

JANUSZ MORAJDA

# O użyteczności sieci neuronowych i algorytmów genetycznych w realizacji inwestycyjnych systemów decyzyjnych

## 1. Wprowadzenie

W działalności każdego przedsiębiorstwa lub instytucji finansowej niezwykle istotne jest efektywne zarządzanie finansami, obejmujące m.in. dokonywanie inwestycji w określone instrumenty finansowe. Do podstawowych instrumentów, stanowiących przedmiot tych inwestycji, zaliczyć można papiery wartościowe (np. akcje, obligacje, bony skarbowe). Bardzo ważnym elementem działalności inwestycyjnej staje się zatem właściwe zarządzanie portfelem inwestycyjnym, tj. zestawem posiadanych papierów wartościowych, a często także zestawem instrumentów pochodnych (takich, jak np. opcje czy kontrakty terminowe).

Metody konstrukcji i zarządzania portfelem inwestycyjnym zależą w głównej mierze od przyjętych celów i warunków działalności inwestycyjnej, a te z kolei są zdeterminowane przez strategiczne cele oraz preferencje inwestora. Niewątpliwie jednak metody te, aby były dostatecznie efektywne, powinny być oparte na szeroko pojętej, systematycznej analizie rynku finansowego oraz jego instrumentów, realizowanej przy wykorzystaniu najlepszych dostępnych narzędzi. Wynika stąd potrzeba stałego rozwoju i doskonalenia (a także oceny i weryfikacji) narzędzi dla takiej analizy, służących m.in. do generowania prognoz i/lub do wspomaganie decyzji.

## 2. Klasyczne metody wykorzystywane w działalności inwestycyjnej

Naukowe teorie dotyczące inwestowania w papiery wartościowe wywodzą się głównie z połączenia statystyki oraz nauki o finansach. Stanowią one podstawy podejmowania decyzji inwestycyjnych w warunkach niepewności i ryzyka, a więc

---

\* Dr inż. Janusz Morajda jest zatrudniony na stanowisku adiunkta w Katedrze Informatyki i Metod Ilościowych Małopolskiej Wyższej Szkoły Ekonomicznej w Tarnowie; pełni funkcję jej kierownika; Autor jest również pracownikiem Akademii Ekonomicznej w Krakowie.

w sytuacji stale panującej na rynkach finansowych. Teorie te są również bazą dla wielu stosowanych obecnie w praktyce strategii inwestycyjnych. Najbardziej znaczące osiągnięcia w tej dziedzinie, mające decydujący wpływ na rozwój nauki o inwestowaniu oraz praktycznych metodologii analizy instrumentów finansowych i budowy portfela inwestycyjnego, zostały poniżej skrótowo wymienione<sup>1</sup>.

**Teoria portfela** określa metody tworzenia tzw. portfeli efektywnych, tj. optymalnych z punktu widzenia maksymalizacji zysku i minimalizacji ryzyka, oraz portfela rynkowego uwzględniającego też instrumenty pozbawione ryzyka. Teoria ta jest oparta na analizie stóp zysku i ryzyka (rozumianego jako odchylenie standardowe stóp zysku), oraz współczynników korelacji papierów wartościowych. Podstawy tej teorii stworzył Markowitz (1952). Uproszczoną metodę konstrukcji portfela zaproponował Sharpe (1963). Kolejnym ważnym uzupełnieniem tej teorii był opracowany przez Sharpe'a, Lintnera i Mossina model równowagi rynku papierów wartościowych CAPM (*Capital Asset Pricing Model*). Metody konstrukcji portfela papierów wartościowych zostały omówione i rozwinięte w dość bogatej literaturze (zob. np. Bodie et al., 1993; Jajuga & Jajuga, 1996; Haugen, 1996) i stanowią podstawę powszechnie stosowanej w praktyce tzw. analizy portfelowej.

**Analiza papierów wartościowych** (*security analysis*) stanowi metodologię określania wartości papierów wartościowych (głównie akcji) w oparciu o prognozy przyszłych dywidend i zysków danej firmy. Obejmuje szeroko pojętą analizę wskaźników makroekonomicznych i branżowych<sup>2</sup>, analizę sprawozdań finansowych i wybranych wskaźników finansowych dla danej spółki, oraz wykorzystanie określonych modeli wyceny akcji, jak np. model zdyskontowanych dywidend (*dividend discount model*) w powiązaniu z określonymi modelami wzrostu dywidendy<sup>3</sup>. Działalność ta jest podstawą tzw. analizy fundamentalnej, której wynikiem może być wyszukanie papierów niedoszacowanych (dla których wartość rynkowa jest niższa od wartości otrzymanej wyceny) oraz analogicznie papierów przeszacowanych, i w konsekwencji podjęcie odpowiednich decyzji inwestycyjnych.

**Analiza pochodnych papierów wartościowych** obejmuje zagadnienia wyceny instrumentów pochodnych (derywatów), przede wszystkim opcji. Powszechnie stosowanym modelem służącym do określania wartości tych papierów jest model Blacka-Scholesa.

