

Michał Sarapata

Uniwersytet Ekonomiczny w Katowicach

PROGNOZOWANIE FINANSOWYCH SZEREGÓW CZASOWYCH Z WYKORZYSTANIEM MODELI JEDNOKIERUNKOWYCH SIECI NEURONOWYCH

Wprowadzenie

Kluczową kwestią w procesie podejmowania decyzji inwestycyjnych jest w głównej mierze, poza analizą warunków teraźniejszych czy też panujących w przeszłości, umiejętność przewidywania konsekwencji zaplanowanych przedsięwzięć, a także wybór na tej podstawie wariantu optymalnego spośród zbioru możliwości alternatywnych. Sztuka precyzyjnego przewidywania nadchodzących w przyszłości poziomów zróżnicowanych wielkości ekonomicznych czy też, co z praktycznego punktu widzenia jest zazwyczaj sprawą bardziej istotną, zdolność do dokładnego wyznaczenia przyszłych kierunków zmian takich wielkości ekonomicznych, jak m.in. kursy walut, ceny akcji czy surowców, może stanowić fundamentalne źródło korzyści finansowych.

Rozwój technologii informatycznych, a przede wszystkim systemów przetwarzania danych, umożliwił wdrożenie złożonych metod matematycznych. Jednym z przykładów tego rodzaju metod są modele sztucznych sieci neuronowych, które należą do grupy metod opierających się na sztucznej inteligencji. Sztuczne sieci neuronowe mogą stanowić niezwykle użyteczne narzędzie znajdujące zastosowanie w analizach rynku finansowego.

Celem rozważań niniejszego artykułu jest zaprezentowanie możliwości prognostycznych sztucznych sieci neuronowych. Badania dotyczą tworzenia jednosesyjnych prognoz kierunków zmian kursów zamknięcia wybranych instrumentów finansowych. Powodzenie strategii inwestycyjnych jest w znacznej mierze zdeterminowane przez sygnały kupna i sprzedaży, dlatego do oceny poprawności poszczególnych modeli wykorzystano m.in. takie mierniki, jak: współczynnik zgodności kierunków zmian DS (ang. *Directional Symmetry*), współczynnik CU (ang. *Correct Up trend*) oraz CD (ang. *Correct Down trend*).

Przedmiotem badań są spółki notowane na Giełdzie Papierów Wartościowych w Warszawie:

- BRE Bank S.A. (BRE),
- PKN Orlen S.A. (PKNORLEN),
- TVN S.A. (TVN).

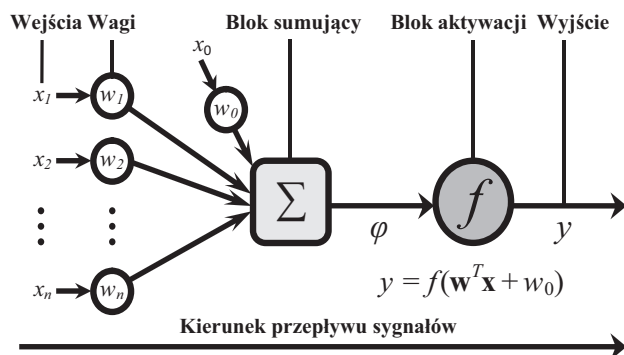
W doświadczeniach wykorzystano jeden z najpopularniejszych rodzajów sieci neuronowych, jakim jest perceptron wielowarstwowy (ang. *Multi-Layer Perceptron* – MLP) z jedną warstwą ukrytą, trenowany przy pomocy algorytmu wstecznej propagacji błędów z członem momentum oraz z adaptacyjnym dobowym współczynnikiem uczenia. Na końcu dokonano porównania kształtowania się zysków i strat z inwestycji w dany instrument finansowy na podstawie wygenerowanych przez zastosowane modele sygnałów kupna i sprzedaży.

