

Rozenberg Leonard<sup>1</sup>

Rychcicki Robert<sup>2</sup>

## Poprawa efektywności portfela aktywów z wykorzystaniem optymalizacji hybrydowej

**Streszczenie:** W artykule omówiono przykład zastosowania hybrydowej procedury optymalizacji w doborze struktury i spółek do portfela inwestycyjnego. Pokazano w ten sposób, że istnieją proste metody racjonalizacji efektywności portfela, które nie zawsze związane muszą być z analizą techniczną czy fundamentalną. Wskazano przykład zastosowania specjalnej procedury optymalizacji, który może być wykorzystywany w selekcji spółek do portfela inwestycyjnego oraz doboru jego struktury. Ponadto, na przykładach przedstawiono sposób działania opisywanego rozwiązania do analizy struktury zbioru spółek, który został poddany analizie.

**Słowa kluczowe:** analiza portfela inwestycyjnego, metoda optymalizacji, analiza techniczna, portfel inwestycyjny, wartość rynkowa

---

### Wstęp

---

Na warszawskiej GPW notowanych jest kilkaset spółek, co oznacza, że z punktu widzenia ryzyka inwestora, niezwykle ważne są metody selekcji spółek do portfela inwestycyjnego. Najczęściej stosowane metody doboru spółek do portfela oparte są wyłącznie na analizie cen akcji. Obliczenia zaprezentowane poniżej w oparte są nie tylko o wyceny akcji, ale także ich stopy zwrotu i różne miary ryzyka. Pozwalają więc na optymalizację portfela poprzez rozwiązanie zadania programowania liniowego, ale częściej programowania nieliniowego (zwykle wypukłego). Dobór spółek do portfela może być także wykonany w oparciu o wskaźniki finansowe charakteryzujące spółkę giełdową, a metody wykorzystywane w takiej selekcji są metodami wielowymiarowej analizy danych.

Metody wielowymiarowej analizy danych, przede wszystkim dzięki rozwojowi narzędzi komputerowych, są niezwykle ważne we współczesnej nauce, szczególnie w medycynie, biologii, genetyce, ekonomii i w wielu innych dziedzinach, a ich duża skuteczność i przydatność znalazła już powszechne uznanie. Zwróćmy uwagę – dla przykładu – na analizę dyskryminacyjną, która stosowana jest od wielu lat w naukach przyrodniczych oraz do celu prognozowania upadłości przedsiębiorstw [Altman 1968; Morrison 1990].

Rozwój nowoczesnych technologii (przede wszystkim informatycznych i komunikacyjnych) spowodował zmianę podejścia do większości problemów finansowych i kreacji wartości firm, dając podstawy tzw. nowej ekonomii, a więc gospodarki zglobalizowanej i opartej na wiedzy.

---

<sup>1</sup> Profesor Zachodniopomorskiego Uniwersytetu Technologicznego w Szczecinie oraz Zachodniopomorskiej Szkoły Biznesu w Szczecinie

<sup>2</sup> Doktorant na Wydziale Informatyki Zachodniopomorskiego Uniwersytetu Technologicznego w Szczecinie; pracownik firmy BrightONE sp. z o.o. w Szczecinie.

---

---

## Budowa modelu symulacyjnego – teoria portfelową Markowitza

---

Budowa portfela inwestycyjnego jest przykładem rzeczywistego systemu wspomagania decyzji, a więc jest systemem klasy SWD (ang. *Decision Support System*) zbudowanym na bazie teorii przedstawionej przez Markowitza [w: Markowitz, et al., 2000]. Poniżej pokazane zostanie wykorzystanie teorii Markowitza, która wyeliminuje zjawisko „krótkiej sprzedaży” (szczególnie niebezpieczne dla początkujących graczy), przy czym porównane zostaną obliczenia wykonane w oparciu o metodę mnożników Lagrange’a oraz wyniki uzyskane przy zastosowaniu hybrydowej metody optymalizacji.

Zakładamy, że na portfel inwestycyjny składa się  $K$  różnych walorów ( $W$ ), określonych przez:

- $\mu_i$  – oczekiwana stopa zwrotu z waloru,
- $\sigma_i$  – odchylenie standardowe waloru, które jest analogiem ryzyka inwestycyjnego, jeśli za podstawę miary ryzyka przyjmiemy zmienność notowań waloru.

