

Słowa kluczowe: sztuczna inteligencja, sztuczne sieci neuronowe, uczenie sieci neuronowych, wspomaganie decyzji inwestycyjnych

WYBÓR NAJATRAKCYJNIEJSZYCH SPÓŁEK NA WGPW PRZY UŻYCIU SZTUCZNYCH SIECI NEURONOWYCH

Wstęp

Aby skutecznie inwestować na rynkach finansowych konieczna jest nieustanna analiza informacji rynkowych, generowanie prognoz w oparciu o te informacje, aby ostatecznie podjąć odpowiednie decyzje. Dokładna analiza dużej ilości danych w połączeniu z koniecznością podejmowania szybkich decyzji inwestycyjnych mogą stanowić problem nawet dla najbardziej doświadczonych analityków. Dlatego też zauważyć można tendencję do coraz szerszego wykorzystania komputerowych systemów wspomaganie decyzji. Znaczny potęg w dziedzinie technologii komputerowych, w tym metod opartych na sztucznej inteligencji, przyczynił się do rozwoju nowych narzędzi wykorzystywanych do prognozowania kursów instrumentów notowanych na rynkach finansowych. Duża część tych metod opiera się na sztucznych sieciach neuronowych, po to aby bezpośrednio generowały one prognozy lub podejmowały samoczynnie decyzje³⁴⁷. Celem niniejszej pracy jest przybliżenie działania Sztucznych Sieci Neuronowych jako elementu Sztucznej Inteligencji. Dodatkowo zostanie oceniona ich skuteczność w kwestii wyboru najatrakcyjniejszych spółek giełdowych notowanych na Warszawskiej Giełdzie Papierów Wartościowych (WGPW).

1. Sztuczna inteligencja

Niemalże od wynalezienia pierwszych komputerów, zastanawiano się nad możliwością ich najpełniejszego wykorzystania. Oprócz maszyny do szybkich obliczeń chciano aby było to urządzenie do wykonywania złożonych zadań, dla których niemożliwe jest utworzenie algorytmów. Dążono do tego, aby funkcjonowanie komputera przypominało procesy zaobserwowane podczas działalności intelektualnej człowieka³⁴⁸. Termin sztuczna inteligencja został użyty po raz pierwszy na przełomie lat 50 i 60 dwudziestego wieku. Oznaczał on wówczas skupienie uwagi na najważniejszych obszarach ludzkiego poznania, czyli na racjonalnym myśleniu, logice oraz na umiejętności rozwiązywania problemów³⁴⁹. Dzisiaj sztuczna inteligencja tłumaczona jest jako dziedzina wiedzy, której celem i przedmiotem badań są

³⁴⁶ Praca napisana pod kierunkiem dr Olgi Dębickiej, Instytut Transportu i Handlu Morskiego, Wydział Ekonomiczny Uniwersytetu Gdańskiego.

³⁴⁷ J. Morajda, *O użyteczności sieci neuronowych i algorytmów genetycznych w realizacji inwestycyjnych systemów decyzyjnych*, „Zeszyty Naukowe Małopolskiej Wyższej Szkoły Ekonomicznej w Tarnowie” 2006, nr 1 (9), s. 221.

³⁴⁸ M. Białko, *Sztuczna inteligencja i elementy hybrydowych systemów ekspertowych*, Wydawnictwo Uczelniane Politechniki Koszalińskiej, Koszalin 2005, s. 15.

³⁴⁹ T. Motowidlak, *Zastosowanie systemów sztucznej inteligencji w różnych dziedzinach nauki*, „Pieniądze i Więź” 2007, nr 3, s. 121.

maszyny, które potrafiłyby rozwiązywać zadania i problemy, przy rozwiązywaniu których człowiek korzysta ze swojej inteligencji³⁵⁰.

Początkowa Sztuczna Inteligencja odnosiła się wyłącznie do systemów ekspertowych. Dzisiaj, po blisko 60 latach rozwoju tej dziedziny nauki, do sztucznej inteligencji włącza się również Sztuczne Sieci Neuronowe, Algorytmy Ewolucyjne (w tym Genetyczne) oraz Systemy Rozumowania Rozmytego wraz z logiką rozmytą i z teorią zbiorów rozmytych. Wszystkie te dziedziny związane są z symulacją komputerową procesów, które zachodzą w organizmach biologicznych³⁵¹.

