

*Przemysław Stochel**

WYKORZYSTANIE SIECI NEURONOWYCH I ANALIZY PORTFELOWEJ W PROGNOZOWANIU KURSÓW AKCJI NA GIEŁDZIE PAPIERÓW WARTOŚCIOWYCH

1. Wstęp

Celem niniejszej pracy jest przybliżenie i poszerzenie wybranych elementów wiedzy na temat metodologii wspomagającej decyzje inwestycyjne na rynku kapitałowym, ze szczególnym uwzględnieniem realiów i ograniczeń występujących aktualnie w Polsce oraz implementacji odpowiednich systemów komputerowych, możliwych do realizacji na dostępnym sprzęcie klasy PC.

Dotyczy to pokazania tych metod ilościowych, gdzie w badaniu rynku kapitałowego eliminuje się w znacznym stopniu subiektywny czynnik ludzki.

Artykuł ten był pisany na przełomie 1996/97 roku, a od tego czasu giełda warszawska ewoluowała i zawarte krytyczne uwagi pod jej adresem nie są w pełni adekwatne do obecnego stanu. W badanym okresie listopad 94 – sierpień 96 na parkiecie giełdy notowanych było znacznie mniej spółek (ok. 70 na rynku podstawowym) oraz występowało, przy co prawda niskiej kapitalizacji, mniejsze rozwarstwienie pomiędzy spółkami o największej i najmniejszej kapitalizacji (nie istniał rynek wolny). W badanym okresie mały był jeszcze udział kapitału zagranicznego (szczególnie dużego), który stabilizowałby notowania.

W pracy skoncentrowano się przede wszystkim na problematyce budowy sieci neuronowych do prognozowań finansowych na giełdzie papierów wartościowych i analizy portfelowej opartej na teorii H. Markowitza i uproszczonej metody W. Sharpe'a [5, 9, 14].

Szczególnie zaś zadaniem artykułu było udowodnienie, że mało rozpowszechnione metody zastosowań sieci neuronowych mogą stanowić konkurencyjne narzędzie do prognozowań giełdowych w stosunku do innych metod powszechnie stosowanych, takich jak analiza techniczna, czy analiza fundamentalna [5, 8, 14].

* Katedra Automatyki, Akademia Górniczo-Hutnicza, Kraków

Analiza rynków kapitałowych charakteryzuje się wielką ilością danych, które mogą wpływać na przewidywane wielkości, oraz często zawiłym charakterem ich powiązań, tak że głównie komputery wykorzystujące sieci neuronowe wydają się narzędziami mogącymi je wszystkie uchwycić. Sieci neuronowe pozwalają częściowo zastąpić doświadczenie inwestora oraz wyeliminować czynniki irracjonalne.

2. Ogólna charakterystyka pracy

2.1. Zdefiniowanie problemu

Papier wartościowy jest to instrument finansowy, który potwierdza jedną z trzech sytuacji [9]:

- 1) nabycie prawa do współwłasności firmy,
- 2) udzielenie kredytu rządowi, firmie bądź instytucji,
- 3) uzyskanie prawa do otrzymania w przyszłości pewnej wartości w postaci instrumentu finansowego.

Istnieje wprawdzie wiele klasyfikacji papierów wartościowych, w zależności od przyjętych kryteriów, lecz w tym artykule przyjęto podział wynikający z podanej powyżej definicji.

Podstawowymi charakterystykami papierów wartościowych, którymi obraca się na giełdzie, a w szczególności akcji, są kursy tzn. ceny giełdowe. Upraszczając, można powiedzieć, że są dwa zasadnicze sposoby ustalania kursów akcji, prowadzące w konsekwencji do ustalenia dwóch rodzajów kursów: jednolitego i zmiennego.

- 1) Kurs jednolity jest ustalany raz na danej sesji giełdowej poprzez skojarzenie ofert kupna i sprzedaży. Ustalona jest taka cena akcji, przy której zrealizowana zostaje największa liczba transakcji.
- 2) Kurs zmienny to cena zmieniająca się od transakcji do transakcji, przy czym transakcje te dokonywane są na bieżąco, np. na parkiecie giełdy.

Papiery wartościowe są produktami finansowymi i podlegają takim samym prawom, jak inne produkty [2]. W szczególności dokonuje się nimi obrotu na rynku. Rozróżnia się tutaj rynek pierwotny i wtórny. W związku z tym, że rynek pierwotny papieru wartościowego występuje tylko w momencie sprzedaży papieru wartościowego przez emitenta pierwszemu właścicielowi, a sama emisja dokonywana jest przy spełnieniu określonych wymogów prawnych, w niniejszym opracowaniu został on pominięty.

Natomiast podstawowym rynkiem tutaj rozważanym jest wtórny rynek papierów wartościowych. Na tym rynku papier wartościowy często zmienia swojego właściciela. To właśnie wtórny rynek kształtuje cenę, czyli wartość danego papieru wartościowego. Często ta wartość znacznie różni się od ceny emisyjnej.

2.2. Uwarunkowania i ograniczenia

Niniejszy artykuł, ze względu na przyjęte założenia wynikające z oparcia się na realiach rynku kapitałowego występującego aktualnie w Polsce, nie może pokazać takich wyników, jakie możliwe byłyby do uzyskania w przypadku oparcia się na danych którejs z dużych giełd światowych – ze względu na szereg uwarunkowań.

Do takich głównych uwarunkowań należą [6]:

- niemożność zaliczenia polskiej giełdy do efektywnych rynków papierów wartościowych. Rynek efektywny to taki rynek (giełda), w przypadku którego cała dostępna informacja jest w całości i natychmiast odzwierciedlana w cenach [9];
- mała ilość podmiotów na giełdzie;
- relatywnie duża ilość inwestorów indywidualnych, którzy w warunkach polskich w swoich poczynaniach kierują się głównie celami krótkookresowymi (uzyskanie stosunkowo dużych zysków w krótkim czasie), na podstawie własnej wiedzy i intuicji. Natomiast występuje stosunkowo mała liczba inwestorów instytucjonalnych, stabilizujących giełdę poprzez dużą skalę inwestycji opartych na szczegółowej analizie rynku i kierujących się głównie celami długookresowymi;
- niska płynność finansowa. Brak kapitału na giełdzie. Nawet niewielkim wzrostom akcji towarzyszy spadek obrotów i przewaga ofert sprzedaży. Na wysokość kursów akcji wyraźnie wpływają nowe emisje, które ściągają kapitał. Ogromną konkurencją dla giełdy stanowi emisja obligacji państwowych, które nie niosą praktycznie ryzyka, a poprzez system ulg w podatku dochodowym zapewniają inwestorom satysfakcjonujący zysk;
- boom na giełdzie w okresie kwiecień 1993 – marzec 1994 r., w czasie którego była zupełnie nieprzewidywalna, a działania inwestorów były nieracjonalne, co musiało doprowadzić do krachu i w efekcie znacznego wycofania się inwestorów z giełdy.

Niezależnie od powyższych uwarunkowań giełdowych, dane będące podstawą obliczeń w prezentowanej w niniejszym opracowaniu koncepcji prognozowania kursów giełdowych posiadają ograniczenia wynikające z samej metody obliczeń, takie jak [1,14]:

- dane wejściowe muszą być ogólnodostępne (jawne),
- dane muszą być skwantyfikowane,
- czas obliczeń powinien pozwalać wykorzystać wyniki (powinien być znacznie krótszy niż czas predykcji).

W opracowaniu zrezygnowano z preprocesingu danych, wymagającego od użytkownika klasyfikacji danych do określonych klas, co wiązałoby się z koniecznością posiadania sporego doświadczenia w zakresie rynku giełdowego. Proces ten mógłby polegać na dodaniu dodatkowych danych wejściowych wyprowadzonych z danych ogólnodostępnych, takich jak kurs i wolumen, a określających np. fazę trendu w jakim znajduje się badany papier wartościowy. Założenie to wydaje się tym słuszniejsze, iż uwiarygodnienie takiej klasyfikacji wymagałoby opracowania danych przez kilku niezależnych specjalistów, a dla drobnego inwestora jest to właściwie nie do zrealizowania. Korzystanie z opinii ekspertów wiąże się jeszcze z jednym ryzykiem. Każdy ekspert ma określone preferencje i jego zachowanie może sprawdzać się w określonej sytuacji, a w innej nie.

2.3. Oś koncepcyjna pracy

Mówiąc na początku pracy o inwestowaniu w papiery wartościowe, wskazano, że działalność ta (szczególnie gdy dotyczy to giełdy) wiąże się z niepewnością i ryzykiem. Wynika to z tego, że przyszłe zyski z tytułu posiadania papieru wartościowego zależą od wielu czynników, z których być może najważniejsza jest przyszła sytuacja na rynku papierów wartościowych.

Celem niniejszej pracy jest pokazanie, jak można wykorzystać w prognozowaniu kursów akcji na giełdzie papierów wartościowych dwa obszary nauki, tj. teorię zarządzania portfelem inwestycyjnym i technikę sieci neuronowych.

Drugim wykorzystanym w pracy obszarem badań jest zastosowanie sieci neuronowych do prognozowań finansowych. Ten drugi obszar jest głównym tematem artykułu, ponieważ pozwala znaleźć kolejne zastosowanie dla sieci neuronowych i wykazać ich nieograniczone możliwości modyfikacji i dostosowań.

Głównymi celami artykułu są więc:

- utworzenie portfela akcyjnego wg wybranego kryterium (teoria Sharpe'a),
- utrzymanie takiej struktury portfela, która zapewni określony zysk (sieci neuronowe),
- pokazanie metod jej osiągania.

3. Podstawowe pojęcia i zagadnienia

3.1. Ekonomiczne metody prognozowań giełdowych [4, 5, 6, 8, 9]

3.1.1. Analiza fundamentalna

Podstawowe założenia

W przeciwieństwie do analizy technicznej analiza fundamentalna opiera się przede wszystkim na ocenie firmy emitującej akcje, a nie na ocenie aktualnego kursu akcji. Fundamentalista kieruje się zasadą: zbadaj, dopiero wtedy inwestuj. Studiuje wyniki finansowe spółek, czyta prospekty emisyjne, nie zaniedbuje analizy takich czynników, jak sytuacja polityczna i gospodarcza kraju czy koniunktura międzynarodowa. Pamięta, że żadne przedsiębiorstwo nie jest samotną wyspą – nie działa w oderwaniu od konkurentów ani ogólnej sytuacji rynkowej. Celem jest oczywiście wyszukanie takiej spółki, która ma dobre podstawy (fundamenty – stąd nazwa) pomyślnego i trwałego rozwoju. Rozwój firmy powoduje, że jej wartość wzrasta, jeśli nie w krótkim, to przynajmniej w długim okresie. Wraz ze zwiększeniem wartości wzrasta też cena akcji firmy.

