

Politechnika Łódzka  
Wydział Elektroniki, Elektrotechniki, Informatyki i Automatyki  
Instytut Informatyki Stosowanej

Streszczenie rozprawy doktorskiej

**Predykcja cen akcji na giełdzie z zastosowaniem  
modeli analityczno-neuronowych**

mgr inż. MICHAŁ PALUCH

Promotor pracy:  
dr hab. inż. Lidia Jackowska-Strumiłło, prof. PŁ

Łódź, 2016 r.

## **Spis treści**

Spis treści.....	2
<b>1. Wstęp.....</b>	<b>3</b>
<b>2. Cel, tezy i zakres pracy.....</b>	<b>5</b>
<b>3. Analiza danych na GPW.....</b>	<b>7</b>
3.1 Podstawy funkcjonowania GPW.....	7
3.2 Analiza techniczna.....	8
3.3 Analiza Fraktalna.....	9
<b>4. Sztuczne Sieci Neuronowe.....</b>	<b>14</b>
4.1 Wiadomości wstępne.....	14
4.2 Jednokierunkowe sztuczne sieci neuronowe.....	15
4.3 Rekurencyjne sztuczne sieci neuronowe.....	16
<b>5. Badania eksperymentalne.....</b>	<b>17</b>
<b>6. Ekspertowy system informatyczny wspomagający podejmowanie decyzji     inwestycyjnych.....</b>	<b>20</b>
<b>7. Podsumowanie.....</b>	<b>23</b>
<b>Bibliografia.....</b>	<b>26</b>

# 1. Wstęp

W obecnych czasach prawie każda dziedzina nauki i jej zastosowań jest skomputeryzowana i zautomatyzowana. W wielu branżach przedsiębiorstwa nie są w stanie prawidłowo funkcjonować bez rozwiązań informatycznych. Jedną z ważniejszych tego typu dziedzin są finanse, utożsamiane z prosperowaniem firm oraz standardem życia podstawowej jednostki ekonomicznej jaką jest gospodarstwo domowe. Bez względu jednak na to, czy jest to osoba fizyczna czy prawna, każda pragnie maksymalizować zyski. Rynek finansowy udostępnia wiele produktów realizujących ten cel np. konta oszczędnościowe, lokaty, fundusze inwestycyjne, waluty, obligacje oraz instrumenty finansowe takie jak akcje. Każdy z nich charakteryzuje się określonym ryzykiem utraty środków. Największe występuje w przypadku handlu akcjami, a jego wysokość jest proporcjonalna do możliwości osiągnięcia dużych zysków w krótkim okresie czasu (Dębski, 2010). Ten czynnik sprawia, że handel akcjami jest dla wielu inwestorów ważną formą zarabiania pieniędzy. Możliwość przewidywania przyszłych kursów akcji jest istotna nie tylko w przypadku decyzji inwestycyjnych lecz również przy planowaniu strategii rozwoju firmy, wybierania partnerów do współpracy, analizy finansowej przedsiębiorstwa, itp.

Na rynku informatycznym istnieje wiele narzędzi wspierających inwestorów w podejmowaniu decyzji inwestycyjnych. Najczęściej stosowanymi narzędziami są systemy informatyczne implementujące wskaźniki analizy technicznej, które na podstawie historycznych danych prezentują sposób kształtowania się cen akcji na wykresach. W prognozowaniu trendów coraz popularniejsze stają się również, stosowanie sztucznej inteligencji – dziedziny powstałej z inspiracji biologicznymi modelami.

Dostępne na rynku informatyczne systemy transakcyjne skupiają się na prezentacji na wykresach wskaźników analizy technicznej, które użytkownik sam może wybrać (czasem ma do wyboru nawet kilkaset wskaźników). Jeden wykres przeznaczony jest dla jednej firmy co znacznie wydłuża proces analizy danych. Jeżeli inwestor chciałby zainwestować w firmę „X” musiałby przejrzeć ogromny zbiór danych, a biorąc pod uwagę tempo zmian cen na Giełdzie Papierów Wartościowych (GPW), zanim by skończył analizować dane, sytuacja na giełdzie mogłaby się na tyle zmienić, że jego decyzja mogłaby spowodować skutki odwrotne do zamierzonych. Z powyższej sytuacji można wywnioskować, że inwestorzy albo nie wykorzystują pełnych możliwości systemów analitycznych i opierają się na „własnym doświadczeniu”, kilku wybranych wskaźnikach lub analizach domów maklerskich. Ilustruje to problem z jakim dzisiejszy inwestorzy muszą się na co dzień mierzyć.

Żyjemy w epoce tzw. Społeczeństwa informacyjnego, w czasach, w których na każdym kroku jesteśmy zalewani ogromną liczbą danych, z których każdy musi wybierać te najważniejsze dla niego. Na rynku pojawia się coraz więcej firm zajmujących się dostarczaniem rozwiązań informatycznych służących do klasyfikowania dużych zbiorów danych tzw. „Big Data”, jednak nie powstał jeszcze lub nie jest ogólnodostępny, system ekspertowy, który na podstawie rozbudowanej analizy danych historycznych, przedstawiłby decydentowi strategię inwestycyjną w ramach tzw. „daytradingu”, czyli zakupu i sprzedaży walorów tego samego dnia.

W ramach rozprawy doktorskiej przedstawione zostały badania nad zastosowaniem sztucznych sieci neuronowych (SSN) oraz wskaźników analizy technicznej i analizy fraktalnej do przewidywania cen akcji na giełdzie. Zaproponowano modele hybrydowe, które są mniej podatne na fałszywe sygnały pochodzące z GPW niż SSN i choć zapewniają mniejszy zysk, zmniejszają ryzyko popełnienia błędu oraz strat.

W ramach rozprawy, zaprojektowano także i zbudowano ekspertowy system informatyczny oraz algorytmy decyzyjne wykorzystujące sztuczne sieci neuronowe, które w oparciu o modele analizy technicznej (AT) oraz analizy fraktalnej (AF), spośród spółek notowanych na giełdzie, wybierają te, które osiągną maksymalny zysk danego dnia, w stosunku do ceny otwarcia waloru. System ekspertowy został przetestowany na przykładzie GPW w Warszawie.

## **2. Cel, tezy i zakres pracy**

Dostępne na rynku finansowym aplikacje umożliwiają przede wszystkim wyświetlanie wykresów ze wskaźnikami lub technikami analizy technicznej, modyfikację wskaźników lub budowanie ich przez samych inwestorów. Dostępne są również narzędzia informatyczne wykorzystujące sztuczne sieci neuronowe do prognozowania zmian cen na giełdzie. Takie programy jak Amibroker lub MetaStock dają możliwość klientom budowania własnych SSN, pod warunkiem znajomości ich wewnętrznego języka programowania lub implementacji gotowych skryptów, nie gwarantując wiarygodności wyników. Już sama ta cecha odstrasza wielu prywatnych inwestorów i czyni z SSN zaledwie dodatkowy sygnał kupna/sprzedaży lub „giełdową ciekawostkę”. Tymczasem na całym Świecie prowadzone są badania nad zastosowaniem istniejących i budową nowych modeli prognozujących dane finansowe m.in. ceny akcji.

### **Głównymi celami rozprawy są:**

1. Opracowanie nowego, hybrydowego podejścia do przewidywania cen akcji na giełdzie, łączącego AT, AF i SSN oraz porównanie go z tradycyjnymi modelami SSN zbudowanymi na podstawie danych historycznych z giełdy.
2. Opracowanie strategii inwestycyjnej wykorzystującej algorytmy decyzyjne z zastosowaniem SSN i modeli predykcji cen akcji oraz zbadanie jej skuteczności na podstawie porównania osiągniętych zysków z wartościami indeksów giełdowych.
3. Zbudowanie inteligentnego systemu informatycznego, w którym zaimplementowane będą opracowane modele, strategia oraz analiza wykresów cen akcji.

