

OPTIMALIZACJA PARAMETRÓW ALGORYTMU EWOLUCYJNEGO W ZADANIU REGULACJI NAPIĘCIA W ROZLEGŁEJ SIECI ROZDZIELCZEJ

STRESZCZENIE

Treścią artykułu jest problem doboru parametrów algorytmu ewolucyjnego, stosowanego do optymalizacji regulacji napięcia w rozległych sieciach rozdzielczych. W artykule przedstawiono metodę poszukiwań optymalnych wartości parametrów, mających decydujący wpływ na efektywność algorytmu, oraz zamieszczono wybrane wyniki badań.

Słowa kluczowe: elektroenergetyczne sieci rozdzielcze, regulacja napięcia, algorytmy ewolucyjne

OPTIMIZATION OF PARAMETERS OF EVOLUTIONARY ALGORITHM SOLUTION OF VOLTAGE REGULATION IN A LARGE DISTRIBUTION NETWORK

As a contents of the paper is selection of parameters of the evolutionary algorithm using to optimization of voltage control in large distribution electrical networks. The method of search of the optimal values of parameters which have decisive influence for algorithm efficiency and selected results of investigations were presented in the paper.

Keywords: power distribution networks, voltage control, evolutionary algorithms

1. WPROWADZENIE

Metody obliczeniowe, których zasada działania jest oparta na zjawisku symulowanej ewolucji, są stosowane do rozwiązywania różnorodnych zagadnień optymalizacyjnych. Jednym z nich jest optymalizacja poziomów napięć w elektroenergetycznych sieciach rozdzielczych. Skuteczność algorytmu ewolucyjnego w odnajdywaniu optymalnych rozwiązań, zależy przede wszystkim od odpowiedniego zestawienia elementów jego konstrukcji. Mechanizmy składające się na całość algorytmu opisane są wieloma parametrami, które całkowicie wyznaczają zasięg i kierunek cyfrowej ewolucji. Prawidłowy dobór ich wartości dokonywany jest w dużej mierze intuicyjnie, na podstawie doświadczeń własnych oraz zaczerpniętych z literatury, a następnie sprawdzany eksperymentalnie. Wartości parametrów są optymalnymi tylko dla rozwiązywanego zagadnienia.

W artykule przedstawiono obliczenia mające na celu optymalną regulację napięcia w rzeczywistej sieci rozdzielczej, w której pracuje transformator 110 kV/SN zasilający sieć średniego napięcia z 242 transformatorami SN/nn.


2. CHARAKTERYSTYKA ROZWIĄZYWANEGO PROBLEMU

Zadanie optymalnej regulacji napięcia polega na minimalizacji funkcji celu F za pomocą wektora $[x, y]$, stanowiącego reprezentację połączeń wszystkich transformatorów SN/nn i 110 kV/SN, pracujących w optymalizowanej sieci. Funkcja celu F zależy od całkowitego odchylenia napięcia od wartości znamionowej w punkcie sieci, w którym prowadzona jest regulacja.

Przedstawiony problem optymalnej regulacji napięcia jest typowym zadaniem z ograniczeniami, w którym:

- dziedzina funkcji celu jest określona, jako zbiór możliwych połączeń zaczerpniętych transformatora 110 kV/SN i transformatorów SN/nn;
- dopuszczalność uzyskanych rozwiązań determinują dozwolone odchylenia napięcia u odbiorców.

Idea konstrukcji zastosowanego algorytmu ewolucyjnego bazuje na elementarnym algorytmie genetycznym (EAG), przedstawionym na rysunku 1, uwzględniającym dodatkowe mechanizmy.



Rys. 1. Schemat blokowy elementarnego algorytmu genetycznego (EAG)

* Dział Projektowania Stacji Elektroenergetycznych Wysokich Napięć, Energoprojekt Kraków S.A.

