

# DOĞRUSAL OLMAYAN PAR SİSTEMLER KULLANILARAK KAOTİK ZAMAN SERİSİ KESTİRİMİ

**Şaban ÖZER, Hasan ZORLU**

Erciyes Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 38030, Melikgazi,  
KAYSERİ

[sozer@ercives.edu.tr](mailto:sozer@ercives.edu.tr), [hzorlu@ercives.edu.tr](mailto:hzorlu@ercives.edu.tr)

(Geliş/Received: 21.12.2010; Kabul/Accepted: 31.01.2012)

## ÖZET

Bu çalışmada kaotik zaman serilerinin kestirimi için doğrusal olmayan polinomsal özbağlanım (polynomial autoregressive – PAR) sistemler kullanılmıştır. Bu amaçla literatürde yer alan Mackey-Glass ve Lorenz kaotik sistemlerine ait zaman serilerinin kestirimi için doğrusal olmayan PAR zaman serilerine dayalı çeşitli matematiksel model yapıları sunulmuştur. Sunulan modellerdeki parametre değerlerinin belirlenmesi amacıyla sezgisel algoritmaların genetik algoritma (GA), diferansiyel gelişim algoritması (DGA) ve klonal seçme algoritması (KSA), klasik algoritmalar ise içsel en küçük kareler (recursive least square-RLS) algoritması uyarlanır algoritmalar olarak kullanılmış ve başarımları karşılaştırılmıştır. Benzetim sonuçlarına göre hem kaotik sistemler için sunulan matematiksel model yapıları hem de bu model yapılarına ait parametrelerin belirlenmesi için farklı algoritmalarla yapılan optimizasyon işlemleri oldukça başarılı olmuştur.

**Anahtar Kelimeler:** Kaotik zaman serisi kestirimi, Kaotik sistemler, PAR sistem, Esnek Hesaplama Algoritmaları.

## CHAOTIC TIME SERIES PREDICTION USING THE NONLINEAR PAR SYSTEMS

## ABSTRACT

In this work, the nonlinear polynomial autoregressive (PAR) system has been applied to predict chaotic time series. For this purpose, different mathematical model structures based on nonlinear PAR time series have been presented to prediction of Mackey-Glass and Lorenz chaotic time series. As adaptive algorithms, Genetic algorithm (GA), differential evolution algorithm (DEA) and clonal selection algorithm (CSA) in heuristic algorithms, recursive least square algorithm (RLS) in classic algorithms have been used to determine the parameter values in the presented models and compared its performances. The simulation results have shown that both the presented mathematical models for chaotic systems and optimization works using the different algorithms to determine the parameters of these model structures have been highly successful.

**Key Words:** Chaotic time series prediction, Chaotic systems, PAR system, Soft Computing Algorithms.

## 1. GİRİŞ (INTRODUCTION)

Herhangi bir sistemin modellenmesi işleminde, deneysel veya matematiksel yolla elde edilmiş verilerden faydalananarak sistemlerin iç yapısının belirlenmesi amaçlanmaktadır. Sistemin etkin bir şekilde kontrol edilebilmesi, çıkış değeri hakkında her zaman bilgi sahibi olunabilmesi ve geliştirilebilmesi açısından sistem modelinin ve tahmin edilen modele ait parametre değerlerinin mümkün olan en az hata ile belirlenmesi gereklidir [1]. Sistemlerin matematiksel modellerinin önemi bugün mühendislikteki tüm tasarımlarda hızla artmaktadır. Modelleme işlemi,

kağıt, demir, cam veya kimyasal birleşim üretimi gibi, endüstriyel ve kontrol alanlarında, tahmin, veri haberleşmesi, ses işaretleri işleme, radar, sonar, elektrokardiyogram analizi, kanal denkleştirme, yanık bastırımı ve adaptif gürültü bastırımı gibi, işaret işleme ve haberleşme alanlarında kullanılmaktır olup biyoloji, ekoloji ve ekonomi gibi alanlarda da kullanılmaktadır [1].


Sistem modelleme işlemi için doğrusal ve doğrusal olmayan modelleme yöntemleri kullanılmaktadır [1-26]. Sistemin giriş-çıkış ilişkisinin doğrusal eşitliklerle ifade edildiği doğrusal modelleme, teorik

altyapısının gelişmiş olmasından dolayı yaygın bir şekilde kullanılmaktadır [1–5]. Hâlbuki gerçek hayatı karşılaşılan birçok sistem doğrusal olmayan davranışlara sahiptir. Bu tür sistemlerin kimliklendirilmesinde doğrusal modelleme yöntemleri yetersiz kalmakta ve doğrusal olmayan modelleme yöntemlerinin kullanılması gerekmektedir [10–21]. Doğrusal olmayan modellemede, sistemin giriş-çıkış ilişkisi, diferansiyel denklemler, üstel ve logaritmik fonksiyonlar gibi doğrusal olmayan matematiksel ifadelerlerle sağlanır. Doğrusal sistem modelleme yöntemlerinin doğrusal olmayan sistemlerin modellenmesinde genel bir çözüm oluşturmadığı anlaşılmış ve doğrusal olmayan zaman serileri olarak volterra, bilineer ve polinomsal özbağlanım (polynomial autoregressive -PAR) modeller geliştirilmiştir [22–26]. PAR modeller, robot hata algılama [25], görüntü iyileştirme, biyomedikal işaretlerin işlenmesinde [26], kaotik sistemlerin modellenmesinde gibi bilimsel alanlarda yaygın bir şekilde kullanılmaktadır. Kalp hızı dinamiklerinin analizinde doğrusal polinomsal modeller kullanılmaktadır. Ancak yakın zamanlarda kalp hızı dinamiklerinin doğrusal olmadığı ve kaotik olabileceği kabul edilmiştir [26]. Volterra ve bilineer modeller limit saykollar ve kaos gibi zengin dinamikler sergileyemediklerinden dolayı yüksek dinamik yapıya sahip olan sistemlerin modellenmesinde hem volterra hem de bilineer model yetersiz kalır. Polinomsal ardisılık yapısından dolayı PAR modelin kararsız yapısı kaotik davranışa sebep olur. Bu nedenle yüksek yapılı dinamik sistemlere örnek olarak kaotik davranış gösteren sistemler verilebilir. Böyle sistemlerin modellenmesinde doğrusal olmayan zaman serisi olarak PAR modeli önerilmiştir [19]. PAR modelinde çıkış işaretini

