

**WYŻSZA SZKOŁA
INFORMATYKI STOSOWANEJ
I ZARZĄDZANIA**



**ANALIZA SYSTEMOWA
W FINANSACH I ZARZĄDZANIU**

Wybrane problemy

Pod redakcją
Jerzego HOŁUBCA

**WYŻSZA SZKOŁA
INFORMATYKI STOSOWANEJ
I ZARZĄDZANIA**

**ANALIZA SYSTEMOWA
W FINANSACH I ZARZĄDZANIU
Wybrane problemy**

Pod redakcją
Jerzego HOŁUBCA

Warszawa 1999

Wykaz opiniodawców artykułów zamieszczonych w tomie:

prof. dr hab. Jerzy **HOLUBIEC**

prof. dr hab. Janusz **KACPRZYK**

prof. dr hab. Tadeusz **NOWICKI**

prof. dr hab. Stanisław **PIASECKI**

prof. dr hab. Piotr **SZCZEPANIAK**

prof. dr hab. Tadeusz **TRZASKALIK**

doc. dr hab. Sławomir **WIERZCHOŃ**

doc. dr hab. Leszek **ZAREMBA**

© **Wyższa Szkoła Informatyki Stosowanej i Zarządzania**

Warszawa 1999

ISBN 83-85847-24-3

Przedmowa

Na niniejszą publikację składa się zbiór prac doktorantów Zaocznych Studiów Doktoranckich "Informatyka w zarządzaniu i finansach" działających przy *Instytucie Badań Systemowych Polskiej Akademii Nauk*.

Prace te były referowane na konferencji BOS'98 "Rozwój średnich i małych miast w XXI wieku w Polsce: Rola badań operacyjnych i systemowych", Kutno, 8-10 czerwca 1998 r.¹, a także na seminariach Studiów Doktoranckich "Informatyka w zarządzaniu i finansach". Nad stroną merytoryczną publikacji czuwał Pan Prof. dr hab. Jerzy Hołubiec oraz grono recenzentów i opiekunów naukowych doktorantów.

Prace dotyczą głównie problemów analizy systemowej oraz jej zastosowań w dziedzinie finansów, a zwłaszcza - teorii portfela, obligacji i problemów inwestycyjnych. Niektóre prace przy analizie finansowej posługują się tzw. algorytmami genetycznymi i sieciami neuronowymi, a także modelowaniem rozmytym i strukturami fraktalnymi. Część prac dotyczy zarządzania i sterowania produkcją.

Wypada zauważyć, iż doktoranci Studiów atakują w swych pracach tematy nowoczesne i znajdujące się w obszarze tzw. frontu badawczego analizy systemów. Wypada im życzyć sukcesów i wytrwałości w pracy, która winna zakończyć się obronioną pracą doktorską.

¹ Głównymi organizatorami konferencji było Polskie Towarzystwo Badań Operacyjnych i Systemowych oraz Instytut Badań Systemowych PAN.

Wypada także zaznaczyć, iż wydanie niniejszej publikacji stało się możliwe dzięki wsparciu finansowemu ze strony *Wyższej Szkoły Informatyki Stosowanej i Zarządzania*, działającej w ramach Fundacji Krzewienia Nauk Systemowych. Fundacja ta została założona w 1991 roku z inicjatywy Prof. L. Kuźnickiego, wówczas Sekretarza Naukowego Polskiej Akademii Nauk. Do zadań Fundacji należy, między innymi, wspieranie i promocja prac młodych pracowników nauki, a zwłaszcza prac doktorantów.

Mamy nadzieję, iż publikacja niniejsza zostanie życzliwie przyjęta przez specjalistów działających w obszarze nauk systemowych.

Rektor WSISiZ
Prof. Roman Kulikowski

ALGORYTMY GENETYCZNE W ZASTOSOWANIACH FINANSOWYCH

Włodzimierz MAGIERA
Zaoczne Studia Doktoranckie IBS PAN

Praca zawiera przegląd zastosowań algorytmów genetycznych w dziedzinie finansów. W rozdziale pierwszym wyjaśniono zaczerpnięte z nauk biologicznych podstawowe pojęcia występujące w technikach ewolucyjnych. Drugi rozdział omawia skrótkowo zasady działania prostego algorytmu genetycznego i jego elementy składowe. W rozdziale trzecim przedstawiono szczegóły budowy i wyniki eksperymentów z algorytmami genetycznymi wykorzystywanymi w wybranych zastosowaniach finansowych takich jak budowa modeli decyzji inwestycyjnych, strategia wyboru rynku oraz zarządzanie funduszem indeksowym. Rozdział czwarty zawiera wnioski z przedstawionego przeglądu dotyczące przydatności algorytmów genetycznych dla aplikacji finansowych.

1. Podstawowe pojęcia teorii algorytmów genetycznych

Algorytmy genetyczne są to metody poszukiwania rozwiązań problemów o dużym stopniu złożoności, wzorowane na naturalnych procesach ewolucyjnych organizmów biologicznych. Mechanizm ewolucji bazujący na zasadzie doboru naturalnego i zasadzie przeżywania osobników najlepiej przystosowanych opisany zastał po raz pierwszy przez Karola Darwina w dziele *O pochodzeniu gatunków*. Osobniki, które najlepiej radzą sobie z przystosowaniem do środowiska i w konkurencyjnej walce o partnera, będą miały relatywnie liczniejsze potomstwo. Najślabiej dostosowane w ogóle nie doczekają się potomstwa. Dzięki temu, geny osobników najlepiej przystosowanych

będą powielane w coraz większej ilości potomków w każdej następnej generacji. Kombinacja korzystnych cech pochodzących od różnych przodków może czasami spowodować pojawienie się osobnika, przystosowanego znacznie lepiej niż którykolwiek z jego rodziców. Proces ten umożliwi coraz lepsze dostosowanie się do środowiska kolejnych generacji osobników.

Idea algorytmów genetycznych opiera się na analogii do tych naturalnych procesów. Również nazewnictwo podstawowych pojęć, z którego korzysta teoria algorytmów genetycznych zapożyczona została z genetyki:

- populacja to zbiór osobników, które mogą współdziałać np. w celu skojarzenia w pary, wygenerowania potomstwa itp. (określony podzbiór przestrzeni rozwiązań),
- osobnik to pojedynczy członek populacji (zakodowane w postaci chromosomów rozwiązanie zadania),
- genotyp to pełna informacja genetyczna zawarta w chromosomach określająca budowę i funkcjonowanie osobnika,
- chromosom to uporządkowany ciąg genów,
- gen to segment chromosomu, zawierający kod jednej lub kilku powiązanych cech i zajmujący ustaloną pozycję (locus) w chromosomie,
- allel to stan ,w jakim może znajdować się gen,
- fenotyp to żywy organizm ukształtowany w wyniku współdziałania pełnego zespołu genetycznego ze środowiskiem (rozwiązanie problemu).

