Turkish Studies
International Periodical for the Languages, Literature and History of Turkish or Turkic
Volume 12/23, p. 121-132
DOI Number: http://dx.doi.org/10.7827/TurkishStudies.12000
ISSN: 1308-2140, ANKARA-TURKEY

Article Info/Makale Bilgisi
Referees/Hakemler: Doç. Dr. Devrim AKGÜN – Yrd. Doç. Dr. Aytürk KELEŞ

This article was checked by iThenticate.

DOĞRUSAL OLMAYAN REGRESYON PARAMETRELERİNİN SEZGİSEL YÖNTEMLERLE TAHMİNİ

Pakize ERDOĞMUŞ - Simge EKİZ*

ÖZET

Gerçek dünyadaki deneysel olarak elde edilen veriler ve sinyallerin matematiksel modelleri her zaman kesin ve belirli değildir. Sinyal işlemede ve diğer deneysel çalışmalarda veriler için bir matematiksel model elde etmek ve bu matematiksel modelin parametrelerinin tahmini önemli bir konudur. Bu çalışmada üç farklı veri seti ve bu veri setleri için literatürde önerilen beş farklı modelin parametreleri doğrusal olmayan regresyon metodları ve sezgisel arama algoritmaları ile tespit edilmeye çalışılmıştır. Doğrusal olmayan regresyon metodlarının en büyük dezavantajı yakınsamalarının parametrelerin ilk tahminlerine bağlı olmasıdır. Oysa bu çalışmada kullanılan sezgisel algoritmaların en iyi sonuca yakınsamaları başlangıç değerlerinden bağımsızdır. Bu amaçla iki tür test yapılmıştır. Birinci testte veri setleri ve her veri seti için önerilen modellere gerçek değerlerine yakın ilk değerler atanmış ve modeller hem klasik hemde sezgisel algoritmalar ile optimize edilmeye çalışılmıştır. Sezgisel agoritmalardan Genetic Algoritma(GA) ve Parçacık Sürü Optimizasyonu(PSO) algoritmaları ile elde edilen sonuçlar, klasik algoritmalar ile karşılaştırılmıştır. Birinci testte hem klasik yöntemler hemde sezgisel yöntemler model parametrelerini tahmin etmişlerdir. İkinci testte ise modellerin ilk değerleri gerçek değerlerden uzak seçilmiştir. Bu testte sezgisel algoritmalar daha başarılı sonuçlar vermiştir. Doğrusal olmayan regresyon analizinde kullanılan klasik algoritma sonuçları gerçek parametre değerine tüm çözümlerde yakınsayamamıştır. Yapılan analizler sonucunda model parametrelerinin ik değerleri hakkında bir bilgi olmadığı durumlarda sezgisel yöntemlerin doğrusal olmayan regresyon analizinde iyi bir alternatif olacağı görülmüştür.

Anahtar Kelimeler: Parametre tahmini, Genetik Algoritma, Parçacık Sürü Optimizasyonu

* Doç. Dr. Düzce Üniversitesi Bilgisayar Mühendisliği, El-mek: pakizeerdogmus@duzce.edu.tr

ESTIMATION OF THE NON LINEAR REGRESSION PARAMETERS WITH HEURISTIC METHODS

ABSTRACT

In real world, the mathematical models of the signals and experimental data are not always exact and precise. To fit a mathematical model and estimate the parameters of this mathematical model is an important issue. In this study, three different data set and five different model for each data set were used. In order to estimate the parameters of these models both nonlinear regression algorithms and heuristic search algorithms. The major disadvantage of the nonlinear regression methods is that these algorithms are dependent to the initial estimates of the parameters. Whereas convergances of heuristic algorithms used in this study are independent to the initial values. With this aim two test case were used. At first test, the initial estimates were selected near to the real values. The models parameters have been optimized both classical and heuristic algorithms. The results obtained from Genetic Algorithm (GA) and Particle Swarm Optimization (PSO) have been compared with classical algorithms. At first test, both classical and heuristic algorithms have been successful to estimate the model paramters. At second test, the initial values of the models have been assigned quite far from the real values. In this test, heuristic algorithms have been more successful than classical algorithms. Classical algorithm results have not been converged to the real values for all the models. As a results, heuristic algorithms have been accepted as a good alternative, when we have not any information about the inital values of the parameters of nonlinear regression model.

STRUCTURED ABSTRACT

In real world, the relation between independent and dependent variables aren't certain. It is difficult to create a mathematical model for these dependent and independent variables pair. The first step for regression analysis is to find a model which fits the variables best. The second step is to estimate the parameters of proposed model. In some situations, dataset fits more than a model. At this situation, the model giving the minimum sum of the square errors is preferred.

