

OPTIMALIZACJA EKSPLOATACJI ELEKTROWNI Z POMOCĄ ALGORYTMU GENETYCZNEGO

Dr hab.inż. Władysław Brzozowski
Politechnika Częstochowska
Instytut Elektroenergetyki
Al. Armii Krajowej 17
42-201 Częstochowa

1. Wstęp

Artykuł przedstawia algorytm genetyczny, wykorzystujący podstawowe procesy i mechanizmy genetyki: selekcję, krzyżowanie oraz mutację, w zastosowaniu do globalnej optymalizacji procesu eksploatacji elektrowni. Autor sporządził program komputerowy PROGEN 3.0 w oparciu o ten algorytm, a następnie wykonał przykładowe wielowariantowe obliczenia optymalizacyjne na bazie danych jednej z dużych elektrowni krajowych.

Podprogramy, które modelują opisane na wstępie procesy genetyczne, zostały zaczerpnięte z pracy D.E.Goldberga [2] (powołującego się z kolei na pracę D.E.Knutha [3]); zostały jednak merytorycznie i informatycznie uaktualnione i zmienione, a także adaptowane do potrzeb optymalizacji procesu eksploatacji elektrowni przez autora niniejszego artykułu. Algorytm genetyczny i program przetestowano, realizując równoległe komputerowe obliczenia optymalizacyjne metodą przeliczania wszystkich kombinatorycznie określonych wariantów rozwiązań.

Celem pracy było zbadanie możliwości zastosowania algorytmu genetycznego do optymalizacji procesu, a także porównanie tego algorytmu z innymi metodami optymalizacji globalnej procesu, opracowanymi przez autora w [1], w szczególności z kombinowaną metodą losowego poszukiwania ekstremum i planowania eksperymentu oraz z metodą Gaussa-Seidela.

2. Optymalizacja globalna procesu eksploatacji

Optymalizacji decyzji eksploatacyjnych elektrowni dokonuje się w systemie decyzyjnym, obejmującym dwa podstawowe poziomy: nadrzędnej (globalnej) optymalizacji procesu oraz komputerowych modeli decyzyjnych i optymalizacji lokalnej. Na poziomie nadrzędnym dokonuje się optymalizacji podzbioru Z^{dgc} ważnych i interakcyjnie powiązanych zmiennych decyzyjnych eksploatacji elektrowni. Ze względu na dużą liczbę tych zmiennych, jak i ze względu na powtarzalność (etapowość) decyzji elektrownianych, proces optymalizacji globalnej dekomponuje się na na K podprocesów decyzyjnych.

Przestrzeń decyzji wyróżnionego, k-tego podprocesu optymalizacji globalnej, po zrealizowaniu wstępnych procedur selekcji/filtracji zmiennych decyzyjnych jest określona podzbiorem

$$\{Z_{kpze}^{dkg}\}, \quad p = \overline{1, P_k}, \quad z = \overline{1, Z_{pk}}, \quad e = \overline{1, E_k} \quad (1)$$

gdzie: Z_{kpze}^{dkg} - z-ta zmienna decyzyjna, p-tego problemu decyzyjnego, e-tego etapu decyzyjnego i k-tego podprocesu decyzyjnego, optymalizowana globalnie; k, p, z, e - wskaźniki wielkości jak opisano wyżej; P_k - liczba problemów decyzyjnych objęta k-tym podprocesem decyzyjnym; Z_{pk} - liczba zmiennych decyzyjnych p-tego problemu decyzyjnego w k-tym podprocesie decyzyjnym; E_k - liczba etapów decyzyjnych k-tego podprocesu decyzyjnego.

Kryterium optymalizacji globalnej procesu jest maksimum $\overline{Z^{dnd}}$ - wartości oczekiwanej zdyskontowanego skorygowanego zysku do samodzielnego podziału w elektrowni, zliczanego z lat okresu eksploatacji.

Obliczenia optymalizacyjne realizuje się w kolejnych wariantach i kolejnych przebiegach (powtórzeniach) losowych. Procesem tym steruje algorytm globalnej optymalizacji, tu algorytm genetyczny. Funkcję kryterium oblicza się na trajektorii obliczeń przebiegającej podzbiór komputerowych modeli decyzyjnych podprocesów, odpowiednio wybrany do danego k-tego podprocesu decyzyjnego. Spośród tych modeli, ze względu na ekonomiczny charakter funkcji kryterium, podstawowe znaczenie posiada model decyzyjny systemu ekonomiczno-finansowego elektrowni.