Duże znaczenie w problematyce analizy rynków finansowych i wykorzystania dostępnej informacji do podejmowania decyzji inwestycyjnych wniosła **hipoteza efektywności rynków finansowych** (*Efficient Market Hypothesis* — EMH) (zob. Fama, 1970). Opierając się na pewnych ogólnych założeniach stwierdza ona, iż

<sup>1</sup> Wyczerpujący opis problematyki inwestycji finansowych na rynkach kapitałowych można znaleźć np. w (Bodie, Kane, Marcus, 1993; Haugen, 1996).

<sup>2</sup> Zyski firmy zależą w dużej mierze od otoczenia ekonomicznego, w którym ona funkcjonuje.

<sup>3</sup> Por. (Bodie et al., 1993; Jajuga & Jajuga, 1996).

cała dostępna informacja o rynku jest już odzwierciedlona w aktualnych cenach i w związku z tym przyszłe ruchy cen akcji są nieprzewidywalne i podlegają one jedynie przypadkowym zmianom (*random walk*). W zależności od kontekstu, w jakim rozumiemy pojęcie informacji o rynku, wyróżniamy takie pojęcia efektywności rynków, jak:

— słaba efektywność (*weak-form efficiency*) — dotyczy rynków, na których informacja o przeszłych ruchach cen i wolumenie obrotu jest już uwzględniona w aktualnym poziomie cen, informacje te nie przyniosą zatem ponadprzeciętnych zysków;

— średnia efektywność (*semistrong-form efficiency*) — jest pojęciem szerszym, zakładającym, że cała publicznie dostępna informacja o rynku i o perspektywach działalności poszczególnych firm znalazła już odzwierciedlenie w cenach akcji;

— mocna efektywność (*strong-form efficiency*) — wiąże się z hipotezą, że cała informacja, również aktualnie niedostępna publicznie, jest już odzwierciedlona w aktualnych cenach akcji, a więc nawet wykorzystanie informacji poufnych (*insider trading*) nie przyniesie ponadprzeciętnych zysków.

Fakt braku efektywności danego rynku nawet w słabej postaci, który może być potwierdzony odpowiednimi badaniami statystycznymi, lub też zakwestionowanie pewnych założeń, na których oparta jest hipoteza efektywności rynków, i tym samym wniosków z tej teorii płynących, stanowić mogą przesłanki do wykorzystania metod analizy technicznej w celu wspomagania decyzji inwestycyjnych<sup>4</sup>. Analiza techniczna zajmuje się próbą prognozowania przyszłych ruchów cen akcji na podstawie dotychczasowych przebiegów ich kursów oraz wolumenu obrotów. Jej aspektami są: analiza trendów, średnich ruchomych, wielkości obrotów, formacji rysujących się na wykresach cenowych, oraz wskaźników technicznych. Opiera się nie tyle na naukowych podstawach matematycznych, co na różnych hipotezach wysnutych przez analityków na podstawie wieloletnich obserwacji rynków finansowych (należą do nich np. teoria Dowa, teoria Elliotta, i szereg innych).

### 3. Aktywne zarządzanie portfelem inwestycyjnym

Dwa podstawowe zagadnienia związane z działalnością inwestycyjną opartą na teorii portfela to analiza poszczególnych papierów wartościowych pod kątem określenia ich oczekiwanych stóp zysku, ryzyka i korelacji pomiędzy nimi, oraz konstruowanie portfela w oparciu o wyniki tej analizy i odpowiednie podstawy teoretyczne. Przy szacowaniu oczekiwanej stopy zysku często stosowaną metodą jest przyjęcie średniej stopy zysku z pewnego okresu z przeszłości, a zatem przy-

<sup>4</sup> Analogiczne rozumowanie z uwzględnieniem średniej efektywności rynku można przeprowadzić w celu uzasadnienia możliwości wykorzystania analizy fundamentalnej.

jęcie założenia, że zysk z danego papieru oraz związane z nim ryzyko (a także korelacja z innymi papierami) będą się kształtowały, podobnie jak w przeszłości. W istocie teoria EMH wyklucza przydatność prognoz rynkowych, przyjmując, że wszelkie informacje mogące być podstawą tego typu prognoz zostały już odzwierciedlone w bieżących cenach. Przy takich założeniach celowe jest przyjęcie pasywnej metody zarządzania portfelem inwestycyjnym, polegającej na konstrukcji zdywersyfikowanego portfela w oparciu o podstawy teoretyczne, a następnie na jego konsekwentnym trzymaniu z możliwością okresowych korekt w przypadku zmian charakterystyk poszczególnych jego składników.

Bardziej wnikliwe podejście do zagadnienia zarządzania portfelem inwestycyjnym może wyłonić pewne przesłanki, stanowiące uzasadnienie dla prób dokonywania prognoz przyszłego zachowania się rynku oraz poszczególnych jego instrumentów. W teorii EMH można dopatrzeć się bowiem pewnych wad, które mogą spowodować jej zakwestionowanie przez część inwestorów (podane w wątpliwość może być m.in. jej istotne założenie przyjmujące pełną racjonalność zachowań uczestników rynku i nie uwzględniające tym samym ewidentnie występującego czynnika psychologicznego). Innym aspektem jest potwierdzony przez szereg badań fakt, iż nawet rynki rozwinięte (jak np. rynek w USA) charakteryzują się występowaniem pewnych zjawisk zaprzeczających pełnej efektywności tych rynków nawet w słabej postaci; tego typu zjawiska, jak np. efekt stycznia, efekt końca tygodnia, czy też efekt małych firm, mogą być znacznie bardziej wyraźne na słabiej rozwiniętych rynkach.