Gauss-Newton, Levenberg-Marquardth and some methods based on derivative are used for the parameter estimation in non-linear regression. Gauss-Newton is an iterative optimization method based on derivative. If a model has n unnown parameters called B_{1init}, B_{2init},..., B_{ninit}, the algorithm updates the parameters in a way that minimizes the total error between the real values and estimated values.

The performance of the algorithm is related to the initial variables. If these initial variables aren't selected properly, the algorithm gets stuck in local optimum (Altunkaynak vd, 2004). The disadvantege of Gauss-Newton is that it requires intensive matrix operation and derivative. Another method is Levenberg-Marquardt method which is faster than

Gauss-Newton(Aşkın vd, 2011). In this study, parameters for non-linear regression models for three different dataset are estimated with heuristic optimization algorithms. In this study, Genetic Algorithm and Particle Swarm Optimization algorithms are used for the parameter estimation.

Genetic algorithm is developped in 1976 by Holand and since then GA is the most studied heuristic algorithm(Erdogmus, 2016). Independent variables of the function are called chromosome. Each candidate solution using independent variables is called individual. Algorithm starts a set of initial solutions containing n independent variables. It is called a generation. Some operators like Rulet Wheel, tournament selection and some others are used for selection(Keskintürk vd, 2009). After selection, crossover and mutation are applied with the proper rates. While crossover is applied with low probability, mutation is applied with high probability.

PSO is introduced by Eberhart and Kenedy in 1995(Kenedy vd, 2014). PSO is also population based algorithm. Since PSO has no operator like crossover, PSO is faster than GA and applied successully to the problems in Engineering(Juan vd, 2007; Schwaab vd 2007; Okabe vd 2016; Yang vd,2017).

PSO simulates the social behaviours of bird flocking or fish schooling. In PSO, the potential solutions are the positions of the particles. All particles are called swarm. The initial positions of the particles are created randomly between the upper and lower bound. The particles update their positions according to the local and global best position which means the nearest position to the food.

In this study, the parameter estimation is realized with Levenberg-Marquardt Algorithm, Genetic Algorithm and Particle Swarm Optimization. Three data set and for each data set five models are used for simulations. In the simulations "Intel(R) Core(TM) i7-4720HQCPU 2.60GHz processor", 64-bit Windows 10 version with R2015a Matlab© is used. The data set and models are taken (Altunkaynak vd, 2004) and (Keskintürk vd, 2009).

Parameter estimation is handled as unconstrained optimization problem. The object function is the sum of the square errors between the real values and exected values. In classical methods, the performance of the algorithm depends on the initial values. If the initial values are selected properly, algorithm converges slowly or can't converge. This means that the number of iteration and the solution time increases.

Whereas heuristic optimisation algorithms are less dependent to the initial solution than classical methods. So in this study PSO and GA are used for testing the estimation performances. For this aim, two different simulations are realized. All results are attained with 30 simulations.

In the first simulation, initial values are selected near to the optimium values. With these initial values, it has been seen that classical method gives the best results as given in the literature. In the second simulation, initial values are selected quite far from the real values. While classical algorithm didn't converge the optimum parameter values, PSO and GA converged the optimum values.

As a result, if there is no information about the initial estimates of the parameters, heuristic optimization algorithms especially PSO is proposed to be used for non-linear regression parameter estimation, since PSO converges fast.

Keywords: Parameter Estimation, Genetic Algorithm, Particle Swarm Optimization

1. GİRİŞ

Gerçek dünyada çoğu sinyal durağan değildir ve sinyalin matematiksel ifadesinin ne olduğu bilinmez. Bu durumlarda sinyalin matematiksel modeli tahmin edilmeye çalışılır. Sinyalin zaman veya frekans domeninde ki bilinmeyen parametrelerinin tahmini istatistiksel sinyal işlemenin önemli bir konusudur. Sinyalin matematiksel modeli ve spektral parametreleri tahmin edilirken çok çeşitli yöntemler kullanılır.

Deneysel olarak elde edilen gözlenen ve beklenen değerlerinde bir matematiksel modele oturtulduktan sonraki en önemli aşaması, bu modele ait parametrelerin tahminidir. Dolayısıyla regresyon analizinde en önemli ilk aşama bu veri setine uygun modeli bulmak ve ikinci aşama ise bu modele ait parametreleri tahmin etmektir. Bazı durumlarda veri seti birden fazla modele uygun gözükebilir. Bu durumda bu modellere ait parametreler tahmin edilerek gerçek değerler ile model tarafından üretilen değerlerin farkının minimum olduğu model tercih edilen model olur.

Zaman serisi tahminlerinde, sistemin zaman serisini üreten parametrelerin arayışı üzerinde durulmaktadır. Tahminler yapılırken zaman serisinin lineer bir sistem tarafından üretilen sinyal ve beyaz gürültü toplamından oluştuğu varsayılarak, zaman serisinin güç spektrumu ile uyuşacak modelin parametrelerin tahmini yapılmaktadır (Yürüklü vd, 2012).

