

ROLA SZTUCZNYCH SIECI NEURONOWYCH W PROGNOZOWANIU FINANSOWYCH SZEREGÓW CZASOWYCH

PAWEŁ JAMRÓZ*

1. Wstęp

Szybki rozwój rynków finansowych, wzrost konkurencji oraz popularyzacja nowoczesnych technologii informatycznych spowodował wzrost zainteresowania modelami matematycznymi, w tym sztucznymi sieciami neuronowymi (SSN), jako narzędziami analiz finansowych szeregów czasowych. Powstały one z interdyscyplinarnej syntezy nauk tradycyjnych obejmujących biologię, fizykę i matematykę, naśladujących działanie biologicznych struktur mózgowych.

Początek sztucznych sieci neuronowych przypisuje się na rok 1943, w którym to opublikowana została pionierska praca W.S. McCullocha i W. Pittsa¹, zawierająca po raz pierwszy opis matematyczny modelu komórki nerwowej. Model McCullocha-Pittsa był punktem wyjścia do konstrukcji najprostszej jednokierunkowej sieci neuronowej o nazwie **perceptron**. Historię badań nad SSN omówiono szerzej m.in. w: [3], [8], [13].

Sieć neuronowa składa się z sieci węzłów obliczeniowych zwanych neuronami i ich połączeń. Dostosowanie sieci do rozwiązania określonego problemu odbywa się poprzez jej uczenie przy użyciu ciągu typowych pobudeń i odpowiadających im pożądanym reakcji, a nie przez sprecyzowanie algorytmu i zapisanie go w postaci programu, jak w przypadku stosowania metod tradycyjnych. Dzięki czemu sieci neuronowe mogą być stosowane tam, gdzie

* Mgr Paweł Jamróz, Uniwersytet w Białymstoku.

¹ Praca ta została wydana w Bulletin of Mathematical Biophysics, pod tytułem *Alogical Calculus of Ideas Immanent in Nervous Activity*.

zastosowanie tradycyjnych metod napotyka wielkie trudności, szczególnie w zadaniach wymagających kojarzenia informacji. [10, s. 234]

SSN charakteryzują się cechami zarezerwowanymi dotychczas dla organizmów żywych jak zdolność do „uczenia się”, umiejętność abstrakcji czy odporność na uszkodzenia. Dzięki możliwości uczenia się oraz swoistej strukturze, sztuczne sieci neuronowe cechuje [12, s. 2]:

- zdolność przetwarzania informacji rozmytych, chaotycznych, niekompletnych, a nawet sprzecznych;
- szybkie i efektywne przetwarzanie dużych ilości danych;
- przetwarzanie równoległe, rozproszone;
- skojarzeniowy dostęp do informacji zawartej w sieci (tzw. pamięć skojarzeniowa).

Obszar zastosowania sieci jest rozległy i obejmuje m.in. [por. 14 i 10, s. 234]:

- prognozowanie i ocena ryzyka ekonomicznego;
- prognozowanie zmian cen rynkowych (indeksów, walut);
- ocena zdolności kredytowej podmiotów;
- prognozowanie zapotrzebowania na energię elektryczną;
- rozpoznawanie wzorców (znaków, liter, sygnałów sonarowych);
- klasyfikowanie obiektów;
- diagnostyka medyczna;
- dobór pracowników.

Dzięki swej zdolności do uczenia się i uogólniania, właściwości te pozwalają wykorzystać sieci w różnych dziedzinach gospodarki, gdzie istnieje potrzeba przewidywania pewnych sygnałów na podstawie danych wejściowych.

2. Model sztucznego neuronu

Sztuczny neuron należy traktować jako przetwornik, który w wyniku przetworzenia sygnałów wejściowych generuje odpowiednie sygnały wyjściowe. Obejmuje on następujące elementy [5, s. 90]:


- połączenia wejściowe, z którymi są powiązane pewne liczby zwane wagami synaptycznymi;
- element sumujący pobudzenie uzyskiwane z połączeń wejściowych;
- element progowy, dający na wyjściu stan wysoki bądź niski, w zależności od wartości sumy.

Model sztucznego neuronu przedstawia rysunek 1.

