

**Grzegorz Wojarnik\***

Uniwersytet Szczeciński

**METODY EWOLUCYJNE  
W ANALIZIE ZMIAN KURSU AKCJI  
SPÓŁEK GIEŁDOWYCH****Streszczenie**

Metody ewolucyjne są jedną z dróg rozwoju sztucznej inteligencji, która czerpiąc z teorii doboru naturalnego, pozwala na rozwiązywanie złożonych problemów, trudnych do rozwiązania tradycyjnymi metodami ekonometrycznymi, statystycznymi lub przy pomocy badań operacyjnych.

Jedną z podstawowych metod ewolucyjnych są algorytmy genetyczne, które były wielokrotnie wykorzystane do rozwiązywania różnorodnych problemów związanych z inwestowaniem na rynku papierów wartościowych. Dlatego celem artykułu jest systematyka doświadczeń związanych z wykorzystaniem algorytmów genetycznych w analizie zmian kursu akcji spółek giełdowych oraz podsumowanie osiągnięć w tym zakresie.

Jednocześnie artykuł będzie stanowił próbę przedstawienia warunków brzegowych oraz klas problemów z obszaru giełdy papierów wartościowych, najbardziej dogodnych i nadających się do wykorzystania metod ewolucyjnych ze szczególnym uwzględnieniem algorytmów genetycznych.

**Słowa kluczowe:** algorytmy genetyczne, giełda papierów wartościowych, analiza techniczna

---

\* Adres e-mail: [grzegorz.wojarnik.us@gmail.com](mailto:grzegorz.wojarnik.us@gmail.com).

## Wprowadzenie

Metody ewolucyjne, których głównym przedstawicielem są algorytmy genetyczne znalazły liczne zastosowania w różnych dziedzinach, gdzie najczęściej celem ich implementacji było odkrywanie nieoczekiwanych wzorców i prawidłowości rządzących badanymi obiektami czy zjawiskami. Metody te wykorzystywane są w sytuacjach, gdy liczba potencjalnych rozwiązań problemu jest tak duża, że ze względu na czas lub koszty potrzebne do znalezienia rozwiązania optymalnego są czasowo nieosiągalne lub koszty uzyskania takiego rozwiązania znacznie przewyższają spodziewane korzyści.

Oczywiście znane są ograniczenia tych metod, spośród których najistotniejszym jest fakt, że znalezione przez metody ewolucyjne rozwiązania są rozwiązaniami suboptymalnym – takimi, co do których nie ma pewności, że są tymi najlepszym dla spośród wszystkich możliwych rozwiązań. Jednak sam fakt znalezienia rozwiązania „zadawalającego” jest na tyle istotny, że warto z tych metod korzystać, zwłaszcza, że *de facto* nie są to metody odkryte przez człowieka, ale zaadaptowane na grunt metod analizy danych z obszaru biologii, gdzie sama przyroda posługuje się nimi podczas procesu ewolucji.

W związku z powyższym, warto przyjrzeć się metodom ewolucyjnym (szczególnie algorytmom genetycznym) w kontekście ich wykorzystania do analizy zjawisk zachodzących w obszarze giełdy papierów wartościowych, gdzie liczba potencjalnych czynników wpływających na zmienność oraz zachowanie kursów walorów na nich notowanych jest tak duża, że często standardowe metody analizy danych nie radzą sobie dobrze lub dają bardzo uproszczony obraz rzeczywistości giełdowej. Dlatego też celem niniejszej pracy jest przegląd wykorzystania algorytmów genetycznych w analizie danych giełdowych. Artykuł ten stanowi przyczynek do dalszej pracy badawczej autora, który planuje wykorzystać opracowane przez niego założenia ewolucyjnego systemu analizy danych (Wojarnik, 2013), do analizy czynników wpływających na prognozowane zmiany kursy spółek giełdowych. Oczywiście jest, że w takiej pracy nie jest możliwe wyczerpanie wszystkich możliwych przykładów wykorzystania metod sztucznej inteligencji jakimi są metody ewolucyjne, dlatego autor zdecydował się na przedstawienie kilku przykładów ich wykorzystania w obszarze różnych giełd papierów wartościowych. Jednocześnie, aby przybliżyć zasadę działania algorytmów genetycznych w pierwszej części pracy zostanie przedstawiona specyfika

oraz zasada działania algorytmów genetycznych, którego celem jest przybliżenie czytelnikowi problematyki metod ewolucyjnych w analizie danych.

