



Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences



Geliş Tarihi :06/08/2018
Kabul Tarihi : 18/12/2018

Received Date : 06/08/2018
Accepted Date : 18/12/2018

PI Katsayıları ve Sistem Performansı Arasındaki İlişkinin Çıkarılmasında ANFIS ve YSA Yöntemlerinin Karşılaştırılması

Comparison of ANFIS and ANN Methods in Deriving the Relationship between PI Coefficients and System Performance

Seydi Vakkas ÜSTÜN¹, Ahmet NUR^{1*}, Mustafa KAYA¹

¹Adıyaman Üniversitesi, Elektrik-Elektronik Mühendisliği, Adıyaman, Türkiye

*Sorumlu Yazar / Corresponding Author: Ahmet NUR, anur@adiyaman.edu.tr

ÖZET

Bu çalışmada, dolaylı vektör kontrollü asenkron motor kontrolünde kullanılan PI katsayıları (K_p - K_i) ile bütün sistemin performansı arasındaki ilişkiyi modellemede uyarlamalı sinirsel bulanık çıkartım sistemi (ANFIS) ve Yapay Sinir Ağları (YSA) yöntemlerinin başarıları karşılaştırılmıştır. PI katsayılarının optimum bir şekilde ayarlanabilmesi için sistem modeline ihtiyaç duyulmaktadır. Bütün sistem başarılı bir şekilde modellendiği takdirde kontrolör katsayılarını optimum olarak ayarlayabilmek mümkün olacaktır. Bu amaçla işlemci olarak Sayısal İşaret İşlemci (DSP) dsPIC33FJ128MC804, güç elemanı olarak Akıllı Güç Modülü (IPM) kullanılarak gerçekleştirilen sürücü devre tasarlanmıştır. Bu sürücü devre ile sistemin farklı K_p - K_i katsayıları için performansı bulunmuştur. Performans, maksimum aşım (M_o) ve referans hıza yerleşme zamanının (T_s) kullanıldığı bir formül ile 0-1 aralığında elde edilmiştir. Elde edilen eğitim veri setleri ile ANFIS ve YSA modelleri oluşturulmuş ve test veri seti ile de modellerin başarıları karşılaştırılmıştır.

ABSTRACT

In this study, we compared the performance of the adaptive Neuro Fuzzy Inference System (ANFIS) and Artificial Neural Networks (ANN) in a relation model between the PI coefficients (K_p - K_i) used for indirect vector controlled asynchronous motor control and the performance of the whole system. In order to optimize the PI coefficients, a system model is needed. If the whole system is successfully modeled, it will be possible to optimize the controller coefficients. For this purpose, we designed the driver circuit using Digital Signal Processor (DSP) dsPIC33FJ128MC804 as processor and Intelligent Power Module (IPM) as power component. With this drive circuit, the performance of the system for different K_p - K_i coefficients has been found. The performance was obtained in a range from 0 to 1 with a formula using the maximum overshoot (M_o) and reference speed settling time (T_s). The ANFIS and ANN models were obtained by using the training data sets and the success of the models were compared with the test data set.

Anahtar Kelimeler: ANFIS, YSA, Dolaylı Vektör Kontrol, DSP.

Keywords: ANFIS, ANN, Indirect Vector Control, DSP.

1. GİRİŞ

Vektörel kontrol, bir DC motorunu çalışmasına benzer şekilde, bir asenkron motorun akı ve torkunu birbirinden ayırmak için geliştirilmiş bir kontrol stratejisidir. Bu yöntemin avantajı, asenkron motorun dayanıklılık, yüksek etkinlik ve çok sık bakım gerektirmeme özelliklerine ek olarak, bir DC motor gibi kolay kontrol edilebilirliğidir. Bu özellikleri taşıyan bir asenkron motorun endüstride yaygın birçok uygulama alanı vardır (Bose, 2002; Nur ve ark., 2017; Kılıç ve ark., 2016).