Przedstawiony poniżej model sztucznego neuronu składa się z:

- x_i – sygnałów wejściowych (dla $i = 1, \dots, n$);

- w_i – wag synaptycznych poszczególnych sygnałów wejściowych (dla $i = 1, \dots, n$), waga może być dodatnia (pobudzająca) lub ujemna (hamująca) lub wynosić zero (brak połączeń między neuronami);
- U – potencjał membranowy (łączne pobudzenie neuronu);
- $F(U)$ – funkcja aktywacji neuronu;
- Y – sygnał wyjściowy uogólniony (wartość funkcji aktywacji).



Rys. 1. Model sztucznego neuronu

Źródło: Opracowanie własne na podstawie [3, s. 37] i [5, s. 90].

Na podstawie danych, wprowadzonych na wejścia sieci, oblicza się całkowite pobudzenie neuronu U najczęściej jako kombinację liniową wejść, często uzupełnioną wyrazem wolnym (zwanym *bias* – w_0), co można wyznaczyć według wzoru [12, s. 3]:

$$U = \sum_{i=1}^n w_i x_i = \mathbf{w}^T \mathbf{x} \quad , \quad (1)$$

gdzie:

$\mathbf{x} = [x_i]$ jest wektorem sygnałów wejściowych,

$\mathbf{w} = [w_i]$ jest wektorem wag, które z jednej strony wyrażają stopień ważności informacji przekazywanej i-tym wejściem, a z drugiej stanowią swego rodzaju pamięć neuronu.

Wartość sygnału wyjściowego Y przekazywanego przez neuron zależy od jego całkowitego pobudzenia (stanu neuronu), co może być opisane różnymi funkcjami np. prostą funkcją liniową, wówczas [13, s. 144]:

$$Y = f(U) \quad , \quad (2)$$

gdzie:

f – jest pewną funkcją, zwaną funkcją aktywacji lub funkcją przejścia neuronu, a jej postać określa typ i obszar jego zastosowań.

Inną postacią funkcji aktywacji jest funkcja skoku jednostkowego (progowa), zaproponowana w modelu McCullocha i Pittsa, w tym przypadku sygnał wyjściowy jest równy [3, s. 38 i por. 13, s. 144]:

$$Y = \begin{cases} 1 & \text{gd}y \ U > b \\ 0 & \text{gd}y \ U \leq b \end{cases}, \quad (3)$$

gdzie:

b – zadana stała wartość progowa.

Zatem neuron pozostaje w spoczynku, dopóki jego całkowite pobudzenie jest mniejsze od pewnej wartości progowej b , po przekroczeniu której neuron emituje sygnał jednostkowy.

Funkcja aktywacji może przybierać zarówno postać liniową, jak i postacie nieliniowe, w których charakter zależności wiążącej sygnał wyjściowy z sygnałami wejściowymi może być praktycznie dowolny. Wyróżnia się następujące typy funkcji aktywacji [5, s. 91]:

- funkcja liniowa,
- funkcja skoku jednostkowego,
- funkcja nieliniowa (np.: logistyczna (zwana sigmoidalną), tangens hiperboliczny, signum, sinus, BAM, BSB) [szerzej 12, s. 4-5 i 6, s. 19-20].

3. Architektura SSN

Pojedyncze neurony posiadają ograniczone możliwości przetwarzania i gromadzenia informacji, dlatego stosuje się sieci neuronowe składające się z szeregu połączonych ze sobą neuronów. Sygnały wprowadzane na wejście neuronu są przetwarzane zgodnie z relacjami (1) oraz (2) i przesyłane do innych neuronów. Proces ten powtarza się aż do chwili, w której przesyłany przez sieć sygnał dotrze do neuronów warstwy wyjściowej lub spełnione zostanie inne kryterium zakończenia działania sieci. Różnice między sieciami wynikają przede wszystkim z liczby neuronów i ich wzajemnego układu (topologii).

Do najczęściej spotykanych typów sieci neuronowych zalicza się [4, s. 15]:

- **sieci jednokierunkowe** – neurony pogrupowane są w warstwy, wyróżnia się warstwę wejściową, warstwę ukryte oraz warstwę wyjściową; przepływ sygnałów odbywa się tylko w jednym kierunku od warstwy wejściowej do warstwy wyjściowej;
- **sieci rekurencyjne** (ze sprzężeniem zwrotnym) – neurony tworzą warstwy, sygnał może być przesyłany od neuronów warstwy wejściowej do neuronów warstwy wyjściowej, jak również (dzięki występującym sprzężeniom zwrotnym) w kierunku przeciwnym;

- **sieci o radialnych funkcjach bazowych (RBF)** – neurony tworzą trzy warstwy: warstwę wejściową, warstwę ukrytą o neuronach radialnych i wyjściową o neuronach posiadających liniową lub logistyczną funkcję aktywacji [szerzej 12, s. 8-16];
- **sieci komórkowe** – nie występują warstwy, neurony komunikują się wyłącznie ze swoimi najbliższymi sąsiadami (połączenia nieliniowe i opisane przez układ równań różniczkowych).


