




Wydawnictwo
Naukowe
AKAPIT



ZASTOSOWANIE SIECI KOHONENA DO GENEROWANIA WIELOKRYTERIALNYCH STRATEGII DECYZYJNYCH

RADOMIR DOMARADZKI, JANUSZ MORAJDA

GENERATION OF MULTICRITERION STRATEGIES DECISIONS USING KOHONEN NEURAL NETWORKS

Abstract

A method of generation of initial grouping of input values vectors, using self-organizing neural network - Kohonen network as an instrument, is described in this work. This main aim of the paper is demonstration of new methodology for grouping data during producing strategies decisions, which can be further applied in the field of materials engineering. Described approach is illustrated by example, which characterizes share market condition.

1. WSTĘP

W ostatnim czasie mamy do czynienia z zalewem informacji pochodzących z różnych źródeł, a co się z tym wiąże – powstaje problem ich szybkiego i efektywnego przetwarzania oraz selekcji. Tradycyjne techniki przetwarzania informacji nie zawsze dają oczekiwany efekt w rozsądnym czasie. Ponadto w szybko zmieniających się warunkach działania wielu przedsiębiorstw i związanych z nimi systemów informatycznych pojawia się konieczność szybkiego dostosowywania istniejących algorytmów do nowych warunków, a to nie jest rzeczą ani łatwą, ani tanią.

Często także nie istnieją ani teoretyczne ani praktyczne rozwiązania dla przedstawionych powyżej problemów. Tymczasem rozwiązanie przynajmniej niektórych problemów może być znalezione, pod warunkiem, że w obszar rozwiązań dopuszczalnych

włączone zostaną metody niestandardowe (jak chociażby sieci neuronowe), co na pewno przyniesie korzyść dla gospodarki i techniki.

2. SIECI NEURONOWE

Sieci neuronowe od czasu swych narodzin w latach czterdziestych przeżywały okresy wzlotów i upadków. Od początkowej fascynacji ich możliwościami, poprzez znaczny spadek zainteresowania, wręcz zapomnienia po książce Minskiego^{*)}, aż po renesans w latach osiemdziesiątych i dziewięćdziesiątych.

Inspiracją dla tej dziedziny nauki, modelem, do którego, początkowo bezpośrednio, odwoływali się

^{*)} Minsky M., Papert S., „Perceptrons”, MIT Press, Cambridge 1969 – Ta publikacja zahamowała rozwój sieci neuronowych na prawie 15 lat, gdyż zawierała formalny dowód na to, że jednowarstwowe sieci neuronowe mają bardzo ograniczony zakres zastosowań.

badacze sieci neuronowych jest mózg. Ten najbardziej skomplikowany i tajemniczy z ludzkich organów stanowi dla nas ciągle zagadkę. Dzisiejsze, tak szerokie i powszechne zainteresowanie sieciami neuronowymi zarówno wśród inżynierów, przedstawicieli nauk ścisłych – matematyki i fizyki oraz biologów czy neurofizjologów wynika przede wszystkim z poszukiwań nad sposobami budowy bardziej efektywnych i bardziej niezawodnych urządzeń do przetwarzania informacji a układ nerwowy jest tutaj niedoścignutym wzorem. Z punktu widzenia dzisiejszej informatyki ważne jest nie tyle całościowe modelowanie mózgu, ile możliwość wykorzystania sposobów, jakimi on przetwarza informacje. Ciekawy z punktu widzenia informatyki jest także fakt, że dzięki tym modelom można rozwiązywać zadania, z którymi z trudem radzą sobie inne techniki obliczeniowe. Sieci neuronowe bowiem, mogą być stosowane wszędzie tam, gdzie pojawiają się problemy związane z przetwarzaniem i analizą danych, z ich predykcją, klasyfikacją czy sterowaniem. Można pokusić się nawet o stwierdzenie, że łatwiej wymienić problemy, w których sieci neuronowe się nie sprawdzają, od tych w których z powodzeniem można je zastosować (i w których zapewne były już stosowane). Głównym czynnikiem przemawiającym za praktycznym stosowaniem sieci neuronowych jest ich zdolność do uogólnień zdobytej wiedzy, która daje im jak gdyby pewną dozę inteligencji. Ciekawym i równie ważnym czynnikiem jest to, że sieci neuronowe są wyposażone w swoje wewnętrzne algorytmy przetwarzania informacji, które umożliwiają im rozwiązywanie nawet gatunkowo różnych zadań. Sposób w jaki sieć neuronowa zyskuje wiedzę o zadanym problemie, polega na nauce na podstawie znanych poprawnych przykładach (zwanych wzorcami uczącymi) rozwiązania danego problemu, lub prościej na bazie obserwacji prezentowanej jej wiedzy. Celem nauki jest sposób opisania wewnętrznych korelacji zachodzących pomiędzy wzorcami uczącymi. Na tej podstawie nauczona sieć neuronowa potrafi odpowiadać na pytania zarówno z zakresu wzorców uczących jak i spoza nich.

Mózg człowieka ciągle jest najpotężniejszym z istniejących obecnie urządzeń liczących do celów przetwarzania informacji w czasie rzeczywistym. Fascynacje mózgiem, jego własnościami (odpornością na uszkodzenia, równoległym przetwarzaniem itp.) już w latach 40-tych zaowocowały pracami, których fundamentalne znaczenie odczuwamy jeszcze dzisiaj.

Choć niewielu z nas potrafi przemnożyć w pamięci dwie liczby dwucyfrowe, co bez problemu robi najprostszy kalkulator, każdy bezbłędnie rozpoznaje twarze znajomych osób, z czym komputery mają jeszcze olbrzymie problemy. Mózg może pokonać nawet najszybszy superkomputer, pomimo że w tym procesie

neurony jako jednostki przetwarzające są o wiele rzędów wielkości wolniejsze od swoich elektronicznych czy optoelektronicznych odpowiedników.

Sieci neuronowe odziedziczyły po swoim pierwotnym wzorze kilka cech odróżniających ich działanie od innych systemów przetwarzania danych, a upodabniających je do mózgu. I choć nie mają monopolu na naśladowanie mózgu, to właśnie najczęściej sieci neuronowe odczytują ręczne pismo, prognozują kursy akcji na giełdzie, rozpoznają mowę, obrazy czy twarze.

Mówiąc o sieciach neuronowych w aspekcie technicznym w istocie mamy na myśli sztuczne sieci neuronowe wzorowane na ludzkim mózgu będącym prototypem tego narzędzia. W praktyce są to programy komputerowe, które symulują działanie mózgu. Istnieje wiele symulatorów sieci neuronowych, np. BrainMaker czy Statistica Neural Network firmy Statsoft. Jednak sztuczna sieć neuronowa jest niezwykle okrojonym modelem rzeczywistości, gdyż jak wynika z badań anatomicznych na ludzki mózg składa się około 10 miliardów komórek nerwowych – neuronów, a sztuczna sieć (modelowana sieć) neuronowa w przeważającej większości posiada nie więcej niż kilkaset takich elementarnych „komórek”.

