

Maciej Bac

Uniwersytet Ekonomiczny we Wrocławiu

**KONCEPCJA WYKORZYSTANIA SIECI KOHONENA
DO WSPIERANIA DECYZJI
INWESTORA GIELDOWEGO**

Streszczenie: Zainteresowanie rynkami giełdowymi na świecie wzrasta z roku na rok. Przyciągani możliwością osiągnięcia szybkiego i łatwego zysku inwestorzy zwiększają płynność instrumentów bazowych i instrumentów pochodnych, co budzi poczucie bezpieczeństwa i jeszcze bardziej zwiększa atrakcyjność rynków. Coraz bardziej zaawansowane techniki są wykorzystywane do wsparcia analizy instrumentów finansowych. Poza wykorzystywaniem komputerów do przeprowadzania standardowych analiz coraz częściej wykorzystuje się sztuczną inteligencję jako narzędzie do predykcji. W obliczu powyższych spostrzeżeń celem niniejszego artykułu jest prezentacja i weryfikacja koncepcji zastosowania sieci neuronowych SOM do wspomaganie decyzji inwestycyjnych.

Słowa kluczowe: SOM, sieć Kohonena, giełda.

1. Wstęp

Zainteresowanie rynkami giełdowymi na świecie wciąż wzrasta. Przyciągani możliwością osiągnięcia szybkiego i łatwego zysku inwestorzy zwiększają płynność instrumentów bazowych oraz instrumentów pochodnych, co budzi poczucie bezpieczeństwa i jeszcze bardziej zwiększa atrakcyjność rynków. Powstają coraz bardziej zaawansowane techniki i narzędzia wspierające analizę instrumentów finansowych. Posiadające coraz większy kapitał różnego rodzaju fundusze inwestycyjne dołączają do grona swoich maklerów i analityków finansowych, również informatyków. Mają oni wspomóc prognozowanie trendów, cykli ekonomicznych i zmian na rynkach w celu zwiększenia zysków z inwestycji. Poza wykorzystywaniem komputerów do przeprowadzania standardowych analiz coraz częściej wykorzystuje się sztuczną inteligencję jako narzędzie do predykcji. Jest to dziedzina, w której znacznie więcej pozostało do odkrycia, niż już zdefiniowano, stąd też zainteresowanie autora niniejszą tematyką.

Tradycyjne metody analizy i przewidywania rynku nie przynoszą graczom giełdowym satysfakcjonujących rezultatów. Odpowiednie wykorzystanie algorytm-

mów genetycznych, zazwyczaj dobrze radzących sobie z przeszukiwaniem gigantycznych przestrzeni rozwiązań w krótkim czasie, mogłoby być kluczowym odkryciem w analizie rynków giełdowych. Podobnie jak sieci neuronowe, mające doskonałą umiejętność uczenia się i uogólniania, poradziłyby sobie z zagadnieniem przewidywania zachowań giełdy. Połączenie sygnałów otwierania pozycji z powyższych metod w system wieloagentowy [Korczak, Lipiński 2006; 2008] pozwoliłoby na jeszcze pewniejsze lokowanie pieniędzy na rynkach finansowych.

W obliczu powyższych spostrzeżeń celem niniejszego artykułu jest prezentacja (i weryfikacja) koncepcji zastosowania sieci neuronowych Kohonena (*Self-Organizing Map* – SOM) do wspomagania decyzji inwestora giełdowego. W pierwszej kolejności autor przybliży podstawowe założenia swojej koncepcji, następnie zaprezentuje model jej implementacji w systemie informatycznym. Zwieńczeniem opracowania będzie przedstawienie wyników badań przeprowadzonych przez autora z wykorzystaniem opracowanego systemu informatycznego, czyli próba praktycznej weryfikacji zaprezentowanej koncepcji. Takie przedstawienie problemu znajdzie odzwierciedlenie w kolejnych punktach artykułu.

