

Çift Pervaneli Çok Girişli Çok Çıkışlı (TRMS) Sistemin Parçacık Sürü Optimizasyonu ve Yapay Arı Kolonisi Kullanarak Parametrik Modellenmesi

¹Selim İlhan, *¹Ibrahim Mucuk, ¹Ayhan Ozdemir
¹ Sakarya University, Department of Electrical & Electronics Engineering, Sakarya, Turkey

Özet

Çift pervaneli çok girişli çok çıkışlı (TRMS) sistem helikopter ile benzer dinamiklere sahip kontrol deneyleri için kullanılan bir deney düzeneğidir. TRMS'nin aşırı nonlineer olması, girişleri arasında kublaj etkisi bulması ve tüm durumlarının ölçülmemesi gibi zorlayıcı mühendislik problemleri bulunmaktadır. Sistemin model doğruluğunu arttırmak için hava sürtünmesi, atalet momenti gibi ölçülemeyen/hesaplanamayan parametrelerin optimizasyon ile elde edilmesi gerekmektedir. Bu çalışmada TRMS'nin model parametreleri, sistemin giriş çıkış verileri kullanılarak sezgisel optimizasyon yöntemlerinin performansları karşılaştırılarak elde edilmiştir. İlk olarak, TRMS yatay düzlem dinamik denklemleri elde edilmiştir. Parçacık sürü optimizasyonu (PSO) ve yapay arı kolonisi (ABC) algoritmaları ile parametre tahmini yapılmıştır. Elde edilen sonuçlar incelendiğinde PSO algoritmasının daha iyi performans gösterdiği görülmüştür.

Anahtar Kelimeler: TRMS, parametre tahmini, sistem tanımlama, PSO, ABC, sezgisel optimizasyon

Abstract

The Twin Rotor multiple input multiple output System (TRMS) is an experimental setup used for control experiments with similar dynamics to helicopters. There are challenging engineering problems of TRMS such as extremely nonlinear, coupling effect and not measuring all states. In order to increase the model accuracy of the system, unmeasurable/uncalculated parameters such as air friction and moment of inertia should be obtained by optimization. In this study, the model parameters of TRMS are obtained by comparing the performance of the heuristic optimization methods using the input and output data of the system. First, the TRMS horizontal plane dynamic equations are obtained. Parameter estimation was made with particle swarm optimization (PSO) and artificial bee colony (ABC) algorithms. When the results obtained were examined, it is seen that the PSO algorithm performed better.

Key words: TRMS, parameter estimation, system identification, PSO, ABC, metaheuristic optimization

1. Giriş

Kontrol edilen sistemin model bilgisi mevcut çoğu kontrol yaklaşımı için gereklidir. Model doğruluğu tasarlanan kontrolörün tatmin edici performans göstermesini doğrudan etkileyecektir. Sistemlerin modelleri genellikle çeşitli yaklaşımlar, fizik kanunları kullanılarak dinamik denklemler ile ifade edilmektedir. Sistemlerin modellerinde ölçülemeyen ya da hesaplanamayan parametreler bulunabilir. Sistemin giriş çıkış verileri kullanılarak, bu parametrelerin optimize edilmesiyle modelleme doğruluğu artırılır.

TRMS sistem parametreleri, tasarım kısıtları ve sistemin bulunduğu ortam şartlarına bağlı olarak farklı çalışma bölgelerinde değişebilen özelliktedir. Dolayısıyla gerçek sistemi farklı çalışma bölgelerinde en yakın şekilde ifade edecek model sistemin doğru belirlenmesi oldukça değerlidir

*Corresponding author: Address: Faculty of Engineering, Department of Electrical Electronical Engineering Sakarya University, 54187, Sakarya TURKEY. E-mail address: ibrahimmucuk@sakarya.edu.tr, Phone: +902642955825

[1]. TRMS için model sistemin parametreleri farklı parametre kestirimi yöntemleri ile elde edilebilir. Literatürde konuyla ilgili Chalupa ve ark. MATLAB programının hazır optimizasyon çözümleri vasıtasıyla sistemi tanımlayan transfer fonksiyonlarını elde etmiştir [2]. Joseph ve Arjunan TRMS parametre kestirimi için Autoregressive with Exogenous Input (ARX) and Autoregressive Moving Average with Exogenous input (ARMAX) yöntemlerini kullanmış ve ARX tabanlı kestirim yönteminin daha başarılı olduğunu raporlamışlardır [3]. Subudhi Genetic Algorithm (GA), PSO ve Differential Evolution (DE) sezgisel optimizasyon yöntemleri ile Neural Network (NN) yöntemini birleştirerek TRMS için sistem tanımlama yapmıştır [4]. Toha ve ark. sistemin parametrik modellenmesinde Dynamic Spreading Factor yaklaşımı ile geliştirilmiş PSO yöntemini uygulamıştır [5]. Toha ve Tokhi aynı amaca yönelik olarak adaptive neuro-fuzzy inference system (ANFIS) yöntemini PSO ve recursive least squares (RLS) yaklaşımları ile geliştirerek kullanmıştır [6]. Huu ve Ismail TRMS modellemede GA optimizasyon yöntemini ele almıştır [7]. Rahideh çalışmasında Newtonian yaklaşımı TRMS sistemi dinamik denklemlerini elde etmiş ve modeldeki ölçülemeyen parametreleri Genetik Algoritma (GA) yöntemini kullanarak optimize etmiştir [8]. Toha çalışmasında TRMS sistemi yatay düzlem hareketini ARX model yapısı seçmiş ve Karınca Kolonisi (AC) optimizasyon yöntemi ile model parametrelerini elde etmiştir [9].

Bu çalışmada TRMS sisteminde bilinmeyen parametreler PSO ve ABC sezgisel optimizasyon yöntemleri kullanılarak elde edilmiştir. İlk olarak TRMS sistemi yatay düzlem dinamik denklemleri verilmiştir. PSO ve ABC sezgisel optimizasyon yöntemleri ile modelde bulunan bilinmeyen parametreler elde edilmiş ve yöntemlerin doğrulukları karşılaştırılmıştır. Bölüm 2’de çalışmada kullanılan yöntemler anlatılmaktadır. Bölüm 3’te PSO ve ABC sezgisel optimizasyon yöntemlerinin sonuçları karşılaştırılmaktadır. Çalışmaya ait tartışma Bölüm 4’te verilmektedir.