Najbardziej popularnym typem sieci neuronowych jest sieć jednokierunkowa (*feedforward*), w której przepływ sygnałów odbywa się w jednym kierunku, od wejścia do wyjścia. Typowym przykładem sieci jednokierunkowej jest perceptron wielowarstwowy. Na rysunku 2 przedstawiono przykładową strukturę wielowarstwowej sieci jednokierunkowej.

Pojedyncze neurony łączone są w rozległe sieci, których topologia może być bardzo różnorodna, zazwyczaj jednak sieć taka składa się z tzw. warstwy wejściowej, jednej lub kilku warstw ukrytych (pośrednich) i warstwy wyjściowej. [2, s. 146-7] Zasadnicze przetwarzanie neuronowe odbywa się w warstwach ukrytych oraz w warstwie wyjściowej. Połączenia między neuronami sąsiednich warstw mogą być realizowane na wiele sposobów (liczbę możliwych struktur sieci dla 20 neuronów szacuje się na 10^{96} [por. 8, s. 20]. Najczęściej korzysta się ze schematu połączeń typu „każdy z każdym”. Warstwa wyjściowa generuje sygnały wyjściowe dla całej sieci, stąd liczba elementów tej warstwy powinna odpowiadać liczbie zmiennych charakteryzujących wymiar rozwiązywanego problemu. Wprowadzenie warstw ukrytych (o nieliniowej funkcji aktywacji) znacznie poszerza zakres odwzorowań, które sieć potrafi zrealizować. [12, s. 10-11]

W toku badań podjęto próbę określenia odpowiedniego algorytmu uczenia sieci w celu osiągnięcia trafnego wyniku. Wartości współczynników wagowych dobierane są przez sieć neuronową w czasie procesu jej uczenia. Podstawowym celem procesu uczenia jest taki dobór współczynników wagowych, aby sieć mogła w jak najlepszy sposób rozwiązywać określonej klasy problem. Wyróżnia się dwie główne metody uczenia sieci neuronowej [por. 5, s. 92]:

- **z nadzorem** (nauczycielem) – oznacza uczenie sieci pod kontrolą zewnętrznego nauczyciela. Wagi są dobierane w ten sposób, aby zminimalizować błąd sieci tj. różnicę sygnału wyjściowego oraz pożądanego sygnału wyjściowego. W następnych cyklach sieć dobiera wagi w taki sposób, aby jej odpowiedzi były jak najbardziej zbliżone do wzorców uczących;
- **bez nadzoru** – charakteryzuje się występowaniem elementu rywalizacji między neuronami, które współzawodniczą ze sobą, aby stać się neuronami aktywnymi (tylko jeden neuron może być aktywny). Zwycięża ten neuron, którego wartość wyjściowa jest największa, zdobywa on

przywilej dalszego uczenia się. Sieci uczone tym sposobem, na podstawie dostarczonych wartości wejściowych ustalają istotne informacje, znajdują zależności statystyczne, aż wreszcie dokonują grupowania zbioru próbek dostarczonych na wejściu.



Rys. 2. Przykładowa struktura wielowarstwowej sieci jednokierunkowej

Źródło: Opracowanie własne na podstawie [10, s. 235] i [14].

Metod uczenia się sieci, czyli algorytmów dobierania wartości współczynników wag jest wiele, najbardziej popularna jest metoda tzw. **wstecznej propagacji błędu** (gradientowa). Algorytm wstecznej propagacji określa strategię doboru wag w sieci wielowarstwowej. [por. 2, s.147] Metoda ta polega na rzutowaniu wstecz błędu neuronu wyjściowego do wszystkich tych neuronów, których sygnały stanowiły jego wejścia. Postępując konsekwentnie w ten sposób można wyliczyć przybliżone błędy wszystkich neuronów w kolejnych warstwach, a tym samym określić korektę współczynników wagowych tych neuronów. [szerzej 12, s. 22-26]