W tym miejscu pragnę podziękować profesorowi Jerzemu Korczakowi za jego cenne uwagi, które przyczyniły się ostatecznego kształtu artykułu.

2. Podstawowe założenia koncepcji

Charakteryzowana w niniejszym artykule koncepcja bazuje na trzech podstawowych zagadnieniach, które zostaną tu pokrótce przybliżone. Charakterystyka ta będzie obejmowała zagadnienia związane z analizą techniczną, świecami japońskim oraz zastosowaniem sieci Kohonena.

Analiza techniczna i analiza fundamentalna odgrywają ważną rolę w analizie rynku giełdowego. „Celem **analizy fundamentalnej** jest monitorowanie i klasyfikowanie aktywów finansowych pod względem ich jakości inwestycyjnej (jako szacunkowej oceny ryzyka) oraz oczekiwanej stopy zwrotu” [Ritchie 1977, s. 31]. Analitycy fundamentalni wyceniają spółkę i jeśli uznają, że dana spółka jest na rynku niedowartościowana, to rekomendują jej kupno, w przeciwnym wypadku – sprzedaż. Analitycy biorą pod uwagę takie czynniki, jak: obecna i prognozowana sytuacja makroekonomiczna regionu i kraju, wysokość stóp procentowych, możliwości rozwoju branży itp. Do wykonania raportu opisującego stan firmy oraz jej perspektywy długo- i średnioterminowe konieczne są informacje trudno dostępne dla zwykłych akcjonariuszy. Dlatego też przedmiotem zainteresowań autora jest analiza techniczna. **Analiza techniczna** opiera się na badaniu skutków zachowań rynku (cen, wolumenów) i poszukiwaniu na wykresach cen historycznych trendów i formacji (wzorców), które pomogą przewidzieć zachowanie rynku [Ikeda, Tokinaga 2007; Li, Tsang 1999]. Warto zauważyć, że wystąpienie formacji na wykresie jest kwestią subiektywną, analitycy giełdowi często zauważają różne formacje w tym samym czasie. Dana formacja może się rozciągać w długim lub krótkim

czasie, któraś z faz kształtowania formacji może nie wystąpić, dlatego trudno jest opisywać je algorytmicznie. W odróżnieniu od nich, świece japońskie są precyzyjne, dlatego też one zostały wybrane do analizy [Bac, Kwaśnicka 2009].

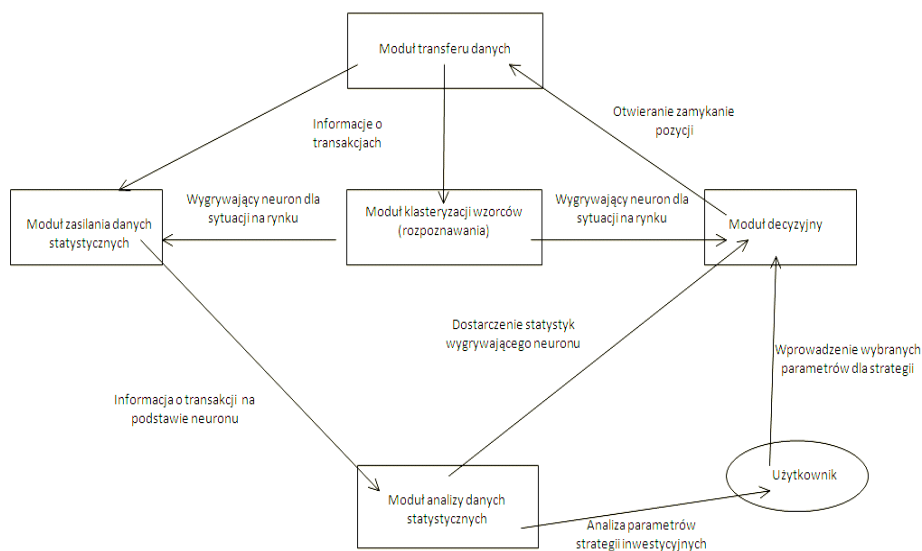
Podstawą wykresów świecowych są **świece japońskie**. Należą one do najstarszych metod analizy wykresów, powstały w Japonii ponad 300 lat temu. Do Europy i Stanów Zjednoczonych dotarły dopiero w latach 90., dosyć dobrze przyjęły się także w Polsce. Do skonstruowania świecy japońskiej potrzebny jest kurs otwarcia, zamknięcia oraz maksymalny i minimalny kurs z danego okresu. Świeca dzienna zawiera informacje o otwarciu, zamknięciu, kursie maksymalnym i minimalnym danego dnia. Długość świecy symbolizuje różnicę między kursem maksymalnym a minimalnym z danego okresu. Natomiast długość ciała świecy symbolizuje różnicę między kursem otwarcia a kursem zamknięcia. Cienie świecy są odzwierciedleniem różnicy kursów skrajnych i kursów otwarcia/zamknięcia. Kolor świecy mówi, czy wartość kursu wzrosła od otwarcia, czy też zmalała. Świeca o białym korpusie symbolizuje okres wzrostu kursu, natomiast świeca o czarnym korpusie oznacza spadek kursu. W zależności od okresu, jaki symbolizuje jedna świeca, mamy niezasumioną perspektywę długo-, średnio- lub krótkoterminową [Bac, Kwaśnicka 2009].