2. Elementarny algorytm genetyczny Hollanda

Algorytm genetyczny zaproponowany po raz pierwszy przez Johna Hollanda [Holland 1975] jest wzorowany na mechanizmach ewolucyjnych zaczerpniętych z genetyki. Holland wyodrębnił trzy

podstawowe mechanizmy genetyczne: selekcję, krzyżowanie i mutację.

Mechanizmy te zostały wkomponowane w algorytm genetyczny składający się z kolejno wykonywanych kroków:

- wyboru reprezentacji,
- inicjalizacji polegającej na utworzeniu populacji początkowej,
- oceny wszystkich osobników populacji zgodnie z funkcją przystosowania,
- selekcji puli rodzicielskiej na podstawie dokonanej oceny osobników,
- zastosowania operatorów genetycznych: krzyżowania i mutacji .

Proces następnie powtarza się poczynając od oceny wszystkich osobników nowej generacji. Dynamicznie zmieniające się populacje osobników poddawane są kolejnym iteracjom, aż do spełnienia założonego kryterium, którym może być np. ustalona liczba generacji lub znalezienia osobnika, dla którego wartość funkcji przystosowania jest powyżej ustalonego poziomu.

2.1. Reprezentacja

Chromosomy w algorytmie Hollanda przedstawiane są jako ciągi zer i jedynek, czyli łańcuchy binarne. Ta prosta reprezentacja umożliwia kodowanie zarówno stanów binarnych jak i liczb dziesiętnych, czy list elementów.

2.2. Inicjalizacja

W fazie inicjalizacji tworzona jest populacja początkowa o założonej liczebności n . Generacja populacji początkowej zaproponowana przez Hollanda polegała na wygenerowaniu losowo n ciągów binarnych o zadanej długości s .

2.3. Funkcja przystosowania

Funkcja przystosowania jest odwzorowaniem przyporządkowującym każdemu osobnikowi (chromosomowi) liczbę, która charakteryzuje jak dobrze osobnik ten rozwiązuje problem postawiony przed algorytmem genetycznym. Służy do oceny wszystkich osobników populacji. Czym większa jest wartość funkcji przystosowania osobnika, tym większa szansa wygenerowania potomstwa. Funkcja przystosowania nie może być określona w sposób uniwersalny i musi być zaprojektowana w sposób specyficzny dla każdego problemu.

2.4. Selekcja

Operacja selekcji polega na wybraniu osobników, które będą stanowiły pulę rodzicielską dla następnego pokolenia (następnej generacji). Wybór ten wzorowany jest na darwinowskiej zasadzie doboru naturalnego, zgodnie z którą przeżywają, osiągają dojrzałość i wydają potomstwo osobniki najlepiej przystosowane.

Obecnie istnieje wiele metod algorytmicznej realizacji operacji selekcji. Holland zastosował selekcję proporcjonalną zwaną też metodą ruletki, która do dziś jest najpowszechniejsza ze względu na swą prostotę. Każdemu chromosomowi odpowiada wycinek koła ruletki proporcjonalny do wartości funkcji przystosowania tego chromosomu. Im wyższa jest wartość funkcji przystosowania danego chromosomu, tym większy jest rozmiar przyporządkowanego mu wycinka koła, a zatem tym większe prawdopodobieństwo wylosowania chromosomu do puli rodzicielskiej. Chromosomy o najwyższej wartości funkcji przystosowania mogą być wylosowane kilkakrotnie. Losowanie powtarza się do momentu zapelnienia puli rodzicielskiej, której liczebność jest równa liczebności bieżącej populacji.

2.5. Operator krzyżowania

Operacja krzyżowania prostego przebiega w dwóch etapach. Pierwszy z nich polega na losowym łączeniu w pary osobników z puli

rodzicielskiej. Nie jest przy tym istotne, czy skojarzone osobniki są różne czy identyczne. W drugim etapie, dla każdej pary osobników rodzicielskich ustala się - zgodnie z zadaniem parametrem p_k zwanym prawdopodobieństwem krzyżowania - czy właściwe krzyżowanie powinno mieć miejsce.

Jeżeli wynik tego ustalenia jest negatywny, to nie dochodzi do wymiany materiału genetycznego pomiędzy osobnikami rodzicielskimi i w populacji potomnej tworzone są dwa nowe osobniki identyczne z rodzicami.

W przeciwnym przypadku określa się najpierw w sposób losowy punkt krzyżowania (*podziału*). Jest to liczba naturalna k z przedziału $\langle 1, s \rangle$, gdzie s jest liczbą genów w chromosomie. Następnie dla każdej pary chromosomów pochodzących od osobników rodzicielskich tworzy się dwa osobniki potomne w następujący sposób:

- chromosom pierwszego potomka zbudowany jest z k początkowych genów pierwszego rodzica oraz końcowych genów (od pozycji $k+1$ do s) drugiego rodzica,
- chromosom drugiego potomka zbudowany jest z k początkowych genów drugiego rodzica oraz końcowych genów (od pozycji $k+1$ do s) pierwszego rodzica.

Przykładowo, jeżeli w procesie krzyżowania skojarzono dwa chromosomy: 00000 i 11111, a jako punkt krzyżowania wylosowano 2, to w wyniku tego procesu powstaną dwa osobniki potomne: 00111 oraz 11000.

W algorytmie Hollanda w każdym cyklu reprodukcyjnym cała poprzednia populacja chromosomów zastępowana jest przez tak samo liczną populację potomków.

2.6. Operator mutacji

Mutacja polega na przypadkowej, zachodzącej z określonym prawdopodobieństwem p_m , zmianie wartości elementu chromosomu.

Po wylosowaniu danego chromosomu do mutacji również losowo ustala się pozycję genu (locus), który ma ulec mutacji. Mutacja ma zapobiegać wyeliminowaniu wartościowego materiału genetycznego. Ma ona znaczenie pomocnicze w procesie ewolucji. Nie odgrywa tak istotnej roli jak selekcja i krzyżowanie. W przypadku operatora mutacji binarnej zastosowanego przez Hollanda zamienia on zero na jedynkę lub odwrotnie. Jeżeli przykładowo wylosowano do mutacji chromosom 11100 i również losowo ustalono, że pozycja genu, który ma ulec mutacji jest równa 2, to w wyniku mutacji otrzymamy chromosom 10100.

3. Przegląd zastosowań finansowych

Opisany powyżej klasa algorytmów Hollanda korzystających z reprezentacji binarnej, losowego generowania populacji początkowej, selekcji proporcjonalnej, krzyżowania jednopunktowego i mutacji bitowej określana jest obecnie jako tradycyjne algorytmy genetyczne. Algorytmy Hollanda są algorytmami uniwersalnymi w tym sensie, że można je stosować z powodzeniem do bardzo różnorodnych problemów. Praktyczne jego zastosowanie wymaga od użytkownika jedynie określenia funkcji przystosowania i wyspecyfikowania parametrów algorytmu: wielkości populacji, prawdopodobieństwa krzyżowania i prawdopodobieństwa mutacji.