Poprawnie zbudowana sieć musi mieć wystarczający stopień złożoności, żeby w jej strukturze można było (w toku uczenia) wykształtować potrzebne połączenia i struktury [8, s. 53]. Dzięki trzem warstwom możliwe jest utworzenie dowolnych obszarów i zrealizowanie dowolnego odwzorowania, dlatego najczęściej są stosowane sieci trójwarstwowe. Zakłada się, że liczba elementów zbioru treningowego nie może być mniejsza niż liczba szacowanych wag. Przy małej liczności zbioru treningowego często konieczna jest redukcja

liczby neuronów wejściowych. Dane wprowadzane do sieci nie powinny być ze sobą skorelowane. Korzystne jest natomiast dołączenie danej z pozoru mało przydatnej, gdyż sieć sama w procesie uczenia dokonuje selekcji. SSN bywają „nadgorliwe” wyszukując zależności, które w rzeczywistości nie występują. Nadmierne trenowanie (uczenie) prowadzi do efektu „uczenia się na pamięć” wzorców zawartych w zbiorze treningowym, co oznacza utratę przez sieci zdolności do generalizacji wiedzy. Celem testowania sieci jest ocena poprawności jej działania. [12, s. 33-34]

Sieci o zbyt dużej liczbie neuronów i powiązań między nimi mogą dopasowywać sieć do nieistotnych szczegółów, co prowadzi do **przeuczenia** sieci. Natomiast zbyt mała liczba neuronów w sieci powoduje, że sieć dokonuje prognozy niedokładnie. **Niedouczenie** sieci wynika z tego, że błąd dopasowania odpowiedzi sieci do wartości zadanych na wyjściu jest zbyt duży. Sieć niedouczona będzie zaliczać do danej kategorii dane wejściowe, które do niej nie należą. [10, s. 239]

4. Mierniki pomiaru jakości działania sieci

Algorytm wstecznej propagacji błędu minimalizuje błąd popełniany przez sieć na danych treningowych. Aby ocenić rzeczywistą jakość działania modelu, należy jednak przetestować go również na danych testowych, nie uwzględnionych we wcześniejszym procesie uczenia. [13, s. 156]

Do wyrażenia jakości działania sieci wykorzystuje się miary opierające się na wartości funkcji błędu generowanego przez sieć. Konstrukcja miernika jest niezależna od przyjętej dla danej sieci definicji minimalizowanej w trakcie uczenia funkcji kryterium (funkcji celu). Naturalnym miernikiem jakości modelu neuronowego jest *suma kwadratów odchyleń* (SSE) między wartościami rzeczywistymi i teoretycznymi [4, s. 86]:

$$SSE = \sum_{p=1}^R \sum_{i=1}^M (\hat{y}_{pi} - y_{pi})^2, \quad (4)$$

gdzie:

R – liczba elementów w zbiorze uczącym;

M – liczba neuronów w warstwie wyjściowej;

\hat{y}_{pi} - wartość zakładana;

y_{pi} - wartość otrzymana na wyjściu sieci.

Wadą powyższego miernika jest brak możliwości porównań sieci opisujących różne zjawiska oraz zależność od liczby obserwacji wykorzystanych przy konstrukcji modelu.

Częściowo wad tych nie posiadają klasyczne metryki i powszechnie używane miary dokładności prognoz, które mogą być wykorzystywane zarówno do oceny jakości pracy sieci, jak i monitorowania jej stanu podczas treningu [13, s. 157 oraz por. 11, s. 206]:

$$MSE = \frac{\sum_{i=1}^N (y_i^* - y_i)^2}{N}, \quad (5)$$

gdzie:

MSE – błąd średniokwadratowy;

y_i^* - wartość rzeczywista prognozy dla i -tego wzorca testowego;

y_i - wartość otrzymana na wyjściu sieci;

N – rozmiar próbki testowej (wzorców uczących).

Pierwiastek kwadratowy błędu średniokwadratowego ($RMSE$) jest miernikiem opisującym jakość sieci [4, s. 86]:

$$RMSE = \sqrt{MSE}. \quad (6)$$

Dogodnym miernikiem umożliwiającym porównywanie jakości różnych sieci jest znormalizowany błąd średniokwadratowy ($nRMSE$) [4, s. 87]:

$$nRMSE = \frac{RMSE}{s_d}, \quad (7)$$

gdzie:

s_d – odchylenie standardowe obliczone dla zbioru wartości oczekiwanych na wyjściu sieci.

