

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**ÇİMENTO ENDÜSTRİSİNDEKİ HARMANLAMA
PROSESİNİN DEĞİŞİK TİPTE YAPAY SİNİR AĞLARI
İLE TANILANMASI VE KIYASLANMASI**

YÜKSEK LİSANS TEZİ
Müh. Güven Emre
(503011150)

142716

İT. YÜKSEK LİSANS TEZİ
ENSTİTÜSÜNE GİRİŞ

Tezin Enstitüye Verildiği Tarih : 5 Mayıs 2003

Tezin Savunulduğu Tarih : 30 Mayıs 2003

Tez Danışmanı : Prof.Dr. Can ÖZSOY

Diğer Jüri Üyeleri Prof.Dr. Ahmet KUZUCU (İ.T.Ü.)

Prof.Dr. Vedat KARADAĞ (İ.T.Ü.)

Özsoy
Kuzucu
Karadağ

MAYIS 2003

ÖNSÖZ

Tüm çalışmam boyunca verdiği destek ve önerilerinden dolayı tez danışmanım Prof. Dr. Can Özsoy'a ve öğrenim hayatım boyunca maddi ve manevi desteğini esirgemeyen aileme en içten teşekkürlerimi iletirim.

Nisan,2003

Güven Emre



İÇİNDEKİLER

KISALTMALAR	v
TABLO LİSTESİ	vi
ŞEKİL LİSTESİ	vii
SEMBOL LİSTESİ	xi
ÖZET	xii
SUMMARY	xiii
1. GİRİŞ	1
1.1 Giriş ve Çalışmanın Amacı	1
2. ÇİMENTO ENDÜSTRİSİNDEKİ HARMANLAMA PROSESİ	3
2.1 Giriş	3
2.2 Hammadde Harmanlama Sistemi	4
2.3 Nuh Çimento Hammadde Harmanlama Prosesi	4
2.4 Çimento Üretim İşleminin Yapısı	5
2.5 Harmanlama Prosesinin Tanılanması	6
3. YAPAY SİNİR AĞLARI İLE SİSTEM TANILAMA	9
3.1 Yapay Sinir Ağları	9
3.1.1 Giriş	9
3.1.2 Nöron Modeli	9
3.1.3 YSA Mimarileri	11
3.2 YSA ile Sistem Tanılamada Kullanılan Bazı Yöntemler	13
3.2.1 Çok Katmanlı İleri Beslemeli(ÇKİB) Sinir Ağları	13
3.2.2 Radyal Bazlı Yapay Sinir Ağları	22
3.2.3 Yinelenen YSA	25
4. UYGULAMA SONUÇLARI VE TARTIŞMA	28
4.1 Uygulama Verisinin Tanıtılması	28
4.2 Model 1	28
4.2.1 Çok Katmanlı İleri Beslemeli YSA Sonuçları	29
4.2.2 Radyal Bazlı YSA Sonuçları	39
4.2.3 Yinelenen YSA Sonuçları	43
4.3 Model 2	50
4.3.1 Çok Katmanlı İleri Beslemeli YSA Sonuçları	51
4.3.2 Radyal Bazlı YSA Sonuçları	57
4.3.3 Yinelenen YSA Sonuçları	61
4.4 Model 3	65
4.4.1 Çok Katmanlı İleri Beslemeli YSA Sonuçları	65

4.4.2	Radyal Bazlı YSA Sonuçları	72
4.4.3	Yinelenen YSA Sonuçları	77
4.5	YSA Tiplerinin Kıyaslanması	82
4.5.1	Çok Katmanlı İleri Beslemeli(ÇKİB) YSA Sistem Tanılama Özellikleri	82
4.5.2	Radyal Bazlı(RB) YSA Sistem Tanılama Özellikleri	83
4.5.3	Yinelenen YSA Sistem Tanılama Özellikleri	84
5.	GENEL SONUÇLAR ve ÖNERİLER	85
	KAYNAKLAR	91
	ÖZGEÇMİŞ	93



KISALTMALAR

YSA	: Yapay Sinir Ağları
ÇKİB YSA	: Çok Katmanlı İleri Beslemeli YSA
RB YSA	: Radyal Bazlı YSA
SSE	: Hataların Kareleri Toplamı
SSW	: Ağırlıkların Kareleri Toplamı
SAE	: Hataların Mutlak Değerleri Toplamı



TABLO LİSTESİ

	<u>Sayfa No</u>
Tablo 2.1. Harmanlama prosesi besleme akış verisi	6
Tablo 5.1. Model 1 Sonuçları.....	86
Tablo 5.2. Model 2 Sonuçları.....	87
Tablo 5.3. Model 3 sonuçları	89



ŞEKİL LİSTESİ

	<u>Sayfa No</u>
Şekil 2.1: Hammadde akış diyagramı	5
Şekil 3.1: Nöron modeli.....	9
Şekil 3.2 : Vektörel girişli nöron modeli	10
Şekil 3.3: Aktivasyon fonksiyonları	10
Şekil 3.4 : Tek katmanlı YSA modeli.....	11
Şekil 3.5: Çok katmanlı YSA modeli	12
Şekil 3.6: Yinelenen YSA(Elman Ağı)	13
Şekil 3.7: Bir gizli katmanlı YSA.....	15
Şekil 3.8: Radyal bazlı nöron modeli	22
Şekil 3.9: Radyal bazlı aktivasyon fonksiyonu	23
Şekil 3.10: RB YSA mimarisi	23
Şekil 3.11: Yinelenen YSA mimarisi	26
Şekil 4.1: Model 1	28
Şekil 4.2: Model 1 için ÇKİB YSA eğitim süreci	29
Şekil 4.3: Model 1 ÇKİB YSA eğitim verisi için post-regresyon analizi	30
Şekil 4.4: Model 1 için eğitim girişi	30
Şekil 4.5: Model 1 için Eğitim Çıkışı.....	31
Şekil 4.6: Model 1 için ÇKİB YSA ve eğitim çıkışları	31
Şekil 4.7: Model 1 için ÇKİB YSA eğitim hata analizi	32
Şekil 4.8: Model 1 için ÇKİB YSA test verisi post-regresyon analizi	32
Şekil 4.9: Model 1 için test girişi.....	33
Şekil 4.10: Model 1 için test çıkışı	33
Şekil 4.11: Model 1 için ÇKİB YSA ve Test Çıkışları	34

Şekil 4.12: Model 1 için ÇKİB YSA test hata analizi	34
Şekil 4.13: Model 1 için ÇKİB YSA eğitim post-regresyon analizi	36
Şekil 4.14: Model 1 için ÇKİB YSA ve eğitim çıkışları	36
Şekil 4.15: Model 1 için ÇKİB YSA eğitim hata analizi	37
Şekil 4.16: Model 1 için ÇKİB YSA test post-regresyon analizi	37
Şekil 4.17: Model 1 için ÇKİB YSA ve test çıkışları	38
Şekil 4.18: Model 1 için ÇKİB YSA test hata analizi	38
Şekil 4.19: Model 1 için RB YSA eğitim süreci	39
Şekil 4.20: Model 1 için RB YSA eğitim post-regresyon analizi	40
Şekil 4.21: Model 1 için RB YSA ve eğitim çıkışları	40
Şekil 4.22: Model 1 için RB YSA eğitim hata analizi	41
Şekil 4.23: Model 1 için RB YSA post-regresyon analizi	41
Şekil 4.24: Model 1 için RB YSA ve test çıkışları	42
Şekil 4.25: Model 1 için RB YSA test hata analizi	42
Şekil 4.26: Model 1 için Yinelenen YSA eğitim süreci	43
Şekil 4.27: Model 1 için Yinelenen YSA eğitim post-regresyon analizi	44
Şekil 4.28: Model 1 için Yinelenen YSA ve eğitim çıkışları	44
Şekil 4.29: Model 1 için Yinelenen YSA eğitim hata analizi	45
Şekil 4.30: Model 1 için Yinelenen YSA test post-regresyon analizi	45
Şekil 4.31: Model 1 için Yinelenen YSA ve test çıkışları	46
Şekil 4.32: Model 1 için Yinelenen YSA ve test hata analizi	46
Şekil 4.33: Model 1 için Yinelenen YSA eğitim post-regresyon analizi	47
Şekil 4.34: Model 1 için Yinelenen YSA ve eğitim çıkışları	48
Şekil 4.35: Model 1 için Yinelenen YSA eğitim hata analizi	48
Şekil 4.36: Model 1 için Yinelenen YSA eğitim post-regresyon analizi	49
Şekil 4.37: Model 1 için Yinelenen YSA ve test çıkışları	49
Şekil 4.38: Model 1 için Yinelenen YSA test hata analizi	50
Şekil 4.39: Model 2	50
Şekil 4.40: Model 2 için ÇKİB YSA eğitim süreci	51
Şekil 4.41: Model 2 için ÇKİB YSA eğitim post-regresyon analizi	52

Şekil 4.42: Model 2 için eğitim girişleri.....	52
Şekil 4.43: Model 2 için eğitim çıkışları	53
Şekil 4.44: Model 2 için ÇKİB YSA ve eğitim çıkışları	53
Şekil 4.45: Model 2 için ÇKİB YSA eğitim hata analizi	54
Şekil 4.46: Model 2 için ÇKİB YSA test post-regresyon analizi	54
Şekil 4.47: Model 2 için test girişleri	55
Şekil 4.48: Model 2 test çıkışı	55
Şekil 4.49: Model 2 için ÇKİB YSA test çıkışları	56
Şekil 4.50: Model 2 için ÇKİB YSA test hata analizi	56
Şekil 4.51: Model 2 için RB YSA eğitim süreci	57
Şekil 4.52: Model 2 için RB YSA eğitim post-regresyon analizi	58
Şekil 4.53: Model 2 için RB YSA ve eğitim çıkışları	58
Şekil 4.54: Model 2 için RB YSA eğitim hata analizi.....	59
Şekil 4.55: Model 2 için RB YSA test post-regresyon analizi	59
Şekil 4.56: Model 2 için RB YSA ve test çıkışları	60
Şekil 4.57: Model 2 için RB YSA test hata analizi	60
Şekil 4.58: Model 2 için Yinelenen YSA eğitim süreci	61
Şekil 4.59: Model 2 için Yinelenen YSA eğitim post-regresyon analizi	62
Şekil 4.60: Model 2 için Yinelenen YSA ve eğitim çıkışları	62
Şekil 4.61: Model 2 için Yinelenen YSA hata analizi.....	63
Şekil 4.62: Model 2 için Yinelenen YSA post-regresyon analizi.....	63
Şekil 4.63: Model 2 için Yinelenen YSA ve test çıkışları.....	64
Şekil 4.64: Model 2 için Yinelenen YSA test hata analizi	64
Şekil 4.65: Model 3	65
Şekil 4.66: Model 3 için ÇKİB YSA eğitim süreci	66
Şekil 4.67: Model 3 için ÇKİB YSA eğitim post-regresyon analizi	66
Şekil 4.68: Model 3 girişleri	67
Şekil 4.69: Model 3 çıkışları.....	67
Şekil 4.70: Model 3 için ÇKİB YSA ve eğitim çıkışları	68
Şekil 4.71: Model 3 için ÇKİB YSA eğitim hata değerleri.....	68

Şekil 4.72: Model 3 için ÇKİB YSA eğitim hata yüzdeleri	69
Şekil 4.73: Model 3 için ÇKİB YSA test post-regresyon analizi	69
Şekil 4.74: Model 3 girişleri	70
Şekil 4.75: Model 3 çıkışları	70
Şekil 4.76: Model 3 için ÇKİB YSA ve eğitim çıkışları	71
Şekil 4.77: Model 3 için ÇKİB YSA test hata değerleri	71
Şekil 4.78: Model 3 için ÇKİB YSA test hata yüzdeleri	72
Şekil 4.79: Model 3 için RB YSA eğitim süreci	73
Şekil 4.80: Model 3 için RB YSA eğitim post-regresyon analizi	73
Şekil 4.81: Model 3 için RB YSA ve eğitim çıkışları	74
Şekil 4.82: Model 3 için RB YSA test hata değerleri	74
Şekil 4.83: Model 3 için RB YSA eğitim hata yüzdeleri	75
Şekil 4.84: Model 3 için RB YSA test hata yüzdeleri	75
Şekil 4.85: Model 3 için RB YSA ve test çıkışları	76
Şekil 4.86: Model 3 için RB YSA test hata değerleri	76
Şekil 4.87: Model 3 için RB YSA test hata yüzdeleri	77
Şekil 4.88: Model 3 için Yinelenen YSA eğitim süreci	78
Şekil 4.89: Model 3 için Yinelenen YSA eğitim post-regresyon analizi	78
Şekil 4.90: Model 3 için Yinelenen YSA ve eğitim çıkışları	79
Şekil 4.91: Model 3 için Yinelenen YSA hata değerleri	79
Şekil 4.92: Model 3 için Yinelenen YSA eğitim hata yüzdeleri	80
Şekil 4.93: Model 3 için Yinelenen YSA test hata yüzdeleri	80
Şekil 4.94: Model 3 için Yinelenen YSA ve test çıkışları	81
Şekil 4.95: Model 3 için Yinelenen YSA test hata değerleri	81
Şekil 4.96: Model 3 için Yinelenen YSA test hata yüzdeleri	82
Şekil 5.1: Model 1 Gerçekleme Grafikleri	86
Şekil 5.2: Model 2 gerçekleştirme grafikleri	88
Şekil 5.3: Model 3 için gerçekleştirme grafikleri	90

SEMBOL LİSTESİ

A,H	: Hatanın ikinci dereceden türevleri, hessian matrisi
b	: Yanlı terim
e	: Hata
Er	: Hata vektörü
f	: Aktivasyon fonksiyonu
g	: Gradyen
i	: Ağ çıkışı numarası
j	: Ağ girişi numarası
J	: Jakobyen matrisi
k	: Ağırlık numarası
n	: Toplam çıkış sayısı
net	: Aktivasyon fonksiyonunun girişi
q	: Gizli katmandaki aktivasyon fonksiyonunu numarası
s	: Toplam giriş sayısı
w	: Ağırlık, ağırlık vektörü
W	: Ağırlık matrisi
z	: Ağ girişleri
α	: Öğrenme oranı, ssw'yu içeren hata teriminin katsayısı
β	: sse'yi içeren hata teriminin katsayısı
γ	: Efektif parametre sayısı
μ	: Levenberg-Marquardt'da birim matrisin ayarlanabilir katsayısı

ÇİMENTO ENDÜSTRİSİNDEKİ HARMANLAMA PROSESİNİN DEĞİŞİK TİPTE YAPAY SİNİR AĞLARI İLE TANILANMASI VE KIYASLANMASI

ÖZET

Çimento endüstrisindeki harmanlama prosesinin temel amacı, silolardan uygun miktarlarda hammaddelerin alınıp, belirli çimento kalite standartlarına en yakın kimyasal kompozisyona sahip harmanın hazırlanmasıdır. Ancak, oksit bileşenleri içeren bu hammaddelerin kimyasal kompozisyonları uzun dönemli ortalama değerlere göre zamanla değişmekte ve bu değişimler prosese bozucu olarak etkiyerek proses parametrelerinin değişmesine yol açmaktadır. Bu sebeple, stokastik ve etkileşimli bir yapıya sahip olan çok girişli-çok çıkışlı prosesin modellenmesi oldukça güçleşmektedir. Bu çalışmada hedeflenen, Hereke/İzmit’de faaliyet gösteren Nuh Çimento fabrikasındaki harmanlama prosesinden elde edilmiş veriyi kullanarak, harmanlama prosesini en iyi şekilde temsil edecek ve kontrol uygulamaları için sağlıklı bir temel olacak dinamik bir modelin elde edilmesidir. Belirtilen proses; yüksek mamül, düşük mamül ve demir cevheri girişleri ve demir oksit ve/veya kireç modülleri çıkışları oluşturmak üzere, üç farklı biçimde modellenmiştir.