Obliczenia, wykonywane przy zastosowaniu algorytmu, są prowadzone w następujących etapach:

Przed startem

Etap poprzedzający start algorytmu ma na celu:

1. Zakodowanie zmiennych decyzyjnych w postaci łańcucha znaków (chromosomu) o ustalonej długości. W zadaniu zastosowano kodowanie naturalne (zmiennopozycyjne). Budowa chromosomu jest opisana przy zastosowaniu następującej zależności

$$c_i = [x_1, \dots, x_n, y_1, \dots, y_s] \quad (1)$$

gdzie:

- n – liczba regulowanych stacji transformatorowych SN/nn,
- s – liczba stref czasowych, w obrębie których utrzymywane są jednakowe nastawy przełącznika zaczepów transformatora 110 kV/SN.

2. Określenie kształtu funkcji przystosowania, która stanowi kryterium oceny jakości uzyskanego rozwiązania (osobnika) i decyduje o jego dalszej ewolucji bądź eliminacji. Ponieważ zadanie jest problemem minimalizacji funkcji celu, a algorytm ewolucyjny służy do rozwiązywania problemu maksymalizacji, dlatego przystosowanie P określono jako

$$P = C_{\max} - F([x, y]) \quad (2)$$

gdzie $C_{\max}$ – stała.

Budowa populacji początkowej

Bazowa populacja osobników, od której algorytm rozpoczyna proces ewolucyjny, jest tworzona losowo, ale w taki sposób, aby zawierała jedynie dopuszczalne rozwiązania zadania. Kontrola zachowywania zdefiniowanych ograniczeń i korekty w strukturze każdego osobnika, jest wykonywana przez odpowiedni algorytm naprawczy. W obliczeniach przyjęto stałą liczebność populacji N (w ramach każdego pokolenia), będącą parametrem zadania.

Selekcja

Selekcja osobników odbywa się za pomocą metody koła ruletki (selekcja proporcjonalna). Prawdopodobieństwo p_i wybrania i -tego ciągu kodowego c_i do reprodukcji jest określone wzorem

$$p_i = \frac{P(c_i)}{\sum_{j=1}^N P(c_j)} \quad (3)$$

gdzie:

$$P(c_i) \text{ – wartość przystosowania } i\text{-tego ciągu,}$$

$$\sum_{j=1}^N P(c_j) \text{ – suma przystosowań wszystkich ciągów.}$$

Krzyżowanie

Jest to proces, w którym następuje wymiana informacji genetycznej (podciągów) pomiędzy osobnikami dobranymi losowo w pary. Miarą częstości „zadziałania” tego operatora jest kolejny parametr zadania – prawdopodobieństwo krzyżowania p_c .

Mutacja

Mutacja polega na sporadycznej zmianie wartości losowo wybranego genu w strukturze chromosomu. Jej wskaźnikiem ilościowym jest prawdopodobieństwo mutacji p_m , będące również parametrem zadania.

Skalowanie funkcji przystosowania (mechanizm dodatkowy)

Celem skalowania funkcji przystosowania jest:

- ograniczenie wpływu ponadprzeciętnych osobników na przedwczesną zbieżność algorytmu w kierunku optimum lokalnego (w początkowej fazie ewolucji),
- zorientowanie procesu w kierunku najlepszego rozwiązania z populacji osobników o wysokich przystosowaniach (w końcowej fazie ewolucji).

W zadaniu zastosowano skalowanie liniowe, polegające na przekształceniu funkcji przystosowania P na P' przez taką zależność liniową

$$P' = a \cdot P + b \quad (4)$$

aby spełnione były zależności określone wzorami:

$$P'_{sr} = P'_{sr} \quad (5)$$

$$P'_{\max} = Z \cdot P'_{sr} \quad (6)$$

gdzie:

a, b – stałe,

$P'_{sr}, P'_{\max}$ – odpowiednio średnia i maksymalna wartość przystosowania osobników w populacji,

Z – tzw. współczynnik zwielokrotnienia.

