikle senaryo-1 için (çıkış pH değerinin input parametresi olarak kullanılması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda ilk olarak nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Daha sonra bulunan en iyi öğrenme algoritması sabit tutularak nöron sayıları değiştirilmiştir. Çizelge 4.5. ve Çizelge 4.6.'dan de görüldüğü üzere çıkış KOİ tahmininde en iyi öğrenme algoritması trainrp olup, en iyi nöron sayısı 3 olarak bulunmuştur. (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.99, 0.95 ve 0.98). Elde edilen korelasyon grafikleri Şekil 4.21.'te; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.22.'de gösterilmiştir. Senaryo 1'ye göre çıkış KOİ değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir



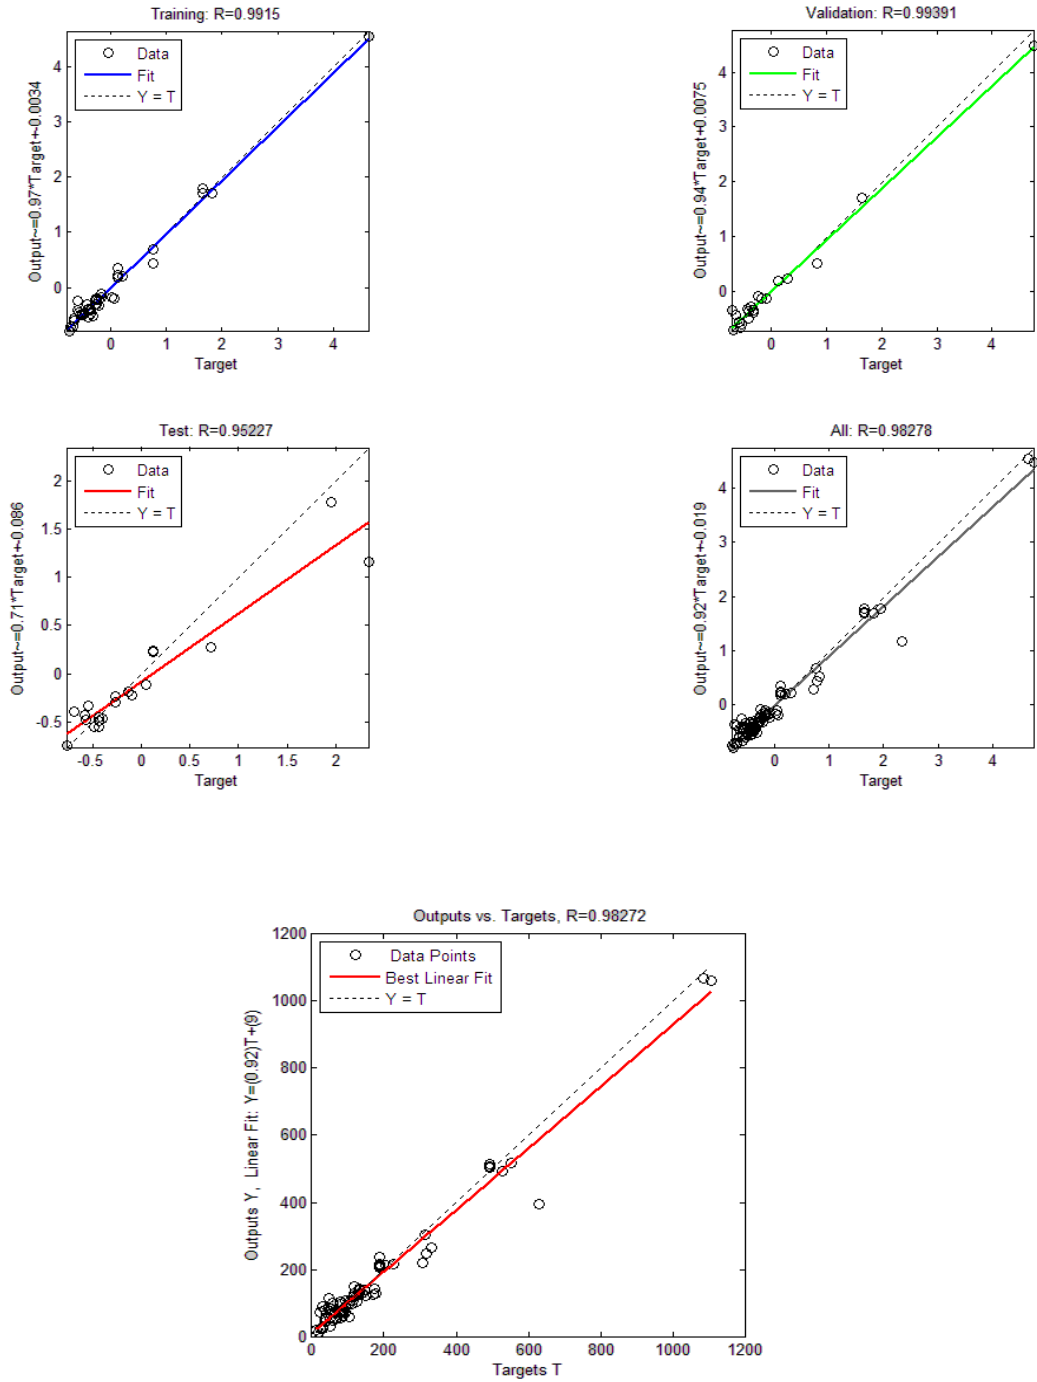
Şekil 4.21. Senaryo-1'e göre Reaktör-2 çıkış KOI tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)






Şekil 4.22. Senaryo-1'e göre (Reaktör-2) çıkış KOİ için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

Senaryo-2 için (çıkış pH değerinin input parametresi olarak kullanılmaması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiş ve bulunan en iyi algoritmaya göre en iyi nöron sayısının tespitine çalışılmıştır. Çizelge 4.7.'den görüldüğü üzere çıkış KOİ tahmininde en iyi öğrenme algoritması trainrp olup, Çizelge 4.8.'de en iyi nöron sayısının 10 olduğu tespit edilmiştir. (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.99, 0.95 ve 0.98). Elde edilen korelasyon grafikleri Şekil 4.23.'te; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.24.'de gösterilmiştir. Senaryo-2'ye göre çıkış KOİ değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.



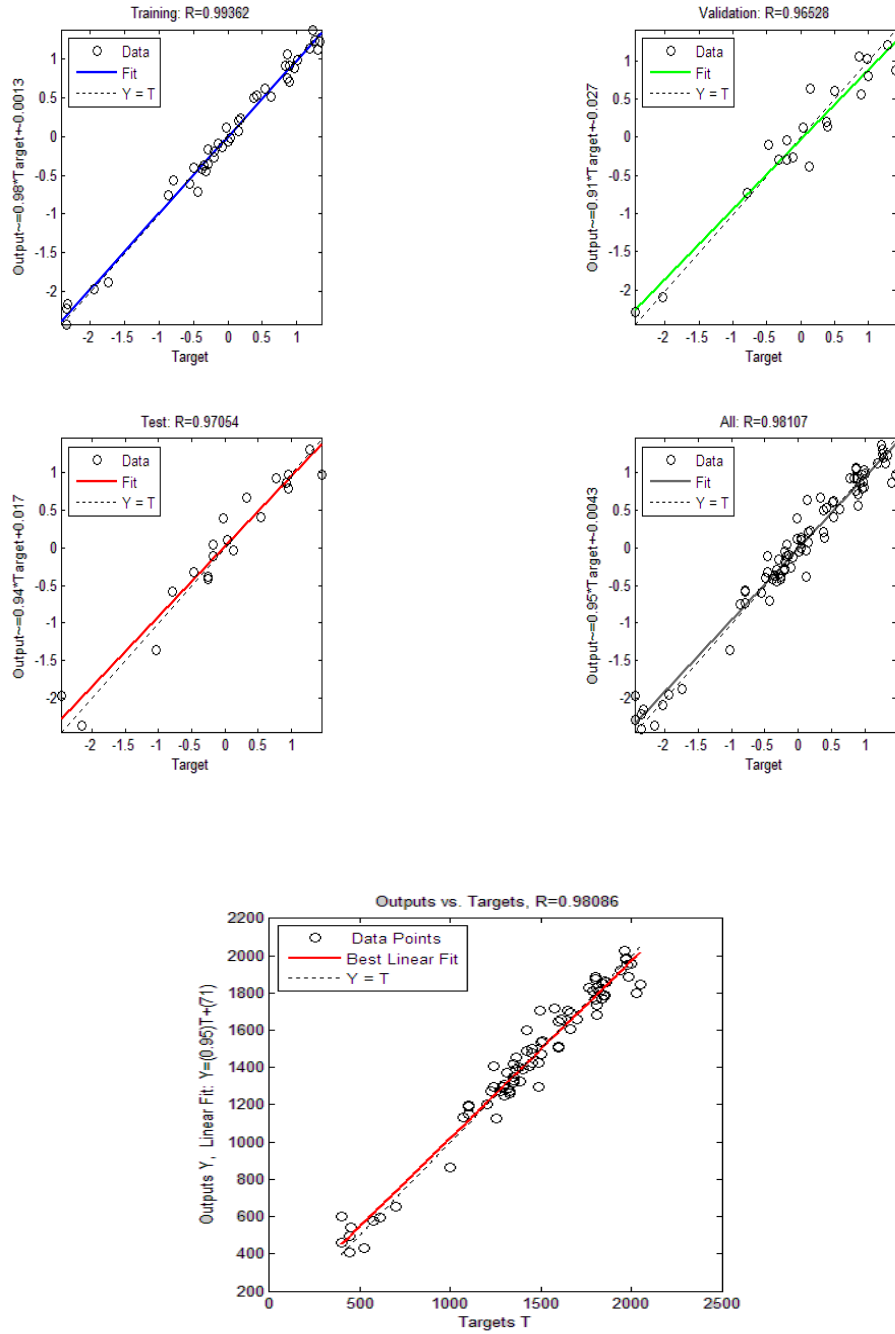
Şekil 4.23. Senaryo-2'ye göre Reaktör-2 çıkış KOI tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)




Şekil 4.24. Senaryo-2'ye göre (Reaktör-2) çıkış KOİ için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

#### 4.2.3. Çıkış alkalinite değerlerinin tahmin edilmesi

Senaryo-1 için (çıkış pH değerinin input parametresi olarak kullanılması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.5.'den de görüldüğü üzere çıkış Alkalinite tahmininde en iyi öğrenme algoritması trainrp'dir. Çizelge 4.6.'da en iyi öğrenme algoritmasına göre en iyi nöron sayısı 10 olarak tespit edilmiştir. (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.97, 0.97 ve 0.98). Elde edilen korelasyon grafikleri Şekil 4.25'te; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.26.'da gösterilmiştir. Senaryo-1'e göre çıkış Alkalinite değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.