W badaniach empirycznych dotyczących notowań trzech wybranych spółek użyto danych pochodzących z okresu od 15.04.2005 r. do 30.04.2010 r., pobranych ze strony internetowej Domu Maklerskiego BOŚ S.A. [WWW1].

W przeprowadzonych analizach zastosowano programy: Gretl (określenie charakteru poszczególnych szeregów czasowych), Matlab z uwzględnieniem zaimplementowanych w nim bibliotek służących tworzeniu modeli sieci neuronowych – Neural Network Toolbox™, a także operacjom na finansowych szeregach czasowych – Financial Toolbox™.

1. Teoretyczne podstawy sztucznych sieci neuronowych

Pierwowzorem sztucznych sieci neuronowych jest biologiczny układ nerwowy.



Rys. 1. Ogólny schemat sztucznego neuronu

Rys. 1 przedstawia ogólny schemat sztucznego neuronu. Każdy sztuczny neuron przetwarza pewną skończoną ilość wejść x_i , $i = 1, \dots, n$ na jedno wyjście y . Sygnały wejściowe mogą pochodzić albo z zewnątrz sieci (dane pierwotne),

albo z wyjść innych komórek nerwowych, które wchodzą w skład danej sieci (dane pośrednie). Synapsy w biologicznym neuronie zostały sprowadzone w przypadku ich sztucznego odpowiednika do roli operatorów przemnażających sygnały wejściowe przez współczynniki wagowe¹, które są ustalane w trakcie procesu uczenia sieci. Sygnały wejściowe są wprowadzane do neuronu poprzez połączenia o określonych współczynnikach wagowych w_i , $i = 1, \dots, n$, które z jednej strony odzwierciedlają siłę tych sygnałów, z drugiej zaś stanowią pamięć neuronu, gdyż są w stanie zapamiętać relacje zachodzące między tymi sygnałami a sygnałem wyjściowym. Istotne w stosowaniu sieci neuronowych jest to, że wagi w sztucznym modelu mogą przyjmować zarówno wartości dodatnie, jak i ujemne, przy czym pojedyncza synapsa może w trakcie uczenia zmieniać znak swojej wagi.

W bloku sumującym jest wyznaczana ważona suma wejść (obliczana jako kombinacja liniowa wektora sygnałów wejściowych \mathbf{x} oraz wektora odpowiadających im współczynników wag \mathbf{w}). Czasami również tak utworzona suma jest uzupełniana wyrazem wolnym (*bias*) – na rys. 1 oznaczonym symbolem w_0 . Bias traktuje się jako zwykłe wejście, a jego wagi podlegają zwykłemu procesowi uczenia, przy czym przyjmuje się, że jego wartość na wejściu zawsze wynosi 1. Można to zapisać w postaci wzoru:

$$\varphi = \sum_{i=1}^n w_i x_i + w_0 = \mathbf{w}^T \mathbf{x} + w_0 \quad (1)$$

Tak uzyskana wartość φ określa łączne pobudzenie neuronu². Przyjmuje się, że wartość ta odpowiada, z pewnym przybliżeniem, biologicznemu pojęciu sumarycznego (wypadkowego) postsynaptycznego potencjału neuronu³.

W bloku aktywacji następuje przekształcenie sygnału reprezentującego całkowite pobudzenie neuronu φ przez określoną funkcję aktywacji neuronu f (zwaną często również funkcją przejścia neuronu). Wartość wyznaczona przez tę funkcję stanowi wyjściową wartość y (sygnał wyjściowy) neuronu:

$$y = f(\mathbf{w}^T \mathbf{x} + w_0) = f(\varphi) \quad (2)$$

¹ Współczynniki te są więc odpowiednikami efektywności transmisji, a także oddziaływania biologicznego neurotransmitera w obrębie synapsy w neuronie biologicznym.

² Całkowite pobudzenie neuronu jest także określane w literaturze jako potencjał membranowy.

