

Tomasz Karczyński
Edward Radościński

Politechnika Wroclawska

IMPLEMENTACJA I OCENA SYSTEMU EKSPERCKIEGO SIECI NEURONOWYCH W ANALIZIE RYNKU AKCJI

Wprowadzenie

Specyfika rynków kapitałowych, a dokładniej ich zależność od ogromnej liczby czynników, zarówno ekonomicznych, jak i psychologicznych, nieustannie zmieniających się w czasie, stwarza bardzo poważne problemy w jednoznacznej analizie [3; 5; 9; 13]. Mówiąc o metodach analiz rynków giełdowych warto wspomnieć o dwóch dominujących nurtach. Pierwszy, zwany fundamentalnym, jest oparty na modelach matematycznych. Modele te uwzględniają tylko wybrane wycinki rzeczywistości, w jakiej działają rynki kapitałowe. Kolejny nurt, zwany technicznym, jest oparty na założeniu, że rynki kapitałowe dyskontują wszelkie informacje w cenach aktywów [5]. Wadą tego nurtu jest mnogość metodyk analiz oraz niejednoznaczność w ich interpretacji. Często skłaniają one inwestorów do podejmowania pochopnych decyzji [7]. Rozwój technik komputerowych wpłynął w znaczącym stopniu na szybkość i jakość pozyskiwanych analiz ekonomicznych [4]. Powszechne stało się wykorzystywanie komputerowych systemów giełdowych, zintegrowanych z systemami eksperckimi (tzw. HFT), które pozwalają na bardzo szybkie reagowanie na zmiany na rynkach akcji.

Do jednego z nurtów współczesnej informatyki, którego potencjał wydaje się nie w pełni wykorzystywany w rozwiązywaniu problemów ekonomicznych należy obszerna tematyka sztucznej inteligencji [4]. Moce obliczeniowe komputerów, zdolności gromadzenia, przetwarzania i analizowania danych za pomocą technik sztucznej inteligencji pozwalają przypuszczać, że wspomniany problem wiel-

kowymiarowości i zmienności w czasie czynników decydujących o zachowaniu rynków kapitałowych w końcu może być rozwiązany. Jakość analiz wygenerowanych przez systemy eksperckie powinna w sposób znaczący przewyższać jakość analiz wykonywanych przez człowieka [15].

W niniejszej pracy zaprezentowany zostanie system zbudowany na potrzeby analizy rynków akcji. Jego architektura została oparta na rozwiązaniach sztucznej inteligencji, a dokładnie na dwóch modelach sieci neuronowych: sieci wielowarstwowej, uczonej algorytmem wstecznej propagacji błędów oraz sieci typu SOM. Opracowany system bazuje na założeniu analizy technicznej, że ceny aktywów giełdowych zawierają wszelkie informacje rynkowe. Rynek dyskontuje informacje i definiuje cenę aktywa. Założenie to pozwoliło na modelowanie wiedzy na podstawie danych opisujących przebieg sesji giełdowej.

Przeprowadzone badania mają na celu uzyskanie odpowiedzi na pytanie: czy wyniki wygenerowane przez opracowany system ekspercki istotnie różnią się od wyników klasycznych metod analizy rynków akcji.