W przypadku, gdy na wejściu mogą się pojawiać tylko wartości z pewnego zbioru o małej liczbie elementów (np. wartości binarne), miernikiem może być procent poprawnych odpowiedzi [por. 13, s. 158]:

$$\frac{\text{liczba poprawnych odpowiedzi}}{N} * 100\%. \quad (8)$$

Miernikiem znajdującym zastosowanie do oceny jakości sieci służącej do analizowania szeregów czasowych jest współczynnik poprawności szacowania kierunku zmian [4, s.88]:

$$d = \frac{1}{N} \sum_{i=1}^N a_i, \quad (9)$$

gdzie:

$$a_i = \begin{cases} 1 & \text{gdy } (y_t - y_{t-1})(\hat{y}_t - \hat{y}_{t-1}) > 0 \\ 0 & \text{w przeciwnym przypadku} \end{cases}$$

W przypadku analizy danych w postaci szeregów czasowych, można porównać oszacowanie przyszłej wartości szeregu uzyskane za pomocą sieci z wartością tzw. prognozy trywialnej. Regułą prognozy trywialnej zakłada, że najlepszym oszacowaniem kolejnej wartości szeregu jest wartość go poprzedzająca. Miernikiem porównującym obie wielkości jest współczynnik Theila (współczynnik pojemności informacyjnej) [4, s. 87]:

$$T = \frac{\sqrt{\sum_{i=1}^R (\hat{y}_i - y_i)^2}}{\sqrt{\sum_{i=1}^R (y_i - y_{i-1})^2}}. \quad (10)$$

Jeżeli współczynnik T przyjmuje wartości wyższe od 1, to oznacza, że sieć generuje wyniki gorsze od wartości prognozy, a im bliższe 0, tym jakość prognozy jest lepsza.

W systemach służących do prognozowania stosowane mogą być popularne miary dokładności prognoz jak: absolutny błąd procentowy ($MAPE$), średniokwadratowy błąd procentowy ($RASE$), średniokwadratowy błąd procentowy ($RMSE$), procentowy absolutny błąd maksymalny (MAE), skorygowany maksymalny błąd prognozy ($\overline{MP\bar{E}}$), współczynnik rozbieżności Theila (I^2), współczynnik janusowy (J), $NAIC$ (Normalized Akaike's Information Criterion) i wiele innych [szerzej 7, s. 91-93; 13, s.157-160; 12, s. 64-68; 11, s. 203-209; 4, s. 88]. Definiowanych jest wiele mierników, które uwzględniają nie tylko różnice pomiędzy wartościami obliczonymi i wartościami zakładanymi, ale również złożoność modelu sieciowego [szerzej 4, s. 87-88].

5. Prognozowanie indeksu WIG20 na rynku kapitałowym przy pomocy SSN

Jednym z zastosowań sztucznych sieci neuronowych jest badanie finansowych szeregów czasowych. Rzeczywistość dostarcza wielu przykładów takich szeregów, z których każdy może być obiektem badań i analiz prowadzonych za pomocą sieci neuronowych. Przedmiotem badań prowadzonych za pomocą SSN są najczęściej: ceny akcji, kursy walut, indeksy giełdowe, stopy zwrotu oraz sygnały kupna/sprzedaży.

Wykorzystanie sieci neuronowych do prognozowania szeregów czasowych wymaga [12, s. 98]:

- zdefiniowania zmiennej prognozowanej oraz zmiennych, które będą pełniły rolę deskryptorów;
- określenia topologii sieci;
- wybrania okresu, z którego będą pochodziły dane wykorzystane do trenowania;
- ustalenia horyzontu prognozy.

Modelowanie krótkookresowych procesów na rynkach kapitałowych opiera się zwykle na technicznej analizie ruchów cenowych poszczególnych walorów. Do celów prognostycznych wykorzystywane są więc różnego rodzaju metody analizy szeregów czasowych. Metody szeregów czasowych opierają się na analizie chronologicznej sekwencji obserwacji prognozowanej zmiennej. Ich celem jest wykrycie zależności i korelacji między pomiarami wykonanymi w różnych momentach. Zidentyfikowane wzorce zachowania prognozowanej zmiennej są następnie ekstrapolowane w przyszłość. Istnieje cały szereg różnych metod zaliczanych do tej klasy, począwszy od tzw. modeli prostych (np. średnich ruchomych, wygładzania wykładniczego), poprzez analizę trendu, skończywszy na modelach ARMA. [13, s. 180]

