

ARMA SİSTEM MODELLEMEDE KLASİK VE YAPAY SİNİR AĞLARI ALGORİTMALARININ KARŞILAŞTIRILMASI

Şaban ÖZER¹

Şeref SAĞIROĞLU²

Hasan ZORLU³

^{1,3}Erciyes Üniversitesi, Elektronik Mühendisliği Bölümü, 38039, Melikgazi, Kayseri

² Erciyes Üniversitesi, Bilgisayar Mühendisliği Bölümü, 38039, Melikgazi-Kayseri

¹e-posta: sozer@erciyes.edu.tr

²e-posta: ss@erciyes.edu.tr

³e-posta: hzorlu@erciyes.edu.tr

Anahtar sözcükler: ARMA, Sistem modelleme, Yapay Sinir Ağları, Klasik algoritmalar, Öğrenme algoritmaları

ÖZET

Bu çalışmada, klasik algoritmalar ile farklı öğrenme algoritmalarıyla eğitilmiş yapay sinir ağı (YSA) modellerinin, lineer ARMA sistem modellemedeki performansları karşılaştırılmıştır. Simülasyonlarda 3 farklı sistem, gürültülü ve gürültüsüz durumlar için test edilmiştir. Klasik algoritmalar olarak; en küçük kareler, yinelemeli en küçük kareler, q-slice, zaman serisi ve kafes algoritmaları, YSA öğrenme algoritmaları olarak; geri-yayılım, Fletcher-Reeves eşleştirmeli gradyent, Polak-Ribiere eşleştirmeli gradyent, Powell-Beale eşleştirmeli gradyent, Broyden-Fletcher-Goldfarb-Shanno kuasi Newton, tek adım sekant kuasi Newton, Levenberg-Marquardt ve esnek yayılım, öğrenme algoritmaları kullanılmıştır. Sonuç olarak klasik metotların sistem kimliklendirmede başarılı oldukları görülmüştür. Gürültülü durumda ise klasik algoritmalar YSA'na göre daha düşük performans sergilemişlerdir. Levenberg-Marquardt öğrenme algoritması ile eğitilmiş YSA modeli 8 farklı algoritma içerisinde en başarılı eğitim algoritması bulunmuştur. Klasik metotlarda ise kafes yapısı en iyi algoritmadır.

problem için geçerli çözüm sunamamaktadır. ARMA (Autoregressive Moving Average) modeller, ses, radyo, radar ve sismoloji gibi sürekli işaretlerin, ayrık zamanlı olarak gösterilimi için kullanılırlar [3],[11]. Literatürde YSA ile sistem kimliklendirmede birçok çalışmalar mevcuttur [14-16]. Sunulan yaklaşımlarda YSA'ların genelde başarılı oldukları bildirilse de, bazı çalışmalarda farklı öğrenme algoritmalarında iyi sonuçlar alınmadığı rapor edilmiştir [15]. Bu çalışmada ARMA sistem modelleme için , en küçük kareler (Least Square-LS), yinelemeli en küçük kareler (Recursive Least Square-RLS), q-slice (QS), artık zaman serisi (Residual-R) ve kafes (Lattice-LAT) gibi klasik algoritmalar kullanılmıştır. Aynı zamanda geri-yayılım (GY), Fletcher-Reeves eşleştirmeli gradyent (FREG), Polak-Ribiere eşleştirmeli gradyent (PREG), Powell-Beale eşleştirmeli gradyent (PBEG), Broyden-Fletcher-Goldfarb-Shanno (BFGS), tek adım sekant (TAS), Levenberg-Marquardt (LM) ve esnek yayılım (EY), algoritmaları YSA'ları eğitmede kullanılan öğrenme algoritmaları olmuşlardır. Literatürde mevcut sonuçlarla karşılaştırıldığında bu çalışmada sunulan YSA modelinin literatürdeki sonuçlardan [15] çok iyi olduğu görülmüştür.