1. System analiz danych giełdowych – budowa i architektura

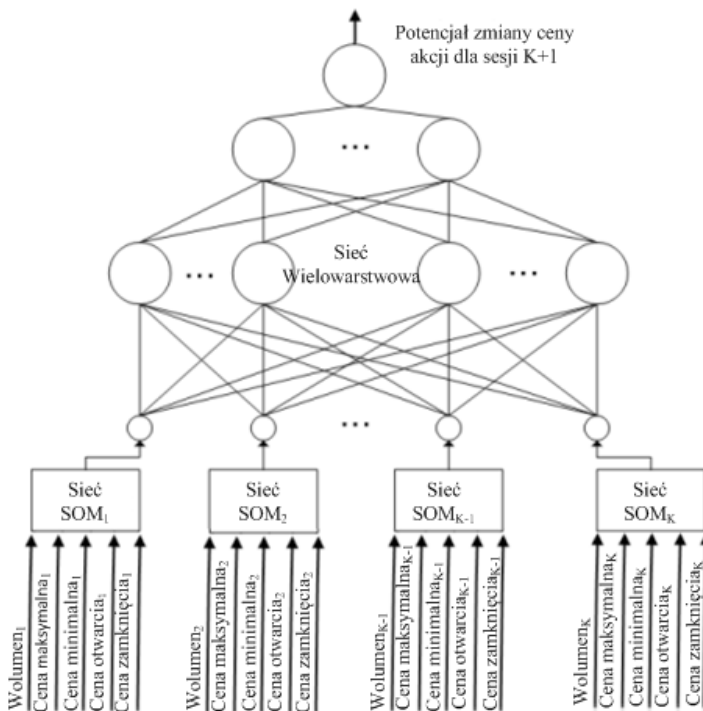
Architektura sieci neuronowych użytych do budowy systemu eksperckiego analiz giełdowych bazuje na pięciu fundamentalnych zbiorach danych, opisujących zachowania aktywa podczas sesji. Są to odpowiednio informacje o:

- wolumenie obrotów aktywa na koniec sesji,
- cenie minimalnej dla sesji, jaką należało zapłacić za walor,
- cenie maksymalnej dla sesji, jaką należało zapłacić za walor,
- cenie za walor na otwarciu sesji,
- cenie za walor na zamknięciu sesji.

Dla celów badawczych, na wejście sieci neuronowej zaprezentowane zostaną dane opisujące sesje kolejno następujące po sobie. Aby zmniejszyć rozmiar danych dokonano redukcji wektora danych giełdowych, prezentowanego na wejściu systemu. Było to możliwe dzięki wykorzystaniu modelu sieci neuronowej opartej na architekturze SOM. Sieci tego typu nadają się idealnie do rozwiązywania problemu klasyfikacji i kompresji danych [10; 14]. Te cechy sprawiły, że oprócz wspomnianej redukcji wymiaru danych wyeliminowane zostały dane sesji bardzo podobnych do siebie. Tak zredukowany ciąg danych został zaprezentowany na wejściu sieci wielowarstwowej, uczonej algorytmem wstecznej propagacji błędów [10; 14]. Na wyjściu sieci oczekiwana jest wartość opisująca potencjał zmia-

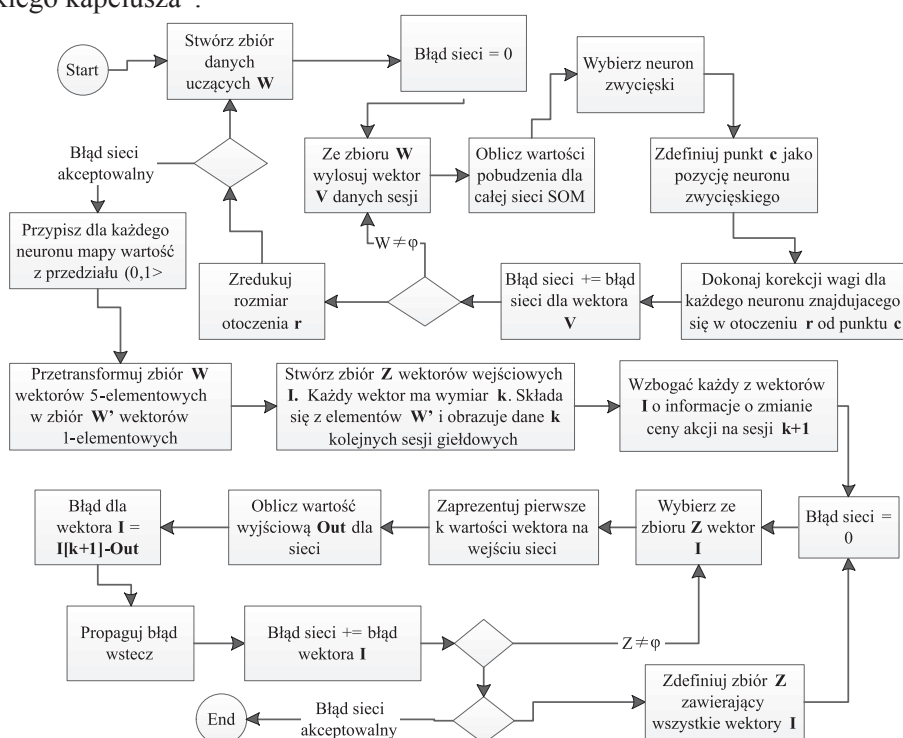
ny ceny waloru na kolejnej sesji giełdowej. Wartość ta stanowi informację analityczną, wygenerowaną przez system ekspercki.