## Specyfika algorytmów genetycznych

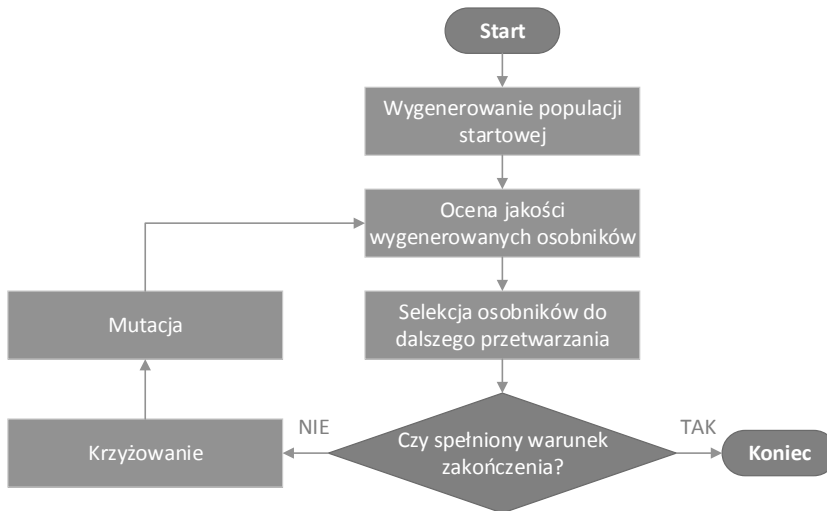
Algorytmy genetyczne (*genetic algorithm* – w skr. GA) stanowią podejście do przeszukiwania przestrzeni możliwych rozwiązań w złożonych problemach poprzez przedstawianie modelu tych rozwiązań za pomocą zjawisk zachodzących w obszarze kodowania danych w świecie materii ożywionej. Mamy tutaj do czynienia ze zmianami populacji chromosomów kodujących genotyp stworzeń. Zmiany te nazywamy ewolucją. Jednym słowem w kolejnych iteracjach poprzez naśladowanie mikro-ewolucyjnych wydarzeń, takich jak „krzyżowanie” i „mutacja” GA naśladują to co się odbywa ciągle w świecie istot żywych. Może to odgrywać pewną rolę w rozwiązywaniu problemów optymalizacji w analizie danych.

Algorytmy genetyczne są dziedziną sztucznej inteligencji, w której przyjęto za paradygmat założenia zaczerpnięte z teorii ewolucji. Zauważono, bowiem, że ewolucja opiera się na zmienności populacji osobników, która to zmienność zapewnia różnorodność zestawu cech osobników, co z kolei pozwala, mówiąc w największym uogólnieniu, na przetrwanie oraz przekazywanie swoich cech tym osobnikom, które są najlepiej przystosowane do otaczającego je środowiska. Właśnie cecha adaptacji decyduje o tym w jakim stopniu poszczególne osobniki są zdolne do przeżycia w otaczającym je środowisku.

W GA, chodzi o wyłonienie spośród generowanych rozwiązań rozpatrywanego problemu rozwiązania, które najlepiej spośród wszystkich wyłonionych odpowiada na postawiony problem.

W przyrodzie podstawową strukturą odpowiadającą za kodowanie informacji o danym osobniku jest kwas dezoksyrybonukleinowy (popularnie zwany jako DNA), w którym najmniejszymi nośnikami informacji są cztery zasady – adenina, guanina, cytozyna oraz tymina. Poszczególne sekwencje tych czterech zasad kodują poszczególne cechy organizmu (osobnika), o cechach tych mówimy, że są geny – stąd właśnie nazwa algorytmy genetyczne. Jednak na potrzeby algorytmów genetycznych oczywiste jest, że nie ma obowiązku kodowania danych z wykorzystaniem notacji czwórkowej, ale najczęściej wykorzystywana jest kodowanie binarne (zerojedynkowe) lub liczbami całkowitymi.

W przypadku GA potocznie mówi się o jednym rozwiązaniu stanowiącym zespół genów (czyli konkretnych zakodowanych cech, taką cechą może być rekomendacja giełdowa, gdzie wyróżnić można trzy stany – kup, sprzedaj, trzymaj), że jest to osobnik. Warto dodać, że można wyobrazić sobie taką sytuację, że każda z cech takiego osobnika będzie zakodowana w różny sposób, np. za pomocą liczby całkowitej, a inna binarnie.