Pomimo swoich wad i niedoskonałości tematyka sztucznej inteligencji, zwłaszcza wykorzystanie technik uczenia się maszyn, rozwija się w niezwykłym tempie, czemu sprzyja między innymi znaczny wzrost możliwości sprzętowych. Stosują się ją powszechnie między innymi w systemach doradczych tworzonych na potrzeby medycyny, w urządzeniach automatyki przemysłowej, w wojsku, w grach komputerowych oraz w finansach³⁵².

2. Sztuczne Sieci Neuronowe (SSN)

Historia tworzenia sztucznych sieci neuronowych ma swoje początki w latach czterdziestych XX wieku. Wtedy to matematyk W. Pitts i psychiatryneurolog W. McCulloch matematycznie opracowali pojęcie sztucznego neuronu, który był w stanie odzwierciedlić w swoim działaniu funkcję logiczną. Zasadę uczenia pojedynczego neuronu opracował D. Hebb w 1949 roku³⁵³. Obecnie sztuczne sieci neuronowe są jedną z najbardziej dynamicznie rozwijających się gałęzi sztucznej inteligencji. Zyskały one uznanie w bardzo rozległych dziedzinach życia i nauki. Znajdują one także zastosowanie w naukach ekonomicznych, które wcześniej głównie opierały się na modelach optymalizacyjnych, statystycznych i ekonometrycznych³⁵⁴.

Sztuczna sieć neuronowa składa się ze wzajemnie połączonych elementów, które przetwarzają informacje. Elementy te są nazywane neuronami, węzłami lub jednostkami. Każdy z nich przyjmuje sygnały wejściowe (od poprzednich lub ze świata zewnętrznego), przetwarza je i generuje sygnał wyjściowy. Między nimi występują połączenia z przyporządkowanymi współczynnikami wagowymi, które określają siłę powiązań i tworzą zbiór parametrów modelu. Jednostki te grupowane są w większe zespoły, które są nazywane warstwami. Wewnętrzna struktura oraz sposoby przechodzenia sygnału między neuronami tworzą architekturę sieci neuronowej. Wiedza sieci na temat sposobu rozwiązania danego problemu jest przechowywana w jej strukturze oraz w zdefiniowanych wartościach wag i jest przywoływana zawsze, gdy pojawi się określony sygnał. Wagi przydzielane są losowo, albo wyznaczone są w procesie uczenia, gdzie sieć identyfikuje wzorce lub odwzorowuje przekształcenia³⁵⁵.

³⁵⁰ M. J. Kasperski, *Sztuczna inteligencja. Droga do myślących maszyn*. Wydawnictwo HELION, Gliwice 2003, s. 17.

³⁵¹ M. Biało, op. cit., s. 44

³⁵² M. J. Kasperski, op. cit., s. 11.

³⁵³ T. Seroczyński, *Konekjonizm w praktyce, czyli Sztuczne Sieci Neuronowe*, Uniwersytet Warszawski, Warszawa 2003, s. 4 - 5.

³⁵⁴ W. Bartkiewicz, *Inteligentne systemy w zarządzaniu. Teoria i praktyka*, pod red. J. S. Zielińskiego, Wydawnictwo Naukowe PWN, Warszawa 2000, s. 141.

³⁵⁵ Ibidem, s. 141.

2.1. Właściwości sieci neuronowej

Do najczęściej spotykanych zastosowań sieci neuronowych zalicza się³⁵⁶:

- Prognozowanie – predykcja wartości zmiennej na podstawie jej przeszłych wartości lub wartości innych zmiennych. Głównie wykorzystywane w modelach ekonomicznych i meteorologicznych.
- Klasyfikację – sieć neuronowa potrafi nie gorzej wykonać zadanie, które wymaga tradycyjnej metody analizy dyskryminacyjnej. Może być między innymi wykorzystana do obliczenia wielkości plonów na podstawie zdjęć satelitarnych czy do rozpoznania choroby serca na podstawie kardiogramów.
- Rozkład zakłóceń – rozpoznawanie pewnej liczby obiektów wzorcowych (np. fragmentów szeregów czasowych czy obrazów). Sieć potrafi odtworzyć wzorec nawet gdy zostanie jej podana zakłócona część oryginału. Metodę tą stosuje się, z wielkim powodzeniem, do zadań poprawiania obrazu.