Sieci neuronowe SOM były wielokrotnie wykorzystywane do wspomagania decyzji inwestycyjnych graczy giełdowych. Doskonale nadawały się do zauważania podobieństwa między sytuacją techniczną lub fundamentalną poszczególnych walorów notowanych na rynkach finansowych. Bazując na wskaźnikach analizy fundamentalnej, grupowały walory giełd w Bombaju [Khan, Bandopadhyaya, Sharm 2009] i USA [Stankevicius 2001], pomagając w ten sposób dobrać zawartość najefektywniejszego portfela inwestycyjnego. **Sieć Kohonena** wspomagała dobieranie walorów o podobnych wykresach w ciągu ostatnich 30 dni [Simunic 2003], co miało ułatwić dobranie spółek o podobnej sytuacji technicznej. Wspomaganiu decyzji o zakupie bądź sprzedaży waloru służy sieć analizująca 57 wartości ostatnich notowań kursu [Afolabi, Olude 2007] oraz maksymalną i minimalną wartość kursu, obrót i różnicę między poprzednim i aktualnym zamknięciem notowań. Możliwość wykorzystania sieci samoorganizujących się do odnajdywania podobieństw między obserwowaną sytuacją a sytuacjami historycznymi zainspirowała autora do zaproponowania poniższego rozwiązania.

3. Model implementacji koncepcji – architektura systemu

Ogólny model systemu, w którym zaimplementowana została koncepcja zastosowania sieci neuronowych SOM do wspomagania decyzji inwestycyjnych, został zaprezentowany na rys. 1. Trzy jego podstawowe moduły które zostaną scharakteryzowane poniżej, to:

- a) moduł klasteryzacji/rozpoznawania wzorców,
- b) moduł statystyczny,
- c) moduł podejmowania decyzji.



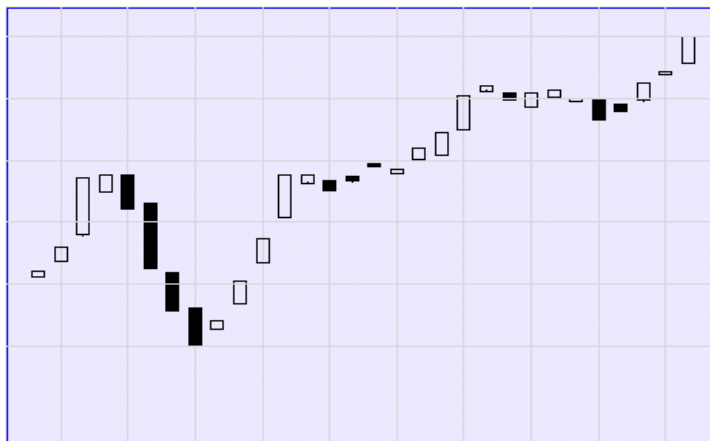
Rys. 1. Schemat ogólnego modelu systemu

Źródło: opracowanie własne.

