

OPTYMALNE DECYZJE

Katarzyna Jakowska-Suwalska

Adam Sojda

Politechnika Śląska w Gliwicach

ZASTOSOWANIE ALGORYTMU VEGA DO WYZNACZANIA POZIOMU ZAMÓWIEŃ NA MATERIAŁY W PRZEDSIĘBIORSTWIE GÓRNICZYM*

Wprowadzenie

Działalność wydobywcza w kopalni węgla kamiennego związana jest z prowadzeniem prac w warunkach charakteryzujących się zmiennością losową. Struktura geologiczna górotworu nie jest do końca zbadana, zatem nie jest możliwe dokładne określenie zapotrzebowania na materiały. Zmiany w strukturze geologicznej mogą powodować zmiany o charakterze ilościowym, konieczność zwiększenia zapotrzebowania na dany materiał, np. zmniejszenie odstępów pomiędzy poszczególnymi odrzwiami obudowy do zabudowy chodnika, ale może również wymusić zmianę typu obudowy na mocniejszą. Przeprowadzane badania potwierdzają losowy charakter zużycia materiałów w kopalni węgla kamiennego. Planowanie zapotrzebowania materiałowego powinno z jednej strony uwzględniać ten specyficzny aspekt działalności przedsiębiorstwa, z drugiej racjonalna i ekonomicznie uzasadniona działalność gospodarcza powinna minimalizować koszty zakupu materiałów.

* Praca powstała w ramach realizacji projektu badawczego nr N N524 552038 „Wielokryterialne wspomaganie planowania i kontrolowania potrzeb materiałowych w przedsiębiorstwie górniczym” finansowanego przez Ministerstwo Nauki i Szkolnictwa Wyższego.

1. Postać modelu

W długoterminowym planowaniu wielkości zapotrzebowania na materiały w kopalni uwzględnia się plany wydobywania i związane z nim planowane metry robót przygotowawczych, planowane liczby zbrojonych i likwidowanych ścian. Każdy materiał związany jest z odpowiednim typem produkcji (wydobycie, zbrojenie, likwidacja ścian, roboty przygotowawcze), dla której jest on przeznaczony. Jako jednostkę produkcji przyjęto jednostki odpowiednie dla typów produkcji i tak: dla wydobywania – tony, dla robót przygotowawczych – metry bieżące, dla zbrojenia i likwidacji ścian ich liczbę lub długość w metrach.

Oznaczono przez Z_i wielkość zapotrzebowania na materiał M_i , natomiast przez z_i wielkość zapotrzebowania na ten materiał na jednostkę produkcji ($i = 1, 2, \dots, r$). W pracy założono, że tendencje zużycia z_i materiału M_i wyznaczone na podstawie historycznych wielkości x_{it} ($t = 1, 2, \dots, n$) nie ulegną zmianie w planowanym okresie. W ogólnym modelu ustalania wielkości zapotrzebowania za kryteria oceniające przyjęto:

(a) wielkość odchylenia zapotrzebowania z_i od historycznych wielkości zużycia materiałów x_{it} ($t = 1, 2, \dots, n$),

(b) koszty zakupu wszystkich analizowanych materiałów.

Zagadnienie można zapisać w postaci

$$\left\{ \begin{array}{ll} |x_{it} - z_i| \rightarrow \min, & (a) \\ \sum_{i=1}^r c_i z_i W_i \rightarrow \min & (b) \\ \sum_{i=1}^r c_i z_i W_i \leq K \\ z_i^{\text{dolne}} \leq z_i \leq z_i^{\text{górne}} \\ z_i W_i \in S_i \\ i = 1, 2, \dots, r \\ t = 1, 2, \dots, n. \end{array} \right. \quad (1)$$

gdzie:

c_i – cena jednostki materiału M_i ,

K – kwota przeznaczona na zakup materiałów,

W_i – planowana wielkość produkcji, na którą przeznaczony jest materiał M_i ,

z_i – wielkość zapotrzebowania na materiał M_i na jednostkę produkcji,

S_i – zbiór wyznaczony na podstawie dodatkowych warunków, dla zmiennej z_i (np. S_i to zbiór liczb naturalnych, jeśli wielkość zapotrzebowania $Z_i = W_i z_i$ na materiał M_i wyrażona w jednostkach naturalnych ma być liczbą całkowitą),

