



Radosław Jeż

Uniwersytet Ekonomiczny w Katowicach
Wydział Zarządzania
Katedra Logistyki Społecznej
radoslaw.jez@ue.katowice.pl

SZTUCZNE SIECI NEURONOWE I ICH ZASTOSOWANIE W MODELOWANIU ZJAWISK GOSPODARCZYCH

Streszczenie: W artykule podjęto próbę umiejscowienia sztucznych sieci neuronowych w praktyce gospodarczej oraz ukazania szeroko rozumianej sieciowości jako instrumentu, który zajmuje istotne miejsce w tworzeniu społeczeństwa innowacyjnego, wykorzystującego nowoczesne technologie oraz wiedzę w tym zakresie. Na podstawie literatury przedmiotu dotyczącej wykorzystywania sztucznych sieci neuronowych w ekonomii można wskazać podstawowe grupy tematyczne, w których z powodzeniem odnajdują się sztuczne sieci neuronowe.

Słowa kluczowe: sieci neuronowe, gospodarka, prognozowanie zjawisk gospodarczych, wiedza, innowacyjność.

Wprowadzenie

Zasoby wiedzy i informacji stały się w ostatnich czasach wyznacznikami postępu technologicznego oraz innowacyjności gospodarki. Są zasobami strategicznymi, które w coraz większym stopniu decydują o przewadze konkurencyjnej danego podmiotu. Umiejętność dopasowania się do szybko zmieniającego się otoczenia, zastosowanie odpowiednich technik i metod łączenia oraz przetwarzania zasobów wiedzy i informacji, wprowadzania zmian technologicznych i organizacyjnych są gwarantem rozwoju i stabilnej pozycji finansowej. Na pierwszy plan wysuwają się umiejętności komunikacyjne, zarządzanie wiedzą oraz odpowiedzialne gromadzenie kapitału intelektualnego, które dają podstawy do budowania organizacji inteligentnych, samodoskonalących się i przewidujących kierunki zmian pod wpływem zachodzących procesów gospodarczych.

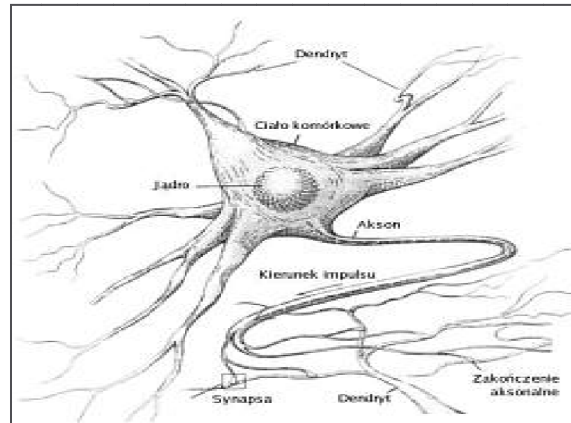
Wielkość PKB, poziom bezrobocia, poziom inflacji, przyrost zasobów pieniężnych gospodarstw domowych, wysokość kursu walut czy ceny akcji to tylko wybrane wskaźniki, które odgrywają znaczącą rolę w kształtowaniu rzeczywistości gospodarczej. Coraz częściej interpretacja rzeczywistości gospodarczej wymaga zastosowania dużej ilości danych i informacji, gdyż otoczenie, w którym działają podmioty, staje się coraz bardziej dynamiczne, a systemy informacyjne przetwarzające dostępne informacje wymuszają zastosowanie nowych rozwiązań do istniejących już algorytmów. Realizacja złożonych metod i wykorzystanie odpowiednich narzędzi na potrzeby gospodarki staje się zatem możliwa poprzez zastosowanie odpowiednich modeli sieci neuronowych, które należą do grupy metod sztucznej inteligencji. Celem artykułu jest próba przedstawienia roli i znaczenia sztucznych sieci neuronowych (SSN) oraz wykorzystanie ich w analizie zjawisk gospodarczych. Sztuczne sieci neuronowe okazały się narzędziem, za pomocą którego można realizować wiele praktycznych zadań. Są one wykorzystywane w szerokim zakresie w ekonomii, finansach, medycynie czy fizyce, czyli wszędzie tam, gdzie mamy do czynienia z analizą danych, ich predykcją, sterowaniem, grupowaniem czy klasyfikacją.