Rys. 1. Zasada działania klasycznego algorytmu genetycznego

Źródło: opracowanie własne.

W klasycznym algorytmie genetycznym populację stanowią osobniki opisane genami skonstruowanymi na potrzeby rodzaju rozwiązywanego problemu. W algorytmie tym każdy osobnik przedstawia możliwe rozwiązanie badanego problemu. Każde rozwiązanie jest oceniane na podstawie miary jego dopasowania względem kryteriów określonych mianem funkcji dopasowania.

Tak więc każda nowa populacja to zbiór osobników najlepiej przystosowanych do funkcji dopasowania. Na etapie operacji genetycznych następuje użycie operatorów genetycznych takich jak krzyżowanie, czy mutacja wprowadzających zmiany w genotypie osobników.

Podstawowymi operatorami wykorzystywanymi w algorytmach genetycznych są operatory krzyżowania, mutacji oraz selekcji.

Operator krzyżowania zapewnia losowe kojarzenie osobników celem wyłonięcia osobników potomnych, które będą miały wymieszane geny ze swoich genomów (czyli materiałów genetycznych).

Operator mutacji powoduje zmiany o mniejszym zasięgu ponieważ losowo wprowadza drobne zmiany w genomie osobnika. Kolejność wykonania tych operatorów jest dowolna.

Dodatkowo należy wiedzieć, że operatorom krzyżowania i mutacji nie podlegają wszystkie osobniki, ale wybrane losowo z góry narzuconym prawdopodobieństwem. Praktyka pokazała, że najbardziej skuteczne jest ustalenie prawdopodobieństwa wykonania operacji krzyżowania o rząd wielkości większe od prawdopodobieństwa wykonania operacji mutacji, np. 0,3 dla krzyżowania i 0,03 dla mutacji.

Zadaniem operatora selekcji jest wybór osobników do dalszego przetwarzania. W AG chodzi o to, aby kolejne populacje osobników stanowiących rozwiązanie danego problemu zawierały coraz lepsze jakościowo rozwiązania tego problemu, dlatego podczas selekcji chodzi o taki wybór osobników, aby do dalszego przetwarzania zostały wybrane te lepsze.

I dochodzimy tutaj do funkcji dopasowania (*fitness function*), która musi być wykonana dla każdego osobnika w populacji dotychczas wygenerowanych osobników. Funkcja dopasowania, to nic innego jak pewna procedura oceny danego osobnika, która pozwala określić jego wartość w kontekście rozwiązywanego problemu, a tym samym porównać kolejne osobniki, aby można było stwierdzić, który jest lepszy, a który gorszy z punktu widzenia celu rozwiązywanego problemu.

Znając wartości funkcji oceny dla każdego osobnika do dalszego przetwarzania najczęściej wybierane są wszystkie najlepiej przystosowane osobniki (zarówno z pokolenia pierwotnego, jak i potomnego) – czasami i tu wprowadza się pewną losowość, aby różnicować populację potomną.

### **Wykorzystanie algorytmów genetycznych na giełdzie papierów wartościowych**

W tym miejscu zostanie zaprezentowanych kilka przykładowych sposobów wykorzystania algorytmów genetycznych na giełdzie papierów wartościowych.

Oczywiste jest, że na giełdzie papierów wartościowych, analiza techniczna jest użyteczną metodą przewidywania cen akcji. Chociaż profesjonalni analitycy giełdowi i zarządzający funduszami zazwyczaj dokonują subiektywnych osądów, na podstawie obiektywnych wskaźników technicznych, jednak dla nieprofesjonalistów prognozowanie na podstawie tych wskaźników jest trudne ponieważ istnieje zbyt wiele skomplikowanych wskaźników technicznych, jakie powinny być uwzględniane podczas analiz. Ponadto, stwierdzono dwie główne wady w wielu modelach prognostycznych (Cheng, Chen, Ying Wei, 2010):