W latach późniejszych opublikowano wiele prac dotyczących zastosowań algorytmów genetycznych w różnych dziedzinach badań. Algorytmy przedstawiane w tych pracach różniły się od algorytmu Hollanda bądź to metodą inicjalizacji, bądź to mechanizmami genetycznymi, ale były znacznie lepiej dostosowane do rozwiązywania problemów specyficznych dla danej dziedziny, choć oczywiście straciły cechę uniwersalności.

Obszar zastosowań poszerzony został o genetyczne systemy uczące się (genetic-based machine learning - GBML) generujące zestawy reguł postaci: *jeżeli <warunek> to <akcja>*. Możliwe są tutaj dwie metodologie postępowania. W pierwszej z nich osobnikami po-

populacji są pojedyncze reguły, a zbiór reguł jest reprezentowany przez całą populację (tzw. podejście Michigan). W drugiej metodologii (tzw. podejście Pitt) każdy osobnik reprezentuje cały zestaw reguł.¹

Na początku obecnego dziesięciolecia zaczęły pojawiać się zastosowania algorytmów genetycznych w dziedzinie finansów, w tym również dotyczące rynku kapitałowego. Poniżej przedstawiono wybór zastosowań w tej dziedzinie ograniczony do trzech problemów: budowy modeli decyzji inwestycyjnych, strategii wyboru rynku i zarządzania funduszem indeksowym. Dla każdego z prezentowanych algorytmów opisano kolejno: reprezentację problemu, funkcję przystosowania, operację selekcji, operatory genetyczne krzyżowania i mutacji oraz przytoczono wyniki eksperymentów opublikowane przez autorów.

We wszystkie przedstawionych zastosowaniach populacja początkowa została wygenerowana w sposób losowy.

3.1. Modelowanie decyzji inwestycyjnych

Próby zastosowania zaawansowanych technik obliczeniowych do wspomagania decyzji inwestycyjnych podejmowane są od dawna. Eksperti inwestyjni próbowali przekształcać liczne posiadane informacje historyczne o kursach giełdowych, wynikach finansowych i środowisku makroekonomicznym w stosunkowo proste zasady podejmowania korzystnych decyzji inwestycyjnych. Zasady takie można stosować w szczególności przy komputerowym podejmowaniu decyzji. Jednym z możliwych podejść do automatyzacji tego procesu jest budowa modeli inwestycyjnych (*trading models*). Modele inwestycyjne to reguły postaci:

if warunek **then** generuj sygnał *s1*

¹ Dokładne omówienie obu podejść można znaleźć w [Michalewicz 1997].

lub

if warunek **then** generuj sygnał *s1* **else** generuj sygnał *s2*

gdzie *s1* i *s2* są sygnałami typu: kupuj, sprzedaj lub trzymaj odnoszącymi się do określonych instrumentów finansowych.

W ciągu kilku ostatnich lat zaczęto stosować techniki ewolucyjne do budowy modeli inwestycyjnych. W roku 1994 Michael de la Maza i Deniz Yuret z Laboratorium Sztucznej Inteligencji Massachusetts Institute of Technology opublikowali [Yuret, de la Maza 1994] wyniki swoich prac nad zastosowaniem algorytmów genetycznych do modelowania decyzji inwestycyjnych na rynku opcji. Ich badania dotyczyły wypracowania reguł inwestycyjnych przewidujących jednodniowe zmiany cen OEX.²

Dwa lata później zespół ekspertów z Research Institute for Applied Economics w Zurichu oraz Uniwersytetu w Genewie zaprezentował [Pictet i in. 1996] metodę budowy modeli inwestycyjnych dla rynku walutowego. Podobnej tematyce poświęcona jest praca Goonatilake [1997].

Poniżej przedstawiono wyniki pierwszej z wymienionych prac badawczych.

3.1.1. Reprezentacja

Algorytm genetyczny zbudowany przez de la Maza i Yureta jest przykładem genetycznego systemu uczącego się GBML. Modele inwestycyjne poszukiwane przez algorytm mają postać reguł:

if warunek **then** generuj sygnał kupna

² OEX jest kontraktem opcyjnym typu amerykańskiego notowanym na giełdzie Chicago Board of Trade. Instrumentem bazowym dla OEX jest indeks Standard & Poor 100.

Uproszczony schemat postępowania inwestora zakładał, że w przypadku wygenerowania sygnału kupna nastąpi zakup opcji call na OEX, a następnie sprzedaż tej opcji na sesji giełdowej w dniu następnym. Baza danych, z których korzysta model zawiera informacje o najwyższych i najniższych dziennych kursach opcji oraz o kursie zamknięcia dla każdego z poprzednich 10 dni.

Przestrzenią poszukiwania dla algorytmu genetycznego jest populacja możliwych *warunków* (osobników populacji), z których każdy jest koniunkcją warunków elementarnych postaci:

$$(Am > Bn) \quad (3.1)$$

lub

$$(Am < Bn) \quad (3.2)$$

gdzie A i B mogą przyjmować dowolną z trzech wartości: H - dla oznaczenia najwyższego kursu dziennego, L - dla najniższego kursu dziennego, C - dla kursu zamknięcia, a symbole m . i n przyjmują wartości liczbowe całkowite od 0 do 9 i oznaczają przesunięcia w czasie mierzone w dniach. Przykładowo H2 oznacza najwyższy kurs dzienny sprzed dwóch dni, a warunek elementarny (L3 > C2) oznacza, że kurs najniższy sprzed trzech dni musi być wyższy niż kurs zamknięcia sprzed dwóch dni.

Model inwestycyjny może mieć zatem przykładowo postać:

if (L3 < C2) and (L1 > H0) then generuj sygnał kupna

co oznacza, że sygnał kupna będzie wygenerowany, jeżeli kurs najniższy sprzed trzech dni jest niższy od kursu zamknięcia sprzed dwóch dni i jednocześnie kurs najniższy z dnia poprzedniego jest wyższy od kursu najwyższego z dnia bieżącego.

3.1.2. Funkcja przystosowania

Funkcja przystosowania wykorzystana przez algorytm genetyczny przy ocenie modelu inwestycyjnego bierze pod uwagę dwa kryteria. Pierwsze kryterium ocenia aktywność modelu; czym częściej model generuje sygnał kupna tym większa jest jego użyteczność, a zatem tym wyższa wartość funkcji przystosowania. Modele uaktywniane bardzo rzadko (albo - w krańcowym przypadku - wcale) nie są przydatne.

Drugie kryterium bierze pod uwagę zyskowność generowanych transakcji. Ta cecha modelu inwestycyjnego mierzona jest średnią różnicą pomiędzy ceną sprzedaży opcji dnia następnego, a ceną zakupu dnia poprzedniego dla wszystkich transakcji zawartych w wyniku realizacji sygnałów wygenerowanych przez model.

