

PAPER DETAILS

TITLE: PNÖMATİK SİSTEMDE GERÇEK ZAMANLI LVQ YAPAY SINIR AGİ ALGORİTMASI İLE
ARIZA TESPİTİ

AUTHORS: Mustafa DEMETGÜL

PAGES: 83-90

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/190958>

PNÖMATİK SİSTEMDE GERÇEK ZAMANLI LVQ YAPAY SİNİR AĞI ALGORİTMASI İLE ARIZA TESPİTİ

Mustafa DEMETGÜL

Marmara Üniversitesi, Teknik Eğitim Fakültesi, Makine Eğitimi Bölümü, Göztepe/İstanbul

Geliş Tarihi : 02.07.2007

ÖZET

Bu çalışmada, pnömatik sistemde arıza meydana geldiğinde bunun çok çabuk teşhis edilmesi ve gerekli önlemlerin alınması için yapay sinir ağı geliştirilmiştir. Deney amaçlı geliştirmiş olduğumuz şişe dolum tesisinde bir arıza olduğunda sistemin değişik yerlerine konulan basınç sensörleri ve doğrusal cetvellerden gelen analog değerlere göre hiçbir müdahale olmadan sistemin neresinde arıza olduğu tespit edilebilmektedir. Yapay Sinir Ağı (YSA) ile deney seti üzerindeki şişe yok, B kapak kapama silindiri çalışmıyor, C kapak sıkıştırma silindirine hava gelmiyor, sistemin hava basıncı yetersiz, su yok, sistemin hava basıncı az arızaları bulunmaktadır. Arızalar LVQ yapay sinir ağı algoritması ile teşhis edilmektedir. Arıza tespitinde geleneksel programlama veya PLC yardımı ile arıza tespiti yapmak mümkündür. Yapay sinir ağı kullanılmasının sebebi kullanıcıya arızanın bulunduğu yeri bildirmesi ve farklı sistemler üzerinde bu geliştirilen programın kullanılabilir olmasıdır. Amaç, pnömatik sistemde bir arıza olduğunda sistem üzerinden veri toplama kartı ile alınan verileri kullanarak yapay sinir ağı vasıtasıyla gerçek zamanlı olarak arıza teşhisi yapmaktır. Geliştirilen programın mekatronik sistemlerin bulunduğu tesislerde arıza tespitine katkı sağlayacaktır.

Anahtar Kelimeler : Yapay sinir ağı, Arıza teşhisi, LVQ (Lineer Victor Quantization), Pnömatik.

EXPERIMENT BASED FAULT DIAGNOSIS ON BOTTLE FILLING PLANT WITH LVQ ARTIFICIAL NEURAL NETWORK ALGORITHM

ABSTRACT

In this study, an artificial neural network is developed to find an error rapidly on pneumatic system. Also the ANN prevents the system versus the failure. The error on the experimental bottle filling plant can be defined without any interference using analog values taken from pressure sensors and linear potentiometers. The sensors and potentiometers are placed on different places of the plant. Neural network diagnosis faults on plant, where no bottle, cap closing cylinder B is not working, bottle cap closing cylinder C is not working, air pressure is not sufficient, water is not filling and low air pressure faults. The fault is diagnosed by artificial neural network with LVQ. It is possible to find an failure by using normal programming or PLC. The reason offing Artificial Neural Network is to give a information where the fault is. However, ANN can be used for different systems. The aim is to find the fault by using ANN simultaneously. In this situation, the error taken place on the pneumatic system is collected by a data acquisition card. It is observed that the algorithm is very capable program for many industrial plants which have mechatronic systems.

Key Words : Neural network, Fault diagnosis, LVQ (Lineer Victor Quantization), Pneumatic.