$$y_n = \sum_{i=1}^N a_i y_{n-i} + \sum_{i=1}^N \sum_{j=1}^N b_{i,j} y_{n-i} y_{n-j} + \sum_{i=1}^N \sum_{j=1}^N \sum_{k=1}^N c_{i,j,k} y_{n-i} y_{n-j} y_{n-k}$$

denklemiyle elde edilir. Bu denklemde  $a$ ,  $b$  ve  $c$  model parametreleridir. Döngüsel yapısından dolayı, modelin kararsız olma eğilimi vardır [20]. Bu durum modelin kaotik davranış göstermesine sebep olur [21]. PAR modelleri, işaretlerin çeşitli doğrusal olmama üretme mekanizmalarını modellemek için yeterlidir. Özellikle sınırlı gürültü destekli PAR modeller stasyoner verileri modellemede kullanılmışlardır.

Zaman serisi tahmini işlemi sistem modellemenin uygulama alanları arasında yer almaktak ve birçok alanda başarıyla uygulanmaktadır [1]. Uyarlanır zaman serisi tahmini işlemine ait blok diyagram Şekil 1' de verilmektedir. Burada görüldüğü gibi çıkış dizisinin  $n$ . elemanı olan  $y(n)$ 'nin değerini, daha önceki elde edilen dizi değerlerini ( $y(n-1)$ ,  $y(n-2)$ , ...) kullanarak belirlenmektedir.



Şekil 1. Zaman Serisi Tahmini için Blok Diyagram (Block Diagram for Time Series Prediction)

Şekil 1'deki blok diyagram ele alındığında bilinmeyen bir sistemin zaman serilerinin tahmini için ortaya atılan modellerdeki parametre tahmini, adaptasyon algoritmaları yardımıyla yapılmaktadır. Uyarlanır modelleme olarak isimlendirilen bu işlem, model parametrelerini, hatayi sıfır yapacak şekilde ayarlamak için kullanılır [22–24]. Bu işlemdeki temel yaklaşım, modellenecek sistem parametrelerinin elde edilmesi aşamasında, her bir iterasyon sonucunda oluşan hata değerinin minimize edilmesi için model parametrelerini belirli bir şekilde değiştirmektir. Hata değerinin minimuma indirilmesi için klasik ve yapay zeka tekniklerine dayalı farklı yapıtlarda algoritmalar kullanılmaktadır [27–37]. Literatürde klasik teknikler olarak adlandırılan algoritmalar, model yapısının ve bazı istatistikî değerlerin (model derecesi, giriş ve gürültünün dağılımı v.b.) bilinmesi durumunda iyi çözümler sunarlar [27]. Bu bilgilerin elde edilemediği durumlarda performansta düşme yaşanmaktadır. Klasik teknikler, düşük donanım maliyeti, yakınsak olması, hata analizinin yapılabilmesi gibi özelliklerinden dolayı en fazla kullanılan yöntemlerdir. Son yıllarda ise doğrusal ve doğrusal olmayan sistemlerin modellenmesinde yapay zekâya dayalı yöntemlerin kullanılmaya başlaması modelleme uygulamalarına farklı bir bakış açısı getirmiştir [28–37]. Yapay zeka tekniklerinde model yapısının bilinmesi zorunluluğu ortadan kalkmaktadır, fakat bu yöntemlerde de bazı iç parametrelerin sisteme bağımlı olarak doğru şekilde seçilmesi ve çeşitli deneme-yanılma işlemlerinin yapılması gerekmektedir. Yapay zeka teknikleri arasında yer alan, sezgisel nitelik taşıyan ve evrim (evolution) prensibine dayalı algoritmala ilgi oldukça artmış ve sistemlerin modellenmesinde sıkılıkla kullanılmaya başlamıştır [31–37]. Bu algoritmalar, özellikle parametre optimizasyon problemlerini çözmek için geliştirilmiştir. Bu sezgisel algoritmalar örnek olarak genetik algoritma, evrimsel programlama, genetik programlama, klonal seçme algoritması, yapay bağışıklık algoritması, tabu araştırma algoritması, diferansiyel gelişim algoritması, parçacık sürü optimizasyonu ve evrimsel gelişime dayalı çeşitli araştırma algoritmaları sayılabilir [38–47]. Ayrıca

literatürde bu yöntemlerin çeşitli özelliklerini birlikte kullanan melez yöntemlerde bulunmaktadır [48, 49].