Prony's metodu(Coccetti vd, 2004), Otoregresif model(Wei, 2013), Otoregresiv hareketli ortalamalar modelleri(Gannabathula vd, 1988)sinyal modelleme ve tahmin yöntemlerinden bazılarıdır. Bu çalışmada ise parametre tahmininde kullanılan en küçük kareler yöntemi(Zhang, 2016) üzerinde durulmaktadır.

En küçük kareler yöntemi ile parametrelerinin tahmini problemi bir optimizasyon problemidir. Gerçek değerler ile tahmin edilen değerler arasındaki farkın karesinin minimizasyonunu sağlayan parametreler bulunmaya çalışılır.

Çalışmanın ikinci bölümünde doğrusal olmayan regresyon üzerinde durulmuştur. Üçüncü bölümde ise bu çalışmada kullanılan sezgisel yöntemlerden GA ve PSO üzerinde durulmuştur. Çalışmanın dördüncü bölümünde literatürden alınan bazı veri setlerinde parametre tahmini klasik yöntemler ve sezgisel yöntemlerle elde edilmiş ve son bölümde sonuçları sunulmuştur.

2. DOĞRUSAL OLMAYAN REGRESYON

Regresyon analizi, bir ölçüm veya gözlem sonucu elde edilmiş olan bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi en uygun matematiksel model ile ifade etmeye yarar. Önce verilere bakılarak uygun bir model seçilir. Bu model doğrusal veya doğrusal olmayan bir model olabilir. Modele karar verildikten sonraki en önemli aşama ise modeldeki parametrelerin tahminidir.

Doğrusal olmayan bir model aşağıda denklem 1'deki gibi verilir.

$$Y=f(x,B)+e; \quad (1)$$

f fonksiyonu doğrusal olmayan bir fonksiyon olup, $B=(B_1, B_2,\ldots, B_n)$ gibi parametrelere sahiptir. Doğrusal olmayan regresyonda amaç gözlenen değerler ile bu modelden elde edilecek değerler arasındaki farkı minimum yapacak $B_1, B_2,\ldots, B_n$ parametrelerinin bulunmasıdır.

Doğrusal olmayan modellerin parametrelerinin tahmininde Gauss-Newton, Levenberg-Marquardt ve türeve dayalı metodlar gibi birçok yöntem kullanılmaktadır. Gauss-Newton yöntemi basit türeve dayalı iteratif bir optimizasyon yöntemidir. Gauss-Newton yöntemi, lineer olmayan fonksiyonun Taylor seri açılımını esas alarak, ardışık işlemler sonucu, parametreleri yaklaşık hesaplamaya dayanır(Bayram, 2009). $B_{1init}, B_{2init},\ldots, B_{ninit}$ ilk değerleri türev bilgisi kullanılarak gözlenen ve beklenen değerler arasındaki farkı minimize edecek şekilde iteratif olarak en iyi değerlerine yaklaşır. Sinyal işlemede parametre tahmininde kullanılan yöntemlerdendir(Nayak vd, 2015; Rahman vd, 2016).

Algoritmanın performansı $B_{1init}, B_{2init},\ldots, B_{ninit}$ ilk değerlerine bağlıdır. Bu ilk değerler iyi seçilmez ise algoritma yerel optimumlara takılabilir(Altunkaynak vd, 2004). Gauss-Newton Yönteminin bir başka dezavantajı ise yoğun matris işlemi ve türev bilgisi gerektirmesidir. Doğrusal olmayan modellerin parametrelerinin tahmininde kullanılan diğer bir yöntem ise Levenberg-Marquardt metodudur. Levenberg-Marquardt temel olarak maksimum komşuluk üzerine kurulmuş bir metoddur. Bu algoritma Gauss-Newton ve gradient-descent algoritmalarının en iyi özelliklerinden oluşur ve bu iki metodun kısıtlamalarını kaldırır. Genel olarak Gauss-Newton'a göre daha hızlı yakınsar(Aşkın vd, 2011).

3. SEZGİSEL YÖNTEMLER

Bu çalışmada doğrusal olmayan regresyon modelinin parametrelerinin tahmininde sezgisel yöntemlerden Genetik Algoritma ve Parçacık Sürü Optimizasyonu kullanılmıştır.