$$z_i^{dolne} \leq \min(x_{it}; t = 1, 2, \dots, n), i = 1, 2, \dots, r,$$

$$z_i^{gorne} \geq \max(x_{it}; t = 1, 2, \dots, n), i = 1, 2, \dots, r.$$

Wartości z_i^{dolne} , z_i^{gorne} mogą być również wyznaczone przez decydenta na podstawie doświadczenia bądź dodatkowych informacji o zapotrzebowaniu.

Zagadnienie (1) jest zagadnieniem programowania nieliniowego (nieliniowa grupa $r \cdot n$ funkcji celów (a)) z liniowymi ograniczeniami.

Niech wielkości $w_t > 0$ będą wagami nadanymi historycznym wielkościom zużycia x_{it} ($t = 1, 2, \dots, n$) materiałów M_i .

Można wprowadzić wagi postarzające informacje tak, aby wielkości zużycia najbliższe planowanemu okresowi miały największą wartość dla decydenta. W pracy przyjęto wagi liniowe, które wyznacza się ze wzoru

$$w_t = \frac{2t}{n(n+1)} \quad \text{dla } t = 1, 2, \dots, n \quad (2)$$

Zagadnienie przyjmie wtedy postać

$$\left\{ \begin{array}{l} \sum_{t=1}^n w_t |x_{it} - z_i| \rightarrow \min \quad (a) \\ \sum_{i=1}^r c_i z_i W_i \rightarrow \min \quad (b) \\ \sum_{i=1}^r c_i z_i W_i \leq K \\ z_i^{dolne} \leq z_i \leq z_i^{gorne} \\ z_i W_i \in S_i \\ i = 1, 2, \dots, r. \end{array} \right. \quad (3)$$

Będzie to zagadnienie z r nieliniowymi funkcjami celu (a), liniową funkcją celu (b) i liniowymi ograniczeniami.

W wypadku, gdy decydent potrafi nadać poszczególnym materiałom M_i wagi $u_i > 0$ ($i = 1, 2, \dots, r$) uwzględniające ich ważność w procesie produkcyjnym, można wprowadzić dla grupy r funkcji celów (a) funkcję skalaryzującą¹, np. ważoną sumę funkcji celu.

Aby można było przeprowadzić taką skalaryzację, należy sprowadzić wszystkie funkcje celu z grupy (a) do jednakowej skali. W związku z tym zaproponowano unitaryzację² na podstawie wzorów

$$z_i^u = \frac{z_i - z_i^{\text{dolne}}}{z_i^{\text{górne}} - z_i^{\text{dolne}}}, \quad x_{it}^u = \frac{x_{it} - \min(x_{it}; t=1, 2, \dots, n)}{\max(x_{it}; t=1, 2, \dots, n) - \min(x_{it}; t=1, 2, \dots, n)} \quad (4)$$

Zagadnienie można wtedy zapisać w postaci

$$\left\{ \begin{array}{l} \sum_{t=1}^n w_t \sum_{i=1}^r u_i |x_{it}^u - z_i^u| \rightarrow \min, \quad (a) \\ \sum_{i=1}^r c_i Q_i \rightarrow \min \quad (b) \\ \sum_{i=1}^r c_i Q_i \leq K \\ 0 \leq z_i^u \leq 1 \\ Q_i \in S_i \\ i = 1, 2, \dots, r, \end{array} \right. \quad (5)$$

gdzie $Q_i = (z_i^u(z_i^{\text{górne}} - z_i^{\text{dolne}}) + z_i^{\text{dolne}})W_i$.

Do rozwiązania zagadnienia (5) zaproponowano algorytm genetyczny VEGA poszukujący rozwiązań niezdominowanych – Pareto suboptymalnych.

