



Jakub Morkowski

Metoda neuronowo-rozmyta w prognozowaniu
kierunku zmian wybranych kursów walutowych

The neural-fuzzy method in predicting the
direction of changes in selected exchange rates

Praca doktorska

Promotor: dr hab. Agata Kliber, prof. UEP
Promotor pomocniczy: dr Aleksandra Rutkowska
Pracę przyjęto dnia:

Podpis Promotora

Poznań 2022

WSTĘP.....	5
ROZDZIAŁ I. MOŻLIWOŚCI INWESTYCJI NA RYNKU FOREX	10
1. RYNEK FOREX.....	10
1.1. Powstanie rynku FOREX.....	11
1.2. Zasady działania rynku FOREX.....	12
2. INSTRUMENTY POCHODNE.....	13
2.1. Charakterystyka instrumentów pochodnych.....	14
2.2. Kontrakty terminowe	17
2.3. Opcje.....	21
2.4. Opcje binarne	25
2.5. Strategie opcyjne	27
3. WYCENA OPCJI.....	39
ROZDZIAŁ II. PROGNOZOWANIE ZA POMOCĄ MODELI KLASYCZNYCH ORAZ SIECI NEURONOWYCH	42
1. KLASYCZNE MODELE STATYSTYCZNE	42
1.1. Prognozowanie naiwne	42
1.2. Model ARMA	43
1.2.1. Proces AR	43
1.2.2. Proces MA	45
1.2.3. Proces ARMA.....	45
2. SIECI NEURONOWE	47
2.1. Idea sieci neuronowych	47
2.2. Uczenie sieci neuronowych	48
2.3. Uczenie zespołowe.....	50
2.4. Klasyfikacja sieci neuronowych	50
2.5. Charakterystyka wybranych sieci neuronowych	55
2.5.1. Charakterystyka sieci neuronowych typu MLP.....	55
2.5.2. Charakterystyka sieci neuronowych typu ELM	56
2.5.3. Charakterystyka sieci LSTM.....	58
2.6. Sieci neuronowe w prognozowaniu kursów walutowych	62
ROZDZIAŁ III. METODA NEURONOWO-ROZMYTA.....	64
1. KONCEPCJA ZBIORÓW ROZMYTYCH ORAZ PODSTAWOWE POJĘCIA.....	64
2. FUNKCJE PRZYNALEŻNOŚCI.....	66
3. LOGIKA ROZMYTA.....	70
4. ZBIORY ROZMYTE W INWESTOWANIU	72
5. METODA NEURONOWO-ROZMYTA.....	74
6. METODA NEURONOWO-ROZMYTA A INNE PODEJŚCIA ŁĄCZĄCE SIECI NEURONOWE I ZBIORY ROZMYTE.....	76
ROZDZIAŁ IV. BADANIE MOŻLIWOŚCI POPRAWY TRAFNOŚCI PROGNOZ ZMIAN KURSÓW WALUTOWYCH Z WYKORZYSTANIEM PODEJŚCIA NEURONOWO-ROZMYTEGO	79
1. SCHEMAT BADANIA ORAZ PYTANIA BADAWCZE.....	81
1.1. Badanie wpływu ustawień sieci neuronowych na jakość prognoz kierunku zmian kursu walutowego	81
1.2. Badanie możliwości poprawy jakości prognoz z wykorzystaniem metody rekurencyjnej.....	82
1.3. Badanie możliwości poprawy jakości prognoz z wykorzystaniem logiki rozmytej.....	83
2. OPIS ORAZ CHARAKTERYSTYKA DANYCH	83
3. PROGNOZOWANIE KIERUNKU ZMIAN KURSU WALUTOWEGO Z WYKORZYSTANIEM SIECI MLP, ELM I LSTM	87
3.1. Oznaczenia i kluczowe pojęcia.....	87
3.2. Wpływ ustawień sieci neuronowych na trafność prognozowania kierunku zmiany kursu walutowego	88
3.3. Badanie porównawcze trafności sieci neuronowych o różnych ustawieniach z klasycznymi modelami ekonometrycznymi	105
3.4. Trafność prognozowania kierunku zmiany kursu – porównanie wyników dla sieci uczonych na cenach i zwrotach	111
4. TRAFNOŚĆ PROGNOZOWANIA KIERUNKU ZMIANY KURSU WALUTOWEGO METODĄ REKURENCYJNĄ.....	115
5. METODA NEURONOWO-ROZMYTA.....	128
5.1. Trafność prognoz zmian kursu walutowego uzyskanych metodą neuronowo-rozmytą.....	128
5.2. Badanie porównawcze trafności prognoz metodą neuronowo-rozmytą z klasycznymi modelami ekonometrycznymi	131

5.3. Badanie porównawcze trafności prognoz uzyskanych metodą neuronowo-rozmytą z metodą wyboru prognozy na podstawie wskazań większości sieci	132
5.4. Badanie porównawcze trafności prognoz metodą neuronowo-rozmytą z trafnością prognoz uzyskanych metodą rekurencyjną	135
5.5. Połączenie metody neuronowo-rozmytej z metodą rekurencyjną	137
6. PODSUMOWANIE WYNIKÓW	144
ROZDZIAŁ V. ZASTOSOWANIE METODY NEURONOWO-ROZMYTEJ DO INWESTYCJI W INSTRUMENTY POCHODNE.....	146
1. ZYSK Z INWESTYCJI UZYSKANYCH NA PODSTAWIE PROGNOZ SIECI NEURONOWYCH	149
1.1. Inwestycja w kontrakty	149
1.2. Inwestycja w opcje kupna i sprzedaży	153
1.3. Inwestycja w opcje kupna i sprzedaży lub strategię stelaża	157
1.4. Porównanie inwestycji w opcje oraz w strategię stelaża	160
2. ZYSKOWNOŚĆ INWESTYCJI PRZY WYKORZYSTANIU WSKAZAŃ METODY REKURENCYJNEJ	162
2.1. Inwestycja w kontrakty	162
2.2. Inwestycja w opcje kupna i sprzedaży	164
2.3. Inwestycja w opcje kupna i sprzedaży lub strategię stelaża	167
3. ZYSKI Z INWESTYCJI NA PODSTAWIE PROGNOZ UZYSKANYCH Z METODY NEURONOWO-ROZMYTEJ	168
3.1. Inwestycja w kontrakty	168
3.2. Inwestycja w opcje kupna i sprzedaży	170
3.3. Inwestycja w opcje kupna i sprzedaży lub strategię stelaża	171
3.4. Porównanie metody rekurencyjnej z neuronowo-rozmytą dla inwestycji w opcje	172
3.5. Porównanie metody rekurencyjnej z neuronowo-rozmytą dla inwestycji w opcje lub strategię stelaża	174
4. PORÓWNANIE PRZECIĘTNEGO ZYSKU OSIĄGANEGO Z ZASTOSOWANIEM PROGNOZ UZYSKANYCH RÓŻNYMI METODAMI	175
ZAKOŃCZENIE.....	179
BIBLIOGRAFIA.....	187
WYKAZ RYSUNKÓW	200
WYKAZ TABEL.....	201

Wstęp

Wraz z postępującym rozwojem rynków finansowych, zarówno naukowcy, jak i praktycy poszukują coraz nowszych metod prognozowania zmian cen instrumentów finansowych. Celem stawiania prognoz jest próba osiągnięcia ponadprzeciętnego zysku z inwestycji. Z wysokim zyskiem łączy się zazwyczaj adekwatne ryzyko. Jedną z możliwości jego ograniczenia jest wykorzystanie instrumentów pochodnych. Są one zarówno narzędziem spekulacyjnym, jak i zabezpieczającym inwestycje. Jednym z powszechnie stosowanych instrumentów pochodnych są opcje, z wykorzystaniem których inwestor może budować różne strategie, w zależności od tego, czy oczekuje wzrostu, spadku, czy stabilizacji ceny instrumentu podstawowego w przyszłości. Instrumentem podstawowym, wykorzystywanym w opcjach, mogą być akcje, indeksy giełdowe, ale też kursy walutowe.

Kursy walutowe i ich wahania odgrywają kluczową rolę w gospodarce w czasach globalizacji (Schrimpf, Sushko, 2020). Mają one realny i znaczący wpływ na aktualną sytuację gospodarki w danym kraju. Prognozowanie kursów walutowych stanowi ważne zagadnienie ze względu zarówno na możliwości spekulacyjne, a tym samym generowanie zysków, jak i ze względu na zabezpieczanie pozycji w handlu międzynarodowym (Markova, 2019). Zmiany kursów walutowych mają znaczący wpływ na wiele sfer gospodarki, takich jak handel zagraniczny, przepływ kapitałów, zarządzanie portfelem aktywów oraz na realną aktywność gospodarczą. Mają również wymierne znaczenie dla konsumentów, przedsiębiorstw krajowych i prowadzących działalność międzynarodową oraz gospodarek narodowych.

W związku z tym, że najistotniejsze waluty świata podlegają ciągłym wahaniom, prognozowanie zmian kursów walutowych jest istotnym zagadnieniem z punktu widzenia podmiotów gospodarczych, instytucji, a także gospodarek. Warto przy tym podkreślić, że fluktuacje kursów walutowych mają znaczenie również dla krajów o innym niż płynny kursie walutowym, ponieważ waluty tych krajów bardzo często są uzależnione od kursu tych z systemu płynnego (głównie dolara amerykańskiego oraz euro). W związku z powyższym poszukiwanie nowych metod poprawiających trafność prognoz kursów jest zagadnieniem aktualnym i istotnym.

W niniejszej rozprawie doktorskiej poszukuję skutecznej metody prognozowania kierunku zmian kursu walutowego w celu wykorzystania jej do skonstruowania strategii opcyjnej przynoszącej zysk w momencie wzrostu, spadku lub stabilizacji kursu. Ponieważ docelowo zakładam taki typ inwestycji, nie interesuje mnie prognoza dokładnej wartości

kursu, a jedynie kierunek zmiany: wzrost lub spadek, dlatego moją metodę oceniam pod kątem trafnego prognozowania kierunku zmiany kursu. Klasycznymi już metodami prognostycznymi są metody ekonometryczne, na przykład liniowe modele ARMA lub ARMA-GARCH. W ostatnich czasach popularność zyskują sieci neuronowe (Alakhras, 2005, Strader i inni, 2020) oraz hybrydowe sieci neuronowe (Hao, Gao, 2020) stanowiące syntezę sieci neuronowych z inną metodą (na przykład ekonometryczną) (Zhang, Wan, 2007, Henrique i inni, 2019). Popularność zyskują również rozmyte sieci neuronowe, w których z wykorzystaniem logiki rozmytej tworzone są reguły rozmyte w procesie uczenia się sieci i wykorzystywane następnie do dokonywania prognoz (de Campos Souza, 2020).

Celem niniejszej rozprawy jest skonstruowanie autorskiej metody neuronowo-rozmytej do prognozowania kierunku zmian kursów walutowych i późniejszego wykorzystania tych prognoz do konstrukcji strategii opcyjnych – innych w przypadku gry na wzrost, spadek i stabilizację. **Tezą** rozprawy doktorskiej jest: *rozmyte prognozy kierunku zmian kursu walutowego z autorskiego podejścia neuronowo-rozmytego umożliwiają generowanie wyższych zysków z inwestycji w strategię opcyjnie na wzrost, spadek i stabilizację, niż wykorzystanie zespołowych prognoz sieci neuronowych*. Badanie empiryczne przeprowadziłem na trzech parach walutowych (CHF/EUR, GBP/EUR oraz USD/EUR) oraz z wykorzystaniem trzech typów sieci neuronowych: MLP, ELM i LSTM o różnych, w sumie 140, kombinacjach hiperparametrów. Zakres czasowy badania obejmuje lata 1.01.2014-31.12.2019, a dane są kwotowane w częstotliwości dziennej, co daje łącznie 1440 obserwacji na jedną parę walutową. Badany okres obejmuje momenty wzrostowe, spadkowe oraz charakteryzujące się względną stabilizacją.

Tworząc metodę neuronowo-rozmytą inspirowałem się podejściem *ensemble learning*, którego ideą jest łączenie wyników wielu prostych algorytmów uczenia maszynowego w celu uzyskania optymalnego rezultatu. W moim podejściu wykorzystuję prognozy postawione z użyciem sieci neuronowych różnych typów i o różnych parametrach. Stosuję różne metody grupowania wyników, od prostej metody średniej i większości, poprzez rozmywanie wszystkich prognoz z wykorzystaniem różnych kształtów funkcji przynależności, do rozmywania połączonego z rekurencyjnym wyborem najlepiej prognozujących sieci.

Pytania badawcze postawione w tej rozprawie są przypisane do poszczególnych etapów badania. W pierwszym etapie stawiam prognozy zmian kierunku kursów walutowych z wykorzystaniem trzech typów sieci neuronowych: ELM, MLP i LSTM o różnej

hiperparametryzacji. Prognozy za pomocą sieci neuronowych stawiane są na podstawie danych o interwale jednodniowym, a horyzont prognozy wynosi od 1 do 10 dni.

Pytania badawcze przypisane do tego etapu są następujące:

- 1.1. Czy trafność prognozowania kierunku zmian kursu zależy od horyzontu prognozy?
- 1.2. Czy trafność prognozowania kierunku zmian kursu zależy od hiperparametryzacji sieci?
- 1.3. Czy trafność prognozowania kierunku zmian kursu jest uzależniona od typu sieci?
- 1.4. Czy trafność prognozowania kierunku zmian kursu za pomocą sieci neuronowych jest wyższa niż modeli ekonometrycznych?

W drugim etapie badania konstruuje prognozy z wykorzystaniem metody rekurencyjnej. Metoda rekurencyjna polega na dokonaniu prognoz za pomocą zawężonego podzbioru dwudziestu sieci o różnych hiperparametrach, które okazały się najlepsze w okresie poprzedzającym moment stawiania nowej prognozy. Celem tego etapu jest sprawdzenie czy metoda rekurencyjna pozwoli na wytypowanie rodzajów sieci neuronowych oraz określonej hiperparametryzacji, charakteryzujących się wyższym poziomem trafności dla danej waluty oraz horyzontu prognozy. Pytania badawcze przypisane do tego etapu są następujące:

- 2.1. Czy trafność prognoz uzyskanych metodą rekurencyjną będzie wyższa niż trafność prognoz uzyskana prognozą naiwną lub modelem ARMA?
- 2.2. Czy prognozy z metody rekurencyjnej będą trafniejsze niż średnie prognozy dla pojedynczych sieci?

W etapie trzecim konstruuje prognozy z wykorzystaniem podejścia neuronowo-rozmytego. W podejściu tym grupuje wyniki uzyskane z użyciem wszystkich lub wybranych prognoz dokonanych przez trzy różne typy sieci neuronowych o różnych hiperparametrach, w celu postawienia jednej prognozy rozmytej. Pytania badawcze dotyczą różnic między wynikami uzyskanymi przez zastosowanie różnego typu funkcji przynależności w podejściu neuronowo-rozmytym oraz porównania tej metody do metod z etapów poprzednich:

- 3.1. Czy typ funkcji przynależności ma wpływ na trafność prognoz w podejściu neuronowo-rozmytym?

3.2. Czy metoda neuronowo-rozmyta cechuje się wyższą trafnością prognoz niż sieci neuronowe?

3.3. Czy metoda neuronowo-rozmyta charakteryzuje się wyższą trafnością prognoz niż model ARMA i prognoza naiwna?

3.4. Czy połączenie podejścia rekurencyjnego z podejściem neuronowo-rozmytym poprawi trafność prognoz?

Etap czwarty został przedstawiony w V rozdziale rozprawy. Wykorzystuję w nim prognozy uzyskane w poprzednich etapach badania do inwestycji w instrumenty pochodne. Pytania, jakie przyświecają badaniom przedstawionym w tej części rozprawy, są następujące:

4.1. Czy wykorzystanie rozmytych prognoz zmian kierunku cen pozwoli na osiągnięcie wyższego zysku z inwestycji w kontrakty oraz opcje niż wykorzystanie wskazań uzyskanych z prognoz sieci neuronowych oraz metody rekurencyjnej?

4.2. Czy zastosowanie prognoz rozmytych do strategii opcyjnej na stabilizację pozwoli na ograniczenie potencjalnych strat lub osiągnięcie wyższych zysków niż stosowanie tylko gry na wzrost lub spadek?

Rozprawa doktorska podzielona jest na pięć rozdziałów. Pierwsze trzy stanowią merytoryczne wprowadzenie do zagadnień stanowiących bazę niniejszej pracy, natomiast ostatnie dwa zawierają przedstawienie wyników badań empirycznych.

Pierwszy rozdział stanowi wprowadzenie do zagadnień związanych z rynkiem FOREX i możliwościami inwestycyjnymi w kursy walutowe. W rozdziale tym przedstawiam strukturę i sposób działania rynku FOREX, a także koncepcję i charakterystykę instrumentów pochodnych, wraz ze wskazaniem na możliwości inwestycyjne (lub zabezpieczające) płynące ze stosowania różnego ich typu i budowanych na ich podstawie strategii opcyjnych. Rozdział kończę przedstawieniem metod wyceny instrumentów pochodnych.

W rozdziale drugim opisuję metody wykorzystywane w badaniu empirycznym do prognozowania kierunku zmian cen, które następnie stają się podstawą do dokonywania inwestycji. Na wstępie przedstawiam klasyczne modele statystyczne, czyli prognozowanie naiwne i model ARMA. Metody te stanowią punkt odniesienia do oceny trafności prognozowania kierunku zmian kursów metodami stosowanymi w dalszej części pracy. Druga

część rozdziału została poświęcona sieciom neuronowym. Opisuję w nim różnego rodzaju sieci oraz przedstawiam przegląd literatury na temat tych, które z powodzeniem stosowane są w prognozowaniu. Przegląd ten stanowi podstawę do wyboru typów sieci neuronowych, których używam w badaniu empirycznych.

W trzecim rozdziale przedstawiam propozycję autorskiej metody neuronowo-rozmytej. Zaczynam od wprowadzenia podstawowych pojęć z zakresu zbiorów i logiki rozmytej a także przedstawiam różne metody tworzenia funkcji przynależności. Prezentuję też istniejące w literaturze sposoby łączenia sieci neuronowych z podejściem rozmytym, wskazując na podobieństwa i różnice między nimi, a proponowaną przeze mnie metodą.