³ W każdej pojedynczej synapsie w biologicznym neuronie jest ustalana tzw. wartość PSP (ang. *postsynaptic potential*). W zależności od tego, czy waga konkretnej synapsy jest dodatnia czy ujemna, wyróżnia się EPSP (ang. *excitatory postsynaptic potential*) – pobudzający potencjał postsynaptyczny lub IPSP (ang. *inhibitory postsynaptic potential*) – hamujący potencjał postsynaptyczny. Sygnał łącznego pobudzenia powstaje poprzez procesy sumowania (przestrzennego oraz czasowego) tych potencjałów.

Pojedynczy model sztucznego neuronu ma stosunkowo niewielką moc obliczeniową, a także ograniczone możliwości gromadzenia i przetwarzania danych. Mankament ten może być wyeliminowany poprzez łączenie neuronów w sieć. Jeżeli tak utworzona sieć ma mieć wartość użytkową, to musi mieć ustalone wejścia oraz wyjścia (wyznaczające wynik obliczeń). Sygnały wejściowe są przetwarzane w neuronie, a następnie przesyłane do kolejnych neuronów. Proces ten trwa aż do momentu wyprowadzenia tych sygnałów na zewnątrz sieci. Współdziałanie neuronów oraz rodzaj połączeń między tymi neuronami, wejściami i wyjściami sieci określają architekturę (topologię) sieci neuronowej. Neurony będące elementami sztucznej sieci neuronowej najczęściej są zorganizowane w warstwach.

2. Wstępne określenie charakteru szeregów czasowych

Celem określenia charakteru szeregów czasowych wyznaczono wartości wykładnika Hursta.

Tabela 1

Wartości wykładnika Hursta dla finansowych szeregów czasowych poszczególnych spółek

	WARTOŚĆ WYKŁADNIKA HURSTA
BRE	0,620844
PKNORLEN	0,550987
TVN	0,568455

Z zaprezentowanych w tab. 1 wyników dotyczących wielkości wykładnika Hursta wynika, że dla każdego z analizowanych finansowych szeregów czasowych wartości tego parametru przekraczają poziom progowy, tj. 0,5, co świadczy o tym, że w badanych szeregach zachodzi długoterminowa zależność danych, tzn. występuje w nich efekt długiej pamięci (szeregi te są persystentne). Potwierdza to, że istnieje możliwość przewidywania przyszłych kierunków zmian kursów akcji rozpatrywanych spółek z wykorzystaniem wskaźników analizy technicznej.

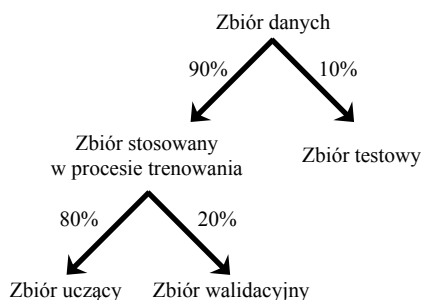
3. Ustalenie zbioru danych

Lista możliwych do zastosowania w modelach sieci neuronowych w charakterze informacji wejściowych wskaźników jest niemal nieograniczona. Co więcej,

można je poddawać różnego rodzaju przekształceniom. Pierwotnie w analizach, będących przedmiotem niniejszego punktu, przyjęto dla każdego modelu ten sam zestaw zmiennych wejściowych⁴:

- cenę otwarcia w czasie $t - 1$,
- cenę maksymalną w czasie $t - 1$,
- cenę minimalną w czasie $t - 1$,
- cenę zamknięcia w czasie $t - 1$,
- wolumen obrotów w czasie $t - 1$,
- logarytmiczną stopę zwrotu w czasie $t - 1$,
- cenę zamknięcia w czasie $t - 2$,
- 4-okresową średnią kroczącą ceny zamknięcia w czasie $t - 1$,
- oscylator akumulacji/dystrybucji w czasie $t - 1$,
- oscylator stochastyczny w czasie $t - 1$,
- 12-okresowy wskaźnik momentum w czasie $t - 1$,
- wskaźnik %R Williamsa w czasie $t - 1$,
- indeks negatywnego wolumenu NVI w czasie $t - 1$,
- 12-okresowy wskaźnik ROC (ang. *Rate Of Change*) w czasie $t - 1$,
- 12-okresowy wskaźnik VROC (ang. *Volume Rate Of Change*) w czasie $t - 1$.