¹ A. Ameljańczyk: Optymalizacja wielokryterialna w problemach sterowania i zarządzania. Ossolineum Wrocław 1984; E. Konarzewska-Gubała: Programowanie przy wielorakości celów. PWN, Warszawa 1980; J. Branke, K. Deb, K. Miettinen, R. Słowiński: Multiobjective Optimization – Interactive and Evolutionary Approaches Lecture Notes in Computer Science. Springer-Verlag Berlin-Heidelberg 2008; Multiple Criteria Decision Analysis. State of the art Surveys. Red. J. Figueira, S. Greco, M. Ehrgott. Springer Science, 2005; W. Ogryczak: Wielokryterialna optymalizacja liniowa i dyskretna. Uniwersytet Warszawski, Warszawa 1997; B. Roy, D. Bouyssou: Aide Multicritere a la Decision: Methodes et Cas. Economica, Paris 1993.

² K. Miettinen: Nonlinear Multiobjective Optimization. Kluwer Academic Publishers, Boston 1998; K. Kukuła: Metoda unitaryzacji zerowej. PWN, Warszawa 2000; J. Branke, K. Deb, K. Miettinen, R. Słowiński: Op. cit.

2. Opis algorytmu genetycznego VEGA

Algorytm genetyczny VEGA został zaprezentowany przez S.D. Schaffera w 1984 roku. Jest to jeden z najstarszych i najczęściej wykorzystywanych algorytmów do rozwiązywania zagadnień wielokryterialnych. Algorytm ten jest prosty w implementacji i zajmuje niewiele pamięci komputera. Poszukuje się w nim rozwiązań niezdominowanych – Pareto suboptymalnych³. Do uruchomienia algorytmu potrzebne są dane początkowe:

N – rozmiar populacji,

T – maksymalna liczba pokoleń (iteracji algorytmu),

P_k – prawdopodobieństwo krzyżowania,

P_m – prawdopodobieństwo mutacji,

K – liczba funkcji celu.

W etapie początkowym w dowolny sposób generuje się pierwszy zbiór N rozwiązań.

Zbiór ten dzieli się na K równoliczne podpopulacje. Selekcja rozwiązań do dalszej reprodukcji odbywa się odrębnie w każdej podpopulacji na podstawie jednej funkcji celu f_k ($k = 1, 2, \dots, K$). Każdy z osobników – rozwiązań jest oceniany poprzez funkcję przystosowania. Funkcja przystosowania pozwala na ocenę rozwiązania pod względem wartości optymalizowanej funkcji bądź spełnienia dodatkowych ograniczeń⁴. Im lepsze rozwiązanie reprezentuje danych osobnik, tym większa jest wartość funkcji przystosowania. Na podstawie jej wartości wybierane są te rozwiązania – osobniki, które będą brać udział w procesie reprodukcji. Sam proces wyboru może być oparty na metodzie koła ruletki, metodzie turniejowej, metodzie stochastycznej⁵ itp. Wybrane osobniki ze wszystkich podpopulacji łączy się w jedną populację. Następnie wybrane osobniki biorą udział w procesie reprodukcji, na który składają się dwa operatory: operator krzyżowania oraz operator mutacji. Po zastosowaniu tych operatorów tworzone jest nowe pokolenie – nowy zbiór rozwiązań. Ponieważ w przyrodzie ewolucja odbywa się przez pokolenia, w implementacji zajmuje to odpowiednią liczbę iteracji, stąd procedurę tę powtarza się T razy. Po wykonaniu każdej iteracji wyszukiwane i zapamiętywane są rozwiązania Pareto suboptymalne. Po zakończeniu algorytmu VEGA rozwiązania Pareto suboptymalne z każdego po-

³ J.D. Schaffer: Some Experiments In Machine Learning Using Vector Evaluated Genetic Algorithms. PhD Dissertation. Vanderbilt University, Nashville 1984.

⁴ Z. Michalewicz: Algorytmy genetyczne + struktury danych = programy ewolucyjne. WNT, Warszawa 1996, s. 174.