1. GİRİŞ

Teknolojik gelişmelere paralel olarak otomasyon sistemleri oldukça yaygın olarak kullanılmaya başlanmıştır. Bazı otomasyon sistemleri pnömatik sistemlerden meydana gelmektedir. Bir fabrikanın tamamı otomasyon sistemleri ile çalışıyorsa bir yerde problem olduğu zaman bütün işlem bundan etkilenmekte ve ekonomik kayıplar ortaya çıkmaktadır. Pnömatik sistemlerde tek tek arıza aramak yorucu ve zaman alıcıdır. Bunu önlemek için yapay sinir ağları ile anında arıza tespitine ihtiyaç vardır. Son yıllarda sanayide aşılması zor problemlerin çözümünde yapay sinir ağı uygulamalarına başvurulmaktadır. Yapay Sinir Ağı'nın en temel görevi, kendisine gösterilen bir girdi setine karşılık gelebilecek bir çıktı seti belirlemektir. Bunun yapılabilmesi için ağ, ilgili olayın örnekleri ile eğitilerek genelleme yapabilecek yeteneğe kavuşturulur. Bu genelleme ile benzer olaylara karşılık gelen çıktı setleri belirlenir. Bu konuda yapılan çalışmalarda (Samanta, 2004), dişli arızalarının tespiti için yapay sinir ağı geliştirmiştir. Çalışmada makinelerdeki titreşimlere göre arıza tespiti yapılmış ve Matlab Neural Network Toolbox'ında geriye yayılım algoritması kullanılmıştır. Yang v.d., (2004) yapay sinir ağı ile dönen makine elemanlarında meydana gelen arızaların tespitini yapmışlardır. Algoritma olarak ART-KOHONEN, SOFM (Self Organization Feature Maps), LVQ (Learning Vector Quantisation), RBF (Radial Basis Function) algoritmaları sistemin performansını artırmak için birlikte kullanmışlardır. Yapay sinir ağı ile yanlış ayarlamalar, dengeleme hataları, tınlama, bilyalı yatak arızaları bulmuşlardır (Yang, 2004). Angeli ve Smirni (1999) hidrolik sistemde meydana gelen arızaların tahmini yapmışlardır. Bu çalışmada DASYLab ve KPW yazılımlarını kullanmışlardır (Angeli, 1999).

Chen ve Wang (2000) dişli arızalarının sınıflandırılmasında çok katmanlı ağ kullanmışlardır. Çıktılar hedef ve hatalı sonuçlar olarak ikiye ayrılmaktadır. Farklı gizli katman nöron sayıları, momentum sabiti, iterasyon sayıları için yapay sinir ağını eğitmişlerdir. Algoritma olarak geri beslemeli ağ algoritması kullanmışlardır Bayır ve Bay (2004) marş motorunda meydana gelen arızaların tespiti için Visual Basic 6.0'da yapay sinir ağı geliştirmişlerdir. Ağ yapısı olarak geri beslemeli ağ algoritması kullanılmıştır. Karpenko v.d., (2003) Fisher Resemount G67 kontrol valfinde arıza aramak için yapay sinir ağı geliştirmişlerdir. Çok katmanlı ağ yapısı kullanmışlardır. Demetgül ve Yenitepe (2004) pnömatik sistemde arızaların tespiti

için uzman sistemi Visual Basic 6.0'da geliştirmişlerdir. Bu çalışma bilgisayar ortamında kullanıcıya pnömatik sistemde olabilecek arızaları sormakta ve verilen evet hayır cevapları ile kullanıcıya olabilecek arızayı tahmin etmektedir. Sandt v.d., (1997) gerçek zamanlı olarak hidrolik sistemde arıza tespiti için yapay sinir ağı kullanmışlardır. Sistemin arızalarını titreşimlere göre bulmuşlardır. Wang v.d., (2004) dönen makine elemanlarında meydana gelen arızaların tahmini için Neuro-Fuzzy algoritmasını kullanmışlardır. Geliştirilen yapay sinir ağı ısınmış, çatlamış ve yüzey pürüzlülüğü olan dişlilerin tespiti için kullanılmışlardır. Seong v.d., (2005) yapay sinir ağı ile çek valflerde meydana gelen arızaların tespitini yapmışlardır. Akustik emisyon sensörleri ve hız değişim sensörlerinden gelen veriler yapay sinir ağına işlenmişlerdir. Ağ algoritması olarak geri yayılım algoritması kullanmışlardır.