Warunek zatrzymania

Warunkiem zatrzymania algorytmu ewolucyjnego jest określenie przed startem liczby pokoleń, po której ma nastąpić przerwanie obliczeń. Aby umożliwić właściwą interpretację odnalezienia optymalnego rozwiązania, ustalono długość procesu ewolucyjnego na $4 \cdot 10^4$ pokoleń.

3. OPTIMALIZACJA PARAMETRÓW ALGORYTMU EWOLUCYJNEGO

O skuteczności działania algorytmu decyduje przede wszystkim liczebność populacji początkowej – N oraz zestaw operatorów sterujących procesem ewolucyjnym, tj. selekcja, krzyżowanie i mutacja (rys. 1). Istotny wpływ na selekcję ma skalowanie funkcji przystosowania.

Reprezentację ilościową wymienionych mechanizmów stanowią:

- p_c – prawdopodobieństwo krzyżowania,
- p_m – prawdopodobieństwo mutacji,
- Z – współczynnik zwielokrotnienia.

Odpowiedni dobór tych parametrów wpływa na prawidłowe ukierunkowanie całego procesu ewolucji, a w konsekwencji na znalezienie optymalnego rozwiązania w możliwie najkrótszym czasie.

Heurystyczno-stochastyczny charakter algorytmu ewolucyjnego sprawia, że proces optymalizacji jego parametrów ma charakter eksperymentalny. Nie istnieje bowiem ani uniwersalny zestaw optymalnych parametrów, ani analityczna metoda ich wyznaczenia. Wykorzystując dotychczasowe doświadczenia z tej dziedziny, przedstawione m.in. w literaturze [3–6], zawężono przestrzeń poszukiwanych wartości. Prawidłowy dobór wartości parametrów został przeprowadzony doświadczalnie dla przybliżonego (testowego) modelu zadania, a następnie sprawdzony na modelu pełnym. Każdy eksperyment został wielokrotnie powtórzony, ponieważ w przypadku rozwiązywania takiego zadania miarodajna jest tylko statystyczna ocena efektywności algorytmu.

Wprowadzono następujące wielkości, stanowiące kryteria oceny uzyskanych wyników:

- poziom zbieżności uzyskiwanych rozwiązań względem rozwiązania optymalnego określony wzorem

$$x_c = \frac{1}{T_N} \sum_{t_N=1}^{T_N} P_{\%}^*(t_N) \quad (7)$$

gdzie:

t_N – numer testu,

$P_{\%}^*$ – procentowa wartość przystosowania najlepszego rozwiązania z danego testu, w stosunku do rozwiązania optymalnego,

- tempo zbieżności procesu ewolucyjnego wyrażone wzorem

$$x_g = \frac{1}{T_N} \sum_{t_N=1}^{T_N} G_N^*(t_N) \quad (8)$$

gdzie G_N^* – średnia wartość numeru pokolenia, w którym najlepszy osobnik osiągnął po raz pierwszy maksymalne przystosowanie.

Na podstawie literatury [4, 5] dotyczącej optymalnego doboru parametrów algorytmu ewolucyjnego opracowano następujący harmonogram procesu badawczego:

1. Warunki wstępne przeprowadzania eksperymentów:
 - określenie zakresu, rozdzielczości oraz szeregu reprezentatywnych wartości dla każdego z badanych wskaźników;
 - wytypowanie początkowego zbioru wartości p_c , p_m , Z i N ;
 - ustalenie kolejki do eksperymentu w taki sposób, aby jako pierwszy badany był element, mający największy wpływ na efektywność i czas obliczeń algorytmu (stopniowe „dostrajanie”).

Po przetestowaniu danego parametru, wprowadzenie optymalnej wartości jako startowej przy badaniu kolejnego wskaźnika.

