İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

ÇİMENTO ENDÜSTRİSİNDE HAMMADDE HARMANLAMA PROSESİNİN KLASİK VE AKILLI YÖNTEMLER KULLANARAK MODELLENMESİ

YÜKSEK LİSANS TEZİ

Mak. Müh. Kemal KIZILASLAN
(503011152)

Tezin Enstitüye Verildiği Tarih : 22 Aralık 2003
Tezin Savunulduğu Tarih : 12 Ocak 2004

Tez Danışmanı : **Y.Doç.Dr. Şeniz ERTUĞRUL**
Diğer Jüri Üyeleri **Doç.Dr. Kenan KUTLU (İ.T.Ü.)**
Y.Doç.Dr. Ekrem TÜFEKÇİ (İ.T.Ü.)

OCAK 2004

ÖNSÖZ

Çimento günlük hayatta yoğun olarak kullanılan bir yapı malzemesidir. Çimento endüstrisi yüksek enerji tüketen sektörlerden biridir. Prosesin karmaşıklığı, hassasiyeti ve hammadde maliyetlerinin yüksek olmasından dolayı çimento üretimi oldukça pahalı bir süreçtir. Ürün kalitesinin belli bir standartta tutulabilmesi prosesin hassas bir şekilde kontrol edilmesi ile mümkündür. Bu çalışmada, kontrol sistemi tasarımının ilk aşaması olan proses modellemesi üzerinde durulmuştur. Sözü edilen proses, klasik ve akıllı yöntemler ile modellenmiştir.

Sadece tezin hazırlanmasında olan katkıları için değil aynı zamanda bana şans tanıdığı, görüşlerini paylaştığı ve yol gösterdiği için Sayın Hocam Y. Doç. Dr. Şeniz Ertuğrul' a, harmanlama prosesinin ayrıntılarını kendilerinden öğrendiğim Y. Doç. Dr. Ayhan Kural ve Prof. Dr. Can Özsoy' a ve bir dönem beraber çalıştığım, bana desteklerini esirgemeyen Otomatik Kontrol Birimi' nin değerli personelleri Dr. Ertan Öznergiz, Dr. Mustafa R. Becan ve Araş. Gör. Bülent Bölat' a teşekkürlerimi sunarım.

Aralık 2003 Kemal KIZILASLAN

İÇİNDEKİLER

KISALTMALAR **vi**
TABLO LİSTESİ **vii**
ŞEKİL LİSTESİ **viii**
SEMBOL LİSTESİ **xi**
ÖZET **xii**
SUMMARY **xiii**

1. GİRİŞ **1**

1.1 Giriş 1
1.2 Sistem Tanılama ve Modelleme Literatürü 2

2. ÇİMENTO ENDÜSTRİSİNDE HARMANLAMA PROSESİ **4**

2.1 Çimento Üretim İşlemi 4
2.2 Harmanlama Prosesi 4
2.3 Çimento Yapısı ve Kimyasal Denklemler 6
2.4 Harmanlama Prosesinde Analiz (Ölçme) Sistemi 7

3. SİSTEM TANILAMA VE MODELLEME **8**

3.1 Giriş 8
3.2 Sistem Tanılamada Giriş İşareti Seçimi 10
3.2.1 Beyaz gürültü ve PRBS (Sözde-Rastgele İkili Dizi) 10
3.2.2 Sürekli uyaran (Persistently Exciting) sinyal 12
3.3 Sinyal Şartlandırma 13
3.3.1 DC bileşenlerinin yokedilmesi 13
3.3.2 Verinin ölçeklendirilmesi 13
3.4 Model Karmaşıklığının Tahmini 14
3.4.1 Gürültüsüz sistemin model karmaşıklığının tahmini 14
3.4.2 Beyaz gürültülü sistemin model karmaşıklığının tahmini 15
3.5 Lineer Parametrik Sistem Tanılama ve ARX Model Yapısı 15
3.6 Model Geçerliliğinin Test Edilmesi 18
3.6.1 Otokorelasyon testi 18
3.6.2 Çapraz korelasyon testi 19
3.7 Model Yapısının Seçimi ve Modelin Geçerliliği Konusunda Ek Bilgiler 19

4. YAPAY SİNİR AĞLARI **20**

4.1 Giriş 20
4.2 Basit Nöron Yapısı ve Fonksiyonları 21
4.2.1 Biyolojik nöron 21
4.2.2 Yapay nöron 22
4.2.3 Yapay nöron etkinlik fonksiyonları 23
4.3 YSA' da Öğrenme 25
4.3.1 Öğreticili öğrenme (Supervised learning) 25
4.3.2 Öğreticisiz öğrenme (Unsupervised learning) 25

4.4 Yapay Sinir Ağ Modelleri 26
4.4.1 Tek katmanlı ileri beslemeli ağlar 26
4.4.2 Çok katmanlı ileri beslemeli ağlar 28
4.5 Geri Yayılma Eğitim Algoritması 29
4.5.1 Delta kuralı 29
4.5.2 Geriye yayılma algoritması ile eğitmede işlem sırası 33
4.6 Eğitim Zamanını Azaltan Yöntemler 33
4.6.1 Uyarlanabilir öğrenme oranı (Adaptive learning rate) 33
4.6.2 Momentum yöntemi 34
4.6.3 Levenberg-Marquardt algoritması 34

5. SİNİRSEL-BULANIK ÇIKARTIM SİSTEMİ 35

5.1 Radyal Tabanlı Fonksiyon Ağı (RTFA) 35
5.2 Sugeno-Takagi Bulanık Çıkartım Sistemi (ST-BÇS) 36
5.3 Uyarlanabilir Sinirsel-Bulanık Çıkartım Sistemi (USBÇS) 37

6. ÇİMENTO ENDÜSTRİSİNDE HARMANLAMA PROSESİNİN DOĞRUSAL PARAMETRİK YÖNTEMLE MODELLENMESİ 40

6.1 Giriş İşaretinin Analizi ve Sinyal Şartlandırma 40
6.1.1 Verinin DC bileşenlerinin yok edilmesi ve ölçeklendirme 40
6.1.2 Giriş işaretlerinin kovaryans fonksiyonu ve sürekli uyarma mertebesi 44
6.2 Harmanlama Prosesinin ARX Yapısında Modellenmesi 44
6.2.1 Model 1' in ARX model parametrelerinin kestirimi 45
6.2.2 Model 2' nin ARX model parametrelerinin kestirimi 50
6.3 ARX Modellerin Öngörü Kapasiteleri 54
6.3.1 Model 1' in ARX modelinin 5 adım ötesini öngörüsü 54
6.3.2 Model 2' nin ARX modelinin 5 adım ötesini öngörüsü 55

7. ÇİMENTO ENDÜSTRİSİNDE HARMANLAMA PROSESİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ 57

7.1 Yapay Sinir Ağı (YSA) Modelleri 57
7.1.1 Model 1 için Yapay Sinir Ağı modeli 60
7.1.2 Model 2 için Yapay Sinir Ağı modeli 66
7.2 Yapay Sinir Ağı Modellerinin Öngörü Kapasiteleri 72
7.2.1 Model 1 için YSA modelinin 5 adım ötesini öngörüsü 72
7.2.2 Model 2 için YSA modelinin 5 adım ötesini öngörüsü 73

8. ÇİMENTO ENDÜSTRİSİNDE HARMANLAMA PROSESİNİN UYARLANABİLİR SİNİRSEL-BULANIK ÇIKARTIM SİSTEMİ İLE MODELLENMESİ 75

8.1 Uyarlanabilir Sinirsel-Bulanık Çıkartım Sistemi (USBÇS) Modelleri 75
8.1.1 Model 1 için USBÇS modeli 76
8.1.2 Model 2 için USBÇS modeli 81
8.2 USBÇS Modellerinin Öngörü Kapasiteleri 86
8.2.1 Model 1 için USBÇS modelinin 5 adım ötesini öngörüsü 86
8.2.2 Model 2 için USBÇS modelinin 5 adım ötesini öngörüsü 87

9. SONUÇLAR VE TARTIŞMA **89**

9.1 Model 1 için Belirlenen Modellerin Karşılaştırılması 92
9.2 Model 2 için Belirlenen Modellerin Karşılaştırılması 94

ÖZGEÇMİŞ **100**

KISALTMALAR

YSA : Yapay Sinir Ağları
USBÇS : Uyarlanabilir Sinirsel-Bulanık Çıkartım Sistemi
BM : Bulanık Mantık
PGNAA : Prompt Gamma Neutron Activation Analyzer
SISO : Single Input-Single Output
MIMO : Multi Input-Multi Output
PRBS : Pseudo Random Binary Sequence
ARX : Auto Regressive with Exagenous Input
LM : Levenberg-Marquardt
M+UÖO : Momentum ile Uyarlamalı Öğrenme Oranı
HKO : Hataların Karesel Ortalaması
RTFA : Radyal Tabanlı Fonksiyon Ağı
ST-BÇS : Sugeno-Takagi Bulanık Çıkartım Sistemi
ÜF : Üyelik Fonksiyonları

TABLO LİSTESİ

Sayfa No

Tablo 2.1	Hammaddelerin nominal değerleri, konsantrasyonları ve maliyetleri	5
Tablo 4.1	Bazı etkinlik fonksiyonları ve türevleri	32
Tablo 6.1	Verilerin tanımlayıcı istatistiksel özellikleri	42
Tablo 6.2	Model 1 için ARX modelin hataları	49
Tablo 6.3	Model 2 için ARX modelin hataları	54
Tablo 6.4	Model 1 için ARX modelin öngörü hataları	55
Tablo 6.5	Model 2 için ARX modelin öngörü hataları	56
Tablo 7.1	Model 1 için denenen bazı YSA yapılandırmaları	61
Tablo 7.2	Model 1 için seçilen YSA modelinin parametreleri	63
Tablo 7.3	Model 2 için denenen bazı YSA yapılandırmaları	68
Tablo 7.4	Model 2 için seçilen YSA modelinin parametreleri	69
Tablo 7.5	Model 1 için YSA modelinin öngörü hataları	73
Tablo 7.6	Model 2 için YSA modelinin öngörü hataları	74
Tablo 8.1	Model 1 için bazı USBÇS yapılandırmaları	77
Tablo 8.2	Model 1 için seçilen USBÇS modelinin parametre ve sonuçları ...	78
Tablo 8.3	Model 2 için bazı USBÇS yapılandırmaları	82
Tablo 8.4	Model 2 için seçilen USBÇS modelinin parametre ve sonuçları ...	83
Tablo 8.5	Model 1 için USBÇS modelinin öngörü hataları	87
Tablo 8.6	Model 2 için USBÇS modelinin öngörü hataları	88
Tablo 9.1	Model 1 için çeşitli modellerin hatalarının karesel ortalaması	92
Tablo 9.2	Model 1 için belirlenen modellerin öngörü hataları (HKO)	93
Tablo 9.3	Model 2 için çeşitli modellerin hatalarının karesel ortalaması	94
Tablo 9.4	Model 2 için belirlenen modellerin öngörü hataları (HKO)	95

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1 : Harmanlama prosesinin şematik gösterimi 5
Şekil 3.1 : Sistem tanılamanın şematik akış diyagramı 9
Şekil 3.2 : N=5, L=31 olan PRBS sinyalinin üretimi 11
Şekil 3.3 : PRBS'in en uzun darbesinin seçimi 12
Şekil 3.4 : ARX model yapısının blok diyagramı 16
Şekil 4.1 : Bir biyolojik nöron 22
Şekil 4.2 : Yapay nöron modeli 22
Şekil 4.3 : Doğrusal etkinlik fonksiyonu 23
Şekil 4.4 : Eşik etkinlik fonksiyonu 23
Şekil 4.5 : Lojistik sigmoid etkinlik fonksiyonu 24
Şekil 4.6 : Tanjant sigmoid etkinlik fonksiyonu 24
Şekil 4.7 : Tek katmanlı ileri beslemeli ağ modeli 27
Şekil 5.1 : İki giriş-tek çıkışlı 4 alıcı elemandan oluşan RTFA 35
Şekil 5.2 : Her girişe iki üyelik fonksiyonu olan 2 girişli 4 bulanık kurallı USBÇS 38
Şekil 6.1 : Birinci giriş; Düşük Mal 41
Şekil 6.2 : İkinci giriş; Demir Cevheri 41
Şekil 6.3 : Birinci modelin çıkışı; Demir Oksit 41
Şekil 6.4 : İkinci modelin çıkışı; Kireç Standardı (ML) 42
Şekil 6.5 : DC etkileri giderilmiş ve ölçeklendirilmiş birinci giriş verisi 43
Şekil 6.6 : DC etkileri giderilmiş ve ölçeklendirilmiş ikinci giriş verisi 43
Şekil 6.7 : DC etkileri giderilmiş ve ölçeklendirilmiş birinci çıkış verisi 43
Şekil 6.8 : DC etkileri giderilmiş ve ölçeklendirilmiş ikinci çıkış verisi 44
Şekil 6.9 : Model 1 için değişik ARX model yapıları 45
Şekil 6.10 : Model 1 için seçilen ARX modelin kutup-sıfır yerleri 46
Şekil 6.11 : Model 1 için ARX modelin tanılama verisi ile karşılaştırılması ... 46
Şekil 6.12 : Model 1 için ARX modelin sınama verisi ile karşılaştırılması 47
Şekil 6.13 : Model 1 için ARX modelin tanılama ve sınama kümeleri için artıkları 47
Şekil 6.14 : Model 1 için ARX model artıklarının otokorelasyonu 48
Şekil 6.15 : Model 1 için ARX model artıklarının girişlerle çapraz korelasyonu 48
Şekil 6.16 : Model 2 için değişik ARX model yapıları 50
Şekil 6.17 : Model 2 için seçilen ARX modelin kutup-sıfır yerleri 51
Şekil 6.18 : Model 2 için ARX modelin tanılama verisi ile karşılaştırılması ... 51
Şekil 6.19 : Model 2 için ARX modelin sınama verisi ile karşılaştırılması 52
Şekil 6.20 : Model 2 için ARX modelin tanılama ve sınama kümeleri için artıkları 52
Şekil 6.21 : Model 2 için ARX model artıklarının otokorelasyonu 53

Şekil 6.22 : Model 2 için ARX model artıklarının girişlerle çapraz korelasyonu 53
Şekil 6.23 : Model 1 için ARX modelin öngörüsüz ve öngörülü çıkışı 55
Şekil 6.24 : Model 2 için ARX modelin öngörüsüz ve öngörülü çıkışı 56
Şekil 7.1 : YSA için ölçeklendirilmiş giriş-çıkış verisi 58
Şekil 7.2 : Model 1 için Yapay Sinir Ağı blok diyagramı 60
Şekil 7.3 : Tek gizli katmanda 10 nöron olan LM ile eğitilmiş YSA modeli . 62
Şekil 7.4 : Hatanın karesel ortalamasının (HKO) eğitim süresince azalması . 63
Şekil 7.5 : Model 1 için seçilen YSA modelinin eğitim verisi çıkışları 64
Şekil 7.6 : Model 1 için seçilen YSA modelinin sınama verisi çıkışları 64
Şekil 7.7 : Model 1 için YSA modelinin eğitim ve sınama kümeleri için artıkları 65
Şekil 7.8 : Model 1 için YSA model artıklarının otokorelasyonu 65
Şekil 7.9 : Model 1 için YSA modelinin artıklarının girişlerle çapraz korelasyonu 66
Şekil 7.10 : Model 2 için Yapay Sinir Ağı blok diyagramı 67
Şekil 7.11 : Hatanın karesel ortalamasının (HKO) eğitim süresince azalması . 69
Şekil 7.12 : Model 2 için seçilen YSA modelinin eğitim verisi çıkışları 69
Şekil 7.13 : Model 2 için seçilen YSA modelinin sınama verisi çıkışları 70
Şekil 7.14 : Model 2 için YSA modelinin eğitim ve sınama kümeleri için artıkları 70
Şekil 7.15 : Model 2 için YSA model artıklarının otokorelasyonu 71
Şekil 7.16 : Model 2 için YSA modelinin artıklarının girişlerle çapraz korelasyonu 71
Şekil 7.17 : Model 1 için YSA modelinin sınama kümesi için 5 adım ötesini öngörüsü 72
Şekil 7.18 : Model 2 için YSA modelinin sınama kümesi için 5 adım ötesini öngörüsü 73
Şekil 8.1 : Model 1 için USBÇS blok diyagramı 77
Şekil 8.2 : Model 1 için seçilen USBÇS modelinin eğitim verisi çıkışları 78
Şekil 8.3 : Model 1 için seçilen USBÇS modelinin sınama verisi çıkışları 79
Şekil 8.4 : Model 1 için USBÇS modelinin eğitim ve sınama kümeleri için artıkları 79
Şekil 8.5 : Model 1 için USBÇS model artıklarının otokorelasyonu 80
Şekil 8.6 : Model 1 için USBÇS modelinin artıklarının girişlerle çapraz korelasyonu 80
Şekil 8.7 : Model 2 için USBÇS blok diyagramı 81
Şekil 8.8 : Model 2 için seçilen USBÇS modelinin eğitim verisi çıkışları 83
Şekil 8.9 : Model 2 için seçilen USBÇS modelinin sınama verisi çıkışları 84
Şekil 8.10 : Model 2 için USBÇS modelinin eğitim ve sınama kümeleri için artıkları 84
Şekil 8.11 : Model 2 için USBÇS model artıklarının otokorelasyonu 85
Şekil 8.12 : Model 2 için USBÇS modelin artıklarının girişlerle çapraz korelasyonu 85
Şekil 8.13 : Model 1 USBÇS modelin sınama kümesi için 5 adım ötesini öngörüsü 87
Şekil 8.14 : Model 2 USBÇS modelin sınama kümesi için 5 adım ötesini öngörüsü 88
Şekil 9.1 : YSA Model tabanlı öngörülü kontrol sistemi blok diyagramı 91
Şekil 9.2 : Model 1 için çeşitli modellerin çıkışları 92

Şekil 9.3 **:** Model 1 için çeşitli modellerin 5 adım ötesini öngörü çıkışları 93
Şekil 9.4 **:** Model 2 için çeşitli modellerin çıkışları 95
Şekil 9.5 **:** Model 2 için çeşitli modellerin 5 adım ötesini öngörü çıkışları 96

SEMBOL LİSTESİ

ML	: Kireç Standardı
MA	: Alüminyum Modülü
MS	: Silika Modülü
Ru	: Kovaryans matrisi
$RN(i)$	: Otokorelasyon ve çapraz korelasyon matrisi
w_{ij}	: j. nörona gelen i. girişin ağırlığı
b_j	: j. nöronun yanlılık terimi
s	: Nöronda ağırlıklı toplam
$f(s)$	: Etkinlik fonksiyonu
J_r	: Geri yayılım algoritmasında maliyet fonksiyonu
J	: Levenberg-Marquardt yönteminde Jakobian matrisi
α	: Öğrenme oranı
$R_i(.)$	: Radyal tabanlı fonksiyon
μ_{injmfi}	: j. girişin i. üyelik fonksiyonu
f_k	: Bulanık mantık k. eğer-ise kuralı

ÇİMENTO ENDÜSTRİSİNDE HAMMADDE HARMANLAMA PROSESİNİN KLASİK VE AKILLI YÖNTEMLER KULLANARAK MODELLENMESİ

ÖZET

Çimento endüstrisinde hammadde harmanlama prosesi, proses karakteristiği itibariyle, stokastik bir prosestir. Çimento kalitesi, sistemin girişleri olan üç hammaddenin içinde de bulunan ve rastgele değişkenlik gösteren 4 oksit tarafından belirlenir. Bu oksitler; Kalsiyum Oksit (CaO), Silisyum Oksit (SiO_2), Demir Oksit (Fe_2O_3) ve Alüminyum Oksit (Al_2O_3)'tir. Çimentonun istenen kalitede elde edilmesi ancak harmanlanmış yarı mamul içindeki bu oksitlerin istenen ağırlık oranlarında olması ile mümkündür. Hammadde ve işletme maliyetlerinin yüksek olmasından dolayı çimento üretimi oldukça pahalı bir süreçtir. Prosesin maliyete duyarlılığı da oksit oranlarının hassas kontrol altında tutulmasını gerektirmektedir. Bu amaçla istenen oksit oranlarını elde etmek için hammadde oranlarını ayarlayacak bir kontrol sistemi tasarımı amaçlanmaktadır. Bütün kontrol sistemlerinin tasarımında ilk adım olan sistemin bir matematik modelinin elde edilmesi bu yüzden zaruridir. Sistem, yapısı itibariyle deterministik bir model çıkarılmasına müsaade etmediği için sistem tanılama gibi deneysel yöntemler sistemin modelinin elde edilmesinde tek alternatiftir.

Bu çalışmada, çimento endüstrisinde hammadde harmanlama prosesinin klasik ve akıllı yöntemler ile modellenmesi incelenmiştir. Harmanlama prosesi, öncelikle sistem tanılamada yaygın olarak kullanılan lineer parametrik bir model yapısı olan ARX model olarak tanılanmıştır. Daha sonra sistem, yapay sinirsel ağlar (YSA) ve uyarlanabilir sinirsel-bulanık çıkartım sistemi (USBÇS) ile modellenmiştir. Çalışma sonucunda YSA ve USBÇS yöntemlerinin stokastik ve doğrusal olmayan proseslere de başarıyla uygulanabildiği ve akıllı sistemlerin sistem tanılamada ve model geliştirmede lineer parametrik modellemeden daha başarılı olduğu anlaşılmıştır.

Çalışma, hammadde harmanlama prosesinin tanıtımı ile başlamaktadır. 3. Bölüm' de sistem tanılama kavramı üzerinde durulmuş ve sistem tanılama yaygın olarak kullanılan lineer parametrik yöntemlerden bahsedilmiştir. 4. ve 5. Bölüm akıllı yöntemlerden olan yapay sinir ağları ve uyarlanabilir sinirsel bulanık çıkartım sistemi ile ilgili teorik bilgiler içermektedir. 6. 7. ve 8. Bölüm' lerde daha önceki bölümlerde anlatılan yöntemlerin harmanlama prosesine uygulanmasının ayrıntıları üzerinde durulmuştur. 9. Bölüm' de uygulanan yöntemler karşılaştırılmış ve çalışmanın ileriki uygulamalarına yol gösterilmiştir.

MODELING OF RAW MATERIAL BLENDING PROCESS IN CEMENT INDUSTRY USING CONVENTIONAL AND INTELLIGENT TECHNIQUES

SUMMARY

The raw material blending process in cement industry is a stochastic process by nature. The quality of the end product depends on blending correct amounts of 4 oxides, which exist in each of three raw materials with variable amounts. Namely, those oxides are; Calcium Oxide (CaO), Silica Oxide (SiO_2), Iron Oxide (Fe_2O_3) and Aluminum Oxide (Al_2O_3). The desired quality of cement is obtained only when the oxide weight ratios are at required levels. Due to the high levels of raw material and processing costs, cement production is an expensive process. This characteristic of the process also adds up to the need for an accurate control of the process. Thus, the long-term objective of the study is designing a control system that will successfully adjust the feeding amounts of raw materials in order to level the oxides in blended material. Obviously, obtaining a mathematical model is the first step for each control system design process. Since this process is not deterministic in nature, experimental methods are used for obtaining a system model.

In this study, the raw material blending process is modeled by using conventional and intelligent techniques. At the first step, the blending process is identified using the well-known linear parametric methods. ARX model structure is used for identification. At the second step; artificial neural networks (ANN) and adaptive neuro-fuzzy inference system (ANFIS) are used for identification and modeling due to the non-linear characteristics of the process. As a result, it is shown that ANN and ANFIS can be successfully applied to modeling of stochastic and non-linear processes. It is also concluded that, intelligent techniques are more successful in modeling of this system than linear parametric method.

The study begins with a description of raw material blending process. Part 3 is concerned with the concept of system identification. Commonly used methods of linear parametric system identification are mentioned. Parts 4 and 5 present the theoretical basis of ANN and ANFIS. Parts 6, 7, and 8 contain the applications of introduced methods to the process. Finally, the results are compared in Part 9, and implications of results for future studies are discussed.

1. GİRİŞ

1.1 Giriş

Çimento endüstrisi dünya ekonomisinde önemli bir yere sahiptir. Çimento günlük hayatta yoğun olarak kullanılan bir yapı malzemesidir. Ayrıca, bu endüstri en yüksek enerji tüketen sektörlerden biridir. Bu yönüyle de çimentonun üretim ve tüketim kapasitesi bir ülkenin gelişmişlik düzeyiyle doğrudan ilişkilidir. Çimento teknolojisi son yüz yılda gelişmiştir. Prosesin karmaşıklığı, hassasiyeti ve hammadde maliyetlerinin yüksek olmasından dolayı çimento üretimi oldukça pahalı bir süreçtir. Firmaların, günümüz ekonomik şartlarında pazar paylarını yüksek tutabilmeleri için yapmaları gereken, ürün kalitesini mümkün olduğunca yüksek tutmak, bunu yaparken de maliyetleri düşürmeye çalışmak olmalıdır.

Çimento üretiminde harmanlama prosesi temel olarak, hammaddelerin belli oranlarda karıştırılması ve bu karışımın değirmenden geçirilmesi işlemidir. İşlemin zorluğu, çok değişkenli (bir kaç hammadde) olmasından, ayrıca hammaddelerin içeriğinin rasgele değişmesinden kaynaklanmaktadır. Bu yönüyle proses stokastik bir prosestir. Hammaddelerin içinde değişik oranlarda bulunan dört temel oksit'in (CaO, SiO_2, Al_2O_3 ve Fe_2O_3) harmanlanmış yarı mamuldeki oranları (veya bu oranların çeşitli lineer kombinasyonları) çimentonun kalitesini belirler.

Harmanlama prosesi, çimento kalitesini belirleyen en önemli etken olduğu için prosesin iyi bir algoritmayla kontrolü büyük önem arz etmektedir. Ne var ki, geliştirilebilecek bütün kontrol algoritmaları, prosesin bir matematik modeline ihtiyaç duymaktadır. Sistemin stokastik karakteristiği, matematik modelin, fiziğin temel prensiplerine dayanılarak elde edilmesine müsaade etmemektedir. Bu noktada, sistem tanılama gibi deneysel modelleme yöntemleri kullanmak kaçınılmaz olmaktadır.

Sistemlerin deneysel veriye dayanan matematik modellerinin elde edilmesinde parametrik veya parametrik olmayan lineer yöntemler yaygın olarak kullanılmaktadır. Endüstride çok karşılaşılan lineer olmayan sistemlerin karakteristiklerini modelleyecek lineer olmayan modeller vardır. Ancak, bu modellerin karmaşıklığı ve iyi tesis edilmiş genel teorilerinin olmaması, bu modellerin belirli çalışma bölgesi civarında lineerleştirilmiş olarak kullanılmasına yol açmaktadır. Yapay sinir ağları (YSA), sinirsel-bulanık sistemler (SBS) gibi akıllı sistemlerin son yıllarda büyük önem kazanmasının ve kabul görmesinin altında lineer olmayan sistemlerin de modellenmesindeki başarımları yatmaktadır.

1.2 Sistem Tanılama ve Modelleme Literatürü

Parametrik sistem tanılama yöntemlerinin temelinde iyi bilinen istatistiksel yöntemlerden en küçük kareler ve en büyük benzerlik (maximum likelihood) prensipleri vardır. Bu metotların dinamik sistemleri uygulanabilir hale getirilmesi modern kontrol teorisinin ortaya çıktığı 1960'lı yıllara rastlamaktadır [1]. Daha sonra sistem tanılamanın teorik temelleri geliştirilmiştir. Sistem tanılama için geliştirilen bu tekniklerin endüstriyel prosesler için uygulanması Ljung ile başlamıştır [2]. Günümüzde sistem tanılama literatürü çok geniştir. Sistem tanılama teorisi üzerine Eykhoff [3], Goodwin ve Payne [4], Söderstrom ve Stoica [5] ve Ljung [6]' un eserleri temel kaynaklardır.

Akıllı yöntemler ve uygulamaları ise kısmen yeni bir alandır. Yapay Sinir Ağları' yla sistem tanılama kavramı 1943 yılında ortaya çıkmıştır. McCulloch ve Pitts tarafından yapılan çalışmayla, yapay nöronlardan oluşan bir ağın matematiksel ve mantıksal işlevleri yapabileceği gösterilmiştir. Ancak YSA' nın ilk pratik uygulaması 1958' de Frank Rosenblatt tarafından yapılmıştır. Rosenblatt, ortaya koyduğu perseptron modeli ile örüntü tanıma (pattern recognition) konusunda çalışmalar yapmıştır. Minsky ve Papert, 1969 yılında, perseptronun karmaşık mantıksal fonksiyonlar için kullanılamayacağını ispatlamaları ile çalışmalar durma noktasına gelmiştir. Ancak bazı bilim adamları çalışmalarına devam etmiştir. 1976'da Grossberg, Adaptif Rezonans Teori (ART)' yi, 1982' de Hopfield dinamik Hopfield ağını (recurrent network) geliştirmiştir. 1986 yılında, Rumelhart ve McClelland çok katmanlı ileri beslemeli ağlarda geriye yayılma algoritmasını ortaya koyarak Minsky ve Papert

tarafından ortaya konan problemi çözmüş ve yapay sinir ağlarına olan ilgiyi bir anda arttırmışlardır [7].

Diğer bir akıllı sistem olan Adaptif Sinirsel-Bulanık Çıkartım Sistemi'nin (ANFIS; **A**daptive **N**euro-**F**uzzy **I**nference **S**ystem) sistem tanılama amacıyla kullanılmasının temelleri de Jang vd.' nin eserinde ortaya konmuştur [8].

Akıllı yöntemler (yapay sinir ağları, bulanık mantık (BM) vb.) üretim alanında, proses modellemesi ve kontrolü, görsel kalite denetleme sistemleri, kimyasal proseslerin dinamik modellenmesi, tekstil kalite muayenesi ve tahmini konularında kullanılmaktadır. Üretim sektöründen başka, YSA, bankacılık ve finans, elektronik, robot teknolojisi, haberleşme, görüntü ve ses teknolojileri gibi birçok uygulama alanına sahiptir [7]. Yapay sinir ağlarının modelleme ve sistem tanılama amacıyla kullanılmasına yönelik çalışmalar gün geçtikçe artmaktadır. Modelleme amaçlı YSA kullanımına dair bazı çalışmalar [9-11]'de verilmiştir.

Literatürde çimento sektörüyle ilgili birçok akademik çalışma bulunmakla birlikte özel olarak harmanlama prosesinin akıllı sistemlerle modellenmesine dair bir çalışma bulunmamaktadır.

2. ÇİMENTO ENDÜSTRİSİNDE HARMANLAMA PROSESİ

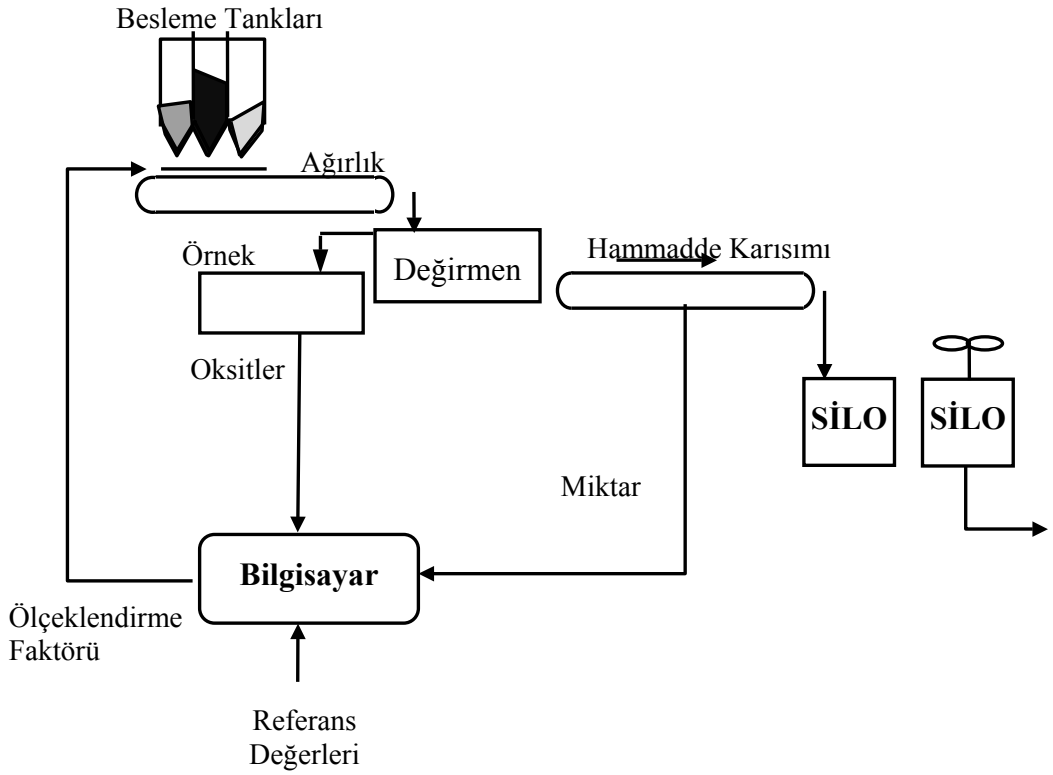
2.1 Çimento Üretim İşlemi

Çimento prosesi, maden elde edilmesi, harmanlama, öğütme, ve fırınlama aşamalarından oluşur. Üretim yaş veya kuru olarak yapılabilir. Yaş üretimde hammaddeler belli oranlarda su ile karıştırılarak bir çamur elde edilir. Elde edilen çamur oranlanarak karıştırılır ve fırınlanır. Kuru hammadde harmanlama işlemi daha zor bir işlemdir ancak daha az maliyetlidir. Kuru üretimde, hammadde oranlanır, harmanlanır ve fırınlanır. Harmanlanmış hammadde fırında bir dizi kimyasal reaksiyona uğrar. Fırınlamanın son aşamasında 1400-1450 ^{0}C de gerçekleşen ve sinterleme adı verilen bir işlemle klinker adı verilen ve kendine has fiziksel ve kimyasal özellikleri olan bir madde elde edilir. Klinker soğutulur, ufalanır ve özel bir tür kireçle (gypsum) karıştırılır. Sonuç olarak Portland çimentosu olarak bilinen mamül elde edilir. Çimento silo adı verilen büyük depolarda muhafaza edilir ve buradan otomatik paketleme makinasına beslenir [12].

2.2 Harmanlama Prosesi

Çalışmada, Nuh Çimento Fabrikası' nın harmanlama sistemi incelenmiştir. Harmanlama prosesinin şematik gösterimi Şekil 2.1'de görülmektedir. Proseste, üç ayrı depodan gelen hammadde ağırlık ölçen besleyici ile değirmene beslenmektedir. Değirmende hammaddeler karıştırılır ve öğütülür. Bu hammaddelerden ilki düşük mal diye tabir edilen kil ve marn karışımıdır. İkinci depodan yüksek mal beslenir. Yüksek malda kireç oranı yüksektir ve yüksek mal düşük mala göre daha pahalıdır. Üçüncü depodan ise demir cevheri beslenir. Kontrolör tasarımı yapılan çalışmada [12] üç girişten ikisi (düşük mal ve demir cevheri) giriş olarak alınmıştır. Dolayısıyla, tasarlanacak kontrolörün bu iki girişi kontrol etmesi öngörülmüştür. Sistem kapalı çevrim kontrolle çalışmaktadır. Ancak sistemin stokastik karakteristiğinden dolayı kapalı çevrim kontrol yetersiz kalmaktadır. Ölçüm kapalı

çevrimli sistemden yapılmaktadır. Ölçme cihazı değirmen girişinde henüz karışmış olan harmandan otomatik örnek almakta ve harmanın oksit içeriğini ölçmektedir. Ölçüm cihazı PGNAA (hızlı gamma nötron aktivasyon analizcisi) olup, dakikada bir analiz sonucunu bilgisayara aktarmaktadır.



Şekil 2.1 Harmanlama prosesinin şematik gösterimi

Hammaddelerin nominal akış oranları, konsantrasyonları ve maliyetleri Tablo 2.1' de verilmiştir [12].

Tablo 2.1 Hammaddelerin nominal değerleri, konsantrasyonları ve maliyetleri

Hammadde	Nominal Akış (%)	CaO (%)	SiO_2 (%)	Fe_2O_3 (%)	Al_2O_3 (%)	Maliyet (USD/ton)
Düşük Mal (Kil + Marn)	50.51	40.55	19.03	1.32	2.58	0.22
Yüksek Mal (Kireç+Marn)	38.31	48.15	7.59	1.58	1.59	1.54
Demir Cevheri	11.18	2.26	13.85	61.91	10.34	7.21

Tablo 2.1' de görüldüğü gibi akış oranlarının kontrol altında tutulması ve optimal besleme oranlarının tahmin edilmesini sağlayacak bir kontrolör maliyeti de doğrudan etkileyecektir. Kontrolörün kestirim yeteneği ise sistemin iyi bir matematik modelinin bulunmasına dayanmaktadır.

2.3 Çimento Yapısı ve Kimyasal Denklemler

Üretilen çimentonun kimyasal içeriği dört temel bileşikten oluşur. Bu bileşikler fırınlama sırasında meydana gelen kimyasal reaksiyonda ortaya çıkar. Bu bileşikler ve ağırlık oranları şöyledir:

- Tri-kalsiyum Silikat, C_3S ($\approx 60\%$),
- Di-kalsiyum Silikat, C_2S ($\approx 25\%$),
- Tri-kalsiyum Aluminat, C_3A ($\approx 5\%$),
- Tetra-kalsiyum Aluminoferrit, C_4AF ($\approx 10\%$).

Bu dört bileşiğin istenen oranlarda oluşumu fırınlama öncesinde harman içindeki dört temel oksidin yüzdelerine bağlıdır. Bileşiklerle oksitler arasındaki bağıntı Bogue denklemi (2.1) olarak bilinir [13].

$$\begin{bmatrix} C_3S \\ C_2S \\ C_3A \\ C_4AF \end{bmatrix} = \begin{bmatrix} 4.07 & -7.6 & -1.43 & -6.72 \\ -3.07 & 8.60 & 1.08 & 5.07 \\ 0.0 & 0.0 & -1.69 & 2.65 \\ 0.0 & 0.0 & 3.04 & 0.0 \end{bmatrix} \begin{bmatrix} CaO \\ SiO_2 \\ Fe_2O_3 \\ Al_2O_3 \end{bmatrix} \tag{2.1}$$

Çimentonun mukavemeti ve kalitesi bu bileşiklerin kuvvetli bir fonksiyonudur. Bileşiklerin istenen oranlarda olması oksit yüzdelerinin hassas bir şekilde istenen değerlerde olmasıyla mümkündür. Bu nedenle hammadde beslemesinin kararlı olması ürün kalitesi için çok önemlidir. Ürün kalitesi için gerekli hammadde oranları, kimyasal denklemdeki oranlardan hareketle, oksit yüzdelerinin birbirine göre oranlarını yansıtan lineer denklemler şeklinde de yazılabilir. Dört oksit; CaO, SiO_2, Al_2O_3 ve Fe_2O_3, sırasıyla C, S, A ve F ile gösterilirse, Nuh Çimento Fabrikası'nın belirlediği standart değerleri aşağıdaki gibidir.

Kireç standardı (veya modülü):

$$ML = \frac{100\,C}{2.8S + 1.1A + 0.8F} \tag{2.2}$$

Alüminyum modülü:

$$MA = \frac{A}{F} \tag{2.3}$$

Silika modülü:

$$MS = \frac{S}{A + F} \tag{2.4}$$

2.4 Harmanlama Prosesinde Analiz (Ölçme) Sistemi

Harmanin analizinde PGNAA (hızlı gamma nötron aktivasyon analizcisi) kullanılmaktadır. Ölçümün temeli, PGNAA' nın harman üzerine nötron bombardımanı yapması, bazı atomların bu nötronları emmesi ve yüksek enerjili gamma radyasyonu yayması prensibine dayanır. Ölçüm dakikada bir yapılmaktadır. Bu periyot, kalsiyum, silisyum, demir ve alüminyum' un hassas bir şekilde ölçülmesi için yeterlidir. Bilgisayara aktarılan data ile oksit yüzdeleri hesaplanır. Bu ölçüm değerleri sistem üzerinde var olan kontrolörün düzeltme sinyali üretmesini sağlamaktadır. PGNAA, çimento endüstrisinde kullanılabilen en hızlı ölçme sistemidir. PGNAA 1000 ton/saat' e kadar olan sürekli akışta ayrıca numune almaksızın analiz yapabilmektedir. Çimento endüstrisinde kullanılan diğer bir yöntem de X ışını analiz yöntemidir. Bu yöntemde harmandan ton başına 0.1 kg numune alınarak analiz yapılır. İlk analiz sonuçları genelde 5 dakika sonra elde edilir. Oksit yüzdelerinin belirlenmesinde yaş analiz denilen bir yöntem daha kullanılmaktadır. Yaş analizde alınan numunenin $CaCO_3$ ve $MgCO_3$ titrasyonu yapılır. Bu yöntemle ancak saatte bir sonuç almak mümkündür. Ölçme cihazları içinde hem sistem tanılama hem de kontrol amacına yönelik en iyi ölçme cihazı PGNAA' dir. Bu çalışmada PGNAA' dan alınan ölçümler kullanılmıştır.

