

BULANIK KURALLARI ÇIKARMAK İÇİN RADYAL TABANLI FONKSİYONLAR AĞININ OPTİMAL DİZAYNI ve METODUN MOTOR HATA BULMA ve TANISI İÇİN UYGULAMASI

Yaman AKBULUT

Fırat Üniversitesi
Enformatik Bölümü, ELAZIĞ
yamanakbulut@firat.edu.tr

Ayşegül UÇAR

Fırat Üniversitesi
Elektrik-Elektronik Mühendisliği, ELAZIĞ
agulucar@firat.edu.tr

Yakup DEMİR

Fırat Üniversitesi
Yakup DEMİR
ydemir@firat.edu.tr

Anahtar sözcükler: Radyal Tabanlı Fonksiyonlar Ağı, Bulanık Çıkarımlı Sistemler, Motor Hata Bulma

ABSTRACT

In this article, an efficient method to design radial basis function neural networks (RBFNs) in data sets for fuzzy rule extraction is presented. The method takes advantage of the functional equivalence between RBFNs and fuzzy inference systems (FISs). Advanced fuzzy clustering is used to design an optimal RBFN. Optimality concerns the smaller number of hidden nodes possible with adequate shapes of kernel functions with high accuracy. The performances of the optimal RBFN are demonstrated on induction motor fault detection and diagnosis problems. Simulation results are presented in term of motor fault detection accuracy. Results suggest new and promising research areas for using optimal RBFN for incipient fault detection and diagnosis in induction motors.

1.GİRİŞ

Kural öğrenme, makine öğrenme ve veri madenciliği araştırmalarında gittikçe önem kazanan bir konudur. Makine öğrenme; bilgiyi veya ustalığı öğrenen program veya algoritmanın gelişmesiyle, veri madenciliği ise verideki gizli kurallar veya örüntülerin bulunması ile ilgilenir. Üzerinde çalışılan konu sistemin uygun giriş-çıkış değerlerinin bir kümesi verildiği zaman, giriş-çıkış değerleri arasındaki ilişkiyi formüle etme ve tanımadan oluşur. Böyle ilişkileri tanımlamak için, fonksiyonel giriş-çıkış tanıma üretilebilir. Fakat, kompleks işlemlerle ilgilenildiğinde bu genellikle uygun olmaz. Dolayısıyla alternatif metotlar arama ihtiyacı duyulmuş ve bulanık kurallar yardımıyla tanımlanan bulanık modellerin kullanımı başarılı olarak uygulanmıştır. Gerçekten, sonuçlar veya yapılan işler hakkındaki bilgi bulanık çıkarımlı sistemin (BÇS) bulanık eğer-o halde kurallarının bir kümesiyle ifade edilebilir.

BÇS'nin temel yapısı üç kavramsal bölümden oluşur. Bunlar; bulanık kural tabanının seçimi, bulanık kurallarda kullanılan üyelik fonksiyonlarının tanımı ve sonuçların çıkarım mekanizmasıdır. Genelde, BÇS

hedef sistemin bilinen geçmiş davranışları temeline dayanarak dizayn edilir ve ondan hedef sistemin davranışını tekrar üretmesi beklenilir. BÇS modeli iyi bir şekilde yapılanmış bilgi gösterimine sahip olmasına rağmen, değişen dış ortam ile ilgili adapta olabirlikten yoksundur. BÇS sadece taklit etmek için değil aynı zamanda öğrenmek ve öğretmek içinde kullanılır. Eğer öğrenme ve otomatik kural çıkarma yetenekleri gerekli ise, yapay sinir ağları (YSA) BÇS'lere tercih edilir. YSA'lar, öğrenme ve adaptifliğinden dolayı araştırmacıların dikkatini çekmiştir. Bununla birlikte çözülecek problemler yardımıyla YSA'ların anlaşılabilirliği açık değildir, çünkü bilgi ağırlıkların bir kümesiyle alınır ve bu nedenle kapalı kutu sistemler olarak düşünülür. [1]'de BÇS'ler ve YSA'ların belirli şartlar altında fonksiyonel olarak eşit olduğu düşünülmüştür. Bunun sonucunda, YSA'lar ve bulanık sistemlerin avantajlarını birleştiren nöral-bulanık modeller oluşturulmuş ve bir çok alanda başarı ile uygulanmıştır. [2-6].