2. Yöntem

2.1. Çift Pervaneli Çok Girişli Çok Çıkışlı Sistem (TRMS)

TRMS laboratuvar ölçeğinde helikopter türü hava araçları üzerine modelleme ve kontrol çalışmaları yapmakta kullanılan Feedback firmasına ait iki serbestlik dereceli bir sistemdir [10]. Sistem dinamikleri açısından doğrusal olmayan özelliklere sahiptir. TRMS sistemi kule, serbest çubuk ve denge çubuğundan oluşmaktadır. Serbest çubuğun iki ucunda birbirine dik pervaneler bulunmaktadır. DC motorlar ile sürülen bu pervanelerin ürettiği kuvvet sistemim yatay ve dikey eksenlerdeki hareketi sağlar. Sistemin hareketli gövdesinin yatay ve düşey eksenlerle yaptığı açılar motor terminal gerilimlerinin değiştirilmesi ile kontrol edilir. Sistemin gerçek zaman görünüşü Şekil 1(a). ile verilmiştir.

Sistemin dikey düzlem dinamik denklemleri Denklem (1)-(6) ile ifade edilmektedir [7]. Sistem parametreleri Tablo 1. ile verilmiştir.

$$\frac{dw_m}{dt} = \frac{K_{av}K_1u_1}{R_{av}J_{mv}} - \frac{K_{av}K_{bv}w_m}{R_{av}J_{mv}} - \frac{B_{mv}w_m}{J_{mv}} - \frac{T_{ym}(\omega_m)}{J_{mv}} \quad (1)$$

$$\frac{d\Omega_v}{dt} = \frac{l_m F_v(\omega_m) - k_{vfv}\Omega_v - g(mr_1l_{r1} \cos(\alpha_v) + mr_2l_{r2} \sin(\alpha_v))}{(J_1 + J_2)} \quad (2)$$

$$\frac{d\alpha_v}{dt} = \Omega_v \quad (3)$$


$$T_{ym} = \begin{cases} k_{tvp}\omega_m|\omega_m| & \omega_m \geq 0 \\ k_{tvn}\omega_m|\omega_m| & \omega_m < 0 \end{cases} \quad (4)$$

$$F_v = \begin{cases} k_{fvp}\omega_m|\omega_m| & \omega_m \geq 0 \\ k_{fvn}\omega_m|\omega_m| & \omega_m < 0 \end{cases} \quad (5)$$

$$y = \alpha_v \quad (6)$$



(a)



(b)

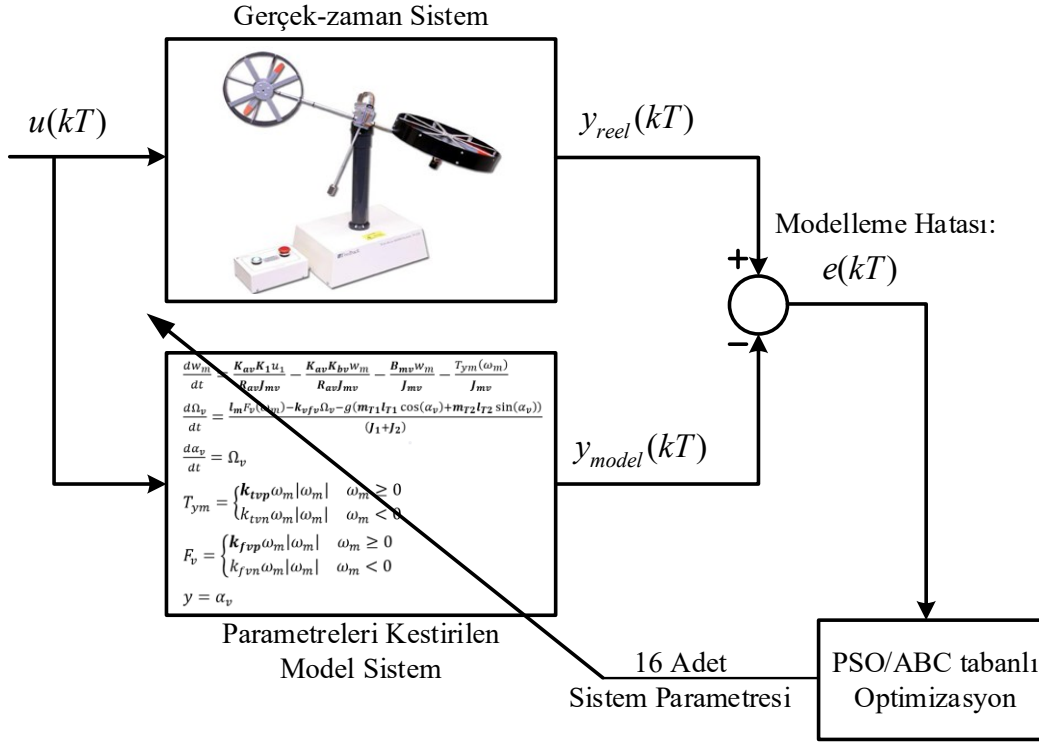
Şekil 1. Çift Pervaneli Sistem (a), Sistemin serbest cisim gösterimi (b)

Tablo 1. Sistem Parametreleri

B_{mv}	Ana motor viskoz sürtünme katsayısı ($kg\ m^2/s$)	l_m	Serbest çubuk ana bölüm uzunluğu(m)
F_v	Pervanenin ürettiği kuvvet (N)	l_{T1}	Serbest çubuğun ağırlık merkezi (m)
g	Yer çekimi ivmesi (m/s^2)	l_{T2}	Denge çubuğunun ağırlık merkezi (m)
J_1	Serbest çubuğun atalet momenti ($kg\ m^2$)	m_{T1}	Serbest çubuğun toplam kütlesi (kg)
J_2	Denge çubuğunun atalet momenti ($kg\ m^2$)	m_{T2}	Denge çubuğunun toplam kütlesi (kg)
J_{mv}	Ana DC motor atalet momenti ($kg\ m^2$)	R_{av}	Ana motor armatür direnci (Ω)
K_{bv}	Ana motor ters elektromotor sabiti(Vs/rad)	T_{ym}	Ana motor yük momenti
K_1	Ara yüz devre kazancı (V/V)	u_1	Giriş
K_{av}	Ana motor akım kazancı (Nm/A)	w_m	Ana motor dönme hızı (rad/s)
k_{vfv}	Viskoz sürtünme katsayısı ($kg\ m^2/s$)	y	Çıkış
$k_{fvp/fvn}$	Ana pervane yük momenti kazancı	Ω_v	Mesnet etrafında dönme açısal hızı (rad/s)
$k_{tvp/tvn}$	Ana pervane kuvvet kazancı	α_v	Yatay ile yapılan açı (rad)