Zastosowanie wyżej wymienionych parametrów spowodowało skrócenie wykorzystywanych w badaniach finansowych szeregów czasowych o 11 pierwszych obserwacji.



Rys. 2. Podział zbioru danych

Zgodnie z zaleceniami S. Osowskiego [2006, s. 95] oraz E. Gately’ego [1999, s. 72], dokonano podziału zbioru danych na podzbiory: uczący, walidacyjny oraz testowy w proporcjach ukazanych na rys. 2.

Do zbioru testowego przydzielono „najświeższe” 10% próbek ze zbioru danych. Z pozostałej zaś części 80% obserwacji wybrano do zbioru uczącego, reszta

⁴ W celu ustalenia optymalnego zestawu zmiennych wejściowych etap ten był poprzedzony licznymi badaniami empirycznymi na zadanych finansowych szeregach czasowych.

stanowiła zbiór walidacyjny. Szczegółowy podział zbiorów danych wraz z liczbami obserwacji wchodzących w skład tych zbiorów dla poszczególnych spółek został zaprezentowany w tab. 2.

Tabela 2

Podział zbioru danych dla poszczególnych spółek

Nazwa spółki	Zbiór stosowany w procesie trenowania				Zbiór testowy	
	Data	Liczba obserwacji	Zbiór uczący	Zbiór walidacyjny	Data	Liczba obserwacji
			Liczba obserwacji			
BRE	02/05/2005 – 29/10/2009	1130	904	226	30/10/2009 – 30/04/2010	125
PKN ORLEN	02/05/2005 – 29/10/2009	1130	904	226	30/10/2009 – 30/04/2010	125
TVN	02/05/2005 – 29/10/2009	1130	904	226	30/10/2009 – 30/04/2010	125

4. Konstrukcja sieci typu MLP – prognozowanie sygnałów kupna i sprzedaży

W niniejszym punkcie podjęto próbę wygenerowania decyzji spekulacyjnej na 1 sesję naprzód, jaką należałoby podjąć w celu wypracowania zysku. Dla każdej analizowanej spółki giełdowej zbudowano model perceptronu wielowarstwowego. W badaniach nad finansowymi szeregami czasowymi rozpatrywanych spółek przyjęto następujące parametry konstrukcji modeli:

- liczba neuronów w warstwie wejściowej jest zdeterminowana przez wymiar wektora wejściowego – każdy model ma ten sam zbiór sygnałów wejściowych,
- sieć typu MLP ma jedną warstwę ukrytą,
- struktura sieci zawiera połączenia neuronów typu „każdy z każdym”,
- w modelu sieci typu MLP jako funkcję aktywacji dla wszystkich neuronów warstwy ukrytej zastosowano tangens hiperboliczny, do warstwy wyjściowej zastosowano zaś liniową funkcję aktywacji,
- do modelu perceptronu wielowarstwowego zastosowano algorytm wstecznej propagacji błędów z członem momentum (ustalonym w opisywanym przypadku na zalecanym poziomie 0,9) oraz z adaptacyjnym współczynnikiem uczenia (początkowa wartość tego współczynnika została ustalona na poziomie 0,01),

– każdy model ma jedną zmienną wyjściową – kurs akcji poszczególnych spółek notowanych na Gieldzie Papierów Wartościowych w Warszawie na 1 sesję naprzód.

Sieci każdorazowo rozpoczynają proces nauki od losowo wybranych wartości początkowych wag, dlatego wszystkie eksperymenty zostały wykonane 5-krotnie. Czynność ta miała na celu zmniejszenie prawdopodobieństwa zatrzymania algorytmu w minimum lokalnym funkcji błędu.