Innego typu postulaty, stojące w sprzeczności do hipotezy rynków efektywnych (EMH), wywodzą się z nabierającej coraz większej popularności teorii chaosu deterministycznego. W jej ujęciu rynki kapitałowe stanowią nieliniowe systemy dynamiczne, posiadające naturę fraktalną (Peters, 1997), przy czym charakteryzują się one występowaniem tzw. efektów długotrwałej pamięci<sup>5</sup>. Teorię tę potwierdzają liczne badania finansowych szeregów czasowych, wykorzystujące tzw. analizę R/S (statystykę Hursta).

Przedstawione wyżej fakty mogą uzasadniać celowość wykorzystywania prognoz zachowania się rynku i/lub prognoz stóp zysku poszczególnych papierów wartościowych, a także analiz poszczególnych papierów pod kątem ich niedoszacowania lub przeszacowania. Tego typu prognozy, generowane np. na podstawie wskazań analizy technicznej, analizy fundamentalnej, lub odpowiednio skonstruowanych modeli statystycznych, mogą być szczególnie przydatne na rynkach instrumentów o dużym stopniu ryzyka, jak np. rynek akcji i ich pochodnych. Związane z tymi prognozami strategie inwestycyjne zakładać mogą kupno lub sprzedaż całego portfela papierów wartościowych (ew. relokację środków finansowych w inny typ papierów, np. sprzedaż akcji i kupno obligacji) w przypadku

<sup>5</sup> Efekty te są związane z wpływem poprzednich wartości szeregu czasowego z pewnego (dość długiego) okresu przeszłości na bieżące jego realizacje i pojawiają się w tzw. persystentnych szeregach czasowych, charakteryzujących się występowaniem wyraźnych trendów.

wykorzystywania prognoz rynku (ang. *market timing*), lub też kupno walorów niedoszacowanych i sprzedaż przeszacowanych w przypadku wykorzystywania ocen poszczególnych papierów (ang. *security selection*). Działalność taką, polegającą na dokonywaniu permanentnych korekt składu portfela na podstawie bieżących prognoz i analiz, określa się mianem **aktywnego zarządzania portfelem** (ang. *active portfolio management*), zob. np. (Bodie et al., 1993).

Zasadniczym elementem warunkującym efektywność aktywnych metod zarządzania portfelem inwestycyjnym jest źródło możliwie wiarygodnych i precyzyjnych prognoz rynkowych i/lub właściwych sygnałów kupna lub sprzedaży poszczególnych walorów lub grup walorów, tylko bowiem wtedy strategia aktywna może okazać się lepsza od pasywnej. Szereg badań statystycznych potwierdza w pewnych przypadkach możliwość uzyskiwania efektywnych prognoz i tym samym skuteczność aktywnych strategii inwestycyjnych (zob. np. Taylor & Yoder, 1994). Powstaje zatem dylemat skonstruowania odpowiednich narzędzi służących do generowania jak najlepszych prognoz lub sygnałów kupna/sprzedaży. Dylemat ten stanowi niewątpliwą inspirację do prowadzenia badań naukowych nad rozwojem instrumentów oraz doskonaleniem technik służących do predykcji rynków finansowych i generowania sygnałów transakcyjnych, przy wykorzystaniu m.in. najnowszych osiągnięć informatyki, w tym metod sztucznej inteligencji.

#### 4. Systemy wspomaganie decyzji inwestycyjnych

Stałym elementem stosowania aktywnych strategii inwestycyjnych jest ciągła analiza informacji napływających z rynku, generowanie bieżących prognoz w oparciu o te informacje i w konsekwencji podejmowanie odpowiednich decyzji inwestycyjnych w oparciu o uzyskane prognozy. Precyzyjne analizy dużych ilości informacji w połączeniu z koniecznością podejmowania szybkich decyzji inwestycyjnych, pozbawionych dodatkowo czynnika emocjonalnego, mogą stanowić trudność nawet dla doświadczonych analityków. Fakt ten stanowi przesłankę do wykorzystania do tego celu komputerowych systemów wspomaganie decyzji inwestycyjnych (systemów transakcyjnych, ang. *trading systems*), których zadaniem jest automatyczne generowanie decyzji dotyczących kupna lub sprzedaży poszczególnych walorów notowanych na rynku i realizacja tym samym określonej aktywnej strategii inwestycyjnej zdeterminowanej przez konstrukcję systemu. Jakkolwiek stosowanie tego typu systemów nie jest warunkiem koniecznym efektywności aktywnych metod zarządzania portfelem inwestycyjnym, może jednak istotnie poprawić skuteczność podejmowanych decyzji.

