




POLSKA AKADEMIA NAUK
Instytut Badań Systemowych

**WSPOMAGANIE INFORMATYCZNE
ROZWOJU
SPOŁECZNO-GOSPODARCZEGO
I OCHRONY ŚRODOWISKA**

Redakcja:
Jan Studziński
Ludostaw Drelichowski
Olgierd Hryniewicz





**WSPOMAGANIE INFORMATYCZNE
ROZWOJU
SPOŁECZNO-GOSPODARCZEGO
I OCHRONY ŚRODOWISKA**

Polska Akademia Nauk Instytut Badań Systemowych

Seria: BADANIA SYSTEMOWE

tom 36

Redaktor naukowy:

Prof. dr hab. Jakub Gutenbaum

Warszawa 2004

**WSPOMAGANIE INFORMATYCZNE
ROZWOJU
SPOŁECZNO-GOSPODARCZEGO
I OCHRONY ŚRODOWISKA**

Redakcja:

Jan Studziński
Ludosław Drelichowski
Olgierd Hryniewicz

Książka wydana dzięki dotacji KOMITETU BADAŃ NAUKOWYCH

Książka zawiera wybór artykułów poświęconych omówieniu aktualnego stanu badań w kraju w zakresie rozwoju modeli, technik i systemów zarządzania oraz ich zastosowań w różnych dziedzinach gospodarki narodowej. Wyodrębnioną grupę stanowią artykuły omawiające aplikacyjne wyniki projektów badawczych i celowych KBN.

Recenzenci artykułów:

Dr Lucyna Bogdan
Prof. dr hab. inż. Olgierd Hryniewicz
Dr Grażyna Petriczek
Prof. dr hab. inż. Andrzej Straszak
Dr inż. Jan Studziński



Senia 45187

Komputerowa edycja tekstu: Anna Gostyńska

© Instytut Badań Systemowych PAN, Warszawa 2004

Wydawca: Instytut Badań Systemowych PAN
ul. Newelska 6, 01-447 Warszawa

Sekcja Informacji Naukowej i Wydawnictw IBS PAN
tel. 836-68-22

Druk: Zakład Poligraficzny Urzędu Statystycznego w Bydgoszczy
Nakład 110 egz.

ISBN 83-85847-92-8
ISSN 0208-8028

ZASTOSOWANIE METOD „SOFT COMPUTING” DO EFEKTYWNEJ REDUKCJI EMISJI ZANIECZYSZCZEŃ

Piotr Holnicki, Andrzej Kaluszko, Jarosław Stańczak

Instytut Badań Systemowych, Polska Akademia Nauk

<holnicki@ibspan.waw.pl, kaluszko@ibspan.waw.pl, stanczak@ibspan.waw.pl>

In the paper a problem of optimal allocation of financial means for the reduction of air pollutants (sulfur oxides in this case) concentration in a given region is considered. The problem is formally stated as cost-constrained minimization of the environmental damage function by the optimal choice of desulfurization technologies, within the predefined set of the controlled plants (power and heating plants), thus belonging to a class of integer-type optimization problems.

The full enumeration of all solutions cannot be applied due to the large number of combinations, so the problem is solved using two soft computing methods. The first method is a heuristic algorithm based on the calculation of the damage function gradient. The second approach uses a genetic algorithm designed for solving this specific problem.

Both methods have been implemented and tested on the real data for Silesia Region (Poland) with the set of 20 major power plants, and 8 desulfurization technologies, which are to be allocated. Solving the relaxation of the integer problem, using the classical continuous-type gradient optimization algorithm, assesses the quality of solutions given by the above methods.

Keywords: Air pollution, mathematical modeling, emission abatement, heuristic algorithms, genetic algorithms.

1. Wstęp

W pracy opisano problem opracowania strategii redukcji koncentracji zanieczyszczeń atmosferycznych w wybranym regionie. Głównym celem pracy jest stworzenie narzędzia wspomagania decyzji, umożliwiającego kompleksową analizę kosztów i efektywności różnych technologii redukcji emisji zanieczyszczeń. Polska jest w tej chwili jednym z najbardziej zanieczyszczonych obszarów w Europie Środkowej. Zanieczyszczenie powietrza jest związane przede wszystkim z emisją dużych ilości tlenków siarki, emitowanych przez liczne elektrownie i ciepłownie, zakłady przemysłowe, domowe urządzenia grzewcze oraz transport kołowy. Największy wpływ na zanieczyszczenie atmosfery ma sektor energetyczny, ponieważ produkcja energii jest oparta w największej mierze na spalaniu węgla (również brunatnego). Unowocześnienie tego sektora i redukcja emitowanych zanieczyszczeń jest jednym z najważniejszych zadań w dziedzinie ochrony środowiska w najbliższym czasie.