2.2. Optimizasyon Şeması

Önceki başlık altında anlatılan sistemin gerçek zamanda çalıştırılmasından elde edilen belli bir deneysel giriş zaman serisine karşılık çıkış zaman serisi ile giriş ve çıkış arasındaki dinamik ilişkiyi yararlanılarak sistemin daha önce Denklem (1)-(6)'da verilen dinamik denklemlerindeki koyu yazı tipi ile işaretlenen on altı tane sistem parametresinin sezgisel optimizasyon teknikleriyle



Şekil 2. PSO ve ABC tabanlı parametre kestirimi optimizasyon şeması


tahmininin yapılması amaçlanmaktadır. Bu amaçla deneysel ortamda uygulanan belli bir girişe $u(kT)$ karşılık gelen ana motor çıkışı gerçek/reel çıkış y_{reel} olarak kaydedilmiştir. Kullanılan sezgisel optimizasyon yöntemlerinden PSO ve ABC ile elde edilen parametrelerden oluşan sisteme de aynı giriş uygulanarak dinamik denklemler kullanılıp model çıkışı y_{model} elde edilmiştir. Bahsi edilenler Şekil 2’de optimizasyon şeması şeklinde görselleştirilmiştir. Burada $e(kT)$ modelleme hatasıdır ve bu hata parametreler en uygun seçilerek en az yapılmak istenmektedir.

Parametre kestirimi için optimizasyonda kullanılacak maliyet fonksiyonu modelleme karesel hatasının integrali (ISE) kriteri ile Denklem (7)’deki gibi ifade edilebilir. Bu maliyet fonksiyonunu en küçük yapacak sistem parametre değerlerinin PSO ve ABC sezgisel optimizasyon yöntemleriyle bulunması amaçlanmaktadır.

$$J = \sum_{k=1}^N (y_{reel}[kT] - y_{model}[kT])^2 \quad (7)$$

2.3 PSO Algoritması

Parçacık Sürü Optimizasyonu (PSO) ortak ve en iyi fayda için sürü davranışı gösteren canlıların sürü içinde bireysel hareketleri ile etkileşim halinde oldukları diğer sürü elemanlarıyla olan ilişkisel hareketlerinden esinlenilmiş bir arama algoritmasıdır ve optimizasyon problemlerinde yaygın olarak kullanılmaktadır [11]. Bu algoritma üzerine birçok yaklaşım önerilmiştir. Literatürde standart PSO yerine yakınsamayı garanti edecek şekilde Kısıtlanmış (Constricted) PSO [11]



Şekil 3. Sürü komşuluk topolojileri: yıldız (solda), halka (sağda) [12]

Tablo 2. Sistem parametre kestirimi için PSO algoritması detaylı sözde kodu

Gerçek sisteme uygulanan giriş $u(kT)$ ve buna karşılık elde edilen sistem çıkışı $y_{reel}(kT)$ yükü.

Model sistem parametrelerine (ρ_d , $d = 1,2, \dots, 16$) ait başlangıç değerlerini yükü.

Sistemi ifade eden dinamik denklemler ve $u(kT)$ kullanarak $y_{model}(kT)$ elde et.

Her bir sistem parametresi için başlangıç değerleri etrafında çalışma uzayı belirle.

Sürü büyüklüğü/parçacık sayısı ve iterasyon sayısı seç. N : komşu sayısı (L_{best} yöntemi için) seç.

Parçacıkların başlangıç konumlarını belirlenen çalışma uzayında rastgele dağılım ile ata.

Parçacık başlangıç hızlarını sıfır al. Hız engelleme için V_{max} belirle.

c_1 bilişsel ivme sabiti ve c_2 sosyal ivme sabiti ($c_1 + c_2 > 4$) belirle, χ hesapla.

Başlangıç maliyet fonksiyonu değerini ve en iyi çözümü elde et.

Döngü (belirlenen iterasyon sayısınca) (n : mevcut iterasyon sayısı)

Döngü (her parçacık için) (i : mevcut parçacık)

Parçacığın tuttuğu konumları (x_{id}) sistem parametrelerine ata ($\rho_d \leftarrow x_{id}^{(n)}$, $d = 1,2, \dots, 16$)

$u(kT)$ için dinamik denklemleri kullanarak sistem modeli çıkışını $y_{model}(kT)$ elde et.

Maliyet fonksiyonu değerini hesapla $J_i^{(n)} = \sum_{k=1}^N [y_{reel}[kT] - y_{model}[kT]]^2$

IF $J_i^{(n)} < p_{id}$ ($x_{id}^{(n)}$ i . Parçacık için en iyi uygunluk değerini verdi mi?)

Uygunluk değerini kaydet. P_{best} güncelle. $p_{id} \leftarrow x_{id}$

endif

G_{best} : P_{best} 'lerin en iyi uygunluk değeri verenini G_{best} (p_{Gd}) (global) seç.

L_{best} : $2N$ komşuluktaki P_{best} 'lerin en iyi uygunluk değeri verenini L_{best} (p_{Ld}) (lokal) seç.

Döngü (her parametre için) (d : mevcut parametre)

r_{1d} ve r_{2d} $[0,1]$ arasında rastgele seç.