Karkoub v.d., (1999) eksenel pistonlu pompanın performansını yapay sinir ağı ile tahminini yapmışlardır. Geri yayılım algoritması kullanmışlardır. Sistemin performansını deney setinin belirli yerlerine yerleştirdikleri akış ölçer ve basınç ölçerlerden aldıkları verilerle tahmin etmeye çalışmışlardır. Parlos v.d., (2004) makinedeki ölçülen elektriksel ölçüm değerlerine göre makinedeki arızayı tespit etmeye çalışmışlardır. Sensörlerin montaj edilmesi, birçok kablodan oluşması ve maliyetlerinin yüksek olmasından dolayı sensör kullanmadan arıza tespiti yapmaya çalışmışlardır. Recurrent ve geri beslemeli yapay sinir ağı modellerini birlikte kullanmışlardır. Wuxing ve arkadaşları dişli arızalarını gerçek zamanlı tespit etmek için radyal tabanlı ve geri beslemeli yapay sinir ağı algoritmaları kullanmışlardır. Hataların nonliner ve sesli sinyaller olmak üzere ikiye ayrılması için yapay sinir ağını kullanmışlardır. Radyal tabanlı algoritmanın geri beslemeli algoritmadan daha iyi olduğu sonucuna varmışlardır. Shi ve Sepehri (2005) LVQ ve Matlab Anfis yardımı ile Neuro-Fuzzy ile arıza teşhisi yapmışlardır. Sistemdeki basınçlar normal, düşük ve yüksek diye sınıflandırmışlardır. Deney seti olarak selenoid 5/3 impuls valf ile bir çift konumlu silindir kullanılmıştır. Wang (2000) otomobil motorlarının arızalarını bulmak için yapay sinir ağı geliştirmiştir. Algoritma olarak Levenberg Marquart ve geri yayılım algoritmasını kullanmıştır. Yapay sinir ağına eğitilmesinde Neural Network Toolbox kullanılmıştır. Yapılan çalışmada gerçek zamanlı olarak veriler alınmış daha sonra bu veriler yapay sinir ağına girilerek arıza tespiti yapılmıştır. Sistem gerçek zamanlı arıza tespiti yapmamaktadır. Sınıflandırma yapıldığında bugüne kadar dönen makine elemanlarında, otomobil motorlarında,

yataklarda, hidrolik servo valflerde, servo motorlarda, odun bölme makinesinde, dönen makine elemanlarında, çek valflerde, mars motorunda, elektrik motorlarında, dişlilerde, makinelerde, dişli kutusu, bilyelerde, hidrolik sistemde, pompalarda, gaz tribünlerinde, eksenel pistonlu pompalarda, Fisher Rosemount isimli özel valfte, su motorunda, kompresör arızalarının tespitinde yapay sinir ağı kullanılmıştır. Yapay sinir ağı algoritması olarak arıza tespitinde en çok Levenberg Marquart, Geri Yayılım Algoritması, Neuro-Fuzzy, Art-Kohonen, SOFM (Self Organization Feature Maps), LVQ Learning Vector Quantisation), RBF (Radial Basis Function) algoritmaları kullanılmıştır.

Bilindiği gibi teknoloji insana gerek kalmadan akıllı sistemler vasıtasıyla makinelerin kontrolü, uzaktan kontrolü, meydana gelen arızaları söylemeleri konularında hızlı bir şekilde ilerlemektedir. Yapılan çalışmalardan yararlanarak deney amaçlı geliştirilmiş olduğumuz şişe dolum tesisinde arızaları LVQ yapay sinir ağı algoritması kullanarak arıza tespiti yaptık. Amaç pnömatik sistemde bir arıza olduğunda kimsenin müdahalesi olmadan sistemin neresinde arıza olduğu tespit edebilmektir.