Na rysunku 3 podany jest przykład modelu neuronowego prognozy wskaźnika WIG20 na następny miesiąc. Jako zmienne wejściowe, oprócz zmian indeksu w poprzednich miesiącach ($\Delta WIG20$), mogą zostać wykorzystane dane dotyczące [12, s. 98]:

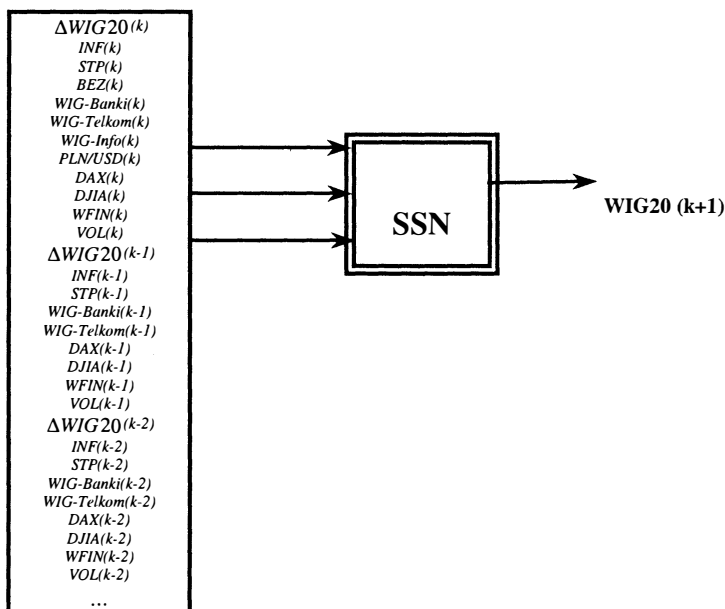
- ogólnej sytuacji gospodarczej np.: stopa inflacji (*INF*), wysokość stóp procentowych (*STP*), stopa bezrobocia (*BEZ*);
- sytuacji na rynku kapitałowym np.: indeksy „branżowe” (*WIG-Banki*, *WIG-Telkom*, *WIG-Info*);
- sytuacji na rynku pieniężnym i walutowym np.: kursy walut (*PLN/USD*);
- sytuacji na giełdach światowych np.: indeksy giełdowe (*DJIA*, *FTSE*, *DAX*);
- sytuacji poszczególnych spółek notowanych na giełdzie i wchodzących w skład prognozowanego indeksu np.: wskaźniki finansowe (*WFIN*), wartości kursów i obrotów (*VOL*).

W analizach giełdowych, wykorzystujących sztuczne sieci neuronowe, zmiennymi wyjściowymi mogą być [por. 1, s. 13-15] i [12, s. 100]:

- cena akcji po upływie k okresów y_{T+k} , gdzie T jest okresem, z którego pochodzi ostatnia obserwacja w ciągu uczącym;
- ostatnia zmiana kursu;
- współczynniki kierunkowe funkcji trendu kursów akcji;
- wskaźniki sygnałów kupna/sprzedaży akcji;

- wskaźniki pokazujące czy bieżące dane reprezentują maksimum, czy minimum rynku;
- wskaźniki opisujące podatność na gwałtowne wahania.

W literaturze przedmiotu autorzy pomijają zazwyczaj informacje dotyczące metod doboru zmiennych, które wprowadzane są na wejścia sieci. Prawdopodobnie zmienne te wyznaczone są arbitralnie lub określane metodą prób i błędów. [12, s. 100]



Rys. 3. Model neuronowy prognozy wskaźnika WIG20 w k -okresie

Źródło: Opracowanie własne na podstawie [13, s. 183] i [12, s. 98-99].

Do praktycznego zilustrowania możliwości zastosowania sztucznych sieci neuronowych w badaniach na rynku kapitałowym konieczny jest dostęp do profesjonalnego oprogramowania oraz dobrze zdefiniowany problem. Obecnie na polskim rynku są dostępne różnorodne symulacje sieci neuronowych o dużych możliwościach konfiguracyjnych. Przykładami takich programów są: NPG4.5 firmy ASHER [por. 9, s.28], *Statistica Neural Networks PL* [por. 9, s. 175], *NEURONIX* firmy AITECH [por. 10, s. 240], *Koho* opracowany w Katedrze Badań Operacyjnych wrocławskiej Akademii Ekonomicznej

[7, s. 165], *FLiNN* stworzony na Politechnice Częstochowskiej [6, s. 377], czy amerykański *FlexTool* [6, s. 409].