Zasada działania systemu jest następująca (rys. 1): informacje o zmianach wartości kursu dostarczone przez moduł transferu danych zostają sklasteryzowane przez sieć Kohonena i zwracany jest wygrywający neuron. Moduł podejmowania decyzji pobiera z modułu analiz dane statystyczne dotyczące wytypowanego neurona. Na podstawie statystyk i zadanych parametrów system decyduje, czy otworzyć, czy zamknąć pozycję.

Moduł klasyfikacji/rozpoznawania wzorców bazuje na sieci neuronowej SOM i jest zaimplementowany jako część aplikacji w języku C#. Neuron reprezentuje N kolejnych świec. Możemy zdecydować, czy ma brać pod uwagę dane z otwarcia, zamknięcia, kurs maksymalny, kurs minimalny bądź też średnią z otwarcia i zamknięcia. Na rys. 2 została zaprezentowana wizualizacja neurona reprezentującego 30 kolejnych świec – otwarcie i zamknięcie.

Sygnal wejściowy dla takiej sieci jest reprezentacją aktualnej technicznej sytuacji wybranego waloru (rys. 2). Reprezentacja musi być identyczna jak dla neurona danej sieci, czyli musi brać pod uwagę N ostatnich świec i odpowiednie parametry świecy (otwarcia, zamknięcia, kurs minimalny, kurs maksymalny...). Kolejne wartości sygnału wejściowego sieci są normalizowane do 1. Dla każdego sygnału wejściowego sieć typuje neuron, który jest najbliższy sygnałowi wejściowemu. W zależności od jakości wyuczenia sieci wytypowany wzorec jest mniej lub bardziej podobny do sygnału wejściowego.



Rys. 2. Wizualizacja neuronu reprezentującego 30 kolejnych świec – wartości otwarcia i zamknięcia
Źródło: opracowanie własne.

Moduł statystyczny zaimplementowany na bazie danych MS SQL przechowuje dane dotyczące zachowania kursu po wystąpieniu określonego wzorca na wykresie. Długość okresu, jaki jest obserwowany (moment zamknięcia pozycji), jest zależna od strategii. Obserwowane wartości to maksymalny kurs po wystąpieniu wzorca (rys. 3), minimalny kurs po wystąpieniu wzorca oraz kurs otwarcia i zamknięcia po określonym czasie. Na podstawie tak zgromadzonych danych jesteśmy w stanie wyznaczyć parametry opisujące neuron. Do parametrów tych należą:

- średnie maksymalne odchylenie kursu do góry procentowo AMDU (średnia maksymalnych odchyień kursu do góry ze wszystkich pozycji otwieranych przez dany neuron);
- średnie maksymalne odchylenie kursu w dół procentowo AMDD (średnia maksymalnych odchyień kursu w dół ze wszystkich pozycji otwieranych przez dany neuron);
- współczynnik kierunku otwierania pozycji FDOP (różnica między średnim odchyleniem kursu w górę i średnim odchyleniem kursu w dół). Współczynnik ten pokazuje, czy lepiej otwierać pozycję długą, czy krótką po uaktywnieniu danego neuronu. Im większa wartość tego współczynnika, tym silniejszy sygnał;
- odchylenie standardowe wartości współczynnika kierunku otwierania pozycji pomiędzy otwartymi pozycjami VFDOP;
- liczba okresów, jakie otwierał dany neuron;
- odchylenie standardowe liczby okresów, jakie otwierał dany neuron.