### **Tezy rozprawy sformułowano następująco:**

#### **Teza 1.**

Modele hybrydowe łączące obliczenia neuronowe, analizę techniczną i analizę fraktalną umożliwiają dokładniejszą predykcję cen akcji na giełdzie od rozdzielnie stosowanych modeli analitycznych oraz modeli neuronowych.

#### **Teza 2.**

Ekspertowy system informatyczny wykorzystujący analityczno-neuronowe algorytmy decyzyjne i modele predykcji cen akcji umożliwia zaplanowanie strategii inwestycyjnej na giełdzie papierów wartościowych i osiągnięcie zysków na poziomie wyższym od indeksów giełdowych.

### **Realizacja celów pracy wymagała wykonania następujących zadań:**

1. Implementacja najczęściej stosowanych, polecanych przez ekspertów, wskaźników analizy technicznej.
2. Zbudowanie i przetestowanie wskaźników analizy fraktalnej.
3. Zastosowanie algorytmów uczenia sztucznych sieci neuronowych zgodnie z zaproponowaną metodyką.
4. Wskazanie najdokładniejszych modeli i ich wykorzystanie do krótkoterminowej predykcji cen akcji.

5. Zbudowanie, systemu ekspertowego, który na podstawie wyników sieci oraz algorytmów decyzyjnych, dokonuje kompleksowej analizy spółek i wybiera te, których ceny w kolejnym dniu wzrosną. Najważniejszym kryterium wyboru jest najwyższy przewidywany wzrost. Wybór systemu jest wyświetlany użytkownikowi jako portfel inwestycyjny na kolejny dzień sesji na giełdzie papierów wartościowych.

### **3. Analiza danych na GPW**

W poniższym rozdziale opisano stan wiedzy na temat funkcjonowania giełdy papierów wartościowych. Przedstawiono zasady w oparciu, o które działa analiza techniczna, wskaźniki oraz techniki AT wykorzystywane w pracy.

#### **3.1. Podstawy funkcjonowania GPW**

Giełda Papierów Wartościowych jest miejscem, w którym kupujący i sprzedający wymieniają się określonymi towarami po ustaleniu wspólnie akceptowanej ceny. Obrót jest obrotem niematerialnym. To znaczy, że wszystkie papiery wartościowe przechowywane są w formie zapisów elektronicznych w systemie Krajowego Depozytu Papierów Wartościowych oraz na rachunkach inwestycyjnych klientów w biurach maklerskich.

Każde zlecenie kupna i sprzedaży musi zawierać ściśle określone informacje np. nazwę papieru wartościowego, rodzaj zlecenia, datę złożenia, wartość, liczbę itp. Inwestując na GPW, w krótkim czasie można dużo zyskać, lub też wiele stracić. Nie można jednak mówić o długookresowych, stałych przychodach bez posiadania strategii. Pod tym względem inwestorów można podzielić na dwie grupy:

- Inwestorów długoterminowych, którzy w oparciu o szczegółową analizę fundamentalną spółek, zakupują dużą liczbę akcji i sprzedają po dłuższym kilku- lub kilkunastomiesięcznym okresie;
- Inwestorów krótkoterminowych, którzy, aby zminimalizować ryzyko zamykają pozycję każdego dnia, a swoje decyzje inwestycyjne opierają o analizę techniczną.

Analiza fundamentalna oznacza szczegółowe zagłębienie się w działalność spółki, sektora, w którym się znajduje oraz sektorów powiązanych i nie będzie w ramach pracy poruszana. Analiza techniczna natomiast, opiera się na badaniu skutków zachowań

rynku (w formie cen) oraz poszukuje na wykresach, trendów oraz ich kształtów, czyli formacji, które pomogą przewidzieć zachowanie rynku, maksymalizując zysk inwestora. Cel ten jest osiągnięty poprzez znajdowanie oraz analizę trendów.

**Trend** interpretowany jest jako utrzymywanie się przez pewien czas, tendencji kursu do zmian cen walorów w pewnym kierunku. Wyróżnić można trzy rodzaje trendów:

- Wzrostowy
- Spadkowy
- Horyzontalny

## **3.2. Analiza techniczna**

### **Charakterystyka ogólna**

Analiza techniczna opiera się na trzech przesłankach:

- rynek dyskontuje wszystko – co oznacza, że zmiany cen powinny odzwierciedlać, realne zmiany w relacji popytu do podaży. Jeżeli podaż przewyższa popyt ceny będą spadać, w sytuacji odwrotnej, rosnać.
- ceny podlegają trendom – analiza techniczna opierając się na interpretacji ruchów cen przy pomocy wykresów, skupia się na znalezieniu trendów, na podstawie których można określić czy ceny będą rosnać czy spadać
- historia się powtarza - badanie wykresów pozwala odnaleźć powtarzające się wzory według których zmieniają się ceny. Wynika to z powtarzalności ludzkich zachowań w określonych sytuacjach. Analitycy znając najczęściej występujące wzory, starają się odnaleźć je w bieżących notowaniach i na tej podstawie prognozować przyszłość.

Można wyróżnić następujące zalety analizy technicznej:

- jako narzędzie analityczne może być z powodzeniem stosowana na różnych rodzajach rynków np. kapitałowym oraz terminowym;
- może służyć do prognozowania gospodarczego, ponieważ kierunek cen towarów wiele mówi o kierunku inflacji oraz sile bądź słabości gospodarki;
- może być stosowana do różnych wymiarów czasu, ponieważ wykresy oraz średnie mogą być podstawą analizy niezależnie od tego czy inwestuje się długoterminowo (średnia „Dow Jones Industrial” stosowana jest nieprzerwanie

od 26 maja 1896 roku (Reuters, 2006)), czy gra na niewielkich wahanach cen w ciągu dnia;

- obejmuje badaniami tylko to, co rzeczywiście dzieje się na rynku;
- opiera się na dokładnych i aktualnych danych dostępnych w czasie rzeczywistym.

Wadami analizy technicznej są (Reuters, 2006):

- wychodzi z założenia, że ludzka natura nie zmienia się, natomiast zachowania rynku są powtarzalne, co jest tylko częściowo prawidłowym założeniem, ponieważ historia nie powtarza się w identyczny sposób, a formacje nie zawsze pojawiają się w tych samych miejscach. Rezultatem tego, interpretacja wykresów i tym samym przewidywanie przyszłych zachowań rynku, zależą wyłącznie od umiejętności inwestora;
- określa wyłącznie pewne prawdopodobieństwo wystąpienia danego zdarzenia w przyszłości (osiągnięcia danej ceny przez pewien walor);
- obarczona jest dużą dozą subiektywizmu wynikającą z konieczności interpretacji wykresów oraz wyników matematycznych modeli, co w praktyce może oznaczać, że inwestor w analizie zobaczy „to co chce widzieć”, opierając się w ten sposób na subiektywnej opinii i popełniając kosztowne błędy;

### **3.3. Analiza fraktalna**

Jedną z alternatywnych hipotez rynku jest, dynamicznie rozwijająca się hipoteza rynku fraktalnego (FMH, ang. *Fractal Market Hypothesis*), wprowadzona przez Petersa (1997). Bazuje ona na fraktalach oraz teorii chaosu.

Pojęcie „fraktal” zostało wprowadzone i spopularyzowane w książce Benoita Mandelbrota (1982). Jej istotnym przesłaniem był pogląd, że w naturze wszystkie obiekty geometryczne mają naturę fraktalną, natomiast figury takie jak koło, kwadrat czy linia prosta są jedynie ich uproszczeniem. Mandelbrot scharakteryzował fraktale następującymi własnościami:

- Ich wymiar nie jest liczbą całkowitą
- Są określone zależnością rekurencyjną
- Posiadają cechy samopodobieństwa (samopodobieństwo występuje gdy figurę można podzielić na części, z których każda jest podobna do całości (Białynicki-Birula i Białynicka-Birula, 2004))



Wymienione właściwości fraktali, nie stanowią jednak ścisłej definicji matematycznej, choćby dlatego, że te same obiekty można opisać w różny sposób, zarówno rekurencyjnie jak i iteracyjnie (Kudrewicz, 2015). Precyzyjna definicja jest oparta na pojęciu wymiaru fraktalnego.