2. Kolejność przeprowadzania eksperymentów:
 - „strojenie wstępne” (pięciokrotne uruchomienie programu dla każdej testowanej wartości ze zbioru p_c , p_m i Z);
 - sterowanie rozmiarem populacji N (test dziesięciokrotny dla każdej badanej wartości);
 - „dostrajanie” algorytmu (określenie optymalnych wartości parametrów p_c , p_m i Z po testach dziesięciokrotnych).
3. Sprawdzenie wyznaczonych doświadczalnie parametrów na pełnym modelu zadania.

4. WYNIKI SYMULACJI KOMPUTEROWYCH

Przy wykorzystaniu danych zawartych w literaturze [7] wytypowano startowe wartości optymalizowanych parametrów: $p_c = 0,9$, $p_m = 0,02$, $Z = 1,8$, $N = 200$. Kolejka do badań: 1– p_c , 2– p_m , 3– Z . Symulacje wykonano na komputerze z procesorem 1,6 GHz i 1 GB pamięci RAM. Przedstawiono najbardziej reprezentatywne wyniki doświadczeń.

W wyniku ponad pięciuset uruchomień programu wytypowano dwa optymalne rozwiązania zadania: R1 i R2, różne ze względu na sposób realizacji. Ich ogólną strukturę, z wyróżnionymi genami „y” oraz wartości przystosowań (przy $C_{\max} = 17 \cdot 10^4$) przedstawiono poniżej:

R1: $[x_1, \dots, x_n, 9.31, 9.31, 7.98, 6.65]$, $P(R1) = 169009,8$;

R2: $[x_1, \dots, x_n, 5.32, 3.99, 2.66, 1.33]$, $P(R2) = 169103,7$.

Ocena poziomu zbieżności względem dwóch różnych rozwiązań jest możliwa przez porównanie genów „y” najlepszego osobnika z danego testu i rozwiązania optymalnego.

Wyniki eksperymentów przedstawiono w postaci histogramów procentowych wartości przystosowań najlepszych osobników z danego testu (rys. 2–4). Pod każdym rysunkiem umieszczono tabelę zawierającą statystyczne porównanie poziomów i tempa zbieżności (tab. 1–3). Na ich podstawie dokonano ostatecznej oceny doświadczeń.

Strojenie wstępne


Wyniki strojenia przedstawiono na rysunku 2 i w tabeli 1.

Sterowanie rozmiarem populacji

Wyniki sterowania rozmiarem populacji przedstawiono na rysunku 3 i w tabeli 2.

Mimo iż w większej populacji $N = 200$, algorytm wcześniej odnajduje optymalne rozwiązanie, to jednak relatywny czas jego uzyskania jest dużo większy niż w przypadku populacji mniejszych (przy założeniu zachowania maksymalnej efektywności). Dlatego nie uznano jej za optymalną.

Duże populacje początkowe dają możliwość do analizy większej ilości informacji, zwiększając pewność znalezienia optymalnego rozwiązania, a więc stanowią dobry punkt wyjścia do badań nad innymi parametrami.



Rys. 2. Optimalizacja parametrów p_c , p_m i Z. Histogramy przystosowań najlepszych osobników

Tabela 1

Statystyczne porównanie poziomów i tempa zbieżności

Wartość	x_{es} [%]	x_{g^*} [G_N^*]
Optimalizacja p_c		
0,9	99,9922	—
0,8	99,9961	—
0,7	99,9984	—
0,6	99,9995	—
0,5	99,9939	—
Optimalizacja p_m		
0,030	99,7549	—
0,020	99,9995	—
0,010	100,0000	17838
0,005	100,0000	24557
0,001	99,0449	—
Optimalizacja Z		
2,0	100,0000	15515
1,8	100,0000	14670
1,6	99,9851	—
1,3	99,9984	—
1,0	niezbieżny	—


Tabela 2

Optimalizacja N.