3. SİSTEM TANILAMA VE MODELLEME

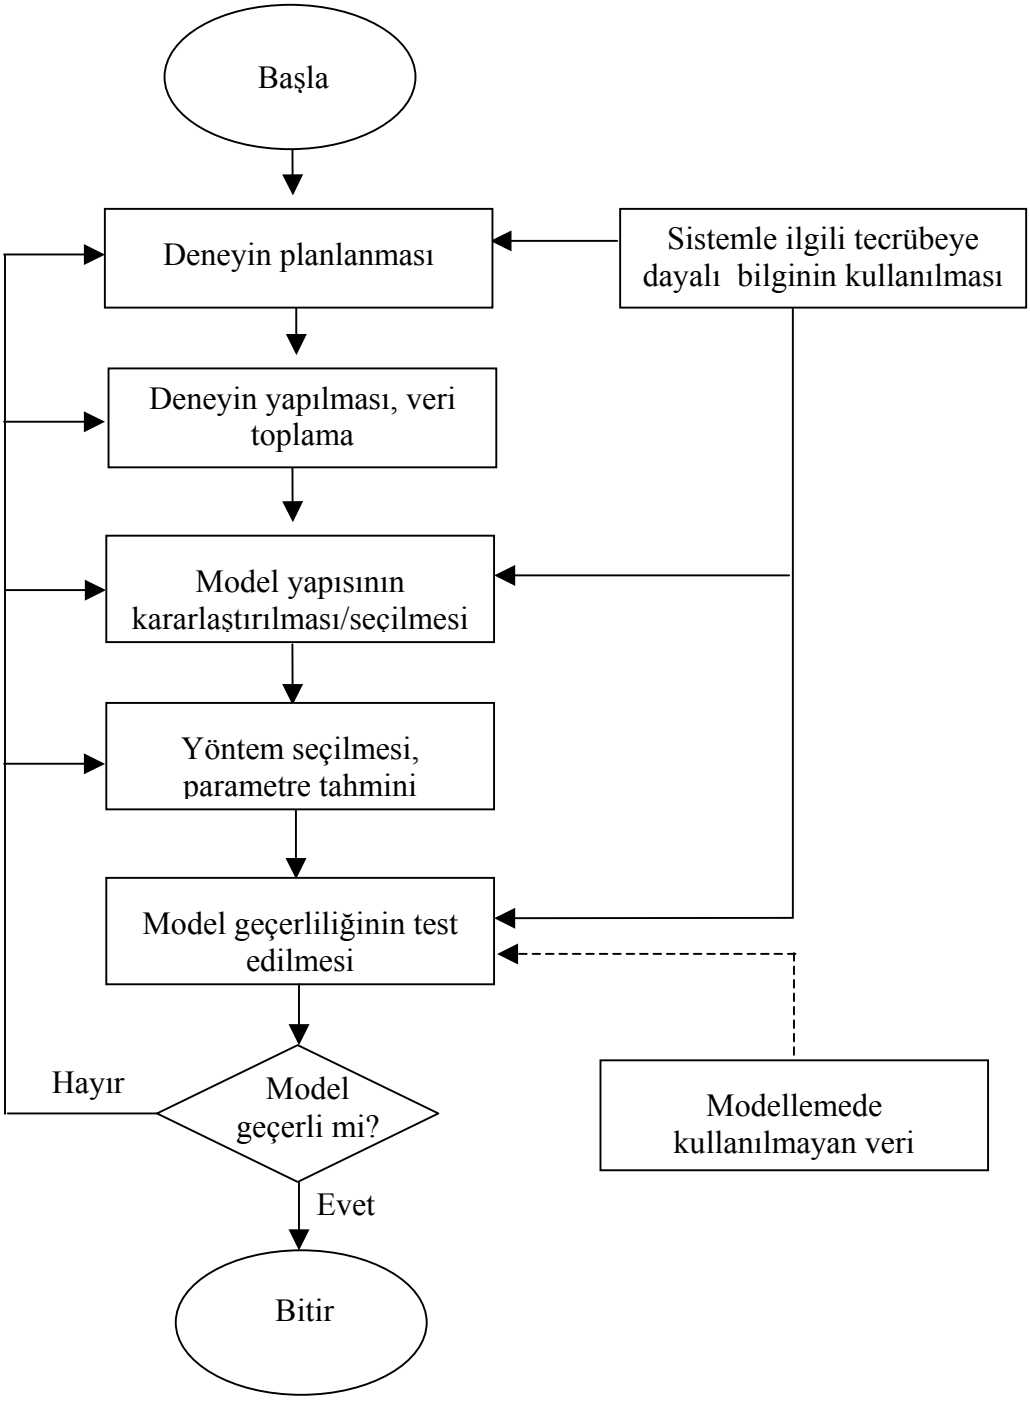
3.1 Giriş

Sistem tanılama, dinamik bir sistemin modelinin gerçek sistemden alınan giriş-çıkış ölçümleriyle bulunması anlamına gelir. Model bir giriş ve bir çıkış arasındaki matematiksel ilişkiyi ortaya koymak amacıyla oluşturulabileceği gibi, bir çok çıkış (veya ölçüm) ile bir çok giriş arasındaki ilişkiyi de inceleyebilir. Sistem tek giriş-tek çıkışlı ise SISO (single input-single output), çok giriş bir çıkışlı ise MISO (Multi input-single output), çok giriş-çok çıkışlı ise MIMO (Multi input-multi output) sistem olarak adlandırılır. Sistem tanılama süreci, deneysel planlama ve veri toplama, modellerin kurulması, deney verilerinden bilinmeyen sistem parametrelerinin tahmin edilmesini ve bulunan modelin geçerliliğinin test edilmesini içerir. Daha önce bahsedildiği gibi sistem modelinin bilinmesi, sistem karakteristiklerinin formulize edilmesi ve buna dayanarak yüksek performanslı kontrol sistemlerinin tasarımı ve gerçekleştirilmesi için önemlidir.

Sistem tanılama prosedürü 4 ana aşamadan oluşur.

- Deneysel planlama,
- Model yapısının seçimi,
- Parametre kestirimi,
- Kurulan modelin geçerliliğinin test edilmesi.

Sistemin geçerli bir matematik modelinin elde edilmesi başından sonuna kadar dikkat ve titizlik gerektiren bir işlemdir. Sistem tanılamanın sistematik bir akış diyagramı Şekil 3.1' de verilmiştir [5].



Şekil 3.1 Sistem tanılamanın şematik akış diyagramı

Sistem tanılama işlemi, sistemi uyaracak uygun giriş sinyalinin seçimi ile başlar. Sistemden elde edilen tanılamaya uygun veri ile bir model belirlenir ve belirlenen bir yöntemle parametreler kestirilir. Bu yolla elde edilen model geçerlilik testlerini

geçemezse algoritmada aşağıdan yukarıya doğru hareket edilir. Önce parametre kestirim yöntemi değiştirilir. Eğer model çeşitli denemelere rağmen yine geçersizse model yapısı değiştirilir ve algoritmada aşağıya hareket edilir. Model yapısını değiştirmenin de bir sonuca varmadığı durumlarda sistemin deneysel planlamasına geri dönülür. Sistemin lineer bir modelle temsil edilemediği veya tanılamanın (hata ölçülerine göre) yeteri kadar başarılı bulunmadığı sonucuna varılırsa akıllı sistemlerin de içinde bulunduğu lineer olmayan modelleme yapılarına başvurulur.

3.2 Sistem Tanılamada Giriş İşareti Seçimi

Uygun bir giriş sinyalinin seçimi, tanılama problemlerinin en önemli adımlarından biridir. Bu seçimdeki temel ölçüt, giriş-çıkış verilerinin farklı modeller arasında ayrım yapmaya yetecek ölçüde bilgi içerip içermemesidir. Birbiriyle ilişkisiz (uncorrelated) sözde rasgele ikili diziler (pseudo random binary sequences-PRBS) bu türden uygun giriş sinyallerine örnek olarak verilebilir. Eğer sistem, istenilen bir giriş sinyali ile uyarılabilecek bir sistem ise genelde PRBS sinyali kullanılır. Ancak sistemin karakteristikleri bu tür bir girişe müsaade etmiyorsa (harmanlama prosesinde olduğu gibi) iyi bir modelleme için sistemin giriş sinyalinin belli istatistiksel özellikleri sağlaması gerekir.

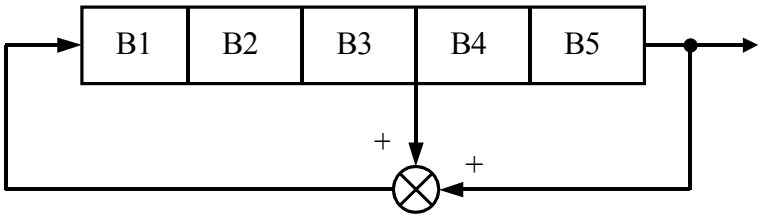
3.2.1 Beyaz Gürültü ve PRBS (Sözde-Rastgele İkili Dizi)

Lineer sistemler için kullanılacak giriş işaretinin istatistiksel karakteristiğini belirlemede işaretin birinci ve ikinci dereceden momentlerini (beklenen değer ve kovaryans fonksiyonu) bilmek yeterlidir. Ancak unutulmaması gereken bir nokta aynı ortalama değer ve kovaryans fonksiyonuna sahip iki sinyalin sayısal değerlerinin tamamen farklı olacağıdır. Beyaz gürültü normal dağılımlı beklenen değeri sıfır, varyansı σ^2 olan sinyaldir. Beyaz gürültü, her frekans içeriği zengin olan bir sinyaldir. Dolayısıyla sistemin bütün dinamiklerini (her mertebeden sistemi) uyarabilir. Beyaz gürültü geçmiş değerleriyle ilişkisizdir (uncorrelated). Giriş sinyalinin beyaz gürültü karakteristiği göstermesi sistemin dinamiklerinin ortaya çıkarılması ve dolayısıyla geçerli ve hassas modeller elde edilmesi açısından son derece önemlidir.

Kısaca PRBS olarak ifade edilen sözde-rastgele ikili diziler (pseudo-random binary sequence) genliği sabit, fakat sürerliliği değişen dikdörtgen darbeler şeklinde sinyallerdir. PRBS, analog sistemlerdeki beyaz gürültünün ayrık zamanlı karşılığı olarak kabul edilebilir. Dolayısıyla PRBS sinyalinin frekans içeriği oldukça zengindir. Bu sinyalin bir avantajı da genliğinin sabit olması ve frekans içeriğini etkilemeden istenen seviyede uygulanabilmesidir.

Sözde-rastgele terimi; PRBS' in her ne kadar genişliği rastgele değişen darbelerden oluştuğu ifade edilse de "dizi uzunluğu (sequence length)" ile gösterilen bir süre sonra tekrar ediyor (periyodik) olmasından kaynaklanmaktadır.

PRBS sinyalleri (donanım veya yazılımlarla gerçekleştirilen) geri beslemeli bellek hücreleri ile üretilirler. N bellek hücresi sayısı olmak üzere dizi uzunluğu $L=2^N-1$'dir. Şekil 3.2'de bellek hücresi N=5, uzunluğu L=31 olan PRBS sinyalinin üretimi gösterilmektedir [14].

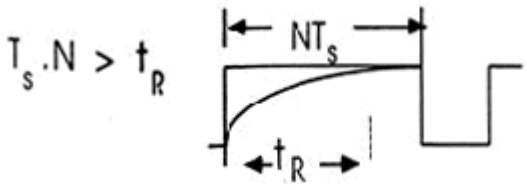


Şekil 3.2 N=5, L=31 olan PRBS sinyalinin üretimi

PRBS' in en uzun genişlikteki darbesi, bellek hücresi sayısı ile örnekleme periyodunun çarpımı kadar bir sürede uygulanmakta olup; bu süre sistem tanılama için çok önemlidir.

Bir sisteme ait sürekli durum kazancının doğru olarak tanılanabilmesi için, darbelerden en az bir tanesinin (örneğin en uzun süreli darbe) sistemin yükselme zamanı t_R' den daha uzun süreli olması gerekmektedir (Şekil 3.3).

$$NT_s > t_R \tag{3.1}$$



Şekil 3.3 PRBS'in en uzun darbesinin seçimi

PRBS sinyali, tanılanacak sisteme düşük genliklerde (sistem girişinin sürekli rejim değerinin % 1 ÷ 5'i gibi) uygulanabilir. Ancak uygulanan sinyalin, sistemin gürültü seviyesinden daha büyük genlikte olmasına dikkat edilmelidir.

3.2.2 Sürekli Uyaran (Persistently Exciting) Sinyal

Herhangi bir mertebeden sürekli uyaran sinyal şöyle tarif edilir: Eğer u(t) sinyalinin kovaryans matrisi (3.2) pozitif tanımlı bir matris ise sinyal n. mertebeden sürekli uyarandır.

$$R_u(n) = \frac{1}{N}\sum_{t=1}^{N}\phi(t)\phi(t)^T \tag{3.2}$$

Burada $\phi(t) = (u^T(t-1).....u^T(t-n))^T$'dır. Bu formülün uygulanması giriş işaretinin ortalamasının sıfır olduğu (ya da DC bileşenlerinin kaldırılması ile ortalamanın sıfırlandığı) kabulüne bağlıdır. Herhangi bir nxn boyutlu A matrisi,

$$x^T Ax > 0 \tag{3.3}$$

şartını sağlayan bir x matrisi varsa pozitif tanımlıdır. Böyle bir matrisin varlığı ise A matrisinin bütün özdeğerlerin pozitif olması anlamına gelir. Öyleyse belli bir mertebe için hesaplanan bir kovaryans matrisinin bütün özdeğerleri pozitifse sinyal o mertebeden sürekli uyarandır. Verilen bir kovaryans matrisinin rankı sistemin sürekli uyaran olduğu en üst mertebeyi verir [15].

Sinyalin sürekli uyaran olduğu mertebe, sistem tanıma için önerilen model mertebesini geçemez. Çünkü sinyal sürekli uyarma mertebesinden daha yüksek mertebedeki sinyallerin dinamiğini ortaya koyacak frekans zenginliğine sahip

değildir. Örnek vermek gerekirse, giriş sinyali olarak basamak fonksiyonu seçilirse, kovaryans matrisinin rankı 1' dir. Dolayısıyla basamak fonksiyonu birinci mertebeden yüksek mertebeli sistemlerin modellenmesinde kullanılamaz.

Beyaz gürültü, her mertebeden sürekli uyarandır. PRBS sinyali ise ancak periyodu kadar mertebeye kadar sürekli uyarandır. Ancak pratikte, PRBS sinyalinin periyodu çok yüksek olduğundan PRBS kullanılması sürekli uyarma açısından bir problem oluşturmamaktadır.

3.3 Sinyal Şartlandırma

3.3.1 DC Bileşenlerinin Yokedilmesi

Tanılama için kullanılacak veri fiziksel bir prosesten elde ediliyorsa fiziksel birimlerle ölçüm yapılır. Prosesin giriş ve çıkışındaki ölçümlerin sayısal değerleri birbirinden çok farklı seviyelerde olabilir. Bu ise seviyeleri ayarlamak için modellerde gereksiz parametre kullanımına yol açar [2]. Tanılama için kullanılan modellerin yapıları (bir çalışma noktası civarında girişteki değişimlerin fonksiyonu olarak ifade edilen çıkıştaki değişimleri belirten) dinamik modellere karşılık geldiğinden, doğru bir tanılama için (söz konusu çalışma noktasına karşılık gelen) DC bileşenlerin yok edilmesi gereklidir. Verinin ortalama değerlerinin hesaplanması ve her veriden bu değerin çıkarılması ile yeni giriş-çıkış veri seti elde edilir. Eğer veride lineer bir eğilim (lineer trend) de varsa eğilimin etkisi de o noktada ortalamaya katılarak bu değer giriş-çıkış verisinden çıkarılarak sıfır ortalamalı ve eğilimsiz veri kümesi elde edilir.

3.3.2 Verinin Ölçeklendirilmesi

Sistem tanımada, giriş-çıkış verilerini ölçeklendirmek yaygın bir yaklaşımdır. Ölçeklendirme giriş-çıkış verisi arasındaki seviye farklarını giderir. Ayrıca, veri sıfıra çok yakınsa özellikle kuadratik maliyet fonksiyonu kullanan parametre tahmin yöntemlerinde yuvarlatma hataları yüksektir. Ölçeklendirilen veri bu etkinin de azaltılması için kullanışlıdır. Eğer her veri sütunu kendi varyansına bölünürse (DC bileşenleri de giderilmişse) sıfır ortalamalı ve varyansı bir olan eş-dağılımlı

(identical) veri kümesi elde edilir. Bu işlem özellikle MIMO sistemlerde kullanışlıdır [17].

3.4 Model Karmaşıklığının Tahmini

3.4.1 Gürültüsüz Sistemin Model Karmaşıklığının Tahmini

Bozucuların olmadığı ayrık zamanlı bir sistemin darbe transfer fonksiyonu aşağıdaki gibidir:

$$y(t) = \frac{q^{-d}B(q^{-1})}{A(q^{-1})}u(t) \tag{3.4}$$

Burada;

$$A(q^{-1}) = 1 + a_1 q^{-1} + K + a_{nA} q^{-nA} \tag{3.5}$$

$$B(q^{-1}) = b_1 q^{-1} + K + b_{nB} q^{-nB} \tag{3.6}$$

şeklinde tanımlanmış olup y(t) sistem çıkışı, u(t) sistem girişi, d gecikme (delay) ve q geciktirme (zamanda öteleme) operatörüdür. Model karmaşıklığının tahmininin amacı, doğrudan doğruya giriş-çıkış verilerini kullanarak, model katsayılarını tanılamaksızın, sisteme ait A ve B polinomlarının mertebelerini ve gecikmeyi tahmin etmektir. Sistemde gürültü bulunmuyorsa; bir modelin karmaşıklığının (mertebesinin) tahmini için rank testi yapılır.

$\hat{n}$ model mertebesini ($\hat{n} = maks(n_A, n_B + d)$; n_A A polinomunun mertebesi, n_B B polinomunun mertebesi) tahmin etmek için;

$$[\tilde{y}(0)\ MR(\hat{n})] \tag{3.7}$$

matrisi tanımlanmış olsun. Burada;

$$\tilde{y}(0) = \begin{bmatrix} y(0) \\ y(-1) \\ M \\ y(-N+1) \end{bmatrix} \tag{3.8}$$

$$R(\hat{n}) = \begin{bmatrix} y(-1) & u(-1) & y(-2) & u(-2) & K & y(-\hat{n}) & u(-\hat{n}) \\ y(-2) & u(-2) & y(-3) & u(-3) & K & y(-\hat{n}-1) & u(-\hat{n}-1) \\ M & M & M & M & O & M & M \\ y(-N) & u(-N) & y(-N-1) & u(-N-1) & K & y(-\hat{n}-N+1) & u(-\hat{n}-N+1) \end{bmatrix} \tag{3.9}$$

ile verilmektedir. Eğer $[\tilde{y}(0)\, MR(\hat{n})]$ matrisinin rankı tam ise $\hat{n} < n$, tam değilse (küçükse) $\hat{n} \geq n$ anlamına gelmektedir. N değeri 1'den başlayıp $\hat{n} \geq n$ koşulu sağlanana kadar artırılmak yoluyla model mertebesi bulunur.

3.4.2 Beyaz Gürültülü Sistemin Model Karmaşıklığının Tahmini

Bir önceki altbölümde verilen yöntem uygulamada, sistemdeki gürültüden dolayı matris hiçbir zaman tekil olmadığı için, kullanışlı olmaz. Bunun için model mertebesini tahmin etmek üzere en küçük kareler tahminini içeren bir test uygulanabilir:

$$V_{LS}(\hat{n}) = \min \frac{1}{N} \left\| \tilde{y}(0) - R(\hat{n})\, \hat{\theta} \right\|^2 \tag{3.10}$$

Burada $\hat{\theta}$, $\tilde{y}(0)$'ın $R(\hat{n})$'nın kolonlarına lineer bağımlılığını ifade etmektedir.

3.5 Lineer Parametrik Sistem Tanılama ve ARX Model Yapısı

Giriş-çıkış verileriyle sistem tanılama yapılırken frekans analizi, korelasyon analizi, basamak cevabı, spektral analiz gibi tekniklerle parametrik olmayan modeller elde edilebilir. Ancak günümüzde bilgisayar teknolojisinin de gelişmesiyle parametrik modeller hem hassasiyet hem uygulanabilirlik açısından parametrik olmayan modellere üstün gelmiştir.

Bir prosesin bozucuları stokastik prosesler olarak tarif edildiğinde, tanılama problemi bir istatistiksel parametre tahmini problemi şeklinde formüle edilebilir. Tanılamada model parametrelerinin bulunması bir maliyet fonksiyonu belirlenerek bir optimizasyon problemine dönüştürülebilir. Maliyet fonksiyonunun minimize edilmesi iyi bilinen en küçük kareler yöntemi ile yapılabilir. Ancak en küçük kareler yönteminin kullanımı lineer olan model yapıları ile sınırlıdır.

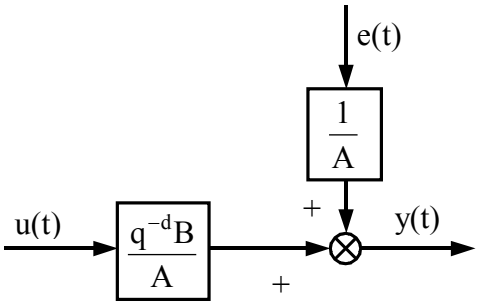
Parametrik modelin genel yapısı (3.11)' de verilmiştir.

$$y(t) = G(q^{-1})u(t) + H(q^{-1})e(t) \tag{3.11}$$

Denklemde $G(q^{-1})$ ve $H(q^{-1})$' in farklı tanımlanması farklı isimlerde model yapılarını oluşturur. Bu model yapılarından biri olan ARX (Auto-regressive with Exagenous Input)' in denklemi (3.12)'de verilmiştir.

$$A(q^{-1})\,y(t) = q^{-d}B(q^{-1})\,u(t) + e(t) \tag{3.12}$$

$A(q^{-1})$ ve $B(q^{-1})$ polinomları (3.5) ve (3.6) denklemlerinde verilmiştir. d terimi sistemin gecikmesini göstermektedir. Bu model yapısının blok diyagramı Şekil 3.4' de verilmiştir.



Şekil 3.4 ARX model yapısının blok diyagramı

Parametre vektörü θ (3.13)' de giriş-çıkış data bilgisi vektörü φ ise (3.14)' de tanımlanmıştır.

$$\theta^T = [-a_1 \;\; -a_2 \;\; ,..., \;\; -a_{nA} \;\; b_1 \;\; ,..., \;\; b_{nB}] \tag{3.13}$$

$$\varphi^T(t) = [y(t-1),..,y(t-n_A),u(t-1),..,u(t-n_B)] \tag{3.14}$$

Bu tanımlarla y(t) çıkışı (3.15)' deki gibi yazılabilir:

$$y(t) = \varphi^T(t)\theta + e(t) \tag{3.15}$$

(3.15) denklemi kullanılarak y(t) çıkışı vektörel formda (3.16) ve (3.17)' de tekrar yazılmıştır.

$$\begin{bmatrix} y(1) \\ y(2) \\ . \\ . \\ . \\ y(N) \end{bmatrix} = \begin{bmatrix} \varphi^T(1) \\ \varphi^T(2) \\ . \\ . \\ . \\ \varphi^T(N) \end{bmatrix} \theta + \begin{bmatrix} e(1) \\ e(2) \\ . \\ . \\ . \\ e(N) \end{bmatrix} \tag{3.16}$$

$$\mathrm{y} = \phi\hat{\theta} + \hat{\mathrm{e}} \tag{3.17}$$

Denklem (3.18)' de verilen maliyet (veya kayıp) fonksiyonunu minimize eden $\hat{\theta}$ parametre vektörü denklem (3.19)' da verilmiştir.

$$\mathrm{V_N}(\theta) = \frac{1}{\mathrm{N}}\sum_{\mathrm{t=1}}^{\mathrm{N}} \mathrm{e}^2(\mathrm{t}) \tag{3.18}$$

$$\hat{\theta} = \left[\frac{1}{\mathrm{N}}\sum_{\mathrm{t=1}}^{\mathrm{N}} \varphi(\mathrm{t})\varphi^{\mathrm{T}}(\mathrm{t})\right]^{-1}\left[\frac{1}{\mathrm{N}}\sum_{\mathrm{t=1}}^{\mathrm{N}} \varphi(\mathrm{t})\mathrm{y}(\mathrm{t})\right] \tag{3.19}$$

Denklem (3.19) şöyle de ifade edilebilir (3.20):

$$\hat{\theta} = [\phi^{\mathrm{T}}\phi]^{-1}[\phi^{\mathrm{T}}\ \mathrm{y}] \tag{3.20}$$

3.6 Model Geçerliliğinin Test Edilmesi

Model geçerliliğinin test edilmesinde öncelikle artık (residual) üzerinde inceleme yapılır. Eğer artık, diğer bir deyişle kestirim hatası beyaz gürültü özelliği taşıyorsa, bu; tanılanan modelin, gerçek sistemi en iyi şekilde temsil ettiği anlamına gelir. Beyaz gürültü özelliği taşımak hatanın geçmiş ve gelecek değerleriyle ve diğer herhangi bir değişkenle ilişkili (correlated) olmaması anlamına gelir. Hatanın geçmiş ve gelecek değerleriyle ilişkisi otokorelasyon testiyle, giriş sinyaliyle ilişkisi ise çapraz korelasyon (cross-correlation) testiyle kontrol edilir. Eğer bu testler uygun sonuçlar verirse sistemin giriş ve çıkışı arasındaki ilişki tamamıyla tanılanmış model ile temsil ediliyor demektir. Eğer bir sisteme ait sistem ve bozucu modeli doğru seçilmiş ise, uygun tanılama yöntemi kullanılmış ise, modeldeki polinomların mertebesi doğru ise kestirim hatası e(t) asimptotik olarak beyaz gürültüye doğru gider.

3.6.1 Otokorelasyon Testi

Normalleştirilmiş kovaryans fonksiyonu R(i) veya otokorelasyon şöyle tanımlanır:

$$RN(i) = \frac{R(i)}{R(0)} = \frac{\frac{1}{N}\sum_{t=1}^{N-i} e(t)e(t-i)}{\frac{1}{N}\sum_{t=1}^{N-i} e^2(t)} \qquad i=i_{max},\ldots 3,2,1,0,-1,-2,-3,\ldots,i_{max}\ (i_{max}\geq n_a) \quad (3.21)$$

Eğer çıkış hatası beyaz gürültü ise ve N çok büyükse RN(0)=1, RN(i)=0 (i≥1) olur. Bu, geçmiş ve gelecek hatanın şu andaki hatayla ilişkili olmadığını gösterir. Gerçekte ise e(t) üzerindeki mertebe ve doğrusal olmayan etkilerden ve sınırlı veri sayısı (N)' den dolayı RN(i)≠0'dir. Bu durumda geçerlilik için pratik olarak, % 97 güvenilirlik seviyesi için aşağıdaki denklem yazılır.

$$RN(0)=1,\ |RN(i)| \leq \frac{2.17}{\sqrt{N}},\ i\geq 1 \qquad (3.22)$$

Eğer RN(i), güvenilirlik seviyesi ile belirlenen aralık içinde kalıyorsa otokorelasyon testi başarılı sayılır.

3.6.2 Çapraz Korelasyon Testi

Normalleştirilmiş çapraz korelasyon denklemi aşağıda verilmiştir.

$$RN(i) = \frac{\frac{1}{N}\sum_{t=1}^{N-i} u(t)e(t-i)}{\left[\left(\frac{1}{N}\sum_{t=1}^{N-i} e^2(t)\right)\left(\frac{1}{N}\sum_{t=1}^{N-i} u^2(t)\right)\right]^{1/2}} \qquad i = i_{max},\ldots 3,2,1,0,-1,-2,-3,\ldots,i_{max} \qquad (3.23)$$

Eğer artık ile giriş sinyali mükemmel bir şekilde ilişkisiz ise i≥1 için RN(i)=0 elde edilir. Otokorelasyon testinde verildiği gibi pratik olarak % 97 güvenilirlik seviyesi için aşağıdaki denklem yazılır (3.24).

$$RN(0)=1,\ |RN(i)| \le \frac{2.17}{\sqrt{N}},\ i\ge 1 \qquad (3.24)$$

3.7 Model Yapısının Seçimi ve Modelin Geçerliliği Konusunda Ek Bilgiler

Kapalı çevrim sistemlerin incelenmesinde OE (Output Error-Çıkış Hatası) ve BJ (Box-Jenkins) yapıları geçerli modeller vermez [5]. Ayrıca spektral analiz ve durum-uzay modeli de güvenilir modeller değildir [2]. Model yapılarının karşılaştırılmasında sınama verisi kullanmak iyi bir yöntemdir. Eldeki veri kümesinde sondan % 10 kadarı sınama verisi olarak ayrılıp parametre tahmininde kullanılmaz, farklı model yapılarının sınama verisinin girişlerine ürettikleri çıkışlar ile gerçek çıkışlar karşılaştırılır. Ortak bir hata ölçütü (mutlak hataların toplamı, hataların kareleri toplamı, ortalama karesel hata vb.) seçilerek karşılaştırma yapılır.

Model mertebesinin tahmininde kutup-sıfır yok etmesi (pole-zero cancellation) grafiği incelenebilir. Eğer kutup ve sıfır üst üsteyse veya birbirine çok yakınsa model mertebesini düşürmek söz konusu olabilir. Sistemde geri besleme varsa model geçerliliğinin test edilmesinde daha dikkatli davranılmalıdır. Çapraz korelasyon testinde giriş ile artık sinyallerinin geçmiş değerleri arasında ilişki bulunması çıkış geri beslemesine işaret eder. Bu ilişki modelin reddedilmesini gerektirmez. Çapraz korelasyon testinde pozitif kısmın incelenmesi yeterlidir.

4. YAPAY SİNİR AĞLARI

4.1 Giriş

İnsan beyninde; okuma, hareket etme, nefes alma ve düşünme gibi işlemleri gerçekleştiren, çoklu bağlantıya sahip yaklaşık 10^{11} sinir hücresi bulunur [7]. Öğrenme işlemi, sinir hücreleri (nöronlar) arasında yeni bağlantılar kurulması veya var olan bağlantıların yenilenmesi ile meydana gelmektedir. Biyolojik sinir ağlarının yapısı ve işlevlerini nasıl yerine getirdiği öğrenilince "basit bir yapay sinir ağı kümesi oluşturulabilir mi?" sorusu akla gelmiştir. Bu sorunun cevabı, yapay sinir ağları fikrinin temelini oluşturur.

Yapay Sinir Ağları (YSA)' nın tanımı şöyle yapılabilir: YSA, birbirine yoğun bir şekilde paralel olarak bağlanmış, basit (genelde uyarlanabilir) işlem elemanlarından oluşmuş ve gerçek dünyadaki nesnelerle biyolojik sinir sisteminin yaptığının aynı şekilde etkileşmek üzere hiyerarşik olarak düzenlenmiş ağlardır [18].

YSA' da ağ, nöron denilen yapıtaşlarının birbirlerine belirli bir geometri ile bağlanmasından oluşur. Nöronlar, çok giriş–çok çıkışlı, yüksek dereceden doğrusal olmayan dinamik alt devrelerdir. Bir nöronun girişi, dış girişler, komşu nöronların çıkışları ve yanlılık terimi (bias) olabilir. Nöronun eğitilmesi bağlantı ağırlıklarının değiştirilmesi ile gerçekleşir. YSA' nın en çok kullanılan bilgi işlem yöntemlerine göre üstünlükleri şöyle sıralanabilir:

Paralellik: YSA' da işlemler bilgisayarlarda olduğu gibi seri olarak değil paralel olarak yapılır. Yani YSA' da aynı katmandaki nöronlar arasında zaman bağımlılığı yoktur. Birçok nöron eş zamanlı çalışır ve karmaşık bir işlev çok sayıda küçük nöron aktivitesinin bir araya gelmesiyle oluşur. Bu, zaman içerisinde herhangi bir nöronun işlev dışı kalması durumunda ağ başarımını dikkate değer ölçüde etkilemeyeceği anlamına gelir [19].

Yerel Bilgi İşleme: YSA' da her bir işlem birimi, çözülecek problemin tümü ile ilgilenmek yerine, sadece problemin bir parçasıyla ilgilenmektedir. Nöronlar, çok basit işlemler yapmalarına rağmen sağlanan görev paylaşımı nedeniyle çok karmaşık ve zor problemler çözülebilmektedir.

Öğrenebilirlik: Alışılagelmiş veri işleme yöntemlerinin çoğu programlama yoluyla hesaplamaya dayanır. Bu yöntemler ile tam tanımlı olmayan bir problem çözülemez. Ayrıca, herhangi bir problemin çözümü için probleme yönelik algoritma yazmak gerekir. YSA ise problemleri, verilen örnekleri kullanarak çözer. Çözülecek problemler için algoritma değil, parametreler değiştirilir [18].

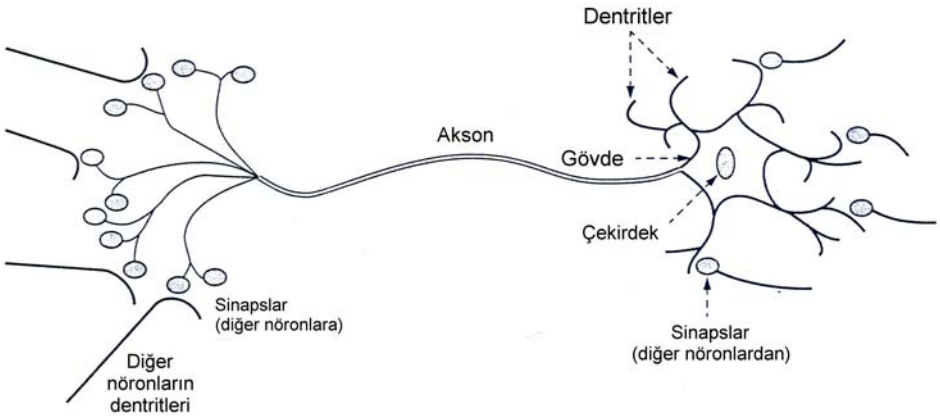
Genelleştirme: YSA' da ağ yapısı, eğitim için kullanılan sayısal bilgilerden eşleştirmeyi tanımlayan kaba özellikleri elde eder. Böylece yapay sinir ağı, girişler üzerindeki olası bozucuları kompanze edebilmektedir. Eğitimde kullanılmayan girişler için de anlamlı çıkışlar elde etmek mümkündür [19].

4.2 Basit Nöron Yapısı ve Fonksiyonları

Yapay sinir ağları, insanın biyolojik sinirsel yapısının incelenmesi ve modellenmesi ile ortaya çıkmıştır. Yapay bir nöron, gerçek bir sinir hücresinin sahip olduğu bağlantılarla aynı işlevi yapan bağlantılara sahiptir. Bu bölümde, öncelikle biyolojik nöron ve basit yapay nöron yapısı üzerinde durulacak, daha sonra YSA' da öğrenme ve YSA modelleri konuları incelenecektir.

4.2.1 Biyolojik Nöron

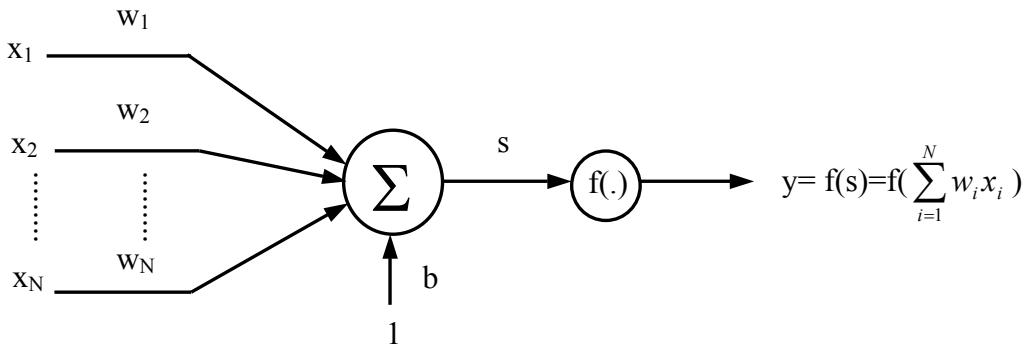
Bir biyolojik nöron, hücre gövdesi, akson ve dentritlerden oluşur (Şekil 4.1). Dentritler, nöron çevresini saran ince filamentlerdir. Aksonların ucunda diğer nöronlarla iletişimin sağlandığı sinapslar vardır. Dentritlerin ağaçsı yapısı birçok nöronla (100-100,000) aynı zamanda etkileşimi sağlar ve hücre gövdesine elektriksel sinyalleri taşır [20]. Hücre gövdesi gelen bu elektrokimyasal sinyalleri toplar ve eşiklendirir. Yapay ağlarla, biyolojik ağlar arasında iki temel benzerlik vardır: Birincisi; iki ağ yapısında da ana bileşenler birbirlerine sıkıca bağlı matematik fonksiyonlardır. İkincisi; bağlantının şekli ağın işlevini belirler [7].



Şekil 4.1 Bir biyolojik nöron

4.2.2 Yapay Nöron

Bir yapay nöronun matematik modeli Şekil 4.2' de gösterilmiştir.



Şekil 4.2 Yapay nöron modeli

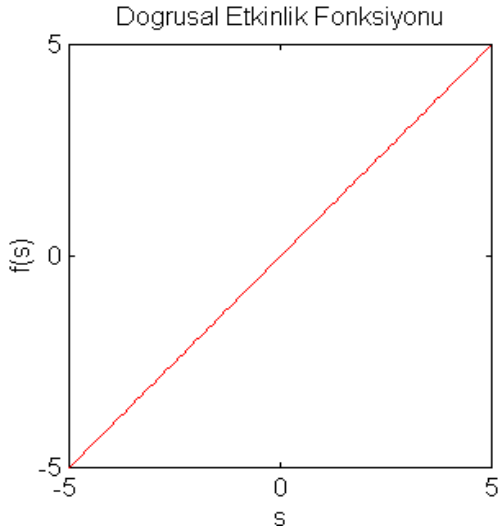
Burada, $\mathbf{x}=[x_1 \quad x_2 \quad ... \quad x_N]^T$ vektörü nörona uygulanan girişlerden oluşur. Bütün girişler sürekli sinyaller taşırlar ve belirli ağırlık oranına göre nörona etki eder. Yani her bir giriş kendisiyle ilgili ağırlık terimiyle çarpılır. w_1, w_2, ..., w_N ağırlıkları da vektörel olarak **w** ile gösterilir. b, sabit girişin ağırlığı olup yanlılık terimi (bias) olarak adlandırılır. Bu tanımlar altında s ağırlıklı toplamı şöyle yazılabilir:

$$s(\mathrm{x},\mathrm{w}) = b + x_1 w_1 + x_2 w_2 + ... + x_N w_N = b + \sum_{i=1}^{N} x_i w_i \qquad (4.1)$$

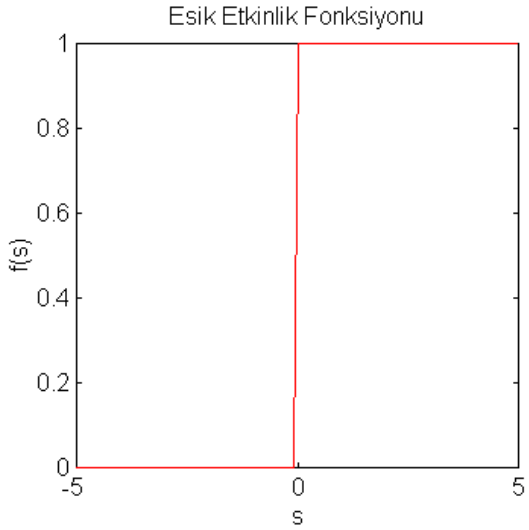
Ağırlıklı toplamın hesaplanmasından sonra bu toplam bir etkinlik (activation) fonksiyonundan geçirilerek çıkış üretilir.