1. założenia statystyczne dotyczące zmiennych są wymagane dla modeli szeregowych czasowych, takich jak autoregresja średniej ruchomej modelu (ARiMR) oraz warunkowej autoregresji heteroskedastyczność (ARCH), do produkcji modeli prognozowania równań matematycznych, i nie są one łatwe do zrozumienia przez inwestorów giełdowych;
2. zasady odkrywane dzięki niektórym metodom sztucznej inteligencji, takich jak sieci neuronowych, nie są łatwe do wykorzystania i implementacji. W celu zlikwidowania tych wad, autorzy (Cheng, Chen, Ying Wei, 2010) proponują hybrydowy model prognozowania, za pomocą wielu wskaźników analizy technicznej do przewidywania trendów cen akcji. Ponadto, proponowanych przez nich model obejmuje cztery proponowane procedury w modelu hybrydowym, aby zapewnić skuteczne zasady prognozowania, które wywodzą się z wyodrębnionych zasad o wysokiej wartości nośnej, stosując narzędzie oparte o teorię zbiorów przybliżonych (RST):
  - a) wybór zasadniczych wskaźników technicznych, które są w znacznej mierze powiązane z przyszłymi cenami akcji, dla popularnych wskaźników AT opartych na macierzy korelacji;
  - b) stosowanie metody dystrybucji skumulowanego prawdopodobieństwo (CDPA) i minimalizacja podejścia zasada entropii (MEPA) do podziału wartości wskaźnika technicznego oraz codziennych wahań cen na wartości językowych, na podstawie charakterystyki rozkładu danych;
  - c) wykorzystanie algorytmu RST w celu wyodrębnienia reguł językowych z językowego zestawu danych wskaźników technicznych;
  - d) wykorzystanie algorytmów genetycznych (GA) do udoskonalenia wyodrębnionych reguł w celu uzyskania lepszej dokładności prognozowania i zwrotu z inwestycji w akcje.

Skuteczność proponowanego modelu jest weryfikowana dla dwóch rodzajów oceny wydajności, dokładności i zwrotu z inwestycji w akcje, przy użyciu

w ciągu sześciu lat z TAIEX (indeks Taiwan Stock Exchange Capitalization Weighted Stock Index)) jako zbioru danych eksperymentalnych. Wyniki badań pokazują, że proponowany model jest lepszy od obu wymienionych modeli prognostycznych (RST i GA) w odniesieniu do dokładności, a oceny zwrotu wykazały, że zyski wytworzone przez proponowany model są wyższe niż trzech wymienionych modeli (Buy-and-Hold, RST i GA).

Inne podejście zaprezentowali Kim i Han, którzy zaproponowali wykorzystanie algorytmów genetycznych w celu definicji funkcji dyskretyzacji i określania wag połączeń dla sztucznych sieci neuronowych (SSN) do przewidywania kształtowania indeksu cen akcji (Kim i Han, 2000).

Modele sztucznej inteligencji, które znalazły możliwości wykorzystania dzięki przełożeniu ludzkiego rozumowania do świata rozwiązań informatycznych za pomocą eksperymentów dla różnych modeli w wielu dziedzinach, w tym przewidywań finansowych szeregów czasowych. Zakrojone na szeroką skalę badania zostały wykorzystane w wielu zastosowaniach finansowych z wykorzystaniem modeli sztucznej inteligencji. Ponieważ inwestycje giełdowe są jedną z podstawowych przejawów działalności inwestycyjnej, brak dokładnych informacji i kompleksowej wiedzy powoduje pewne straty w procesie inwestowania. Stąd, tworzenie prognozy na rynku akcji było zawsze przedmiotem zainteresowania większości inwestorów i profesjonalnych analityków. Prognozowanie zachowania rynku akcji jest dużym wyzwaniem, ponieważ niepewność zawsze jest widoczna jako element zmiany na rynku. Praca (Asadi, Hadavandi, Mehmanpazir, Masoud Nakhostin, 2012) proponuje hybrydowy inteligentny model przewidywania kursu indeksów giełdowych. Model proponowany przez S. Asadi, E. Hadavandi, F. Mehmanpazir, M. Masoud Nakhostin jest połączeniem metod preprocesora danych, algorytmów genetycznych i algorytmu Levenberga Marquardt (LM) uczenia sieci neuronowych. Proponowane podejście zakłada zmianę pierwotnych wag sieci neuronowych poprzez ich strojenie z użyciem algorytmu LM przez algorytm genetyczny. Używane tu są również metody wstępnego przetwarzania danych, takich jak przekształcenia i wybór zmiennych wejściowych dla poprawy dokładności modelu. Skuteczność proponowanej metody jest testowana przez zastosowanie jej do przewidywania pewnych wskaźników giełdowych znanych z literatury. Wyniki pokazują, że proponowane podejście jest w stanie poradzić sobie z wahaniami wskaźników i indeksów giełdowych, a także daje dobrą dokładność przewidywania. Tak więc może on być stosowany do modelowania

skomplikowanych zależności między wejściami i wyjściami lub do wyszukiwania wzorców w danych podczas tworzenia prognoz finansowych.