Po wyznaczeniu wymienionych w punkcie 3 wskaźników przekonwertowano je do macierzy, a także usunięto 11 pierwszych obserwacji, które – ze względu na wyliczenia wspomnianych wskaźników – zawierały wartości nieokreślone.

Kolejnym etapem był podział danych na zbiór uczący, walidacyjny oraz testowy (zgodnie z informacjami zamieszczonymi w tab. 2), a także na wejścia i wyjścia sieci. Z uwagi na to, że wyjście sieci stanowił kurs akcji na 1 sesję naprzód, dokonano odpowiedniego przesunięcia kolumny zawierającej ceny zamknięcia dla każdej spółki. Tak podzielone zbiory poddano przeskalowaniu do przedziału $[-1; 1]$. Zabieg ten był podyktowany zastosowaniem tangensa hiperbolicznego jako funkcji przejścia w warstwie ukrytej.

Błąd sieci był sprawdzany na bieżąco, tj. w każdej epoce uczenia. Jeżeli zmierzał on w kierunku ustalonego celu, to wartość współczynnika uczenia ulegała każdorazowo powiększaniu poprzez przemnażanie jej przez czynnik lr_inc . W sytuacji zaś, gdy następowało zwiększanie błędu sieci, przy czym tempo tego wzrostu przekraczało wartość wyznaczoną przez parametr max_perf_inc , współczynnik uczenia był korygowany poprzez przemnażanie jego wartości przez mnożnik lr_dec . W przypadku skonstruowanego na potrzeby niniejszego punktu modelu, wielkości parametrów lr_inc , max_perf_inc , lr_dec zostały ustalone na poziomie odpowiednio: 1,05, 1,04 oraz 0,7.

Opisany algorytm kończy się w przypadku spełnienia jednego z poniższych warunków [Demuth, Beale, Hagan, 1992-2010, s. 16-345 – 16-347]:

- liczba epok osiągnęła maksymalną wartość, jaka została ustalona dla danej sieci $(1000)^5$,
- został przekroczony maksymalny czas trenowania sieci ($t \rightarrow \infty$),
- błąd modelu osiągnął pożądane minimum (0),
- gradient błędów sieci spadł poniżej parametru min_grad ($1E-10$),
- błąd wyznaczony na podstawie zbioru walidacyjnego uległ zwiększeniu więcej razy niż ustalona wartość parametru max_fail , licząc od momentu, kiedy po raz ostatni jego wartość spadła (100).

Początkową liczbę neuronów w warstwie ukrytej ustalono na poziomie średniej geometrycznej liczby neuronów w warstwie wejściowej n oraz wyjściowej m , tj. $\sqrt{n \times m}$ [Rybarczyk, red., 2008]. W sytuacji gdy błąd dla zbioru walidacyjnego nie osiągał satysfakcjonującej wartości, zwiększano liczbę neuronów w warstwie

⁵ Wartości umieszczone w nawiasach odpowiadają parametrom użytym w analizowanym przypadku.

ukrytej. Gdy wspomniany błąd ulegał zwiększaniu przed uzyskaniem pożądanego pułapu, zredukowano liczbę neuronów tej warstwy.

Oceny jakości poszczególnych modeli dokonywano na podstawie pierwiastka ze średniokwadratowego błędu procentowego RMSPE, współczynnika korelacji Pearsona (r) oraz współczynników: DS, CU oraz CD. Optymalny dla konkretnego przypadku model sieci wyznaczano na podstawie wyników dla zbioru testowego.

Za każdym razem po ukończeniu procesu trenowania dokonywano symulacji sieci na wszystkich zbiorach danych wejściowych. Otrzymane wyniki dla zbioru testowego przekształcono do jednostek, w jakich były wyrażone dane źródłowe (poprzez zastosowanie procesu odwrotnego do przeprowadzonego wcześniej skalowania), a następnie wyniki te posłużyły do analizy jakości skonstruowanej sieci.