Zanim zostanie zaprezentowana symulacja wykorzystania samoorganizującej sieci neuronowej do generowania finansowych strategii inwestycyjnych słów parę na temat budowy i funkcjonowania sieci SOM na przykładzie sieci Kohonena.

2.1. Budowa i funkcjonowanie sieci Kohonena (SOM)

Sieć Kohonena została nazwana przez jej twórcę (Kohonen 1995) samoorganizującym odwzorowaniem (Self-Organizing Map – SOM) i jest niewątpliwie najbardziej popularnym typem sieci określanej mianem samoorganizującej.

Idea takiego systemu samoorganizującego pojawiła się w latach 50-tych, a terminu tego użyli Farley i Clark. Sam termin był definiowany bądź jako system, który zmienia swą podstawową strukturę na podstawie informacji docierającej do niego z otoczenia, bądź jako szersze pojęcie obejmujące zarówno złożony obiekt jak i jego otoczenie. Idea samoorganizacji jest ważna, gdyż istnieje dość powszechne przekonanie, iż wszelkie procesy życiowe zawierają w sobie etap samoorganizacji.

Istotnym elementem, którego istnienie warunkuje możliwość pojawienia się procesu samoorganizacji, jest asymetria istniejących oddziaływań, co oznacza, że jeśli pewne zdarzenie porządkujące ma miejsce, to warunkiem pojawienia się samoorganizacji jest, by oddziaływanie rozbijające porządek w systemie, było

słabsze od porządkującego.

Sieć Kohonena jest jednym z najbardziej znanych typów sieci neuronowej uczonej w trybie bez nauczyciela. Jest siecią o bardzo prostej strukturze (Rys. 1), gdyż posiada tylko dwie warstwy, a przepływ informacji w tej sieci jest ściśle jednokierunkowy. Mimo prostej budowy i nieskomplikowanych metod określających sposób jej funkcjonowania, możliwości aplikacyjne tego typu modelu są olbrzymie.

Sieć Kohonena składa się z dwóch warstw: warstwy wejściowej i warstwy wyjściowej. Neurony wchodzące w skład pierwszej warstwy sieci Kohonena praktycznie nie dokonują przetwarzania danych – posiadają jedynie pojedyncze wejście i pojedyncze wyjście, a jedynym ich celem jest rozesłanie do wszystkich neuronów drugiej warstwy wszystkich wartości wprowadzonych na wejścia sieci (wykorzystuje się tu znowu regułę połączeń typu „każdy z każdym”). Funkcjonalność sieci Kohonena zapewniają więc wyłącznie neurony warstwy wyjściowej, które bardzo często działają w sposób przedstawiony na rys. 2.

Agregacja danych wejściowych odbywa się w nich zgodnie ze wzorem:


$$q = \sum_{i=1}^n (x_i - w_i)^2 \quad (1)$$

Wejściowa wartość zintegrowana jest więc niczym innym jak kwadratem odległości Euklidesa pomiędzy wektorem wartości wejściowych (oznaczonym symbolem x), a wektorem współczynników wagowych w_i . Neurony o tak skonstruowanej funkcji agregacji noszą nazwę neuronów radialnych. Funkcją aktywacji w sieci Kohonena jest pierwiastek kwadratowy funkcji agregującej.


$$y = \sqrt{q} \quad (2)$$

W efekcie na wyjściu neuronu uzyskujemy wartość, która jest odległością Euklidesa pomiędzy wektorem wag w_i a wektorem wejściowym x_i .


Jednym z podstawowych pojęć związanych z siecią Kohonena jest pojęcie sąsiedztwa. Dotyczy ono neuronów wchodzących w skład warstwy wyjściowej sieci. Za sąsiadów pewnego wybranego neuronu uznaje się inne neurony znajdujące się w jego bliskości. Zasięg sąsiedztwa charakteryzowany jest przez tzw. promień sąsiedztwa. Rysunek 3 przedstawia przykładowy układ neuronów wyjściowych sieci. Jako przykład można rozważyć sąsiedztwo neuronu znajdującego się w trzeciej kolumnie i w czwartym wierszu. Sąsiedztwo o promieniu zerowym obejmuje tylko ten jeden neuron. Sąsiedztwo o promieniu jednostkowym obejmuje dany neuron oraz jego bezpośrednich sąsiadów, to znaczy neurony umieszczone w kolumnach i wierszach o numerach różniących się co najwyżej



Rys. 1. Schemat przykładowej sieci Kohonena. Trójkąty symbolizują neurony warstwy wejściowej, a kółka - neurony warstwy wyjściowej (Structure of a Kohonen neural network. Triangles represent neurons belonging to input layer, whilst circles - neurons of output layer).



Rys. 2. Schemat neuronu warstwy wyjściowej sieci Kohonena (Structure of output neuron in a SOM neural network).



Rys. 3. Sąsiedztwo w sieci Kohonena (The idea of neighborhood in a SOM network).

o jedną jednostkę. Sąsiedztwo o promieniu równym dwa zawiera wszystkie te neurony, które wchodziły w skład sąsiedztwa o promieniu jeden oraz ich bezpośrednich sąsiadów. To, że jeden neuron jest sąsiadem innego wynika z ustalonego arbitralnie sposobu rozmieszczenia neuronów na płaszczyźnie i nie jest za-

leżne od wartości wag neuronów. W czasie uczenia zmieniają się wartości wag neuronów wyjściowych, nie zmieniają się natomiast zależności sąsiedzkie.

Sieć Kohonena jest uczona w trybie bez nauczyciela, co oznacza, że wykorzystywany zbiór uczący obejmuje wyłącznie wartości zmiennych wejściowych i nie zawiera żadnych wiadomości dotyczących wartości oczekiwanych na wyjściach sieci. Uczenie ma charakter iteracyjny – zbiór uczący jest wielokrotnie prezentowany sieci. Uczenie rozpoczyna się od losowych, zwykle skupionych wokół zera, wartości współczynników wagowych; przy czym losowe generowanie wartości współczynników wagowych przeprowadza się po ustaleniu struktury sieci, co powoduje, że początkowe wartości wag neuronów sąsiadujących ze sobą nie pozostają w żadnym związku.

W trakcie uczenia sieci prezentowane są kolejne wzorce uczące. Po wprowadzeniu pierwszego z nich wartości wszystkich zmiennych wejściowych wchodzących w skład tego wzorca są przekazywane do wszystkich neuronów warstwy drugiej. Neurony wchodzące w jej skład obliczają swoje sygnały wyjściowe. Każdy neuron drugiej warstwy określa swój sygnał wyjściowy niezależnie od innych neuronów tej warstwy, przy czym wartość sygnału wyjściowego określonego neuronu jest równa odległości Euklidesa pomiędzy wprowadzonym wektorem wartości wejściowych a wektorem wag rozważanego neuronu. Po przeprowadzeniu tych obliczeń nadrzędny algorytm uczący porównuje wartości wyznaczone na wyjściach poszczególnych neuronów i wybiera ten neuron, dla którego wyznaczona wartość jest najmniejsza (czyli ten, którego wektor wag znajduje się w najmniejszej odległości od wektora wejściowego x). Wyznaczony w ten sposób neuron zostaje nazwany neuronem zwycięskim, gdyż on właśnie wygrał współzawodnictwo pomiędzy neuronami warstwy wyjściowej. Jak z tego wynika rywalizacja pomiędzy neuronami sieci Kohonena polega na wyborze takiego neuronu, którego wektor wag jest w największym stopniu zbliżony do wprowadzonego wektora wartości wejściowych.