Motor kontrolü, geleneksel olarak, sabit kazanç orantılı integral (PI) ve oransal integral türev (PID) kontrol teknikleri ile gerçekleştirilir. Bu tip sabit kazanç kontrolörleri, parametre değişikliklerine, yük arızalarına vb. karşı çok hassastır. Bu nedenle, kontrolör parametrelerinin sürekli ayarlanması gerekmektedir. Bu sorun, model referans uyarlamalı kontrol, kayma modu kontrolü, değişken yapı kontrolü ve kendi kendini ayarlayan PI denetleyicileri gibi çeşitli kontrol teknikleri yardımıyla çözülebilir. Bu çözümlerin tümü sistemin tam bir matematiksel modeliyle yapılabilir. Ancak, belirsiz yük değişimi, doyumluk ve farklı sıcaklık durumları nedeniyle kaçınılmaz parametre değişimleri sonucu sistemin matematiksel modelinin oluşturulması genellikle zordur (Wang ve ark., 2000; Krause ve ark., 2002; Gani ve ark., 2015).

Performans düzeyi yüksek uygulamalarda, sürücü davranışını temsil eden karmaşık ilişkileri modellemek önemlidir. Değişik öğrenme algoritmaları, değişken hızlı sürücülerini otomatik olarak modellemek de, güçlü bir araç olabilir. Bunlar, sürücü davranışını temsil eden ilişkiyi, fonksiyonel bir ilişki şeklinde otomatik olarak çıkartabilirler. Böylece, matematiksel model ve parametrelerin tam değerlerine ihtiyaç duymadığından klasik yöntemlere göre bazı avantajlar sunabilmektedir.

Elektromekanik sistemlerin, matematiksel olarak modellenmesi zor olan, doğrusal olmayan ve parametre sapması oluşturan durumları içerdigi de bir gerçektir (Üstün ve ark., 2005; Toliyat ve ark., 2004).

Bazı parametrelerin ihmal edilmesi ve parametre sapmalarından dolayı matematiksel model fiziksel sistemi tam olarak temsil edemeyebilir. Halbuki, kontrolör katsayılarının doğru bir şekilde ayarlanabilmesi için tam bir sistem modeline ihtiyaç vardır. Tam bir sistem modelinin çıkartılamaması, sürücü katsayılarının uygun şekilde ayarlanamamasına sebep olur. Bulanık mantık, uzman deneyimleri ve girdi-çıkı verilerinden elde edilen ilişkileri bulanık bilgi olarak değerlendirme ve işlemede başarılıdır. Bulanık mantıklı sistemler ile, sistem modelleme, sistem kontrolü, sistem tanımlama ve sistem tahmini gibi alanlarda yaygın olarak çalışılmaktadır. Bulanık sistemler insan bilgisini kolayca ele alabilmektedir fakat bulanık sistemlerin öğrenme yeteneği bulunmamaktadır. Yapay sinir ağlarında ise verilen girdi-çıkı verileri için öğrenme ve uyarlanabilme kabiliyeti vardır. Yapay sinir ağlarının veri kümeleri ve geri beslemeleri kullanarak bir öğrenme yeteneği olsa da, öğrendiği bilginin insan tarafından anlaşılması oldukça güçtür. Bu özelliklerinden dolayı yapay sinir ağları ve bulanık mantık, öngörülen girdi-çıkı eşlerini elde etmek için gerekli olan üyelik fonksiyonları ve bulanık kurallar kümesi oluşturulurken birlikte kullanılmaktadır. Bu melez yöntem ANFIS denilmektedir (John ve ark., 2008; Sadati ve ark., 2009; Ertunç ve ark., 2013; Özdemir ve ark., 2018).