2. DENEY DÜZENEĞİ

Şekil 1’de sistemin genel çalışma prensibi gösterilmiştir. Sistemde Analog sensör olarak basınç sensörleri ve doğrusal cetveller kullanılmıştır. Sayısal sensör olarak sistemin kontrolünü sağlayan sınır anahtarları, indüktif ve kapasitif sensörler kullanılmıştır. Analog sensörlerden alınan verilerin örnekleme frekansı 2 dir. Basınç sensörlerinin vermiş olduğu volt cinsinden değerler 1V 1 bar basınca eşittir. Doğrusal cetvellerdeki 1 V 15 mm ye eşittir. Pnömatik sistem 140 saniyede bir proses yapmaktadır. Veriler Matlab Real Time Windows Target da Dac (Veri Toplama Kartı) vasıtasıyla alınmaktadır. Sistemdeki analog sensörlerin verileri Dac(Veri toplama kartı) kartı vasıtasıyla alınmaktadır. Kullanıcı arayüzü sistem üzerindeki değişikliklerin izlenmesinde kullanılmaktadır.



Şekil 1. Sistemin çalışma şekli.

Deney düzeneği Şekil 2’de görülmektedir. Deney düzeneğinde A ile gösterilen silindiri boş olan şişeyi alıp ileri doğru götürür. Şişe olmadığında şişe algılama sensörü yardımıyla sistem çalışmaz. A silindiri ileri konuma ulaştığında sınır anahtarı sinyal verdiğinde ‘I’ ile gösterilen Selenoid vana açılır ve şişeye su dolar. Selenoid vananın üst kısmında su haznesi bulunmakta ve burada su bittiğinde yan tarafta bulunan su deposundan su depolanır. Şişe istenilen seviyeye kadar su ile doldurulduktan sonra seviye algılama sensörü yardımı ile selenoid vana kapanır. A silindiri, su dolduktan sonra biraz bekler ve geri hareket yapar. A silindiri orta konuma geldiğinde durur.



Şekil 2. Deney prensibi.

B ile gösterilen şişe kapak kapama silindiri aşağıya inerek şişenin kapağını kapatır. Daha sonra B silindiri geri konuma geçer. A silindiri son konuma gelir. C şişe kapak kapama silindiri aşağıya iner. Adım motoru enerjilenir. Kapak sıkıştırılır. C silindiri geri konuma gelir. Böylece bir süreç tamamlanmış olur. Deney düzeneğinde harfle gösterilen parçalar Tablo 1’de açıklanmıştır.

Tablo 1. Şekil 3’teki Resimdeki Deney Düzeneği Elemanları.

A	A Silindiri
B	B Silindiri
C	C Silindiri
D	Basınç Sensörü
E	Lineer Potansiyometre
F	İndüktif Sensör
G	Step Motor
H	Ara Bağlantı Bloğu
I	Selenoid Vana
K	PLC
L	Dac

Sistem normal çalışırken alınan veriler Tablo 2’de gösterildiği gibi “a” ile gösterilmektedir. Şişe yok arızası “b” ile gösterilmektedir. B kapak kapama

silindiri çalışmıyor arızası “c” ile gösterilmektedir. C kapak sıkıştırma silindiri arızası “d” ile gösterilmektedir. Sistemin havası yetersiz arızası “e” ile gösterilmektedir. Şişeye su dolmuyor arızası “f” ile gösterilmektedir. Sistemin hava basıncı az arızası “g” ile gösterilmektedir.

Tablo 2. Deney Düzeneginde Olan Arızalar.


a	Normal
b	Şişe yok
c	B Kapak Kapama Silindiri Çalışmıyor
d	C Kapak Sıkıştırma Silindiri Çalışmıyor
e	Sistem Havası Yetersiz
f	Şişeye Su Dolmuyor
g	Sistemin Hava Basıncı Az

Şekil 3a’da Tablo 2’de belirtilen arıza durumlarında zamana göre A silindiri konum değişimi gösterilmektedir. Silindir 5-65 s arasında 200mm açılmaktadır. 65-85 s arasında 80 mm orta konumda B kapak kapama silindirinin kapağı kapaması için beklemektedir. 85-140 s arasında başlangıç konumuna dönerek C kapak sıkıştırma silindiri çalışmaktadır. B kapak kapama silindiri çalışmadığı zaman A silindiri düzgün olarak çalışmaktadır. Aynı şekilde kapak kapama silindiri arızası A silindirini etkilememektedir. C kapak kapama silindiri arızasında A silindiri konum değişimi değişmemektedir. Sistem havası yetersiz olduğunda sistem çalışmadığı için 0 a yakın konum değişimi vermektedir. Su bittiğinde A silindiri ileriye hareket etmekte fakat geri dönmediği için şişeye su dolmuyor arızası olmakta ve 200 mm de kalmaktadır.


