Primjena PSO algoritma u estimaciji parametara transformatora

DANILO S. MUJIČIĆ, Elektprivreda Crne Gore, Nikšić, Crna Gora

MARTIN P. ČALASAN, Univerzitet Crne Gore,

Elektrotehnički fakultet, Podgorica, Crna Gora

MILOVAN V. RADULOVIĆ, Univerzitet Crne Gore,

Elektrotehnički fakultet, Podgorica, Crna Gora

Stručni rad

UDC: 621.314.222.6

DOI: 10.5937/tehnika1902251M

U ovom radu je razmatrana upotreba Particle Swarm Optimization algoritma u estimaciji parametara transformatora. Estimirani parametri zamjenske šeme rezultat su procesa minimizacije razlike između estimiranih i izmjerenih vrijednosti odgovarajućih električnih veličina. U cilju određivanja parametara transformatora korišćene su vrijednosti struje primara i vrijednosti napona i struje sekundara. Dobijeni rezultati upoređeni su sa rezultatima dobijenim pomoću klasične metode za određivanje parametara mašine, a koja se bazira na izvođenju oglada praznog hoda i kratkog spoja. Zaključeno je da PSO algoritam predstavlja veoma efikasan metod za estimaciju parametara transformatora.

Ključne riječi: transformator, zamjenska šema, parametri, PSO algoritam

1. UVOD

Transformatori snage značajan su segment bilo koje prenosne ili distributivne mreže. Samim tim, pravilno funkcionisanje ovih uređaja neophodno je radi pravilnog funkcionisanja elektroenergetskog sistema u cjelini [1]. Usljed djelovanja raznih faktora, dolazi do degradacije određenih komponenti transformatora i njegove performanse, vremenom, postaju slabije. Iz tog razloga, procjena stanja pojedinih komponenti poželjna je kako bi se osiguralo odsustvo kvarova ili kako bi se određene intervencije mogle unaprijed planirati.

Parametri zamjenske šeme transformatora, mogu se odrediti sprovođenjem standardnih eksperimentalnih postupaka, koji se baziraju na izvođenju oglada praznog hoda i kratkog spoja, kako nalažu IEEE odrednice [2]. Međutim, primjena ovih metoda podrazumjeva isključenje transformatora sa mreže. Zbog ovih nepovoljnosti, značajan trud se ulaže ka razvoju metoda koje omogućavaju estimaciju parametara transformatora bez potrebe izlaska iz pogonskog stanja.

Jedan pristup rješavanju ovog problema, orijentisan je ka upotrebi podataka sa natpisne pločice transfo-

rmatora, u cilju određivanja parametara zamjenske šeme [3]. Nedostaci ovog pristupa ogledaju se u činjenici da se tokom rada mašine, usljed ambijentalnih ili nekih drugih faktora, njene karakteristike mogu izmjeniti. Promjene u izolacionom materijalu, promjene provodnosti namotaja, samo su neki primjeri izmjena koje mogu uticati na karakteristike mašine. Sve te promjene praćene su promjenama vrijednosti parametara zamjenske šeme transformatora. Zbog toga, prednost imaju metode koje se zasnivaju na upotrebi podataka dobijenih mjerenjem odgovarajućih električnih veličina, tokom normalnog rada transformatora.

Kroz literaturu, razmotrene su primjene brojnih metaheurističkih metoda i algoritama, sa ciljem određivanja parametara zamjenske šeme transformatora, uz pristup orijentisan ka upotrebi podataka dobijenih mjerenjem. Tako se u [4,5] predlaže upotreba BF (Bacterial Foraging) metode u cilju estimacije parametara mašine, dok se u [6,7] koristi PSO (Particle Swarm Optimization) algoritam. Upotreba genetskog algoritma GA (Genetic Algorithm), u istom cilju, razmotrena je u [8, 9], dok se u [10] koristi MOABC (Multi-Objective Artificial Bee Colony) optimizacija.