Nöral bulanık sistemlerin, son yıllarda ilgi çeken araştırma alanlarından bir tanesi de motor hata bulma ve tanımadır. AC ve DC motorlarda değişen çalışma ortamı ve dinamik yüklenme nedeniyle rotor çubuklarının kırılması, mil yatağının bozulması gibi başlangıç halinde olan hatalar ortaya çıkmaktadır. Bu hatalar uygun bir şekilde bulunmaz ve kontrol altına alınmaz ise, ciddi performans azalması ve bunun sonucunda sistem bozulmaları ile sonuçlanabilir. Düzeltilmiş güvenlik ve güvenilirlik bakımı koruyucu kavramına götüren uygun erken hata tanı stratejileri ile sağlanabilir. Üstelik büyük bakım bedelleri geliştirmekte olan bu bozuklukları bulmak için ileri hata bulma metotları uygulayarak önlenir. Bu nedenle, bu probleme YSA ve BÇS'leri uygulamak bir çok araştırmacı tarafından ele alınmıştır [7-10].

Bu çalışmada, BÇS ve adaptif ağların fonksiyonel eşitliğinin avantajlarını alarak bulanık kuralları çıkarmak için nöral-bulanık modelleme ve optimal

öbekleme temeline dayanan bir yaklaşım sunulmuştur. Veri kümesinde bulanık kural çıkarımı için optimal nöral-bulanık modelin dizayn prosedürü verilerek asenkron motorda sürtünme hatasını bulma ve tanıma probleminde bir çözüm önerilmiştir

2.BULANIK ÇIKARIMLI SİSTEMLER

BÇS'lerde bulanık kurallar 'eğer x, A'ya eşit ise o halde y, B'dir' formunda tanımlanır, burada A ve B sırasıyla X ve Y tanım aralığı üzerinde ön görülen dilsel değerlerdir. A bulanık kümesi, üyelik fonksiyonu (ÜF) $\mu_A(x)$ ile karakterize edilir.

$$A = \{(x, \mu_A(x)) / x \in X\}$$

ÜF, X'in her bir elemanını 0 ve 1 arasında üyelik derecesine dönüştürür. Kural tabanındaki 'eğer x, A'ya eşitse' kısmı kuralların önceki kısmı ve 'o halde y, B'dir' kısmı ise kuralların sonraki kısmı olarak adlandırılır. Genellikle bulanık kurallar birden fazla önceki kısımlara sahiptir. İki önceki kısma sahip olan bir bulanık kural aşağıdaki formda yazılabilir:

'eğer x, A'ya eşitse ve y, B'ye eşitse, o halde z, C'dir'

BÇS'ler genel olarak Mamdani veya Sugeno bulanık modeller ile gösterilir [11]. İki model arasındaki fark kurallarının sonuç bölümüne dayanır. Mamdani BÇS çıkışı bir bulanık kümedir ve sayısal çıkış istenirse bir durulaştırma adımı gerektirir. Sugeno bulanık model sayısal bir değer üretir. Sugeno modelde tipik bir bulanık kural 'eğer x, A'ya eşitse ve y, B'ye eşitse; o halde z, f(x,y)' formundadır. Burada f ağırlık değişkenleri olan x ve y'ye, bağlı bir polinomdur. BÇS'de; eğer f(x,y) sıfıncı dereceden bir polinom ise sıfıncı dereceden Sugeno BÇS'ye, birinci dereceden bir polinom ise birinci dereceden Sugeno BÇS'ye karşılık gelir. Her bir kural sayısal bir çıkışa sahip olduğu için, sistemin tüm çıkışı ağırlıklı ortalama veya ağırlıklı toplam ile elde edilir.

3.RADYAL TABANLI FONKSİYONLAR AĞI

Radyal tabanlı fonksiyonlar ağı (RTFA), Denklem (1) veya Denklem (2)'deki ilişkiye göre girişlerin lineer olmayan dönüşümünün lineer kombinasyonu ile giriş-çıkış ilişkisini sonuçlandıran ve tek gizli katmanlı ileri beslemeli bir YSA'dır.

$$o_i = \sum_{j=1}^m w_j \phi_j(\bar{x}) \quad (1)$$


$$o_i = \frac{\sum_{j=1}^m w_j \phi_j(\bar{x})}{\sum_{j=1}^m \phi_j(\bar{x})} \quad (2)$$

Burada; x:giriş vektörünü, w_j : j. yenilikçi alanın uzunluğunu, m: yenilikçi alanların sayısını ve $\phi_j(\bar{x})$: orijinde bir tek maksimumu olan yenilikçi alanın cevabını gösterir ve $\phi_j(\bar{x})$ tipik olarak Denklem (3)'deki gibi tanımlanır.