1. GİRİŞ

Sistemlerin modellenmesinde kullanılan klasik teknikler, model yapısının ve bazı istatistiki değerlerin (model derecesi, giriş ve gürültünün dağılımı v.b.) bilinmesi durumunda iyi çözümler sunarlar [1-3]. Bu bilgilerin elde edilemediği durumlarda performansta düşme yaşanmaktadır. Yapay zeka teknikleri öğrenme, genelleme yapma, kolaylıkla farklı problemlere uygulanabilme, gürültüye karşı toleransları ve hızlı işlem yapabilmelerinden dolayı farklı problemlerin çözümünde sıklıkla kullanılmaktadır [4],[5]. Bazı yapay zeka parametrelerinin sisteme bağımlı olarak doğru şekilde seçilmesi ve çeşitli deneme-yanılma işlemlerinin yapılması bu yaklaşımlarda karşılaşılan güçlüklerdir.

Literatürde sistem modelleme için kullanılan birçok algoritma ve uygulamaları mevcuttur [1-3],[6-13]. Kullanılan algoritma ve teknikler, kendine has problemleri çözmek için geliştirildiğinden dolayı, her

2. SİSTEM MODELLEME

Sistem modelleme, deneysel veya matematiksel yolla elde edilmiş verilerden faydalanarak sistemlerin modellerinin elde edilmesidir [1]. Sistem modellemede amaç, bilinmeyen bir sistemin transfer fonksiyonu adı verilen geçiş eğrisinin yani iç yapısının belirlenmesidir. Pratik uygulamalarda karşılaşılan birçok ayrık zamanlı sistemlerde, veri olarak giriş ve çıkış değerlerinin yardımıyla sistemin modellenmesi gerekir. Bu tür sistemler için ARMA modelleme yöntemleri geliştirilmiştir [1-3],[6-13]. Genel olarak bu modellerde, giriş dizisi $u[n]$ ile, çıkış dizisi ise $y[n]$ ile ifade edilir. Bu diziler arasında

$$y[n] = -\sum_{k=1}^p a_k y[n-k] + \sum_{k=0}^q b_k u[n-k] \quad (1)$$

şeklinde lineer fark denklemi yazılabilir. Burada, p AR model derecesini, q MA model derecesini belirtir, a_k ve b_k ise model parametreleridir. Burada model

parametreleri farklı yaklaşımlar kullanılarak belirlenir. Bu değerlerin aynısını elde etmek model başarımına bağlıdır.

3. KLASİK ALGORİTMALAR

Sistem modellemede sıkça kullanılan algoritmalar aşağıda kısaca özetlenmiştir.

LS algoritmasında, parametreler her iterasyonda hatayı en aza indirecek şekilde değiştirilmektedir [1]. Bu metot Gaussian dağılımlı gürültü durumunda, model parametrelerini hesaplayan metot olarak ele alınır. LS metodu, gürültü dağılımının beyaz Gaussian olması durumunda iyi tahmin yapabilmektedir [2], fakat Gaussian olmayan dağılımlarda optimal çözümünden uzaklaşmaktadır [6].

RLS algoritması, literatürde birçok alanda uygulanmaktadır [7],[8]. RLS metotları, giriş istatistiklerine daha az duyarlı bir teknik olarak bilinmektedir [1]. Gerçek zamanlı işaret işleme uygulamaları için RLS metodunun hesap yükünü azaltan hızlı algoritmalar geliştirilmiştir [8].

LAT algoritmasında, giriş ve çıkış işaretlerine ayrı ayrı AR modeli uygulanarak iki kanallı LAT yapısı elde edilmesi prensibine dayanır. Giriş ve çıkış işaretlerinin hem ileri, hem de geri hata formülleri kullanılarak model katsayıları belirlenir [1],[9],[10],[18]. Bu yapılar sonlu kesinlikli gürültüye duyarsız, modüler ve daha hızlı yakınsama sağladığı için faydalı bir metottur. Bu uygulamalarda, çok büyük sayıda LAT parametresi depolanır ve bu parametrelerin azaltılması için çalışmalar yapılmıştır [11].

QS algoritmasında, AR ve MA parametreleri ayrı ayrı hesaplanır. MA parametrelerinin tahmini için çıkış kumulantlarından yararlanılarak birçok algoritma geliştirilmiştir [12].

R algoritmasında, parametrelerin tahmini üç aşamada yapılır. Birinci aşamada AR parametreleri tahmin edilir, ikincisinde MA(q) zaman serisi oluşturulur, son aşamada ise MA parametreleri tahmin edilir [13].