1. Sztuczne sieci neuronowe (SSN) – podstawowe zagadnienia

Zainteresowanie sztucznymi sieciami neuronowymi nastąpiło w latach dwudziestych, o czym świadczą wydania wielu pozycji naukowych w tym zakresie. Jednakże początkiem badań nad znaczeniem SSN jest ukazanie się w 1943 roku pracy W.S. McCullocha i W.H. Pittsa, w której to autorzy po raz pierwszy opisali matematyczny model sztucznego neuronu [McCulloch, Pitts, 1946, s. 115-133].

Oryginalną inspiracją do analizy sztucznych sieci neuronowych była budowa naturalnych neuronów, łączących je synaps oraz układów nerwowych, w szczególności mózgu. Poprzez dendryty pojedynczy neuron gromadzi sygnały pochodzące z innych komórek i receptorów. Pozyskane z wszystkich dendrytów sygnały są gromadzone i sumowane w komórce nerwowej (perikarionie). Jest on także odpowiedzialny za wyznaczenie sygnału wyjściowego. Następnie informacja jest przekazywana przez akson, który wyprowadza sygnał wyjściowy i przekazuje do innych neuronów poprzez rozwarstwioną strukturę wyjściową (telodendron). Synapsy są odpowiedzialne za przekierowanie sygnału do neuronu. Neuron pod wpływem synaps staje się bardziej aktywny i wysyła przez swój akson sygnał elektroniczny, który jest właściwy, charakterystyczny dla danego neuronu, ma swój kształt, odpowiednią amplitudę oraz czas trwania. Neuron staje się aktywny wówczas, gdy sygnał, który dotarł do ciała komórki, przekroczył pewien prógowy poziom (rys. 1). Punktem odniesienia przy konstruowaniu SSN

jest mózg ludzki, który składa się z około 10^{10} komórek nerwowych, które przetwarzają dane w sposób równoległy w powiązaniu z pracą wielu połączonych ze sobą neuronów [Witkowska, 2000, s. 82-87; Tadeusiewicz, 1995, s. 82-87].



Rys. 1. Struktura i elementy składowe biologicznego neuronu

Źródło: Kandel, Schwartz i Jessell [2000].

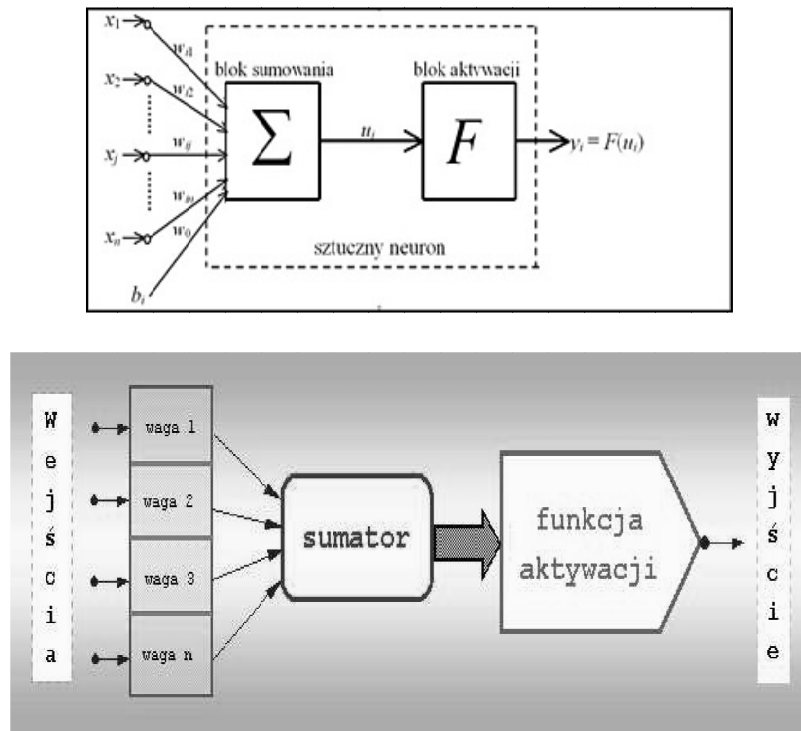
Sieci neuronowe (sztuczne sieci neuronowe) to nazwa struktur matematycznych oraz ich narzędziowych i programowych modeli, za pomocą których są realizowane obliczenia lub poprzez rzędy elementów, zwanych sztucznymi neuronami, które są odpowiedzialne za wykonanie podstawowych operacji na swoim wejściu. Są w znacznej mierze uproszczonym modelem biologicznych komórek nerwowych. W miejsce dendrytów zostały wkomponowane wektory wejściowe (x_1, \dots, x_N) , z kolei aksonem odpowiedzialnym za wyprowadzanie sygnałów jest wektor wyjściowy neuronu (y_i) (rys. 2). Sztuczne neurony charakteryzują się zatem występowaniem wielu sygnałów wejścia z przypisanymi odpowiednimi wagami (w_{i1}, \dots, w_{iN}) i jednego sygnału wyjścia.