Sistemin hava basıncı az olduğunda A silindiri konum değişimi biraz uzun olmaktadır. Şekil 3b’de A valfi basınç değişimi gösterilmektedir. Valf 5-65 s arasında silindir ileride olduğu için 4.2 bar basınçta çalışmaktadır. 65-85 s arasında A orta konumda B kapak kapama silindirinin kapağı kapması için beklediğinden basınç 1.2 bar a düşmektedir. 85-140 s arasında A silindiri başlangıç konumuna dönmekte ve C kapak sıkıştırma silindiri çalışmaktadır. B kapak kapama silindiri çalışmadığı zaman A valfi düzgün olarak çalışmaktadır. Aynı şekilde kapak kapama silindiri arızası A valfi etkilememektedir. C kapak kapama silindiri arızasında A valfi basınç değişimi değişmeyecektir. Sistem havası yetersiz olduğunda sistem çalışmadığı için 0 a yakın basınç değeri vermektedir. Su bittiğinde A silindiri ileriye hareket etmekte fakat geri dönmediği için şişeye su dolmuyor arızası olmakta ve basınç 4.2 bar da de kalmaktadır. Sistemin hava basıncı az olduğunda A valfi basıncı 2.6 olmaktadır.

Şekil 3c B silindiri konum değişimi görülmektedir. Silindir 65-85s arasında 150mm açılmaktadır. 85s


den sonra başlangıç konumuna dönerek C kapak sıkıştırma silindiri çalışmaktadır. C kapak kapama silindiri arızasında B silindiri konum değişimi değişmemektedir. Sistem havası yetersiz olduğunda sistem çalışmadığı için 0 a yakın konum değişimi vermektedir. Su bittiğinde şişeye su dolmuyor arızası olmakta ve B silindiri çalışmamaktadır. Sistemin hava basıncı az olduğunda B silindiri konum değişimi biraz uzun olmaktadır. Şekil 3d’ de B valfi basınç değişimi gösterilmektedir. Basınç sensörü valfin silindiri geri konumda bıraktığı kısma bağlandığı için başlangıçta 4.2 bar basıncı göstermektedir. Valf 65-85 s arasında silindir ileride olduğu için 0 bar basınç değerine düşmektedir. Daha sonra silindir kapandığı için tekrar eski basınç değerine çıkmaktadır. Şekil 3e’de C silindiri konum değişimi gösterilmektedir. Silindir 105-125 s arasında 150mm açılmaktadır. 105s den sonra başlangıç konumuna dönerek bir proses tamamlanmaktadır. B kapak kapama silindiri arızasında C silindiri konum değişimi değişmemektedir. Sistem havası yetersiz olduğunda sistem çalışmadığı için 0 a yakın konum değişimi verecektir. Su bittiğinde şişeye su dolmuyor arızası olacak ve C silindiri çalışmayacaktır. Sistemin hava basıncı az olduğunda C silindiri konum değişimi biraz uzun olmaktadır. Şekil 3f’de C valfi basınç değişimi gösterilmektedir. Valfin basınç değişimi 105-125 s arasında silindir ileride konumda iken 4.3 bar a çıkmaktadır. Daha sonra silindir kapandığı için tekrar eski basınç değerine düşmektedir. Sistem basıncı az olduğunda 3 bar basınçtır.




(a)




(b)




(c)



(d)



(e)



(f)

Şekil 3. Deney düzeneği üzerinde meydana gelen arızalar. a) A Silindiri lineer potansiyometre; b) A Silindiri basınç sensörü; c) B Silindiri lineer potansiyometre; d) B Silindiri basınç sensörü; e) C Silindiri lineer potansiyometre; f) C Silindiri basınç sensörü.