W rozdziale czwartym i piątym przedstawiam wyniki badań. W rozdziale czwartym koncentruję się na trafności prognoz kierunku zmian kursów. Porównuję trafność prognozowania metody neuronowo-rozmytej z metodami ekonometrycznymi, metodą podążania za wskazaniem większości sieci oraz metodą rekurencyjnego wyboru sieci o najlepszych hiperparametrach.

W rozdziale piątym skupiam się na możliwości generowania zysków z dokonywanych inwestycji na podstawie prognoz uzyskanych w rozdziale czwartym. Uwzględniam inwestycje w kontrakty oraz opcje, w tym strategie opcyjne nakierowane na wzrost, spadek i stabilizację.

Częściowe wyniki niniejszej rozprawy doktorskiej były prezentowane na seminarium SEFIN, seminariach Katedry Matematyki Stosowanej oraz konferencjach: *Carpe Scientiam - Lomonosov Moscow State University* (Moskwa, 2018), *XX SIGEF Congress - Harnessing Complexity through Fuzzy Logic* (Neapol, 2019) oraz *The 21st International Conference on Artificial Intelligence and Soft Computing* – ICAISC (online, 2022). Chciałbym podziękować uczestnikom seminariów i konferencji za wszystkie uwagi merytoryczne. Szczególnie chciałbym podziękować panu doktorowi Marcinowi Bartkowiakowi za konsultacje i wsparcie merytoryczne, szczególnie przy pisaniu rozdziału piątego niniejszej rozprawy.

Rozdział I. Możliwości inwestycji na rynku FOREX

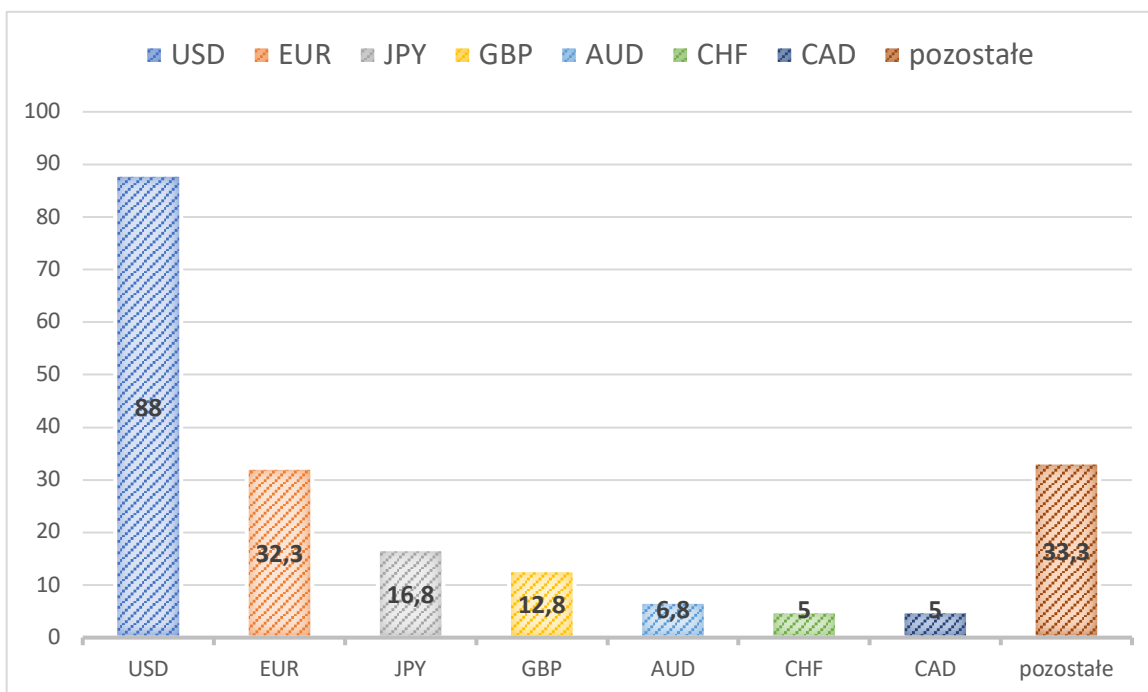
Rozdział ten obejmuje tematykę rynku FOREX oraz możliwości inwestowania na nim. W pierwszym podrozdziale przedstawiona zostanie historia rynku FOREX, statystyki z nim związane oraz zasady działania. W drugim podrozdziale przedstawione zostaną instrumenty pochodne wraz ze swoją charakterystyką.

1. Rynek FOREX

Rynek FOREX (Foreign Exchange Market lub FX Market) jest największym rynkiem finansowym na świecie pod względem wolumenu obrotów, płynności i wartości. W związku z brakiem siedziby rynku FOREX, nazywany jest on rynkiem OTC (ang. *Over-the-Counter*). (Kochan, 2006). W przeciwieństwie do innych rynków finansowych, jak rynek akcji, notowania na rynku FOREX są ciągłe. Dzienny obrót na rynku FOREX w 2019 roku wzrósł w stosunku do roku 2016 z 5,1 biliona dolarów do 6,6 biliona dolarów ($6,6 \cdot 10^{12}$).¹ Na rynku FOREX notowanych jest 190 par walutowych, przy czym najpopularniejszy jest dolar amerykański (USD) – 88% transakcji zawieranych na tym rynku odbywa się z udziałem tej waluty. Pozostałe sześć walut, wraz ze wskazaniem ich procentowego udziału w transakcjach na rynku FOREX wymieniono poniżej oraz zobrazowano na rysunku 1:

- Euro (EUR) – 32,3 %
- Jen japoński (JPY) – 16,8%
- Funt brytyjski (GBP) – 12,8%
- Dolar australijski (AUD) – 6,8%
- Dolar kanadyjski (CAD) – 5%
- Frank szwajcarski (CHF) – 5%

¹ <https://www.compareFOREXbrokers.com/FOREX-trading/statistics/>



Rysunek 1. Procentowy udział danej waluty w transakcjach na rynku FOREX stan na maj 2022

Źródło: <https://www.compareFOREXbrokers.com/FOREX-trading/statistics/>

1.1. Powstanie rynku FOREX

Historii rynku walutowego należy poszukiwać wraz z początkiem historii pieniądza. Sam rynek pieniądza na przestrzeni lat przeszedł wiele ewolucyjnych zmian, a za jego początek należy uznać zastąpienie handlu barterowego przez handel z wykorzystaniem jednolitego środka płatniczego. Zmiana ta znacząco wpłynęła na ułatwienie wymiany handlowej. Za pierwszy pieniądz rozumiany w sposób współczesny należy uznać wprowadzony w Mezopotamii srebrny szekel, będący zarówno monetą jak i wyrażoną w srebrze miarą wartości. Na przestrzeni wielu lat głównym narzędziem tezauryzacji były surowce, ze szczególnym uwzględnieniem złota oraz srebra. Czynnikiem wpływającym na dobór takich surowców była rzadkość ich występowania. Za początek walut narodowych uznawane jest rozpoczęcie wykorzystywania not bankowych jako środka rozliczeniowego po powstaniu pierwszych instytucji bankowych (Morawski, 2002).

Głównym problemem związanym z opieraniem środka płatniczego na kruszcach jest skończoność zasobów kruszców. System monetarny powiązany z parytetem złota obowiązywał do I Wojny Światowej. Ideą tego systemu była konieczność posiadania pokrycia za noty bankowe w złocie deponowanym w banku centralnym danego kraju. Historycznym wydarzeniem zmieniającym ten porządek był układ Bretton Woods z 1944 roku. Na podstawie

podpisanych w tym układzie postanowień wprowadzono system sztywnego kursu walutowego względem dolara amerykańskiego oraz przypisano sztywną wartość jednej uncji złota wyrażonej w USD – kurs wymiany jednej uncji złota wynosił 35 USD. Za początek rozwoju rynku walutowego należy uznać decyzje 37. prezydenta Stanów Zjednoczonych Ameryki, Richarda Nixona, który w sierpniu 1971 r. zniósł wymienialność dolara na złoto. Sytuacja ta zakończyła porządek panujący po układzie z Bretton Woods. W przeciągu dwóch lat od tej decyzji na świecie wprowadzona została pełna wymienialność walut. Moment ten był przełomowy i sprawił, że wartość poszczególnych walut od tej pory kształtowana jest rynkowo przez popyt i podaż na nie. Waluty, których wartość kształtowana jest rynkowo to waluty z systemu kursu płynnego. Poza systemem kursu płynnego istnieją jeszcze systemy kursu sztywnego (sztywne związanie waluty krajowej z walutą obcą lub koszykiem walut obcych) i system kursu pośredniego (jest to system płynny, ale zakładający pewne ograniczenia w kształtowaniu się kursu tej waluty) (Milewski, M., 2012).

1.2. Zasady działania rynku FOREX

Do najpopularniejszych transakcji zawieranych na rynku FOREX należą transakcje *forward* oraz *spot*. Na rynku *spot* transakcje dokonywane są w bieżących cenach walut, natomiast rozliczanie takich transakcji nie musi być dokonywane natychmiast². W momencie składania zleceń za pomocą brokerów z innych państw, rozliczenia dokonywane są w ciągu dwóch dni roboczych, przy czym należy zauważyć, że muszą być to dwa dni robocze w obu krajach. Skutkiem takiego rozliczania jest czasami konieczność czekania z wypłaceniem środków z rachunku do momentu rozliczenia transakcji. Do fizycznej dostawy aktywów, na rynku zarówno kasowym jak i terminowym, nie zawsze dochodzi. Za brak dostawy odpowiadają głównie duże banki i instytucje spekulujące na rynku oraz podmioty zabezpieczający pozycje walutowe, które nie oczekują rzeczywistej dostawy aktywów – interesuje ich generowanie zysków na różnicach kursowych.

Do uczestników rynku walutowego zaliczane są banki (komercyjne, inwestycyjne, centralne), fundusze, brokerzy, przedsiębiorstwa oraz inwestorzy indywidualni. W związku z wielkością podmiotów, największy wpływ na rynek mają banki komercyjne i inwestycyjne, które działają na rynku walutowym spekulując. Banki centralne, dzięki udziałowi w rynku

² Wyjątkiem są transakcje u brokerów rodzimych.

walutowym, mogą wpływać i realizować politykę wytyczoną przez organy nimi zarządzające. Fundusze walutowe również mogą realnie wpływać na wahania kursów walut notowanych na rynku poprzez swoje decyzje. Wynika to z bardzo dużych środków, jakimi dysponują oraz tendencją do podejmowania większego ryzyka niż banki, w celu osiągnięcia ponadprzeciętnych zysków.

Ze względu na globalizację, udział na rynku walutowym przedsiębiorstw stał się naturalnym zjawiskiem. Obecność przedsiębiorstw na tym rynku może mieć kilka przyczyn. Do głównych można zaliczyć posiadanie kredytów w walutach obcych, prowadzenie działalności międzynarodowej wiążącej się z kupowaniem i sprzedawaniem dóbr i usług za walutę obcą. W związku z tym, działalność przedsiębiorstw na rynku walutowym opiera się w największej mierze na zabezpieczaniu przed niekorzystnymi wahaniami kursów walut.

Na rynku walutowym handluje się parami walut. Oznacza to, że gdy mówimy o zmianie kursu jednej waluty, zawsze mamy na myśli zmianę kursu jednej waluty względem innej. Waluta, o której zmianie kursu mówimy, to waluta bazowa, natomiast waluta, względem której nastąpiła zmiana, to waluta kwotowana. Zapis EUR/USD oznacza, że euro jest walutą bazową a dolar amerykański walutą kwotowaną. Informacja o kursie takiej pary walutowej mówi, ile dolarów należy zapłacić za jedno euro. W przypadku pary USD/EUR sytuacja wygląda odwrotnie i to dolar amerykański jest walutą bazową a euro walutą kwotowaną. Oferta kupna (pozycja długa) danej waluty to *bid* a sprzedaży (pozycja krótka) *ask*. Różnica między ofertami kupna i sprzedaży nazywana jest *spreadem* i jego wysokość to główny czynnik generujący zyski dla brokerów (Zalewski, 2010).

2. Instrumenty pochodne

Od swojego powstania FOREX pełnił funkcję usprawniającą handel na rynku międzynarodowym. Jednak zauważalna zmienność oraz płynność tego rynku otworzyła nowe możliwości spekulacji inwestorom z całego świata. Aktualnie spekulacje stanowią ok. 90% transakcji na rynku FOREX. Na rynku walutowym do największej liczby transakcji dochodzi za pomocą CFD (ang. *contract for difference*), czyli kontraktów na różnice kursowe. Kontrakty te są instrumentami pochodnymi, w których, w momencie rozliczenia, dochodzi do wymiany kwoty stanowiącej różnicę między ceną otwarcia a ceną zamknięcia. W związku z tym należy zaznaczyć, że na rynku FOREX handel nie odbywa się walutami, a kontraktami opartymi na kursach par walutowych. Główną konsekwencją takiego działania rynku FOREX jest fakt, iż

kupując kontrakt CFD na daną walutę nie nabywa się tej waluty, tylko możliwość generowania zysków wynikających z wahanja jej kursu (Kurzajewski, Nowalińska, 2017). Wraz z rozwojem rynku FOREX, pojawiły się też inne możliwości spekulacji na zmianach kursów walut z wykorzystaniem instrumentów pochodnych, na przykład za pomocą opcji. W niniejszym rozdziale przedstawiam główne charakterystyki instrumentów pochodnych oraz strategii budowanych za ich pomocą.

2.1. Charakterystyka instrumentów pochodnych

Instrumenty pochodne można podzielić według kryteriów takich jak stopień złożoności czy miejsce obrotu. Ze względu na stopień złożoności wyróżniamy:

- instrumenty pierwszej generacji – kontrakty, opcje, swapy;
- instrumenty drugiej generacji – instrumenty pochodne oparte na innych instrumentach pochodnych, o znacznie wyższym stopniu złożoności.

Ze względu na miejsce, w którym dochodzi do obrotu, można wskazać instrumenty, którymi handluje się:


- na giełdzie - na przykład: opcje i kontrakty *futures*,
- na rynkach pozagiełdowych (OTC) – przede wszystkim kontrakty *forward* oraz *swapy* (Pietrzak, 2003).

Instrumentom pochodnym można przypisać trzy podstawowe role jakie odgrywają one na rynku:

- instrument zabezpieczający (*hedging*) – instrumenty pochodne nabywane są w celu zabezpieczenia przed niekorzystnym wzrostem lub spadkiem ceny (kursu) aktywów bazowych, które mogłyby spowodować straty,
- arbitraż – z wykorzystaniem instrumentów pochodnych zawierane są jednocześnie transakcje na rynku kasowym i terminowym w celu uzyskania zysku bez ponoszenia ryzyka,
- spekulacje – polegają na wykorzystaniu instrumentów pochodnych do dokonywania transakcji w celu osiągnięcia zysku na wahaniami ceny danego dobra, będącego efektem przewidywań kierunków zmian cen aktywów bazowych instrumentu pochodnego.

Jednym z elementów charakterystycznych dla rynku instrumentów pochodnych jest mechanizm dźwigni finansowej. Mechanizm ten znany jest w wielu dziedzinach finansów. W odniesieniu do instrumentów pochodnych należy go interpretować jako mechanizm pozwalający na zawarcie transakcji bez konieczności posiadania wszystkich środków umożliwiających jego pokrycie (wystarczy wnieść depozyt w wysokości ok. 5-15% wartości kontraktu). Mechanizm dźwigi finansowej umożliwia generowanie wysokich zysków poprzez spekulacje na instrumentach pochodnych, jednak wraz ze wzrostem potencjalnego zysku rośnie ryzyko danej transakcji na rynku finansowym. Szczególnie przy zawieraniu ryzykownych kontraktów bez konieczności wnoszenia całej wartości kontraktu, inwestor może osiągnąć zarówno wysokie zyski jak i ponieść adekwatne straty. Instrumenty pochodne mają za zadanie zapewnić obu stronom transakcji dostawę określonych dóbr, w ogólnie określonej cenie, w ustalonym momencie w przyszłości. Jeżeli rynek danych aktywów bazowych charakteryzuje się zmiennością, pojawia się ryzyko. Istnienie instrumentów pochodnych jest odpowiedzią na potrzebę zminimalizowania ryzyka wahań cen. Bardzo duży wpływ na rozwój instrumentów pochodnych ma szeroko rozumiana globalizacja, charakteryzująca się większą liczbą powiązań z przedsiębiorstwami z innych krajów. Sytuacja ta stwarza ryzyko związane ze zmianą wartości aktywów lub zobowiązań, w wyniku zmian kursów walutowych (Czekaj, 2017).


Na rysunku 2 przedstawiono popularność kontraktów terminowych na rynku globalnym z podziałem na stosowany instrument, według wartości zawieranych kontraktów podanych w miliardach dolarów amerykańskich. Można zauważyć dynamicznie rosnącą popularność kontraktów *forward* i utrzymujący się na w miarę stabilnym poziomie udział opcji i *swapów*.



Rysunek 2. Popularność kontraktów terminowych według zastosowanych instrumentów na rynku globalnym, według wartości zawieranych kontraktów podanych w miliardach dolarów amerykańskich

Źródło: opracowanie własne na podstawie: stats.bis.org

Na rysunku 3. został przedstawiony podział kontraktów terminowych ze względu na udział walut w transakcjach na rynku globalnym, podanych według wartości zawieranych kontraktów w miliardach dolarów amerykańskich. Przedstawione na tym rysunku wielkości stanowią uzasadnienie dla wyboru walut do badania empirycznego przedstawionego w tej rozprawie.



Rysunek 3. Popularność kontraktów dewizowych według waluty na rynku globalnym, według wartości zawieranych kontraktów w miliardach dolarów amerykańskich

Źródło: opracowanie własne na podstawie: stats.bis.org

Na rysunku 3. oraz w badaniach w dalszej części rozprawy doktorskiej, uwzględniono cztery z najbardziej najpopularnych walut uczestniczących w transakcjach. Są to: dolar amerykański, euro, funt brytyjski oraz frank szwajcarski. Główną przyczyną takiego doboru walut do analizy w części empirycznej była popularność danych par walutowych. Wśród walut można zauważyć następującą zależność. Udział czterech z nich w rynku można uznać za stabilny i wykazujący niewielkie wahania. Znaczący wzrost można zauważyć w przypadku dolara amerykańskiego, którego udział w rynku systematycznie rośnie z roku na rok.