Po zidentyfikowaniu neuronu zwycięskiego modyfikowane są jego wagi (co jest zasadniczym etapem każdego procesu uczenia). Modyfikacja wag przeprowadzana jest tak, aby neuron zwycięski jeszcze bardziej przybliżył się do wprowadzonego aktualnie wektora wejściowego. Stosowana formuła jest bardzo prosta. Jeśli przyjmiemy, że wektor wag neuronu zwycięskiego jest równy w_{zw} , zaś wektor wejściowy oznaczymy przez x , to wyznaczyć można wektor r stanowiący różnicę pomiędzy interesującymi nas wektorami:

$$r = x - w_{zw} \quad (3)$$

Jeśli obliczony w ten sposób wektor r zostałby

w całości dodany do aktualnego wektora wag neuronu zwycięskiego w_{zw} , to zostałaby uzyskana równość wektora wejściowego x i nowego wektora wag. Zazwyczaj jednak wagi neuronu zwycięskiego modyfikowane są nie o cały wektor różnic, lecz o pewną część wektora r . Realizowane jest to według wzoru:

$$w_{zw}^{(t+1)} = w_{zw}^{(t)} + \mu r \quad (4)$$

gdzie μ jest współczynnikiem uczenia przyjmującym wartości z przedziału (0; 1). Im większa wartość współczynnika uczenia μ zostanie zastosowana, tym w większym stopniu nowe wagi neuronu zwycięskiego przybliżą się do prezentowanego przypadku uczącego.

Najczęściej jednak podczas uczenia sieci Kohonena stosuje się zmienną wartość współczynnika uczenia μ . W początkowych epokach jego wartość ustala się na stosunkowo wysokim poziomie (np. $\mu = 0,8$). Powoduje to, że zmiany wag są duże i poszczególne neurony warstwy wyjściowej dość szybko upodabniają się do kolejnych przypadków uczących. W czasie dalszego treningu wartość współczynnika uczenia jest jednak stopniowo zmniejszana do bardzo małej wartości (np. $\mu = 0,001$). Zmiany w wartościach wag mają w związku z tym coraz mniejszy charakter i sieć w dalszych etapach procesu uczenia może w płynny sposób, precyzyjnie dostosować się do prezentowanych przypadków.

Istotną cechą algorytmu uczenia stosowanego w sieci Kohonena jest przeprowadzanie modyfikacji wag nie tylko dla neuronu zwycięskiego, lecz również dla jego sąsiadów. Liczba neuronów modyfikowanych w czasie uczenia jest określona przez obowiązujący w danej chwili promień sąsiedztwa. W początkowej fazie uczenia promień sąsiedztwa jest tak ustalany, aby niezależnie od lokalizacji neuronu zwycięskiego, jego sąsiedztwo obejmowało wszystkie neurony warstwy wyjściowej sieci (co powoduje, że modyfikowane są zawsze wszystkie neurony). W czasie kontynuacji procesu uczenia promień sąsiedztwa stopniowo się zmniejsza – aż do wartości zerowej wówczas modyfikacji podlega tylko sam neuron zwycięzca. Podczas uczenia sąsiadów zachowany jest kierunek zmian wyznaczony dla neuronu zwycięskiego, natomiast – wraz z oddalaniem się sąsiada od neuronu zwycięskiego – maleje siła wprowadzonych zmian. To sprawia, że wraz z oddalaniem się od zwycięzcy wektor poprawek przemnażany jest przez coraz mniejszy współczynnik sąsiedztwa. Współczynnik ten ustawia się w taki sposób, że dla neuronu zwycięskiego przyjmuje on wartość 1, a dla sąsiadów ma odpowiednio mniejsze wartości i maleje do zera wraz z oddalaniem sąsiadów od neuronu zwycięskiego.

Takie stopniowe zmniejszanie zarówno promienia sąsiedztwa jak i współczynnika uczenia umożliwia dokonywanie precyzyjnych rozróżnień we wszystkich

obszarach mapy topologicznej, zaś w fazie ostatecznej dokonywane jest wyregulowanie położenia pojedynczych neuronów.

Ostatecznie algorytm Kohonena prowadzi do dopasowania siatki utworzonej przez warstwę wyjściową sieci do obiektów uczących. Oznacza to, że:

- Poszczególne neurony dopasowują się do wzorców uczących czyli prezentacji każdego obiektu towarzyszy uaktywnienie jednego neuronu, posiadającego wektor wag najbardziej zbliżony do wartości zmiennych charakteryzujących obiekt. Często się zdarza, że ten sam neuron jest zwycięzcą dla wielu różnych wektorów wejściowych. Oznacza to, że charakteryzowane przez nie obiekty są podobne, a wektor wag odpowiadającego im neuronu reprezentuje całą tę grupę. Kolejne pokazy w trakcie uczenia i kolejne korekty prowadzą do tego, że wagi tego neurony stają się uśrednionymi wzorcami cech charakteryzujących wszystkie obiekty. Sieć Kohonena dzieli więc obiekty zbioru uczącego na klasy, które reprezentowane są przez poszczególne neurony wyjściowe. W sposób bezpośredni badacz nie może zadać liczby klas, na które podzielone zostaną obiekty zawarte w eksplorowanych danych. Może to jednak zrobić w sposób pośredni – określając strukturę warstwy wyjściowej sieci. Im więcej neuronów będzie wchodzić w jej skład, tym większe będzie rozdrobnienie uzyskanych grup. Należy jednak pamiętać, że nie zawsze liczba grup będzie równa liczbie neuronów, gdyż w następstwie samouczenia sieci nie dostajemy nigdy tak dobrych wyników grupowania, jak w przypadku zastosowania uczenia z nauczycielem. Dlatego w sieci Kohonena często pewna liczba neuronów pozostaje niewykorzystana – nie stają się one neuronami zwycięskimi dla żadnego przypadku uczącego.
- Sieć Kohonena zachowuje informację o zależnościach pomiędzy zidentyfikowanymi grupami obiektów. Zależności te głównie odwołują się do pojęcia bliskości (w sensie metryki Euklidesa) odpowiednich wektorów danych, a tę bliskość z kolei możemy kojarzyć z pojęciem podobieństwa opisywanych przez te dane obiektów. Oznacza to, że wraz ze wzrostem podobieństwa pomiędzy wyznaczonymi grupami obiektów, przybliżają się do siebie również reprezentujące je neurony. W efekcie sąsiadujące ze sobą neurony odpowiadają podobnym do siebie grupom danych, zaś neurony oddalone od siebie odpowiadają zróżnicowanym grupom.