Belirtilen modeller, prosese ait 655 giriş-çıkış verisi kullanılarak sistem tanılama yoluyla elde edilmiştir. Sistem tanılama için, son yıllarda benzeri uygulamalarda sıkça başvuru yapılan Yapay Sinir Ağları(YSA) kullanılmıştır. YSA kendi özgün yapısından kaynaklanan sebeplerle, nonlinear fonksiyonlara yakınsayabilme özelliğine sahiptir. Dolayısıyla, proses dinamiğinin nonlinear olduğu endüstriyel uygulamaların modellenmesinde de etkili bir araçtır. Bu çalışmada, ortaya konulan modelleme probleminin çözümü için üç farklı YSA tipi kullanılmıştır. Bunlar, Çok Katmanlı İleri Beslemeli(ÇKİB), Radyal Bazlı(RB) ve Yinelenen YSA’lardır. Bu YSA’ların sistem tanılama davranışları, kendi kurgularından kaynaklanan çeşitli sebeplerle farklılaşırlar. Bu tezin kapsamı altında, YSA’ların genel yapısı ve değişik tipler arasında bahsedilen farklılaşmaya sebep olan tanılama davranışları, matematiksel temelleri ışığında detaylı olarak incelenmiştir. Bu çalışmanın ikincil amacı, aynı proses üzerine uygulanan bu ayrı tip YSA’ların kıyaslanması yapılarak, sistem tanılamada YSA kullanımına ilişkin genel sonuçlara gitmektir.

Belirlenen amaçları gerçekleştirme maksadıyla, Matlab® The Neural Network Toolbox® 4.0.1 kullanılarak her bir YSA tipi için, ikisi üç girişli-tek çıkışlı(demir oksit veya kireç modülü) ve biri üç girişli-iki çıkışlı(demir oksit ve kireç modülü) olmak üzere 9 ayrı model kurulmuş ve sistem dinamiğini kavrama özellikleri test edilmiştir. Elde edilen sonuçlar, demir oksit için modellemenin başarılı olduğu fakat kireç modülü için başarısız olduğunu ortaya koymaktadır. Başarısızlığının sebebi olarak, kireç modülünün tanımı gereği dört ayrı oksit değerine bağlı oluşu ve bu tüm oksit bileşenlerine ait tanılama olumsuzlarını barındırması sonucuna varılmıştır. Farklı YSA tiplerinin, yeter sayıda denemeden sonra benzer sonuçlar verdiği ve hangisinin sistem tanılama için kullanılması gerektiğinin, modellenen prosese ve elde edilecek modelin uygulanacağı yapıya bağlı olduğu ortaya çıkmıştır.

THE IDENTIFICATION AND COMPARISON OF THE BLENDING PROCESS IN CEMENT INDUSTRY WITH VARIOUS TYPE OF NEURAL NETWORKS

SUMMARY

The goal of the raw material blending process in a cement factory is to mix the raw materials in order to produce cement raw meal that has closest chemical compositions to the specified cement quality standards. On the other hand, the chemical compositions of the raw materials which include oxide components vary according to the long-term average values and these variations cause the changes of the system parameters by acting on the process as disturbances. Therefore, the modeling task of the process that is multi-input multi-output and has stochastic and interactive structure is quite difficult. The objective of this study is to construct an experimental dynamic model that is appropriate for to be implemented in control applications of the blending process by using the data obtained from Nuh Cement Factory in Hereke/Izmit. The clarified process is modeled in three different way in which the high grade, low grade and iron ore constitutes the inputs and the outputs are assumed as iron oxide and/or lime module.

The system that is under interest is identified by using the data which is formed from the 655 input-output records of the process. The Neural Networks(NNs-which are information processing units and are inspired from biological neurons of human brain), that have gained a general use in constructing models of complex nonlinear industrial processes because of their inherent ability to learn and approximate a nonlinear function, are used for system identification. Three different type of NNs which are Multi-Layer Perceptron(MLP), Radial Basis(RB) and Recurrent are implemented for the solution of the modeling problem that is under consideration. The system identification behaviour of the each of these NNs differs from the others for the various reasons that come from their own specific structures. The general principles of NNs and system identification behaviours of various types of NNs which are implemented under the scope of this study are examined in the light of the mathematical foundations. The secondary purpose of this thesis is to obtain general results for the NNs usage in system identification by comparing these various type of NNs those are applied on the same process.

For carrying out the determined targets, two of which is three input-one output and the third is being three input-two output for each of the three type of NNs, 9 different models are constructed and their ability of learning the system dynamic are tested by using Matlab® The Neural Network Toolbox® 4.0.1. The results indicate the success on the task of modeling iron oxide output but failure in lime module. The specific definition of the lime module that is dependent to four different oxides and as a result of this situation that is to be included all the negative identification influences of these four oxides is brought up for the lack of success. The reality of the similar results of the various types of NNs after sufficient trial procedures is observed and the dependency of the selection of the NN type for any system identification task to the application that the model is to be integrated is stated.

1. GİRİŞ

1.1 Giriş ve Çalışmanın Amacı

Mühendislik sistemlerinin incelenmesinde genellikle ele alınan sistemin dinamik davranışını tanımlayan pratik ve doğru bir modele ihtiyaç duyulur. Bu husus özellikle otomatik kontrol uygulamaları için geçerlidir. İnceleme konusu olan sistemin özelliklerine göre, fiziğin, kimyanın veya diğer disiplinlerin ilk prensiplerinden yararlanılarak dinamik bir model elde etmek mümkündür. Fakat böyle bir modelin bahsedilen prensiplerden türetilmesi, hem uzman bilgisi hem de çok detaylı bir sistem analizi gerektirir. Ayrıca buna rağmen, hangi dış ve iç faktörlerin sistem davranışı üzerinde etkili olduğu, hangilerinin ihmal edilebilir olduğu her zaman bilinmeyebilir. Bu durumda sistemin belirli koşullar altında ölçülmüş giriş çıkış bilgisi kullanılarak, sistem dinamiğini tanımlayan bir matematik model elde edilebilir.

Sistem tanılama, kısaca, sistemin dinamiğini kavramaya uygun bir giriş sinyaline sistemin verdiği çıkışların ölçülmesi ve ölçülen bu değerlerin sistem için seçilmiş bir matematik modelin parametrelerinin tayininde kullanılarak, bulunan modelin yeni giriş-çıkış verileriyle gerçekleştirilmesidir. Her ne kadar model mertebesinin belirlenmesi ve giriş-çıkış değerlerinin eldesi için uygun deney koşullarının sağlanması, yine uzman yaklaşımı gerektirse de, ilk prensiplerden elde edilmiş olana göre daha sağlıklı ve daha az emek isteyen bir dinamik model bulunabilir. Sistem tanılama ile genellikle, çevrim içi uygulamalara ve model temelli kestirime uygun, güvenilir ve pratik modeller elde edilir. Belli sistem modelleri nonlinear modellerin dinamik davranışlarını tanımlamada sınırlı bir kesinliğe kadar uygun olsa da, genel problemi çok karmaşıktığından, sistem tanılamasının lineer uygulamaları pratikte daha çok ilgi görmüştür. Fakat lineer modellerin uygulamadaki kolaylıklarına ve tüm diğer cazip özelliklerine rağmen, gerçek dünyadaki sistemlerin çoğu nonlinear karakterlidir. Lineer modeller, ancak çok sınırlı bir değer aralığında sonuç vermektedirler. Özellikle son yıllarda, çok geniş değer aralıklarında çalışabilecek modellere ihtiyacın artmasından dolayı, nonlinear modellere dayanarak sistem

tanılama önem kazanmıştır. Yapay sinir ağıları bu amaca uygun çok önemli bir araçtır[3].

Adından anlaşılacağı gibi, Yapay Sinir Ağları(Neural Networks), insan beynindeki nöronlar arasındaki iletişimden esinlenilerek elde edilmiş bir bilgi işleme mekanizmasıdır. Birbirine paralel fonksiyonların oluşturduğu çeşitli katmanlardan meydana gelen bu yapılar, herhangi bir nonlinear fonksiyona çok hassas bir yaklaşıklıkla yakınsayabilmektedirler[10]. Bu çalışmanın amacı, çimento endüstrisindeki harmanlama prosesinin değişik tipte yapay sinir ağları kullanılarak tanılanmasının yapılmasıdır. Bahsedilen tanılama işlemi için, literatürde yaygın olarak kullanılan yapay sinir ağları tipleri kullanılmış ve bu ayrı tiplerin sistemin dinamik karakteristiğini kavrama özellikleri karşılaştırılarak, genel sonuçlara gidilmesine çalışılmıştır.



2. ÇİMENTO ENDÜSTRİSİNDEKİ HARMANLAMA PROSESİ

2.1 Giriş

Çimento üretimi, tüm dünyada günlük hayatın bir çok alanında uygulamaları olan köklü bir endüstri ve aynı zamanda ülkelerin gelişmişlik düzeyini gösteren önemli bir parametredir. Çimento üretim teknolojisi yaklaşık yüz yıldır bilinmektedir. Fakat o günden bu yana, kapasiteyi, kaliteyi ve verimliliği arttırmak amacıyla üretim metodları sürekli gelişmiştir ve gelişmeye devam etmektedir.

Bir çimento fabrikasındaki hammadde harmanlama prosesinin amacı, hammaddeleri fırınlamaya uygun biçimde toz haline getirmektir. Bu toz halindeki hammaddenin oksit bileşimleri, belirli dayanımlar için üretilen çimentonun kalitesini büyük ölçüde belirlemektedir. Bununla birlikte, hammaddelerin kimyasal bileşimleri zamanla değişmekte ve bu değişim ölçülmemektedir. Ayrıca, hammaddelerin her biri değişen ölçülerde oksit bileşimleri içermektedir. Hammaddelerin uzun dönemli ortalama bileşimlerindeki değişimlerden kaynaklanan bozucu etkenler, sistem parametrelerinin değişmesine sebep olmaktadır. Bu nedenle, stokastik bozucu etkisine sahip hammadde harmanlama prosesini temsil etmek için, prosesin önsel verilerini kullanarak deneysel bir model kurmak zorunludur. Ancak böyle bir modelin varlığında, arzu edilen sistem davranışını gösteren bir kontrolör tasarımı mümkündür.

Bu çalışmada amaçlanan, Nuh Çimento fabrikasından elde edilen veri grubunu kullanarak, yukarıda bahsedilen deneysel modeli kurmak veya başka bir deyişle sistemin tanınmasını gerçekleştirmektir. Veriler, değişik çalışma şartlarında bilgisayar kontrollü bir sistem üzerinden toplanmıştır. Tanılama kısmında, üç değişik yapay sinir ağı tipi ile dokuz ayrı model kurulmuştur. Prosesin girişleri, hammadde bileşenleri besleme oranları(düşük mamül ve demir cevheri) ve çıkışları da, demir oksit ve/veya kireç modülü olmak üzere, her yapay sinir ağı tipi için üç ayrı model kurulmuştur. Tanılama işlemi gerçekleştirilirken, sisteme ait giriş-çıkış bilgisi dışında hiçbir bilgi kullanılmamıştır. Prosesin dinamiği ve rahatsız edici faktörün karakteristiği ile ilgili hiçbir kabul yapılmamıştır. Yapay sinir ağlarının nonlineer

yapısı kullanılarak ve tanılama verisinin ortalama değerden çok farklı değerleri elimine edilerek, ilgili model kurulmuştur.

2.2 Hammadde Harmanlama Sistemi


Çimento üretim prosesi basitçe, maden kazma, ezme, öğütme, fırınlama ve alçıtaşı ile öğütme aşamalarından oluşur. Çimento üretimi için kullanılan iki ayrı metod vardır: Kuru metod ve Islak Metod. Kuru metod, ıslak olanına göre daha az enerji tüketir fakat yüksek kalitede ürün verebilecek çimento tozunu(veya ununu) elde etmek daha zordur. Islak proseste, uygun oranlarda hammadde yeteri kadar su ile karıştırılır ve macun haline getirilir. Bu formda, hammadeler oranlanır, karıştırılır, öğütülür, ezilip toz haline getirilir ve sonra eğimli, dönen bir fırına sürülür. Kuru metodda da fırına malzemenin kuru durumda sürülmesi dışında benzer işlemlere gerçekleştirilir. Fırının içinde hammadde karışımı çeşitli bir dizi reaksiyon geçirir. Son aşama olarak, yaklaşık 1400-1450 °C de sinterleme(bir maddeyi eritmeden ısıtarak yapışkan bir konuma getirme, toplıştırma) gerçekleşir ve kendi özel kimyasal ve fiziksel özellikleri olan cüruf elde edilir. Çüruf soğutulur, ezilir ve çimentonun oturma zamanını düzenlemek için önceden belirlenmiş miktarda alçıtaşı ile karıştırılır. Elde edilen ürüne portland çimento denir ve otomatik paketleme makinalarına beslendiği silo denilen büyük hacimli depolarda muhafaza edilir.

2.3 Nuh Çimento Hammadde Harmanlama Prosesi

Şekil 2.1 de Nuh Çimento Fabrikası'ndaki harmanlama prosesinin basitleştirilmiş bir diagramı gösterilmiştir.

Şekil 2.1 den de görüldüğü gibi, sistemde üç ayrı besleyici akım mevcuttur ve bu akımlarla gelen hammadde, değirmende tamamıyla öğütülmeden önce konveyör hattında karıştırılarak ağırlık besleyiciler tarafından hammadde değirmenine beslenir. Bu çalışmada bu üç besleyici akımın; yüksek mamül, düşük mamül ve demir cevherinin, demir oksit ve/veya kireç modülü üzerindeki etkileri modellenenecektir. Demir oksit ve kireç modülü çıkışlarının modellenmesinin sebebi, Nuh Çimento Fabrikası yetkililerinin bu çıkışlara ait değerleri kontrol etmek istemeleri ve dolayısıyla kontrol stratejilerini uygulayacak bir modele ihtiyaç duymalarıdır. Demir oksit ve kireç modülü değerleri, elde edilecek çimentonun kalitesi açısından çok önemlidir.

BESLEME SİLOLARI



Şekil 2.1: Hammadde akış diyagramı

Bahsedilen hammadde karışımının bir örneği hammadde mil değirmeninin girişinden bir otomatik örnekleyici tarafından toplanır ve dakika başı PGNAА ile analiz edilip bir veri iletim hattı yoluyla bilgisayara iletilir. Dolayısıyla, ölçüm dört temel oksidin çıkış derişimlerinden oluşur. Daha sonra elde edilen hammadde unu, silo ortalama değerleri civarındaki derişim değışimlerinin sürekli karıştırma ile düşürüldüğü homojenizasyon havuzlarına transfer edilir. Bir havuzun tam dolması için 16 saate ihtiyaç vardır.

Nominal akış oranları, derişimler, maliyetler ve besleme akışlarının genel isimleri Tablo 2.1’de verilmiştir.

2.4 Çimento Üretim İşleminin Yapısı

Çimento üretim prosesi iki ana aşamadan oluşur: (1) hammaddenin harmanlanması ve öğütülmesi ve (2) fırına verilmesi ve şu tahmini oksit ağırlık oranlarına sahip ince toz karışımının elde edilmesi: trikalsiyum silikat($C_3S \approx 60\%$), dikalsiyum silikat($C_2S \approx 25\%$), trikalsiyum alüminat($C_3A \approx 5\%$) ve tetracalsiyum alüminyum ferrit($C_4AF \approx 10\%$).