U ovom radu je analizirana primjena PSO algoritma na problem estimacije parametara zamjenske šeme transformatora. Najprije je izložen model transformatora, tj. njegova egzaktna zamjenska šema, uz odgovarajuće matematičke relacije koje se vezuju za pomenutu šemu. Nakon toga je, u kratkim crtama, opisana ideja na kojoj počiva PSO algoritam. Primjena

Adresa autora: Danilo Mujičić, Elektprivreda Crne Gore, Nikšić, Vuka Karadžića 2, Crna Gora

e-mail: daco2206@gmail.com

Rad primljen: 22.11.2018.

Rad prihvaćen: 31.01.2019.

samog algoritma izložena je u poglavlju 4. Poglavlja 5 i 6 posvećena su analizi rezultata ostvarenih primjenom klasične metode koja se bazira na sprovođenju oglada praznog hoda i kratkog spoja, i poređenju tih rezultata sa onim koji se dobijaju primjenom PSO optimizacije. Štaviše, upoređeni su i odgovarajući talasni oblici dobijeni simulacijama koje uvažavaju rezultate jedne i druge metode, sa strujnim i naponskim talasnim oblicima, snimljenim u laboratoriji. Time se nudi značajan uvid u mogućnosti koje pruža primjena ovog algoritma

2. ZAMJENSKA ŠEMA TRANSFORMATORA

Zamjenska šema monofaznog transformatora, prikazana je na slici 1. Sa R_1 i X_1 , označena je aktivna otpornost, odnosno rasipna reaktansa primarnog namotaja, dok su R_2' i X_2' otpornost i rasipna reaktansa sekundara, svedene na primar. Otpornost poprečne grane označena je sa R_0 , dok je X_0 reaktansa magnetčenja.

Slika 1 - Ekvivalentna T šema transformatora

Impedansa primara i impedansa sekundara svedena na primar mogu se napisati u obliku:

$$\begin{aligned} \underline{Z}_1 &= R_1 + jX_1 \\ \underline{Z}_2' &= R_2' + jX_2' \end{aligned} \quad (1)$$

a impedansa poprečne grane:

$$\underline{Z}_0 = \frac{R_0 \cdot jX_0}{R_0 + jX_0} \quad (2)$$

Zamjenska šema transformatora, u slučaju priključenog opterećenja, prikazana je na slici 2.

Slika 2 - Ekvivalentno kolo opterećenog transformatora

Ukoliko se sa $\underline{Z}_{pot}$ označi impedansa potrošača, ekvivalentna impedansa ovog kola jednaka je:

$$\underline{Z} = \underline{Z}_1 + \underline{Z}_0 \parallel (\underline{Z}_2' + \underline{Z}_{pot}) \quad (3)$$

Efektivna vrijednost struje primara se može izračunati kao:

$$I_1 = \frac{U_1}{Z} \quad (4)$$

gdje je Z moduo ekvivalentne impedanse kola, a U_1 efektivna vrijednost napona primara.

Struja sekundara, svedena na primar, određena je relacijom:

$$I_2' = \left| \frac{\underline{Z}_0}{\underline{Z}_0 + (\underline{Z}_2' + \underline{Z}_{pot})} \cdot \left(\frac{U_1}{Z} \right) \right| \quad (5)$$

Efektivna vrijednost napona sekundara, svedena na naponski nivo primara je:

$$U_2' = I_2' \cdot |\underline{Z}_{pot}| \quad (6)$$

3. PSO ALGORITAM

PSO algoritam je optimizacioni algoritam, sa brojnim oblastima primjene [11-13]. Ideja na kojoj je ovaj algoritam koncipiran i kasnije razvijen, bazirana je na modelovanju kretanja ptica ili insekata u jatima, odnosno rojevima [14].

Ova optimizaciona metoda pogodna je za primjenu na problemima čije se rješenje može zamisliti kao tačka u nekom n-dimenzionom prostoru. Problemu se pristupa definisanjem granica tog prostora, koji se naziva prostorom pretrage. Zatim se formira skup promjenljivih, kojima se dodjele početne vrijednosti (početne pozicije). Nakon ovog inicijalnog koraka, počinje iterativni proces (slika 3.), tokom kojeg promjenljive mijenjaju svoje pozicije unutar prostora pretrage.