Algorytm genetyczny poszukuje zatem aktywnych modeli generujących zyskowne transakcje. Zastosowana przez de la Mazę i Yuretta funkcja przystosowania wyraża się formułą:

$$f(X) = ((g(X))^{0,7} \cdot r(X)) \quad (3.3)$$

gdzie:

$f(X)$ - funkcja przystosowania modelu inwestycyjnego X

$g(X)$ - ilość sygnałów kupna wygenerowanych przez model X

$r(X)$ - średnia różnica między kursem sprzedaży a kursem kupna dla wszystkich transakcji wygenerowanych przez model X .

Przykładowo jeżeli model X wygenerował 10 transakcji, a średnia dla nich zmiana kursu wyniosła 0,5 punktu OEX, to funkcja przystosowania tego modelu przybierze wartość:

$$f(X) = 10^{0,7} \cdot 0,5 \approx 2,5 \quad (3.4)$$

3.1.3. Selekcja

Zastosowana procedura selekcji osobników do krzyżowania tworzy n_i kopii każdego osobnika:

$$n_i = [f_i/F] \quad (3.5)$$

gdzie:

n_i - liczba kopii osobnika i (z zaokrągleniem do najbliższej całkowitej),

f_i - wartość funkcji przystosowania osobnika i ,

F - średnia wartość funkcji przystosowania w całej populacji.

Przykładowo, jeżeli wartość funkcji przystosowania pewnego osobnika wynosi 9, a średnia wartość dla całej populacji jest równa 3, to osobnik ten jest powielony w trzech kopiach.

3.1.4. Operatory genetyczne

Operator krzyżowania wybiera losowo punkt podziału niezależnie dla każdego z obojga rodziców po czym tworzy dwoje potomków. Pierwszy potomek powstaje z początku chromosomu pierwszego osobnika rodzicielskiego i końca chromosomu drugiego osobnika rodzicielskiego. Drugi potomek tworzony jest przez połączenie początkowego fragmentu chromosomu drugiego osobnika rodzicielskiego z końcem chromosomu pierwszego rodzica.

Tak określony operator krzyżowania umożliwia tworzenie osobników o różnej długości chromosomów. Na przykład jeżeli do krzyżowania wylosowano dwa osobniki, których chromosomy mają odpowiednio postać:

$$w_{1,1} \ w_{1,2} \ w_{1,3} \ w_{1,4} \ w_{1,5}$$

oraz

$$w_{2,1} w_{2,2} w_{2,3} w_{2,4} w_{2,5}$$

gdzie $w_{i,j}$ - warunki elementarne

i jako punkt krzyżowania dla pierwszego chromosomu ustalono 2, a dla drugiego chromosomu 3, to w wyniku krzyżowania otrzymamy chromosomy:

$$w_{1,1} w_{1,2} w_{2,4} w_{2,5}$$

oraz

$$w_{2,1} w_{2,2} w_{2,3} w_{1,3}, w_{1,4} w_{1,5} .$$

Należy zauważyć, że sposób określenia funkcji przystosowania zapobiega tworzeniu się zbyt długich łańcuchów genów ponieważ czym dłuższy jest warunek modelu, tym mniejsza szansa, że wygeneruje on sygnał kupna. Dłuższy warunek wymaga bowiem spełnienia większej ilości warunków elementarnych.

3.1.5. Wyniki

Autorzy otrzymali bardzo obiecujące wyniki przedstawionego algorytmu genetycznego. W badaniach testowych przeprowadzonych na danych ze 100 dni obrotu OEX najlepszy osobnik wygenerował 24 transakcje, przy czym ponad 70% nastąpiło w odpowiednim momencie tzn. zakup następował przed zwyżką kursu. Średnia różnica pomiędzy kursem sprzedaży i kursem zakupu dla wszystkich wygenerowanych transakcji wyniosła 0,88 punktu OEX. Strategia porównawcza, która zawsze generowała sygnał kupna była poprawna w 53%, a średnia dla tej strategii różnica kursów sprzedaży i zakupu wyniosła 0,2 punktu OEX.

Skonstruowany przez de la Mazę i Yuretta algorytm genetyczny wziął udział w konkursie dla inwestorów na rynku opcji (U.S. Inve-

sting Championship - Option Division). W zawodach tych przeprowadzanych w ostatnim kwartale 1993 roku ich algorytm wygenerował 7 transakcji - wszystkie z nich przyniosły zysk, a łączna stopa zwrotu sięgnęła 44%.

3.2. Strategia wyboru rynku

Obrót papierami wartościowymi dzielony jest często na segmenty zwane rynkami. Można więc np. wyróżnić: rynek akcji, rynek akcji małych firm, rynek obligacji przedsiębiorstw, rynek obligacji skarbowych, rynek bonów skarbowych.

Każdy z tych rynków ma swą odrębną charakterystykę. Giełdowe cykle występujących na przemian okresów hossy i bessy nie pokrywają się, ale przebiegają na każdym rynku w sposób dla niego specyficzny. Często zdarza się na przykład, że okres tendencji zniżkowej na rynku akcji pokrywa się z okresem zwyczajki na rynku obligacji skarbowych. Strategia wyboru rynku (w literaturze angielskojęzycznej *market timing*) to wykorzystanie tej obserwacji w praktyce i przeniesienie we właściwym czasie swych inwestycji z jednego rynku na drugi lub pomiędzy kilkoma rynkami np. poprzez lokowanie zasobów w fundusze inwestycyjne (w szczególności indeksowe) bazowane na tych rynkach.

Analiza danych historycznych pokazuje, że optymalny wybór rynku może przynieść bardzo wysokie zyski. Przykładowo optymalne przenoszenie zasobów w okresach miesięcznych pomiędzy tylko dwoma rynkami: akcji notowanych na giełdzie nowojorskiej i amerykańskich obligacji skarbowych mogło przynieść w latach 1962 -1991 średnią roczną stopę zwrotu przekraczającą 32%. Jeszcze wyższy zwrot - 46,54% w stosunku rocznym - mógł uzyskać inwestor optymalnie lokujący swoje zasoby na przemian na rynku akcji małych firm i rynku amerykańskich obligacji skarbowych. Tak wysoka stopa zwrotu powoduje, że z początkowego kapitału w wysokości 1 000\$ zainwestowanego na początku 1962 roku mógł on uzyskać w 1991 roku kwotę 95 161 285\$.

R. Bauer [1994] zaproponował zastosowanie algorytmów genetycznych do wyszukiwania optymalnych reguł wyboru rynku: m.in. wyboru pomiędzy rynkiem akcji i rynkiem bonów skarbowych oraz pomiędzy rynkiem obligacji skarbowych i rynkiem obligacji przedsiębiorstw. Poniżej przedstawimy wyniki jego badań dotyczących budowy algorytmu genetycznego generującego reguły wyboru pomiędzy rynkami akcji i bonów skarbowych.