Utworzona w trakcie samouczenia sieć Kohonena może posłużyć do zbadania prezentowanego w trakcie uczenia zbioru danych i do ujawnienia takich jego cech, o których istnieniu twórca sieci mógł wcale nie wiedzieć. Nauczona sieć stanowi również pewien

model przechowujący wiedzę o strukturze zbiorowości. Może on być wykorzystany dla klasyfikacji i porządkowania także innych danych niż te, które prezentowane były w czasie uczenia. Nauczona sieć Kohonena ma bowiem tę właściwość, że po wprowadzeniu na jej wejścia dowolnych danych (byle tylko tego samego typu, jak wartości podawane na wejścia sieci podczas uczenia), zawsze uaktywni się jakiś neuron wskazujący na klasę, do której najprawdopodobniej powinien zostać przypisany nowy obiekt.

Uogólniając powyższe rozważania należy stwierdzić, że sieć Kohonena dokonuje grupowania obiektów, opisuje zależności pomiędzy tymi grupami oraz pozwala na zaklasyfikowanie nowych obiektów do wcześniej rozpoznanych klas. Jest to więc bogate w możliwości, wysoce użyteczne narzędzie mogące służyć do eksploracyjnej analizy danych.

3. SIECI NEURONOWE W INŻYNIERII MATERIAŁOWEJ I METALURGII

Sieci neuronowe mają liczne i różnorodne zastosowania, a w wielu zagadnieniach technicznych i ekonomicznych pojawia się potrzeba opracowywania strategii decyzyjnych. Podejmowanie decyzji związane jest z procesem wyboru odpowiedniego kursu działania. Często wymaga to dokonania wyboru „najlepszej” opcji z wielu możliwych rozwiązań.

Obecnie, kiedy postęp techniczny jest niewyobrażalnie szybki zachodzi konieczność zarządzania coraz większym zbiorem danych. Poprzez zarządzanie należy rozumieć odkrywanie struktur wiedzy wspomagającej proces podejmowania decyzji w warunkach ograniczonej pewności.

Idea tzw. zgłębiania danych (data mining) zdobywa coraz większą popularność jako narzędzie zarządzania informacją. W procesie data mining, po przygotowaniu danych, przychodzi etap właściwego przeszukiwania, przerzucania danych, zgłębiania ich, kopania w pokładach informacji. Poszukujemy ukrytych prawidłowości lub anomalii, poszukujemy wiedzy w ogromie danych.

Zgłębianie danych jest często traktowane jako zagadnienie z pogranicza statystyki, sztucznej inteligencji oraz badania baz danych, które do niedawna nie było powszechnie akceptowane jako obszar zainteresowań dla statystyków. Jednak ze względu na swą praktyczną użyteczność, to podejście badawcze przyjmuje charakter głównego i gwałtownie rozwijającego się obszaru, w którym dokonuje się gwałtowny postęp w zakresie teorii. W literaturze przedmiotu brak jest powszechnie uznanej typologii metod. Autorzy Berry i Linoff (2000) wyróżniają trzy techniki data mining: automatyczne wykrywanie skupień, drzewa decyzyjne oraz sieci neuronowe. Z kolei Hastie i in.

(2001) dzielą metody na supervised i unsupervised, co można tłumaczyć jako metody „z nauczycielem” (prognozowanie wartości zmiennej wyjściowej na podstawie realizacji zmiennych wejściowych) i „bez nauczyciela” (znalezienie związków i prawidłowości tylko na podstawie cech wejściowych). Do metod supervised autorzy zaliczają bardzo szeroko rozumianą regresję, wnioskowanie poprzez znajdowanie k najbliższych sąsiadów i sieci neuronowe (uczone w trybie z nauczycielem, czyli np. sieci typu perceptron, czy RBF). Metody unsupervised obejmują: badanie zasad asocjacji, analizy skupień, metodę głównych składowych, oraz samoorganizujące sieci neuronowe.

Bardzo często poszukując przy pomocy sieci neuronowych, pewnych relacji przyczynowo-skutkowych zarówno w inżynierii materiałowej, metalurgii, ekonomii, i innych dziedzinach nauki wykorzystywane są sieci neuronowe uczone pod nadzorem (z nauczycielem). Jednak w problemach wchodzących w obszar data mining nie zawsze są nam znane zależności przyczynowo skutkowe pozwalające na obliczanie interesujących danych wyjściowych na podstawie znanych danych wejściowych. Przy budowie tego modelu odwołujemy się bowiem wyłącznie do eksplorowanych danych, licząc na to, że ich analiza pozwoli zbudować model, używany potem jako skuteczne narzędzie diagnostyczne, prognostyczne lub kontrolne. Proces uczenia sieci ma więc pozwolić na wydobycie wiedzy zawartej implícite w rozważanych (eksplorowanych) danych, przy czym sensowność tego procesu związana jest głównie z faktem, że zazwyczaj wiedza taka może być potem uogólniana na przypadki, które nie wchodziły w skład eksplorowanej bazy danych. Silną stroną sieci neuronowych stosowanych w tym obszarze jest fakt, że mogą one być łatwo i wygodnie łączone z innymi technikami sztucznej inteligencji takimi jak: zbiory rozmyte lub algorytmy genetyczne.

Jako przykład możliwości wykorzystania sieci neuronowej typu SOM w zgłębianiu danych można przedstawić problematykę modelowania i sterowania procesami walcowania blach, a także modelowania mikrostruktury i własności mechanicznych stopów.

Zagadnienie sterowania w systemie on-line procesem walcowania nie jest zagadnieniem nowym. Pierwsze układy sterowania zostały wprowadzone już w latach 60-ych. Szybki rozwój komputeryzacji pozwolił na wzbogacenie modeli sterowania o nowe parametry procesu walcowania. Niestety dokładne określenie wartości parametrów wymaga długich czasów obliczeń co sprawia, że nie mogą one być wykorzystywane bezpośrednio w systemach automatycznej regulacji w czasie rzeczywistym. A to wszystko przekłada się na jakość oraz dokładność wymiarów walcowanych produktów, które wciąż często pozostawiają dużo

do życzenia.

Możliwość zastosowania sieci neuronowej typu SOM w sterowaniu procesem walcowania stali przedstawiają w swojej publikacji Roning i Elsila (1998). Autorzy prowadzili badania na podstawie danych z Rautaruukki Steel. Ponieważ proces walcowania stali jest procesem zazwyczaj w pełni zautomatyzowanym, to na każdym jego etapie są mierzone poszczególne parametry zarówno skład chemiczny stali, temperaturę procesu walcowania jak i siły nacisku walców. Autorzy Roning i Elsila (1998) wskazują, że największym problemem nie jest zbieranie danych, a obsługa powstających podczas procesu technologicznego, ogromnych baz danych oraz ich analiza, która jest powolna i bardzo kosztowna.

W takim przypadku próba użycia narzędzia jakim są samoorganizujące sieci neuronowe jest wręcz intuicyjna. Mamy bowiem dużo danych (parametrów procesu), jednak nie zawsze w szybki sposób jesteśmy w stanie znaleźć korelacje pomiędzy nimi oraz ich wpływ na proces technologiczny, w tym przypadku na jakość walcowania stali.