4.2.3 Yapay Nöron Etkinlik Fonksiyonları

Nöron etkinlik fonksiyonu olarak çok çeşitli fonksiyonlar olmakla birlikte en çok kullanılan fonksiyonlar; doğrusal, eşik, lojistik sigmoid, tanjant sigmoid, ve tanjant hiperbolik fonksiyonlarıdır. İlk YSA modellerinde etkinlik fonksiyonu olarak eşik etkinlik fonksiyonu kullanılmıştır ancak bu durumda nöron çıkışları ikili olmakta yani ara değerler üretilememektedir [21]. Şekil 4.3' de doğrusal, Şekil 4.4' te eşik etkinlik fonksiyonu görülmektedir.



Şekil 4.3 Doğrusal etkinlik fonksiyonu



Şekil 4.4 Eşik etkinlik fonksiyonu

Doğrusal etkinlik fonksiyonunun çıkışı ağırlıklı toplamın kendisidir.,

$$y = linear(s(\mathbf{x}, \mathbf{w})) = s(\mathbf{x}, \mathbf{w}) \tag{4.2}$$

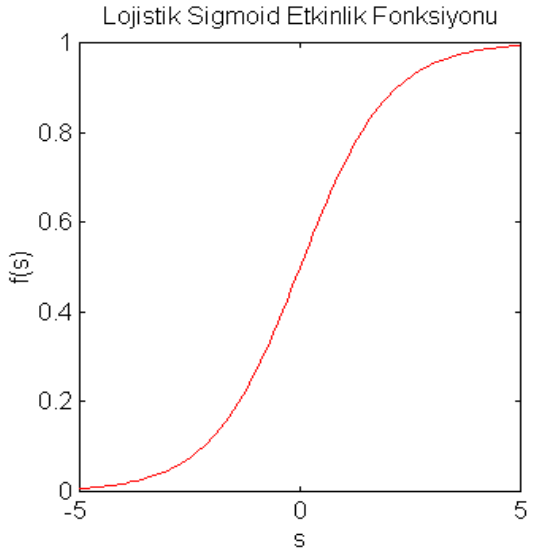
Eşik etkinlik fonksiyonunda çıkış şu şekilde elde edilir:

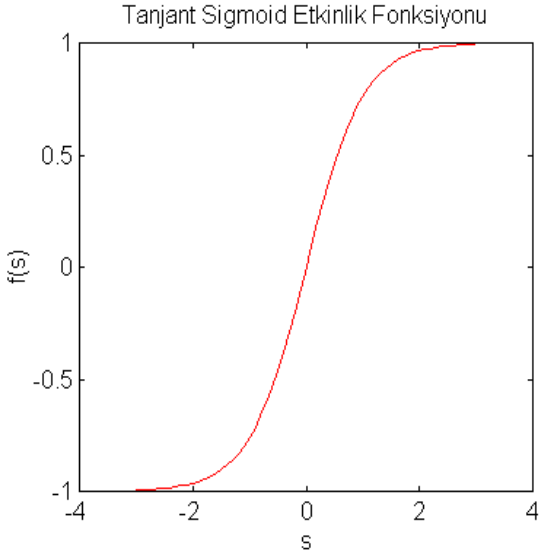
$$y = sign(s(\mathbf{x}, \mathbf{w}))$$

$$s(\mathbf{x}, \mathbf{w}) \geq 0 \; ise \; y = 1 \tag{4.3}$$

$$s(\mathbf{x}, \mathbf{w}) < 0 \; ise \; y = 0$$

Lojistik sigmoid etkinlik fonksiyonu Şekil 4.5' te, tanjant sigmoid etkinlik fonksiyonu Şekil 4.6' da gösterilmiştir.





Şekil 4.5 Lojistik sigmoid etkinlik fonksiyonu Şekil 4.6 Tanjant sigmoid etkinlik fonksiyonu

Lojistik sigmoid etkinlik fonksiyonu ile tanjant sigmoid etkinlik fonksiyonları sırasıyla şunlardır:

$$f(s) = \frac{1}{1 + e^{-\lambda s}}$$

$$f(s) = \frac{1 - e^{-\lambda s}}{1 + e^{-\lambda s}} \tag{4.4}$$

λ, fonksiyonun eğimini belirler ve genel olarak 1 veya 2 alınır. Ayrıca tanjant sigmoid etkinlik fonksiyonunda λ=2 alınarak tanjant hiperbolik etkinlik fonksiyonu elde edilir.

4.3 YSA' da Öğrenme

Sinir ağlarında öğrenme, hem biyolojik hem de yapay sinir ağları için önemli bir araştırma konusudur. Genel anlamda öğrenme, sinir ağının, giriş uyarıcılarını kullanarak kendini istenen sonuçları vermek üzere adapte etmesidir. Biyolojik olarak bu işlem, sinaptik ağırlıkların giriş uyarıcılarıyla güncellenmesidir [22]. YSA' nda ise değişebilen sistem parametreleri, hücreler arası bağlantıları sağlayan sinapsları temsil eden bağlantıların ağırlıklarıdır. Öğrenme için bir eğitim kümesine ihtiyaç vardır. Eğitim kümesi YSA' na öğrenmek için uygulanacak girişlerden ve varsa istenen çıkışlardan oluşmaktadır.

Her adımda, eğitim kümesinden sırayla veya rastgele örnekler alınmakta ve ağın bu girişlere ilişkin çıkışları bulunmaktadır. Adım sonunda veya tüm örnekler bir defa ağa uygulandıktan sonra (çevrim sonunda) belirli bir amaç ölçütü uyarınca ağın bağlantı ağırlıkları değiştirilmektedir. Öğrenme, eğer ağırlıklar, adım sonunda değiştiriliyorsa, veri uyarlamalı öğrenme, çevrim sonunda değiştiriliyorsa grup uyarlamalı öğrenme olarak adlandırılır [21, 18]. YSA, öğreticili ve öğreticisiz olmak üzere iki şekilde eğitilebilir.

4.3.1 Öğreticili Öğrenme (Supervised Learning)

Öğreticili öğrenmede ağ, çevreden aldığı girişlere karşı, bir öğreticinin (eğiticinin) belirlediği doğru çıkışı üretmek hedefiyle kendini ayarlamaktadır. Ağa hem girişler hem de bu girişlere karşılık gelen istenen çıkışlar verilmektedir. Ağ tarafından üretilen gerçek çıkış ile istenen çıkış arasındaki fark (hata), bağlantı ağırlık katsayılarının ne kadar değişeceğini belirlemektedir [18]. Öğreticili öğrenme şu örnekle açıklanabilir; yabancı dil öğrenirken, öğretmenden duyulan bir kelimenin telaffuzu beyne kaydedilir. Bu kelime öğrenci tarafından tekrar söylenir ve kayıtlı olan sesle karşılaştırma yapılır. Bu tekrarlama kelimenin doğru telaffuzu yakalanana kadar devam eder. Kelime doğru telaffuz edilmeye başlandığında tekrarlama durur.

4.3.2 Öğreticisiz Öğrenme (Unsupervised Learning)

Öğreticisiz öğrenmede, hedef çıkışlar yoktur yani öğrenme sisteminde bir öğretici yoktur. YSA' nın bağlantı ağırlık katsayıları, oluşan hatayı göz önüne almaksızın bir

amaç ölçüt uyarınca sadece girişlere bağlı olarak değişmektedir. Öğreticisiz öğrenme algoritmaları daha çok, sistemin geçmişte karşı karşıya kaldığı veri kümesinin içerdiği istatistiksel bilgilerin çıkarsınmasını amaçlar. Böylelikle çok elemanlı veri kümeleri içerisinde deneyim yoluyla bilgi genelleştirilmesi yapabilir [19]. Bu tür bir öğrenme, her YSA modeli için uygulanabilir değildir ve her probleme uygulanamaz. Hebb Öğrenme Kuralı ve Kazanan-Herşeyi-Alır Öğrenme Kuralı öğreticisiz öğrenmede kullanılan bazı amaç ölçütü belirleyici kurallardır [20].

4.4 Yapay Sinir Ağ Modelleri

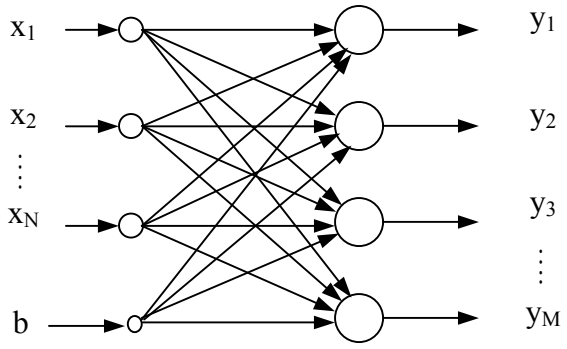
YSA mimarisi, modelleme ve tasarım için belirlenmesi gereken en önemli kriterdir. YSA mimarisinin belirlenmesi; ağ yapısının, öğrenme için kullanılacak parametrelerin ve öğrenme algoritmasının seçimini içerir. YSA modelleri biyolojik sinir sisteminin prensipleri ile mühendislikte bilinen teorilerin bütünleştirilmesiyle oluşturulmuştur. YSA modellerini ileri ve geri beslemeli ağlar olarak iki gruba ayırmak mümkündür. İleri beslemeli ağlar, işaretin ağ girişinden çıkışına doğru tek yönlü olarak iletildiği ağlardır. Bir katmandaki nöronlar, ancak bir önceki katmanın çıkışını giriş olarak alabilir. Her katman önceden belirlenen bir fonksiyonu içeren nöronlardan oluşur. Bu nedenle ileri beslemeli ağlara cebrik ağlar da denir.

Geri beslemeli ağlarda, (recurrent networks) bir katmandaki nöronlar, sadece bir önceki katmanın çıkışlarını değil aynı zamanda o katmanın veya daha sonraki katmanların da çıkışlarını giriş olarak alabilirler. Bu yüzden çıkış, sadece o anki girişlere değil, başlangıç durumuna ve daha önceki girişlere de bağlıdır. Geri beslemeli ağlara dinamik ağlar da denir. Hopfield ağı, Grossberg ağı, ART1 en çok bilinen geri beslemeli ağlardır. Geri beslemeli ağlar özellikle optimizasyon problemlerinde başarılı sonuçlar vermektedir [7]. Bu çalışmada ileri beslemeli ağlar üzerinde durulmuştur.

4.4.1 Tek Katmanlı İleri Beslemeli Ağlar

Genelde tek bir nöron, istenen giriş-çıkış işlemini yerine getirmez. Bunun için bağlantı ağırlıkları dışında aynı özelliklere sahip nöronlar bir araya getirilerek katmanlar oluşturulur. Tek katmanlı ileri beslemeli ağlarda bir katmandaki bütün

nöronların girişleri aynıdır. Şekil 4.7' de N girişli, M çıkışlı tek katmanlı ileri beslemeli bir ağ modeli görülmektedir [18].



Şekil 4.7 Tek katmanlı ileri beslemeli ağ modeli

w_{ij}, j. nörona gelen i. girişin ağırlığı ve bu ağırlıklardan oluşan, j. nöronun ağırlık vektörü w_j şöyledir:

$$w_j = \begin{bmatrix} w_{j1} & w_{j2} & \dots & w_{jN} \end{bmatrix}^T \tag{4.5}$$

b_j, j. nöronun yanlılık (bias) terimi olmak üzere j. nöronun ağırlıklı toplamı ve çıkışı ise şöyledir:

$$s_i = \sum_{i=1}^{M} w_j x + b_j \tag{4.6}$$

$$y_j = f(s_i) \tag{4.7}$$

Çıkış denkleminde görülen f(s) ifadesi etkinlik fonksiyonudur. Bu ifadeleri matris-vektör formunda şu şekilde yazmak mümkündür:

$$\mathbf{w} = \begin{bmatrix} w_1 & w_2 & \dots & w_M \end{bmatrix}^T \tag{4.8}$$

$$\mathbf{b} = \begin{bmatrix} b_1 & b_2 & \dots & b_M \end{bmatrix}^T \tag{4.9}$$

$$\Gamma[.] = \begin{bmatrix} f(.) & 0 & \dots & 0 \\ 0 & f(.) & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & f(.) \end{bmatrix} \tag{4.10}$$

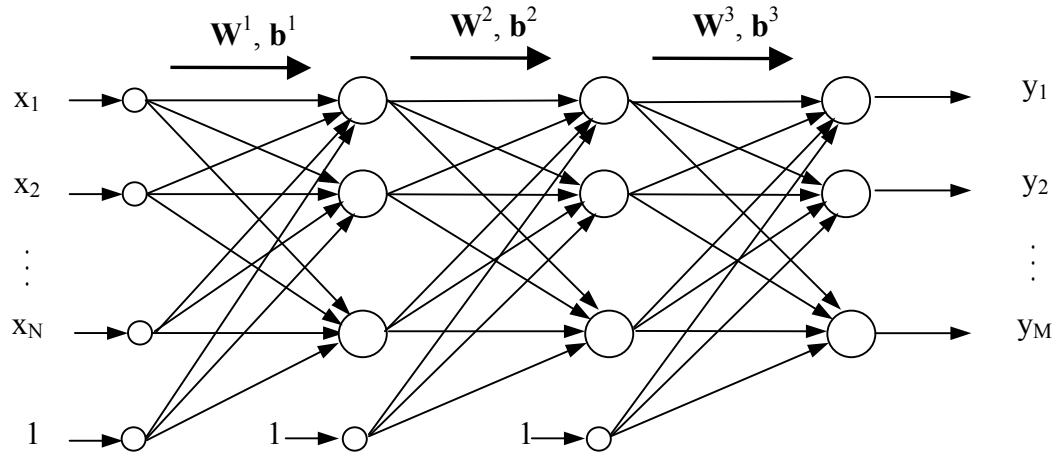
$$\mathbf{y} = \begin{bmatrix} y_1 & y_2 & \dots & y_M \end{bmatrix}^T \tag{4.11}$$

Bu tanımlamalar altında çıkış vektörel formda şu şekildedir:

$$\mathbf{y} = \Gamma[\mathbf{W}\mathbf{x} + \mathbf{b}] \tag{4.12}$$

4.4.2 Çok Katmanlı İleri Beslemeli Ağlar

Katmanların kaskat (seri) bağlanmasından çok katmanlı ağlar oluşur. Bir katmanın girişi, bir önceki katmanın çıkışıdır. Şekil 4.8' de 3 katmanlı ileri beslemeli bir ağ görülmektedir [18]. Çok katmanlı ağlarda giriş ve çıkış aynıdır. Ancak giriş katmanı ile çıkış katmanı arasında gizli katmanlar bulunmaktadır. Giriş nöronları gelen bilgileri herhangi bir işleme tabi tutmadan gizli katmana aktarırlar ve bu nedenle gerçek anlamda katman sayılmazlar [21]. Gizli katmanların dış ortamla doğrudan bilgi alışverişi yoktur. Çok katmanlı YSA' da nöronlar arası bağlantılar girişten çıkışa doğru ve katman atlamadan yapılır.



Şekil 4.8 Üç katmanlı ileri beslemeli YSA modeli

W^i, i. katmanın ağırlık matrisi, b^i, i. katmanın yanlılık (bias) vektörü ve $\Gamma^i[.]$, i. katmanın matris operatörü olmak üzere 3 katmanlı bir ağın çıkışı şu şekilde hesaplanmaktadır.

$$\mathbf{y} = \mathbf{\Gamma}^3[\mathbf{W}^3\mathbf{\Gamma}^2[\mathbf{W}^2\mathbf{\Gamma}^1[\mathbf{W}^1\mathbf{x} + \mathbf{b}^1] + \mathbf{b}^2] + \mathbf{b}^3] \tag{4.13}$$

4.5 Geri Yayılma Eğitim Algoritması

Geriye yayılma eğitim algoritması, günümüzde en çok kullanılan öğrenme algoritmasıdır. Bunda, öğrenme kapasitesi ve algoritmanın basitliği etkilidir.. Geriye yayılma yöntemi, lineer olmayan sistem tanılama ve kontrolünden ses tanıma problemlerine kadar YSA ile çözüm üretilen birçok alanda başarı ile kullanılmaktadır.

Geriye yayılma algoritması, kuadratik formda olan bir maliyet fonksiyonunun en küçük değerini aldığı noktanın iteratif olarak bulunması temeline dayanır. Maliyet fonksiyonunun minimize edilmesinde eğim düşüm (gradient descent) yöntemi olarak bilinen yöntem kullanılır. Maliyet fonksiyonu ve kısmi türevi şöyledir:

$$\begin{aligned} J_r &= \frac{1}{2}\phi^2 \\ \Delta\phi &= -\alpha\frac{\partial J_r}{\partial\phi} \end{aligned} \tag{4.14}$$

Denklem (4.14)' de α öğrenme oranı (learning rate) olarak tanımlanır. Pratikte öğrenme oranı α çok küçükse, hata uzunca bir süre içinde orijine doğru yakınsarken, büyük bir değer orijin etrafında salınımlara hatta ıraksamaya neden olabilir. Katman ve nöron sayısı seçimi gibi öğrenme oranı seçimi de birçok uygulamada deneme yanılma ile yapılır [19].

4.5.1 Delta Kuralı

Eğim düşüm yöntemi tek katmanlı ileri beslemeli YSA' nda hata geri yayılması için şöyle uyarlanabilir: Geri yayılma algoritması, gerçek çıkış (ağın çıkışı) **y** ile istenen çıkış **d** arasındaki karesel hatayı minimize etmek için aynı yöntem kullanılırsa;

$$E(k) = \frac{1}{2}\sum_{i=1}^{M}(d_i(k) - y_i(k))^2 \tag{4.15}$$

Formülün başındaki 1/2 katsayısı türev alınırken sadeleşir. Karesel hata fonksiyonunun **w** ağırlığına ve **b** yanlılık değerine göre gradyeninin negatif doğrultusunda hareket edilerek hata minimum yapılır. Ağırlıklar için değişim şu şekilde tanımlanabilir:

$$\Delta w_{ij} = -\alpha \frac{\partial E}{\partial w_{ij}} \quad (i = 1, 2, ..., M \ ve \ j = 1, 2, ..., N) \tag{4.16}$$

E(k) fonksiyonunun ağırlığa göre kısmi türevi yeniden yazılabilir;

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial s_i} . \frac{\partial s_i}{\partial w_{ij}} \tag{4.17}$$

Burada,

$$s_i = \mathbf{w}_i^T \mathbf{x} + b_i \tag{4.18}$$

olup denklem (4.6)' ya eşittir. (4.17) eşitliğinde çarpımın ilk terimi δ hata terimi olarak adlandırılır ve;

$$\delta_i = -\frac{\partial E}{\partial s_i} \tag{4.19}$$

şeklinde tanımlanır. (4.17) denkleminin ikinci terimini ise (4.18) denklem kullanılarak;

$$\frac{\partial s_i}{\partial w_{ij}} = x_j \tag{4.20}$$

olarak yazılabilir. Bu durumda (4.17) denklemi yeniden yazılabilir:

$$\frac{\partial E}{\partial w_{ij}} = -\delta_i . \mathbf{x}_j \tag{4.21}$$

Bu durumda (4.16)' daki ağırlık değişim denklemi şu şekilde yazılabilir:

$$\Delta w_{ij} = \alpha \delta_i x_j \tag{4.22}$$

δ_i ifadesi tekrar zincir kuralına göre açılırsa;

$$\delta_i = -\frac{\partial E}{\partial s_i} = -\frac{\partial E}{\partial y_i} . \frac{\partial y_i}{\partial s_i} \tag{4.23}$$

elde edilir. (4.23) denkleminin sağındaki ifadeler, (4.15) ve (4.7)' den yararlanılarak tekrar yazılırsa;

$$\frac{\partial E}{\partial y_i} = -(d_i - y_i)$$

$$\frac{\partial y_i}{\partial s_i} = f'(s_i) \tag{4.24}$$

olarak yazılırsa (4.23), şu hale dönüşür:

$$\delta_i = (d_i - y_i).f'(s_i) \tag{4.25}$$

Bu durumda, tek katmanlı ileri beslemeli bir ağ için ağırlık değişim formülü şöyle yazılabilir:

$$\Delta w_{ij} = \alpha (d_i - y_i) f'(s_i) x_j \tag{4.26}$$

(4.26) denkleminden görüldüğü gibi çıkış fonksiyonunun türevini almak gerekmektedir. Bazı etkinlik fonksiyonları ve türevleri Tablo 4.1' de verilmiştir [23].

Tablo 4.1 Bazı etkinlik fonksiyonları ve türevleri

Fonksiyon Adı	Etkinlik Fonksiyonu	Etkinlik Fonksiyonunun Türevi
Doğrusal	$f(s) = s$	$f'(s) = 1$
Lojistik Sigmoid	$f(s) = \frac{1}{1+e^{-\lambda s}}$	$f'(s) = \lambda f(s)(1-f(s))$ $f'(s) = y_i(1-y_i),\ (\lambda = 1)$
Tanjant Sigmoid	$f(s) = \frac{1-e^{-\lambda s}}{1+e^{-\lambda s}}$	$f'(s) = \frac{1}{2}\lambda(1-f(s)^2)$ $f'(s) = \frac{1}{2}(1-y_i^{\,2}),\ (\lambda = 1)$
Tanjant Hiperbolik	$f(s) = \frac{e^{\lambda s}-e^{-\lambda s}}{e^{\lambda s}+e^{-\lambda s}}$	$f'(s) = \lambda(1-f(s)^2)$ $f'(s) = (1-y_i^{\,2}),\ (\lambda = 1)$

Etkinlik fonksiyonlarının türevleri kullanıldığı için çıkış katmanındaki nöronlarda kullanılan etkinlik fonksiyonunun, türevi alınabilir olması gereklidir. Bu nedenle geri yayılma algoritmasında etkinlik fonksiyonu olarak eşik fonksiyonu kullanılamaz. Bu durumda basamak değişimi yerine sigmoid fonksiyonlarda olduğu gibi daha yumuşak geçişli ve türevi alınabilen fonksiyonlar tercih edilmektedir [21]. Sonuç olarak ağırlık güncelleme formülü olan,

$$w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij} \tag{4.27}$$

ifadesinde Δw_{ij}, (4.26) denklemindeki eşitliğiyle yerine konulursa;

$$w_{ij}(k+1) = w_{ij}(k) + \alpha(d_i(k) - y_i(k))f'(s_i(k))x_j(k) \tag{4.28}$$

olarak elde edilir. Yanlılık terimi için de aynı işlemler yapılarak yanlılık terimleri ayarlama formülü şöyle elde edilir [21]:

$$b_j(k+1) = b_i(k) + \alpha(d_i(k) - y_i(k))f'(s_i(k)) \tag{4.29}$$

Buraya kadar tek katmanlı ileri beslemeli ağlar için geriye yayılma yönteminin temel prensipleri anlatılmıştır. Geriye yayılma yöntemi çok katmanlı ileri beslemeli ağlar için de uygulanabilmektedir. Aynı matematiksel temele sahip olan algoritmada kullanılan kurala genelleştirilmiş delta kuralı denmektedir.

4.5.2 Geriye Yayılma Algoritması ile Eğitmede İşlem Sırası

P örnekten oluşan bir eğitim kümesiyle geriye yayılma yöntemine dayalı bir eğitmede, c çevrim sayısını ve p çevrimdeki adım sayısını göstermek üzere geriye yayılma algoritması, 8 adımda şöyle özetlenebilir [18]:

1. Öğrenme oranı α (>0) ve kabul edilebilir hata E_{max} seçilir. W ağırlıklarına ve b yanlılık değerlerine rastgele küçük değerler atanır.
2. Girişler ağa uygulanır ve tüm nöronların çıkışı hesaplanır.
3. Hata hesaplanır.
4. Her katmanın hata işaret vektörleri (δ) hesaplanır.
5. Çıkış katmanının ağırlıkları ve yanlılık katsayısı ayarlanır.
6. Gizli katmanların ağırlıkları ve eşikleri hesaplanır.
7. p<P ise p←p+1, c←c+1 ve 2. adıma git. p<P değilse 8. adıma git.
8. E≤E_{max} ise eğitimi bitir. E> E_{max} ise E←0 ve p←1 ve 2. adıma git.

4.6 Eğitim Zamanını Azaltan Yöntemler

Geriye yayılma algoritmasının iki temel dezavantajı vardır. Bunlardan birincisi eğitim sırasında ağın, tüm gradyen tabanlı yöntemlerde olduğu gibi hata fonksiyonunun bir yerel minimuma yakınsayabilmesi, ikincisi ise eğitim zamanının çok uzun olabilmesidir. Daha önce bahsedildiği gibi birinci problem öğrenme oranının seçilmesiyle yakından ilgilidir. Eğitim zamanı ise ilk ağırlıklar, öğrenme oranı, saklı katman sayısı ve saklı katmanlardaki nöron sayılarıyla ilgilidir. Eğitim zamanını azaltmak için pek çok çalışma yapılmış ve yöntemler geliştirilmiştir. Bunlardan uyarlanabilir öğrenme oranı, momentum metodu ve Levenberg-Marquardt algoritması kısaca anlatılmıştır.

4.6.1 Uyarlanabilir Öğrenme Oranı (Adaptive Learning Rate)

Uyarlanabilir öğrenme oranı yönteminde bir çevrimdeki hata, E(c), bir önceki çevrimdeki hatadan, E(c-1), küçükse α, belirli bir sabitle (meselâ 1.05) ile çarpılarak arttırılır. E(c), E(c-1)' in belirli bir katından (meselâ 1.04) büyükse, yeni hesaplanan ağırlıklar ve hata iptal edilir ve α, belirli bir sabitle (meselâ 0.7) çarpılarak azaltılır.

Uyarlanabilir öğrenme oranı uygulanarak ağ, uygun olan en büyük öğrenme oranıyla eğitilmiş olur, böylece eğitim zamanı kısaltılır [18].

4.6.2 Momentum Yöntemi

Momentum yöntemi, yakınsama hızını arttırmanın yanı sıra, küçük yerel minimumlara takılmamayı sağlar [7]. Bu metotta, o anki ağırlık değişimine, daha önceki ağırlık değişiminin belli bir oranı eklenir. Bu durumda bir k anındaki ağırlık değişimi şöyle yazılabilir:

$$\Delta w(k) = -\alpha \nabla E(k) + \beta \nabla w(k-1) \tag{4.30}$$

Bu denklemde β, momentum oranı olup, pozitif bir sabittir (genellikle 0.1~0.9) arası seçilir). İfadenin sağ tarafındaki ikinci terim momentum terimi olarak adlandırılır.

4.6.3 Levenberg-Marquardt Algoritması

Levenberg-Marquardt (LM) algoritması, Newton metodundan türetilmiş bir algoritmadır. Newton metodu, bir fonksiyonu minimize etmek için kullanılır ki buradaki fonksiyon başka lineer olmayan fonksiyonların hatalarının kareleri toplamını temsil etmektedir. LM algoritmasının YSA' yı eğitmekte kullanıldığında başarım ölçütü (performance index) hataların karelerinin ortalaması olmaktadır. Ağırlıkların değişimi şu şekilde yazılabilir:

$$\Delta w_{ij} = (J^T J + \mu I)^{-1} J^T E \tag{4.31}$$

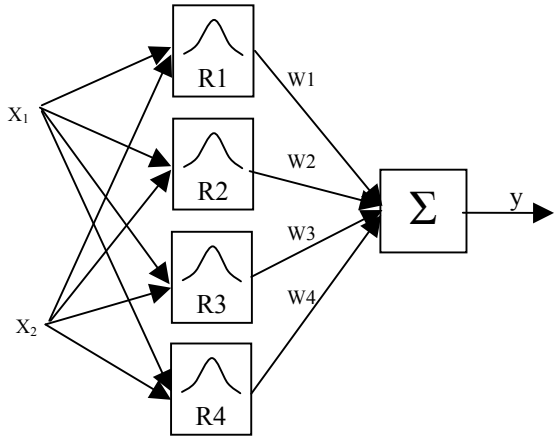
Uyarlanabilir öğrenme oranında olduğu gibi Levenberg-Marquardt algoritmasında da ağırlıkların yenilenmesinde uyarlanabilir bir katsayı olan minimum gradient (μ) kullanılır. Levenberg-Marquardt algoritması aşağıdaki adımlardan oluşur.

1. Tüm girişleri ağa uygula, çıkışları ve hatayı hesapla.
2. Hataların ağırlıklara göre değişimini içeren Jakobien matrisini hesapla.
3. Ağırlıkların değişimini hesapla.
4. Yeni ağırlık değerlerini bul. Yeni ağırlıklara göre hatayı tekrar hesapla. Eğer hata bir önceki çevrimden küçükse μ' yü arttır. Eğer hata büyüdüyse μ' yü azalt.
5. Hata, kabul edilen değerin altına düştüyse dur. Düşmediyse adım 2' e git.

5. SİNİRSEL-BULANIK ÇIKARTIM SİSTEMİ

5.1 Radyal Tabanlı Fonksiyon Ağı (RTFA)

Radyal tabanlı fonksiyon ağının (Radial-Basis Function Network) şematik resmi Şekil 5.1' de verilmiştir.



Şekil 5.1 İki giriş-tek çıkışlı 4 alıcı elemandan oluşan RTFA

Bu ağda i. alıcı elemanın etkinlik seviyesi (ya da ağırlığı) şöyledir:

$$w_i = R_i(x) = R_i(\|x - u_i\| / \sigma_i),\ \ i = 1,2,3..,H \tag{5.1}$$

$R_i(.)$ orijinde tekil bir maksimumu olan radyal tabanlı fonksiyondur. x giriş vektörü, u_i fonksiyonun merkezini ve σ_i fonksiyonun şeklini belirleyen ve x ile aynı boyutlu olan vektörler, H radyal tabanlı fonksiyon sayısını göstermektedir. Tipik olarak $R_i(.)$ bir Gauss fonksiyonu (5.2) veya lojistik fonksiyondur (5.3).

$$R_i(x) = \exp\left(-\frac{\|x - u_i\|^2}{2\sigma_i^2} \right) \tag{5.2}$$

$$R_i(x) = \frac{1}{1 + \exp\left(\|x - u_i\|^2 / \sigma_i^2 \right)} \tag{5.3}$$

Radyal tabanlı fonksiyonda ağırlığın maksimum değeri, x vektörü, o birimin merkezindeyken (u_i) elde edilir. RTFA' nin yakınsama kabiliyeti, radyal tabanlı fonksiyonun merkez (u_i) ve şeklini (σ_i) değiştirerek arttırılabilir. Bunu yapmaya yönelik literatürde çeşitli çalışmalar vardır [8]. Ayrıca her alıcı ünitenin çıkışında bir lineer fonksiyon kullanmak normal RTFA' ya göre daha iyi sonuçlar vermiştir. c_i giriş değişkeninin lineer bir fonksiyonu olmak üzere:

$$c_i = a_i x + b_i \tag{5.4}$$

şeklinde tanımlanabilir. Burada a_i bir parametre vektörü, b ise skaler bir değerdir. Bu durumda RTFA' nin çıkışı şöyledir:

$$y(x) = \sum_{i=1}^{H} c_i w_i = \sum_{i=1}^{H} c_i R_i(x) \tag{5.5}$$

5.2 Sugeno-Takagi Bulanık Çıkartım Sistemi (ST-BÇS)

Sugeno-Takagi tipi bir bulanık çıkartım sisteminde çıkışın hesaplanmasında kullanılan bulanık Eğer-İse kuralı iki giriş için şöyle yazılabilir:

$$\text{Eğer } x_1 \ A_{1i} \ ve \ x_2 \ B_{2j} \ ise \ f_k = p_k x_1 + q_k x_2 + r_k \tag{5.6}$$

$$(i=1,2,\ldots,n \ \ j=1,2,\ldots,m \ \ k=1,2,\ldots n.m)$$

Burada x_1 ve x_2 girişler, A_{1i} ve B_{1j} bulanık üyelik fonksiyonları, n ve m sırasıyla 1. ve 2. girişin üyelik fonksiyonu sayısı, ve p_k, q_k ve r_k de skaler parametrelerdir.

5.3 Uyarlanabilir Sinirsel-Bulanık Çıkartım Sistemi (USBÇS)

Uyarlanabilir Sinirsel-Bulanık Çıkartım Sistemi, radyal tabanlı fonksiyon ağı kullanarak Sugeno-Takagi tipi bir bulanık sistemin oluşturulması ve ince ayarının yapılması temeline dayanır. Matematiksel olarak USBÇS' nin lineer olmayan fonksiyonlar da dahil olmak üzere sınırsız yakınsama gücü olduğu gösterilmiştir [8]. Bu nedenle USBÇS, örüntü tanıma (pattern recognition), robotik, lineer olmayan regresyon ve lineer olmayan sistem tanılama gibi birçok alana uygulanabilmektedir.

USBÇS' nin temelinde RTFA ile ST-BÇS arasındaki fonksiyonel eşitlik vardır. Bu eşitlik şu terimlerden oluşur:

- Her ikisi de çıkışı hesaplamak için ağırlıklı ortalama kullanır.
- RTFA' da toplam alıcı ünite sayısı bulanık çıkartım sistemindeki bulanık eğer-ise kurallarının sayısına eşittir.
- Radyal tabanlı fonksiyon, bulanık çıkartım sistemindeki Gauss üyelik fonksiyonuyla aynı parametrelere sahiptir.
- ST-BÇS ile RTFA da kullanılan lineer denklemler eşit yapıdadır.

Her girişi temsil eden bulanık üyelik fonksiyonlarının sayısına bağlı olarak çıkış fonksiyonunun parametrelerini hesaplamak uzun zaman alabilir. RTFA ile ST-BÇS arasında bahsedilen fonksiyonel eşitlikten dolayı giriş-çıkış verisi üyelik fonksiyonlarının şekil ve merkezleri ayarlanmış bir ST-BÇS elde etmek için kullanılabilir. İki giriş-bir çıkışlı ve her giriş için iki üyelik fonksiyonuna sahip bir USBÇS modeli Şekil 5.2' de verilmiştir [25].

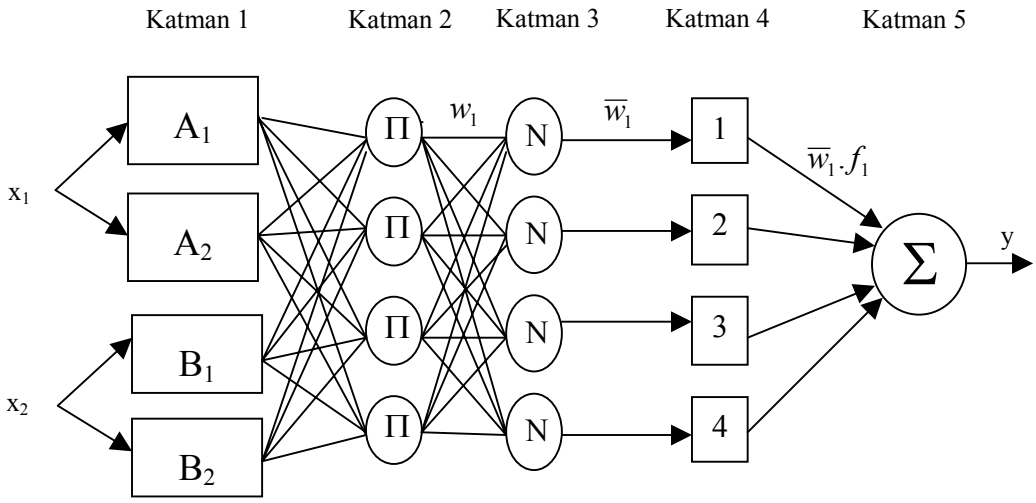
Bu yapıda bulanık eğer-ise kuralları şöyledir:

Kural 1: Eğer x_1 A_1 ve x_2 B_1 ise $f_1 = (p_1 x_1 + q_1 x_2 + r_1)$

Kural 2: Eğer x_1 A_2 ve x_2 B_1 ise $f_2 = (p_2 x_1 + q_2 x_2 + r_2)$

Kural 3: Eğer x_1 A_1 ve x_2 B_2 ise $f_3 = (p_3 x_1 + q_3 x_2 + r_3)$

Kural 4: Eğer x_1 A_2 ve x_2 B_2 ise $f_4 = (p_4 x_1 + q_4 x_2 + r_4)$



Şekil 5.2 Her girişe iki üyelik fonksiyonu olan 2 girişli 4 bulanık kurallı USBÇS

Birinci katmanda girişleri temsil eden üyelik fonksiyonları vardır. Üyelik fonksiyonu uygun herhangi bir fonksiyon olabilir. Genelleştirilmiş çan fonksiyonu (5.7) sık kullanılır.

$$\mu_{in_j,mf_i} = \frac{1}{1+\left|\frac{x-c_i}{a_i}\right|^{2b_i}} \tag{5.7}$$

Üyelik fonksiyonunun şeklini ve yerini belirleyen üç parametre vardır. Dolayısıyla her üyelik fonksiyonu için $\{a_i, b_i, c_i\}$ parametre seti hesaplanmaktadır. Bu parametrelere öncül (premise) parametreler denir.

İkinci katmanda, düğümün çıkışı; düğüme giren üyelik fonksiyonlarının çarpımı ile elde edilir. Her düğümün çıkışı ilgili bulanık kuralın ağırlığını belirler (5.8).

$$w_i = \mu_{A_i}(x).\mu_{B_i}(x) \tag{5.8}$$

Üçüncü katmanda, her düğüm i. ağırlığın toplam ağırlığa oranını hesaplar (5.9).

$$\overline{w}_i = \frac{w_1}{\sum w_i} \tag{5.9}$$

Dördüncü katmanda, üçüncü katmanda hesaplanan ağırlık oranları kuralda belirtilen lineer fonksiyonla çarpılır (5.10).

$$\overline{w}_i f_k = \overline{w}_i.(p_k x_i + q_k y + r_k) \tag{5.10}$$

Bu katmanda kullanılan $\{p_k, q_k, r_k\}$ parametrelerine ardıl (consequent) parametreler denir. Son katmanda ise dördüncü katmanda üretilen ağırlıklı fonksiyonların çıkışları toplanır ve çıkış üretilir.

6. ÇİMENTO ENDÜSTRİSİNDE HARMANLAMA PROSESİNİN DOĞRUSAL PARAMETRİK YÖNTEMLE MODELLENMESİ

Harmanlama prosesinde temel olarak girişlerin oranları, harmanın içeriğindeki dört oksidin yüzdeleri ve oksit oranları kullanılarak elde edilen standartlar (modüller) sistemden elde edilen verileri oluşturmaktadır. Sistemin modeli olarak önerilen iki ayrı model şöyledir [12]:

Model 1: u_1: düşük mal, u_2: demir cevheri, y_1: demir oksit

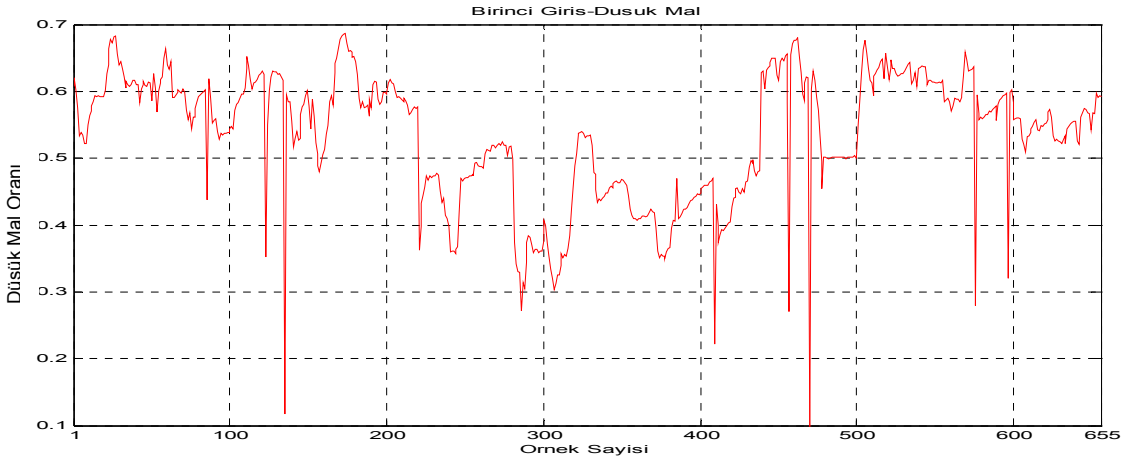
Model 2: u_1: düşük mal, u_2: demir cevheri, y_1: kireç standardı (ML)

Modellerde u girişleri, y ise çıkışları göstermektedir. Bu modellerden her ikisi de iki giriş- bir çıkışlı (MISO) sistem modelidir. [12]' de iki giriş iki çıkışlı bir sistem modeli de önerilmektedir. Bu modelde, sistemin girişleri yukarıdakilerle aynı, çıkışları ise her iki modelde ayrı ayrı elde edilen çıkışlardır. Bu çalışmada MIMO model üzerinde durulmamıştır. Bunun en temel sebebi, uyarlanabilir sinirsel-bulanık çıkartım sisteminin (USBÇS) çoklu çıkışa uygun olmamasıdır. Ayrıca, MISO sisteminin daha az karmaşık olmasından dolayı, iki giriş-iki çıkışlı bir sistem yerine paralel çalışan, iki giriş-bir çıkışlı iki sistem tercih edilmiştir.