Opisane parametry pomagają w podjęciu decyzji, jak się zachować, gdy moduł rozpoznawania wzorców wytypuje neuron, który najlepiej odpowiada aktualnej sytuacji danego waloru.



Rys. 3. Wizualizacja pozycji

Źródło: opracowanie własne.

W ramach **modułu podejmowania decyzji** na podstawie informacji, który neuron najlepiej odpowiada bieżącej sytuacji na wykresie, i informacji dotyczącej zachowań kursu po aktywowaniu danego neuronu w okresach historycznych, może zostać podjęta decyzja inwestycyjna. W module tym zaimplementowano trzy strategie inwestycyjne:

- strategia podstawowa (strategia 1) – strategia ta zakłada otwieranie pozycji zgodnie z kierunkiem wyznaczanym przez współczynnik kierunku otwierania pozycji (FDOP). Pozycja zamykana jest po czasie, który jest parametrem narzuconym z góry. Parametry zewnętrzne: minimalna bezwzględna wartość współczynnika kierunku otwierania pozycji (FDOP), maksymalna wartość odchylenia standardowego współczynnika kierunku otwierania pozycji (VFDOP);
- strategia współczynnika kierunku otwierania pozycji (strategia 2) – strategia ta zakłada otwieranie pozycji zgodnie z kierunkiem wyznaczanym przez współczynnik kierunku otwierania pozycji (FDOP). Pozycja zamykana jest w dwóch sytuacjach. W przypadku gdy osiągnięta zostanie oczekiwana wartość kursu, która wyliczana jest na podstawie wzoru:

$$EV = O + (O * FDOP * M),$$

- gdzie: *EV* – oczekiwana wartość kursu,
O – kurs otwarcia,
FDOP – współczynnik kierunku otwarcia pozycji,
M – mnożnik, parametr zewnętrzny.

Jeżeli kurs nie osiągnie oczekiwanej wartości, to pozycja jest zamykana po czasie, który jest parametrem narzuconym z góry. Parametry zewnętrzne: minimalna wartość współczynnika kierunku otwierania pozycji, maksymalna wartość odchylenia współczynnika kierunku otwierania pozycji, mnożnik.

- Strategia średniego odchylenia kursu w górę/dół (strategia 3) – strategia ta zakłada otwieranie pozycji zgodnie z kierunkiem wyznaczanym przez współczynnik kierunku otwierania pozycji (FDOP). Pozycja zamykana jest w dwóch sytuacjach. W przypadku gdy osiągnie oczekiwaną wartość kursu, która wyliczana jest na podstawie wzoru:
 - jeżeli $FDOP > 0$

$$EV = O + (O * AMDU * M)$$

- jeżeli $FDOP < 0$

$$EV = O + (O * AMDD * M)$$

w innym przypadku – strategia nie otwiera pozycji

gdzie: EV – oczekiwana wartość kursu,

O – kurs otwarcia,

$AMDU$ – średnie maksymalne odchylenie kursu w górę – procentowo,

$AMDD$ – średnie maksymalne odchylenie kursu w dół – procentowo,

M – mnożnik, parametr zewnętrzny.

Jeżeli nie osiągnie oczekiwanego kursu, to zamykana jest po czasie, który jest parametrem narzuconym z góry. Parametry zewnętrzne: minimalna wartość współczynnika kierunku otwierania pozycji, maksymalna wartość odchylenia współczynnika kierunku otwierania pozycji, mnożnik.