Cel i metody analizy fundamentalnej

Analizę fundamentalną stosuje się dla inwestycji długoterminowych – przy tworzeniu portfela inwestycyjnego. O opłacalności inwestycji decydują wyniki spółki, możliwości jej rozwoju, pozycja na rynku. Ideałem byłoby wyszukanie firm lub branż rozwojowych, które przynoszą zyski, a co za tym idzie – odpowiednio duże dywidendy oraz wzrost cen akcji. W analizie fundamentalista opiera się na tzw. udokumentowanej przeszłości. Na podstawie opublikowanych sprawozdań finansowych firm, raportów itp. stara się przewidzieć przyszłość. Chce zainwestować w takie akcje, które mają niższy kurs, niż wynikałoby to z kondycji finansowej przedsiębiorstw, a więc których cena prawdopodobnie wzrośnie. Jego praca polega na gromadzeniu i analizowaniu tysięcy informacji obrazujących kondycję finansową i rynkową przedsiębiorstwa, strategię jego zarządu w określonych warunkach ekonomicznych. Dla celów praktycznych musi ograniczyć się do stałej liczby kryteriów,

takich samych w przypadku wszystkich firm, bez względu na ich profil czy wielkość. Wynika to chyba ze słusznego założenia, że w gospodarce kapitalistycznej wszystkie firmy działają według tej samej logiki rynkowej – ich zasadniczym celem jest wypracowanie jak największego zysku. Niektóre firmy państwowe działają co prawda według logiki przyjętej ze starego systemu scentralizowanego, ale z oczywistych względów nie interesują one inwestora giełdowego.

Ile powinno być takich kryteriów oceny firm? Nie ma reguły. Z jednej strony zbyt mała ich ilość może spowodować, że w analizie zabraknie istotnego szczegółu. Z kolei przekroczenie krytycznej liczby kryteriów prowadzi do utraty czytelności. Na naszej giełdzie inwestorzy najczęściej patrzą na **zysk netto** spółki. Z obserwacji rynku wynika, że jeśli firma osiągnęła w danym okresie większy zysk netto niż w takim samym okresie w przeszłości, to bez względu na przyczynę tego wzrostu prawie zawsze od razu szły w górę ceny jej akcji. Inne wyniki nie miały tak wielkiego znaczenia. Warto to wiedzieć, gdyż wartość rynkowa firmy, a więc kursy jej akcji, zależą od jej obrazu w oczach większości inwestorów. Jednak żaden z czynników oceny spółki nie może być analizowany bez uwzględnienia innych elementów. Informacja, że spółka A osiągnęła w okresie t_1 zysk x razy większy niż w okresie t_0 jest oczywiście bardzo ważna, ale niepełna. Należałoby te dane porównać z analogicznymi danymi spółki B i C, a także powiązać z innymi danymi, takimi jak np. kapitał własny spółki, przychody ze sprzedaży netto, zysk brutto oraz np. z wysokością inflacji [12].

Powiedzenie „nikt nie jest samotną wyspą” w szczególnie trafny sposób odnosi się więc nie tylko do przedmiotu analizy, jakim jest spółka, ale i do poszczególnych jej elementów. Powiązania między poszczególnymi danymi liczbowymi tworzą tak zwane wskaźniki, które z łatwością dają się porównać. Porównanie wskaźników pozwala na wychwytywanie istotnych odchyłeń od sytuacji uznanych za standardowe.

3.1.2. Analiza techniczna

Podstawowe założenia

Analiza techniczna zjawisk zachodzących na giełdach papierów wartościowych jest diametralnie różna od analizy fundamentalnej, której wyznawcy zakładają, iż zasadniczy wpływ na giełdę, a więc notowania akcji, mają zjawiska i procesy zachodzące poza giełdą. Według fundamentalistów na kursy wpływają, w sposób pośredni, wyniki finansowe firm. Tymczasem analiza techniczna wychodzi jakby z odwrotnego założenia: to właśnie kursy akcji zwiastują zmiany gospodarcze. Ceny są kształtowane przez relacje popytu i podaży, te zaś przez nastroje optymizmu i pesymizmu uczestników rynku.

Wszystkie procesy gospodarcze, w tym zachowania kursów, podporządkowane są pewnym dającym się opisać i przewidzieć cyklom, z których najdłuższy obejmuje 80 lat, najkrótszy zaś jest kilkugodzinny. Tak więc z zachowania cen akcji wysnuć można wnioski co do koniunktury na danym rynku.

Analiza techniczna to nic innego, jak proces studiowania aktualnych i przeszłych kursów akcji i innych wielkości, np. wartości obrotu, a następnie wyodrębnianie powtarzających się sekwencji. W podobnej sytuacji rynek ma tendencję do zachowania się w podobny sposób. Metoda ta, zdaniem jej wyznawców, umożliwia przewidywanie przyszłych

trendów kursów giełdowych. Analitycy nie wczytują się w dane finansowe spółek. Wystarczy im, że w rynku uczestniczą inwestorzy posiadający informacje o sytuacji spółek, których nie mają inni, i w ten sposób kształtują kursy rynkowe. Ceny odzwierciedlają bowiem wszystkie czynniki, także zachowanie fundamentalistów. Ponieważ stosowanie analizy technicznej jest powszechne, nic dziwnego, że prawdopodobieństwo jej skuteczności jest duże. Po prostu inwestorzy zachowują się tak, jak wynika to z ich analizy rynku, a ich działanie wpływa z kolei na kształt rynku. Ma to więc wszelkie znamiona samospełniającej się prognozy.

Technicy jako główne narzędzie pracy wykorzystują wykresy, stąd zwani są czasami czartystami (chartists od charts). Podstawy teoretyczne czerpią przede wszystkim z teorii Dow'a i teorii fal Elliotta.

Teoria Dow'a

Wiele elementów tego, co dziś uznaje się powszechnie za analizę techniczną wywodzi się w tej bądź innej formie z teorii Dow'a. Stworzony przez niego indeks, będący dziś jednym z najważniejszych wskaźników aktywności rynku kapitałowego, pozostaje po ponad 90 latach po śmierci swego twórcy (1902 r.) podstawowym narzędziem dla analityków rynku.

Teoria Dow'a opiera się na sześciu podstawowych zasadach.

- 1) *Średnie giełdowe dyskontują wszystko.* Jest to jedna z podstawowych przesłanek współczesnej teorii analizy technicznej, tyle że czynnikiem dyskontującym wszystko jest tu nie rynek, a średnia giełdowa.
- 2) *Trzy trendy rynkowe.* Dow zdefiniował trend wzrostowy jako sytuację, w której kolejne szczyty i dołki kształtują się na coraz wyższym poziomie. Trend spadkowy to sytuacja odwrotna. Dow wyodrębnił trzy kategorie trendu – główny, wtórny i krótkookresowy. Przedmiotem jego zainteresowania były przede wszystkim trendy główne, trwające zazwyczaj ponad rok, a nawet kilkanaście lat. Był on przekonany, że większość inwestorów giełdowych interesuje się właśnie głównym kierunkiem rynku. Trend wtórny, czyli średniookresowy, stanowi korektę trendu głównego i na ogół trwa od trzech tygodni do trzech miesięcy. Korekty te zwykle znoszą się od jednej trzeciej do dwóch trzecich poprzedniego ruchu cen. Trendy mniejsze, krótkookresowe, trwają zwykle niespełna trzy tygodnie i stanowią krótkie korekty trendu wtórnego.
- 3) *Trzy fazy trendu głównego.* Trend główny przebiega zwykle w trzech fazach. Pierwsza z nich, zwana fazą akumulacji, polega na kupowaniu akcji przez najbardziej wytrwałych inwestorów, kiedy wszystkie „złe” wiadomości zostają zdyskontowane przez rynek. Faza druga, w której zaczyna uczestniczyć większość tych inwestorów, którzy opierają się na technicznej analizie trendu, przebiega pod znakiem szybkich wzrostów cen i napływania coraz lepszych wiadomości gospodarczych. Trzecią i ostatnią fazę cechuje masowy udział inwestorów, optymistyczne publikacje w prasie, doskonałe wiadomości o sytuacji gospodarczej oraz nasilenie działań spekulacyjnych. Właśnie podczas tej fazy ci inwestorzy, którzy zaczęli „akumulować” akcje blisko rynkowego dna, kiedy nikt nie chciał kupować, zaczynają sprzedawać – kiedy wydaje się z kolei, że nikt jeszcze nie pozbywa się akcji.

- 4) *Średnie rynkowe muszą się nawzajem potwierdzać.* Dow odwoływał się do średniej przemysłowej i średniej transportowej. Zakładał, że każdy istotny sygnał zapowiadający hossę lub bessę musi zostać potwierdzony przez wskazania obu tych średnich. Inaczej mówiąc, obie średnie muszą przebić się ponad ostatni szczyt z poprzedniego trendu wtórnego, aby można było mówić o początku hossy. Jeśli tylko jedna z tych średnich daje taki sygnał, nie jest to wiarygodna zapowiedź rynku „byka”. Sygnały te nie muszą wystąpić jednocześnie, ale im bliżej siebie w czasie, tym lepiej. Kiedy średnie dają rozbieżne sygnały, należy zakładać, że dotychczasowy trend będzie kontynuowany.
- 5) *Wolumen jako potwierdzenie trendu.* Jeśli główny trend ma charakter wzrostowy, wolumen powinien zwiększać się wraz ze wzrostem cen i zmniejszać podczas spadków. W trendzie spadkowym na odwrót. Należy jednak podkreślić, jest tu czynnikiem wtórnym. Rzeczywiste sygnały kupna i sprzedaży w teorii Dow oparte są wyłącznie na cenach zamknięcia.
- 6) *Trend jest kontynuowany dopóki nie pojawią się definitywne oznaki świadczące o jego odwróceniu.* Wykrycie sygnału odwrócenia trendu nawet współcześnie nie jest tak łatwe. Poziomy wsparcia i oporu, formacje cenowe, linie trendu i średnie kroczące to niektóre z szeregu dostępnych narzędzi technicznych, wskazujących, kiedy może się dokonać zmiana trendu. Wykorzystanie zaś oscylatorów pomaga w uzyskaniu jeszcze wcześniejszych sygnałów mówiących o osłabieniu impetu cechującego trend.

Teoria fal Elliotta

Teoria fal Elliotta stanowi w pewnym sensie uzupełnienie i rozwinięcie teorii Dow. Uzasadnieniem takiego stwierdzenia może być to, że znaczna część koncepcji Elliotta jest zgodna z teorią Dow i tradycyjnymi metodami stosowanymi do analizy wykresów. Teoria Elliotta wykracza jednak poza tradycyjną analizę techniczną, ukazując całościową perspektywę rynku, która pomaga wyjaśnić, dlaczego i gdzie powstają określone formacje i dlaczego zapowiadają taki a nie inny bieg wydarzeń. Pomaga ona także analitykowi zorientować się, w którym miejscu cyklu znajduje się aktualnie rynek.

Analiza techniczna, o czym wspomniano wcześniej, w znacznym stopniu opiera się na obserwacji trendu. Teoria Dow, pomimo wszystkich jej zalet, przekazuje sygnały z opóźnieniem, kiedy nowy trend został już ukształtowany. Teoria Elliotta daje analitykowi szybsze ostrzeżenia przed nadchodzącym odwróceniem trendu, które można następnie potwierdzić, stosując bardziej tradycyjne metody.