Dla każdego waloru określić musimy także jego względny udział w całym portfelu, oznaczany jako:  $x_i$ .

Strukturę portfela opisują więc wagi  $x_i$ , spełniające warunek:

$$\sum_{i=1}^K x_i = 1 \quad (1)$$

Dla każdej pary walorów określimy teraz następujące współczynniki:

$\rho_{ij}$  – współczynnik korelacji walorów  $i, j$ ,

$\sigma_{ij}$  – kowariancja walorów  $i, j = \rho_{ij} \sigma_i \sigma_j$

Macierz kowariancji da się zapisać w postaci:

$$\Sigma_{(K \times K)} = \begin{bmatrix} \sigma_1^2 & \dots & \sigma_{1K} \\ \vdots & \ddots & \vdots \\ \sigma_{K1} & \dots & \sigma_K^2 \end{bmatrix} \quad (2)$$

Dla każdego portfela możemy łatwo określić oczekiwaną stopę zwrotu, jako sumę ważoną o postaci (3):

$$\mu_p = \sum_{i=1}^K x_i \mu_i \quad (3)$$

oraz jego wariancję, rozumianą jako wariancja waloru, który odpowiadałby strukturze portfela będąc walorem jednostkowym według wzoru (4):

$$\sigma_p^2 = \sum_{i=1}^K x_i^2 \sigma_i^2 + 2 \sum_{i=1}^K \sum_{j>i}^K x_i x_j \sigma_{ij} \quad (4)$$

Pamiętać jednak należy, że wariancja jest jednocześnie miarą ryzyka portfela, które rozumiemy jako relację: większa zmienność  $\Leftrightarrow$  większe ryzyko.

Zadanie optymalizacji portfela zapiszemy więc możemy następująco:

$$\left\{ \begin{array}{l} \sigma^2_p = \sum_{i=1}^K x_i^2 \sigma_i^2 + 2 \sum_{i=1}^K \sum_{j>i}^K x_i x_j \sigma_{ij} \rightarrow \min \\ \mu_p = \sum_{i=1}^K x_i \mu_i \\ \sum_{i=1}^K x_i = 1 \end{array} \right. \quad (5)$$

Zależność (5) jest poprawnie zdefiniowanym zdaniem optymalizacji, przy założeniu, że  $\mu_i$  jest stałą wartością, czyli narzuconą przez nas oczekiwaną stopą zwrotu, dla której poszukujemy portfela o minimalnej wariancji, czyli o minimalnym ryzyku. W zapisie macierzowym zagadnienie to przyjmuje następującą postać:

$$\left\{ \begin{array}{l} \sigma^2_p = \mathbf{X}^T \Sigma_{(K \times K)} \mathbf{X} \rightarrow \min \\ \mu_p = \mathbf{X}^T \boldsymbol{\mu} \\ \mathbf{X}^T \mathbf{1}_{(1 \times K)} = 1 \end{array} \right. \quad (6)$$

przy czym:

$$\begin{aligned} \mathbf{X} &= [x_1 \quad \dots \quad x_K]^T \\ \boldsymbol{\mu} &= [\mu_1 \quad \dots \quad \mu_K]^T \\ \mathbf{1} &= [1 \quad \dots \quad 1]^T \end{aligned}$$

Zadania optymalizacji wymagają opisanie ograniczeń, definiujących obszar dopuszczalnych poszukiwań, co w naszym przypadku sprowadza się do postaci „G(x)=0”, a to możemy z kolei zapisać następująco:

$$\left\{ \begin{array}{l} \sigma^2_p = \mathbf{X}^T \Sigma \mathbf{X} \rightarrow \min \\ \mu_p - \mathbf{X}^T \boldsymbol{\mu} = 0 \\ 1 - \mathbf{X}^T \mathbf{1}_{(1 \times K)} = 0 \end{array} \right. \quad (7)$$

---

## Rozwiązanie rzeczywistego zadania optymalizacji

---

W teorii złożoności obliczeniowej za kryterium praktycznej „obliczalności” algorytmu przyjęto odpowiedź na pytanie, czy liczba operacji, jakie wykonują, da się ograniczyć wielomianem zależnym od rozmiaru przestrzeni danych. Algorytmy o opisanych tu właściwościach nazywane są algorytmami wielomianowymi, a klasa problemów, dla których algorytmy takie istnieją jest oznaczana symbolem P.