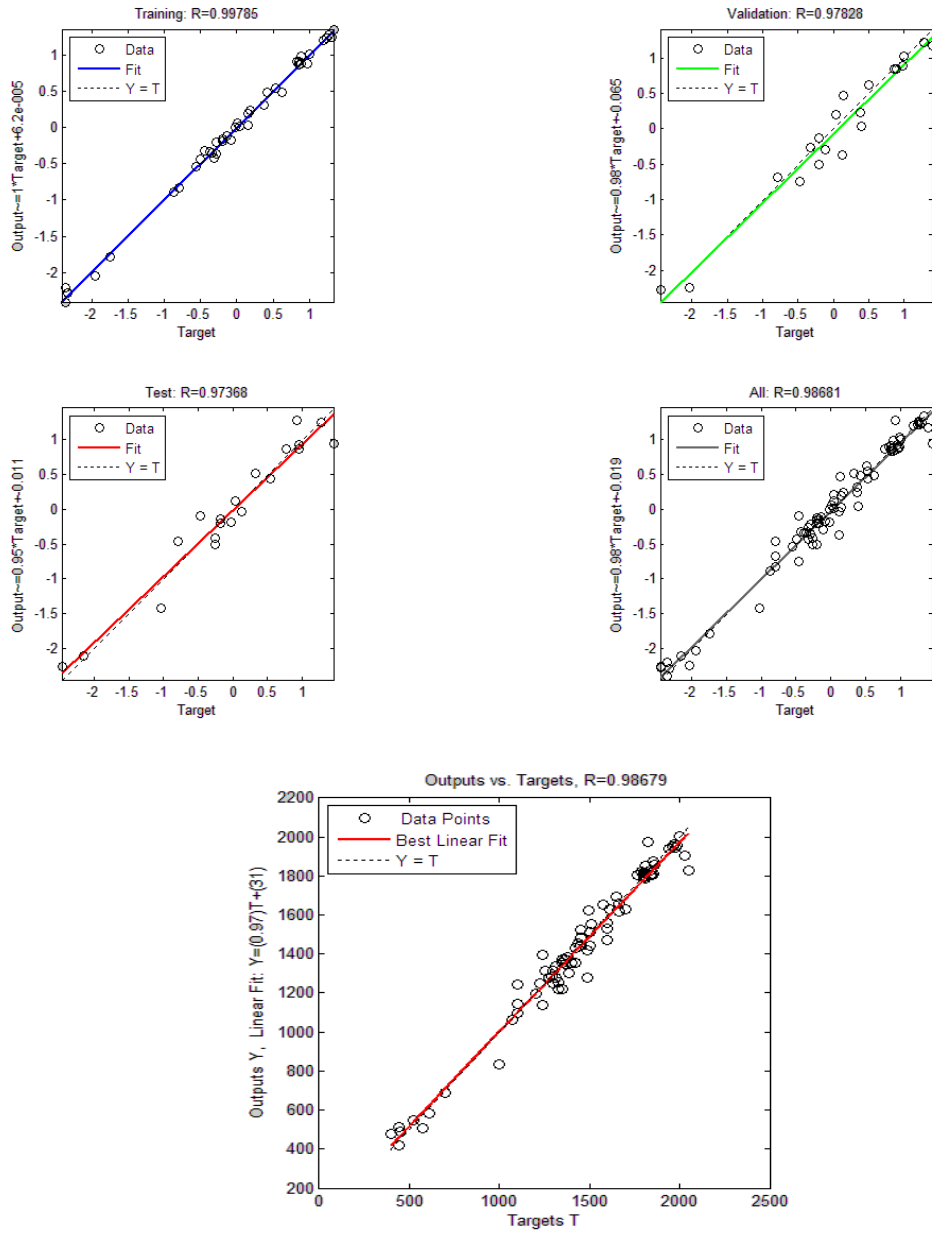


Şekil 4.25. Senaryo-1'e göre Reaktör-2 çıkış alkalinite tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)

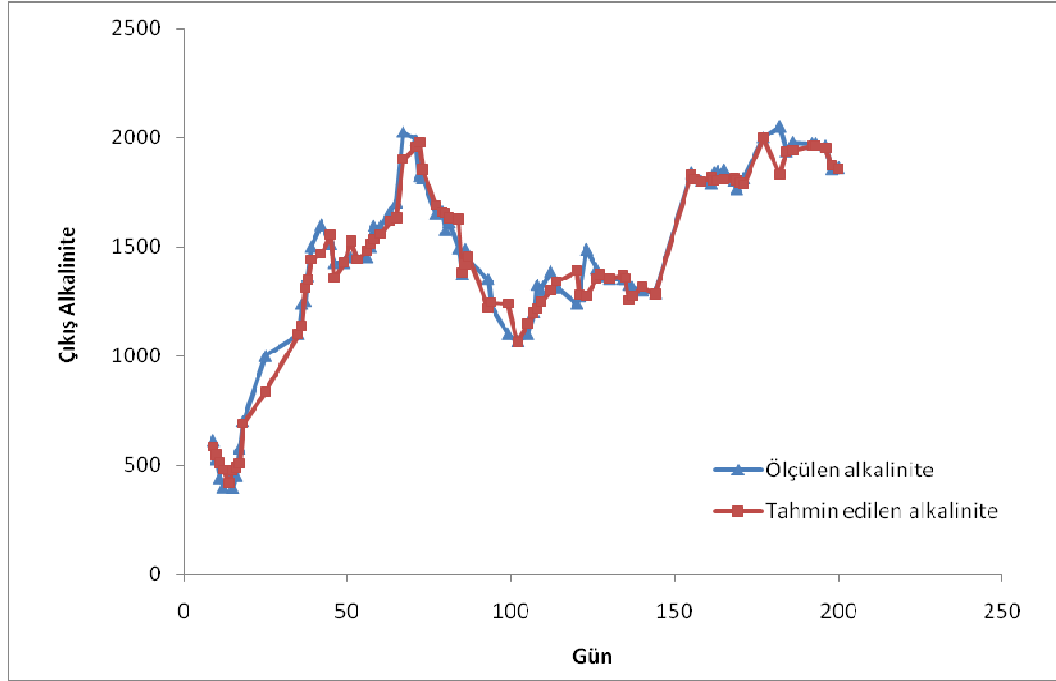


Şekil 4.26. Senaryo-1'e göre (Reaktör-2) çıkış alkalinite için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

Senaryo-2 için (çıkış pH değerinin input parametresi olarak kullanılmaması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.7.'de çıkış Alkalinite tahmininde en iyi öğrenme algoritması trainlm olup Çizelge 4.8.'de de en iyi öğrenme algoritmasına göre en uygun nöron sayısı 5 olarak tespit edilmiştir. (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.98, 0.97 ve 0.98). Elde edilen korelasyon grafikleri Şekil 4.27.'te; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.28.'te gösterilmiştir. Senaryo-2'ye göre çıkış Alkalinite değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.



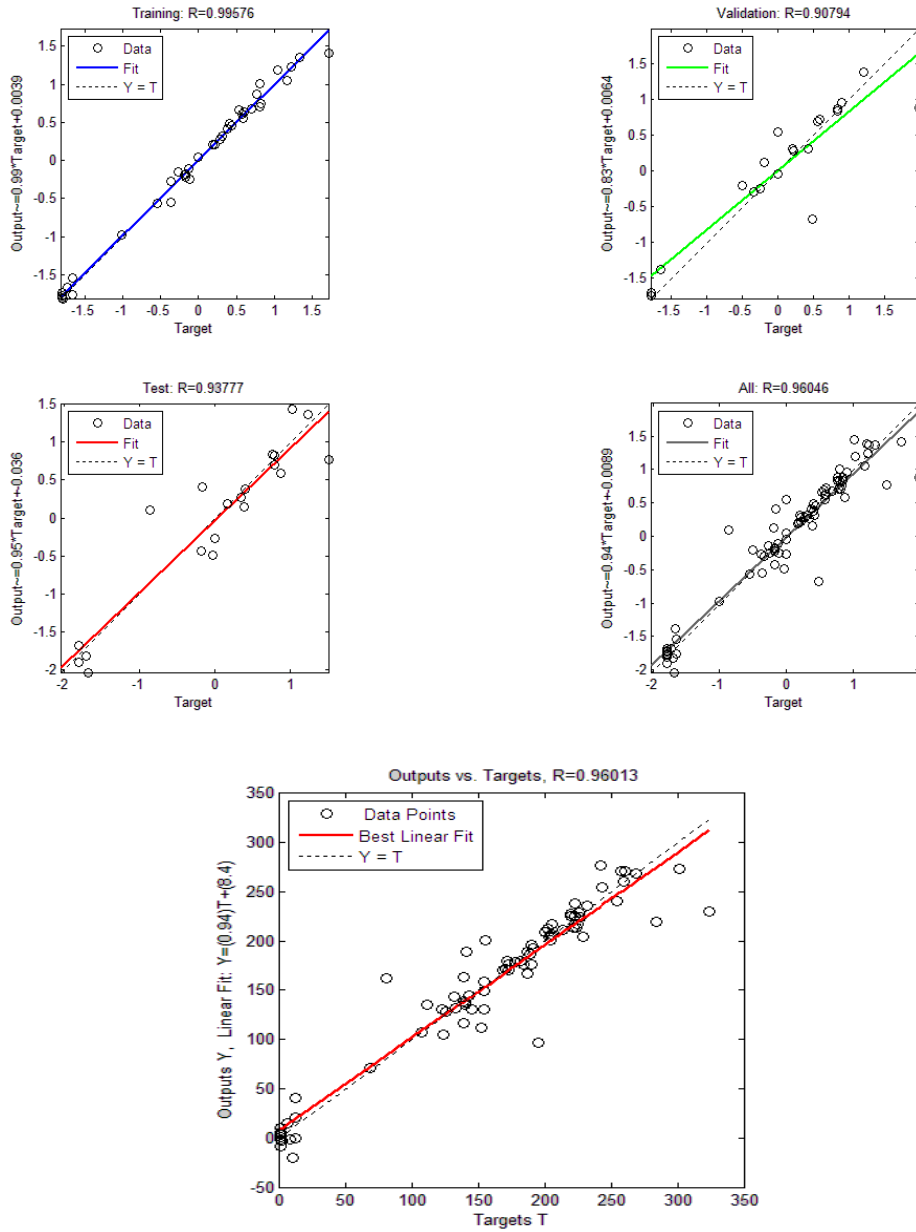
Şekil 4.27. Senaryo-2'ye göre Reaktör-2 çıkış alkalinite tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)



Şekil 4.28. Senaryo-2'ye göre (Reaktör-2) çıkış alkalinite için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması


#### 4.2.4. Çıkış sülfür değerlerinin tahmin edilmesi

Senaryo-1 için (çıkış pH'nın input olarak kullanılması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.7. ve 4.8.'den de görüldüğü üzere çıkış Sülfür tahmininde en iyi öğrenme algoritması trainrp olup en iyi nöron sayısı 20 olarak tespit edilmiştir. (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.91, 0.94 ve 0.96). Elde edilen korelasyon grafikleri Şekil 4.29.'da; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.30.'da gösterilmiştir. Senaryo-1'e göre çıkış Sülfür değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.



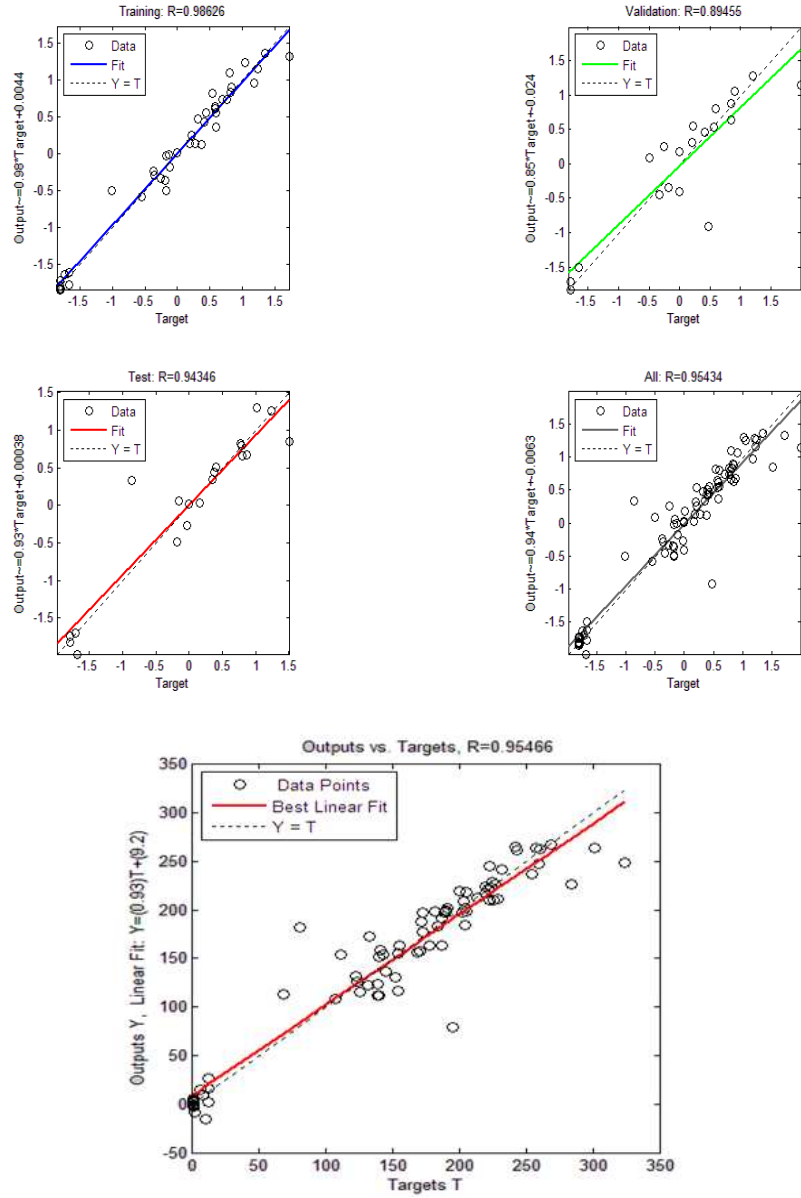
Şekil 4.29. Senaryo-1'e göre Reaktör-2 çıkış sülfür tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)






Şekil 4.30. Senaryo-1'e göre (Reaktör-2) çıkış sülfür için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

Senaryo-2 için (çıkış pH değerinin input parametresi olarak kullanılmaması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.7. ve Çizelge 4.8.'den görüldüğü üzere çıkış sülfür tahmininde en iyi öğrenme algoritması trainrp olup, en iyi nöron sayısı 20 olarak tespit edilmiştir. (R-training, R-validation, R-test ve R-all sırasıyla 0.98, 0.90, 0.94ve 0.96). Elde edilen korelasyon grafikleri Şekil 4.31.'te; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.32.'de gösterilmiştir. Senaryo-2'ye göre çıkış sülfür değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.