⁵ D.E. Goldberg: Algorytmy genetyczne i ich zastosowania. WNT, Warszawa 1998, s. 136.

kolenia są łączone w jeden zbiór rozwiązań i znów wyszukiwane są rozwiązania niezdominowane. Po spełnieniu warunku zatrzymania otrzymane najlepsze rozwiązanie uznaje się za rozwiązanie zadania.

3. Przykład zastosowania algorytmu VEGA do wyznaczania wielkości zamówień na wybrane materiały

Do analizy wybrano:

M_1 – drewno kopalniane (używane do obudowy chodników),

M_2 – klej poliuretanowy (używany do uszczelniania wyrobisk),

M_3 – krążniki stalowe gładkie M_3 (jeden z elementów przenośników taśmowych).

Wielkości zapotrzebowania Z_i na materiały M_i wyrażone są w następujących jednostkach: Z_1 w m^3 , Z_2 w kg, Z_3 w sztukach. Ponieważ materiały M_1 , M_2 są używane w procesie robót przygotowawczych, natomiast M_3 w procesie wydobywania, wielkości zapotrzebowania z_i będą wyrażone w następujących jednostkach: z_1 w m^3 /metry robót przygotowawczych, z_2 w kg/metry robót przygotowawczych, z_3 w sztukach/tonę wydobywania. Przyjęto, że wszystkie rozważane materiały są tak samo ważne w procesie wydobywania, zatem wagi przyporządkowane materiałom M_1 , M_2 , M_3 , to $u_1 = u_2 = u_3 = 1/3$. W tabeli 1 podano planowane wielkości wydobywania, liczby metrów robót przygotowawczych, ceny jednostkowe zakupu materiałów M_1 , M_2 , M_3 oraz kwotę K przeznaczoną na zakup materiałów w planowanym okresie.

Tabela 1

Ceny jednostkowe materiałów M_1 , M_2 , M_3 , planowane roczne wydobywanie, planowana liczba metrów robót przygotowawczych, roczna kwota wydatków na zamawiane materiały

Prognostowana średnia cena kg kleju – c_1	13,75 zł
Prognostowana średnia cena za m^3 drewna – c_2	296 zł
Prognostowana średnia cena za krążnik – c_3	16,96 zł
Planowane wydobywanie – W_3	398000 t
Planowana liczba metrów robót przygotowawczych $W_1 = W_2$	14100 m
Maksymalna kwota przeznaczona na zakup materiałów – K	9 420 000 zł

Źródło: Dane kopalni.

W tabeli 2 podano podstawowe parametry wielkości zużycia materiałów M_1, M_2, M_3 na jednostkę produkcji.

Tabela 2

Podstawowe parametry rozkładów zużycia kleju, drewna i krążników na jednostkę produkcji

	Klej (kg/m)	Drewno (m ³ /m)	Krążniki (szt./t)
Średnia	52,0398	1,4810	0,0058
Mediana	37,6613	1,2940	0,0042
Odchylenie standardowe	32,7428	0,8154	0,0053
Kurtoza	-0,5595	0,0107	3,1878
Skośność	0,7601	0,7603	1,7337
Minimum	10,3400	0,3313	0,0080
Maksimum	122,9789	3,4621	0,0220
Współczynnik zmienności	0,6159	0,5389	0,9052

Źródło: Obliczenia własne na podstawie dwuletnich danych kopalni będącej oddziałem Kompanii Węglowej S.A.

Jak widać, zużycie rozważanych materiałów wykazuje dużą zmienność.

W tabeli 3 podano wartości z_i^{dolne} , $z_i^{górne}$ wyznaczone na podstawie wartości historycznych.

Tabela 3

Wartości z_i^{dolne} , $z_i^{górne}$ dla wybranych materiałów

	z_i^{dolne}	$z_i^{górne}$
Klej	10,3400	122,9789
Drewno	0,3313	3,4621
Krążniki	0,0080	0,0220

4. Budowa algorytmu

Implementacja algorytmu VEGA wymaga zdefiniowania poszczególnych jego elementów oraz określenia warunków jego działania.