Na rys. 1 zaprezentowano ideę budowy systemu. Bazując na danych spółki giełdowej, na wejściu systemu przedstawione są wektory danych obrazujące przebieg k następujących po sobie sesji giełdowych. W pierwszym etapie, wykorzystując sieci typu SOM, dla każdej z k sesji dokonana zostanie transformacja wektorów o wymiarze 5 na wektory jednoelementowe [8]. Przetworzone dane zostaną przekazane na wejście sieci wielowarstwowej. Ta część systemu generuje ostateczną informację systemu eksperckiego o potencjale zmiany ceny waloru dla kolejnej sesji, tj. $k + 1$. Najistotniejszym etapem budowy opisywanego systemu jest proces uczenia sieci neuronowych, mający szczególne znaczenie dla działania systemu. System, bazując na olbrzymiej ilości danych z sesji giełdowych dla spółki, jakie odbyły się pomiędzy 2005 r. a 2008 r. stara się odnaleźć wzorce pozwalające na dokonanie trafnej analizy kursu akcji w przyszłości. Ciąg danych zwany jest ciągiem uczącym. W pierwszym etapie procesu uczenia następuje optymalizacja wartości połączeń pomiędzy neuronami w sieci SOM. Jest to tzw. nauczanie bez nauczyciela.



Rys. 1. Model budowy systemu analiz danych giełdowych

W toku tego procesu sieć stara się tak dostosować wartości wag połączeń neuronów, aby w sposób jednoznaczny dokonywać klasyfikacji danych dla sesji giełdowych [10; 14; 16]. Dzięki temu zabiegowi sesje, które cechują się dużym stopniem zbieżności względem siebie zostaną zaklasyfikowane do tej samej grupy. Po ich transformacji w wektor jednoelementowy zachowana zostanie informacja o podobieństwie – z podobną siłą będą wzbudzały sygnał na wejściu kolejnej sieci. Po zakończeniu procesu uczenia sieci SOM i dokonaniu transformacji danych następuje proces uczenia sieci wielowarstwowej. Jest to tzw. nauczanie z nauczycielem. Każdy wektor danych zostaje wzbogacony o informację o prawdziwej, maksymalnej cenie kursu akcji na kolejnej sesji giełdowej. Wartość ta nie będzie nigdy podawana na wejściu sieci. W toku nauczania oczekiwane jest otrzymywanie wyników systemu zgodnych z nowo dodaną informacją [8]. Warto nadmienić, że proces uczenia sieci SOM odbywał się według algorytmu „meksykańskiego kapelusza”.



Rys. 2. Przebieg procesu nauki w systemie analiz danych giełdowych

Metoda rozróżnia siłę, z jaką mają zostać skorygowane wartości wag neuronów sąsiadujących z neuronem zwycięskim. Im „bliższy sąsiad zwycięzcy”, tym większa siła zmian jego wag [10]. Idee wyraża się wzorem:

$$h(\rho, r) = \exp\left[-\frac{\|\rho\|^2}{2\sigma^2(t)}\right]$$

gdzie:

$\sigma^2(t)$ – współczynnik zmiany siły korekcji wag w zależności od kolejności cyklu uczenia,

ρ – dystans do neuronu zwycięskiego.