#### 4.1. Problemy modelowania rynków finansowych

Elementami systemu decyzyjnego mogą być odpowiednie modele reprezentujące wiedzę na temat danego rynku (systemu rzeczywistego) zawartą w postaci równań matematycznych lub reguł logicznych. Konstrukcja modeli (modelowanie), jako powszechnie stosowana metoda opisu rzeczywistych systemów, sprowadza się do stworzenia takiego typu równań lub reguł, które zdolne są opisać system możliwie wiernie z punktu widzenia realizacji założonego celu. Model nie musi zatem odzwierciedlać wszystkich zależności i zjawisk zachodzących wewnątrz rzeczywistego systemu, a jedynie uwzględniać te zmienne wejściowe, zmienne stanu i zmienne wyjściowe oraz powiązania między nimi, które mają istotny wpływ na osiągnięcie przyjętego celu. W szczególności celem takim może być uzyskiwanie wiarygodnych prognoz dynamiki cen akcji lub wybranych wskaźników rynkowych, albo generowanie decyzji kupna lub sprzedaży dla poszczególnych walorów notowanych na rynku. Zadania takie mogą realizować wybrane klasy modeli ekonometrycznych (stanowiące podstawę konstrukcji odpowiedniego predyktora), albo odpowiednie modele decyzyjne. Elementy generujące prognozy lub decyzje niekoniecznie muszą być zbudowane w postaci równań matematycznych, mogą to być odpowiednio konstruowane systemy ekspertowe<sup>6</sup>, wykorzystujące przechowywaną w formie reguł logicznych wiedzę o danym rynku, pochodzącą od ekspertów z zakresu inwestowania. Niekiedy systemy ekspertowe mogą być zintegrowane z klasyczną procedurą tworzenia portfela papierów wartościowych.

Rozważając problem stworzenia odpowiednich modeli mogących wchodzić w skład systemów decyzyjnych, natrafiamy na bardzo istotną barierę charakterystyczną dla wszystkich rynków finansowych. Rynki te są bowiem niezwykle skomplikowanymi systemami dynamicznymi, charakteryzującymi się m.in.:

— występowaniem olbrzymiej liczby czynników (zmiennych egzogenicznych), oraz zmiennych stanu, mających wpływ na odpowiedź systemu (zachowanie się rynku); zmienne te są często powiązane relacjami trudnymi lub wręcz niemożliwymi do zidentyfikowania,

— występowaniem znacznych szumów i zakłóceń o trudnych do zidentyfikowania parametrach (szumy te mają często podłoże psychologiczne i emocjonalne związane z zachowaniem się inwestorów).

Wymienione czynniki sprawiają, że budowa efektywnych predyktorów lub modeli decyzyjnych (i w konsekwencji całego systemu decyzyjnego) w tradycyjny sposób, a więc na podstawie znajomości praw rządzących rynkiem lub poprzez identyfikację systemu na podstawie obserwacji jego wejść i wyjść, może okazać się zadaniem niezwykle trudnym. Dodatkowy istotny problem stanowi tu trudno

<sup>6</sup> W ogólnym pojęciu system ekspertowy zawiera zestaw wnioskujących reguł logicznych, stworzonych przez eksperta z danej dziedziny wiedzy, generujących odpowiednie prognozy, diagnozy lub decyzje na podstawie dostarczonych informacji wejściowych.



przewidywalna zmienność systemu rzeczywistego w czasie, co powoduje konieczność budowy modelu niestacjonarnego lub ciągłej adaptacji przynajmniej parametrów modelu, a być może także jego struktury.

#### 4.2. Wykorzystanie narzędzi alternatywnych

##### — przesłanki metodologiczne

W świetle omówionych problemów modelowania rynków finansowych, w procesie konstrukcji systemów decyzyjnych lub ich elementów generujących prognozy albo decyzje, celowe wydaje się wykorzystanie pewnych narzędzi alternatywnych w stosunku do klasycznych metod budowy modeli. Narzędzia te, uwzględniając fakt stosunkowo niskiego poziomu wiedzy apriorycznej o systemie rzeczywistym, powinny spełniać następujące postulaty:

— pozyskiwać dodatkową, przydatną do celów generowania prognoz i/lub decyzji wiedzę — podczas etapu konstrukcji elementów predykcyjnych lub decyzyjnych,

— selekcjonować wiedzę istotną dla założonych celów, przy jednoczesnej eliminacji czynników nieistotnych,

— wykorzystywać metody nieliniowe i nieparametryczne, które ani nie zakładają *a priori* postaci funkcji tworzącej model (zależności pomiędzy wejściem i wyjściem), ani nie czynią założeń dotyczących postaci i parametrów rozkładów zmiennych losowych,

— charakteryzować się odpornością na występujące w rzeczywistym systemie szumy.

W celu realizacji powyższych postulatów obiecujące może okazać się wykorzystanie do budowy modułów systemu decyzyjnego pewnych metod sztucznej inteligencji (ang. *artificial intelligence*), takich jak sztuczne sieci neuronowe i algorytmy genetyczne. Techniki te omówiono szerzej w sekcji 5.