Najprostsza strategia redukcji zanieczyszczeń na skalę regionalną polega na zmniejszeniu emisji we wszystkich branych pod uwagę źródłach o zadany mnożnik. Takie rozwiązanie nie jest jednak efektywne ekonomicznie. Naszym zadaniem jest opracowanie takiej strategii, która bierze pod uwagę nie tylko osiągnięte efekty środowiskowe, ale także koszt stosowanych technologii. Takie opisanie zadania prowadzi do jego sformułowania jako zadania optymalizacji.

2. Opis zadania

Załóżmy, że rozpatrujemy N sterowalnych źródeł emisji w regionie Ω i M technologii redukcji emisji. Każda technologia jest scharakteryzowana wydajnością redukcji emisji i kosztami jednostkowymi (inwestycyjnymi i eksploatacyjnymi). Naszym celem jest taki przydział technologii do źródeł emisji, żeby funkcja strat środowiskowych (funkcja celu) przyjęła wartość minimalną, przy ograniczeniach na całkowity koszt wprowadzenia tych technologii.

Wprowadźmy następujące oznaczenia:

$\Omega = L_x \times L_y$ – rozpatrywany obszar (prostokąt),

N – liczba sterowalnych źródeł,

M – liczba dostępnych technologii redukcji emisji,

C – ograniczenie na całkowite uśrednione roczne koszty (inwestycyjne i eksploatacyjne) wprowadzenia technologii,

$\vec{u} = [u_1, u_2, \dots, u_N]$ – wektor wielkości emisji rozpatrywanych źródeł,

$\vec{e} = [e_1, e_2, \dots, e_M]$ – wektor efektywności technologii redukcji emisji,

$F = \{f_{ij}\}, 1 \leq i \leq N, 1 \leq j \leq M$ – macierz kosztów redukcji emisji na jednostkę emisji,

$X = \{x_{ij}\}, 1 \leq i \leq N, 1 \leq j \leq M$ – macierz "0-1" przydziału technologii do źródeł (macierz zmiennych decyzyjnych).

Funkcja strat środowiskowych (funkcja celu) ma następującą postać

$$J(d) = \frac{1}{2} \int_{\Omega} w(x, y) [\max(0, d(x, y) - d_{ad})]^2 d\Omega, \quad (1)$$

gdzie:

$w(x, y)$ – funkcja wrażliwości (wagi) podobszaru,

d_{ad} – dopuszczalny poziom koncentracji zanieczyszczeń.

Prognoza koncentracji w równaniu (1) jest wyznaczana w następujący sposób

$$d(x,y) = d_0(x,y) + \sum_{i=1}^N A_i(x,y) \cdot u_i, \quad (x,y) \in \Omega \quad (2)$$

gdzie:

$d_0(x,y)$ – tło (wpływ źródeł niesterowalnych),

$A_i(x,y)$ – jednostkowa macierz transformacji (relacji emisja \rightarrow koncentracja) dla i -tego źródła.

Jednostkowa macierz transformacji $A_i(x,y)$ – reprezentuje wpływ i -tego źródła na całkowitą koncentrację, odniesiony do jednostkowej emisji. Wszystkie macierze $A_i(x,y)$; ($i = 1, \dots, N$), dla rozpatrywanych sterowalnych źródeł są wyznaczone wcześniej przez odpowiedni model prognostyczny. Tło koncentracji $d_0(x,y)$ jest także wyliczone wcześniej, przez uwzględnienie źródeł niesterowalnych w rozpatrywanym regionie i napływu zanieczyszczeń z sąsiednich regionów. Bieżąca emisja z i -tego źródła zależy od jego emisji początkowej $-u_i^0$ i efektywności zastosowanej technologii redukcji, zgodnie z wzorem

$$u_i = u_i^0 \sum_{j=1}^M (1 - e_j) \cdot x_{ij}, \quad \sum_{j=1}^M x_{ij} = 1, \quad x_{ij} \in \{0,1\}, \quad 1 \leq i \leq N \quad (3)$$

gdzie:

u_i – wielkość emisji bieżącej i -tego źródła,

u_i^0 – wielkość emisji początkowej i -tego źródła.