Każda kolejna epoka uczenia charakteryzuje się spadkiem siły korekcji wag. Po zakończeniu procesu uczenia sieci SOM następuje proces transformacji danych wejściowych z wektora pięcioelementowego na wektor jednoelementowy. Każdemu neuronowi w warstwie mapy sieci SOM przypisana jest unikalna wartość z przedziału $(0,1)$. Zachowana zostaje zasada, że różnica wartości nadana neuronom zawierającym skrajnie różne dane wynosi 1. Po procesie transformacji tworzony jest zbiór wektorów o długości k , zawierających wartości wyliczone w poprzednim kroku. Wektor ten modeluje skompresowane dane z k następujących po sobie sesji giełdowych. Każdy tak utworzony wektor wzbogacony zostaje o informacje o maksymalnej cenie akcji w kolejnej sesji, tj. $k+1$. Podczas procesu nauczania sieci wielowarstwowej, wszystkie wartości do indeksu k traktowane są jako dane wejściowe. Wartość na pozycji $k+1$ stanowi oczekiwaną wartość, jaką powinien zwrócić system. Proces nauki w wykorzystanej sieci wielowarstwowej, bazując na algorytmie wstecznej propagacji błędu, minimalizuje funkcję błędu sieci [10; 14]. Samą funkcję można zdefiniować za pomocą wzoru:

$$Q(n) - \sum_{i=1}^N \varepsilon_i^2(n) = \sum_{i=1}^N [d_i(n) - y_i(n)]^2$$

gdzie:

Q – funkcja błędu sieci dla n -tego wektora danych wejściowych,

N – liczba warstw sieci wielowarstwowej,

ε_i – błąd sieci w warstwie i ,

d – oczekiwana wartość wyjścia sieci,

y – wartość zwrócona przez sieć.

Proces korekcji wag jest zależny od współczynnika nauczania oraz składowej gradientu funkcji błędu [10; 14] i wyrażony jest wzorem:

$$w_{ij}^k(n+1) = w_{ij}^k(n) + 2\omega \delta_i^k(n) x_j^k(n) + \alpha [w_{ij}^k(n) - w_{ij}^k(n-1)]$$

gdzie:

w_j^k – wartość wagi i -tego neuron w warstwie k -tej dla j -tego wektora danych,

δ_i^k – gradient funkcji błędu dla k -tej warstwy,

ω – współczynnik nauki,

x_j^k – j -ty sygnał wejściowy przekazany do warstwy k -tej,
 α – współczynnik momentum propagujący kierunek zmiany gradientu funkcji błędu.

2. Idea procesu oceny system eksperckiego

Na potrzeby procesu oceny systemu analiz danych giełdowych wykorzystano dane z sesji giełdowych pomiędzy 01.01.2009 r. a 31.12.2009 r. Dane te obrazowały zachowania akcji polskich spółek należących do różnych sektorów gospodarki:

- PKO Bank Polski S.A. – jeden z największych banków komercyjnych w Europie Środkowowschodniej,
- KGHM Polska Miedź S.A. – dziewiąty pod względem wielkości producent miedzi na świecie i trzeci na świecie producent srebra,
- PKN Orlen S.A. – jedna z największych rafinerii ropy naftowej oraz sieci dystrybucji paliw płynnych w Europie Centralnej,
- Grupa LOTOS S.A. – koncern rafineryjno-wydobywczy prowadzący sprzedaż detaliczną i hurtową produktów ropopochodnych.

Przedsiębiorstwa notowane są na Warszawskiej Giełdzie Papierów Wartościowych należą do indeksu WIG20, który obrazuje stan notowań dwudziestu najbardziej wartościowych spółek na GPW.