#### 4.3. Wykorzystanie narzędzi alternatywnych — przesłanki informatyczne

Obecnie większość programów komputerowych wykorzystywanych w dziedzinie zarządzania portfelem inwestycyjnym realizuje przetwarzanie i analizę napływających z rynku danych na postać wynikową posiadającą najczęściej formę wykresów lub tabel. Prezentowane w takiej formie informacje stanowią niewątpliwie istotną pomoc dla analityka posługującego się analizą techniczną, fundamentalną lub portfelową i ułatwiają podejmowanie finalnych decyzji. Jednak w dobie gwałtownego rozwoju informatyki i technologii związanej z produkcją komputerów oraz powszechnej dostępności tych narzędzi, powstają coraz większe i stale rosnące rezerwy mocy obliczeniowej komputerów, będących w dyspozycji inwes-

torów operujących na rynkach finansowych. Fakt ten stanowi inspirację do wykorzystania tych rezerw do realizacji dalszych etapów przetwarzania napływających z rynku informacji, a więc do tworzenia i zastosowania komputerowych implementacji coraz bardziej zaawansowanych systemów decyzyjnych. Postęp w dziedzinie informatyki stwarza więc coraz szersze pole do budowy nowych technik wspomagania decyzji inwestycyjnych w oparciu o komputerową analizę informacji daleko wykraczającą poza formę prostego przetwarzania i zwykłej prezentacji wykresów i wskaźników, a także do prowadzenia badań nad przydatnością tych technik w procesie zarządzania portfelem.

Powyższe czynniki szczególnie sprzyjają rozwojowi metod sztucznej inteligencji i ich zastosowań do konstrukcji systemów decyzyjnych. Do metod sztucznej inteligencji zaliczamy m.in. wymienione już poprzednio, obiecujące z metodologicznego punktu widzenia, sieci neuronowe i algorytmy genetyczne. Narzędzia te wymagają nieporównanie więcej mocy obliczeniowej niż klasyczne techniki wspomagania decyzji inwestycyjnych, fakt ten jednak w obecnej dobie gwałtownego rozwoju technologii komputerowych nie jest w ogóle przeszkodą, a wręcz stanowi inspirację do teoretycznych i praktycznych badań nad wykorzystaniem metod inteligentnych w inwestycyjnych systemach wspomagania decyzji.

Analizując szerzej aspekt zapotrzebowania na moc obliczeniową należy podkreślić, że zarówno sieci neuronowe, jak i algorytmy genetyczne posiadają naturalną właściwość, polegającą na zdolności do przetwarzania informacji w sposób równoległy. Cecha ta wywodzi się z biologicznych, rzeczywistych pierwowzorów tych metod. Pomimo faktu, iż większość obecnych implementacji sztucznych sieci neuronowych i algorytmów genetycznych dokonywana jest na komputerach sekwencyjnych, należy liczyć się z szybkim rozwojem komputerowych architektur równoległych, a także specjalizowanych układów elektronicznych<sup>7</sup>, umożliwiających realizację operacji przetwarzania informacji w sposób rzeczywiście równoległy. Fakt ten pozwala na bardzo znaczące przyspieszenie obliczeń związanych z wykorzystaniem metod sztucznej inteligencji, a tym samym na istotną poprawę ich efektywności w zastosowaniach praktycznych.

## 5. Sztuczne sieci neuronowe i algorytmy genetyczne jako narzędzia inwestycyjnych systemów decyzyjnych

### 5.1. Sztuczne sieci neuronowe

Sztuczne sieci neuronowe są to programy komputerowe lub moduły elektroniczne realizujące przetwarzanie informacji w sposób analogiczny do tego, jaki

<sup>7</sup> Tego typu układy (neurokomputery), realizujące sprzętową implementację sieci neuronowych są już produkowane i są też dostępne w powszechnej sprzedaży.



ma miejsce w naturalnych strukturach komórek nerwowych w mózgach organizmów żywych. Stanowią one więc pewne cybernetyczne modele biologicznych sieci neuronowych. Dokładny opis tych narzędzi można znaleźć w bogatej literaturze (zob. np. Tadeusiewicz, 1993; Haykin, 1994; Rutkowska et al., 1997; Zieliński, 2000; Morajda, 2002; Rutkowski, 2005), nie będzie on zatem przedmiotem szczegółowych rozważań w niniejszym opracowaniu.

Sztuczne sieci neuronowe (nazywane często krócej: „sieci neuronowe” i oznaczane skróttem SN) posiadają zdolność nabywania wiedzy (a następnie jej przechowywania i późniejszego wykorzystywania) na podstawie dostępnych informacji z otoczenia (np. z rynku finansowego), pochodzących z pewnego okresu przeszłości. Adaptacyjny proces gromadzenia wiedzy i wykształcania relacji pomiędzy wejściem i wyjściem nazywamy procesem uczenia, w jego trakcie struktura sieci nie podlega zmianom, natomiast modyfikowane są wartości jej parametrów (tzw. wag).

Proces uczenia sieci neuronowej realizowany jest przy wykorzystaniu odpowiedniego zbioru danych związanych z analizowanym zagadnieniem, zawartych w tzw. ciągu uczącym. Wiedza (np. o określonych zależnościach występujących na rynku finansowym) nie jest tu przekazywana sieci *a priori* (jak to ma miejsce np. w przypadku konstrukcji algorytmów lub systemów ekspertowych), ale w trakcie iteracyjnego procesu uczenia, polegającego na wielokrotnej prezentacji poszczególnych wzorców (przykładów), wchodzących w skład ciągu uczącego. W wyniku tego procesu następuje „dostrojenie” dużej liczby adaptowalnych parametrów sieci — wag połączeń pomiędzy jej poszczególnymi komórkami — w taki sposób, że sieć potrafi prawidłowo reagować na wzorce, których się „nauczyła”, oraz — co więcej — na inne wzorce, które nie występowały podczas fazy uczenia. Zwrócić należy tu uwagę na istotne podobieństwo tego procesu do uczenia się i gromadzenia doświadczeń przez człowieka, a następnie wpływu nabytej wiedzy na podejmowane decyzje.