G_{best} : Parçacığa ait hızı güncelle. $v_{id}^{(n+1)} = \chi (v_{id}^{(n)} + c_1 r_{1d} (p_{id} - x_{id}^{(n)}) + c_2 r_{2d} (p_{Gd} - x_{id}^{(n)}))$

L_{best} : Parçacığa ait hızı güncelle. $v_{id}^{(n+1)} = \chi (v_{id}^{(n)} + c_1 r_{1d} (p_{id} - x_{id}^{(n)}) + c_2 r_{2d} (p_{Ld} - x_{id}^{(n)}))$

Hızın V_{max} değerini geçmesini engelle. $v_{id}^{(n+1)} = \text{sign}(v_{id}^{(n+1)}) \cdot \min(\text{abs}(v_{id}^{(n+1)}), V_{max})$

Parçacığa ait konumu güncelle. $x_{id}^{(n+1)} = x_{id}^{(n)} + v_{id}^{(n+1)}$

Döngü Sonu (d)

Döngü Sonu (i)

Grafik çizdirme amaçlı iterasyona bağlı algoritma gelişimini kayıt altına al.

Döngü Sonu (n)

önerilmektedir. Bu yöntemdeki temel farklılık parçacık hızının güncellenmesinde ve ilgili parametrelerin doğru aralıkta belirlenmesindedir. Kısıtlanmış PSO için parçacık güncelleme ifadesi Denklem (8) ile verilmiştir. Buradaki parametreler ve kullanımları Tablo 2’deki sözde kod ile detaylı olarak verilmiştir.

$$v_{id}^{(n+1)} = \chi \left(v_{id}^{(n)} + c_1 r_{1d} (p_{id} - x_{id}^{(n)}) + c_1 r_{1d} (p_{Gd} - x_{id}^{(n)}) \right) \quad (8)$$

$$v_{id}^{(n+1)} = \chi \left(v_{id}^{(n)} + c_1 r_{1d} (p_{id} - x_{id}^{(n)}) + c_1 r_{1d} (p_{Ld} - x_{id}^{(n)}) \right) \quad (9)$$

Ayrıca algoritmada sürü içindeki sosyal ilişki yapısını temsil eden topoloji türlerinden G_{best} yıldız topolojisine ilaveten L_{best} halka topolojisi karşılaştırma amaçlı ayrı ayrı ele alınmıştır. L_{best} halka topolojisi için hız güncelleme ifadesi Denklem (9) şeklinde alınmıştır. Bu yaklaşımda tüm sürüdeki global en iyi çözüm ifadesi (p_{Gd}) yerine belli sayıdaki komşu parçacıklar arasındaki en iyi çözüm ifadesi (p_{Ld}) kullanılır [12]. Bahsi edilen sürüdeki sosyal ilişki topolojilerinin temsili Şekil 3’te verilmiştir.

PSO’da bir diğer yaklaşım ise parçacıkların çalışma uzayı dışına süratle çıkmasını engellemek adına Velocity Clamping adı verilen V_{max} ile hız sınırlama/engelleme yöntemidir [13], [14]. Bu amaçla parçacık hız güncelleme işleminin ardından Denklem (10) ifadesi ile hız sınırlanmaktadır.

$$v_{id}^{(n+1)} = \text{sign} \left(v_{id}^{(n+1)} \right) \cdot \min \left(\text{abs} \left(v_{id}^{(n+1)} \right), V_{max} \right) \quad (10)$$

Tipik olarak PSO yönteminde her bir yeni iterasyonda parçacıkların yeni konumları ise hıza bağlı olarak Denklem (11) ifadesi ile hesap edilir.

$$x_{id}^{(n+1)} = x_{id}^{(n)} + v_{id}^{(n+1)} \quad (11)$$

Buraya kadar verilen bilgiler ışığında TRMS sistemine yönelik parametre kestirimi problemine uyarlanmış PSO algoritmasına dair kapsamlı sözde kod Tablo 2’de verilmiştir.

2.4 ABC Algoritması

Yapay Arı Kolonisi (ABC) optimizasyon algoritması, arı kolonilerinde en kaliteli nektar kaynaklarının tespitinde çalışan görevli, gözcü ve kâşif şeklinde 3 tip görev sınıfında arı olduğunu varsayan ve arıların bireysel hareket ve etkileşimsel davranışlarından esinlenen sezgisel bir yöntemdir. Algoritmanın temel adımları Tablo 3’te verilmiştir [15].

Tablo 3. ABC algoritması temel adımları [15]

Başlangıç/Ayar Fazı
Döngü (Toplam iterasyon sayısı kadar)
Görevli Arı Fazı
Gözcü Arı Fazı
Kâşif Arı Fazı
Bulunan Sonuçların Kaydı
Döngü Sonu

Ele aldığımız optimizasyon problemi olan TRMS parametre kestirimine yönelik olarak uyarlanan ABC algoritmasının kapsamlı sözde kodu Tablo 4’te verilmiştir.

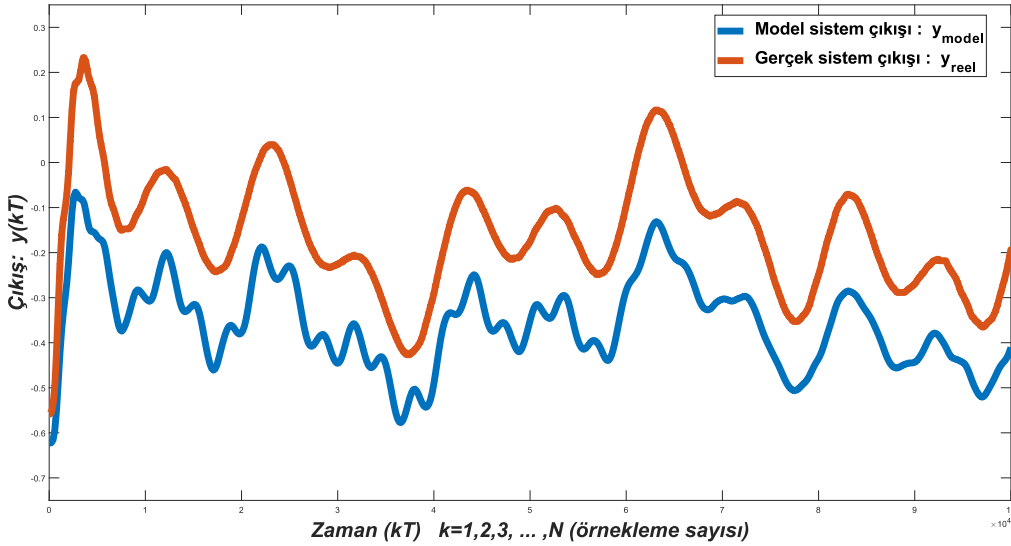
Tablo 4. Sistem parametre kestirimi için ABC algoritması detaylı sözde kodu