Parametry w strategiach umożliwiają decydowanie o tym, na podstawie których neuronów chcemy inwestować. **Minimalna wartość współczynnika kierunku otwierania pozycji**, a właściwie wartości bezwzględnej ze współczynnika kierunku otwierania pozycji, pozwala odrzucić neurony, które historycznie charakteryzowały się podobną zmiennością zarówno w górę, jak i w dół. Takie neurony nie dają jednoznacznego sygnału do otwarcia pozycji w którąkolwiek stronę. **Maksymalna wartość odchylenia współczynnika kierunku otwierania pozycji** pozwala na odrzucenie neuronów, które w różnych okresach miały rozbieżne wartości współczynnika kierunku otwierania pozycji. Sygnał od takich neuronów również nie jest jednoznaczny, gdyż w jednych okresach dawały jasne sygnały otwierania pozycji krótkich, w innych okresach sygnały otwierania pozycji długich. Ostatnim parametrem jest **mnożnik**. Umożliwia on zamknięcie pozycji, gdy osiągnie ona oczekiwany kurs. Jeśli więc współczynnik kierunku otwierania pozycji ma wartość x , możemy za pomocą mnożnika zwiększyć oczekiwaną wartość zamykania pozycji, tak aby nie były one zamykane zbyt wcześnie (ze zbyt małym zyskiem). Analogicznie działa mnożnik przy strategii średniego odchylenia kursu w górę/dół. Możemy zmniejszać lub zwiększać wartość oczekiwanego zysku z pozycji.

4. Weryfikacja praktyczna

Celem eksperymentów była weryfikacja skuteczności systemu. Neuron sieci reprezentował sygnały otwarcia i zamknięcia 30 kolejnych świec. Sieć neuronowa liczyła 1024 neurony i była uczona na serii kontraktów FW20U9 w okresie od 18 czerwca 2009 do 18 września 2009. Dane statystyczne poszczególnych neuronów sieci zostały wzięte z okresów FW20Z7 (18 września 2007 – 18 grudnia 2007), FW20H8 (18 grudnia 2007 – 18 marca 2008), FW20M8 (18 marca 2008 – 18 czerwca 2008), FW20U8 (18 czerwca 2008 – 18 września 2008), FW20Z8 (18 września 2008 – 18 grudnia 2008), FW20H9 (18 grudnia 2008 – 18 marca 2009), FW20M9 (18 marca 2009 – 18 czerwca 2009), FW20U9 (18 czerwca 2009 – 18 września 2009). Były to okresy największej aktywności wybranych serii kontraktów.

Badania przeprowadzono dla maksymalnego czasu trzymania pozycji (1 h). Największe zyski przynosiły neurony, których wartość bezwzględna współczynnika kierunku otwierania pozycji była w zakresie $\langle 0.25; 0.3 \rangle$, natomiast maksymalne odchylenie współczynnika kierunku otwierania pozycji w zakresie $\langle 0.25; 0.55 \rangle$. Po ustaleniu grupy neuronów które przynosiły największe zyski, autor przebadiał współczynniki, które są odpowiedzialne za zamykanie pozycji dla dwóch ostatnich strategii. Najrentowniejsze były pozycje, których progim realizacji zysku był wzrost procentowy o wartość współczynnika kierunku otwarcia pozycji pomnożony przez $\langle 2.1; 2.4 \rangle$. Natomiast dla strategii, która zamyka pozycję według średniego odchylenia kursu w górę/dół, najskuteczniejsze współczynniki były w przedziale $\langle 1.6 ; 1.8 \rangle$.

Tabela 1. Wyniki badań (minimalna wartość FDOP = 0.25, maksymalna wartość VFDOP = 0.3; mnożnik dla strategii 2 = 2.5; mnożnik dla strategii 3 = 1.6)

Seria	Kurs odniesienia	Buy and hold	Zysk "buy and hold" procentowo	Liczba transakcji	Maksymalny zysk	Strategia 1	Strategia 2	Strategia 3
FW20U9	1903	187	9,826589595	547	5508	9	-205,8	88,2
FW20M9	1460	446	30,54794521	683	6078	172	66,8	120,8
FW20H9	1822	-327	-17,94731065	1090	13282	705	-319,0	-272,0
FW20Z8	2458	-668	-27,17656631	625	10704	1632	761,0	1418,0
FW20U8	2690	-431	-16,02230483	376	4080	-146	28,6	2,6
FW20M8	2770	-52	-1,877256318	321	3768	-125	341,6	195,6
FW20H8	3501	-747	-21,33676093	588	10981	939	670,8	1189,8
FW20Z7	3613	-150	-4,151674509	268	3785	611	759,8	615,8
	Suma:	3008			58186	3797	2103,8	3358,8

Źródło: opracowanie własne.