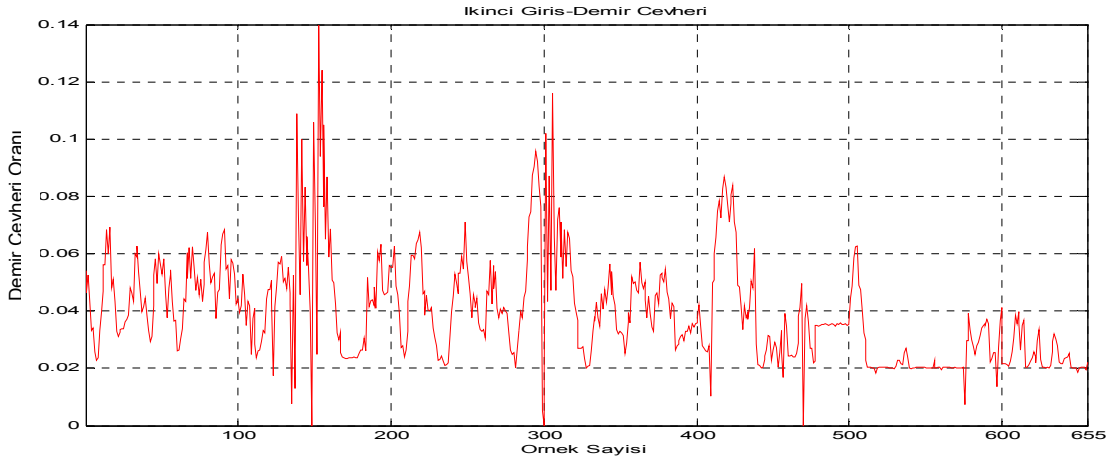
6.1 Giriş İşaretinin Analizi ve Sinyal Şartlandırma

6.1.1 Verinin DC Bileşenlerinin Yok Edilmesi ve Ölçeklendirme

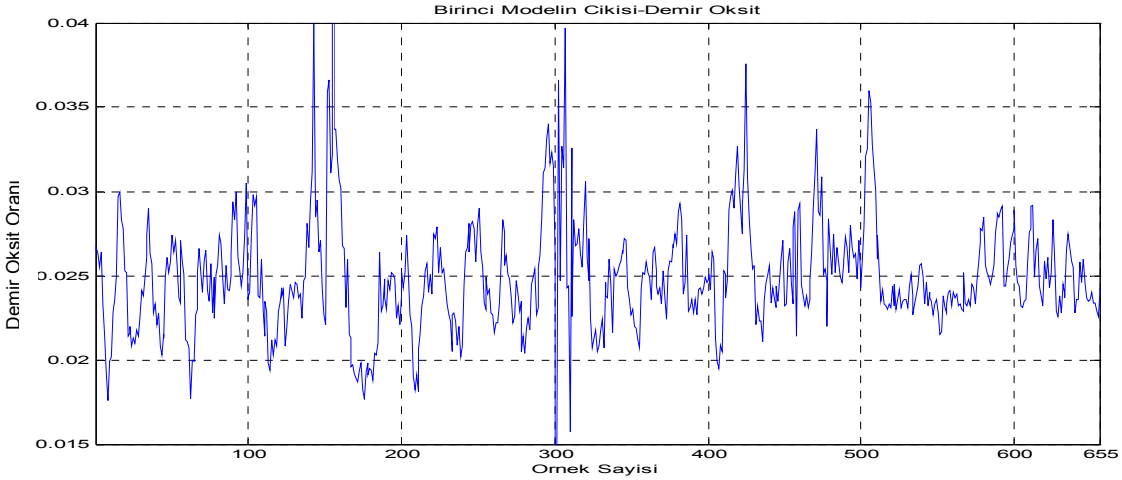
Sistem tanıma için kullanılacak olan giriş ve çıkış verilerinin DC bileşenlerinden arındırılması ve ölçeklendirilmesi için MINITAB® istatistik paket programı kullanılmıştır. Ham veri olarak adlandırılabilecek prosesten ölçülen değerler Şekil 6.1-6.4' de verilmiştir. Veri seti 655 örnekten oluşmaktadır.



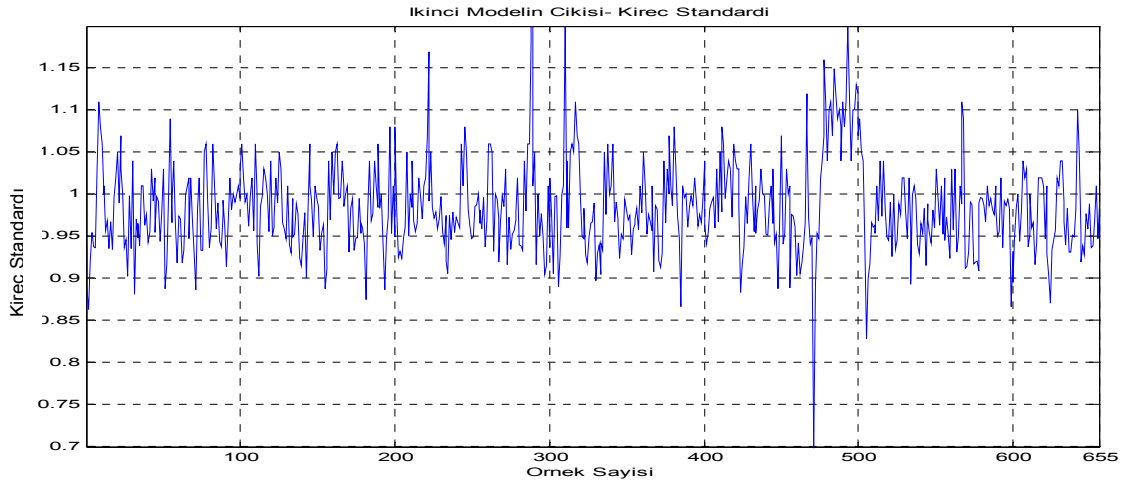
Şekil 6.1 Birinci giriş; Düşük Mal



Şekil 6.2 İkinci giriş; Demir Cevheri



Şekil 6.3 Birinci modelin çıkışı; Demir Oksit



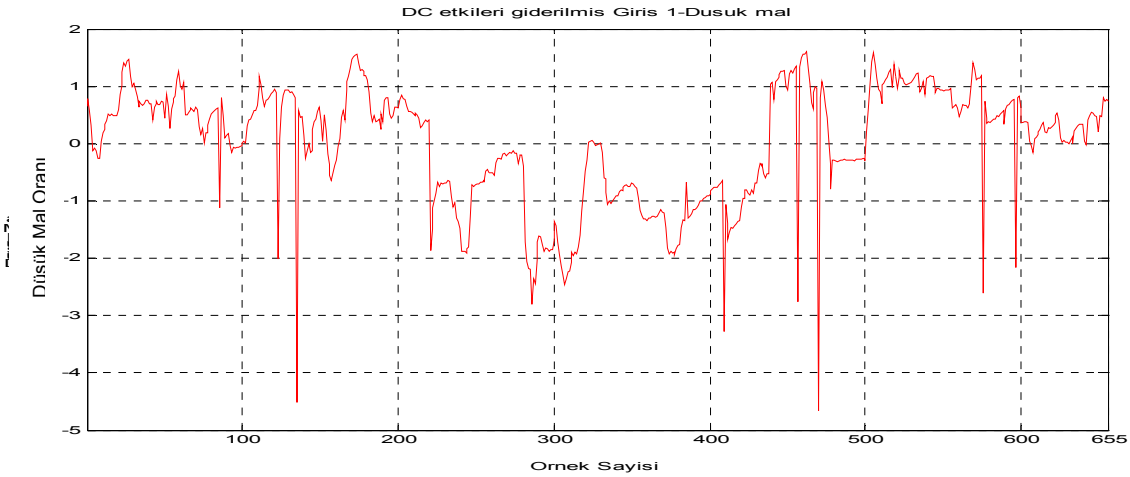
Şekil 6.4 İkinci modelin çıkışı; Kireç Standardı (ML)

Giriş ve çıkış verilerinin tanımlayıcı istatistiksel özellikleri Tablo 6.1' de verilmiştir.

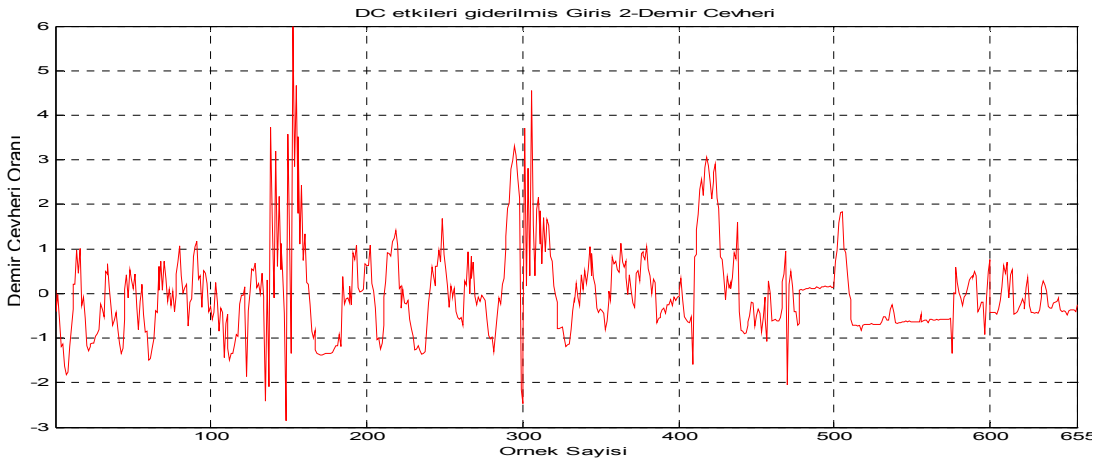
Tablo 6.1 Verilerin tanımlayıcı istatistiksel özellikleri

	Giriş 1	**Giriş 2**	**Çıkış 1**	**Çıkış 2**
Ortalama	0.53406	0.03972	0.02492	0.98466
Standart sapma	0.09433	0.01825	0.00330	0.05456
Minimum	0.09030	0.0	0.0149	0.6610
Maksimum	0.687	0.146	0.04070	1.2100

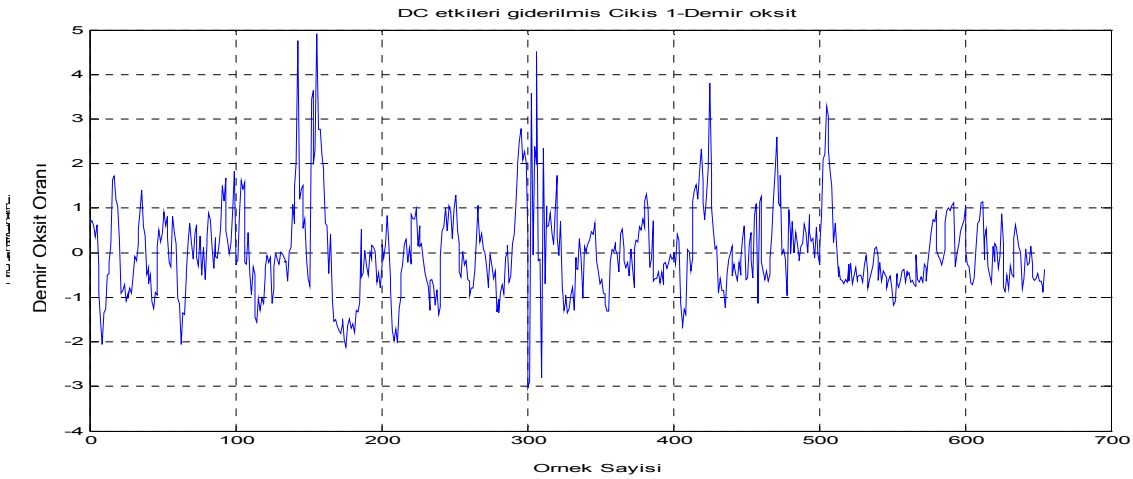
Görüldüğü gibi, verinin ortalamaları sıfırdan farklıdır. Ayrıca sayısal büyüklükleri de farklıdır. Ölçeklendirme için her veri sütunu kendi varyansına bölünmüştür. Böylece sıfır ortalamalı, standart sapması 1.0 olan veri seti elde edilmiştir. Birçok fiziksel yapıda olduğu gibi bu proses için de sistem giriş-çıkış verisi normal dağılımlıdır. Sistemin dinamik karakteristiğinden dolayı (çıkışın geçmiş giriş ve çıkış değerlerine bağlı olmasından dolayı), ortalamadan aşırı sapma yapan (3 standart sapmadan fazla) veriler (outliers) veri kümesinden çıkarılmamıştır. DC etkileri giderilen ve ölçeklendirilen veriler Şekil 6.5-6.8' de verilmiştir.



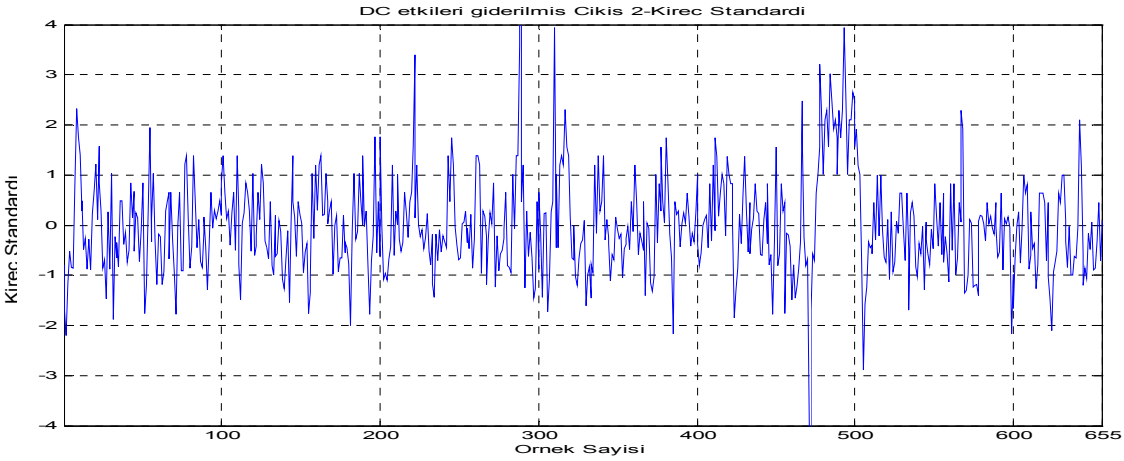
Şekil 6.5 DC etkileri giderilmiş ve ölçeklendirilmiş birinci giriş verisi



Şekil 6.6 DC etkileri giderilmiş ve ölçeklendirilmiş ikinci giriş verisi



Şekil 6.7 DC etkileri giderilmiş ve ölçeklendirilmiş birinci çıkış verisi



Şekil 6.8 DC etkileri giderilmiş ve ölçeklendirilmiş ikinci çıkış verisi

6.1.2 Giriş İşaretlerinin Kovaryans Fonksiyonu ve Sürekli Uyarma Mertebesi

Giriş işaretlerinin sistemin dinamiklerini yeterince uyarabildiğine karar verebilmek için verinin sürekli uyarma mertebesine bakılır. Her iki giriş verisi de yüksek mertebeye kadar sürekli uyaran bulunmuştur. Giriş 1 ve Giriş 2 için 40 mertebeye kadar kovaryans matrislerine bakılmıştır. Kovaryans matrisleri devamlı pozitif tanımlıdır. Dolayısıyla giriş sinyali sistemin dinamiklerini uyarabilecek kapasitededir. Giriş işaretinin kovaryans fonksiyonu sinyalin geçmiş değerlerinden tamamen bağımsız olmadığını göstermektedir. Bunun sebebi sistemdeki geri beslemedir.

6.2 Harmanlama Prosesinin ARX Yapısında Modellenmesi

Model mertebesinin seçimi ve model geçerliliğinin incelenmesi her üç model için aşağıda verilmiştir. Sistem tanılama işlemi için MATLAB Sistem Tanılama Araç Kutusu kullanılmıştır. 655 verinin 605 tanesi sistem tanılamada kullanılmış, son 50 tanesi ise sınama verisi olarak ayrılmıştır. Sistemin giriş, çıkış ve girişlerin gecikmesi mertebelerini belirlemek için çeşitli kombinasyonlar denenmiştir. Her model yapısı için; modelin uyumu (yüzde), kutup-sıfır iptali, hatanın otokorelasyonu, hatanın girişlerle çapraz korelasyonu incelenmiştir. Eğer kutup-sıfır iptali söz konusu ise, modelin mertebesi düşürülmüştür. Modelin % 97 güven aralığı için otokorelasyon testi ve çapraz korelasyon testi başarılı değilse model elenmiştir. Geriye kalan

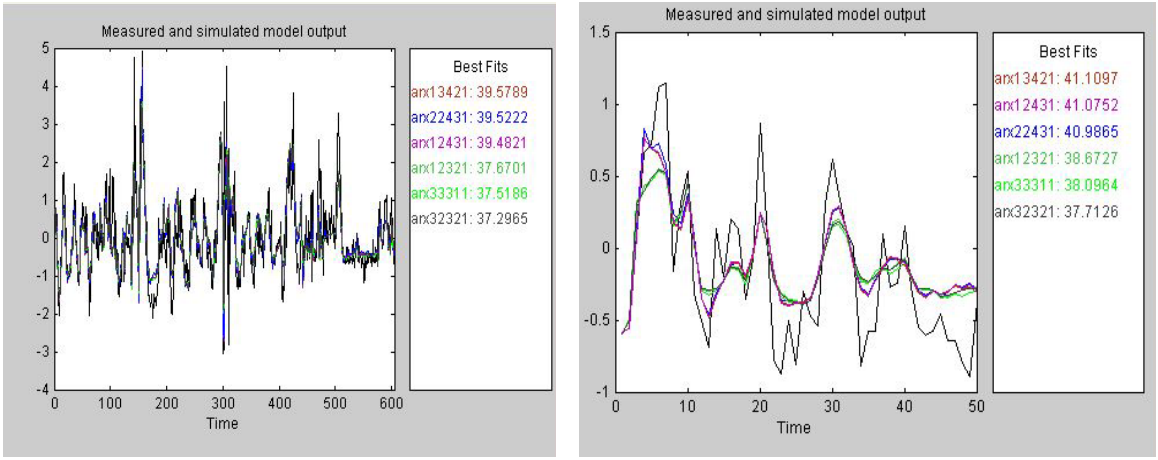
modellerden tanıma verisi ve sınama verisi için en yüksek uyumu veren model seçilmiştir.

ARX model gösterimi denklem (3.4), (3.5) ve (3.6)' da verilmişti. Aşağıda kullanılan modellerin isimleri model yapısı hakkında bilgi vermektedir. Model ismindeki numaralandırma; çıkış bilgileri, giriş bilgileri ve girişin gecikme bilgileri şeklinde sıralanmıştır. Mesela, iki giriş-bir çıkışlı bir ARX model için modele verilen 'arx22431' ismi çıkışın mertebesinin (nA) 2, birinci girişin mertebesinin (nB_1) 2, ikinci girişin mertebesinin (nB_2) 4, birinci girişin gecikmesinin (d_1) 3, ikinci girişin gecikmesinin (d_2) 1 olduğunu gösterir.

6.2.1 Model 1' in ARX Model Parametrelerinin Kestirimi

Model 1: u_1: düşük mal, u_2: demir cevheri, y_1: demir oksit

Model 1 için seçilen modellerin tanılama ve sınama verisi için çıkışları ve uyumları Şekil 6.9' da verilmiştir.



Şekil 6.9 Model 1 için değişik ARX model yapıları

Elde edilen 6 uygun modelden otokorelasyon testinde en iyi model 'arx22431' olarak belirlenmiştir. Model uyumu açısından bu modelden daha iyi bir model olmakla beraber, modelin geçerliliği daha önemli olduğundan bu model seçilmiştir. Bu durumda Model 1 için ARX model yapısı aşağıdaki gibidir. e(t) sisteme t anında eklenen rastgele bozucuyu q ise zaman gecikmesini temsil etmektedir. q' nun üssü zamanın kaç örnekleme periyodu geciktirildiğini gösterir.

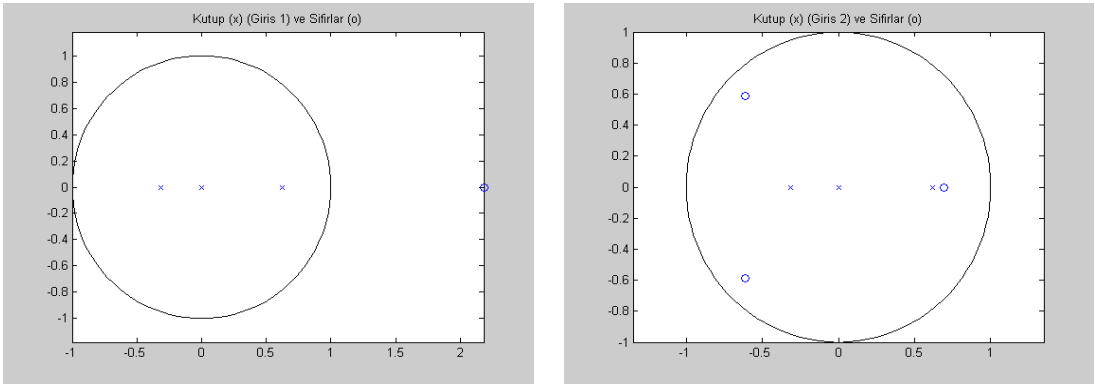
$$A(q)y(t) = B_1(q)u_1(t)\ B_2(q)u_2(t) + e(t) \quad (6.1)$$

$$A(q) = 1 - 0.3049\ q^{-1} - 0.1957\ q^{-2} \quad (6.2)$$

$$B_1(q) = -0.06418\ q^{-3} + 0.14\ q^{-4} \quad (6.3)$$

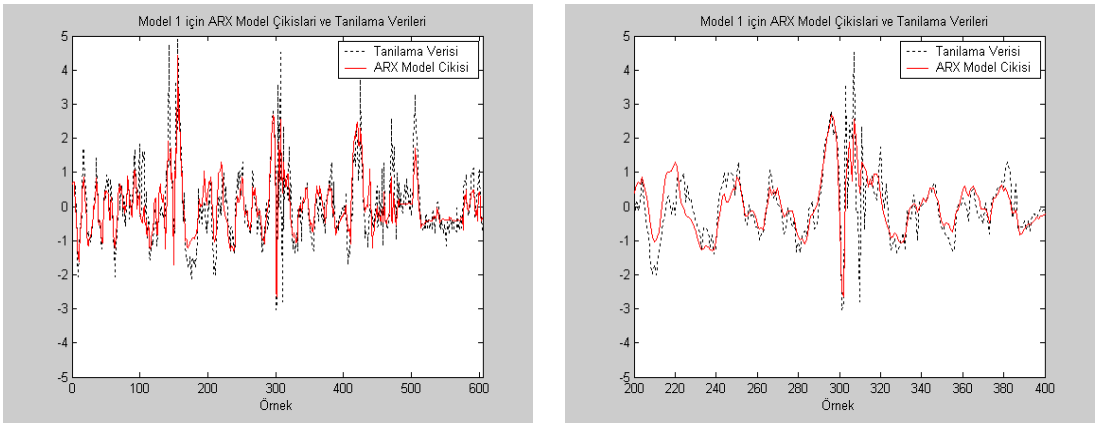
$$B_2(q) = 0.4813\ q^{-1} + 0.2565\ q^{-2} - 0.06316\ q^{-3} - 0.2415\ q^{-4} \quad (6.4)$$

Seçilen modelin her iki giriş için kutup-sıfır yerleri Şekil 6.10' de verilmiştir.



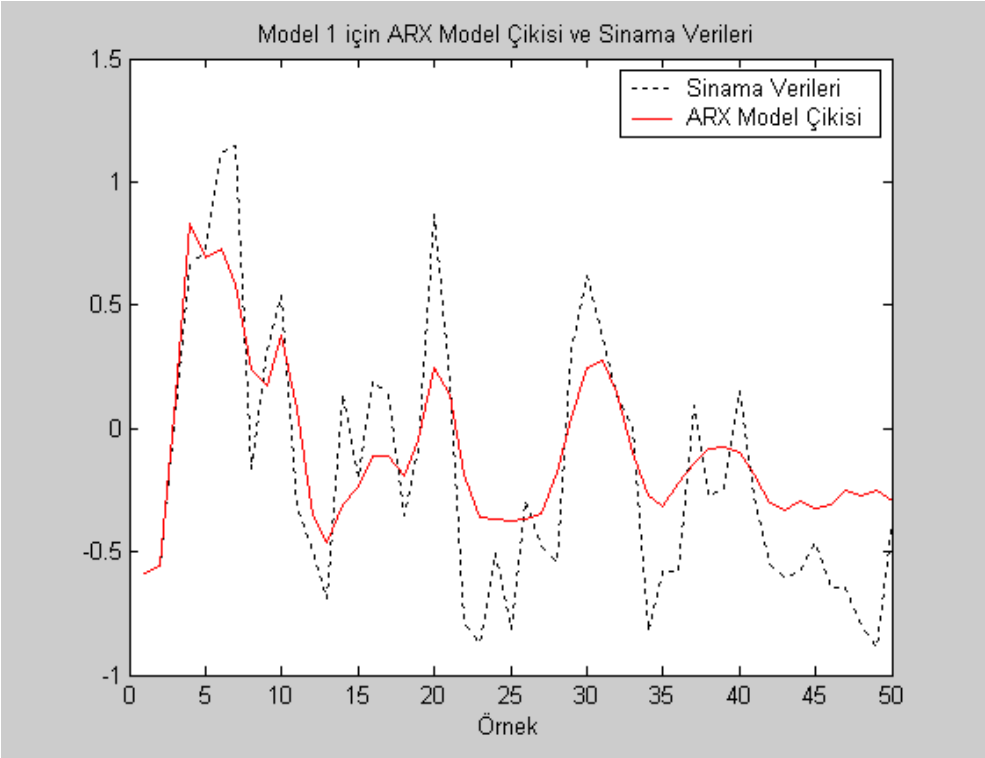
Şekil 6.10 Model 1 için seçilen ARX modelin kutup-sıfır yerleri

Seçilen modelin ürettiği çıkışların tanılama verisi ile karşılaştırılması Şekil 6.11' da verilmektedir. Şeklin sağ tarafındaki grafikte aynı kümenin 200 ile 400. örnekleri arasındaki 200 veri için büyültülmüş şekli görülmektedir .



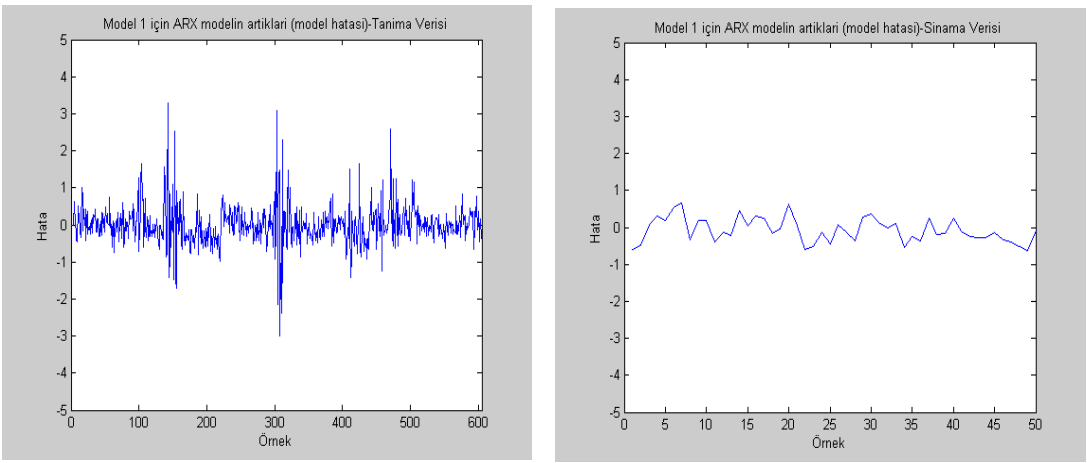
Şekil 6.11 Model 1 için ARX modelin tanılama verisi ile karşılaştırılması

Seçilen modelin çıkışların sınama verisi (son 50 örnek) ile karşılaştırılması Şekil 6.12' da verilmektedir.



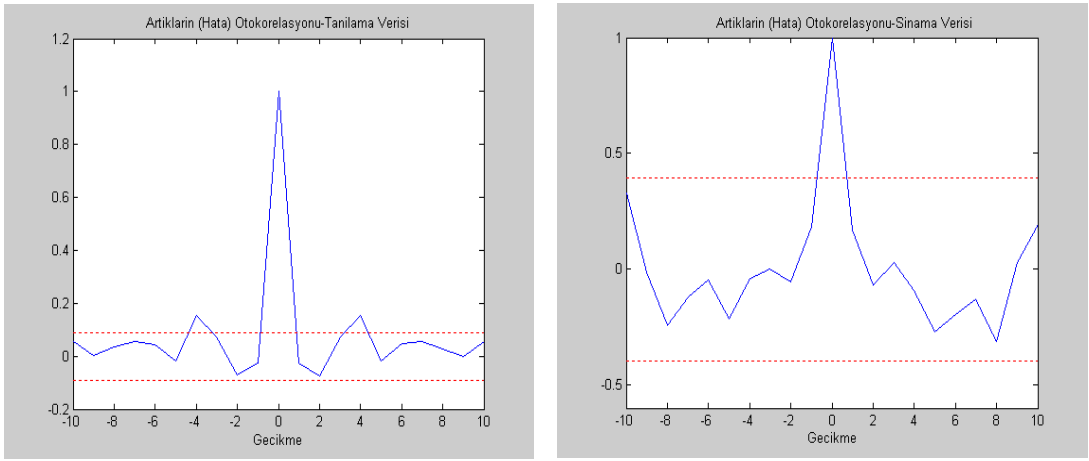
Şekil 6.12 Model 1 için ARX modelin sınama verisi ile karşılaştırılması

Model 1 için bulunan ARX modelin artıkları (model hatası) tanılama ve sınama kümeleri için Şekil 6.13' da verilmektedir.



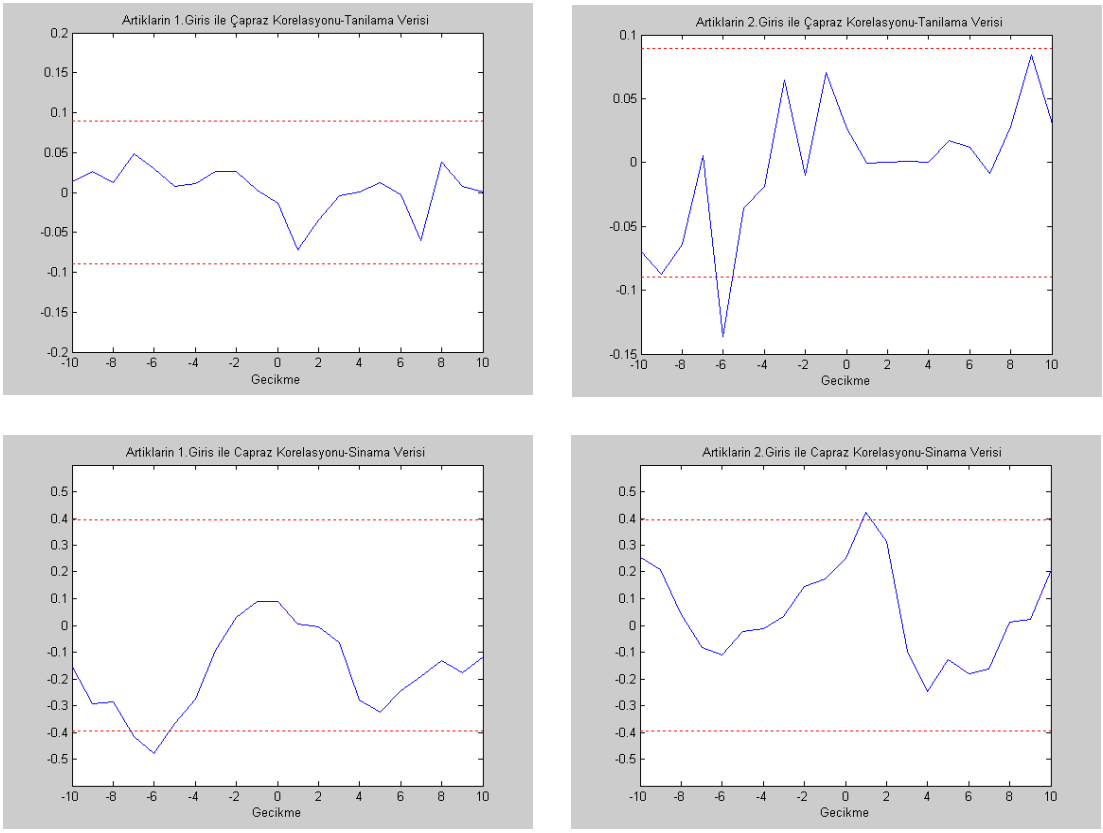
Şekil 6.13 Model 1 için ARX modelin tanılama ve sınama kümeleri için artıkları

Tanılama verisi ve sınama verisi için artıkların (hatanın) % 97 güven aralığında otokorelasyon grafiği 10 gecikme için Şekil 6.14' da verilmektedir.



Şekil 6.14 Model 1 için ARX model artıklarının otokorelasyonu

Tanılama verisi ve sınama verisi için artıkların (hatanın) her iki girişle çapraz korelasyonu grafiği 10 gecikme için Şekil 6.15' da verilmiştir.



Şekil 6.15 Model 1 için ARX model artıklarının girişlerle çapraz korelasyonu

Model artıklarının tanılama ve sınama kümeleri için otokorelasyon grafiğinden görüldüğü gibi, model hatalarının otokorelasyonu % 97 güven aralığının dışına pek taşmamaktadır. Eğer bu aralığın dışına ciddi anlamda çıkılırsa otokorelasyon derecesi istatistiksel olarak anlamlı (significant) sayılır ki, bu hatanın geçmiş değerleriyle ilgisi olduğuna işarettir. Sistem tanılamada, bulunan bir modelin artıklarının geçmiş değerleriyle bağlantılı olması istenmez. Bu durumun varlığı modelin geçerli bir model olmadığı anlamına gelir.

Çapraz korelasyon grafiklerinde pozitif gecikmeler için olan kısımda güven aralığı fazlaca aşılmamaktadır. Negatif gecikmeler için güven aralığının aşılması sistemde geri besleme olduğunun bir göstergesidir. Daha önce bahsedildiği gibi, kapalı çevrim sistemlerin sistem tanılamasında negatif gecikmeler için çapraz korelasyon derecesinin istatistiksel olarak anlamlı olması modelin geçersiz sayılmasını gerektirmez [2]. Her iki korelasyon grafiğinin incelenmesinden sonra görülen odur ki, bu sistem için bulunan ARX modeli geçerli bir modeldir.

Model 1 için bulunan ARX modelin, incelenen diğer modelleme yöntemleri ile karşılaştırılması için bu modele ait hataların karesel ortalaması (HKO) hesaplanmıştır. HKO şu şekilde hesaplanmaktadır (6.5):

$$HKO = \frac{1}{N}\sum_{t=1}^{N}(y(t) - \hat{y}(t))^2 \tag{6.5}$$

Burada, N veri sayısını, *y(t)* sistemin t anındaki çıkışını, $\hat{y}(t)$ modelin t anındaki çıkışını göstermektedir.

Model 1 için ARX modelin verdiği hatalar, tanıma ve sınama veri grupları için HKO cinsinden Tablo 6.2' de verilmiştir.

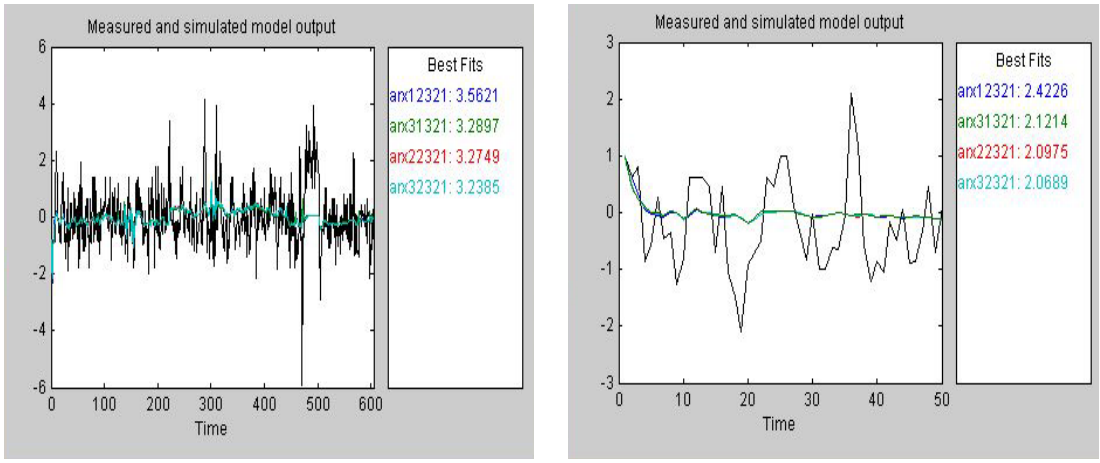
Tablo 6.2 Model 1 için ARX modelin hataları

	Tanılama Verisi	**Sınama Verisi**
HKO	0,3899	0,1142

6.2.2 Model 2' nin ARX Model Parametrelerinin Kestirimi

Model 2: u_1: düşük mal, u_2: demir cevheri, y_1: kireç standardı (ML)

Model 2 için seçilen modellerin tanılama ve sınama verisi için çıkışları ve uyumları Şekil 6.16' da verilmiştir.



Şekil 6.16 Model 2 için değişik ARX model yapıları

Model 2 için denenen birçok model yapısından ancak 4 tanesi kutup-sıfır iptali söz konusu olmadan yapılandırılabilmiştir. Ne var ki, elde edilen modellerin hiçbirinin sistemi tatminkar bir şekilde temsil edebileceğini söylemek mümkün değildir. Açıkça görülmektedir ki Model 2 için lineer modelleme yeterli olmamaktadır. Ancak yine de karşılaştırma maksadıyla, elde edilen 4 uygun modelden en iyi uyumu sağlayan ve otokorelasyon testinde başarılı olan 'arx12321' modeli Model 2' nin lineer modeli olarak belirlenmiştir. Bu durumda Model 2 için ARX model yapısı aşağıdaki gibidir.