Gerçek sisteme uygulanan giriş $u(kT)$ ve buna karşılık gelen sistem çıkışı $y_{reel}(kT)$ yükle.
 Model sistem parametrelerine (ρ_d , $d = 1,2, \dots, 16$) ait başlangıç değerlerini yükle.
 Sistemi ifade eden dinamik denklemler ve $u(kT)$ kullanarak $y_{model}(kT)$ elde et.
 Her bir sistem parametresi için başlangıç değerleri etrafında çalışma uzayı belirle.
 Koloni büyüklüğü ve iterasyon sayısı seç. L : gelişememe limiti belirle.
 Nektar kaynağı başlangıç konumlarını belirlenen çalışma uzayında rastgele dağılım ile ata.
 Başlangıç maliyet fonksiyonu değerini ve en iyi çözümü elde et.
Döngü (belirlenen iterasyon sayısına) (n : mevcut iterasyon sayısı)
 // Görevli Arı Fazı:
Döngü (her nektar kaynağı için) (i : mevcut nektar kaynağı)
 Görevli arı i . nektar kaynağı konumundan rastgele belirlenen k . nektar kaynağı konumuna yaklaşmak veya uzaklaşmak suretiyle yeni konuma gider. $x_{id}^{(n)} = x_{id}^{(n-1)} + \phi_{id}(x_{id}^{(n-1)} - x_{kd}^{(n-1)})$
 Nektar kaynağı konumlarını (x_{id}) sistem parametrelerine ata ($\rho_d \leftarrow x_{id}^{(n)}$, $d = 1,2, \dots, 16$)
 $u(kT)$ için dinamik denklemleri kullanarak sistem modeli çıkışını $y_{model}(kT)$ elde et.
 Maliyet fonksiyonu değerini hesapla $J_i^{(n)} = \sum_{k=1}^N [y_{reel}[kT] - y_{model}[kT]]^2$
IF $J_i^{(n)} < p_{id}$ ($x_{id}^{(n)}$ ile i . Nektar kaynağı gelişim sağladı mı?)
 Öncekini bırakıp, yeni kaynağı benimse ve i . Nektar için en iyi çözüm güncelle. $p_{id} \leftarrow x_{id}$
elseIF
 $C_i = C_i + 1$ i . Nektar kaynağı için gelişememe değerini bir artır.
endIF
Döngü Sonu (i)
 // Gözcü Arı Fazı:
 Maliyet değerlerinden uygunluk değerleri elde edilir. $fit_i = \begin{cases} \frac{1}{1+J_i}, & J_i \geq 0 \\ 1 + abs(J_i), & J_i < 0 \end{cases}$
 Olasılıklar elde edilir. $P_i = \frac{fit_i}{\sum_{i=1}^m fit_i}$
Döngü (her gözcü arı için) (m : mevcut gözcü arı)
 Rulet tekerleği ile i . nektar kaynağı olasılıksal olarak seçilir. Gözcü arı görevli arı olur.
 Görevli arı i . nektar kaynağı konumundan rastgele belirlenen k . nektar kaynağı konumuna yaklaşmak veya uzaklaşmak suretiyle yeni konuma gider. $x_{id}^{(n)} = x_{id}^{(n-1)} + \phi_{id}(x_{id}^{(n-1)} - x_{kd}^{(n-1)})$
 Nektar kaynağı konumlarını (x_{id}) sistem parametrelerine ata ($\rho_d \leftarrow x_{id}^{(n)}$, $d = 1,2, \dots, 16$)
 $u(kT)$ için dinamik denklemleri kullanarak sistem modeli çıkışını $y_{model}(kT)$ elde et.
 Maliyet fonksiyonu değerini hesapla $J_i^{(n)} = \sum_{k=1}^N [y_{reel}[kT] - y_{model}[kT]]^2$
IF $J_i^{(n)} < p_{id}$ ($x_{id}^{(n)}$ ile i . Nektar kaynağı gelişim sağladı mı?)
 Öncekini bırakıp, yeni kaynağı benimse ve i . Nektar için en iyi çözüm güncelle. $p_{id} \leftarrow x_{id}$
elseIF
 $C_i = C_i + 1$ i . Nektar kaynağı için gelişememe değerini bir artır.
endIF
Döngü Sonu (m)
 // Kâşif Arı Fazı:
 L : gelişememe limitini dolduran her görevli arı kâşif arıya dönüşüp çalışma uzayı içerisinde rastgele nektar kaynaklarına gider ve maliyet değerleri J_i güncellenir, gelişememe sayaçları C_i sıfırlanır.
 Grafik çizdirme amaçlı iterasyona bağlı algoritma gelişimini kayıt altına alınır.
Döngü Sonu (n)

3. Sonular

TRMS sistemine ait model parametrelerinin belirlenmesinde verilen sezgisel optimizasyon algoritmaları 300 ve 1000 iterasyon olmak üzere iki farklı senaryoda işletilmiştir. Algoritmaların her biri 10 sefer 300 iterasyon ve 10 sefer 1000 iterasyon yapacak şekilde koşturulmuştur. Her algoritmanın adil değerlendirilebilmesi amacıyla popülasyonlarının başlangıta aldıkları rastgele deęerler ortak tutulmuştur. Algoritmalara ait alıřma parametreleri için PSO yöntemlerinde popülasyon büyüklüęü (paracık sayısı) 50 paracık olarak alınmış, halka topoloji Lbest-PSO yönteminde komşuluk sayısı 10 seçilmiştir. ABC yönteminde koloni boyutu benzer şekilde 50 arı belirlenmiştir. Uygulamalar Intel i5-8400 4.0 GHz işlemci, 16 GB RAM bellek ve 512 GB SSD hafıza şeklinde sistem özellikleri olan bir bilgisayarda yürütülmüştür.