3.1. Genetik Algoritma

Genetik algoritma 1976 yılında Holand tarafından geliştirilmiş Evrim teorisinin "En iyi olan hayatta kalır." prensibini temel alan bugüne kadar en çok çalışılan popülasyon temelli sezgisel algoritmadır(Erdogmus, 2016). Gerçek dünyadaki optimize edilecek fonksiyonun bağımsız değişkenleri kromozomlara karşılık gelmektedir. Her bir çözüm bir birey olarak adlandırılır. Ve algoritma bir nesil olarak adlandırılan n adet bireyden oluşan bir ilk çözüm ile başlar. Bireyler arasında bir sonraki nesli oluşturmak için ebeveynler seçilir. Rulet tekerleği ve turnuva seçimi gibi en çok kullanılan ve yöntemlerle ebeveynler seçilir (Erdoğmuş vd, 2012). Seçilen bu ebeveynlere çaprazlama uygulanarak, iki bireyin farklı özelliklerini taşıyan yeni bireyler oluşturulur. Çaprazlama için de çok çeşitli yöntemler geliştirilmiştir. Tek nokta, iki nokta ve çok noktalı çaprazlama en bilinenleridir. Çaprazlama işleminden sonra ise mutasyon işlemi uygulanır. Çaprazlama yüksek olasılıkla uygulanan bir işlem iken, mutasyon düşük olasılıkla uygulanan bir işlemdir ve bireylerin tek tipleşmesini önlemek için uygulanan bir ya da birkaç gen üzerinde yapılan kalıcı değişikliklerdir. Genetik algoritmanın adımları aşağıda Şekil 1'de verildiği gibidir.

Genetik Algoritma

1 Başlangıç popülasyonunu oluştur. Uygunluk fonksiyon değerlerini elde et.

2 Seçim işlemini gerçekleştir.

3 Çaprazlama ve mutasyon işlemini gerçekleştir.

4 Durma kriteri sağlanmadı ise 2. Adıma dön, sağlandı ise dur.

Şekil 1: Genetik Algoritma

3.2. Parçacık Sürü Optimizasyonu

PSO ilk olarak Eberhart ve Kenedy tarafından 1995 yılında bir konferansta tanıtılmıştır(Kenedy vd, 2014). PSO da GA gibi popülasyon temelli bir algoritmadır. Ancak GA gibi operatörlerinin olmayışı, daha kolay uygulanabilir bir algoritma olması, daha hızlı olması ve hızlı yakınsaması gibi sebeplerden dolayı birçok alanda başarı ile uygulanmıştır (Juan vd, 2007; Schwaab vd 2007; Okabe vd 2016; Yang vd,2017).

PSO kuş ve balık sürülerinin yiyecek arama davranışını simule eden bir algoritma olup, her bir çözüme parçacık adı verilir. Algoritmadaki tüm parçacıklar sürüyü oluşturur. Sürüdeki her parçacık ilk başta rastgele konumlarda ve hızlarda harekete başlarlar. Bu konumlarda yiyeceğe yakınlık durumlarına göre hızlarını adapte ederek hareket ederler. Sürüde iki türlü hafıza kullanılmaktadır. Her parçacık kendi en iyisini(yiyeceğe en yakın olduğu konumu) ve tüm sürünün en iyisini bilmektedir. Bu şekilde belli iterasyon sonunda yiyeceğe en yakın konum(en optimum çözüm) bulunmuş olur. PSO algoritmasının adımları aşağıda Şekil 2'de verildiği gibidir.

Parçacık Sürü Optimizasyonu
1 Parçacıklara ilk konum ve hız değerleri ata.
2 Uygunluk fonksiyonu değerini hesapla, yerel ve küresel en iyileri bul
3 Parçacıkların hız ve konum değerlerini güncelle.
4 Durma kriteri sağlanmadı ise 2. Adıma dön, sağlandı ise dur.

Şekil 2: Parçacık Sürü Optimizasyonu Algoritması

4. DENEYSEL ÇALIŞMA

Çalışmada doğrusal olmayan regresyon analizinde parametrelerin tahmin edilmesi işleminde klasik algoritmalardan Levenberg-Marquardt Algoritması, sezgisel algoritmalardan ise Genetik Algoritma ve Parçacık Sürü Optimizasyonu algoritması kullanılarak gerçekleştirilmiştir. Kodlamalar "İntel(R) Core(TM) i7-4720HQCPU 2.60GHz işlemci", 64-bit Windows 10 versiyonu ile R2015a Matlab© kullanılarak gerçekleştirilmiştir. Tablo 1'de kullanılan veri setleri görülmektedir. Tabloda y bağımlı değişken, x bağımsız değişkeni göstermektedir. Tablo 2'de ise bu veri setleri için önerilen modeller görülmektedir. Bu veri setleri ve önerilen modeller (Altunkaynak vd, 2004) and (Keskintürk vd, 2009)'ün çalışmalardan referans olarak kullanmak için alınmıştır.