Koszty redukcji emisji w źródle składają się z dwu części: kosztów inwestycji i kosztów eksploatacji. Obydwa koszty: inwestycyjne i eksploatacyjne zależą od specyfiki technologii i parametrów źródła, gdzie dana technologia ma być zastosowana. Posługujemy się tutaj uproszczonym obliczaniem kosztów, gdzie koszty inwestycyjne wprowadzenie j -tej technologii redukcji do i -tego źródła emisji są wyliczane jako koszty roczne, uśrednione po całym okresie amortyzacji. Całkowite roczne koszty redukcji, rozpatrywane jako suma kosztów redukcji w poszczególnych źródłach, muszą być nie większe od zadanych

$$\sum_{i=1}^N c_i = \sum_{i=1}^N u_i^0 \sum_{j=1}^M f_{ij} \cdot x_{ij} = \sum_{i=1}^N u_i^0 \sum_{j=1}^M (f_{ij}^1 + f_{ij}^2) \cdot x_{ij} \leq C \quad (4)$$

gdzie:

f_{ij} – uśrednione roczne koszty całkowite j -tej technologii wprowadzonej do i -tego źródła,

f_{ij}^1 – uśrednione roczne koszty inwestycyjne j -tej technologii wprowadzonej do i -tego źródła,

f_{ij}^2 – uśrednione roczne koszty eksploatacyjne j -tej technologii wprowadzonej do i -tego źródła.

Możemy teraz sformułować następujące zadanie przydziału technologii redukcji emisji do źródeł emisji:

ZADANIE PRZYDZIAŁU (ZP): *Określ zbiór technologii redukcji emisji*

$$X^* = \{x_{ij}^* \in \{0,1\}: \sum_{j=1}^M x_{ij}^* = 1, 1 \leq i \leq N, 1 \leq j \leq M \}$$

w ten sposób, żeby funkcja strat środowiskowych (1) osiągnęła wartość minimalną

$$J(d(X^*)) \Rightarrow \min$$

przy uwzględnieniu ograniczeń na koszty całkowite

$$\sum_{i=1}^N c_i \leq C$$

3. Algorytmy optymalizacji

Zmienne decyzyjne x_{ij} w powyżej sformułowanym zadaniu **ZP** mogą przyjmować tylko wartości binarne $\{0,1\}$, **ZP** jest wobec tego zadaniem typu binarnego. Jego rozwiązanie przez prosty przegląd rozwiązań jest niemożliwy, ponieważ istnieje M^N możliwych kombinacji, co w przypadku 20 źródeł i 8 technologii daje liczbę 8^{20} . W celu rozwiązania **ZP** opracowano 2 metody przybliżone:

- algorytm heurystyczny oparty na wyznaczaniu gradientu funkcji celu,
- algorytm genetyczny.

Każda z tych metod wyznacza rozwiązanie bliskie optymalnemu lub optymalne. Do oceny tak uzyskanego rozwiązania została opracowana dodatkowa metoda, rozwiązująca **ZP** jako zadanie ze zmiennymi ciągłymi, w którym zmienne x_{ij} mogą przyjmować dowolne wartości pomiędzy 0 i 1.


3.1 Algorytm heurystyczny

Zasada działania algorytmu heurystycznego opiera się na uproszczeniu algorytmu wyboru i oceny. Schemat algorytmu wyboru i oceny jest przedstawiony poniżej. Jego idea polega na wyliczaniu w kolejnych iteracjach gradientu funkcji celu J (przy założeniu, że zmienne decyzyjne x_{ij} mogą przybierać wartości ciągłe) i wyboru zmiennej x'_{ij} , której odpowiadająca składowa gradientu funkcji J jest największa. Wybrana zmienna x'_{ij} z nadaną wartością 1 jest umieszczana na stosie zmiennych. Składowa gradientu funkcji J względem wybranej zmiennej może pozostawać największa w całym przedziale zmienności $0 \leq x'_{ij} \leq 1$ (rys. 1), lub przeciwnie, w całym rozpatrywanym przedziale nie jest największa (rys. 2). W przypadku pokazanym na rys. 2, składowa gradientu funkcji względem wybranej zmiennej nie jest największa w całym przedziale zmienności zmiennej decyzyjnej, choć jest taka na początku przedziału, co powoduje wybór tej zmiennej. Oznacza to, że ten wybór wymaga dalszej oceny – tę zmienną umieszczoną na stosie zmiennych oznaczamy jako zmienną „do oceny”. Szybkość działania algorytmu zależy od liczby zmiennych na stosie, oznaczonych „do oceny”.