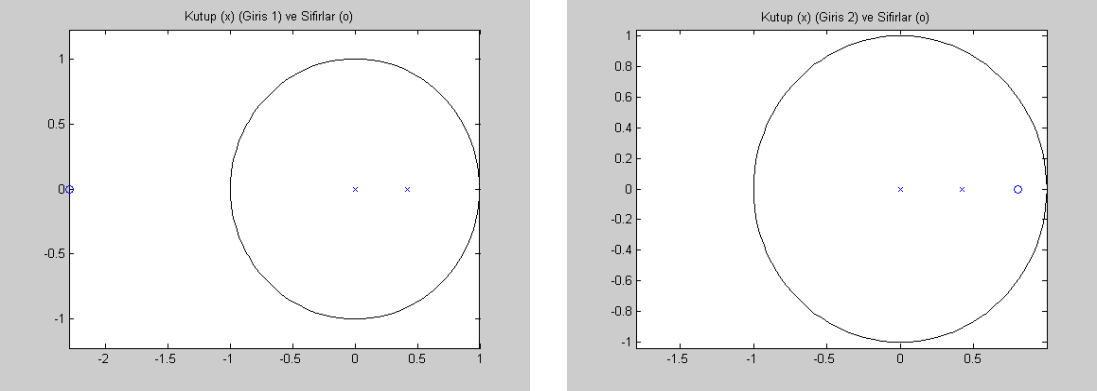
$$A(q)y(t) = B_1(q)u_1(t)\ B_2(q)u_2(t) + e(t) \tag{6.6}$$

$$A(q) = 1 - 0.4208\ q^{-1} \tag{6.7}$$

$$B_1(q) = -0.0455\ q^{-2} - 0.1044\ q^{-3} \tag{6.8}$$

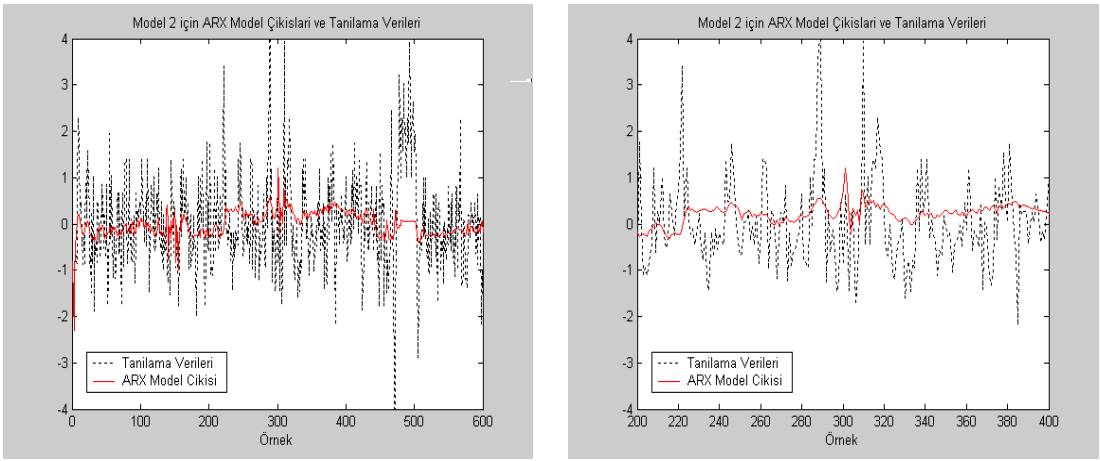
$$B_2(q) = -0.07935\ q^{-1} - 0.07896\ q^{-2} + 0.1152\ q^{-3} \tag{6.9}$$

Seçilen modelin her iki giriş için kutup-sıfır yerleri Şekil 6.17' de verilmiştir.



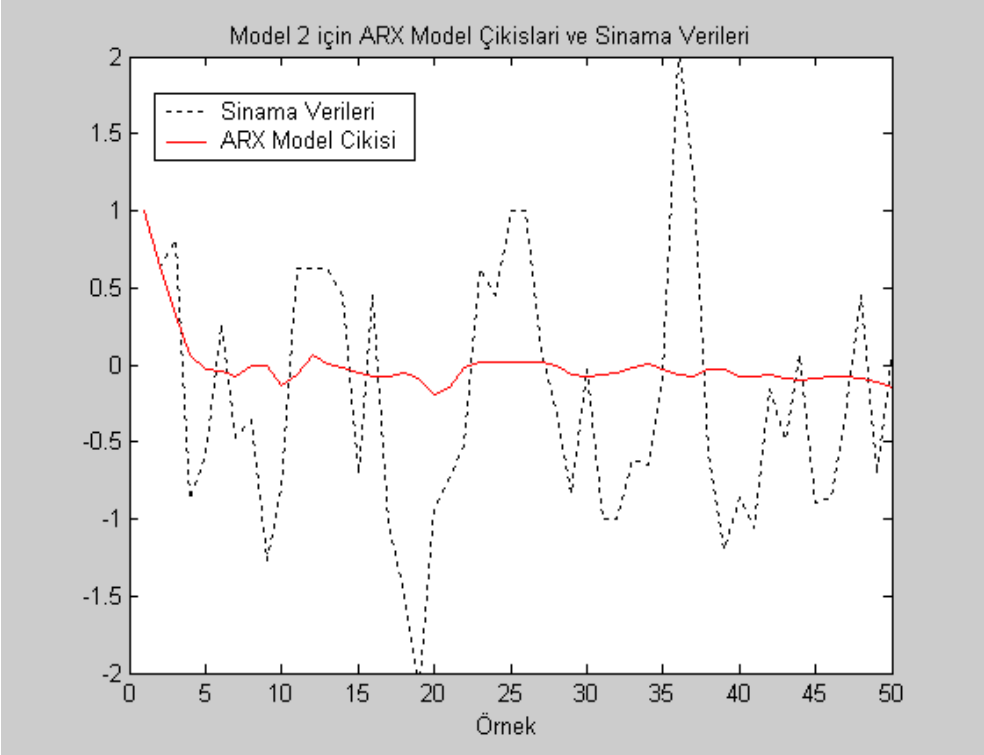
Şekil 6.17 Model 2 için seçilen ARX modelin kutup-sıfır yerleri

Seçilen modelin ürettiği çıkışların tanılama verisi ile karşılaştırılması Şekil 6.18' da verilmektedir. Şeklin sağ tarafındaki grafikte aynı kümenin 200 ile 400. örnekleri arasındaki 200 veri için büyültülmüş şekli görülmektedir .



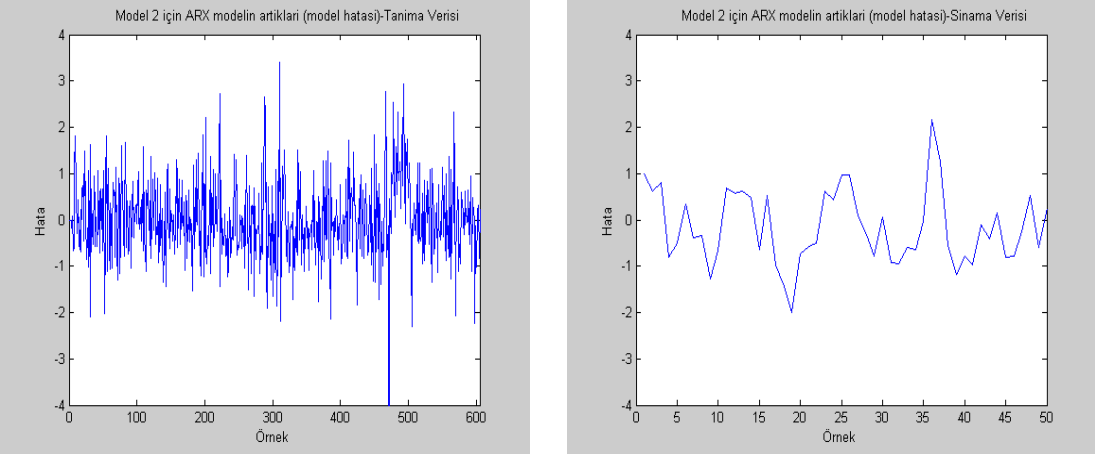
Şekil 6.18 Model 2 için ARX modelin tanılama verisi ile karşılaştırılması

Seçilen modelin çıkışların sınama verisi ile karşılaştırılması Şekil 6.19' da verilmektedir.



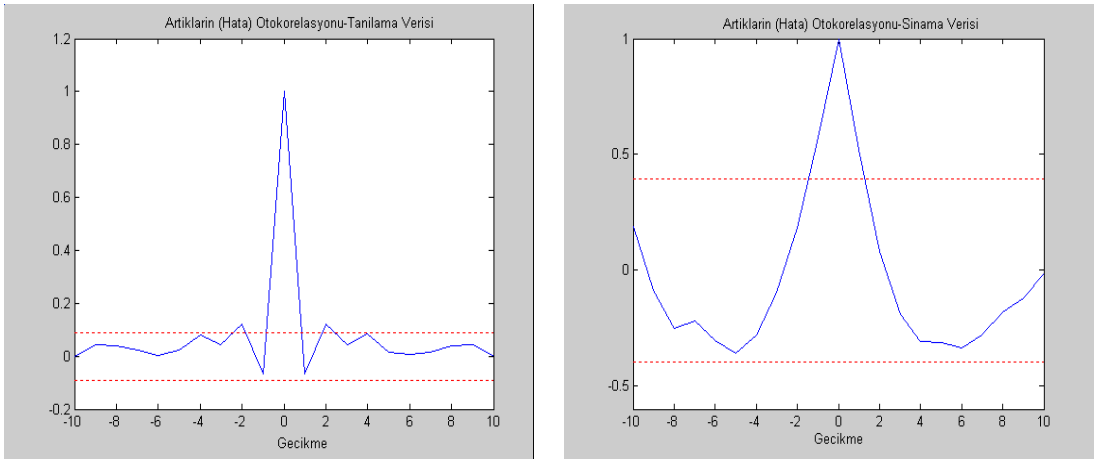
Şekil 6.19 Model 2 için ARX modelin sınama verisi ile karşılaştırılması

Model 2 için bulunan ARX modelin artıkları (model hatası) tanılama ve sınama kümeleri için Şekil 6.20' de verilmektedir.



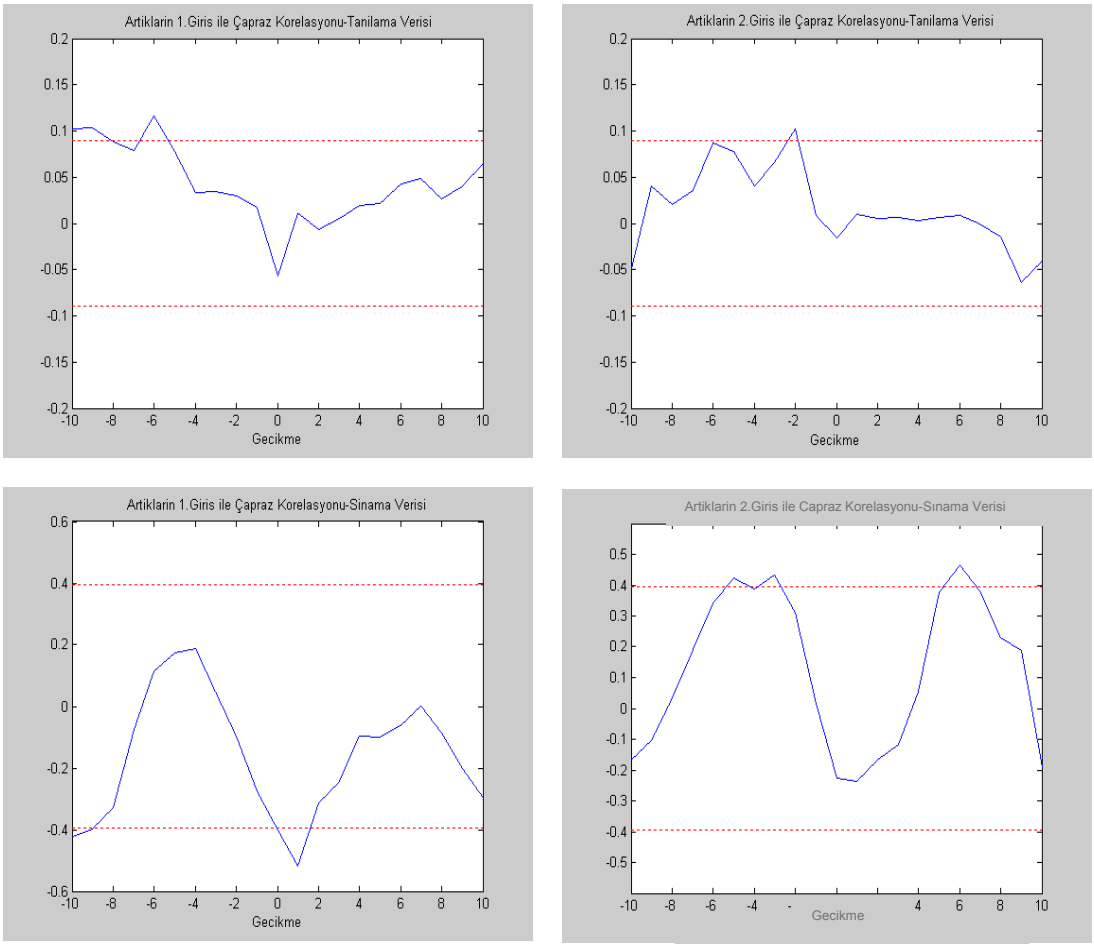
Şekil 6.20 Model 2 için ARX modelin tanılama ve sınama kümeleri için artıkları

Tanılama verisi ve sınama verisi için artıkların (hatanın) % 97 güven aralığında otokorelasyon grafiği 10 gecikme için Şekil 6.21' da verilmiştir.



Şekil 6.21 Model 2 için ARX model artıklarının otokorelasyonu

Tanılama verisi ve sınama verisi için artıkların (hatanın) her iki girişle çapraz korelasyonu grafiği 10 gecikme için Şekil 6.22' da verilmiştir.



Şekil 6.22 Model 2 için ARX model artıklarının girişlerle çapraz korelasyonu

Model 2 için seçilen ARX modelin otokorelasyon grafikleri bazı gecikme değerleri için modelin artıklarının geçmiş değerleriyle ilişkisinin olduğunu göstermektedir. Ayrıca modelin çapraz korelasyon grafiklerinde (pozitif kısım) artıkların özellikle ikinci girişle ilişkili (correlated) olduğu görülmektedir. Modelin grafiksel performansının da düşük olduğu göz önünde bulundurularak, Model 2 için ARX gibi lineer sistem tanıma yöntemiyle bulunabilecek en iyi modelin bile geçerliliğinin tartışılır olduğu sonucuna varılmaktadır. Bu durumda Model 2' nin lineer olmayan sistem tanıma yöntemleriyle tanılanması gerektiği görülmektedir.

Model 2 için ARX modelin verdiği hatalar, tanıma ve sınama veri grupları için HKO cinsinden Tablo 6.3' de verilmiştir.

Tablo 6.3 Model 2 için ARX modelin hataları

	Tanılama Verisi	**Sınama Verisi**
HKO	0,9669	0,6606

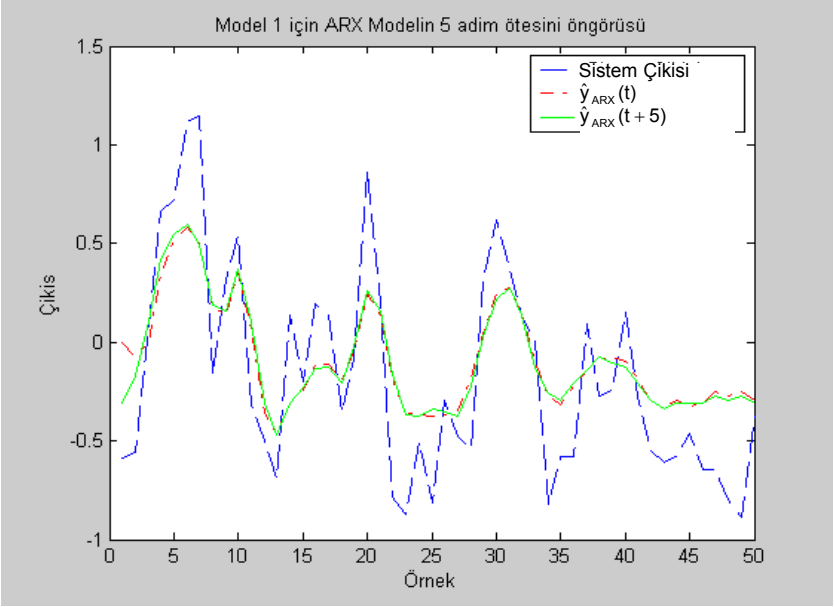
6.3 ARX Modellerin Öngörü Kapasiteleri

Modellerin öngörü (prediction) kapasitelerinin/yeteneklerinin incelenmesi, modelin, gelecekte kullanılabileceği öngörülü kontrol algoritmalarındaki başarımı açısından önemlidir. Modelin öngörü yeteneği araştırılırken ilk yapılacak şey bir öngörü ufku seçmektir. Model verilen bir giriş-çıkış veri seti ve seçilen bir öngörü ufku için test edilir. Model, sistemin k adım ötedeki çıkışını öngörmek için (t-k) anında çıkışı gerçek sistemden alır. Bu adımdan sonra model kendi ürettiği çıkışları ARX modelin iteratif döngüsünde kullanır. Elbette modelin kullandığı girişler gerçek sistemin girişleridir. İyi bir modelden beklenen, modelin çıkışının sistem çıkışını en az hata ile takip edebilmesidir. Ancak unutulmamalıdır ki, modelin öngördüğü değerler ancak modelin sistemi temsil edebildiği kadar kaliteli olacaktır.

6.3.1 Model 1' in ARX Modelinin 5 Adım Ötesini Öngörüsü

Model 1' in öngörü yeteneğini incelemek için modele sistemin bütün giriş-çıkış verisi girilmiştir. MATLAB' in 'predict' fonksiyonu kullanılarak öngörülmüş çıkış

elde edilmiştir. Son 50 veri için sistemin çıkışı, modelin öngörüsüz çıkış ($\hat{y}_{ARX}(t)$) ve öngörülü çıkışı ($\hat{y}_{ARX}(t+5)$) Şekil 6.23' de verilmiştir.



Şekil 6.23 Model 1 için ARX modelin öngörüsüz ve öngörülü çıkışı

Model 1 için ARX modelin öngördüğü çıkışlar ile sistem çıkışları arasındaki hata, tanıma ve sınama veri grupları için HKO cinsinden Tablo 6.4' de verilmiştir.

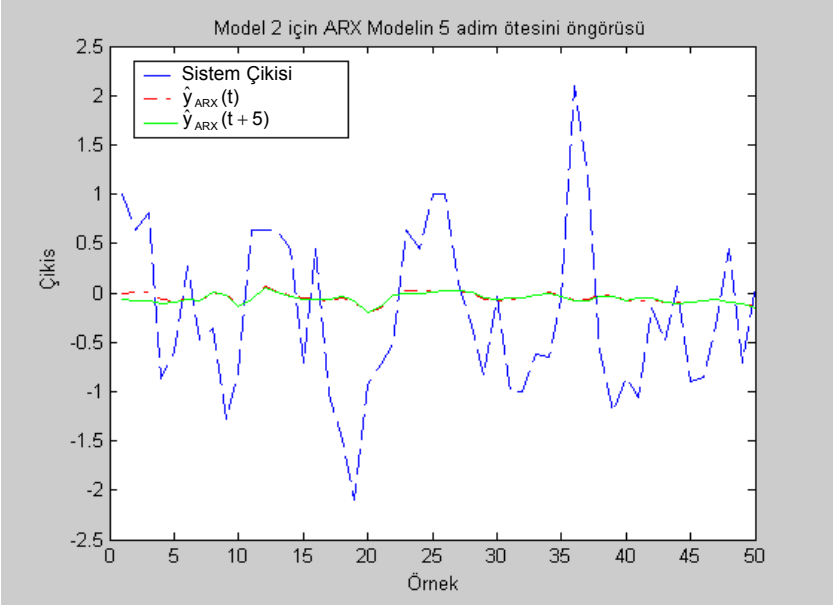
Tablo 6.4 Model 1 için ARX modelin öngörü hataları

	Tanılama Verisi	**Sınama Verisi**
HKO	0,3777	0,1069

Grafiksel olarak bakıldığında ise modelin öngörülü ve öngörüsüz çıkışı arasında büyük bir fark görülmemektedir. Bu durumdan yola çıkarak sistem modeli olarak kullanılabilecek bu ARX modelin sistem çıkışlarını öngörü için de kullanılabileceği sonucuna varılmaktadır.

6.3.2 Model 2' nin ARX Modelinin 5 Adım Ötesini Öngörüsü

Model 2 'nin son 50 verisi için sistemin çıkışı, modelin öngörüsüz çıkış ($\hat{y}_{ARX}(t)$) ve öngörülü çıkışı ($\hat{y}_{ARX}(t+5)$) Şekil 6.24' de verilmiştir.



Şekil 6.24 Model 2 için ARX modelin öngörüsüz ve öngörülü çıkışı

Model 2 için ARX modelin öngördüğü çıkışlar ile sistem çıkışları arasındaki hata, tanıma ve sınama veri grupları için HKO cinsinden Tablo 6.5' de verilmiştir.

Tablo 6.5 Model 2 için ARX modelin öngörü hataları

	Tanılama Verisi	**Sınama Verisi**
HKO	0,9484	0,6715

Model 2 için ARX modelde tanılama verisi için öngörü hatalarının öngörüsüz model çıkışlarına göre daha az hata verdiği görülmektedir. Ancak sınama verisi için öngörü hatası öngörüsüz çıkışın hatasına göre artmıştır. Ayrıca modelin grafik performansında herhangi bir iyileşme görülmemektedir.

7. ÇİMENTO ENDÜSTRİSİNDE HARMANLAMA PROSESİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ

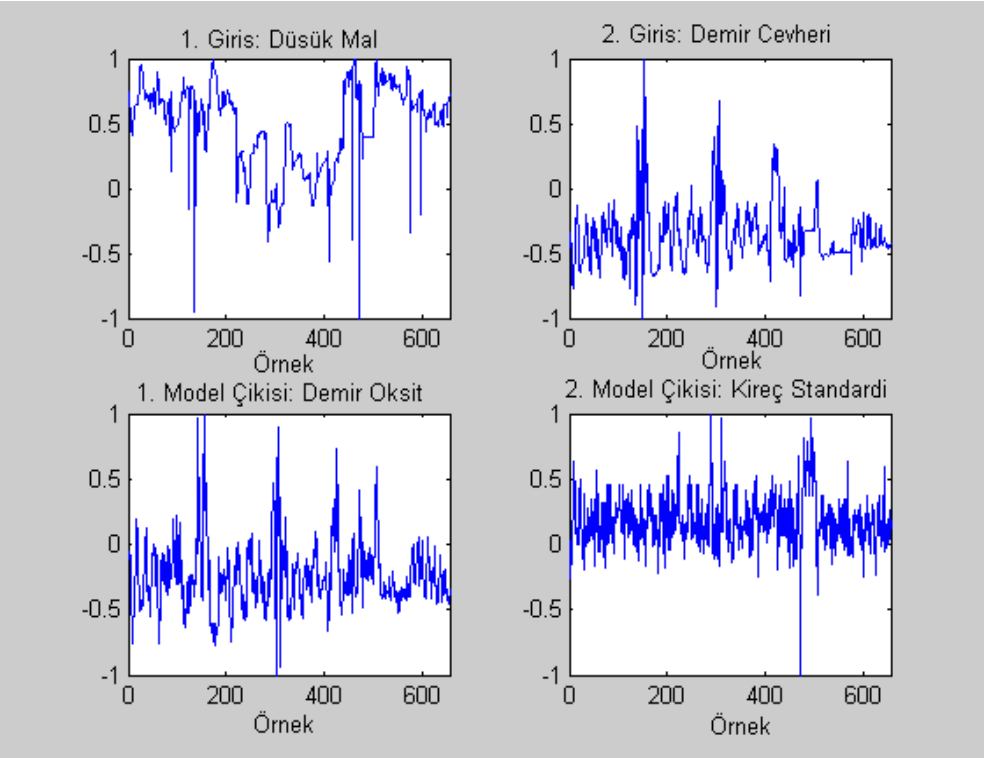
Proseslerin tanılama ve modellenmesi için lineer sistem tanılama yöntemleri yaygın olarak kullanılmaktadır. Lineer sistem tanılamada, tanılama işleminin başarısı sistem dinamiğinin lineer karakteristik göstermesi veya çalışma noktası etrafında lineerleştirilmesi gerekir. Ancak bu iki gereksinim sistemin karakteristiğinin gerçekten ortaya konmasında ve elde edilen modelin kullanılmasında oldukça kısıtlayıcıdır. Çünkü, gerçekte endüstriyel proseslerde karşılaşılan birçok sistem lineer olmadığı gibi çoğu zaman olasıl karakteristiği sahiptir. Sistemin olasıl özellikte olması herhangi bir anda sistemin girişlerinin ve dolayısıyla çıkışlarının tahminden uzak olması sonucunu doğurur. Diğer bir deyişle bu tür sistemler lineer deterministik değil lineer olmayan stokastiktir. Bu durumda lineerlik kabulü ile tasarlanan sistem modelinin sistemi yeteri kadar iyi temsil etmesi beklenemez.

Harmanlama prosesi gibi karmaşık, öngörüsü zor ve lineer olmayan bir prosesin ARX gibi lineer yöntemlerle modellenmesi bazı durumlarda yetersiz kalmaktadır. Bir önceki bölümde özellikle ikinci model için görüldü ki ARX model sistem modeli olarak yeterli performans gösterememektedir. Bu durumda lineer olmayan sistemleri de tanılayabilen başka yöntemlere ihtiyaç duyulmaktadır. Yapay Sinir Ağları (YSA)' nın, proses modellemede lineer olmayan sistemleri de başarıyla modelleyebildiği bilinmektedir [30]. Bunun yanı sıra, YSA modelinin genelleştirme gücü ve değişen sistem karakteristiğine uyarlanabilir yapısı, bu tür modellerin kontrol algoritmaları için de başarıyla uygulanabileceğini ortaya koymuştur [31]. Bu nedenle harmanlama sisteminin YSA ile modellemesi yapılmıştır.

7.1 Yapay Sinir Ağı (YSA) Modelleri

ARX modellemede yapıldığı gibi 655 örnek olan sistem verisinin 605 tanesi eğitim için kullanılmış, 50 tanesi sınama verisi olarak ayrılmıştır. Sınama verileri YSA

eğitiminde kullanılmadığı için, YSA modelinin yeni veriye karşı test edilmesinde ve varsa ezberleme problemlerinin ortaya çıkarılmasında kullanışlıdır. Veri, ARX modelinde olduğu gibi sinyal şartlandırma aşamasından geçirilmiştir. ARX modelden farklı olarak, YSA için kullanılan veri, YSA' na girilmeden önce [-1, 1] aralığında ölçeklenmiştir. Bunun sebebi, YSA' nın ara ve son katmanlarında kullanılan etkinlik fonksiyonlarının [-1, 1] aralığında tanımlı lineer olmayan fonksiyonlar olmalarıdır. YSA için kullanılan verinin sistemin karakteristiğini YSA' ya doğru aktarabilmesi açısından bu önemli bir aşamadır. YSA çıkışı elde edildikten sonra ölçeklendirme veri üzerinden kaldırılmış ve veri eski haline getirilmiştir. Karşılaştırmalarda kullanılan veri ölçeklendirmenin kaldırılmasından sonra elde edilen veridir. YSA için kullanılan giriş-çıkış verisi Şekil 7.1' de verilmiştir.



Şekil 7.1 YSA için ölçeklendirilmiş giriş-çıkış verisi

YSA yapılandırmasında karar verilmesi gereken bazı parametreler vardır. Bu parametrelerden bazıları ağın fiziksel ve matematiksel yapısıyla doğrudan bağlantılıdır. Bu parametreler; giriş-çıkış sayısı, gizli katman sayısı, katmanlardaki nöron sayıları, katmanlardaki etkinlik fonksiyonlar vb.' dir. Diğer bir parametre grubu ise eğitim algoritmasıyla ilgilidir. Bu gruptaki parametreler; öğrenme sınıfı (artışsal (incremental) veya toplu (batch) öğrenme), öğrenme oranı, çevrim

(iterasyon) sayısı, öğrenme algoritması ve öğrenme yöntemi (uyarlanabilir öğrenme oranı, momentum, Levenberg-Marquardt (LM)) olarak sayılabilir.

Bu çalışmada, daha önce ayrıntıları anlatılan tek ve çok katmanlı ileri beslemeli ağlar kullanılmıştır. Eğitim temel olarak geriye yayılma eğitim algoritmasıyla yapılmıştır. Toplu öğrenme benimsenmiştir. Eğitim zamanını azaltan yöntemlerden uyarlanabilir öğrenme oranı ve momentum yöntemlerinin birlikte kullanıldığı, momentum ile uyarlanabilir öğrenme oranı yöntemi ve Levenberg-Marquardt (LM) yöntemi kullanılmıştır. Öğrenme oranının ilk değeri 0.1 olarak sabit tutulmuştur. Sistem üzerinde yapılan başlangıç çalışmalarda, sabit öğrenme oranı ve uyarlanabilir öğrenme oranının tek başlarına kullanılmasının yeterli performans vermediği gözlenmiştir. Bu nedenle sabit öğrenme oranı ve momentumsuz uyarlanabilir öğrenme oranı yöntemleri kapsam dışında bırakılmıştır.

Dinamik sistemlerin YSA ile modellenmesinde, sistemin geçmiş çıkış değerlerine bağlılığını (sistem mertebesiyle orantılı) temsil etmek için, sistem mertebesi kadar gecikmiş çıkış, sisteme giriş olarak verilmektedir [26, 27, 28]. Bu nedenle her model için oluşturulan ağ yapısında giriş olarak, ARX ile belirlenen model mertebesi kadar geciktirilerek geri beslenen sistem çıkışları ve sistemin asıl girişleri kullanılmıştır. Sistem girişlerinin gecikmesi ARX ile bulunan değer olarak alınmıştır. Çünkü bu değer sistemin fiziksel karakteristiğinden kaynaklanmaktadır. Ancak, girişlerin mertebesi 1 olarak alınmıştır. Bu yaklaşımın ardında YSA modelinin sistemin lineer olmayan karakteristiğini giriş verisinin geçmiş değerlerine gerek duymaksızın tanıyabileceği hipotezi vardır. Eğer YSA modeli bu haliyle tatminkar sonuçlar verirse bu hipotezin doğruluğu ispatlanacaktır. Aksi halde, girişlerin geçmiş değerleri de YSA yapısına katılabilir.

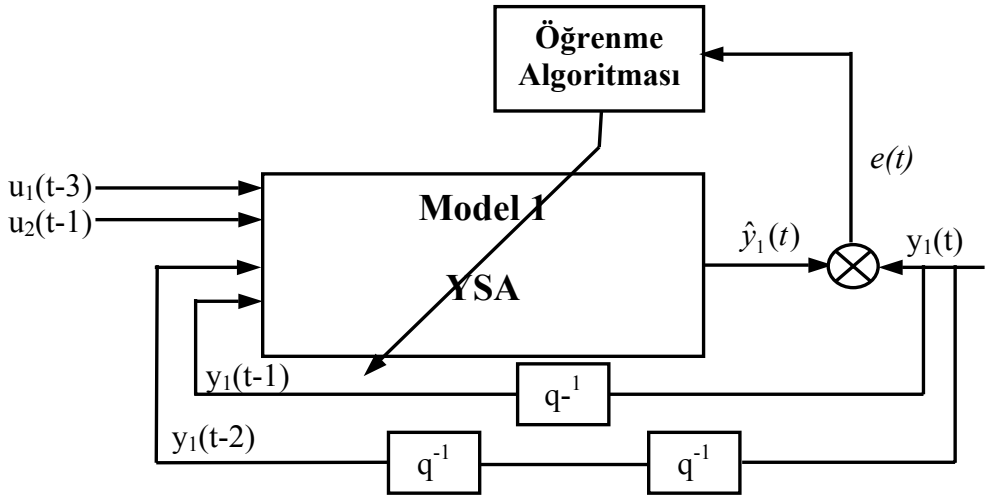
Bir ağ yapılandırmasının performansı iki önemli yöntemle belirlenir. Bu yöntemlerden birisi yapılandırmanın eğitim ve sınama kümesi için verdiği hatanın karşılaştırılmasıdır. İyi bir yapılandırmadan beklenen her iki veri grubu için de düşük hata vermesidir. Ancak ağın sınama verisi performansı daha önemli bir kriterdir. Zira, sınama verisi eğitimde kullanılmamıştır. Dolayısıyla, ağın eğitimden sonra, sistem modeli olarak nasıl davranacağının göstergesidir. Ayrıca, YSA' nın bazı durumlarda eğitim verisini öğrenmekten ziyade ezberlediği bilinmektedir [21]. Bu durumun fark edilmesinde de yine sınama verisi etkin rol oynamaktadır. İkinci

yöntem ise sistem çıkışları ile ağ çıkışlarının grafiksel olarak karşılaştırılmasıdır. Elbette grafik performansı belli ölçüde hataya bağlıdır. Ancak grafiklerin incelenmesi verinin görsel olarak birebir karşılaştırılması anlamındadır. Bu nedenle bu grafikler değerli bilgiler taşır.

7.1.1 Model 1 için Yapay Sinir Ağı Modeli

Model 1: u_1: düşük mal, u_2: demir cevheri, y_1: demir oksit

Model 1 için ARX modelinde, çıkış mertebesi 2, 1. girişin mertebesi 2 ve gecikmesi 3, 2. girişin mertebesi 4 ve gecikmesi 1 olarak belirlenmişti. Bu durumda Model 1 için yapılandırılacak YSA modelinde çıkış $y_1(t)$, girişler ise $u_1(t-3)$, $u_2(t-1)$, $y_1(t-1)$ ve $y_1(t-2)$' dir. Model 1 için YSA sisteminin blok diyagramı Şekil 7.2' de verilmiştir.



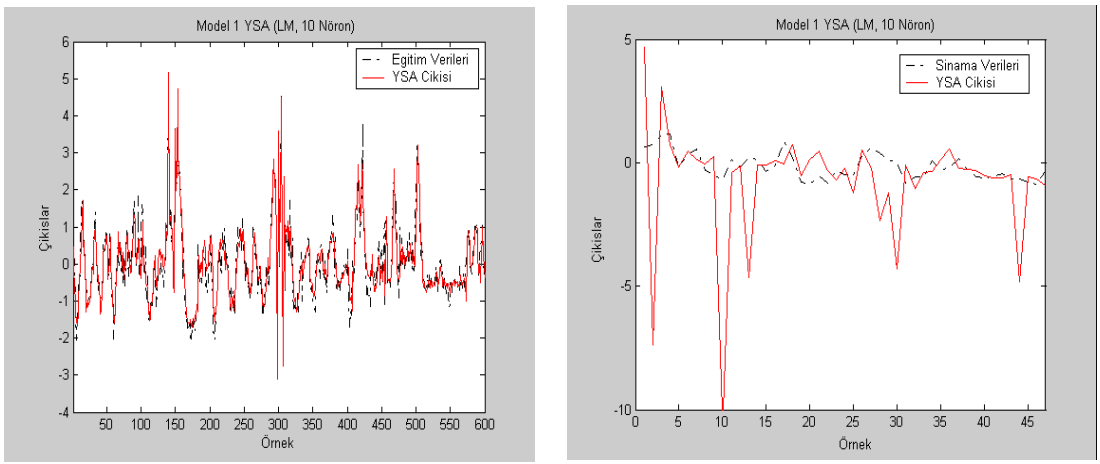
Şekil 7.2 Model 1 için Yapay Sinir Ağı blok diyagramı

Model 1 için uygun YSA yapısının bulunması için YSA yapılandırmasına bir gizli katman ve düşük nöron sayılarıyla başlanmış, ağın yapısının yetersiz olduğu görülürse önce nöron sayıları arttırılmış, daha sonra gizli katman eklenmiştir (tree-growing). Algoritmada hata hedefi sıfır olarak belirlenmiştir. Dolayısıyla algoritma çevrim sayısını tamamladığı zaman durmaktadır. Model 1 için denenen YSA yapılandırmalarından bazıları Tablo 7.1' de verilmiştir. Tablo 7.1' de, öğrenme yöntemi sütununda momentum ile uyarlanabilir öğrenme oranı için M+UÖO ve Levenberg-Marquardt için LM kısaltmaları kullanılmıştır.

Tablo 7.1 Model 1 için denenen bazı YSA yapılandırmaları

Yapılandırma	Öğrenme Yöntemi	Gizli Katman Sayısı	Gizli Katmanlardaki Nöron Sayısı	Gizli Katmanlardaki Etkinlik Fonksiyonları	Çevrim Sayısı	Hataların Karesel Ortalaması (HKO)	
						Eğitim Kümesi	Sınama Kümesi
1	LM	1	6	Log Sigmoid	1000	0,3231	7,4218
2	LM	1	10	Log Sigmoid	1000	0,1587	8,1387
3	LM	1	14	Log Sigmoid	1000	0,1357	2,6974
4	LM	1	14	Tan Sigmoid	2500	0,1482	0,7507
5	LM	2	6-6	Tan Sigmoid	2500	0,1648	5,4392
6	M+UÖO	1	8	Tan Sigmoid	10000	0,2780	0,3223
7	M+UÖO	1	9	Tan Sigmoid	10000	0,2523	0,1269
8	M+UÖO	1	14	Tan Sigmoid	10000	0,2459	0,1862
9	M+UÖO	2	6-5	Tan Sigmoid	5000	0,2646	0,1950
10	M+UÖO	2	7-7	Log Sigmoid	5000	0,2732	0,1452
11	M+UÖO	2	7-7	Log Sigmoid	20000	0,2373	0,0887
12	M+UÖO	2	7-7	Tan Sigmoid	20000	0,2087	0,1823

Tablo 7.1’ de görüldüğü gibi, Levenberg-Marquardt algoritması eğitim kümesi için düşük hata üretirken, sınama kümesinde genelde diğer algoritmaya oranla çok büyük hatalar üretmiştir. LM algoritması bir hata değerine (maliyet fonksiyonunun minimumu) çok hızlı yakınsamaktadır. Her ne kadar LM algoritması 1000 veya 2500 çevrim sayısıyla çalıştırılsa da, genelde hata 500 çevrimden sonra pek değişmemektedir. LM ile bulunan YSA modeline sınama verileri girilince, ağ tutarsız tepeler üretmektedir. Sınama verileri için HKO’ nun çok yüksek olmasının sebebi budur. Temelde bu durum, bu model için LM kullanılan YSA modellerinin ezberlemeye meyilli olduğu şeklinde yorumlanabilir. LM algoritmasının kullandığı tek gizli katmanda 10 nöron olan YSA yapısının (Yapılandırma 2) eğitim ve sınama verileri için çıkışları Şekil 7.3’ de verilmiştir.



Şekil 7.3 Tek gizli katmanda 10 nöron olan LM ile eğitilmiş YSA modeli

Şekil 7.3’ den görüldüğü gibi LM öğrenme yöntemi bu model için iyi sonuçlar üretememektedir. Dolayısıyla seçilecek model, momentum ile uyarlanabilir öğrenme oranı yöntemini kullanacaktır.

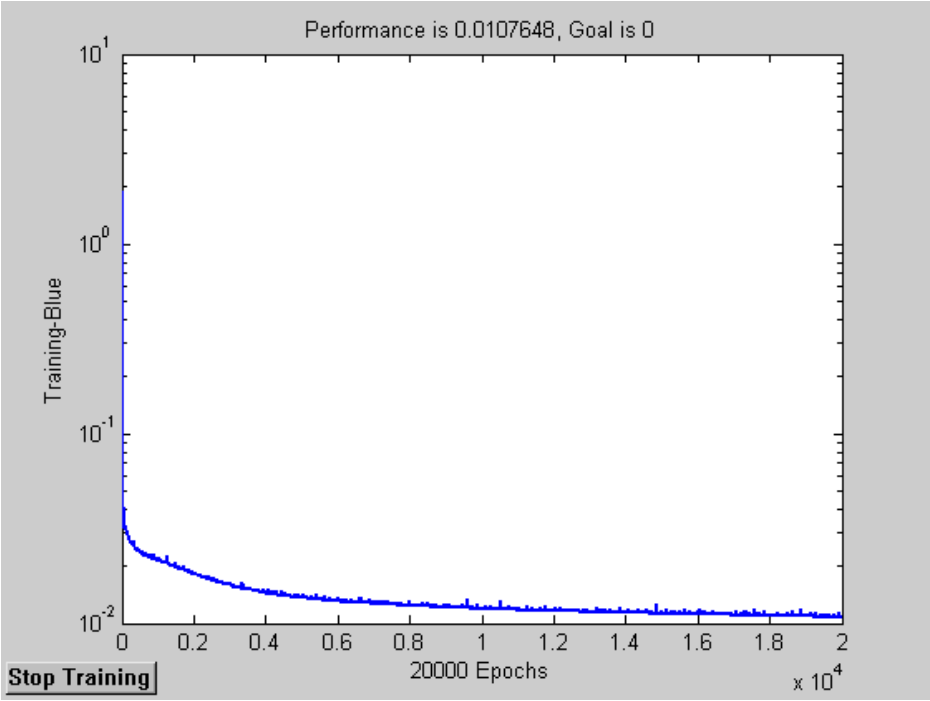
Momentum ile uyarlanabilir öğrenme oranı yöntemi kullanan yapılandırmalarda, diğer parametreler aynı kalmak şartıyla, katmanlarda tanjant sigmoid etkinlik fonksiyonu kullanan yapılandırma’ nın (Yapılandırma 12) lojistik sigmoid kullanan yapılandırmaya göre (Yapılandırma 11), eğitim kümesi için daha düşük, sınama kümesi içinse daha yüksek hata verdiği görülmüştür. Sınama kümesi performansı daha önemli görüldüğü için, en düşük sınama kümesi hatasını veren yapılandırma seçilmiştir. Bu yapılandırma, 20000 çevrim sayısı ile eğitilen, iki gizli katmanda 7’

şer nöron bulunduran ve katmanlarda lojistik sigmoid etkinlik fonksiyonu kullanan Yapılandırma 11'dir. Bu yapılandırmanın parametreleri Tablo 7.2' de verilmiştir.