$$\phi(\bar{x}) = \exp \left[-\frac{\|\bar{x} - \bar{c}_j\|^2}{\sigma_j^2} \right] \quad (3)$$

Burada; c_j : j. merkez vektörünü, σ_j : j. yenilikçi alanın genişliğini ve $\|\cdot\|$: Euclidean normunu göstermektedir.

m gizli nöronlu tek çıkışlı bir RTFA'nın yapısı Şekil 1'de görülmektedir. RTFA'ların gizli ve çıkış katman ağırlıkları genel olarak ard arda eğitilir. Önce radyal taban fonksiyon (RTF) parametreleri sabitlenir, daha sonra optimal lineer ağırlıklar hesaplanır.



Şekil 1. m gizli nöronlu tek çıkışlı RTFA.

4.FONKSİYONEL EŞİTLİK

[1]'de Jang tarafından belirtildiği gibi, RTFA ve BÇS aynı temelden gelir. RTFA radyal taban fonksiyonlarından oluşurken, BÇS üyelik fonksiyonlarının belirli sayısından oluşur. Her iki model küçük yenilikçi alanlara merkezi ağırlıklanmış bir cevap üretir. BÇS ve RTFA aşağıdaki şartlar altında fonksiyonel olarak eşittir.

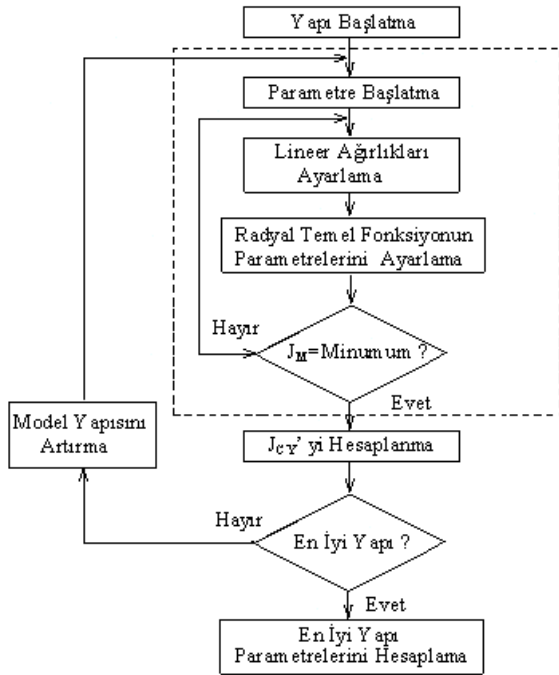
1. RTF birimlerinin sayısı BÇS'deki bulanık kuralların sayısına eşittir.
2. RTFA'nın her bir radyal taban fonksiyonu uygun bulanık kuralın önceki bölümünün Gaussian ÜF'sine eşittir.
3. Her bir kuralın çıkışı bir değerdir (Mamdani veya sıfıncı dereceden Sugeno model).
4. Hem RTFA hem de BÇS çıkışlarını bulmak aynı toplama kuralını kullanır (ağırlıklı ortalama veya ağırlıklı toplam).

5.RTFA'LARIN BULANIK ÖBEKLEME TEMELLİ OPTİMAL DİZAYNI

RTFA'lardaki taban fonksiyon ve BÇS'deki üyelik fonksiyonları arasındaki uygunluk RTFA'ların dizaynına alternatif bir yol üretir. Gerçekte, kümelerin

bulanık ÜF'lerini otomatik olarak oluşturmak için kullanılan bulanık öbikleme tekniği bu fonksiyonel eşitliğe dayanarak RTFA'ların parametrelerine otomatik olarak uygulanabilir. Bu nedenle optimal öbikleme algoritması optimal RTFA yapısının dizaynına da götürür.

Bu çalışmada, optimal öbikleme kullanılarak uygun ÜF şekli ve genişliği ile öbeklerin optimal sayısının otomatik tanımı verilmiştir. Gizli katmandaki her bir nöron bir kurala karşılık geldiği için, kuralların optimal kümesi böylece tanımlanmış olur. Şekil 2'de bu çalışmada geliştirilen optimal RTFA dizaynının akış diyagramı verilmiştir. Bu algoritmanın adımları kısaca aşağıdaki gibidir:




Şekil 2. Optimal RTFA'nın öğrenme prosedürü

1. Adım: İlk olarak m boyutlu eğitim veri noktalar kümesi X_i ($i=1, \dots, n$) toplanır. Bu küme giriş ve çıkış verilerini içerir. Daha sonra kuralları çıkarmak için kümelerin maksimum ve minimum sayısı ile çapraz-ilişki kümelerinin sayısı dizayn edici tarafından ayarlanır.