3. YAPAY SİNİR AĞININ OLUŞTURULMASI

Yapay sinir ağları biyolojik sinir hücresi (nöron) yapısından esinlenerek modellenen ve kendi kendine öğrenip karar verebilen algoritmaya sahip sistemlerdir. Nöron adı verilen ve bilgiyi işleyen birimlerden oluşmaktadır. Nöronlar bilgiyi kendi aralarında bulunan bağlantı hatları ile taşımaktadırlar. Bu bağlantı hatlarının önemine göre bir ağırlık değerleri vardır. Bu herbir nöronun değeri ile diğer nöronun bağlantı hattının ağırlık değeri çarpılmakta eşik değerleri ile toplanarak nöronların toplam enerjisi bulunmaktadır. Bu nöronların toplam çıktısı enerji değerinin bir aktivasyon fonksiyonunda geçirilmesi ile bulunmaktadır.

LVQ ağının öğrenme kuralına Kohonen öğrenme kuralı da denmektedir. Öğrenme kuralı, Kohonen tabakasındaki proses elemanlarının birbirleri ile yarışmaları ilkesine dayanır. Hangi proses elemanın referans vektörü girdi vektörüne en yakın ise o yarışmayı kazanmaktadır. Girdi vektörü X ile referans vektörü A arasındaki mesafe d ile gösterilirse, i. Proses elemanın mesafesi 1 deki şekilde hesaplanmaktadır (Öztemel, 2003).

$$d_i = \|A_i - X\| = \sqrt{\sum_j (A_{ij} - x_j)^2} \quad (1)$$

Ağın ağırlıklarının değiştirilmesi (2)'ye göre yapılmaktadır. Burada λ öğrenme katsayısıdır. Zaman içerisinde sıfır değerini alacak şekilde azaltılır. Bunun nedeni girdi vektörünün referans vektörüne çok yaklaştığında durması ve aksi yönde tekrar uzaklaşmaması içindir.

$$A_y = A_e + \lambda(X - A_e) \quad (2)$$


Kazanan proses elemanı yanlış sınıftan olduğu durumda ağırlık vektörü girdi vektöründen uzaklaştırılır. Bir daha aynı örnek geldiğinde aynı proses elemanı kazanmasın diye bu uzaklaştırma yapılır. 3 te gösterildiği gibi ağırlıklar değiştirilir.

$$A_y = A_e - \lambda(X - A_e) \quad (3)$$

Kohonen katmanındaki proses elemanlarının çıktıları bu proses elemanlarını çıktı katmanına bağlayan ağırlık değerleri ile çarpılarak 4'te gösterildiği gibi ağın çıktısı hesaplanır.

$$C_i = \sum_j C_j^k \alpha_{ki} \quad (4)$$

Şekil 4’de LVQ ağının yapısı gösterilmektedir. Girdi olarak A silindiri konum değişimi, B silindiri konum değişimi, C silindiri konum değişimi, A valfi basınç değişimi, B valfi basınç değişimi ve C valfi basınç değişimi alınmaktadır. Ağı Çıkışları ise Normal, Arızalıdır.



Şekil 4. LVQ ağının yapısı (Öztemel, 2003).


LVQ ağının denemeler sonunda Tablo3 de gösterildiği gibi gizli katman nöron sayısı 10, giriş katmanının nöronlarının yüzdesi 0.4, gizli katmandaki nöronların yüzdesi 0.6, öğrenme oranı 0.1 ve iterasyon sayısı 1000 alınmıştır.

Tablo 3. Yapay Sinir Ağıının Parametreleri.

Gizli Katman Nöron Sayısı	10
Giriş Katmanı Nöronların Yüzdesi	0.4
Gizli Katmandaki Nöronların Yüzdesi	0.6
Öğrenme Oranı	0.1
İterasyon Sayısı	1000

4. BULGULAR VE TARTIŞMA

Şekil 5’de ağın eğitim sonucu gösterilmektedir. Ağ 1000 iterasyon sonucu eğitilmiştir. Ağın performansı 0.1666’dır.



Şekil 5. Ağın eğitimi.