Podobnie sytuacja wygląda w przypadku zagadnienia modelowania mikrostruktury i własności mechanicznych stopów stali. Tu również można pokusić się o próbę zastosowania do tego problemu samoorganizującej sieci neuronowej.

O jakości wyrobów stalowych świadczą w dużej mierze ich własności mechaniczne kształtowane podczas procesów obróbki cieplno-plastycznej, a także zawartość niektórych pierwiastków chemicznych. Znacząca ilość wyrobów stalowych charakteryzuje się strukturą ferrytyczno-perlityczną, a parametry mikrostrukturalne, które kształtują własności mechaniczne tej struktury obejmują: ułamek ferrytu przedeutektoidalnego, ułamek perlitu, ułamek ferrytu Widmanstättena^{*)}, wielkość ziarna ferrytu, wielkość ziarna perlitu, wielkość kolonii perlitu, odległość między płytkami cementytu w perlicie, grubość płytki cementytu.

Zasadniczo opracowane dotychczas modele, za pomocą których przewidywane są parametry mikrostruktury, można podzielić na dwie grupy:

- Modele fenomenologiczne oparte na klasycznej teorii przemian fazowych.
- Modele empiryczne, które wiążą parametry mikrostrukturalne struktury ferrytyczno-perlitycznej z zawartością podstawowych pierwiastków (C, Mn, Si) w stali, wielkością ziarna austenitu oraz prędkością chłodzenia stali.

^{*)} Ferryt Widmanstättena bardzo negatywnie wpływa na własności plastyczne i ciągliwość oraz na udamność stali. Składnik ten tworzy się w stali w przypadku uzyskania dużego ziarna austenitu w procesie przeróbki plastycznej i/lub w przypadku stosowania dużych prędkości chłodzenia stali po przeróbce.

Niestety takie podejście ma zasadniczą wadę, jaką może być uwzględnianie w modelu tylko podstawowych pierwiastków (C, Mn, Si), a przecież występowanie zanieczyszczeń w postaci pozostałych pierwiastków może znacząco wpływać na własności stali po procesie technologicznym. Takie nieco okrojone podejście wiąże się zapewne z tym, iż proces budowania modeli wymaga bardzo żmudnych i długotrwałych badań, przeprowadzanych zarówno w warunkach laboratoryjnych, jak i w warunkach przemysłowych (etap wdrażania modelu). A przecież na każdym etapie produkcji powstaje duża liczba danych gromadzonych w bazach danych, które można byłoby wykorzystać do budowy modelu.

W niektórych przypadkach, a w szczególności w problemach dotyczących grupowania danych, eksploracji danych (data mining), gdy nie do końca wiadomo jakie związki mogą zachodzić pomiędzy danymi, jakościowo lepsze rezultaty może przynieść zastosowanie sieci neuronowych typu SOM, np. sieci Kohonena. Aby to unaocznić, w kolejnym rozdziale prezentowanej pracy podjęto próbę zdefiniowania nowych metod tworzenia strategii decyzyjnych z wykorzystaniem sieci Kohonena.

Ponieważ najwięcej doniesień literaturowych dotyczących tworzenia wielokryterialnych strategii decyzyjnych wiąże się z problemem predykcji rynków finansowych, notowań giełdowych (zob. Haefke i Helmenstein (1996), Hiemstra (1996), Refenes (1995), Schoeneburg (1990), Trippi i Turban (1996)), w związku z czym, aby mieć możliwość porównania referowanych w tej pracy wyników z wynikami publikowanymi przez innych autorów w dalszej części pracy również przebadano nowe metody tworzenia strategii decyzyjnych w oparciu o strategię giełdowe i o predykcję notowań.

4. SYMULACJA – MODEL GENERUJĄCY FINANSOWE STRATEGIE INWESTYCYJNE

4.1. Charakterystyka metody

Realizacja efektywnej strategii inwestycyjnej na giełdowym rynku akcji, chociaż często oparta jest na wspieranej doświadczeniem intuicji inwestora (co prowadzi z reguły do dość przypadkowych efektów), powinna zasadniczo bazować na odpowiednio skonstruowanym modelu decyzyjnym. Wobec braku jawnych i możliwych do zidentyfikowania relacji wiążących dostępne na rynku akcji informacje z przyszłą dynamiką rynku, tworzenie tego typu modeli poprzez dobór a priori odpowiednich równań lub reguł logicznych na ogół nie jest celowe. Budowa efektywnych

modeli decyzyjnych zazwyczaj oparta jest na analizie i przetwarzaniu historycznych danych opisujących zachowanie się kursów akcji.

W sytuacji, gdy w analizowanym systemie brak jest możliwości identyfikacji jawnych reguł opisujących dynamikę systemu, a dodatkowo występują w nim znaczne zakłócenia, natomiast dostępna jest duża ilość zaobserwowanych danych, sprawdzonym narzędziem służącym do modelowania tego typu systemów są sieci neuronowe. Przesłanki te, występujące także wyraźnie w systemach finansowych takich jak rynki akcji, wskazują na celowość zastosowania metodyki opartej na sztucznych sieciach neuronowych w zagadnieniach modelowania i wspomagania decyzji finansowych. Efektywność wykorzystania tych metod na rynkach finansowych została również potwierdzona przez liczne badania, a także publikacje dokumentujące praktyczne rezultaty zastosowań (zob. Bar i Mani (1994), Beltratti i in. (1996), Morajda (1999), Morajda (2000), Morajda (2003), Refenes (1995)). W zdecydowanej większości zastosowań jako narzędzie do tworzenia modeli decyzyjnych stosowane są sieci uczone w sposób nadzorowany (np. perceptron lub RBF), przy czym zmienną wyjściową (której realizacje w ciągu uczącym stanowią wzorcowe wartości wyjściowe sieci) jest z reguły pewna wielkość (np. stopa zwrotu) charakteryzująca dynamikę zmian kursu akcji w odpowiedzi na zadane wartości zmiennych wejściowych.

W niniejszym opracowaniu zaproponowano metodę generowania strategii transakcyjnych, wykorzystującą sieć neuronową Kohonena (SOM) jako narzędzie wstępnego grupowania wektorów wartości wejściowych, opisujących stan rynku akcji. Jest to podejście jakościowo odmienne od większości technik neuronowych w problemach modelowania rynków finansowych, gdyż wykorzystuje sieć uczoną w sposób nienadzorowany. Metoda wykorzystuje właściwości sieci SOM jako narzędzia realizującego nieliniowe przekształcenie dowolnej przestrzeni metrycznej w przestrzeń dyskretną, a także nieparametryczną regresję dokonującą dopasowania skończonej liczby wektorów kodowych (wektorów wag neuronów mapy) do rozkładu obiektów w przestrzeni cech. Wykorzystanie tych właściwości jest szczególnie uzasadnione w zagadnieniu analizy rynków finansowych (z przyczyn opisanych wyżej). W istocie sieci SOM dość często używa się w zagadnieniu identyfikacji skupień wzorców (formacji) generowanych przez finansowe szeregi czasowe i możliwych do zaobserwowania na ich wykresach, oraz do identyfikacji typowych wzorców (zob. np. Deboeck (1997), Lula (2002)).