Przyjęto:

$N = 100$ – rozmiar populacji,

$T = 3000$ – maksymalna liczba pokoleń (iteracji algorytmu),

$P_k = 0,5$ – prawdopodobieństwo krzyżowania,

$P_m = 0,05$ – prawdopodobieństwo mutacji,

$K = 2$ – liczba funkcji celu,

A – zbiór rozwiązań wybranych ze wszystkich pokoleń.

Każdy osobnik (rozwiązanie) reprezentowany jest przez trzelementowy wektor liczb zmiennoprzecinkowych $\mathbf{x}_i = [z_{1i}^u, z_{2i}^u, z_{3i}^u]$, $i = 1, \dots, 100$, gdzie $z_{1i}^u, z_{2i}^u, z_{3i}^u$ to zunitaryzowane wielkości planowanego zapotrzebowania na materiały M_1, M_2, M_3 w i -tym rozwiązaniu.

Pierwsza populacja otrzymywana jest w sposób losowy. W każdym rozwiązaniu, dla każdej zmiennej z_{ji}^u ($j = 1, 2, 3$), wygenerowana zostaje liczba pseudolosowa z przedziału $(0, 1)$ i przyjęto, że jest to wartość zmiennej z_{ji}^u . Podczas losowania w wypadku, gdy wygenerowane rozwiązania nie spełniają ograniczenia kosztowego, zaproponowano heurystyczną procedurę naprawczą mającą na celu zmniejszenie wartości poszczególnych zmiennych do otrzymania rozwiązania dopuszczalnego. Dla rozwiązania niespełniającego ograniczenia kosztowego wybierana jest losowo zmienna, która będzie zmieniana (zmniejszana). Jej wartość jest pomniejszana o współczynnik skalowania, który jest przemnażany przez liczbę pseudolosową z przedziału $(0, 1)$. Procedura ta jest powtarzana do momentu uzyskania rozwiązania spełniającego ograniczenie kosztowe. Wartości poszczególnych zmiennych są zmniejszane, zatem po pewnej skończonej liczbie powtórzeń procedury można otrzymać rozwiązanie dopuszczalne, spełniające warunki kosztowe.

Ze względu na charakter optymalizacji (obie funkcje kryterium są minimalizowane) funkcje przystosowania zdefiniowano następująco

$$eval_1(\mathbf{x}) = 85 - \sum_{t=1}^{24} w_t \sum_{i=1}^3 u_i |x_{it}^u - z_{it}^u| \quad (6)$$

$$eval_2(\mathbf{x}) = 39\,000\,000 - \sum_{i=1}^r c_i Q_i \quad (7)$$

Wartości 85 i 39 000 000 wybrano jako największe możliwe wartości, które mogą być przyjęte przez funkcje kryteria (5)(a) i (5)(b). Wartość 85 jest większa od maksymalnej wartości wyznaczonej dla funkcji kryterium (5)(a). Wartość 39 000 000 jest większa od wartości 38 528 017 wyznaczonej, jako koszt zakupu maksymalnych wielkości (wyznaczonych na podstawie danych historycznych) każdego z materiałów. W ten sposób, dla każdego z wygenerowanych rozwiązań spełnione jest założenie odnośnie do oceny rozwiązania poprzez funkcje dopasowania tzn. im rozwiązanie jest lepsze tym ma przypisaną większą wartość funkcji przystosowania. Funkcja zaś nie przyjmuje wartości ujemnych.

W dalszej części algorytmu populacja jest dzielona na dwie podpopulacje, każda składa się z 50 osobników. Rozwiązania w każdej z podpopulacji są oceniane poprzez funkcje przystosowania (6) i (7) odpowiednio dla pierwszej i drugiej podpopulacji. Wyznaczane są prawdopodobieństwa

$$p_j(\mathbf{x}_{i,j}) = \frac{eval_j(\mathbf{x}_{i,j})}{\sum_{i=1}^{50} eval_j(\mathbf{x}_{i,j})}, \quad j=1, 2 \quad (9)$$

gdzie:

j – numer podpopulacji,

$\mathbf{x}_{i,j}$ – i -te rozwiązanie w podpopulacji j -tej.

Pozwalają one ustalić szansę na udział danego rozwiązania w procesie reprodukcji.