EK 1’de gösterilen yatay sütundaki 1, 2. sensör A basınç sensörü ve doğrusal cetvelidir. 3, 4. sensör B basınç sensörü ve doğrusal cetvelidir. 5, 6 C basınç sensörü ve doğrusal cetvelidir. Sistemden her bir sensör 140 veri almaktadır. Her bir sensörden alınan 140 veri 1’e eşitlenmektedir. Toplam 840 veri ile ağ eğitilmektedir. Sonra arıza teşhisinde her bir sensörden gelen verilerin 1’e ne kadar yakın olduğuna bakılmaktadır. 2 arızalı kısımları göstermektedir. Ağ normal, şişe yok, B kapak kapama silindiri çalışmıyor, C Kapak sıkıştırma silindiri çalışmıyor, Sistem hava basıncı yetersiz, şişeye su dolmuyor sistem hava basıncı az arızalarını bulmaktadır.

Şişe yok arızasında 6 sensör çıkış değerleri 2a yakın değerler olmaktadır. Çünkü sistem çalışmamaktadır. B Kapak kapama silindiri çalışmıyor arızasında 3 ve 4. sensör çıktı değerleri 2’ye yakın değerler çıkmaktadır. 5. sensör değerinin 2 çıkmasının sebebi ağın hatalı sonuç vermesidir. C Kapak sıkıştırma silindiri çalışmıyorsa 5 ve 6. sensör çıkış değerleri 2 ye yakın değerler çıkmıştır. 5. sensör C silindiri doğrusal cetvelidir. 6. sensör C valfi basınç sensörüdür. Sistemin hava basıncı yetersiz olduğunda ağ çıkış değerleri 2’ye yakın değerler çıkmaktadır. Şişeye su dolmuyor arızasında A silindiri ileriye gidip orda arıza olduğu için yapması gereken hareketin yarısını yaptığı için basınç sensörü çıkış değeri 2 değerini almıştır. Yani arızalı gruba atılmıştır. Doğrusal cetvel değerlerinde 1 olarak alınmıştır. Problemsiz gruba dahil edilmiştir. Diğer sensör çıkışları 2 ye yakın değerler çıkmıştır. Çünkü su olmadığı için şişeye su dolamış ve B ve C silindirleri çalışmamışlardır.

5. SONUÇ

Bu çalışmada liner potansiyometrelerden ve basınç sensörlerinden gelen analog bilgiler yardımıyla sistem üstünde olan arızaların tespiti yapılmıştır. Eğitim girdileri ile yapay sinir ağının bu konuda uzmanlaşması sağlanmıştır. Test girdi değerleri ile yapay sinir ağının bu konuda ne kadar uzman olduğu, ne kadar anladığı test edilmektedir. Sistem üzerindeki sensörler yapay sinir ağına bağlandıktan sonra yapay sinir ağı eğitilmiştir. Daha sonra sistem üzerinde bir problem olduğunda eğitim verileri ile arızalı veriler yapay sinir ağı ile karşılaştırılmış ve arıza tespit edilmiştir. Bunun sayesinde arıza tespiti yapılabilmektedir. Bu gerçek zamanlı yapay sinir ağını sanayide değişik sistemlere uygulanması mümkündür.

6. EKLER

EK 1. Ağıın Çıktı Değerleri.

Arızalar	1. Sensör	2. Sensör	3. Sensör	4. Sensör	5. Sensör	6. Sensör
Düzgün Çalışan Sistem	1	1	1	1	2	1
Şişe Yok	2	2	2	2	2	2
B Kapak Kapama Bozuk	1	1	2	2	2	1
C Kapak Kapma Silindiri Bozuk	1	1	1	1	2	2
Sistemde Yeterli Hava Yok	2	2	2	2	2	2
Su Yok	2	1	2	2	2	2

7. KAYNAKLAR

Angeli, C. and Smirni, N. 1999. An Online Expert System For Fault Diagnosis in Hydraulic Systems. Expert System. May, 1999. 115-120.

Bayır, R. and Bay, Ö. F. 2004. Serial Wound Starter Motor Faults Diagnosis Using Artificial Neural Network. **IEEE ICM'04**, 194-199, İstanbul.