Bu çalışmada doğrusal olmayan davranış sergileyen polinomsal özbağlanım (polynomial autoregressive – PAR) sistemler yardımıyla kaotik zaman serilerinin kestirimi işlemi gerçekleştirilmiştir. Bu amaçla literatürde yer alan kaotik sistemlerden Mackey-Glass ve Lorenz kaotik sistemleri için PAR sistem tabanlı çeşitli matematiksel model yapıları sunulmuş ve bu yapıların parametre değerleri farklı algoritmalarla elde edilmeye çalışılmıştır. Sunulan modellerdeki parametre değerlerinin belirlenmesi amacıyla sezgisel algoritmaların genetik algoritma (GA), diferansiyel gelişim algoritması (DGA) ve klonal seçme algoritması (KSA), klasik algoritmaların ise içsel en küçük kareler (recursive least square-RLS) algoritması kullanılmış olup bu algoritmaların modelleme ve tahmin işlemindeki başarıları karşılaştırılmıştır.

## 2. ALGORİTMALAR (ALGORITHMS)

Bu çalışma kapsamında kaotik zaman serilerinin tahmini için sunulan modellerdeki parametre değerlerinin belirlenmesini sağlayan uyarlanır algoritmaların birisi olan RLS algoritması model parametrelerini her iterasyonda hatayı en az indirecek şekilde değiştirmektedir [2]. Model parametreleri, arzu edilen çıkış ile sistem çıkışı arasındaki farkı minimize edecek şekilde her iterasyonda bir önceki hata ve çıkış değerlerinden faydalananarak hesaplanır [2]. Bu çalışmada kullanılan diğer uyarlanır algoritmalar ise evrim (evolution) prensibine dayalı olarak çalışmaktadır. [50]. Son zamanlarda bu prensibe dayanan tekniklerin hepsini temsilen ortak bir terim olarak evrimsel hesaplama terimi yaygın olarak kullanılmaya başlanmıştır. Bu sınıfa giren algoritmalar örnek olarak genetik algoritma, evrimsel programlama, genetik programlama, klonal seçme algoritması, yapay bağışıklık algoritması ve diferansiyel gelişim algoritması sayılabilir. Ayrıca literatürde bu yöntemlerin çeşitli özelliklerini birlikte kullanan melez yöntemlerde bulunmaktadır. Bir evrimsel algoritmanın temel adımları aşağıda verilmiştir.

<p>Başlangıç popülasyonunu oluştur Değerlendir</p> <p><b>Aşağıdaki adımları durma kriteri sağlanıncaya kadar tekrarla</b></p> <p><b>Adım 1:</b> Önceki popülasyonda bulunan bireylere seçme işlemi uygulayarak yeni popülasyon oluştur.</p> <p><b>Adım 2:</b> Yeni popülasyonu değiştir</p> <p><b>Adım 3:</b> Değiştirilmiş yeni popülasyonu değerlendir</p>
--

Evrimsel heseplama teknikleri arasında oldukça benzerlikler olmasına rağmen bir çok farklılıklar mevcuttur. Evrimsel stratejiler, özellikle parametre optimizasyon problemlerini çözmek için geliştirilmiştir. Evrimsel stratejilerden olan **genetik algoritma (GA)** [51] fikri J. Holland'a aittir. GA, yönlendirilmiş rasgele araştırma algoritmalarının bir türüdür. Tabii seçme (seleksiyon) ile canlılarda bulunan genetik gelişimin benzetişimini gerçekleştirmektedir. Temel bir GA seleksiyon operatörü, çaprazlama operatörü ve mutasyon operatörünü ihtiya etmektedir. Paralel yapısından dolayı GA, geniş araştırma uzayını etkin bir şekilde araştırabilir ve operatörleri içerisinde geçiş kurallarını uygular. Bununla birlikte standart bir GA yerel araştırma yeteneklerinin yeterli olmaması ve erken yakınsama gibi dezavantajlara sahiptir. Bu dezavantajların giderilmesi için Storn ve Price tarafından **diferansiyel gelişim algoritması (DGA)** önerilmiştir. DGA basit ama güçlü popülasyon tabanlı bir algoritmadır. DGA, özellikle nümerik optimizasyon problemlerinin çözümü için geliştirilmiş ve yeni çözümlerin üretilmesinde çözümler arasındaki farklardan faydalanan oldukça yeni bir algoritmadır [43, 50]. DGA popülasyon tabanlı bir algoritma olup yerel yakınsama hızlarının çok yüksek olması, az sayıda kontrol parametresi kullanması ve çok modlu bir araştırma uzayındaki evrensel minimumu bulabilme kabiliyetleri gibi avantajlara sahiptir. DGA ve GA'nın sistem modelleme problemine uygulanması ile ilgili literatürde çalışmalar bulunmaktadır [32-37]. Diğer bir gelişime dayalı evrimsel optimizasyon algoritması insanın bağışıklık sisteminden esinlenerek modellenen **klonal seçme algoritması (KSA)**. Basit yapısı, her türlü probleme kolaylıkla uygulanabilirliği, parametrelere çok fazla bağımlı olmaması ve yüksek yakınsama hızı sayesinde pek çok mühendislik probleminin çözümünde kullanılmaktadır [52-54]. Klonal seçme algoritması [55], temel olarak antijen uyarlarına karşı bağışıklık cevabının temel özelliklerini açıklamak için kullanılır. Bu prensibe göre sadece antijenleri tanıyan hücreler çoğalmak üzere seçilir. Seçilen bu hücreler, seçici antijenlere olan benzerliklerini artırmak için benzerlik olgunlaşması işlemine (affinity maturation process) tabi tutulur. Vücutta bir antijen tespit edildiği zaman bu antijenler kemik iliğinden üretilen antikorlarla karşılaşırlar. Antijen, antikorlara bağlanır ve T yardımcı hücrelerinden aldığı sinyalle B hücrelerini, bölünmeleri ve plazma hücreleri denilen antikor salgılayan hücrelere dönüşmesi için uyarır. Hücre bölünmesi süreci bir klon oluşturur, tek bir hücreden bir hücre veya hücreler kümesi oluşturulabilir. Klonal seçim mekanizması, negatif seçimin rolünü tamamlayıcı olarak, bir "nonsel" hücre, bir "B" hücresi tarafından tanındığı zaman nasıl bir bağışıklık tepkisi vereceğini açıklamak için kullanılmaktadır.