Dla każdej podpopulacji na podstawie wyznaczonych prawdopodobieństw tworzona jest empiryczna dystrybucja. Generowane są liczby pseudolosowe o rozkładzie jednostajnym z przedziału (0, 1). Porównywane są one z wartościami skumulowanych prawdopodobieństw. Pozwala to wskazać rozwiązanie, które będzie brało udział w kolejnym etapie – reprodukcji.

Po wybraniu do procesu reprodukcji 50 rozwiązań z każdej podpopulacji, łączone są one w nową populację złożoną ze 100 rozwiązań. Na elementach tej populacji stosowane są dwa operatory tworzenia nowych rozwiązań: operator krzyżowania i operator mutacji. Zastosowanie operatora krzyżowania wymaga wybrania dwóch rozwiązań. Dla każdego rozwiązania zostaje wygenerowana liczba pseudolosowa z przedziału (0, 1) w przypadku, kiedy jest ona mniejsza od założonego prawdopodobieństwa P_k (zastosowania operatora krzyżowania) rozwiązanie takie będzie mogło tworzyć nowe rozwiązanie. Ponieważ rozwiązania łączone są w pary, w przypadku wyboru nieparzystej liczby rozwiązań do zastosowania operacji krzyżowania jedno jest odrzucane.

Operator krzyżowania zdefiniowano następująco: dla każdych dwóch rozwiązań $\mathbf{x}_1 = [z_{1,1}^u, z_{1,2}^u, z_{1,3}^u]$ i $\mathbf{x}_2 = [z_{2,1}^u, z_{2,2}^u, z_{2,3}^u]$ generowana jest liczba pseudolosowa r z przedziału (0,1) i wyznaczane jest dziesięć nowych rozwiązań

$$\mathbf{y}_1 = r\mathbf{x}_1 + (1-r)\mathbf{x}_2,$$

$$\mathbf{y}_2 = \mathbf{x}_1 + r\mathbf{x}_1 + (1-r)\mathbf{x}_2,$$

$$\mathbf{y}_3 = \mathbf{x}_2 + r\mathbf{x}_1 + (1-r)\mathbf{x}_2,$$

$$\mathbf{y}_4 = (1-r)\mathbf{x}_1 + r\mathbf{x}_2,$$

$$\mathbf{y}_5 = \mathbf{x}_1 + (1-r)\mathbf{x}_1 + r\mathbf{x}_2,$$

$$\begin{aligned}
\mathbf{y}_6 &= \mathbf{x}_2 + (1-r)\mathbf{x}_1 + r\mathbf{x}_2, \\
\mathbf{y}_7 &= \mathbf{x}_1 - (r\mathbf{x}_1 + (1-r)\mathbf{x}_2), \\
\mathbf{y}_8 &= \mathbf{x}_2 - (r\mathbf{x}_1 + (1-r)\mathbf{x}_2), \\
\mathbf{y}_9 &= \mathbf{x}_1 - ((1-r)\mathbf{x}_1 + r\mathbf{x}_2), \\
\mathbf{y}_{10} &= \mathbf{x}_2 - ((1-r)\mathbf{x}_1 + r\mathbf{x}_2),
\end{aligned}$$

z których w sposób losowy wybierane są dwa.


Rozszerzenie klasycznej metody krzyżowania zmiennopozycyjnego o dodatkowe rozwiązania pozwala rozwiązać problem generowania rozwiązań o wartościach z_{ji}^u pomiędzy wartościami $z_{ji_1}^u$, $z_{ji_2}^u$ rodziców.

Zastosowanie operatora mutacji polega na zmianie wartości poszczególnej zmiennej z_{ji}^u w rozwiązaniu, a nie całego rozwiązania. Dla każdej zmiennej w populacji, czyli dla 300 zmiennych, generowana jest liczba pseudolosowa z przedziału $(0, 1)$. Jeśli wartość ta jest mniejsza od wartości przyjętego prawdopodobieństwa P_m (zastosowania operatora mutacji), wartość zmiennej zastępowana jest wygenerowaną liczbą pseudolosową z przedziału $(0, 1)$.