Trzy podstawowe elementy teorii fal to kształt, proporcje oraz czas, w tej kolejności, jeśli chodzi o ich znaczenie. Najważniejszym aspektem całej teorii jest kształt, czyli formacja fali. Analiza proporcji jest użyteczna przy określaniu zasięgu przyszłego ruchu cen, czego dokonuje się, mierząc relacje pomiędzy poszczególnymi falami. Na koniec mamy relacje w czasie, które można wykorzystać dla potwierdzenia formacji fali i proporcji.

W swojej najbardziej podstawowej formie teoria ta mówi, że rynek akcji podlega powtarzającemu się rytmowi pięcioletniego ruchu w górę, po którym następuje trójfaldowy spadek.

Obok stałej formy różnych fal bardzo istotny jest stopień cyklu, do którego należy dana fala. Istnieje bardzo wiele stopni trendu. Teoria Elliotta uwzględnia dziewięć różnych stopni trendu, poczynając od wielkiego supercyklu obejmującego dwieście lat do cyklu najmniejszego, trwającego tylko kilka godzin. Należy jednak pamiętać, że niezależnie od stopnia badanego trendu zawsze mamy do czynienia z podstawowym cyklem składającym się z ośmiu fal.

Do najbardziej istotnych założeń teorii fal zaliczyć można:

- pełny cykl hossy składa się z ośmiu fal,
- trend dzieli się na pięć fal biegnących w kierunku trendu wyższego stopnia,
- korekty zawsze mają trzy fale,
- fale mogą tworzyć struktury dłuższe i dzielić się na fale krótsze,
- czasami jedna z fal impulsu wydłuża się. Dwie pozostałe powinny być równe pod względem wielkości i czasu trwania,
- matematyczną podstawą teorii Elliotta jest ciąg liczbowy Fibonacciego,
- liczba fal odpowiada liczbom ciągu Fibonacciego,
- dla określenia zasięgu ruchu cen wykorzystuje się proporcje Fibonacciego,
- zasada zmienności ostrzega, by nie oczekiwać dwa razy z rzędu tego samego zjawiska,
- bessa nie powinna zejść poniżej poziomu czwartej fali poprzedniego trendu wzrostowego,
- fala czwarta nie powinna zachodzić na falę pierwszą.

Teoria Elliotta uchodzi za najpełniejszą teorię techniczną stosowaną do prognozowania zachowań rynków. Jedynym w zasadzie pewnym minusem jej jest niesprawdzanie się tak dobrze w przypadku kursów poszczególnych akcji.

3.1.3. Inne metody

W teorii badań nad zjawiskami posiadającymi nieregularne przebiegi czasowe znajduje się wiele metod podejmujących próby jak najdokładniejszego przybliżenia zachowań zjawiska w przyszłości. Można tu wymienić na przykład:

Metodę przeciętnych miesięcznych, stosowaną wówczas, gdy trend jest wielkością stałą a wahania sezonowe są albo addytywne (powtarzające się co rok z tym samym nasileniem), albo multiplikatywne (powtarzające się ze zmiennym nasileniem). Polega ona na obliczeniu dla każdego miesiąca przeciętnej wartości obrotu za wszystkie lata, a następnie obliczeniu średniej przeciętnej miesięcznej. Wtedy dzieli się przeciętne miesięczne przez ogólną średnią i w ten sposób otrzymuje się wskaźniki sezonowości.

Analizę harmoniczną, będącą użytecznym narzędziem analizy wahań, zarówno cyklicznych, jak i sezonowych i krótkookresowych. Pozwala ona na jednoczesne analizowanie wszystkich rodzajów wahań okresowych, dzięki możliwości rozłożenia w czasie na trzy harmoniki o różnych amplitudach, okresach i przesunięciach. Analiza harmoniczna opiera się na wykorzystaniu funkcji trygonometrycznych sinus oraz cosinus.

Bardzo interesującym narzędziem, niezwykle użytecznym w analizie rynków cechujących się brakiem wyraźnego trendu, kiedy ceny wahają się wewnątrz horyzontalnie biegnących granic, są oscylatory. W sytuacjach takich większość systemów opartych na analizie trendu okazuje się w zasadzie nieużyteczna, natomiast dzięki oscylatorom jest możliwe osiągnięcie zysków również w tych okresach.

Znaczenie oscylatorów nie ogranicza się jednak do okresów bocznych ruchów cen. Wykorzystywane w połączeniu z wykresami cen podczas trendów wzrostowych lub spadkowych oscylatory stają się źródłem cennych sygnałów informujących o krótkoterminowych sytuacjach skrajnych, nazwanych powszechnie wykupieniem i wyprzedaniem rynku. Mogą również ostrzegać, że trend traci swój impet, zanim stanie się to widoczne w zachowaniach cen, mogą też, ukazując różne dywergencje, sygnalizować, że pewien trend dobiega końca. Oscylator jest wskaźnikiem o charakterze wyłącznie pomocniczym w tym sensie, że ich stosowanie powinno być podporządkowane podstawowej analizie trendu. Zaznaczyć należy, że w pewnych okresach oscylatory są bardziej użyteczne, a w innych mniej, np. na początku istotnych ruchów cen analiza oscylatorów nie jest szczególnie pomocna, ale pod koniec tych ruchów oscylator okazuje się niezwykle cennym wskaźnikiem.

Generalnie ujmując, oscylatory są najbardziej przydatne w trzech rodzajach sytuacji, które charakterystyczne są dla większości stosowanych oscylatorów:

- 1) Kiedy osiągają skrajne wartości minimalne lub maksymalne. Stanowi to ostrzeżenie przed możliwością zmiany kierunku ruchu cen.
- 2) Dywergencja, czyli rozbieżność pomiędzy zachowaniem oscylatora i ruchem cen w sytuacji, gdy oscylator znajduje się blisko swego ekstremum, jest zazwyczaj ostrzeżeniem przed możliwością zmiany trendu.
- 3) Przecięcie poziomu zerowego może stanowić ważny sygnał do zawierania transakcji zgodnych z kierunkiem głównego trendu.

3.2. Analiza portfelowa

Jednym ze sposobów analizy rynków finansowych jest metoda minimalizacji ryzyka inwestycyjnego przy zastosowaniu teorii Markowitza [5, 9, 14]. W przeciwieństwie do innych metod podejmowania decyzji wymaga ona skomplikowanych obliczeń statystycznych (możliwych do zrealizowania wyłącznie przy pomocy szybkich komputerów). Powoduje to małą popularność metody wśród inwestorów indywidualnych. Jest ona jednak jednym z podstawowych narzędzi profesjonalnych instytucji zajmujących się inwestowaniem na rynkach kapitałowych. Z powodu dużej złożoności obliczeniowej powstały inne uproszczone modele rynku, między innymi jednoindeksowy model Sharpe'a. W niniejszym rozdziale zostanie przedstawiona teoria Markowitza, a następnie zmiany i uproszczenia wprowadzone przez Sharpe'a.

3.2.1. Wprowadzenie

W rozdziale tym zostało zastosowane słownictwo charakterystyczne dla omawianego problemu, a więc związane z rynkiem kapitałowym. Poniżej przedstawiono krótkie wyjaśnienia pewnych pojęć.

- Przez **walor** rozumiana będzie spółka lub inny instrument finansowy uwzględniany w obliczeniach.
- **Okres jednostkowy** to okres, względem którego prowadzone są obliczenia. Może to być dzień, tydzień lub miesiąc.
- **Jednostkowa stopa zysku** jest zyskiem (zmianą procentową) waloru w danym okresie jednostkowym. Może być ona ujemna.

3.2.2. Teoria Markowitza

W teorii Markowitza dwoma podstawowymi pojęciami są oczekiwana stopa zysku i ryzyko. Oczekiwana stopa zysku jest określana jako średnia arytmetyczna jednostkowych stóp zysku z określonej ilości okresów jednostkowych w przyszłości. Obliczenia są prowadzone na podstawie różnych okresów jednostkowych – najczęściej dni, tygodni lub miesięcy. Wzór określający oczekiwaną stopę zysku wygląda następująco (1)

$$R = \frac{\sum_{i=1}^n R_i}{n} \quad (1)$$

gdzie:

- R – oczekiwana stopa zysku,
- R_i – stopa zysku w i -tym okresie jednostkowym,
- n – ilość okresów jednostkowych wziętych pod uwagę.

Ryzyko waloru oblicza się jako odchylenie standardowe jednostkowych stóp zysku (w okresie branym pod uwagę) od oczekiwanej stopy zysku (2)

$$s = \sqrt{\frac{\sum_{i=1}^n (R_i - R)^2}{n - 1}} \quad (2)$$

gdzie:

- s – oczekiwane ryzyko związane z danym papierem wartościowym,
- R – oczekiwana stopa zysku,
- R_i – stopa zysku w i -tym okresie,
- n – ilość okresów wziętych pod uwagę.

Istnieje również alternatywny sposób obliczania ryzyka. Jak widać w powyższym wzorze (2) na wielkość ryzyka wpływ mają zarówno odchylenia w dół (straty), jak i w górę (zyski) od oczekiwanej stopy zysku. Z punktu widzenia inwestycji kapitałowych niekorzystne są tylko odstępstwa od średniej w dół. Możliwe jest więc obliczanie ryzyka za pomocą semi-odchylenia standardowego, biorącego pod uwagę tylko niekorzystne (ujemne) odchyłki (3)

$$sv = \sqrt{\frac{\sum_{i=1}^n d_i^2}{n - 1}} \quad (3)$$

przy czym

$$d_i = \begin{cases} 0 & \text{gd } R_i \geq R \\ R_i - R & \text{gd } R_i < R \end{cases} \quad (4)$$

gdzie:

- sv – oczekiwane ryzyko związane z danym papierem wartościowym,
- R – oczekiwana stopa zysku,
- R_i – stopa zysku w i -tym okresie,
- n – ilość okresów wziętych pod uwagę.

Ryzyko jest podawane w procentach i informuje, o ile obliczona oczekiwana stopa zysku może się różnić od rzeczywistej.

Ekonomiści używają pojęcia portfela inwestycyjnego. Jest to zestaw instrumentów finansowych, najczęściej o różnych oczekiwanych stopach zysku i ryzyku. Teoria Markowitza zajmuje się takim dobraniem składu procentowego walorów w portfelu, aby zminimalizować jego ryzyko przy zachowaniu możliwie maksymalnej oczekiwanej stopy zwrotu. Wzory powyższe wykorzystywane są do obliczania stóp zysku i poziomu ryzyka dla pojedynczych walorów. Poniżej podane zostaną wzory pozwalające na obliczanie tych wartości w przypadku portfeli.

Oczekiwana stopa zysku portfela (5)

$$R_p = \sum_{i=1}^n w_i R_i \quad (5)$$

gdzie:

- R_p – oczekiwana stopa zysku portfela,
- R_i – oczekiwana stopa zysku i -tego składnika,
- w_i – udział i -tego składnika w portfelu,
- n – ilość składników w portfelu,

przy spełnionym warunku

$$\sum_{i=1}^n w_i = 1 \quad (6)$$

Jak widać, oczekiwana stopa zysku portfela jest ważoną średnią arytmetyczną z oczekiwanych stóp zysku walorów wchodzących w jego skład.