3.2.1. Reprezentacja

Jednym z najpowszechniej uznawanych aksjomatów teorii inwestowania jest zasada dywersyfikacji portfela inwestycyjnego. Zgodnie z nią nie należy lokować wszystkich swoich zasobów w jednej choćby najbardziej atrakcyjnie rokującej inwestycji, ale podzielić je w sposób racjonalny pomiędzy kilka inwestycji ocenianych pozytywnie.

Na analogicznej zasadzie bazuje prezentowana poniżej metoda R. Bauera. Jej celem nie jest znalezienie pojedynczej superdoskonałej reguły wyboru rynku, ale przynoszącego zysk zbioru wielu reguł.

Poszukiwane są reguły wyboru rynku w postaci:

if warunek **then** inwestuj w rynek akcji **else** inwestuj w rynek bonów skarbowych

przy czym każdy warunek zbudowany jest z dokładnie trzech warunków elementarnych odpowiednio pogrupowanych i połączonych operatorami logicznymi alternatywy i koniunkcji. Przykładowym warunkiem reguły wyboru może być wyrażenie:

(warunek_elementarny_1 OR warunek_elementarny_2) AND warunek_elementarny_3

Warunkiem elementarnym jest wyrażenie postaci:

$$(A < X) \tag{3.6}$$

lub

$$(A \geq X) \tag{3.7}$$

gdzie A reprezentuje zmienne makroekonomiczne (np. stopa procentowa, kurs marki niemieckiej w stosunku do dolara, wartość indeksu giełdowego Dow-Jonesa), a X - poziom wartości.

Tak zdefiniowana reguła wyboru rynku reprezentowana jest przez ciąg złożony z 21 bitów. Początkowe trzy grupy pięciobitowe odpowiadają poziomom wartości zmiennych makroekonomicznych występujących w trzech warunkach elementarnych (32 dopuszczalne poziomy wartości dla każdej zmiennej makroekonomicznej), kolejne trzy bity odpowiadają ośmiu możliwym kombinacjom operatorów porównań ($<$, \geq), a ostatnie trzy bity odpowiadają ośmiu możliwościom grupowania logicznego trzech warunków elementarnych.

Pozostała jeszcze do omówienia sprawa określenia kombinacji trzech zmiennych makro-ekonomicznych występujących w regule wyboru rynku. R. Bauer przeanalizował bazę danych makroekonomicznych zawierającą 167 miesięcznych szeregów czasowych i obliczył dodatkowo szeregi zmian jedno-, trzy- i dwunastomiesięcznych dla każdego z tych 167 szeregów. Spośród tej ilości danych makroekonomicznych wybrał 10 szeregów najsilniej skorelowanych z szeregiem czasowym miesięcznych stóp zwrotu z inwestycji w akcje.

Z 10 zmiennych makroekonomicznych można utworzyć 120 kombinacji trzejelementowych. Dla każdej z nich przeprowadzono niezależny przebieg algorytmu genetycznego w celu znalezienia najlepszej reguły zbudowanej dla tych trzech zmiennych. Następnie powtórzono 120 przebiegów algorytmu genetycznego starając się tym razem znaleźć regułę najgorszą (przynoszącą największą stratę) tzn. minimalizującą funkcję przystosowania. Otrzymano w ten sposób zbiór 120 „dobrych” reguł wyboru rynku oraz drugi zbiór 120 „złych” reguł wyboru.

Bazując na tym zestawie reguł zbudowano portfel inwestycyjny zajmując pozycję długą dla każdej „dobrej” reguły i pozycję krótką dla każdej „złej” reguły. Pomijając koszty transakcyjne zbudowanie takiego portfela nie wymaga nakładów inwestycyjnych. Jego wartość w momencie początkowym jest równa 0. Jeżeli w praktyce nie wystąpi różnica pomiędzy wynikiem osiągniętym przez zbiór reguł „dobrych”, a wynikiem zbioru reguł „złych” to zwrot z całego portfela inwestycyjnego będzie średnio równy 0. Jeżeli „dobre” reguły dadzą wynik lepszy niż reguły „złe”, to zwrot z portfela będzie dodatni.

3.2.2. Funkcja przystosowania

Funkcję przystosowania reguły wyboru rynku określono jako wartość pięcioletniej średniej ruchomej rocznych stóp zwrotu ze strategii postępowania opisanej regułą wyboru w ciągu poprzednich pięciu lat.

3.2.3. Selekcja

W wyniku obliczenia funkcji przystosowania dla wszystkich osobników populacji (reguł wyboru rynku) możliwe jest uszeregowanie ich w kolejności zaczynając od osobników, dla których wartość funkcji przystosowania jest najwyższa, a kończąc na osobnikach z małą wartością funkcji przystosowania. Selekcja osobników do puli rodzicielskiej odbywa się poprzez umieszczenie w niej dwóch kopii osobników, które zajęły trzy pierwsze miejsce w tym rankingu i po jednym egzemplarzu wszystkich pozostałych z wyjątkiem trzech najsłabszych. Dodatkowe kopie trzech najlepszych osobników zastępują zatem trzy najsłabiej przystosowane.

3.2.4. Operatory genetyczne

W konstruowanym algorytmie genetycznym R. Bauer zastosował standardowe operatory genetyczne Hollanda: krzyżowanie proste z prawdopodobieństwem krzyżowania równym 0,6 i mutację binarną z

prawdopodobieństwem 0,001. Sposób działania tych operatorów opisany został poprzednio.

3.2.5. Wyniki

Rezultaty działania algorytmu genetycznego zweryfikowano budując portfel złożony z inwestycji w akcje reprezentowane w indeksie Standard & Poor 500 i w bony skarbowe w okresie lat 1989 - 1991. Jak powiedziano powyżej konstrukcja portfela inwestycyjnego polegała na zajęciu długiej pozycji dla każdej reguły „dobrej” i pozycji krótkiej dla każdej pozycji „złej”. Przyjmijmy dla ułatwienia wielkość 10 000\$ jako kwotę bazową inwestycji.

Jeżeli zatem np. 90 ze 120 reguł „dobrych” wskazywało na inwestowanie w akcje, a pozostałe 30 reguł wygenerowało sygnał inwestowania w bony skarbowe to zbiór „dobrych” reguł wyboru nakazywałyby w danym miesiącu zainwestowanie 7 500\$ w akcje i 2 500\$ w bony skarbowe. Jeżeli jednocześnie zbiór „złych” reguł sugeruje podział 20% : 80% pomiędzy akcje i bony skarbowe dla pozycji krótkich, to nakazuje on zajęcie pozycji krótkiej wartości 2 000\$ w akcjach i pozycji krótkiej wartości 8 000\$ w bonach skarbowych. Efektem netto tych sugestii jest zatem zainwestowanie w akcje 5 500\$ i zajęcie pozycji krótkiej o tej samej wartości w bonach skarbowych.