Optimizasyona dayalı algoritmalarının uygulanması öncesinde parametre kestirimi algoritmalarına girdi olacak sistem giriş ve buna karşılık gözlenen sistem ıkışı deęer dizileri şeklinde belirli bir örnekleme ile gerçek sistemin baęlı bulunduğu bilgisayarda kayıt altına alınmıştır. Bunlar gerçek-zaman sistem giriş ve ıkışlarıdır. Aynı girişin sürekli-zaman dinamik denklemlerin ayrıklaştırılması ve parametre başlangı deęerleri kullanılması yoluyla model sisteme uygulanması ile model sistem ıkışı elde edilmiştir. Modelden elde edilecek ıkış ile daha önce kaydedilen gerçek-zaman sistem ıkışı arasındaki fark (modelleme hatası) tespit edilmiştir. Gerçek parametre deęerleri kestirilmek istenen sistem modelinin ilk kořullar için elde edilen ıkış grafięi ile gerçek-zaman sistemin ıkış grafięi Şekil 4'te verilmiştir. Görüldüęü üzere parametre deęerleri gerçek alıřma kořullarına uygun olacak biçimde doęru belirlenemedięi durumda modelleme hatası oluşmaktadır. Asıl sistem model tarafından hassas derecede iyi temsil edilememektedir. Burada görülen modelleme hatasını minimum yapacak şekilde model parametreleri optimizasyona dayalı bulunmuş, kullanılan optimizasyon yöntemlerinin başarımı karşılaştırılmalı olarak ařaęıda sunulmuştur.



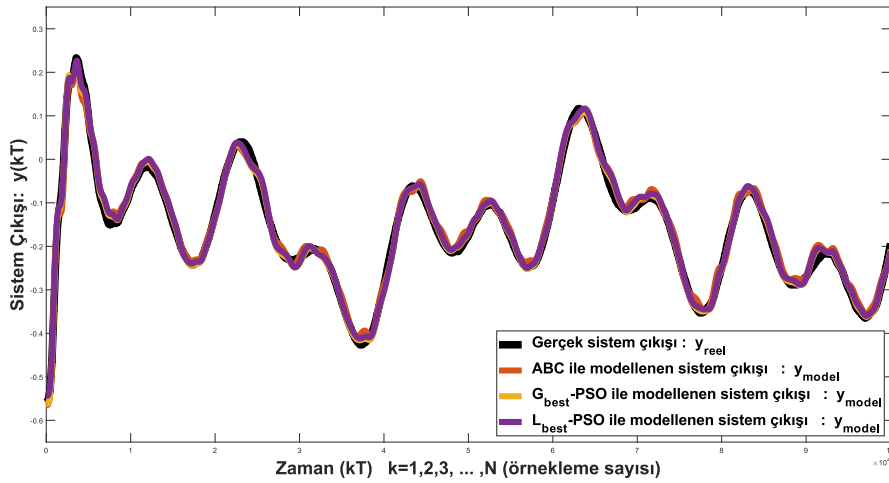
Şekil 4. Optimizasyon öncesi model sistem ile gerçek sistem ıkışları

İlgilenilen TRMS parametre kestirimi optimizasyon problemine yönelik olarak PSO ve ABC sezgisel yöntemlerinin sonuç çıktılarında performansa dair en belirleyici olanı, iterasyonlar boyunca ve sonunda en iyi çözüm üretilmesine dair uygunluk değeri gelişimi grafiği 300 iterasyon için Şekil 5’de verilmiştir. Grafikte açıkça görüldüğü üzere en iyi çözümü PSO yöntemi vermiştir. Gbest-PSO yaklaşımı Lbest-PSO yaklaşımına göre az bir farkla daha iyi sonuç vermesinin yanı sıra görece daha hızlı yakınsamaktadır. ABC yöntemi de hızlı yakınsama göstermesine karşın ürettiği çözümü iterasyonlar boyunca geliştirememiştir.

Gerçekleştirilen parametre kestirim optimizasyonları sonucunda model sistem ile gerçek sistem çıkışlarının birlikte gösterimine dair grafikler kullanılan yöntemlere göre Şekil 6’da gösterilmektedir. Uygulanan tüm yöntemlerin sonucunda da tatmin edici şekilde gerçek sistem çıkışı ile örtüşen model sistem çıkışını sağlayan sistem parametreleri tahmin etmiştir. Ancak özellikle ABC ve halka topoloji ile çalışan Lbest-PSO yöntemlerine kıyasla yıldız topoloji ile çalışan Gbest-PSO yönteminden elde edilen sistem modeli, gerçek sistem davranışını daha yakın takip etmiştir.




Şekil 5. Ele alınan yöntemlerin iterasyonlar boyunca maliyet fonksiyonu değeri gelişimi

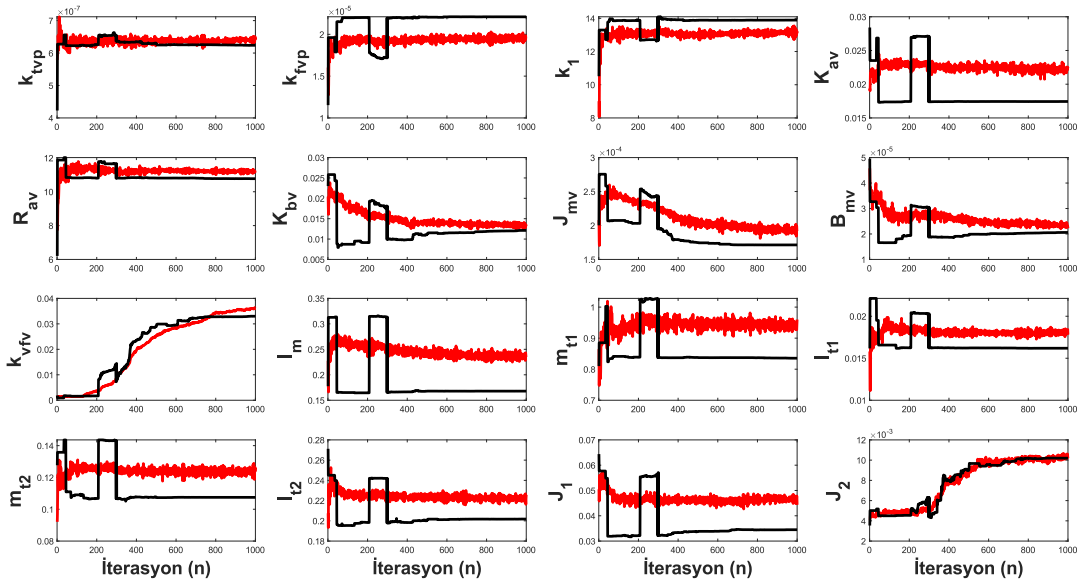


Şekil 6. Parametreleri optimizasyon ile kestirilen model sistemlerin çıkış takip performansı