4. YAPAY SİNİR AĞLARI (YSA)

YSA' lar, bir çok alanda başarıyla uygulanmaktadırlar [4],[5]. Bu ağları öğretmede bir çok algoritma kullanılmaktadır. Bir YSA temel olarak giriş, ara kat ve çıkış katı olmak üzere üç katmandan oluşmuştur ve ara katta iki saklı tabaka mevcuttur. Giriş katındaki nöronlar tampon gibi davranırlar ve giriş sinyali (x_i) ara kattaki nöronlara dağıtırlar. Ara kattaki her bir nöron j 'nin çıkışı, kendine gelen bütün giriş sinyallerini takip eden bağlantı ağırlıkları (w_{ji}) ile çarpımlarının toplanması ile elde edilir. Elde edilen bu toplam, y_j 'nin toplam bir fonksiyonu olarak

$$y_i = f(\sum w_{ji} x_i) \quad (2)$$

şeklinde ifade edilebilir. Burada f basit bir eşik fonksiyonu, bir sigmoid, hiperbolik tanjant (HT) veya

radyal tabanlı bir fonksiyon olabilir. Diğer katlardaki nöronların çıkışları da aynı şekilde hesaplanır. Literatürde, bir çok YSA öğrenme algoritması bulunmaktadır [4],[5]. Bu çalışmada kullanılan YSA öğrenme algoritmaları kısaca tanıtılmıştır. Geri yayılım (GY) algoritması; anlaşılması kolay ve matematiksel olarak gösterimi kolay olmasından dolayı en çok tercih edilen öğrenme algoritmasıdır. GY algoritması gradiyent azaltan ve YSA'ların eğitiminde en sık kullanılan algoritmadır [5]. Bu algortmada lokal minimuma takılma problemi vardır. Esnek yayılım (EY) algoritması; Türev yerine yalnızca işarete göre parametrelerin yenilenmesini sağlamak amacıyla geliştirilmiştir [5]. Broydon-Fletcher-Goldfarb-Shanno (BFGS) algoritması; Hessian matrisinin her iterasyonda yaklaşık değerinin hesaplanması esasına dayanır [5]. Fakat sınır ağırlarındaki parametre sayısı fazlalaştıkça yakınsaması uzun zaman alır. Levenberg-Marquardt (LM) algoritması, maksimum komşuluk fikrine dayanan en küçük kareler yöntemidir [5]. Tek adım sekant (TAS) algoritması, ise bir önceki iterasyondaki Hessian matrisinin birim matris olduğu varsayılır, böylece matrisin tersi alınması işlemine gerek kalmaz. Performans açısından karşılıklı türev yöntemleri ile BFGS yöntemi arasında yer alır [5]. Eşleştirmeli gradiyent algoritmaları, temel olarak üç farklı formda bulunabilir. Bunlar Fletcher-Reeves (FREG) eşleştirmeli gradiyent, Polak-Ribiere (PREG) eşleştirmeli gradiyent, Powell-Beale (PBEG) eşleştirmeli gradiyent algoritmalarıdır [5]. Basit GY algoritması ağırlık değerlerini gradiyentin negatifi yönünde dengeler. Bu doğrultu, gradiyentin hızla düştüğü doğrultu olarak bilinir. Eşleştirmeli gradiyent algoritmalarında düşüş doğrultusundan genellikle daha çabuk sonuca yakınsayan eşleştirme doğrultusunda bir arama işlemi uygulanır. Performans fonksiyonunun yakınsama doğrultusu boyunca minimize edilmesi için güncelleme adım boyutunun belirlenmesi amacıyla eşleştirmeli gradiyent doğrultusu boyunca bir arama gerçekleştirilir.