W opisanych dalej obliczeniach zastosowano zintegrowany symulacyjny, komputerowy model decyzyjny eksploatacji elektrowni MDE1, łączący funkcje modelu systemu ekonomiczno-finansowego elektrowni oraz modelu technologicznego elektrowni.

3. Algorytm genetyczny optymalizacji globalnej procesu. Program komputerowy PROGEN 3.0

Dla uproszczenia zapisu wprowadzony zostanie zastępczy wskaźnik zmiennych decyzyjnych k-tego podprocesu, q ($q = \overline{1, Q}$), taki że

$$Q = E_k \sum_{p=1}^{P_k} Z_{pk} \quad (2)$$

gdzie: Q - liczba zmiennych decyzyjnych k-tego podprocesu decyzyjnego; q - wskaźnik zmiennych decyzyjnych k-tego podprocesu decyzyjnego; $k, p, z, e, P_k, Z_{pk}, E_k$ - jak we wzorze (1).

Definiuje się pojęcie populacji złożonej z N osobników, o wskaźniku n ($n = \overline{1, N}$; N - parzyste). Pojedynczy osobnik jest odpowiednikiem pojedynczego wariantu obliczeń optymalizacyjnych k-tego podprocesu decyzyjnego. Osobnika cechuje stopień przystosowania do otoczenia, którego odpowiednikiem jest wartość funkcji kryterium w danym wariantie optymalizacji.

Każdy osobnik jest nośnikiem cech genetycznych w postaci chromosomu, będącego zbiorem (ciągiem) genów. Materiał genetyczny osobnika jest odpowiednikiem zbioru wartości Q zmiennych decyzyjnych podprocesu w danym wariantie. W zastosowanym algorytmie genetycznym i w obliczeniach przyjęto (za algorytmami z [2]), że reprezentacją genu jest liczba binarna (choć w ogólności może to być liczba przybierająca wartość z dowolnego, określonego zbioru cyfr, liter lub innych znaków). Chromosom osobnika jest więc ciągiem A genów, liczących I genów a_i o wskaźniku i ($i = \overline{1, I}$) [2]

$$A = a_1, a_2, \dots, a_i, \dots, a_I \quad (3)$$

gdzie: A - chromosom osobnika; a_i - i -ty gen w chromosomie osobnika; i - wskaźnik genu w chromosomie osobnika; I - liczba genów osobnika.

Ciąg A składa się z szeregowo następujących podciągów A_q genów, kodujących poszczególne cechy osobnika, będące odpowiednikami poszczególnych zmiennych decyzyjnych danego wariantu obliczeń

$$A_q = a_{(i=I_q^p)}, a_{(i=I_q^p+1)}, \dots, a_{(i=I_q^k)}; \quad q = \overline{1, Q} \quad (4)$$

gdzie: A_q - podciąg genów będący odpowiednikiem q -tej zmiennej decyzyjnej wariantu obliczeń; I_q^p - wartość wskaźnika i dla pierwszego genu podciągu reprezentującego q -tą zmienną

decyzyjną; I_q^k - wartość wskaźnika i dla ostatniego genu podciągu reprezentującego q -tą zmienną decyzyjną; Q, q - jak we wzorze (2).

Zakodowana w genach wartość q -tej cechy osobnika wynosi zatem

$$C_q = \sum_{i=I_q^p}^{I_q^k} \left(a_i 2^{-(i-I_q^k)} \right) \quad (5)$$

gdzie: C_q - zakodowana w genach wartość q -tej cechy osobnika, będąca odpowiednikiem zakodowanej wartości q -tej zmiennej decyzyjnej w danym wariancie obliczeń; i, a_i - jak we wzorze (3); I_q^p, I_q^k - jak we wzorze (4).