Şekil 4.31. Senaryo-2'ye göre Reaktör-2 çıkış sülfür tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)



Şekil 4.32. Senaryo-2'ye göre (Reaktör-2) çıkış sülfür için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

### 4.3. Aşağı Akışlı Akışkan Yataklı Reaktör (R3) Çıkış Değerlerinin YSA ile Tahmin Edilmesi

Bu kısımda, AMS arıtan aşağı akışlı akışkan yataklı reaktörden (Reaktör 3) elde edilen veriler olan;“işletme süresi, giriş pH, çıkış pH, giriş sülfat, giriş kimyasal oksijen ihtiyacı (KOİ) ve giriş metal” olmak üzere toplam 6 input parametresi kullanılarak; “çıkış sülfat, çıkış KOİ, çıkış alkalinite ve çıkış sülfür” konsantrasyonları YSA ile tahmin edilmeye çalışılmıştır. Bu amaçla, 2 senaryo üzerinde çalışılmıştır (Çizelge 4.9, Çizelge 4.10, Çizelge 4.11, Çizelge 4.12). İlkinde çıkış pH değeri input parametreleri içerisinde yer alırken (Senaryo-1); ikinci senaryoda (Senaryo-2) çıkış pH değeri input parametreleri arasından çıkarılmış ve YSA ile reaktör performansının modellenmesine çalışılmıştır. Senaryo-2 ile, AMS arıtımı amaçlı kullanılacak olan bir reaktör henüz kurulmadan performansının tahmin edilmesi hedeflenmektedir.

Çizelge 4.9.Senaryo-1'e göre Reaktör-3 çıkış değerleri için çeşitli öğrenme algoritmalarının değerlendirilmesi ( nöron 20 )

BP Algorithms		Trainlm	Traincgp	Traingd	Traingda	Traingdz	Trainrp	Trainscg	Trainoss	Traincgf	Trainbfg	Traingdm	Traincgb
Sülfat	T-R	0,99	0,7	0,93	0,93	0,95	0,93	0,95	0,26	0,53	0,28	0,91	0,27
	V- R	0,77	0,7	0,7	0,77	0,81	0,68	0,77	0,8	0,75	0,8	0,68	0,79
	Tt-R	0,92	0,7	0,91	0,93	0,93	0,91	0,93	0,93	0,95	0,93	0,92	0,89
	A-R	0,92	0,1	0,88	0,89	0,91	0,87	0,91	0,47	0,61	0,47	0,87	0,25
KOİ	T-R	0,99	0,6	0,98	0,97	0,94	0,99	0,99	0,6	0,61	0,33	0,8	0,57
	V- R	0,95	0,96	0,94	0,97	0,96	0,94	0,97	0,97	0,97	0,96	0,74	0,96
	Tt-R	0,95	0,93	0,96	0,94	0,95	0,9	0,96	0,97	0,96	0,94	0,71	0,97
	A-R	0,97	0,49	0,96	0,96	0,94	0,95	0,97	0,5	0,69	0,33	0,74	0,51
Alkalinite	T-R	0,99	0,41	0,97	0,93	0,98	0,97	0,98	0,08	0,01	0,35	0,66	0,37
	V- R	0,91	0,86	0,82	0,88	0,91	0,84	0,87	0,84	0,87	0,87	0,47	0,79
	Tt-R	0,94	0,93	0,91	0,84	0,86	0,93	0,92	0,91	0,94	0,92	0,51	0,9
	A-R	0,95	0,38	0,92	0,88	0,92	0,92	0,93	0,4	0,2	0,43	0,52	0,3
Sülfür	T-R	1	0,16	0,94	0,93	0,9	0,97	0,97	0,33	0,14	0,18	0,49	0,21
	V- R	0,88	0,88	0,77	0,84	0,84	0,87	0,81	0,83	0,89	0,81	0,54	0,94
	Tt-R	0,79	0,87	0,76	0,76	0,74	0,9	0,84	0,8	0,85	0,88	0,32	0,85
	A-R	0,92	0,41	0,86	0,87	0,85	0,94	0,9	0,34	0,23	0,51	0,44	0,49

Çizelge 4.10. Senaryo-1'e göre her bir out-put parametresi (Reaktör-3) için farklı nöron sayılarında elde edilen tahminlerin kıyaslanması

Nöron Sayısı		3	5	10	20	30	40
Sülfat (trainlm)	T-R	0,85	0,97	0,98	<b>0,99</b>	0,99	0,99
	V-R	0,52	0,61	0,74	<b>0,77</b>	0,71	0,63
	Tt-R	0,73	0,95	0,92	<b>0,92</b>	0,88	0,86
	A-R	0,75	0,89	0,91	<b>0,92</b>	0,91	0,88
KOİ (trainscg)	T-R	0,98	<b>0,99</b>	0,98	0,99	0,99	0,99
	V-R	0,95	<b>0,97</b>	0,98	0,97	0,95	0,89
	Tt-R	0,97	<b>0,97</b>	0,97	0,96	0,95	0,83
	A-R	0,97	<b>0,98</b>	0,98	0,97	0,97	0,92
Alkalinite (trainlm)	T-R	0,98	0,99	0,99	<b>0,99</b>	0,99	0,99
	V-R	0,82	0,82	0,73	<b>0,91</b>	0,62	0,85
	Tt-R	0,95	0,93	0,9	<b>0,94</b>	0,8	0,86
	A-R	0,94	0,93	0,9	<b>0,95</b>	0,84	0,92
Sülfür (trainrp)	T-R	0,95	0,96	0,97	<b>0,98</b>	0,96	0,97
	V-R	0,9	0,82	0,86	<b>0,87</b>	0,72	0,83
	Tt-R	0,86	0,86	0,78	<b>0,90</b>	0,64	0,73
	A-R	0,91	0,9	0,9	<b>0,94</b>	0,83	0,88

Çizelge 4.11.Senaryo-2' ye göre Reaktör-3 çıkış değerleri için çeşitli öğrenme algoritmalarının değerlendirilmesi ( nöron 20 )

BP Algorithm		Trainim	Traincgp	Traingd	Trainгда	Traingdх	Trainrp	Trainscg	Trainoss	Traincgf	Trainbfg	Traingdm	Traincgb
Süfat	T-R	0.96	0.14	0.94	0.94	0.96	<b>0.96</b>	0.96	0.62	0.24	0.56	0.07	0.12
	V- R	0.95	0.71	0.78	0.80	0.81	<b>0.85</b>	0.85	0.88	0.83	0.87	0.02	0.86
	Tt-R	0.94	0.93	0.95	0.94	0.94	<b>0.96</b>	0.93	0.35	0.94	0.95	0.25	0.92
	A-R	0.93	0.17	0.91	0.91	0.92	<b>0.93</b>	0.92	0.48	0.15	0.41	0.11	0.28
KOİ	T-R	<b>0.99</b>	0.52	0.98	0.97	0.99	0.98	0.99	0.20	0.32	0.41	0.75	0.67
	V- R	<b>0.97</b>	0.97	0.96	0.96	0.97	0.96	0.97	0.97	0.97	0.97	0.58	0.97
	Tt-R	<b>0.97</b>	0.97	0.96	0.96	0.96	0.97	0.97	0.97	0.96	0.96	0.53	0.97
	A-R	<b>0.98</b>	0.47	0.97	0.96	0.98	0.97	0.98	0.25	0.17	0.62	0.57	0.14
Alkalinite	T-R	<b>0.99</b>	0.15	0.97	0.94	0.88	0.97	0.97	0.47	0.45	0.39	0.36	0.64
	V- R	<b>0.87</b>	0.88	0.88	0.86	0.83	0.87	0.92	0.87	0.86	0.87	0.31	0.86
	Tt-R	<b>0.93</b>	0.95	0.92	0.90	0.78	0.89	0.95	0.93	0.94	0.94	0.03	0.92
	A-R	<b>0.95</b>	0.23	0.93	0.91	0.84	0.93	0.95	0.23	0.58	0.20	0.22	0.38
Sülfür	T-R	<b>0.98</b>	0.34	0.92	0.91	0.77	0.98	0.95	0.67	0.31	0.29	0.91	0.50
	V- R	<b>0.96</b>	0.95	0.92	0.87	0.68	0.96	0.89	0.92	0.96	0.97	0.89	0.95
	Tt-R	<b>0.83</b>	0.83	0.80	0.79	0.66	0.82	0.83	0.80	0.84	0.85	0.80	0.85
	A-R	<b>0.94</b>	0.06	0.89	0.87	0.72	0.94	0.91	0.19	0.07	0.45	0.88	0.07

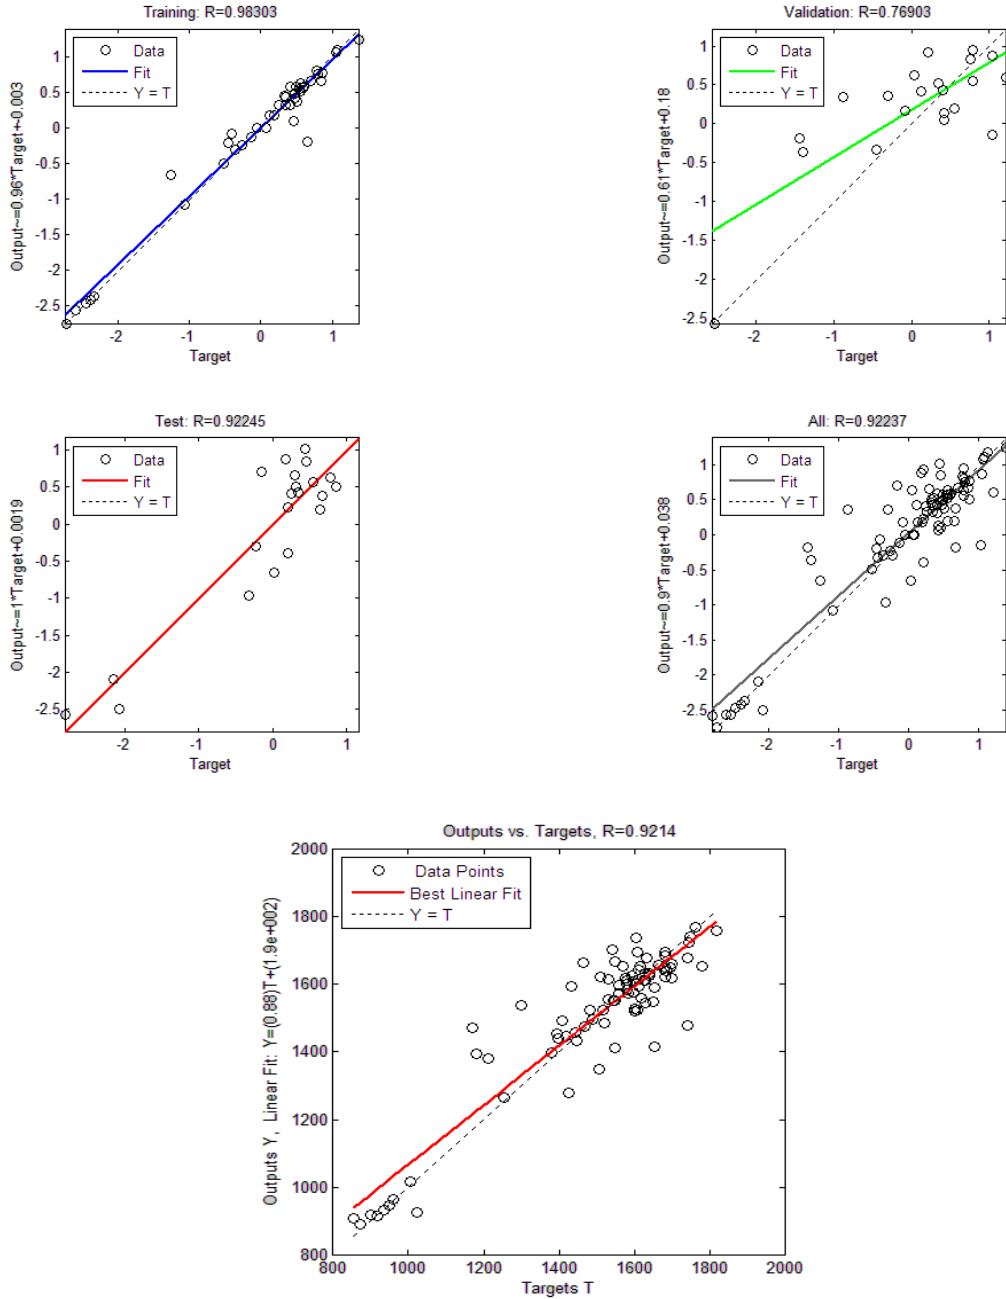
Çizelge 4.12. Senaryo-2'ye göre her bir out-put parametresi (Reaktör-3) için farklı nöron sayılarında elde edilen tahminlerin kıyaslanması