2.2. Ogólna struktura

Sztuczna sieć neuronowa składa się ze wzajemnie połączonych elementów, które przetwarzają informacje. Elementy te są nazywane neuronami, węzłami lub jednostkami. Między nimi występują połączenia z przyporządkowanymi współczynnikami wagowymi, które określają siłę powiązań i tworzą zbiór parametrów modelu. Jednostki te grupowane są w większe zespoły, które są nazywane warstwami. Wewnętrzna struktura oraz sposoby przechodzenia sygnału między neuronami tworzą architekturę sieci neuronowej. Wiedza sieci na temat sposobu rozwiązania danego problemu jest przechowywana w jej strukturze oraz w zdefiniowanych wartościach wag i jest przywoływana zawsze gdy pojawi się określony sygnał. Wagi przydzielane są losowo albo wyznaczone są w procesie uczenia, gdzie sieć identyfikuje wzorce lub odwzorowuje przekształcenia³⁵⁷.


Aby rozwiązać większość problemów wystarczy zastosować sieci trójwarstwowe. Składają się one z warstwy wejściowej przyjmującej sygnały, warstwy ukrytej i warstwy wyjściowej, która daje wyniki. Pierwsza warstwa składa się z tylu neuronów ile jest danych wejściowych. Warstwa wyjściowa musi liczyć tyle neuronów, ile wymaganych jest odpowiedzi na dany problem. Nie ma natomiast jednoznacznego warunku ile neuronów powinna liczyć warstwa ukryta. Co więcej w danej sieci może występować kilka warstw ukrytych³⁵⁸. Na rysunku 1 przedstawiono model sieci neuronowej składającej się z 4 neuronów w warstwie wejściowej, 5 neuronów w warstwie ukrytej i jednego neuronu w warstwie wyjściowej.

³⁵⁶ T. Masters, *Sieci neuronowe w praktyce. Programowanie w języku C++*, Wydawnictwa Naukowo – Techniczne, Warszawa 1996, s. 20.

³⁵⁷ W. Bartkiewicz, op. cit., s. 141.

³⁵⁸ P. Garszka, M. Łażewski, *Prognozowanie cen akcji notowanych w systemie ciągłym z wykorzystaniem sieci neuronowych na podstawie obserwacji „tick by tick”*, [w] *Rynek kapitałowy : skuteczne inwestowanie: konferencja naukowa zorganizowana przez Katedrę Ekonometrii i Statystyki Wydziału Nauk Ekonomicznych i Zarządzania, Międzyzdroje, 5-7 września 2004 r. Cz. 2* pod red. W. Tarczyńskiego, Wydawnictwo Naukowe Uniwersytetu Szczecińskiego, Szczecin 2004, s. 235.

Architektura sztucznej sieci neuronowej



Źródło: K. Borowski, S. Grabowski, *Analiza zależności międzyrynkowych przy użyciu sztucznych sieci neuronowych – empiryczny przykład neuronowego systemu transakcyjnego na wartość indeksu WIG*, „Studia i Prace Kolegium Zarządzania i Finansów” 2006, z. 68, s. 93.

Oprócz liczby warstw, sieci mogą się różnić układem połączeń pomiędzy neuronami. Wyróżnić tu można dwie podstawowe grupy³⁵⁹:

Sieci jednokierunkowe – sygnał przekazywany jest z warstwy wejściowej, poprzez warstwę ukrytą, do warstwy wyjściowej. Wartości wejść w danym neuronie nie zależą w żaden sposób od jego wartości wyjściowej.

Sieci rekurencyjne – powstają w wyniku dodania połączeń od wyjść neuronów do ich wejść. Powoduje to, że sygnały na wyjściach zależą zarówno od aktualnego stanu wejść, jak i od poprzednich sygnałów wejściowych. Dynamika działań tego typu sieci jest znacznie bardziej skomplikowana.