W tab. 1 pokazano wyniki działania systemu dla dobranych parametrów (minimalna wartość współczynnika kierunku = 0.25; maksymalna wartość odchylenia

współczynnika kierunku = 0.3; mnożnik dla strategii współczynnika kierunku = 2.5; dla strategii średniego odchylenia kursu w górę/dół mnożnik wynosił 1.6). Tabela pokazuje wyniki po odliczeniu kosztów prowizji.

Z zestawienia wyników badań można wywnioskować, że najwięcej zarobiła strategia podstawowa, która zakładała utrzymanie pozycji przez jedną godzinę (tab. 1 – strategia 1; 3797 pkt. zysku). Niewiele gorsza była strategia realizująca zysk według średniego odchylenia w górę/dół (tab. 1 – strategia 3; 3358,8 pkt. zysku). Strategia „buy and hold” (tab. 1 – „buy and hold”) na tych okresach, przy założeniu, że prawidłowo przewidzieliśmy kierunek otwarcia pozycji, mogła zarobić 3008 pkt. Najgorsza okazała się strategia otwierania i zamykania pozycji według współczynnika kierunku otwierania pozycji (tab. 1 – Strategia 2; 2103,8 pkt.). Jak pokazano w tab. 1, przewaga strategii podstawowej została zbudowana tylko na jednym okresie FW20H9. W tym okresie zaistniało parę sygnałów, które generowały dużo większe zyski, niż przewidziano. Strategie, które przewidywały oczekiwany zysk i zamykały pozycje po jego osiągnięciu, nie pozwalały w tym okresie na pełną realizację zysków. Jednak w innych badanych okresach zamykanie pozycji po osiągnięciu oczekiwanego zysku przynosiło lepsze efekty niż zamykanie dyktowane z góry ustalonym interwałem czasowym.

5. Zakończenie

Wyniki uzyskane przez system zachęcają do dalszych badań nad zastosowaniem systemów bazujących na sieciach neuronowych we wspomaganie decyzji inwestycyjno-spekulacyjnych. Mimo że rozwiązanie dawało wyniki niewiele lepsze od strategii „buy and hold” (jeżeli znalazłbyśmy kierunki, jak należy otwierać pozycje) i w niektórych okresach przynosiło niewielkie straty, autor uważa, że obrany kierunek badawczy jest obiecujący. Strategia „buy and hold” czerpała zyski ze zmian kursów pomiędzy sesjami, natomiast prezentowane rozwiązanie zakładało czerpanie zysków tylko i wyłącznie ze zmian kursów w ciągu trwania sesji.

Ze względu na to, że rzeczywiste sygnały dostarczane do sieci nie są rozproszone w całej przestrzeni możliwych rozwiązań, lecz grupują się w małym, gęstym jej wycinku, który trudno byłoby rzutować na dwuwymiarową przestrzeń SOM, zasadne byłoby zastosowanie gazu neuronowego lub rosnącego gazu neuronowego. Można by pójść w kierunku zmiany postaci neuronu, tak aby ostatnie świece z podawanego ciągu miały większą wagę – zwiększyłyby to wrażliwość na to, co działo się tuż przed zaistnieniem sygnału, kosztem tego, co działo się nieco wcześniej (było bardziej odległe).