Role komórki nerwowej (perikarionu) pełni część odpowiedzialna za grupowanie i sumowanie sygnałów otrzymanych z wejść (+). Za sygnał wyjściowy jest odpowiedzialna tzw. funkcja aktywacji $(f(u_i))$ ¹.

¹ Funkcja aktywacji występuje w różnych postaciach, jednak jak każda funkcja, aby mogła pełnić tę rolę, musi być łatwo różniczkowalna i ciągła. Najczęściej stosuje się funkcję: liniową, logistyczną, tangens hiperboliczny (funkcja sigmoidalna), sinus oraz signum. Jedną z najczęściej wykorzystywanych funkcji aktywacji jest funkcja sigmoidalna. Można ją opisać za pomocą wzoru:

$$\gamma = \frac{1}{1 + \exp(-2 * s * \chi)}$$

$$d = 2 * s * \gamma * (1 - \gamma)$$



Rys. 2. Struktura i podstawowe elementy sztucznego neuronu

Źródło: Kuźniar [2007].

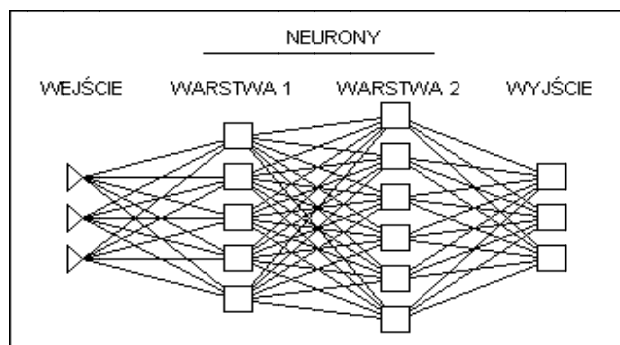
Można zatem stwierdzić, że neuron wyznacza pewną sumę ważoną swoich wejść i jeżeli jego sygnał wyjściowy przekracza wartość progową, przechodzi w stan zapłonu.

W literaturze przedmiotu można też spotkać określenie dotyczące sztucznych sieci neuronowych jako interdyscyplinarnej dziedziny wiedzy, która jest odpowiedzialna za konstrukcję oraz badanie możliwości tego rodzaju sieci. Bardzo ważną cechą różnicującą sztuczne sieci neuronowe od programów algorytmicznych, które przetwarzają informacje, jest zdolność uogólniania, czyli generalizacji wyników wiedzy dla nowych czynników, zmiennych, danych, niewykorzystywanych wcześniej na gruncie nauki. Zdolność do uogólnień jest

Funkcja jest rozpatrywana w przedziale $0 < y < 1$, gdzie: χ – wejście funkcji aktywacji; γ – wyjście funkcji; s – stromizna funkcji; d – pochodna funkcji. Ze względu na fakt, że pojedynczy neuron ma małe możliwości w zakresie przetwarzania danych/informacji, tworzy się strukturę nazywaną siecią neuronową, która powstaje w wyniku łączenia grup neuronów w warstwy. Stosowana jest zatem zasada łączenia każdego neuronu warstwy wcześniejszej/poprzedniej z każdym neuronem warstwy kolejnej.

określona jako zdolność do aproksymacji wartości funkcji wielu zmiennych w przeciwieństwie do interpolacji możliwej do otrzymania przy przetwarzaniu algorytmicznym².