Nöron Sayısı		3	5	10	20	30	40
Sülfat (trainrp)	T-R	0.92	0.88	0.95	<b>0.96</b>	0.95	0.96
	V- R	0.80	0.74	0.84	<b>0.85</b>	0.85	0.86
	Tt-R	0.90	0.92	0.95	<b>0.96</b>	0.93	0.96
	A-R	0.89	0.86	0.93	<b>0.93</b>	0.92	0.93
KOl (trainlm)	T-R	0.97	0.99	0.99	<b>0.99</b>	0.99	1
	V- R	0.98	0.98	0.98	<b>0.97</b>	0.96	0.96
	Tt-R	0.98	0.97	0.97	<b>0.97</b>	0.96	0.96
	A-R	0.97	0.97	0.98	<b>0.98</b>	0.97	0.98
Alkalinite (trainlm)	T-R	0.95	0.98	0.98	<b>0.99</b>	0.99	0.99
	V- R	0.79	0.87	0.85	<b>0.87</b>	0.87	0.80
	Tt-R	0.89	0.92	0.94	<b>0.93</b>	0.94	0.94
	A-R	0.89	0.94	0.94	<b>0.95</b>	0.95	0.94
Sülfür (trainlm)	T-R	0.97	0.98	0.98	<b>0.98</b>	0.99	0.99
	V-R	0.96	0.96	0.97	<b>0.96</b>	0.96	0.93
	Tt-R	0.82	0.82	0.83	<b>0.83</b>	0.80	0.82
	A-R	0.93	0.93	0.94	<b>0.94</b>	0.94	0.93




#### 4.3.1. Çıkış sülfat değerlerinin tahmin edilmesi

Öncelikle senaryo-1 için (çıkış pH değerinin input parametresi olarak kullanılması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.10.'dan da görüldüğü üzere çıkış sülfat tahmininde en iyi öğrenme algoritması trainlm olup, Çizelge 4.11.'de de nöron sayısı 20 olarak bulunduğu gösterilmiştir. (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.77, 0.92 ve 0.92). Elde edilen korelasyon grafikleri Şekil 4.33.'de; ölçülen değerler ile tahmin değerlerinin kıyaslanması için reaktör işletme zamanına göre elde edilen grafik ise Şekil 4.34.'de gösterilmiştir. Senaryo-1'e göre çıkış sülfat değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir

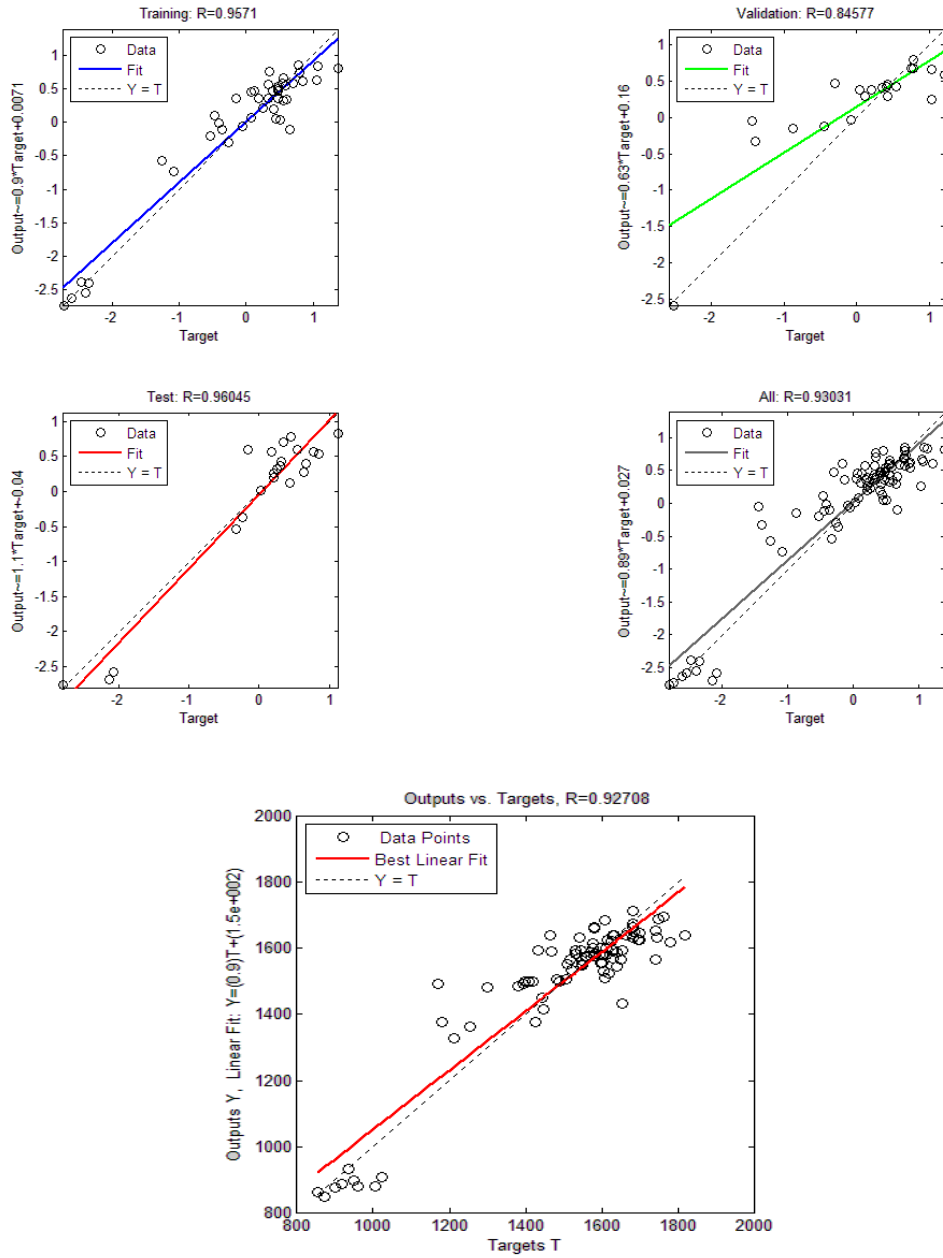


Şekil 4.33. Senaryo-1'e göre Reaktör-3 çıkış sülfat tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)




Şekil 4.34. Senaryo-1'e göre (Reaktör-3) çıkış sülfat için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

Senaryo-2 için (çıkış pH değerinin input parametresi olarak kullanılmaması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.12.'den de görüldüğü üzere çıkış sülfat tahmininde en iyi öğrenme algoritması trainrp olup nöron sayısı 20 olarak bulunmuştur.(R-training, R-validation, R-test ve R-all sırasıyla 0.96, 0.85, 0.96 ve 0.93). Elde edilen korelasyon grafikleri Şekil 4.35.'te; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.36.'da gösterilmiştir. Senaryo-2'ye göre çıkış sülfat değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.



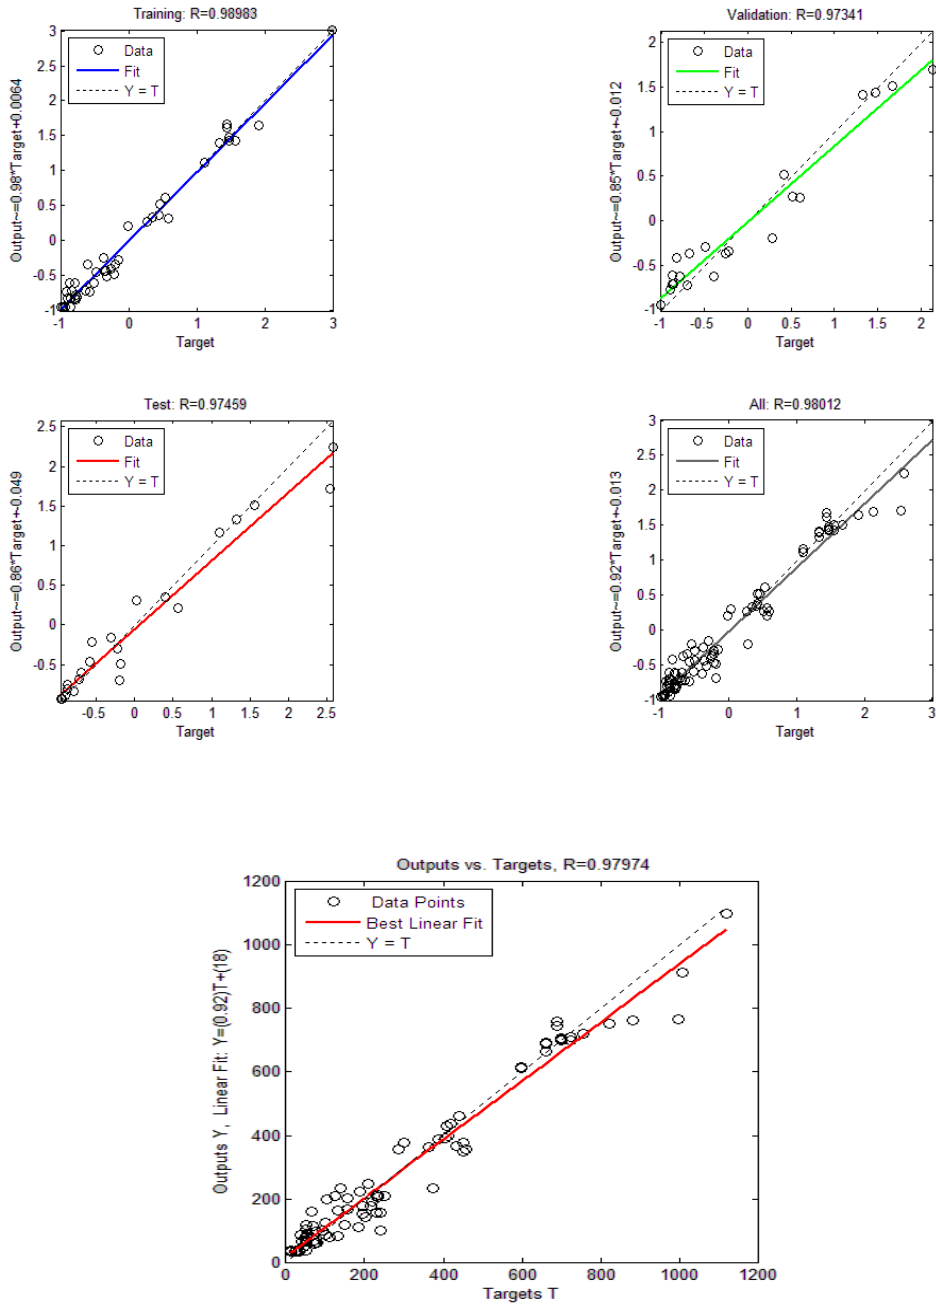
Şekil 4.35. Senaryo-2'ye göre Reaktör-3 çıkış sülfat tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)