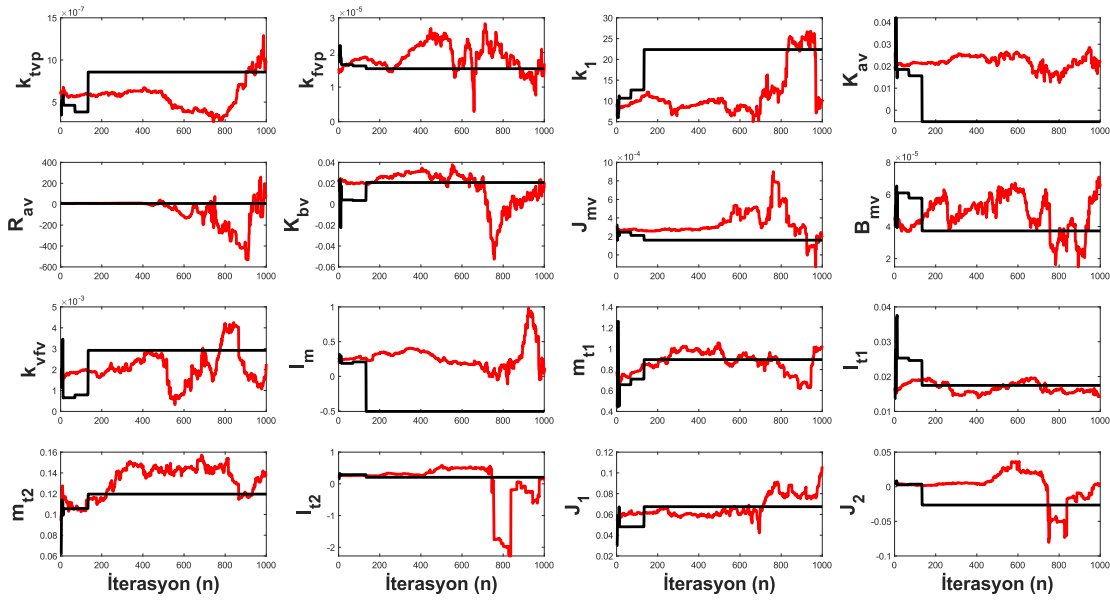
Model sisteme ait parametre değerlerinin en iyi çözümü vereni ile tüm popülasyon ortalamasının 1000 iterasyon boyunca değişimi Şekil 7, Şekil 8 ve Şekil 9’da kullanılan 3 yöntem için sırasıyla verilmiştir. Gbest-PSO yönteminde parametre ortalamalarının en iyi çözümü takip ettiği başka bir deyişle tüm sürünün iterasyonlar boyunca optimum noktaya çok dağılmadan ilerlediği görülmektedir. Lbest-PSO yönteminde ise parametre değerleri daha geniş bir dağılım göstermekte ve daha homojen ama yavaş bir arama yapılmaktadır. ABC yönteminde de Lbest-PSO yöntemine benzer bir koloni dağılımı gerçekleşmekte genel itibariyle parametre değerlerinin gelişimi durağandır.



Şekil 7. Sistem parametrelerinin popülasyon ortalama ve en iyi değerleri değişimi (Gbest-PSO)



Şekil 8. Sistem parametrelerinin popülasyon ortalama ve en iyi değerleri değişimi (Lbest-PSO)



Şekil 9. Sistem parametrelerinin popülasyon ortalama ve en iyi değerleri değişimi (ABC)

Ele alınan sezgisel yöntemlerde çıktılar rastgele seçilen başlangıç koşullarından etkilendiğinden yöntemleri birbiri arasında kıyaslayabilmek için her bir yöntem birbiriyle aynı ve her bir seferde farklı rastgele başlangıç koşulları olacak şekilde 10 defa tekrarlanarak ortalama başarımlar ve hesap maliyetleri elde edilmiş olup Tablo 5'te özetlenmiştir. 1000 iterasyon için tartışmasız Gbest-PSO yöntemi tüm başarımlar ölçütlerinde en iyi sonucu vermiştir. 300 iterasyonda ise Gbest-PSO yöntemi hızlı yakınsama özelliği ile beklenildiği üzere daha iyi sonuç elde etmiştir.

Tablo 5. Kullanılan optimizasyon yöntemlerinin karşılaştırmalı başarımları

	G _{best} -PSO		L _{best} -PSO		ABC		
Çalıştırma sayısı	10	10	10	10	10	10	-
İterasyon sayısı	300	1000	300	1000	300	1000	2000
Popülasyon/Koloni büyüklüğü	50	50	50	50	50	50	50
Ulaşılan en iyi maliyet fonksiyonu değeri	8.37	7.6371	9.27	7.6387	19.29	19.29	19.09
Ulaşılan en iyi maliyetlerin ortalaması	12	7.66	12.43	7.9	33.43	27.71	28.53
En iyi maliyetlerin standart sapması	4.62	0.03	2.23	0.27	10.61	7.29	5.95
Ortalama hesap süresi (s)	125	475.57	129.4	483.28	302.96	1079.6	1568.4

Lbest-PSO yöntemi çalışma uzayına daha iyi dağılma ve yerel ekstremumlara daha az takılma özelliği ile 300 iterasyonda maliyetlerin standart sapmasının düşüklüğü ile daha kararlı/tutarlı davranış göstererek genel olarak oldukça kabul edilebilir sonuçlar verirken ABC yöntemi nispeten

daha kötü başarımlar gösterip hesap maliyeti de aynı iterasyon sayısında PSO yöntemlerinden yaklaşık 3 kat daha fazladır. ABC yöntemi tabloda verildiği üzere 2000 iterasyon da yapılırsa istenen oranda gelişim gösterememiştir. Buna rağmen tüm bu kullanılan sezgisel optimizasyon yöntemlerinin TRMS sistemine yönelik model parametrelerinin tahmininde elverişli olduğu görülmüştür.