Po ośmiu miesiącach od rozpoczęcia eksperymentu skumulowany zwrot z portfela był dodatni i wynosił 8,94%. Trzeba przy tym zaznaczyć, że pojęcie zwrotu z portfela jest w tym przypadku w znacznym stopniu sztuczne, ponieważ inwestycja netto wynosi 0\$. Taki poziom zwrotu należy zatem rozumieć jako zysk w wysokości 894\$ przy założeniu, że maksymalne zaangażowanie po każdej stronie wynosiło stale 10 000\$. Zwrot z portfela inwestycyjnego dla całego trzyletniego eksperymentu wyniósł 13.76%, co wskazuje, że algorytm genetyczny poprawnie zidentyfikował dwa zbiory reguł wyboru rynku o przeciwstawnych charakterystykach zwrotu.

R. Bauer dodaje, że jego dalsze prace doprowadziły do lepszego rozdzielania obu grup reguł co znacznie zwiększyło ich atrakcyjność dla inwestorów.

3.3. Zarządzanie funduszem indeksowym

Fundusz indeksowy jest to fundusz inwestycyjny, którego portfel inwestycyjny wzorowany jest na kompozycji jednego z głównych indeksów giełdowych takich jak Standard & Poor 500 (Nowy Jork), FTSE 100 (Londyn), DAX (Frankfurt).

U podstaw budowy funduszu indeksowego leży założenie, że generalnie kursy giełdowe papierów wartościowych prawidłowo oddają ich wartość. Zarządzający funduszem indeksowym stawia zatem sobie za cel nie wyszukiwanie papierów wartościowych, których kursy giełdowe są zaniżone w stosunku do ich obecnej lub przyszłej wartości, ale naśladowanie zachowania się jednego z powszechnie znanych indeksów giełdowych (*index tracking*).

Takie podejście zyskuje sobie coraz większe zainteresowanie wśród inwestorów. W ostatnich latach szybko wzrasta zarówno ilość funduszy indeksowych jak i wielkość kwot, którymi takie fundusze zarządzają. (tylko w USA - kilkaset miliardów dolarów).³

Dopasowanie zachowania się portfela inwestycyjnego do indeksu giełdowego może być osiągnięte na dwa sposoby. Jeden z nich to pełne odtworzenie struktury indeksu (*full replication*), polegające na włączeniu do portfela funduszu indeksowego wszystkich składników indeksu w wielkości proporcjonalnej do ich udziału w indeksie. Strategia taka zapewnia doskonale zharmonizowanie zachowania indeksu giełdowego i portfela funduszu, ale rodzi wysokie koszty transakcyjne

³ W sierpniu 1997 roku rozpoczął działalność pierwszy polski fundusz indeksowy - Eurofundusz IV bazowany na indeksie giełdy warszawskiej WIG.

oraz trudności w takim bieżącym zarządzaniu portfelem, by ta harmonia była utrzymywana.

Drugi sposób - próbkowanie indeksu (*index sampling*) polega na budowie portfela funduszu z akcji niewielkiej ilości spółek wchodzących w skład indeksu, ale w taki sposób by różnica pomiędzy zachowaniem się wartości indeksu giełdowego, a zachowaniem się wartości portfela indeksu była jak najmniejsza. Metoda ta redukuje koszty transakcyjne i ułatwia równoważenie funduszu, ale wprowadza znaczny błąd metody, który może być mierzony odchyleniem indeksu giełdowego od wartości portfela funduszu indeksowego.

Na początku lat dziewięćdziesiątych pojawiły się publikacje referujące zastosowania algorytmów genetycznych do zarządzania funduszami indeksowymi. D. Edelbüttel [1992] zbudował algorytm genetyczny wspomagający zarządzanie funduszem bazowanym na indeksie giełdy frankfurckiej DAX, a J. Shapcott [1992] przedstawił odmienny algorytm dla zarządzania funduszem opartym o FTSE-100 - indeks giełdy londyńskiej. Poniżej przedstawiono metodę konstrukcji algorytmu genetycznego zaproponowaną przez Edelbüttela.

3.3.1. Reprezentacja

W skład indeksu DAX wchodzi 30 akcji największych spółek akcyjnych notowanych na giełdzie w Frankfurtach. Uszeregowane one zostały w sposób alfabetyczny i ponumerowane liczbami od 1 do 30. Tak więc np. (jeżeli przyjąć skład indeksu DAX z 1992 roku) numerowi 1 odpowiada firma Allianz, numerowi 2 - BASF, numerowi 3 - Bayer itd. Zadanie algorytmu polega na wyborze podzbioru k - elementowego ($k \leq 30$) akcji wchodzących do portfela funduszu oraz procentowego udziału tych akcji w portfelu.

Każdy osobnik jest reprezentowany przez wektor $X = [x_1, \dots, x_k, x_{k+1}, \dots, x_{2k}]$ złożony z dwóch typów elementów. Pierwsze k elementów jest nazywane selektorami. Są to liczby binarne z przedziału $\langle 00000, 11111 \rangle$ (w zapisie dziesiętnym $\langle 0, 31 \rangle$) reprezentujące po-

szczególne akcje w indeksie DAX. Ponieważ liczbom 0 i 31 nie odpowiada żaden składnik indeksu DAX przypisano im znaczenie *brak wyboru akcji*. Praktycznie oznacza to zmniejszenie liczebności podzbioru akcji wchodzącego w skład portfela funduszu indeksowego.

Pozostałe elementy o subskryptach od $k+1$ do $2k$ są nazywane wagami. Są to liczby binarne z przedziału $\langle 0, 1023 \rangle$, które po znormalizowaniu reprezentują procentowy udział danej akcji w portfelu funduszu.

Relacja pomiędzy selektorami i wagami określona jest w sposób naturalny: selektorowi x_i ($1 \leq i \leq k$) odpowiada waga x_{k+i} . Jeżeli zatem np. $x_1=2$, a $x_{k+1}=367$, to oznacza to, że pierwszym elementem portfela funduszu są akcje firmy BASF, a ich procentowy udział w wartości portfela funduszu wynosi (po znormalizowaniu):

$$u_1 = \frac{367}{M} \cdot 100 \quad (3.8)$$

gdzie M jest sumą wszystkich wag :

$$M = \sum_{i=k+1}^{2k} x_i \quad (3.9)$$

3.3.2. Funkcja przystosowania

Funkcją mierzącą przystosowanie osobnika jest odchylenie (błąd) standardowy różnicy pomiędzy zwrotem z indeksu a zwrotem z portfela funduszu odpowiadającego danemu osobnikowi X . Jest to funkcja błędu naśladowania (*tracking error*):

$$TE = \left(\frac{1}{T} \left(\sum_{t=1}^T (r_{p,t} - r_{m,t}) - E(r_{p,t} - r_{m,t}) \right)^2 \right)^{\frac{1}{2}} \quad (3.10)$$

W powyższym wzorze $r_{p,t}$ - oznacza zwrot z portfela funduszu na sesji giełdowej w dniu t , a $r_{m,t}$ - zwrot z indeksu giełdowego, przy czym zwroty te liczone są odpowiednio z wzorów:

$$r_{p,t} = \frac{w_{p,t} - w_{p,t-1}}{w_{p,t-1}} \cdot 100 \quad (3.11)$$

$$r_{m,t} = \frac{w_{m,t} - w_{m,t-1}}{w_{m,t-1}} \cdot 100 \quad (3.12)$$

gdzie $w_{p,t}$ oznacza wartość portfela funduszu liczoną wg cen (zamknięcia) z sesji w dniu t , a $w_{m,t}$ - wartość indeksu giełdowego na sesji w dniu t .