Z powyższych założeń wynika stwierdzenie, że fraktale są pewnym rodzajem obiektów geometrycznych i mogą występować na przestrzeniach o jednym lub wielu wymiarach (Kudrewicz, 2015). Można wymienić kilka przykładów obiektów geometrycznych na płaszczyźnie  $R^2$ :

- Zbiór Cantora – zbiór punktów opisany w 1883 r. przez Geoga Cantora jest najstarszą samopodobną strukturą (Białynicki-Birula i Białynicka-Birula, 2004). Budowa zbioru zaczyna się od odcinka  $[0,1]$ , który następnie dzieli się na dwa odcinki  $[0,1/3]$  i  $[2/3,1]$ , usuwając przedział  $[1/3,2/3]$ . Powstałe w ten sposób dwa odcinki dzieli się ponownie, zgodnie z powyższą zasadą. Procedura powtarzana do nieskończoności tworzy zbiór Cantora (Białynicki-Birula i Białynicka-Birula, 2004).
- Krzywa Kocha – zasada jej powstawania jest podobna do zbioru Cantora. Punktem wyjścia jest jednostkowy odcinek dzielony na trzy części z czego część środkowa jest wyginana w trójkąt, a nie usuwana. W każdej kolejnej iteracji, każdy fragment odcinka jest dzielony zgodnie z powyższą zasadą. Zastosowanie powyższej konstrukcji na trójkącie równobocznym generuje tzw. płatek śniegu Kocha. W każdej kolejnej iteracji obrzeże figury wzrasta o  $1/3$ . Zatem obwód ograniczonej figury jest nieskończony, jednak ponieważ można ją wpisać w skończony okrąg, jej powierzchnia jest ograniczona.
- Brzeg zbioru Mandelbrota (Mandelbrot, 1980) – na płaszczyźnie zmiennej zespolonej należy rozpatryć ciąg wyrazów  $z_1, z_2, \dots$ , w którym wyraz początkowy jest zerem, natomiast kolejne wyrazy określone są zależnością:

$$z_{n+1} = z_n^2 + c \quad (3.1)$$

gdzie:

$c$  – parametr zespolony.

W zależności od parametru  $c$ , ciąg dąży do nieskończoności lub jest ograniczony. Zbiór Mandelbrota jest tworzony przez te wartości parametru  $c$ , dla których ciąg pozostaje ograniczony.

- Trójkąt Sierpińskiego – jest to jedna z najbardziej znanych samopodobnych figur. Punktem wyjściowym w jego tworzeniu jest pełny trójkąt. W pierwszej iteracji trójkąt jest dzielony na 4 części, w ten sposób, że łączone są środki boków trójkąta liniami prostymi. Utworzony przez nie wewnętrzny trójkąt jest usuwany, natomiast pozostałe 3 trójkąty poddawane są poprzednim procedurom. Po wykonanie tych operacji nieskończenie wiele razy, zostaje utworzony trójkąt Sierpińskiego.

Obiekty fraktalne, poza atrakcyjną wizualnie formą mają praktyczne zastosowanie m.in. w następujących dziedzinach:

- Kompresja obrazów
- Badanie nieregularności powierzchni
- Badanie struktury łańcuchów DNA itd.
- Badanie cen akcji na giełdzie papierów wartościowych

### **Wymiar fraktalny**

Najstarszym i najczęściej stosowanym wymiarem, jest wymiar topologiczny, opierający się na zastosowaniu liczb jako współrzędnych opisujących badany obiekt. Wymiar jest również jedną z podstawowych charakterystyk fraktali. Zgodnie z definicją Mandelbrota, fraktalem można nazwać „taki zbiór, którego wymiar topologiczny jest różny (mniejszy) od wymiaru Hausdorffa” (Kudrewicz, 2015). Powyższa definicja, ma precyzyjny opis matematyczny, jednak nie jest on niezbędny w przypadku stosowania analizy fraktalnej do badania cen akcji. Dlatego w rozprawie stosowana jest definicja Minkowskiego (Falconer, 1990; Peitgen i inni, (1997); Mattila i inni., 1999), występująca w literaturze pod różnymi nazwami: wymiaru fraktalnego, wymiaru pudełkowego lub wymiaru pojemnościowego.

Pojęcie wymiaru fraktalnego może zostać wyjaśnione na podstawie następującego przykładu:

Niech obiekt geometryczny  $F$  znajdujący się w  $n$ -wymiarowej przestrzeni euklidesowej zostanie pokryty zbiorem kwadratów, kostek - „pudełek” o boku długości  $\varepsilon$  (w zależności od liczby wymiarów mogą to być również sześciiany, kule, czy inne wypukłe bryły).

Aby pokryć kwadrat o długości boku 1, pudełkiem z  $\varepsilon=1$ , wystarczy 1 pudełko. Jeżeli jednak ten sam kwadrat należałoby pokryć pudełkami z  $\varepsilon=1/2$ , potrzebne byłyby 4 pudełka, dla  $\varepsilon=1/4$ , potrzebnych jest 16 pudełek itd. Zatem liczba pudełek rośnie odwrotnie proporcjonalnie do kwadratu długości boku pudełka.

Niech  $N_\varepsilon(F)$ , będzie minimalną liczbą „pudełek”, potrzebnych do okrycia powierzchni całego obiektu  $F$ . W takim wypadku, gdy:

- $F$  jest odcinkiem linii, to  $N_\varepsilon(F) \sim 1/\varepsilon$
- $F$  jest obiektem w przestrzeni dwuwymiarowej, to  $N_\varepsilon(F) \sim (1/\varepsilon)^2$
- $F$  jest obiektem w przestrzeni trójwymiarowej, to  $N_\varepsilon(F) \sim (1/\varepsilon)^3$

Przy małych wartościach  $\varepsilon$  zachodzi w przybliżeniu proporcjonalność:

$$N_\varepsilon(F) \sim (1/\varepsilon)^d \quad (3.2)$$

gdzie:

$d$  – wymiar obiektu

Na podstawie wzoru 3.24 można zdefiniować wymiar fraktalny w następujący sposób:

$$d(F) = \lim_{\varepsilon \rightarrow 0} \frac{\log N_\varepsilon(F)}{\log(\frac{1}{\varepsilon})} \quad (3.3)$$

W celu zmierzenia wymiaru fraktalnego na rynku kapitałowym, wykres cen akcji należy pokryć  $N$  kwadratami, a następnie podzielić na dwa równe okresy (Ethlers, 2004; Ethlers, 2005). Liczba kwadratów w okresie  $T_1$  będzie równa:

$$N_{T_1}(k) = \frac{H_{T_1}(k) - L_{T_1}(k)}{T_1} \quad (3.4)$$

gdzie:

$H_{T_1}(k)$  – najwyższa cena akcji w okresie  $T_1$ ,

$L_{T_1}(k)$  – najniższa cena akcji w okresie  $T_1$

w okresie  $T_2$  będzie równa:

$$N_{T_2}(k) = \frac{H_{T_2}(k) - L_{T_2}(k)}{T_2} \quad (3.5)$$

gdzie:

$H_{T_2}(k)$  – najwyższa cena akcji w okresie  $T_2$ ,

$L_{T_2}(k)$  – najniższa cena akcji w okresie  $T_2$

w całym badanym okresie  $T_{1-2}$  liczba kwadratów będzie równa:

$$N_{T_{1-2}}(k) = \frac{H_{T_{1-2}}(k) - L_{T_{1-2}}(k)}{T_{1-2}} \quad (3.6)$$

gdzie:

$H_{T_{1-2}}(k)$  – najwyższa cen akcji w całym badanym okresie,

$L_{T_{1-2}}(k)$  – najniższa cen akcji w całym badanym okresie.

na podstawie wzorów 3.25 - 3.28, można wyprowadzić wzór na wymiar fraktalny  $D$  wykresu cen akcji:

$$D = \frac{\log\left(\frac{N_{T_1} + N_{T_2}}{N_{T_{1-2}}}\right)}{\log\left(\frac{T_2}{T_{1-2}}\right)} = \frac{\log(N_{T_1} + N_{T_2}) - \log(N_{T_{1-2}})}{\log(2)} \quad (3.7)$$

### Średnia fraktalna

Wymiar fraktalny na rynkach kapitałowych może być stosowany w różnorodny sposób. Na przykład do określenia ryzyka inwestycji w indeksy (Orzeszko, 2010) lub na przykładzie Ethlersa (2004) do budowy średniej ruchomej (Kaufman 2005).

FMA (ang. *Fractal Moving Average*) - Fraktalna adaptacyjna średnia ruchoma zdefiniowana jest wzorem 3.30:

$$FMA_{N,C}(k) = \frac{C(k) + (1-\alpha)C(k-1) + \dots + (1-\alpha)^{N-1}C(k-N+1)}{1 + (1-\alpha) + \dots + (1-\alpha)^{N-1}} \quad (3.8)$$

gdzie:

$\alpha$  określona jest wzorem:

$$\alpha = \exp(-4,6 * (D-1)) \quad (3.9)$$

gdzie:

$D$  – wymiar fraktalny określony wzorem 3.29.

Średnia FMA znacznie szybciej od średniej SMA sygnalizuje zmianę trendu z horyzontalnego na spadkowy lub wzrostowy, natomiast w przypadku silnych trendów sygnały sprzedaży, bądź kupna, wyprzedzają dane pochodzące z SMA.

## 4. Sztuczne sieci neuronowe

W tym rozdziale opisano podstawowe zagadnienia dotyczące sztucznych sieci neuronowych stosowanych w pracy. Przedstawiono również ich modele oraz metody nauki.

### 4.1 Wiadomości wstępne

Historyczna praca McCulloch'a i Pitts'a (1943) zapoczątkowała nową dziedzinę badań: sztuczne sieci neuronowe (SSN). Matematycy przedstawili w niej sztuczny neuron - model komórki nerwowej oraz powiązali jej działanie z przetwarzaniem danych. Od tego czasu dziedzina była stale rozwijana. Donald Hebb (1949) odkrył, że informacja może być przechowywana w strukturze połączeń między neuronami po czym zaproponował nową metodę uczenia SSN polegającą na zmianie wag połączeń pomiędzy neuronami. Słowo „Perceptron” zostało zaproponowane przez Rosenblatta (1965), który wraz z Charlesem Wightmanem w 1957 roku zbudowali sieć neuropodobną. Był to układ częściowo elektroniczny, częściowo elektromechaniczny, służący do rozpoznawania znaków alfanumerycznych. Była to pierwsza fizyczna i działająca tego typu maszyna. Powyższe osiągnięcie doprowadziło do rozpropagowania zainteresowania sieciami neuronowymi oraz badań nad nimi na całym Świecie. Dopiero Minsky i Papert (1969) zahamowali ich rozwój. W swojej pracy udowodnili bowiem, że sieci jednowarstwowe mają ograniczony zakres zastosowań – nie są w stanie rozwiązać problemów liniowo-separowalnych. Renesans SSN zapoczątkowały prace m.in. Rumelharta i innych (1986) oraz Andersona i Rosenfelda (1988), którzy opracowali algorytm wstecznej propagacji błędów umożliwiający uczenie sieci wielowarstwowych. Przyczyniło się do gwałtownego zainteresowania tematyką SSN oraz wzrostu badań nad ich zastosowaniem, budową oraz metodami uczenia (Tadeusiewicz, 1993).

Dzisiaj sztuczne sieci neuronowe znalazły zastosowanie w wielu dziedzinach życia. Wśród wielu ciekawych zastosowań sieci neuronowych można wymienić:

- Rozpoznawanie obrazów (Tadeusiewicz i Mikrut 1994; Tadeusiewicz, 1994; Jajuga, 1995);
- Sterowanie robotami (Al-Junaid, 2015, 2015; Moldovan et al., 2015);

- Prognozowanie procesów gospodarczych (Tadeusiewicz, 1995; Morajda, 1997);
- Kodowanie i dekodowanie informacji;
- Klasyfikacja bezwzorcową (Kohonen, 1995; Grabowski 1997);
- Fotokatalityczna degradacja barwnika tekstylnego (Lenzi et al., 2016);
- System klasyfikujący i rozpoznający sygnały sonarowe (Tadeusiewicz, 2007);
- Modelowanie właściwości dynamicznych czujników temperatury (Jackowska-Strumiłło, 2011);
- Przewidywanie obciążeń sieci energetycznych (Dudek et al., 2015);
- I inne.


Duże zainteresowanie sztucznymi sieciami neuronowymi wynika przede wszystkim z poszukiwań nowych sposobów budowy bardziej efektywnych i niezawodnych modeli do przetwarzania informacji. Spośród najważniejszych cech SSN można wymienić (Tadeusiewicz, 2007):

- zdolność do generalizowania zdobytej wiedzy;
- w przeciwieństwie do klasycznych modeli komputerowych posiadają zdolność nabywania wiedzy poprzez uczenie;
- równoległe przetwarzanie informacji - informacja przetwarzana jest jednocześnie we wszystkich neuronach w SSN;
- zdolność do adaptacji, wynikająca ze zdobywania wiedzy przez naukę - SSN może być douczana, przy pomocy zmodyfikowanego ciągu uczącego, wskutek czego „może” zaadoptować się do nowych danych.

## **4.2 Jednokierunkowe sztuczne sieci neuronowe**

W zakresie przetwarzania informacji możliwości pojedynczego neuronu są stosunkowo niewielkie. Wynika to z ograniczonej możliwości gromadzenia informacji w postaci wag. Wynika z tego wniosek, że sieć neuronowa musi być zbudowana z większej liczby neuronów, aby mogła spełniać swoje zadania. W związku z tym podobnie jak w przypadku biologicznej sieci neuronowej, sztuczne neurony łączą się w grupy, które pozwalają na przeprowadzanie bardziej złożonych obliczeń i dzieli się je

na warstwy. Przykład architektury sieci jednokierunkowej wielowarstwowej (MLP – *Multilayer Perceptron*) został zaprezentowany na rysunku 4.1.



Rys. 4.1 SSN typu perceptron wielowarstwowy o strukturze (3-5-1)

Cechą charakterystyczną sieci MLP jest występowanie, co najmniej jednej warstwy ukrytej neuronów, która pośredniczy w przekazywaniu sygnałów między węzłami wejściowymi, a warstwą wyjściową. Na rys. 4.1 zaprezentowano przykładową architekturę sieci jednokierunkowej dwuwarstwowej o strukturze (3-5-1), tzn. zbudowanej z warstwy wejściowej (3 wejścia) oraz dwóch warstw neuronów: warstwy ukrytej (5 neuronów) oraz warstwy wyjściowej (1 neuron). Na rysunku 4.1 na czerwono zaznaczone są dodatkowe wejścia ( $x_0=1$ ) nazywane „biasami”, czyli stałymi wartościami wspomagającymi proces nauki SSN.