Chen, D. and Wang, J. W. 2000. Classification of Wavelet Map Patterns Using Multi-Layer Neural Networks for Gear Fault Detection. Mechanical Systems and Signal Processing. 695-704. August, 2000.

Chen, C., Mo, C. 2004. A Method For Intelligent Fault Diagnosis of Rotating Machinery. Digital Signal Processing, 203-217.

Demetgül, M. ve Yenitepe, R. 2004. Pnömatik Sistem Arızalarının Giderilmesi Bir Uzman Sistem Uygulaması. Z.K.Ü. Teknoloji Dergisi. Sayı 2. 289-295.

Efe, M.Ö. ve Kaynak, O. 2000. Yapay Sinir Ağları ve Uygulamaları. Boğaziçi Üniversitesi, İstanbul.

Feeman, J. A. and Skapura D. M. 1991. Neural Networks (Algorithms, Application and Programming Techniques). Addison-Wesley. Texas. ABD.

Haykin, S. 1994. Neural Networks. Prentice Hall. New Jersey, ABD.

Karpenko, M., Sepehri, N., Scuse, D. 2003. Diagnosis of Process Valve Actuator Faults Using a Multilayer Neural Network. Control Engineering Practice. 1289-1299.

Karkoub, M. A., Gad, O.E. and Rabie, M. G. 1999. Predicting Axial Piston Pump Performance Using Neural Network. Mechanism and Machine Theory 34, 1211-1226.

McGhee, J., Henderson, I. A. and Baird, A. 1997. Neural Network Applied for the Identification and Fault Diagnosis of Process Valves and Actuators. Measurement 20, 267-275.

Nabiyev, V. V. 2003. Yapay Zeka (Problemler-Yöntemler-Algoritmalar). Seçkin Yayınları. Ankara.

Öztemel, E. 2003. Yapay Sinir Ağları. Papatya Yayınları. İstanbul.

Parlos, A.G., Kim, K. and Bharadwaj R. M. 2004. Sensorless Detection of Mechanical Faults in Electromechanical Systems. Mechatronics 14, 357-380.

Samanta, B. 2004. Gear Fault Detection Using Artificial Neural Network and Support Vector Machines With Genetic Algorithms. Mechanical Systems and Signal Processing 18, 625-644.

Sandt, J., Rinkinen, J. and Laukka, J. 1997. Particle and Water Online Monitoring for Hydraulic System Diagnosis. The Fifth Scandination International Conference on Fluid Power, Linköping, Sweden, 257-268, Vol3.

Seong, S. H., Hur, S., Kim, J. S., Kim, J. T., Park W. M., Lee, U. C. and Lee, S. K. 2005. Development of Diagnosis Algorithm For the Check Valve With Spectral Estimations and Neural Network Models Using Acoustic Signals. Annals of Nuclear Energy 32, 479-492.

Shi, L. and Sepehri, N. 2005. Fault Diagnosis of Pneumatic Actuator Using Adaptive Network-Based Fuzzy Inference System Models and a Learning Victor Quantization Neural Network. IEEE

Proceceeding of the Fourth International Conference on Machine Learning and Cybernetics, Guangzhou. 18-31. August, 2005.

Yang, B. S., Han T. and An, J. L. 2004. ART-KOHONEN Neural Network for Fault Diagnosis of Rotating Machinery. Mechanical Systems and Signal Processing 18, 645-657.

Wang, W.Q., Golnaraghi M. F. and Ismail, F. 2004. Prognosis of Machine Health Condition Using

Neuro-Fuzzy Systems. Mechanical Systems and Signal Processing 18, 813-831.

Wang, T. K. 2000. On-Board Neural Network-Based Sensor Fault Diagnosis System for Automotiv Engines. *PhD Thesis*. Case Western Reserve University. USA, January, 2000.

Wuxing, L., Tse, P.W., Guicai Z. and Tielin, S. 2004. Classification of Gear Faults Using Cumulants and the Radial Basis Function Network. Mechanical Systems and Signal Processing 18, 381-389.