Podobnie Chang, Chen, Chien koncentrują się na danych giełdowych z wieloma wskaźnikami analizy technicznej i problemem klasyfikacji jest dla nich znalezienie sygnałów kupna i sprzedaży na podstawie wskaźników analizy technicznej (Chang Chien, Chen, 2010). Proponują GA oparty na budowie klasyfikatora asocjacyjnego, który może odkryć reguły obrotu giełdowego bazując na tych wskaźnikach. Wyniki przeprowadzonego przez Y.-W. Chang Chien, T.-L. Chen doświadczenia wykazały, że proponowane podejście jest skuteczną techniką klasyfikacji z wysoką dokładnością przewidywania.

Powszechnie wiadomo, że odpowiednio dobrany portfel inwestycyjny jest ważny dla zabezpieczenia ryzyka inwestycji na rynku akcji. Wybór oznacza odpowiednią selekcję wybranej grupy walorów spośród wszystkich dostępnych. W swoich badaniach Y. Orito, H. Yamamoto, G. Yamazaki wyszli z założenia, że inwestujemy w liczbę  $c$  akcji każdej wybranej firmy (Orito, Yamamoto, Yamazaki, 2003). W wykonanym badaniu przyjęli jako istotną wartość całkowitą stopę zwrotu z grupy  $n$  spółek, z uwzględnieniem rosnącej wartości indeksu cen akcji na rynku. Y. Orito, H. Yamamoto, G. Yamazaki przyjęli współczynnik determinacji (CDP) jako miarę oceny dopasowania między całkowitym zwrotem z inwestycji w kontekście rosnących cen na rynku akcji. Głównym celem ich eksperymentu było zaproponowanie prostego sposobu wyboru. Ich metoda składa się z dwóch etapów. Pierwszym z nich jest, aby wybrać  $N$  firm z rynku zgodnie z podejściem heurystycznym. Drugim jest budowa grupy spółek  $n$ , nazwijmy je  $I_{nN}$ , stosując algorytmy genetyczne dla listy  $N$  firm. Metoda została zastosowana do 1. i 2. Sekcji Giełdy w Tokio. Wyniki pokazują: metoda daje bliskie optymalne rozwiązanie dla przypadku wyboru  $n$  z firm obecnych na rynku. W badaniach pokazano, że możliwe jest skonstruowanie odpowiedniej grupy spółek  $I_{nN}$ , nawet przy małej liczbie  $N$  wszystkich spółek oraz małej liczbie  $n$  wyselekcjonowanych spółek w do portfela. Metoda działa szczególnie dobrze, gdy rosną wartości indeksu cen akcji w badanym okresie.

Z kolei praca Laury Nuñez-Letamendia bada problem zmian w konstrukcji algorytmu genetycznego (GA), które mają wpływ na wyniki uzyskane w rzeczywistych zastosowaniach. W badaniu tym, skoncentrowano się na zastosowaniu GA do strojenia technicznych aspektów handlu na rynkach finansowych. Wstępna teza jest taka, że GA jest solidną metodą w odniesieniu do zmian w projekcie systemu analizy technicznej danych giełdowych (Nuñez-Letamendia, 2007). Optymaliz-