### 4.3 Rekurencyjne sztuczne sieci neuronowe

Sieci rekurencyjne różnią się od sieci jednokierunkowych występowaniem sprzężenia zwrotnego pomiędzy warstwą wyjściową i wejściową. Liczba sprzężeń nie jest stała i może być uzależniona od zadanego problemu. Wśród sieci rekurencyjnych można wyróżnić sieci jednowarstwowe (jedna warstwa neuronów wyjściowych) oraz sieci wielowarstwowe – posiadające dodatkową warstwę ukrytą.

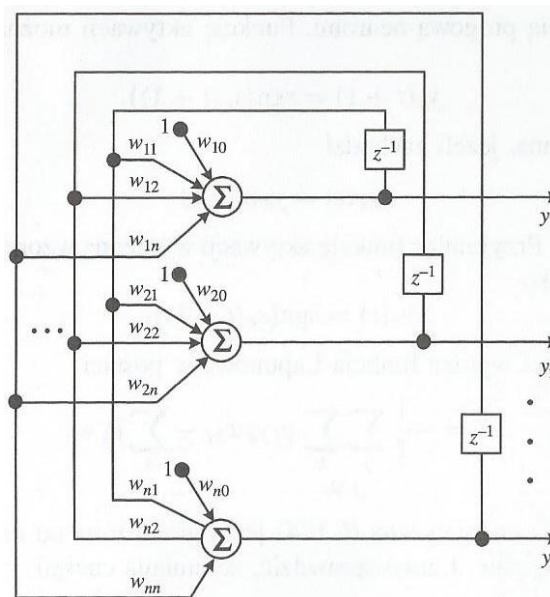
Do modelowania systemów dynamicznych często stosowane są sieci MLP ze sprzężeniami zwrotnymi, dzięki czemu można modelować zmiany ich właściwości. Efekt modelowania dynamicznego można też uzyskać wprowadzając na wejście sieci jednokierunkowej typu MLP oprócz bieżących wartości sygnałów, także ich próbki z chwil poprzednich (Narendra i Parthasarathy 2012, Jackowska-Strumiłło 2009).

Często stosowaną rekurencyjną SSN, jest sieć Hopfielda. Nazywana jest również pamięcią autoasocjacyjną. Po raz pierwszy została zaprezentowana przez Hopfielda

(1982) i była punktem zwrotnym w badaniach nad sieciami neuronowymi. Można ją scharakteryzować następującymi cechami (Tadeusiewicz, 1993):

- wszystkie połączenia stanowią w niej sprzężenia zwrotne,
- każdy neuron jest powiązany z każdym innym na zasadzie dwukierunkowego sprzężenia zwrotnego,
- procesy w niej zachodzące są stabilne

Strukturę przykładowej sieci Hopfielda pokazano na rysunku 4.2.



Rys. 4.2. Struktura sieci Hopfielda (Rutkowski 2009)

Stabilność sieci Hopfielda osiągnięto poprzez wprowadzenie regularnej struktury wewnętrznej (każdy neuron jest połączony z każdym i wszystkie znajdują się w jednej warstwie (Rutkowski, 2009), brak sprzężeń zwrotnych w obrębie pojedynczego neuronu oraz symetryczność współczynników wagowych, tzn. pomiędzy dwoma neuronami  $j, k$ , waga  $w_{kj} = w_{jk}$ .

Sieć Hopfielda, dzięki swojej budowie oraz własnościom znalazła wiele zastosowań w różnych dziedzinach nauki, m.in. do:


- Rekonstrukcji obrazów (Matkowski i Fałat, 2012)
- Rozpoznawania wzorców (Szandała, 2015)
- Analizy i przetwarzania danych sejsmicznych (Huang and Yang, 2015)



Powyższe przykłady pokazują wybrane, ostatnio publikowane zastosowania sieci Hopfielda.

## 5. Predykcja cen akcji na giełdzie papierów wartościowych

Celem badań było wybranie najlepszej struktury modelu hybrydowego z SSN oraz określenie najlepszej kombinacji wskaźników AT i AF, które zapewnią przewidywanie cen zamknięcia akcji z najmniejszym błędem i będą najbardziej odporne na chwilowe zmiany na giełdzie. Przykładowy model hybrydowy, w którym zastosowano analizę techniczną i SSN pokazano na rysunku 5.1.



Rys. 5.1. Przykładowy model hybrydowy typu AT-SSN (Paluch i Jackowska-Strumiłło, 2012)

W rozprawie badano zastosowanie wskaźników analizy technicznej i fraktalnej w różnych architekturach sieci hybrydowych zależnych od okresu branego pod uwagę w obliczeniach. Razem przebadano 88 wskaźników (66 - analizy technicznej oraz 22 – analizy fraktalnej). W celu wyłonienia najlepszej struktury modelu z SSN, przeprowadzono dużą liczbę badań eksperymentalnych dla jednej firmy i wybrano zbiór najlepszych modeli. W następnych krokach zwiększano liczbę badanych firm i zmniejszano liczbę zbioru struktur modeli, metodą kolejnych eliminacji, na podstawie oceny błędu średniokwadratowego dla danych testowych (Paluch i Jackowska-Strumiłło, 2016).

Łącznie przebadanych zostało 1.219.107 modeli hybrydowych SSN, których struktury w zależności od wprowadzonych danych można podzielić na 7 typów:

- AT-SSN – model hybrydowy, w którym na wejście sztucznej sieci neuronowej wprowadzane są wskaźniki analizy technicznej
- AF-SSN – model hybrydowy, w którym na wejście sztucznej sieci neuronowej wprowadzane są wskaźniki analizy fraktalnej
- AF-AT-SSN – model hybrydowy, w którym na wejście sztucznej sieci neuronowej wprowadzane są wskaźniki analizy fraktalnej i technicznej (należy

jednak zwrócić uwagę na fakt, iż w tym zbiorze mogą się znaleźć sieci nauczone tylko na podstawie wskaźników AT jak również tylko AF.

- AF-C-SSN – model hybrydowy, w którym na wejście sztucznej sieci neuronowej wprowadzane są wskaźniki analizy fraktalnej oraz cen zamknięcia z poprzednich  $n$ -dni
- AT-C-SSN – model hybrydowy, w którym na wejście sztucznej sieci neuronowej wprowadzane są wskaźniki analizy technicznej oraz cen zamknięcia z poprzednich  $n$ -dni
- AF-AT-C-SSN – model hybrydowy, w którym na wejście sztucznej sieci neuronowej wprowadzane są wskaźniki analizy fraktalnej i technicznej oraz cen zamknięcia z poprzednich  $n$ -dni
- C-SSN – model, w którym na wejście sztucznej sieci neuronowej wprowadzane są ceny zamknięcia akcji z poprzednich  $n$ -dni

Badano także:

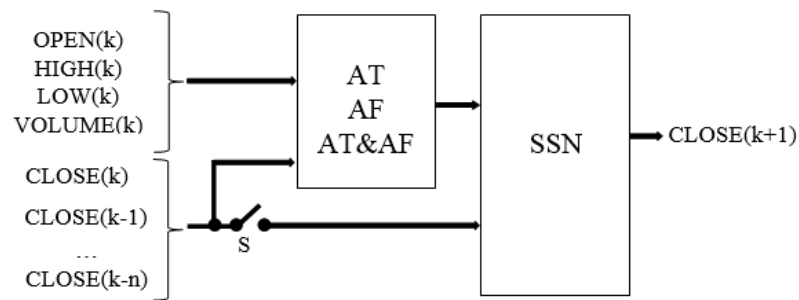
- 3 metody uczenia SSN: algorytm wstecznej propagacji błędu, algorytm Levenberga-Marquardta, algorytm RPROP (ang. *Resilient backPROPagation*)
- 3 funkcje aktywacji neuronów: sigmoidalna, tangens hiperboliczny, logarytmiczna
- 4 architektury SSN zgodnie z tabelą 5.1

Tabela 5.1. Kombinacje testowanych architektur SSN

Warstwa wejściowa	Warstwa ukryta	Warstwa wyjściowa
n	n+1	1
	1.5n	
	2n-1	
	2n+1	

gdzie  $n$  – liczba neuronów ( $n = 4, 5..30$ )

Dane wprowadzane były do sieci zgodnie ze schematem 5.2.