Yapılan çalışma ile, gerçek sistem üzerinden alınan verilerin oluşturduğu eğitim veri kümesi kullanılarak, PI Katsayıları ile sistemin uygunluğu arasındaki ilişki ANFIS ile modellenmiştir. Aynı veri kümesi YSA modelinin oluşturulmasında kullanılmıştır. Yine gerçek sistem üzerinden alınmış eğitim veri kümesinde olmayan test verileri ile sonuçlar elde edilip, bu iki yöntem ile gerçekleştirilen modellerin başarısı karşılaştırılmıştır.

2. ANFIS YÖNTEMİ VE YAPAY SİNİR AĞLARI İLE SİSTEM MODELLEME

ANFIS, yapay sinir ağları mimarisinin bulanık mantık ilkeleriyle birlikte kullanılabilirdiği uyarlamalı bir ağıdır. Ayarlama işlemi YSA'nın öğrenme metodları ile yapılır. Bu şekilde normalde öğrenme yeteneği olmayan bulanık sistemlere modelleyeceği veri setleri ile öğrenme kabiliyeti sağlanmış olunur. ANFIS öğrenme metodu olarak geri yayılım metodu veya geri yayılım metodu ile en küçük kareler kestirim metodu hibrit sistemini kullanmaktadır. ANFIS 5 adet katmandan oluşmaktadır. Her katmanda bulanık mantık kural sayısı kadar nöron bulunur. Bu mimaride her katman farklı bir işlev icra eder. Şekil 1 (a)'da 2 girişli ve 2 kurallı bulanık mantık sisteminin Sugeno yöntemiyle modellenmiş çıkarsama yapısı ve Şekil 1 (b)'de bu modelin eşdeğer ANFIS mimarisi verilmiştir. ANFIS ağ yapısında yuvarlak biçimde gösterilmiş olan düğüm noktaları statik olup, kare biçiminde olan düğüm noktaları ise uyarlanabilirler. Bulanık mantık yaklaşımında bir kuralın sonuç bölümü uzman görüşü ile alınmış dilsel bir ifadedir. Sonuç bölümü, Sugeno çıkartım yöntemiyle girişlerin doğrusal toplamı olarak ifade edilebilir (Gökçe ve ark., 2016; Sun ve ark., 2005; Üstün ve ark., 2009; Kılıç ve ark., 2018). Örneğin;

Kural 1: If X is A1 and Y is B1, then $f_1 = p_1x + q_1y + r_1$

Kural 2: If X is A2 and Y is B2, then $f_2 = p_2x + q_2y + r_2$


Çıkış,

$$f = \frac{w_1f_1 + w_2f_2}{w_1 + w_2} \quad (1)$$

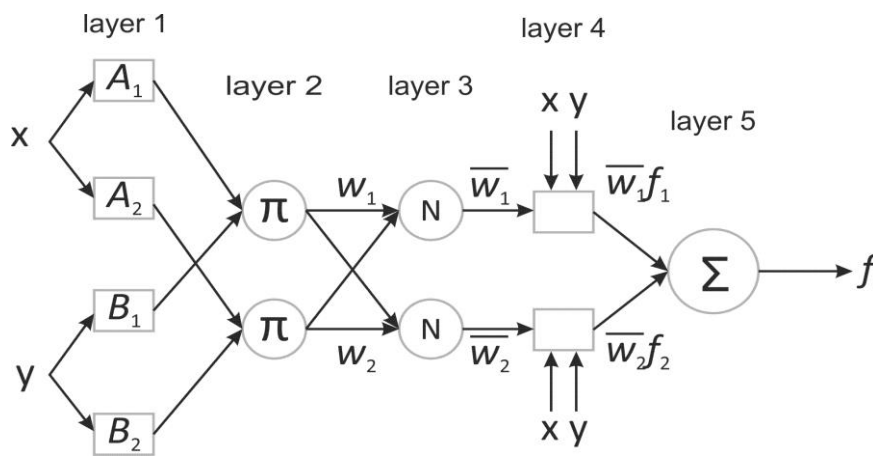
veya

$$f = \frac{\mu_{A1}(x)\mu_{B1}(y)(p_1x + q_1(y) + r_1) + \mu_{A2}(x)\mu_{B2}(y)(p_2x + q_2(y) + r_2)}{\mu_{A1}(x)\mu_{B1}(y) + \mu_{A2}(x)\mu_{B2}(y)} \quad (2)$$

şeklinde ifade edilebilir.