Sieci neuronowe mają w szczególności charakter nieliniowy i należą do wysublimowanych grup technik modelowych, zdolnych do złożoności funkcji. Od wielu lat nadrzędną techniką matematyczną stosowaną do opisywania różnych zjawisk i procesów zachodzących w gospodarce było modelowanie liniowe i takie działania są też z powodzeniem stosowane dzisiaj, przynosząc korzystne rezultaty, głównie z uwagi na dobrze znaną strategię optymalizacji stosowaną przy konstrukcji modeli tego typu [Tadeusiewicz, StatStof]. Istnieje jednak wiele sytuacji, gdzie nie ma podstaw do aproksymacji liniowej badanych zjawisk, co powoduje tym samym brak zasadności stosowania modeli liniowych. Prowadzi to często do fałszywych twierdzeń o częściowym lub całkowitym braku możliwości matematycznej interpretacji badanych procesów i zjawisk. Większość współcześnie tworzonych sieci neuronowych ma budowę warstwową, przy czym ze względu na dostępność w trakcie procesu uczenia wyróżnia się warstwy: wejściową, wyjściową oraz tak zwane warstwy ukryte (rys. 3). SSN w ramach tworzonych modeli doskonale odnajdują się w takich sytuacjach, gdyż mają umiejętność odwzorowywania zależności nieliniowych. Sieci te dają możliwość kontrolowania złożonego procesu wielowymiarowości, który przy stosowaniu innych metod znacząco utrudnia próby modelowania funkcji nieliniowych z dużą liczbą zmiennych niezależnych (funkcje wektorowe).



Rys. 3. Przykładowa struktura sieci neuronowej

Źródło: Gately [1999, s. 9-11].

² Systemy ekspertowe z reguły wymagają zgromadzenia i bieżącego dostępu do całej wiedzy na temat zagadnień, o których będą rozstrzygały. SSN wymagają natomiast jednorazowego poznania i przyswojenia. Jednocześnie wykazują one tolerancję na nieciągłości, przypadkowe zaburzenia lub wręcz braki w zbiorze uczącym. Pozwala to na zastosowanie ich tam, gdzie nie da się rozwiązać tego problemu w inny możliwy i efektywniejszy sposób.

Sieci neuronowe mają umiejętność konstruowania potrzebnych modeli, ponieważ są wyposażone w możliwości automatycznego uczenia się. Użytkownik sieci gromadzi potrzebne dane, które pokazują, jak kształtuje się interesująca go zależność, a następnie uruchamia algorytm uczenia, który ma na celu automatyczne wytworzenie w pamięci sieci potrzebnej struktury danych. Opierając się na samodzielnie stworzonej strukturze danych, tzw. współczynnikach wagowych, sieć automatycznie realizuje wszystkie możliwe funkcje związane z wykorzystaniem stworzonego modelu.

Stosowane w praktyce sieci neuronowe bardzo często są złożone z pewnej liczby warstw neuronów połączonych między sobą w sąsiednich warstwach. Pomimo wielu uogólnień i uproszczeń sztuczne sieci neuronowe charakteryzują się cechami zarezerwowanymi dla organizmów żywych [Witkowska, 2000, s. 16]. Do najważniejszych cech należy zaliczyć:

- łatwość i zdolność „uczenia się”, co pozwala sieci neuronowej przyswoić prawidłowe reakcje na określone bodźce,
- uogólnianie wiedzy przyswojonej w trakcie trenowania (umiejętność abstrakcji),
- odporność na uszkodzenia – sieć neuronowa potrafi działać poprawnie nawet z uszkodzonymi elementami.

2. Zastosowanie sztucznych sieci neuronowych w prognozowaniu zjawisk gospodarczych

Praktyka gospodarcza bardzo szybko wykorzystwała pojawiającą się szansę na wykorzystanie w swoich analizach prognostycznych sztucznych sieci neuronowych. Zachowanie podmiotów rynkowych, podejmowanie decyzji strategicznych z wykorzystaniem SSN stało się kwestią pożądaną na każdym etapie działalności gospodarczej. Na podstawie literatury przedmiotu [Stawowy i Jastrzębski, 1996, s. 118-123; Staniec, 1997, s. 56-57; Dasgupta, Dispensa, Caporaletti i in., 1994, s. 481-495; Ghose, 1994, s. 235-244; Scott, 2005; Peretto, 2000; Markowska-Kaczmar i Kwaśnicka, 2005] dotyczącej wykorzystywania sztucznych sieci neuronowych w ekonomii można wskazać podstawowe grupy tematyczne, w których z powodzeniem odnajdują swoje zastosowanie:

- prognozowanie i modelowanie kursów akcji wybranych spółek;
- ocena zdolności kredytowej i prognozowanie ryzyka ekonomicznego podmiotów – trenowanie i testowanie SSN wymaga odpowiedniego przygotowania danych opisujących sytuację danego przedsiębiorstwa (na wejściu), np. wskaźniki rentowności, wskaźniki opłacalności oraz opinie ekspertów jako wartości niemierzalne z odpowiednią wartością liczbową (ranga); na podstawie tak opracowanego zbioru uczącego trenuje się sieć neuronową, która dokonuje automatycznie klasyfikacji obiektów w obszarze np. bankructwa danego podmiotu;