2.3. Uczenie

Proces przystosowania sieci neuronowej do prawidłowego działania nazywany jest uczeniem. Na podstawie przedstawionych rzeczywistych przypadków, sieć stara się odkryć i zapamiętać ogólne prawidłowości. Rozpoznane zasady sieć neuronowa przechowuje w postaci współczynników wagowych neuronów. W praktyce więc, proces uczenia polega na prawidłowym określeniu współczynników wagowych neuronów na podstawie informacji wyodrębnionych ze zbioru uczącego. W trakcie uczenia wartości wag jednego lub kilku neuronów ulegają zmianie, przy czym reguły tych zmian są tak ustalone, by każdy neuron sam potrafił określić, które z wag ma zmienić, w którą stronę i o ile³⁶⁰. Dzięki temu sieć ma wyprowadzić wyniki identyczne z wynikami podanymi w przykładach. Wnioskuje się wtedy, że gdy otrzyma ona na wejściu inny zestaw wartości, również wskaże poprawne wyniki³⁶¹.

Istnieją dwie metody uczenia sieci: „z nauczycielem” i „bez nauczyciela”. Pierwsza z nich polega na tym, że sieci podaje się przykłady poprawnego działania, które potem powinna ona naśladować w swoim bieżącym działaniu. Poprzez te przykłady sieć otrzymuje konkretne sygnały wejściowe i wyjściowe, dowiadując się w ten sposób jaka jest oczekiwana odpowiedź

³⁵⁹ J. Żurada, M. Barski, W. Jędruch, *Sztuczne sieci neuronowe. Podstawy teorii i zastosowania*, Wydawnictwo Naukowe PWN, Warszawa 1996, s. 43-47.

³⁶⁰ T. Motowidlak, op. cit., s. 130-131.

³⁶¹ S. Nissan, *Tworzenie sieci neuronowych – to proste*, „Software 2.0” 2005, nr 2, s. 16.

dla pewnej konfiguracji danych wejściowych.. „Nauczyciel” przekazuje sieci ciąg uczący (zbiór zgromadzonych przykładów wykorzystywanych w procesie uczenia) i na jego podstawie uczy się ona prawidłowego działania³⁶².

Uczenie „bez nauczyciela” polega na tym, że sieci przekazuje się kolejne przykłady sygnałów wejściowych, nie podając informacji, o tym, co z nimi trzeba zrobić. Sieć na podstawie obserwacji występujących sygnałów stopniowo sama odkrywa, jakie jest ich znaczenie i sama ustala zachodzące między nimi zależności. Po podaniu do sieci neuronowej kolejnego zestawu sygnałów wejściowych tworzy się w niej pewien rozkład sygnałów wejściowych, tzn. niektóre neurony są pobudzane bardzo silnie, inne słabiej, a jeszcze inne mają sygnały wyjściowe ujemne. Po określonym czasie takiego samouczenia powstaną w sieci wzorce poszczególnych typów sygnałów występujących na jej wejściu. Sieć nauczy się, ile klas podobnych do siebie sygnałów pojawia się na jej wejściach oraz sama przyporządkuje im neurony, które nauczą się je rozróżniać, rozpoznawać i sygnalizować³⁶³.

Rzadziej spotykanymi metodami są: uczenie ze współzawodnictwem oraz uczenie ze wzmocnieniem. Pierwsza z nich polega na konkurowaniu neuronów między sobą o uzyskanie stanu aktywacji. Po podaniu bodźca na wejściu konkurujące neurony generują swoje odpowiedzi. Wygrywa neuron, którego odpowiedź jest najbliższa odpowiedzi pożądaney, na przykład uzyskuje najwyższy potencjał aktywacji. Proces ten często bywa nazywany specjalizacją, ponieważ dzięki niemu neurony uczą się reagować na inne typy bodźców. Natomiast uczenie ze wzmocnieniem (uczenie z krytykiem) ma miejsce gdy uczenie następuje poprzez ciągłą interakcję systemu (sieci) ze środowiskiem (otoczeniem). Wejściem systemu jest stan środowiska, a wyjściem proponowane przez system akcje (działania). W tym przypadku nadzorca (lub krytyk) nie ocenia stopnia dopasowania wyjścia sieci i pożądaney odpowiedzi, ale ocenia za pomocą określonego skalarnego wskaźnika jakości, czy efekt działania sieci jest pozytywny czy negatywny. W pierwszej sytuacji następuje wzmocnienie, a w drugiej osłabienie, tendencji sieci do podejmowania tych działań w przyszłości³⁶⁴.