(a)



(b)

Şekil 1. İki Kurallı ANFIS Yapısı. (a) Tip-3 Bulanık Mantık Çıkartımı. (b) Eşdeğer ANFIS


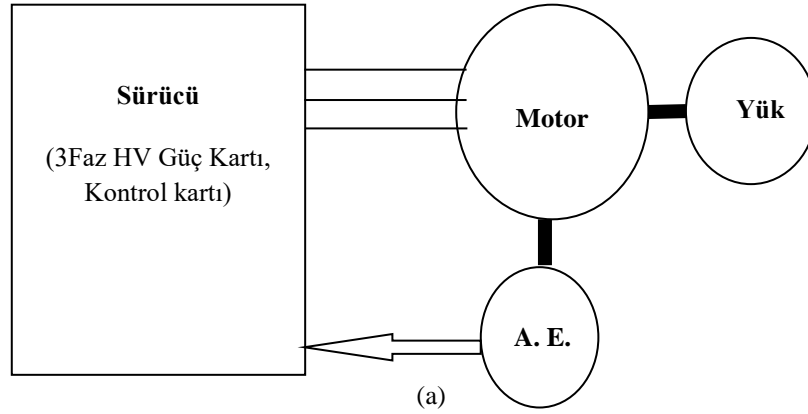
Yapay sinir ağları (YSA); insan beyninin çalışma sisteminin yapay benzetimi çabalarının bir sonucu olarak ortaya çıkmıştır. YSA, en genel anlamda insan beynindeki birçok sinir hücresinin (nöronun) ya da yapay olarak basit işlemcilerin birbirlerine değişik etki seviyeleri ile bağlanması sonucu oluşan karmaşık bir sistem olarak düşünülebilir. Sistem teorideki temel konulardan biri olan sistem tanıma, bir sistemin deneysel olarak elde edilen giriş-çıkış verilerinden yararlanarak, sistemin matematiksel modelini oluşturmaktır. Temel bir sistem tanıma blok şeması Şekil 2'te gösterilmiştir (Haykin, 1999; Yüksel ve ark., 2009).