Niestety, dla dużej liczby ważnych problemów nie udało się dotychczas skonstruować algorytmów wielomianowych, co gorsza znaleziono wiele przesłanek wskazujących, że problemy te nie należą do klasy P, czyli, że algorytmy wielomianowe dla nich nie istnieją. Takie problemy nazywa się problemami (zadaniami) NP-trudnymi.

Niektóre zagadnienia (np. problem plecakowy) mają rozwiązania w postaci algorytmów klasy P jedynie, gdy przyjmie się pewne dodatkowe założenia, al. założenia te wpływają zazwyczaj na kształt funkcji celu lub ograniczeń i zakładają, że optymalizowane zadanie da się wprost opisać analitycznie.

W praktyce obliczeniowej, z optymalizacyjnym problemem NP-trudnym można spotkać się stosunkowo często, jak choćby z szeroko opisanym problemem komiwojażera (TSP – ang. *Traveling Salesman Problem*). Mamy z tym algorytmem do czynienia nie tylko w zadaniach logistycznych (optymalizacja transportu), ale również w produkcji układów VLSI, czy też przy niektórych problemach optymalizacji zarządzania.

Klasycznym rozwiązaniem w takim wypadku jest zastosowanie metod heurystycznych, często o gwarantowanej jakości, czyli takich, w stosunku do których udowodniono matematycznie, że osiągnięty wynik nie jest gorszy o więcej niż o konkretny czynnik (normę) od rozwiązania optymalnego. Istnieje również grupa algorytmów, których wyniki poprawiane są wraz z każdą kolejną iteracją. Niewątpliwą zaletą takich algorytmów jest akceptowalny czas działania, na który mamy wpływ ograniczając żądaną dokładność obliczeń.

Dla pewnych algorytmów wadą jest brak jakichkolwiek gwarancji jakości znalezionej odpowiedzi. Jakość algorytmu szacuje się zwykle na podstawie porównania wyników, jakie on produkuje z pewnym „wzorcowym” zestawem danych *benchmarku* lub z wynikami innych algorytmów, jak też obserwując proces zbieżności produkowanych rozwiązań w czasie. Jeśli wzorcowy zestaw nie jest reprezentatywny, to wyciąganie na tej podstawie wniosków co do zachowania się badanego algorytmu na innych zestawach, niekoniecznie znajduje uzasadnienie.

---

## Rozwiązania suboptymalne

---

W podejściu formalnym, oczekiwanym efektem każdej optymalizacji jest znalezienie punktu globalnego ekstremum badanej funkcji. W praktyce zadowalającym rozwiązaniem są już tzw. rozwiązania suboptymalne (DeJong, 1991). Wynika to z faktu, że w przypadku rozwiązywania wielu rzeczywistych zadań (szczególnie ekonomicznych czy biologicznych) i podejmowania rzeczywistych decyzji, pod ocenę nie jest brany fakt osiągnięcia ściśle najlepszego z możliwych efektów, a pozycja proponowanego rozwiązania na tle

rozwiązań konkurencyjnych lub już stosowanych. Należy też wziąć pod uwagę fakt, że rozwiązanie suboptymalne (a więc zadowalające, ang: *VtR – Value to Rich*) może zostać znalezione w znacznie krótszym czasie i przy użyciu nierzadko znacznie prostszych metod i narzędzi. Zatem celem optymalizacji nie musi być ściśle dążenie do perfekcji, lecz dążenie do poprawy pozycji bieżącej na pozycję lepszą, czyli zdobycie przewagi konkurencyjnej

### Benchmark – rozwiązanie analityczne

Dla zadań minimalizacji funkcji danych w powyższej postaci (kwadratowa funkcja celu i liniowe ograniczenia w postaci równości) można – na szczęście – zastosować analityczną metodę obliczania rozwiązań zwaną metodą Karush–Kuhn–Tucker’a.

W kroku pierwszym tej metody należy określić funkcję Lagrange’a dla układu równań, która dla tak postawionego zadania przyjmuje postać (8):

$$L(\lambda, X) = X^T \Sigma X + \lambda_1(1 - X^T \mathbf{1}) + \lambda_2(\mu_p - X^T \mu) \quad (8)$$

Jak widać, jest to funkcja celu (wariancja naszego portfela) z dodanymi do niej warunkami brzegowymi, które są zdefiniowane jako zerowe. Dlatego, szukając ekstremum funkcji Lagrange’a znajdziemy jednocześnie ekstremum funkcji celu.