W podrozdziałach 2.2. oraz 2.3. zostaną szczegółowo scharakteryzowane kontrakty terminowe oraz opcje, z których niektóre zostaną wykorzystane w badaniu empirycznym. Przedstawiam również strategie budowane przy użyciu kontraktów, opcji oraz obu instrumentów jednocześnie.

2.2. Kontrakty terminowe

Kontrakt *forward* to zindywidualizowana umowa, w której dwie strony zgadzają się na wymianę danego instrumentu po wcześniej określonej cenie i w czasie w przyszłości. Kontrakty terminowe są sprzedawane na rynku OTC, a nie na giełdzie. Kontrakt *futures* jest standaryzowaną wersją kontraktu *forward*, który jest publicznie notowany na giełdzie kontraktów *futures*. Podobnie jak kontrakt *forward*, kontrakt *futures* charakteryzuje się ustaloną wcześniej ceną oraz czasem na zakup lub sprzedaż danego instrumentu, na który jest wystawiony - zwykle akcji, obligacji lub towarów (na przykład złota) (Hull, Dąbrowski, Sobkowiak, 1997, Jurek, 2001). Przykładem kontraktu *forward* na rynku FOREX jest kontrakt CDF, charakterystyczne dla tego typu kontraktu jest brak fizycznej dostawy aktywa a realizacja zysku przez rozliczenie różnic kursowych. Jednak zarówno w przypadku kontraktu *forward* jak i kontraktu CDF nie ma różnicy w profilu wypłaty tylko w różnicach formalnych.


Główną cechą odróżniającą kontrakty *futures* od kontraktów *forward* jest fakt, iż kontrakty *futures* są publicznie notowane na giełdzie, a kontrakty *forward* na rynku niepublicznym. Sytuacja ta niesie ze sobą kilka kolejnych różnic między nimi, przy czym podstawowe z nich zostały przedstawione w tabeli 1.

Tabela 1. Różnice między kontraktami forward i futures

	Kontrakt <i>forward</i>	Kontrakt <i>futures</i>
Definicja	Umowa zawarta pomiędzy dwiema stronami, która dotyczy zakupu lub sprzedaży składnika aktywów we wcześniej ustalonym terminie w przyszłości po określonej cenie.	Umowa zawarta pomiędzy dwiema stronami, która dotyczy zakupu lub sprzedaży składnika aktywów we wcześniej ustalonym terminie w przyszłości po określonej cenie.
Struktura oraz cel zawierania transakcji	Dostosowane do potrzeb klienta. Zwykle nie wymaga wstępnej płatności. Zwykle używany do zabezpieczenia.	Standaryzowany. Wymagana jest wstępna płatność depozytu zabezpieczającego. Zwykle używany do spekulacji.
Metoda zawarcia transakcji	negocjowany	kwotowany na giełdzie
Rynek	nieregulowany	regulowany
Rozliczenie gwarantowane przez	strony kontraktów	izbę rozliczeniową
Ryzyko	wysokie	niskie
Dostarczenie	zazwyczaj dostarczenie towaru	zazwyczaj brak dostarczenia, rozliczenie różnicy kursowej
Termin wygaśnięcia	negocjowany i ustalany indywidualnie przez strony	standaryzowany
Wielkość kontraktu	w zależności od transakcji i wymagań kontrahentów	standaryzowana
Rynek	pierwotny	pierwotny i wtórny

Źródło: opracowanie własne na podstawie: Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India oraz Valdez, S., & Molyneux, P. (2015). *An introduction to global financial markets*. Macmillan International Higher Education

Na rysunku 4. oraz 5. zostaną przedstawione podstawowe profile wypłaty dla dwóch pozycji, jakie inwestor może zająć w kontraktach terminowych. Profil wypłaty obrazuje możliwe do osiągnięcia zyski (straty) dla zmieniającej się ceny instrumentu. Na rysunku 4. przedstawiono profil wypłaty przy zajęciu pozycji długiej w kontrakcie terminowym. Zajęcie pozycji długiej gwarantuje zyski w momencie, gdy cena instrumentu bazowego wzrośnie w stosunku do ceny wykonania. Większy wzrost ceny oznacza dla inwestora zajmującego pozycję długą większe zyski, które teoretycznie mogą być nieograniczone.

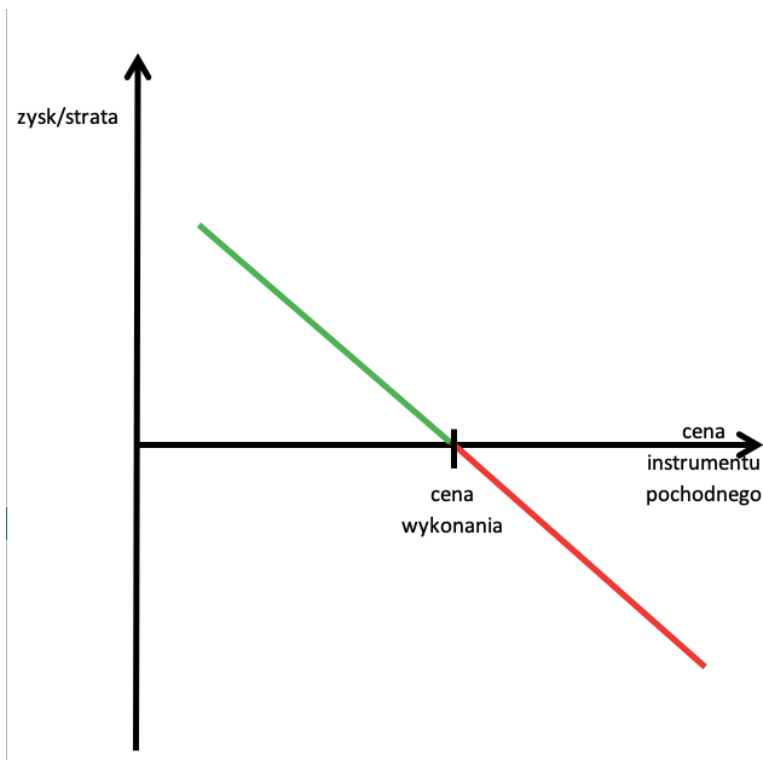


Rysunek 4. Profil wypłaty z pozycji długiej na kontrakcie terminowym

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Kolorem czerwonym zaznaczono przedział cenowy, w którym profil wypłaty osiąga stratę, natomiast zieloną zysk.

Rysunek 5. przedstawia profil wypłaty dla pozycji krótkiej zawartej w kontrakcie terminowym. W przypadku inwestowania w pozycję krótką inwestor oczekuje spadku ceny instrumentu bazowego. W przeciwieństwie do pozycji długiej, w tym przypadku maksymalna możliwa strata jest nieograniczona, natomiast maksymalny możliwy zysk ograniczony jest przez oś rzędnych (oznaczający cenę instrumentu bazowego równą 0).



Rysunek 5. Profil wypłaty z pozycji krótkiej na kontrakcie terminowym

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Kolorem czerwonym zaznaczono przedział cenowy, w którym profil wypłaty osiąga stratę, natomiast zieloną zysk

Reasumując, w terminie realizacji kontraktu, w przypadku kontraktów terminowych istnieją trzy możliwe scenariusze: gdy cena na rynku jest niższa, wyższa lub równa cenie danego instrumentu bazowego wynikającego z kontraktu. Posługując się rysunkiem 4. i 5. możemy stwierdzić, że pierwsza z sytuacji zaistnieje, gdy cena w momencie wykonania będzie niższa od ceny wykonania (cena przesunie się w lewo na osi X). Sytuacja ta jest korzystna dla posiadacza pozycji krótkiej w kontrakcie: w takim wypadku sprzeda on aktywa po cenie wyższej niż cena, jaką aktualnie mógłby uzyskać na rynku. W związku z tym sytuacja ta jest niekorzystna dla posiadacza pozycji przeciwnej – długiej – ponieważ inwestor jest zobowiązany do wykonania kontraktu, w którym aktualne ceny instrumentu bazowego na rynku są korzystniejsze, niż te wynikające z kontraktu.

Drugim możliwym scenariuszem jest przypadek, w którym cena aktywów bazowych będzie wyższa na rynku, niż ta zapisana w kontrakcie; w takim przypadku zysk osiągnie inwestor zajmujący pozycję długą – uzyskując zysk równy różnicy między wyższą ceną, jaką musiałby zapłacić na rynku, a niższą ceną wynikającą z kontraktu.

W trzecim przedstawionym przypadku rynkowa cena instrumentu bazowego jest taka sama, jak zapisana w kontrakcie. Nie dochodzi do przepływów pieniężnych między

posiadaczami kontraktu (instrumenty nierzeczywiste) oraz żadna ze stron nie zyskuje nic na kontrakcie.

2.3. Opcje

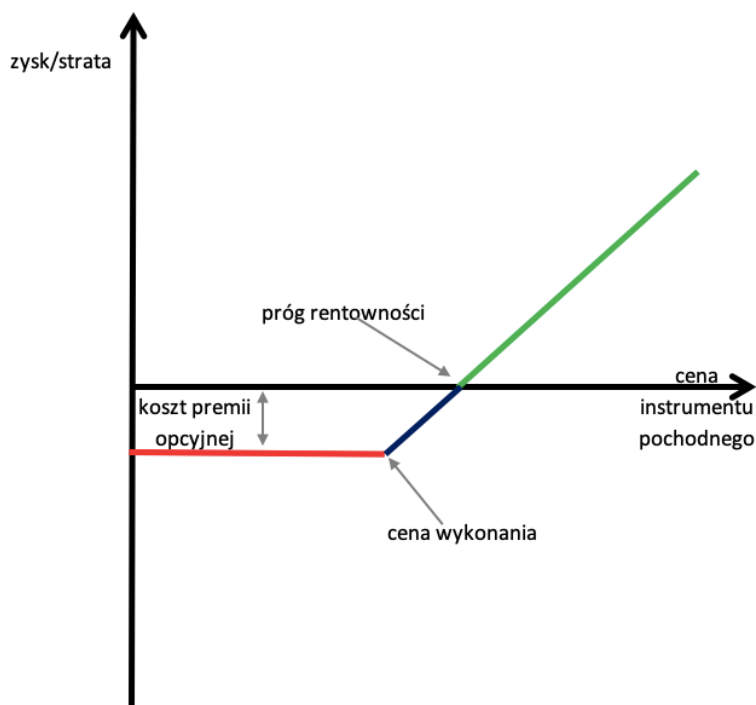
Posiadacz opcji posiada prawo do kupna lub sprzedaży określonego instrumentu bazowego po cenie oraz w terminie wskazanym w kontrakcie opcyjnym. Cena ta nazywana jest ceną wykonania a ostateczny termin na wykonanie opcji nazywany jest datą wygaśnięcia. Podstawowym kryterium podziału opcji jest podział na opcje kupna oraz sprzedaży.

Nabywca opcji kupna ma prawo kupić określone aktywa po określonej cenie i w określonym czasie, a wystawiający opcję ma obowiązek sprzedania instrumentu bazowego na zasadach ustalonych w kontrakcie opcyjnym. Nabywca opcji sprzedaży ma natomiast prawo sprzedaży określonych aktywów po określonej cenie i w określonym czasie. W przypadku, gdy nabywca opcji sprzedaży zdecyduje się na sprzedaż instrumentu pochodnego, druga strona kontraktu opcyjnego (wystawca) ma obowiązek kupienia go na wcześniej określonych zasadach (Hull, 2003).

Kolejną kluczową cechą opcji są dwa możliwe sposoby jej wykonania. Wyróżniamy tutaj opcję europejską oraz opcje amerykańską. Nabywca opcji europejskiej ma prawo wykonać opcję tylko w dniu jej wygaśnięcia. Opcja amerykańska charakteryzuje się możliwością wykonania jej przez posiadacza: od daty zawarcia kontraktu opcyjnego aż do upływu terminu wygaśnięcia (Tarczyński, 2003).

Z wyżej opisanej charakterystyki opcji wynikają podstawowe elementy, które powinny być określone przed zawarciem takiego kontraktu. Należą do nich: instrument bazowy (np. waluta, indeks giełdowy), styl wykonania opcji, wartość opcji, kurs wykonania, data wygaśnięcia oraz sposób rozliczenia opcji.

Dokładniejsza charakterystyka podstawowych typów opcji zostanie zaprezentowana poniżej, na podstawie profili wypłaty. Profile wypłat dla opcji kupna i sprzedaży w pozycji długiej oraz krótkiej zostały przedstawione na rysunkach 6-9. Profil wypłaty z pozycji długiej to profil wypłaty charakteryzujący wypłatę dla posiadacza opcji natomiast z pozycji krótkiej – dla wystawcy.

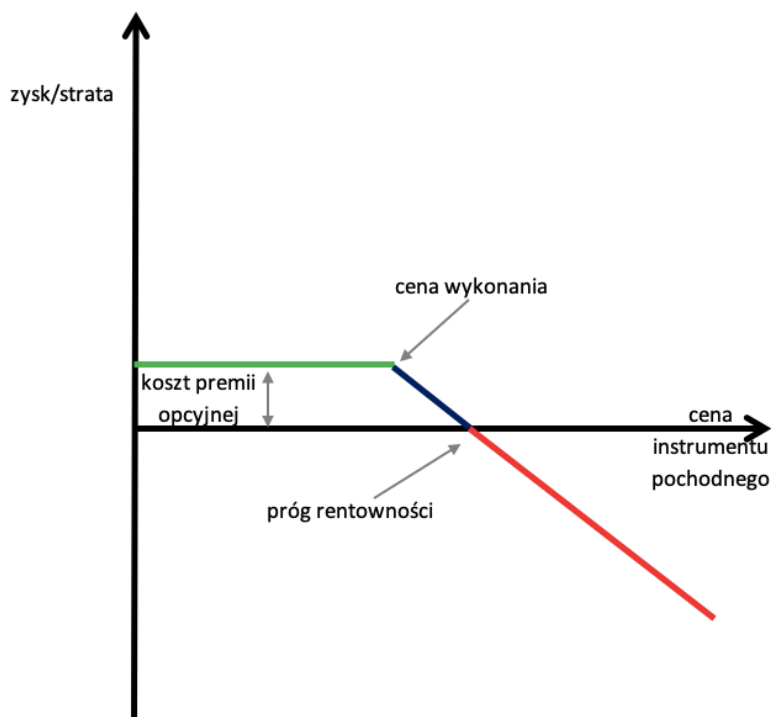


Rysunek 6. Profil wypłaty z pozycji długiej na opcji kupna

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, niebieskim, kiedy generowana jest strata, ale mniejszy niż suma kosztów premii opcyjnych (strata maksymalna), natomiast zieloną linią oznaczono maksymalny zysk, który rośnie wraz ze wzrostem ceny.

Nabywca opcji wykona ją wtedy, gdy na rynku znajdą korzystne dla niego warunki. Rozważając opcję kupna, nabywca wykona opcję, gdy cena instrumentu bazowego będzie wyższa niż cena zawarta w kontrakcie opcyjnym (cena wykonania). Należy jednak zauważyć, że wykonanie opcji przez nabywcę nie jest jednoznaczne z osiągnięciem przez niego zysku. Powodem tego jest fakt konieczności zapłacenia przez nabywcę premii opcyjnej. Na rysunku 6. sytuacja taka zaznaczona jest kolorem niebieskim. W tym wypadku nabywca również poniesie stratę, jednak będzie ona mniejsza niż maksymalna możliwa strata, jaką jest wysokość premii opcyjnej. Strata ta (kolor niebieski) przechodzi w zysk (kolor zielony) w punkcie, w którym poziom wzrostu ceny aktywów bazowych zrówna się z wysokością premii opcyjnej. Punkt ten nazywany jest progiem rentowności. Jak już wspomniano, maksymalna strata w pozycji długiej opcji kupna równa jest wysokości zapłaconej premii opcyjnej, natomiast maksymalny zysk jest teoretycznie nieograniczony.




Rysunek 7. Profil wypłaty z pozycji krótkiej na opcji kupna

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, niebieskim, kiedy generowana jest zysk, ale mniejszy niż suma kosztów premii opcyjnych (zysk maksymalny), natomiast zieloną linią oznaczono maksymalny zysk, który równy jest sumie kosztów premii opcyjnej.

Przeciwieństwem długiej pozycji w opcji kupna jest zajęcie pozycji krótkiej na opcji kupna. W związku z tym, w kontekście pozycji krótkiej mówimy o wystawcy opcji. Wystawca opcji osiągnie zysk w przypadku, gdy cena instrumentu bazowego spadnie, przy czym maksymalny zysk, jaki może osiągnąć, jest równy zapłaconej przez nabywcę premii opcyjnej. W przypadku, gdy nabywca opcji dobrze przewidzi kierunek zmiany ceny aktywów bazowych, wystawca opcji ponosi stratę (na rysunku 7. zaznaczamy ją kolorem czerwonym). Strata, jaką może ponieść wystawca opcji kupna, jest nieograniczona.




Rysunek 8. Profil wypłaty z pozycji długiej na opcji sprzedaży

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, niebieskim, kiedy generowana jest strata, ale mniejszy niż suma kosztów premii opcyjnych (strata maksymalny), natomiast zieloną linią oznaczono zysk, którego wartość rośnie wraz ze spadkiem ceny.

Nabywca (zajmujący pozycję długą) w opcji sprzedaży poprzez zakup tego typu instrumentu spodziewa się spadku ceny instrumentu bazowego w czasie. Natomiast wystawiający (zajmujący pozycję krótką) opcję sprzedaży oczekuje wzrostu ceny instrumentu bazowego. W związku z takimi oczekiwaniami stron kontraktu opcyjnego, nabywca opcji sprzedaży (Rysunek 8.) poniesie stratę równą premii opcyjnej, gdy cena instrumentu bazowego spadnie lub wzrośnie, ale o mniej niż wyniósł koszt premii opcyjnej. Zysk nabywca opcji sprzedaży uzyska, gdy cena instrumentu bazowego będzie spadać. Jego teoretyczny maksymalny zysk ograniczony jest osią pionową. W związku z tym, nabywca opcji sprzedaży osiągnie maksymalny zysk, gdy cena instrumentu bazowego osiągnie cenę równą 0.