Główna idea metody jest następująca:

- W oparciu o ciąg uczący (obejmujący historyczne notowania danego waloru z pewnego okresu i za-



wierający zmienne istotne z punktu widzenia opisu stanu dynamiki notowań) realizowany jest proces grupowania wzorców (wektorów), opisujących stan rynku w poszczególnych chwilach czasowych (sesjach giełdowych). Po zakończeniu procesu uczenia sieci SOM (grupowania) pewne neurony mapy reprezentują związane z nimi skupienia (klasy) wzorców.

- Dokonywana jest analiza przyszłych stóp zwrotu uzyskanych dla wzorców należących do każdej grupy osobno, analiza ta obejmuje obliczenie średniej przyszłej stopy zwrotu dla wzorców z danej klasy oraz obliczenie pewnego przyjętego wskaźnika będącego miarą ryzyka inwestycyjnego; wskaźnikiem takim może być np. odchylenie standardowe przyszłych stóp zwrotu dla rozważanej klasy.
- Na podstawie analizy otrzymanych dla każdej klasy wskaźników zysku i ryzyka, a także w oparciu o indywidualne preferencje inwestora (dotyczące np. poziomu akceptowalnego ryzyka), z każdą grupą wzorców kojarzona jest określona decyzja inwestycyjna, np. kup, sprzedaj, utrzymuj pozycję inwestycyjną.
- W trybie realizacji (wykorzystania) skonstruowanego modelu, zakwalifikowanie pojawiającego się nowego wzorca opisującego bieżącą dynamikę rynku danego waloru do określonej klasy jednoznacznie determinuje decyzję inwestycyjną; model taki jest więc funkcjonalnym modelem decyzyjnym realizującym określoną strategię inwestycyjną.

Rezultaty badań dotyczących wykorzystania metody w procesie generowania decyzji inwestycyjnych dotyczących akcji wybranej spółki giełdowej (BRE Banku) zaprezentowano w kolejnej sekcji.

4.2. Rezultaty wykorzystania opracowanej metody

Poniżej przedstawiono wyniki badań efektywności modelu decyzyjnego zbudowanego według proponowanej metody, w zagadnieniu realizacji strategii inwestycyjnej dla akcji spółki BRE Bank w przyjętym okresie czasu. Zadaniem modelu było generowanie decyzji inwestycyjnej (na podstawie analizy bieżącej sytuacji rynkowej) dla okresu od zamknięcia notowań w dniu bieżącym (moment realizacji decyzji) do zamknięcia notowań podczas kolejnej sesji giełdowej (kiedy może zostać zrealizowana następna transakcja). W trakcie realizacji aktywnej strategii

inwestycyjnej założono możliwość realizacji dwóch typów transakcji: kupna akcji za całość posiadanych w portfelu środków, oraz krótkiej sprzedaży akcji o wartości równej posiadanych w portfelu środków (bez możliwości zajmowania pozycji pośrednich)*).

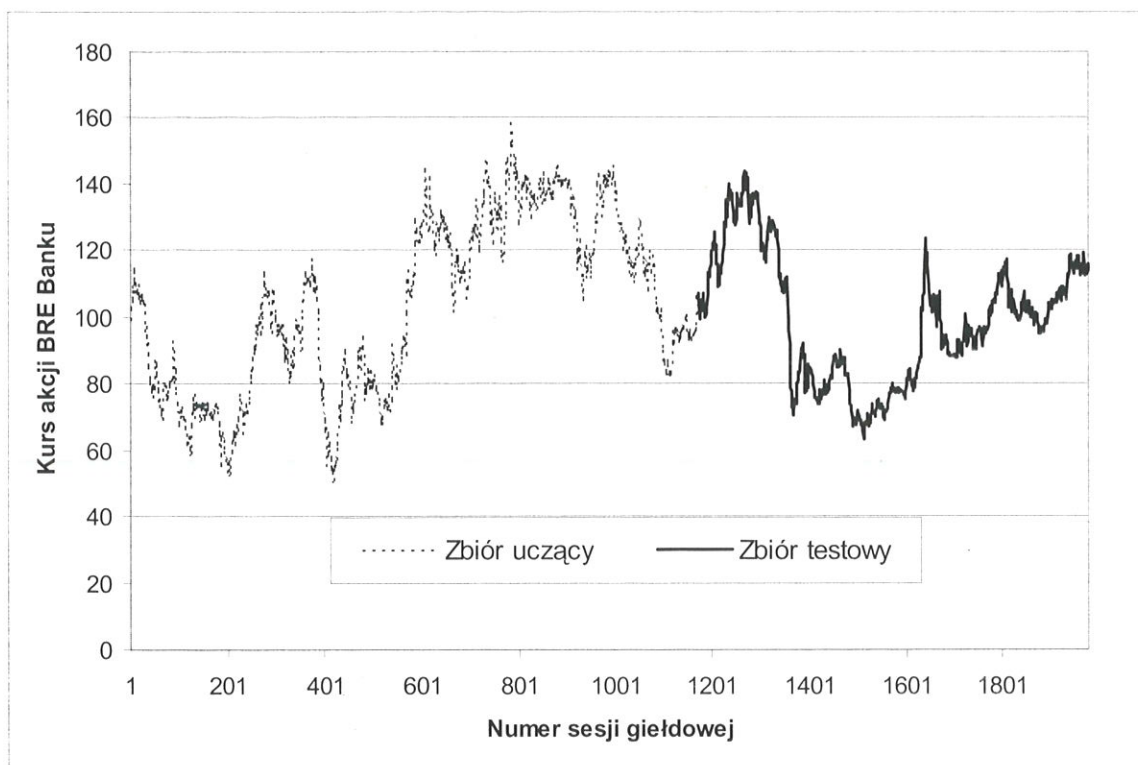
Wykorzystane w badaniach dane obejmowały notowania (kursy zamknięcia) spółki BRE Bank w okresie od 06.02.1997 do 27.12.2004. Jako dane wejściowe dla modelu przyjęto (arbitralnie) 13 zmiennych, których wartości w poszczególnych dniach obliczono na podstawie notowań akcji. Zestaw zmiennych wejściowych zawierał: cztery ostatnie logarytmiczne jednodniowe stopy zwrotu, dwie kolejne ostatnie logarytmiczne dwudniowe stopy zwrotu, nachylenia pięciodniowego trendu** kursu: obecne i sprzed czterech dni, obecne nachylenie dziesięciodniowego trendu, dynamikę zmiany logarytmicznych jednodniowych stóp zwrotu (różnicę tych stóp), dynamikę zmiany logarytmicznych dwudniowych stóp zwrotu, dynamikę zmiany pięciodniowego trendu (różnicę wskaźników trendu obecnego i sprzed 4 dni), oraz różnicę między nachyleniem trendu 5-dniowego i 10-dniowego.