Kolejny wniosek z przeprowadzonych badań jest oparty na faktach, że badania na różnych, równie dobrze wyuczonych sieciach na tym samym okresie przynoszą różne wyniki oraz że wiele neuronów dawało niejednoznaczne sygnały. Ciągi świec identyfikowane przez sieć jako bardzo podobne (z jednego klastra) dawały sygnały, które raz przynosiły znaczne zmiany kursu w górę, innym razem znaczne zmiany kursu w dół. Drobny wpływ na uczenie sieci w kierunku kojarzenia wzorców pod względem przynoszonych korzyści może poprawić jakość działania opi-

sywanego systemu. Podobieństwo wzorców było oceniane jedynie po odległości euklidesowej pomiędzy nimi. Sieć nie zwracała uwagi na szczegóły, które mogły być jednoznacznym sygnałem otwarcia pozycji długiej/krótkiej. Można wnioskować, że do wychwytywania takich specyficznych dla konkretnych sygnałów reguł mogłyby się sprawdzić algorytmy genetyczne lub *gene expression programming*.

Literatura

- Afolabi M.O., Olude O., *Predicting stock prices using a hybrid Kohonen Self Organizing Map (SOM)*, [w:] *Proceedings of the 40th Annual Hawaii International Conference on System Sciences*, IEEE Computer Society, Washington 2007, s. 814-821.
- Bac M., Kwaśnicka H., *Możliwości zastosowania algorytmów genetycznych w systemach informacyjnych wspomagających proces podejmowania decyzji gracza giełdowego*, [w:] *Inżynieria i systemy ekspertowe*, red. A. Grzech, K. Juszczyszyn, H. Kwaśnicka, Akademicka Oficyna Wydawnicza Exit, Warszawa 2009, s. 663-676.
- Ikeda Y., Tokinaga S., *Multi-fractality analysis of time series in artificial stock market generated by multi-agent systems based on the genetic programming and its applications*, [w:] *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, Oxford University Press, Oxford 2007, s. 2212-2222.
- Khan A.U., Bandopadhyaya T.K., Sharm S., *Classification of stocks using Self-Organizing Map*, [w:] *International Journal of Soft Computing Applications* Issue 4, EuroJournals Publishing 2009, s. 19-24.
- Korczak J., Lipiński P., *Systemy agentowe we wspomaganii decyzji na rynku papierów wartościowych*, [w:] *Rozwój informatycznych systemów wieloagentowych*, red. S. Stanek, Placet, Warszawa 2008, s. 289-301.
- Korczak J., Lipiński P., *Technology of intelligent agents used in financial data analysis*, [w:] *Nowoczesne technologie informacyjne w zarządzaniu*, AE, Wrocław 2006, s. 350-359.
- Li J., Tsang E.P.K., *Improving technical analysis predictions: an application of genetic programming*, *Proceedings of the Twelfth International Florida Artificial Intelligence Research Society Conference*, AAAI Press, USA 1999, s. 108-112.
- Ritchie J.C., *Analiza fundamentalna*, Wig-Press, Warszawa 1977.
- Simunic K., *Visualization of stock market charts*, *Proceedings from The 11th International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision* 2003.
- Stankevicius G., *Forming of the investment portfolio using the Self-Organizing Maps (SOM)*, "Informatica" 2001, vol. 12, no. 4, Vilnius, s. 573-584.

KOHONEN NETWORK APPLICATION TO SUPPORT THE DECISIONS OF STOCK MARKET INVESTOR

Summary: The popularity of stock markets in the world grows every year. Attracted by the possibility of easy profits, investors increase the liquidity of base instruments and derivatives. It arouses the sense of security and makes the markets more attractive. More and more advanced techniques are used to support the analysis of financial instruments. Apart from using computers to carry out standard analysis more and more often artificial intelligence is used as a prediction tool. Referring to those observations the objective of this article is to present (and review) the concept of SOM neural network application for the investment decisions support.