Tablo 2.1 Harmanlama prosesi besleme akış verisi

Nominal Derişimler (%)						
İsim	Nominal Akış (%)	CaO	SiO ₂	Fe ₂ O ₃	Al ₂ O ₃	Maliyet (USD/Ton)
Düşük Mamül (Kil + Marn)	50.51	40.55	19.03	1.32	2.58	0.22
Yüksek Mamül (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

Bu dört çimento bileşiminin derişimleri yanmış dört oksidin(CaO, SiO₂ , Fe₂O₃ , and Al₂O₃) derişimlerine bağlıdır. Bu nedenle, yüksek kaliteli çimento elde etmek için çimento bileşimlerinde gerek duyulan sınırlamalar, bu yanmış oksit bileşimlerine yönelik daha hassas sınırlamalarla sonuçlanmaktadır.

2.5 Harmanlama Prosesinin Tanılanması

Harmanlama prosesinin tanılanmasının zorluğu ve çeşitli stokastik faktörlerin sonuç üzerindeki bozucu etkisi önceki kısımlarda ortaya konulmuştu. Bu çalışmada, belirtilen kısıtlara rağmen, her yapay sinir ağı tipi için demir cevheri, düşük mamül ve yüksek mamülün girişler ve demir oksit yüzdesi ve/veya kireç modülünün çıkışlar oldukları üç ayrı model kurularak değişik YSA tipleri ile sistem tanılama gerçekleştirilecektir:



Dört önemli oksit yüzdesine(CaO, SiO₂, Al₂O₃ ve Fe₂O₃) sırasıyla C, S, A ve F denirse, yukarıda bahsedilen kireç modülü:

$$ML = \frac{100C}{2.8S + 1.1A + 0.8F} \tag{2.1}$$

Denklem 2.1 de gösterilen ve Nuh Çimento Fabrikası'nda kullanılan kireç modülünün, istenen çimento kalitesine ulaşmak için belli değerler arasında tutulması gerekir. Bundan dolayı, proses girişleri için, demir oksit ile beraber bu izafi oranın davranışının da bilinmesine ihtiyaç vardır.[7]



3. YAPAY SİNİR AĞLARI İLE SİSTEM TANILAMA

3.1 Yapay Sinir Ağları


3.1.1 Giriş

Yapay sinir ağları(YSA), eğitim verisini kullanarak öğrenme, hatırlama ve genelleştirme yeteneği elde edebilen yeni bir bilgi işleme yöntemidir. Bu sistemler insan beyninin bazı organizasyon prensiplerini taklit ederek, eğri uydurma, optimizasyon, karakter ve görüntü tanıma gibi çeşitli maksatları gerçekleştirmek üzere tasarlanırlar. YSA, birbirine paralel olarak çalışan basit elemanlardan oluşmaktadır. Bu elemanlar beyindeki biyolojik nöronlardan esinlenilerek modellenmiştir.[2]

YSA'nın işleyişi, genel olarak bahsedilen nöronlar arasındaki bağlar yoluyla belirlenir. Bağ değerleri(ağırlıklar), yapay sinir ağının belli bir fonksiyonu gerçekleştirmesi için ayarlanır. Bu işleme, YSA'nın eğitilmesi denir. Eğitim genellikle, bir giriş değerinin belli bir hedef çıkış değerine, daha önceden belirlenmiş bir algoritma kullanılarak, yakınsatılması yoluyla yapılır.[2]

3.1.2 Nöron Modeli


Bir nöron YSA'nın çalışmasına esas teşkil eden bir bilgi işleme birimidir. Şekil 3.1'de iki basit nöron örneği verilmiştir.



Şekil 3.1: Nöron modeli


Solda gösterilen nörona sadece bir tek skalar giriş vardır ve nöron, yanlı terim(bias) ihtiva etmemektedir. Skalar giriş, p , ağırlığı w olan bir bağlantı üzerinden nörona

yine bir skalar olan $w.p$ çarpımı şeklinde iletilmektedir. Bu nöronda wp , a çıkışı veren fonksiyonun tek argümanıdır. Sağdaki nöronda, soldakinden farklı olarak b ile gösterilen yanlı terim vardır. Bu yanlı terimin değeri, wp 'ye eklenerek, yine bir skalar olan, $w.p+b$ argümanı elde edilir. Yanlı terim, fonksiyonu b oranında kaydıran ayarlanabilir bir katsayı olarak düşünülebilir. f fonksiyonuna transfer fonksiyonu denir. Nöron için skalar bir giriş değil de, vektörel bir giriş söz konusu ise, a çıkışının hesaplanması Şekil 3.2 de gösterildiği gibi olur.



Şekil 3.2 [1]: Vektörel girişli nöron modeli

Şekil 3.2' deki R indisi, giriş vektöründeki eleman sayısını belirtir. Hedeflenen maksada göre, transfer fonksiyonunun seçimi çok çeşitli olabilir. Ancak, uygulamada edinilen tecrübeler ışığında belli bazı transfer fonksiyonları genel olarak kabul görmüştür. Bu çalışmada kullanılacak transfer fonksiyonları Şekil 3.3 de gösterilmiştir. Bu transfer fonksiyonlarının sonuçlar üzerindeki etkileri, daha sonra uygulamalarıyla beraber tartışılacaktır.




Şekil 3.3 [1]: Aktivasyon fonksiyonları

3.1.3 YSA Mimarileri

Son yıllarda, literatürde çeşitli maksatlar için önerilen çok sayıda YSA mimarisi vardır. Bu çalışmada bunlardan sadece üç farklı tür takdim edilecektir: Tek katmanlı YSA, çok katmanlı YSA ve yinelenen(recurrent) YSA.

3.1.3.1 Tek Katmanlı YSA

Katmanlar şeklinde organize edilmiş ve nöronlardan oluşmuş bir ağ, katmanlı YSA olarak gözönüne alınır. Katmanlı YSA'nın en basit hali, girişleri bulunduran kutupların, her biri bu kutupların tamamına bağlı çıkış nöronlarına, bu bağlantılar üzerinden veri ilettiği tek katmanlı durumdur. Belirtilen işleyişin tersi geçerli değildir. Bir başka deyişle böyle bir YSA sadece ileri beslemeli(feedforward)dir. R giriş elemanlı ve S nöron sayılı bir tek katmanlı YSA Şekil 3.4'de gösterilmiştir.




Şekil 3.4 [1]: Tek katmanlı YSA modeli

Şekil 3.4'de gösterilen tek katmanlı YSA modelinde, ağırlık değerleri $w_{i,j}$ biçiminde temsil edilmiştir. Burada ilk alt indis i , hedef nöronu, ikinci alt indis j ise girişi ifade eder. Bu ağırlık değerleri W ağırlık matrisini oluştururlar.

3.1.3.2 Çok Katmanlı YSA

Çok katmanlı YSA, bir giriş katmanı, bir veya birkaç gizli katman ve bir çıkış katmanından oluşur. Her bir katman da, tümü diğer katmanlardaki her bir nörona bağlı nöronlardan ibarettir. Bu YSA, Şekil 3.5'de gösterildiği gibi ileri beslemeli bir veri akış yapısına sahiptir. Şekil 3-5 bir tane gizli katmana sahip bir YSA yı

göstermektedir. Çok katmanlı bir YSA da giriş-çıkış değerlerinin belirlenmesi, iki unsur üzerinden olmaktadır. İlki; bir önceki katmandaki nöronların çıkışını, ilgili nöronun girişine dönüştüren bağlantılar ve dolayısıyla ağırlık değerleri, ikincisi ise; bahis konusu olan nöronun aktivasyon fonksiyonudur. Şekil 3.5’de bu yapının matematiksel işleyişi izah edilmiştir.




Şekil 3.5 [1]: Çok katmanlı YSA modeli

Şekil 3.5’de gösterilen bağıntılardaki üst indisler, ilgili katman numarasını temsil etmektedir. R girişli ve S çıkışlı bir çok katmanlı sistemin veri akışı, ara basamak işlemleri ile beraber anlatılmıştır.

3.1.3.3 Yinelenen(Recurrent) Yapay Sinir Ağları

Bir yinelenen YSA, kendisini ileri beslemeli YSA dan ayıran en az bir geri besleme döngüsüne sahiptir. Yinelenen YSA bir veya daha fazla katmandan oluşabilir ve her bir nöronun girişi, diğer nöronların çıkışlarından meydana gelebilir. Yinelenen YSA’lar çok çeşitlidir ve yaygın uygulamaları daha çok görüntü, karakter ve ses tanıma gibi alanlardadır. Bu çalışmada kullanılacak Elman Ağı’nın en belirgin özelliği; çıkış değerinin, girişin ve çıkışın zaman içindeki değişimine bağlı olduğu veya bir başka deyişle zaman içinde uzamsal olan biçimlerin öğrenilmesinin gerekli olduğu hallerde kullanılabilmesidir. Elman ağı Şekil 3.6’ da gösterilmiştir. Bahsedilen YSA nın sistem tanımlarken ya da bir fonksiyona yakınsarken gösterdiği davranış daha sonra incelenecektir.



Şekil 3.6 [1]: Yinelenen YSA(Elman Ağı)

Bir Elman Ağı genellikle, ilk katmanın çıkışından ilk katmanın girişine bir geri beslemenin olduğu, iki katmanlı bir YSA dır. Bu geri besleme zamanla değişen biçimlerin öğrenilmesine imkân tanır. Gizli katmanlardaki nöronlar, nöron modelinin anlatıldığı Bölüm 3.1.2' de takdim edilmiş tanjant sigmoid(tansig) fonksiyonunu kullanmaktadırlar.

3.2 YSA ile Sistem Tanılamada Kullanılan Bazı Yöntemler


3.2.1 Çok Katmanlı İleri Beslemeli(ÇKİB) Sinir Ağları

3.2.1.1 Giriş

Bu bölümde kullanılan YSA, geri yayımlı YSA diye de tanımlanabilir. Bu, sistem tanımlarken kullanılan eğitim algoritmasından veya başka bir deyişle, ağırlıklar diye nitelendirilen bağ katsayılarının belirlenme biçiminden kaynaklanmaktadır. Bu algoritma, elde etmek istenilen çıkışlar(hedef değerler) ve YSA çıkışları arasındaki hataların, ağ boyunca geri yayınımlı yaptırılarak, sistem katsayılarının ayarlanmasına dayanır. Bahsedilen geri yayınımlı fiziksel karşılığı yoktur, sadece sonuca ulaşmak için kullanılan matematiksel bir manipölasyondur[2]. Bu çalışmada kullanılan geri yayımlı YSA, Levenberg-Marquardt eğitim algoritmasını ve Bayesian Regölasyonunu kullanarak, ilgili sistem tanılama maksadını gerçekleştirmiştir. Daha sonra detaylarıyla anlatılacağı gibi, YSA'da eğitim algoritmasının seçimi yakınsama ve dolayısıyla eğitim hızını belirler.


3.2.1.2 Yapı(Structure) Seçimi:

Yapı seçimi nöronlardaki transfer fonksiyonlarının belirlenmesi anlamına gelir. Bu çalışmada geri yayınlı YSA için, gizli katman(lar)da bipolar tanjant sigmoid(tansig) ve çıkış katmanında lineer(purelin) fonksiyonları kullanılmıştır[8]. Bu fonksiyonlar, grafikleri ile beraber denklem 3.1 ve 3.2 de gösterilmiştir.



$$a(n) = \frac{2}{1 + e^{-2 \cdot n}} - 1 \quad (3.1)$$

Bu fonksiyon matematiksel olarak tanjant hiperbolik fonksiyonuna denktir. Grafikten de anlaşılacağı gibi, sıfıra yakın giriş değerlerinde, fonksiyon girişe çok yakın bir çıkış değeri verir. Sıfırdan çok büyük veya küçük giriş değerleri için, fonksiyon çıkışı en düşük -1 değerine ve en yüksek +1 değerine yakınsatır. Bu tip bir sıkıştırıcı(squashing) fonksiyon kullanmanın başlıca faydası, hem istenen değer aralığı içinde, fonksiyonun sisteme özgü nonlineer davranışı gösterebilmesi hem de çıkışı belli bir aralığa sıkıştırarak, sistem kararlılığını sağlamasıdır[2].




$$a(n) = n \quad (3.2)$$

Çıkış nöronları için genelde tansig fonksiyonları tercih edilmez. Bunun sebebi, sistemin 1'den büyük veya -1 den küçük hedef değerleri bu fonksiyonlarla karşılayamayaz oluşudur. Dolayısıyla çıkış nöronlarında, fonksiyonun çıkışını girişine eşitleyen lineer fonksiyonlar kullanılır.

3.2.1.3 Parametre Kestirim Algoritması

Burada algoritma ile kastedilen, hedef değerler ve YSA çıkışı arasındaki farkın minimum olması için en uygun parametreleri tayin eden matematiksel işlemler dizisidir.



Şekil 3.7 [12]: Bir gizli katmanlı YSA

Şekil 3.7’de gösterildiği gibi tek gizli katmana sahip ileri beslemeli bir YSA modelini gözönüne alalım. Verilen örnek YSA da saklı ve çıkış katmanlarındaki nöronların yanlı terime sahip olduğu gözönüne alınmıştır. Bu yanlı terimin değeri 1 dir. Bu ağın gizli katmanındaki herhangi bir tansig fonksiyonunun girişi veya giriş katmanının çıkışı denklem 3.3 deki gibi olur.

$$net_q = \sum_{j=1}^m w_{qj}^1 z_j \quad (3.4)$$

denkleminde q , girişi hesaplanan gizli katmandaki nöronun numarasını, m yanlı terimin de dahil olduğu toplam giriş sayısını ve ağırlıklara ait üst indis ise, bu ağırlıkların hangi katmana ait olduğunu belirtir. Gizli katmandaki q nöronunun çıkış değeri:

$$f_q(net_q) = \text{tansig}_q \left(\sum_{j=1}^m w_{qj}^1 z_j \right) \quad (3.5)$$

Çıkış katmanındaki i nöronunun giriş değeri:

$$net_i = \sum_{q=1}^l w_{iq}^2 f_q = \sum_{q=1}^l w_{iq}^2 \tanh \left(\sum_{j=1}^m w_{qj}^1 z_j \right) \quad (3.6)$$

ve son olarak i nöronunun çıkış değeri:

$$y_i = F_i(net_i) = \text{purelin} \left(\sum_{q=1}^l w_{iq}^2 f_q \right) = \sum_{q=1}^l w_{iq}^2 \tanh \left(\sum_{j=1}^m w_{qj}^1 z_j \right) \quad (3.7)$$

YSA modelinin i inci çıkışı denklem 3.7 de ifade edildiği gibidir. Şimdi seçilen YSA modeli ile gerçek sistem davranışı arasındaki ilişkiyi belirleyen bir performans fonksiyonu seçilir. Bu çalışmada seçilen ve denklem 3.8 ile gösterilen performans fonksiyonu, en küçük kareler toplamıdır. Bu performans fonksiyonunun seçilmesinin sebebi, daha sonra anlatılacak ve uygulanacak olan Levenberg-Marquardt sayısal yöntemine uygun oluşudur.

$$E(e) = \sum_{i=1}^n e^2 = \sum_{i=1}^n (t_i - F_i(net_i))^2 \quad (3.8)$$

3.8 denkleminde, n , çıkış katmanındaki nöron sayısını, t , hedef değerleri ve e de model çıkışı ve hedef çıkış arasındaki farkı, hatayı temsil etmektedir. Buna göre, amaç, ağırlık ve yanlı terim parametrelerini bu fonksiyonu minimum yapacak şekilde ayarlamaktır. Minimumu bulunmaya çalışılan performans fonksiyonu incelenirse, fonksiyonun tansig ifadesinin karelerini içerdiği ve bu sebeple bir çok lokal minimuma sahip olduğu anlaşılır. Bu durumda, fonksiyonun genel minimumunu garanti edecek kesin bir çözüm olmadığı için, ağırlık ve yanlı terim parametrelerinin seçimi çok önemlidir. Bu gayeyle çeşitli yöntemler geliştirilmiştir[2].