Łącznie (po pominięciu notowań niezbędnych do obliczenia wartości początkowych wszystkich zmiennych) wyodrębniono 1971 wzorców, z czego pierwsze 1171 wektorów utworzyło zbiór uczący, a ostatnie 800 wzorców zaliczono do zbioru testowego (przeznaczonego do końcowego testowania i oceny efektywności modelu). Podział danych na uczące i testowe zrealizowano przy uwzględnieniu proporcji (w przybliżeniu) 60% / 40% oraz w taki sposób, aby całkowite stopy zwrotu dla obu tych okresów wynosiły w przybliżeniu 0. Kurs akcji BRE Banku w okresie obejmującym dane uczące oraz testowe zaprezentowano na rys. 4.

Dobierając parametry struktury i uczenia sieci SOM przyjęto sieć zawierającą 9 neuronów na dwuwymiarowej mapie o wymiarach 3 x 3, euklidesową metrykę określającą odległość między wektorami w przestrzeni cech, oraz współczynnik uczenia równy 0,6 i malejący wraz z upływem czasu uczenia. Przyjęto 50 epok uczenia. Rozmiar sąsiedztwa ustalono na początku procesu uczenia na maksymalny (obejmujący wszystkie neurony), ale malejący liniowo podczas uczenia do zera (dla 50 epoki). Zastosowano standaryzację zmiennych wejściowych poprzez taką transformację, aby średnia (dla zbioru uczącego) wynosiła zero, a odchylenie standardowe: jeden. Wektory wag początko-

* Nawet jeśli krótka sprzedaż akcji (tzn. sprzedaż akcji pożyczonych od maklera, czyli zajęcie pozycji z ujemną liczbą akcji) w rzeczywistości nie jest na giełdzie możliwa, można ją zrealizować poprzez sprzedaż kontraktów terminowych na akcje (kontrakty terminowe na akcje BRE Banku są notowane na GPW w Warszawie). Posiadanie pozycji krótkiej (krótko sprzedanych akcji) jest zyskowne w przypadku spadku ich notowań.

** Nachylenie trendu było obliczone jako współczynnik kierunkowy prostej regresji dla pięciu ostatnich logarytmów notowań.



Rys. 4. Kurs akcji BRE Banku w okresie zawierającym dane uczące oraz dane testowe (BRE Bank stock quotations in the period including learning and test data). Źródło: opracowanie własne.

wych sieci określono jako losowo wybrane wektory wejściowe z ciągu uczącego.

Po przeprowadzeniu procesu uczenia sieci zaobserwowano, iż liczba wzorców ze zbioru uczącego przyporządkowana poszczególnym neuronom mapy (tzn. wektorów, dla których dany neuron stał się neuronem zwycięskim) waha się pomiędzy 96 a 200. Przyjęto zatem, iż każdy neuron reprezentuje osobne skupienie (grupę) wzorców (choć sąsiadnie obszary mapy mogą odwzorowywać podobne wzorce), a zatem liczba tych grup jest równa 9. Obliczone dla zbioru uczącego istotne wskaźniki charakteryzujące poszczególne grupy, takie jak: liczba wzorców n , średnia przyszła logarytmiczna jednodniowa stopa zwrotu r (pomnożona przez 1000), oraz odchylenie standardowe dla tych stóp zwrotu σ (pomnożone przez 1000) przedstawiono w tabeli 1.

W celu powiązania z każdą grupą wzorców określonej decyzji inwestycyjnej przyjęto, iż podstawę tej decyzji stanowić będzie wartość wskaźnika s przedstawiająca stosunek stopy zwrotu do ryzyka dla wzorców danej grupy (miarą ryzyka jest odchylenie standardowe stóp zwrotu). W istocie σ to powszechnie używany w analizie finansowej wskaźnik Sharpe'a przy założeniu, iż stopa procentowa aktywów wolnych od ryzyka wynosi zero. Wskaźnik ten jest często wykorzystywaną przez inwestorów miarą efektywności inwestycji w dany walor, uwzględnia bowiem powiązane ze sobą dwa podstawowe czynniki decyzyjne:

oczekiwany zysk oraz ryzyko. W niniejszych badaniach założono, iż jeśli wartość bezwzględna tego wskaźnika przekracza określoną wielkość (przyjęto 6%), stanowi to podstawę do podjęcia decyzji kupna (gdy $s > 0,06$) lub krótkiej sprzedaży waloru (gdy $s < -0,06$); w przeciwnym przypadku należy utrzymać bieżącą pozycję inwestycyjną bez zmian. Tą regułą decyzyjną można więc wyrazić formułą:

- Jeżeli $s > 6\%$ (a akcje są krótko sprzedane) to dokonaj kupna akcji (K),
- Jeżeli $s < -6\%$ (a akcje są kupione) to dokonaj krótkiej sprzedaży akcji (S),
- W przeciwnym przypadku utrzymaj bieżącą pozycję inwestycyjną bez zmian (T).

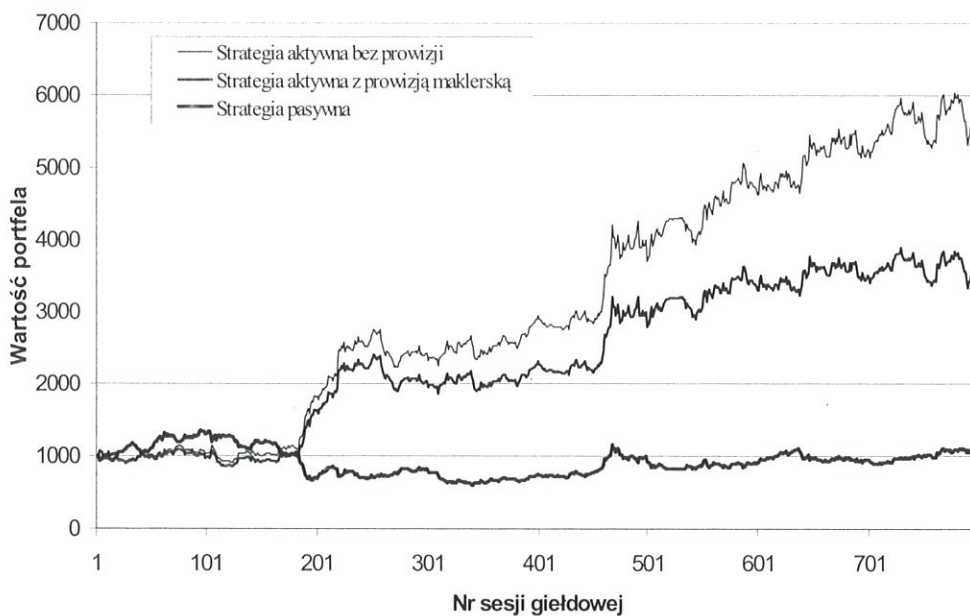
Wartości współczynnika s (dla danych uczących), oraz związane z nimi decyzje inwestycyjne przyporządkowane do poszczególnych klas wzorców zidentyfikowanych przez sieć SOM, umieszczono również w tabeli 1.