Poprawnie skonstruowana i nauczona sieć neuronowa potrafi dawać rozsądne odpowiedzi nie tylko na sygnały wejściowe, wchodzące w skład ciągu uczącego, ale również na inne wzorce wejściowe, które nie były sieci wcześniej pokazywane (a należy zakładać, że w większości praktycznych zastosowań z takimi sygnałami sieć będzie miała do czynienia w fazie realizacji określonego zadania, np. predykcji). Właściwość ta nazywa się zdolnością do generalizacji (uogólniania) wiedzy. Sieć taka, przechowująca określoną wiedzę w postaci odpowiednio dostrojonych współczynników wag połączeń neuronowych, może być następnie wykorzystywana do generowania właściwych prognoz lub do sugerowania poprawnych reakcji na aktualne dane pochodzące z analizowanego systemu (np. rynku finansowego).

Przyjęcie nieliniowego modelu neuronu prowadzi do uzyskania nieliniowej zależności między wejściem a wyjściem dla całej sieci, a więc do skonstruowania modelu nieliniowego. Przy odpowiedniej architekturze sieci może ona zrealizo-

wać dowolne nieliniowe odwzorowanie wiążące wartości wejściowe i wyjściowe sieci<sup>8</sup>. Metodę opartą na sieciach neuronowych uznaje się również za metodę nieparametryczną w sensie braku konieczności przyjmowania *a priori* postaci funkcyjnej modelu (zob. Refenes, 1995). Cechy te mają istotne znaczenie w aspekcie konieczności modelowania zjawisk nieliniowych, występujących m.in. na rynkach finansowych. Jakkolwiek dla tego typu problemów mogą być wykorzystane inne nieliniowe techniki, to SN ze względu na łatwość implementacji i możliwość realizacji dowolnych odwzorowań wejście — wyjście mogą okazać się narzędziem najbardziej efektywnym (zob. Azoff, 1994).

Problematyka wykorzystania sieci neuronowych w zagadnieniach prognozowania dynamiki rynków finansowych i konstrukcji inwestycyjnych systemów decyzyjnych stała się przedmiotem wielu publikacji poruszających różne aspekty teoretyczne i praktyczne tych zastosowań SN, a także prezentujących przykłady efektywnych realizacji strategii inwestycyjnych opartych na prognozach lub decyzjach modeli neuronowych. Warto tu wymienić m.in. takie pozycje, jak (Azoff, 1994; Refenes, 1995; Zieliński, 2000; Morajda, 2003a; Morajda, 2003b; Morajda & Domaradzki, 2005).

## 5.2. Algorytmy genetyczne

Idea algorytmu genetycznego (AG) została zaczerpnięta z nauk przyrodniczych opisujących zjawiska doboru naturalnego i dziedziczności. Mechanizmy te, ujmując je w uproszczeniu, polegają na przetrwaniu osobników najlepiej dostosowanych w danym środowisku, podczas gdy osobniki gorzej przystosowane są eliminowane. Z kolei osobniki, które przetrwają, przekazują informację genetyczną swoim potomkom. Krzyżowanie informacji genetycznej otrzymanej od „rodziców” prowadzi do sytuacji, w której kolejne pokolenia są przeciętnie coraz lepiej dostosowane do warunków środowiska; mamy więc tu do czynienia ze swoistym procesem optymalizacji. Tego typu postępowanie może mieć miejsce nie tylko w przyrodzie, ale również w wielu podobnych systemach o analogicznym stopniu złożoności i rządzonych podobnymi prawami, a więc np. na rynkach finansowych.

Algorytmy genetyczne są w istocie metodami optymalizacji (formalnie proces ten sprowadza się do poszukiwania ekstremum przyjętej funkcji celu<sup>9</sup>), w których rolę osobników pełnią odpowiednio zakodowane potencjalne rozwiązania określonego problemu. Zbiory potencjalnych rozwiązań (osobników) stanowią tzw. populacje. Trzy podstawowe operacje, wykonywane na osobnikach (rozwiązaniach)

<sup>8</sup> Dotyczy to tylko sieci wielowarstwowych, podstawę matematyczną stanowi tu tzw. twierdzenie Kołmogorowa.

<sup>9</sup> Należy podkreślić, że algorytmy genetyczne stosowane są w zagadnieniach, w których użycie klasycznych metod optymalizacji jest niemożliwe ze względu na złożoność problemu.

z populacji to selekcja, krzyżowanie i mutacja (funkcjonują one analogicznie do naturalnych procesów genetycznych obserwowanych w przyrodzie). Gromadzenie wiedzy następuje w procesie łączenia informacji z najlepiej ocenionych poprzednich rozwiązań i jej wykorzystania do budowy następnych. Algorytmy genetyczne realizują zatem iteracyjną procedurę umożliwiającą konstrukcję i ocenę kolejnych, coraz efektywniejszych rozwiązań pośrednich (o coraz lepszych wartościach funkcji celu), zmierzającą do znalezienia rozwiązania optymalnego. Narzędzia te można więc z powodzeniem zastosować do optymalizacji parametrów systemu wspomaganego decyzji inwestycyjnych.