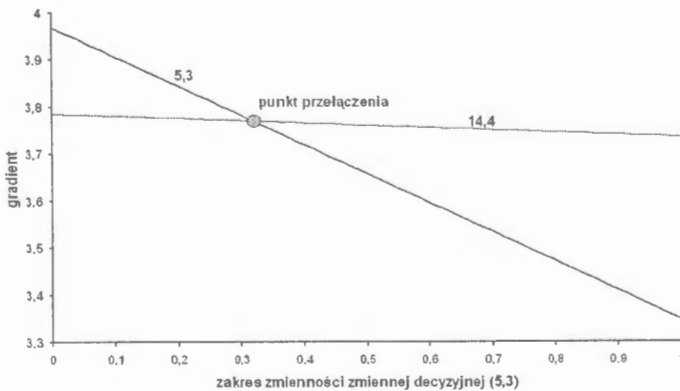
Schemat algorytmu wyboru i oceny

- KROK 1:** Ze zbioru wszystkich zmiennych decyzyjnych x_{ij} , $1 \leq i \leq N$, $1 \leq j \leq M$, wybierz te, które są związane z zastosowaniem wydajniejszej (tym samym droższej) technologii redukcji spalin w danym źródle i które mogą być zrealizowane ze względu na ograniczenia kosztowe i zapisz te zmienne w zbiorze X^{\sim} . Jeśli zbiór X^{\sim} jest pusty, przejdź do kroku 5. W przeciwnym przypadku, ze zbioru X^{\sim} wybierz zmienną x_{ij}^{\sim} , dla której składowa gradientu funkcji celu J jest największa i nadaj tej zmiennej wartość $x_{ij}^{\sim} = 1$.
- KROK 2:** Dodaj wybraną zmienną $x_{ij}^{\sim} = 1$ do nowego rozwiązania i oblicz nową wartość funkcji strat środowiskowych J . Jeśli ta wartość jest niższa od dotychczas najniższej J_{\min} , zapisz ją w J_{\min} .
- KROK 3:** Jeśli składowa gradientu funkcji J jest największa w całym przedziale zmienności x_{ij}^{\sim} , oznacz x_{ij}^{\sim} jako „ustalone”; w przeciwnym przypadku oznacz x_{ij}^{\sim} jako „do oceny”.
- KROK 4:** Dodaj zmienną x_{ij}^{\sim} do stosu rozwiązań. Przejdź do kroku 1.

KROK 5: Czy na stosie zmiennych są wyłącznie zmienne oznaczone jako „ustalone”? Jeśli tak, zakończ. W przeciwnym przypadku zdejmij ze stosu wszystkie zmienne powyżej pierwszej od góry zmiennej „do oceny”, zmień wartość tej zmiennej na 0, a oznaczenia na „ustalone”. Przejdź do kroku 1.



Rysunek 1. Składowa gradientu dla zmiennej (12,2) jest największa w całym przedziale jej zmienności



Rysunek 2. Składowa gradientu dla zmiennej (5,3) nie jest największa w całym przedziale jej zmienności

Opisany powyżej algorytm wyboru i oceny wyznacza rozwiązanie optymalne, ale czas obliczeń może być długi, w zależności od tego ile zmiennych umieszczonych na stosie będzie oznaczonych „do oceny”. W skrajnym przypadku wszystkie

zmienne na stosie mogą być oznaczone „do oceny”, co oznacza, że wykonujemy pełny przegląd.

Metoda heurystyczna rozwiązania ZP polega na uproszczeniu przedstawionego algorytmu w ten sposób, że rezygnujemy z oceny zmiennych umieszczonych na stosie. Poprawiamy w ten sposób zasadniczo czas obliczeń, kosztem jakości rozwiązania. Z przeprowadzonych obliczeń testowych wynika, że pogorszenie jakości rozwiązań nie jest duże. Ocena jakości uzyskanych rozwiązań jest przedstawiona w dalszej części pracy.

3.2 Algorytm genetyczny

Zakodowanie rozwiązania

Kolejne rozwiązania, uzyskiwane w kolejnych iteracjach algorytmu genetycznego traktujemy jako osobniki populacji, które są wektorami liczb całkowitych o długości N (liczba źródeł emisji) i M możliwych wartościach na każdej pozycji (liczba możliwych technologii redukcji emisji). Każdy osobnik jest dodatkowo opisany pewnymi elementami, wymaganymi przez algorytm genetyczny:

- wektor współczynników jakości operatorów, o długości równej liczbie zastosowanych operatorów genetycznych,
- liczba całkowita – numer aktualnie wybranego operatora genetycznego do modyfikacji rozwiązania,
- flaga (true/false) – identyfikująca, czy dany osobnik był już modyfikowany w danej iteracji algorytmu.