Zdekodowana z chromosomu osobnika i skwantyfikowana wartość Z_q q -tej zmiennej decyzyjnej wynosi

$$\begin{aligned} Z_q &= Z_q^{\min} + m\Delta Z_q, \text{ gdzie} \\ m: (X - Z_q) &\leq [Z_q^{\min} + (m+1)\Delta Z_q - X]; \\ X &= \frac{Z_q^{\max} - Z_q^{\min}}{2^{I_q^k - I_q^p + 1} - 1} C_q \end{aligned} \quad (6)$$

gdzie: Z_q - zdekodowana z chromosomu osobnika i skwantyfikowana wartość q -tej zmiennej decyzyjnej w danym wariancie obliczeń optymalizacyjnych; $Z_q^{\min}, Z_q^{\max}$ - odpowiednio: dolna i górna granica założonego przedziału zmienności q -tej zmiennej decyzyjnej; ΔZ_q - założony skok zmienności (kwant) q -tej zmiennej decyzyjnej; m, X - zmienne pomocnicze; C_q - jak we wzorze (5); I_q^p, I_q^k - jak we wzorze (4).

Algorytm genetyczny polega na generowaniu populacji N osobników, w kolejnych pokoleniach o wskaźniku g ($g = 0, G$), gdzie G - założona maksymalna liczba pokoleń (generacji). Punktem startu jest zerowa generacja, w której osobnicy do populacji są dobierani losowo, tj. w taki sposób, że każdy gen ich chromosomów jest losowany z równomiernym prawdopodobieństwem ze zbioru $\{0,1\}$; każdy gen jest więc pseudolosową liczbą binarną.

Następuje, w odniesieniu do każdego osobnika populacji, zdekodowanie wartości Q zmiennych decyzyjnych za pomocą wzorów (5,6) oraz określenie wartości funkcji kryterium $\overline{Z^{\text{dnd}}} = f(Z_q, q = 1, Q)$, za pomocą symulacyjnego modelu decyzyjnego eksploatacji elektrowni MDE1. Funkcja ta jest, jak wspomniano, miarą stopnia przystosowania do otoczenia poszczególnych osobników.

Celem wygenerowania populacji osobników w kolejnym pokoleniu, algorytm genetyczny wykorzystuje mechanizm selekcji (selection) według stopnia przystosowania osobników do otoczenia. Do reprodukcji dobiera się $N/2$ par rodziców na zasadzie losowania, ze zwracaniem, osobników z dotychczasowej populacji (osobnik może stać się rodzicem wielokrotnie). Dany ($n=N'$)-ty osobnik z dotychczasowej populacji staje się rodzicem wówczas gdy (wzór na podstawie algorytmów komputerowych z [2])

$$\alpha \geq \frac{\sum_{n=1}^{N'} \overline{Z_n^{\text{dnd}}}}{\sum_{n=1}^N \overline{Z_n^{\text{dnd}}}} \quad (7)$$

gdzie: α - liczba pseudolosowa równomiernie rozłożona w przedziale $[0,1]$; n - wskaźnik osobników w populacji (jak wyżej); $n=N'$ - wartość wskaźnika osobników w populacji dla rozpatrywanego osobnika; $\overline{Z_n^{\text{dnd}}}$ - funkcja kryterium określona dla n -tego osobnika w populacji; N - licznosc populacji (jak wyżej).

Każda para rodziców zostaje poddana z kolei, przez algorytm genetyczny, z założonym z góry prawdopodobieństwem, działaniu mechanizmu krzyżowania (crossover). Następuje losowanie liczby pseudolosowej α jak wyżej. Jeśli

$$\alpha \leq f_c \quad (8)$$

gdzie: α - jak we wzorze (7); f_c - założone z góry prawdopodobieństwo skrzyżowania rodziców,

to rodzice zostają poddani skrzyżowaniu. Następuje wylosowanie miejsca skrzyżowania chromosomów rodziców, tj. określenie takiej wartości wskaźnika $i=I_c$ genu w obu chromosomach, że podciągi utworzone przez pozostałe geny wymieniają się, tworząc dwa organizmy potomne (dzieci; wzór na podstawie algorytmów komputerowych z [2])

$$a_i^{d1} = \begin{cases} a_i^{r1} & \Leftarrow i \leq I_c; \\ a_i^{r2} & \Leftarrow i > I_c; \end{cases} \quad (9)$$

$$a_i^{d2} = \begin{cases} a_i^{r2} & \Leftarrow i \leq I_c; \\ a_i^{r1} & \Leftarrow i > I_c \end{cases}$$

gdzie: a_i^{d1} , a_i^{d2} - i-ty gen w chromosomie, odpowiednio: dziecka pierwszego i drugiego; a_i^{r1} , a_i^{r2} - i-ty gen w chromosomie, odpowiednio: rodzica pierwszego i drugiego; i - jak we wzorze (3); I_c - wartość wskaźnika genu w chromosomach rodziców, od którego pozostałe geny podlegają skrzyżowaniu.