Tablo 1. *Kullanılan veri seti*

1. Veri Seti		2. Veri seti		3.Veri Seti	
y	**X**	**y**	**x**	**y**	**x**
8.93	9	16.08	1	1.23	0
10.80	14	33.83	2	1.52	1
18.59	21	65.80	3	2.95	2
22.33	28	97.20	4	4.34	3
39.35	42	191.55	5	5.26	4
56.11	57	326.20	6	5.84	5
61.73	63	386.87	7	6.21	6
64.62	70	520.53	8	6.50	8
67.08	79	590.03	9	6.83	10
		651.92	10		
		724.93	11		
		699.56	12		
		689.96	13		
		637.56	14		
		717.41	15		

Tablo 2. *Kullanılan veri setleri için önerilen modeller*

Model Adı	Model Parametre Sayısı	Model
Gompertz	3	$f(x) = \alpha e^{-e^{(\beta-\gamma x)}}$
Logistic	3	$f(x) = \alpha/(1+e^{(\beta-\gamma x)})$
Richards	4	$f(x) = \alpha/(1+e^{(\beta-\gamma x)})^{(\frac{1}{\delta})}$
MMF	4	$f(x) = (\beta\gamma + \alpha x^{\delta})/(\gamma + x^{\delta})$
Weibull	4	$f(x) = \alpha - \beta e^{-\gamma x^{\delta}}$

Bu çalışmada parametrelerin tahmini işlemi kısıtsız bir optimizasyon problemi olarak ele alınmıştır. Amaç fonksiyonu aşağıda denklem 2'de verildiği gibidir.

$$\text{Fobj}=\sum_{i=1}^{n}(\text{f}(x_i, \text{B}) - y_i)^2 \quad (2)$$

Klasik yöntemlerde algoritmanın performansı başlangıç değerlerine bağlıdır. Başlangıç değerleri iyi seçilmez ise yakınsama yavaşlayabilir veya hiç yakınsama olmayabilir. Yakınsamanın yavaş olması iterasyon sayısının gereksiz yere artması ve çözüm süresinin artması demektir. Sezgisel yöntemler ise klasik yöntemlere göre başlangıç değerlerden daha az etkilenirler. Bu amaçla literatürden alınan üç veri setinin parametrelerinin tahmini için iki farklı simülasyon yapılmıştır. İlk simülasyonda başlangıç değerleri gerçek değerlere yakın değerler verilerek tahmin edilen parametreler elde edilmiştir. İkinci simülasyonda ise başlangıç değerleri gerçek değerlere uzak değerler verilerek, tahmin edilen parametreler elde edilmiştir. Bu çalışma (Altunkaynak vd, 2004) and (Keskintürk vd, 2009)'ün çalışmaları temel alınarak yapılan bir karşılaştırma çalışmasıdır. (Altunkaynak vd, 2004) Gauss-Newton ve Genetik Algoritma çözümlerini, (Keskintürk vd, 2009) ise Gauss-Newton, Genetik Algoritma ve Gerçek değer kodlamalı Genetik Algoritma çözümlerini karşılaştırmıştır. Çalışmalarda algoritmalar için hangi başlangıç değerlerinin seçildiği

belirtilmemiştir. Sonuçta elde edilen katsayılar denklem 2'de verilen amaç fonksiyonunu minimize eden değerlerdir. Yöntemleri karşılaştırmak için referans çalışmalarda denklem 3 kullanılmıştır.

$$\sigma = Fobj/(n-p) \quad (3)$$

n, veri setindeki veri sayısı, p ise modeldeki parametre sayısını ifade etmektedir. Her bir veri seti ve o veri setinin uygulandığı model parametrelerinin tahmini için algoritmalar 30 kez çalıştırılarak sonuçlar bir dosyada saklanmış ve bu sonuçların en iyi değerleri ve ortalama değerleri sonuç tablolarda verilmiştir. Çalışmada GA, PSO ve Levenberg-Marquardth Algoritması kullanan klasik en küçük kareler(LSQ:Least Squares) yöntemi kullanılmıştır.

Birinci simülasyonda başlangıç parametreleri (Altunkaynak vd, 2004) and (Keskintürk vd, 2009)'ün çalışmalarda elde edilen model parametrelerine yakın değerler seçilerek simülasyon yapılmış ve bu simülasyonlar sonucu elde edilen ortalama sonuçlar Tablo 4 'te verilmiştir.

Tablo 3. *Birinci simülasyonda kullanılan başlangıç parametreleri*

Kullanılan Model ve Parametre Başlangıç Değerleri						
Veri Seti	*Parametre*	**Gompertz**	**Logistic**	**Richards**	**MMF**	**Weibull**
1. Veri Seti	α	80	72	69	80	70
	β	1	2	4	9	61
	γ	0	0	0	49000	0
	δ			2	3	2
2. Veri Seti	α	723	702	699	723	690
	β	2	4	5	33	670
	γ	0	0	0	6200	0
	δ			1	4	3
3. Veri Seti	α	6	6	6	6	6
	β	0	1	1	1	5
	γ	0	0	0	12	0
	δ			1	2	1

Tablo 4. *Birinci simülasyon sonucunda elde edilen ortalama model parametreleri ve* σ değerleri