Rysunek 9. Profil wypłaty z pozycji krótkiej na opcji sprzedaży

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.
 Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, niebieskim, kiedy generowana jest zysk, ale mniejszy niż suma kosztów premii opcyjnych (zysk maksymalny), natomiast zieloną linią oznaczono maksymalny zysk, który równy jest sumie kosztów premii opcyjnej.

Wystawca opcji sprzedaży, tak jak w przypadku wystawcy opcji kupna, może osiągnąć zysk maksymalnie równy zapłaconej premii opcyjnej przez nabywcę, a wysokość jego zysku nie jest zależna od wielkości wzrostu ceny instrumentu bazowego – rysunek 9. Można jednak zauważyć pewną różnicę, ponieważ maksymalna strata dla pozycji krótkiej na opcji sprzedaży jest ograniczona ceną równą 0 (jednak jest to przypadek bardzo teoretyczny). Dla pozycji krótkiej na opcji kupna, maksymalna strata jest nieograniczona (Sundaram, Das, 2016).

2.4. Opcje binarne

Opcje binarne są jednym z typów opcji posiadających charakterystyczny profil wypłaty. Charakteryzują się one stałą wypłatą dla nabywcy opcji w momencie jej wygaśnięcia. Stała wypłata oznacza, że nie ma znaczenia wielkość zmiany ceny instrumentu bazowego, lecz jej kierunek.

Opcje binarne mają charakter spekulacyjny i bardzo często porównywane są do prostego mechanizmu zakładu, ponieważ inwestor decydujący się na inwestycje w opcje binarne ma

tylko dwie możliwe wielkości wypłaty – z góry określony zysk lub z góry określoną stratę. Oznacza to, że wysokość zysku nie zależy od kształtowania się kursu instrumentu bazowego. Na przykład, w opcji kupna im cena instrumentu bazowego jest wyższa, tym wyższy jest zysk na opcji. W przypadku opcji binarnych możliwy zysk jest stały i zależy od wystąpienia danego zdarzenia, którego opcja binarna dotyczy (Kiiskinen, 2016, Kolkova, Lenartova, 2016).

Rynek handlu opcjami binarnymi wiąże się z pewnymi rodzajami kontrowersjami, które wynikają z możliwości nadużyć związanych z charakterystyką tego typu opcji. Europejski Urząd Nadzoru Giełd i Papierów Wartościowych zakazał na pewien czas handlu opcjami binarnymi uznając je za nielegalne, jednak zakaz ten miał charakter tymczasowy. Podobne decyzje podjęła w Polsce Komisja Nadzoru Finansowego, która najpierw zakazała tymczasowo obrotu opcjami binarnymi a następnie zakazała obrotu, dystrybucji lub sprzedaży opcji binarnych, ale tylko dla klientów detalicznych (Decyzja KNF, sygn. DAS.456.1.2019). Sytuacja ta wskazuje na możliwe nadużycia brokerów oferujących opcje binarne klientom indywidualnym, a wspomniane akty prawne mają na celu ochronę interesów inwestorów detalicznych. Jednocześnie coraz częściej w artykułach naukowych pojawiają się propozycje rozwiązań minimalizujących ryzyko związane z opcjami binarnymi i ograniczające zagrożenie wynikające z możliwości manipulowania cenami instrumentów bazowych (Tian, 2021). Działania te wskazują na to, że być może w niedalekiej przyszłości handel opcjami binarnymi zostanie uregulowany prawnie. Ze względu na specyfikę tego instrumentu, zdecydowałem się przeanalizować go w tej rozprawie jako zagadnienie czysto teoretyczne.


Wyróżnić można kilka typów opcji binarnych:

- *high/low* – w których profil wypłaty oparty zależy od tego, czy cena instrumentu podstawowego na rynku będzie w dniu wypłaty wyższa lub niższa niż w dniu zakupu opcji,
- *touch/not touch* – w których profil wypłaty zależy od tego, czy cena instrumentu bazowego osiągnie wskazany poziom w dniu wygaśnięcia,
- *boundary* – w których profil wypłaty zależy od utrzymania lub nieutrzymania ceny instrumentu bazowego w pewnym przedziale cenowym.

Opcje binarne przyjmują dwie formy *cash-or-nothing* oraz *asset-or-nothing*. Opcja binarna typu *cash-or-nothing* wypłaca użytkownikowi stałą kwotę lub nic. Opcja typu *asset-or-nothing* jest w zasadzie bardzo podobna, ale wypłata jest równa cenie instrumentu bazowego. Binarna opcja kupna wypłaca odpowiednią kwotę, jeśli w terminie zapadalności cena instrumentu

podstawowego jest wyższa od ceny wykonania i zero w przeciwnym razie. Opcja binarna sprzedaży wypłaca tę kwotę, jeśli cena instrumentu bazowego jest niższa od ceny wykonania i zero w przeciwnym przypadku.

Przykładowy profil wypłaty dla opcji binarnej typu *boundary* zaprezentowano na rysunku 10. Inwestor osiągnie zysk, gdy cena utrzyma się w przedziale między 1 a 1,1, gdy znajdują się, poza tym przedziałem odnotowuje stratę.



Rysunek 10. Profil wypłaty dla opcji binarnej o wypłacie, gdy cena instrumentu bazowego utrzyma się w przedziale między 1 a 1,1.

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, po osiągnięciu pewnego poziomu ceny strategia zaczyna przynosić z góry określony zysk co zaznaczono zieloną linią a od pewnego poziomu ponownie zaczyna generować stratę.

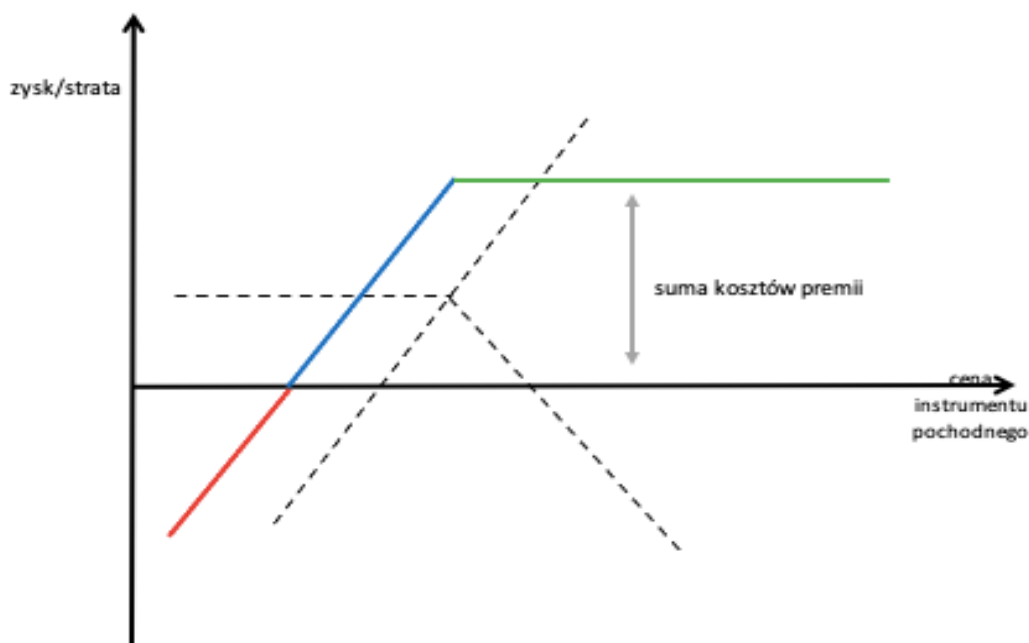
2.5. Strategie opcyjne

W oparciu o przedstawione w podrozdziale 2.3. podstawowe rodzaje opcji budowane są strategie opcyjne. Strategie opcyjne to kombinacja dwóch lub więcej pozycji w opcjach i (lub) kontraktach terminowych (przedstawionych w podrozdziale 2.2.).

W literaturze strategie opcyjne dzielone są na (Ziętek-Kwaśniewska, 2009):

- strategie bez pokrycia – cztery strategie, które zostały już przedstawione, tj. zajęcie długiej oraz krótkiej pozycji na opcji kupna i sprzedaży,
- strategie z pokryciem – cztery podstawowe strategie zabezpieczone (pokryte) dodatkowo przez fizyczny zakup instrumentu bazowego na rynku,
- strategie zaawansowane – w których można wyróżnić strategie rozpiętościowe oraz kombinowane.

Opcje z pokryciem, nazywane również opcjami osłoniętymi, buduje się poprzez nabycie lub wystawienie opcji w celu ochrony posiadanych już aktywów. Inwestor posiadający aktywa, chciałby je zabezpieczyć przed ewentualną niekorzystną dla niego możliwością wzrostu ich ceny, w związku z czym wystawia opcję kupna. Oznacza to, że zabezpiecza on długą pozycję w zakupionym instrumencie przez zajęcie krótkiej pozycji w opcji kupna. Profil wypłaty w powyżej opisanym przypadku jest bardzo zbliżony do wykresu charakterystycznego dla krótkiej opcji sprzedaży. Przedstawioną sytuację prezentuję na rysunku 11.




Rysunek 11. Opcja osłonięta typ I

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, niebieskim, kiedy generowana jest zysk, ale mniejszy niż suma kosztów premii opcyjnych (zysk maksymalny), natomiast zieloną linią oznaczono maksymalny zysk, który równy jest sumie kosztów premii opcyjnej. Przerywanymi liniami zaznaczono kształtowanie się profili wypłaty pojedynczych instrumentów składających się na daną strategię.

Stosując strategie opcyjne z pokryciem można również otrzymać wykres oraz profile wypłaty zbliżone do zajęcia długiej pozycji w opcji kupna. W tym celu należy zająć długą pozycję w opcji sprzedaży oraz kupić instrument będący instrumentem bazowym w opcji. Sytuacja taka została przedstawiona na rysunku 12.




Rysunek 12. Opcja osłonięta typ II

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, niebieskim, kiedy generowana jest strata, ale mniejszy niż suma kosztów premii opcyjnych (strata maksymalny), natomiast zieloną linią oznaczono zysk, którego wartość rośnie wraz ze wzrostem ceny. Przerywanymi liniami zaznaczono kształtowanie się profili wypłaty pojedynczych instrumentów składających się na daną strategię.

Możemy również wyobrazić sobie odwrotną sytuację, gdy dokonujemy krótkiego zakupu instrumentu bazowego, żeby zabezpieczyć się przed możliwością dużego spadku jego ceny. Należy wtedy również wystawić opcję, ale tym razem sprzedaży. Profil wypłaty z takiej strategii jest wtedy zbliżony do długiej opcji sprzedaży, jak przedstawiono na rysunku 13.




Rysunek 13. Opcja osłonięta typ III

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, niebieskim, kiedy generowana jest strata, ale mniejszy niż suma kosztów premii opcyjnych (strata maksymalny), natomiast zieloną linią oznaczono zysk, którego wartość rośnie wraz ze spadkiem ceny. Przerywanymi liniami zaznaczono kształtowanie się profili wypłaty pojedynczych instrumentów składających się na daną strategię.

W celu otrzymania profilu wypłaty zbliżonego do krótkiej opcji kupna, należy zająć krótką pozycję w instrumencie bazowym oraz wystawić opcję sprzedaży. Przy zajęciu samej pozycji krótkiej, inwestor narażony jest na straty, gdy cena instrumentu bazowego spadnie. Natomiast zastosowanie strategii z pokryciem poprzez krótką sprzedaż instrumentu bazowego zabezpiecza przed tymi negatywnymi skutkami (Jakubowski, Palczewski, Rutowski, Stettner, 2003).



Rysunek 14. Opcja osłonięta typ IV

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.


Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, niebieskim, kiedy generowana jest zysk, ale mniejszy niż suma kosztów premii opcyjnych (zysk maksymalny), natomiast zieloną linią oznaczono maksymalny zysk, który równy jest sumie kosztów premii opcyjnej. Przerywanymi liniami zaznaczono kształtowanie się profili wypłaty pojedynczych instrumentów składających się na daną strategię.

Zaawansowane strategie opcyjne można podzielić na rozpiętościowe oraz kombinowane. Strategie rozpiętościowe polegają na zakupie oraz wystawieniu opcji na ten sam instrument bazowy. Można wyróżnić następujące strategie rozpiętościowe (Majewska, 2006):

- poziomą, w której opcje mają tę samą cenę wykonania, ale różnią się terminem wykonania,
- pionową, w której termin wykonania jest taki sam, lecz ceny są różne,
- diagonalną, w której ceny i terminy są różne.

Najbardziej charakterystycznymi strategiami rozpiętościowymi są: strategia byka oraz niedźwiedzia. Strategie te zawdzięczają swoje nazwy potocznemu nazewnictwu stanów, jakie

mogą zaistnieć na rynku. Rynek niedźwiedzia to taka sytuacja na giełdzie, gdy wśród inwestorów dominują nastroje pesymistyczne, w związku z czym wyprzedają oni swoje akcje, czego konsekwencją są spadki cen aktywów. Rynek byka oznacza sytuację, w której nastroje inwestorów są pozytywne, dominuje tendencja do kupowania, co prowadzi do wzrostów cen aktywów. W nawiązaniu do przedstawionych definicji poszczególnych rynków - strategia byka jest strategią opcyjną zarabiającą w sytuacji wzrostu ceny instrumentu bazowego; strategia niedźwiedzia będzie zarabiać, gdy dochodzi do spadków cen. Strategia byka polega na zajęciu długiej oraz krótkiej pozycji w opcji kupna tego samego instrumentu bazowego. Najważniejsze dla zbudowania tej strategii jest, aby długa pozycja w opcji kupna miała niższą cenę wykonania od krótkiej pozycji w opcji kupna przy tych samych terminach wygaśnięcia. W praktyce, bardzo dużą zaletą tej strategii jest niższy koszt, jaki musi ponieść osoba budująca taką strategię, niż w przypadku, gdy zajmie długą pozycję jedynie w opcji kupna – spowodowane jest to otrzymaniem premii opcyjnej za krótką pozycję. Jednak w przeciwieństwie do długiej opcji kupna, w strategii byka maksymalny zysk jest ograniczony. W związku z tym stosowana jest głównie w przypadkach, w których inwestor oczekuje niewielkiego wahanía kursu instrumentu bazowego w górę. Profil wypłaty strategii byka zaprezentowano na rysunku 15.




Rysunek 15. Strategia Byka

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, po osiągnięciu pewnego poziomu ceny strategia zaczyna przynosić zysk co zaznaczono zieloną linią. Przerywanymi liniami zaznaczono kształtowanie się profili wypłaty pojedynczych instrumentów składających się na daną strategię.

Budując strategię niedźwiedzia należy zająć długą oraz krótką pozycję na opcjach sprzedaży. W tej strategii ceny wykonania obu opcji muszą być różne, przy czym cena wykonania pozycji długiej w opcji sprzedaży powinna być niższa niż cena wykonania pozycji krótkiej. Analogicznie do strategii byka, w strategii niedźwiedzia oczekuje się niewielkich wahań cen, jednak tym razem w dół, co zaprezentowano na rysunku 16.




Rysunek 16. Strategia Niedźwiedzia

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, po osiągnięciu pewnego poziomu ceny strategia zaczyna przynosić zysk, co zaznaczono zieloną linią. Przerywanymi liniami zaznaczono kształtowanie się profili wypłaty pojedynczych instrumentów składających się na daną strategię.

W dwóch poprzednich przypadkach strategia opcyjna była nastawiona na zarabianie w sytuacji ewentualnych wzrostów lub spadków. Przeciwnościem tych strategii jest strategia motyla. Motywacją do konstrukcji tej strategii jest przekonanie inwestora o utrzymaniu ceny instrumentu bazowego w pewnym określonym przedziale. W celu konstrukcji strategii motyla, należy zająć krótką pozycję w opcji kupna z ceną wykonania znajdującą się pomiędzy dwoma cenami wykonania pozycji długich, zajętych również na opcji kupna. Graficzne przedstawienie profilu wypłaty ze strategii motyla przedstawiono na rysunku 17.



Rysunek 17. Strategia Motyla

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, po osiągnięciu pewnego poziomu ceny strategia zaczyna przynosić zysk co zaznaczono zieloną linią. Przerywanymi liniami zaznaczono kształtowanie się profili wypłaty pojedynczych instrumentów składających się na daną strategię.

Strategie kombinowane polegają na zakupie lub sprzedaży różnych rodzajów opcji wystawionych na te same aktywa bazowe. W tym rozdziale zostaną zaprezentowane najpopularniejsze ze strategii kombinowanych takich jak (Suresh, 2015):


- strategię stelaża (*straddle*),
- rozszerzonego stelaża (*strangle*).

Obie te strategie można budować na dwa sposoby – przy użyciu opcji kupna lub opcji sprzedaży. Oznacza to, że krótka strategia rozszerzonego stelaża będzie zbudowana z krótkich opcji kupna i sprzedaży, a długa strategia rozszerzona stelaża złożona – z długich opcji kupna i sprzedaży. Tak samo można zbudować strategię stelaża.

Strategie, które zostaną zbudowane na krótkich pozycjach będą charakteryzować się ograniczonym zyskiem, gdy zostanie utrzymana cena instrumentu bazowego w okolicach cen wykonania obu opcji. Strategie długiego stelaża oraz długiego rozszerzonego stelaża będą przynosiły w takim przypadku stratę, natomiast zyski w sytuacji dużej zmienności cen

instrumentu bazowego. Krótkie strategie stelaża oraz rozszerzonego stelaża są strategiami podobnymi w zastosowaniu, co długa jak i krótka strategia motyla. W związku z ich konstrukcją są jednak bardziej ryzykowne, ponieważ mogą wygenerować znaczą stratę, kiedy na rynku dojdzie do dużego wzrostu lub spadku cen aktywów.


Opisane powyżej strategie i ich profile wypłaty znajdują się na rysunkach 18 i 19. Kolorem czerwonym zaznaczono potencjalne straty przy wahaniami kursów niekorzystnych dla budującego te strategie.