Na potrzeby oceny analiz wygenerowanych przez opisywany system ekspercki wyniki zostaną skonfrontowane z wynikami uzyskanymi za pomocą klasycznych technik analizy danych giełdowych. Są to:

- Metoda portfelowa Markowitza – metoda inwestowania długoterminowego. Na potrzeby oceny ustalono minimalny poziom zysku, na poziomie rentowności dziesięcioletnich obligacji Skarbu Państwa. Parametry portfela zostały ustalone na podstawie danych giełdowych spółek z sesji w latach 2005-2008 [3; 5; 9].
- Bootstrap – metoda oparta na idei „Monte Carlo”, która pozwala szacować kierunek zmian wszędzie tam, gdzie nieznan jest rozkład prawdopodobieństwa wystąpienia pewnych wartości. W przypadku analiz giełdowych rozkład prawdopodobieństwa wartości zmian kursu akcji jest szacowany na podstawie danych historycznych [2; 12]. Metoda ta do celów badawczych została użyta jako krótkoterminowa, tzn. dopuszczalne jest sprzedawanie bądź kupowanie składników portfela akcji na koniec każdej sesji [2; 6].

- MACD – metoda średnich kroczących. Bazuje na relacji między dwoma średnimi (tzw. EMA): z 26 i 12 sesji. Średnia z 12 sesji „wygładza” średnią z 26 sesji. Za linię sygnału wykorzystano średnią 9 kolejnych sesji. Każde przecięcie przez nią średnich z 26 i 12 sesji może wygenerować sygnał zakupu bądź sprzedaży akcji [1; 5]. Metoda ta ma charakter krótkoterminowy.

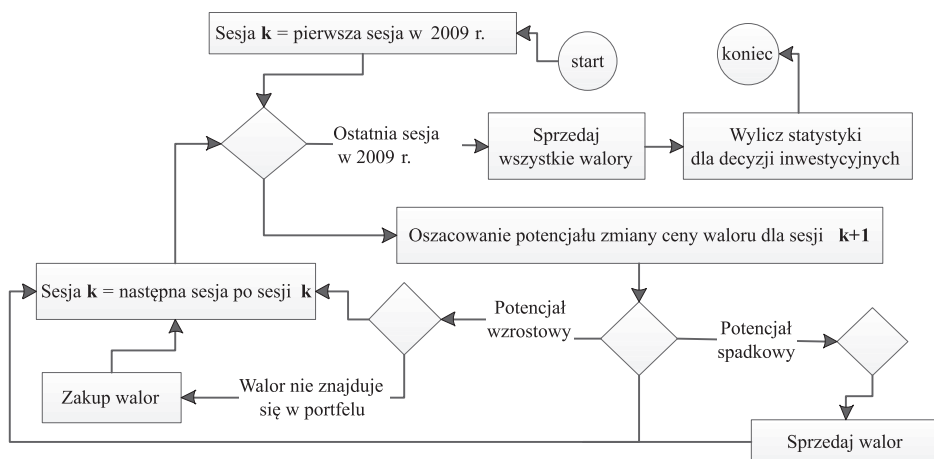
Idea oceny skuteczności analiz poszczególnych metod opiera się na modelu portfelowym. Jest to podyktowane faktem, że na potrzeby badawcze użyty został również model Markowitza. W związku z tym, oceniając skuteczność analiz wybranych metod należy brać pod uwagę nie precyzję szacowań wartości zmian poszczególnych walorów, ale precyzję szacunków dla całego portfela [17]. Przyjęta została zasada, że dla metod innych niż metoda portfela Markowitza procentowy udział walorów w portfelu nie będzie w czasie procesu badawczego optymalizowany.

Tabela 1

Udział walorów w portfelu

Metoda	Spółka	Udział w portfelu
Markowitz	PKO Bank Polski	13,3%
	KGHM Polska Miedź SA	1,9%
	PKN Orlen	0,0%
	Grupa LOTOS S.A	84,8%
Bootstrap MACD System sieci neuronowych	PKO Bank Polski	25,0%
	KGHM Polska Miedź SA	25,0%
	PKN Orlen	25,0%
	Grupa LOTOS S.A	25,0%