Zastosowanie operatorów krzyżowania może doprowadzić do sytuacji, gdy otrzymane nowe rozwiązanie nie będzie spełniało warunków ograniczających. W wypadku, kiedy wartości zmiennych nie należą do przedziału $(0, 1)$, są do tego przedziału zawężane. Dla operatora mutacji nie istnieje takie niebezpieczeństwo. Dodatkowo należy pamiętać, że rozwiązanie musi spełniać ograniczenie kosztowe. W tym celu stosowana jest procedura heurystyczna zaproponowana do poprawy populacji początkowej. Rozwiązania niezdominowane wyznaczone w bieżącej iteracji umieszczane są w zbiorze A.

Poprawiona populacja jest gotowa do kolejnej iteracji. Proces tworzenia nowych rozwiązań trwa do momentu zatrzymania. Jako warunek zatrzymania określono liczbę pokoleń równą $T = 3000$. Po zatrzymaniu algorytmu wszystkie rozwiązania niezdominowane z poszczególnych pokoleń znajdują się w zbiorze A z niego wybiera się rozwiązania Pareto suboptymalne.

Ponieważ proces wyznaczania rozwiązań niezdominowanych nie jest procesem deterministycznym za każdym uruchomieniem algorytmu można uzyskać inny zbiór rozwiązań. Na rys. 1 pokazano przykładowe rozwiązania Pareto suboptymalne.



Rys. 1. Otrzymane rozwiązania Pareto suboptymalne dla przykładowego przebiegu algorytmu

Decydent stwierdził, że nie interesują go rozwiązania skrajne i dlatego zaproponował odrzucenie 5% rozwiązań dających najwyższe i najniższe wartości funkcji celu. Na podstawie wykresu wybrał zbiór rozwiązań określając, że interesuje go:

- pięć kolejnych rozwiązań z najwyższymi kosztami,
- pięć kolejnych rozwiązań z najniższymi kosztami,
- dziesięć rozwiązań z kosztami w granicach od 5 do 6 mln zł.

W tabeli 4 podano zbiór rozwiązań, które zostały wybrane przez decydenta według określonych powyżej zasad.

Tabela 4

Rozwiązania wybrane przez decydenta

Kryterium		Wielkość zapotrzebowania na materiał		
Koszt mln zł	odchylenia	Z_1 materiał M_1	Z_2 materiał M_2	Z_3 materiał M_3
1	2	3	4	5
3,477	0,557	145794	4677	3256
3,504	0,555	145794	4768	3258
3,539	0,553	145794	4888	3258
3,619	0,547	145794	5159	3253
3,636	0,546	145794	5213	3251
5,067	0,460	147465	9974	3252
5,136	0,458	159982	9624	3260

cd. tabeli 4

1	2	3	4	5
5,205	0,455	155236	10074	3276
5,278	0,453	163197	9955	3242
5,352	0,449	171928	9796	3269
5,547	0,442	177335	10204	3256
5,621	0,439	189051	9908	3275
5,743	0,435	195890	10004	3285
5,836	0,431	195972	10316	3262
5,975	0,426	214871	9909	3243
6,002	0,424	221622	9687	3250
7,519	0,377	296207	11344	3258
7,863	0,370	321179	11345	3274
7,991	0,368	344494	10695	3269
8,067	0,365	338193	11248	3256

Podsumowanie

Zaproponowany algorytm VEGA umożliwia wyznaczenie skończonego zbioru rozwiązań niezdominowanych. Z rozwiązań tych decydent może wybrać rozwiązanie, które uważa za najlepsze, może też wykorzystać metody stosowane do rozwiązywania wielokryterialnych zagadnień deterministycznych. Na rys. 1 przedstawiona jest aproksymacja pewnej wypukłej funkcji określającej zależność pomiędzy sumarycznymi wielkościami odchylenia od wartości historycznych a kosztem. Na podstawie tej funkcji decydent może zakładając minimalny koszt, jaki jest skłonny ponieść na zakup materiałów, może oszacować sumaryczne minimalne odchylenia zapotrzebowania od wartości historycznych. Może też odwrócić sytuację i przy założonych maksymalnych odchyleniach zapotrzebowania od wartości historycznych oszacować minimalny koszt. Aproksymowana otrzymanymi rozwiązaniami Pareto suboptymalnymi funkcja wydaje się analogiczna do funkcji określającej rozwiązana sprawne z modelu Markowitza w analizie portfelowej.