zacja systemów analizy technicznych jest odpowiednim obszarem zastosowania metod heurystycznych czego przykładem są GA. Można zauważyć, że złożoność problemu rośnie wykładniczo, wraz z dodaniem kolejnych wskaźników do systemu analizy technicznej. Równocześnie wraz ze wzrostem złożoności kluczowym zagadnieniem jest czas odpowiedzi systemu, który jest niezbędny przy jego wykorzystaniu w czasie rzeczywistym. Zdaniem Nuñez-Letamendia do tej pory, większość aplikacji GA w obszarze wykorzystania w systemach analizy technicznej lekceważyło kwestię możliwych konsekwencji zależności otrzymywanych wyników od konstrukcji GA. Wykonany przez nią eksperyment pokazał, że nie można odrzucić hipotezy, która mówi że implementacja konstrukcji GA stanowi solidną podstawę systemu handlu papierami wartościowymi w oparciu o analizę techniczną. W jej pracy algorytm genetyczny jest używany do strojenia systemu analizy technicznej obrotu akcjami na giełdzie w Madrycie, w kontekście skuteczności wyników działania odpowiednio zaprojektowanego GA. Autorka wykorzystuje meta-algorytm do strojenia parametrów działania GA, który ma za zadanie odkrywanie reguł wynikających z przetwarzania wskaźników analizy technicznej. Podobne podejście już z innego obszaru jest widoczne w pracy G. Wojarnika (Wojarnika, 2009). Eksperyment pokazał, że strojenie GA nie jest zadaniem prostym, a jego rezultaty nie są jednoznaczne, dlatego warto podjąć dalsze wysiłki w kierunku poszukiwań zmierzających do badania parametrów działania GA w obszarze giełdy papierów wartościowych. Niektórzy autorzy (I.C. Yeh, C.H. Lien, Y.C. Tsai) zauważyli ignorowanie tzw. problemu przecuczenia (*over-learning*) na poziomie modelu systemu obrotu akcjami giełdowymi, co prowadzi do niskiej wydajności takiego systemu wspomagania decyzji w obszarze obrotu akcjami opartego o metody obliczeń ewolucyjnych. W swojej pracy przedstawili nowe, ewolucyjne podejście do oceny zdolności generalizacji na poziomie modelu (I.C. Yeh, C.H. Lien, Y.C. Tsai, 2011). Badanie to wykorzystuje podejście ewolucyjne do generowania parametrów działania systemu wspomagania decyzji opartego o sieci neuronowe. Z kolei inni autorzy (Y. Hua, B. Feng, X. Zhang, E.W.T. Ngai, M. Liu) proponują hybrydowy (łączy badanie długoterminowe i krótkoterminowe tendencji na rynku papierów wartościowych) algorytm ewolucyjny (eTrend), który łączy strategię inwestycyjną z rozszerzonym systemem klasyfikacyjnym (XCS). W swojej pracy zaproponowali algorytm eTrend, który ma dwie podstawowe zalety: połączenie strategii inwestycyjnych na rynku akcji z metodami uczenia wykorzystującymi podejście ewolucyjne, które może znacznie poprawić wydajność obliczeń i możliwości

praktycznego wykorzystania (Hua, Feng, Zhang, Ngai, Liu, 2015). Drugą zaletą jest zdolność systemu klasyfikacyjnego do automatycznego dostosowania do aktualnego kierunku na danym rynku oraz zdolność do odkrywania zrozumiałych reguł obrotu akcjami przydatnych do dalszych analiz, które mogą uniknąć irracjonalnych zachowań inwestora. Aby ocenić skuteczność algorytmu ewolucyjnego, eksperyment badawczy przeprowadzany został przy użyciu zestawu dziennych danych obrotu trzech głównych indeksów na Szanghajszej Giełdzie Papierów Wartościowych.

Wyniki eksperymentu wykazały, że opracowany przez autorów algorytm ewolucyjny przewyższa strategię kup i trzymaj o wysokiej wartości wskaźnika Sortino w kosztach transakcji (Sortino, Price, 1994). Wydajność tego algorytmu przewyższa wydajność metody drzewa decyzyjnego oraz modeli giełdowych opartych o sieci neuronowe. Równocześnie autorzy podkreślają, że znajdowane rozwiązania są suboptymalne, co oczywiście wynika z właściwości algorytmów genetycznych.

Kolejnym przykładem jest wykorzystanie GA w zastosowaniach giełdowych praca, w ramach której jej autorzy zaproponowali badanie skuteczności hybrydowego podejścia do badania właściwości serii czasowych za pomocą sieci neuronowych (Kim, Shin, 2007). Sieci neuronowe zostały połączone z algorytmem genetycznym do odkrywania tymczasowych wzorców w zadaniach przewidywania zachowania rynków giełdowych. H.J. Kim, K.S. Shin wykazali wysoką zasadność wykorzystania GA w takim hybrydowym podejściu.

## Podsumowanie

Jak widać dzięki przytoczonym przykładom zastosowanie algorytmów genetycznych, czy też szerzej metod ewolucyjnych ma miejsce w różnych aspektach analizy danych giełdowych. Można tu mówić o kilku prawidłowościach, przede wszystkim algorytmy genetyczne wykorzystywane są najczęściej jako składnik szerszych metodyk implementowanych w systemach analizy giełdowej. Dodatkowo należy zauważyć, że dane do tych metod obejmują zestawy danych wskaźników analizy technicznej, które stanowią zmienne niezależne, od których najczęściej zależy zachowanie kursu danego waloru.