Şekil 4.36. Senaryo-1'e göre (Reaktör-3) çıkış sülfat için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

#### 4.3.2. Çıkış KOI değerlerinin tahmin edilmesi

Öncelikle senaryo-1 için (çıkış pH değerinin input parametresi olarak kullanılması halini) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.10.'dan da görüldüğü üzere çıkış KOİ tahmininde en iyi öğrenme algoritması trainscg olup, Çizelge 4.11.'de de nöron sayısının 5 olarak bulunduğu gösterilmiştir. (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.97, 0.97 ve 0.98). Elde edilen korelasyon grafikleri Şekil 4.37.'de; ölçülen değerler ile tahmin değerlerinin kıyaslanması için reaktör işletme zamanına göre elde edilen grafik ise Şekil 4.38.'de gösterilmiştir. Senaryo-1'e göre çıkış KOİ değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir

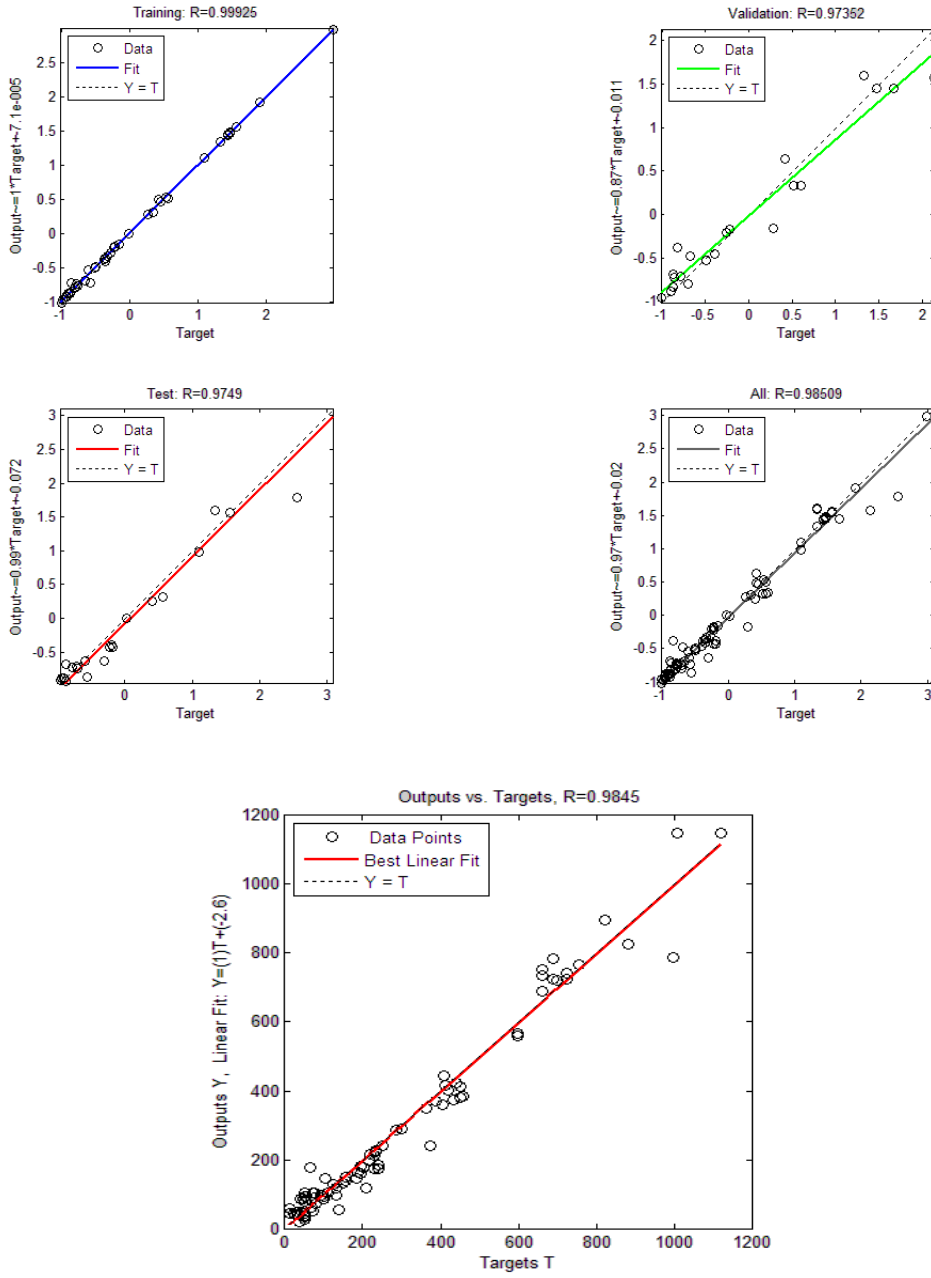


Şekil 4.37. Senaryo-1'e göre Reaktör-3 çıkış KOI tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)




Şekil 4.38. Senaryo-1'e göre (Reaktör-3) çıkış KOİ için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

Senaryo-2 için (çıkış pH değerinin input parametresi olarak kullanılmaması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.12.'den de görüldüğü üzere çıkış KOİ tahmininde en iyi öğrenme algoritması trainlm olup, çizelge 4.13.'ten de nöron sayısının 20 olarak bulunduğu gösterilmiştir.(R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.97, 0.97 ve 0.98). Elde edilen korelasyon grafikleri Şekil 4.39.'da; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.40.'da gösterilmiştir. Senaryo-2'ye göre çıkış KOİ değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.



Şekil 4.39. Senaryo-2'ye göre Reaktör-3 çıkış KOI tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)

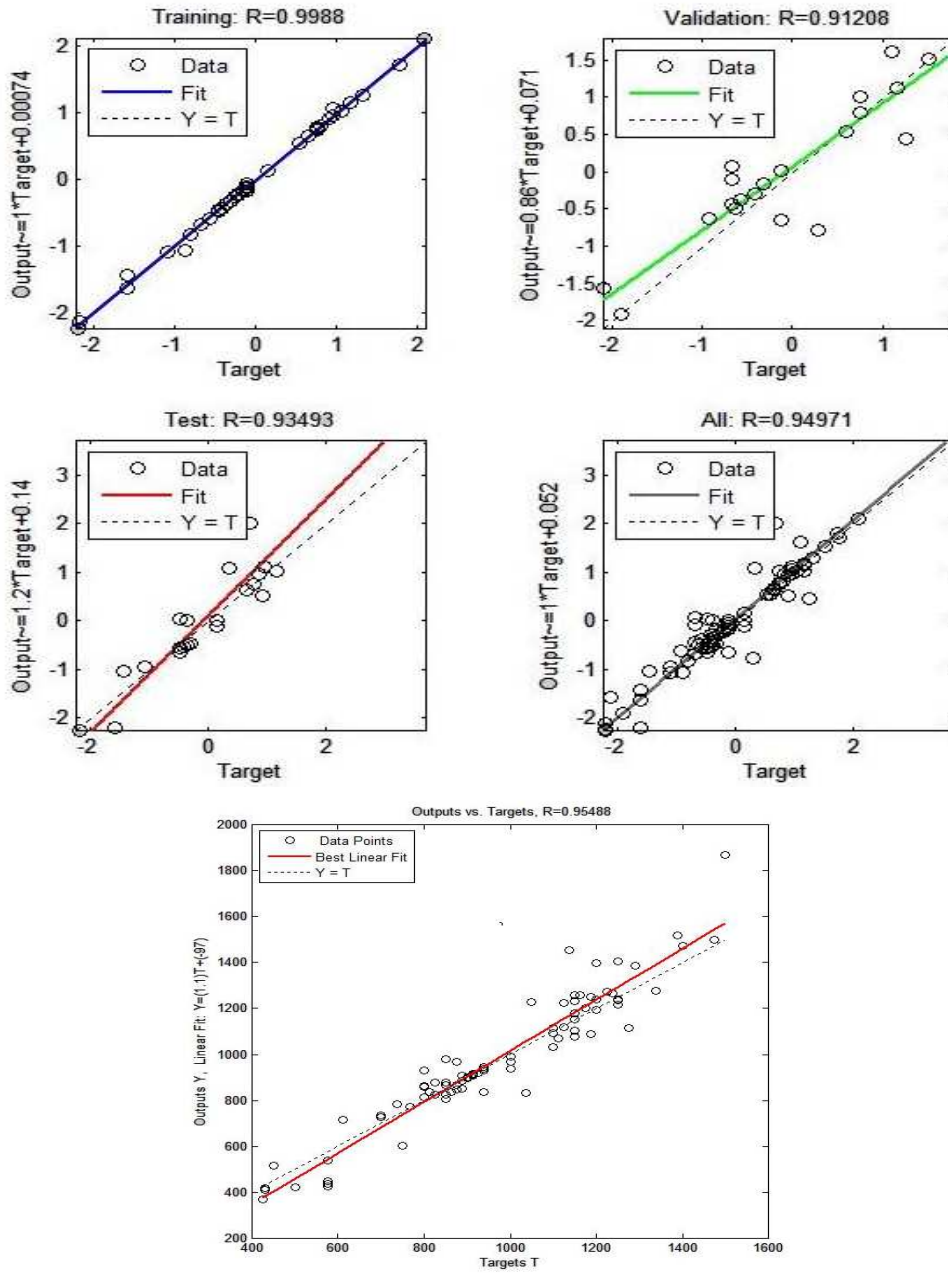





Şekil 4.40. Senaryo-2'ye göre (Reaktör-3) çıkış KOİ için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

#### 4.3.3. Çıkış alkalinite değerlerinin tahmin edilmesi

Öncelikle senaryo-1 için (çıkış pH değerinin input parametresi olarak kullanılması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.10.'dan da görüldüğü üzere çıkış alkalinite tahmininde en iyi öğrenme algoritması trainlm olup, Çizelge 4.11.'de de nöron sayısının 20 olarak bulunduğu gösterilmiştir. (R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.91, 0.94 ve 0.95). Elde edilen korelasyon grafikleri Şekil 4.41.'de; ölçülen değerler ile tahmin değerlerinin kıyaslanması için reaktör işletme zamanına göre elde edilen grafik ise Şekil 4.42.'de gösterilmiştir. Senaryo-1'e göre çıkış alkalinite değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.