Şekil 2. Sistem Tanıma

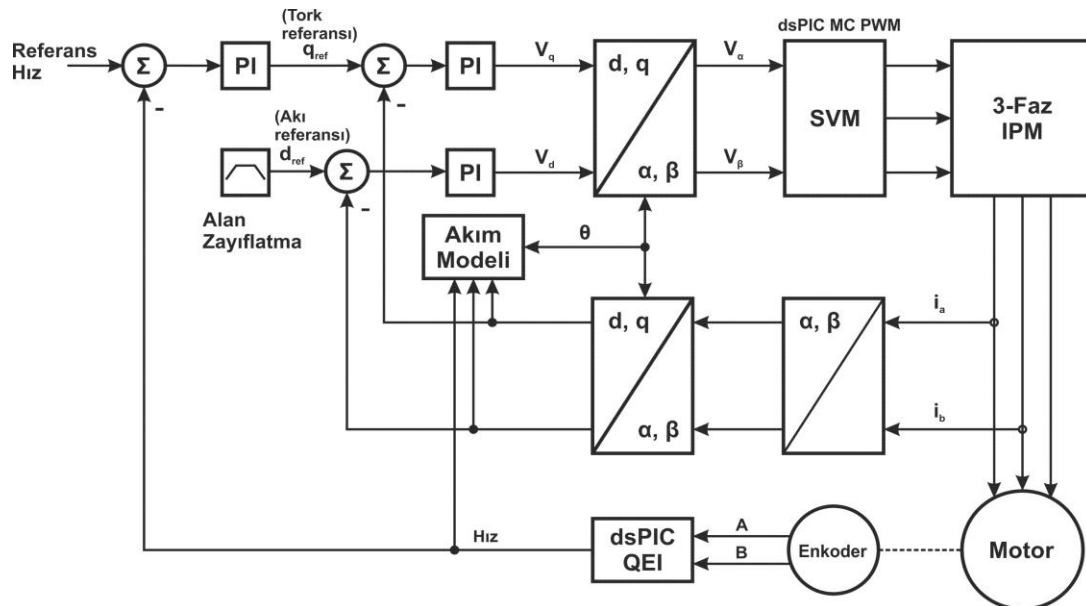
3. UYGULAMA SETİ

Uygulama, bir motor ve bir bağlantı elemanı ile motora bağlı jeneratörden oluşmaktadır. Aynı zamanda motora monteli bir artımsal enkoder bulunmaktadır. Motorun etiket değerleri, 1.5 kW, 6.2A, 50 Hz, Cosφ=0.8, üç fazlı sincap kafesli endüksiyon motordur. Kontrol kartı dsPIC33FJ128MC804 Dijital Sinyal İşlemci (DSP) işlemci temelli olarak tasarlanmıştır. Sürücüdeki verileri PC'ye alabilmek için kontrol kartına bir SD kart birimi eklenmiştir. Bu uygulama devresinin blok diyagramı ve resmi Şekil 3'te gösterilmektedir.



Şekil 3. Uygulama Devre Blok Diyagramı (a) ve Şekli (b)

Asenkron motorlarında vektör kontrolünün kullanımının ana amacı, DC makinelerde olduğu gibi, torku ve akıyı birbirinden bağımsız olarak kontrol etmektir. Bu amaçla Şekil 4'te gösterildiği gibi bir kontrol yapısı kullanılmaktadır.



Şekil 4. Vektör Kontrollü Sürme Sistemi (Ross ve ark., 2005)

Sürücü devrenin anahtarlama frekansı 6 kHz alınmış, böylece uygulama 170 mikro saniyelik bir PWM time base ile çalıştırılmıştır. Sistemin cevap verme süresi dikkate alınarak, kontrol, her 30 PWM time base de bir defa gerçekleştirilmiştir. Kullanılan dsPIC33FJ128MC804 DSP, aynı fazdaki IGBT'lerin iletme geçme zamanları arasındaki ölü zamanı donanımsal

olarak gerçekleştirmektedir. Bu 5 mikro saniye olarak ayarlanmış ve gerçekleştirilmiştir. Sürücü yazılımı makine dili ve C dili ile yazılmıştır. Programın geliştirilmesi ve derlenmesi MPLAB ortamında gerçekleştirilmektedir.

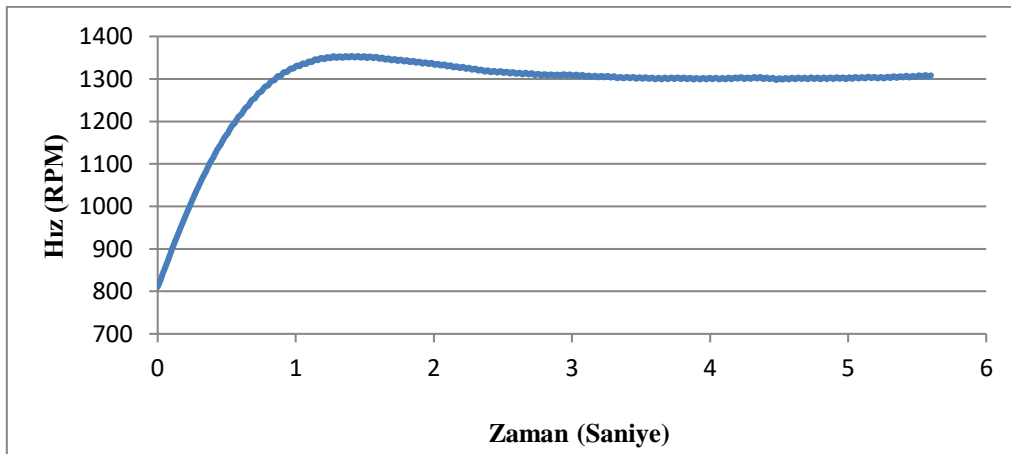
4. ANFIS VE YSA İLE KOMPLE SİSTEMİN MODELLENMESİ