Tablo 7.2 Model 1 için seçilen YSA modelinin parametreleri

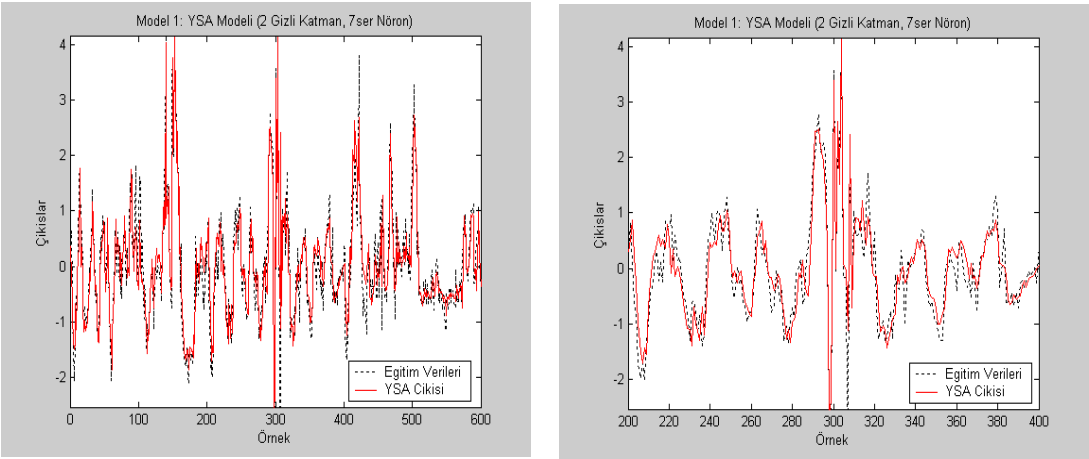
Öğrenme Yöntemi	Gizli Katman Sayısı	Gizli Katmanlardaki Nöron Sayısı	Gizli Katmanlardaki Etkinlik Fonksiyonları	Çevrim Sayısı	Hataların Karesel Ortalaması (HKO)	
					Eğitim Kümesi	Sınama Kümesi
M+UÖO	2	7-7	Log Sigmoid	20000	0,2373	0,0887

20000 çevrim sayısına doğru hatadaki değişim iyice azalmıştır. YSA' nın eğitimi sırasında maliyet fonksiyonunun (HKO) azalmasını gösteren grafik Şekil 7.4' de verilmiştir.



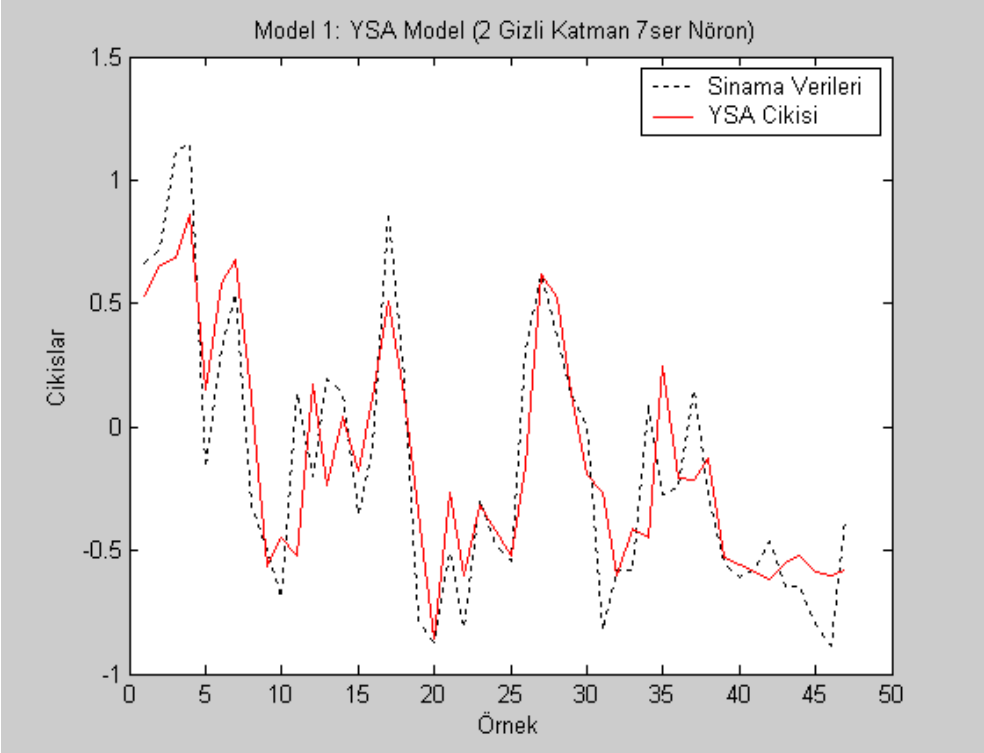
Şekil 7.4 Hatanın karesel ortalamasının (HKO) eğitim süresince azalması

Şekil 7.5' de seçilen YSA modelinin eğitim verisi ile karşılaştırılması verilmektedir. Şeklin sağ tarafındaki grafikte aynı kümenin 200 ile 400. örnekleri arasındaki 200 veri için büyültülmüş şekli görülmektedir.



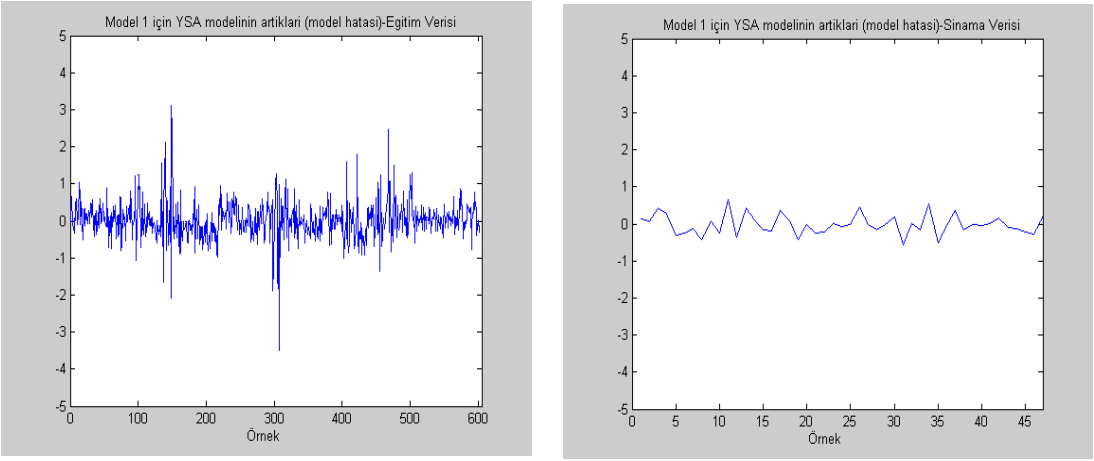
Şekil 7.5 Model 1 için seçilen YSA modelinin eğitim verisi çıkışları

Şekil 7.6' da Model 1 için seçilen YSA' nın sınama verileri için grafik performansı verilmiştir.



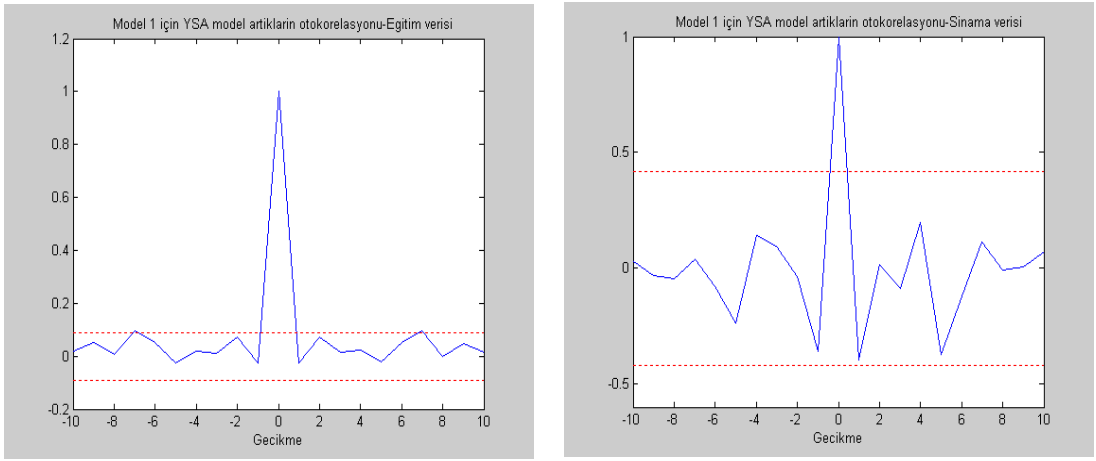
Şekil 7.6 Model 1 için seçilen YSA modelinin sınama verisi çıkışları

Model 1 için seçilen YSA modelinin artıkları (model hatası) eğitim ve sınama kümeleri için Şekil 7.7' de verilmektedir.



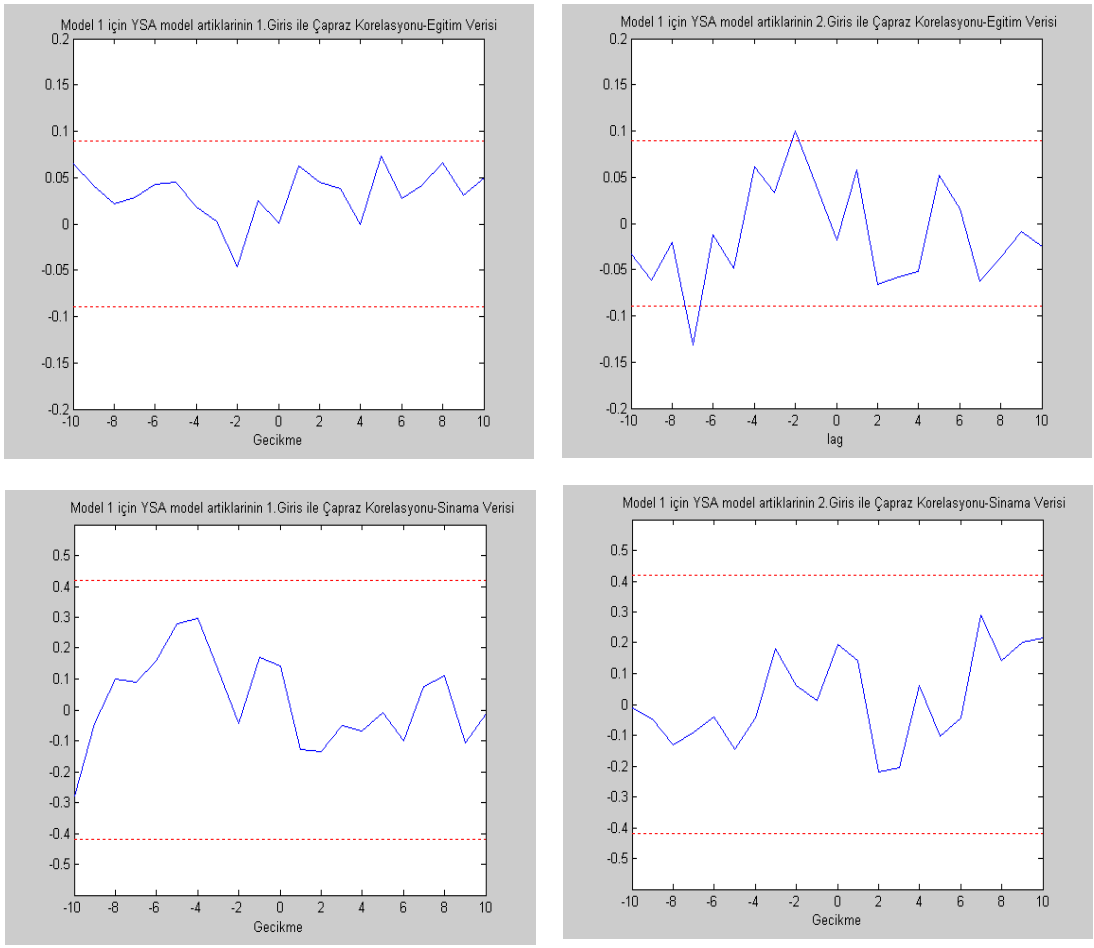
Şekil 7.7 Model 1 için YSA modelinin eğitim ve sınama kümeleri için artıkları

Eğitim verisi ve sınama verisi için artıkların % 97 güven aralığında otokorelasyon grafiği 10 gecikme için Şekil 7.8' da verilmiştir.



Şekil 7.8 Model 1 için YSA model artıklarının otokorelasyonu

Eğitim verisi ve sınama verisi için artıkların her iki girişle çapraz korelasyonu grafiği 10 gecikme için Şekil 7.9' da verilmiştir.



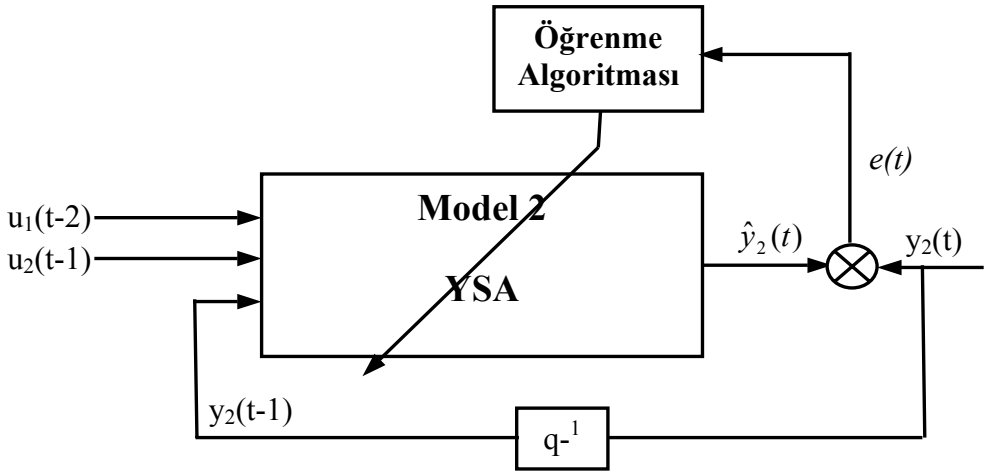
Şekil 7.9 Model 1 için YSA modelinin artıklarının girişlerle çapraz korelasyonu

Model artıklarının eğitim ve sınama kümeleri için otokorelasyon grafiğinden görüldüğü gibi, model hatalarının otokorelasyonu % 97 güven aralığının dışına taşmamaktadır. Çapraz korelasyon grafiklerinde pozitif gecikmeler için olan kısımda modelin hem eğitim hem de sınama kümeleri için güven aralığının dışına çıkmadığı görülmektedir. Bu durumda önerilen YSA modeli başarılı ve geçerli bir sistem modelidir.

7.1.2 Model 2 için Yapay Sinir Ağı Modeli

Model 2: u_1: düşük mal, u_2: demir cevheri, y_1: kireç standardı (ML)

Model 2 için ARX modelinde, çıkış mertebesi 1, 1. girişin mertebesi ve gecikmesi 2, 2. girişin mertebesi 3 ve gecikmesi 1 olarak belirlenmişti. Bu durumda Model 2 için yapılandırılacak YSA modelinde çıkış $y_2(t)$, girişler ise $u_1(t-2)$, $u_2(t-1)$, ve $y_2(t-1)$' dir. Model 2 için YSA sisteminin blok diyagramı Şekil 7.10' de verilmiştir.



Şekil 7.10 Model 2 için Yapay Sinir Ağı blok diyagramı

Model 2 için uygun YSA yapısının bulunmasında da Model 1' de anlatılan yöntem kullanılmıştır (tree-growing). Model 1 için denenen YSA yapılandırmalarından bazıları Tablo 7.3' de verilmiştir. Tabloda, öğrenme yöntemi sütununda momentum ile uyarlanabilir öğrenme oranı için M+UÖO ve Levenberg-Marquardt için LM kısaltmaları kullanılmıştır.

Tablo 7.3' de (sonraki sayfa) görüldüğü gibi, Levenberg-Marquardt algoritması eğitim kümesi için düşük hata üretirken, sınama kümesinde genelde diğer algoritmaya oranla çok büyük hatalar üretmiştir. LM yönteminin bu model için de performanslı olmadığı görülmüştür. Momentum ile uyarlanabilir öğrenme oranı yöntemiyle en iyi YSA modeli iki gizli katmanla, ilk katmanda 13, ikinci katmanda 10 nöron kullanarak elde edilmiştir. Katmanlarda tanjant sigmoid etkinlik fonksiyonunun daha başarılı olduğu görülmüştür. Bu yapılandırmanın parametreleri Tablo 7.4' de verilmiştir. Bu YSA' nın eğitimi 20000 çevrime kadar uzatılmıştır. Bu yapılandırma sınama kümesi için en küçük, eğitim kümesi için de M+UÖO yöntemi kullanılan yapılandırmalar arasında en küçük hatayı vermiştir. Ayrıca dikkat edilmesi gereken bir nokta da katmanlıkta kullanılan nöron sayısının çokluğudur. Bu durum Model 2' nin karmaşıklığının bir sonucudur.

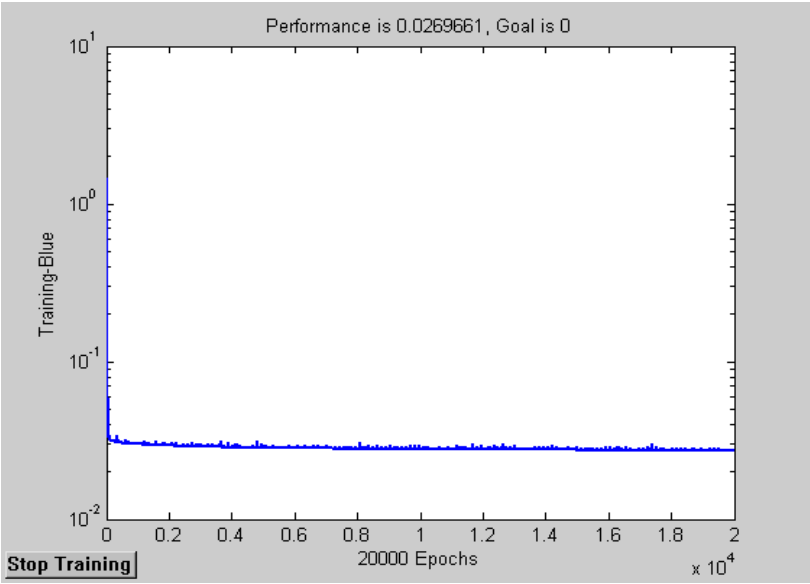
Tablo 7.3 Model 2 için denenen bazı YSA yapılandırmaları

Yapılandırma	Öğrenme Yöntemi	Gizli Katman Sayısı	Gizli Katmanlardaki Nöron Sayısı	Gizli Katmanlardaki Etkinlik Fonksiyonları	Çevrim Sayısı	Hataların Karesel Ortalaması (HKO)	
						Eğitim Kümesi	Sınama Kümesi
1	LM	1	9	Tan Sigmoid	1000	0,6109	3,2812
2	LM	1	10	Tan Sigmoid	1000	0,6216	2,1997
3	LM	1	14	Log Sigmoid	1000	0,5422	15,1581
4	M+UÖO	1	6	Log Sigmoid	5000	0,8232	0,7347
5	M+UÖO	1	8	Tan Sigmoid	10000	0,7466	0,8022
6	M+UÖO	1	9	Log Sigmoid	10000	0,7710	0,9836
7	M+UÖO	1	9	Tan Sigmoid	10000	0,7287	0,8011
8	M+UÖO	2	5-5	Tan Sigmoid	10000	0,7521	0,7142
9	M+UÖO	2	7-7	Tan Sigmoid	10000	0,7258	0,7799
10	M+UÖO	2	10-10	Tan Sigmoid	15000	0,6682	0,6596
11	M+UÖO	2	12-12	Tan Sigmoid	15000	0,6581	0,8984
12	M+UÖO	2	12-10	Tan Sigmoid	20000	0,7118	0,6791
13	M+UÖO	2	13-10	Log Sigmoid	20000	0,6212	0,8585
14	M+UÖO	2	13-10	Tan Sigmoid	20000	0,6163	0,5831

Tablo 7.4 Model 2 için seçilen YSA modelinin parametreleri

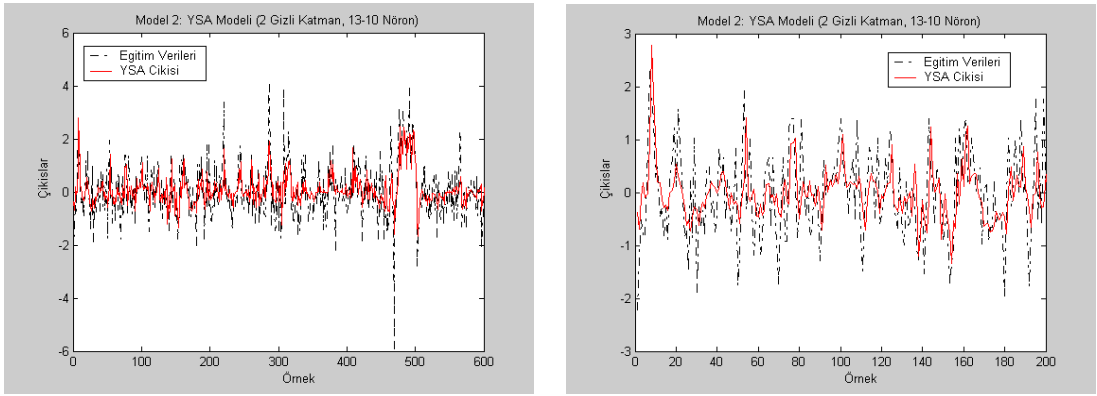
Öğrenme Yöntemi	Gizli Katman Sayısı	Gizli Katmanlardaki Nöron Sayısı	Gizli Katmanlardaki Etkinlik Fonksiyonları	Çevrim Sayısı	Hataların Karesel Ortalaması (HKO)	
					Eğitim Kümesi	Sınama Kümesi
M+UÖO	2	13-10	Tan Sigmoid	20000	0,6163	0,5831

YSA' nın eğitimi sırasında maliyet fonksiyonunun (HKO) azalmasını gösteren grafik Şekil 7.11' de verilmiştir.



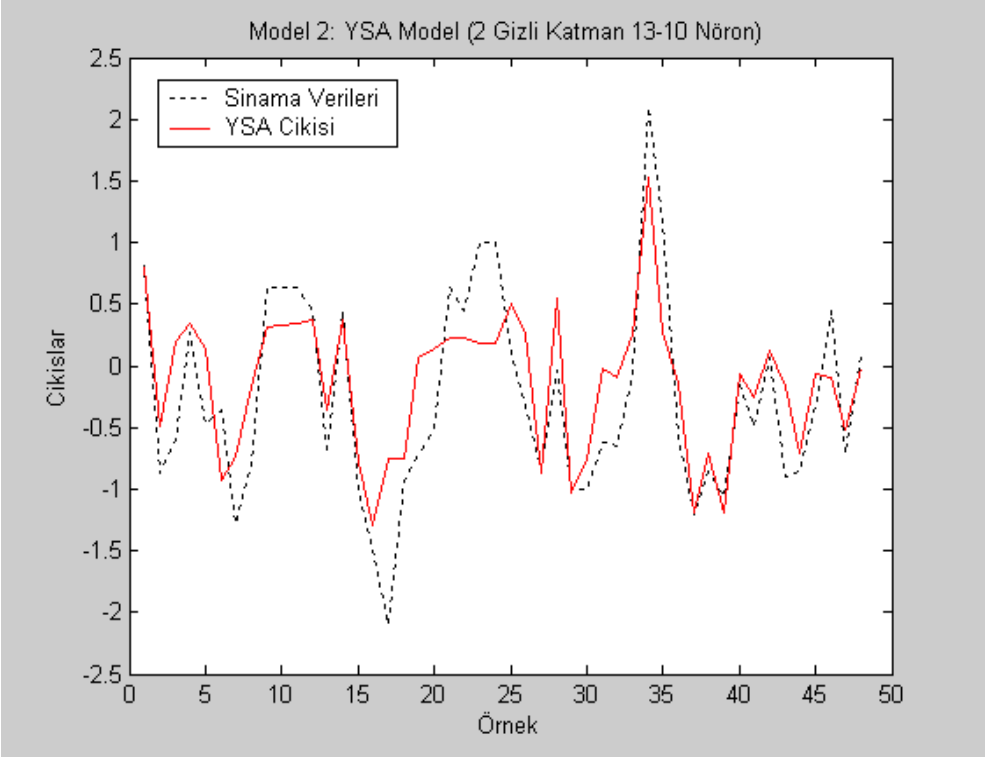
Şekil 7.11 Hatanın karesel ortalamasının (HKO) eğitim süresince azalması

Şekil 7.12' de seçilen YSA modelinin eğitim verisi ile karşılaştırılması verilmektedir. Şeklin sağ tarafındaki grafikte aynı kümenin son 200 veri için büyültülmüş şekli görülmektedir.



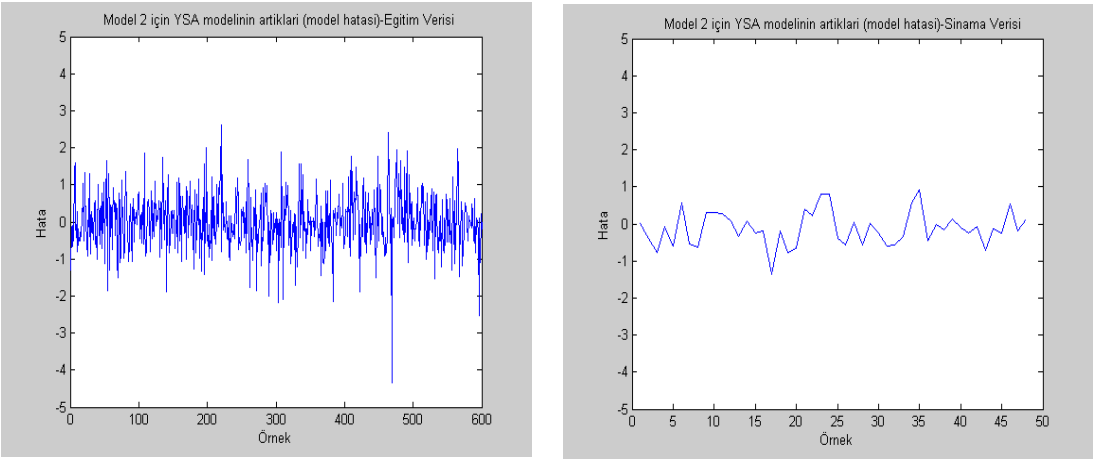
Şekil 7.12 Model 2 için seçilen YSA modelinin eğitim verisi çıkışları

Şekil 7.13' da Model 2 için seçilen YSA' nın sınama verileri için grafik performansı verilmiştir.



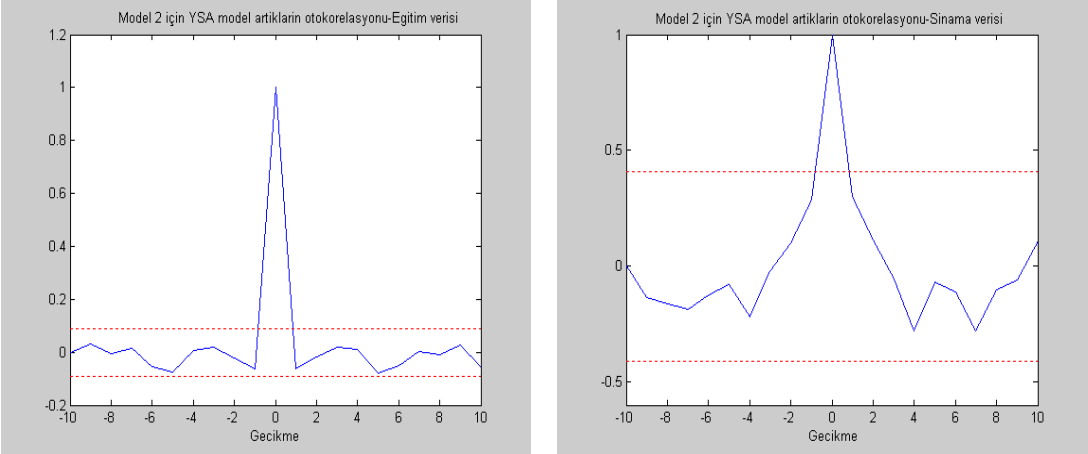
Şekil 7.13 Model 2 için seçilen YSA modelinin sınama verisi çıkışları

Model 2 için seçilen YSA modelinin artıkları (model hatası) eğitim ve sınama kümeleri için Şekil 7.14' de verilmektedir.



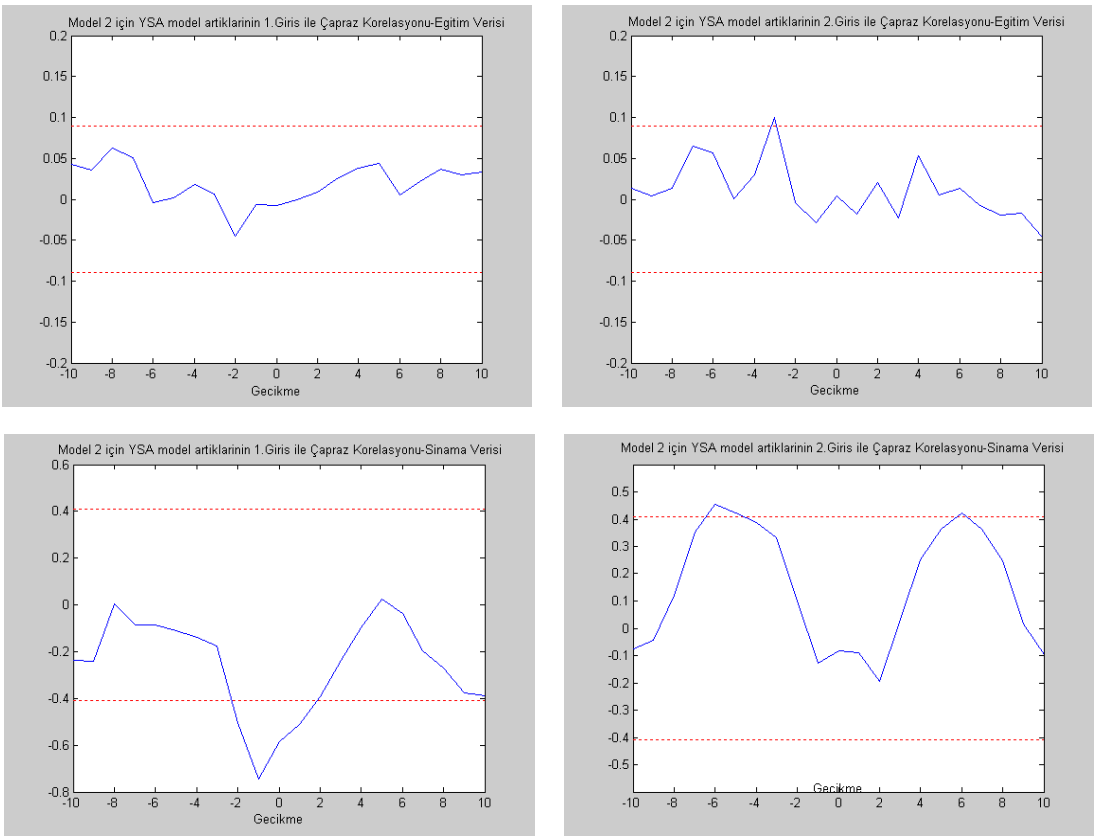
Şekil 7.14 Model 2 için YSA modelinin eğitim ve sınama kümeleri için artıkları

Eğitim verisi ve sınama verisi için artıkların % 97 güven aralığında otokorelasyon grafiği 10 gecikme için Şekil 7.15' da verilmiştir.



Şekil 7.15 Model 2 için YSA model artıklarının otokorelasyonu

Eğitim verisi ve sınama verisi için artıkların her iki girişle çapraz korelasyonu grafiği 10 gecikme için Şekil 7.16' da verilmiştir.



Şekil 7.16 Model 2 için YSA modelinin artıklarının girişlerle çapraz korelasyonu

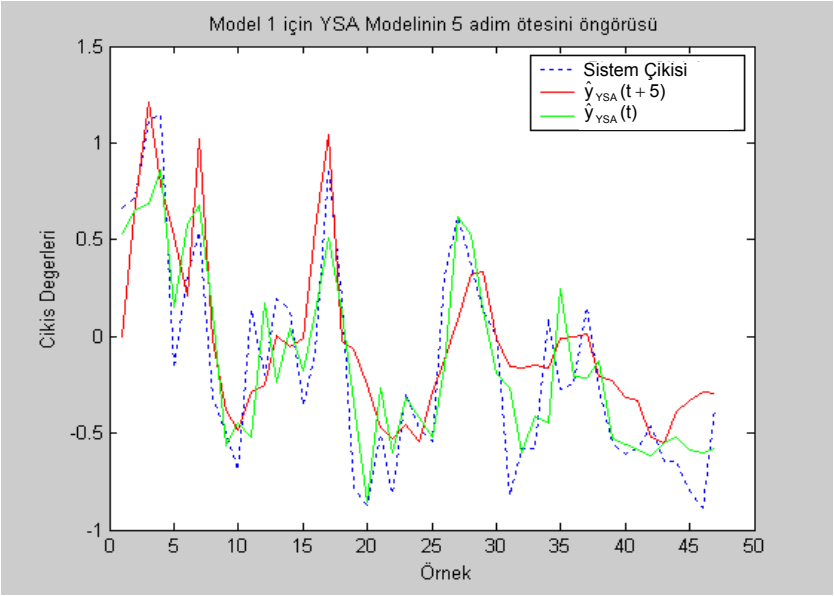
Model artıklarının eğitim ve sınama kümeleri için otokorelasyon grafiğinden görüldüğü gibi, model hatalarının otokorelasyonu % 97 güven aralığının dışına taşmamaktadır. Çapraz korelasyon grafiklerinde pozitif gecikmeler için olan kısımda modelin hem eğitim hem de sınama kümeleri için güven aralığının dışına kayda değer bir şekilde taşmadığı görülmektedir. Bu nedenlerden ötürü Model 2 için önerilen YSA modeli geçerli bir sistem modelidir.

7.2 Yapay Sinir Ağı Modellerinin Öngörü Kapasiteleri

YSA modellerinin öngörü kapasitelerinin incelenmesi, modellerin, gelecekte kullanılabileceği öngörülü kontrol algoritmalarındaki başarımı açısından önemlidir. ARX modellerde olduğu gibi YSA modellerinde de öngörü ufku 5 olarak seçilmiştir. YSA modelinin, sistemin 5 adım ötedeki çıkışını ($y_p(t)$) öngörmesi için (t-5) anında modele giriş olarak, o andaki gerçek çıkışın model yapısıyla belirlenen kadar geciktirilmişi ve sistemin gerçek girişleri verilir. Bu adımdan sonra model kendi ürettiği çıkışları iteratif döngüsünde kullanır. İyi bir sistem modelinden beklenen modelin çıkışının sistem çıkışını olabildiğince iyi yakalayabilmesidir.

7.2.1 Model 1 için YSA Modelinin 5 Adım Ötesini Öngörüsü

Son 50 veri (sınama verisi) için sistemin çıkışı, YSA modelinin öngörüsüz çıkışı ($\hat{y}_{TSA}(t)$) ve öngörülü çıkışı ($\hat{y}_{YSA}(t+5)$) Şekil 7.17' de verilmiştir.



Şekil 7.17 Model 1 için YSA modelinin sınama kümesi için 5 adım ötesini öngörüsü

Model 1 için YSA modelin 5 adım ötesini öngörüsü, genel anlamda modelin öngörüsüz çıkış karakteristiğine yakın özellik sergilemektedir. Ancak, öngörülü çıkışın, öngörüsüz model kadar sistem çıkışındaki tepeleri yakalamakta başarılı olmadığı görülmektedir. Öngörülü çıkışın gerçek çıkışla arasındaki öngörü hatası HKO cinsinden Tablo 7.5' de verilmiştir.

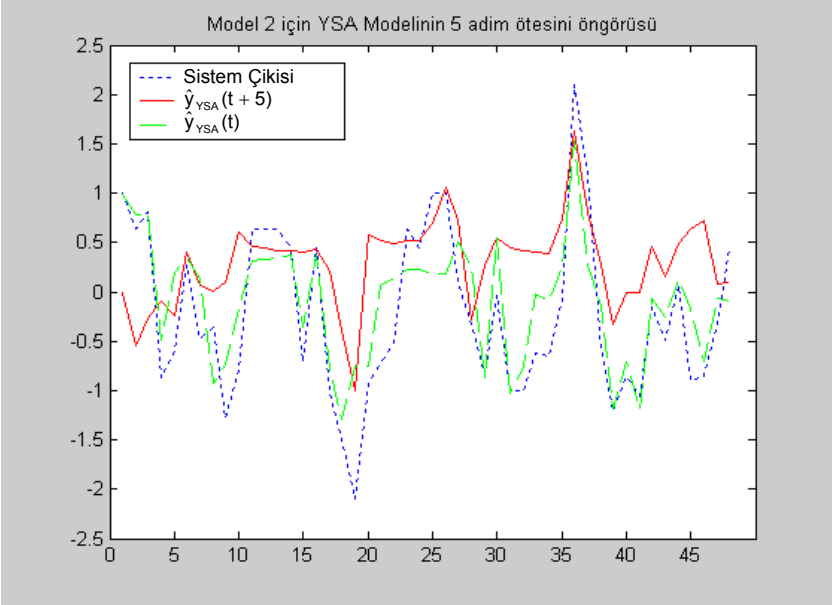
Tablo 7.5 Model 1 için YSA modelinin öngörü hataları

	Tanılama Verisi	**Sınama Verisi**
HKO	0,2879	0,0982

HKO yönünden incelendiğinde öngörülen çıkışın, öngörüsüz çıkışa göre biraz daha fazla hata verdiği görülmektedir. Ancak grafik performanstan da görüleceği gibi öngörülü model, sistemin dinamiğini temsil edebilmektedir.

7.2.2 Model 2 için YSA Modelinin 5 Adım Ötesini Öngörüsü

Son 50 veri (sınama verisi) için sistemin çıkışı, YSA modelinin öngörüsüz çıkışı ($\hat{y}_{TSA}(t)$) ve öngörülü çıkışı ($\hat{y}_{YSA}(t+5)$) Şekil 7.18' de verilmiştir.



Şekil 7.18 Model 2 için YSA modelinin sınama kümesi için 5 adım ötesini öngörüsü

Model 2 için YSA modelin 5 adım ötesini öngörüsü, sistem çıkışındaki yön değişimlerini belli ölçüde takip edebilmekte fakat modelin öngörüsüz çıkışı kadar uyum sağlayamamaktadır. Sistemin karmaşıklığı göz önünde bulundurularak,

modelin öngörülü çıkışının çok kötü olmayan bir performans gösterdiği söylenebilir. Öngörülü çıkışın gerçek çıkışla arasındaki öngörü hatası HKO cinsinden Tablo 7.6' de verilmiştir.