### 3. BENZETİM ÇALIŞMALARI (SIMULATIONS)

Bu çalışmada yüksek dinamik yapıya sahip kaotik davranış gösteren sistemlerden Mackey-Glass ve Lorenz kaotik sistemlerine ait zaman serilerinin tahmini doğrusal olmayan PAR sistemler kullanılarak yapılmıştır. Bu amaçla kaotik sistemler için PAR sistem tabanlı matematiksel model yapıları sunulmuş ve bu yapıların parametre değerleri farklı uyarlanır algoritmalarla elde edilmiştir.

#### 3.1. Örnek Problem 1: Lorenz Sistemi (Example Problem 1: Lorenz System)

Yapılan bu örnek çalışmada zaman serisi tahmini işlemine ait blok diyagram (Şekil 1) göz önüne alındığında bilinmeyen sistem olarak doğrusal olmayan kaotik salınımalar üreten matematiksel ifadesi Denklem 1'de verilen Lorenz sistemi [56] seçilmiştir. Bu sistemin tahminini yapmak üzere ise matematiksel ifadesi Denklem 2'de verilen PAR model seçilmiştir. Lorenz kaotik sistemi, 40 yıl kadar önce Lorenz tarafından, iki boyutlu akışkan konveksiyon için bir model olarak sunulmuştur [56, 57]. Lorenz sistemi;

$$\begin{aligned}\frac{dx_1(t)}{dt} &= \sigma[x_2(t) - x_1(t)] \\ \frac{dx_2(t)}{dt} &= x_1(t)[r - x_3(t)] - x_2(t) \\ \frac{dx_3(t)}{dt} &= x_1(t)x_2(t) - bx_3(t)\end{aligned}\quad (1)$$

denklemi ile ifade edilir [56]. Burada;  $\sigma$ ,  $b$  ve  $r$  durum değişkenleridir. Sistemin karakteristik özelliği, spektrumu geniş bir frekans bölgesine yayılmış


periyodik olmayan salınımalar üretmesidir. Sistemin kaotik davranış sergilediği parametre değerleri  $\sigma=10$ ,  $b=8/3$  ve  $r=28$  şeklindedir.

$$y_m(n) = a_1 y(n-1) + a_2 y(n-2) + a_3 y(n-3) + b_{1,1} y^2(n-1) + b_{2,2} y^2(n-2) \quad (2)$$


Bu çalışmada Denklem 2'de sunulan PAR model ile Lorenz sisteminin bir adım sonraki durumu tahmin edilmeye çalışılmıştır. Önerilen PAR modele ait parametreler GA, DGA, KSA ve RLS algoritmaları tarafından bulunmuştur. Benzetim çalışmalarında tahmin edilecek zaman serisi olarak Lorenz sistemindeki 1. dinamik  $\{x_1(t)\}$  kullanılmıştır ve Şekil 2'de verilmiştir. Bu çalışmada kullanılan PAR modelin eğitimi esnasında bu zaman serisinin ilk 200 verisi kullanılmış olup sonraki 800 veri ise test işleminde kullanılmıştır. Önerilen PAR modele ait parametreler, model çıkışı  $\{y_m(n)\}$  ile Lorenz sisteminde 1.dinamikteki kaotik zaman serisine ait  $\{x_1(t)\}$  çıkış arasındaki hata minimize edilinceye kadar uyarlanır algoritmalar tarafından optimize edilmiştir. Optimizasyonlar sonucunda oluşan parametre değerleri Tablo 1'de verilmiştir. Bununla birlikte Lorenz sisteminde 1.dinamikteki kaotik zaman serisine ait  $\{x_1(t)\}$  çıkış ile model çıkışı arasındaki farkın MSE değerleri ise yine aynı tabloda verilmiştir. Ayrıca uyarlanır algoritmaların başarılardının karşılaştırılması için farklı algoritmalarla optimize edilen önerilen model çıkışında elde edilen zaman serileri ile gerçek kaotik zaman serisi grafiksel olarak Şekil 3, 4, 5 ve 6'da verilmiştir.

**Tablo 1.** Lorenz Sisteminin Tahminine Yönelik Önerilen Modele ait Parametre ve MSE Değerleri  
(The Parameter and MSE Values the Proposed Model for Lorenz System Prediction)


Algoritmalar	Parametreler					MSE	İterasyon	Süre (s)
	a <sub>1</sub>	a <sub>2</sub>	a <sub>3</sub>	b <sub>1,1</sub>	b <sub>2,2</sub>			
<b>KSA</b>	1,9990	-1,2810	0,2461	0,0000	-0,0002	0,5734	1000	286,7
<b>DGA</b>	2,4115	-2,0760	0,6478	0,0002	-0,0003	0,4391	1000	132,2
<b>GA</b>	2,4254	-2,1050	0,6635	0,0001	-0,0002	0,4393	1000	124,2
<b>RLS</b>	2,3340	-1,6120	0,3080	0,0090	-0,0040	1,184	1	0,18