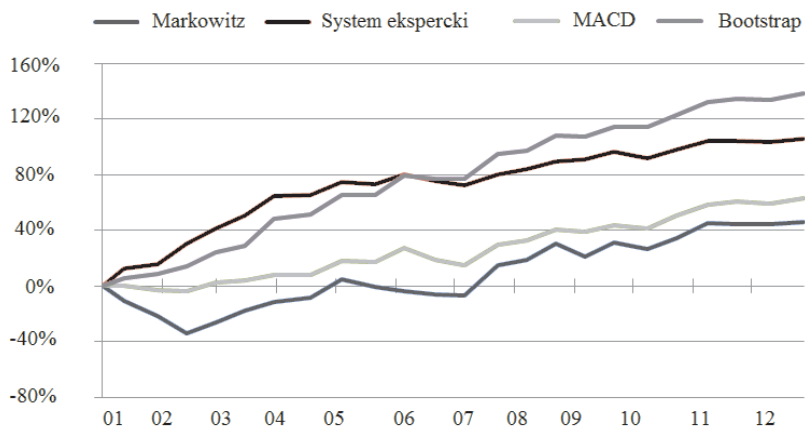
Na potrzeby oceny systemu analiz danych giełdowych wykorzystano informacje z sesji giełdowych pomiędzy 01.01.2009 r. a 31.12.2009 r. W oparciu o sygnały wygenerowane przez poszczególne metody, walory wchodzące w skład portfela mogą zostać sprzedane bądź zakupione. Rysunek 3 prezentuje ideę algorytmu inwestycyjnego.



Rys. 3. Idea algorytmu realizacji procesu inwestycyjnego

3. Wyniki oceny analiz systemu eksperckiego

Na rys. 4 zaprezentowano zyskowność inwestycji porównywanych metod analizy rynków akcji. Każda z inwestycji rozpoczyna się na pierwszej sesji 2009 r. Na kolejnych sesjach giełdowych, w oparciu o wyniki analiz danych giełdowych, skład portfeli badanych metod analiz ulegał modyfikacji. Wyjątkiem jest metoda Markowitza traktowana jako inwestycja długoterminowa [17]. Na ostatniej sesji 2009 r. wszystkie walory są sprzedawane. Po tej operacji następuje wyliczenie podstawowych miar cechujących przebieg inwestycji.



Rys. 4. Przebieg inwestycji dla porównywanych modeli analiz

W celu poprawy jakości oceny decyzji inwestycyjnych wzbogacono zbiór badanych modeli o trzy quasi-modele stanowiące punkty odniesienia w procesie porównawczym:

- Maksimum – model idealistyczny, składający się tylko z tych decyzji inwestycyjnych, które maksymalizują zyskowność portfela.
- Minimum – model składający się tylko z tych decyzji inwestycyjnych, które minimalizują zyskowność portfela.
- Rzeczywisty – koncepcja “kup i czekaj”; brak decyzji inwestycyjnych zmieniających skład portfela.

Dla celów oceny decyzji inwestycyjnych użyto siedem wskaźników:

- zyskowność – finalna zyskowność portfela na koniec 2009 r.,
- odchylenie standardowe – tożsamy z ryzykiem inwestycyjnym,
- dzienny zysk – średni dzienny zysk portfela inwestycyjnego,
- wzrosty – liczba decyzji zwiększających zyskowność portfela,
- spadki – liczba błędnych decyzji inwestycyjnych,
- trafność decyzji – miernik przyjmujący wartość z zakresu $<0,1>$; wartość 1 oznacza, że portfel generował wyłącznie zyski; wartość 0 sugeruje, że portfel inwestycyjny generował wyłącznie straty,
- poziom ufności – wraz ze średnią wartością wyznacza przedziały mogące dostarczyć informacji o potencjalnej zbieżności pomiędzy wynikami portfeli.

Wartości finalne zyskowności i odchylenia standardowego stanowią kryteria oceny przebiegu procesu inwestycyjnego dla badanych metod.