Rysunek 18. Strategia krótkiego stelaża

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Czerwoną linią oznacza zakres cen, przy którym generowana jest strata, po osiągnięciu pewnego poziomu ceny strategia zaczyna przynosić zysk co zaznaczono zieloną linią. Przerywanymi liniami zaznaczono kształtowanie się profili wypłaty pojedynczych instrumentów składających się na daną strategię.




Rysunek 19. Strategia krótkiego rozszerzonego stelaża

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.


Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, po osiągnięciu pewnego poziomu ceny strategia zaczyna przynosić zysk, co zaznaczono zieloną linią. Przerywanymi liniami zaznaczono kształtowanie się profili wypłaty pojedynczych instrumentów składających się na daną strategię.

Strategie oparte na długich pozycjach są stosowane, gdy inwestor liczy na duże wahania cen instrumentów bazowych. Strategia długiego stelaża (Rysunek 20) polega na zajęciu długiej pozycji w opcji kupna i sprzedaży, z założeniem, że cena wykonania obu opcji jest taka sama. Przy budowaniu strategii długiego rozszerzonego stelaża (Rysunek 21) należy również nabyć opcje kupna i sprzedaży; jednak w tej strategii cena wykonania długiej opcji kupna musi być wyższa niż cena wykonania opcji sprzedaży. Powoduje to sytuację, w której osoba budująca tę strategię posiada szerszy przedział strat, a co za tymi idzie, wahanie ceny instrumentu bazowego, by przynieść zysk, muszą być większe. Jednak w związku z ustaleniem ceny wykonania poniżej ceny aktualnej instrumentu bazowego (w momencie zawierania transakcji) koszt zawarcia takich pozycji jest niższy (Dziwago 2010).



Rysunek 20. Strategia długiego stelaża

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.
 Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, po osiągnięciu pewnego poziomu ceny strategia zaczyna przynosić zysk co zaznaczono zieloną linią. Przerwanymi liniami zaznaczono kształtowanie się profili wypłaty pojedynczych instrumentów składających się na daną strategię.



Rysunek 21. Strategia długiego rozszerzonego stelaża

Źródło: opracowanie własne na podstawie Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.

Opis: Czerwoną linią oznaczono zakres cen, przy którym generowana jest strata, po osiągnięciu pewnego poziomu ceny strategia zaczyna przynosić zysk co zaznaczono zieloną linią. Przerwanymi liniami zaznaczono kształtowanie się profili wypłaty pojedynczych instrumentów składających się na daną strategię.

3. Wycena opcji

W wycenie opcji duże znaczenie odgrywa stosunek ceny instrumentu bazowego w momencie wygaśnięcia opcji, a ceną jej wykonania. Można rozróżnić trzy możliwe warianty dla opcji kupna:

- *in-the-money* - wartość instrumentu bazowego jest wyższa niż cena wykonania,
- *out-of-the-money* - gdy wartość instrumentu bazowego jest niższa niż cena wykonania,
- *at-the-money* - gdy obie ceny są równe.

W przypadku opcji sprzedaży, opcje *in-the-money* oraz *out-of-the-money* interpretuje się odwrotnie.

W cenie opcji, czyli premii opcyjnej, można rozróżnić dwie wartości: czasową oraz wewnętrzną. Wartość wewnętrzna opcji jest dodatnia tylko w przypadku opcji *in-the-money*. Wartość czasowa jest związana z czasem, jaki pozostał do wygaśnięcia opcji. Wyłączając europejską opcję sprzedaży, która może mieć ujemną wartość czasową dla opcji *in-the-money* w przypadku niskiej ceny instrumentu bazowego, można zauważyć następujące własności:

- w każdym momencie przed wygaśnięciem:
 - opcja *in-the-money* posiada zarówno wartość czasową, jak i wewnętrzną,
 - opcje *out-of-the-money* oraz *at-the-money* ma tylko wartość czasową;
- w dniu wygaśnięcia:
 - opcja *in-the-money* ma tylko wartość wewnętrzną,
 - opcje *out-of-the-money* oraz *at-the-money* nie posiadają ani jednej, ani drugiej wartości.

Czynniki wpływające na wartość opcji przedstawiono w tabeli 2. Przedstawiono również wpływ poszczególnych czynników na dany typ opcji. „+” oznacza ruch w tym samym kierunku np. cena wykonania rośnie to wartość opcji kupna spada a opcji sprzedaży rośnie.

Tabela 2. Czynniki kształtujące wartość opcji

	Opcja kupna	Opcja sprzedaży
Cena wykonania	-	+
Cena instrumentu bazowego	+	-
Czas do wygaśnięcia	+	+
Zmienność ceny aktywa bazowego	+	+
Stopa procentowa	+	-
Stopa dywidendy	-	+

Źródło: M., Bartkowiak, K., *Echaust Instrumenty pochodne. Wprowadzenie do inżynierii finansowej* s.125

Wycena opcji jest jednym z głównym problemów, jakimi zajmują się ekonometria i matematyka finansowa. Najpopularniejszym modelem używanym do wyceny jest model Blacka-Scholesa (Black i Scholes, 1972) który został sporządzony z myślą o opcjach na akcje, lecz można go stosować również w przypadku innych instrumentów bazowych. Model dla opcji kupna oraz sprzedaży można przedstawić następującymi wzorami:

$$c = c(S, X, T, r, \sigma) = S \cdot N(d_1) - X \cdot e^{-rT} N(d_2) \quad (1)$$

$$p = p(S, X, T, r, \sigma) = -S \cdot N(-d_1) + X \cdot e^{-rT} N(d_2) \quad (2)$$

dla:

$$d_1 = \frac{\ln\left(\frac{S}{X}\right) + \left(r + \frac{\sigma^2}{2}\right)T}{\sigma\sqrt{T}} \quad (3)$$

$$d_2 = \frac{\ln\left(\frac{S}{X}\right) + \left(r - \frac{\sigma^2}{2}\right)T}{\sigma\sqrt{T}} = d_1 - \sigma\sqrt{T} \quad (4)$$

gdzie:

c – cena opcji kupna,
 p – cena opcji sprzedaży,
 S – cena początkowa,
 $N(\cdot)$ – dystrybuanta standaryzowanego rozkładu normalnego,
 X – cena wykonania,
 r – stopa procentowa wolna od ryzyka,
 T – czas pozostały do wygaśnięcia opcji,
 σ – zmienność ceny opcji.

W modelu przyjmuje się następujące założenia (Bartkowiak i Echaust, 2014):

- brak dywidend,
- nieskończoną podzielność akcji,
- stałość w czasie parametrów r oraz σ ,
- zupełność rynku kapitałowego
- to, że cena akcji w nieskończenie krótkim czasie dt opisywana jest przez geometryczny ruch Browna.

Podsumowując, z przedstawionej powyżej charakterystyki kontraktów oraz opcji wynika, że do inwestycji w te instrumenty inwestor potrzebuje poprawnie przewidzieć kierunek zmiany kursu. Z mnogości czynników wpływających na wahania kursu walutowego (obok popytu i podaży: zmiany polityczne, społeczne i gospodarcze w państwach posługujących się daną walutą) wynikają trudności z jego prognozowaniem za pomocą prostych modeli ekonometrycznych. Trafne zaprognozowanie dokładnej wartości kursu walutowego jest zadaniem prawie niewykonalnym. Stąd, w zaproponowanej przeze mnie metodzie, przewiduję jedynie kierunek zmiany kursu walutowego, co – jak pokazuję w badaniu empirycznym – również jest zadaniem nietrywialnym. Kolejny rozdział poświęcam przeglądowi wybranych metod prognostycznych.

Rozdział II. Prognozowanie za pomocą modeli klasycznych oraz sieci neuronowych

Rozdział ten poświęcony jest metodom prognostycznym, które zostały wykorzystane w badaniu empirycznym. W pierwszej jego części przedstawiono klasyczne modele statystyczne stanowiące punkt odniesienia (*benchmark*) dla wyników uzyskanych za pomocą uczenia maszynowego. Do modeli klasycznych zaliczono prognozowanie naiwne oraz model ARMA. Następnie opisuję ideę działania sieci neuronowych, ze szczególnym uwzględnieniem tych, które wykorzystałem w badaniu empirycznym. Są to: perceptron wielowarstwowy (MLP – ang. *Multilayer perceptron*), maszyny uczenia ekstremalnego (ELM – ang. *Extreme Learning Machine*) oraz sieci o długiej pamięci krótkotrwałej (LSTM - ang. *Long short-term memory*).

1. Klasyczne modele statystyczne

W modelowaniu ekonometrycznym przyjmujemy, że analizowane szeregi czasowe są realizacjami pewnych procesów stochastycznych. Stosując tę konwencję, w pracy przyjmuję następującą notację, realizacja procesu stochastycznego $(X_t)_{t \in T}$, gdy $T \subseteq \{1, 2, \dots\}$, która jest ciągiem (x_t) obserwacji x_1, x_2, \dots będzie nazywana szeregiem czasowym i oznaczana (x_t) (Doman, M., i Doman, R., 2009).

1.1 Prognozowanie naiwne

Prognozowanie naiwne należy uznać za najprostszy model prognostyczny. Jego działanie polega na przyjęciu, że prognoza na moment t równa jest wartości z okresu poprzedniego ($t - 1$). Model ten zazwyczaj stanowi punkt odniesienia dla bardziej zaawansowanych modeli statystycznych. Można go przestawić w następujący sposób:

$$y_t^* = y_{t-1} \tag{5}$$

gdzie:

y_t^* – prognoza zmiennej y na moment t ,

y_{t-1} – wartość prognozowanej zmiennej y zaobserwowana w momencie $t - 1$.

1.2 Model ARMA

W ekonometrii finansowej do opisu i prognozowania zmian cen na rynkach najczęściej stosuje się modele liniowe z grupy ARMA. Na model ARMA (p, q) (*Autoregressive Moving Average Model*) składają się dwa komponenty:

- AR (ang. *Autoregressive*) – proces autoregresyjny,
- MA (ang. *Moving Average*) – proces średniej ruchomej.

W celu zaprezentowania działania modelu ARMA, poniżej omawiam podstawowe pojęcia z nim związane. Podczas opisu modelu ARMA wraz z jego poszczególnymi składowymi i ich charakterystykami skorzystano z pozycji (Tsay, 2016) oraz (Enders, 2010).

1.2.1 Proces AR

Ideą modelu autoregresyjnego jest założenie, że przeszłość prognozuje przyszłość, co odpowiada założeniu, że istnieje liniowa zależność między zwrotem r_{t-1} oraz r_t . Autoregresja oznacza zatem regresję z wykorzystaniem wcześniejszych wartości danego szeregu, w celu prognozowania jego wartości przyszłych (Nielsen, 2020). Najprostszy model AR, model AR(1), można przedstawić za pomocą równania:

$$r_t = a_0 + a_1 r_{t-1} + \varepsilon_t, \quad (6)$$

gdzie ε_t jest ścisłym białym szumem o zerowej średniej i stałej wariancji σ_ε^2 . Model ten charakteryzuje się następującymi zależnościami:

$$E(r_t | r_{t-1}) = a_0 + a_1 r_{t-1}, \quad (7)$$

$$\text{var}(r_t | r_{t-1}) = \text{var}(\varepsilon_t) = \sigma_\varepsilon^2, \quad (8)$$

Warunkowa wartość oczekiwana r_t , gdy znamy r_{t-1} , wynosi $a_0 + a_1 r_{t-1}$ oraz warunkowa wariancja zmiennej r_t , pod warunkiem, że znamy r_{t-1} , jest równa wariancji ścisłego białego szumu ε_t . Zależności te wynikają z faktu, że warunkowa wartość oczekiwana zmiennej ε_t jest

równa jej bezwarunkowej wartości oczekiwanej – wynosi 0 – czyli informacja o procesie r_t nie ma wpływu na oczekiwania dotyczące ε_t (Doman, M. i Doman, R., 2009).

Uogólniony model AR można przedstawić za pomocą następującego wzoru:

$$r_t = a_0 + a_1 r_{t-1} + \dots + a_p r_{t-p} + \varepsilon_t. \quad (9)$$

W celu ustalenia liczby opóźnień w modelu AR, korzysta się najczęściej z kryteriów informacyjnych. Za najpopularniejsze kryterium informacyjne należy uznać kryterium Akaikego (ang. AIC – *Akaike Information Criterion*).

$$AIC = -2 \frac{\ln L(\hat{\theta})}{T} + 2 \frac{k}{T} \quad (10)$$

gdzie:

- k - liczba parametrów modelu,
- $L(\hat{\theta})$ - wartość funkcji wiarygodności dla obserwacji $\{r_1, \dots, r_T\}$, wyliczona dla oszacowanego wektora parametrów $\hat{\theta}$, który ją maksymalizuje.

Proces wyboru parametrów polega na wyznaczeniu ich wartości dla modeli $AR(l)$, gdzie $l = 0, 1, \dots, p$, a następnie wybraniu takiego l , dla którego kryterium informacyjne AIC przyjmuje najmniejszą wartość.

Innym często stosowanym kryterium jest Bayesowskie kryterium informacyjne Schwarza (BIC). W kryterium tym k i T są definiowane jak w AIC a $L(\theta)$ to funkcja wiarygodności dla oszacowanego wektora parametrów:

$$BIC = k \ln(T) - 2 \ln L(\theta). \quad (11)$$

Kryterium BIC w odróżnieniu od kryterium AIC preferuje modele o oszczędnej parametryzacji (Schwarz, 1978).

1.2.2. Proces MA

W modelu średniej ruchomej (MA) zakłada się, że realizacja procesu w pewnym momencie czasu t jest zależna od funkcji ostatnich niezależnych od siebie wartości składników błędu.

Model MA(1) można przedstawić jako:

$$r_t = c_0 + \varepsilon_t - b_1 \varepsilon_{t-1}. \quad (12)$$

Ogólną postać modelu średniej ruchomej MA(q) można zatem przedstawić następująco:

$$r_t = c_0 + \varepsilon_t - b_1 \varepsilon_{t-1} - \dots - b_q \varepsilon_{t-q}, \quad (13)$$

gdzie c_0 jest stałą, a ε_t jest ścisłym białym szumem z zerową średnią.

Procesy opisywane przez MA są kowariancyjnie stacjonarne, ponieważ są one skończonymi kombinacjami liniowymi zmiennych tworzących ścisły biały szum. Dla ogólnej postaci modelu zachodzą następujące zależności:

$$E(r_t) = c_0, \quad (14)$$

$$\text{var}(r_t) = (1 + b_1^2 + b_2^2 + \dots + b_q^2) \sigma_\varepsilon^2. \quad (15)$$

1.2.3. Proces ARMA

Procesem łączącym własności obu procesów: AR(p) i MA (q) jest proces ARMA (p, q). Połączenie tych modeli pozwala na opisanie długotrwałych zależności z wykorzystaniem mniejszej liczby parametrów. Najprostszy z modeli ARMA - model ARMA(1,1) - można przedstawić w postaci wzorów:

$$r_t - a_1 r_{t-1} = a_0 + \varepsilon_t - b_1 \varepsilon_{t-1}, \quad (16)$$

gdzie $a_1 \neq b_1$, a ε_t jest ścisłym białym szumem z zerową średnią.

Jeśli szereg r_t jest kowariancyjnie stacjonarny, to:

$$E(r_t) = \mu = \frac{a_0}{1 - a_1}, \quad (17)$$

$$\text{var}(r_t) = \gamma_0 = \frac{(1 - 2a_1b_1 + b_1^2)\sigma_\varepsilon^2}{1 - a_1^2}. \quad (18)$$

Zatem warunkiem słabej stacjonarności jest $-1 < a_1 < 1$.

Ogólna postać modelu jest następująca:

$$r_t = a_0 + \sum_{i=1}^p a_i r_{t-i} + \varepsilon_t - \sum_{i=1}^q b_i \varepsilon_{t-i}, \quad (19)$$

gdzie ε_t jest ścisłym białym szumem z zerową średnią, p i q są nieujemnymi liczbami całkowitymi.

Estymacja parametrów wybranego modelu ARMA(p, q) może odbywać się za pomocą metody największej wiarygodności oraz warunkowej metody największej wiarygodności. Jakość dopasowania modelu może być sprawdzana za pomocą testów przeprowadzanych na resztach z modelu – Boxa-Pierce’a lub Ljung-Boxa. Dobrze dobrany model powinien wyjaśniać wszystkie zależności liniowe w danych.

2. Sieci neuronowe

Oprócz modeli ekonometrycznych, do prognozowania zmian cen na rynkach finansowych coraz częściej wykorzystuje się sieci neuronowe. W kolejnym podrozdziale prezentuję działanie oraz charakterystykę sieci neuronowych.

2.1. Idea sieci neuronowych

Sieci neuronowe wzorowane są na działaniu ludzkiego mózgu oraz układu nerwowego. Zadanie sieci neuronowych jest zbliżone do zadań, jakie w ludzkim organizmie pełni układ nerwowy. Układ nerwowy składa się z nerwów oraz komórek zwanych neuronami, które odpowiedzialne są za przekazywanie informacji między różnymi częściami ciała. Przekazywanie to odbywa się za pomocą neuroprzekaźników, czyli substancji chemicznych uwalnianych przez aksony. Pierwszą fazą w procesie reakcji na bodźce jest zebranie informacji zarówno endogenicznych, jak i egzogenicznych. Informacje te są przewodzone przez układ nerwowy (sygnały „podróżują” wzdłuż neuronu ruchowego z prędkością nawet do 431 km/h) a następnie, na podstawie zmian w wykrytych informacjach, wypracowywane są odpowiednie reakcje na dany bodziec.

Budowa sztucznej sieci neuronowej jest wzorowana na jej biologicznym odpowiedniku. Sieci neuronowe budowane są z warstw neuronów. Neurony pierwszej warstwy tworzą tak zwaną *warstwę wejściową*. Dociera do nich pewna liczba *sygnałów wejściowych*. Przykładem takiego sygnału mogą być dane przekazywane sieci do obliczeń, na przykład wartość kursu walutowego w danym dniu. Każda wartość wprowadzana jest do neuronu przez połączenie o pewnej *wadze*. Dodatkowo, każdemu neuronowi przypisana jest tak zwana *wartość progowa*. Określa ona, jak silne musi być jego pobudzenie, aby został aktywowany. *Pobudzenie neuronu* obliczane jest jako różnica między sumą wartości sygnałów wejściowych przemnożonych przez odpowiednie wagi, a wartością progową. Następnie sygnał reprezentujący pobudzenie neuronu przekształcany jest przez *funkcję aktywacji*. Wartość obliczona przez funkcję aktywacji nazywana jest *wartością wyjściową* lub sygnałem wyjściowym (Tadeusiewicz, Szaleniec, 2015).