Kretanje promjenljivih kroz ovaj prostor nije nasumično, već se za pronalazak optimalnog rješenja usko vezuje pojam minimizacije tzv. kriterijumske funkcije J . Ova funkcija je definisana u svakoj tački prostora pretrage A , pa se može pisati:

$$J: A \rightarrow \mathbb{R}, \quad A \subset \mathbb{R}^n \quad (7)$$

Drugim riječima, svakoj tački prostora A može se dodijeliti odgovarajuća vrijednost funkcije J . Imajući u vidu da je kretanje promjenljivih ograničeno upravo na prostor pretrage, u svakom koraku iterativnog procesa, svakoj promjenljivoj odgovara neka vrijednost kriterijumske funkcije. Što je ta vrijednost manja, pozicija je bolja. Na taj način moguće je uvesti pojmove sopstvene i globalne najbolje pozicije. Sopstvena najbolja pozicija svojstvena je svakoj promjenljivoj, dok je

globalni optimum zajednički za sve. Kroz iteracije, koordinate ovih tačaka se mijenjaju, a rješenje koje algoritam nudi ustvari je konačni globalni optimum, tj. tačka koja je na kraju optimizacionog procesa najbliža minimumu kriterijumske funkcije. Međutim, na kretanje promjenljivih uticaj ima i tzv. inercijalna komponenta kojom se izražava tendencija da se kretanje promjenjljive nastavi po prethodnom tragu. Naime, svakoj promjenljivoj se uz poziciju pripisuje i vektor brzine, koji uz sopstvenu i globalnu najbolju poziciju definiše kretanje u prostoru.

Slika 3 - Tok PSO algoritma

Ako su x_i i v_i vektori pozicije i brzine, pripisani i-toj promjenljivoj, P_i - njena trenutna najbolja pozicija, a g - trenutni globalni optimum, onda se kretanje u prostoru pretrage može opisati sljedećim matematičkim relacijama:

$$v_i(t+1) = w \cdot v_i(t) + c_1(P_i(t) - x_i(t)) + c_2(g(t) - x_i(t)) \quad (8)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (9)$$

Pri tome su r_1 i r_2 slučajni brojevi između 0 i 1, dok su c_1 i c_2 , konstante ubrzanja. Parametar w je tzv. inercijski težinski koeficijent, dok je t iterativni korak.

Potrebno je naglasiti da konstante c_1 i c_2 imaju veliki uticaj na brzinu konvergencije. Ukoliko su ove vrijednosti male, optimizacioni proces sporo konvergira ka rješenju. Međutim, proces može postati i nestabilan, ukoliko su njihove vrijednosti velike.

4. ESTIMACIJA PARAMETARA ZAMJENSKE ŠEME MONOFAZNOG TRANSFORMATORA

PSO algoritam opisan u prethodnom poglavlju primjenjen je na monofazni transformator (2 kVA, 220/110 V, 9.1/18.2 A, 50 Hz), sa ciljem određivanja njegovih parametara. Algoritam je realizovan kroz programski kod napisan u MATLAB okruženju (R2017a - 64 bit). Simulacije su izvršene na računaru sa 4 GB radne memorije i i3 (3227u @ 1.90GHz) procesorom.

Upotreba ovog algoritma, u svrhu estimacije parametara zamjenske šeme zahtjeva sprovođenje odgovarajućih mjernih postupaka. Naime, potrebno je izmjeriti napone i struje sa primarne i sekundarne strane, pri različitim vrijednostima opterećenja. Aparatura koja je u ogledima korišćena pri mjerenju pomenutih veličina, prikazana je na slici 4, zajedno sa potrošačem i transformatorom čiji se parametri estimiraju.

Slika 4 - Laboratorijska postavka

U konkretnom slučaju, posmatran je čisto aktivan potrošač. Variranjem otpornosti potrošača transformator je izložen različitim vrijednostima opterećenja.

Tabela 1. Izmjerene vrijednosti napona i struja

Mjerenje	I_1 [A]	U_2 [V]	I_2 [A]
1	2.09	109.0	3.38
2	2.76	108.5	4.99
3	4.04	107.9	7.57
4	5.16	107.0	9.90
5	6.00	106.2	11.6
6	7.42	105.5	14.28
7	8.25	104.7	16.00
8	9.33	104.0	18.20

Rezultati mjerenja prikazani su u tabeli 1. Sva mjerenja su izvršena pomoću uređaja Power Analyzer LMG 450, klase tačnosti 0.1%.