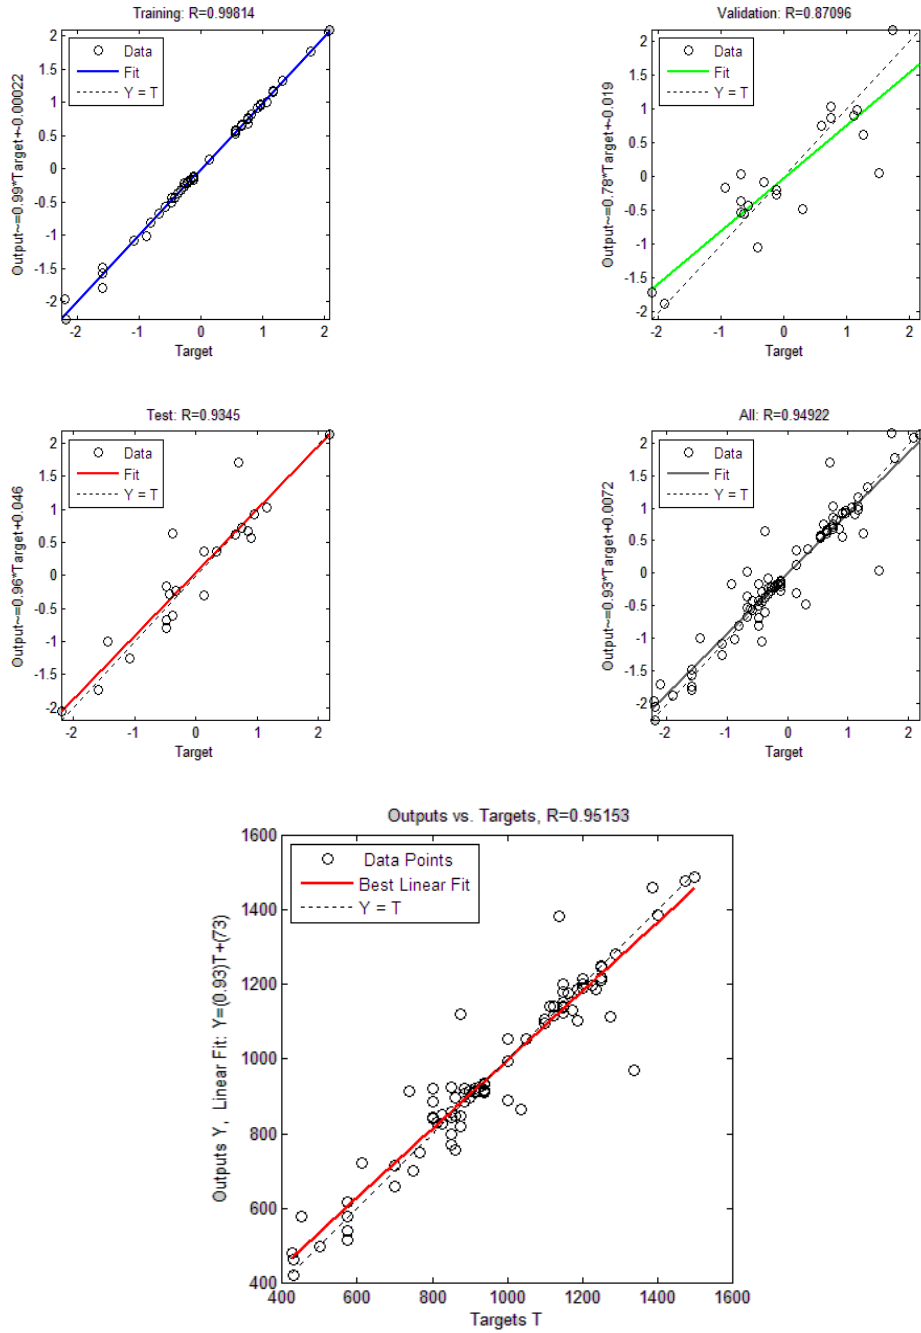


Şekil 4.41. Senaryo-1'e göre Reaktör-3 çıkış alkalinite tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)




Şekil 4.42. Senaryo-1'e göre (Reaktör-3) çıkış alkalinite için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

Senaryo-2 için (çıkış pH değerinin input parametresi olarak kullanılmaması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.12.'den de görüldüğü üzere çıkış alkalinite tahmininde en iyi öğrenme algoritması trainlm olup, çizelge 4.13.'ten de nöron sayısının 20 olarak bulunduğu gösterilmiştir.(R-training, R-validation, R-test ve R-all sırasıyla 0.99, 0.97, 0.93 ve 0.95). Elde edilen korelasyon grafikleri Şekil 4.43.'te; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.44'te gösterilmiştir. Senaryo 2'ye göre çıkış alkalinite değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.



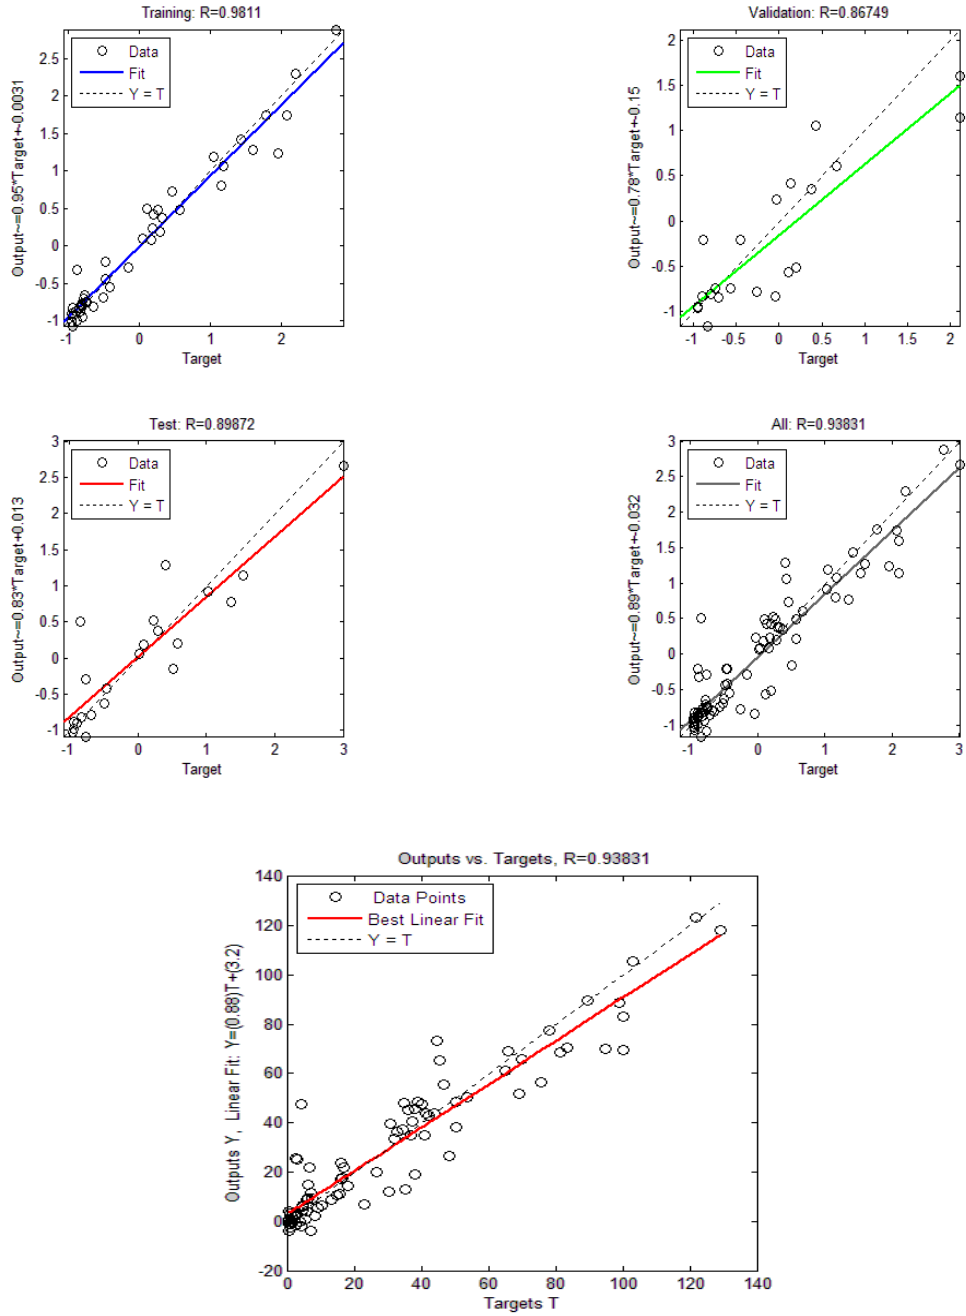
Şekil 4.43. Senaryo-2'ye göre Reaktör-3 çıkış alkalinite tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)




Şekil 4.44. Senaryo-2'ye göre (Reaktör-3) çıkış alkalinite için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

#### 4.3.4. Çıkış sülfür değerlerinin tahmin edilmesi

Öncelikle senaryo-1 için (çıkış pH değerinin input parametresi olarak kullanılması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.10.'dan da görüldüğü üzere çıkış sülfür tahmininde en iyi öğrenme algoritması trainrp olup, Çizelge 4.11.'de de nöron sayısının 20 olarak bulunduğu gösterilmiştir. (R-training, R-validation, R-test ve R-all sırasıyla 0.98, 0.87, 0.90 ve 0.94). Elde edilen korelasyon grafikleri Şekil 4.45.'te; ölçülen değerler ile tahmin değerlerinin kıyaslanması için reaktör işletme zamanına göre elde edilen grafik ise Şekil 4.46.'da gösterilmiştir. Senaryo-1'e göre çıkış sülfür değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.

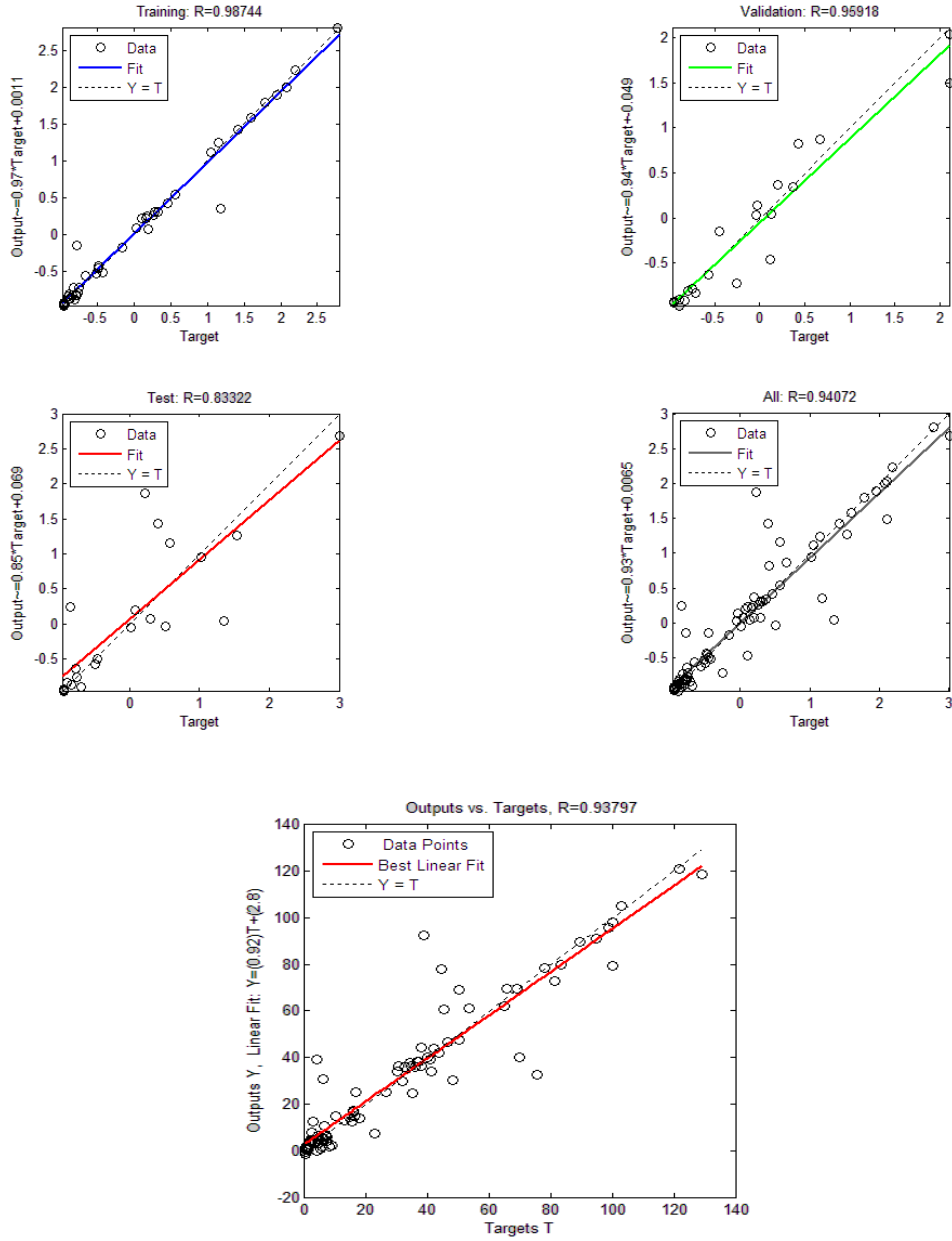


Şekil 4.45. Senaryo-1'e göre Reaktör-3 çıkış sülfür tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)




Şekil 4.46. Senaryo-1'e göre (Reaktör-3) çıkış sülfür için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

Senaryo-2 için (çıkış pH değerinin input parametresi olarak kullanılmaması hali) en iyi öğrenme algoritmasının seçimi çalışmaları yapılmıştır. Burada 12 farklı öğrenme algoritması kullanılarak öğrenme (training), doğrulama (validation), test ve tüm datalar (all) için R değerleri karşılaştırılmıştır. Bu karşılaştırmalarda nöron sayısı 20'de sabit tutularak sadece öğrenme algoritması değiştirilmiştir. Çizelge 4.12.'den de görüldüğü üzere çıkış sülfür tahmininde en iyi öğrenme algoritması trainlm olup, çizelge 4.13.'ten de nöron sayısının 20 olarak bulunduğu gösterilmiştir.(R-training, R-validation, R-test ve R-all sırasıyla 0.98, 0.96, 0.83 ve 0.94). Elde edilen korelasyon grafikleri Şekil 4.47.'te; ölçülen değerler ile tahmin değerlerinin kıyaslanması ise Şekil 4.48'te gösterilmiştir. Senaryo 2'ye göre çıkış sülfür değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.