**Şekil 2.** Lorenz Sisteminde 1. Dinamiğe  $\{x_1(t)\}$  ait Zaman Serisi  
(The First Dynamic Time Series  $\{x_1(t)\}$  of Lorenz System)




**Şekil 5.** Lorenz Zaman Serisi ve GA Algoritması Yardımıyla Optimize Edilen PAR Model ile Tahmin Edilen Zaman Serisi  
(Lorenz Time Series and the Time Series Predicted by PAR Model Optimized using GA)



**Şekil 3.** Lorenz Zaman Serisi ve KSA Algoritması Yardımıyla Optimize Edilen PAR Model ile Tahmin Edilen Zaman Serisi  
(Lorenz Time Series and the Time Series Predicted by PAR Model Optimized using KSA)



**Şekil 6.** Lorenz Zaman Serisi ve RLS Algoritması Yardımıyla Optimize Edilen PAR Model ile Tahmin Edilen Zaman Serisi  
(Lorenz Time Series and the Time Series Predicted by PAR Model Optimized using RLS Algorithm)



**Şekil 4.** Lorenz Zaman Serisi ve DGA Algoritması Yardımıyla Optimize Edilen PAR Model ile Tahmin Edilen Zaman Serisi  
(Lorenz Time Series and the Time Series Predicted by PAR Model Optimized using DGA)

### 3.2. Örnek Problem 2: Mackey-Glass Sistemi

(Example Problem 1: Mackey-Glass System)

PAR model yardımıyla yapılan tahmin işlemine yönelik olarak yapılan bu örnek çalışmada literatürde sıkılıkla kullanılan doğrusal olmayan Mackey-Glass kaotik zaman serisi ele alınmıştır [58-60]. Mackey-Glass zaman serisine ait matematiksel ifade Denklem 3'deki gibidir. Burada  $\tau > 17$  seçildiğinde kaotik zaman serisi oluşmaktadır.


$$\frac{dy(t)}{dt} = \frac{0.2y(t-\tau)}{1+y^{10}(t-\tau)} - 0.2y(t) \quad (3)$$

Literatürde yapılan çalışmalar baz alındığında  $y(t+6)$  zaman serisinin,  $y(t)$ ,  $y(t-6)$ ,  $y(t-12)$  ve  $y(t-18)$  zaman serilerinden, tahmini yapılmaya çalışılmıştır. Bu durum göz önüne alınarak Mackey-Glass zaman serilerinin tahmini için önerilen PAR modele ait


matematiksel ifade Denklem 4' de verilmiştir. Sunulan PAR model ile Mackey-Glass zaman serisinin altı adım sonraki durumu tahmin edilmeye çalışılmıştır.

$$\begin{aligned} y_m(n+6) = & a_1 y(n) + a_6 y(n-6) + a_{12} y(n-12) + a_{18} y(n-18) + \\ & b_{1,1} y^2(n) + b_{6,6} y^2(n-6) + b_{12,12} y^2(n-12) + b_{18,18} y^2(n-18) + \\ & b_{1,6} y(n)y(n-6) + b_{1,12} y(n)y(n-12) + b_{1,18} y(n)y(n-18) + \\ & b_{6,12} y(n-6)y(n-12) + b_{6,18} y(n-6)y(n-18) + \\ & b_{12,18} y(n-12)y(n-18) \end{aligned} \quad (4)$$

Yapılan benzetim çalışmalarında kullanılan Mackey-Glass sistemine ait zaman serisi grafiksel olarak Şekil 7'de verilmiştir. Bu çalışmalar esnasında kullanılan PAR modelin eğitimi esnasında bu zaman serisinin ilk 200 verisi kullanılmış olup sonraki 800 veri ise test işleminde kullanılmıştır. Önerilen PAR model parametreleri, model çıkışı ile Mackey-Glass zaman serisi arasındaki hata minimize edilinceye kadar KSA, DGA, GA, ve RLS tarafından optimize edilmiştir. Optimizasyonlar sonucunda oluşan parametre değerleri Tablo 2'de verilmiştir. Bununla birlikte Mackey-Glass sistem çıkışı ile model çıkışı arasındaki farkın MSE değerleri yine aynı tabloda verilmiştir. Uyarlanır algoritmaların başarılarının karşılaştırılması için önerilen model çıkışında elde edilen zaman serileri ile gerçek zaman serileri grafiksel olarak Şekil 8, 9, 10 ve 11'de verilmiştir. Ayrıca literatürdeki çalışmalarla kıyas edilebilmesi için Mackey-Glass sistem çıkışı ile model çıkışı arasındaki farkın ortalama karekök hata (Root Mean Square Error-RMS) değerleri Tablo 3'de verilmiştir.




**Şekil 7.** Mackey-Glass sistemine ait zaman serisi  
(Time Series of Mackey-Glass System)



**Şekil 8.** Mackey-Glass Zaman Serisi ve KSA Algoritması Yardımıyla Optimize Edilen PAR Model ile Tahmin Edilen Zaman Serisi  
(Mackey-Glass Time Series and the Time Series Predicted by PAR Model Optimized using KSA)


**Tablo 2.** Mackey-Glass sisteminin tahminine yönelik önerilen modele ait parametre ve MSE değerleri  
(The Parameter and MSE Values the Proposed Model for Mackey-Glass Prediction)