2. Adım: Bulanık çok boyutlu elipsoidal öbikleme algoritması kullanılarak veriler öbeklenir [11]. Bu prosedür giriş/çıkış dönüşümünün kaba bir gösterimi olan çok boyutlu elipsoitler kümesini elde ederek giriş-çıkış alanındaki verileri öbekler. Bu çalışmada BÇS ve RTFA'ların fonksiyonel eşitliğinden faydalanarak lineer ağırlıkların parametrelerini başlatmak için elipsoidin eksenleri (saçılma matrisinin öz değerleri) kullanılmıştır. Taban fonksiyonların merkezlerini başlatmak için, giriş alanı üzerinde öbek merkezleri tasarlanmış, taban fonksiyonunun genişliğini hesaplamak için ise saçılma matrisi adapte edilmiştir. Verinin v_1 ve v_2 prototipli iki gruba

öbeklendiği elipsoidal bulanık öbikleminin bir örneği Şekil 3'de görülmektedir.



Şekil 3. Çok boyutlu elipsoidal öbikleme.

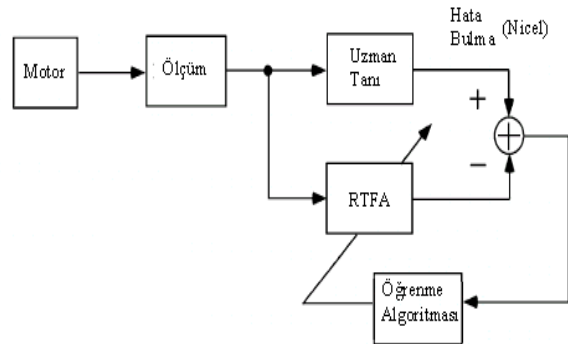
3. Adım: 2.Adımda başlatılan parametreler sadece eğitim kümesine bağlı olan en küçük kareler amaç fonksiyonu (J_M) minimize edilerek optimize edilir. Bu çalışmada, sadece Sugeno model kullanıldığı için; lineer çıkış ağırlıkları en küçük-kareler algoritması ile, RTF'ların merkez ve genişlikleri ise Levemberg-Marquardt algoritması ile hesaplanmıştır. Fazla hesapsal yükün istenmediği durumlarda en dik iniş algoritması kullanılabilir.

4. Adım: Lokal modellerin sayısı derece derece artırılarak, kuralların optimal kümesi yardımıyla en iyi yapı aranır [12]. Farklı yapılar değerlendirilir ve K-katlı çapraz geçerliliğindeki performanslarına (J_{CV}) göre karşılaştırılır [13]. Bu prosedür ağı eğitmek için mevcut verinin oldukça yüksek bir oranını kullanır ve genelleştirmede parametrenin oldukça güvenilir olarak hesaplamasını sağlar.

5. Adım: En yüksek performansı veren, m_{opt} gizli düğümlü RTFA yapısı giriş çıkış dönüşümünü göstermek için seçilir ve son olarak test edilir.

6.MOTOR HATA BULMA ve TANIMA İÇİN OPTİMAL RTFA


Asenkron motor hatalarını tanımak amacıyla optimal RTFA'yı kullanmak için, ağı giriş ve çıkışlarının uygun bir şekilde seçilmesi ve uygun veri ile eğitilmesi gerekir. RTFA'nın hata tanıma için eğitim yapısı Şekil 4'de görülmektedir.



Şekil 4. RTFA'nın eğitim aşaması.

Asenkron motor yapısında; stator akımları (i) ve rotor açılma hızı (ω), farklı yük momentini (τ) ve motor sürtünmesi (B) altında ölçülür. Motor sürtünmesinin ve yük momentinin genliği motor çalışmasını dolayısıyla hız ve akım ölçümlerini etkiler. Bununla birlikte, motor sürtünmesinin genliği doğrudan ölçülemez. Ayrıca başlangıç halinde olan sürtünme hataları yük momentinin etkileri ile benzerdir. Bu nedenle bu çalışmada uygun ölçmeler temelinde dayanarak motor sürtünmesinin hesaplanması amaçlanmıştır.