Wyniki najlepszych modeli neuronowych dla poszczególnych spółek zaprezentowano w tab. 3.

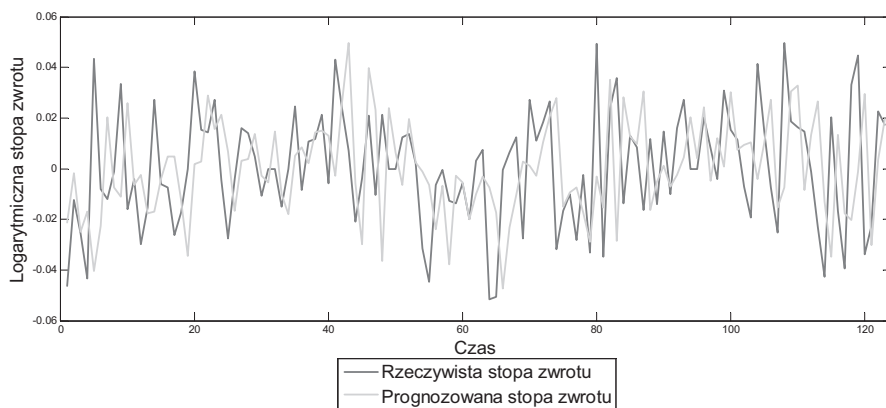
Tabela 3

Wybrane mierniki oceny jakości prognoz szeregów czasowych na podstawie danych pochodzących ze zbioru testowego najlepszego modelu sieci typu MLP dla poszczególnych spółek

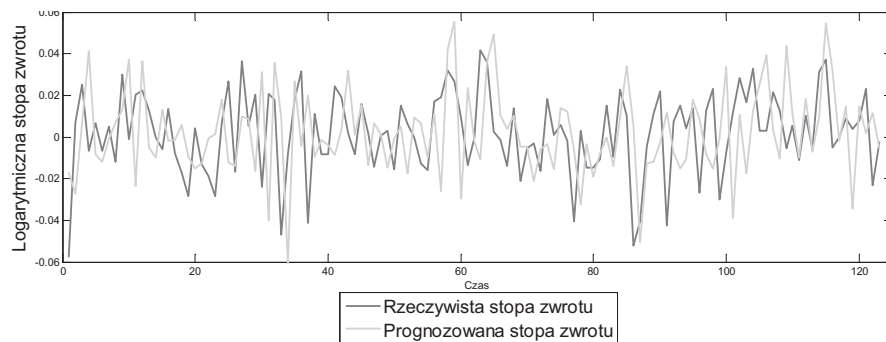
Nazwa spółki	Liczba neuronów	RMSPE	r	DS	CU	CD
BRE	16 – 6 – 1	2,84%	0,9255	58,54%	69,09%	70,00%
PKNORLEN	16 – 19 – 1	2,21%	0,9637	57,72%	60,87%	59,62%
TVN	16 – 6 – 1	2,75%	0,9654	53,66%	60,00%	60,34%

Wartości pierwiastka ze średniokwadratowego błędu procentowego RMSPE kształtują się na zbliżonym, zadowalająco niskim poziomie (od 2,21% dla PKNORLEN do 2,84% dla BRE). Dla każdej z badanych spółek osiągnięto wartość współczynnika korelacji Pearsona powyżej 0,9 (najwyższą dla TVN, a najniższą dla BRE). Wielkości miary zgodności kierunków zmian DS przekraczają 50%. Znacznie lepsze rezultaty uzyskano dla współczynników CU i CD. Miary te w większości przypadków przekraczają 60%. Dla spółki BRE wyniosły one odpowiednio: 69,09% i 70%.