4. Tartışma

İlgilenilen TRMS parametre tahmini optimizasyon problemine yönelik olarak PSO ve ABC sezgisel yöntemlerinin sonuç çıktıları oldukça tatmin edici olarak karşımıza çıkmıştır. Sonuçlara karşılaştırmalı olarak bakıldığında ise TRMS sisteminin sezgisel optimizasyon tabanlı parametre tahmini uygulamasında PSO yöntemi ABC yöntemine göre genel olarak daha üstün bir performans vermiştir. ABC yöntemine göre PSO yönteminde tahmin edilen parametrelere bağlı geliştirilen model sistemin çıkışının gerçek sistem çıkışını daha küçük bir hata ile yakaladığı/takip ettiği görülmüştür. Ayrıca bu yöntemin hesap maliyeti nispeten düşüktür. PSO yaklaşımları arasında ise G_{best} yani yıldız topolojisindeki komşuluk yapısı bu problem için görece daha iyi sonuçlar vermiştir.

Bu çalışmada ilgilenilen sistemin düşey ekseninde yaptığı hareket ve buna karşılık gelen sistem parametreleri tahmin edilmiştir. Sistemin düşey, yatay ve iki hareketin birlikte gerçekleşmesine karşılık gelen diğer sistem parametrelerinin tahmin edilmesi gelecek bir çalışma olarak irdelenebilir.

Referanslar

- [1] A. Ozdemir, I. Mucuk, and S. Ilhan, 'Çift Pervaneli Çok Girişli Çok Çıkışlı (TRMS) Sistemin Kontrolü için Ayrık Zaman PID Kontrolör Tasarımı ve Gerçek Zaman Uygulaması', Acad. Perspect. Procedia, vol. 3, no. 1, pp. 597–608, 2020, doi: 10.33793/acperpro.03.01.113.
- [2] P. Chalupa, J. Přikryl, and J. Novák, 'Modelling of twin rotor MIMO system', Procedia Eng., vol. 100, no. January, pp. 249–258, 2015, doi: 10.1016/j.proeng.2015.01.365.
- [3] A. V. Joseph and S. P. Arjunan, 'Comparative Analysis of Parameter Estimation Techniques for Modelling a Twin Rotor MIMO System', 2019 3rd Int. Conf. Recent Dev. Control. Autom. Power Eng. RDCAPE 2019, pp. 704–709, 2019, doi: 10.1109/RDCAPE47089.2019.8979083.
- [4] B. Subudhi and D. Jena, 'Nonlinear system identification of a twin rotor MIMO system', IEEE Reg. 10 Annu. Int. Conf. Proceedings/TENCON, pp. 1–6, 2009, doi: 10.1109/TENCON.2009.5395966.
- [5] S. F. Toha, I. Abd Latiff, M. Mohamad, and M. O. Tokhi, 'Parametric modelling of a TRMS using dynamic spread factor particle swarm optimisation', 11th Int. Conf. Comput. Model.

- Simulation, UKSim 2009, pp. 95–100, 2009, doi: 10.1109/UKSIM.2009.109.
- [6] S. F. Toha and M. O. Tokhi, ‘ANFIS modelling of a twin rotor system using particle swarm optimisation and RLS’, 2010 IEEE 9th Int. Conf. Cybern. Intell. Syst. CIS 2010, 2010, doi: 10.1109/UKRICIS.2010.5898130.
- [7] T. Dang Huu and I. B. Ismail, ‘Modelling of Twin Rotor MIMO system’, 2016 2nd IEEE Int. Symp. Robot. Manuf. Autom. ROMA 2016, 2017, doi: 10.1109/ROMA.2016.7847803.
- [8] A. Rahideh and M. H. Shaheed, ‘Grey-box modelling of a non-linear aerodynamic system using genetic algorithms’, Proc. Inst. Mech. Eng. Part G J. Aerosp. Eng., vol. 225, no. 8, pp. 863–873, 2011, doi: 10.1177/0954410011403817.
- [9] S. F. Toha, S. Julai, and M. O. Tokhi, ‘Ant colony based model prediction of a twin rotor system’, Procedia Eng., vol. 41, no. November 2015, pp. 1135–1144, 2012, doi: 10.1016/j.proeng.2012.07.293.
- [10] Feedback Instruments Ltd, ‘Twin Rotor MIMO System Control Experiments 33- 949S Laboratory Manual’, U.K., p. 46, 2005, [Online]. Available: <http://www.cpdee.ufmg.br/~palhares/33-942rotor.pdf>.
- [11] G. Nápoles, I. Grau, and R. Bello, ‘Constricted Particle Swarm Optimization based Algorithm for Global Optimization’, Polibits, vol. 46, no. 46, pp. 5–11, 2012, doi: 10.17562/pb-46-1.
- [12] D. Bratton and J. Kennedy, ‘Defining a standard for particle swarm optimization’, Proc. 2007 IEEE Swarm Intell. Symp. SIS 2007, no. Sis, pp. 120–127, 2007, doi: 10.1109/SIS.2007.368035.
- [13] M. Clerc and J. Kennedy, ‘The particle swarm-explosion, stability, and convergence in a multidimensional complex space’, IEEE Trans. Evol. Comput., vol. 6, no. 1, pp. 58–73, 2002, doi: 10.1109/4235.985692.
- [14] R. C. Eberhart and Y. Shi, ‘Comparing inertia weights and constriction factors in particle swarm optimization’, Proc. 2000 Congr. Evol. Comput. CEC 2000, vol. 1, no. February 2015, pp. 84–88, 2000, doi: 10.1109/CEC.2000.870279.
- [15] D. Karaboga and B. Basturk, ‘Artificial Bee Colony (ABC) optimization algorithm for solving constrained optimization problems’, Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics), vol. 4529 LNAI, no. December, pp. 789–798, 2007, doi: 10.1007/978-3-540-72950-1_77.