Funkcja dopasowania osobnika

Funkcja dopasowania osobnika oparta jest na minimalizacji funkcji F , będącej ważoną sumą funkcji strat środowiskowych J i kary za przekroczenie ograniczeń kosztowych. Funkcja wyrażająca karę za przekroczenie ograniczeń kosztowych została dobrana doświadczalnie

$$F = J + 10000 \cdot \sqrt{\max(0, \sum_{i=1}^N c_i - C)} \quad (5)$$

Zastosowane operatory genetyczne

Efektywność algorytmów genetycznych zależy w dużej mierze od dopasowania operatorów genetycznych do specyfiki zadania. W naszym przypadku zastosowano następujące operatory:

- mutacja (pojedyncza i wielokrotna) – zastąpienie wybranej metody (technologii) inną, wylosowaną,

- przestawienie (pojedyncze i wielokrotne) – wymiana metod pomiędzy dwoma osobnikami na wybranych pozycjach,
- krzyżowanie – wymiana fragmentów wektorów o wylosowanej długości pomiędzy dwoma osobnikami,
- inwersja – odwrócenie kolejności metod w wybranym fragmencie wektora,
- mutacja „inteligentna” – podstawienie na wybranej pozycji metody, która daje najlepszą wartość funkcji dopasowania (M możliwości),
- mutacja „inteligentna” II – jak wersja poprzednia, lecz sprawdzane są dwie pozycje na raz (M^2 możliwości).

Algorytm genetyczny z oceną operatorów

Obecność wielu operatorów genetycznych powoduje konieczność ustalenia prawdopodobieństw ich doboru. Im bardziej dany operator polepsza funkcję celu danego osobnika, tym większa staje się przypisana mu wartość współczynnika jakości, a co za tym idzie, większe jest prawdopodobieństwo jego doboru, co ilustruje wzór (6)

$$p_{ij}(t) = \frac{q_{ij}(t)}{\sum_{i=1}^{L(t)} q_{ij}(t)} \quad (6)$$

gdzie:

$q_{ij}(t)$ – współczynnik jakości i -tej operacji w chwili t dla j -tego osobnika populacji,

$p_{ij}(t)$ – prawdopodobieństwo wystąpienia i -tej operacji w chwili t dla j -tego osobnika,

$L(t)$ – liczba operacji genetycznych (może zależeć od czasu).

Każdy osobnik populacji ma, oprócz zakodowanego rozwiązania, swój własny ranking jakości operatorów, na którego podstawie losuje operator, który modyfikuje go w bieżącej iteracji. Należy zaznaczyć, że na danego osobnika działa w jednej iteracji tylko jeden operator, można zatem jego działaniu jednoznacznie przypisać zasługi modyfikacji osobnika. Współczynnik jakości operatora jest powiększany lub pomniejszany w zależności od odpowiednio powodzenia lub niepowodzenia modyfikacji osobnika, zgodnie z poniższym wzorem (7)

$$q_{ij}(t+1) = \begin{cases} q_{0ij}(t) + \frac{x_{ij}(t+1)}{\bar{x}(t)} + \alpha_{ij}(t) * q_{ij}(t), & \text{dla } i = l \\ q_{ij}(t), & \text{dla } i \neq l \end{cases} \quad (7)$$

gdzie:

- $q_{ij}(t)$ – wartość współczynnika jakości operacji i osobnika j w iteracji t ,
- $q_{0ij}(t)$ – wartość stała (kredyt), uniemożliwiająca całkowite wyeliminowanie operatora (może zależeć od czasu);
- $x_{ij}(t+1)$ – poprawa funkcji celu (wartość nieujemna, = 0 w przypadku niepowodzenia),
- $\bar{x}(t)$ – średnia wartość poprawy funkcji celu uzyskana dotychczas,
- $a_{ij}(t)$ – współczynnik zapominania, uwytatniający rolę najnowszych danych, przy osłabianiu dawniejszych (może zależeć od czasu),
- l – indeks operatora wybranego w danej iteracji do modyfikacji rozwiązania.

Współczynnik jakości operatora nigdy nie schodzi poniżej pewnej wartości minimalnej dzięki występowaniu we wzorze (7) składowej $q_{0ij}(t)$. Każdy operator, nawet nie przynoszący dotychczas żadnych korzyści, może je przynieść w przyszłości. Składowa $x_{ij}(t)$ jest znormalizowaną poprawą funkcji celu rozwiązywanego zadania. W przypadku braku poprawy jest równa zero. Trzecia składowa wzoru (7) przechowuje informację o dawniejszych osiągnięciach operatora, przemnożonych przez współczynnik zapominania $\alpha(t)$, odpowiedzialny za właściwe wyważenie wpływu nowszych i starszych osiągnięć na wartość współczynnika jakości operatora.