W związku z powyższym w ocenie autora warto podejmować wysiłki zmierzające do wykorzystania ewolucyjnych metod analizy danych giełdowych czy to

w celu odkrywania czynników wpływających na zachowanie kursu, czy to w celu prognozowania zachowania kursu akcji. Dlatego w dalszych swoich badaniach autor planuje skoncentrować się na próbach wykorzystania opracowanego przez siebie ewolucyjnego systemu analizy danych (Wojarnik, 2013) do odkrywania kombinacji wskaźników analizy technicznych, które stoją za późniejszym wzrostem (ale również spadkiem) kursu akcji spółek giełdowych. Znajomość tych kombinacji w dalszej kolejności pomoże w kształtowaniu portfela akcji wg preferencji inwestora.

## Bibliografia

- Asadi S., Hadavandi E., Mehmanpazir F., Masoud Nakhostin M. (2012), *Hybridization of evolutionary Levenberg–Marquardt neural networks and data pre-processing for stock market prediction*, „Knowledge-Based Systems”, no. 35, s. 245–258.
- Cheng C.H., Chen T.L., Ying Wei L. (2010), *A hybrid model based on rough sets theory and genetic algorithms for stock price forecasting*, „Information Sciences”, no. 180, s. 1610–1629.
- Chang Chien Y.W., Chen Y.L. (2010), *Mining associative classification rules with stock trading data-A GA-based method*, „Knowledge-Based System”, no. 23, s. 605–614.
- Hua Y., Feng B., Zhang X., Ngai E.W.T., Liu M. (2015), *Stock trading rule discovery with an evolutionary trend following model*, „Expert Systems with Applications”, no. 42, s. 212–222.
- Kim K., Han I. (2000), *Genetic algorithms approach to feature discretization in artificial neural networks for prediction of stock index*, „Expert System with Application”, no. 19, s. 125–132.
- Kim H.J., Shin K.S. (2007), *A hybrid approach based on neural networks and genetic algorithms for detecting temporal patterns in stock markets*, „Applied Soft Computing”, no. 7, s. 569–576.
- Nuñez-Letamendia L. (2007), *Fitting the control parameters of a genetic algorithm: An application to technical trading systems design*, „European Journal of Operational Research”, no. 179, s. 847–868.
- Orito Y., Yamamoto H., Yamazaki G. (2003), *Index fund selections with genetic algorithms and heuristic classifications*, „Computers & Industrial Engineering”, no. 45, s. 97–109.
- Sortino F.A., Price L.N. (1994), *Performance Measurement in a Downside Risk Framework*, „The Journal of Investing”, vol. 3, no. 3, s. 59–64.

- Wojarnik G. (2013), *Ewolucyjny system analizy danych w warunkach braku metod zindywidualizowanych (rozprawa habilitacyjna)*, Uniwersytet Szczeciński, Szczecin.
- Wojarnik G. (2009), *The searching procedure for parameters control working of genetic algorithm*, „Polish Journal of Environmental Studies”, vol. 18, no. 3B, s. 398–402.
- Yeh I.C., Lien C.H., Tsai Y.C. (2011), *Evaluation approach to stock trading system using evolutionary computation*, „Expert Systems with Applications”, no. 38, s. 794–803.

## EVOLUTIONARY METHODS FOR THE ANALYSIS OF CHANGES IN PRICE OF COMPANY STOCK EXCHANGE

### Summary

Evolutionary methods are one of the paths of development of artificial intelligence, which is drawing from the theory of natural selection allows you to solve complex problems, that are difficult to solve using traditional methods econometric, statistical or operations research.

One of the basic evolutionary methods are genetic algorithms that are repeatedly used to solve various problems associated with investing in the stock market. Therefore the aim of this article is to review the experience associated with the use of genetic algorithms in the analysis of the share price of listed and to present examples of achievements in this field.

Simultaneously this article can be described as an attempt to present a class of problems in the area of the stock market that are most suitable for use evolutionary methods with particular emphasis on genetic algorithms.

*Translated by Grzegorz Wojarnik*

**Keywords:** genetic algorithms, stock exchange, technical analysis