Statystyczne porównanie poziomów i tempa zbieżności

Wartość	x_{es} [%]	x_{g^*} [G_N^*]	t , [min[s]]
200	100,0000	12269	7'10"
100	100,0000	21480	6'16"
50	100,0000	21908	3'12"
30	100,0000	17731	1'46"
20	99,9581	—	—

Po wstępnym zoptymalizowaniu parametrów procesu ewolucyjnego, optymalna wydaje się populacja 30-osobnikowa. Taka wartość parametru N, zapewnia maksymalną efektywność i szybkość w uzyskiwaniu najlepszych osobników.



Rys. 3. Optimalizacja N.

Histogramy przystosowań najlepszych osobników

Należy przy tym zaznaczyć, że mniejsze populacje posiadają większą tendencję do wyrwania się z maksimum lokalnego funkcji przystosowania (rozwiązanie R1), podczas gdy większe w nim osiadają (rys. 3).

Tabela 3


Statystyczne porównanie poziomów i tempa zbieżności

Wartość	x_{es} [%]	x_{gs} [G_N^*]
Optimalizacja p_c		
0,9	99,6634	—
0,8	99,8857	—
0,7	99,8878	—
0,6	100,0000	—
0,5	99,7756	—
Optimalizacja p_m		
0,030	99,7960	—
0,020	99,8810	—
0,010	100,0000	17731
0,005	100,0000	19579
0,001	99,8509	—
Optimalizacja Z		
2,0	98,8878	—
1,8	100,0000	14515
1,6	100,0000	23489
1,3	99,8339	—
1,0	niezbieżny	—

pokazują eksperymenty, nie musi. Dobór prawdopodobieństwa krzyżowania na średnim poziomie 0,6 pozwala na częściowe zbilansowanie ekstremalnych rozwiązań, zabezpieczając populację przed wpadnięciem w optimum lokalne bądź przed regresją. Jednocześnie zapewnia jej zrównoważony rozwój.

Odpowiednia wartość prawdopodobieństwa mutacji umożliwia populacji zmianę złe obranego kierunku ewolucji. Zbyt duże wartości mogą ją z kolei doprowadzić do przypadkowego błędzenia i braku możliwości uzyskania najlepszego rozwiązania. Na tej podstawie oraz w świetle uzyskanych wyników, wartość $p_m = 0,01$ znajduje swoje uzasadnienie.

Zastosowanie skalowania przystosowań pozwoliło na lepsze i wydajniejsze sterowanie procesem ewolucji. Zbyt mała wartość współczynnika zwielokrotnienia $Z = 1$, powodowała, że osobniki z wysokimi wartościami przystosowań nie mogły doprowadzić populacji do optymalnego rozwiązania (za duże spłaszczenie populacji). Współczynnik ten ma duży wpływ na zróżnicowanie uzyskiwanych optymalnych rozwiązań. Zadając $Z = 2$ zwiększono częstość wykrywania nieco lepszego rozwiązania R2. Optymalną wartością zarówno i ze względu na poziom zbieżności, jak i zrównoważenie wykrywalności obu rozwiązań okazuje się wartość 1,8.

**Rys. 4.** Optimalizacja parametrów p_c , p_m i Z . Histogramy przystosowań najlepszych osobników

Strojenie główne


Jak widać z przedstawionych wyników symulacji, każdy z badanych parametrów wpływa na zachowanie procesu ewolucyjnego.

Duże prawdopodobieństwo krzyżowania stwarza ryzyko uzyskania populacji z większym udziałem osobników o skrajnych wartościach przystosowań. Może się to opłacać, ale jak

5. OCENA EFEKTYWNOŚCI ALGORYTMU Z OPTYMALNIE DOBRANYMI PARAMETRAMI

Wobec wyznaczenia optymalnych nastaw parametrów algorytmu ewolucyjnego wykonano serię 20 uruchomień programu na pełnym modelu zadania. Działanie to miało na celu weryfikację uzyskanych wyników badań, a także ostateczne ustalenie ilości i struktury rozwiązań zadania.