Bu çalışmada, kontrol sisteminin performansını belirleyen PI katsayıları (K_p ve K_i) giriş olarak ele alındı. Bu giriş değerleri ile çalışan sistemin performansı ise çıkış olarak ele alındı. Sistem, yükte çalışırken, motor hızının 800 d/dak'dan 1300 d/dak'ya çıkartılması senaryosu ile çalıştırılmıştır. Referans hızın değiştirilmesi ile, hızda oluşan maksimum aşım ve referans hıza belli bir tolerans ile yerleşme zamanı kontrol sisteminin başarı ölçütünü belirleyen parametreler olarak alınmaktadır. Uygunluk değeri bu iki parametrenin bir fonksiyonu olarak 0 ile 1 arasında elde edilmiştir.

Uygunluk değerini veren uygunluk fonksiyonu Denklem 3 ile verilmiştir.


$$f = \frac{1}{(Mo + Ts)} \quad (3)$$

ANFIS ve YSA girişler ve çıkışı arasında lineer olmayan ilişkileri, eğitime-öğrenme sonucu, modelleyebilen bir yapıya sahiptir. Uygulama devresinden alınan veriler iki giriş (K_p , K_i) ve bir çıkışı (uygunluk değeri) olacak şekilde, bu iki yönteme uygulanmıştır. Deneme yoluyla, K_p ve K_i çiftleri için, geçerli değer aralıkları sırasıyla (0.2-0.5) ve (0.0045-0.024) olarak bulunmuştur. Bu aralıklardan, 42 farklı K_p - K_i çifti, uygulama devresine verilerek ayrı ayrı uygunluk değerleri bulunup, eğitim veri seti oluşturulmaktadır. Bu veri setinden rasgele, $K_p=0.25$ ve $K_i=0.024$ çifti için, sistemin hız değişimi Şekil 5'te gösterilmiştir.

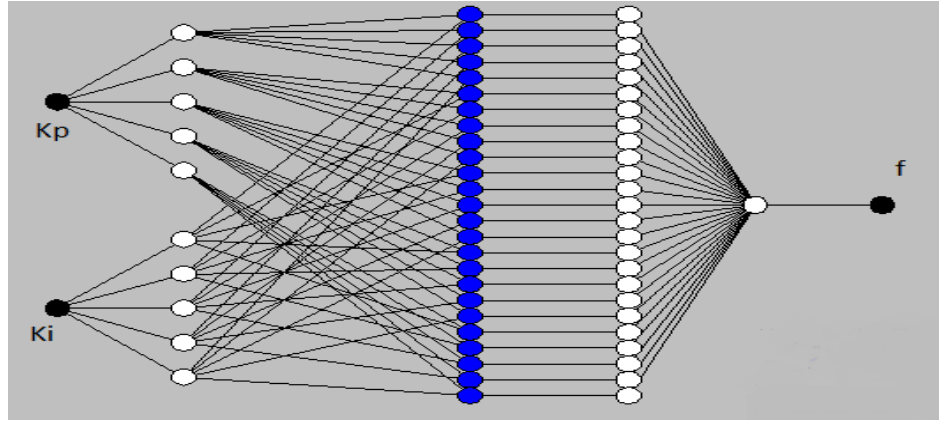


Şekil 5. $K_p=0.25$ ve $K_i=0.024$ için Motor Hızı

K_i değeri çok küçük olmasından sistem üzerinde kullanılan gerçek değerler eğitim ve test setlerinde 20 ile çarpılarak normalize edilmiştir. Böylece ANFIS ve YSA modellerinin oluşturulmasında hata minimize edilebilmektedir. Bu eğitim seti ile MATLAB toolbox ortamında ANFIS ve YSA parametreleri, kuralları ve ağırlıkları ayarlanmaktadır. Bu modellerin şematik gösterimi Şekil 6'de verilmiştir.