3.2.1.4 Başlangıç Parametrelerinin Atanması

Bir YSA yı eğitirken, ağ parametreleri için başlangıç değerleri atanmalıdır. İleri beslemeli ve gizli katmanında tansig fonksiyonları bulunduran bir çok katmanlı YSA nın yakınsama özellikleri incelenirse, başlangıç parametrelerinin atanmasında iki temel prensibe uyulmasının gerekliliği görülür. Bu prensiplerin ilki, başlangıç parametrelerinin sıfıra atanmamasıdır. Çünkü böyle bir durumda, parametre uzayının orijininin, performans uzayı açısından ölü nokta(saddle point) olma ihtimali vardır. İkinci prensip, başlangıç değerlerinin çok büyük değerlere atanmamasıdır. Bu

durumun sakıncası, performans yüzeyinin optimum noktadan çok uzaklarda büyük ölçüde yassılaşması ve bir yakınsamayı ya mümkün kılmaması ya da çok uzun zamana ihtiyaç olmasıdır. Genel olarak bu iki prensip, ağırlıklar ve yanlı terimlere ait başlangıç değerlerinin, küçük ve geliş güzel sayılara atanması olarak özetlenebilir [2].

Bu çalışmada başlangıç parametrelerinin seçimi için Nguyen-Widrow metodu denilen başka bir yöntem kullanılacaktır[9]. Nguyen-Widrow tekniği bir katmandaki nöronların aktif bölgelerinin aşağı yukarı tüm giriş uzayına dağılmasını sağlayacak şekilde, ağırlıklar ve yanlı terimler için başlangıç değerleri üretir. Bu yöntemin başlangıç değerleri için geliş güzel değerler kullanmaya karşı çeşitli üstünlükleri vardır: (1) Daha az nöron kullanılır(çünkü tüm nöronların aktif bölgeleri giriş uzayına dahildir), (2) Eğitim daha hızlı olur(çünkü giriş uzayının her alanı aktif nöron bölgelerine sahiptir). Bu teknik istatistik yöntemlere dayanılarak elde edilmiştir ve detayları burada tartışılmayacaktır.

3.2.1.5 Azalan Gradyen Metodu

Azalan gradyen metodu, geriyayınımlı öğrenmenin en basit uygulamasıdır. Ağ parametreleri, performans fonksiyonunun en çok azaldığı doğrultuda-fonksiyonun gradyeni ile negatif yönde olacak şekilde ayarlanır.

$$\nabla_w E(w) = \frac{\partial E}{\partial w_k} = g_k \quad \text{ve} \quad \alpha = \text{öğrenme oranı(learning rate) denirse :}$$

$$w_{k+1} = w_k - \alpha g_k \quad (3.9)$$

Bu yöntemle ağ parametrelerinin eğitilmesine geri yayınımlı eğitim algoritması denmesinin sebebi, performans fonksiyonunun türevlerinin önce en son katmanda elde edilmesi ve daha sonra, gizli katmandaki ağırlıklara göre türevlerinin eldesi için zincir kuralı kullanılarak ağ boyunca geriye takibinin yapılmasıdır.

Azalan gradyen yöntemi pratik uygulamalar için genellikle çok yavaş olduğundan, bu çalışmada hızlı yakınsama için bir sayısal optimizasyon yöntemi olan Levenberg-Marquardt algoritmasının YSA'ya uyarlanmış biçimi kullanılacaktır[2]. İyi bir genelleştirme elde etmek için de, Bayesian Öğrenmesine[5] Gauss-Newton yaklaşımı[6] gerçekleştirilecektir.

3.2.1.6 Levenberg Marquardt Geri Yayını

Levenberg-Marquardt algoritması Newton metodunun, nonlinear fonksiyonların toplamını minimum yapmak için tasarlanmış bir varyasyondur.

Newton Metodu: Azalan gradyen yönteminin türetilmesi, birinci dereceden Taylor serilerinin açılımına dayanıyordu. Newton metodu, Taylor serilerinin ikinci dereceden açılımına dayanır:

$$F(w_{k+1}) = F(w_k + \Delta w_k) \approx F(w_k) + g_k^T \Delta w_k + \frac{1}{2} \Delta w_k^T A_k \Delta w_k \quad (3.10)$$

3.10 kuadratik fonksiyonunun Δw_k ya göre gradyeni alınır ve sıfıra eşitlenirse:

$$\Delta w_k = -A_k^{-1} g_k \quad (3.11)$$

3.11 eşitliği elde edilir ve Newton metodu 3.12’de olduğu gibi tanımlanır.

$$w_{k+1} = w_k - A_k^{-1} g_k \quad (3.12)$$

Gauss-Newton Metodu: Newton metodunda, 3.12 denkleminde A ile gösterilen ikinci türevlerden oluşan Hessian matrisinin(H) ve tersinin hesaplanması gerekir. Bu işlem, pratik uygulamalar açısından çok zordur. Gauss-Newton metodunun avantajı, YSA hatalarının ağ parametrelerine göre ilk türevlerinden oluşan Jakobian matrisini(J) kullanarak yaklaşık bir Hessian matrisinin bulunmasıdır. O halde, bu yaklaşık matris:

$$H = J^T J \quad (3.13)$$

Levenberg-Marquardt Metodu: $H = J^T J$ matrisinin tersi her zaman bulunamayabilir. Levenberg-Marquardt algoritması ile $G = H + \mu I$ uyarlaması yapılarak, bu problemin üstesinden gelinir. Eğer ağ hatasına $e = t - y$ ve gradyen için $g_k = J^T e$ denirse, algoritma 3.14’ de gösterildiği gibi olur.

$$w_{k+1} = w_k - [J^T J + \mu I]^{-1} J^T e \quad (3.14)$$

Çok katmanlı ileri beslemeli YSA için, Levenberg-Marquardt algoritması daha detaylı olarak çıkarılabilir[4]. Ama önce Levenberg-Marquardt eğitim algoritmasının

uygulanması için takım eğitimi(batch training) yöntemine gerek olduğu söylenmelidir. Bu yöntemde, YSA yı eğitmek için kullanılacak eğitim verilerinin tamamı ağı sunulduktan sonra ağırlıklar yenilenir. Şekil 3.7 de gösterilen çok katmanlı ağ için s tane eğitim verisine sahip olduğu varsayılırsa, performans fonksiyonu:

$$E(w) = \sum_{p=1}^s \sum_{i=1}^n e^2 = \sum_{p=1}^s \left[\sum_{i=1}^n (t_{ip} - y_{ip})^2 \right] \quad (3.15)$$

Bu durumda parametre vektörü :

$$W = [w_1 \ w_2 \ \dots \ w_N]^T \quad (3.16)$$

Hata vektörü:

$$Er = [e_{11} \dots e_{1n} \ e_{21} \dots e_{2n} \ \dots \ e_{s1} \dots e_{sn}] \quad (3.17)$$

Bu durumda performans fonksiyonu :

$$E(w) = Er^T Er \quad (3.18)$$

Jakobian matrisi, ağ hatalarının katmanlar üzerinden geri yayılımıyla elde edilir:

$$J = \begin{bmatrix} \frac{\partial e_{11}}{\partial w_1} & \frac{\partial e_{11}}{\partial w_2} & \dots & \frac{\partial e_{11}}{\partial w_N} \\ \frac{\partial e_{21}}{\partial w_1} & & \ddots & \\ \frac{\partial e_{n1}}{\partial w_1} & & & \\ \frac{\partial e_{12}}{\partial w_1} & & & \\ \vdots & & & \\ \frac{\partial e_{ns}}{\partial w_1} & \dots & \dots & \frac{\partial e_{ns}}{\partial w_n} \end{bmatrix} \quad (3.19)$$

Ve sonuç olarak Levenberg-Marquardt algoritması denklem 3.20 deki gibi elde edilir.

$$W_{k+1} = W_k - \left[J_k^T J_k + \mu_k I \right]^{-1} J_k^T E r_k \quad (3.20)$$

Levenberg-Marquardt geri yayılım algoritmasının en cazip tarafı μ_k nın değeri değiştirilerek algoritmanın karakterinin değiştirilebilmesi. μ_k nın büyük değerleri için, algoritma, sanki küçük bir öğrenme oranına sahip azalan gradyen algoritmasındaki gibi davranır. μ_k nın küçük değerleri için ise Gauss-Newton yaklaşımına dönüşür. Böylece Newton metodunun hızı ve azalan gradyen yönteminin garantili yakınsaması arasında denge kurulmuş olur.

Hatanın minumumu civarında Newton metodu daha hızlı ve kesin sonuç verir. Bu sebeple, amaç algoritmayı bir an evvel Newton metoduna yaklaştırmaktır. Bunun için, her başarılı adımdan sonra(performans fonksiyonundaki azalma), μ_k bir sabite bölünerek küçültülür ve her başarısız adımdan sonra(performans fonksiyonundaki artış) μ_k bir sabitle çarpılarak artırılır. Böylece performans fonksiyonunun her bir iterasyonda sürekli olarak azalması sağlanır.

3.2.1.7 Bayesian Regülasyonu ile Levenberg-Marquardt Geri Yayılım Algoritması

YSA kullanılarak sistem tanımlarken karşılaşılan en önemli problemlerden birisi YSA nın aşırı uyum(overfitting) veya ezberleme yapmasıdır. Bu durumda, oluşturulan YSA modeli eğitim verileri için çok küçük hata vermesine rağmen, sınav verileri için yüksek hatalar verebilmektedir. YSA eğitim örneklerini iyi anımsamakta fakat yeni durumlar için genelleştirme yapamamaktadır.

YSA genelleştirmesini iyileştiren metodlardan bir tanesi de yeterli uyumu sağlayacak en az büyüklüğe sahip bir ağı kullanmaktır. Ne kadar büyük YSA kullanılırsa, YSA nın ürettiği fonksiyonlar da o kadar karmaşık olur. Eğer küçük YSA kullanılırsa, aşma yapmak için gerekli güç bulunamayacaktır[1]. Bu metodla ilgili problem, daha önceden belirli bir uygulama için gerekli ağı büyüklüğünü bilmenin zorluğudur.

Bu çalışmada, genelleştirmeyi iyileştirmek için Foresee ve Hagan'ın Bayesian Regülasyonuna Gauss-Newton yaklaşımı kullanılacaktır[6].

Regülasyonun püf noktası, genel olarak eğitim kümesinin hatalarının kareleri toplamı olarak seçilen performans fonksiyonunu, ağırlık ve yanlı terimlerin kareleri toplamından oluşan bir terim ekleyerek değiştirmektir.

$$E_b = \beta \sum_{i=1}^n e_i^2 + \alpha \sum_{j=1}^N w_j^2 \quad (3.21)$$

3.21 bağıntısında gösterilen performans fonksiyonu YSA'nın daha küçük ağırlıklara ve yanlı terimlere sahip olmasını sağlar. Böylece YSA cevabı daha düzgün ve aşma eğilimi daha az olur. Buradaki problem, 3.21 de gösterilen regülasyon parametrelerinin ayarlanmasıdır.

David McKay'ın Bayesian öğrenmesi[5], optimum regülasyon parametrelerinin otomatik bir biçimde belirlenmesi için bir yöntem önerir. Bu yaklaşımda, YSA'nın ağırlıkları ve yanlı terimleri belirli dağılımlara sahip rasgele değişkenler olarak kabul edilir. Regülasyon parametreleri bu dağılımlarla ilişkili bilinmeyen değişimlerdir. Dolayısıyla, bu parametreler istatistik yöntemler kullanılarak belirlenebilir. Bu çalışmada kullanılan Foresee ve Hagan'ın yaklaşımından[6] elde edilmiş sonuçlar aşağıdaki gibidir:

$$H = \nabla^2 E(w) \approx 2\beta J^T J + 2\alpha I_N \quad (3.22)$$

$$\gamma = N - 2\alpha \text{tr}(H)^{-1} \quad (3.23)$$

$$\alpha = \frac{\gamma}{2E_w(w)} \quad (3.24)$$

$$\beta = \frac{n - \gamma}{2E_D(w)} \quad (3.25)$$

Burada, N ağ parametresi sayısını, n eğitim verisi sayısını, E_D performans fonksiyonundaki hata terimini, E_w performans fonksiyonundaki ağırlık terimini ve γ de etkili ağ parametresi sayısını belirtir. Bu algoritmanın bir diğer avantajı, ne kadar ağ parametresinin(ağırlıklar ve yanlı terimler) YSA tarafından etkin olarak kullanıldığını bildiren γ sayısını vermesidir. Toplam ağ parametrelerinin sayısı ne olursa olsun, γ belli bir değerden sonra sabit kalmalıdır. Dolayısıyla γ sabit kalana kadar ağ parametreleri sayısı artırılarak, optimum parametre sayısına ulaşılabilir. Bu yaklaşımla aşmayı engellemek için fazladan bir önlem uygulanmış olur.

3.2.2 Radyal Bazlı Yapay Sinir Ağları


3.2.2.1 Giriş

Çok katmanlı ileri beslemeli YSA lardan farklı olarak, radyal bazlı YSA lar, radyal yapılı bir mekanizma kullanırlar. Burada radyal bazlı yapıdan kastedilen, ilk katmandaki nöronlar için seçilen aktivasyon fonksiyonunun karakteristiği ve bu fonksiyona giriş olacak değerin belirlenme biçimidir[10]. Bir sonraki, yapı seçimi bölümünde bu yeni mekanizma detaylı olarak anlatılacaktır.

Radyal Temelli YSA ların kullanımı, standart ileri beslemeli geriyayınımlı YSA lara göre genellikle daha fazla nöron gerektirir. Fakat, daha iyi enterpolasyon kabiliyetine sahiptirler ve dolayısıyla eğitim süreleri çok daha kısadır. Ayrıca en iyi performansı çok sayıda eğitim verisinin varlığında gösterirler[10].

3.2.2.2 Yapı Seçimi

Aktivasyon fonksiyonunun karakteristiğini tartışmadan önce, bu yeni tip YSA'nın kendine özgü nöron modelini tanıtmak gerekir.




Şekil 3.8 [1]: Radyal bazlı nöron modeli

Şekil 3-7 de görüldüğü gibi, radyal bazlı aktivasyon fonksiyonu farklı tipte bir girişe sahiptir. Burada fonksiyonun girişi, bu fonksiyona ait ağırlık vektörü ile ağ giriş vektörü arasındaki vektörel uzaklığın yanlı terimle çarpılmış halidir. Yanlı terim hassasiyeti belirlemeye yarar. Şekil 3-7 de $\| \text{dist} \|$ ile gösterilen işlem denklem 3.26 da ifade edilen öklid uzaklığını bulur.

$$\text{dist} = \sqrt{[(w_1 - p_1)^2 + (w_2 - p_2)^2 + \dots]} \quad (3.26)$$

Daha önce de tanıtılmış olan, radyal bazlı aktivasyon fonksiyonunun yapısı Şekil 3-8 da gösterildiği gibidir.