Tablo 7.6 Model 2 için YSA modelinin öngörü hataları

	Tanılama Verisi	**Sınama Verisi**
HKO	0,7218	0,6352

Beklendiği gibi, modelin öngörü performansı, çıkış hatası yönünden incelendiğinde de öngörülen çıkışın, öngörüsüz çıkışa göre daha fazla hata verdiği görülmektedir.

8. ÇİMENTO ENDÜSTRİSİNDE HARMANLAMA PROSESİNİN UYARLANABİLİR SİNİRSEL-BULANIK ÇIKARTIM SİSTEMİ İLE MODELLENMESİ

Uyarlanabilir Sinirsel-Bulanık Çıkartım Sistemi (USBÇS), radyal tabanlı fonksiyon ağı kullanarak Sugeno-Takagi tipi bir bulanık sistemin oluşturulması ve ince ayarının yapılması temeline dayanır. 5. Bölüm' de anlatıldığı gibi, matematiksel olarak USBÇS' nin lineer olmayan fonksiyonlar da dahil olmak üzere sınırsız yakınsama gücü olduğu gösterilmiştir. Bu nedenle bu bölümde, USBÇS' nin harmanlama prosesine uygulanması ve model performansının gözlenmesi ele alınmıştır.

8.1 Uyarlanabilir Sinirsel-Bulanık Çıkartım Sistemi (USBÇS) Modelleri

USBÇS modellerinin eğitilmesinde de ARX ve YSA modellemede yapıldığı gibi 655 örnek olan sistem verisinin 605 tanesi eğitim için kullanılmış, 50 tanesi sınama verisi olarak ayrılmıştır.

USBÇS modellerinin yapılandırması YSA modelleriyle birebir aynıdır. Sistemin dinamik karakteristiğini göz önünde bulundurmak için YSA' da yapıldığı gibi sistem çıkışları, model mertebesi kadar geciktirilerek USBÇS' e giriş olarak verilmiştir.

USBÇS modelinin yapılandırılmasında karar verilmesi gereken önemli parametreler vardır. Bu parametreler; girişlerin üyelik fonksiyonları (ÜF) sayısı, ÜF' nin türü (Gauss, genelleştirilmiş çan vb.), çevrim sayısı, öğrenme oranı, öğrenme oranı arttırma katsayısı ve öğrenme oranı azaltma katsayısı ve hata hedefi olarak sıralanabilir.

Bir USBÇS yapılandırmasının performansı, eğitim ve sınama verileri için model çıkış hatası (HKO) ve modelin grafiksel performansıyla değerlendirilmektedir. Daha önce belirtildiği gibi, iyi bir yapılandırmadan beklenen her iki veri grubu için de

düşük hata vermesidir. Ancak sınama verisi performansı daha önemli bir kriterdir. Zira, sınama verisi eğitimde kullanılmamıştır. Dolayısıyla, modelin eğitimden sonra, sistem modeli olarak nasıl davranacağının göstergesidir.

USBÇS eğitiminde diğer bir önemli husus da eğitimin bilgisayara hesap yüküdür. Örnek olarak, her girişinde m üyelik fonksiyonu ve toplam n girişi olan bir USBÇS' de m^n tane eğitilecek kural vardır. Üyelik fonksiyonu türü olarak genelleştirilmiş çan ('gbellmf') seçilirse, bir üyelik fonksiyonun şeklini belirleyen 3 tane lineer olmayan parametre vardır. Dolayısıyla toplam $3mn$ tane lineer olmayan parametre çözülecektir. Öte yandan, her bir kural için $(n+1)$ tane lineer parametre vardır. Dolayısıyla hesaplanması gereken $m^n(n+1)$ tane de lineer parametre ortaya çıkar. Sayısal örnek verilecek olursa, 4 girişi olan (Model 1 gibi) ve her girişinde 3 üyelik fonksiyonu bulunan bir USBÇS yapısında 81 tane kural ve optimize edilmesi gereken 36 lineer olmayan ve 405 lineer parametre vardır. Bir eğitim işlemi, bilgisayarın hızına ve seçilen parametrelere (çevrim sayısı, giriş sayısı, girişlerin üyelik fonksiyonu sayısı vb.) göre değişmekle birlikte yarım saati aşan süreler alabilmektedir [29].

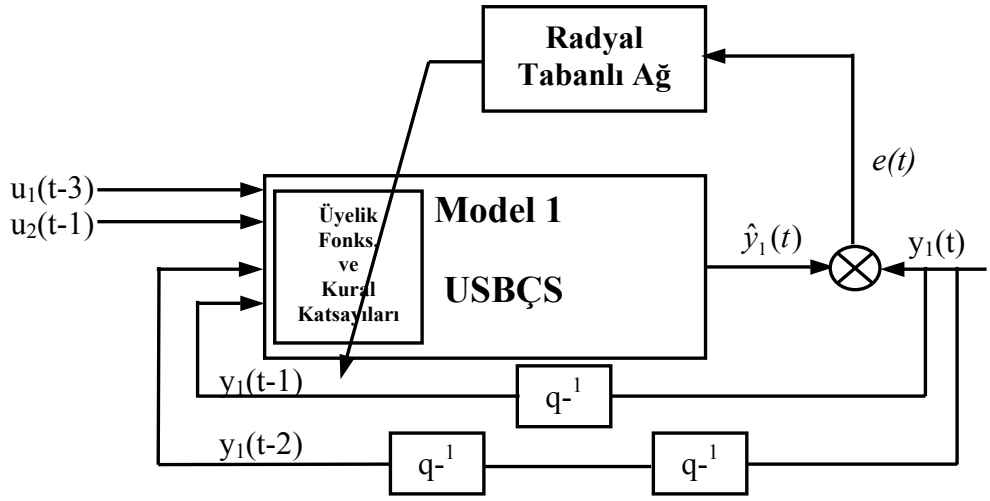
USBÇS eğitiminde çeşitli yapılandırmalar arasında sabit tutulan parametreler; öğrenme oranı (0.01), öğrenme oranı arttırma katsayısı (1.1) ve öğrenme oranı azaltma katsayısı (0.9) ve hata hedefi (0.0) ve üyelik fonksiyonu türü (genelleştirilmiş çan)'dır. Modeller arasında değişen parametreler ise, girişlerin üyelik fonksiyonu sayıları ve eğitim çevrim sayısıdır.

8.1.1 Model 1 için USBÇS Modeli

Model 1: u_1: düşük mal, u_2: demir cevheri, y_1: demir oksit

Model 1 için USBÇS yapılandırması giriş-çıkış parametreleri açısından YSA yapılandırmasının aynısıdır. Model 1 için yapılandırılacak USBÇS modelinde çıkış $y_1(t)$, girişler ise $u_1(t-3)$, $u_2(t-1)$, $y_1(t-1)$ ve $y_1(t-2)$' dir. Model 1 için USBÇS sisteminin blok diyagramı Şekil 8.1' de verilmiştir.

Model 1 için denenen USBÇS yapılandırmalarından bazıları Tablo 8.1' de verilmiştir. 'Girişlerin Üyelik Fonksiyonları Sayısı' sütunundaki sayılar sırasıyla ise u_1, u_2, $y_1(t-1)$ ve $y_1(t-2)$ girişlerinin üyelik fonksiyonu sayılarıdır.



Şekil 8.1 Model 1 için USBÇS blok diyagramı

Tablo 8.1 Model 1 için bazı USBÇS yapılandırmaları

Yapılandırma	Girişlerin Üyelik Fonksiyonu Sayısı	Çevrim Sayısı	Hataların Karesel Ortalaması (HKO)	
			Eğitim Kümesi	Sınama Kümesi
1	2-2-2-2	50	0,1664	0,0709
2	2-2-2-2	100	0,1586	0,1133
3	2-2-2-2	200	0,1348	0,1261
4	3-2-2-2	100	0,1294	0,1119
5	2-3-2-2	100	0,1311	0,1029
6	2-2-3-3	100	0,1066	0,3076
7	3-3-2-2	100	0,0973	0,1419
8	3-3-3-3	100	0,0483	0,8065
9	4-3-2-2	50	0,0781	0,1749

Tablo 8.1' den görüleceği gibi, Model 1 için sistem en düşük sınama verisi hatasını üreten yapılandırma ilk yapılandırmadır. Ne var ki, bu yapılandırma için eğitim verisi hatası diğer yapılandırmalara oranla daha yüksek kalmaktadır. USBÇS eğitiminde aynı giriş üyelik fonksiyonu sayısına sahip yapılandırmalarda, çevrim sayısı arttıkça eğitim kümesi hatasının kararlı bir şekilde düştüğü gözlenmiştir (ilk üç yapılandırma karşılaştırılabilir). Ancak bu durum sınama kümesine tersiyle yansımaktadır. Yani sınama kümesinin hataları çevrim sayısı arttıkça artmaktadır. Bu durumun sebebi USBÇS' nin eğitim kümesi için aşırı uyum (overfitting) göstermeye başlaması

olarak açıklanabilir [8]. Bu sebeple eğitim kümesinin hatasından ziyade, modelin eğitiminde kullanılmayan sınama kümesinin hatası belirleyici olmalıdır. Çevrim sayısını arttırmanın yarattığı diğer bir önemli problem de USBÇS yapılandırmasının artan hesap yüküdür.

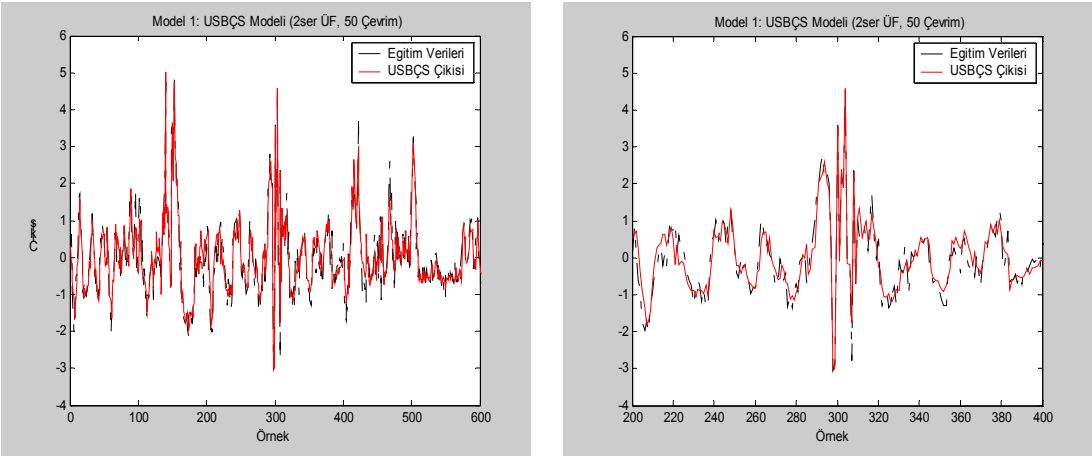
Öte yandan, geri beslenen çıkışların üyelik fonksiyonu sayısının arttırılmasının sınama kümesi hatasını arttırdığı gözlenmiştir (yapılandırma 6 ve 2 karşılaştırılabilir). Üyelik fonksiyonu sayısını ve çevrim sayısını mümkün olduğu kadar küçük tutmak ve aynı zamanda performanstan çok ödün vermemek göz önünde bulundurularak Model 1 USBÇS yapılandırması, Yapılandırma 1 olarak belirlenmiştir.

Yapılandırma 1' in yapısı ve sonuçları Tablo 8.2' de verilmiştir.

Tablo 8.2 Model 1 için seçilen USBÇS modelinin parametre ve sonuçları

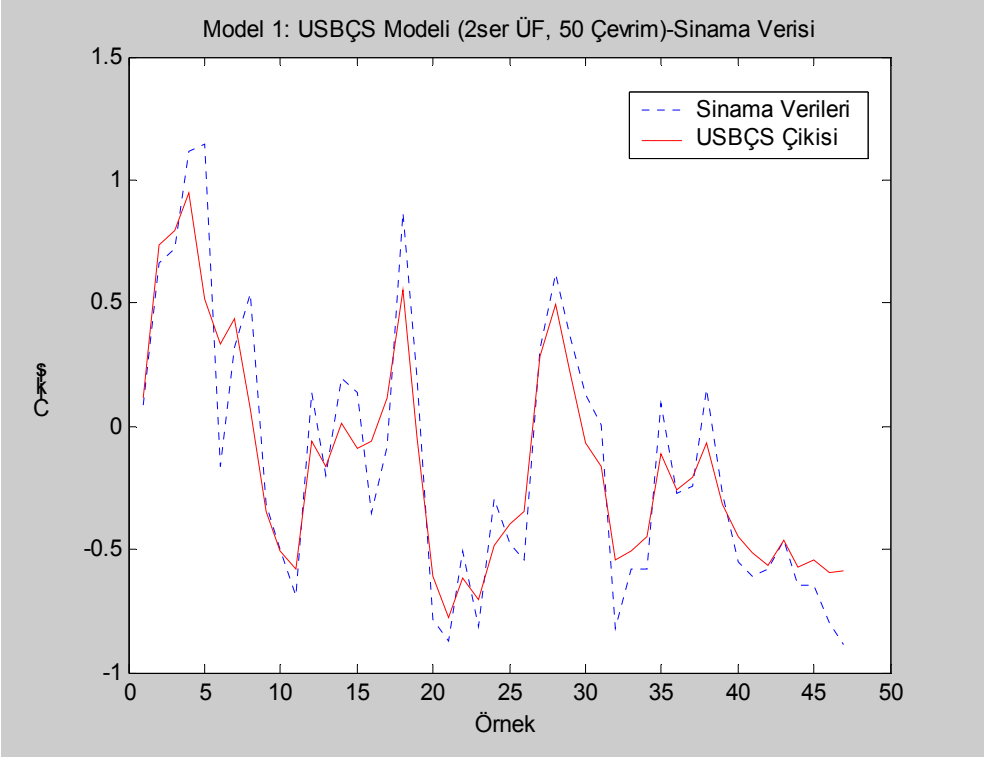
Girişlerin Üyelik Fonksiyonu Sayısı	Çevrim Sayısı	Hataların Karesel Ortalaması (HKO)	
		Eğitim Kümesi	Sınama Kümesi
2-2-2-2	50	0,1664	0,0709

Şekil 8.2' de seçilen USBÇS modelinin eğitim verisi ile karşılaştırılması verilmektedir. Şeklin sağ tarafındaki grafikte aynı kümenin 200 ile 400. örnekleri arasındaki 200 veri için büyültülmüş şekli görülmektedir.



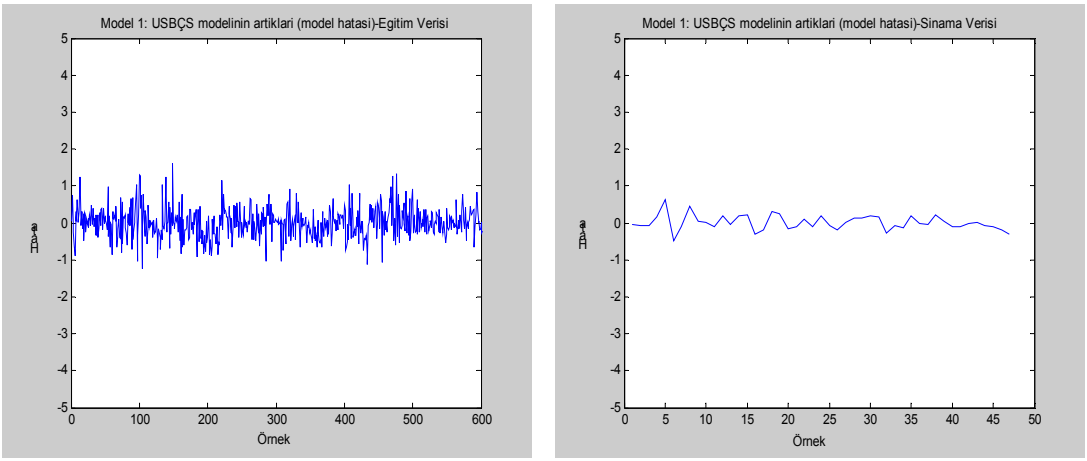
Şekil 8.2 Model 1 için seçilen USBÇS modelinin eğitim verisi çıkışları

Şekil 8.3' de Model 1 için seçilen USBÇS' nin sınama verileri için grafik performansı verilmiştir.



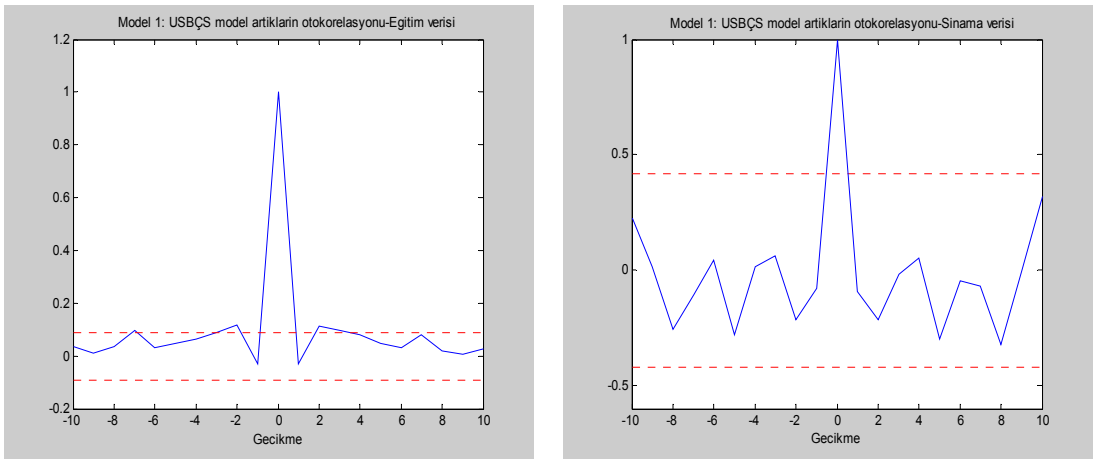
Şekil 8.3 Model 1 için seçilen USBÇS modelinin sınama verisi çıkışları

Model 1 için seçilen USBÇS modelinin artıkları (model hatası) eğitim ve sınama kümeleri için Şekil 8.4' de verilmiştir.



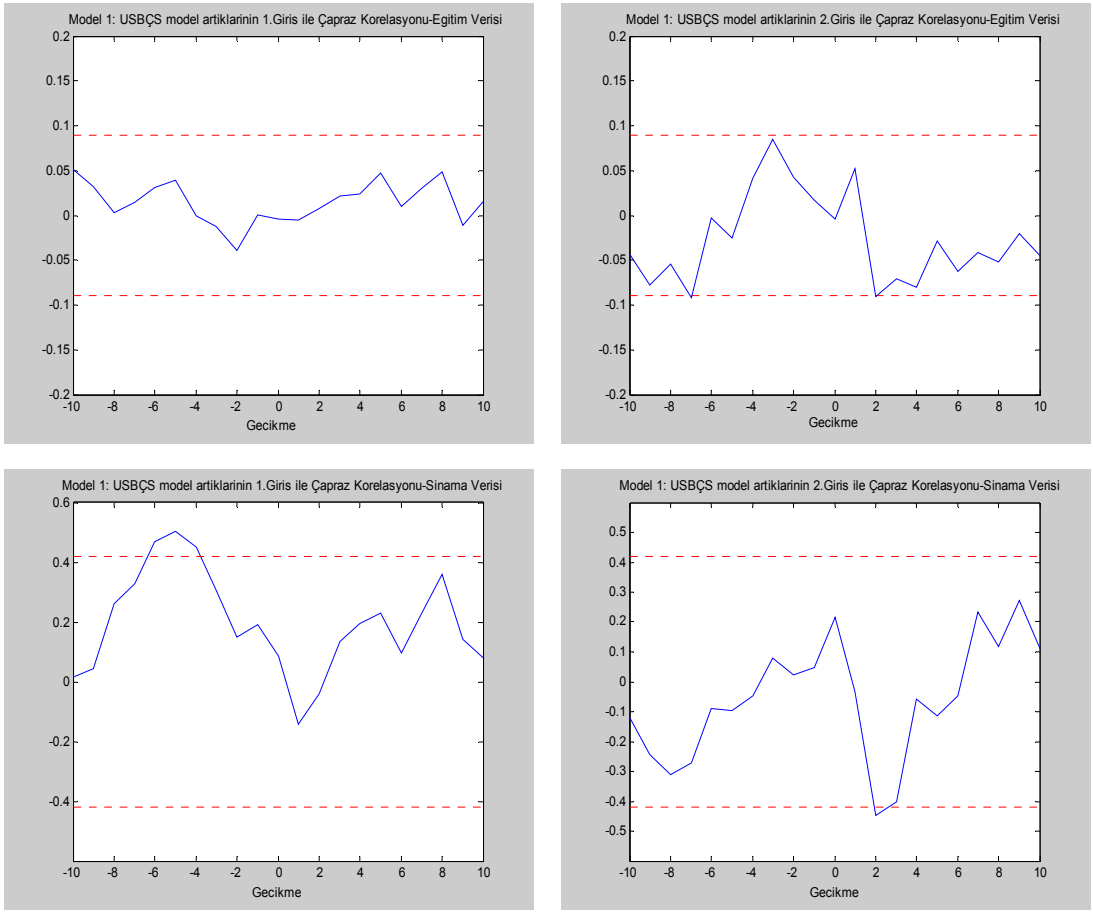
Şekil 8.4 Model 1 için USBÇS modelinin eğitim ve sınama kümeleri için artıkları

Eğitim verisi ve sınama verisi için artıkların % 97 güven aralığında otokorelasyon grafiği 10 gecikme için Şekil 8.5' da verilmiştir.



Şekil 8.5 Model 1 için USBÇS model artıklarının otokorelasyonu

Eğitim verisi ve sınama verisi için artıkların her iki girişle çapraz korelasyonu grafiği 10 gecikme için Şekil 8.6' da verilmiştir.



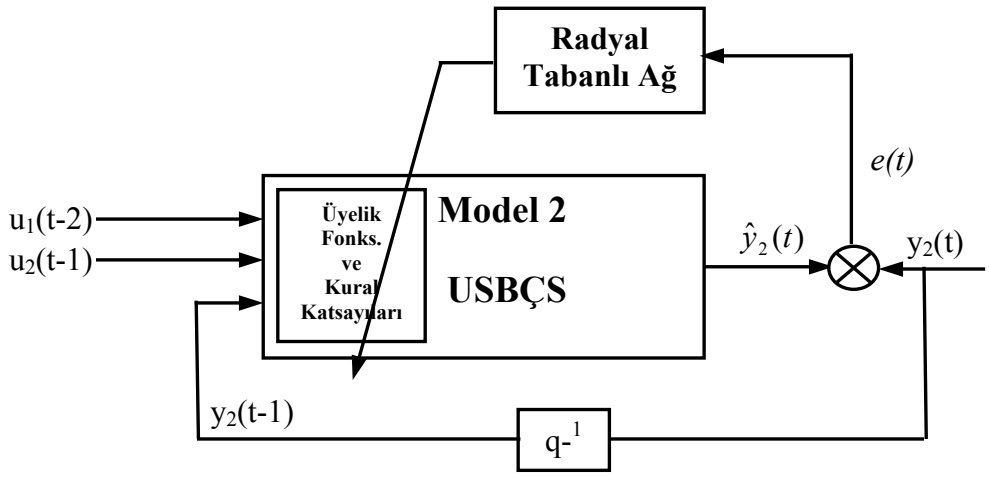
Şekil 8.6 Model 1 için USBÇS modelinin artıklarının girişlerle çapraz korelasyonu

Model artıklarının eğitim kümesi için otokorelasyon grafiğinde USBÇS modelin ± 2. gecikme için % 97 güven aralığının biraz dışına taşmaktadır. Ancak sınama kümesi için bu durum söz konusu değildir. Model hatalarının çapraz korelasyon grafiklerinde model artıklarının eğitim kümesi için bant dışına çıkmadığı ancak sınama kümesi için 2. girişle 2. gecikmede korelasyon içinde olduğu görülmektedir. Ancak bu aşma yüksek değerde değildir. Grafiksel performans da göz önünde bulundurularak, bulunan USBÇS modelinin Model 1 için geçerli bir model olduğu sonucuna varılmıştır.

8.1.2 Model 2 için USBÇS Modeli

Model 2: u_1: düşük mal, u_2: demir cevheri, y_2: kireç standardı (ML)

Model 2 için USBÇS yapılandırması giriş-çıkış parametreleri açısından Model 2 için YSA yapılandırmasının aynısıdır. Model 2 için yapılandırılacak USBÇS modelinde çıkış $y_2(t)$, girişler ise $u_1(t-2)$, $u_2(t-1)$ ve $y_2(t-1)$' dir. Model 2 için USBÇS sisteminin blok diyagramı Şekil 8.7' de verilmiştir.



Şekil 8.7 Model 2 için USBÇS blok diyagramı

Model 2 için denenen USBÇS yapılandırmalarından bazıları Tablo 8.3' de verilmiştir. 'Girişlerin Üyelik Fonksiyonları Sayısı' sütunundaki sayılar sırasıyla ise u_1, u_2 ve çıkışın bir gecikmeli geri beslenmişinin üyelik fonksiyonu sayılarıdır.

Tablo 8.3 Model 2 için bazı USBÇS yapılandırmaları

Yapılandırma	Girişlerin Üyelik Fonksiyonu Sayısı	Çevrim Sayısı	Hataların Karesel Ortalaması (HKO)	
			Eğitim Kümesi	Sınama Kümesi
1	2-2-2	100	0,6600	0,6725
2	2-2-2	200	0,6525	0,6790
3	3-2-2	100	0,5869	0,7327
4	2-3-2	100	0,6301	0,5729
5	2-4-2	50	0,6142	0,5208
6	3-3-2	100	0,5527	0,6841
7	3-3-2	200	0,5451	0,6906
8	3-3-3	100	0,4996	0,6812
9	3-3-3	200	0,4905	0,7085
10	3-4-2	100	0,4935	0,7073
11	4-3-2	100	0,5179	0,8374

Tablo 8.3' den görüleceği gibi, Model 2 için en düşük sınama verisi hatasını üreten yapılandırma 5. yapılandırmadır. Ne var ki, bu yapılandırma için eğitim verisi açışından en düşük hatayı veren yapılandırma değildir. Ayrıca, Model 1 için USBÇS yapılandırmasında gözlenen durum burada da gözlenmektedir; USBÇS eğitiminde aynı giriş üyelik fonksiyonu sayısına sahip yapılandırmalarda, çevrim sayısı arttıkça eğitim kümesi hatasının kararlı bir şekilde düşmektedir. Ancak bu durum sınama kümesinde aynı değildir. Sınama kümesinin hataları çevrim sayısı genelde artma eğilimindedir.

Geri beslenen çıkışın üyelik fonksiyonu sayısının arttırılmasının eğitim kümesi hatasını azalttığı ancak sınama kümesi hatasını ciddi anlamda değiştirmediği görülmüştür (yapılandırma 6 ve 8 karşılaştırılabilir). Ayrıca, genel olarak u_1 ve u_2 girişlerinin üyelik fonksiyonu sayısını arttırmak eğitim hatasının azalmasıyla sonuçlanmaktadır (yapılandırma 1, 6, 10 ve 11 karşılaştırılabilir). Özel olarak ise u_1 girişinin üyelik fonksiyonu sayısını arttırmak sınama kümesi hatasını ciddi anlamda arttırmıştır (yapılandırma 4, 6 ve 11 karşılaştırılabilir). Yapıyı basit tutmanın hesap yükü açısından avantajını göz önünde bulundurarak, geri beslenen çıkışın üyelik fonksiyonu 2 olarak belirlenmiştir. Öte yandan, yukarıda bahsedilen sebeplerden ötürü ikinci girişin üyelik fonksiyonu yüksek, birinci girişinkini ise düşük tutmak gerektiğine karar verilmiştir. Bu durumda performanstan fazla ödün vermeden

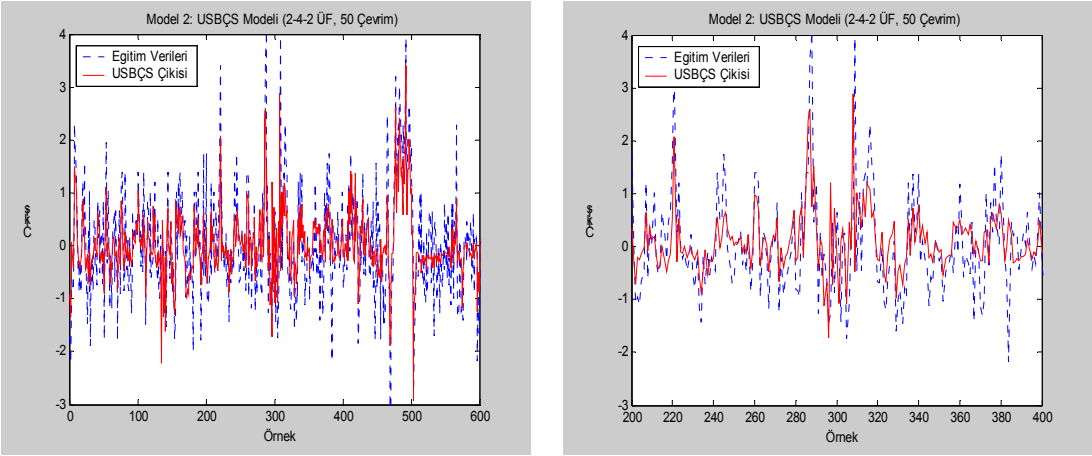
yapılabilecek seçim yapılandırma 5 olacaktır. Yapılandırma 5' in yapısı ve sonuçları Tablo 8.4' de verilmiştir.

Tablo 8.4 Model 2 için seçilen USBÇS modelinin parametre ve sonuçları

Girişlerin Üyelik Fonksiyonu Sayısı	Çevrim Sayısı	Hataların Karesel Ortalaması (HKO)	
		Eğitim Kümesi	Sınama Kümesi
2-4-2	50	0,6142	0,5208

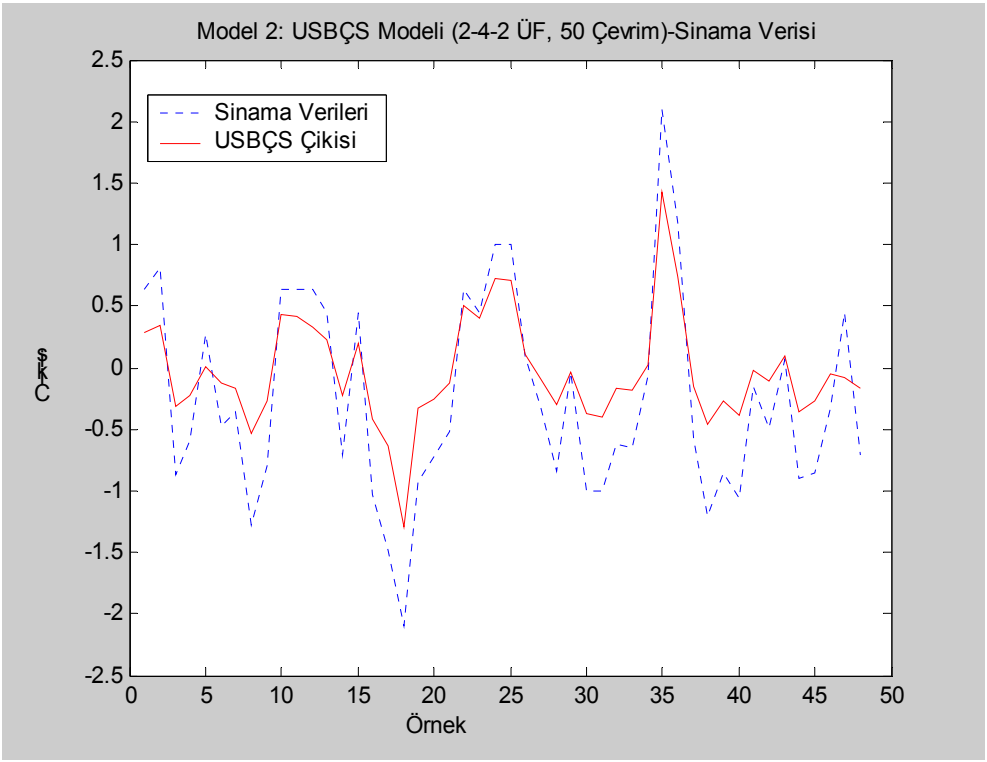
Bu yapılandırma için sırasıyla 100 ve 200 çevrim denenmiş, çevrim sayısı arttıkça eğitim hatasının azaldığı ancak sınama hatasının kararlı olarak arttığı gözlenmiştir. Modelin grafiksel performansı da gözle görülür düzeyde değişmemiştir. Bu nedenle 50 çevrim hem performans hem hesap yükünün azlığından dolayı tercih edilmiştir.

Şekil 8.8' de seçilen USBÇS modelinin eğitim verisi ile karşılaştırılması verilmektedir. Şeklin sağ tarafındaki grafikte aynı kümenin 200 ile 400. örnekleri arasındaki 200 veri için büyültülmüş şekli görülmektedir.



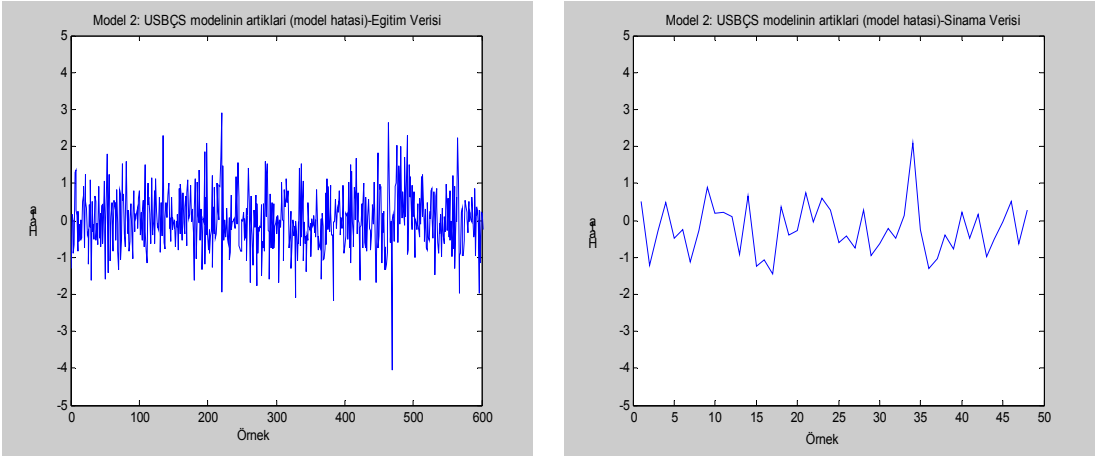
Şekil 8.8 Model 2 için seçilen USBÇS modelinin eğitim verisi çıkışları

Şekil 8.9' de Model 2 için seçilen USBÇS' nin sınama verileri için grafik performansı verilmiştir.



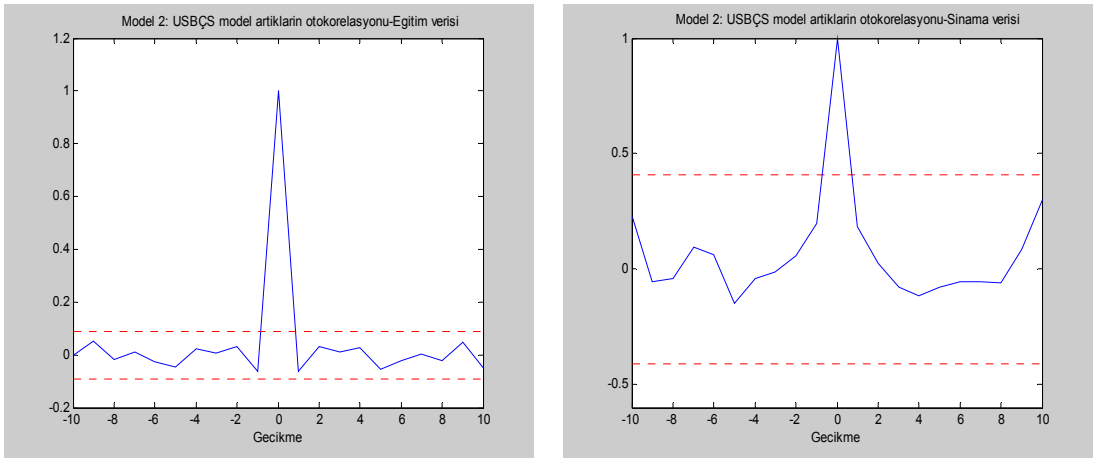
Şekil 8.9 Model 2 için seçilen USBÇS modelinin sınama verisi çıkışları

Model 2 için seçilen USBÇS modelinin artıkları eğitim ve sınama kümeleri için Şekil 8.10' de verilmiştir.



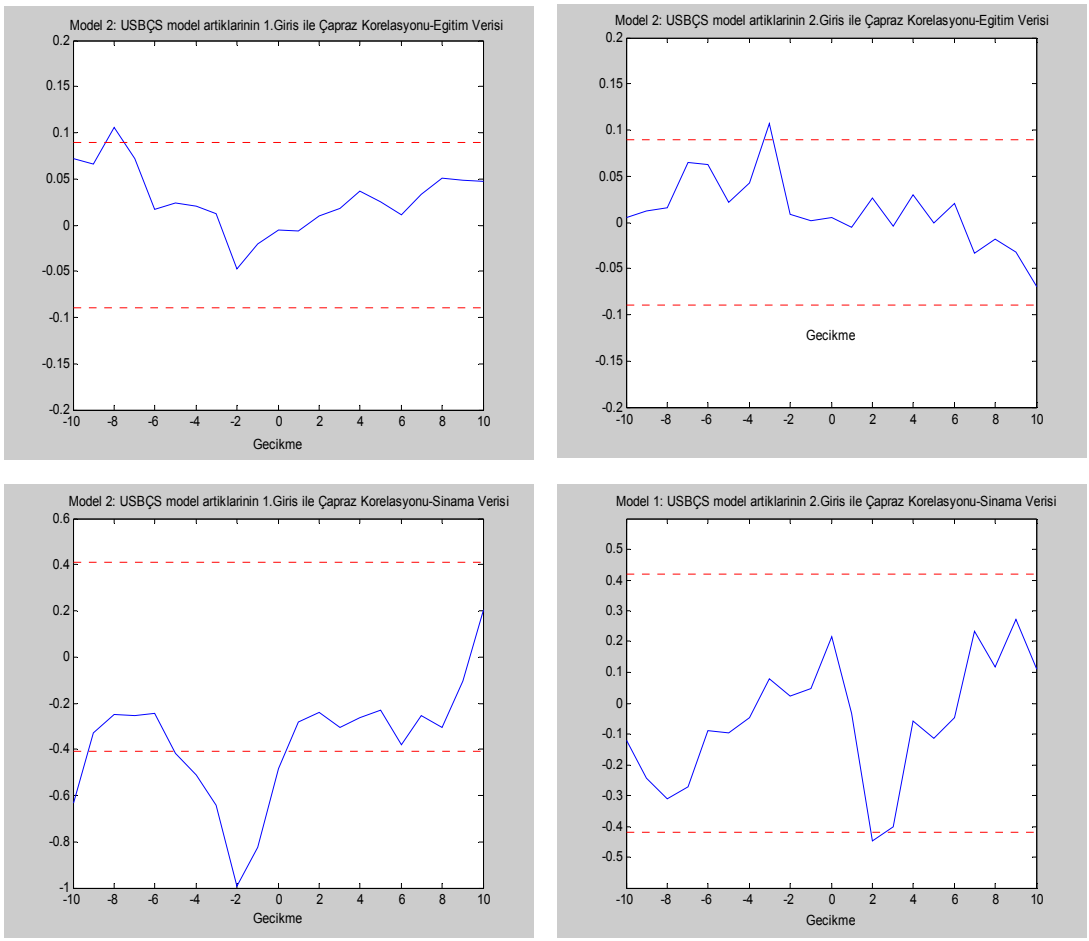
Şekil 8.10 Model 2 için USBÇS modelinin eğitim ve sınama kümeleri için artıkları

Eğitim verisi ve sınama verisi için artıkların % 97 güven aralığında otokorelasyon grafiği 10 gecikme için Şekil 8.11' da verilmiştir.



Şekil 8.11 Model 2 için USBÇS model artıklarının otokorelasyonu

Eğitim verisi ve sınama verisi için artıkların her iki girişle çapraz korelasyonu grafiği 10 gecikme için Şekil 8.12' da verilmiştir.