Przy wyznaczaniu wartości poziomu ryzyka dla złożonych portfeli kluczowe znaczenie mają korelacje pomiędzy poszczególnymi składnikami portfela.

Współczynnik korelacji obliczamy z następującego wzoru (7)

$$\rho_{12} = \frac{\sum_{i=1}^n (R_{1i} - R_1)(R_{2i} - R_2)}{(n-1)(s_1 s_2)} \quad (7)$$

gdzie:

- ρ_{12} – współczynnik korelacji składników 1 i 2,
- R_{1i} – stopa zysku składnika 1 w i -tym okresie,
- R_{2i} – stopa zysku składnika 2 w i -tym okresie,
- R_1 – oczekiwana stopa zysku składnika 1,
- R_2 – oczekiwana stopa zysku składnika 2,
- s_1 – odchylenie standardowe dla składnika 1,
- s_2 – odchylenie standardowe dla składnika 2,
- n – ilość okresów wziętych pod uwagę w obliczeniach.

Współczynnik korelacji dwóch akcji określa, w jaki sposób stopy zysku dwóch akcji są ze sobą powiązane. Jego własności i interpretacja są następujące:

- współczynnik korelacji akcji przyjmuje wartości z przedziału $[-1; 1]$,
- wartość bezwzględna współczynnika korelacji wskazuje na siłę powiązania stóp zysku akcji. Im wyższa wartość bezwzględna, tym powiązanie jest mocniejsze,
- znak współczynnika korelacji wskazuje na kierunek powiązania stóp zysku akcji. Gdy jest on dodatni, to wzrostowi (spadkowi) stopy zysku jednej akcji towarzyszy wzrost (spadek) stopy zysku drugiej akcji. Gdy korelacja jest ujemna, to wzrostowi (spadkowi) stopy zysku jednej akcji towarzyszy spadek (wzrost) stopy zysku drugiej akcji.

Mając obliczone współczynniki korelacji pomiędzy wszystkimi możliwymi elementami portfela, obliczamy ryzyko portfela ze wzoru (8)


$$s_p = \sqrt{\sum_{i=1}^n w_i^2 s_i^2 + 2 \sum_{i=1}^{n-1} \sum_{j=i+1}^n w_i w_j s_i s_j \rho_{ij}} \quad (8)$$

gdzie:

- s_p – ryzyko portfela,
- w_i – udział akcji i -tej w portfelu,
- s_i – ryzyko akcji i -tej spółki,
- ρ_{ij} – współczynnik korelacji dla spółek i oraz j .

Aby łatwiej przedstawić korzyści, jakie daje zastosowanie teorii Markowitza w tworzeniu portfeli o optymalnym stosunku zysku do ryzyka, posłużymy się wykresami ryzyko – zysk. Oś pozioma obrazuje ryzyko (s – ang. *standard deviation*), pionowa zaś stopę zysku (R – ang. *rate*).

Portfele uzyskane na drodze obliczeń przedstawionych powyżej tworzą na mapie ryzyka figury, których węzłami są punkty reprezentujące poszczególne elementy wchodzące w skład portfela. Węzeł taki uosabia portfel złożony tylko z jednego waloru. Kształt figur jest uzależniony od wartości współczynników korelacji pomiędzy walorami wchodzącymi w skład portfela.



Rys. 1. Figura przedstawiająca portfele w układzie ryzyko – zysk

Rysunek 1 przedstawia portfel złożony ze składników o dodatnich i ujemnych współczynnikach korelacji. Jak widać, można uzyskać portfel o poziomie ryzyka mniejszym niż ryzyko najmniej ryzykownego waloru wchodzącego w jego skład. Zaznaczono go na rysunku symbolem E , jest to tzw. portfel efektywny o minimalnym ryzyku. Krzywą łączącą ten punkt z punktem C nazywamy zbiorem portfeli efektywnych (ang. *efficient set*).

Portfel efektywny charakteryzuje się tym, że:

- nie istnieje portfel o tej samej stopie zysku i mniejszym ryzyku,
- nie istnieje portfel o tym samym ryzyku i większej stopie zysku.

3.2.3. Teoria Sharpe'a

W poprzednim punkcie przedstawiono klasyczne podejście do tworzenia portfela zaproponowane przez Markowitza. Ze względu na konieczność stosowania dużej ilości obliczeń (szczególnie przy wyznaczaniu współczynników korelacji) powstały inne teorie mające doprowadzić do ich ograniczenia. Jedną z nich jest teoria Sharpe'a.

U podstaw tego modelu leży zaobserwowany fakt, że stopy zysku większości akcji zależą od działania pewnego czynnika, który można nazwać czynnikiem rynku (giełdy). Zależność stopy zysku akcji od stopy zysku indeksu giełdy przedstawia się za pomocą następującego równania (9)

$$R_i = a_i + \beta_i R_1 + sl_i \quad (9)$$

gdzie:

- R_i – stopa zysku i tej akcji,
- R_1 – stopa zysku indeksu giełdy (wskaźnika rynku),
- a_i, β_i – współczynniki równania,
- sl_i – składnik losowy równania.

Główne obliczenia w tym podejściu są związane z wyznaczaniem parametru. Jego interpretacja jest następująca: współczynnik beta akcji wskazuje, o ile procent w przybliżeniu wzrośnie stopa zysku akcji, gdy stopa zysku wskaźnika rynku wzrośnie o 1%.

Obliczenia parametru β (10) prowadzi się według wzoru

$$\beta = \frac{\sum_{i=1}^n (R_i - SR)(R_{1i} - SR_1)}{\sum_{i=1}^n (R_{1i} - R_1)^2} \quad (10)$$

przy czym:

$$SR = \frac{\sum_{i=1}^n R_i}{n} \quad (11)$$

$$SR_1 = \frac{\sum_{i=1}^n R_{1i}}{n} \quad (12)$$

gdzie:

- R_i – stopa zysku składnika portfela w i -tym okresie,
- R_{1i} – stopa zysku indeksu giełdy (wskaźnika rynku) w i -tym okresie,
- SR_i – średnia stopa zysku dla składnika,
- SR_{1i} – średnia stopa zysku indeksu,
- n – ilość okresów wziętych do obliczeń.

Parametr β jest współczynnikiem kierunkowym prostej w metodzie najmniejszych kwadratów. Po jego obliczeniu możemy uzyskać pozostałe współczynniki pomocnicze (13) i (14):

- parametr a $a = SR - \beta \cdot SR$ (13)
- ryzyko dla indeksu s_1 (liczone z klasycznego wzoru),
- ryzyko składnika losowego,

$$s_l = \sqrt{\frac{\sum_{i=1}^n (R_i - a - \beta \cdot R_{1i})^2}{n - 1}} \quad (14)$$

Mając te współczynniki, możemy w prosty sposób obliczyć oczekiwane stopy zysku i ryzyka dla poszczególnych walorów i współczynniki korelacji pomiędzy nimi:

- stopa zysku $R = a + \beta \cdot SR_1$ (15)

- ryzyko $s = \sqrt{\beta^2 \cdot s_1^2 + s_l^2}$ (16)

- współczynnik korelacji dla spółek i -tej oraz j -tej

$$\rho_{ij} = \frac{\beta_i \cdot \beta_j \cdot s_i^2}{s_i \cdot s_j} \quad (17)$$

Oznaczenia w powyższych wzorach są zgodne z użytymi w podanym powyżej wzorze na parametr β . Dalsze postępowanie jest identyczne jak w podstawowej teorii Markowitza.

3.2.4. Kryteria minimalizacji

Istnieje wiele kryteriów, w oparciu o które można przeprowadzać minimalizację. Jednym z nich jest oczekiwane ryzyko poszukiwanego portfela. Drugim możliwym podejściem jest minimalizacja tzw. współczynnika zmienności. Współczynnik ten jest ilorazem ryzyka portfela do oczekiwanego zysku. Przedstawia więc ilość ryzyka przypadającego na jednostkę zysku. Wzór służący do jego obliczania wygląda następująco (18)

$$W = \frac{s}{R} \quad (18)$$

gdzie:

- W – współczynnik zmienności,
- R – oczekiwany zysk,
- s – ryzyko.

4. Przyjęte rozwiązania

4.1. Utworzenie portfela akcyjnego

W opracowaniu jako punkt wyjścia przyjęto portfel obliczony za pomocą arkusza kalkulacyjnego Microsoft Excel z wykorzystaniem modelu Sharpe'a. Przyjęcie takiego rozwiązania miało na celu wyeliminowanie subiektywnych zachowań osoby tworzącej taki portfel na podstawie innych kryteriów, niepoddających się automatyzacji. Przyjęcie pewnego wyjściowego portfela pozwala ograniczyć obliczenia wykonywane przez sieć neuronową tylko do papierów wchodzących w skład tego portfela. W przypadku niekorzystnych notowań walorów wchodzących w skład portfela (kursy tych walorów po zastosowaniu sieci neuronowych będą wykazywały znaczne spadki) lub po pewnym ustalonym okresie można powtórnie zastosować analizę portfelową w celu wygenerowania nowego portfela. Analiza portfelowa generuje portfel na dany moment w oparciu o dane historyczne i nie posiada możliwości predykcji, które posiada sieć neuronowa. Dlatego też dodatkowe zastosowanie sieci neuronowej dla papierów wchodzących w skład starego i nowego portfela pozwoli na możliwie najkorzystniejsze przejście z jednego portfela do drugiego.

Stanowi to zaletę w stosunku do zastosowania samej analizy portfelowej, która generuje portfele, natomiast w przypadku dużych różnic między tymi portfelami koszty zamiany papierów wchodzących w skład jednego portfela na drugi powodują nieopłacalność całej operacji.

Jako założenie przyjęto obliczanie portfeli trój-, cztero- i pięcioskładnikowych. Słuszność takiego założenia wynika z badań, jakie przeprowadzono na wielu dużych giełdach światowych. Badania wykazały, iż portfel 10-składnikowy jest w zupełności wystarczający. Ponieważ badania prowadzono na dużych giełdach, więc w celu dostosowania do realiów warszawskiej giełdy podzielono tę liczbę przez dwa. Założenie to wydaje się uzasadnione faktem, iż w momencie pisania artykułu na rynku podstawowym notowanych było około 100 spółek.

Zgodnie z przyjętymi tezami opracowania dla tak utworzonego portfela akcyjnego następnym krokiem jest utrzymanie takiej struktury portfela, która zapewni maksymalizację zysku. Realizacja tego celu jest dokonywana poprzez odpowiednie wykorzystanie sieci neuronowych.