- analiza przyrostów pieniężnych gospodarstw domowych – punktem odniesienia przy wyznaczaniu parametrów zdolności i przyrostów zasobów pieniężnych są kwartalne przyrosty zasobów, stopa procentowa długookresowych depozytów bankowych oraz dochody ludności ogółem;
- prognozowanie sygnałów kupna-sprzedaży;
- prognozowanie stopy inflacji – miernikiem inflacji jest CPI (*Consumer Price Index*), który charakteryzuje stosunek kosztów odpowiedniego koszyka dóbr do kosztów tych dóbr przyjęty za wyjściowy; za zmienną wyjaśnianą, która jest wartością końcową sieci – zarówno w modelach ekonometrycznych, jak i w przypadku SSN – przyjmuje się indeks cen dóbr i usług konsumpcyjnych, z kolei za zmienne wyjaśniające (wejście do sieci) należy przyjąć płace nominalne, stopę bezrobocia, poziom produkcji w przemyśle ogółem;
- szacowanie nakładów inwestycyjnych, których wielkość, struktura i dynamika w ujęciu makroekonomicznym jest odzwierciedleniem rozwoju gospodarczego danego kraju oraz miernikiem sytuacji gospodarczej;
- dobór i selekcja pracowników;
- eksploracja danych w marketingu w ramach systemu CRM – budowa pozytywnych relacji z klientem;
- diagnostyka medyczna.

Zastosowanie sztucznych sieci neuronowych dobrze wkomponowuje się w badania zależności i procesów zachodzących na rynkach finansowych. Wynika to z niestacjonarności procesów, a także braku podstaw do przyjmowania, dających się zweryfikować, założeń modelowych [Witkowska, 2000, s. 111]. Podczas analizy i porównań w obszarze rynków finansowych najczęstszym punktem odniesienia stają się kursy walut, ceny akcji czy indeksy giełdowe. Sieci neuronowe są modelami nieliniowymi, a więc dają większe szanse rozwiązania problemu niż tradycyjnie stosowane modele szeregów czasowych czy modele ekonometryczne.

Do analizy procesów gospodarczych opartych na SSN jest wykorzystywanych wiele programów. Wynika to z dużego w ostatnich latach zainteresowania sieciami neuronowymi. Można je podzielić na następujące grupy [Witkowska, 2000, s. 233]:

- profesjonalne aplikacje neuronowe (np. Neural Works, Matlab, Statistica) – tworzone przez największe firmy informatyczne i adresowane do specjalistów w zakresie SSN; budowa tych programów opiera się na dużej ilości algorytmów uczenia, co umożliwi tworzenie odpowiednich (w zależności od potrzeb), różnych typów sieci neuronowych; atutem tych programów jest radzenie sobie z dużą liczbą danych;

- niekomercyjne aplikacje (np. WinNN, Qnet, Neural Planner) – aplikacje z ograniczonymi możliwościami technicznymi, które często uwzględniają tylko jeden algorytm uczenia, przez co ich możliwości wykorzystania są ograniczone; aplikacje te są najczęściej wykorzystywane do klasycznych sieci jednokierunkowych;
- programy oparte na języku komend (np. NetTeach) – należą do kategorii aplikacji niekomercyjnych, nie mają graficznego interfejsu, co stanowi poważne utrudnienie w obsłudze; opierają się często na jednym wyspecjalizowanym algorytmie uczenia, co w połączeniu z brakiem interfejsu sprawia, że mogą z niego korzystać użytkownicy dobrze znający tematykę SSN;
- programy specjalistyczne (np. AINet) – są przeznaczone do zastosowania w obszarze danej specjalizacji bądź dziedzinie, nie wymagają znajomości problematyki SSN; programy te są adresowane do użytkowników, którzy postrzegają sieci neuronowe jako odpowiednie narzędzie, gdzie wprowadzając pewne dane, otrzymamy konkretną odpowiedź;
- moduły współpracujące z innymi programami – do ich zastosowania jest konieczne posiadanie zewnętrznego programu, gdzie następuje wymiana danych; w tej kategorii programów można wskazać na makrodefinicje, które są adresowane do rozszerzenia programów matematycznych i statystycznych oraz modułów bibliotecznych (Visual Basic).