Tak zdefiniowaną aktywną strategię inwestycyjną zastosowano następnie w okresie obejmującym dane testowe (przy założeniu początkowej wartości portfela równej 1000). Zgodnie z przyjętym założeniem inwestor (bazujący na zbudowanym modelu) mógł zajmować jedynie dwa rodzaje pozycji inwestycyjnych: kupione akcje (za całość posiadanych aktualnie środków finansowych), oraz krótko sprzedane akcje (o wartości całego portfela w chwili sprzedaży). Wobec takich założeń model może generować zysk



Tabela 1. Wartości podstawowych wskaźników (obliczonych dla zbioru uczącego) oraz wynikających z nich decyzji inwestycyjnych dla poszczególnych grup wzorców. The values of basic indicators (calculated for the learning set) and related investment decisions assigned to particular 9 clusters (SOM neurons).

Nr grupy (neuronu SOM)	Liczba wzorców n	Śr. log. stopa zwrotu $r \times 1000$	Odch. std. $\sigma \times 1000$	$s = r / \sigma$	Decyzja
1	97	3,2	33,9	9,3%	K
2	96	1,9	31,4	5,9%	T
3	101	-3,8	36,9	-10,2%	S
4	182	-1,9	27,4	-6,8%	S
5	97	1,6	33,9	4,6%	T
6	200	2,8	28,1	10,1%	K
7	136	-0,7	27,3	-2,7%	T
8	122	2,3	42,5	5,3%	T
9	140	-4,5	26,3	-17,3%	S



Rys. 5. Wartość portfela w okresie testowym przy zastosowaniu trzech strategii inwestycyjnych: pasywnej, aktywnej opartej o decyzje analizowanego modelu przy zerowej prowizji maklerskiej, oraz aktywnej jw. przy prowizji wynoszącej 0,2% (Portfolio value changes during the test period for three investment strategies: passive, active based on the model decisions (no broker's commission) and active based on the model decisions with commission 0,2%). Źródło: obliczenia własne.

sycznego zastosowania sieci neuronowych typu perceptron w tym zagadnieniu. Również w przypadku przyjęcia niezerowej prowizji maklerskiej, pobieranej przy zmianie pozycji inwestycyjnej z krótkiej na długą lub odwrotnie i wynoszącej 0,2% wartości aktywów portfe-

la (co jest wielkością realną na rynku) uzyskano wysoką stopę zwrotu wynoszącą 238,9% (na ograniczenie kosztów wynikających z prowizji maklerskiej duży wpływ ma częste stosowanie decyzji typu „utrzymaj bieżącą pozycję” (T) co ogranicza znacznie liczbę transakcji).

Przebieg zmian wartości portfela dla rozwiązywanej aktywnej strategii inwestycyjnej (w porównaniu do pasywnej inwestycji polegającej na kupnie i utrzymywaniu portfela akcji przez cały okres) dla danych testowych przedstawiono na rys 5.

Otrzymane wyniki świadczą o wysokiej efektywności rozwiązywanej metody. Do jej dodatkowych zalet zaliczyć można elastyczność dostosowania parametrów strategii decyzyjnej modelu do indywidualnych preferencji inwestora (np. dotyczących ryzyka inwestycyjnego). Z kolei jako kierunek dalszych badań (stanowiących potencjalną tematykę kolejnych opracowań) należy wskazać kwestię doboru parametrów sieci SOM.

5. PODSUMOWANIE

Wykorzystanie grupowania danych przy pomocy samoorganizujących sieci neuronowych typu Kohonena do generowania finansowych strategii decyzyjnych na giełdzie papierów wartościowych to nowatorskie podejście, które zaproponowali autorzy

niezależnie od kierunku zmiany cen akcji (pod warunkiem trafnych decyzji) lub – w przypadku błędnych decyzji – przynosić straty.

Model zastosowany do danych w okresie testowym wygenerował poprawne decyzje w 56,07% przypadków. Okazuje się jednak, że ten wynik jest bardzo dobry przy założeniu, że generowane są poprawne decyzje w kluczowych momentach poprzedzających znaczne ruchy cen. Rzeczywistą efektywność modelu potwierdzają bowiem wyniki finansowe: na końcu okresu obejmującego dane testowe osiągnięto końcową wartość portfela (przy założeniu zerowej prowizji maklerskiej) równą 5430, to znaczy uzyskano całkowitą stopę zwrotu wynoszącą 443% (wobec zerowej stopy zysku w przypadku pasywnej inwestycji w akcje BRE Banku w tym okresie). Ten wynik jest lepszy niż w przypadku kla-

niniejszego artykułu. Jak pokazano, stworzony model przynosi całkiem dobre rezultaty i można przypuszczać, że wykorzystanie tych metod także na gruncie technologii materiałów przyniesie zadowalające efekty.

LITERATURA

- Barr, D.S., Mani G., *Using Neural Nets to Manage Investments*, AI Expert, 1994, 16-21.
- Beltratti, A., Margarita, S., Terna, P., *Neural Networks for Economic and Financial Modelling*, ITCP, London, 1996.
- Berry, M.J.A., Linoff, G.S., *Mastering data mining*, John Wiley & Sons, New York, 2000.
- Deboeck, G., Investment Maps of Emerging Markets, w: *Visual Explorations in Finance*, ed., Deboeck, G., Kohonen, T., Springer-Verlag, 1997, 83-105.
- Haefke, C., Helmenstein, C., Neural Networks in the Capital Markets: An Application to Index Forecasting, *Computational Economics*, 1996, 37-50.
- Hastie, T., Tibshirani, R., Friedman, J., *The elements of Statistical Learning*. Data mining, Inference, and Prediction, Springer, New York - Berlin - Heidelberg, 2001.
- Hiemstra, Y., Linear Regression Versus Backpropagation Networks to Predict Quarterly Stock Market Excess Returns, *Computational Economics*, 1996, 67-76.

- Kohonen, T., *Self-organizing maps*. Springer-Verlag, Berlin, 1995.
- Lula, P., Morajda, J., Klasyfikacja wzorców występujących w finansowych szeregach czasowych przy użyciu sieci neuronowych Kohonena, *Zeszyty naukowe AE w Krakowie*, nr 604, Prace z zakresu informatyki i jej zastosowań, Kraków, 2002.
- Morajda, J., Applications of neural networks in the financial markets - selected aspects, *Mat. 4. Konf. Neural Networks and Their Applications*, Zakopane, Częstochowa 1999.
- Morajda, J., Neural networks as predictive models in financial futures trading, *Mat. 4. Konf. Neural Networks and Their Applications*, Zakopane, Częstochowa 1999.
- Morajda, J., Neural Networks and Their Economic Applications, w: *Artificial Intelligence and Security in Computing Systems*, ed., Soldek, J., Drobiazgiwicz, L., Kluwer Academic Publishers, Boston-Dordrecht-London, 2003.
- Refenes, A.P., (ed.), *Neural networks in the capital markets*, Wiley, Chichester, 1995.
- Roning, J., Elsila, U., *Knowledge Discovery in Steel Industry Measurements*, University of Oulu, Oulu, 1998.
- Schoeneburg, E., Stock Price Prediction Using Neural Networks, *A Project Report, Neurocomputing*, vol. 2, 1990, 17-27.
- Trippi, R.R., Turban, E., *Neural Network in Finance and Investing*, Probus Publishing, Chicago, 1996.

Artykuł otrzymano 16 maja 2005 r.