Parametreler	Algoritmalar			
	KSA	DGA	GA	RLS
$a_1$	1,9958	4,4524	1,4493	3,5027
$a_6$	1,9375	-1,590	0,8829	-0,2018
$a_{12}$	-0,5000	-1,006	-0,6076	-0,1386
$a_{18}$	-1,1250	1,1934	0,3998	-0,4033
$b_{1,1}$	-1,0312	-4,5365	-0,6574	-2,8479
$b_{6,6}$	1,2500	-8,1855	-0,9526	-2,4578
$b_{12,12}$	2,000	-6,8551	1,0582	-0,8110
$b_{18,18}$	1,2812	-2,3658	0,6458	0,0476
$b_{1,6}$	-0,9062	9,6268	0,8604	3,8650
$b_{1,12}$	-0,2510	-7,3777	-0,8053	-3,0098
$b_{1,18}$	1,5156	2,0368	0,4183	1,2710
$b_{6,12}$	-1,8828	15,1749	0,8115	3,8640
$b_{6,18}$	-2,0000	4,4524	-1,243	-2,879
$b_{12,18}$	-1,3750	-1,590	-1,349	1,1351
<b>MSE</b>	0,0085	0,0038	0,0081	0,0056
<b>İterasyon</b>	1000	1000	1000	1
<b>Süre (s)</b>	253,8	255,3	90,15	0,21




**Şekil 9.** Mackey-Glass Zaman Serisi ve DGA Algoritması Yardımıyla Optimize Edilen PAR Model ile Tahmin Edilen Zaman Serisi

(Mackey-Glass Time Series and the Time Series Predicted by PAR Model Optimized using DGA)



**Şekil 10.** Mackey-Glass Zaman Serisi ve GA Algoritması Yardımıyla Optimize Edilen PAR Model ile Tahmin Edilen Zaman Serisi

(Mackey-Glass Time Series and the Time Series Predicted by PAR Model Optimized using GA)



**Şekil 11.** Mackey-Glass Zaman Serisi ve RLS Algoritması Yardımıyla Optimize Edilen PAR Model ile Tahmin Edilen Zaman Serisi

(Mackey-Glass Time Series and the Time Series Predicted by PAR Model Optimized using RLS)

**Tablo 3.** Mackey-Glass sistemi için literatürde yer alan çalışmalarla önerilen modelin RMS değerleri açısından karşılaştırılması

(The Comparison of the Proposed Model with Other Models presented in Literature in terms of RMS for Mackey-Glass System)

Referans çalışma	RMS
Autoregressive model [58]	0,1900
Linear Prediction Method [58]	0,5500
Wang model [59 ]	0,0907
Classical RBF [60]	0,0114
KSA (Önerilen)	0,0922
DGA (Önerilen)	0,0616
GA (Önerilen)	0,0900
RLS (Önerilen)	0,0748

PAR model yardımıyla literatürde kıyaslama problemlerinde sıkılıkla kullanılan Mackey-Glass ve Lorenz kaotik sistem davranışlarının tahmin edilmesine yönelik yapılan çalışmalar incelendiğinde sunulan PAR modellerin tahmin işleminde [60] nolu kaynak hariç başarılı oldukları tespit edilmiştir. Sunulan modellerin parametreleri uyarlanır algoritmalar yardımıyla tahmin edilmeye çalışılmıştır. Tablo 1, 2 ve 3 incelendiğinde uyarlanır algoritmaların farklı parametreler elde ettiği gözlemlenmiş ve hata değerleri açısından yakın sonuçlar vermişlerdir. Sezgisel algoritmalar hesaplama süresi ve karmaşalık açısından değerlendirildiğinde GA algoritması diğer sezgisel algoritmalarдан daha kısa sürede sonuca ulaşmıştır. Ancak hesaplama doğruluğu açısından DGA en başarılı algoritma olarak dikkat çekmektedir.

#### 4. SONUÇLAR (RESULTS)

Bu çalışmada Lorenz ve Mackey-Glass kaotik sistemlerine ait zaman serilerinin tahmini için doğrusal olmayan PAR sistemlere dayalı çeşitli matematiksel model yapıları sunulmuştur. Sunulan modellerdeki parametre değerleri genetik algoritma (GA), diferansiyel gelişim algoritması (DGA), klonal seçme algoritması (KSA) ve içsel en küçük kareler (recursive least square-RLS) algoritması ile tespit edilmiştir ve birbirlerine göre başarıları karşılaştırılmıştır. Benzetim sonuçlarına göre hem kaotik sistemler için sunulan matematiksel model yapıları hem de bu model yapılarına ait parametrelerin belirlenmesi için farklı algoritmalarla yapılan optimizasyon işlemleri oldukça başarılı olmuştur. Yapılan parametre optimizasyonu işlemlerinde, optimizasyon algoritmaları hata değerleri açısından yakın sonuçlar vermiş olmakla beraber DGA en başarılı algoritma olarak tespit edilmiştir. Kaotik sistemlere ait zaman serilerinin tahmini işleminde doğrusal olmayan PAR sistemlere dayalı matematiksel model yapılarının başarıyla kullanılabileceği görülmüştür.