Şekil 3.9 [1]: Radyal bazlı aktivasyon fonksiyonu

Şekil 3-8 deki grafikten de görüldüğü gibi, radyal bazlı fonksiyon en yüksek çıkış değerini sıfır girişi için vermektedir. w ve p vektörleri arasındaki uzaklık azaldıkça, fonksiyonunun çıkış değeri artar. Bu matematiksel ilişkiyi anlatan fonksiyon çıkışı denklem 3-27 de verilmektedir.

$$a(n) = e^{-n^2} \quad (3.27)$$

3.2.2.3 Radyal Bazlı YSA Mimarisi

Radyal bazlı YSA, bir gizli radyal bazlı ve bir de lineer çıkış katmanı olmak üzere, iki katmandan oluşur. Radyal bazlı YSA'nın, gizli katmanı radyal bazlı nöronlardan, çıkış katmanı da lineer aktivasyon fonksiyonlu nöronlardan oluşur. Giriş vektöründeki eleman sayısı R , gizli katmandaki nöron sayısı S^1 ve çıkış katmanındaki nöron sayısı S^2 olan bir radyal bazlı YSA şekil 3-9 da gösterilmiştir.



Şekil 3.10 [1]: RB YSA mimarisi

3.2.2.4 Ağ Davranışı ve Parametre Kestirim Algoritması

Bu ağın çalışması şekil 3-9 da p giriş vektörünün a^2 çıkışına kadar takibi yapılarak anlaşılabilir. Eğer bu ağa şekilde gösterildiği gibi bir giriş vektörü sunulursa, radyal tabanlı katmandaki her bir nöron bu giriş vektörünün kendi ağırlık vektörüne olan uzaklığıyla orantılı bir çıkış değeri verir. Dolayısıyla p giriş vektöründen tamamen farklı ağırlık vektörüne sahip nöronlar sıfıra yakın bir çıkış verirler. Bu nöronların sonuç üzerindeki etkisi ihmal edilebilir. Karşıt biçimde, giriş vektörü ile aynı ağırlık vektörüne sahip nöronlar çıkış olarak 1 değerini verirler. Eğer gizli katmandaki bir nöronun çıkış değeri 1 ise, bu nörona ait ikinci katmandaki çıkış ağırlıkları değerlerini olduğu gibi ikinci katmandaki lineer nöronlara ulaştırırlar. Mantıken, gizli katmandaki nöronlardan sadece birinin çıkışının 1, diğerlerininin 0 olması gerekir ve dolayısıyla ikinci katmandaki lineer nöronların çıkışları , aktif nöronun çıkış ağırlıkları olması gerekir. Bu pratikte çok uç bir durumdur. Genelde her giriş vektörü için belirli sayıda nöron değişen ölçülerde çıkış verirler[1].

Radyal bazlı YSA lar için çeşitli parametre kestirim yaklaşımları mevcuttur. Bu çalışmada radyal bazlı YSA için kullanılan kestirim metodu verilmeden önce, ‘spread’ kavramı üzerinde durmak gerekir. Spread, giriş vektörü ile gizli katmandaki radyal bazlı nöronların ağırlık vektörleri arasındaki uzaklığın sonuca etki edebilecek anlamda bir çıkış verebildikleri en yüksek değerdir. Bir başka deyişle, tasarımcı tarafından belirlenen bu değer yardımıyla gizli katmandaki aktivasyon fonksiyonlarının giriş uzayındaki etki bölgeleri tanımlanmaktadır. Bu değerın çok düşük olması, sadece çok az veya bir nöronun çıkış vermesine sebep olur ki, bu durum model açısından kötü bir genelleştirmeye işaret eder. Aksi şekilde, çok büyük seçilen spread, giriş vektörü için tüm nöronların çıkış vermesi anlamına gelir ki, bu da tanılama işlemini işlevsiz kılar[1]. Özet olarak, kurulan YSA modeli için iyi bir genelleştirme elde etmek için, kullanılan nöron sayısı kadar, spread katsayısının makul bir değer aralığında seçiminin de önemi büyüktür.

Radyal Bazlı YSA’nın eğitimi yapılırken, çok katmanlı ileri beslemeli YSA da olduğu gibi, tanılama maksadını ifade eden bir performans fonksiyonu tanımlanır ve bu performans fonksiyonu minimize edilir. Lineer ya da çıkış katmanındaki ağırlıkların ayarlanması, yine çok katmanlı ileri beslemeli YSA da anlatılan parametre kestirim metodlarından herhangi biri uygulanarak gerçekleştirilebilir. Radyal Bazlı YSA’yı farklı kılan gizli katmandaki eğitim yapısıdır. Bu katmandaki

radyal bazlı aktivasyon fonksiyonlarının, her birinin beraber tanımlı olduğu ağırlık vektörleri vardır. Bu ağırlık vektörleri ayarlanmaz. Ağa, giriş vektörlerinden oluşan bir P girişler matrisi sunulur ve hata değeri hesaplanır. Bu hata değeri, belli bir hedef hata değerinden(goal) büyükse, hatayı en fazla yapan giriş vektörüne eşit bir ağırlık vektörüne sahip yeni bir radyal bazlı nöron gizli katmana eklenir. Bu proses, arzu edilen hata gerçekleştirilene kadar tekrarlanır. Radyal bazlı YSA'nın eğitimi dört madde ile özetlenebilir:

- 1) YSA çıkışı hesaplatılır.
- 2) Hatanın değerini en fazla yükselten giriş vektörü bulunur.
- 3) YSA'nın gizli katmanına, ağırlık vektörü bu hata vektörüne eşit olan radyal bazlı bir nöron eklenir.
- 4) İkinci katmandaki ağırlıklar, hatayı minimize etmek için tekrar ayarlanır.

3.2.3 Yinelenen YSA

3.2.3.1 Giriş

Bir yinelenen YSA, kendisini ileri beslemeli YSA dan ayıran en az bir geri besleme döngüsüne sahiptir. Yinelenen YSA bir veya daha fazla katmandan oluşabilir ve her bir nöronun girişi, diğer nöronların çıkışlarından meydana gelebilir. Yinelenen YSA, çıkış değeri, girişin ve çıkışın zaman içindeki değişimine bağlı olduğu veya bir başka deyişle zaman içinde uzamsal olan biçimlerin öğrenilmesinin gerekli olduğu hallerde kullanılabilir.


Literatürde tanıtılan çok sayıda yinelenen YSA tipi vardır. Bu çalışmada 'Elman ağı' kullanılacaktır[11].

3.2.3.2 Yapı seçimi

Yinelenen YSA'nın gizli katmanı tanjant sigmoid aktivasyon fonksiyonuna ve çıkış katmanı da lineer aktivasyon fonksiyonuna sahip nöronlardan oluşur. Daha önce anlatıldığı üzere, böyle bir yapı gizli katmanında yeter sayıda nörona sahip olması durumunda tüm nonlinear fonksiyonlara yakınsayabilir. Çıkış katmanında lineer fonksiyonların kullanılmasının sebebi, -1'den küçük veya +1'den büyük çıkışların mümkün olabilmesidir. Çünkü tanjant sigmoid fonksiyonları tüm girişler için -1-+1 aralığında çıkış verir.

3.2.3.3 Yinelenen YSA Mimarisi:

Bu çalışmada Elman ağı denilen ve Şekil 3.10' da gösterilen bir yinelenen YSA türü kullanılmıştır.



Şekil 3.11 [1]: Yinelenen YSA mimarisi

Bir Elman Ağı genellikle, ilk katmanın çıkışından ilk katmanın girişine bir geri beslemenin olduğu, iki katmanlı bir YSA dır. Bu geri besleme zamanla değişen biçimlerin öğrenilmesine imkân tanır. Gizli katmanlardaki nöronlar, tanjant sigmoid (tansig) fonksiyonunu kullanmaktadırlar.

3.2.3.4 Ağ Davranışı ve Parametre Kestirim Metodu

Yinelenen YSA'nın geri besleme döngüsü bir önceki zamana ait değerleri, mevcut zamanda kullanabilmek için depolar. Bu bilgi depolama özelliği sayesinde uzamsal biçimler gibi, geçici biçimleri de öğrenebilir[1]. Gizli katmanlarında tanjant sigmoid ve çıkış katmanında lineer fonksiyonlu nöronları bulunduran Elman Ağı, gizli katmandaki nöron sayısının yeterli olması halinde tüm fonksiyonlara yakınsayabilir[8]

Elman ağının eğitimi için, geri yayımlı eğitim algoritmalarından herhangi biri kullanılabilir. Bu çalışmada Bölüm 3.2.1'de anlatılmış olan Levenberg-Marquardt geri yayımlı algoritması ve Bayesian Regülasyonu kullanılmıştır.

Elman ağının eğitimi kısaca üç aşamadan oluşur:

- 1)Tüm giriş dizisi ağa sunulur ve bu girişler için hesaplatılan ağ çıkışları hedef değerlerle kıyaslanarak, hata dizisi oluşturulur.
- 2)Her bir zaman adımı için, hata değerlerinin ağ üzerinde geri yayınımlı yaptırılarak, bu hata değerlerinin her bir ağırlık ve yanlı terime göre gradyenleri bulunur. Burada

geri besleme döngüsüne ait ağırlıkların ve yanlı terimlerin hataya etkisi ihmal edildiğinden, bulunan hata gradyeni yaklaşık bir değerdir

3)Son olarak, bu hata gradyenleri Levenberg-Marquardt eğitim algoritması ve genelleştirmeyi iyileştirmek için uygulanan Bayesian Regülasyonu tarafından ağ parametrelerini kestirmek için kullanılır.



4. UYGULAMA SONUÇLARI VE TARTIŞMA


4.1 Uygulama Verisinin Tanıtılması

Bu çalışmada, daha önce tanıtımı yapılan çimento endüstrisindeki harmanlama prosesine ait üç girişli-iki çıkışlı sistemin 655 giriş-çıkış verisi kullanılmıştır. Sistem girişleri olarak demir cevheri, düşük mamül ve yüksek mamül, çıkışlar olarak demir oksit ve/veya kireç modülü olmak üzere üç ayrı model kurulmuş ve Bölüm 3 de tanıtımı yapılan YSA tipleri için Matlab® Neural Network Toolbox® kullanılarak uygulamaları yapılmıştır. Uygulama kodu Ek I’de mevcuttur.

Bu 655 verideki ortalama değerden çok fazla sapan değerler elimine edilerek veri sayısı 638 e indirilmiştir. Bu 638 verinin ilk 500’ü eğitim için kullanılmış, geri kalan 138 değer de YSA’yı test için kullanılmıştır.

4.2 Model 1


Sistem mertebesi 2 olarak kabul edilmiştir.



Şekil 4.1: Model 1


4.2.1 Çok Katmanlı İleri Beslemeli YSA Sonuçları

Kurulan çok katmanlı ileri beslemeli YSA(MLBP) modelinde gizli katmanda 3, çıkış katmanında 1 olmak üzere toplam dört nöron kullanılmıştır.




Şekil 4.2: Model 1 için ÇKİB YSA eğitim süreci

Şekil 4.2'deki grafikte çok katmanlı ileri beslemeli YSA'nın eğitim aşaması gösterilmiştir. Kullanılan Levenberg Marquardt parametre optimizasyon yöntemi ve Bayesian Regülasyonu ile hataların kareleri toplamı(sse) ve ağırlıkların kareleri toplamı(ssw) minimize edilmeye çalışılmıştır. En alttaki grafik efektif parametre sayısını göstermektedir. Şekil 4.3 den 4.7' ye kadar eğitim verisinin kurulan modele göre post-regresyon analizi, giriş ve çıkış değerlerinin sunumu, eğitim verisi için gerçek çıkışların YSA model çıkışları ile kıyaslanması ve hata analizleri yapılmıştır. Şekil 4.7'den 4.12'e kadar aynı işlemler test verisi için tekrar edilmiştir. Şekil 4.3'de eğitim verisi için post-regresyon analizi yapılmıştır. Bir başka deyişle, ağ çıkışları ve gerçek çıkışlar arasındaki korelasyon araştırılmıştır. Bu korelasyonu ifade eden sabit R'dir. Daha sonra vurgulanacağı gibi, R değerinin test verileri için elde edilmiş olan YSA modellerinin başarı kriteri olarak kullanılacaktır. Bu değer 1'e mümkün olduğunca yakın olması istenir.




Şekil 4.3: Model 1 ÇKİB YSA eğitim verisi için post-regresyon analizi

Şekil 4.6'daki grafikte ÇKİB YSA'nın eğitim hedef çıkışı ile kurulan modelin verdiği çıkışlar beraber gösterilmektedir. Grafikten de görüldüğü gibi model eğitim




Şekil 4.4: Model 1 için eğitim girişi




Şekil 4.5: Model 1 için Eğitim Çıkışı

verisini çok iyi şekilde öğrenmiştir. YSA modelinin nöron sayısı artırılarak bu öğrenme daha da kusursuzlaştırılabilir. Fakat bu durum arzulanmaz çünkü asıl amaç




Şekil 4.6: Model 1 için ÇKIB YSA ve eğitim çıkışları




Şekil 4.7: Model 1 için ÇKIB YSA eğitim hata analizi

YSA modelinin eğitim verisini ezberlemesi değil, sistemin dinamik davranışını öğrenmesidir. Bu sebeple, modelin başarılı olup olmadığının belirlenmesi, Şekil 4.9




Şekil 4.8: Model 1 için ÇKIB YSA test verisi post-regresyon analizi




Şekil 4.9: Model 1 için test girişi


ve 4.11 de gösterilen test giriş-çıkış verisinin sistem tarafından ne ölçüde gerçekleştirildiğine bağlıdır. Şekil 4.8’de gösterilen test verisine ait post-regresyon



Şekil 4.10: Model 1 için test çıkışı



Şekil 4.11: Model 1 için ÇKIB YSA ve Test Çıkışları



Şekil 4.12: Model 1 için ÇKIB YSA test hata analizi

analizinde, R ile gösterilen katsayı YSA modelinin test girişine verdiği çıkışlar ile gerçek çıkışlar arasındaki korelasyonu belirleyen bir katsayıdır. Bu katsayının 1

değerine eşit olması tanılamının mükemmel biçimde gerçekleştirildiğini ifade eder. Dolayısıyla bu çalışmada yapılan tanılamaların başarıları, ilgili tanılamının test çıkışları için elde edilmiş korelasyon katsayısının 1 değerine yakınlığı ile orantılı olarak takdir edilecektir. Ayrıca, bu katsayı model hatalarının mutlak değerleri toplamı(SAE) ile beraber farklı YSA modellerinin birbirleriyle kıyaslanmasının ölçütleri olarak kullanılacaklardır. YSA modelinin geçerliliğini incelerken gözönünde tutulan en önemli görsel unsur, Şekil 4.10'da gösterilen ve test verisi için, YSA modelinin gerçek çıkışı ne ölçüde izleyebildiği bilgisini veren grafiklerdir. Şekil 4.10'da mevcut YSA modelinin, gerçek sistemin karakteristiğini gayet iyi temsil ettiğini fakat çok az bir zaman gecikmesi ve hemen hemen 1×10^{-3} civarında bir izleme hatası olduğu görülür. Bu izleme hatası YSA modelindeki çıkış nöronuna ait yanlış terimin değeri değiştirilerek azaltılabilir. Bu değişiklik aşağıdaki komutları kullanarak, Matlab® komut penceresinde gerçekleştirilir:

```
mnet.b{2}
```


```
ans =
```

```
1.1783
```


YSA'nın çıkış nöronuna ait yanlış terimin değeri öğrenildikten sonra, mevcut değere 0.7×10^{-3} eklenerek, yanlış terim değiştirilir:

```
mnet.b{2}=1.1790
```