3. Zastosowanie SSN do wyboru najatrakcyjniejszych spółek na WGPW

Aby sprawdzić czy sztuczne sieci neuronowe mogą być skutecznie stosowane w praktyce autor opracowania przeprowadził badania na akcjach notowanych na Giełdzie Papierów Wartościowych w Warszawie. Badania miały na celu zweryfikowanie, czy przy wykorzystaniu SSN można osiągnąć lepsze wyniki finansowe niż średnio cały rynek. Skuteczność sprawdzano na 11 spółkach, które w całym okresie przeprowadzania i oceny badań (pełne lata kalendarzowe 2006-2010) były składnikami indeksu WIG20. W skład zakwalifikowanych spółek weszły: Bank Pekao, Bank Zachodni WBK, BRE Bank, Globe Trade Centre, Grupa LOTOS, KGHM Polska Miedź, PKN Orlen, PKO Bank Polski, Polskie Górnictwo Naftowe i Gazownictwo, Telekomunikacja Polska i TVN. Okres w którym dokonano badania został podzielony na dwadzieścia trzymiesięcznych faz (każda faza odpowiadała kwartałowi danego roku).

Do utworzenia sieci neuronowych oraz symulacji został użyty program Neuronix 4.0 – symulator sieci neuronowej. Zastosowano jednokierunkową sieć z dwiema warstwami ukrytymi,

³⁶² G. Kowerda, *Dobór zmiennych i proces uczenia w analizach rynku papierów wartościowych za pomocą sztucznych sieci neuronowych*, „Optimum” 2008, nr 2, s. 92 – 95.

³⁶³ T. Motowidlak, op. cit., s. 132 – 133.

³⁶⁴ J. Łęski, *Systemy neuronowo – rozmyte*, Wydawnictwo Naukowo – Techniczne, Warszawa 2008, s. 209 – 210.

z czego pierwsza składała się z sześciu neuronów, a druga z trzech. Jako dane wejściowe wykorzystano: średnią dodatkową stopę zwrotu uzyskaną z inwestycji w daną akcję w ciągu danej fazy, współczynnik beta danej akcji, jej ryzyko niesystematyczne, stosunek średniej dodatkowej stopy zwrotu do współczynnika beta oraz współczynnik C z modelu Sharpe'a. Informacją wyjściową była wartość 1 w sytuacji gdy w kolejnej fazie stopa zwrotu z danej akcji była dodatnia, lub 0 w sytuacji gdy w następnej fazie stopa zwrotu z danej akcji była ujemna. Dane pochodzące od początku 2006 roku do końca trzeciego kwartału 2009 roku posłużyły jako ciąg uczący, natomiast od czwartego kwartału 2009 roku służyły jako weryfikacja skuteczności działania sieci. Tak stworzona sieć miała wskazać akcje, które w czterech kwartałach 2010 roku przyniosłyby zysk inwestorowi. Daną akcję uznano jako atrakcyjną (dającą potencjalne zyski), w sytuacji gdy wskazany przez sieć wynik był w jej przypadku większy od 0,5. W sytuacji gdy sieć wskazała kilka akcji przyjęto, że na zakup każdej z nich przeznaczono taką samą kwotę.

W badaniu założono, że transakcje kupna oraz sprzedaży są nieodpłatne oraz nie brano pod uwagę należnych dywidend. Przyjęto również, że możliwe jest przyjmowanie wyłącznie pozycji długich, czyli klasyczna operacja giełdowa polegająca na zakupie walorów po włączeniu ich do portfela, a następnie sprzedaży po zakończeniu badanej fazy. Przeprowadzane badania mają charakter statyczny, a nie dynamiczny, ponieważ reakcja inwestora polegająca na włączeniu w danym okresie danego waloru do portfela zależy tylko od wyników wskazanych przez sieć. Decydent nie analizuje, czy panująca tendencja jest stosunkowo trwała, czy wygasa i niebawem zaniknie.