Zgodnie z procedurą obliczamy gradient funkcji Lagrange’a (*grad L* – wektor pierwszych pochodnych funkcji), czyli funkcję Lagrange’a różniczkujemy względem każdej ze zmiennych.

Pamiętać należy, że warunkiem koniecznym (choć nie wystarczającym) istnienia ekstremum w  $x_0$  jest:

- równość *grad L* w punkcie  $x_0$  z wektorem zerowym,
  - zerowa wartość funkcji warunków brzegowych w punkcie  $x_0$
- Przy poczynieniu tych założeń otrzymujemy układ macierzy (9):

$$\Gamma = [\lambda_1 \ \lambda_2 \ X_0] \begin{bmatrix} 0 & 0 & 1 & \cdots & 1 \\ 0 & 0 & \mu_1 & \cdots & \mu_K \\ 1 & \mu_1 & 2\sigma_1^2 & \cdots & 2\sigma_{1K} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & \mu_K & 2\sigma_{K1} & \cdots & 2\sigma_K^2 \end{bmatrix} = \begin{bmatrix} 1 \\ \mu_p \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (9)$$

Z powyższej równości łatwo już wyznaczymy wagi portfela (ale i współczynniki Lagrange’a), czyli rozwiązanie danego problemu optymalizacji, pod warunkiem, że macierz jest dobrze określona. Mamy więc:

$$\Gamma = [\lambda_1 \ \lambda_2 \ X_0] = \begin{bmatrix} 1 \\ \mu_p \\ 0 \\ \vdots \\ 0 \end{bmatrix} \begin{bmatrix} 0 & 0 & 1 & \cdots & 1 \\ 0 & 0 & \mu_1 & \cdots & \mu_K \\ 1 & \mu_1 & 2\sigma_1^2 & \cdots & 2\sigma_{1K} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & \mu_K & 2\sigma_{K1} & \cdots & 2\sigma_K^2 \end{bmatrix}^{-1} \quad (10)$$

Niestety otrzymany punkt może nie być jednak punktem ekstremum, a jedynie tzw. punktem siodłowym. Tak więc rozwiązując zadanie znaleźliśmy jedynie wagi portfela, dla których gradient funkcji Lagrange'a jest zerowy. Wykorzystując następnie tzw. hesjan obrzeżony badamy **warunek wystarczający** istnienia ekstremum w wyznaczonym punkcie. To dopiero pozwoli nam ustalić jednoznacznie, czy znaleziony punkt to w istocie minimum, maksimum czy też punkt siodłowy.

Gradient (macierz pierwszych pochodnych L), przyjmuje (po wyłączeniu  $\lambda_1 \lambda_2 x_1 \dots x_k$ ) następującą postać:

$$\gamma = [\lambda_1 \lambda_2 \mathbf{X}_0] \begin{bmatrix} 0 & 0 & 1 & \dots & 1 \\ 0 & 0 & \mu_1 & \dots & \mu_K \\ 1 & \mu_1 & \sigma_1^2 & \dots & \sigma_{1K} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & \mu_K & \sigma_{K1} & \dots & \sigma_K^2 \end{bmatrix} \quad (11)$$

Macierz Hessego (czyli macierz drugich pochodnych L) ma więc bardzo podobną postać:

$$H = \begin{bmatrix} 0 & 0 & 1 & \dots & 1 \\ 0 & 0 & \mu_1 & \dots & \mu_K \\ 1 & \mu_1 & \sigma_1^2 & \dots & \sigma_{1K} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & \mu_K & \sigma_{K1} & \dots & \sigma_K^2 \end{bmatrix} \quad (12)$$

Oznaczamy teraz przez  $H_k$  odpowiedni minor główny tej macierzy, czyli wyznacznik macierzy złożonej z  $k$  pierwszych wierszy i  $k$  pierwszych kolumn macierzy Hessego.

Zgodnie z twierdzeniem, jeśli w punkcie  $P(x_0, \lambda_0)$ :

jest spełniony warunek konieczny

oraz dla każdego  $k=(m+1) \dots K$  zachodzi  $(-1)^m H_k(P) > 0$   $(-1)^m H_k(P) > 0$ ,

gdzie  $m$  to liczba warunków brzegowych (w naszym przypadku 2), to w punkcie  $P(x_0, \lambda_0)$  funkcja celu osiąga minimum warunkowe.