Pomiędzy warstwą wejściową a wyjściową często stosowane są warstwy pośrednie, nazywane *warstwami ukrytymi*. W przypadku sieci jednokierunkowych przepływ sygnału odbywa się tylko w kierunku od wejścia do wyjścia, czyli od warstwy zawierającej dane do warstwy podającej rozwiązanie. Odmiernym przykładem sieci neuronowej są sieci

rekurencyjne, w których neurony mogą być połączone dwukierunkowo lub w których występuje sprzężenie zwrotne (Witkowska, 2002).

2.2 Uczenie sieci neuronowych

Uczenie sieci może zachodzić na wiele różnych sposobów, z wykorzystaniem tak zwanych reguł uczenia. Podczas tego procesu dochodzi do zmiany wag występujących przy neuronach na skutek adaptacji. Uogólniając, można powiedzieć, że wektory wag zmieniają się proporcjonalnie do sygnałów, które wchodzi do danego neuronu oraz sygnałów wynikających z procesu uczenia się. Trzecim czynnikiem determinującym opisywany proces może być sygnał generowany przez nauczyciela (przy tak zwanym uczeniu nadzorowanym).

Metody uczenia sieci neuronowych można podzielić na metody uczenia *nadzorowanego* i *bez nadzoru*. Podstawowa różnica między tymi dwoma grupami polega na tym, że w tej pierwszej (zwanej też metodą uczenia z nauczycielem) sieci porównują sygnały wyjściowe z sieci ze znanymi odpowiedziami. W oparciu o błędy popełniane przez sieć tworzona jest pewna funkcja błędu, którą należy zminimalizować. W uczeniu nienadzorowanym sieć samodzielnie dostosowuje się do analizy danych, które pojawiają się na jej wejściu. Sieć samoucząca automatycznie dobiera swoje parametry tak, aby wykryć zależności w danych uczących, które to dane następnie porządkuje i klasyfikuje (Rusiecki, 2007, Tadeusiewicz, 1993).

W uczeniu nienadzorowanym można wyróżnić *uczenie bez nauczyciela* oraz *uczenie konkurencyjne*. Uczenie sieci *bez nauczyciela* wynika z możliwości uczenia się sieci poprzez zmiany wag przypisywanych do neuronów. Reguła ta jest znana jako reguła Hebb'a i oparta została na jego obserwacjach (Hebb, 1949) o wzmacnianiu połączenia między dwoma neuronami w przypadku, gdy oba są aktywne w tym samym czasie, a w przeciwnym przypadku osłabieniu tego połączenia. Wzmocnieniu podlegają też drogi przekazywania sygnałów, które tworzą połączenia między ośrodkami ulegającymi równoczesnemu pobudzeniu lub hamowaniu. Za wadę tej reguły uważa się możliwy nieograniczony wzrost wartości wag (Qin, Duan, 2020).

W *uczeniu konkurencyjnym*, w którym nie występuje nauczyciel, a neurony „rywalizują” ze sobą, należy wyróżnić m.in. metodę *wygrywający bierze wszystko* (ang. *winner takes all* – WTA) oraz *wygrywający bierze najwięcej* (ang. *winner takes most* – WTM). W metodzie WTA tylko jeden z neuronów pozostaje aktywny i przyjmuje stan 1, przez co ma

możliwość modyfikacji wag dochodzących do niego. Neurony, które „przegrają”, przyjmują wartość 0, co uniemożliwia modyfikację wag neuronów do nich dochodzących. Neuron „zwycięzca” modyfikuje swoje wagi według reguły Kohonena (Kohonen, 1990). Regułę WTM można uznać za modyfikację metody WTA. W WTA tylko neuron wygrywający miał możliwość modyfikacji wag, w WTM możliwość tą otrzymują również neurony bezpośrednio sąsiadujące z neuronem wygranym.

W badaniu empirycznym będącym częścią tej rozprawy doktorskiej korzystam z danych historycznych do uczenia sieci w celu prognozowania kierunku ich zmian. Sieci uczą się na danych historycznych, a po dokonaniu prognozy porównują swoją prognozę z realną historyczną wartością i otrzymują w ten sposób informację o trafności lub wielkości błędu jaki popełniają. W związku z tym, wszystkie trzy stosowane przeze mnie sieci będą uczyć się w sposób nadzorowany (z *nauczycielem*).

Jedną z najprostszych metod uczenia z nauczycielem, jest reguła uczenia perceptronu, która opiera swój sygnał uczący na różnicy między wartością oczekiwaną a rzeczywiście zarejestrowaną. Dla każdego wektora wejściowego $x(k)$ można zdefiniować następującą funkcję błędu $e(k)$:

$$e(k) = d(k) - y(k), \tag{20}$$

gdzie:

- $y(k)$ - odpowiedź na wektor wejściowy,
- $x(k), d(k)$ - wartość oczekiwana wyjścia neuronu przy założonym wektorze wejścia k .

Celem tej metody jest minimalizacja funkcji błędu poprzez odpowiednią modyfikację wag przy poszczególnych neuronach. Zasady modyfikacji wag są intuicyjne. Gdy funkcja błędu jest mniejsza od zera, co oznacza, że wartość oczekiwana wyjścia neuronu przy założonym wektorze wejścia jest mniejsza od odpowiedzi na wektor wejściowy ($d(k) < y(k)$), następuje zwiększenie wagi. Natomiast w sytuacji odwrotnej, dla błędu większego od zera, następuje zmniejszenie wagi. Uogólnieniem metody perceptronowej, w której dobór wag neuronów może być dyskretny lub ciągły, jest metoda Widrowa-Hoffa. Metoda Widrowa-Hoffa przy wartościach binarnych przechodzi w regułę uczenia perceptronu (Widrow, 1960). Inną regułą uczenia bazującą na regule perceptronu jest reguła delta, stosowana dla ciągłej funkcji aktywacji, w której dochodzi do aktualizacji wag po każdej prezentacji pary uczącej. W tej regule minimalizowane jest kwadratowe kryterium błędu.

W sieciach wielowarstwowych powszechnie stosowana jest propagacja wsteczna błędów. W tej metodzie błąd z ostatniej warstwy jest cofany do warstw wcześniejszych w celu modyfikacji wag w tych warstwach, co ostatecznie ma doprowadzić do minimalizowania tego błędów (Osowski, 1996).

2.3 Uczenie zespołowe

W literaturze popularność zyskuje uczenie zespołowe (*ensemble learning*), które jest techniką uczenia maszynowego wykorzystującą kilka podstawowych modeli i tworzącą z nich optymalny model predykcyjny. Uczenie zespołowe nie jest nowym typem uczenia, ale paradygmatem łączącym wiele modeli w jeden. Istnieją dwa podstawowe typy uczenia zespołowego (Zhou, Wu, Tang, 2002):

- *Bagging* – każdy z modeli uczy się niezależnie od siebie. Wybór ostatecznej decyzji przez uczenie zespołowe tego typu odbywa się najczęściej przez uśrednienie wyników albo głosowanie większościowe.
- *Boosting* – każdy z kolejnych modeli uczy się sekwencyjnie. Kolejny model (sieć) bierze pod uwagę wyniki, jakie otrzymał model poprzedni i dzięki temu może uczyć się na jego błędach. W uczeniu tym decyzja podejmowana jest na podstawie średniej ważonej – każdemu kolejnemu etapowi przyporządkowane są wagi ze względu na wyniki jakie osiągnął.

Poza dwoma podstawowymi, wyróżnia się również takie metody jak *stacking* lub *blending*. W niniejszej rozprawie doktorskiej w metodzie neuronowo-rozmytej inspirowanej metodą uczenia zespołowego w celu wygenerowania optymalnej prognozy z wykorzystaniem wielu prognoz pojedynczych sieci neuronowych.

2.4. Klasyfikacja sieci neuronowych

W literaturze można spotkać się z wieloma klasyfikacjami sieci neuronowych. W niniejszej rozprawie doktorskiej na podstawie przeglądu literatury stworzyłem klasyfikację zawierającą najczęściej wykorzystywane sieci neuronowe.

(Jain, Mao, Mohiuddin, 1996) uwzględniają w swoim artykule najbardziej powszechny podział sieci neuronowych na sieci jednokierunkowe oraz rekurencyjne. Różnica między sieciami jednokierunkowymi, a rekurencyjnymi wynika z różnic w warstwach ukrytych – w sieciach jednokierunkowych przetwarzanie danych wejściowych odbywa się tylko w jednym

kierunku (z warstwy wejściowej przez warstwę ukrytą do warstwy wyjściowej), natomiast w sieciach rekurencyjnych występuje połączenie wewnątrz warstwy ukrytej umożliwiające powrót sygnału z warstwy wyjściowej do warstwy wejściowej. Przytoczona klasyfikacja sieci neuronowych pochodzi z roku 1996, w związku z czym zawiera podstawowy podział, który nie uwzględnia najnowszych sieci neuronowych (np. konwolucyjnych).

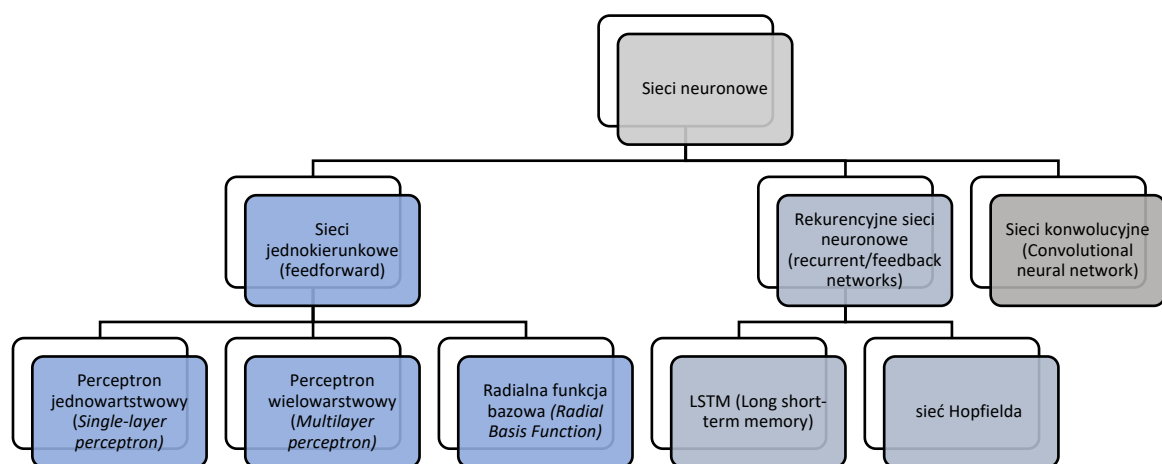
W celu wskazania najistotniejszych różnic między sieciami neuronowymi dokonałem rozszerzenia klasyfikacji na bardziej szczegółową. Przy szerszym podziale wśród sieci jednokierunkowych należy wyróżnić sieci:

- perceptron jednowarstwowy,
- perceptron wielowarstwowy,
- sieci neuronowe o radialnej funkcji bazowej,

Do sieci rekurencyjnych zaliczane są takie typy sieci jak:

- LSTM
- Sieci Hopfielda

Trzecim typem sieci uwzględniony na schemacie zostały sieci konwolucyjne.




Rysunek 22. Klasyfikacja sieci neuronowych

Źródło: opracowanie własne na podstawie różnych prac: (Egmont-Petersen, de Ridder, Handels, 2002, Liu i inni, 2021, Andina, Pham, 2007, Leijnen, Veen, 2020)

W celu przedstawienia różnic między poszczególnymi typami sieci neuronowych posłużę się podziałem zawierającym 6 głównych typów sieci neuronowych, charakteryzując niektóre z nich za pomocą schematów wizualizujących działanie danego typu sieci neuronowej.


Perceptron jednowarstwowy jest jednym z najstarszych i najprostszych modeli neuronów. Stanowi najmniejszą jednostkę sieci neuronowej i składa się z jednego lub wielu neuronów McCullocha-Pittsa (podstawowy model neuronu z wieloma wejściami, ale tylko jednym wyjściem). Każde wejście posiada wagę wejściową, będącą liczbą rzeczywistą, a wartość na wyjściu obliczana jest jako suma iloczynu wag wejściowych z wartościami wejściowymi. Przykład działania sieci jednowarstwowej przedstawiono na rysunku 23.



Rysunek 23. Perceptron jednowarstwowy

Opis: x_n oznacza n -tą warstwę wejściową, w_n to n -ta warstwa ukryta, natomiast y_n symbolizuje warstwę wyjściową

Perceptron wielowarstwowy jest pierwszą z bardziej złożonych sieci neuronowych. Dane wejściowe podążają do warstwy wyjściowej przez wiele warstw ukrytych. Cechą charakterystyczną dla MLP jest połączenie między każdym pojedynczym węzłem w pierwszej warstwie ze wszystkimi neuronami w drugiej warstwie – na rysunku 24. przedstawiono przykład sieci dwuwarstwowej. Schemat działania sieci MLP zostanie opisany szczegółowo w podrozdziale 2.5.1.




Rysunek 24. Sieć neuronowa jednokierunkowa dwuwarstwowa

Opis: x_n oznacza n -tą warstwę wejściową, w_n to n -ta warstwa ukryta, natomiast y_n symbolizuje warstwę wyjściową

Sieci neuronowe o radialnej funkcji bazowej (RBF) zbudowane są z warstwy wejściowej, warstwy z radialną funkcją bazową oraz warstwy wyjściowej. Radialna funkcja bazowa jest funkcją rzeczywistą, której wartość uzależniona jest od odległości dzielącej obecny wektor wejściowy od wektora ustalonego w procesie uczenia się. W sieciach RBF tą odległością jest podobieństwo otrzymanej przez sieć informacji do informacji wygenerowanej w procesie uczenia się (Szymonik, 2013). Działanie sieci neuronowej typu RBF zaczyna się od wprowadzenia danych przez warstwę wejściową, następnie każdy z neuronów RBF oblicza różnicę euklidesową między wprowadzonymi danymi a danymi z procesu uczenia się jakie zostały zapisane w sieci. Neuron RBF zwraca wartość od 0 do 1, która odpowiada podobieństwu wprowadzonych danych do prototypu danego neuronu. Schemat sieci RBF nie różni się znacznie od schematu dla sieci wielowarstwowej, podstawowa różnica wynika z zastosowanej funkcji bazowej w warstwach ukrytych.

W sieciach jednokierunkowych sygnał zawsze przebiega w jedną stronę, od warstwy wejściowej w kierunku warstwy wyjściowej. W **sieciach rekurencyjnych** sygnał przebiega od warstwy wejściowej w kierunku warstwy (lub warstw) ukrytych i tworzy układ zamknięty generujący ostateczną decyzję, która zostaje przesłana do warstwy wyjściowej. Połączenia między neuronami tworzą obieg zamknięty. Podstawowym modelem sieci rekurencyjnej jest sieć Hopfielda (Rysunek 25). Na rysunku widać rekurencję w warstwach wewnętrznych sieci Hopfielda.



Rysunek 25. Sieć Hopfielda

Opis: x_n oznacza n -tą warstwę wejściową, w_{nm} o n -ty neuron w warstwie ukrytej znajdujący się m -tej warstwie ukryte, natomiast y_n symbolizuje warstwę wyjściową

LSTM Jest to jeden z podtypów sieci rekurencyjnych wykorzystujących długą pamięć, z której sieć korzysta w celu optymalizacji podejmowanych decyzji. Stosuje się ją coraz częściej do modelowania szeregów czasowych. Ponieważ jest to jedna z sieci wykorzystanych w badaniu empirycznym, poświęcam jej osobny podrozdział – 2.5.3, w którym wskazuję charakterystykę oraz schemat sieci LSTM.

Siecią o zupełnie innej budowie i zastosowaniu niż sieci przedstawione do tej pory jest **sieć konwolucyjna**. Konwolucyjne sieci neuronowe wykorzystywane są głównie do rozpoznawania i przetwarzania obrazów. Konwolucja to matematyczna operacja, dzięki której istnieje możliwość przekształcania macierzowego fragmentów zdjęcia w celu jego identyfikacji. Najczęściej jest ona stosowana do przetwarzania obrazów (Xu i inni 2014) rozpoznawania mowy (Abdel-Hamid, i inni, 2014) i tłumaczenia maszynowego (Meng i inni, 2015). W odróżnieniu od innych sieci posiada trójwymiarowy układ neuronów. Działanie sieci konwolucyjnej polega na podzieleniu np. obrazu na mniejsze fragmenty, każdy z fragmentów przetwarzany jest przez jeden neuron. Dzięki treningowi sieci uczą się jakie cechy szczególne pomagają w identyfikacji danego obrazu a następnie potrafią dokonywać identyfikacji tego obrazu poprzez zastosowanie filtrów, którego zadaniem jest badanie zależności pomiędzy sąsiednimi pikselami.

2.5. Charakterystyka wybranych sieci neuronowych

W poniższym podrozdziale opisane zostaną trzy sieci neuronowe, wybrane na podstawie analizy bibliograficznej pod kątem możliwego zastosowania do prognozowania kursu walutowego i wykorzystane w późniejszych badaniach empirycznych. Pierwsze dwie sieci, ELM i MLP, są sieciami znacznie mniej złożonymi niż trzecia sieć, którą jest LSTM. Taki wybór posłuży do badania porównawczego między mniej a bardziej złożonymi sieciami oraz analizy możliwości poprawy jakości prognoz dokonywanych sieciami neuronowymi przez agregację ich wyników (*ensemble learning*) z wykorzystaniem zbiorów rozmytych.