(a)



(b)

Şekil 6. Şematik Gösterimler. a. YSA ve b. ANFIS

Şekil 6. (a)'da görüldüğü gibi YSA yapısı iki giriş, bir gizli katman, gizli katmanda 5 nöron ve bir çıkış olacak şekilde seçilmiştir. Hatanın gerilim yayılım algoritması ile öğrenme yapılmaktadır. Şekil 6.(b)'de ise uygulamada kullanılan ANFIS yapısı görülmektedir. Bu yapıda, Sugeno tipi, girişte 5 üçgen tipi üyelik fonksiyonu, 25 kural, sabit tip çıkış ve hibrit öğrenme yöntemi kullanılmaktadır.

5. SONUÇ

Eğitim seti ile parametreleri ayarlanmış YSA ve ANFIS modellerinin başarılarını değerlendirebilmek için eğitim veri setinde olmayan 11 Kp-Ki çifti için sistem üzerinden uygunluk değerleri uygulama devresinden elde edilip test veri seti oluşturulmuştur. Aşağıdaki tabloda bu test verileri ile YSA ve ANFIS modellerinin ürettiği sonuçlar verilmiştir.

Tablo 1. Test Verileri ve ANFIS - YSA Kestirim Sonuçları

Kp Değerleri	Ki Değerleri	Sistemden Elde Edilen Gerçek Uygunluk Değeri	ANFIS Kestirimi	YSA Kestirimi
0.23	0.34	0,2250825	0,2201	0,2348
0.23	0.46	0,21584212	0,2182	0,233
0.26	0.2	0,50078839	0,429	0,3664
0.26	0.44	0,23255777	0,2308	0,2322
0.33	0.28	0,31359728	0,2182	0,2722
0.33	0.44	0,24676131	0,2399	0,2339
0.38	0.2	0,76926296	0,7748	0,6996
0.38	0.44	0,25877308	0,2556	0,2385
0.43	0.34	0,41014356	0,3508	0,3082
0.43	0.46	0,29479542	0,2746	0,2487
0.47	0.46	0,30661863	0,2908	0,2674

Bu sonuçların, R2 (regresyon doğrusundaki determinasyon katsayısı), RMSE (Root Mean Square Error-karesel ortalama hata) ve MAE (Mean Absolute Error-Ortalama Mutlak Hata) yöntemleri ile elde edilen değerleri aşağıdaki tabloda verilmiştir. Modellerin performansının başarısı, R2'de bire yakın olması, RMSE ve MAE'de sifira yakınlığı nispetindedir.

Tablo 2. Sistem Modellemede ANFIS ve YSA Performanslarının Karşılaştırılması

Model Tipi	R2		RMSE		MAE	
	Eğitim	Test	Eğitim	Test	Eğitim	Test
ANFIS	0,998778	0,957058	0,007435936	0,041071153	0,005482	0,02611
YSA	0,96118	0,937936	0,041250214	0,060036081	0,029178	0,044825

Gerek eğitim verileri gerekse test verileriyle yapılan kestirim sonuçları istatistiksel yöntemlerle değerlendirildiğinde, ANFIS modelinin ürettiği sonuçların, YSA modeliyle üretilen sonuçlara göre gerçek değere daha yakın olduğu Tablo 2'de görülmektedir. ANFIS'in YSA'na göre doğrusal olmayan ilişkileri daha başarılı şekilde benzetebilmesinden dolayı, yapılan bu çalışma ile dolaylı vektör kontrollü asenkron motor için sistem modelini elde etmede ANFIS'in daha başarılı olduğu görülmüştür.