Zastosowane metody selekcji

Selekcja mieszana składa się z dwu metod składowych o znacząco różnych właściwościach: selekcji histogramowej (mającej właściwość znaczącego zwiększania zróżnicowania populacji) i deterministycznej ruletki (z silnym naciskiem na promowanie najlepszych osobników).

Metody te są losowo wybierane i wykonywane w trakcie działania algorytmu genetycznego. Prawdopodobieństwo wyboru i wykonania każdej z metod pokazuje wzór:

$$p_{his}(t+1) = \begin{cases} p_{his}(t) \cdot (1-a) & \text{dla } \max(F_{av}(t) - F_{\min}(t), F_{\max}(t) - F_{av}(t)) > 3 \cdot \sigma(F(t)) \\ p_{his}(t) \cdot (1-a) + 0.5 \cdot a & \text{dla } \left(\max(F_{av}(t) - F_{\min}(t), F_{\max}(t) - F_{av}(t)) \geq 0.5 \cdot \sigma(F(t)) \wedge \right. \\ & \left. \max(F_{av}(t) - F_{\min}(t), F_{\max}(t) - F_{av}(t)) \leq 3 \cdot \sigma(F(t)) \right) \\ p_{his}(t) \cdot (1-a) + a & \text{dla } \max(F_{av}(t) - F_{\min}(t), F_{\max}(t) - F_{av}(t)) < 0.5 \cdot \sigma(F(t)) \end{cases}$$

$$p_{det}(t+1) = 1 - p_{his}(t+1)$$

(8)

gdzie:

$P_{his}(t)$ – prawdopodobieństwo wystąpienia selekcji histogramowej,

$p_{det}(t)$ – prawdopodobieństwo wystąpienia selekcji metodą deterministycznej ruletki,

$F_{av}(t)$, $F_{min}(t)$, $F_{max}(t)$ – średnia, minimalna i maksymalna wartość funkcji dopasowania w populacji,

$\sigma(F(t))$ – odchylenie standardowe wartości funkcji dopasowania w populacji.

Jeżeli populacja osobników ma zbyt małe odchylenie standardowe ($\sigma(F(t))$) w stosunku do rozpiętości wartości funkcji dopasowania ($\max(F_{av}(t) - F_{min}(t), F_{max}(t) - F_{av}(t))$), wtedy następuje zwiększenie prawdopodobieństwa wystąpienia selekcji histogramowej (pozycja trzecia we wzorze (8)). W przeciwnym przypadku zwiększane jest prawdopodobieństwo wystąpienia selekcji metodą deterministycznej ruletki (pozycja pierwsza we wzorze (8)). Jeśli natomiast parametry populacji są zawarte w przedziale uznanym za korzystny, to prawdopodobieństwa wystąpienia obu metod selekcji są prawie równe (pozycja druga we wzorze (8)). Należy zaznaczyć także fakt, że zawsze $p_{his}(t) + p_{det}(t) = 1$, czyli któraś z metod zawsze musi wystąpić.


Selekcja metodą deterministycznej ruletki

Metoda deterministycznej ruletki, polega ona na przyjęciu takiej liczby potomków danego osobnika, jaka wynika z zaokrąglonego do najbliższej wartości całkowitej lub przez odrzucenie części ułamkowej stosunku wartości jego funkcji dopasowania do średniej wartości funkcji dopasowania dla całej populacji pomnożonego przez jej liczebność. Otrzymane wartości funkcji dopasowania są skalowane tak, aby zminimalizować błędy całkowitych przybliżeń rzeczywistych wartości funkcji dopasowania. Występujący mimo tego ewentualny niedomiar jest zapełniany najlepszymi osobnikami, które nie weszły do populacji lub też tymi o największych odrzuconych częściach ułamkowych. Nadmiar jest likwidowany przez eliminację odpowiedniej liczby najgorszych z wybranych osobników.