Şekil 4.47. Senaryo-2'ye göre Reaktör-3 çıkış sülfür tahmininde en iyi öğrenme algoritması ve nöron sayısı için training, validation, test ve all için korelasyon grafikleri ve ölçülen ile tahmin edilen verilerin kıyaslanması (Y: tahmin verileri, T: ölçülen değerler)





Şekil 4.48. Senaryo-2'ye göre (Reaktör-3) çıkış sülfür için ölçülen değerler ve YSA tahmin değerlerinin kıyaslanması

## 5. SONUÇLAR ve ÖNERİLER

Bu çalışmada, AMS arıtan yukarı akışlı akışkan yataklı reaktör (Reaktör 1) ve aşağı akışlı akışkan yataklı reaktörlerden (Reaktör 2 ve Reaktör 3) elde edilen veriler olan; “işletme süresi, giriş pH, çıkış pH, giriş sülfat, giriş kimyasal oksijen ihtiyacı (KOİ) ve giriş metal” olmak üzere toplam 6 input parametresi kullanılarak; “çıkış sülfat, çıkış KOİ, çıkış alkalinite ve çıkış sülfür” konsantrasyonları yapay sinir ağı (YSA) ile tahmin edilmiştir. Bu amaçla 2 senaryo üzerinde çalışılmıştır. İlkinde çıkış pH değeri input parametreleri içerisinde yer alırken (Senaryo-1); ikinci senaryoda (Senaryo-2) çıkış pH değeri input parametreleri arasından çıkarılmış ve YSA ile reaktör performanslarının modellenmesi yapılmıştır.

Senaryo 1’e göre çıkış sülfat değerlerinin tahmininde tüm sonuçları (öğrenme-doğrulama-test) temsil eden (all) R değerleri; Reaktör 1, 2 ve 3 için sırasıyla 0.94, 0.95 ve 0.92 olarak belirlenmiştir. Senaryo 1’e göre çıkış sülfat için nöron sayısı 20 de sabit tutularak en iyi öğrenme algoritmaları Reaktör 1, 2, ve 3 için sırasıyla trainrp, trainrp ve trainlm olarak tespit edilmiştir. Öğrenme algoritmaları sabit tutularak optimum nöron sayıları ise Reaktör 1, 2 ve 3 için sırasıyla 20, 20 ve 20 olarak bulunmuştur. Tüm reaktörler için ölçülen ve tahmin edilen çıkış sülfat değerleri arasında öğrenme, doğrulama ve test grafiklerinde yüksek korelasyon sabitleri bulunmuştur.

Senaryo 2’ye göre çıkış sülfat değerlerinin tahmininde tüm sonuçları (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.95, 0.93 ve 0.93 olarak belirlenmiştir. Senaryo-2’ye göre, çıkış sülfat için nöron sayısı 20’de sabit tutularak en iyi öğrenme algoritmaları Reaktör 1, 2 ve 3 için sırasıyla trainlm, trainrp ve trainrp olarak bulunmuştur. Öğrenme algoritmaları sabit tutularak optimum nöron sayıları ise Reaktör 1, 2 ve 3 için sırasıyla 10, 20, 20 olarak belirlenmiştir. Öğrenme, doğrulama, test grafiklerinde korelasyon sabitleri oldukça yüksek bulunmuştur. Senaryo 1 ve 2’ye göre tüm reaktörlerin çıkış sülfat değerleri optimize edilen YSA ile oldukça iyi bir şekilde tahmin edilebilmiştir.

Senaryo 1’e göre çıkış KOİ değerlerinin tüm sonuçlarını (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.95, 0.98 ve 0.98 olarak belirlenmiştir. Çıkış KOİ değerlerinin tahmininde Senaryo-1 için nöron sayısı

20’de sabit tutularak en iyi öğrenme algoritmaları Reaktör 1, 2 ve 3 için sırasıyla trainlm, trainrp ve trainscg olarak belirlenmiştir. Öğrenme algoritmaları sabit tutularak sadece nöron sayıları değiştirilmiş ve optimum nöron sayıları Reaktör 1. 2 ve 3 için sırasıyla 40, 3 ve 5 olarak bulunmuştur.

Senaryo 2’ye göre çıkış KOİ değerlerinin tahmininde tüm sonuçları (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.97, 0.98 ve 0.98 olarak belirlenmiştir. Senaryo-2’ye göre çıkış KOİ tahmini için, nöron sayısı 20’de sabit tutularak, en iyi öğrenme algoritmaları Reaktör 1, 2 ve 3 için sırasıyla trainrp, trainrp ve trainlm olarak bulunmuştur. Öğrenme algoritmaları sabit tutularak sadece nöron sayıları değiştirilmiş ve optimum nöron sayıları Reaktör 1. 2 ve 3 için sırasıyla 20, 10 ve 20 olarak belirlenmiştir. Tüm korelasyon sabitleri oldukça yüksek değerler almıştır. Senaryo 1 ve 2’ye göre tüm reaktörlerin çıkış KOİ değerleri ile tahmin değerleri birbirine çok yakın bulunmuş olup, YSA ile çıkış KOİ değerlerinin başarılı bir şekilde tahmin edilebileceği gösterilmiştir.

Senaryo 1’e göre çıkış alkalinite değerlerinin tüm sonuçlarını (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.97, 0.98 ve 0.95 olarak belirlenmiştir. Çıkış alkalinite değerlerinin tahmininde Senaryo-1 için nöron sayısı 20’de sabit tutularak en iyi öğrenme algoritması Reaktör 1, 2 ve 3 için sırasıyla trainrp, trainrp ve trainlm olarak bulunmuştur. Öğrenme algoritmaları sabit tutularak sadece nöron sayıları değiştirilmiş ve optimum nöron sayıları Reaktör 1, 2 ve 3 için sırasıyla 20, 10 ve 20 olarak belirlenmiştir.

Senaryo-2’ye göre çıkış alkalinite tahmini için en iyi öğrenme algoritması nöron sayısı 20’de sabit tutularak Reaktör 1, 2 ve 3 için sırasıyla trainlm, trainlm ve trainlm olarak bulunmuştur. Öğrenme algoritmaları sabit tutularak sadece nöron sayıları değiştirilmiş ve optimum nöron sayıları ise Reaktör 1, 2 ve 3 için sırasıyla 30, 5 ve 20 şeklinde belirlenmiştir Senaryo 2’ye göre çıkış alkalinite değerlerinin tüm sonuçlarını (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.98, 0.98 ve 0.95 olarak belirlenmiştir. Senaryo 1 ve 2’ye göre tüm reaktörlerin çıkış alkalinite değerleri oldukça başarılı bir şekilde tahmin edilebilmiştir.

Senaryo 1’e göre çıkış sülfür değerlerinin tüm sonuçlarını (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.98,

0.96 ve 0.94 olarak belirlenmiştir. Senaryo 1'e göre çıkış sülfür değerlerinin tahmininde nöron sayıları 20'de sabit tutularak en iyi öğrenme algoritmaları Reaktör 1, 2 ve 3 için sırasıyla; trainrp, trainrp ve trainrp olarak bulunmuştur. Öğrenme algoritmaları sabit tutularak sadece nöron sayıları değiştirilmiş ve optimum nöron sayıları Reaktör 1, 2 ve 3 için sırasıyla 20, 20 ve 20 olarak bulunmuştur.

Senaryo-2'ye göre çıkış sülfür değerlerinin tüm sonuçlarını (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.97, 0.96 ve 0.94 olarak belirlenmiştir. En iyi öğrenme algoritması nöron sayısı 20'de sabit tutularak Reaktör 1, 2 ve 3 için sırasıyla traingdx, trainrp ve trainlm olarak bulunmuştur. Öğrenme algoritmaları sabit tutularak sadece nöron sayıları değiştirilmiş ve optimum nöron sayıları Reaktör 1, 2 ve 3 için sırasıyla 30, 20 ve 20 olarak belirlenmiştir. Korelasyon sabitleri oldukça yüksek değerler almıştır. Senaryo 1 ve 2'ye göre tüm reaktörlerin çıkış sülfür değerleri ile tahmin değerleri birbirine çok yakın bulunmuş olup, YSA ile çıkış sülfür değerlerinin başarılı bir şekilde tahmin edilebileceği gösterilmiştir.

Yapay sinir ağları sürekli olarak gelişerek bilimin bütün alanlarında kullanılmaya başlamıştır. Kullanımına olan ilginin artmasıyla beraber, yapay sinir ağlarının teorik alt yapısı ile öğrenme ve optimizasyon algoritmaları da sürekli olarak geliştirilmektedir. Yapay sinir ağlarının kullanıldığı alanlardan biri de kimyasal ve biyolojik sistemlerin modellenmesidir. Bu tip modellerin normal matematiksel modellerle tanımlanmaya çalışılmasında, birçok katsayının belirlenmesi ve kabulün yapılması gerektiği için, kimi zaman elde edilen sonuçlar doğruluktan çok uzakta olabilmektedir. Dolayısıyla birçok belirsizliğin olduğu bu gibi sistemlerin modellenmesinde, yapay sinir ağları güvenilir ve uygulaması kolay bir alternatif model olarak karşımıza çıkmaktadır.

Bu çalışma sonucunda, sülfidojenik reaktörlerin yapay sinir ağları ile başarılı bir biçimde modellenebileceği gösterilmiştir. İşletim süresinin de giriş parametreleri arasına alınması sonucunda reaktör işletimi süresince farklılaşan ve yeni işletim şartlarına adapte olan bakteriyel komüniteden doğan değişimler de modellemeye dahil edilmiştir. Biyolojik sistemlerle atıksu arıtımında, yapay sinir ağlarının uygulanabilirliğinin araştırılması spesifik ve henüz çalışılmamış bir konu olup, özellikle laboratuvar ölçekli atık su reaktörlerin işletiminin modellenmesinde yapay

sinir ağlarının kullanımıyla ilgili araştırma sayısı da son derece sınırlıdır. Günlük olarak çok sayıda atıksu giriş ve çıkış parametrelerinin analizinin yapıldığı bu sistemlerde modelleme çalışmaları, bu konuda çalışan araştırmacılar için oldukça geniş ufuklar açabilecektir.

Ayrıca, reaktör veya tesis işletimi oldukça maliyetli bir süreçtir. Bu süreçte maliyetleri en aza indirmek için birçok yöntem araştırılmaktadır. Bu bağlamda YSA ile reaktörlerin modellenmesi, işletimde birçok kolaylıklar sağlayabilecektir. Reaktörlerin YSA ile modellenmesi atıksu giriş ve çıkış parametrelerinin analiz sayısını azaltarak finansal ve zamansal açıdan büyük katkılar doğurabilecek ve analiz maliyetlerinin düşmesine imkan vererek Bölgesel veya Ulusal ekonomiye girdiler oluşturabilecektir. Ayrıca bu çalışmamızda uygulanan senaryo 2 ile henüz reaktör kurulmadan performans tahmini de mümkün olabilmektedir. Böylece pilot ölçekli sistemlerin dizayn ve işletiminde önemli iyileştirmeler yapılabilecektir. Sadece 2 tip reaktörde başlatılan bu çalışma, daha değişik sistemlere de uygulanabileceği için, araştırmacılara geniş çalışma alanları sunmaktadır.