		Gompertz			*Logistic*			*Richards*			*MMF*			*Weibull*		
Veri Seti	Parametre	GA	PSO	LSQ	GA	PSO	LSQ	GA	PSO	LSQ	GA	PSO	LSQ	GA	PSO	LSQ
1 Veri Seti	α	78,685	66,508	82,832	54,929	57,777	72,462	70,985	69,569	69,622	80,010	80,950	80,959	75,856	72,076	69,955
	β	1,296	47,334	1,224	74,658	28,459	2,618	3,539	4,286	4,255	8,732	8,897	8,894	80,000	64,477	61,681
	γ	0,042	1,613	0,037	5,884	1,000	0,067	0,079	0,090	0,089	50074,472	49704,097	49570,432	0,008	0,000	0,000
	δ							1,408	1,738	1,724	2,843	2,829	2,828	1,281	2,236	2,378
	σ	4,743	120,892	**3,632**	262,724	172,011	**1,343**	1,381	1,212	**1,210**	2,777	**2,711**	2,711	21,267	2,069	**1,675**
2 Veri Seti	α	719,904	723,108	723,107	675,936	675,913	702,872	694,973	699,518	699,641	723,763	723,930	723,933	694,230	695,042	695,025
	β	2,561	2,500	2,500	6,313	6,312	4,443	6,755	5,296	5,278	33,335	33,350	33,348	699,999	673,514	673,472
	γ	0,461	0,450	0,450	1,000	1,000	0,689	0,901	0,761	0,760	6297,100	6266,123	6265,007	0,009	0,002	0,002
	δ							1,781	1,286	1,279	4,644	4,641	4,641	2,419	3,261	3,261
	σ	1139,448	**1133,845**	1133,845	1941,940	1941,038	**744,157**	838,170	798,980	**798,764**	1015,052	**1015,038**	**1015,038**	1585,681	**712,209**	**712,209**
3 Veri Seti	α	6,923	6,925	6,925	6,686	6,687	6,687	6,645	6,682	6,684	6,985	6,986	6,986	6,661	6,408	6,656
	β	0,769	0,768	0,768	1,746	1,745	1,745	2,304	1,792	1,780	1,182	1,181	1,181	5,564	5,277	5,549
	γ	0,494	0,493	0,493	0,755	0,755	0,755	0,835	0,761	0,759	13,017	12,959	12,959	0,120	0,109	0,118
	δ							1,292	1,023	1,017	2,479	2,475	2,475	1,747	11,692	1,763
	σ	**0,062**	**0,062**	**0,062**	**0,035**	**0,035**	**0,035**	0,044	**0,042**	**0,042**	**0,005**	**0,005**	**0,005**	**0,027**	0,471	**0,027**

Tablo 4 ’ten görüleceği üzere, 1.Veri seti için, Gompertz modelinde, PSO 30 çalıştırmanın 10’unda optimum parametre değerlerini hesaplanmıştır. Diğerlerinde ise lokal optimum çözümlere takılmıştır. GA 30 çalıştırmanın hiç birinde en optimum parametreyi bulmamış, ancak optimuma yakın değerler bulmuştur. Logistic modelinde ise PSO ve GA optimum değerlere yaklaşmamıştır. Richards ve MMF modellerinde ise PSO, 30 çalıştırmada da klasik yöntemle aynı optimum parametre değerlerini bulmuştur. GA ise Richards’ta yakın, MMF’te ise optimum parametre değerlerini bulmuştur. Weibull modelinde de PSO daha optimum sonuçlar bulmuştur. 2.Veri seti için Logistic dışındaki diğer modeller için PSO en iyi parametre değerlerini bulmuştur. GA ise optimuma yakın değerler vermiştir. 3.Veri seti için tüm modellerde PSO ve GA 30 çalıştırmanın tamamında klasik algoritma ile aynı optimum parametreleri tahmin etmiştir. İkinci simülasyonda ise başlangıç değerleri optimum parametrelerden uzak değerler seçilmiştir. Klasik algoritmaların en büyük dezavantajı lokal optimuma takılmalarıdır. Bu sebeple böyle durumlarda sezgisel algoritmalar klasik metodlara iyi bir alternatif olabilirler. Tablo 5’te kullanılan başlangıç değerleri ve Tablo 6’da ise bu başlangıç değerleri için tahmin edilen parametre değerleri verilmiştir.