Parametri PSO algoritma, korišćeni u optimizacionom procesu su: $c_1 = 0.5$, $c_2 = 0.1$, $w_{\min} = 0.1$, $w_{\max} = 0.5$, $N = 1000$. Maksimalan broj iteracija postavljen je na 150.

U ovom radu, funkcija performanse je definisana na sledeći način:

$$J = \sum_{k=1}^M \left[\left(\frac{I_{1est}^{(k)}}{I_1^{(k)}} - 1 \right)^2 + \left(\frac{I_{2est}^{(k)}}{I_2^{(k)}} - 1 \right)^2 + \left(\frac{V_{2est}^{(k)}}{V_2^{(k)}} - 1 \right)^2 \right] \quad (10)$$

gdje je M broj izvršenih mjerenja. U prethodnoj jednačini, $I_{1est}^{(k)}$, $I_{2est}^{(k)}$, $V_{2est}^{(k)}$ predstavljaju estimirane vrijednosti struja i napona, dok su $I_1^{(k)}$, $I_2^{(k)}$, $V_2^{(k)}$ mjerene vrijednosti ovih veličina, koje odgovaraju k -tom izvršenom mjerenju. Prema tome, na ovaj način definisana kriterijumska funkcija uvažava kako struju primara, tako i napon i struju sekundara.

Konvergenzijska karakteristika PSO algoritma u konkretnom slučaju prikazana je na slici 5.

Slika 5 - Konvergencija PSO algoritma

Krajnja tačka konvergenzijske karakteristike odgovara vrijednosti kriterijumske funkcije konačnog globalnog optimuma čije su koordinate, u stvari, estimirani parametri (tabela 3).

Na transformatoru su izvedeni i ogledi praznog hoda i kratkog spoja. Rezultati ovih ogleda dati su u tabeli 2.

Tabela 2. Rezultati mjerenja

	U [V]	I [A]	P [W]
P.H.	220	0.937	19.4
K.S.	12.93	9.16	100.1

U skladu sa procedurama određivanja parametara zamjenske šeme transformatora, na osnovu prije pomenutih ogleda [2], dobijene su vrijednosti koje su takođe prikazane u tabeli 3.

Tabela 3. Parametri zamjenske šeme transformatora

Parametri [Ω]	P.H. i K.S.	PSO
R_1	0.5965	0.5442
X_1	0.3772	0.1428
R_2'	0.5965	0.6457
X_2'	0.3772	1.5878
R_0	2494.8	2559.3
X_0	235.84	207.50

5. ANALIZA REZULTATA

Na slikama 6, 7 i 8 prikazane su, redom, mjerene vrijednosti struje primara, napona i struje sekundara, uporedo sa vrijednostima dobijenim upotrebom parametara estimiranih pomoću PSO algoritma i parametara dobijenih sprovođenjem ogleda praznog hoda i kratkog spoja.

Slika 6 - Struja primara

Slika 7 - Napon sekundara

U tabelama 4, 5 i 6 prikazane su vrijednosti odgovarajućih električnih veličina, pri različitim vrijednostima otpornosti čisto aktivnog potrošača. Pored navedenih vrijednosti, u tabelama su prikazane i vrijednosti apsolutne greške, dobijene oduzimanjem izmjerenih i estimiranih vrijednosti.

Slika 8 - Struja sekundara

Tabela 4. Poređenje rezultata: Struja I_1 [A]

Struja primara	P.H. i K.S.	Greška P.H. i K.S.	PSO	Greška PSO
2.09	2.0042	0.0858	2.0743	0.0157
2.76	2.7426	0.0174	2.8017	0.0417
4.04	3.9738	0.0662	4.0270	0.0130
5.16	5.1202	0.0398	5.1731	0.0131
6.00	5.9729	0.0271	6.0266	0.0266
7.42	7.2957	0.1243	7.3508	0.0692
8.25	8.1710	0.0790	8.2267	0.0233
9.33	9.2718	0.0582	9.3274	0.0026

Tabela 5. Poređenje rezultata : Napon U_2 [V]