Selekcja histogramowa

Selekcja histogramowa tworzy listę osobników o różnych wartościach funkcji dopasowania. Lista ta jest przeważnie krótsza niż lista osobników w całej populacji z uwagi na często występujące powtórzenia tych samych osobników w populacji. Następnie jest obliczana średnia wartość funkcji dopasowania osobników z listy. Każdy osobnik z listy (tylko jeden o danej wartości funkcji dopasowania) przekazuje do populacji potomnej taką liczbę osobników, jaka wynika z zaokrąglonego do najbliższej wartości całkowitej stosunku wartości jego funkcji dopasowania do sumy wartości funkcji dopasowania dla listy, pomnożonego przez

liczność populacji potomnej. Zastosowano tu, podobnie jak w przypadku selekcji metodą deterministycznej ruletki, mechanizm skalowania wartości funkcji dopasowania, aby przeciwdziałać błędom zaokrągleń. Jeśli mimo tego powstanie populacja potomna o większej lub mniejszej od przewidywanej liczbie osobników, populacja jest uzupełniana najlepszymi osobnikami, które nie weszły już do nowego pokolenia (przy niedomiarze) lub też usuwane są najslabsze z wybranych osobników (przy nadmiarze). Rys. 3 pokazuje proces poszukiwania najlepszego rozwiązania przez algorytm genetyczny dla przykładowych danych. Najlepsze rozwiązanie jest znajdowane w ciągu mniej niż 40 iteracji algorytmu.



Rysunek 3. Wykres przebiegu obliczeń algorytmu genetycznego (wartość funkcji celu dla najlepszego rozwiązania na danym etapie).

3.3 Algorytm rozwiązania zadania ciągłego

Zdefiniowane w rozdziale 2 zadanie minimalizacji funkcji przekształcamy w ten sposób, że zmienne decyzyjne x_{ij} mogą przyjmować wartości ciągłe należące do przedziału $[0, 1]$. Nowe zadanie minimalizacji funkcji strat środowiskowych jest opisane poniżej:

$$J(d) = \frac{1}{2} \int_{\Omega} w(x, y) [\max(0, d(x, y) - d_{ad})]^2 d\Omega \Rightarrow \min$$

$$d(x, y) = d_0(x, y) + \sum_{i=1}^N A_i(x, y) \cdot u_i, \quad (x, y) \in \Omega$$

$$u_i = u_i^0 \sum_{j=1}^M (1 - e_j) \cdot x_{ij}$$

$$\sum_{j=1}^M x_{ij} = 1, \quad x_{ij} \geq 0, \quad 1 \leq i \leq N, \quad 1 \leq j \leq M$$

$$\sum_{i=1}^N u_i^0 \left(\sum_{j=1}^M f_{ij} \cdot x_{ij} \right) \leq C$$

Gradient funkcji J względem zmiennej x_{ij} jest wyrażony wzorem

$$J'_{x_{ij}} = u_i^0 (1 - e_j) \int_{\Omega} w(x, y) [\max(0, d(x, y) - d_{ad})] A_i(x, y) d\Omega$$

Schemat algorytmu rozwiązania zadania ciągłego

KROK 1: Ustaw $i=0$, wybierz punkt startowy x_i .

KROK 2: Wylicz wartość funkcji $J(x_i)$.

KROK 3: Wylicz wartość gradientu funkcji $-J'(x_i)$.

KROK 4: Znajdź x_{i+1} takie, że $J(x_{i+1}) \Rightarrow \min$ w kierunku $-J'(x_i)$

KROK 5: Czy x_{i+1} spełnia warunek zakończenia? Jeśli tak, zakończ, jeśli nie, ustaw $x_i = x_{i+1}$ i wróć do kroku 2.

Rozwiązanie wyliczone przez opisany powyżej algorytm jest nie do zrealizowania praktycznego, ponieważ dopuszcza przydział kilku technologii redukcji emisji do jednego źródła. Celem znalezienia takiego rozwiązania jest uzyskanie oszacowania jakości rozwiązania opisanych wcześniej metod przybliżonych. Porównanie uzyskanych rozwiązań przedstawiono w następnym rozdziale.