Tablo 5. *İkinci simülasyonda kullanılan başlangıç parametreleri*

Kullanılan Model ve Parametre Başlangıç Değerleri						
Veri Seti	*Parametre*	**Gompertz**	**Logistic**	**Richards**	**MMF**	**Weibull**
1. Veri Seti	α	50	50	30	50	20
	β	10	10	10	0	30
	γ	10	10	10	0	60
	δ			10	0	60
2. Veri Seti	α	200	200	30	50	20
	β	10	10	30	0	30
	γ	10	10	60	0	60
	δ			60	0	60
3. Veri Seti	α	70	50	30	50	20
	β	10	10	30	10	30
	γ	10	10	60	10	60
	δ			60	10	60

Tablo 6. *İkinci simülasyon sonucunda elde edilen ortalama model parametreleri ve* σ değerleri

		Gompertz			*Logistic*			*Richards*			*MMF*			*Weibull*		
Veri Seti	Parametre	GA	PSO	LSQ	GA	PSO	LSQ	GA	PSO	LSQ	GA	PSO	LSQ	GA	PSO	LSQ
1 Veri Seti	α	38,838	67,798	38,838	38,838	57,779	38,838	69,493	69,513	38,838	99,999	81,621	80,960	76,252	68,275	38,838
	β	12,377	48,199	10,000	12,303	36,980	10,000	4,484	4,359	10,000	0,000	8,743	8,894	79,983	62,065	30,000
	γ	11,826	1,720	10,000	12,011	1,304	10,000	0,093	0,091	10,000	116,654	44648,041	49562,381	0,007	0,356	60,000
	δ							1,839	1,775	10,000	1,206	2,789	2,828	1,300	2,504	60,000
	σ	774,677	**104,784**	774,677	774,677	**172,061**	774,677	**1,317**	1,235	929,613	61,054	2,745	**2,711**	**19,813**	94,798	929,613
2 Veri Seti	α	693,120	719,835	341,678	528,737	675,913	400,068	693,305	698,922	423,295	498,316	723,934	50,012	690,999	695,043	423,295
	β	6,682	3,403	2,679	13,906	6,312	3,532	7,438	5,414	30,000	0,487	33,344	0,000	699,999	673,518	30,000
	γ	1,155	0,602	0,776	2,476	1,000	0,831	0,969	0,773	60,000	197,120	6264,289	-0,625	0,012	0,002	60,000
	δ							2,015	1,324	60,000	3,622	4,641	0,000	2,301	3,261	60,000
	σ	3579,280	**1508,813**	69981,297	16843,121	**1941,038**	47917,639	868,014	**801,092**	97860,145	27816,016	**1015,038**	212520,689	2064,293	**712,209**	97860,145
3 Veri Seti	α	6,924	6,925	6,925	6,686	6,687	6,687	6,345	6,355	6,684	28,929	6,986	6,986	4,931	5,990	4,931
	β	0,769	0,768	0,768	1,746	1,745	1,745	49,616	39,825	1,779	0,894	1,181	1,181	3,701	4,830	3,701
	γ	0,494	0,493	0,493	0,755	0,755	0,755	11,294	9,087	0,759	17,168	12,961	12,959	65,205	17,479	60,000
	δ							32,070	25,732	1,017	0,722	2,476	2,475	64,396	22,483	60,000
	σ	**0,062**	**0,062**	**0,062**	**0,035**	**0,035**	**0,035**	0,206	**0,196**	0,042	0,476	**0,005**	**0,005**	4,909	**1,699**	4,909

İkinci simülasyonda başlangıç değerleri optimum paramatre değerlerinden uzak seçildiğinde, 1. Veri setinde bir model ve 3. Veri setindeki ilk dört model dışında, klasik algoritmanın

optimum parametre değerlerini bulamadığı görülmüştür. Tablo 6'daki toplam onbeş modelden dokuz tanesinde PSO, iki tanesinde GA, birinde LSQ optimum tahmin değerlerini bulmuştur. Geri kalan üç modelde ise her üç algoritma da optimum parametre değerlerini bulmuştur.

5. SONUÇ VE GELECEK ÇALIŞMALAR

Bu çalışmada başlangıç koşullarının klasik algoritmaların optimum çözüme yakınsamalarında önemli olduğu görülmüştür. Bu amaçla iki farklı simülasyon yapılmış ve birinci simülasyonda başlangıç parametreleri optimum parametre değerlerine yakın seçilmiştir. Çalışmada üç temel veri seti ele alınmıştır. Her bir veri seti için beş farklı regresyon modeli uygulanmış ve her bir model için parametreler klasik algoritma, PSO ve GA ile elde edilmeye çalışılmıştır. Tablo 4'ten de görüleceği üzere sezgisel yöntemler, klasik algoritma ile bulunan ve çalışmalarda da verilen optimum parametre değerlerine yakın çözümler vermişlerdir.