Napon sekundara	P.H. i K.S.	Greška P.H. i K.S.	PSO	Greška PSO
109.0	108.7915	0.2085	108.8872	0.1128
108.5	108.3106	0.1894	108.3975	0.1025
107.9	107.5421	0.3579	107.6078	0.2922
107.0	106.8387	0.1613	106.8776	0.1224
106.2	106.3182	0.1182	106.3329	0.1329
105.5	105.5123	0.0123	105.4824	0.0176
104.7	104.9793	0.2793	104.9152	0.2152
104.0	104.3086	0.3086	104.1963	0.1963

Za svaku od mjerenih veličina, proračunata je vrijednost srednje apsolutne greške (Mean Absolute Error) prema formuli:

$$MAE = \frac{1}{M} \sum_{k=1}^M |x_{mjer}^{(k)} - x_{est}^{(k)}| \quad (11)$$

Pri tome su $x_{mjer}^{(k)}$ i $x_{est}^{(k)}$ mjerene, odnosno estimirane vrijednosti odgovarajuće električne veličine koje odgovaraju k – tom mjerenju, dok je M ukupan broj izvršenih mjerenja. Rezultati proračuna prikazani su u tabeli 7.

Tabela 6. Poređenje rezultata : Struja I_2 [A]

Struja sekundara	P.H. i K.S.	Greška P.H. i K.S.	PSO	Greška PSO
3.38	3.3735	0.0065	3.3765	0.0035
4.99	4.9813	0.0087	4.9853	0.0047
7.57	7.5449	0.0251	7.5495	0.0205
9.90	9.8851	0.0149	9.8887	0.0113
11.60	11.6129	0.0129	11.6145	0.0145
14.28	14.2817	0.0017	14.2776	0.0024
16.00	16.0427	0.0427	16.0329	0.0329
18.20	18.2540	0.0540	18.2343	0.0343

Tabela 7. Srednja apsolutna greška

MAE	I_1 [A]	V_2 [A]	I_2 [A]
PSO	0.0256	0.1490	0.0155
P.H. i K.S.	0.0622	0.2044	0.0208

Na osnovu vrijednosti sadržanih u tabeli 7, očigledno je da je greška koja se dobija upotrebom parametara dobijenih PSO estimacijom, manja u odnosu na grešku koja se javlja pri upotrebi parametara dobijenih izvođenjem oglada praznog hoda i kratkog spoja.

Slika 9 - Talasni oblici napona sekundara

6. SIMULACIJE TALASNIH OBLIKA

Parametri dobijeni na osnovu rezultata oglada praznog hoda i kratkog spoja, kao i parametri koji su rezultat upotrebe PSO algoritma, iskorišćeni su u simulacijama talasnih oblika napona i struje sekundarnog namotaja transformatora. Rezultati simulacije su upoređeni sa talasnim oblicima, snimljenim pomoću LMG uređaja u laboratoriji.

Pri nominalnom naponu primjenjenom na primar transformatora, izmjeren je napon od 106.4 V na sekundarnoj strani, dok je vrijednost struje sekundara iznosila 11.5 A. Snimljeni naponski i strujni odzivi prikazani su uporedo sa rezultatima simulacije (slike 9 i 10). Posmatranjem priloženih rezultata može se ustanoviti

veoma dobro poklapanje simuliranih i snimljenih talasa.

Slika 10. Talasni oblici struje sekundara

7. ZAKLJUČAK

U ovom radu opisana je primjena PSO algoritma na transformator, sa ciljem određivanja parametara njegove ekvivalentne šeme. U laboratorijskim uslovima, na monofaznom transformatoru, sprovedeni su ogledi praznog hoda i kratkog spoja. Zatim je, radi primjene PSO algoritma u cilju estimacije parametara zamjenske šeme, transformator opterećen. Pri različitim vrijednostima opterećenja izvršena su mjerenja odgovarajućih električnih veličina i snimljeni odgovarajući talasni oblici. Upotrebom jednog i drugog seta parametara proračunate su efektivne vrijednosti napona i struja primara i sekundara. Upoređivanjem ovih vrijednosti sa izmjerenim vrijednostima može se zaključiti da se primjenom PSO algoritma, uz upotrebu adekvatne mjerne aparature, parametri mogu estimirati sa visokim stepenom preciznosti. Za oba seta parametara, simulirani su i talasni oblici napona i struje sekundara. U oba slučaja, ovi talasni oblici su se u velikoj mjeri poklopili sa snimljenim talasnim oblicima. Međutim, na osnovu priloženih brojnih podataka, očigledno je da je veći stepen preciznosti postignut primjenom PSO algoritma.