## Testowanie skuteczności wybranego podejścia na problemie praktycznym

Jako źródło danych badawczych wykorzystano bazę notowań ciągłych Giełdy Papierów Wartościowych w Warszawie (wszystkie spółki notowane w podanych poniżej okresach). Dane giełdowe były przetwarzane przy wykorzystaniu metod przedstawionych w (Twardochleb, et al., 2009).

Notowania zebrane zostały z następujących okresów:

- Styczeń-grudzień 2007,
- Styczeń-grudzień 2008,
- Styczeń-grudzień 2009.

Badanie zostało przeprowadzone na przykładzie systemu wspomagania decyzji inwestora i polegało na:

- Wyborze 5 walorów spośród dostępnych na giełdzie (wybór przez inwestora lub losowy),
- Wyznaczanie współczynników portfela minimalnowariancyjnego według teorii Markowitza metodą Lagrange'a
- Wyznaczenie współczynników portfela za pomocą proponowanego hybrydowego algorytmu optymalizacji,
- Porównaniu otrzymanych wyników i wyciągnięciu wniosków.

### Szablon wyników

Procedura testowa została wykonana 450 razy, po 150 razy dla każdej z grup danych testowych (za lata 2007, 2008, 2009).

Wyniki każdej procedury testowej były prezentowane w formie tabeli:

Tabela 1. Tabela z przykładowymi wynikami procedury testow

	$m_i$	$\sigma_i$	cov					$X_L$	$X_H$
TPSA	-0,009	1,3783	1,91	-22,37	-0,86	7,99	-5,64	0,484	0,446
EMPERIA	0,3153	28,4574	-22,37	810,54	18,98	-165,67	180,56	0,006	$\theta$
TALEX	0,0017	1,2527	-0,86	18,98	1,57	-5,18	6,56	0,556	0,553
RAFAKO	-0,116	9,2109	7,99	-165,67	-5,18	85,22	-42,28	-0,012	0,001
MCI	0,0416	7,8512	-5,64	180,56	6,56	-42,28	62,05	-0,033	$\theta$
			y=	<b>2007</b>			$\mu_P=$	-0,0015	-0,0031
			z=	<b>2</b>			$\sigma_P=$	<b>0,6400</b>	<b>0,6613</b>

Źródło: Opracowanie własne

Wyjaśnienia:

- Pierwsza kolumna zawiera wybrane walory inwestycyjne,
- Kolumna  $m_i$  – średnia oczekiwana stopa zwrotu na podstawie populacji,
- Kolumna  $\sigma_i$  – odchylenie standardowe populacji,
- Cov – macierz kowariancji, na przekątnej znajdują się kwadraty odchyleń standardowych poszczególnych walorów,
- $X_L$  – udział poszczególnych walorów w portfelu, wyliczony metodą standardową,
- $X_H$  – udział poszczególnych walorów w portfelu, wyliczony proponowaną metodą,
- $\mu_p$  – oczekiwana wartość zwrotu portfela,
- $\sigma_p$  – oczekiwane odchylenie standardowe portfela,
- na czerwono oznaczone zostały „ujemne wagi portfela”, czyli wymóg krótkiej sprzedaży,
- y – oznaczenie populacji, z której pochodzą próbki (rok),
- z – liczba walorów usuniętych z portfela przez proponowaną metodę.

## Trzy przypadki charakterystyczne

Poniższe zestawienia (tabele 2, 3 i 4 skonstruowane według opisanego powyżej szablonu) przedstawiają trzy charakterystyczne przypadki, w których efekt działania porównywanych metod (tj. metody standardowej i metody proponowanej) różni się.