Jeśli warunek (8) nie jest spełniony, skrzyżowanie nie następuje, a chromosom, odpowiednio pierwszego i drugiego dziecka pozostaje zgodny z chromosomem odpowiednio pierwszego i drugiego rodzica.

Na chromosomach obu dzieci, po ich wygenerowaniu działa jeszcze mechanizm mutacji (mutation). W odniesieniu do każdego genu następuje losowanie liczby pseudolosowej α jak wyżej. Jeśli

$$\alpha \leq f_m \quad (10)$$

gdzie: α - jak we wzorze (7); f_m - założone z góry prawdopodobieństwo mutacji, to dany i-ty gen dziecka ulega mutacji. Wówczas (wzór na podstawie algorytmów komputerowych z [2])

$$a_i^d := \neg a_i^d \quad (11)$$

gdzie: a_i^d - i-ty gen dziecka, pierwszego lub drugiego.

W oparciu o powyższy algorytm, wykorzystując podprogramy selekcji, krzyżowania oraz mutacji z [2], autor sporządził program komputerowy PROGEN 3.0. przystosowany do obliczeń globalnej optymalizacji procesu eksploatacji elektrowni. Program został napisany w jęz. Borland Pascal 7.0; w programie zastosowano unowocześnione podprogramy standardowe oraz oryginalne procedury dekodowania i kwantyfikacji zmiennych decyzyjnych.

Za pomocą programu PROGEN 3.0 zrealizowano wielowariantowe przykładowe obliczenia optymalizacyjne na bazie danych jednej z elektrowni krajowych (por. dalej pkt.4, etap 3).

4. Przykładowe obliczenia optymalizacyjne

Do przykładowych obliczeń globalnej optymalizacji procesu eksploatacji elektrowni wybrano podproces decyzyjny obejmujący dwa problemy decyzyjne:

- dobór paliwa dla elektrowni. Zmienną decyzyjną był tu wariant sortymentu paliwa (węgla), obejmujący także mieszanki paliw (zmienna 1). Przedział wartości zmiennej obejmował 17 wariantów;

- dobór parametrów czynnika w obiegu. Zmienną decyzyjną była tu temperatura pary świeżej i wtórnie przegrzanej w obiegu (na dolocie do turbiny; zmienna 2). Do obliczeń przyjęto przedział wartości zmiennej $[530^{\circ}\text{C}, 545^{\circ}\text{C}]$, ze skokiem dyskretyzacji/kwantyfikacji 1°C . Odpowiednio, przedział zmienności zmiennej obejmował 16 wariantów.

Przestrzeń decyzji obliczeń optymalizacyjnych, opisaną powyżej, dobrano celowo w taki sposób, by ze względu na czas obliczeń komputerowych dopuszczalne było zastosowanie, dla celów weryfikacji algorytmu genetycznego, programu PROGEN 3.0 oraz obliczeń optymalizacyjnych, prostej metody przeliczenia wszystkich kombinatorycznie określonych wariantów obliczeń (liczba takich wariantów wyniosła $17 \cdot 16 = 272$). W efekcie, parametry przestrzeni decyzji, zgodnie z notacją zastosowaną we wzorze (1) przedstawiały się następująco: $k = 1$; $P_1 = 2$; $Z_{11} = 1$; $Z_{21} = 1$; $E_1 = 1$. Obliczenia zrealizowano dla 3 wybranych lat eksploatacji badanej elektrowni.

Przykładowe obliczenia optymalizacyjne zostały zrealizowane w 5 poniższych etapach.

Etap 1

Dokonano obliczenia funkcji kryterium dla wszystkich 272 kombinatorycznie określonych wariantów przestrzeni decyzji, określonych powyżej, za pomocą komputerowego modelu MDE1. W wyniku obliczeń określono mapę funkcji kryterium w przestrzeni określonej zmiennością obu zmiennych decyzyjnych. Funkcja kryterium, dla ponad połowy wariantów przyjmuje wartości ujemne. Stwierdzono duże wartości gradientów tej funkcji oraz występowanie licznych ekstremów lokalnych. Maksimum globalne funkcja osiągnęła dla gorszego lecz taniego sortymentu paliwa (wariant 3 doboru paliwa) i dla temperatury pary 532°C . Maksimum to wyniosło $28,174 \cdot 10^9$ st.zł. i traktowane było w następnych etapach obliczeń jako maksimum globalne odniesienia.