Yanlış terimin değiştirilmesi, sabit modelleme hatalarının olduğu durumlarda, bu hataların giderilmesini ve YSA modelinin daha arzu edilir şekilde hedef çıkışları izlemesini sağlar. Ağ yapısında bu tarz bir düzeltme yapmadan önce, eğer imkân dahilinde ise farklı test verileri ile izleme hatasının büyüklüğünden emin olunmalıdır. Çünkü model yapısında yapılan bu değişiklik kalıcıdır. Ayrıca bu değişiklik, YSA'nın yapısında neden yanlış terimler gibi ağ girişlerinden bağımsız parametrelere ihtiyaç duyulduğunu anlamaya da imkân verir. Bununla beraber, eğer çıkış nöronları lineer değilse, sonuçlar üzerinde bu yolla istenen bir değişme elde etmek çok zorlaşır. Çünkü yanlış terimdeki değişimin, çıkışı veren nonlineer fonksiyonun değerini ne ölçüde değiştireceğini tahmin etmek her zaman mümkün değildir. Bu durum da, çıkış katmanlarında lineer fonksiyonlar kullanmanın bir başka avantajı olarak ifade edilebilir. Elde edilen değiştirilmiş YSA modeli, eğitim ve test verileri için tekrar incelenir:



Şekil 4.13: : Model 1 için ÇKİB YSA eğitim post-regresyon analizi




Şekil 4.14: Model 1 için ÇKİB YSA ve eğitim çıkışları




Şekil 4.15: Model 1 için ÇKİB YSA eğitim hata analizi

Yanlı terimde yapılan bu değişiklik, YSA modelinin eğitim çıkışı için gerçek çıkışları izleme kabiliyetini Şekil 4.14’de gösterildiği gibi biraz bozar. Fakat bu




Şekil 4.16: Model 1 için ÇKİB YSA test post-regresyon analizi



Şekil 4.17: Model 1 için ÇKİB YSA ve test çıkışları

bozulmanın tanılama açısından bir sakıncası yoktur. Çünkü zaten problem YSA'nın eğitim verisini aşırı öğrenmesi veya bir başka deyişle ezberleme yapmasından




Şekil 4.18: Model 1 için ÇKİB YSA test hata analizi

kaynaklanmaktadır. Yanlı terimle yapılan ayarlama ile ezberlemeden kaynaklanan sabit izleme hatası kaldırılmıştır. Yapılan düzeltme korelasyon katsayısında bir değişime neden olmaz. Şekil 4.17’de çok katmanlı ileri beslemeli YSA’nın, model 1 için makul bir izleme gerçekleştirildiği görülür. Ayrıca korelasyon katsayısının 1 değerine yakın olması($R=0.797$) tanılamanın başarılı olduğunu gösterir.


4.2.2 Radyal Bazlı YSA Sonuçları

Çok katmanlı ileri beslemeli YSA’da yapılan işlemler, Radyal bazlı YSA için tekrarlanır. Gizli katmanda 20 ve çıkış katmanında 1 olmak üzere toplam 21 nöron kullanılmıştır.




Şekil 4.19: Model 1 için RB YSA eğitim süreci

Burada RB YSA, hedef hata değerine ulaşana kadar gizli katmanına nöron ekleyerek eğitim süreci boyunca ağ büyüklüğünü artırmaktadır. Hedef hata değerine ulaşılamamış, fakat kullanıcı tarafından belirlenen maksimum nöron sayısına ulaşıncaya, eğitim arzu edilen hataya yakın bir değerde durmuştur. Nöron sayısı için bir üst sınır belirlenmesinin sebebi, RB YSA’nın çok sayıda nörona sahip olması durumunda meydana gelecek genelleştirme problemlerinden kaçınmaktır. Çok sayıda nörona sahip RB YSA eğitim çıkışı kusursuz izler ama test çıkışlarını istendiği gibi takip edemez(Eğitim verisinin ezberlenmesi durumu).




Şekil 4.20: Model 1 için RB YSA eğitim post-regresyon analizi

Radyal bazlı YSA'nın eğitim algoritması Bölüm 3'de anlatıldığı gibi farklı yapıdadır. Bu farklılık, ilk katmandaki ağırlıkların belirlenmesi ile ilgilidir. Ağırlıklar ayarlana-




Şekil 4.21: Model 1 için RB YSA ve eğitim çıktıları




Şekil 4.22: Model 1 için RB YSA eğitim hata analizi

bilir katsayılar olmadıklarından ve her bir nöronla bağlantılı ağırlıklar diğerlerinden bağımsız bir vektörü tanımladıklarından, ağırlıkların başlangıç değerleri yoktur. Bu




Şekil 4.23: Model 1 için RB YSA post-regresyon analizi



Şekil 4.24: Model 1 İçin RB YSA ve test çıkışları

durum da ağ parametrelerine başlangıç değerleri atanması problemi ortadan kaldırarak RB YSA'nın diğerlerinden farklı olarak, daha deterministik bir eğitim




Şekil 4.25: Model 1 için RB YSA test hata analizi

sürecine sahip olmasına sebep olur. Yani bir başka deyişle, tüm farklı eğitim denemelerinde aynı sonuçlar elde edilir. Şekil 4.24'de test girişleri için gerçek sistem çıkışları ve YSA çıkışları kıyaslanmaktadır. YSA modelinin gerçek çıkışları izlemesi grafikten görüldüğü üzere iyidir. Ayrıca korelasyon katsayısı 1'e yakın olduğundan ($R=0.757$) tanımlama başarılı olarak nitelendirilebilir.


4.2.3 Yinelenen YSA Sonuçları

Bölüm 4.2.1 ve 4.2.2'de yapılanlar, yinelenen YSA modeli için tekrar edilir. Modelde, gizli katmanda 2, çıkış katmanında 1 olmak üzere toplam 3 nöron kullanılmıştır.




Şekil 4.26: Model 1 için Yinelenen YSA eğitim süreci


Şekil 4.26'daki grafikten, performans fonksiyonunun ilk kısmı olan hataların kareleri toplamı (sse) yaklaşık ilk 20 adımdan sonra son hata değerine ulaşmış olduğu, fakat performans fonksiyonunun ikinci kısmını oluşturan parametrelerin kareleri toplamı (ssw)'nın kullanıcı tarafından müsaade edilen en yüksek iterasyon sayısı olan 300. adıma kadar azaldığı görülmektedir. Bu durumun sebebi, Bayesian öğrenmesi gereği, parametrelerin kareleri toplamının performans fonksiyonu üzerindeki etkinliğini belirleyen katsayının eğitim süreci boyunca artmasıdır. Bu değişim amacı, hedef hata değerinin yanında, iyi bir genelleştirme de elde etmektir.



Şekil 4.27: Model 1 için Yinelenen YSA eğitim post-regresyon analizi




Şekil 4.28: Model 1 için Yinelenen YSA ve eğitim çıktıları




Şekil 4.29: Model 1 için Yinelenen YSA eğitim hata analizi

Yinelenen YSA, gerçek sistemin mertebesinde bir problemin olduğu bazı istisnai durumlar dışında genellikle ÇKİB YSA ile çok benzer sonuçlar verir.




Şekil 4.30: Model 1 için Yinelenen YSA test post-regresyon analizi



Şekil 4.31: Model 1 için Yinelenen YSA ve test çıkışları

Şekil 4.31'de test girişleri için gerçek sistem çıkışları ve YSA çıkışları kıyaslanmaktadır. Çok katmanlı ileri beslemeli ve radyal bazlı YSA modellerinde



Şekil 4.32: Model 1 için Yinelenen YSA ve test hata analizi


olduğu gibi, çok az bir zaman gecikmesine ve yaklaşık 1×10^{-3} büyüklüğünde izleme hatasına rağmen, orijinal sistemin karakteristiği çok iyi öğrenilmiştir. Bahsedilen izleme, daha önce yapıldığı gibi yanlış terimde bir düzeltme ile giderilebilir. Gerekli Matlab® kodu:

```
mnet.b{2}
```

```
ans =
```


```
-0.1971
```

```
mnet.b{2}=-0.1965
```




Şekil 4.33: Model 1 için Yinelenen YSA eğitim post-regresyon analizi


Şekil 4.33'de gösterilen ve eğitim sürecinin başarısına işaret eden korelasyon katsayısının(R) değerini daha da artırıp ideal duruma işaret eden 1 değerine yaklaştırmak mesele değildir. Nöron sayısı artırılarak bu istek gerçekleştirilebilir. Ama böyle bir teşebbüs, Şekil 4.36'da gösterilen, YSA modeli ve ağ çıkışları arasındaki korelasyonu temsil eden ve 1 değerine yakınlığı tanılama amacının gerçekleşip gerçekleşmediğini belirten sabitin değerini düşürür.



Şekil 4.34: Model 1 için Yinelenen YSA ve eğitim çıkışları




Şekil 4.35: Model 1 için Yinelenen YSA eğitim hata analizi




Şekil 4.36: Model 1 için Yinelenen YSA eğitim post-regresyon analizi

Şekil 4.36'da gösterilen korelasyon katsayısı($R=0.787$) 1 değerine yakındır, bu sebeple tanımlama başarılı kabul edilebilir.




Şekil 4.37: Model 1 için Yinelenen YSA ve test çıkışları



Şekil 4.38: Model 1 için Yinelene YSA test hata analizi

4.3 Model 2


Sistem mertebesi 2'dir.



Şekil 4.39: Model 2


4.3.1 Çok Katmanlı İleri Beslemeli YSA Sonuçları

Model iki için çok katmanlı ileri beslemeli YSA'nın gizli katmanında 6, çıkış katmanında 1 olmak üzere toplam 7 nöron kullanılmıştır.




Şekil 4.40: Model 2 için ÇKİB YSA eğitim süreci


Şekil 4.40'da gösterilen Model 2 için ÇKİB YSA eğitim sürecinde, kullanıcı tarafından belirlenen hedef hata değeri 0.001'dir. 300. adımdan sonra elde edilen hataların kareleri toplamının (sse), arzulanan hedeften çok uzakta olduğu ve sadece eğitim sürecini gözlemlemenin bile, bu tanılamamanın sonuçlarının olumsuz olduğuna dair fikir edinmek için yeterli olabileceği söylenebilir. Eğer sse değeri sabitlendikten sonra, ağırlıkların kareleri toplamının (ssw) eğitim sürecindeki değişimini gösteren eğrideki eksi yöndeki eğim son adıma kadar devam etmiş olsaydı, algoritmanın sse değeri sabitlendikten sonra başka bir bağlamda başarılı bir biçimde çalıştığı söylenebilirdi. Fakat ssw değeri de belli bir adımdan sonra sabitlendiğinden, algoritmanın eldeki veri ile istenen sonuca ulaşmada yeterli olmadığı sonucuna varılır. Efektif parametre sayısını gösteren eğrinin, eğitim süreci boyunca hiçbir şekilde negatif yönde ilerlememesi, YSA'nın optimum parametre sayısına ulaşmadığı ve dolayısıyla daha fazla nöron eklenmesi gerektiği izlenimini uyandırabilir. Bununla beraber, belirtilen izlenim sebebiyle kurulan ÇKİB YSA modelinin gizli katmanındaki nöron sayısı artırılarak yapılan denemelerin genelleştirmeyi bozduğu görülmüştür.



Şekil 4.41: Model 2 için ÇKİB YSA eğitim post-regresyon analizi




Şekil 4.42: Model 2 için eğitim girişleri




Şekil 4.43: Model 2 için eğitim çıkışları


Şekil 4.44’de ÇKİB YSA ve eğitim çıkışları gösterilmektedir. YSA modeli eğitim çıkışları için iyi bir izleme göstermektedir.



Şekil 4.44: Model 2 için ÇKİB YSA ve eğitim çıkışları




Şekil 4.45: Model 2 için ÇKİB YSA eğitim hata analizi




Şekil 4.46: Model 2 için ÇKİB YSA test post-regresyon analizi


Şekil 4.46'da RB YSA'nın test çıktıları için post-regresyon analizi gösterilmektedir. Korelasyon sabiti($R=0.33$) 1 değerinden oldukça uzaktır. Bu sebeple RB YSA'nın




Şekil 4.47: Model 2 için test girişleri



Şekil 4.48: Model 2 test çıkışı



Şekil 4.49: Model 2 için ÇKİB YSA test çıktıları




Şekil 4.50: Model 2 için ÇKİB YSA test hata analizi

Model 2 için başarısız bir tanılama gerçekleştirdiği söylenebilir. Bu başarısızlığın muhtemel nedenleri Bölüm 5’de tartışılacaktır.

Şekil 4.49’daki grafik, gerçek sistem ve YSA modelinin test girişlerine verdiği cevapların karşılaştırmasını göstermektedir. Grafik incelendiğinde, YSA modelinin gerçek sistemi izleme performansının kötü olduğunu, yer yer gerçek sistemin karakteristiğini kavramış olduğu izlenimi yaratsa da, daha ileri uygulamalar için güvenilir bir model oluşturamadığı sonucuna varılır.


4.3.2 Radyal Bazlı YSA Sonuçları

Radyal bazlı YSA’nın gizli katmanında 18, çıkış katmanında 1 olmak üzere toplam 19 nöron kullanılmıştır.




Şekil 4.51: Model 2 için RB YSA eğitim süreci


Şekil 4.51’de eğitim süreci gösterilen RB YSA modelinin de, ÇKİB YSA’da olduğu gibi arzulanan hata değerini sağlamadan çok uzakta olduğu söylenebilir. Kullanıcı tarafından müsaade edilen maksimum nöron sayısı 18’dir. Dolayısıyla RB YSA, bu rakama ulaşıncaya dek gizli katmanına nöron ekleyerek hata değerini düşürmeye çalışır. Kullanıcı tarafından her beş nöron artırımında bir bilgi istendiğinden, Şekil 4.51’deki grafikte en son 15. nörona ulaşıldığı duruma ait performans fonksiyonu azalması gözlemlenmektedir.



Şekil 4.52: Model 2 için RB YSA eğitim post-regresyon analizi




Şekil 4.53: Model 2 için RB YSA ve eğitim çıktıları




Şekil 4.54: Model 2 için RB YSA eğitim hata analizi

Şekil 4.55'deki RB YSA post-regresyon analizi incelendiğinde, korelasyon




Şekil 4.55: Model 2 için RB YSA test post-regresyon analizi

katsayısının($R=0.335$) 1 değerinden uzak olduğu ve ÇKİB YSA'da olduğu gibi



Şekil 4.56: Model 2 için RB YSA ve test çıkışları




Şekil 4.57: Model 2 için RB YSA test hata analizi

Model 2 için RB YSA tanılamasının başarısız olduğu sonucuna varılır. Şekil 4.56'daki grafik, YSA modeli ve gerçek sistemin test girişleri için çıkışlarını karşılaştırmalı olarak göstermektedir. Grafik incelendiğinde, radyal bazlı YSA'nın gerçek sisteme ait test çıkışlarını güvenilir bir şekilde izlemeyediği görülür. Bölüm 5'de bu durumun olası sebepleri üzerinde tartışılacaktır.


4.3.3 Yinelenen YSA Sonuçları

Yinelenen YSA modelinin gizli katmanında 3, çıkış katmanında 1 olmak üzere toplam 4 nöron kullanılmıştır.