Tabela 2

Wyniki porównywanych modeli inwestycyjnych

	Zyskowność	Odchylenie standardowe	Dzienny zysk	Wzrosty	Spadki	Trafność decyzji	Poziom ufności
Minimum	-425,21%	2,76%	-1,69%	64	184	0,26	0,0034
Maksimum	597,96%	3,30%	2,37%	199	48	0,81	0,0041
Markowitz	36,41%	2,93%	0,14%	136	116	0,54	0,0036
System ekspercki	107,28%	1,72%	0,43%	138	95	0,59	0,0021
MACD	61,60%	1,98%	0,24%	127	110	0,54	0,0024
Bootstrap	140,44%	2,11%	0,56%	142	95	0,60	0,0026
Rzeczywisty	79,76%	2,69%	0,32%	134	118	0,53	0,0033

Ostatni etap oceny modeli inwestycyjnych oparto na wnioskowaniu statystycznym, tj. na teście T-Studenta. Test ten mierzy, czy wyniki decyzji inwestycyjnych dowolnych dwóch badanych metod są istotnie różne od siebie w znaczeniu statystycznym, tj. czy zyski generowane przez portfele różnią się w istotny sposób między sobą pod względem wartości średniej. Za hipotezę zerową przyjęto rów-

ność średnich zysków dwóch portfeli, za poziom istotności przyjęto wartość 0,05. Za metodę najlepszą zostanie uznana ta, która wykaże największą statystyczną zbieżność z wynikami quasi-metody „maksimum”. Im większa zbieżność, tym lepsza ocena wyników analiz wygenerowanych przez badaną metodę.

Tabela 3

Test t-studenta dla decyzji inwestycyjnych porównywanych metod

	Minimum	Maksimum	Markowitz	System ekspercki	MACD	Bootstrap	Rzeczywisty
Minimum	1	0	0	0	0	0	0
Maksimum	0	1	0	0	0	0	0
Markowitz	0	0	1	0,1900	0,6543	0,0705	0,4928
System	0	0	0,1900	1	0,2731	0,4430	0,5870
MACD	0	0	0,6543	0,2731	1	0,0868	0,7319
Bootstrap	0	0	0,0705	0,4430	0,0868	1	0,2636
Rzeczywisty	0	0	0,4928	0,5870	0,7319	0,2636	1

Duża zbieżność wyników inwestycji badanej metody z quasi-metodą „rzeczywisty” może być interpretowana jako sygnał silnej zależności wartości analiz od sytuacji panującej na rynku. Takie zachowanie pozwala przypuszczać, że podczas bessy na rynku akcji decyzje wygenerowane przez badaną metodę analizy rynku będą błędne.

Podsumowanie

Na podstawie przeprowadzonych badań wykazano, że analizy wygenerowane przez system ekspercki sieci neuronowych mogą być uważane za efektywną metodę podejmowania decyzji inwestycyjnych. Ocena statystyczna potwierdza zdolność do generowania decyzji charakteryzujących się niskim poziomem ryzyka inwestycyjnego, przy jednoczesnym wysokim poziomie zwrotu z inwestycji. Wyniki decyzji systemu eksperckiego nie mogą być uważane za zbieżne z wynikami decyzji optymalnych. Istotny jest również fakt, że żadna spośród badanych metod nie wykazała statystycznej zbieżności z modelem idealnym.

W kolejnych pracach badawczych planowane jest zwiększenie liczby metod uwzględnionych w procesie porównawczym, odejście od założenia braku modyfikacji procentowego udziału danego waloru w portfelu inwestycyjnym. Sam proces badawczy zostanie przeprowadzony w trzech stadiach rynku: „rynku niedźwiedzia”, „rynku byka” i rynku w stanie konsolidacji. System ekspercki zostanie rozbudowany o bazę wiedzy opartą na modelu logiki rozmytej [14]. Baza ta umożliwi

liwi interpretowanie, w oparciu o techniki rozmyte, danych makro- i mikroekonomicznych. Tak zbudowany system będzie miał za zadanie analizowanie możliwie najszerzej zbioru czynników decydujących o zachowaniu rynków giełdowych. Analizowanie szerokiego spektrum danych powinno w sposób istotny poprawić jakość generowanych rezultatów.