2.5.1. Charakterystyka sieci neuronowych typu MLP

Sieć MLP (ang. *Multilayer Perceptron*) to najprostsza sieć wykorzystywana w przedstawionych w tej rozprawie badaniach empirycznych. Zbudowana jest z co najmniej trzech różnych warstw o charakterystycznych zadaniach:

- warstwa wejściowa – otrzymuje sygnał do przetworzenia,
- warstwy ukryte – odpowiedzialne są za przetwarzanie sygnałów z warstwy wejściowej w ten sposób, by wypracować dane pomocnicze. Dane te stanowią podstawę dla wyznaczania ostatecznego rozwiązania poprzez warstwy wyjściowe. Warstwy ukryte pośredniczą między warstwą wejściową i wyjściową, a ich efekt działania jest widoczny pośrednio poprzez wyniki warstwy wyjściowej,
- warstwa wyjściowa - zwracająca rezultat obliczeń dokonanych w warstwach ukrytych.

Schemat działania sieci MLP jest prosty. Każdy z neuronów (z każdej warstwy) oblicza ważoną sumę swoich wejść. Wyliczony poziom pobudzenia jest argumentem przekazywanym do funkcji aktywacji. Ta ostatnia oblicza wartość wyjściową neuronu. Każdy węzeł, poza węzłami wejściowymi, posiada nieliniową funkcję aktywacji, które mogą przyjmować różną formę. Przykładem mogą być np. funkcja sigmoidalna, funkcja unipolarna lub bipolarna (tangens hiperboliczny). Przykładem funkcji sigmoidalnej, której wykres przypomina literę „S”, jest funkcja logistyczna (sigmoidalna funkcja unipolarna):

$$f(x) = \frac{1}{1 + e^{-x}}.$$

(21)

Z kolei tangens hiperboliczny (\tanh) jest dany wzorem:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1}.$$

(22)

MLP jest siecią typu *feedforward*, co oznacza, że sygnał pomiędzy warstwą wejściową i wyjściową przebiega tylko w jedną stronę – od węzłów wejściowych, przez węzły ukryte do węzłów wyjściowych. W pętli nie występują ani cykle, ani pętle.

Mimo swojej prostoty, sieci MLP mogą aproksymować dowolną funkcji ciągłą i mogą rozwiązywać problemy, które nie są liniowe (Abirami, Chitra, 2020). Bardzo ważnym etapem konstrukcji sieci MLP jest ustalenie odpowiedniej liczby warstw i neuronów w warstwach (Hecht-Nielsen, 1992).

(Dash, Dash, Bisoi, 2014) wymieniają jako sieci najczęściej stosowane do prognozowania finansowych szeregów czasowych: perceptron wielowarstwowy (MLP) oraz FLANN (*Functional Link Artificial Neural Network*). Wady MLP wskazywane w literaturze to możliwość zbyt dokładnego dopasowywania się sieci neuronowych do danych, duża liczba iteracji, a co za tym idzie - długi czas obliczeniowy, powolna konwergencja oraz tendencja do kończenia obliczeń przez sieci MLP w minimum lokalnym (Rout i inni, 2017). Podążając za własnym przeglądem bibliograficznym oraz wnioskami z przytoczonych artykułów, pierwszym typem sieci, które wybrałem do badania empirycznego, została sieć MLP. W badaniu empirycznym wykorzystałem implementację MLP z pakietu *nnfor* dostępnego w R. (Kourentzes, Barrow, Crone, 2019).

2.5.2. Charakterystyka sieci neuronowych typu ELM

Kolejnym typem sieci, używanych w niniejszej rozprawie, są sieci typu ELM (ang. *Extreme Learning Machine*). ELM pierwotnie została opracowana dla sieci typu SLFN (ang. *single hidden layer feedforward neural networks*), czyli jako sieć jednowarstwowa. W celu aktywacji neuronów ukrytych, stosuje się w niej ciągłą i różniczkowalną funkcję aktywacji najczęściej stosowane są funkcje sigmoidalne i Gaussowskie (Jastrzębski i inni, 2015). Uczenie sieci neuronowych zachodzi w dwuetapowo. Paradygmat uczenia sieci ELM zakłada losowe generowanie parametrów warstwy ukrytej, w celu odwzorowania danych wejściowych

w przestrzeń cech. Parametry te pozostają niezmiennie (niezależne od procesu uczenia). Drugi etap to minimalizowanie błędu kwadratowego popełnianego przez sieć w kroku pierwszym. Wynikiem drugiego etapu jest ustalenie wag łączących warstwę ukrytą z warstwą wyjściową. Wagi warstwy wyjściowej są uzyskiwane przy użyciu uogólnionej odwrotności macierzy wyjściowej warstwy ukrytej. Metoda ta nazywa jest metodą odwrotności Moore'a Penrose'a (Lu i inni, 2015). Istnieją badania, które udowadniają uniwersalność metody ELM dla losowego doboru ustawień warstw ukrytych (Huang, Chen, 2008). W związku z prostotą działania sieci ELM, schemat jej postępowania można przedstawić w trzech punktach (Dudek, 2016):

1. Sieć ELM losuje wagi i przyporządkowuje je do neuronów, których liczbę w warstwie ukrytej należy podać.
2. Obliczana jest macierz wyjściowej warstwy ukrytej z wykorzystaniem wybranej funkcji aktywacji. Macierz wyjściowa zbudowana jest tak, że i -ta kolumna tworzona jest jako wyjście i -tego neuronu ukrytego.
3. Obliczane są wagi wyjściowe z wykorzystaniem metody odwrotności Moore'a Penrose'a.

Sieci ELM, dzięki prostej strukturze oraz tylko jednej warstwie ukrytej, charakteryzują się znaczną szybkością wykonywania obliczeń oraz wysokim poziomem generalizacji (Huang, Zhu, Siew, 2006). Znajdują szerokie zastosowanie do rozwiązywania problemów wielowymiarowych oraz wykorzystujących duże ilości danych (Cao, Lin, 2015). (Cao i inni 2017) wskazują na takie zalety sieci ELM, jak efektywne oraz szybkie uczenie się, szybką konwergencję, dobre zdolności do generalizacji rozwiązań oraz łatwą implementację. Natomiast ich podstawową wadą jest brak odporności na obserwacje nietypowe. Może to powodować błędy w uczeniu się, takie jak na przykład przeuczenie się sieci neuronowej (Yildirim, Özkale, 2019).

W literaturze można odnaleźć przykłady dobrych wyników predykcji cen walut za pomocą modeli wykorzystujących sieć neuronową ELM. (Das, Mishra, Rout, 2019) wykorzystali ELM do prognozowania dwóch par walutowych, rupii indyjskiej w stosunku do dolara amerykańskiego USD/IND oraz euro do dolara USD/EUR. (Esenyel, Akin, 2017) wykazali, że sieć ELM prognozuje trafnie stopy zwrotu kursów walutowych euro i funta brytyjskiego w porównaniu do modelu ARMA i ARMA-GARCH. Sieć ELM często łączona jest z innymi metodami, jak np. empiryczną dekompozycją trybów (EMD – ang. *empirical mode*

decomposition) oraz rekonstrukcją przestrzeni fazowej (PSR – ang. *phase space reconstruction*) (Yang, Lin, 2017). W takich modelach hybrydowych dodatkowe metody są odpowiedzialne za wstępne przetwarzania danych, których przyszłe wielkości są w kolejnym kroku przewidywane przez sieć neuronową ELM.

Szybkość działania sieci ELM oraz wskazane przykłady artykułów z ostatnich lat determinują wybór sieci ELM jako drugiej do badania empirycznego. W badaniu empirycznym przedstawionym w tej rozprawie wykorzystano ELM z pakietu `nnfor` dostępnego w R (Kourentzes, Barrow, Crone, 2019).

2.5.3. Charakterystyka sieci LSTM


Ostatnim rodzajem sieci neuronowych wykorzystanych w prezentowanym w tej rozprawie badaniu, są sieci LSTM (ang. *Long short-term memory*), należące do klasy sieci rekurencyjnych (dalej: RNN). Charakterystyczną cechą dla sieci LSTM jest posiadanie specjalnej struktury stworzonej do zapamiętywania krótkich wzorców (stąd w nazwie sieci ang. *short-term*). LSTM wstępnie powstała w celu analizy sekwencji i była wykorzystywana w analizie sekwencji tekstów. Przyczyniła się do rozwoju m.in. Google Translate, Siri i asystenta głosowego Google. W późniejszych etapach rozwoju została dostosowana również do szeregów czasowych (Smagulova, James, 2019).

Sieć LSTM składa się z wielu rekurencyjnych bloków pamięciowych połączonych ze sobą. Każdy blok składa się z trzech bramek – wejściowej, wyjściowej oraz pamięci. Bloki pamięci są elementem różniącym LSTM od pozostałych sieci rekurencyjnych. W klasycznych sieciach rekurencyjnych następuje przepływ danych wewnątrz sieci, ale dodatkowo w LSTM występuje tzw. długa pamięć: dzięki bramkom sieć LSTM jest zdolna do przechowywania danych dłużej niż przez jeden okres (Van Houdt, Mosquera, Nápoles, 2020). Należy podkreślić również drugą różnicę między klasycznymi sieciami rekurencyjnymi a LSTM - komórka pamięciowa otrzymuje informację z trzech źródeł wejściowych. Są to:

- X - sygnał wejściowy w danej chwili t ,
- h_{t-1} – sygnał wyjściowy w danej chwili $t - 1$ z poprzedniej komórki pamięci,
- sygnał pamięci z chwili $t - 1$, z poprzedniej komórki pamięci C_{t-1} .

Tym samym, komórka w momencie t musi wytworzyć dwa sygnały wyjściowe: h_t – sygnał wyjściowy w danej chwili t oraz sygnał pamięci z chwili t : C_t . Sygnały te używane są przez

kolejną komórkę w łańcuchu. Opisany proces przepływu sygnałów w czasie od $t - 1$ do $t + 1$ został przedstawiony na rysunku 26.



Rysunek 26. Diagram obrazujący działanie LSTM

Źródło: Osowski, S. (2018). *Głębokie sieci neuronowe i ich zastosowania w eksploracji danych. Przegląd Telekomunikacyjny+ Wiadomości Telekomunikacyjne.*

Opis: Symbole zgodne z zawartymi w opisie – X_t - sygnał wejściowy w danej chwili t , h_t – sygnał wyjściowy w danej chwili t , C_t – sygnał komórki pamięci, \tanh oraz σ – oznaczają typ funkcji aktywacji.

Schemat działania LSTM zgodny z rysunkiem 26. przedstawiono na rysunku 27. W pierwszym kroku komórka przetwarza nieliniowo aktualny sygnał wejściowy X_t oraz sygnał z pamięci C_{t-1} . Decyzja o przepuszczeniu sygnału z pamięci oraz danych wejściowych zapada w bramce zapomnienia (ang. a *forget gate*), która jest jednowarstwową siecią neuronową o sigmoidalnej funkcji aktywacji. Na rysunku 26. bramki zapomnienia zaznaczone są symbolem „x”. W tym miejscu podejmowana jest decyzja, która informacja z chwili $t - 1$ zostanie

przepuszczona do stanu w chwili t . Zadaniem bramek jest decydowanie nie tylko o tym, która informacja zostanie przepuszczona, ale również z jaką wagą (od 0 do 1). Wartość 0 oznacza, że warstwa ta nie przepuszcza żadnego składnika natomiast 1 to decyzja o przepuszczeniu wszystkiego z danego składnika. „+” na rysunku 26. to blok sumatora. Odpowiedzialny jest on za zebranie informacji z dwóch bramek zapomnienia i na podstawie uzyskanych informacji generuje nowy stan pamięci dla górnego schematu (dolnego) C_t (C_{t-1}) (Osowski, 2018).

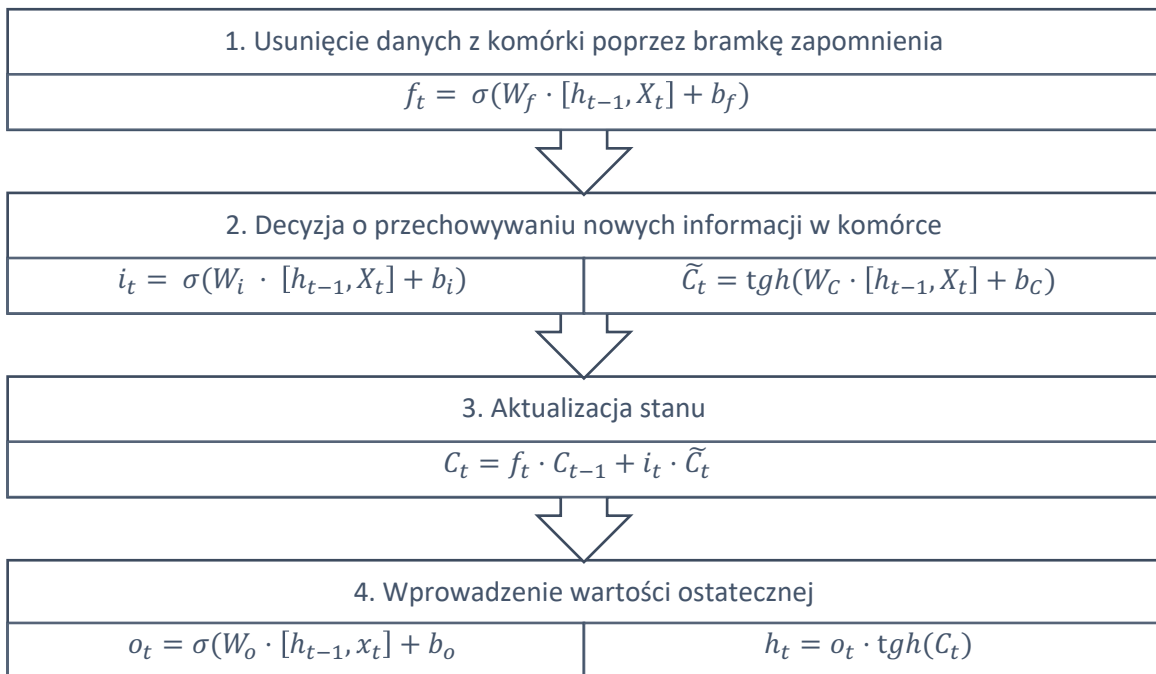
Decyzja wewnątrz komórki podejmowana jest na podstawie wartości h_{t-1} i X_t , gdzie X_t to dane wejściowe z okresu t a h_{t-1} to wartość wprowadzona przez sieć neuronową dla okresu $t - 1$. Wartości te przekazywane są do komórki C_{t-1} , gdzie C_{t-1} oznacza stan komórki, który porównywany jest z przekąźnikiem.

Krok 2 na rysunku 26 odpowiada za podjęcie decyzji przez LSTM o zatrzymaniu pewnych nowych informacji i przechowywaniu ich w komórce. Decyzja ta składa się z dwóch etapów. Pierwszy z nich zachodzi w warstwie z sigmoidalną funkcją aktywacji. W bramce podejmowana jest decyzja o aktualizacji danych, czyli sieć uznaje, które z danych są ważne, a które powinny zostać usunięte w komórce kosztem innych (świeższych). Proces ten zachodzi poprzez wyliczenie współczynnika, z jakim pamięć przechodzi do kolejnego korku i jest iloczynem wartości wyliczonej w warstwie sigmoidalnej ($sigm$) i sygnałem z pamięci poprzedniej. Drugi etap odbywa się w warstwie z funkcją aktywacji tangens hiperboliczny (tgh), gdzie tworzony jest nowy wektor (na rysunku 27. \tilde{C}_t), który może, ale nie musi zostać dodany do stanu C_{t-1} . Miejsce to na rysunku 26. przedstawione zostało w środkowej części diagramu (w odpowiednich komórkach zapisano tgh lub $sigm$).

Krok trzeci działania sieci LSTM wynika bezpośrednio z punktu drugiego i polega na aktualizacji stanu. Decyzje o aktualizacji zostały podjęte w poprzednich krokach; w tym dochodzi do zamiany starego stanu C_{t-1} na nowy C_t , na podstawie danych z punktów 1. i 2. obliczonych za pomocą wzorów zawartych w punktach 1. i 2. na schemacie przedstawiającym działanie LSTM (Rysunek 26). Nowy stan powstaje poprzez sumę iloczynów starego stanu C_{t-1} oraz dwóch wartości powstałych w kroku 2. czyli i_t oraz \tilde{C}_t , gdzie i_t to sygnał wygenerowany przez warstwę sigmoidalną a \tilde{C}_t przez warstwę z funkcją aktywacji tangens hiperboliczny.

Ostateczna decyzja podejmowana jest na podstawie wartości h_t , czyli wyjścia sieci. Wyjście to jest przefiltrowaną wersją stanu komórek w sieci neuronowej, których stany powstały w całym procesie opisanym powyżej. Aktualizacja stanu komórek odbywa się

najpierw w warstwie z funkcją sigmoidalną. W tej warstwie podejmowana jest decyzja o usunięciu części nieistotnych stanów. Po usunięciu stanów niebiorących udziału w dalszym procesie, powstaje nowy stan i jest on przepuszczany przez komórkę z funkcją aktywacji tangens hiperboliczny. Ostateczna wartość h_t , to iloczyn przefiltrowanego stanu w warstwie z funkcją sigmoidalną oraz ze stanem w warstwie z funkcją tgh , przez którą został przepuszczony stan C_t (wzór w punkcie 4. rysunku 27).



Rysunek 27. Działanie LSTM

Źródło: opracowanie własne na podstawie <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

Opis: Symbole zgodne z zawartymi w opisie – x_t - sygnał wejściowy w danej chwili t , h_t – sygnał wyjściowy w danej chwili t , \tanh oraz σ – oznaczają typ funkcji aktywacji, C_t – stan pamięci w danej chwili, W_i - macierz wag i-tego zaworu

(Obthong i inni 2020) w swoim przeglądzie dotyczącym stosowanych metod uczenia maszynowego do prognozowania na giełdzie za pomocą sieci LSTM wskazali wady i zalety tego typu sieci. Za zalety uznali:


- umiejętność analizowania i wykorzystywania interakcji i wzorców występujących w danych poprzez samouczenie się,
- wysoką trafność przewidywać,
- umiejętność dobrego zapamiętywania informacji przez dobry czas.