İkinci simülasyonda başlangıç parametreleri optimum parametre değerlerinden uzak seçilmiştir. Tablo 6'dan görüleceği üzere başlangıç değerleri iyi seçilmediğinde klasik algoritma optimum parametre değerlerini hesaplayamamaktadır. Sezgisel yöntemler başlangıç değerinden etkilenmeden optimuma yakın çözümler vermişlerdir. Sonuç olarak başlangıç tahminleri için bir fikir sahibi olunmadığında sezgisel algoritmalar ve özellikle PSO'nun doğrusal olmayan regresyon analizinde, parametre tahmininde kullanılması önerilir. Çalışmada optimum parametrelerin tahmini amaçlandığından, her bir model için çözümlerin kaç iterasyonda elde edildiğine bakılmamıştır. Ancak çözüm süresi bakımından PSO'nun diğer algoritmalardan daha hızlı yakınsadığı bilinmektedir.

KAYNAKÇA

A. Okabe and K. Kogiso(2016). Application of Particle Swarm Optimization to Parameter Estimation of a McKibben Pneumatic Artificial Muscle Model, *2016 IEEE 4th International Conference on Cyber-Physical Systems, Networks, and Applications (CPSNA)*, Nagoya, 2016, pp. 49-54.

Altunkaynak B., Esin A.,(2004). Doğrusal Olmayan Regresyonda Parametre Tahmini için Genetik Algoritma Yöntemi, G.U. J. Sci., 17(2):43-51

Aşkın, D., İskender, İ., and Mamızadeh A.(2011). Farklı yapay sinir ağları yöntemlerini kullanarak kuru tip transformatör sargısının termal analizi., Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi 26.4.

Bayram M.(2009). Nümerik Analiz, Birsen Yayınevi, İstanbul.

Erdogmus P. and Toz M. (2012). Heuristic Optimization Algorithms in Robotics, Serial and Parallel Robot Manipulators - Kinematics, Dynamics, Control and Optimization, Dr. Serdar Kucuk (Ed.), InTech, DOI: 10.5772/30110.

Erdoğmuş P.(2016), Doğadan Esinlenen Optimizasyon Algoritmaları ve Optimizasyon Algoritmalarının Optimizasyonu, Düzce Üniversitesi Bilim ve Teknoloji Dergisi,4, 293-304.

F. Coccetti and P. Russer,(2004). A Prony's model based signal prediction (PSP) algorithm for systematic extraction of Y-parameters from TD transient responses of electromagnetic structures, *Microwaves, Radar and Wireless Communications, 2004. MIKON-2004. 15th International Conference on*, pp. 791-794 Vol.3.

H. Wei(2103). Vehicle audio signal estimation of AR model and power spectrum estimation based on artificial neural network, *Chinese Automation Congress (CAC), 2013*, Changsha, pp. 876-881.doi: 10.1109/CAC.2013.6775856

J. Kennedy and R. Eberhart(1995). Particle swarm optimization, *Neural Networks, 1995. Proceedings.*

Juan R. Trapero, Hebertt Sira-Ramírez, Vicente Feliu Batlle(2007). An algebraic frequency estimator for a biased and noisy sinusoidal signal, Signal Processing, Volume 87, Issue 6, Pages 1188-1201.

Keskintürk T., Şahin S.(2009). Doğrusal Olmayan Regresyon Analizinde Gerçek Değer Kodlamalı Genetik Algoritma, *Istanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi Yıl:8 Sayı:15 Bahar 2009 s.167-178*

M. A. Rahman and G. K. Venayagamoorthy(2016). Dishonest Gauss Newton method based power system state estimation on a GPU," *2016 Clemson University Power Systems Conference (PSC)*, Clemson, SC,pp. 1-6.

P. K. Nayak, S. S. Pujari and B. N. Sahu(2015). Parameter estimation of nonstationary power signals using an improved Gauss- Newton adaptive filter, *2015 IEEE Power, Communication and Information Technology Conference (PCITC)*, Bhubaneswar, pp. 403-408.

P. S. S. D. Gannabathula and I. S. N. Murthy, (1988).ARMA model estimation for EEG using canonical correlation analysis, *Engineering in Medicine and Biology Society, 1988. Proceedings of the Annual International Conference of the IEEE*, New Orleans, LA, USA, pp. 1204-1205 vol.3.

Schwaab M., Biscaia E. C., Monteiro J.J, Pinto J. C.(2008). Nonlinear parameter estimation through particle swarm optimization, Chemical Engineering Science, Volume 63, Issue 6, 2008, Pages 1542-1552, ISSN 0009-2509.

W. Zhang and X. Wang,(2016). System identification of MISO second-order system based on least square method, *2016 35th Chinese Control Conference (CCC)*, Chengdu, China, pp. 9457-9461.

Yang J., Lu L., Ouyang W., Gou Y., Chen Y., Ma H., Guo J., Fang F.(2017) Estimation of kinetic parameters of an anaerobic digestion model using particle swarm optimization, Biochemical Engineering Journal, Volume 120, 15 April 2017, Pages 25-32.

Yürüklü E., Koçal O.(2012).The Classification and Recognition of Turkish Vowels with Self-Organizing Maps, Uludağ Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, Cilt 17, Sayı 1.