4.2. Parametry sieci [1, 3, 13, 15]

Jako okres predykcji przyjęto 1 tydzień. Wynikało to z następujących przyczyn:

- systemy o dużym stopniu zautomatyzowania nie dorównują człowiekowi pod względem reakcji na aktualne wydarzenia, takie jak np. podanie do wiadomości raportu okresowego spółki czy obniżka stóp procentowych,

- istotną rolę odgrywał też poziom błędu – 5% błąd przy dopuszczalnej zmianie 10% dziennie ma zupełnie inne znaczenie przy zmianie dziennej, a zupełnie inne przy tygodniowej,
- zmiany portfela w krótszym czasie powodują, że większego znaczenia dla inwestora nabierają koszty takiej zamiany (częste składanie zleceń, prowizja biura maklerskiego),
- dłuższy okres (może z wyjątkiem dwóch tygodni) nie wchodził w grę ze względu na krótki okres istnienia giełdy i brak możliwości skompletowania wystarczającej ilości danych uczących.

Ze względu na przyjęcie jako wielkości wyjściowej kursu prognozowanego z tygodniowym wyprzedzeniem, podstawą danych wejściowych jest kurs z danej sesji, kurs z sesji sprzed tygodnia i dwóch tygodni. Nie stwierdzono znaczącego wpływu kursów z dalszej przeszłości z tygodniowym interwałem. Ponieważ poszukiwano wejść o największym wpływie na wejście odwołano się do analizy technicznej, która również bazuje na przeszłym kształtowaniu się kursu waloru i sytuacji na giełdzie (określonej przez indeksy giełdowe).

Podstawową wielkością w analizie technicznej oprócz wartości kursów jest wielkość obrotów, toteż jako wejścia wprowadzono wielkość obrotów na danej sesji, sesji sprzed tygodnia i dwóch tygodni. W celu odzwierciedlenia zachowania całej giełdy wprowadzono wartość i wolumen Warszawskiego Indeksu Giełdowego (WIG) przy przyjęciu identycznych zasad jak dla kursów i obrotów poszczególnych papierów. Jako wolumen WIG rozumiany jest tutaj obrót wszystkich akcji na rynku podstawowym w tys. zł.

Ponieważ wszystkie powyższe wejścia odzwierciedlały dyskretne punkty, należało wprowadzić wejścia umożliwiające sieci odtworzenie trendów. Instrumentem dostosowanym do tego typu zastosowań są np. średnie kroczące, to znaczy średnie z przesuwanym się okienkiem czasowym [1]. Zastosowano średnie kroczące kursu akcji i wartości WIG-u.

Aby wprowadzić elementy analizy fundamentalnej, jako wejście należało zastosować przede wszystkim przychody ze sprzedaży netto i zysk netto. Tutaj wyniknęła jednak komplikacja. Spółki giełdowe obowiązane są do publikacji swoich wyników finansowych raz na kwartał. Publikacje obejmujące najkrótszy okres to publikacje miesięczne. Pozostawienie wejścia niezmiennego przez tak długi okres nie wpływało korzystnie na prognozowanie i spowodowało zastosowanie współczynnika kurs/zysk netto, który charakteryzował się większą zmiennością. Podobny zabieg zastosowano w stosunku do zysku brutto i przychodów ze sprzedaży netto.

W analizie technicznej istotną rolę, prócz analizy trendów i formacji, odgrywają tak zwane oscylatory, czyli wskaźniki opierające się na takich podstawowych wielkościach, jak kurs otwarcia, zamknięcia, kurs minimalny, maksymalny, obrót. W naszych polskich warunkach niektóre oscylatory nie znajdują zastosowania ze względu na fakt, iż większość papierów nie ma notowań ciągłych, czyli ustalana jest tylko jedna cena walorów, przy której zostanie zrealizowanych najwięcej transakcji.

Zastosowano kilka oscylatorów ze względu na różny charakter generowanych przez nie sygnałów, a także fakt, że czasami oscylatory dają błędne sygnały, a większa ich ilość może wskazać poprawne sygnały. Próbowano również sprawdzić, czy w przypadku tak krótkiego okresu predykcji użyteczne okażą się oscylatory stosowane w przypadku dłuż-

szych okresów przewidywania. Znaczna część oscylatorów oparta jest na średnich, starano się więc zaobserwować, czy średnie te w przekształconej postaci będą użyteczne. Jako immanentną cechę zaobserwowano, iż dodawanie wejść należących do różnych „klas” poprawiało wyniki otrzymywane przez sieć, a w szczególności niwelowało większe odchylenia.

Jako wyjście zastosowano nie kurs, lecz jego zmianę w czasie tygodnia. Spowodowało to znaczne poprawienie jakości (uzyskiwanego błędu), gdyż wartość względna (różnica kursu przewidywanego i bieżącego) była wielokrotnie mniejsza niż wartość bezwzględna (kurs przewidywany), a błąd liczony jest jako odchylenie procentowe wielkości wyjściowej. Taka zmiana korzystna jest również dla inwestora, którego bardziej interesują zmiany kursów niż sama ich wartość.

Przeprowadzono próby z predykcją wartości kilku akcji za pomocą jednej sieci, ale wyniki były znacznie gorsze niż przewidywanie za pomocą kilku odrębnych sieci każdego papieru z osobna. Sieć „wieloakcyjna” była gorsza zarówno pod względem czasu uczenia, jak i otrzymywanego błędu.

Przyjęcie sieci z jednym wyjściem może wywołać zaniepokojenie, że decyzja będzie często zależała tylko od jednej liczby. Spróbowano dodać więc drugie wyjście określające znak zmiany kursu. Wyjście to miało więc charakter potwierdzający. Sieć z dwoma wyjściami uczyła się gorzej, a charakter potwierdzający okazał się mocno kontrowersyjny. Program BRAINMAKER [3], będący aplikacją symulującą działanie sieci neuronowych, która została wykorzystana w badaniach, nie umożliwia łączenia kilku sieci w jednym oknie. Nie jest więc możliwe dynamiczne uśrednianie wyników. Możliwe jest jednak uruchomienie kilku sieci w różnych oknach. W celu uwiarygodnienia wyników zdecydowano się na uczenie przewidywania każdego papieru przez dwie niezależne sieci o takiej samej konstrukcji i takich samych wejściach. Pierwsza sieć otrzymywała dane w niezmienionej kolejności (to znaczy zgodnie z datami sesji), natomiast druga dane wymieszane w sposób losowy. Przyjęcie takiego rozwiązania pozwalało przyjrzeć się dwu zagadnieniom:

- 1) podejmowanie decyzji na podstawie dwóch niezależnych sieci,
- 2) stwierdzenie wpływu kolejności prezentacji danych z ciągu uczącego na otrzymane wyniki.

Ad 1) Decyzje podejmowane na podstawie dwóch sieci były trafniejsze o kilka procent.

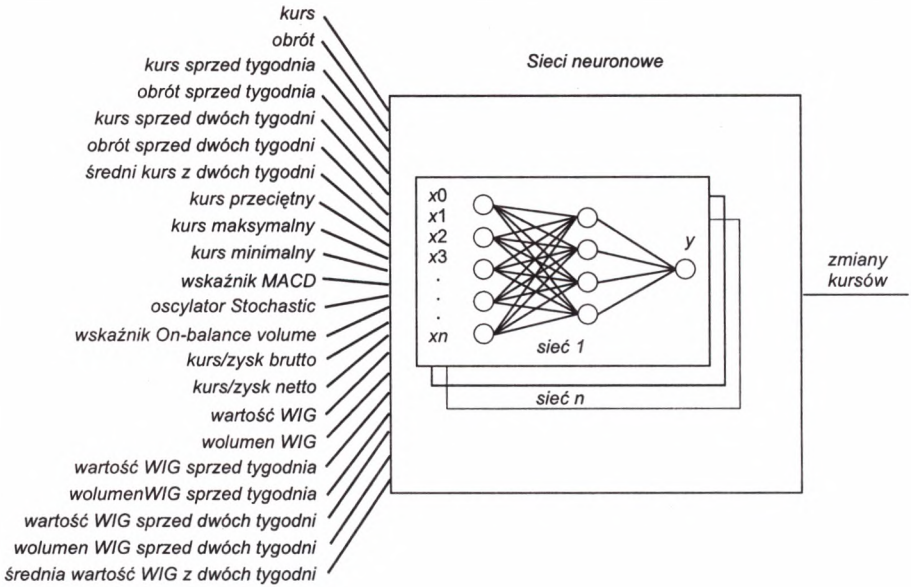
Ad 2) Wpływ mieszania danych na wyniki można uznać za pozytywny, lecz zależał w dużym stopniu od wybranego papieru i okresu, z którego pobierano dane.

Schemat systemu wraz z wymienionymi wejściami obrazuje rysunek 2.

Z powyższych rozważań można wyciągnąć wniosek, że w prognozowaniu finansowym najlepsze efekty otrzymuje się w przypadku stosowania sieci prognozujących zachowanie kursu jednego papieru. Sieć taka powinna mieć kilkanaście – kilkadziesiąt wejść, które obejmują jak najszerszy zakres czynników wpływających na zachowanie danego papieru oraz jedno wyjście.

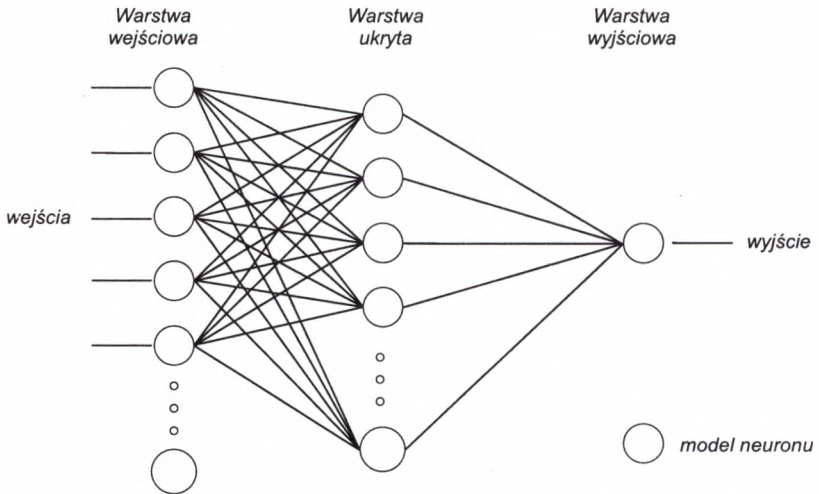
Tak przyjęte wejścia oraz wyjście wskazywały, że najefektywniejszy będzie model trójwarstwowy z jedną warstwą ukrytą (rys. 3).

Ilość sesji, na podstawie których uczymy sieć, jest zdeterminowana ilością wszystkich neuronów w sieci. Obowiązuje prosta reguła mówiąca, iż ciąg uczący powinien składać się z takiej ilości elementów, która stanowi $3 \div 10$ razy ilość wszystkich neuronów [13].



Rys. 2. Schemat systemu z określonymi wejściami i wyjściem

Zaobserwowano, że w przypadku prognozowań finansowych ilość elementów ciągu uczącego powinna być bliska górnej granicy powyższego wzoru, a nawet ją przekraczać.



Rys. 3. Model sieci neuronowej

5. Rezultaty badań

5.1. Badanie efektywności uczenia i testowania pojedynczych sieci

Przedstawione wykresy reprezentują przebieg uczenia i testowania jednej wybranej spółki – *Agrosu*.