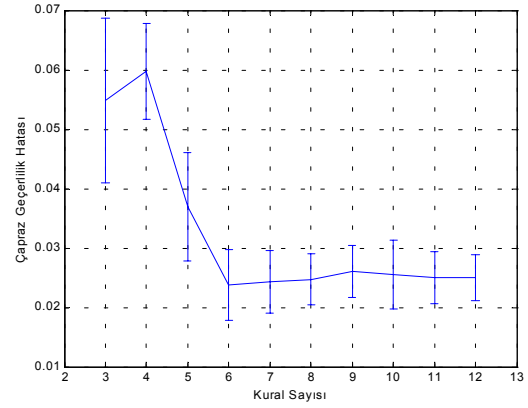
Bu çalışmada optimal RTFA'yı motor hata tanıyıcı olarak değerlendirmek için 60-Hz, 4 kutuplu, 200V, 1-HP gücünde bir asenkron motor kullanılmıştır. MATLAB/SIMULINK ile oluşturulan asenkron motor simülasyonundan deneysel verileri toplanmıştır. Doyum etkisi de simülasyon modelinin içine karıştırılmıştır. Eğitim için kullanılan veri, değişken motor sürtünmesi ve yük momentinin değerleri altında stator akımı ve rotor açılma hızıdır. Simülasyon 2 sn süre ile çalıştırılmış ve [0.6,2] sn aralığında $3e-5$ sn örnekleme periyodu ile toplam 467 veri alınmıştır. Bu örneklerden seçilen 233 veri ağı eğitmek için geriye kalan 232 veri ise ağı test etmek için kullanılmıştır. Eğitim için kullanılan akım, hız, yük momentini ve sürtünme verileri Şekil 5'de görülmektedir.




Şekil 5. Eğitim için kullanılan i , ω , τ ve B verileri.

Giriş verisi olarak özellikle yük momentini göz önüne alınmıştır. Çünkü motor sürtünmesindeki artma, yük

momentindeki artmanın etkisine benzer bir şekilde akımı artırır ve hızı azaltır. Bu nedenle hata tanıyıcının yük hakkındaki bilgiyi içermediği durum doğru olmayan bir hata tanımayla sonuçlanır. İdeal şartlarda motor sürtünmesi sıfırdır. Bu çalışmada motor sürtünmesini simüle etmek için B' 'nin değeri artırılmıştır.



Şekil 6. Çapraz-geçerlilik hatası.



Şekil 7. Test hatası.

Optimal RTFA algoritması 14 dakika çalıştırılmış ve Şekil 6'dan görülen çapraz geçerlilik hatalarına göre optimal bulanık kurallarının sayısı 8 olarak belirlenmiştir. Daha sonra RTFA eğitimde kullanılmayan veriler ile test edilmiştir. Bazı test verileri için Tablo 1'de verilen RTFA çıkışı ve hedef çıkışlardan ve Şekil 7'den görüldüğü gibi oldukça iyi bir kararlılıkla (küçük bir hata) ile sürtünme hesaplanmıştır. Ayrıca bu hata daha fazla eğitim verisi kullanılarak oldukça küçültülebilir. Optimal RTFA algoritmasının çıkarılan bulanık kurallar veya optimal RTFA parametreleri Tablo 2'de verilmektedir. Bu RTFA algoritmasının dezavantajı olarak yapı arama için geçen süre gösterilebilir. Bu çalışmada kullanılan hata bulma planı, motor modelinin herhangi bir bilgisini gerektirmeden usta bilgiye göre veya sadece eğitimde kullanılacak verileri elde edecek denklemler yardımıyla modeli bilinmeyen hata tanıma uygulamalarında iyi sonuçlar verebilir.

Tablo 1. RTFA'yı test etmek için kullanılan verilerden bazıları.

Hedef Çıkış	RTFA Çıkışı
0	0.0065
0.0001	0.0075
0.0002	0.0052
0.0014	0.0096
0.0018	0.0046
0.0806	0.0445
0.0825	0.0482
0.0844	0.0476
0.0862	0.0460
0.0881	0.0482
0.0900	0.0500
0.0918	0.0523
0.0937	0.0489
0.0956	0.0529
0.0975	0.0505

Tablo 2. Çıkarılan bulanık kuralların/optimal RTFA yapısının sırasıyla[σ , c] parametreleri