Zatrzymajmy się na chwilę na pojęciu błędu naśladowania indeksu ponieważ będzie ono wykorzystane także przy ocenie rezultatów przeprowadzonych eksperymentów z zastosowaniem algorytmów genetycznych.

Ze względu na to, że algorytm liczenia indeksu giełdowego jest konstrukcją ściśle teoretyczną powstanie tego błędu jest nie do uniknięcia nawet przy zarządzaniu funduszem indeksowym metodą pełnego odtworzenia indeksu. Przyczyny odchylenia indeksu giełdowego od wartości portfela funduszu indeksowego mogą być bardzo różnorodne.

Jako przykładowe można wymienić przesunięcie czasowe pomiędzy dniem ustalenia prawa do dywidendy a dniem wypłaty dywidendy. Algorytmy obliczania indeksów giełdowych typu total return zakładają, że cała dywidenda jest natychmiast reinwestowana w akcje tej samej spółki, której dywidenda dotyczy. W praktyce wykonanie tej

operacji w trybie natychmiastowym jest niemożliwe ze względu na wspomniane wyżej przesunięcie czasowe.

Zarządzający funduszem ma do wyboru jedna z dwóch możliwości. Pierwsza to zaciągnąć kredyt i nie czekając na wypłatę dywidendy zakupić akcje natychmiast po ustaleniu prawa do dywidendy, ale wówczas musi się liczyć z kosztami zaciągnięcia kredytu, które spowodują obniżenie zwrotu z portfela w stosunku do zwrotu z indeksu. Druga możliwość to poczekać do otrzymania dywidendy, ale wówczas zakup dokonany zostanie już po innej cenie co także spowoduje powstanie omawianego błędu.

Inne przykładowe przyczyny powstawania błędu naśladowania to koszty transakcyjne, które musi ponosić zarządzający funduszem, problemy związane z opodatkowaniem, wyłączenie spółki z portfela indeksu, konieczność zachowania części aktywów funduszu w gotówce itp.

3.3.3. Selekcja

W operacji selekcji zastosowano procedurę zaproponowaną przez Wetzela zwaną *metodą rang* lub *metodą turniejów losowych*. W metodzie tej oblicza się w zwykły sposób prawdopodobieństwo reprodukcji, po czym dokonuje się losowania par osobników wg reguły ruletki. Po wylosowaniu pary, osobnik o wyższej wartości funkcji przystosowania zostaje zwycięzcą i umieszczany jest w puli rodzicielskiej. Proces ten kontynuowany jest aż do całkowitego wypełnienia puli rodzicielskiej.

3.3.4. Operatory genetyczne

Dla rozwiązania problemu użyto krzyżowania dwupunktowego. Założona wartość p_k prawdopodobieństwa krzyżowania wynosiła 0,6. Operator krzyżowania dwupunktowego, zastosowany po raz pierwszy przez De Jonga (1975) różni się tym od klasycznego operatora krzyżowania prostego Hollanda, że zamiast wyboru jednego punktu krzy-

zowania i wymiany informacji po obu stronach tego punktu, wybiera się dwa punkty krzyżowania i wymienia informacje pomiędzy tymi dwoma punktami.

Przykładowo w wyniku zastosowanie operatora krzyżowania dwupunktowego z punktami krzyżowanie 1 i 4 dla chromosomów: 00000 oraz 11111 otrzymamy chromosomy potomne: 01110 i 10001.

Ze względu na binarną budowę genotypu w omawianym algorytmie zastosowano standardowy bitowy operator mutacji z prawdopodobieństwem 0,001.

3.3.5. Wyniki

Zanim omówimy wyniki uzyskane przez algorytm genetyczny przedstawimy jako punkt odniesienia przykładowe błędy naśladowania uzyskiwane w praktyce przez zarządzających funduszami indeksowymi.

Fundusz indeksowy zbudowany metoda pełnego odtworzenia amerykańskiego indeksu Standard & Poor 500 osiągnął w okresie ostatnich 25 lat średni błąd równy w przybliżeniu 0,2%. Fundusz indeksowy w pełni odtwarzający indeks giełdy londyńskiej osiągnął w sześćdziesięciu lat 1983 - 1989 podobny poziom błędu równy 0,2%.

Ilość akcji w portfelu funduszu	400	350	275	200	150	30
Błąd naśladowania indeksu	0,30%	0,35%	0,50%	0,80%	1,00%	3,00%

Dla indeksów budowanych metodą próbkowania za dobry uważa się błąd na poziomie 0,5%. Liesching i Manchanda [1990] przytaczają poniższe zestawienie dla metody próbkowania zastosowanego dla in-

deksu FT - A All Share Index (Londyn) składającego się z akcji 683 spółek:

Cytowane przez Eddelbüttela badanie na ten temat przeprowadzone przez Deutsche Bank stwierdza w konkluzji, że:

- poziom błędu równy 0,2% lub mniej jest uważany za bardzo dobry i może być osiągnięty jedynie metodą pełnego odtworzenia,
- poziom błędu nie przekraczający 0,5% może być uważany za dobry dla metody próbkowania,
- niektóre z funduszy indeksowych stawiają sobie za cel poziom błędu równy 1% i jest to wynik w sposób oczywisty wystarczający do utrzymania się w biznesie.

Jak przy tak określonym kryterium oceny rzeczywistych funduszy indeksowych wypadł zaproponowany algorytm genetyczny? Eddelbüttel opublikował rezultaty dwóch eksperymentów przeprowadzonych z algorytmem genetycznym.

W pierwszym eksperymencie założono z góry, że w portfelu funduszu reprezentowane są wszystkie z 30 akcji indeksu DAX. Zadaniem algorytmu genetycznego było zaproponowanie ich wag czyli wartościowego udziału w portfelu funduszu. W 100 powtórzeniach tego eksperymentu, średni błąd najlepszego osobnika wyniósł w przybliżeniu 0,007 (z wariancją $3,944 \cdot 10^{-6}$) tj. poniżej poziomu błędu uznawanego za bardzo dobry.

W drugim eksperymencie zadaniem algorytmu był zarówno dobór akcji jak i ich wartościowego udziału w portfelu. Wynik drugiego eksperymentu, który również powtarzano 100 razy, był około pięciokrotnie gorszy, ale ciągle na poziomie błędu uznawanym za dobry.