Szczegółowe omówienie tej metodologii i jej zastosowań można znaleźć w literaturze, np. (Goldberg, 1998; Bauer, 1994; Michalewicz, 1999; Rutkowska et al., 1997; Zieliński, 2000).

Jako istotne przykłady szerszych zastosowań algorytmów genetycznych w ekonomii i biznesie (w tym także na rynkach finansowych) warto wymienić:

- prognozowanie kursów walut,
- prognozowanie dynamiki indeksów giełdowych,
- wspomaganie decyzji dotyczących wyboru funduszu powierniczego,
- zarządzanie portfelem inwestycyjnym,
- prognozowanie rentowności przedsiębiorstw,
- poszukiwanie reguł opisujących preferencje konsumentów.

### 5.3. Wspólne cechy metod neuronowych i genetycznych

Zasadniczą wspólną cechą omówionych wyżej metod jest ich rodowód wywodzący się z biologii i obserwacji natury. Obie techniki uznawane są obecnie za jedno z najważniejszych i najbardziej dynamicznie rozwijających się metod sztucznej inteligencji. Wzrost możliwości obliczeniowych dostępnych komputerów stał się przy tym zasadniczym czynnikiem stymulującym intensywny rozwój zarówno badań naukowych, jak i zastosowań praktycznych tych metod.

Należy stwierdzić, że rozważane metody nie tylko nie wykluczają się wzajemnie, ale nawet w pewien sposób uzupełniają. Możliwe jest zatem zastosowanie rozwiązań hybrydowych, wykorzystujących oba podejścia łącznie do budowy elementów systemu decyzyjnego, jak również użycie narzędzi genetycznych jako rozszerzenia i uzupełnienia techniki neuronowej (np. w celu optymalizacji zbioru zmiennych wejściowych i struktury SN).

Zwrócenia uwagi wymagają następujące (uznawane niekiedy za negatywne) aspekty zastosowania SN i AG do budowy finansowych systemów decyzyjnych lub ich elementów:

- w przypadku zastosowania sieci neuronowych brak jest możliwości określenia *explicite* zależności między wejściem i wyjściem sieci, a tym samym poda-

nia uzasadnienia dla tych relacji; jest to wada tego narzędzia eksponowana przez niektórych badaczy i praktyków,

— na ogół jedynym sposobem oceny (weryfikacji) modelu stworzonego przy użyciu tych narzędzi jest analiza wyników jego testowania na rzeczywistych danych (nie wykorzystanych bezpośrednio do konstrukcji modelu), pochodzących z możliwie długiego okresu,

— zastosowanie powyższych narzędzi wymaga dużego nakładu obliczeń komputerowych, niezbędnych do realizacji procesu pozyskiwania wiedzy.

## 6. Podsumowanie

Omówione w opracowaniu metody sztucznej inteligencji należy niewątpliwie uznać za bardzo przydatne i obiecujące narzędzia w modelowaniu rynków finansowych, zwłaszcza w kontekście konstrukcji systemów wspomagania decyzji inwestycyjnych, wspierających działalność inwestora na tych rynkach.

Należy przy tym podkreślić, że w modelowaniu zjawisk ekonomicznych nie zawsze stosowanie tych narzędzi jest celowe. W zagadnieniach, gdzie dostępna jest obszerna aprioryczna wiedza na temat modelowanego systemu oraz relacji pomiędzy informacją wejściową a dynamiką jego zmiennych wyjściowych, istnieje na ogół możliwość skonstruowania efektywnego modelu matematycznego, ekonometrycznego lub algorytmicznego. Użyteczność sieci neuronowych i algorytmów genetycznych w konstrukcji modeli ekonomicznych nabiera istotnego znaczenia w problemach modelowania bardzo złożonych systemów, dla których taką wiedzę wprost nie dysponujemy lub gdy jest ona znikoma, ale w zamian dysponujemy dużą ilością danych (przykładów), które mogą posłużyć do uczenia sieci neuronowej lub oceny efektywności rozwiązań pośrednich (osobników) w algorytmie genetycznym. Do takich właśnie systemów należy zaliczyć rynki finansowe.

W ostatnich latach można zaobserwować intensywny rozwój badań w dziedzinach sieci neuronowych, algorytmów genetycznych, i ich zastosowań na rynkach finansowych. Posiada on odzwierciedlenie w coraz liczniejszych publikacjach na ten temat w prasie i w licznych periodykach naukowych. Publikacje te, oprócz wyników badań stanowiących wkład naukowy w rozwój metod opartych na sieciach neuronowych i algorytmach genetycznych, często zawierają również informacje o efektywnym wykorzystaniu praktycznym tych narzędzi na rynkach finansowych. Obiecujące rezultaty tych badań i implementacji stanowią dodatkową, mocną inspirację do prowadzenia analiz związanych z zastosowaniem wyżej przedstawionych metod w systemach wspomagania decyzji inwestycyjnych.