Literatura

1. Appel G., Dobson E., *Understanding MACD*, Traders Press 2008.
2. Boyle P., Seng Tan K., *Quasi-Monte Carlo Methods in Numerical Finance*, "Management Science" 1996.
3. Brock W., Lakonishok J., Lebaron B., *Simple Technical Trading Rules and the Stochastic Properties of Stock Returns*, "The Journal of Finance" 1992.
4. Chrzan P., Timofiejczuk G., *Porównanie zastosowania sieci neuronowych i modeli klasy GARCH w prognozowaniu stóp zwrotu. Część 1*, s. 147-156, w: *Rynek Kapitałowy. Skuteczne inwestowanie*, red. W. Tarczyński, Uniwersytet Szczeciński, Szczecin 2002.
5. Czekąła M., *Analiza fundamentalna i techniczna*, Akademia Ekonomiczna, Wrocław 2007.
6. Davison, A., Hinkley V., *Bootstrap Methods and their application*, Cambridge University Press 1997.
7. Edwards R., Magee J., Bassetti W.H.C., *Technical Analysis of Stock Trends*, Ninth ed. Boca Raton: CRC Press 2007.
8. Karczyński T., *Techniki sztucznej inteligencji w zarządzaniu – sieci neuronowe w analizie cen akcji*, Politechnika Wroclawska, Wrocław 2010.
9. Mamaysky H., Wang J., *Foundations of Technical Analysis: Computational Algorithms, Statistical Inference, and Empirical Implementation*, "The Journal of Finance" 2000.
10. Markowska-Kaczmar U., *Sieci neuronowe w zastosowaniach*, Oficyna EXIT, Warszawa 2003.
11. Maryański W., *Podstawy analizy technicznej*, wypracowanie: 2005.04.05.
12. Mielczarek B., *Metody próbkowania w symulacji Monte Carlo*, Wydział Informatyki i Zarządzania PWR, Wrocław 2007.
13. Park C., Irwin S., *The Profitability of Technical Analysis: A Review*, AgMAS Project Research Report 2004-04, University of Illinois at Urbana-Champaign.

14. Pliński M., Rudkowska D., Rutkowski L., Sieci neuronowe, algorytmy genetyczne i systemy rozmyte, PWN, Łódź-Warszawa 1997.
15. Radościński E., Systemy informatyczne w dynamicznej analizie decyzyjnej, PWN, Warszawa 2005.
16. Rutkowski L., Metody i techniki sztucznej inteligencji. Inteligencja obliczeniowa, PWN, Warszawa 2005.
17. Tarczyński W., Analiza portfelowa na giełdzie papierów wartościowych, PTE, Szczecin 1996.
18. Cesari R., Cremonini D., Benchmarking, Portfolio Insurance and Technical Analysis: A Monte Carlo Comparison of Dynamic Strategies of Asset Allocation. "Journal of Economic Dynamics and Control" 2003.

IMPLEMENTATION AND EVALUATION OF THE NEURAL NETWORK SYSTEM FOR STOCK MARKET DATA ANALYSIS

Summary

The application of neural network system for multi-dimensional stock market data analysis is presented in the paper. Developed system predicts stock price movements based on daily quotation data like: volume, minimum and maximum session price, opening and closing price. Several studies were carried out, to compare systems investment decisions, with decisions that were made on the basis of some commonly used methods of stock market analysis. These methods are: MACD, Bootstrap, Markowitz Portfolio. For valuation purpose, the real stock market data of the four largest Polish companies were used. All companies are quoted on the Warsaw Stock Exchange and belong to the WIG 20 index. For the benchmarking, only stock data from the year 2009 were used. In order to enrich the benchmarking tests, three investment scenarios were added. First known as the skeptical assume that only incorrect investment decisions were made. Second known as the optimistic assume that only correct investment decisions were made. Last one known as passive assume that no investment decision were made – it is so called “buy and hold” conception.

The benchmarking results confirmed, that the neural network system is able to make investment decisions, that significantly increase the profitability of the investment portfolio. Neural network system provide investment suggestions, that can be considered as an alternative to other commonly used methods of stock market analysis. However statistical tests proved a high correlation between quality of systems investment decisions and

market trend and lack of correlation to the “optimistic” scenario. Neural network systems may help in investment process, but cannot be considered as fully reliable way of investment process automation.