W przypadku, gdy nie zostało to zaznaczone, do badań wykorzystano sieci uczone ciągiem uczącym składającym się z 352 sesji (80% z 440 sesji). Pozostałe 20% danych wykorzystano jako ciąg testujący, przy czym ciąg ten powstał na zasadzie wyboru co piątej sesji. Testowanie odbywało się po każdych 50 prezentacjach ciągu uczącego (25 w przypadku bardzo krótkich czasów uczenia). Jako wejścia zastosowano 22 wielkości: kurs, wolumen akcji i WIG w różnych chwilach czasowych, średnie kroczące, oscylatory i inne wskaźniki. Zostały one szczegółowo opisane w podrozdziale 4.2. Tolerancje uczenia i testowania przyjęto równe 0,1. Wszystkie symulacje sieci korzystały początkowo z losowo wybranego zbioru wag. Sieci uczono przy przyjęciu liniowo malejącego współczynnika uczenia należącego do przedziału $[0,8, 0,2]$, który zależał od ilości odpowiedzi błędnych (gdy malała ta ilość, to malał również współczynnik uczenia). Wykorzystano sieci trójwarstwowe o 22 neuronach w warstwie ukrytej. Nie stosowano sprzężeń zwrotnych w sieciach. Zastępowały je częściowo odpowiednio przetworzone dane wejściowe (na przykład kurs i obrót sprzed tygodnia i dwóch). Zastosowano sieci nieliniowe z funkcją logistyczną *signum*. Sieć uczono do momentu bezbłędnego rozpoznawania całego ciągu uczącego (z przyjętą tolerancją). Jako wyznacznik błędu zastosowano wskaźnik RMS (root mean squared error). Modyfikacje w poszczególnych podpunktach odnoszą się do wyżej wymienionych parametrów.

5.1.1. Współczynniki uczenia

Współczynnik uczenia występujący w algorytmie wstecznej propagacji błędów jest odpowiedzialny za wielkość zmian współczynników wagowych w każdym z neuronów. Algorytm uczenia zmienia współczynniki wagowe wszystkich neuronów po każdej prezentacji elementu z ciągu uczącego. Wielkość zmiany zależy bezpośrednio od współczynnika wagowego. Gdy współczynnik ten ma dużą wartość, reakcja na błędną odpowiedź jest korygowana w sposób gwałtowny. Czyli dla dużych wartości współczynnika uczenia wartości wag są znacznie zmniejszane lub zwiększane. Nie sprzyja to szybkiej nauce sieci. Zbyt mały współczynnik powoduje małe korekty i proces uczenia trwa bardzo długo. Istnieje także zagrożenie „wpadnięcia” sieci w lokalne minimum i nieosiągnięcia minimum globalnego.

Jedną z metod pozwalających na szybsze uczenie sieci nieliniowych jest zmiana wartości współczynnika podczas uczenia. Wygenerowane losowo wagi neuronów powinny jak najszybciej osiągnąć wartości zbliżone do oczekiwanych. Jakkolwiek nie należy dążyć do bezwzględnego polepszania procesu uczenia, gdyż podczas testowania możemy zaobserwować objawy „przeuczenia” się sieci, czyli w miarę coraz lepszego rozpoznawania elementów ciągu uczącego, sieć coraz gorzej rozpoznaje elementy spoza tego ciągu.

Dla zapewnienia zbieżności całego procesu uczenia powinno się stosować mniejszy współczynnik uczenia w pierwszej fazie tego procesu w celu jego ukierunkowania. Natomiast w drugiej fazie należy ten współczynnik stopniowo zmniejszać, przy czym sposób tej

zmiany należy dobrać na drodze dalszych badań [13]. Pierwszy etap ma szczególne znaczenie przy losowej generacji współczynników wagowych.

5.1.2. Różny procent dopuszczalnych odpowiedzi błędnych podczas uczenia

Najwięcej czasu zajmuje sieci nauczenie się ostatnich 5% ciągu uczącego. Przy czym można zaobserwować, iż błąd podczas tego uczenia maleje bardzo nieznacznie. W przypadku prognozowań finansowych sytuację tę można łatwo wytłumaczyć. Zawsze istnieją czynniki, których nie jesteśmy w stanie wprowadzić na wejście sieci, a które mogą znacznie wpłynąć na notowania, np. wystąpienie polityka czy efekt paniki wśród inwestorów.

Ze względu na zbieżność i stabilność najlepszym rozwiązaniem okazało się uczenie sieci do 10% dopuszczalnych odpowiedzi błędnych.

5.1.3. Różne tolerancje uczenia

Od tolerancji uczenia zależy częstość podejmowania działań korekcyjnych przez sieć w trakcie uczenia. Gdy tolerancja jest duża, mniej elementów ciągu uczącego nie mieści się w zadanej tolerancji, a tylko dla takich elementów sieć dokonuje korekty wag. Uczenie jest szybsze, ale mniej dokładne (większy błąd RMS). Zbyt mała tolerancja powoduje jednak częste zmiany wag. Potwierdza to opinię, iż sieć nauczona z małą tolerancją bardziej zapamiętuje ciąg uczący i nie jest zdolna do równie dobrej generalizacji (czyli rozciągnięcia swej wiedzy na dane spoza ciągu uczącego). W analizowanym przypadku najlepsze efekty osiągnięto dla tolerancji uczenia równej 10% obserwowanej zmiany kursu *Agrosu* w badanym okresie i tak duża dopuszczalna tolerancja stanowić będzie niewątpliwie wielkość nie do zaakceptowania dla większości inwestorów i analityków.

5.1.4. Korekta przeprowadzana po prezentacji całego ciągu uczącego bądź pojedynczych elementów

Celem kumulacji błędów i korekcji dopiero po prezentacji całego ciągu uczącego jest przyspieszenie procesu uczenia. Szczególnie przydatne może się to okazać w przypadku dużych sieci.

W przypadku badanych sieci nie zaobserwowano przyspieszenia procesu uczenia. Na wykresach uczenia zaobserwowano, iż należało zmniejszyć współczynnik uczenia po prezentacji całego ciągu uczącego – w stosunku do standardowo przyjętego dla sieci uczonej po prezentacji każdego elementu – gdyż powstawały trwałe oscylacje. Po uczeniu i testowaniu najniższy poziom błędu osiągnęła jednak sieć, w której korekcja była przeprowadzana po prezentacji każdego elementu z ciągu uczącego.

5.1.5. Różny stopień randomizacji ciągu uczącego

Randomizacja ciągu uczącego wpływa na zmniejszenie błędu, a także na „wygładzenie” jego wykresu. Sieć uczona ciągiem niezrandomizowanym zmuszona jest do uczenia się kolejnych trendów, a przeskoki z jednego na drugi powodują oscylacje. W przypadku ciągu

zrandomizowanej sytuacji takie nie mają miejsca. Losowe prezentowanie danych powoduje, iż sieć uczy się niezależnie od wcześniej prezentowanych danych.

W przypadku szeregów czasowych, z którymi mamy do czynienia w niniejszym opracowaniu należy pamiętać jedynie o tym, iż wstępną obróbkę danych (np. wyznaczanie średnich kroczących) należy przeprowadzać przed wymieszaniem ciągu uczącego.

5.1.6. Liczba neuronów w warstwie ukrytej

Zmniejszenie ilości neuronów w warstwie ukrytej ma na celu polepszenie generalizacji wyników. Zbytne ograniczenie (w tym wypadku do 16) neuronów w warstwie ukrytej powodowało pogorszenie wyników, zwłaszcza przez wydłużenie czasu uczenia. Zwiększenie ilości neuronów (do 28) nie powoduje poprawy wielkości błędu, ale powoduje jego stabilizację. W eksperymencie zastosowano sieć z dwoma warstwami neuronów ukrytych, o stosunku ilości neuronów 3:1. Sieć taka wymaga dłuższego czasu uczenia, ale charakteryzuje się dużą stabilnością błędu RMS zarówno podczas uczenia, jak i testowania.

Jeżeli weźmiemy pod uwagę błąd testowania, to najmniejsze wartości wykazuje kolejno sieć z 19, 16, 22 neuronami. Sieć o większej ilości neuronów bardziej „zapamiętuje” wiedzę zawartą w ciągu uczącym i nie jest w stanie tak dobrze uogólnić jej na ciąg walidacyjny (testujący).

Biorąc pod uwagę efektywność uczenia i testowania, najlepsza okazała się sieć o 19 neuronach w warstwie ukrytej.

Jako uwagę dodać należy, iż sieci więcej niż trójwarstwowe są trudniejsze do optymalizacji (w sensie dobrania najlepszych parametrów), gdyż należy podać nie tylko ogólną ilość neuronów ukrytych, ale także ich ilość w poszczególnych warstwach. Należy pamiętać, że nie istnieje prosta reguła, z której wynika, że ok. 15% mniejsza liczba neuronów w warstwie(-ach) ukrytych spowoduje uogólnienie wiedzy sieci na ciąg testujący. Istotnym parametrem jest wielkość sieci. Zbyt mała sieć wymusza zwiększenie ilości neuronów ukrytych w stosunku do wejść, natomiast większa, ze względu na fakt, że ma możliwość pomieszczenia większej wiedzy, pozwala na redukcję proporcji ilości neuronów ukrytych do ilości neuronów wejściowych.

5.1.7. Różna ilość wejść

Przebadano sieci, z których usunięto następujące wejścia:

- oscylatory, wskaźniki kurs/zysk netto, kurs/przychody ze sprzedaży, WIG,
- oscylatory, wskaźniki kurs/zysk netto, kurs/przychody ze sprzedaży,
- sieć pierwsza plus wprowadzono średnią WIG,
- WIG.

Żadna z tych sieci nie nauczyła się w 3 tys. kroków swojego ciągu uczącego, z czym nie miała problemów sieć wyjściowa. Na wykresach uczenia zaobserwowano także, iż najgorsze rezultaty osiągnęła sieć nr 1, a wykres błędu nie wskazuje na możliwość poprawy. Zdeteminowane jest to małą ilością wiedzy dostarczaną w ciągu uczącym. Ale dodanie jednego znaczącego wejścia (średniej kroczącej WIG) w przypadku serii 3 powoduje poprawienie wyniku. Najlepsze rezultaty osiągnięto dla sieci nr 2, w której usunięto wielkości pomocnicze (oscylatory, kurs min. i max., wskaźniki kurs/zysk). Wskazuje to na fakt, iż kierowa-

nie się tymi wielkościami na naszej giełdzie nie stanowi dobrego punktu wyjściowego dla inwestowania albo sieć nie jest w stanie prawidłowo powiązać tych wielkości. Podobne efekty jak sieć nr 3 uzyskuje sieć nr 4, z której usunięto wszystkie wejścia związane z WIG-iem, jakkolwiek efekty te osiągnęte są z większym trudem.

Inny obraz, niż po studiach nad wykresami uczenia, otrzymamy, analizując wykresy testowania. Wynika z nich, iż najmniejszym błędem w czasie testowania charakteryzują się sieci najprostsze (o najmniejszej ilości wejść i neuronów ukrytych).