Tabela 2. Pierwszy przypadek charakterystyczny

	$m_i$	$\sigma_i$	cov					$X_L$	$X_H$	
MONNARI	-0,1028	7,3263	35,28	35,55	16,72	3,09	3,80	-0,049	$\theta$	
KOPEX	-0,1565	9,3687	35,55	49,02	19,48	3,27	4,63	-0,045	$\theta$	
ATLASEST	-0,0683	3,2044	16,72	19,48	10,27	1,46	2,10	-0,042	$\theta$	
GASTELZUR	-0,0101	0,8593	3,09	3,27	1,46	0,33	0,36	0,319	0,999	
MIT	-0,0126	0,8272	3,80	4,63	2,10	0,36	0,50	0,817	0,001	
								$\mu_p =$	0,0015	-0,0101
								$\sigma_p =$	0,2038	0,5760

y= 2008  
z= 3

Źródło: Opracowanie własne

Tabela 3. Drugi przypadek charakterystyczny

	$m_i$	$\sigma_i$	cov					$X_L$	$X_H$	
KOLASTYNA	-0,0009	0,1236	0,02	6,46	0,01	0,50	0,04	0,773	0,677	
WIG-INFO	1,3072	140,1501	6,46	19586,68	22,02	1551,90	71,84	-0,001	$\theta$	
PONAR	-0,0010	0,2399	0,01	22,02	0,06	1,63	0,14	0,256	0,323	
DEBICA	0,1135	11,7332	0,50	1551,90	1,63	137,42	4,95	0,002	$\theta$	
MMPLL	-0,0012	0,7826	0,04	71,84	0,14	4,95	0,61	-0,03	$\theta$	
								$\mu_p =$	-0,0015	-0,0009
								$\sigma_p =$	0,1067	0,1382

y= 2009

z= 3

Źródło: Opracowanie własne

Tabela 4. Trzeci przypadek charakterystyczny

	$m_i$	$\sigma_i$	cov					$X_L$	$X_H$	
COMARCH	-0,0526	27,2189	741,61	5,36	40,03	59,71	-35,78	-0,008	$\theta$	
NOWAGALA	0,0018	0,8609	5,36	0,74	2,78	0,56	5,55	1,065	0,978	
VARIANT	-0,0157	4,3157	40,03	2,78	18,54	7,17	37,52	-0,122	$\theta$	
EFEKT	-0,0142	4,0104	59,71	0,56	7,17	16,08	11,54	0,081	0,022	
PAGED	0,0181	11,7379	-35,78	5,55	37,52	11,54	138,18	-0,016	$\theta$	
								$\mu_p =$	0,0028	0,0014
								$\sigma_p =$	0,6043	0,8605

y= 2007

z= 3

Źródło: Opracowanie własne



W demonstrowanych przypadkach proponowana metoda wyeliminowała „krótką sprzedaż”, co jest o tyle ważne, iż „krótka sprzedaż” jest operacją niebezpieczną, typowo spekulacyjną. W konsekwencji zapewniła spełnienie nałożonych ograniczeń, a więc udział żadnego waloru w portfelu inwestycyjnym nie spadł poniżej 0,0 i nie przekroczył wartości 1,0.

Tabela 5. Wyniki zbiorcze

z	Liczba przypadków	Procent przypadków
0	3	0,7%
1	172	38,2%
2	182	40,4%
3	87	19,3%
4	6	1,3%

Źródło: Opracowanie własne

z – liczba walorów usuniętych z portfela przez proponowaną metodę.

---

## LITERATURA

---

1. Morrison D. F.(1990), *Wielowymiarowa Analiza Statystyczna*, PWN, Warszawa
2. Markowitz, H. M., Todd, G. P. i Sharpe, W. F., (2000); *Mean-Variance Analysis in Portfolio Choice and Capital Markets*. -: John Wiley & Sons
3. Rozenberg, L., 2014. *Symulacja i optymalizacja zjawisk finansowych w systemach gospodarczych; Metodyka wspomaganie decyzji zarządczych w przedsiębiorstwie*. Szczecin: ZUT (monografia w druku),
4. Twardochleb, M., Rychcicki, R. i Kaczmarek, E., 2009. *Weryfikacja skuteczności predykcyjnej wybranych formacji analizy technicznej*. w: *Metody ilościowe w ekonomii*. Szczecin: Uniwersytet Szczeciński, pp. 23-35

## Improving the efficiency of asset portfolio using hybrid optimization

**Summary:** This paper discusses an example of using hybrid optimization procedures in the selection of the structure and the assets in investment portfolio. Thus showing that there are simple ways to rationalize of the portfolio effectiveness, which do not always have to be associated with technical or fundamental analysis. Indicated an example of application specific optimization procedure that can be used in the selection of companies in the investment portfolio and the selection of its structure. Moreover, the examples shows how the described solution for the analysis of structure of a set of companies, which was analyzed.

**Keywords:** investment analysis, portfolio optimization method, technical analysis, portfolio investment