Wyniki przedstawiono w postaci histogramu przystosowań najlepszych osobników z każdego testu (rys. 5).



Rys. 5. Ocena wpływu uzyskanych parametrów na jakość rozwiązań pełnego modelu zadania

Jak widać na załączonym rysunku (rys. 5), algorytm został dostrojony w taki sposób, że w każdej z 20 prób wykazywał stuprocentową zbieżność do rozwiązania optymalnego.

Struktura uzyskanych rozwiązań $R1_p$ i $R2_p$, różni się od rozwiązań testowych jedynie dwoma genami „x”, a także, co wydaje się oczywiste, wartością przystosowań.

$$P(R1_p)=151\,089,8,$$

$$P(R2_p)=155\,227,7.$$

Tempo zbieżności procesu ewolucyjnego x_g kształtuje się na poziomie 16 002 pokolenia, co oznacza, że w cyklu 20 prób algorytm odnajdywał najlepsze rozwiązanie średnio po około $16 \cdot 10^3$ pokoleń. W najlepszej próbie w 9666 pokoleniu, a w najgorszej w 29 426. Dlatego bezpiecznie, ale zarazem wystarczająco, można ustalić warunek zatrzymania na $3 \cdot 10^4$ pokoleniu.

6. PODSUMOWANIE

Na podstawie przedstawionych wyników symulacji komputerowych można stwierdzić, że właściwy dobór parametrów algorytmu ewolucyjnego umożliwia zwiększenie jego efektywności w poszukiwaniu optymalnych rozwiązań, przy zróżnicowanych populacjach początkowych. Problem optymalizacji parametrów algorytmu ewolucyjnego stanowi więc istotny punkt badań, przed zastosowaniem go jako efektywnej metody rozwiązania zadania optymalnej regulacji napięcia.

Literatura

- [1] Goldberg D.E.: *Algorytmy genetyczne i ich zastosowania*. Warszawa, WNT 2003
- [2] Michalewicz Z.: *Algorytmy genetyczne + struktury danych = programy ewolucyjne*. Warszawa, WNT 2003
- [3] De Jong K.A.: *An Analysis of the Behaviour of a Class of Genetic Adaptive Systems*. University of Michigan 1975 (Doctoral Dissertation)
- [4] Grefenstette J.J.: *Optimization of Control Parameters for Genetic Algorithms*. Morgan Kaufmann Publishers, Los Altos, CA, 1987
- [5] Schaffer J.D., Caruana R., Eshelman L., Das R.: *A Study of Control Parameters Affecting Online Performance of Genetic Algorithms for Function Optimization*. Morgan Kaufmann Publishers, Los Altos, CA, 1989
- [6] Helt P., Parol M., Piotrowski P.: *Metody sztucznej inteligencji w elektroenergetyce*. Warszawa 2000
- [7] Kot A.: *Optymalna regulacja napięcia w sieciach średniego napięcia zawierających źródła generacji rozproszonej*. Kraków, Akademia Górniczo-Hutnicza, 2005 (praca doktorska)

Wpłynęło: 11.03.2008 r.

Krzysztof GRUSZKA



Urodził się w 1983 roku w Busku-Zdroju. Absolwent Wydziału Elektrotechniki, Automatyki, Informatyki i Elektroniki Akademii Górniczo-Hutniczej w Krakowie, gdzie w roku 2007 uzyskał tytuł mgr. inż. elektryka. W tym samym roku rozpoczął tam studia doktoranckie. Równocześnie pracuje na stanowisku asystenta w dziale projektowania stacji elektroenergetycznych wysokich napięć w firmie Energoprojekt Kraków S.A. Za interesowania naukowe związane są z metodami optymalizacji systemów elektroenergetycznych oraz ochroną przeciwprzepięciową rozdzielnic z izolacją gazową.

e-mail: gruszka@agh.edu.pl