6. Podsumowanie

Rozwój rynków finansowych przyczynia się do ciągłego doskonalenia i rozwoju metod modelowania i prognozowania szeregów czasowych. Nieliniowy charakter zależności obserwowanych w dziedzinie finansów sprawia, że stosowanie modeli liniowych powoduje zbytne uproszczenie uzyskanego opisu. Możliwości aproksymacyjne sieci neuronowych i adaptacyjny proces doboru ich podstawowych parametrów jest istotną przesłanką przemawiającą za stosowaniem tych narzędzi w procesie modelowania. [4, s. 144-145]

Sztuczne sieci neuronowe są narzędziem informatycznym, które między innymi umożliwiają konstrukcję modeli liniowych i nieliniowych rozwiązujących złożone i trudne do jednoznacznej identyfikacji zadania z zakresu klasyfikacji. Podejście to jest korzystne dla inwestora, ponieważ dzięki niemu możliwe jest konstruowanie modeli (sieci) opartych na właściwościach samych danych, a nie na hipotezach tworzących model. Oczywiście hipotezy te są często podstawą konstruowania modelu, ale sam przebieg procesów i dopasowania sieci od nich nie zależy. Jeżeli hipotezy są błędne, model nie będzie dobry i inwestor nie będzie mógł z niego korzystać bez podejmowania dodatkowego ryzyka. [9, s. 175]

Wykorzystanie sieci neuronowych w prognozowaniu finansowych szeregów czasowych, stanowi bardzo elastyczne narzędzie dla inwestora, gdyż pozwala definiować różne wejścia, bez konieczności posiadania wiedzy o związkach przyczynowo-skutkowych między wielkościami mającymi potencjalny wpływ na np. wskaźnik giełdowy. Sieć neuronowa stanowi nowe narzędzie prognostyczne, wspomagające inwestorów giełdowych przy podejmowaniu decyzji inwestycyjnych, w celu zapewnienia sobie przewagi nad innymi uczestnikami rynku.

LITERATURA

1. Gately E., *Sieci neuronowe. Prognozowanie finansowe i projektowanie systemów transakcyjnych*, WIG-Press, Warszawa 1999.
2. Gwiazda T. D., *Algorytmy genetyczne. Zastosowania w finansach*, Wydawnictwo WSPiZ im. L. Koźmińskiego, Warszawa 1998.

3. Kiełtyk L., *Inteligentny System Prognozowania*, Wydawnictwo Politechniki Częstochowskiej, Częstochowa 2000.
4. Lula P., *Jednokierunkowe sieci neuronowe w modelowaniu zjawisk ekonomicznych*, Wydawnictwo AE w Krakowie, Kraków 1999.
5. Michalski A. (red.), *Wykorzystanie technologii i systemów informatycznych w procesach decyzyjnych*, Wydawnictwo Politechniki Śląskiej, Gliwice 2002.
6. Rutkowska D., Piliński M., Rutkowski L., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, PWN, Warszawa-Łódź 1997.
7. Siedlecki J. (red.), *Wykorzystanie sztucznych sieci neuronowych w modelowaniu ekonomicznym*, Wydawnictwo AE im. O. Langego we Wrocławiu, Wrocław 2001.
8. Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza RM, Warszawa 1993.
9. Tarczyński W., *Fundamentalny portfel papierów wartościowych*, PWE, Warszawa 2002.
10. Trzeciak D., *Zastosowanie sieci neuronowych w prognozowaniu sprzedaży w przedsiębiorstwie* [w:] Dziechciarz J. (red.), *Ekonometria nr 8. Zastosowania metod ilościowych*, Wydawnictwo AE im. O. Langego we Wrocławiu, Wrocław 2001.
11. Welfe A., *Ekonometria*, PWE, Warszawa 1998.
12. Witkowska D., *Sztuczne sieci neuronowe i metody statystyczne. Wybrane zagadnienia finansowe*, Wydawnictwo C. H. BECK, Warszawa 2002.
13. Zieliński J. S. (red.), *Inteligentne systemy w zarządzaniu. Teoria i praktyka*, PWN, Warszawa 2000.
14. http://www.republika.pl/edward_ch/sneuro.html.