#### 4. KAYNAKLAR (REFERENCES)

1. Ljung, L., **System Identification: Theory For The User**, Englewood Cliffs, NJ, Prentice Hall, 1987
2. Gauss, K. F., **Theory of the Motion of Heavenly Bodies**, Dover, 1963.
3. Zadeh, L.A., "From Circuit Theory to System Theory", **Proc IRE**, 50, 856-865, 1962.
4. Töderstrom S., **System Identification**, Prentice-Hall, 1989.
5. Ljung L., Söderström T., **Theory and Practice Of Recursive Identification**, Cambridge, MA, MIT Press, 1983.
6. Makhoul, J., "Linear Prediction: A Tutorial Review", **Proc. IEEE**, Cilt 63, 561-580, 1975.
7. Lim, Y.C., Parker, S.R., "On The Identification Of Systems From Data Measurements Using ARMA Lattice Models", **IEEE TRANS. ASSP**, Cilt 4, 824-827, 1986.
8. Özer, Ş., Taşpinar, N., Güney, K., "ARMA modeli ile Ayrik Zamanlı Lineer Sistemlerin Modellemesi", **Bilkent Üni. Elektrik-Elektronik ve Bilgisayar Mühendisliği Konferansı Bildiri kitabı**, 195-198, 1991.
9. Özer, Ş., Sağıroğlu, Ş., "Kaplan, A., Performance Analysis of Algorithms on Linear ARMA Models", **Proc. Of the Int. Symposium Computer and Information Science XVI**, 445-451, 2001.
10. Widrow, B., Stearns, D., **Adaptive Signal Processing**, Prentice Hall, 1985.
11. Honig, H.L., Messerschmitt, D.G., **Adaptive Filters Structures, Algorithms and applications**, Kluwer Academic Publishers, 1984
12. Isidori A., "Nonlinear Control Systems: An Introduction", **Lecture Notes in Control An Information Science**, Cilt 72, Springer-Verlag, Berlin, 1985.
13. Prochazka, A., Neumann, R., "High Frequency Distortion Analysis Of A Semiconductor Diode For CATV Applications", **IEEE Trans. on Consumer Electronics**, Cilt CE-21, 120-129, 1975.
14. Nam, S.W., Powers, E.J., "Application Of Higher Order Spectral Analysis To Cubically Nonlinear System Identification", **IEEE Trans. on Signal Processing**, Cilt 42, 2124-2135, 1994.
15. Özgunel, S., Kayran, A. H., Panayirci, E., "Nonlinear Channel Equalization and Identification", **Proc. Of Int. Conf. on Digital Signal Proc.**, 260-265, Florence, 1991.
16. Özden, M. T., Kayran, A. H., Panayirci, E., "Adaptive Volterra Filtering with Complete Lattice Orthogonalization", **IEEE Trans. On Signal Proc.**, Cilt 44, 2092-2098, 1996.
17. Griffith, D.W., Arce, G.R., "Partially Decoupled Volterra Filters: Formulation and LMS Adaptation", **IEEE Trans. on Signal Processing**, Cilt 45, 1485-1494, 1997.
18. Lee, J., Mathews, V.J., "A Stability Condition For Certain Bilinear Systems", **IEEE Trans. on Signal Processing**, Cilt 42, 1871-1873, 1994.
19. Cowan, C.F., Grant, P.M., "Nonlinear System Modelling - Concept and Application", **Proceedings Of IEEE Int. Conference On Acoustic Speech and Signal Processing**, 1-4, San Diego, California, 1984.
20. Priestley, M. B., **Nonlinear and Non-Stationary Time Series Analysis**, Academic Press, 1988.
21. Rauf, F., **Nonlinear Adaptive Filtering : A Unified Approach**, Ph.D. Thesis, Boston University, Boston, 1993.
22. Giannakis, G.B., Serpedin, E., "A Bibliography on Nonlinear System Identification", **Signal Processing**, Cilt 81, 533-580, 2001.
23. Khurram, M. U., **Fast Learning Nonlinear Adaptive Filtering Structures**, Ph.D. Thesis, University Of Boston, 1994.
24. Koh, T., Powers, E. J., "Second Order Volterra Filtering and Its Application to nonlinear system identification", **IEEE Trans. on ASSP**, Cilt 33, 1445-1455, 1985.
25. Leuschen, M.L., Walker, I.D.; Cavallaro, J.R., "Fault residual generation via nonlinear analytical redundancy", **IEEE Transactions on Control Systems Technology**, Cilt:13, 452-458, 2005.
26. Goldberger, A.L., "Applications of chaos to physiology and medicine", In: Kim JH, Stringer J, eds. **Applied Chaos**. New York: John Wiley & Sons, 321-329, 1992.
27. Sağıroğlu, Ş., Özer, Ş., "A Neural Identifier for Linear Dynamic Systems", **Journal of Polytechnic**, Cilt 4, 55-61, 2001.
28. Özer, Ş., Sağıroğlu Ş., Zorlu H., "Arma Sistem Modellemeye Klasik ve Yapay Sinir Ağları Algoritmalarının Karşılaştırılması", **Elektrik-Elektronik-Bilgisayar Mühendisliği 10.Uluslararası Kongresi Bildiriler Kitabı**, 434-437, 2003.
29. Narendra, K.S., Mukhopadhyay, S., "Adaptive Control Using Neural Networks and Approximate Models", **IEEE Trans. on Neural Networks**, Cilt 8, 475-485, 1997.
30. Kaplan, A., **Nümerik Tabu Arama Algoritması**, Doktora Tezi, Erciyes Üniversitesi, Kayseri, 2001
31. Wang, Z., Gu, H., "Parameter Identification of Bilinear System Based on Genetic Algorithm", **LNCS 4688**, 83 – 91, 2007.
32. Karaboga, N., "Digital IIR Filter Design Using Differential Evolution Algorithm", **EURASIP Journal on Applied Signal Processing**, Cilt 8, 1269–1276, 2005.
33. Cheng, S. L., Hwang, C., "Optimal approximation of linear systems by a differential algorithm", **IEEE Trans Syst Man and Cybernet—Part A Syst Humans**, Cilt 31, 698–707, 2001.
34. Chang, W.D., "Parameter identification of Rossler's chaotic system by an evolutionary algorithm", **Chaos, Solitons and Fractals**, Cilt 29, 1047–1053, 2006.