## KAYNAKLAR

- AÇIKALIN, S., İLERİ, R. KELEŞ. R., 2006. Adapazarı Kentsel Atıksu Arıtma Tesisi Cıkıs Suyu Parametreleri ve Verim Değerlerinin Yapay Sinir Ağları İle Tahmin Edilmesi.
- AKÇİL, A. ve KOLDAS, S., 2006. "Acid Mine Drainage (AMD): Causes, Treatment and Case Studies". Journal of Cleaner Production
- ALMASRİ, M.N., KALUARACHCHİ, J.J.,2005. Modular neural networks to predict the nitrate distribution in ground water using the onground nitrogen loading and recharge data. Environ Model
- BURGESS, J.E. ve STUETZ, R.M., 2002. "Activated Sludge for the Treatment of Sulphur-rich Wastewaters", Minerals Engineering, 15, 839- 846.
- CINAR, O. YILMAZ, A., 2005. Yapay Sinir Ağlarının Atık su Arıtma Tesisi işletimine Uygulanması: Bir Örnek Çalışma, KSU. Fen ve Mühendislik Dergisi, 27;15-23
- COSTELLO, C. 2003. "Acid Mine Drainage: Innovative Treatment Technologies", U.S. Environmental Protection Agency (EPA), Office of Solid Waste and Emergency Response, Technology Innovatio Office, Washington, DC, USA, 47.
- ÇİFTÇİ, H. AKÇİL, A., 2006. AMD Giderilmesinde Uygulanan Biyolojik Yöntemler, Madencilik Dergisi, 45(1); 35-45.
- HALLBERG, K.B. ve JOHNSON, D.B. 2005. "Microbiology of a Wetla Ecosystem Constructed to Remediate Mine Drainage from a Heavy Metal Mine", Science of the Total Environment, 338, 53-66.
- HEDİN, R. S.; NARİN, R.W. ve KLEİNMAN, R.L.P. 1994. "Passive Treatment of Coal Mine Drainage", Bureau of Land Mine Information Circular 9389.
- KABACA, M., GERGER, V., YETKİN S., SOFUOĞLU S., İNAL F., 2007. İstanbul İli Ozon Konsantrasyonlarının Yapay Sinir Ağları İle Tahmini, 7.Ulusal Çevre Mühendisliği Kongresi Yaşam Çevre Teknolojisi 24-27 Ekim 2007.35-40s, İzmir.
- KAKSONEN, A.H. PUHAKKA J. A. 2007. Sulfate Reduction Based Bioprocesses for the Treatment of Acid Mine Drainage and the Recovery of Metals
- KEPLER, D.A. ve MCCLEARY, E.C. 1994. "Successive Alkalinity-producing Systems (SAPS) for the Treatment of Acidic Mine Drainage. In: Proceedings of the First International Land Reclamation and Mine Drainage Conference and Third International Conference on the Abatement of Acidic Drainage, Pittsburgh, Pennsylvania, USA, 1,195-204.
- KUYUCAK, N., 2002. "Role of Microorganisms in Mining: Generation of Acid Rock Drainage and its Mitigation and Treatment", The European Journal of Mineral Processing and Environmental Protection, 2, (3), 179-196.
- METCALF&EDDY INC 1979. Revised By George Tchobanoglus, Wastewater Engineering Treatment Disp Sal, Tata McGraw-Hill Publishing Company Ltd.
- ÖZTEMEL, E., 2003. "Yapay Sinir Ağları", Papatya Yayınevi, İstanbul, 75 s.
- PULCU YILDIZ, S. 2009. Denizli (Merkez) Atıksu Arıtma Tesisi Performansının Yapay Sinir Ağları Kullanılarak Modellenmesi.

- ŞAHİNKAYA, E. GÜNGÖR, M. BAYRAKTAR, A. YÜCESOY, Z. UYANIK, S. 2009. Separate recovery of copper and zinc from acid mine drainage using biogenic sulfide.
- ŞAHİNKAYA, E. ÖZKAYA, B. KAKSONEN A. H. , PUHAKKA, J. A. 2006. Neural Network Prediction of Thermophilic (65 C) Sulfidogenic Fluidized-Bed Reactor Performance for the Treatment of Metal-Containing Wastewater.
- ŞAHİNKAYA, E. 2008, Biotreatment of zinc-containing wastewater in a sulfidogenic CSTR: Performance and artificial neural network (ANN) modelling studies.
- WILDEMAN, T.R. ve LAUDON, L.S., 1989; “The Use of Wetlands for Treatment of Environmental Problems in Mining: Non-coal Mining Applications”, In: Proceedings of the International Conference on Constructed Wetlands for Wastewater Treatment, Lewis Publishing, Ann Arbor, MI, 221-231.
- YESİLNACAR, M.I., GULLUOĞLU, M.S., 2007. Hydrochemical characteristics and the effects of irrigation on groundwater quality in Harran Plain, GAP Project, Turkey.
- YESİLNACAR, M.I., ŞAHİNKAYA, E., NAZ, M., ÖZKAYA, B., 2007. Neural network prediction of nitrate in groundwater of Harran Plain, Turkey, Environ Geol (2008) 56:19–25.
- YOLCUBAL, İ., 2008. Asit Maden Drenajı (AMD). <http://mf.kou.edu.tr/jeoloji>
- YOUNGER, P.L., BANWART, S.A. ve HEDİN, R.S., 2002. “Mine Water: Hydrology, Pollution, Remediation”, Kluwer Academic Press, ISBN 1- 4020-0137-1, 442 s.

## **ÖZGEÇMİŞ**

1982 yılında Adıyaman' da doğdu. İlk ve orta öğrenimini Adıyaman'da tamamladı ve 2006 yılında Fırat Üniversitesi Mühendislik Fakültesi Çevre Mühendisliği Bölümünden mezun oldu. Mezuniyetinden sonra 2008 yılında yüksek lisans çalışmalarına başladı. 2006 yılından itibaren Adıyaman Erol Gaz A.Ş Dolum Tesisinde sorumlu müdür olarak çalışmaktadır.



## ÖZET

Bu çalışmada, Asidik Maden Sızıntı Sularının (AMS) arıtımında, akışkan yataklı reaktör performanslarının yapay sinir ağları (YSA) ile modellenmesi çalışmaları yapılmıştır. Bu kapsamda 108Y036 nolu Tübitak Projesi kapsamında işletilen yukarı ve aşağı akışlı akışkan yataklı reaktörlerden alınan belirli giriş ve çıkış atıksu verileri kullanılmıştır. AMS arıtan akışkan yataklı reaktörler için “işletim süresi, giriş pH, çıkış pH, giriş sülfat, giriş kimyasal oksijen ihtiyacı (KOİ) ve giriş metal” olmak üzere toplam 6 input parametresini kullanarak; “çıkış sülfat, çıkış KOİ, çıkış alkalinite ve çıkış sülfür” konsantrasyonlarının YSA ile tahmin edilmesi hedeflenmiştir. Bu amaçla, 2 senaryo üzerinde çalışılmıştır; ilkinde çıkış pH değeri input parametreleri içerisinde yer alırken (Senaryo-1); ikinci senaryoda (Senaryo-2) çıkış pH değeri input parametreleri arasından çıkarılarak YSA ile reaktör performansının modellenmesi yapılmıştır. Senaryo-2 ile AMS arıtımı amaçlı kullanılacak olan bir reaktör henüz kurulmadan performansının tahmin edilmesi hedeflenmiştir.

Her bir parametre için ilk olarak YSA giriş parametrelerinin belirlenmesi amacıyla çalışmalar yapılmıştır. İkinci aşamada ise 12 öğrenme algoritması içinden en iyisi deneme yanılma yöntemi ile bulunmuştur. Üçüncü aşamada ise, nöron sayısı optimize edilerek modellenen her bir parametre için YSA yapısı optimize edilmiştir. Yapılan bu çalışmalar sonucunda senaryo-1 ve senaryo-2 için tahminler bulunmuştur. Senaryo 1’e göre çıkış sülfat değerlerinin tahmininde tüm sonuçları (öğrenme-doğrulama-test) temsil eden (all) R değerleri; Reaktör 1, 2 ve 3 için sırasıyla 0.94, 0.95 ve 0.92 olarak belirlenmiştir. Senaryo 2’ye göre çıkış sülfat değerlerinin tahmininde tüm sonuçları (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.95, 0.93 ve 0.93 olarak belirlenmiştir. Senaryo 1’e göre çıkış KOİ değerlerinin tüm sonuçlarını (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.95, 0.98 ve 0.98 olarak belirlenmiştir. Senaryo 2’ye göre çıkış KOİ değerlerinin tahmininde tüm sonuçları (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.97, 0.98 ve 0.98 olarak belirlenmiştir. Senaryo 1’e göre çıkış alkalinite değerlerinin tüm sonuçlarını (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.97, 0.98 ve 0.95 olarak belirlenmiştir. Senaryo 2’ye

göre çıkış alkalinite değerlerinin tüm sonuçlarını (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.98, 0.98 ve 0.95 olarak belirlenmiştir. Senaryo 1'e göre çıkış sülfür değerlerinin tüm sonuçlarını (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.98, 0.96 ve 0.94 olarak belirlenmiştir. Senaryo-2'ye göre çıkış sülfür değerlerinin tüm sonuçlarını (öğrenme-doğrulama-test) temsil eden (all) R değerleri Reaktör 1, 2 ve 3 için sırasıyla 0.97, 0.96 ve 0.94 olarak belirlenmiştir. Tüm reaktörler için ölçülen senaryo-1 ve senaryo-2'ye göre tahmin edilen çıkış sülfat, çıkış KOI, çıkış alkalinite ve çıkış sülfür değerleri arasında öğrenme, doğrulama ve test grafiklerinde yüksek korelasyon sabitleri bulunmuştur.

## SUMMARY

In this study, Acidic Mine Leachate (AML) treatment, fluidized-bed reactor performance of artificial neural networks (ANN) modeling studies are carried out. In this context, TUBITAK Project No. 108Y036 run up and down-flow fluidized bed reactors of wastewater from the specific input and output data are used. To purify AMS the fluidized bed reactor "operating period, pH of input, output pH, sulfate, input of chemical oxygen demand (COD) and the input of metal" for a total of 6 input parameter, "output sulphate, effluent COD, alkalinity, and the output of sulfur output "is aimed to predict the concentrations of ANN. For this purpose, two scenarios are studied, the first of the input parameters included in the output when the pH value (Scenario-1), the second scenario (Scenario-2) by subtracting the output from the pH value of the input parameters of ANN modeling with the performance of the reactor are made. Scenario-2 with a reactor to be used for treatment of AML currently is aimed to predict the performance of the establishment. Each parameter has been studied to determine the parameters of the ANN input. Learning algorithm is the best in the second stage, only 12 are found by trial and error method. In the third stage, the number of neurons modeled by optimizing the structure of ANN is optimized for each parameter with the result of these studies are predictions are found for the scenario-1 and scenario-2. According to Scenario 1, all the results about the prediction of output values of sulfate (learning-validation-test), representing (all) the R values; Reactor are found of 1, 2 and 3, respectively, for 0.94, 0.95 and 0.92, respectively. Scenario 2 all the results to estimate the output values of sulfate (learning-validation-test), representing (all) the R values, Reactor are found 1, 2 and 3, respectively, for 0.95, 0.93 and 0.93, respectively. According to Scenario 1, all the results of effluent COD values (learning-validation-test), representing (all) the R values are found Reactor 1, 2 and 3, respectively, for 0.95, 0.98 and 0.98, respectively. According to the prediction of effluent COD values of all the results in Scenario 2 (learning-validation-test), representing (all) the R values, Reactor 1, 2 and 3, respectively, for 0.97, 0.98 and 0.98, respectively. According to Scenario 1, all the results of the output values of alkalinity (learning-validation-test), representing (all) the R values, Reactor 1, 2 and 3, respectively, for 0.97, 0.98 and

0.95, respectively. Alkalinity values of the output of all the results of Scenario 2 (learning-validation-test), representing (all) the R values Reactor 1, 2 and 3, respectively, for 0.98, 0.98 and 0.95, respectively. According to Scenario 1, all the results of the output values of sulfide (learning-validation-test), representing (all) the R values Reactor are found 1, 2 and 3, respectively, for 0.98, 0.96 and 0.94, respectively. Scenario-2 According to the results of the output values of sulfide (learning-validation-test), representing (all) the R values, Reactor are found 1, 2 and 3, respectively, for 0.97, 0.96 and 0.94, respectively. Measured for all the reactors according to the scenario-1 and scenario 2, the estimated out-sulfate, the output COD, alkalinity, and the output of sulphide between the values of the output of learning, validation and test graphics are high correlation coefficient are found.