Etap 2

W ramach etapu zrealizowano pomocnicze obliczenia dla określenia najefektywniejszych wartości parametrów występowania algorytmu genetycznego (wielkość populacji, liczba generacji, długość chromosomu, prawdopodobieństwo krzyżowania, prawdopodobieństwo mutacji), za pomocą programu PROGEN 3.0, na wzorcowej funkcji matematycznej dwu zmiennych. Funkcją tą jest paraboloida eliptyczna o wierzchołku w punkcie x_0, y_0

$$z = - \left(\frac{(x - x_0)^2}{a^2} + \frac{(y - y_0)^2}{b^2} \right) \quad (20)$$

Obliczenia zrealizowano w wielu wariantach i przebiegach, zmieniając kolejno jeden z parametrów występowania algorytmu genetycznego (metodą Gaussa-Seidela, tj. pozostawiając pozostałe parametry na uprzednio wyznaczonym poziomie optymalnym):

- wielkość populacji w przedziale $[10, 100]$, przy zmiennej liczbie generacji w przedziale $[10, 10000]$ w każdym przebiegu;
- długość chromosomu w przedziale $[16, 60]$, przy zmiennej liczbie generacji jw.;
- prawdopodobieństwo krzyżowania w przedziale $[0, 1]$, co 0,05 i 0,1 w wielu przebiegach, przy stałej liczbie generacji równej 1000000 w każdym przebiegu;
- prawdopodobieństwo mutacji w przedziale $[0, 0,5]$, co 0,005 i 0,01, przy liczbie generacji jw.

Jako kryterium efektywności/optymalizacji przyjęto minimum odchylenia ekstremum określonego przez algorytm genetyczny od ekstremum analitycznego. Określono w ten sposób następujące najefektywniejsze wartości parametrów występowania:

- wielkość populacji (liczba osobników) $N = 30$ (por. pkt 3.);
- długość chromosomu $I = 30$ (jw., wzór (3));
- prawdopodobieństwo krzyżowania $f_c = 0.6$ (jw., wzór (8));
- prawdopodobieństwo mutacji $f_m = 0.03$ (jw., wzór (10)).

Wartości te przyjęto do obliczeń w etapie 3; w większości pokrywają się one z wartościami podanymi w [2]. Liczbę generacji pozostawiono natomiast jako zmienną.

Znamienne jest, że prawdopodobieństwo mutacji równe 0 okazało się niekorzystne dla efektywności algorytmu.

Etap 3

W ramach etapu zrealizowano użytkowe, przykładowe obliczenia optymalizacyjne procesu eksploatacji badanej elektrowni, w wielu wariantach obliczeń i przebiegach algorytmu genetycznego, za pomocą programu PROGEN 3.0 we współpracy z pakietem MDE1. Przy tym, w konfrontacji z wynikami etapu 1 jw., dokonano także weryfikacji poprawności i efektywności działania algorytmu genetycznego i programu PROGEN 3.0. Obliczenia zrealizowano w 2 podetapach jak poniżej.

Podetap 3.1

W ramach podetapu realizowano obliczenia dla stałej, lecz w kolejnych wariantach obliczeń coraz to większej liczby generacji, z określeniem, dla każdego wariantu obliczeń, frakcji przebiegów, w których osiągnięto maksimum globalne odniesienia funkcji kryterium oraz z określeniem średniego osiągniętego maksimum globalnego. W ramach pojedynczego wariantu realizowano po 30 przebiegów algorytmu genetycznego, o charakterze powtórzeń losowych (z tymi samymi danymi wyjściowymi). Wyniki obliczeń podetapu zestawiono w tablicy 1.

Stwierdzono, że algorytm genetyczny odnajdywał maksimum globalne odniesienia z prawdopodobieństwem zależnym od liczby generacji - od liczby generacji 10 dla większości przebiegów. W pozostałych przebiegach algorytm odnajdywał zawsze maksimum lokalne, bliskie globalnemu. Już przy liczbie generacji 5 średnie odnalezione maksimum jest na poziomie 98 % odniesienia, co można uznać za wystarczające w wielu mniej ważnych zastosowaniach. W przypadku elektrowni, praktycznie pewność osiągnięcia maksimum globalnego odniesienia daje liczba generacji 30, co przy liczności populacji 30 daje 900 jako liczbę odwołań do wartości funkcji kryterium (liczba obliczeń tej funkcji, na skutek powtarzalności wariantów jest znacznie mniejsza).