5. SİMÜLASYON SONUÇLARI

Bu çalışmada 5 klasik algoritma ve 8 farklı eğitim algoritmalarıyla eğitilmiş YSA modellerinin farklı lineer sistem modelleme performansları gürültülü ve gürültüsüz durumlar için test edilmiştir. Bu testlerde kullanılan sistemler, 2 kutubu ve 2 sıfırı bulunan ARMA(2,2) [17];

Sistem#1:

$$y(n) = 2.119u(n) - 2.791u(n-1) + 1.793u(n-2) + 1.4y(n-1) + 0.95y(n-2) \quad (3)$$

4 kutubu ve 2 sıfırı bulunan ARMA(4,2) [18];

Sistem#2

$$y(n) = u(n) + 0.433u(n-1) + 0.490u(n-2) + 2.595y(n-1) - 3.339y(n-2) + 2.2y(n-3) - 0.731y(n-4) \quad (4)$$

3 kutubu ve 3 sıfırı bulunan ARMA(3,3) [19];

Sistem#3

$$y(n) = 0.0798u(n) + 0.0791u(n-1) + 0.0791u(n-2) + 0.0798u(n-3) + 1.5558y(n-1) - 1.270y(n-2) + 0.3983y(n-3) \quad (5)$$

sistemleridir. Bu sistemlere gauss dağılımında, sıfır ortalamalı, standart sapma değeri 1 olan, 1000 adet elemana sahip giriş dizisi uygulanmış ve istenen çıkış dizisi elde edilmiştir. Bu dizinin ilk 500'ü YSA'nın eğitimi için diğer 500'ü ise sistemi test için kullanılmıştır. Sistemler, gürültülü ve gürültüsüz durumlar için test edilmiştir. Gürültü olarak yine gauss dağılımında, sıfır ortalamalı, standart sapma değeri 1 olan dizi çıkışa eklenmiştir. Bu örneklerde işaret/gürültü oranı (SNR) 20 dB'dir. YSA için ilk test sisteminde (Sistem#1) giriş olarak, sistem giriş ve çıkış dizisinin birim gecikmeli değerleri kullanılarak 4x500 boyutlarındaki matris, çıkış dizisi olarak ise sistem çıkış dizisinin ilk 500 elemanı kullanılmıştır. Buradaki YSA yapısı 4 nörondan oluşan giriş katmanı, 10 nörondan oluşan gizli katman ve 1 adet nöronun yer aldığı çıkış katmanından ibarettir. İkinci test sisteminde (Sistem#2) 6x500 boyutlarındaki giriş matrisi kullanılmış ve giriş katmanındaki nöron sayısı 6 olarak alınmıştır. Üçüncü test sisteminde (Sistem#3) ise, yine 6x500 boyutlarındaki giriş matrisi kullanılmış ve giriş katmanındaki nöron sayısı 6 olarak alınmıştır. Ara ve çıkış katmanlarındaki transfer fonksiyonları için, modellenen sistemin lineer yapıda olmasından dolayı lineer aktivasyon fonksiyonları seçilmiştir. Sistemler, farklı öğrenme algoritmaları için farklı iterasyonlarda eğitilmiş, daha sonra YSA modeli, öğrenmede kullanılmayan, sistemlerin giriş dizisinin son 500 elemanından oluşan diziyle test işlemine tabi tutulmuştur. Çıkıştan elde edilen dizi ile model çıkışı arasındaki farkın RMS (hataların karelerinin ortalamasının kökü) değerleri gürültülü ve gürültüsüz durumlar için sırasıyla Tablo 1 ve Tablo 2'de verilmiştir. Burada YSA için verilen sonuçlar test işlemi sonucu oluşan hata değerleridir.

5. DEĞERLENDİRME ve SONUÇ

Bu çalışmada, lineer sistem modellemesinde literatürde sıkça kullanılan 5 farklı klasik algoritma ile YSA modellerini eğitmede kullanılan 8 farklı öğrenme algoritmalarının performansları karşılaştırılmıştır. Bu testlerde, gürültüsüz durumlar için klasik metotların daha yüksek performans gösterdikleri ve daha düşük hesaplama zamanına sahip oldukları ve farklı test sistemlerinde farklı performans sergiledikleri görülmüştür. Genel olarak klasik algoritmalar, gürültüsüz durumlarda gerek zaman gerekse performans açısından daha uygun çözümler sunmuşlardır. Klasik algoritmalarla en yüksek performans LAT ve LS algoritmalarıyla elde edilmiştir.