6. TEŞEKKÜR

Yazarlar, çalışmayı destekleyen Adıyaman Üniversitesi Bilimsel Araştırma Projeleri (BAP) Koordinasyon Birimi'ne teşekkür ederler.

7. KAYNAKLAR

Bose B.K, (2002). Modern Power Electronics and AC Drives, *Prentice Hall*, N.J.

Ertunç H.M, Ocak H, Aliustaoğlu C., (2013). ANN and ANFIS based multi-staged decision algorithm for the detection and diagnosis of bearing faults, *Neural Computing and Applications*, 22(1), 435–446.

Gani A., Keçecioglu Ö.F., Açıkgoz H., Şekkeli M., (2015). Uyarlamalı bulanık PI denetim esaslı dinamik senkron kompanzator ile reaktif güç kompanzasyonu benzetim çalışması, *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 18(2), 72-76.

Gökçe B., Sonugür G., (2016). ANFIS ve YSA yöntemleri ile işlenmiş doğal taş üretim sürecinde verimlilik analizi, *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 16, 174-185.

Haykin S., (1999). Neural networks: a comprehensive foundation, *Prentice Hall*, N.J.

John W.F., Damian G., (2008). Controlled AC electric drives, *IEEE Transaction on Industrial Electronics*, 55(2), 481-491.

Kılıç E., Özçalık H.R., Şit S., (2016). Üç fazlı asenkron motor için uzay vektör darbe genişlik modülasyonu kullanan yapay sinir ağı temelli adaptif hız kontrol sistemi tasarımı, *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 19(3), 24-32.

Kılıç E., Şit S., Gani A., Şekkeli M., Özçalık H.R., (2017). Neuro-Fuzzy Based Model Reference Adaptive Control for Induction Motor Drive. *Turkish Journal of Fuzzy Systems*, 8(2), 63-72.

Krause P.C., Wasynczuk O., Sudhoff S.D., (2002). Analysis of electric machinery and drive systems, *Wiley-IEEE Press*, N.J.

Nur A., Omaç Z., Öksüztepe E., (2017). Fuzzy logic based indirect vector control of squirrel cage induction motor, *Sigma Journal of Engineering and Natural Sciences*, 8(1), 65-73.

Özdemir A., Güngör O., (2018). Güneş panellerinde hibrit ve YSA tabanlı algoritmalar ile güç takibi, *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 21(3):258-266.

Ross D., Theys J., (2005). Using the dsPIC30F for vector control of an ACIM, Microchip Technology Inc. Application Notes.

Sadati N., Kaboli S., Adeli H., Hajipour E., Ferdowsi M., (2009). Online optimal neuro-fuzzy flux controller for DTC based induction motor drives, *Applied Power Electronics Conference and Exposition*, Washington, DC, 2009, pp. 210-215.

Sun Q., Cheng M., (2005). Modeling of Doubly Salient Permanent Magnet Motor Based on ANFIS, *International Conference on Electrical Machines and Systems*, Nanjing, pp. 321-325.

Toliyat H.A., Campbell S., (2004). DSP based electromechanical motion control, *CRC press*.

Üstün S.V., Demirtaş M., (2005). Optimal tuning of PI speed controller coefficients for electric drives using neural network and genetic algorithms, *Electrical Engineering*, 87(2), 77-82.

Üstün S.V., Demirtaş M., (2009). Modeling and control of V/f controlled induction motor using Genetic-ANFIS algorithm, *Energy Conversion and Management*, 50(3), 786-791.

Wang Y., Shao H., (2000). Optimal tuning for PI controller, *Automatica*, 36, 147-152.

Yüksel O., Mehmet D., (2009). Speed estimation of vector controlled squirrel cage asynchronous motor with artificial neural network, *Elsevier Energy Conversion and Management*, 52, 675-686.