Podetap 3.2

W ramach podetapu realizowano obliczenia w wielu wariantach (748), o charakterze powtórzeń losowych z tymi samymi danymi wyjściowymi, dla nieograniczonej z góry liczby generacji, aż do momentu osiągnięcia w każdym wariantcie maksimum globalnego funkcji kryterium równego maksimum globalnemu odniesienia. Określono w ten sposób rozkład statystyczny (histogram) liczby generacji, przy której osiągnięto maksimum globalne odniesienia. Wyniki obliczeń zestawiono w tablicy 2.

Stwierdzono, że liczba generacji dająca pewność osiągnięcia maksimum globalnego odniesienia wynosi 130, zaś przy liczbie generacji 30 prawdopodobieństwo osiągnięcia tego maksimum wynosi 92 % (co w przybliżeniu pokrywa się z wynikami obliczeń w etapie 3.1).

Etap 4

W etapie 4 obliczeń dokonano konfrontacji wyników obliczeń z etapów 1 i 3 jw. z wynikami obliczeń za pomocą kombinowanej metody losowego poszukiwania ekstremum i planowania eksperymentu [1]. Obliczenia te zostały zrealizowane w pracy magisterskiej [4], wykonanej pod opieką autora niniejszego artykułu.

Stwierdzono, że przy obliczeniach za pomocą metody kombinowanej również osiągnięto maksimum globalne na poziomie odniesienia. Maksimum to zostało określone z maksimumów lokalnych na trajektoriach z 3 wyjściowych punktów poszukiwań. Ze względu na liczbę maksimumów lokalnych należało jednak przyjąć większą liczbę tych punktów - rzędu 8.

Uwzględniając liczbę oszacowań gradientu i liczbę kroków roboczych, można określić średnią liczbę odwołań do wartości funkcji kryterium na pojedynczej trajektorii poszukiwań w ramach metody kombinowanej na 30, co daje 240 jako całkowitą liczbę odwołań.

Tablica 1. Wyniki obliczeń za pomocą programu PROGEN 3.0 we współpracy z pakietem MDE1, w etapie 3.1 obliczeń.

Numer wariantu	Liczba przebiegów wariantu (powtórzeń losowych)	Liczba generacji w pojedynczym przebiegu wariantu	Przebiegi z osiągnięciem maksimum globalnego równego maksimum globalnemu odniesienia		Osiągnięte maksimum globalne funkcji kryterium, średnie z wszystkich przebiegów wariantu	
			liczba	frakcja	wartość bezwzględna	wartość względna w stosunku do maksimum globalnego odniesienia
				%		%
1	2	3	4	5	6	7
1	30	5	8	26,7	27,62	98,1
2	30	10	20	66,7	27,94	99,16
3	30	15	25	83,3	28,17	99,99
4	30	20	25	83,3	28,11	99,78
5	30	25	28	93,3	28,16	99,96
6	30	30	30	100	28,174	100
7	30	35	29	96,7	28,172	99,997
8	30	40	30	100	28,174	100

Tablica 2. Wyniki obliczeń za pomocą programu PROGEN 3.0 we współpracy z pakietem MDE1, w etapie 3.2 obliczeń.

Przedział liczby generacji, przy której osiągnięto maksimum globalne równe maksimum globalnemu odniesienia		Warianty obliczeń (powtórzenia losowe) o liczbie generacji jak w kol. 1, 2		Maksymalna liczba generacji jak w kol. 1, 2, która wystąpiła w obliczeniach etapu	Średnia liczba generacji jak w kol. 1, 2 z wszystkich wariantów obliczeń etapu 3.2
od	do	liczba	frakcja		
			%		
1	2	3	4	5	6
0	10	458	61,2	130	12,22
11	20	167	22,3		
21	30	61	8,2		
31	40	25	3,3		
41	50	8	1,1		
51	60	12	1,6		
61	70	3	0,4		
71	80	4	0,5		
81	90	2	0,3		
91	100	5	0,7		
101	110	0	0		
111	120	1	0,1		
121	130	2	0,3		
razem		748	100		

Etap 5

W ostatnim etapie obliczeń dokonano analizy porównawczej metody Gaussa-Seidela z algorytmem genetycznym. Metoda polega na przyjmowaniu do obliczeń kolejnych zmieniających się wartości jednej wybranej kolejnej zmiennej decyzyjnej, przy wartościach zmiennych pozostałych ustalonych na poziomie optymalnym. Stwierdzono, że algorytm Gaussa-Seidela, przy starcie z dowolnego z podzbioru 34 punktów startowych w przestrzeni sterowań odnalazł maksimum lokalne, zaś przy starcie z dowolnego z pozostałych 238

punktów - maksimum globalne; w obu wypadkach już przy 2 pełnych cyklach zmienności zmiennych decyzyjnych (66 obliczeń wartości funkcji kryterium).