4. Wnioski

Pierwszą obserwacją jaka nasuwa się z przeglądu publikacji z zakresu zastosowań algorytmów genetycznych w finansach jest mała dostępność informacji dotyczących szczegółów konstrukcji algorytmów i rezultatów przeprowadzonych eksperymentów. Oczywistą przeszkodą w upowszechnianiu takich informacji jest komercyjna wartość wyników badań. Niektóre z opisanych algorytmów pojawiły się później w wersji znacznie ulepszonej i rozszerzonej jako płatne pakiety oprogramowania przeznaczone dla inwestorów.

Jednak wniosek generalny z przedstawionego krótkiego przeglądu jest następujący - wydaje się, że algorytmy genetyczne są szczególnie odpowiednie dla zastosowań finansowych. Ta przydatność wynika z jednej strony ze specyfiki problemów finansowych, a z drugiej z tych charakterystycznych cech algorytmów genetycznych, które różnią je od innych metod poszukiwań.

Specyfika zagadnień finansowych, a w szczególności problemów rynku kapitałowego polega m. in. na tym, że ograniczona wiedza o sposobie rozwiązywania problemu (np. podjęcia optymalnej decyzji inwestycyjnej) idzie w parze z bardzo dużą ilością danych napływających od podmiotów rynku kapitałowego i ich otoczenia makroekonomicznego. Często związek tych danych z rozwiązywanym problemem może wydawać się intuicyjnie oczywisty, chociaż nadanie mu postaci zależności matematycznych jest niezwykle trudne.

Algorytmy genetyczne są natomiast idealne dla rozwiązywania złożonych zagadnień, nie w pełni zdefiniowanych, z dużą przestrzenią poszukiwań.

Złożoność problemów finansowych sprawia, że opisujące je funkcje są często nieregularne, nieróżniczkowalne, z dużą ilością lokalnych ekstremów. Zastosowanie metod analitycznych jest na ogół

uzależnione od istnienia pochodnych i przy nieszczęśliwym doborze punktu startowego, może zakończyć się w ekstremum lokalnym.

Algorytmy genetyczne mają zakres globalny. Ponadto nie wymagają wyboru dobrego punktu startowego. Działając jednocześnie na całej populacji i mając do dyspozycji liczną pulę osobników ponadprzeciętnych redukują możliwość utknięcia w maksimum lokalnym.

Poszukiwanie rozwiązań problemów finansowych nie stwarza konieczności znalezienia rozwiązania najlepszego. Zwykle wystarczy by zastosowane rozwiązanie było bliskie optymalnemu lub nawet by tylko było lepsze od rozwiązań przyjętych przez konkurentów. Nawet mała poprawa rozwiązania, czasami rzędu ułamka procent, warta jest wysiłku.

Algorytmy genetyczne kładą nacisk na efektywność poszukiwania akceptowalnych rozwiązań, co raz lepszych dla każdej następnej generacji, a nie na zbieżność metody do rozwiązania optymalnego.

Próby zastosowania algorytmów genetycznych do rozwiązania zagadnień finansowych zaczęły pojawiać się dopiero od początku lat dziewięćdziesiątych. Opublikowane rezultaty wydają się być zachęcające mimo istnienia naturalnej bariery w ich upowszechnianiu. Należy więc przypuszczać, że dzięki wymienionym powyżej właściwościom algorytmów genetycznych ich zastosowania w zagadnieniach finansowych będą coraz liczniejsze i coraz bardziej owocne.

Literatura

- [1] Bauer, Jr., R. J. (1994) *Genetic Algorithms and Investment Strategies*, J. Wiley, New York.
- [2] Cytowski, J. (1996) *Algorytmy genetyczne. Podstawy i zastosowania*, Akademicka Oficyna Wydawnicza PLJ, Warszawa.
- [3] Deboeck, G. J. (1994) *Trading on the Edge. Neural, Genetic and Fuzzy Systems for Chaotic Financial Markets*, J. Wiley, New York.

- [4] De Jong, K.A. (1975) *An analysis of behavior of class of genetic adaptive systems*, University of Michigan.
- [5] de la Maza, M., Yuret, D. (1995) *A model of stock market participants*, w: Biethahn, J., Nissen, V. (red.), *Evolutionary Algorithms in Management Applications* (str.290--302), Springer-Verlag, Berlin
- [6] Eddelbüttel, D. (1992) *A Genetic Algorithm for Passive Management*, Grege, Marseille.
- [7] Goldberg, D.E. (1995) *Algorytmy genetyczne i ich zastosowania*, WNT, Warszawa.
- [8] Goonatilake, S. (1997) *Intelligent hybrid system for financial decision making*, w: *Handbook of Evolutionary Computation*. Release 97/1, IOP Publishing Ltd and Oxford University Press.
- [9] Holland, J.H. (1975) *Adaptation in Natural and Artificial Systems*, University of Michigan Press, Ann Arbor.
- [10] Holland, J.H. (1992) *Algorytmy genetyczne*, Świat Nauki, wrzesień, str. 34-41.
- [11] Koza, J.R. (1992) *Genetic Programming*, MIT Press, Cambridge, MA.
- [12] Liesching, R., Maschanda, V. (1990) *Establishing the fund*, w: Bishop, E.(red), *Indexation*, Euromoney Publication PLC, London.
- [13] Michalewicz, Z. (1997) *Algorytmy genetyczne + struktury danych = programy ewolucyjne*, WNT, Warszawa.
- [14] Pictet, O. V., Chopard, M. O. B., Tomassini, M. (1996) *Parallel genetic programming: An application to trading models evolution*, w: *Proceedings of the First Annual Conference on Genetic Programming* (str. 357--362), MIT Press, Cambridge, MA.
- [15] Rutkowska, D., Pilinski, M., Rutkowski, L. (1997) *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, PWN, Warszawa.
- [16] Shapcott, J. (1992) *Index Tracking: Genetic Algorithms for Investment Portfolio Selection*, praca niepublikowana.
- [17] Yuret, D., de la Maza, M. (1994) *A genetic algorithm system for predicting the OEX*, *Technical Analysis of Stocks and Commodities*, 12 (6), 58-64.

WYŻSZA SZKOŁA INFORMATYKI STOSOWANEJ I ZARZĄDZANIA

działa pod auspicjami
Polskiej Akademii Nauk

ZAŁOŻYCIELEM

Wyższej Szkoły Informatyki Stosowanej i Zarządzania
jest

FUNDACJA KRZEWIENIA NAUK SYSTEMOWYCH
powołana z inicjatywy
Prezesa
POLSKIEJ AKADEMII NAUK

FUNDATOREM

Fundacji Krzewienia Nauk Systemowych
jest

POLSKA AKADEMIA NAUK

ORGANEM

sprawującym nadzór
jest

MINISTERSTWO EDUKACJI NARODOWEJ

Wyższa Szkoła Informatyki Stosowanej i Zarządzania
prowadzi studia wyższe na kierunkach:

INFORMATYKA
ZARZĄDZANIE I MARKETING

SIEDZIBA

Instytut Badań Systemowych
Polskiej Akademii Nauk

ISBN 83-85847-24-3