Farklı öğrenme algoritmalarıyla eğitilen YSA modelleriyle gürültüsüz durum için elde edilen sonuçlar kabul edilebilir olsa da YSA'lar en iyi sonuçları gürültülü sistemlerde sağlamışlardır. YSA algoritmalarının hesaplama süresinin çok fazla olmasının sebepleri ise kullanılan öğrenme algoritmalarının yerel minimuma takılma, başlangıç arama yönünün iyi belirlenememesi, fazlaca türev ifadeleri içermeleri olarak ifade edilebilir. YSA algoritmaları içerisinde LM öğrenme algoritması hem performans hem de zaman bakımından en iyi sonuçları veren algoritma olmuştur. Genel olarak değerlendirildiğinde YSA'ların gürültülü sistemlerde daha başarılı olduğu ortaya çıkmıştır. Literatürde sunulan yaklaşımda [15] daha iyi sonuç elde edilmemesinin sebebi ise YSA öğrenme algoritma parametrelerinin iyi belirlenemediği ve sisteme doğru bir kimliklendirme yapısı uygulanamamasından dolayı olduğu düşünülmektedir. Bu çalışmada göstermiştir ki farklı öğrenme algoritmaları ile eğitilmiş YSA modellerinde elde edilen sonuçlar literatürdeki birçok çalışmayla uyumluluk içerisinde.

Tablo 1: Klasik ve YSA algoritmalarının RMS hata cinsinden modelleme performansları (Gürültüsüz durum)

Algoritmalar		Sistem#1		Sistem#2		Sistem#3		İterasyon
		RMS hata	Süre(s)	RMS hata	Süre(s)	RMS hata	Süre(s)	
Klasik	RLS	0.0054	1.8700	0.0049	2.3000	0.0002	2.2500	1000
	LS	0.0000	0.1600	0.0000	0.3800	0.0000	0.3900	1000
	LAT	0.0000	0.4900	0.0000	1.1000	0.0000	0.7100	1000
	QS	0.0775	0.9500	0.0687	1.9500	0.0028	1.8700	1000
	R	0.0206	1.3500	0.0195	2.1500	0.0012	2.0900	1000
YSA	BFGS	0.0001	100.74	0.0237	127.28	0.0054	130.52	300
	FREG	0.0052	121.77	0.1090	153.59	0.0021	153.10	750
	PBEG	0.0055	96.330	0.0500	137.74	0.0017	136.44	500
	PREG	0.0180	178.71	0.0540	202.33	0.0051	205.35	500
	GY	0.1238	235.52	0.2524	290.45	0.2220	296.97	2000
	LM	0.0048	97.120	0.0064	109.77	0.0005	114.31	200
	TAS	0.0256	95.780	0.0854	126.00	0.0023	131.13	500
	EY	0.0190	300.39	0.1786	345.74	0.0183	336.76	2000

Tablo 2: Klasik ve YSA algoritmalarının RMS hata cinsinden modelleme performansları (Gürültülü durum)

Algoritmalar		Sistem#1		Sistem#2		Sistem#3		İterasyon
		RMS hata	Süre(s)	RMS hata	Süre(s)	RMS hata	Süre(s)	
Klasik	RLS	0.1907	1.9500	0.1886	2.4900	0.1846	2.5100	1000
	LS	0.1900	0.2600	0.1875	0.5800	0.1839	0.6800	1000
	LAT	0.1896	0.6500	0.1845	1.2500	0.1822	1.1200	1000
	QS	0.2985	1.0500	0.3025	2.5300	0.4025	2.4600	1000
	R	0.2054	2.7200	0.2455	2.7500	0.2923	2.9500	1000
YSA	BFGS	0.0109	105.46	0.0573	128.79	0.0161	137.21	300
	FREG	0.0500	126.14	0.1529	158.52	0.0028	156.52	750
	PBEG	0.0624	99.240	0.0943	140.12	0.0041	138.36	500
	PREG	0.0678	181.64	0.1271	210.93	0.0074	208.96	500
	GY	0.0989	237.98	0.3250	294.15	0.2443	302.75	2000
	LM	0.0102	101.80	0.0244	109.95	0.0124	120.12	200
	TAS	0.0591	96.590	0.4273	129.16	0.0908	135.63	500
	EY	0.0894	309.23	0.6342	351.14	0.0839	338.43	2000