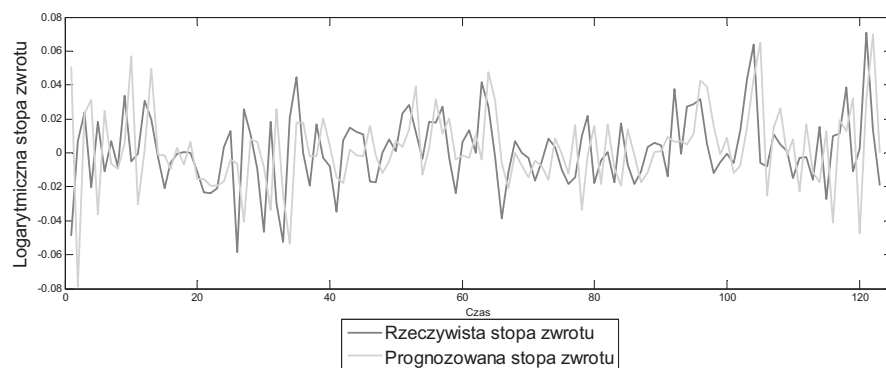
Jednosesyjne prognozy kursów zamknięcia analizowanych spółek wykorzystano do wyznaczenia przewidywań w odniesieniu do przyszłych wartości logarytmicznych stóp zwrotu. Rys. 3-5 przedstawiają wykresy rzeczywistych logarytmicznych stóp zwrotu wraz z ich prognozami.



Rys. 3. Wykres rzeczywistej i prognozowanej wartości logarytmicznych stóp zwrotu – BRE Bank S.A.



Rys. 4. Wykres rzeczywistej i prognozowanej wartości logarytmicznych stóp zwrotu – PKN Orlen S.A.



Rys. 5. Wykres rzeczywistej i prognozowanej wartości logarytmicznych stóp zwrotu – TVN S.A.

5. Strategia inwestycyjna

Celem dokonania głębszej analizy prognoz wygenerowanych przez omawiany model sieci typu MLP, zastosowano prostą strategię inwestycyjną polegającą na przekształceniu danych wyjściowych tego modelu na sygnał decyzyjny, która może dotyczyć nabycia, sprzedaży bądź wstrzymywania się od transakcji związanych z akcjami wybranej spółki giełdowej. Została przyjęta następująca reguła generowania sygnału:

„kupuj”, gdy:

$$\ln(y_t) - \ln(y_{t-1}) > 1\% \quad (3)$$

„sprzedaj”, gdy:

$$\ln(y_t) - \ln(y_{t-1}) < -1\% \quad (4)$$

„czekaj”, gdy:

$$-1\% \leq \ln(y_t) - \ln(y_{t-1}) \leq 1\% \quad (5)$$

gdzie y_t oraz y_{t-1} oznaczają kolejne notowania kursów giełdowych konkretnej spółki.

Hipotetyczny kapitał początkowy ustalono na poziomie 10 000 zł. Następnie poszukiwano pierwszego sygnału „kupuj”. W sytuacji gdy taki sygnał został wygenerowany, dokonywano transakcji nabycia danego waloru za pełną kwotę 10 000 zł. Dopiero po odnalezieniu sygnału „sprzedaj” wykonywano transakcję polegającą na sprzedaży wszystkich posiadanych w tym czasie akcji. Kolejne transakcje były przeprowadzane przy każdorazowej zmianie rekomendacji na przeciwną. Sygnał „czekaj” oznaczał brak jakiegokolwiek działania, tj. brak inwestycji lub brak sprzedaży. Omawiane postępowanie odbywało się aż do momentu wygenerowania ostatniego sygnału. Jeżeli w wyniku zastosowanej procedury doszło do sytuacji, w której po jej zakończeniu w portfelu inwestora znajdowała się określona liczba akcji, to kapitał końcowy był wyznaczany przez pomnożenie liczby tych akcji przez cenę zamknięcia z ostatniego dnia analizowanego okresu. Wartość kapitału końcowego została w kolejnym kroku odniesiona do wartości, jaka zostałaby uzyskana w efekcie zastosowania strategii „kup i trzymaj”, która polegała na nabyciu akcji poszczególnych spółek w pierwszym dniu rozpatrywanego okresu po kursie z tego dnia i ich zbyciu po kursie z dnia ostatniego.