Oznacza to, że największy wpływ mają wejścia związane bezpośrednio z kursem i wolumenem danej akcji (występowały one we wszystkich przypadkach). Wyciągnąć można również dalej posunięte wnioski. Kursy na naszej giełdzie reagują wprawdzie na różne sygnały (np. WIG), ale charakter tej reakcji jest często zbyt zawiły, aby rozwikłała go prosta sieć. Oznacza to również, że inwestor nie musi tworzyć rozbudowanych sieci o dużej ilości wejść, aby otrzymać satysfakcjonujące rezultaty.

Z porównań tych wynika, iż należy rozpatrywać, czy korzyści wynikające z wprowadzenia dodatkowej wiedzy (czyli nowych wejść) zrekompensują straty spowodowane wzrostem i skomplikowaniem struktury sieci. Gdy porównamy sieci rozważane w tym punkcie i w poprzednim, to zaobserwujemy większe znaczenie liczby i dobrania wejść niż liczby neuronów ukrytych. Większa liczba neuronów ukrytych może zarówno wydłużyć, jak i skrócić proces uczenia.

5.1.8. Wielkość ciągu uczącego

Sieci uczono na ciągu liczącym 80% sesji z badanego okresu (440 lub 220 sesji), pozostałe sesje zostały umieszczone w ciągu testującym. Znalazła się w nim co piąta sesja z badanego okresu.


Sieć uczona na 352 sesjach uczyła się dłużej, ale osiągała zbliżoną, a nawet mniejszą wartość błędu niż sieć uczona na 176 sesjach.

Dla porównania efektywności testowania zamieszczono trzy serie danych:

- 1) sieć uczona na 352 sesjach, test na wybranych danych z 440 sesji,
- 2) sieć uczona na 176 sesjach, test na wybranych danych z 220 sesji,
- 3) sieć uczona na 176 sesjach, test na wybranych danych z 440 sesji.

Pomocny do interpretacji okaże się wykres (rys. 4) przedstawiający zmiany kursu *Agrosu* w rozpatrywanym okresie. Wykres ten wyraźnie dzieli się na 2 okresy o horyzontalnym i wzrostowym trendzie średniookresowym.

Sieć uczona na 176 sesjach obejmowała tylko pierwszy okres, o trendzie horyzontalnym. Toteż gdy dane testujące pochodziły tylko z pierwszego okresu, wielkość błędu była poniżej 0,08 i zbliżona była do błędu sieci uczonej na dłuższym okresie. Gdy przeprowadzono test na danych pochodzących z dwóch okresów, błąd dla sieci uczonej na 176 sesjach był dwukrotnie większy i narastał. Sieć uczona na trendzie horyzontalnym nie była w stanie przewidywać kursu na trendzie wzrostowym. Coraz lepsze dostosowanie wag do danych z pierwszych 220 sesji powodowało coraz gorsze ich dostosowanie do danych z następnych sesji. Stąd wypływa wniosek, że sieć do prawidłowych prognoz wymaga zróżnicowanego ciągu uczącego, obejmującego okres, w którym występowały różne trendy.



Rys. 4. Wykres kursu *Agrosu* w badanym okresie

5.1.9. Wprowadzenie szumu

Szum wprowadzamy do ciągu uczącego, aby wymusić na sieci lepszą generalizację wyników. Szum pozwala na korzystanie z mniejszego ciągu uczącego, który zostaje sztucznie zwiększony przez dodanie szumu.

Dodanie szumu okazuje się w przypadku predykcji zmiany kursu akcji zabiegiem korzystnym. Duży szum może wywołać niepożądane efekty (większy błąd, wydłużenie czasu uczenia). Szum ten sumuje się z szumem zawartym w danych. Wynika to z tego, iż dane giełdowe są mocno „zaszumione” i podlegają tak różnorodnym wpływom, że nie jesteśmy w stanie podać ich na wejścia. Stają się więc one dodatkowym szumem.

5.2. Sieć dokonująca predykcji całego portfela i sieci przewidujące pojedyncze akcje wchodzące w skład portfela

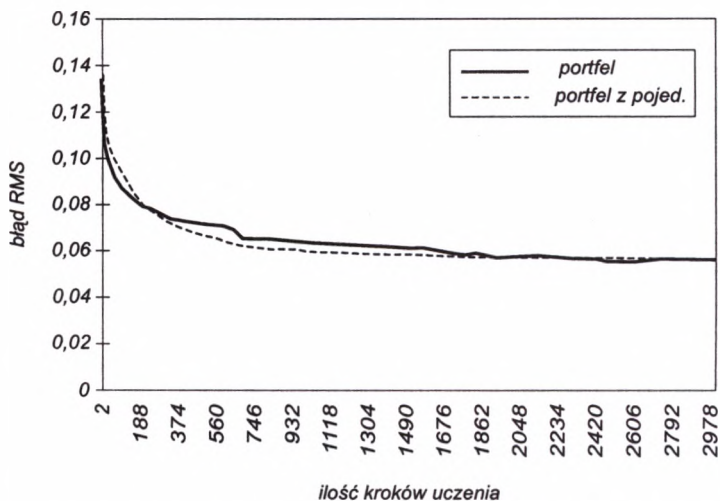
Do badań wykorzystano jeden z optymalnych portfeli wyliczonych przez arkusz kalkulacyjny. Był to portfel bankowy składający się z następujących akcji:

- BPH – 9,8%,
- BRE – 16,3%,
- BSK – 6,7%,
- WBK – 67,1%.

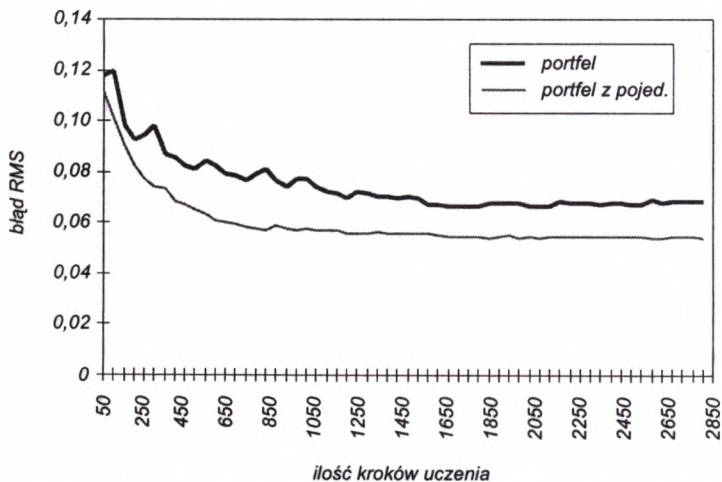
Udział procentowy oznacza udział wartościowy poszczególnych akcji w portfelu. Wybrano portfel bankowy ze względu na jego względnie dużą stabilność. Kryterium optymalizacyjnym była maksymalizacja zysku.

Sieć przewidująca pojedynczą akcję miała 14 wejść: 7 dotyczyło WIG-u, 7 – wybranego papieru. Sieć dokonująca predykcji całego portfela posiadała 35 wejść: 7 dotyczyło WIG-u, 28 – wybranych papierów (po 7 na jeden papier).

Błąd RMS jest podobny dla sieci przewidującej cały portfel (rys. 5), i dla portfela przewidywanego przez cztery sieci, z których każda przewidywała tylko jeden papier. Jeżeli weźmiemy pod uwagę ilość kroków wykonanych przez sieci do momentu prawidłowego rozpoznania 90% ciągu uczącego, to sieci przewidujące jeden papier były 3÷8 razy szybsze.



Rys. 5. Porównanie efektywności uczenia sieci dokonującej predykcji całego portfela i sieci przewidujących pojedyncze akcje wchodzące w skład portfela



Rys. 6. Porównanie efektywności testowania sieci dokonującej predykcji całego portfela i sieci przewidujących pojedyncze akcje wchodzące w skład portfela

Biorąc pod uwagę konieczność uczenia kilku (w tym przypadku 4), a nie jednej sieci, oszczędności czasowe się niwelują. Gładki przebieg uczenia portfela za pomocą sieci przewidujących pojedyncze papiery wynika z uśredniania wyników, który nie ma miejsca w przypadku sieci przewidującej cały portfel.

Swoją wyższość wykazuje portfel przewidywany przez kilka sieci na wykresie testowania (rys. 6). Już od połowy wykresu ustala się duża różnica, która zachowuje w przybliżeniu swoją wartość.

Należy zwrócić uwagę, iż przewidywany portfel składał się tylko z czterech papierów. Dopuszczenie większej ilości papierów w portfelu spowoduje wydłużenie uczenia sieci przewidującej cały portfel, ale może spowodować poprawienie efektywności sieci poprzez wykorzystanie większej ilości związków między wejściami.

6. Podsumowanie

Celem niniejszej pracy było przybliżenie i poszerzenie wybranych elementów wiedzy na temat możliwości zastosowania niestandardowych narzędzi wspomagających decyzje inwestycyjne na rynku kapitałowym, ze szczególnym uwzględnieniem realiów i ograniczeń występujących aktualnie w Polsce. Wykorzystano aplikacje (BrainMakera i Excela), które przy stosunkowo prostej obsłudze charakteryzowały się dużymi możliwościami i zdolnościami adaptacji.

W pracy skoncentrowano się przede wszystkim na problematyce budowy sieci neuronowych do prognozowań finansowych na giełdzie papierów wartościowych i analizie portfelowej opartej na teorii Markowitza i Sharpe'a. Szczególnie zaś zadaniem pracy było udowodnienie, że mało rozpowszechnione metody wykorzystujące sieci neuronowe mogą stanowić konkurencyjne narzędzie w stosunku do innych metod optymalizacji powszechnie stosowanych. Niniejsza praca potwierdza słuszność przyjętych wcześniej założeń, które były celem pracy. Biorąc pod uwagę przedmiot badań, sieci wykazały możliwości dostosowań do wymagań stawianych przez inwestora, a jednocześnie pozwalały zastąpić doświadczenie inwestora oraz wyeliminować czynniki irracjonalne. Szczególna siła sieci tkwi w tym, iż umożliwiają przewidywanie wyjściowych sygnałów bez konieczności stawiania w jasny sposób hipotez o strukturze i naturze związków pomiędzy danymi wejściowymi, a przewidywanymi wynikami. Satysfakcjonujące efekty uzyskane na danych z warszawskiej giełdy dobrze rokują wykorzystaniu rezultatów tej pracy do prognozowań na innych, bardziej stabilnych giełdach, gdzie można bez wielkiego ryzyka przyjąć, iż rozważane narzędzia winny dać lepsze rezultaty. Równocześnie należy podkreślić, iż zaprezentowane w opracowaniu metody będą miały coraz większą wartość użytkową w Polsce wraz ze wzrostem stabilności giełdy.