LITERATURA

- [1] Meier A. *Electric Power Systems: A Conceptual Introduction*, Wiley-IEEE Press, 2006.
- [2] IEEE Standard Test Code for Liquid-Immersed Distribution, Power, and Regulating Transformers, IEEE Std C57.12.90 – 2015.
- [3] Mossad MI, Mohamed A, Abu-Siada A, Transformer Parameters Estimation From Nameplate Data Using Evolutionary Programming Techniques, *IEEE Trans. Power Del.*, Vol. 29, No. 5, pp. 2118 – 2123, 2014.
- [4] Padma S, Subramanian S, Parameter estimation of single phase core type transformer using bacterial foraging algorithm, *Engineering*, Vol. 2, No. 11, pp. 917–925, 2010.
- [5] Padma S, Subramanian S, Bacterial Foraging Algorithm based Parameter Estimation of Three Winding Transformer, *Energy and Power Engineering*, Vol. 3, No. 2, pp. 135-143, 2011.
- [6] Bhowmick D, Manna M, Chowdhury S. K, Estimation of equivalent circuit parameters of transformer and induction motor using PSO, in *Proc. IEEE International Conference on Power Electronics, Drives and Energy Systems*, Trivandrum, India, pp. 1-6, 14-17 December 2016.
- [7] Bhowmick D, Manna M, Chowdhury S. K, Estimation of Equivalent Circuit Parameters of Transformer and Induction Motor from Load Data, *IEEE Trans. Ind. Appl.*, Vol. 54, No. 3, pp. 2784-2791, May-June 2018.
- [8] Thilagar S. H, Rao G. S, Parameter Estimation of Three-Winding Transformer Using Genetic Algorithm, *Engineering Applications of Artificial Intelligence*, Vol. 15, No. 5, pp. 429-437, 2002.
- [9] Bigdeli M, Rahimpour E, Estimation of simplified transient model parameters using genetic algorithm, *18th Iranian Conference on Electrical Engineering*, Isfahan, Iran, pp. 722-726, 11-13 May 2010.
- [10] Yilmaz Z, Oksar M, Basciftci F, Multi-Objective Artificial Bee Colony Algorithm to Estimate Transformer Equivalent Circuit Parameters, *Periodicals of Engineering and Natural Sciences*, Vol. 5, No. 3, pp. 271-277, November 2017.
- [11] Sakthivel V.P, Bhuvaneswari R, Subramanian S, Multi-objective parameter estimation of induction motor using particle swarm optimization, *Eng. Appl. Art. Intell.*, Vol. 23, Iss. 3, pp. 302-312, 2010.
- [12] Hazra J, Sinha AK. A multi-objective optimal power flow using particle swarm optimization. *Eur Trans Electr Power*, Vol. 21, No. 3, pp. 1028-1045, 2011.
- [13] Khanna V, Das B.K, Bisht D, Vandana, Singh P.K. A three diode model for industrial solar cells and estimation of solar cell parameters using PSO algorithm, *Renewable Energy*, Vol. 78, pp. 105-113, 2015.
- [14] Kennedy J, Eberhart R. Particle swarm optimization, in *Proc. IEEE International Conference on Neural Networks*, Vol. 4, Perth, Australia, pp. 1942-1948, 27 November - 1 December 1995.

SUMMARY

APPLICATION OF PSO ALGORITHM IN TRANSFORMER PARAMETER ESTIMATION

In this paper, the determination of transformer parameters, by the use of Particle Swarm Optimization (PSO) algorithm, is presented. Estimated parameters of equivalent circuit are found as the result of error minimization between estimated and measured load data. In order to determine the unknown circuit parameters, the values of primary and secondary current are used, along with the secondary voltage values. The results obtained through PSO method are compared with the results obtained through the use of classical methods for transformer parameter determination, which are based on open-circuit and short-circuit tests. At the end, it is concluded that PSO method represents a very efficient method for transformer parameters determination.