Wyniki zastosowania wyżej opisanej strategii przedstawiono w tab. 4. Wszystkie kalkulacje były wykonywane na zbiorze testowym⁶.

Tabela 4

Wartość kapitału końcowego otrzymanego w wyniku zastosowania strategii opartej na modelu MLP w porównaniu ze strategią „kup i trzymaj” oraz liczba wygenerowanych sygnałów i dokonanych transakcji

Nazwa spółki	Kapitał końcowy		Liczba sygnałów		Liczba transakcji
	MLP	Kup i trzymaj	Kupuj	Sprzedaj	
BRE	13 118,96 zł	10 184,18 zł	40	43	32
PKNORLEN	14 293,59 zł	12 661,06 zł	44	37	41
TVN	14 655,15 zł	12 676,90 zł	42	39	37

Podsumowanie

Z przeprowadzonych analiz wynika, że strategia inwestycyjna oparta na modelu sieci typu MLP przyniosła zysk w badanym okresie dla wszystkich rozpatrywanych spółek. Co więcej, strategia ta umożliwiła uzyskanie wyższych zysków od tych, jakie osiągnięto by, stosując strategię „kup i trzymaj”. Należy zwrócić uwagę, że każdy model sieci wygenerował relatywnie dużą liczbą transakcji, co przy uwzględnieniu prowizji maklerskiej spowodowałoby zmniejszenie wartości zysku. Nie zmienia to jednak faktu przydatności tego typu modeli sztucznych sieci neuronowych w prognozowaniu finansowych szeregów czasowych, a jedynie akcentuje problem wyboru bardziej wyszukanych modeli decyzyjnych w rzeczywistym procesie inwestycyjnym.

Na podstawie przeprowadzonych analiz można stwierdzić, że konstrukcja modelu sieci neuronowej dla finansowych szeregów czasowych o wysokiej częstotliwości z pewnością nie jest zadaniem prostym. Należy mieć na uwadze to, że stosowanie metod opartych na sztucznych sieciach neuronowych nie zawsze prowadzi do uzyskania w pełni satysfakcjonujących wyników. Możliwe jest jednakże stosowanie prostych strategii opartych na modelach neuronowych, które przynoszą spore zyski – bez konieczności przeprowadzania wyrafinowanych badań rynku czy specjalistycznej wiedzy na jego temat.

⁶ W rzeczywistości taka strategia nie powinna być jedynym fundamentem podejmowania decyzji inwestycyjnych. Najlepszym rozwiązaniem jest stosowanie jej w połączeniu z innymi metodami w taki sposób, aby pełniły one razem funkcję weryfikatora. Propozycje systemów inwestycyjnych przedstawia m.in. E. Gately [1999, s. 135].

Literatura

- Demuth H., Beale M., Hagan M., 1992-2010: *Neural Network Toolbox™ User's Guide. Version 6*. The MathWorks.
- Gately E., 1999: *Sieci neuronowe. Prognozowanie finansowe i projektowanie systemów transakcyjnych*. WIG-Press, Warszawa.
- Osowski S., 2006: *Sieci neuronowe do przetwarzania informacji*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
- Rybarczyk A. red., 2008: *Sztuczne sieci neuronowe. Laboratorium*. Wydawnictwo Politechniki Poznańskiej, Poznań.
- [WWW1] <http://bossa.pl/pub/ciagla/omega/omegacgl.zip> [dostęp: 30.04.2012].

APPLICATION OF FEED-FORWARD NEURAL NETWORK MODELS IN FINANCIAL TIME SERIES FORECASTING

Summary

The aim of this paper is to show the prognostic capabilities of artificial neural networks. The analysis concerned creating one-step-ahead forecasts of changes in directions of chosen closing stock prices. One of the most popular types of neural networks, namely multi-layer perceptron with one hidden layer trained with backpropagation algorithm with gradient descent momentum and an adaptive learning rate was used in experiments.