Działanie algorytmu genetycznego wymaga ustalenia pewnych parametrów, np. prawdopodobieństwo krzyżowania oraz mutacji, liczby iteracji czy też rozmiaru populacji. Parametry te ustala się w sposób eksperymentalny. Należy również pamiętać, że zastosowanie algorytmu genetycznego powoduje, że za każdym przebiegiem algorytmu otrzymać można inny zbiór rozwiązań będący aproksymacją funkcji określającej zależność pomiędzy kryteriami.

Literatura

- Ameljańczyk A.: Optymalizacja wielokryterialna w problemach sterowania i zarządzania. Ossolineum, Wrocław 1984.
- Branke J., Deb K., Miettinen K., Słowiński R.: Multiobjective Optimization – Interactive and Evolutionary Approaches Lecture Notes in Computer Science. Springer-Verlag, Berlin-Heidelberg 2008.
- Multiple Criteria Decision Analysis. State of the art Surveys. Red. J. Figueira, S. Greco, M. Ehrgott. Springer Science, 2005.
- Goldberg D.E.: Algorytmy genetyczne i ich zastosowania. WNT, Warszawa 1998.
- Jakowska-Suwalska K., Sojda A., Wolny M.: Statystyczna analiza zapotrzebowania na kruszniki w grupie kopalń węgla kamiennego. Materiały konferencji Górnictwo Zrównoważonego Rozwoju 2011. Gliwice 2011.
- Jakowska-Suwalska K., Sojda A., Wolny M.: Wspomaganie planowania wielkości zamówień w kopalni węgla kamiennego za pomocą modelu wielokryterialnego przy ograniczeniach kosztowych. Materiały konferencji Górnictwo Zrównoważonego Rozwoju 2011. Gliwice 2011.
- Konarzewska-Gubała E.: Programowanie przy wielorakości celów. PWN, Warszawa 1980.
- Kukuła K.: Metoda unitaryzacji zerowej. PWN, Warszawa 2000.
- Miettinen K.: Nonlinear Multiobjective Optimization. Kluwer Academic Publishers, Boston 1998.
- Michalewicz Z.: Algorytmy genetyczne + struktury danych = programy ewolucyjne. WNT, Warszawa 1996.
- Nowak M.: Interaktywne wielokryterialne wspomaganie decyzji w warunkach ryzyka. Metody i zastosowania. Akademia Ekonomiczna, Katowice 2008.
- Ogryczak W.: Wielokryterialna optymalizacja liniowa i dyskretna. Uniwersytet Warszawski, Warszawa 1997.
- Roy B., Bouyssou D.: Aide Multicritere a la Decision: Methodes et Cas. Economica, Paris 1993.
- Schaffer J.D.: Some Experiments in Machine Learning Using Vector Evaluated Genetic Algorithms. PhD Dissertation. Vanderbilt University, Nashville 1984.
- Wolny M., Jakowska-Suwalska K., Sojda A.: Analiza dostaw kleju poliuretanowego w grupie kopalń węgla kamiennego. Materiały konferencji Górnictwo Zrównoważonego Rozwoju 2011. Gliwice 2011.

USE OF VEGA ALGORITHM TO DETERMINE THE LEVEL OF ORDERS FOR MATERIALS IN THE MINING ENTERPRISE

Summary

This paper presents an application of multiobjective nonlinear problems, to assist in planning the size of the demand for materials in the coal mine. To solve the problem proposed genetic algorithm VEGA (Vector Evaluated called Genetic Algorithm)

in multicriteria optimization. For example, some materials used in the production process, and shows the application of the algorithm chosen by the decision maker a set of Pareto sub-optimal Solutions.