KAYNAKLAR

- [1] Ljung L., System Identification : Theory For The User, ENGLEWOOD CLIFFS, NJ, PRENTICE-HALL, 1987.
- [2] Mendel J. M., Lessons in Digital Estimation Theory, ENGLEWOOD CLIFFS, NJ:PRENTICE-HALL, 1987
- [3] Makhoul J., Linear Prediction: A Tutorial Review, PROC. IEEE, Vol 63, pp 561-580,1975
- [4] Haykin S., Neural Networks: A Comprehensive Foundation, MACMILLAN COLLEGE PUBLISHING COMPANY, NEW YORK, USA, ISBN 0-02-352761-7, 1994.
- [5] Hagan M.T., Demuth H.B., and M. H. Beale, Neural Network Design, BOSTON, MA: PWS PUBLISHING, 1996.
- [6] Haykin S., Advances in Spectrum Analysis and Array Processing, ENGLEWOOD CLIFFS, NJ: PRENTICE-HALL, 1991.
- [7] Lee D.T.L., Friedlander B., and Morf M., Recursive Ladder Algorithms for ARMA Modeling, IEEE TRANS. AUTOMAT. CONTR., Vol AC-27, No 4, pp 753-764,1982
- [8] Cioffi J. and Kailath T., Fast Recursive Least Squares Transversal Filters for Adaptive Processing, IEEE TRANS. ACOUST., SPEECH, SIGNAL PROCESSING, Vol ASSP-34, pp 304- 307,1984
- [9] Özer Ş., Taşpınar N., Güney K., ARMA modeli ile Ayrık Zamanlı Lineer Sistemlerin Modellenmesi, BİLKENT ÜNİ. ELEKTRİK-ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĞİ KONFERANSI BİLDİRİ KİTABI, s 195-198, 1991
- [10] Özer Ş. , Kıymık M.K., Lattice ARMA Modeli ile Lineer Sistemlerin Adaptif Modellenmesi, ELEKTRİK. MÜHENDİSLİĞİ, 5. ULUSAL KONGRESİ BİLDİRİ KİTABI, s 45-50, 1993
- [11] Lim Y.C. and Parker S.R., On The Identification Of Systems From Data Measurements Using ARMA Lattice Models, IEEE TRANS. ACOUST., SPEECH, SIGNAL PROCESSING, vol 4, pp 824-827, 1986.
- [12] Swami A. and Mendel J.M., ARMA Parameter Estimation Using Only Output Cumulants, IEEE TRANS. ACOUST., SPEECH, SIGNAL PROCESSING, vol 38, pp 1257-1265, 1990.
- [13] Giannakis G.B. and Mendel J.M., Identification Of Non-Minimum Phase Systems Using Higher-Order Statistics, IEEE TRANS. ACOUST., SPEECH, SIGNAL PROCESSING, vol 37, pp 360-77, 1989.
- [14] Sağiroğlu Ş., Özer Ş. A Neural Identifier for Linear Dynamic Sysytems, JOURNAL OF POLYTECHNIC, vol 4, no 3, pp 55-61, 2001
- [15] Özer Ş., Sağiroğlu Ş., Kaplan A., Performance Analysis of Algorithms on Linear ARMA Models, PROC. OF THE INT. SYMPOSIUM COMPUTER AND INFORMATION SCİENCE XVI, pp 445-451,2001
- [16] Narendra K. S., Parthasarathy K., Identification and control of dynamical systems using neural Networks IEEE TRANS. On NEURAL NETWORKS, vol 1 pp 4-27, 1990
- [17] Friedlander B. and Porat B., A Spectral Matching Technique for ARMA Parameter Estimation, IEEE TRANS. ACOUST., SPEECH, SIGNAL PROCESSING, vol 32, pp 338-342, 1984
- [18] Li S. and Dickinson B.W., Application of the Lattice Filter to Robust Estimation of AR and ARMA Models, IEEE TRANS. ACOUST., SPEECH, SIGNAL PROCESSING, vol 36, pp 502-512, 1988
- [19] Kalliojarvi K. and Astola J., Roundoff Errors in Block-Floating-Point Systems, IEEE TRANS. on SIGNAL PRO., vol 44, pp 783-790,1996