35. Chang, W.D., "Parameter identification of Chen and Lü systems: A differential evolution approach", **Chaos, Solitons and Fractals**, Cilt 32, 1469–1476, 2007.
36. Price, K. V., **An introduction to differential evolution**, in D. Corne, M. Dorigo, and F. Glover, (Ed), **New Ideas in Optimization**, chapter 6, McGraw Hill, London, UK, 1999.
37. Bağış, S., **Yapay Zeka Algoritmaları Kullanılarak Sistem Modelleme**, Yüksek Lisans Tezi, Erciyes Üniversitesi, Kayseri, 2009.
38. Kristinsson, K., Dumont, G.A., "System Identification and Control using Genetic Algorithms", **IEEE Trans. on Systems, Man, and Cybernetics**, Cilt 22-5, 1033-1046, 1992.
39. Pham, D.T., Karaboga, D., **Intelligent Optimisation Techniques: Genetic Algorithms, Tabu Search, Simulated Annealing and Neural Networks**, Springer- Verlag, 2000.
40. Madar, J., Abonyi, J., Szeifert, F., "Genetic Programming for the Identification of Nonlinear Input–Output Models", **Ind. Eng. Chem. Res.**, Cilt 44-9, 3178-3186, 2005.
41. Bağış, A., Özçelik, Y., "Gerçek Kodlu Genetik Algoritma Kullanılarak Sistem Kimliklendirme", **12. Elektrik, Elektronik, Bilgisayar, Biyomedikal Mühendisliği Ulusal Kongresi**, Eskişehir, 2007.
42. Bagis, A., "Performance Comparison of Genetic and Tabu Search Algorithms for System Identification", **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, Cilt 4251 LNAI-I, 94-101, 2006.
43. Price, K., Storn, R., "Differential Evolution: Numerical Optimization Made Easy", **Dr. Dobb's J.**, Cilt 78, 18–24, 1997.
44. Bağış, A., Özçelik, Y., "Farksal Evrim Algoritması Kullanılarak Sistem Kimliklendirme", **Otomatik Kontrol Ulusal Toplantısı (TOK'07)**, 178-183, İstanbul, 2007.
45. Hou, Z., "Wiener Model Identification based on Adaptive Particle Swarm Optimization", **Proceedings of the Seventh International Conference on Machine Learning and Cybernetics**, 1041-1045, Kunming, 12-15 July 2008.
46. Liu, L., Liu, W., Cartes, D.A., "Particle Swarm Optimization based Parameter Identification Applied to Permanent Magnet Synchronous Motors", **Engineering Applications of Artificial Intelligence**, Cilt 21, 1092–1100, 2008.
47. Zorlu, H., Özer Ş., "Doğrusal Olmayan Sistemlerin Klonal Seçme Algoritması Kullanılarak Kimliklendirilmesi", **Sinyal İşleme ve Uygulamaları Kurultayı (SIU)**, 2009.
48. Subudhi, B., Debachisha, J., "A Combined Differential Evolution and Neural Network Approach to Nonlinear System Identification", **IEEE Region 10 Conference, TENCON 2008**, 1-6, 19-21 Nov. 2008.
49. Subudhi, B., Jena, D., Gupta, M.M., "Memetic Differential Evolution Trained Neural Networks for Nonlinear System Identification", **Third International Conference on Industrial and Information Systems (ICIIS'2008)**, 1-6, 2008.
50. Karaboga, D., **Yapay Zeka Optimizasyon Algoritmaları**, Atlas yayın dağıtım, İstanbul, 2004.
51. Holland, J.H., **Adaption in Natural and Artificial Systems**, MAMIT Press, Cambridge, 1975.
52. De Castro, L.N., Von Zuben, F.J., "The clonal selection algorithm with engineering applications", **In Workshop Proceedings of GECCO'00, Workshop on Artificial Immune Systems and their Applications**, 36–37, Las Vegas, 2000.
53. De Castro, L.N., Von Zuben, F.J.: "Learning and optimization using clonal selection principle", **IEEE Transactions on Evolutionary Computation, Special Issue on Artificial Immune Systems**, Cilt 6-3, 239–251, 2001.
54. Aslantas, V., Ozer, S., and Ozturk, S., "A Novel Clonal Selection Algorithm Based Fragile Watermarking Method", **LNCS**, Cilt 4628, 358-369, 2007.
55. Ada, G. L. and Nossal, G., "The clonal selection theory", **Scientific American**, Cilt 257, 50–57, 1987.
56. Lorenz, E.N., "Deterministic Nonperiodic Flow", **Journal of the Athmosferic Sciences**, Cilt 20, 130-141, 1963.
57. González, O.A., Han, G., de Gyvez, J.P., and Edgar, "CMOS Cryptosystem Using a Lorenz Chaotic Oscillator", **Proceedings of the IEEE International Symposium on Circuits and Systems, ISCAS '99**, Cilt 5, 442-445, 1999.
58. Chen Y. A., Yang B. A., Dong J. A., Abraham A., "Time-Series Forecasting Using Flexible Neural Tree Model", **Information Sciences**, Cilt 174, 219–235, 2005.
59. Wang, L.X., Mendel, J.M., "Generating fuzzy rules by learning from examples", **IEEE Transactions on Systems, Man and Cybernetics**, Cilt 22, 1414–1427, 1992.
60. Cho, K.B., Wang, B.H., "Radial basis function based adaptive fuzzy systems their application to system identification and prediction", **Fuzzy Sets and Systems**, Cilt 83, 325–339, 1995.