Rys. 5.2. Schemat wprowadzania danych wejściowych do hybrydowych modeli sztucznych sieci neuronowych, w predykcji cen akcji na kolejny dzień.

Zbiór 5545 struktur modeli hybrydowych z SSN, wybranych spośród wszystkich przebadanych architektur sieci posłużył do nauczania SSN dla 43 firm. Dla każdej ze spółek z osobną, niezależnie, zostało wybranych 300 modeli sztucznych sieci neuronowych z najmniejszym dla danej firmy błędem.

Na podstawie uzyskanych wyników stwierdzono, iż:

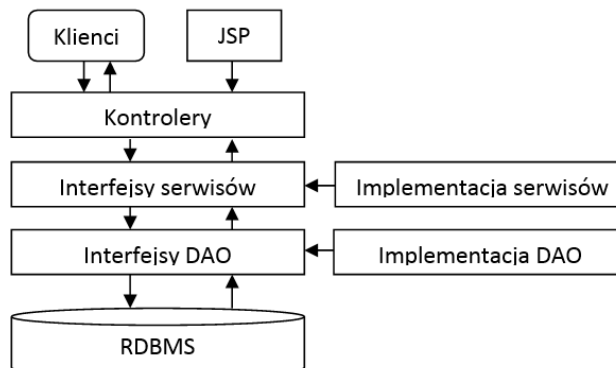
- Najmniejsze błędy dla danych testowych uzyskano w większości przypadków dla modeli hybrydowych typu AF-C-SSN, a w następnej kolejności dla modeli AT-C-SSN oraz AF-AT-C-SSN.
- Największe błędy uzyskano dla sztucznych sieci neuronowych typu C-SSN.
- Mniejsze błędy osiągnięto dla tych modeli, w których na wejściu SSN są wprowadzane średnie, w szczególności najmniejsze błędy osiągnięto dla modeli, w których na wejście SSN wprowadzono fraktalne średnie ruchome.
- Wśród modeli AF-SSN oraz AT-SSN z sieciami FFN, dominują sieci z małą liczbą wejść SSN i małą liczbę neuronów w warstwie ukrytej.
- Najlepsze wyniki uzyskano dla modeli SSN, w których zaimplementowano sigmoidalną funkcję przejścia lub tangens hiperboliczny.

## 6. Ekspertowy system informatyczny wspomagający podejmowanie decyzji inwestycyjnych

W ramach pracy zaprojektowany został autorski ekspertowy system informatyczny „Predyktor”, w którym zaimplementowano moduły programistyczne realizujące opracowane przez autora algorytmy predykcji wartości CLOSE z zastosowaniem badanych modeli hybrydowych z SSN oraz algorytmy decyzyjne z zastosowaniem sieci Hopfielda i zbioru heurystycznych reguł.

Głównymi celami systemu ekspertowego było przewidywanie cen akcji, analiza wskaźników analizy technicznej i fraktalnej, oraz budowa i uczenie stosownych do tego celu sztucznych sieci neuronowych i modeli hybrydowych.

Realizacja powyższych celów oraz założenia konstrukcyjne ekspertowego systemu informatycznego, nakładały wiele ograniczeń na możliwe do zastosowania technologie. Po analizie dostępnych narzędzi informatycznych, do implementacji systemu zastosowano technologię Java oraz Spring Framework (Walls 2011). Spring Framework jest bezpieczny i łatwy w zarządzaniu, zapewnia sprawny dostęp do bazy danych i wykonywania na niej setek tysięcy obliczeń arytmetycznych dziennie. Architekturę systemu opartego o Spring Framework pokazano na rysunku 6.1.



Rys. 6.1. Architektura Spring Framework (Walls 2011)

Wszystkie dane wykorzystywane w systemie oraz parametry konfiguracyjne przechowywane są w bazie danych Oracle, z którą aplikacja łączy się przy pomocy biblioteki Hibernate. Zbudowany system jest wdrożony na serwer Apache Tomcat, skąd jest dostępny dla użytkowników końcowych, którzy mogą prowadzić badania, inwestować na podstawie dostępnego lub nowego zdefiniowanego portfela akcji i zarządzać systemem.

## Porównanie wyników predykcji modeli hybrydowych z SSN

System ekspertowy **Predyktor** posłużył do przetestowania modeli hybrydowych z SSN do przewidywania cen akcji oraz algorytmów decyzyjnych z zastosowaniem sieci Hopfielda. Testy zostały wykonane na danych giełdowych z 2011 roku w oparciu o następujące założenia:

- Zakup i sprzedaż akcji odbywały się tego samego dnia w trakcie otwartej sesji na GPW.
- Zakup odbywał się po cenie otwarcia (Open), natomiast sprzedaż po cenie zamknięcia (Close).
- Jednocześnie prowadzone były testy dla 20 wersji portfela inwestycyjnego. Każda wersja oznaczała inną liczbę spółek, w które inwestowano oraz metodę podziału środków do inwestycji pomiędzy firmy. Oznacza to, że każdego dnia, 20 wątków systemu **Predyktor** inwestowało w 1,2...10 firm. Na każdą z wersji portfela przypadało 10.000 zł.
- Opracowano dwie metody inwestowania środków. Pierwsza metoda polegała na równomiernym podziale środków na wszystkie firmy, w które inwestowano, natomiast druga związana była z procentowym podziałem środków pomiędzy spółki (np. dla dwóch firm: jeżeli na podstawie algorytmu decyzyjnego, wybrane zostały firmy X i Y do inwestycji następnego dnia oraz firma X miała osiągnąć wyższe zyski od firmy Y, to 60% środków było przeznaczonych na zakup akcji firmy X, natomiast 40% na zakup akcji firmy Y).
- Prowizja maklerska wyniosła 0,19%, od każdej operacji (zgodnie z cennikiem jednego z biur maklerskich)
- Bez względu na osiągnięcie w  $k$ -tym dniu zyski lub straty, w dniu  $k+1$  akcje były kupowane za wszystkie środki przeznaczone na dany portfel.
- Wybór jednej firmy do inwestycji, oznaczał, że każdego dnia kupowano akcje tylko jednej firmy wybranej przez algorytm decyzyjny, na podstawie modeli hybrydowych z SSN, w przypadku dwóch firm, każdego dnia inwestowano w dwie firmy itd.
- Ceny zamknięcia były przewidywane dla 43 spółek akcyjnych notowanych na rynku regulowanym.

W przypadku stosowania modeli hybrydowych z SSN do przewidywania cen akcji najwyższą stopę zwrotu osiągnięto dla portfela inwestycyjnego, opierającego się o inwestycje w 4 firmy oraz równy podział środków pomiędzy nimi (86,35%),

natomiast dla zmiennej kwoty, zysk był niższy i wyniósł 71,72%. Dla większej dywersyfikacji portfela (powyżej 6 spółek), jak i mniejszej (2 lub 3 spółek), nieznacznie większy zysk został osiągnięty dla portfeli ze zmienną kwotą inwestycji.