Podsumowanie

Dostępność do nowoczesnych narzędzi wiedzy oraz innowacyjność podmiotów gospodarczych powoduje, że w coraz większym stopniu korzystają one z uniwersalności sztucznych sieci neuronowych. Sprawia to, że coraz częściej są one wybierane jako narzędzie wykorzystywane do analizy zjawisk gospodarczych. Warto zaznaczyć, że bardzo często brak kompletnych danych, mała liczba obserwacji wyklucza zastosowanie tradycyjnych metod statystycznych w sytuacji, gdy sieci neuronowe doskonale radzą sobie z takim zbiorem danych. Należy też podkreślić, że przeprowadzenie prognoz za pomocą sieci neuronowych wymaga mniej czasu niż w przypadku modeli ekonometrycznych, co w przypadku zjawisk gospodarczych ma duże znaczenie aplikacyjne. Sieci neuronowe nie wymagają również założeń co do natury rozkładu danych, gdyż z przynajmniej jedną warstwą ukrytą wykorzystują dane do określenia charakteru zależności między zmiennymi. Sieci te potrafią też doskonale działać nawet w sytuacji, gdy mamy do czynienia z pewnym poziomem uszkodzenia, a także mimo częściowo błędnej informacji wejściowej. Do wad SSN można zaliczyć brak analiz

relacji zachodzących w warstwach ukrytych, jak również błędy w estymacji i predykcji, co wskazuje na konstruowanie sieci zależności na podstawie prób i błędów. Wadą SSN jest też ich skłonność do dopasowania się do wszystkich danych nawet w sytuacji, gdy nie ma między nimi żadnych zależności. Zarówno zwolennicy, jak i przeciwnicy sieci neuronowych wskazują na ich zalety i wady, jednakże popularność sztucznych sieci neuronowych jest w znacznej mierze konsekwencją zmian, jakie zachodzą w otoczeniu.

Kończąc rozważania na temat sztucznych sieci neuronowych, można się pokusić o stwierdzenie, że XXI wiek będzie czasem prac nad rozwojem układów sztucznej inteligencji, a więc i sztucznych sieci neuronowych oraz wykorzystaniem ich w coraz szerszym zakresie w życiu codziennym.

Literatura

- Dasgupta Ch.G. i in. (1994), *A decision support system for in-sample simultaneous equation system forecasting using artificial neuron systems*, "Decision Support Systems", No 11.
- Gately E. (1999), *Sieci neuronowe. Prognozowanie finansowe i projektowanie systemów transakcyjnych*, WIG-Press, Warszawa.
- Ghose S. (1994), *Comparing the predictive performance of a neural network model with some traditional market response models*, "International Journal of Forecasting", No 10.
- Kandel E.R., Schwartz J.H., Jessell T.M. (2000), *Principles of neural science*, 4th ed., McGraw-Hill, New York.
- Kuźniar K. (2007), *Sztuczne sieci neuronowe*, PAP, Kraków, Konspekt 3-4.
- Markowska-Kaczmar U., Kwaśnicka H. (2005), *Sieci neuronowe w zastosowaniach*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław.
- McCulloch W.S., Pitts W.H. (1943), *A logical calculus of ideas immanent in nervous activity*, "Bulletin of Mathematical Biophysics", Vol. 5.
- Peretto P. (2000), *An introduction to the modelling of neural networks*, Cambridge University Press, Cambridge.
- Scott J. (2005), *Social network analysis*, Sage Publications, London.
- Staniec I. (1997), *Bank a sieci neuronowe*, „Bank”, nr 10.
- Stawowy A., Jastrzębski P. (1996), *Zastosowanie sieci neuronowej do oceny ryzyka kredytowego*, Zarządzanie przedsiębiorstwem w gospodarce rynkowej, AGH, Kraków.
- Tadeusiewicz R., *Wprowadzenie do praktyki stosowania sieci neuronowych*, StatStof, www.StatSoft.pl (dostęp: 12.01.2015).
- Tadeusiewicz R. (1995), *Sieci neuronowe*, ENTER.
- Witkowska D. (2000), *Sztuczne sieci neuronowe w analizach ekonomicznych*, Menadżer, Łódź.

**ARTIFICIAL NEURAL NETWORKS AND THEIR APPLICATION
IN MODELING ECONOMIC PHENOMENA**

Summary: The last time, knowledge and information have become determinants of innovation economy. These are strategic resources that are increasingly determined by the competitive advantage of companies. Implementation of complex methods and tools for the needs of the economy becomes possible through the use of appropriate models of neural networks that belong to the influenza artificial intelligence methods. The purpose of this article is an attempt to present the role and importance of artificial neural networks (ANN) in predicting and describing economic phenomena.

Keywords: neural networks, economy, forecasting economic phenomena, knowledge, innovation.