Eğer			O Halde
Taban Fonksiyonlar			Çıkış Ağırlıkları
I	ω	τ	B
1.7489	0.1009	3.6048	0.1068
2.1148	0.9813	-1.0746	
1.0154	0.1006	0.5413	-0.0427
-2.2711	1.0110	1.5463	
1.2622	0.1007	1.1494	-0.0266
2.4245	1.0122	1.5294	
1.9631	0.1011	3.1523	-0.0260
0.2483	1.0232	1.4730	
2.4643	0.1007	0.7900	-0.0640
2.8645	0.9531	-3.9647	
2.7457	0.1001	3.8325	0.0875
-0.6173	0.9815	-1.2483	
3.1723	0.1006	0.2063	-0.0739
-2.8658	0.9529	-3.9691	
2.0519	0.1012	4.0777	0.0955
-2.3999	0.9806	-1.0058	

7.SONUÇLAR

Bu çalışmada, veri kümesinde bulanık kuralları çıkararak RTFA'ları dizayn etmek için bir metot gösterilmiştir. Bu metot BÇS ve RTFA'ların fonksiyonel eşitliğindeki avantajları alarak oluşturulmuştur. Çok boyutlu elipsoidal öbekleme algoritması kullanılarak optimal RTFA dizayn edilmiştir. Burada optimal kavramı ile yüksek kararlılık kernel fonksiyonuna ve çok küçük gizli düğüm sayısına sahip olan RTFA düşünülmüştür. Metodun performansını değerlendirmek için asenkron motorlarda sürtünme hatasının bulunması problemi ele

alınmıştır. Eğitim için kullanılmayan veriler üzerinde sürtünme oldukça iyi bir kararlılıkla hesaplanmıştır. Bu sonuç ile önerilen RTFA'nın yapı modelleme, tahmin gibi uygulamalarda iyi bir performans vereceği açıktır.

KAYNAKLAR

- [1] Jang J-S. R., Sun C-T., Functional Equivalence Between Radial Basis Function Networks and Fuzzy Inference Systems, IEEE TRANS. NEURAL NETWORKS, Vol. 4, Iss 1, pp. 156-159, 1993.
- [2] Mascioli F., Frattale M.G., A Constructive Approach to Neuro-Fuzzy Networks, SIGNAL PROCESSING, Vol. 64, pp. 347-358, 1998.
- [3] Juang C.F., Lin C.T., An On-Line Self-Constructing Neural Fuzzy Inference Network and Its Applications, IEEE TRANS. FUZZY SYSTEMS, Vol. 6, Iss 1, pp. 12-32, 1998.
- [4] Klaw F., Kruse R., Constructing A Fuzzy Controller from Data, FUZZY SETS AND SYSTEMS, Vol. 85, pp.177-135, 1997.
- [5] Liu Z.Q., Yan F., Fuzzy Neural Network in Case-Based Diagnostic System, IEEE TRANS. FUZZY SYSTEMS, Vol. 5, Iss 2, pp. 209-222, 1997.
- [6] Lee K.M., Kwak D., Leekwang H., Tuning of Fuzzy Models by Fuzzy Neural Networks, FUZZY SETS AND SYSTEMS, Vol. 76, Iss 1, pp. 47-63, 1995.
- [7] Altug S., Chow M., Trussell H.J., Heuristic Constraints Enforcement for Training of and Rule Extraction from a Fuzzy/Neural Architecture-Part II: Implementation and Application, IEEE TRANS. FUZZY SYSTEMS, Vol. 7, Iss 2, pp. 151-159, 1999.
- [8] Chow M.Y., Motor Fault Detection and Diagnosis, IEEE IND. ELECTRON. NEWSLETT., Vol. 44, Iss. 4, pp. 4-7, 1997.
- [9] Altug S., Chow M.Y., Trussell H.J., Fuzzy Inference Systems Implemented on Neural Architectures for Motor Fault Detection and Diagnosis, IEEE TRANS. IND. ELECTRON., Vol. 46, pp. 1069-1078,1999.
- [10] Kolla S., Varatharasa L., Identifying Three-Phase Induction Motor Faults Using Artificial Neural Networks, ISA TRANSACTIONS, Vol. 39, pp. 433-439, 2000.
- [11] Babuska R., Verbruggen H.B., Fuzzy Set Methods for Local Modelling and Identification, MULTIPLE MODEL APPROACHES TO MODELING AND CONTROL, Taylor-Francis, pp. 75-100, 1997.
- [12] Vapnik V., The Nature of Statistical Learning Theory, SPRINGER, NEWYORK, NY, 1995.
- [13] Stone M., Cross-Validatory Choice and Assessment of Statistical Predictions, JOURNAL OF THE ROYAL STATISTICAL SOCIETY B, Vol.36, Iss 1, pp.111-147, 1974.