4. Porównanie i ocena jakości otrzymanych rozwiązań

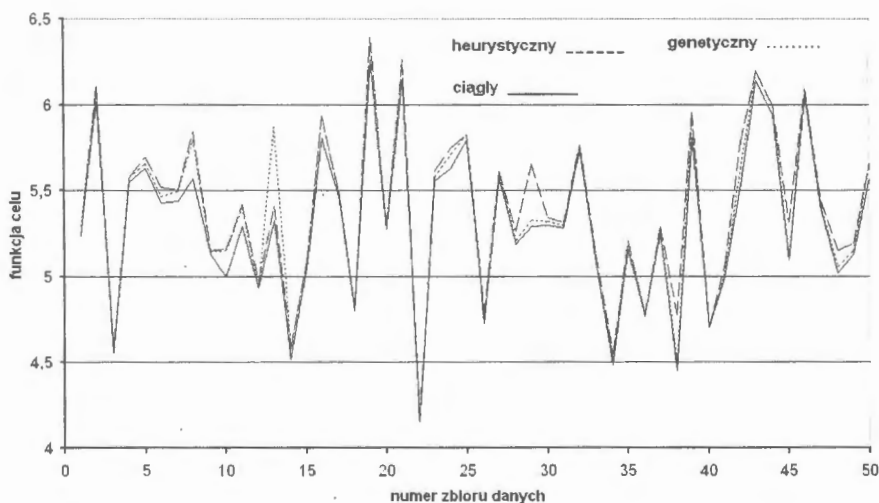
Opisane wyżej metody obliczeniowe sprawdzono na 50 różnych zestawach danych, dla różnych wartości ograniczenia kosztowego. Dane dotyczą regionu Górnego Śląska, o wymiarach 110 km x 76 km, o dużej koncentracji elektrowni i elektrociepłowni. Przy rozwiązywaniu zadania uwzględniono 20 dużych zakładów energetycznych jako źródła emisji. Pod uwagę wzięto 8 technologii redukcji emisji (5 podstawowych i 3 mieszane) o następujących efektywnościach:

- technologia "zerowa" ($e = 0$),
- węgiel niskosiarkowy ($e \cong 30$),
- metoda sucha ($e \cong 35$),
- metoda półsucha ($e \cong 75$),


- metoda MOWAP ($e \cong 85$),
- węgiel niskosiarkowy + metoda sucha ($e \cong 545$),
- węgiel niskosiarkowy + metoda pół sucha ($e \cong 825$),
- węgiel niskosiarkowy + metoda MOWAP ($e \cong 895$).

Rysunki 4 i 5 przedstawiają wyniki obliczeń dla wymienionych wyżej 50 zestawów danych, dla dwóch wartości ograniczeń kosztowych: 100 mln zł/rocznie i 200 mln zł/rocznie.

Jak można zaobserwować na rysunkach, obydwie metody przybliżone: heurystyczna i genetyczna dają rozwiązania bliskie optymalnemu. Rozwiązania uzyskiwane przez te metody są gorsze o kilka procent od rozwiązania otrzymanego dla zadania ciągłego. Rozwiązanie wyliczone przez algorytm genetyczny jest zwykle nieco lepsze od wyliczonego przez algorytm heurystyczny. Metoda heurystyczna jest kilka razy szybsza od genetycznej, przy czym trzeba podkreślić, że są to czasy niewielkie, w przypadku metody heurystycznej kilkadziesiąt sekund. W przypadku metody genetycznej czas obliczeń można skrócić przez ograniczenie liczby iteracji, kosztem niewielkiego pogorszenia jakości rozwiązania. Można uznać, że obydwie opisane metody przybliżone mogą być stosowane do rozwiązania zadania przydziału technologii redukcji emisji do źródeł emisji.



Rysunek 4. Porównanie jakości otrzymanych wyników dla 3 algorytmów obliczeniowych dla ograniczenia kosztowego 100 mln zł/rocznie



Rysunek 5. Porównanie jakości otrzymanych wyników dla 3 algorytmów obliczeniowych dla ograniczenia kosztowego 200 mln zł/rocznie

Literatura

- Pshenitschny B.N. (1983) *Metody linearyzacji* (w języku rosyjskim). Nauka, Moskwa.
- Holnicki P., Kałuszko A., Żochowski A. (1994) A microcomputer implementation of air quality forecasting system for urban scale. *Microcomputer Applications*, 13, 2, 76-84.
- Kałuszko A., Holnicki P. (2000) Decision support method for cost-effective emission control on regional scale. *Annals of Operations Research*, 97, 1.
- Kałuszko A., Holnicki P. (2002) *Wspomaganie decyzji wyboru strategii redukcji koncentracji SO₂ w wybranym regionie*. EXIT, Warszawa.
- Kałuszko A., Holnicki P. (2004) Decision support for optimal emission reduction. *Management of Environmental Quality*, 15, 3.

IBS PAN *Seria*

45187

Bibl. podręczna

ISSN 0208-8028

ISBN 83-85847-92-8

**W celu uzyskania bliższych informacji i zakupu dodatkowych egzemplarzy
prosimy o kontakt z Instytutem Badań Systemowych PAN
ul. Newelska 6, 01-447 Warszawa
tel. 837-35-78 w. 241 e-mail: biblioteka@ibspan.waw.pl**