Tabela nr 1 ukazuje jakie akcje wskazała sieć w danych kwartałach 2010 roku i jaki był ich udział w portfelu.

Tabela nr 1

Akcje wskazane przez SSN jako atrakcyjne

Kwartał 2010 roku	Wskazane akcje
1	BRE Bank, BZWBK, KGHM, LOTOS, PGNiG, PKN Orlen, PKOBP i TVN (udział każdej akcji – 12,50%)
2	PGNiG, TPSA i TVN (udział każdej akcji – 33,33%)
3	KGHM (udział 100%)
4	BRE Bank, BZWBK, GTC, KGHM, PEKAO, PGNiG, TPSA i TVN (udział każdej akcji – 12,50%)

Źródło: Obliczenia własne na podstawie samodzielnie skonstruowanej sieci neuronowej oraz danych z GPW SA.

Tabela nr 2 przedstawia uzyskane stopy zwrotu z portfela rynkowego (portfel składający się z akcji 11 badanych spółek, w którym udział każdej z nich wynosi 1/11) oraz z portfela wskazanego przez sieć neuronową dla poszczególnych faz oraz stopę zwrotu z całego okresu. Ponadto tabela zawiera wartość obu portfeli po każdej z faz.

Tabela nr 2

Stopa zwrotu z portfela rynkowego i portfela wskazanego przez sieć

Fazy	Stopa zwrotu z portfela rynkowego	Wartość portfela po danej fazie (wartość początkowa 1000)	Stopa zwrotu z portfela wskazanego przez SSN	Wartość portfela po danej fazie (wartość początkowa 1000)
1	1,60%	1015,96	2,93%	1029,28
2	-8,82%	926,35	-8,73%	939,45
3	13,66%	1052,90	32,54%	1245,15
4	8,90%	1146,64	8,31%	1348,59
Suma		14,66%		34,86%

Źródło: Obliczenia własne na podstawie samodzielnie skonstruowanej sieci neuronowej oraz danych z GPW SA..

Ogólnie można zauważyć, że różnice w stopach zwrotu z obu rodzajów portfeli nie są zbyt duże, z wyjątkiem fazy trzeciej. Sieć neuronowa wskazała dla tej fazy akcję (KGHM), która była zdecydowanie najbardziej zyskowna. W pozostałych fazach portfel wyznaczony przez sieć osiągał wyniki zbliżone do wyników osiągniętych przez portfel rynkowy. Zadowolające jest to, że w żadnej z faz wynik uzyskany dzięki sieci nie był kategorycznie gorszy. Z drugiej strony warto podkreślić, że wyniki osiągnięte przez inwestora posługującego się sztuczną siecią neuronową, w trzech fazach były lepsze niż wyniki osiągnięte przez rynek. W całym analizowanym okresie, czyli w 2010 roku, rynek zyskał ponad 14%, a przy stosowaniu SSN inwestor mógł zarobić niecałe 35%, czyli ponad dwa razy więcej.

Podsumowanie

W pracy zostały zaprezentowane wyniki badań nad zastosowaniem sieci neuronowych do wyboru atrakcyjnych akcji pod względem ich przyszłej stopy zwrotu. Uzyskane wyniki eksperymentu dla jedenastu spółek wskazują na dużą przydatność tego narzędzia w analizie takiego typu danych. W przedstawionym przykładzie inwestor wykorzystujący do swoich inwestycji sztuczne sieci neuronowe osiąga średnio wyższą stopę zwrotu niż inwestując w portfel rynkowy. SSN mogą być użytecznym narzędziem wspomagającym proces inwestowania. Jednak nie powinna to być jedyna stosowana metoda, a jej wyników nie należy przyjmować bez żadnych wątpliwości. Wyniki uzyskane przez sieć należy poprzeć dokładną analizą spółek, sytuacji rynkowej, koniunktury itd. Użyteczność sztucznych sieci neuronowych jako dodatkowego źródła uzyskiwania informacji jest niewątpliwie nieoceniona. Ponieważ potrafią one znaleźć takie zależności pomiędzy danymi, których najlepszy nawet analityk nie dostrzega. Kluczowa jest także sfera doboru odpowiedniej struktury naszej sieci oraz danych wykorzystywanych podczas procesu uczenia. Należy też pamiętać, że już po wyborze składników portfela inwestycyjnego należałoby systematycznie kontrolować, co dzieje się z wybranymi aktywami, a w sytuacjach dla nas, jako inwestorów, niekorzystnych zmieniać skład portfela. Wyniki osiągnięte w badaniu przedstawionym w niniejszej pracy pozwalają na sformułowanie wniosku o przydatności sztucznych sieci neuronowych do typowania najatrakcyjniejszych akcji na warszawskiej giełdzie.