Przy zastosowaniu modeli hybrydowych z SSN oraz algorytmów decyzyjnych z sieciami Hopfielda do przewidywania cen akcji na GPW, najwyższa stopa zwrotu została osiągnięta w przypadku inwestowania w jedną firmę podczas każdej sesji (173%), a następnie w dwie firmy (125%). Stosowanie takiej taktyki mogłoby jednak spowodować dużą stratę środków, ze względu na brak dywersyfikacji portfela i jest mało prawdopodobne, aby było wykorzystane w praktyce. W przypadku wszystkich badanych portfeli inwestycyjnych dla inwestycji ze zmienną kwotą podziału środków pomiędzy firmami, osiągnięto wyższą stopę zwrotu niż stałej kwoty podziału środków; np. dla czterech spółek osiągnięte stopy zwrotu wyniosły odpowiednio: 91,22% i 75,84%. W 90% badanych portfeli inwestycyjnych zastosowanie sieci Hopfielda poprawiło stopę zwrotu.

W celu porównania poziomu stopy zwrotu badanych modeli, w tabeli 6.1 zaprezentowano stopę zwrotu najważniejszych indeksów na GPW w 2011 roku.

**Tabela 6.1.**  
Stopa zwrotu indeksów na GPW w 2011r.

Nazwa indeksu	Stopa zwrotu
WIG-Plus	-40,77%
sWIG80	-30,47%
mWIG40	-22,51%
<b>WIG20</b>	<b>-21,85%</b>
<b>WIG</b>	<b>-20,83%</b>
WIG-Poland	-20,37%
WIG-INFO	-11,67%
RESPECT	-11,25%
WIG-ENERG	-10,75%
WIG-TELKOM	10,32%
WIG-CHEMIA	18,63%

Inwestycje w żaden z powyższych indeksów nie przyniosłyby takich zysków, jakie zostały osiągnięte przy zastosowaniu modeli hybrydowych z SSN oraz algorytmów decyzyjnych z sieciami Hopfielda. Osiągnięte stopy zwrotu były wyższe o 194% od stopy zwrotu indeksu WIG.

Zyski z inwestycji osiągnięte przy zastosowaniu systemu „Predyktor” potwierdzają, że bez względu na sytuację gospodarczą oraz spadki cen i indeksów, opierając się na algorytmach decyzyjnych z sieciach Hopfielda i modelach hybrydowych z SSN, nauczonych na podstawie analizy technicznej, fraktalnej oraz danych historycznych z giełdy, można osiągać wielokrotnie większe zyski niż w przypadku tradycyjnego inwestowania na podstawie indeksów giełdowych.

## 7. Podsumowanie

Głównymi celami pracy było opracowanie nowego hybrydowego podejścia do przewidywania cen akcji na giełdzie, łączącego analizę techniczną i sztuczne sieci neuronowe, które zapewniłoby dokładniejszą predykcję wartości CLOSE od wcześniej stosowanych metod oraz opracowanie nowej strategii inwestycyjnej, która zapewniłaby osiągnięcie większych zysków niż wynikałoby to z wartości indeksów giełdowych.

Z analizy stanu wiedzy wynika, iż zastosowanie sztucznych sieci neuronowych oraz różnych modeli hybrydowych, zapewnia lepszą dokładność predykcji wartości giełdowych od klasycznych, liniowych modeli analitycznych. Dlatego też w rozprawie skoncentrowano się wyłącznie na modelach z zastosowaniem SSN.

W rozprawie opracowano i zbadano różne struktury modeli hybrydowych analityczno-neuronowych.

W pierwszym etapie prac zbadano możliwości zastosowania na giełdzie sztucznych sieci neuronowych typu MLP, na których wejścia wprowadzano ceny zamknięcia z ostatnich  $n$ -dni (modele C-SSN). Następnie porównano ich wyniki z modelami hybrydowymi AT-SSN, w których na wejścia do SSN wprowadzane były wskaźniki analizy technicznej heurystycznie podzielone na 3 grupy: trendu, zmian oraz impetu. Wykazano, że modele C-SSN, ze względu na opóźnioną interakcję na nagłe zmiany cen, sprawdzają się jedynie w przypadku występowania trendu horyzontalnego i mogą stanowić dodatkową informację dla inwestora. Modele AT-SSN umożliwiają dokładniejszą predykcję cen akcji i są bardziej odporne na fałszywe sygnały z rynku i bardziej wrażliwe na nagłe zmiany cen akcji, wywołane czynnikami zewnętrznymi niż C-SSN. Ponadto SSN w modelach hybrydowych mają mniej skomplikowaną strukturę. Tym niemniej modele AT-SSN nie mogą stanowić jedyne modelu stosowanego do predykcji cen akcji, ze względu na zbyt duże błędy, które mogą prowadzić do niskich zysków (a biorąc pod uwagę prowizję domu maklerskiego, nawet strat).

W kolejnym etapie badań porównano modele AT-SSN oraz AF-SSN, wykazując, że przy użyciu modeli hybrydowych łączących SSN z analizą fraktalną uzyskano mniejsze błędy i lepsze rezultaty predykcji. Zaproponowano również nowe wskaźniki analizy fraktalnej dla zbudowanych modeli.

Następnie badano modele hybrydowe zbudowane z sieci typu MLP, na których wejścia oprócz wskaźników analizy technicznej i fraktalnej wprowadzano też ceny zamknięcia akcji z poprzednich dni. Łącznie przebadanych zostało ponad milion struktur modeli hybrydowych z SSN, które w zależności od wprowadzonych danych podzielono na 7 typów: C-SSN, AT-SSN, AF-SSN, AF-AT-SSN oraz AT-C-SSN, AF-C-SSN i AF-AT-C-SSN. Budowę i testowanie modeli hybrydowych oraz uczenie SSN z zastosowaniem obliczonych wskaźników i danych historycznych przeprowadzono w zautomatyzowany sposób w zbudowanym do tego celu systemie informatycznym. Wykazano, że najmniejsze błędy, a jednocześnie najbardziej stabilne wyniki zostały uzyskane w przypadku modeli AF-C-SSN. Sieci MLP w tych modelach, charakteryzowały się małą liczbą wejść SSN. Najgorsze wyniki predykcji uzyskano dla sieci C-SSN.

W wyniku przeprowadzonych badań stwierdzono również iż pomimo tego, że w całym okresie testowym (**2011 roku**), najlepsze średnie wyniki uzyskano dla modeli z klasy AF-C-SSN, to w krótkich okresach testowych o długości jednego miesiąca najlepsze wyniki uzyskiwano również dla modeli z innych klas, w zależności od sytuacji na giełdzie i sektora gospodarki, w którym działa firma. Wynika stąd, iż decyzje inwestycyjne nie powinny być podejmowane na podstawie wskazań jednego modelu, lecz wielu różnych modeli.

W ramach pracy został zaprojektowany i zbudowany ekspertowy system informatyczny „Predyktor” wyposażony w autorskie algorytmy decyzyjne, który ma pełnić funkcję narzędzia pomocniczego, wspierającego inwestorów w podejmowaniu decyzji inwestycyjnych. W systemie zaimplementowano moduły programistyczne realizujące opracowane przez autora algorytmy predykcji wartości CLOSE z zastosowaniem badanych modeli hybrydowych z SSN.

Przydatność zaprojektowanego systemu ekspertowego i algorytmów decyzyjnych do budowania strategii inwestycyjnej sprawdzono na drodze eksperymentalnej. W oparciu o wyniki przeprowadzonych badań dla każdej rozważanej firmy wybrano 300 modeli hybrydowych SSN charakteryzujących się najmniejszym błędem dla danych testowych w badanym okresie (**2011r.**) oraz 41 wskaźników analizy technicznej i fraktalnej.



Testy systemu ekspertowego przeprowadzono dla 20 różnych portfeli inwestycyjnych, uzupełnianych na podstawie algorytmów, spośród których algorytm decyzyjny, określał których firm akcje można kupić, natomiast algorytm komparatora, w jakiej kolejności i ile przeznaczyć na nie środków. Dla wszystkich przypadków osiągnięto wysokie stopy zwrotu: od 43% do 173%, które były one znacznie większe od stopy zwrotu najważniejszych indeksów na GPW (od -41% do 19%). Dodatkowo badano wynik działania analityczno-neuronowego algorytmu decyzyjnego wykorzystującego sieci Hopfielda do budowy portfela akcji. Wykazano, iż zastosowanie sieci Hopfielda poprawiło stopę zwrotu w 90% badanych portfeli inwestycyjnych i w najlepszym przypadku była ona o 194% lepsza od stopy zwrotu indeksu WIG.