Şekil 4.58: Model 2 için Yinelenen YSA eğitim süreci


Model 2 için Yinelenen YSA eğitim süreci Şekil 4.58'de gösterilmektedir. Başarılan hata değerinin hemen hemen ÇKİB YSA ile aynı olduğu, fakat gerek ağırlıkların kareleri toplamının, gerekse efektif parametre sayısının çok daha düşük olduğu gözlemlenmektedir. Bu durum, Yinelenen YSA'nın Model 2 için daha iyi bir genelleştirme yapacağına işaret eder. Daha sonra, YSA modelinin geçerliliğini test aşamasında bu beklentinin gerçekleştiği görülür.



Şekil 4.59: Model 2 için Yinelenen YSA eğitim post-regresyon analizi




Şekil 4.60: Model 2 için Yinelenen YSA ve eğitim çıkışları




Şekil 4.61: Model 2 için Yenilenen YSA hata analizi

Şekil 4.62’de Model 2 için Yenilenen YSA test post-regresyon analizi




Şekil 4.62: Model 2 için Yenilenen YSA post-regresyon analizi

gösterilmektedir. Korelasyon sabiti($R=0.338$) 1 değerine uzak olduğundan tanılama



Şekil 4.63: Model 2 için Yinelenen YSA ve test çıkışları




Şekil 4.64: Model 2 için Yinelenen YSA test hata analizi

başarısızdır. Şekil 4.63'deki grafik gerçek sistem ve YSA modeli çıkışlarını, test girişleri için karşılaştırmalı olarak vermektedir. Burada da Model 2 için kurulmuş diğer YSA modellerinde olduğu gibi, sağlıklı bir tanılama gerçekleştirilememiştir. Başarısızlığın nedenleri üzerinde daha sonra tartışılacaktır.

4.4 Model 3


Sistem mertebesi 2'dir. Model 3 'de Model 1 ve Model 2'den farklı olarak çok girişli-çok çıkışlı bir YSA yapısı kurulacaktır. Böylece, daha ileri aşamalarda kontrolü istenebilecek Demir Oksit ve Kireç Modülü değerlerinin tek bir model üzerinden eldesi mümkün olabilecektir.




Şekil 4.65: Model 3

4.4.1 Çok Katmanlı İleri Beslemeli YSA Sonuçları


Kurulan YSA modelinin, gizli katmanında 7 ve çıkış katmanında 2 olmak üzere toplam 9 nöronu vardır. Daha önceki modellerde yapılan işlemler, burada da tekrarlanır.




Şekil 4.66: Model 3 için ÇKİB YSA eğitim süreci



Şekil 4.67: Model 3 için ÇKİB YSA eğitim post-regresyon analizi




Şekil 4.68: Model 3 girişleri




Şekil 4.69: Model 3 çıkışları

Şekil 4.70'de çok girişli-çok çıkışlı ÇKİB YSA modelinin eğitim çıkışlarını çok iyi bir şekilde izlediği görülmektedir. Fakat daha önce de vurgulandığı üzere asıl kriter




Şekil 4.70: Model 3 için ÇKİB YSA ve eğitim çıkışları




Şekil 4.71: Model 3 için ÇKİB YSA eğitim hata değerleri

YSA modelinin test çıkışlarını izleme kabiliyetidir. Şekil 4.73'de Model 3 için ÇKİB




Şekil 4.72: Model 3 için ÇKİB YSA eğitim hata yüzdeleri




Şekil 4.73: Model 3 için ÇKİB YSA test post-regresyon analizi

YSA modelinin test verisi için post-regresyon analizi görülmektedir. Demir oksit




Şekil 4.74: Model 3 girişleri




Şekil 4.75: Model 3 çıkışları


çıkışı için korelasyon sabitinin($R=0.683$) 1 değerine, Model 1'deki kadar olmasa da, yakın olduğu ve dolayısıyla tanılamamanın ilk çıkış için başarılı olduğu öne sürülebilir.



Şekil 4.76: Model 3 için ÇKİB YSA ve eğitim çıkışları



Şekil 4.77: Model 3 için ÇKİB YSA test hata değerleri




Şekil 4.78: Model 3 için ÇKİB YSA test hata yüzdeleri

Fakat ikinci çıkış için bulunan korelasyon sabiti($R=0.0622$) 1 değerine oranla çok küçüktür ve çok girişli-çok çıkışlı modelin kireç modülü için tanınması oldukça başarısızdır. Şekil 4.76'daki grafikte, sistemin iki çıkışı(demir oksit ve kireç modülü) için, gerçek çıkışlar ve YSA çıkışları karşılaştırmalı olarak gösterilmiştir. İlk çıkış hem sistem karakteristiğini öğrenme, hem de izleme hatasına göre ikinci çıkıştan daha iyi takip edilmiştir.


4.4.2 Radyal Bazlı YSA Sonuçları

RB YSA'nın gizli katmanındaki özel tip nöronlardan kaynaklanan yerellik özelliği, bir ilk yaklaşım olarak çok girişli-çok çıkışlı modeller için diğer tiplere nazaran daha iyi sonuç vereceği fikrinin oluşmasına sebep olabilir. Bu fikrin ardında, farklı çıkışların birbirine bozucu etki yapmayacağı kabulü vardır. Uygulama sonuçlarına bakarak, bu beklentinin gerçekleşip gerçekleşmediği daha sonra yorumlanacaktır.


YSA modelinin gizli katmanında 19, çıkış katmanında 2 olmak üzere toplam 21 nöron kullanılmıştır. Ve simülasyon sonuçları grafik olarak elde edilmiştir.




Şekil 4.79: Model 3 için RB YSA eğitim süreci



Şekil 4.80: Model 3 için RB YSA eğitim post-regresyon analizi




Şekil 4.81: Model 3 için RB YSA ve eğitim çıktıları




Şekil 4.82: Model 3 için RB YSA test hata değerleri

Şekil 4.84'de RB YSA modelinin test çıkışı için post-regresyon analizi gösterilmek-




Şekil 4.83: Model 3 için RB YSA eğitim hata yüzdeleri




Şekil 4.84: Model 3 için RB YSA test hata yüzdeleri


tedir. Korelasyon sabitleri incelendiğinde tanılamamanın demir oksit çıkışı için başarılı, kireç modülü için başarısız olduğu görülür. Fakat sonuçlar ÇKİB YSA modeline



Şekil 4.85: Model 3 için RB YSA ve test çıkışları



Şekil 4.86: Model 3 için RB YSA test hata değerleri




Şekil 4.87: Model 3 için RB YSA test hata yüzdeleri


göre daha iyidir. Şekil 4.85’de YSA modeli ve gerçek sistemin, test verilerine cevapları açısından kıyaslamaları yapılmıştır. Buradan da açıkça görüldüğü gibi, tanılama demir oksit çıkışının modellenmesi açısından başarılı, kireç modülü çıkışı açısından ise başarısızdır. Bu başarısızlığın nedenleri bölüm 5’de tartışılacaktır. Dikkate değer bir başka husus, RB YSA modelinin çok girişli-çok çıkışlı sistem için ÇKİB YSA’ya göre farkedilir derecede daha iyi sonuç vermesidir. Fakat bu farka dayanarak genel bir sonuca gitmeden önce, Yinelenen YSA’nın aynı tanılamayı ne ölçüde gerçekleştirdiği gözlemlenmelidir. Çünkü, Yinelenen YSA yapısal olarak ÇKİB YSA’ya benzerdir ve ancak RB YSA’nın Yinelenen YSA’ya göre de bir tanılama üstünlüğü farkedilirse, genel bir sonuca gidilir. Aksi takdirde, Bölüm 5’de de vurgulanacağı gibi, bu üstünlük büyük olasılıkla eğitim süreci ile ilgili özel koşullardan kaynaklanmaktadır.

4.4.3 Yinelenen YSA Sonuçları


Model 3 için kurulan Yinelenen YSA modelinin gizli katmanında 9, çıkış katmanında 2 olmak üzere toplam 11 nöron kullanılmıştır.




Şekil 4.88: Model 3 için Yinelenen YSA eğitim süreci



Şekil 4.89: Model 3 için Yinelenen YSA eğitim post-regresyon analizi




Şekil 4.90: Model 3 için Yinelenen YSA ve eğitim çıkışları




Şekil 4.91: Model 3 için Yinelenen YSA hata değerleri

Şekil 4.93'de Model 3 için Yinelenen YSA test post-regresyon analizi görülmektedir




Şekil 4.92: Model 3 için Yinelenen YSA eğitim hata yüzdeleri




Şekil 4.93: Model 3 için Yinelenen YSA test hata yüzdeleri


Grafikteki korelasyon katsayılarının değerlerine göre, demir cevheri için YSA modeli başarılı, kireç modülü için ise başarısızdır.



Şekil 4.94: Model 3 için Yinelenen YSA ve test çıkışları



Şekil 4.95: Model 3 için Yinelenen YSA test hata değerleri



Şekil 4.96: Model 3 için Yenilenen YSA test hata yüzdeleri

Şekil 4.94'deki grafik YSA modeli ve gerçek sistem için test çıkışlarını karşılaştırmalı olarak vermektedir. Yenilenen YSA modelinin demir oksit çıkışını izlemesinin makul olduğu fakat kireç modülü için güvenilir bir izleme elde edilemediği, bu grafik yardımıyla da görülür.

4.5 YSA Tiplerinin Kıyaslanması

Bu çalışmada değişik tipte yapay sinir ağları ile aynı veriler üzerinden yapılan tanılamaları ve bu tiplerle ilgili daha önce yapılmış ve literatürde mevcut olan çalışmaları gözönüne alarak, çok katmanlı ileri beslemeli, radyal bazlı ve yenilenen YSA ların sistem tanılama kabiliyetleri tartışılabilir.

4.5.1 Çok Katmanlı İleri Beslemeli(ÇKİB) YSA Sistem Tanılama Özellikleri

Bu tip YSA'ların enterpolasyon özelliği, sigmoid fonksiyonların biçimine bağlı olarak monotoniktir. Ekstrapolasyon özelliği, sigmoid fonksiyonlarının sönümleyici özelliğinden dolayı, yüksek değer aralıklarında sabittir. Bununla beraber, eğer sigmoid fonksiyonunun eğimi çok düşük ise, düşük değer aralıklarında ekstrapolasyon özelliği lineer olabilir. Hangi genlik seviyesinde ağıın ekstrapolaston yapacağı

bilinmediğinden, ağın bu özellikle ilgili davranışını kestirmek zordur. YSA modelinin çıkış katmanındaki ağırlıklardan birini bile değiştirmek, çok büyük bir giriş uzayı için çıkışlarda önemli etkilere yol açtığından, bu tip YSA ların yerellik özelliği yoktur. Yine de, aktivasyon fonksiyonları çok katı biçimde global olmadığından, bu tip YSA lar sadece aktivasyon fonksiyonları sönümleme yapmadığında yakınsama esnekliğine sahiptirler. Dolayısıyla yakınsama mekanizması kısmen yerelliğe sahiptir. Doğruluk(kesinlik) genellikle çok yüksektir. ÇKİB YSA'nın gizli katmanındaki ağırlıkların optimizasyonu çok güçlü olduğundan aynı doğruluk oranını yakalamak için diğer model mimarilerine göre çok daha az nöron ve dolayısıyla parametre kullanılır. Monotonik enterpolasyon davranışına bağlı olarak, bu tip YSA ların çıkışı düzgün ve yumuşaktır(smooth). Global karakterinden veya başka bir deyişle, parametreleri belirlemek için tüm veri örnekleri kullanıldığından, gürültüye karşı duyarlılığı düşüktür. Parametre optimizasyonu genellikle nonlineer optimizasyon teknikleri ile gerçekleştirilir ve dolayısıyla yavaştır. Çevrimiçi çalışması yavaştır ve parametrelerin nonlineerliğinden ve global yakınsama karakteristiğinden dolayı çok güvenilir değildir. Nonlineer optimizasyon teknikleri kullanıldığından ve muhtemel yetersiz bir local optimuma takılma ihtimali dolayısıyla birkaç kez ağırlıklara yeni başlangıç değerleri verip tekrar deneme ihtiyacı yüzünden, eğitim hızı çok yavaştır. Model bir kez kurulduktan sonra, diğer YSA mimarilerine göre nöron sayısı az olduğundan hesaplama hızı oldukça yüksektir. Genellikle diğer YSA'larda da olduğu gibi yorumlanması ve prosese ait önbilginin kullanılması çok kısıtlıdır. Sonuç olarak bu tip YSA'lar en yaygın kullanılan ve standart YSA'lardır[10].

4.5.2 Radyal Bazlı(RB) YSA Sistem Tanılama Özellikleri

Bazı radyal bazlı fonksiyonların salınımı çok küçük seçildiğinden enterpolasyon davranışı ani inişlere sahip olur ve dolayısıyla monotonik olmamaya meyillidir. Aktivasyon fonksiyonları tipik olarak lokal olduklarından ekstrapolasyon özelliğinin sıfırlara eğilimi vardır. Lokal aktivasyon fonksiyonları kullanıldığından, yerellik(locality) garantilenmiştir. Kesinlik genellikle orta düzeydedir. Gizli katmandaki ağırlıklar genellikle optimize edilmediğinden ve deneysel olarak belirlendiğinden, yüksek kesinlik için çok sayıda nörona ihtiyaç vardır. Çıkışın düzgün ve yumuşak(smooth) olması genellikle seçilen aktivasyon fonksiyonuna bağlıdır. Bu çalışmada kullanılan radyal bazlı YSA'nın yeteri kadar yumuşak bir çıkış vermesi için, bölüm 3 de tanıtılmış olan ve aktivasyon fonksiyonunun giriş

uzayındaki etki alanını belirleyen ‘spread’ sabiti yeterince büyük olmalıdır. Radyal bazlı aktivasyon fonksiyonları giriş uzayının sadece yeteri verinin bulunduğu bölgelerine yerleştirildiğinden ve ağ parametrelerindeki küçük değişimlerin sadece yerel etkisi olduğundan, bu tip YSA’ların gürültüye duyarlılığı çok düşüktür. Gizli katmandaki nöronlar deneysel olarak yerleştirildiğinden ve sadece çıkış ağırlıkları en küçük kareler yöntemiyle optimize edildiğinden, parametre optimizasyonu oldukça hızlıdır. Ve yine sadece çıkış ağırlıkları optimize edildiğinden, çevrimiçi adaptasyon sağlam ve etkilidir. Baz fonksiyonlarının yerelliği sebebiyle, bir çalışma bölgesindeki çevrimiçi işleyiş diğerlerini etkilemez. Bu çalışmada kullanılan radyal bazlı YSA konfigürasyonu için eğitim oldukça hızlıdır. Diğer YSA tipleriyle kıyaslandığında hesaplama hızı düşüktür çünkü diğerleriyle aynı hassasiyeti sağlaması için, gizli katmanında çok sayıda nörona ihtiyaç vardır. Bu durum, modelin simule edileceği ortamdaki işlemci hızı ve hafıza durumuna göre, önemli bir problem teşkil edebilir. Gizli katman fonksiyonlarının deneysel olarak bulunması ve lokal çalışması sebebiyle parametrelerin yorumlanması mümkündür. Ve dolayısıyla prosese ait ön bilgi kullanılarak, verilen çalışma aralığında istenilen davranışı göstermesi sağlanabilir. Kullanışı ÇKİB YSA’lar kadar yaygın olmasa da, gittikçe artmaktadır[10].