W artykule skoncentrowano się na wprowadzeniu szerokiego spektrum wejść, które pozwalałyby na wszechstronną analizę prognozowania zachowania akcji na giełdzie. Badania wykazały, że w polskich warunkach powiązania między różnorodnymi wskaźnikami, a kursem akcji są bardzo zawiłe, co wskazuje na to iż:

- sieci lepiej wyłapują związki między prostymi wielkościami, takimi jak kurs, obrót, niż wskaźnikami, w których zawarte są dane już wstępnie przetworzone,
- inwestorzy nie kierują się z reguły wskaźnikami lub też różnie je interpretują.

W przeprowadzonych badaniach przed zastosowaniem sieci neuronowych portfel inwestycyjny został wygenerowany przy pomocy programu opartego na teorii portfelowej, zaimplementowanego przy użyciu Visual Basica dołączonego do arkusza kalkulacyjnego Excel. W zależności od oczekiwań inwestora co do charakteru portfela (stopnia ryzyka i stopy zysku) można przy pomocy tego programu optymalizować portfel na trzy sposoby:

- 1) minimalizować ryzyko przy ustalonej stopie zysku,
- 2) minimalizować współczynnik zmienności,
- 3) maksymalizować zysk przy ustalonym ryzyku.

Przy doborze sposobu uczenia ważne jest, aby cały proces był zbieżny. Bardzo często zdarza się, że niewłaściwe dobranie metody niweczy całą pracę włożoną w naukę neuronów. Minusem sieci neuronowych jest brak globalnych zasad określających dobór wielu parametrów sieci. Każdy problem wymaga indywidualnego podejścia i unikatowej struktury sieci. Praca niniejsza zmierzała do określenia pewnych zasad, które znalazły zastosowanie w dziedzinie predykcji kursów akcji. Przeprowadzono badania mające dać odpowiedź na podstawowe pytania, jak wpływa na efekt końcowy dobór:

- współczynników uczenia i testowania, charakteru zmian współczynników w czasie procesu uczenia, dopuszczalnych błędów,
- odpowiedniego ciągu uczącego,
- stopienia randomizacji i zaszumienia ciągu uczącego,
- wielkości i struktury sieci.

Ze względu na ograniczenia wynikające z krótkiego okresu istnienia giełdy praca obejmowała tylko prognozowanie na 1 tydzień naprzód.

Pierwszym etapem projektowania sieci było określenie wejść. Charakter wyjścia (zmiana kursu w przeciągu tygodnia) wymusił niektóre wielkości wprowadzane na wejścia (kurs, obrót na określonej sesji, sesji sprzed tygodnia i dwóch). Zachowanie całego rynku miało odzwierciedlać wprowadzenie WIG-u. W celu poszerzenia wiedzy wprowadzanej do sieci zastosowano średnie kroczące, które okazały się najbardziej znaczącymi wejściami. Wielkości pomocnicze, to znaczy obliczane na podstawie poprzednich danych i wielkości bilansowych, takie jak oscylatory i inne wskaźniki, nie powodowały znaczącej poprawy efektywności.

Przeprowadzono badania, które wykazały większą efektywność przewidywania za pomocą kilku sieci, w których każda przewidywała zmianę kursu jednego papieru, niż jednej sieci przewidującej kilka akcji. Sieć przewidująca powinna zatem charakteryzować się jednym wyjściem i kilkunastoma wejściami.

Wykazano, że ciąg uczący powinien obejmować stosunkowo długi okres. Wynika to stąd, że sieć, która podczas uczenia nie „widziała” pewnych trendów, nie będzie ich w stanie przewidzieć. Korzystne dla sieci okazało się również wprowadzenie niewielkiego szumu, który wymusił na sieci lepszą generalizację. Przy prezentowaniu danych wejściowych dla procesu uczenia należało często zadbać o losowy ich dobór, gdyż cykliczne przedstawianie danych nie pozwalało na właściwe nauczenie sieci.

Ważnym i znaczącym parametrem, od którego zależy prawidłowe i skuteczne działanie sieci, jest współczynnik uczenia. Obowiązuje tutaj zasada złotego środka: współczynnik ten nie może być ani za duży, ani za mały. Obserwowano, iż liniowe zmniejszanie tego współczynnika w trakcie procesu uczenia miało bardzo korzystny wpływ na działanie sieci.

W przypadku prognozowań finansowych zawsze istnieją sytuacje odbiegające od „normy”, które powodują, że sieć ma duże problemy z nauczeniem się ich. Dlatego najlepsze efekty otrzymano dla sieci uczoney z dopuszczeniem 10% odpowiedzi błędnych.

Ze względu na fakt, iż sieć uczona ze zbyt małą tolerancją wykazuje tendencje bardziej do zapamiętywania ciągu uczącego niż do generalizacji, nie należy stosować zbyt małej tolerancji uczenia. Zbyt duża tolerancja z kolei powoduje, że sieć co prawda uczy się krótko, ale odpowiedzi są obciążone dużym błędem.

W przypadku niewielkich sieci (większość rozpatrywanych sieci składała się z mniej niż 50 neuronów) korekcja przeprowadzana po prezentacji całego ciągu uczącego nie powodowała przyspieszenia procesu uczenia, co jest głównym celem stosowania tej metody.

Badania zawarte w tym opracowaniu wykazują, iż należy stosować sieci trójwarstwowe, a ilość neuronów ukrytych powinna być nieco mniejsza od ilości wejść, gdy ich ilość przekracza 15. W przypadku malejącej ilości wejść należy zwiększać stosunek ilości neuronów ukrytych do ilości wejść. Zmniejszanie ilości neuronów w warstwie ukrytej ma na celu polepszenie generalizacji wyników osiągniętych przez sieć.

Dogłębnie przebadano wpływ ilości i różnorodności wejść na efektywność sieci. Sieci, na których wejścia wprowadzono tylko kurs, obrót w różnych chwilach czasowych oraz średnie kroczące, uczyły się najszybciej, ale osiągały pewien poziom błędu, którego nie były w stanie przekroczyć. Ale dodanie już jednego znaczącego wejścia powodowało widoczne poprawienie efektywności. Sieci o większej ilości wejść charakteryzowały się malejącym trendem błędu RMS, ale czas potrzebny do nauczenia sieci był znacznie dłuższy. Zaskakujące wydają się wyniki testowania powyższych sieci. Otóż najlepsze rezultaty osiągnięto dla sieci najprostszych. Oznacza to, że w okresie, z którego pobrano dane, prawie wyłączny wpływ na prognozę, „wyłowiony” przez sieci, miały kurs i obrót danej akcji. Zwraca uwagę nieduży wpływ WIG-u. Jest to sytuacja o tyle dziwna, iż indeksy na innych giełdach stanowią podstawowe wielkości uwzględniane we wszelkich analizach, obejmujących również predykcje.

Autor w swoich badaniach, w których wykorzystał walory spółek z parkietu podstawowego w okresie listopad 94 – sierpień 96, otrzymał ok. 70% skuteczność predykcji zmiany kursu z założoną tolerancją 10%. Badania te nie były jednak przeprowadzone na wystarczająco licznej grupie spółek (predykcji można było dokonać po minimum rocznym okresie od rozpoczęcia notowań danego waloru), aby uznać ją za reprezentatywną. Również okres, w jakim dokonywano predykcji, był dość długi w stosunku do istnienia warszawskiej giełdy, ale bardzo krótki w stosunku do czasu istnienia giełd państw wysoko rozwiniętych.

Ze względu na różnorodność stosowanych modeli w analizie technicznej i fundamentalnej nie ma możliwości podania średniej ich skuteczności. W stosunku do analizy fundamentalnej należy jeszcze podkreślić fakt, iż jej zastosowanie ograniczone jest do prognozowań średnio- i długoterminowych.

W celu porównania z innymi systemami przytoczono wyniki uzyskane przez automatyczne systemy transakcyjne oparte na wskaźnikach ruchu kierunkowego DMI i ADX. Systemy te zalicza się do narzędzi analizy technicznej, a są to: DMS (*Directional Movement System*) oraz Średnie i ADX [16]. Systemy te generują sygnały kupna i sprzedaży walorów, toteż działają inaczej niż proponowany system, który przewiduje kształtowanie się kursu walorów, ale decyzyjnie pozostawia inwestorowi.

Dla ww. systemów transakcyjnych w okresie luty 95 – luty 99 przedstawione w literaturze [16] wyniki, obrazujące ilość trafnych decyzji, kształtują się następująco:

- średnia dla 15 głównych indeksów giełdowych (11 europejskich, amerykańskie i azjatyckie rynków akcji oraz WIG-u 20):
 - 46% dla Średnie i ADX,
 - 53% dla DMS;
- średnia dla akcji spółek wchodzących w skład indeksu WIG 20:
 - 32% dla Średnie i ADX,
 - 34% dla DMS.

Dla pierwszego przypadku otrzymano ponad 30% zysk netto, natomiast w drugim zysk netto był ujemny.

Porównanie powyższe wskazuje, że systemom automatycznym daleko jeszcze do oczekiwanej przez inwestorów skuteczności, ale również zniwelowanie różnicy między giełdą warszawską a innymi znaczącymi giełdami pozwoli na otrzymanie lepszych rezultatów niż zaprezentowane w tym artykule.

Literatura

- [1] Bartlett P., Downs T.: *Training a neural networks with a genetic algorithm*. Dept. of Elec. Eng., University of Queensland 1990
- [2] Brigham E.F.: *Podstawy zarządzania finansami*. Warszawa, PWE 1996
- [3] *BrainMaker Professional – Users guide and manual*. Nevada City, California Scientific Software Press 1993
- [4] Burda M., Wyplosz Ch.: *Makroekonomia – Podręcznik europejski*. Warszawa, PWE 1995
- [5] Elton E., Gruber M.J.: *Modern portfolio theory and investment analysis*. New York, Wiley 1981
- [6] Fedorowicz Z.: *Rynek pieniądza i rynek kapitału*. Warszawa, Poltext 1997
- [7] *Genetic Training Option*. Nevada City, California Scientific Software Press 1993
- [8] Houthakker H.S., Williamson P.J.: *The Economics of Financial Markets*. New York – Oxford, Oxford University Press 1996
- [9] Jajuga K., Jajuga T.: *Inwestycje*. Warszawa, PWE 1996
- [10] Jajuga K., Jajuga T.: *Jak inwestować w papiery wartościowe*. Warszawa, PWE 1993
- [11] Rutkowska R., Piliński M., Rutkowski L.: *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. Warszawa, PWN 1997
- [12] Shaal P.: *Pieniądz i polityka pieniężna*. Warszawa, PWE 1996
- [13] Tadeusiewicz R.: *Sieci neuronowe*. Warszawa, Akademicka Oficyna Wydawnicza 1993
- [14] Tarczyński W.: *Rynki kapitałowe, Metody ilościowe*. Warszawa, Agencja Wydawnicza „Placet” 1997
- [15] Trippi R.R., Turban E.: *Neural networks in finance and investing*.
- [16] Wąsowski P.: *Wskaźniki ruchu kierunkowego DMI i ADX*. W: Parkiet – Gazeta Giełdy nr 46, 59, 68, 72 z 1999

Recenzenci:

prof. dr hab. inż. Ryszard Tadeusiewicz

dr inż. Radosław Klimek