5. Wnioski

Algorytm genetyczny potwierdził swą wysoką efektywność w procesie optymalizacji, w tym możliwość zastosowania go do globalnej optymalizacji procesu eksploatacji elektrowni.

Zaletą algorytmu genetycznego jest przeszukiwanie pełnej przestrzeni sterowań - odnajdowanie wszystkich ekstremów lokalnych. Inną ważną zaletą algorytmu jest brak jakichkolwiek wymagań i ograniczeń odnośnie do postaci i cech funkcji kryterium oraz zmiennych decyzyjnych. Algorytm genetyczny nie wymaga wstępnej analizy punktów startowych (choć o taką analizę można go wzbogacić), oszacowań gradientów funkcji, weryfikacji statystycznej itp.

Wadą algorytmu jest znacznie większa, niż w innych metodach liczba odwołań do wartości funkcji kryterium. W przypadku funkcji obliczanych metodami analitycznymi nie ma to praktycznie znaczenia; staje się istotne wówczas, gdy funkcję oblicza się za pomocą modeli komputerowych, tak jak w opisanym powyżej systemie decyzyjnym eksploatacji elektrowni.

Przewaga algorytmu genetycznego nad innymi metodami, w odniesieniu do globalnej optymalizacji procesu eksploatacji elektrowni, ujawni się w podprocesach decyzyjnych o dużej liczbie zmiennych decyzyjnych. Liczba odwołań do wartości funkcji kryterium, na skutek większej złożoności przestrzeni sterowań (znacznie większej liczby ekstremów lokalnych) stanie się wówczas, dla algorytmu genetycznego porównywalna w stosunku do innych metod.

W podprocesach jak powyżej, można poczynić próbę hybrydowego powiązania algorytmu genetycznego z kombinowaną metodą losowego poszukiwania ekstremum i planowania eksperymentu (na możliwość tego typu rozwiązań wskazano w [2]).

W toku dalszych prac należy zbadać celowość zastosowania algorytmu genetycznego wzbogaconego o dalsze, oprócz selekcji, krzyżowania i mutacji, procesy i mechanizmy genetyczne: specjację, płęć, nisze itp.; w tym celu należy śledzić postępy i osiągnięcia genetyki i programowania genetycznego.

W przypadku mało złożonych podprocesów decyzyjnych, mniej obciążającymi metodami w porównaniu z algorytmem genetycznym, w sensie liczby odwołań do wartości funkcji kryterium, są pozostałe opisane powyżej metody: przeliczania wszystkich wariantów, metoda Gaussa-Seidela (najmniejsza liczba odwołań do wartości funkcji kryterium; jest ona jednak dopuszczalna tylko przy braku ograniczeń wiążących zmienne decyzyjne; powinna być ponadto łączona z metodą Monte-Carlo celem losowania punktów startowych poszukiwań) oraz kombinowana metoda losowego poszukiwania ekstremum i planowania eksperymentu.

Literatura

1. Brzozowski W.: Modelowanie i optymalizacja procesu eksploatacji elektrowni cieplnej. Politechnika Częstochowska. Seria Monografie nr. 35. Częstochowa 1995 (rozprawa habilitacyjna).
2. Goldberg D.E.: Algorytmy genetyczne i ich zastosowania. WNT, Warszawa 1995.
3. Knuth D.E.: The Art of Computer Programming. Addison-Wesley, Reading 1981.
4. Krysiński M.: Program na mikrokomputer IBM PC w języku Turbo-Pascal do metody badań operacyjnych: kombinowanej metody losowego poszukiwania ekstremum funkcji i planowania eksperymentu. Wykonanie przykładowych obliczeń z zakresu eksploatacji elektrowni. Politechnika Częstochowska. Częstochowa, 1995 (praca magisterska).