Şekil 8.12 Model 2 için USBÇS modelinin artıklarının girişlerle çapraz korelasyonu

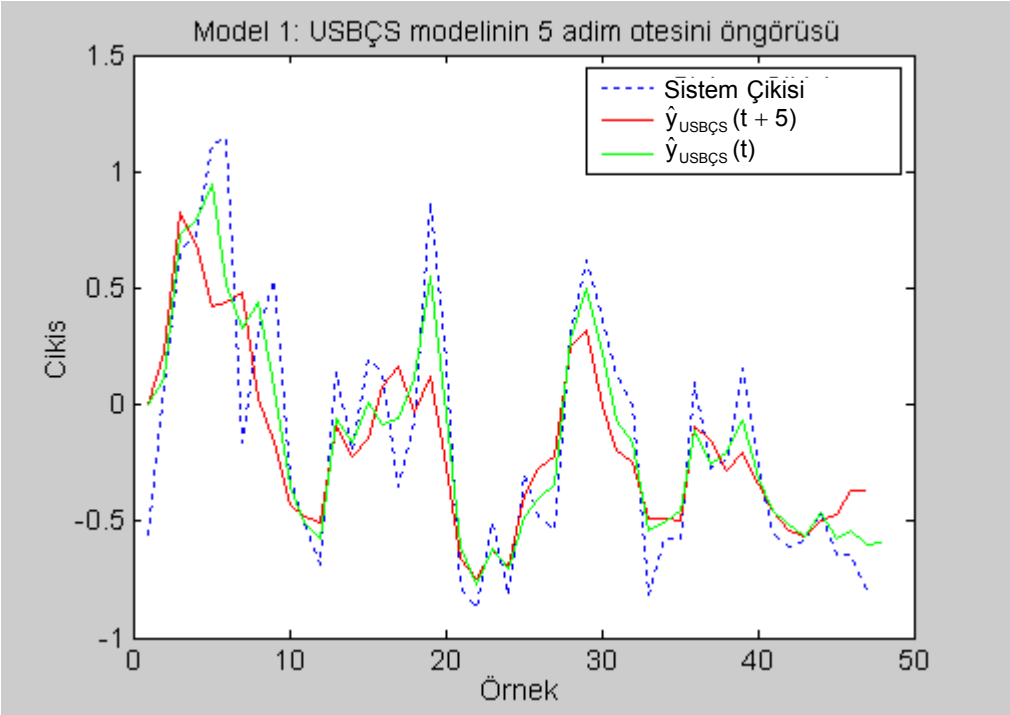
Model artıklarının otokorelasyon grafiklerinden görüldüğü gibi Model 2 için belirlenen USBÇS modelinin artıklarının otokorelasyonu % 97 güven aralığını aşmamaktadır. Model hatalarının çapraz korelasyon grafiklerinde model artıklarının eğitim kümesi için pozitif kısımda bant dışına çıkmadığı görülmektedir. Model 1 için USBÇS modelinde olduğu gibi, artıkların sınama kümesi için 2. girişle 2. gecikmede korelasyon içinde olduğu görülmektedir. Aşmanın değeri model geçerliliğini reddedecek ölçüde yüksek değildir. Belirlenen USBÇS modeli, Model 2 için geçerli bir modeldir.

8.2 USBÇS Modellerinin Öngörü Kapasiteleri

ARX ve YSA modellerinde olduğu gibi USBÇS modellerinin de öngörü kapasitelerinin incelenmesi, modellerin, gelecekte kullanılabileceği öngörülü kontrol algoritmalarında sistem modeli olarak başarımını sorgulamak için önemlidir. ARX ve YSA modellerinde olduğu gibi USBÇS modellerinde de öngörü ufku 5 olarak seçilmiştir. USBÇS modelinin, sistemin 5 adım ötedeki çıkışını ($y_p(t)$) öngörmesi için (t-5) anında modele giriş olarak, o andaki gerçek çıkışın model yapısıyla belirlenen kadar geciktirilmişi ve sistemin gerçek girişleri verilir. Sonraki adımlarda model kendi ürettiği çıkışları kullanır. İyi bir sistem modelinden beklenen modelin çıkışının sistem çıkışını olabildiğince iyi yakalayabilmesidir.

8.2.1 Model 1 için USBÇS Modelinin 5 Adım Ötesini Öngörüsü

Son 50 veri (sınama verisi) için sistemin çıkışı, USBÇS modelinin öngörüsüz çıkışı ($\hat{y}_{USBÇS}(t)$) ve öngörülü çıkışı ($\hat{y}_{USBÇS}(t+5)$) Şekil 8.13' de verilmiştir.



Şekil 8.13 Model 1 için USBÇS modelin sınama kümesi için 5 adım ötesini öngörüsü

Model 1 için USBÇS modelinin 5 adım ötesini öngörüsü, genel anlamda modelin öngörüsüz çıkış karakteristiğine yakın özellik sergilemektedir. Ancak, öngörüsüz çıkışın noktasal olarak öngörülü çıkıştan daha hassas değerler verdiği görülmektedir. Öngörülü çıkışın gerçek çıkışla arasındaki öngörü hatası HKO cinsinden Tablo 8.5' de verilmiştir.

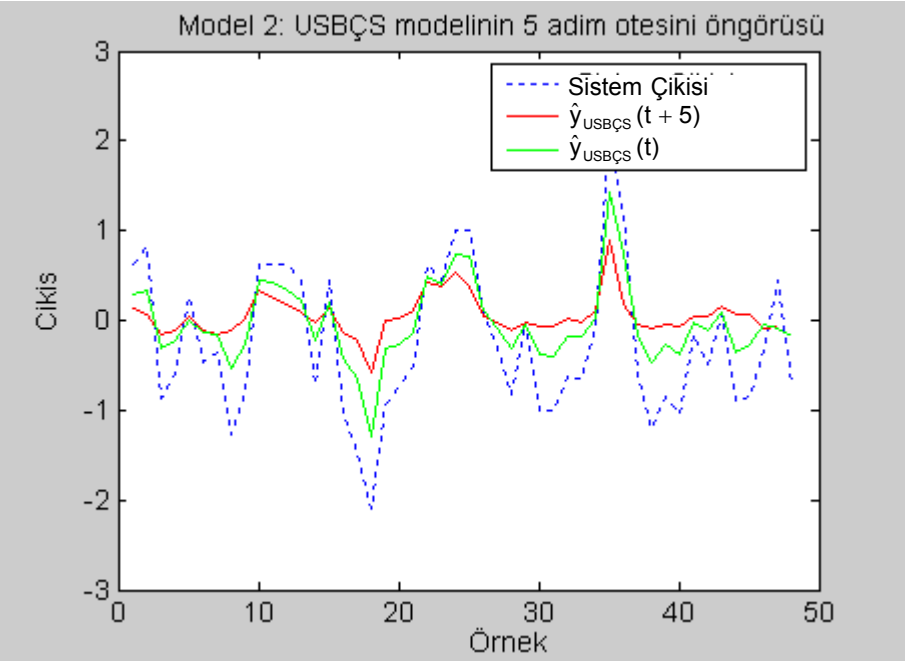
Tablo 8.5 Model 1 için USBÇS modelinin öngörü hataları

	Tanılama Verisi	**Sınama Verisi**
HKO	0,3223	0,1026

HKO yönünden incelendiğinde öngörülen çıkışın, öngörüsüz çıkışa göre hem eğitim hem de sınama kümeleri için daha fazla hata verdiği görülmektedir. Ancak yine de grafik performanstan da görüleceği gibi öngörülü model, sistemin dinamiğini kestirebilmektedir.

8.2.2 Model 2 için USBÇS Modelinin 5 Adım Ötesini Öngörüsü

Son 50 veri (sınama verisi) için sistemin çıkışı, YSA modelinin öngörüsüz çıkışı ($\hat{y}_{USBÇS}(t)$) ve öngörülü çıkışı ($\hat{y}_{USBÇS}(t+5)$) Şekil 8.14' de verilmiştir.



Şekil 8.14 Model 2 için USBÇS modelin sınama kümesi için 5 adım ötesini öngörüsü

Model 2 için USBÇS modelinin 5 adım ötesini öngörüsü, sistem çıkışındaki değişimleri belli ölçüde takip edebilmekte fakat modelin öngörüsüz çıkıştan daha az uyum sağlayabilmektedir. Sistemin karmaşıklığı, öngörü performansını da olumsuz etkilemektedir. Öngörülü çıkışın gerçek çıkışla arasındaki öngörü hatası HKO cinsinden Tablo 8.6' de verilmiştir.

Tablo 8.6 Model 2 için USBÇS modelinin öngörü hataları

	Tanılama Verisi	**Sınama Verisi**
HKO	0,9473	0,7073

Beklendiği gibi, modelin öngörü performansı, çıkış hatası yönünden incelendiğinde de öngörülen çıkışın, öngörüsüz çıkışa göre daha fazla hata verdiği görülmektedir.

9. SONUÇLAR VE TARTIŞMA

Bu çalışmada, çimento endüstrisinde hammadde harmanlama prosesinin klasik ve akıllı yöntemler ile modellenmesi incelenmiştir. Harmanlama prosesi, öncelikle sistem tanılamada yaygın olarak kullanılan lineer parametrik bir model yapısı olan ARX model olarak tanılanmıştır. Daha sonra sistem, yapay sinirsel ağlar (YSA) ve sinirsel-bulanık çıkartım sistemi ile modellenmiştir.

Çimento endüstrisinde hammadde harmanlama prosesi, proses karakteristiği itibariyle, stokastik ve rastgele bozucuların etkisinde bir prosestir. Bu durumun sebebi, harmanlamada kullanılan hammaddelerin oksit içeriklerinin rastgele değişkenlik göstermesidir. Çimento kalitesi, sistemin girişleri olan üç hammaddenin içinde de bulunan ve farklı hammadde partileri arasında değişkenlik gösteren 4 oksit tarafından belirlenir. Bu oksitler; Kalsiyum Oksit (CaO), Silisyum Oksit (SiO_2), Demir Oksit (Fe_2O_3) ve Alüminyum Oksit (Al_2O_3)'tir. Optimal kalitede çimento elde edilmesi için harmanlanmış yarı mamulün kimyasal içeriğinde bu dört oksitin miktarlarının toplam mamul ağırlığına oranı belli (ve sabit)' dir. Bu standart miktarlardan büyük sapmalar hem çimento kalitesini azaltmakta hem de üretim maliyetini arttırmaktadır. Prosese ait bu bilgiler ışığında, üç hammaddenin giriş miktarlarını ayarlayarak harmanlanmış mamulün içindeki oksit oranlarını optimum oranlar etrafında tutabilecek bir kontrol sistemi tasarımı amaçlanmaktadır. Bütün kontrol sistemlerinin tasarımında ilk adım olan sistemin bir matematik modelinin elde edilmesi bu yüzden zorunludur. Sistem, yapısı itibariyle deterministik bir model çıkarılmasına müsaade etmediği için, sistem tanılama gibi deneysel yöntemler sistemin modelinin elde edilmesinde tek alternatiftir.

Harmanlama prosesi için iki ayrı model üzerinde çalışılmıştır. Bu modellerin girişleri aynı çıkışları ise farklıdır. Her iki model de iki giriş-bir çıkışlıdır. Modellerin girişleri aynı (düşük mal ve demir cevheri), birinci modelin çıkışı demir oksit, ikinci modelin çıkışı ise dört oksitin lineer bir kombinasyonu olarak 'hesaplanan' kireç standardıdır.

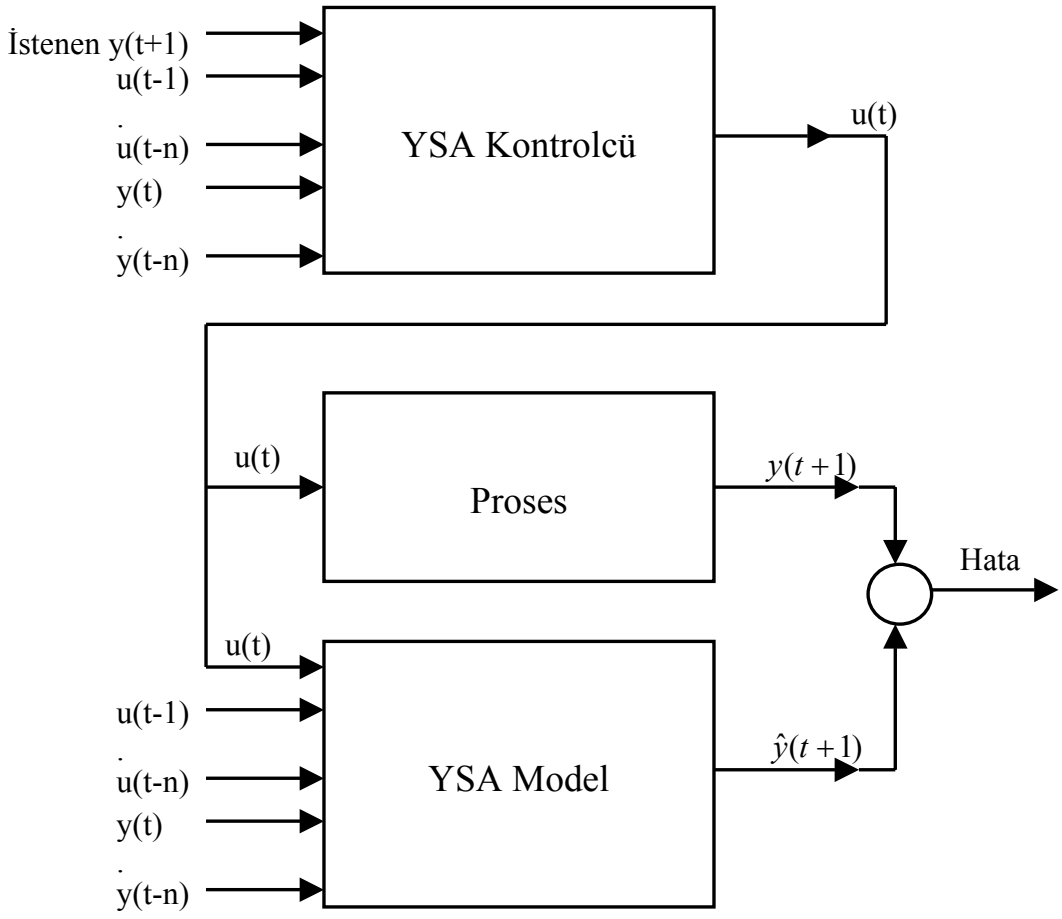
Sistem tanılamada yaygın olarak kullanılan lineer parametrik yöntemler tanılanacak sistemin lineer karakteristiğe sahip olduğu veya sistemin çalışma noktası etrafından büyük sapmalar göstermediği için o nokta etrafında lineerleştirilebileceği kabulüne dayanır. Lineer modellerin tercih edilmesinde en önemli iki sebep vardır. Bunlardan birincisi farklı ve birleştirilmiş girişlerin çıkış üzerindeki etkisinin net olarak gözlenebilmesi (süperpozisyon özelliği), ikincisi ise lineer olmayan tanılama yöntemlerini uygulamanın karşılaştırılamayacak derecede zor olmasıdır [30]. Ne var ki, gerçekte karşılaşılan birçok sistem lineer olmayan karakteristiğe sahip olduğu gibi bazı sistemlere istemli olarak lineer olmayan eklemeler yapılır (güvenlik önlemi olarak eklenen röleler, voltaj kesiciler vb.). Bu gibi durumlarda, sistemin lineer tanılamayla elde edilen modelinin sistemi geniş bir çerçevede başarıyla temsil etmesi beklenemez. Ayrıca, bu sistem modeli kullanılarak tasarlanan kontrol sisteminin de başarısının yüksek olması mümkün değildir.

Öte yandan özellikle son yıllarda lineer olmayan proses tanılamada akıllı sistemlerden olan yapay sinir ağlarının (YSA) kullanımı yaygın hale gelmiştir. Bunun sebebi YSA' nın lineer olmayan fonksiyonları da başarıyla öğrenebilmesi ve yakınsayabilmesidir. Bu durum karmaşık lineer olmayan yapılı prosesler için de YSA' nın kullanılabilmesini mümkün kılar. Literatürde YSA' nın tanılama ve kontrol için kullanıldığı örnekler gün geçtikçe artmaktadır [11, 27, 30, 31].

Diğer bir akıllı yöntem olan sinirsel-bulanık çıkartım sistemi, YSA ile bulanık mantık yaklaşımının bir sentezidir. Aynı şekilde sinirsel-bulanık çıkartım sisteminin de doğrusal olmayan fonksiyonlara yakınsayabildiği bilinmektedir [8]. Bu çalışmada kullanılan Uyarlanabilir Sinirsel-Bulanık Çıkartım Sisteminin (USBÇS) YSA üzerine bir avantajı, YSA' da olduğu gibi eğitim başlangıcında rastgele ağ ağırlıkları atamanın söz konusu olmamasıdır. Bunun sonucu olarak, USBÇS çıkışların tekrarlanabilirliği konusunda daha kararlıdır. Diğer bir deyişle, aynı parametrelerle ve veriyle eğitilen bir USBÇS her zaman aynı çıkışı sağlayacaktır. Ancak YSA' da modelin genel performansı büyük ölçüde parametrelere bağlı olmakla beraber, aynı parametrelerle farklı denemelerde birbirinden farklı sonuçlar elde etmek mümkündür. Öte yandan USBÇS' nin dezavantajı eğitim için gereken sürelerin YSA' ya göre çok daha uzun olabilmesidir. Sayısal olarak; bir P4, 2.4 GHz bilgisayarda, aynı model için (Model 1) momentumlu uyarlanabilir öğrenme oranıyla

20000 çevrim YSA eğitimi 5 dakika sürerken, 100 çevrimli USBÇS eğitimi 18 dakika sürmektedir. Bunun temel sebebi, USBÇS' nin her çevrimde güncellemek durumunda olduğu lineer ve lineer olmayan parametre sayısının çokluğudur.

Üretilen modellerin öngörü performanslarının karşılaştırılması, modelin ilerde sistem modeli olarak kullanılabileceği öngörülü kontrol algoritmalarındaki başarısını kestirebilmek için iyi bir yöntemdir. Öngörülü kontrolün temelinde modelin sistemin o andan birkaç adım sonraki çıkışını tespit etmesi, istenen çıkışla karşılaştırması ve o andaki girişi, istenen çıkışı sağlayacak şekilde yeniden hesaplanması söz konusudur. Modelin öngörü yeteneğinin kontrolün performansını belirleyeceği açıktır. Örnek olarak, bir giriş-bir çıkışlı bir sistemin YSA modelinin bir adım ötesini öngören sistem modeli ve kontrolcü olarak kullanılabileceği bir kontrol sisteminin blok diyagramı Şekil 9.1' de verilmiştir. Bundan amaç, ileriki aşamalarda YSA veya USBÇS model tabanlı kontrol sistemi tasarımında sistem modelinin ve modelin öngörü yeteneğinin öneminin vurgulanmasıdır.



Şekil 9.1 YSA model tabanlı öngörülü kontrol sistemi blok diyagramı

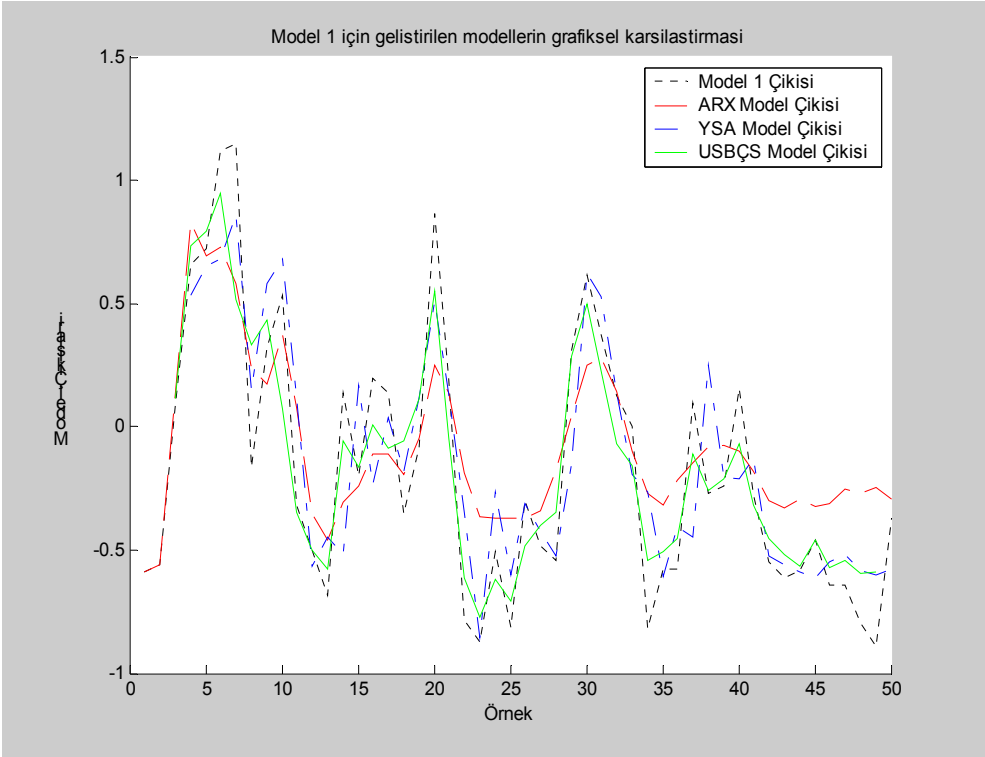
9.1 Model 1 için Belirlenen Modellerin Karşılaştırılması

Model 1 için sistem tanılama çalışması lineer parametrik olarak ARX model yapısıyla, ve akıllı yöntemlerden YSA ve USBÇS ile yapılmıştır. Her bir yöntem için belirlenen modelin çıkışlarının gerçek sistem çıkışlarıyla arasındaki fark (model hataları), hataların karesel ortalaması (HKO) cinsinden Tablo 9.1' de verilmiştir.

Tablo 9.1 Model 1 için çeşitli modellerin hatalarının karesel ortalaması

	Hataların Karesel Ortalaması (HKO)	
	Eğitim/Tanılama Verisi	Sınama Verisi
Lineer Parametrik (ARX Model)	0,3899	0,1142
YSA	0,2373	0,0887
USBÇS	0,1664	0,0709

Modellerin sınama verisi (son 50 veri) için çıkışlarının grafiksel gösterimi Şekil 9.2' de verilmiştir.



Şekil 9.2 Model 1 için çeşitli modellerin çıkışları

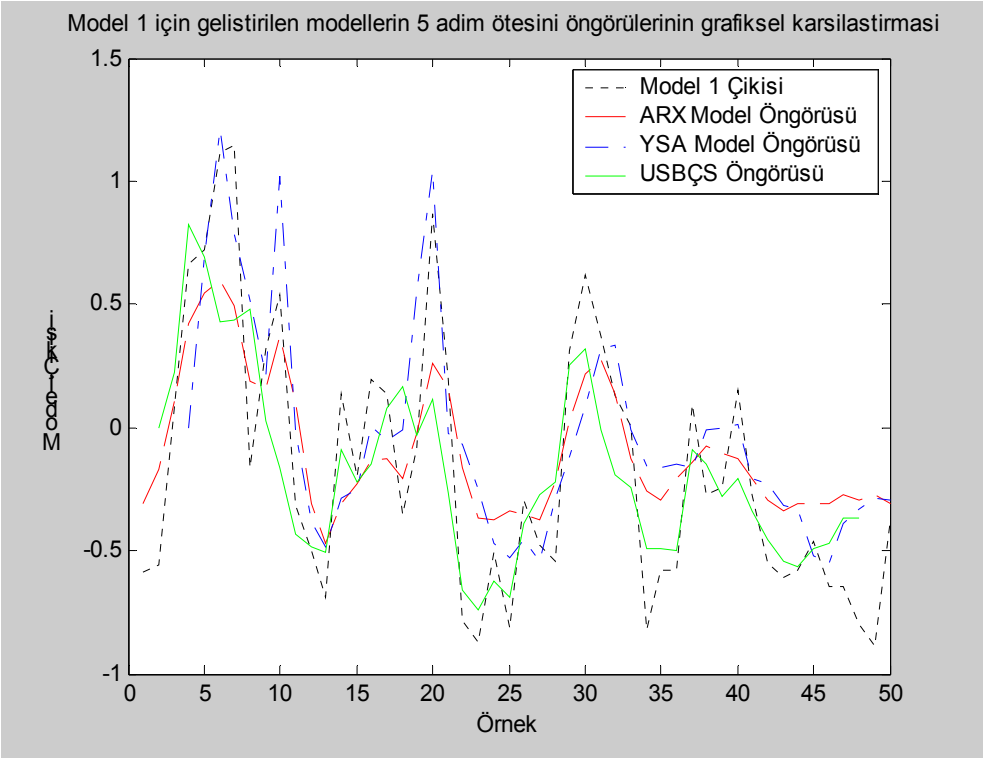
Tablo 9.1' den görüldüğü gibi Model 1 için en düşük eğitim/tanılama ve sınama verisi hatasını veren yöntem USBÇS' dir. Ayrıca Şekil 9.2' den görüldüğü gibi bu modelin grafiksel performansı (sistemin çıkışındaki değişimleri izleyebilmesi) da diğer modellere göre daha iyidir. USBÇS ve YSA' nın çıkış hataları birbirine yakın ve ARX modelin çıkış hatası ikisinden de fazladır. Akıllı yöntemlerin bu modelin tanılanmasında daha başarılı olduğu sonucuna varılmıştır.

Tablo 9.2' de Model 1 için belirlenen modellerin 5 adım ötesini öngörü hataları verilmektedir.

Tablo 9.2 Model 1 için belirlenen modellerin öngörü hataları (HKO)

	Hataların Karesel Ortalaması (HKO)	
	Eğitim/Tanılama Verisi	Sınama Verisi
Lineer Parametrik (ARX Model)	0,3777	0,1069
YSA	0,2879	0,0982
USBÇS	0,3223	0,1026

Modellerin sınama verisi (son 50 veri) için öngörülü çıkışlarının grafiksel gösterimi Şekil 9.3' de verilmiştir.



Şekil 9.3 Model 1 için çeşitli modellerin 5 adım ötesini öngörü çıkışları

Model 1 için çeşitli modellerin içinde öngörü yeteneği en iyi olan model YSA modelidir. Öngörüsüz durumda USBÇS' nin daha iyi sonuç verdiği görülmüştü. Ancak öngörülü durumda YSA modelinin öngörü yeteneğinin bu model için USBÇS' den daha iyi olduğu sonucu ortaya çıkmaktadır. YSA' nın öngörü hataları ARX modele göre düşük kalırken USBÇS modeli ARX modele yakın hata vermiştir. Öngörü grafiğinin incelenmesinden de YSA modelin sistem çıkışlarını daha iyi tahmin ettiği sonucuna varılmaktadır.

9.2 Model 2 için Belirlenen Modellerin Karşılaştırılması

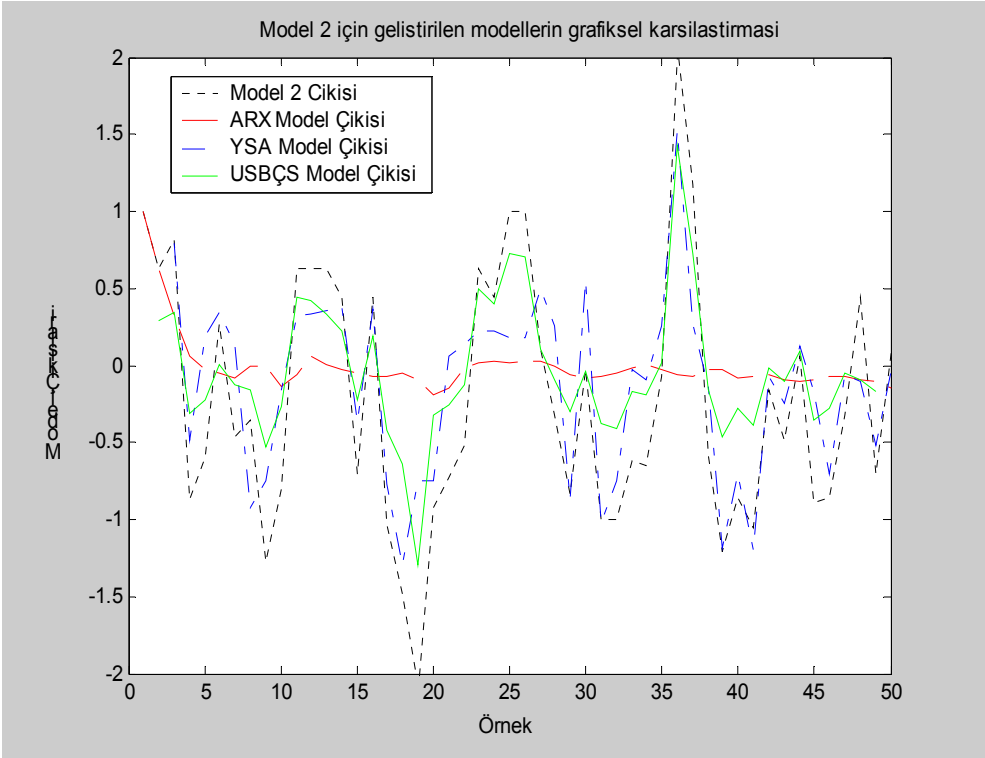
Model 2 için de Model 1 için kullanılan yöntemler kullanılmıştır. Her bir yöntem için belirlenen modelin model hataları hataların karesel ortalaması (HKO) cinsinden Tablo 9.3' de verilmiştir.

Tablo 9.3 Model 2 için çeşitli modellerin hatalarının karesel ortalaması

	Hataların Karesel Ortalaması (HKO)	
	Eğitim/Tanılama Verisi	Sınama Verisi
Lineer Parametrik (ARX Model)	0,9669	0,6606
YSA	0,6163	0,5831
USBÇS	0,6142	0,5208

Modellerin sınama verisi (son 50 veri) için çıkışlarının grafiksel gösterimi Şekil 9.4' de verilmiştir.

Tablo 9.3' den görüldüğü gibi Model 2 için en düşük eğitim/tanılama ve sınama verisi hatasını veren yöntem yine USBÇS' dir. Ancak bu yöntemin verdiği hatalar YSA modelinin hatalarına çok yakındır. Buna ek olarak, Şekil 9.4' de verilen model çıkışlarından görüldüğü gibi bu model için en iyi grafiksel performansı YSA modeli sağlamaktadır. Bu nedenle Model 2 için seçilen model YSA modelidir. Ayrıca Şekil 9.4' de YSA modelinin sistemin karmaşık dinamiğini ARX modelden çok daha iyi temsil edebildiği de görülmektedir. Genel olarak bu model için de akıllı yöntemlerin modellemede daha başarılı olduğu sonucuna varılmıştır.



Şekil 9.4 Model 2 için çeşitli modellerin çıkışları

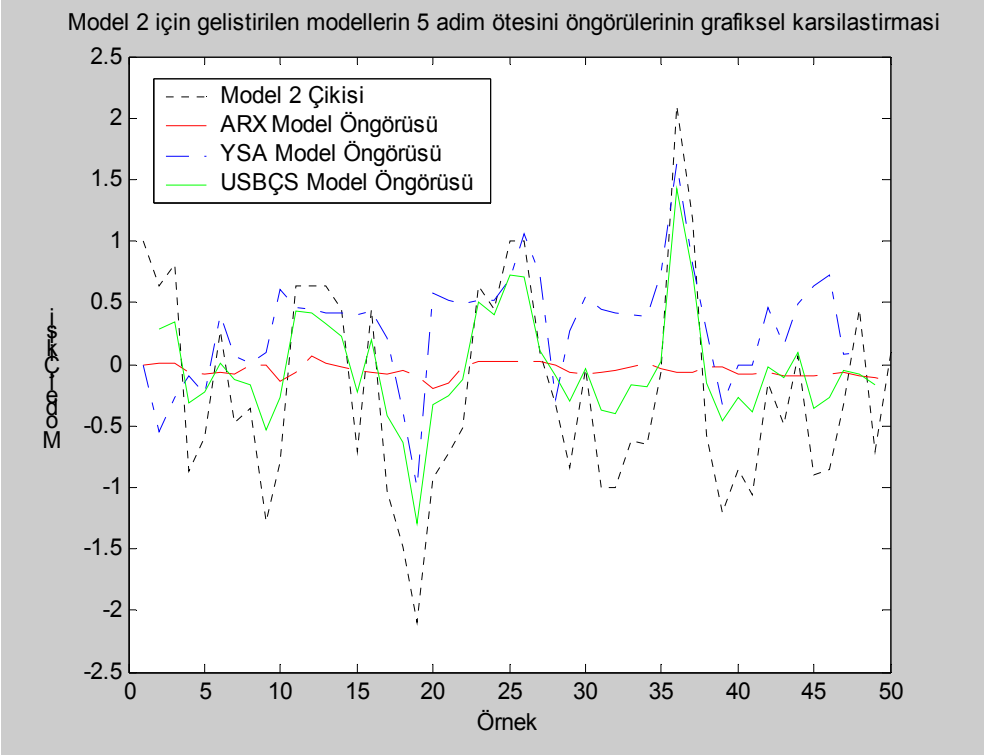
Tablo 9.4' de Model 2 için belirlenen modellerin 5 adım ötesini öngörü hataları verilmektedir.

Tablo 9.4 Model 2 için belirlenen modellerin öngörü hataları (HKO)

	Hataların Karesel Ortalaması (HKO)	
	Eğitim/Tanılama Verisi	Sınama Verisi
Lineer Parametrik (ARX Model)	0,9484	0,6715
YSA	0,7218	0,6352
USBÇS	0,9473	0,7073

Modellerin sınama verisi (son 50 veri) için öngörülü çıkışlarının grafiksel gösterimi Şekil 9.5' de verilmiştir.

Model 2 için çeşitli modellerin içinde öngörü yeteneği en iyi olan model öngörüsüz durumda olduğu gibi YSA modelidir. YSA' nın öngörü hataları ARX modele göre düşük kalırken USBÇS modeli ARX modele yakın hata vermiştir. Öngörü grafiğinin incelenmesinden de YSA modelin sistem çıkışlarını daha iyi tahmin ettiği sonucuna varılmaktadır.



Şekil 9.5 Model 2 için çeşitli modellerin 5 adım ötesini öngörü çıkışları

Her iki model için de belirlenen modellerin karşılaştırılmasında YSA yönteminin öngörü yeteneğinin diğer iki yönteme göre daha iyi olduğu gözlenmiştir. Öngörüsüz durumda USBÇS yönteminin de başarılı sonuçlar verdiği görülmektedir. Ancak incelenen iki Modelin karşılaştırılmasından ortaya çıkan sonuç, YSA' nın karmaşıklığı yüksek modellerde (Model 2 gibi) daha iyi performans verdiğidir. USBÇS' nin hesap yükünün YSA' ya göre daha çok olduğu da göz önüne alınarak bu sistemin modellemesinde üç yöntem arasında YSA' nın tercih edilebileceği sonucuna varılmıştır.

KAYNAKLAR

[1] **Aström, K.J. and Bohlin, T.,** 1965. Numerical identification of linear dynamic systems from normal operating records, *IFAC Symposium on Self-Adaptive Systems,* Teddington, England.

[2] **Ljung, L.,** 1986. The System Identification Toolbox: The Manual, Natick, MA.

[3] **Eykhoff, P.,** 1974. System Identification, Wiley, New York.

[4] **Goodwin, G.C. and Payne, R.L.,** 1977. Dynamic System Identification: Experiment Design and Data Analysis. Academic Pres, New York.

[5] **Söderstrom, T. and Stoica, P.,** 1989. System Identification. Prentice-Hall, London.

[6] **Ljung, L.,** 1987. System Identification – Theory for the User. Prentice-Hall, Englewood Cliffs, New Jersey.

[7] **Hagan, M.T., Demuth, H.B., Beale, M.,** 1995. Neural Network Design, PWS Publishing, Boston.

[8] **Jang, J-S. R., Sun, T., Mizutani, E.,** 1997. Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence, Prentice-Hall, New Jersey.

[9] **Bhat, N., McAvoy, T.J.,** 1990. Use of neural nets for dynamic modeling and control of chemical process systems, *Computers in Chemical Engineering,* **14,** 573-583.

[10] **Radhakrishnan, V.R. Mohamed, A.R.,** 2000. Neural Networks for identification and control of blast furnace hot metal quality, *J. of Process Control,* **10,** 509-524.

[11] **Lennox, B., Montague, G.A., Frith, A.M., Gent, C. Bevan, V**., 2001. Industrial application of neural networks-an investigation, *J. of Process Control,* **11,** 497-507.

[12] **Kural, A.,** 2001. Çimento endüstrisinde harmanlama prosesinin tanılanması ve öngörülü kontrolü, *Doktora Tezi,* İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul.

[13] **Bogue, R.H.,** 1955. Chemistry of Portland Cement, Reinhold, New York.

[14] **Zorlu, A.,** 2002. Pnömatik bir sistemin deneysel modellenmesi ve simülasyonu, *Doktora Tezi,* İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul.

[15] **O'nan, M. Enderton, H.,** 1990. Linear Algebra, Harcourt Brace Jovanovich, San Diego.

[16] **Patterson, D.W.,** 1996. Artificial Neural Networks: Theory and Applications, Prentice Hall, Inc., Singapore.

[17] **Van der Bosch, P.P.J., Van der Klauw, A.C.,** 1994. Modeling, Identification and Simulation of Dynamical Systems, CRC Press, London.

[18] **Yıldızdoğan, M.,** 1995. Yapay Sinir Ağları ile Sistem Tanıma, *Yüksek Lisans Tezi,* İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul.

[19] **Efe, Ö., Kaynak, O.,** 2000. Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi, İstanbul.

[20] **Mehrotra, K., Mohan, C.K., Sanjay, R.,** 1997. Elements of Artificial Neural Networks, MIT Press, Massachusetts.

[21] **Arslan, H.,** 1999. Yapay Sinir Ağları ile Robotlarda Hareket Kontrolü, *Doktora Tezi,* İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul.

[22] **Kartalopoulos, S.V.,** 1996. Understanding Neural Networks and Fuzzy Logic; Basic Concepts and Applications, IEEE Press, New York.

[23] **Hines, J.W.,** 1997. Matlab Supplement to Fuzzy and Neural Approaches in Engineering, John Wiley & Sons Inc., Canada.

[24] **Jang, J-S. R., Sun, T.,** 1995. Neuro-fuzzy modeling and control, *Proc. of IEEE*, 83, 378-405.

[25] **Ertuğrul, Ş., Uçar, N.,** 2000. Predicting bursting strength of cotton plain knitted fabrics using intelligent techniques, *Textile Research Journal,* **70**, 845-851.

[26] **Moscinski, J., Ogonowski, Z.,** 1995. Advanced Control with Matlab & Simulink, Ellis Harwood, London.

[27] **Soloway, D., Haley, P.J**., 1997. Neural Generalized Predictive Control: A Newton-Raphson Implementation, NASA Technical Memorandum 110244, Hampton, Virginia.

[28] **Narendra, K.S., Parthasarathy, K.,** 1990. Identification and control of dynamic systems using neural networks, *IEEE Trans. on Neural Networks,* **1**, 1-24.

[29] **Kızılaslan, K., Ertuğrul, Ş., Kural, A., Özsoy, C.,** 2003. A comparative study on modeling of raw material blending process in cement industry using conventional and intelligent techniques, *IEEE Int. Conference on Control Applications,* İstanbul, Turkey, June 23-25.

[30] **Liu, G.P.,** 2001. Nonlinear Identification and Control: A Neural Network Approach, Springer, London.

[31] **Pao, Y-H, Phillips, S.M., Sobajic, D.J.**, 1994. Neural net computing and the intelligent control of systems, in *Advances in Intelligent Control*, pp. 56-83, Ed. Haris, C.J., Taylor&Francis, London.

ÖZGEÇMİŞ

Kemal KIZILASLAN 1979 yılında Gaziantep' te doğdu. İlk, orta ve lise eğitimini Gaziantep' te tamamladı. 2001 yılında İTÜ Makina Fakültesi, Makina Mühendisliği bölümünden mezun oldu. Aynı yıl İTÜ Makina Fakültesi, Otomatik Kontrol Laboratuvarı' nda araştırma görevlisi olarak çalışmaya ve İTÜ Fen Bilimleri Enstitüsü Makina Teorisi, Sistem Dinamiği ve Kontrol Programı'nda yüksek lisansa başladı. KIZILASLAN, şu anda akademik çalışmalarını yurtdışında devam ettirmektedir.