Streszczenie

W ostatnich latach można zauważyć, że coraz więcej inwestorów przy wyborze instrumentów finansowych, stosuje komputerowe systemy wspomagania decyzji. Bardzo często wykorzystuje się w tym celu sztuczne sieci neuronowe. W pracy przedstawione podstawowe teoretyczne aspekty związane z SSN. Oceniono też ich skuteczność w wyborze najatrakcyjniejszych spółek notowanych na GPW.

Summary

In recent years can be seen that more and more investors use computer decision support system when They are choosing financial instruments. Artificial neural networks (ANN) are often used for this purpose. The paper presents the basic theoretical aspects of the ANN. Evaluated also their effectiveness in selecting the most attractive companies listed on the Warsaw Stock Exchange.

Bibliografia

1. Białko M., *Sztuczna inteligencja i elementy hybrydowych systemów ekspertowych*, Wydawnictwo Uczelniane Politechniki Koszalińskiej, Koszalin 2005.
2. Borowski K., Grabowski S., *Analiza zależności międzyrynkowych przy użyciu sztucznych sieci neuronowych – empiryczny przykład neuronowego sytemu transakcyjnego na wartość indeksu WIG*, „Studia i Prace Kolegium Zarządzania i Finansów” 2006, z. 68.
3. Garsztko P., Łażewski M., *Prognozowanie cen akcji notowanych w systemie ciągłym z wykorzystaniem sieci neuronowych na podstawie obserwacji „tick by tick”*, [w:] *Rynek kapitałowy : skuteczne inwestowanie : konferencja naukowa zorganizowana przez Katedrę Ekonometrii i Statystyki Wydziału Nauk Ekonomicznych i Zarządzania, Międzyzdroje, 5-7 września 2004 r. Cz. 2* pod red. Waldemara Tarczyńskiego, Wydawnictwo Naukowe Uniwersytetu Szczecińskiego, Szczecin 2004.
4. *Inteligentne systemy w zarządzaniu. Teoria i praktyka*, pod red. J. S. Zielińskiego, Wydawnictwo Naukowe PWN, Warszawa 2000.
5. Kasperski M. J., *Sztuczna inteligencja. Droga do myślących maszyn*, Wydawnictwo HELION, Gliwice 2003.
6. Kowarda G., *Dobór zmiennych i proces uczenia w analizach rynku papierów wartościowych za pomocą sztucznych sieci neuronowych*, „Optimum” 2008, nr 2.
7. Łęski J., *Systemy neuronowo – rozmyte*, Wydawnictwo Naukowo – Techniczne, Warszawa 2008.
8. Masters T., *Sieci neuronowe w praktyce. Programowanie w języku C++*, Wydawnictwa Naukowo – Techniczne, Warszawa 1996.
9. Morajda J., *O użyteczności sieci neuronowych i algorytmów genetycznych w realizacji inwestycyjnych systemów decyzyjnych*, „Zeszyty Naukowe Małopolskiej Wyższej Szkoły Ekonomicznej w Tarnowie” 2006, nr 1 (9).
10. Motowidlak T., *Zastosowanie systemów sztucznej inteligencji w różnych dziedzinach nauki*, „Pieniądze i Więź” 2007, nr 3.
11. Nissan S., *Tworzenie sieci neuronowych – to proste*, „Software 2.0” 2005, nr 2.

12. Seroczyński T., *Konekcjonizm w praktyce, czyli Sztuczne Sieci Neuronowe*, Uniwersytet Warszawski, Warszawa 2003.
13. Żurada J., Barski M., Jędruch W., *Sztuczne sieci neuronowe. Podstawy teorii i zastosowania*, Wydawnictwo Naukowe PWN, Warszawa 1996.