W pracy wykazano, że modele hybrydowe wykorzystujące sztuczne sieci neuronowe, analizę techniczną i analizę fraktalną oraz historyczne dane, umożliwiają dokładniejszą predykcję cen akcji na giełdzie od modeli C-SSN oraz od modeli analitycznych opartych wyłącznie na danych historycznych lub analizie technicznej, co dowodzi tezy pierwszej.

Wykazano również, że algorytmy decyzyjne z zastosowaniem SSN i hybrydowych modeli predykcji cen akcji zaimplementowane w systemie informatycznym „Predyktor”, umożliwiają lepsze zaplanowanie strategii inwestycyjnej na giełdzie papierów wartościowych i osiągnięcie zysków na poziomie wyższym od indeksów giełdowych, co udowadnia tezę drugą.

Za główne osiągnięcia pracy, autor uważa:

1. opracowanie hybrydowych modeli do przewidywania cen akcji na GPW z zastosowaniem wskaźników analizy technicznej i fraktalnej oraz SSN,
2. opracowanie nowych wskaźników analizy fraktalnej dla wyżej wymienionych modeli,
3. opracowanie strategii inwestycyjnej wykorzystującej hybrydowe modele predykcji cen akcji i algorytmy decyzyjne z zastosowaniem z sieci Hopfielda i zbioru heurystycznych reguł,
4. zaprojektowanie i zbudowanie ekspertowego systemu informatycznego do wspierania inwestorów w podejmowaniu decyzji inwestycyjnych.

## Bibliografia

- Al-Junaid, H., (2015). *ANN Based Robotic Arm Visual Servoing Nonlinear System*, Procedia Comput. Sci. 62, 23–30. doi:10.1016/j.procs.2015.08.405.
- Anderson J.A., Rosenfeld E., (1988). *Neurocomputing – Foundation of Research*, MIT Press, Cambridge.
- Białynicki-Birula I., Białynicka-Birula I., (2004). *Modeling Reality. How Computers Mirror Life*, Oxford University Press
- Dębski W., (2010). *Rynek finansowy i jego mechanizmy*. PWN, Warszawa.
- Ehlers J., (2004). *Cybernetics Analysis For Stocks And Futures*. John Wiley & Sons, New York.
- Ehlers J., (2004). *The Inverse Fisher Transform*. Technical Analysis of Stocks & Commodities, Seattle.
- Falconer K, (1990). *Fractal Geometry*. Mathematical Foundations and Applications. John Wiley and Sons, New York.
- Hebb D., (1949). *Organization of Behaviour*. Wiley & Sons, New York.
- Huang, K.-Y., Yang, J.-R., 2015. *Seismic Velocity Picking using Hopfield Neural Network*. Presented at the 2015 SEG Annual Meeting, Society of Exploration Geophysicists.
- Jackowska-Strumiłło L., (2011). *Hybrid Analytical and ANN-based Modelling of Temperature Sensors Nonlinear Dynamic Properties*, The 6th International Conference on Hybrid Artificial Intelligence Systems, HAIS 2011, Wrocław, Poland, 23-25 May, Lecture Notes in Artificial Intelligence, LNAI 6678, Springer-Verlag, Part I, pp. 356-363.
- Jackowska-Strumiłło L., (2009). *Modelowanie i korekcja wybranych systemów nieliniowych z zastosowaniem metod analitycznych i aproksymatorów neuronowych – praca habilitacyjna*. Zeszyty naukowe nr 1043, Politechnika Łódzka, Łódź.
- Kohonen T., (1995). *Self-organizing maps*. Springer-Verlag, Berlin.
- Kudrewicz J., (2015). *Fraktale i chaos*. WNT, wydanie V, Warszawa.
- Lenzi, G. g., Evangelista, R. f., Duarte, E. r., Colpini, L. m. s., Fornari, A. c., Menechini Neto, R., Jorge, L. m. m., Santos, O. a. a., (2016). *Photocatalytic degradation of textile reactive dye using artificial neural network modeling approach*. Desalination Water Treat. 57, 14132–14144. doi:10.1080/19443994.2015.1064035
- Mandelbrot B.B., (1982). *The fractal geometry of nature*. W.H. Freeman and Comp., New York.
- Mandelbrot B.B., (1980). *Fractal aspects of the iteration of  $z \rightarrow \lambda z(1-z)$  for complex  $\lambda$  and  $z$* . Annals of the New York Academy of Science, 357, 249-259

- Matkowski, P., Fałat, T., (2012). *Zastosowanie tomografii komputerowej do oceny jakości mikrostruktur elektronicznych*. Elektron. Konstr. Technol. Zastos. 48–51.
- McCulloch W.S., Pitts W., (1943). *A logical calculus of the ideas immanent in nervous activity*. Bulletin of Mathematica Biophysics, No 5.
- Minsky M., Papert S., (1969). *Perceptrons*. MIT Press, Cambridge.
- Narendra K.S., Parthasarathy K., (2012). Identification and control of dynamics systems using neural networks, IEEE Transactions on Neural Networks, vol.1, no. 1, pp. 4-27
- Orzeszko, W., (2010). Wymiar fraktalny szeregów czasowych a ryzyko inwestowania. Acta Univ. Nicolai Copernici Ekon. 41, 57–70.
- Paluch, M., Jackowska-Strumiłło, L., (2016). *Decision system for stock data forecasting based on Hopfield artificial neural network*. Informatics Control Measurement in Economy and Environment Protection. ISSN: 2083-0157
- Peters E.E., (1997). *Teoria chaosu a rynki kapitałowe*. WIG PRESS, Warszawa.
- Popławski T., Dudek G., Łyp J.: *Forecasting methods for balancing energy market in Poland*. International Journal of Electrical Power and Energy Systems, vol. 65, pp. 94-101, 2015.
- Reuters Limited, (2006). *Wprowadzenie do analizy technicznej*. Wolters Kluwer, Kraków.
- Rosenblatt F, (1965). The perceptron. *A theory of statistical separability in cognitive system*. Cornell Aeronautical ab. Inc. Rep. No. VG-1196-G-1.
- Rumelhart D.E., Hinton G.E., Williams R.J., (1986). *Learning internal representations by error propagation*. In Parallel Distributed Processing: Explorations in the Microstructure of Cognition (D.E. Rumelhart & J.L. McClelland, eds.), Vol. 1, Chapter 8, Cambridge MA, MIT Press.
- Rutkowski L., (2009). *Metody i techniki sztucznej inteligencji*. Wydawnictwo naukowe PWN, wydanie 2, Warszawa.
- Szandała, T., (2015). *Comparison of Different Learning Algorithms for Pattern Recognition with Hopfield's Neural Network*. Procedia Comput. Sci., 6th Annual International Conference on Biologically Inspired Cognitive Architectures, BICA 2015, 6-8 November Lyon, France 71, 68–75. doi:10.1016/j.procs.2015.12.205
- Tadeusiewicz R., (1993). *Sieci neuronowe*. Akademicka Oficyna Wydawnicza RM, Warszawa.
- Tadeusiewicz R., (1994). *Neural networks in pattern recognition*. Proceedings of: „Intelligent Information Systems”. IPI PAN, strony 410-426, Warszawa.
- Tadeusiewicz R., (2007). *Odkrywanie właściwości sieci neuronowych przy użyciu programów w języku C#*. Polska Akademia Umiejętności, Kraków.
- Walls C., (2011). *Spring w Akcji*, Helion, wydanie IV.