4.5.3 Yinelenen YSA Sistem Tanılama Özellikleri

Bu çalışmada kullanılan yinelenen YSA’nın genel sistem tanılama özellikleri Bölüm 4.5.1’de anlatılan ÇKİB YSA’ninkilerle aynıdır. Ama bununla beraber, sistem tanılamaya getirdiği bazı avantajlar ve dezavantajlar vardır. Geri besleme döngüsü zaman içinde uzamsal olan biçimlerin öğrenilmesinde etkili olur[1]. Mevcut çıkışın, girişin ve çıkışın önceki değerlerine bağlı olduğu bu tip sistemlerde, özellikle merteye belirlenmesinde sorun varsa yinelenen sinir ağı kullanılabilir. Dezavantajı, geri yayınlı optimizasyon algoritması ile gizli katmandaki ağırlıkları ayarlarken, geri besleme döngüsünü değerleyen ağırlık için tahmini bir rakam kullanması ve bundan kaynaklanabilecek izleme hatalarıdır. Bu tip YSA’lar genellikle görüntü, ses, karakter tanıma gibi alanlarda kullanılsa da, özellikle son yıllarda sistem tanılamadaki uygulamaları artmıştır.

5. GENEL SONUÇLAR ve ÖNERİLER


Bölüm 4’de çimento endüstrisindeki harmanlama prosesine ait süreçler için bulduğumuz YSA modellerinin, eğitim ve test verileri için performanslarını inceledik. Matlab® kullanarak yaptığımız simülasyon sonuçları arasında, sistem tanılama sonucu bulunan modellerin ne kadar işlevsel olduğunu gösteren en önemli veriler; test verileri için yapılan post-regresyon analizlerinden elde edilen korelasyon sabitleri(R), YSA modeli ile gerçek sistem çıkışlarının hatalarının mutlak değerleri toplamı(SAE) ve son olarak bu sayısal kriterlere ek ve görsel olarak tanılanmanın gerçekleşip gerçekleşmediğinin tespiti için YSA modellerinin test girişlerine verdiği çıkışları ve gerçek test çıkışlarını gösteren karşılaştırmalı grafiklerdir. Bu bölümde demir cevheri, yüksek mamül ve düşük mamül girişleri için demir oksit, kireç modülü ve demir oksit+kireç modülü çıkışlarını veren üç ayrı modelin, değişik tipte YSA’lar ile yapılan tanılamaları, sözkonusu veriler dikkate alınarak karşılaştırmak ve genel sonuçlara gidilmesine çalışılacaktır.

Tablo 5.1’de Model 1 için her üç tip YSA modelinin eğitim ve test verisi için korelasyon katsayıları ve hataların mutlak değerleri toplamı gösterilmektedir. Tablodaki R-test(test verisi için korelasyon katsayıları) değerlerine bakıldığında her üç YSA tipinin de Model 1 için başarılı olduğu görülür. Çünkü bu değerlerin tümü ideal tanılamayı belirten 1 değerine çok yakındır. En iyi sonucu 0.797 R-test değeri ve 0.1174 test hatalarının mutlak değerleri toplamı(SAE-test) ile ÇKİB YSA vermiştir. Ama hemen hemen tüm tipler için bu değerler aynı olduğundan, Model 1 için bu ayrı YSA tiplerinin kıyaslanmasına dair çok şey söylenemez. Tablo incelendiğinde, iki ayrı kriter olan SAE ve R değerlerinin özellikle test değerleri için birbirini teyit ettiği gözlemlenmektedir. Bununla beraber, çok nadir olsa da eğitim verileri için çeliştiği gözlenebilir. Fakat sonuçların yorumlanması test verileri için gerçekleştirildiğinden, bu durumun pratik bir önemi yoktur. Bunun dışında, eğitim verileri için bahsedilen değerlerin çok iyi olması, YSA’nın ezberleme yapmış olduğu duruma ya da bir başka deyişle kötü bir genelleştirme özelliğine işaret edebilir. Bu sebeple, test verileri ile gerçeklemeden YSA’nın güvenilirliği ile ilgili bir şey söylenemez.

Tablo 5.1 Model 1 Sonuçları

Model 1	R-eğitim	R-test	SAE-eğitim	SAE-test
ÇKİB YSA	0.770	0.797	0.8403	0.1174
RB YSA	0.756	0.757	0.7844	0.1390
Yinelenen YSA	0.740	0.787	0.8541	0.1215

Şekil 5.1’de Model 1 için çok katmanlı ileri beslemeli, radyal bazlı ve yinelenen YSA ile kurulmuş modellerin test girişi için çıkışları üç ayrı grafikte, gerçek değerlerle kıyaslanarak verilmiştir.

**Şekil 5.1:** Model 1 Gerçekleme Grafikleri

Şekil 5.1’deki grafikleri, gerçek çıkışların oluşturduğu eğrinin tepe noktalarını izleme, en az zaman gecikmesi ve aşma kriterlerine göre incelersek, Model 1 için en uygun tanılamanın çok katmanlı ileri beslemeli YSA ile mümkün olduğunu, yinelenen YSA’nın da ÇKİB YSA’ya çok yakın sonuç verdiğini, radyal bazlı YSA’nın ise göreceli olarak daha kötü sonuç verdiği söylenebilir. Fakat sonuç itibariyle, elde edilen grafikler birbirine çok benzerdir ve bu durum Tablo 5.1’deki değerler baz alınarak varılan sonuçları teyit etmektedir. Kurulan YSA modelleri için ÇKİB YSA’da toplam dört nöron, radyal bazlı YSA’da 21 nöron ve yinelenen

YSA'da toplam 3 nöron kullanılmıştır. Nöron sayısı ve dolayısıyla kurulan modellerin simulasyon maliyetleri gözönüne alındığında radyal bazlı YSA'ların kullanımı Model 1 için diğerlerine nazaran elverişsiz kabul edilebilir. Yinelenen YSA daha az nörona sahip olmasına rağmen, geri besleme döngüsünün işlem maliyeti, ÇKİB YSA ile hemen hemen aynı sürede simüle edilmesine sebep olur. Bu durumda işlem maliyeti ile tanılama performansını beraber gözönüne aldığımızda da, en elverişli tanılamamanın ÇKİB YSA ile ulaşıldığı sonucuna varılır. Yinelenen YSA'nın geri besleme döngüsünün, ÇKİB YSA'ya nazaran bir avantaj getirmemesinin sebebi için, Model 1'in mertebesinin 2 seçilerek zaten sağlıklı biçimde belirlendiği ve bu ekstra uzamsal öğrenme sağlayan donanım ihtiyacı olmadığı sonucuna varılabilir. Dolayısıyla Bölüm 3'de anlatılmış ve bu çalışmada yinelenen YSA olarak kullanılan Elman Ağının işleyişi gözönüne alındığında, geri yayılım ile gizli katmandaki ağırlıkların belirlenmesi sırasında kullanılan geri besleme döngüsüne ait tahmini ağırlık, yinelenen YSA'da ÇKİB YSA'ya göre bir deterministlik zaafı yaratmış ve çok küçük olsa da daha kötü sonuç vermesine yol açmıştır.

Tablo 5.2'de Model 2 için her üç tip YSA modelinin eğitim ve test verisi için korelasyon katsayıları ve hataların mutlak değerleri toplamı gösterilmektedir.

Tablo 5.2 Model 2 Sonuçları

Model 2	R-eğitim	R-test	SAE-eğitim	SAE-test
ÇKİB YSA	0.645	0.330	17.0092	4.7793
RB YSA	0.620	0.335	17.3867	4.5358
Yinelenen YSA	0.528	0.338	18.7359	4.4997


Tablo 5.2 incelendiğinde, R-test korelasyon faktörlerinin her üç tip içinde, ideal değer olan 1'e uzak oldukları ve dolayısıyla Model 2 tanılamasının başarısız olduğu sonucuna varılır. Çıkışın kireç modülü olduğu Model 2' de, eğitim verileri ve Model 1'in hem eğitim hem de test verileri için iyi sonuçlar veren YSA tiplerinin başarısız olması, dikkatlerin kireç modülünün üzerinde toplanmasına yol açar.

Bölüm 2’de sunulan ve kireç modülünü belirleyen denklem 2.1 tekrar gözönüne alınırsa:

$$ML = \frac{100C}{2.8S + 1.1A + 0.8F} \quad (5.1)$$

Kireç modülünün C, S, F ve A ile belirtilen dört ayrı oksit değerinin(CaO , SiO_2 , Fe_2O_3 , and Al_2O_3) oranlanması ile bulunduğu görülür. Dolayısıyla sahip olunan kireç modülü verisi, bu dört ayrı oksitin ölçümüne ait hataların, gürültülerin ve prosese etkien diğer bozucuların olumsuz etkilerinin toplamını barındırır. Bu durum da tanılamayı güçleştirir.

Şekil 5.2’de, değişik tip YSA’larla Model 2 için yapılan tanılama sonuçlarının test edilmesi grafiklerle gösterilmiştir. Bu grafikler de sonucun arzu edilir şekilde gerçekleşmediğini teyit etmektedir.



Şekil 5.2: Model 2 gerçekeleme grafikleri


Tablo 5.3’de Model 2 için her üç tip YSA modelinin eğitim ve test verisi için korelasyon katsayıları ve hataların mutlak değerleri toplamı gösterilmektedir.

Tablo 5.3: Model 3 sonuçları

Model 3	R-e (1)	R-e (2)	R-t(1)	R-t(2)	SAEe1	SA-e2	SAE-t1	SAE-t2
ÇKİB YSA	0.666	0.700	0.683	0.0622	0.9571	15.925	0.2072	5.2492
RB YSA	0.761	0.575	0.762	0.328	0.7906	18.143	0.1583	4.6378
Yinele nen YSA	0.742	0.640	0.770	0.337	0.8138	17.101	0.1530	4.7708

Tablo 5.3 incelendiğinde R-t(1) değerinin her üç çok girişli-çok çıkışlı YSA tipinde de makul olduğu, bir başka deyişle demir oksit çıkışı için tanılamamanın başarılı olduğu söylenebilir. Buna rağmen sonuçlar üç girişli-tek çıkışlı demir oksit modellerinde olduğu kadar iyi değildir. Kireç modülü için elde edilen R-t(2) değerleri her üç ayrı YSA modelinde de ideal değer olan 1'den çok uzaktadırlar ve bir kez daha kireç modülü çıkışı tanılaması başarısız olmuştur. Kireç modülü tanılamasının başarısız olmasının muhtemel nedenleri Model 2 için tartışılmıştı. Aynı koşullar Model 3 için de geçerlidir. ÇKİB YSA modelinin tanılama sonuçları RB YSA ve Yinelenen modellerine oranla daha kötüdür. Fakat bu durumdan genel bir sonuca gitmek çok mümkün değildir. Çünkü yinelenen YSA ÇKİB YSA'ya yapısal olarak çok benzemektedir. Farkları, sadece Yinelenen YSA'nın uzamsal biçimlerin öğrenilmesinde avantaj sağlayan bir geri besleme döngüsüne sahip oluşudur. Bu uzamsal biçim öğrenmesi, tanılama probleminde merteye belirsizliği durumunda elde edilen bir avantaj olarak ortaya konulmuştu. Dolayısıyla, mevcut problemde bir merteye belirleme problemi olmuş olsaydı, RB YSA sonuçlarının da ÇKİB YSA kadar kötü olması gerekirdi. Böyle bir durum söz konusu olmadığına göre, bu izafi başarısızlığın en olası nedeni ÇKİB YSA'nın eğitim sürecinde, ağ parametrelerine atanan ilk değerlerin YSA'nın bir lokal minumuma takılmasına sebep verecek şekilde olmasıdır. Bu problemi ortadan kaldırmak için her bir YSA tipine ait eğitim süreci birkaç kez tekrarlanmış olsa da, bu örnekte belirtilen olumsuzluktan

kaçınılmadığı anlaşılmaktadır Şekil 5.3'de çok girişli-çok çıkışlı durumları da incelememizi sağlayan Model 3 için kurulmuş YSA tiplerinin test sonuçları, gerçek çıkışlarla beraber gösterilmiştir. Söz konusu grafikler Tablo 5.3'e dayanarak yapılan izahları teyit etmekte ve görsel olarak ortaya koymaktadır.



Şekil 5.3: Model 3 için gerçekleştirme grafikleri

Tüm bu incelemeler göz önünde tutularak, ÇKİB YSA, RB YSA ve Yinelene YSA ile sistem tanılama üzerine şunlar denilebilir:

Tüm YSA tipleri, yeterli sayıda denemeden sonra kurulmuş modeller için çok benzer sonuçlar vermektedir. Bu da hangi tipin kullanılması gerektiğini tamamen kurulacak modele ihtiyaç duyan uygulamaya bağımlı kılar. Mesela, kurulan modelin entegre edileceği yapı için simülasyon zamanı önemli bir kriter ise ÇKİB YSA kullanılmalıdır. Sistem mertebesinin belirlenmesi ile ilgili bir kuşku olduğunda, Yinelene YSA olarak kullanılan Elman Ağı etkili bir alternatif sunar. Tanılaması yapılan sistem çok girişli-çok çıkışlı bir sistem ise(bu çalışmadaki örnekte sonuç üzerindeki etkisi çok iyi gözlemlenemese de) yerellik özelliğinden dolayı RB YSA kullanılmalıdır.

KAYNAKLAR

- [1] **Demuth, H. and Beale, M.**, 1997. "Neural Network Toolbox User Guide(version 3.0)" <http://www.mathworks.com>
- [2] **Hagan, M. T., Demuth, H. B. and Beale, M. H.**, 1996. *Neural Network Design*, Boston, MA: PWS Publishing.
- [3] **Liu, G. P.** , 2001 "Nonlinear Identification and Control-A Neural Network Approach," London, Springer-Verlag.
- [4] **Hagan, M. T., and Menhaj, M.**, 1994, "Training feedforward networks with the Marquardt algorithm," *IEEE Transactions on Neural Networks*, vol. 5, no. 6, pp. 989-993.
- [5] **MacKay, D. J. C.**, 1992. "Bayesian interpolation," *Neural Computation*,vol. 4, no. 3, pp.415-447.
- [6] **Foresee, F. D. and Hagan, M. T.**, 1997. "Gauss-Newton approximation to Bayesian regularization," *Proceedings of the 1997 International Joint Conference on Neural Networks*, pages 1930-1935.
- [7] **Kural, A.**, 2001. "Çimento Endüstrisinde Harmanlama Prosesinin Tanılanması ve Model Öngörülü Kontrolü," Doktora Tezi, İ.T.Ü.
- [8] **Cybenko, G.**, 1989. "Approximations by superpositions of a sigmoidal function," *Mathematics of Control, Signals and Systems*, vol. 2,pp.303-314.
- [9] **Nguyen, D., and Widrow, B.** 1990. "Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights," *Proceedings of the International Joint Conference on Neural Networks*, vol 3,pp. 21-26.
- [10] **Nelles, O.**, 2001. "Nonlinear System Identification," Berlin, Springer-Verlag,

- [11] **Elman, J. L.**, 1990. "Finding structure in time," *Cognitive Science*, vol. 14, pp. 179-211.
- [12] **Nørgaard, M.**, 2000. "Neural Network Based System Identification Toolbox (Version 2-User Guide)," Technical Report 00-E-891, Department of Automation Technical University of Denmark.

ÖZGEÇMİŞ

Güven Emre, 1980 yılında Diyarbakır'da doğdu. İlk öğrenimini Elazığ Cumhuriyet İlkokulu'nda, orta öğreniminin ilk iki yılını Elazığ Anadolu Lisesi ve son beş yılını İstanbul Bahçelievler Adnan Menderes Anadolu Lisesi'nde tamamladı. Lisans ve Yüksek Lisans derecelerini İstanbul Teknik Üniversitesi Makina Mühendisliği Bölümü'nde aldı. Kitap, dergi, sinema, ülkedeki ve dünyadaki güncel politik ve ekonomik gelişmeler, futbol, yüzme ve Beşiktaş mühendislik dışı ilgi alanlarını oluşturmaktadır.