## Bibliografia

1. Azoff E.M., 1994. *Neural network time series forecasting of financial markets*. New York: Wiley. ISBN 0471943568.
2. Bauer R. 1994. *Genetic Algorithms and Investment Strategies*. New York: Wiley. ISBN 0471576794
3. Bodie Z., Kane A., Marcus A.J. 1993. *Investments*. 2<sup>nd</sup> ed. Boston: Irwin. ISBN 0256122148.
4. Fama E.F. 1970. *Efficient capital markets: A review of theory and empirical work*. „Journal of Finance” No. 25, May 1970.
5. Goldberg D. E. 1998. *Algorytmy genetyczne i ich zastosowania*. Warszawa: WNT. ISBN 83-204-2272-8.
6. Haugen R.A. 1996. *Teoria nowoczesnego inwestowania*. Warszawa: WIG Press. ISBN 83-903296-5-4.
7. Haykin S. 1994. *Neural networks. A comprehensive foundation*. New York: Macmillan College Publishing Company. ISBN 0023527617.
8. Jajuga K., Jajuga T. 1996. *Inwestycje: instrumenty finansowe, ryzyko finansowe, inżynieria finansowa*. Warszawa: Wydawnictwo Naukowe PWN. ISBN 83-01-12021-5.
9. Markowitz H.M. 1952. *Portfolio selection*. „Journal of Finance” March 1952.
10. Michalewicz Z. 1999. *Algorytmy genetyczne + struktury danych = programy ewolucyjne*. Warszawa: WNT. ISBN 83-204-2881-5.
11. Morajda J. 2002. *Czynniki efektywnego wykorzystania sieci neuronowych w procesie modelowania rynków finansowych*. Zeszyty Naukowe AE w Krakowie nr 604. Kraków.
12. Morajda J. 2003a. *Neural Networks and Their Economic Applications*. W: *Artificial Intelligence and Security in Computing Systems*. Boston — Dordrecht — London: Kluwer Academic Publishers. ISBN 1402073968.
13. Morajda J. 2003b. *Evolutionarily Developed Neural Networks for Investment Strategies Construction*. *Advances in Soft Computing*. W: *Neural Networks and Soft Computing*. Heidelberg: Physica Verlag. ISBN 3790800058.
14. Morajda J., Domaradzki R. 2005. *Application of Cluster Analysis Performed by SOM Neural Network to the Creation of Financial Transaction Strategies*. „Journal of Applied Computer Science” 2005, Volume 13, No 1. Łódź: Technical University Press.
15. Peters E. E. 1997. *Teoria chaosu a rynki kapitałowe*. Warszawa: WIG-Press. ISBN 83-87014-01-X.
16. Refenes A.P. (ed.). 1995. *Neural networks in the capital markets*. Chichester: Wiley. ISBN 0471943649.
17. Rutkowska D., Piliński M., Rutkowski L. 1997. *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. Warszawa: Wydawnictwo Naukowe PWN. ISBN 83-01-12304-4.
18. Rutkowski L. 2005. *Metody i techniki sztucznej inteligencji*. Warszawa: Wydawnictwo Naukowe PWN. ISBN 83-01-14529-3.
19. Sharpe W.F. 1963. *A simplified model for portfolio analysis*. „Management Science” 1963, No. 19.
20. Tadeusiewicz R. 1993. *Sieci neuronowe*. Warszawa: Akademicka Oficyna Wydawnicza RM. ISBN 83-85769-03-X
21. Taylor W.R.L., Yoder J.A. 1994. *Mutual fund trading activity and investor utility*. „Financial Analysts Journal” May — June 1994.
22. Zieliński J.S. (red.) 2000. *Inteligentne systemy w zarządzaniu. Teoria i praktyka*. Warszawa: Wydawnictwo Naukowe PWN. ISBN 83-01-12968-9.

## Streszczenie

W artykule omówiono podstawowe aspekty realizacji aktywnych strategii inwestycyjnych na rynkach finansowych z wykorzystaniem systemów wspomagania decyzji (systemów transakcyjnych), w kontekście klasycznych teorii zarządzania portfelem inwestycyjnym. Wskazano zasadnicze przesłanki zastosowania metod sztucznej inteligencji, takich jak sieci neuronowe i algorytmy genetyczne, do konstrukcji inwestycyjnych systemów decyzyjnych. Omówiono charakterystykę sieci neuronowych oraz algorytmów genetycznych jako efektywnych narzędzi w modelowaniu i prognozowaniu rynków finansowych.

## Słowa kluczowe

metody sztucznej inteligencji, algorytmy genetyczne, sieci neuronowe, rynki finansowe, systemy decyzyjne, zarządzanie portfelem inwestycyjnym

## Usefulness of Neural Networks and Genetic Algorithms in the Development of Investment Decision Systems

## Summary

The paper discusses basic aspects of application of active investment strategies in financial markets — in the context of classic theories of portfolio management. Such active strategies are generated with the use of decision support systems (transaction systems). The main assumptions of utilization of artificial intelligence methods, such as neural networks and genetic algorithms, in the construction of investment decision systems have been indicated. The characteristic of neural networks and genetic algorithms as effective tools in financial markets modelling and prediction has also been discussed here.

## Key words

artificial intelligence methods, genetic algorithms, neural networks, financial markets, decision support systems, portfolio management.