Przywołując następujące artykuły: (Selvin i inni, 2017), (Roncoroni, Fusai, Cummins, 2015), (Khare i inni, 2017) i (Althelaya, El-Alfy, Mohammed, 2018) autorzy wskazali w nich tylko jedną wadę tej sieci – brak mechanizmu indeksowania pamięci podczas zapisu i odczytu danych, natomiast podkreślili takie zalety, jak niskie wartości błędu prognoz oraz wysoka trafność prognozowania dla LSTM. Na wysoką trafność prognoz dokonywaną siecią LSTM wskazują również inne prace, jak chociażby (Moghar, Hamiche, 2020) lub (Roondiwala, Patel, Varma, 2017). (Michańków, Sakowski, Ślepaczuk, 2022) podsumowując swój artykuł badający skuteczność LSTM w algorytmicznej strategii inwestycyjnej dla Bitcoina i S&P500 wskazali, że skuteczność stosowania sieci LSTM ściśle zależy od doboru parametrów sieci, konstrukcji modelu oraz procesu estymacji.

Popularność sieci LSTM wśród innych typów wykorzystywanych w prognozowaniu na rynkach finansowych wzrosła na przestrzeni ostatnich lat. W związku z tym, sieć typu LSTM będzie trzecim typem sieci neuronowej wykorzystanym w badaniu empirycznym mojej rozprawy doktorskiej. W badaniu wykorzystałem implementację LSTM z pakietu keras dostępnego w R (Cholett, 2017).

2.6. Sieci neuronowe w prognozowaniu kursów walutowych

Wraz ze wzrostem mocy obliczeniowej komputerów zwiększają się możliwości wykorzystania sieci neuronowych do prognozowania par walutowych. Przeprowadzone przeze mnie badanie bibliograficzne (Morkowski, 2022) wykazało, że rośnie również liczba artykułów naukowych dotyczących prognozowania kursów walutowych z wykorzystaniem tych narzędzi (zob. rysunek 28). Równolegle, pojawia się coraz więcej podejść hybrydowych łączących sieci neuronowe z innymi metodami, co skutkuje wyższą trafnością prognoz (He, Chen i Tso, 2018). Ostatecznie, bardzo obiecujące wyniki dają również metody stosujące uczenie grupowe.



Rysunek 28. Roczny trend cytowań oraz ilości opublikowanych artykułów na temat wykorzystania sieci neuronowych do prognozowania cen walut

Źródło: opracowanie własne na podstawie ISI Web of Science oraz (Morkowski, 2022)

Na podstawie przeglądu literaturowego, zdecydowałem się na wybór trzech typów sieci do prognozowania kursów walutowych. Dwie mniej złożone sieci: MLP i ELM to takie typy sieci, które w literaturze zostały scharakteryzowane jako potrafiące generować prognozy o dobrej trafności. Trzecia to bardziej skomplikowana sieć LSTM, która w przeglądach literatury uznawana jest za bardzo skuteczną w prognozowaniu szeregów czasowych. Inspirując się metodami uczenia grupowego, w swojej metodzie postanowiłem połączyć wyniki prognoz wszystkich sieci. Uzasadnieniem takiego działania jest chęć wykorzystania możliwości sieci LSTM (która uzyskuje wyższe trafności prognoz w dłuższym horyzoncie, poprzez wykorzystanie długiej pamięci) oraz poszukiwanie rozwiązania prognozującego lepiej w krótszym horyzoncie. Do grupowania prognoz wykorzystuję możliwości logiki rozmytej, która będzie przedmiotem rozważań przedstawionych w kolejnym rozdziale.

Rozdział III. Metoda neuronowo-rozmyta

Niniejszy rozdział stanowi podstawę do rozważań nad wykorzystaniem podejścia hybrydowego, łączącego koncepcję sieci neuronowych ze zbiorami rozmytymi, w celu poprawy trafności prognoz generowanych przez te sieci. Prognozy uzyskane za pomocą trzech (ELM, MLP oraz LSTM) typów sieci neuronowych posłużą jako dane do stworzenia liczby rozmytej, na podstawie, której dokonywane będą decyzje inwestycyjne.

1. Koncepcja zbiorów rozmytych oraz podstawowe pojęcia

Pojęcie zbioru rozmytego wprowadził L.A. Zadeh, w swojej pracy (Zadeh, 1965). Stanowiło ono uogólnienie pojęcia zbioru zwykłego. W zbiorze zwykłym wartość logiczna zawiera się w zbiorze $\{0,1\}$, natomiast w zbiorze rozmytym wartość logiczna należy do przedziału jednostkowego od zera do jeden $I = (0,1)$.

Zbiór rozmyty Z , określony w pewnej przestrzeni X , jest to zbiór (Pedrycz, 1996)

$$Z = \{(x, \mu_Z(x)) : x \in X\},$$

(23)

gdzie

$$\mu_Z(x) : x \rightarrow (0,1)$$

jest funkcją przynależności zbioru rozmytego Z . Wartość funkcji $\mu_Z(x)$ może przyjmować wartości z przedziału $(0,1)$. Przez wartość funkcji przynależności rozumiemy stopień przynależności danego elementu x do zbioru rozmytego Z . Jeżeli $\mu_Z(x) = 1$, mówimy o pełnej przynależności do zbioru rozmytego Z . Ponadto, $\mu_Z(x) = 0$ oznacza brak przynależności elementu x do zbioru rozmytego Z , natomiast wartości między 0 a 1 oznaczają częściową przynależność. Funkcje przynależności opisują szerzej w podrozdziale 2. (Lazzerini, Jain, Dumitrescu, 2000).

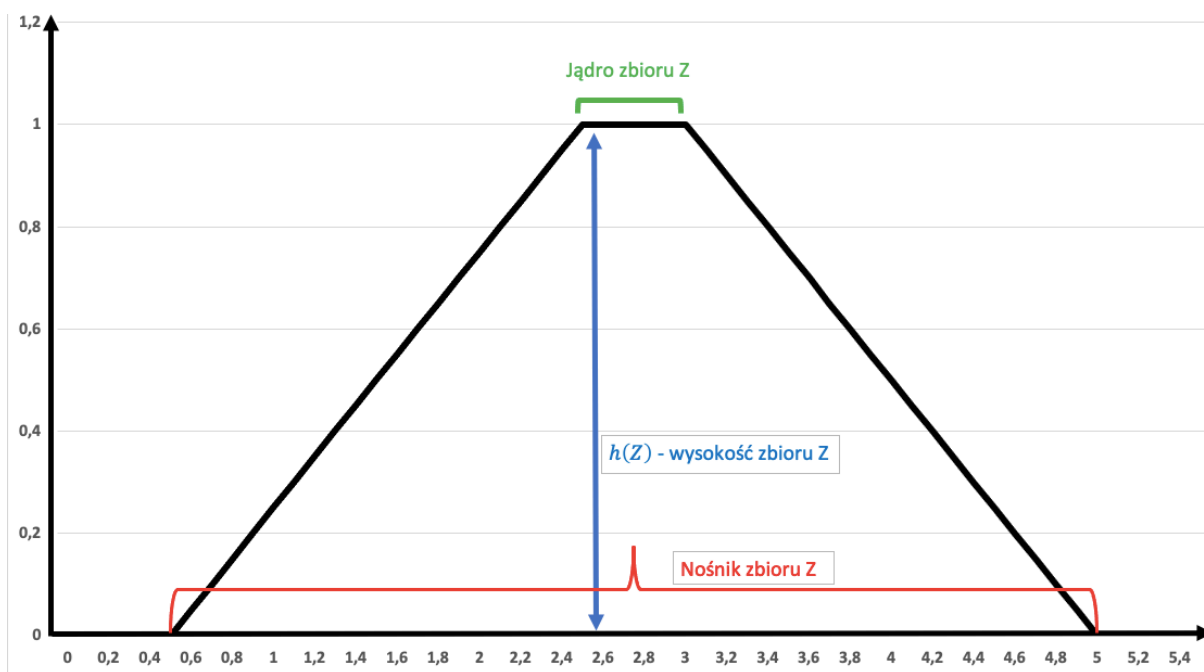
Istnieją dwa najpopularniejsze sposoby przedstawiania zbiorów rozmytych, dla przestrzeni o skończonej liczbie elementów $X \in \{x_1, x_2, \dots, x_n\}$:

- $Z = \left\{ \left(\frac{\mu_Z(x_1)}{x_1} \right), \left(\frac{\mu_Z(x_2)}{x_2} \right), \dots, \left(\frac{\mu_Z(x_n)}{x_n} \right) \right\}$, (Notacja Zadeha)
- $Z = \left\{ (x_1, \mu_Z(x_1)), (x_2, \mu_Z(x_2)), \dots, (x_n, \mu_Z(x_n)) \right\}$.

W przypadku, gdy X jest przestrzenią o nieskończonej liczbie elementów, zbiór rozmyty opisywany jest jako:

$$Z = \int_X \frac{\mu_Z(x)}{x} dx \quad (24)$$

Zbiór rozmyty charakteryzowany jest przez trzy elementy: wysokość zbioru, nośnik zbioru oraz jądro zbioru rozmytego Z . **Wysokość zbioru rozmytego** to maksymalna wartość, jaką funkcja przynależności przyjmuje w całej przestrzeni rozważań X zbioru tzn. $h(Z) = \sup \mu_Z(x)$ (por. rysunek 29, $h(Z)$). **Nośnik zbioru rozmytego** jest podzbiorem nierozmytym zbioru Z , którego wszystkie elementy mają niezerowy stopień przynależności tzn. $\{x \in R : \mu(x) > 0\}$. Natomiast podzbiór nierozmyty złożony z elementów o stopniu przynależności 1 nazywany jest **jądrem zbioru rozmytego** tzn. $\{x \in R : \mu(x) = 1\}$.



Rysunek 29. Wizualizacja przykładowego zbioru rozmytego

Liczbą rozmytą nazywamy zbiór rozmyty, który określony jest w zbiorze liczb rzeczywistych a jego funkcja przynależności $\mu_Z(x)$ spełnia następujące warunki (Pedrycz, 1998):

- Zbiór rozmyty Z jest normalny - zbiór rozmyty nazywamy normalnym wtedy i tylko wtedy, gdy $h(Z) = 1$;

- Zbiór rozmyty Z jest wypukły - zbiór rozmyty Z jest wypukły wtedy i tylko wtedy, gdy dla dowolnego $x_1, x_2 \in R$ oraz $\lambda \in (0,1)$ zachodzi:

$$Z[\lambda x_1 + (1 - \lambda)x_2] \geq \mu_z(x_1) \wedge \mu_z(x_2);$$

- $\mu_z(x)$ jest przedziałami ciągła.

2. Funkcje przynależności

Funkcją przynależności zbioru rozmytego nazywamy funkcję, która przypisuje każdemu elementowi $x \in X$ stopień przynależności do zbioru rozmytego Z . W pracy rozważane będą trzy podstawowe rodzaje funkcji przynależności:

- trójkątna,
- trapezoidalna,
- gaussowska.

Poniżej przedstawiam przykładowe funkcje przynależności wraz z wykresami, w celu pokazania różnic wynikających ze stosowania ich różnych postaci.

Trójkątna funkcja przynależności wyraża się wzorem (Piegat, Pluciński, 2015):

$$\mu(x) = \begin{cases} 0, & \text{dla } x \leq a \\ \frac{x - a}{b - a}, & \text{dla } a < x \leq b \\ \frac{c - x}{c - b}, & \text{dla } b \leq x < c \\ 0, & \text{dla } x \geq c \end{cases}$$

(25)

Rysunek 30. przedstawia przykład graficzny trójkątnej funkcji przynależności dla $a = 0,5$; $b = 1$; $c = 1,5$.



Rysunek 30. Trójkątna funkcja przynależności – przykład graficzny


Źródło: opracowanie własne

Trójkątna funkcja przynależności jest szczególnym przykładem trapezoidalnej funkcji przynależności, której wzór jest następujący (Pedrycz, 1994):

$$\mu(x) = \begin{cases} 0 & \text{dla } x \leq a \\ \frac{x - a}{b - a} & \text{dla } a < x < b \\ 1 & \text{dla } b \leq x \leq c \\ \frac{d - x}{d - c} & \text{dla } c < x < d \\ 0 & \text{dla } x \geq d \end{cases}$$

(26)

W przedstawionym na rysunku 31. przykładzie graficznym zilustrowano wykres funkcji przynależności dla $a = 0,5$; $b = 0,75$; $c = 1,25$; $d = 1,5$.



Rysunek 31. Trapezoidalna funkcja przynależności – przykład graficzny


Źródło: opracowanie własne

Na podstawie powyższego równania można stwierdzić, że trójkątna funkcja przynależności jest trapezoidalną funkcją przynależności $\mu(x)$, gdy $b = c$.

Gaussowska funkcja przynależności wyrażona jest wzorem (Piegat, 2013):

$$\mu(x) = e^{-\left(\frac{x-b}{a}\right)^2}.$$

W przedstawiony poniżej przykładzie graficznym przedstawiono wykres Gaussowskiej funkcji przynależności, gdzie b oznacza jądro zbioru rozmytego, a nośnik zbioru rozmytego.



Rysunek 32. Gausowska funkcja przynależności – przykład graficzny

Źródło: opracowanie własne

Istnieją również inne funkcje przynależności, wśród których można wymienić takie, jak:

- kwadratowa,
- dzwonowa,
- sigmoidalna.

Podstawową opisu zbiorów rozmytych jest funkcja przynależności, która istotnie wpływa na system wnioskowania rozmytego. Pomimo, że funkcja przynależności może przyjmować dowolne kształty, najczęściej spotykane są charakterystyczne funkcje przynależności, które zostały opisane w niniejszym podrozdziale. Istnieją podejścia mówiące o tym, że to nie kształt funkcji przynależności jest kluczowy, a sposób budowy liczby rozmytej (Sadollah, 2018). (Mitaim, Kosko, 1996) przedstawili porównanie funkcji: trójkątnej, trapezoidalnej oraz gaussowskiej (najczęściej spotykane) z wieloma innymi funkcjami, m.in. funkcją Cauchy'ego, sinc, Laplace'a, logistyczną i hiperboliczną, stwierdzając, iż nie potrafią wskazać jednoznacznie przyczyn, dla których jedna z funkcji okazała się lepsza od pozostałych. Wu, w swoim artykule z 2012 roku (Wu, 2012), dokonał porównania trapezoidalnej i gaussowskiej funkcji przynależności i stwierdził, że każda ze wskazanych funkcji przynależności ma swoje wady i zalety – w związku z czym trudne jest bezwzględne wskazanie, że jedna z nich jest lepsza od drugiej. (Rutkowska, 2016) badała wpływ doboru funkcji przynależności na wyniki

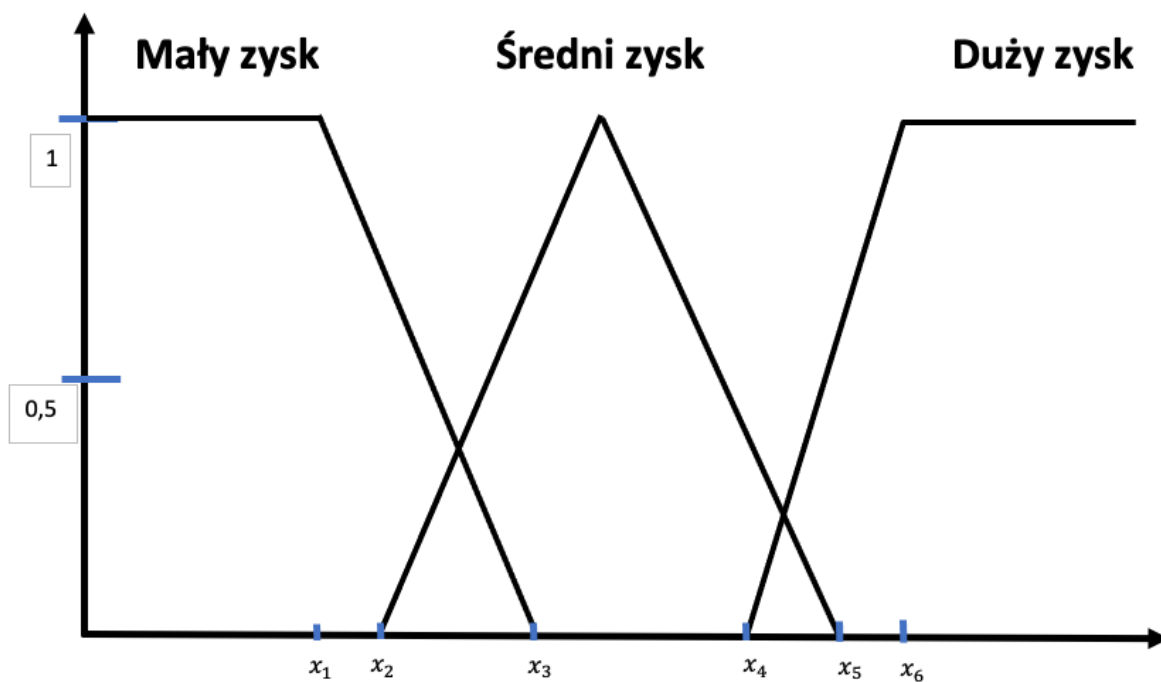
optymalizacji portfela i rozważała, czy trójkątna funkcja przynależności jest wystarczająca do przedstawienia zwrotów rozmytych. W wyniku przeprowadzonych badań wskazała, że kształt funkcji przynależności ma wpływ na wyniki optymalizacji, z zastrzeżeniem, że istnieją miary niepewności, dla których jest on trudniejszy do zauważenia. Wskazała również na brak poprawy wyników po zmianie funkcji przynależności z trójkątnej na gaussowską. Zagadnienie poruszone w cytowanym artykule porusza bardzo szeroki problem badawczy, jakim jest różnica między trójkątną funkcją przynależności, która ma charakter liniowy, a funkcją gaussowską, która jest gładka i niezerowa we wszystkich punktach. Obszerne porównania funkcji przynależności (trójkątna, trapezowa, gaussowska, dzwonowa, sigmoidalna i wielomianowa) w sterowaniu rozmytym napędu z silnikiem indukcyjnym dokonali (Zhao, Bose, 2002). Dla badanego przez nich problemu zastosowanie funkcji trójkątnej dało najlepsze wyniki. Badanie wpływu funkcji przynależności na wydajność adaptacyjnego systemu neuronowo-rozmytego w rozwiązywaniu problemów klasyfikacyjnych (Talpur i inni, 2017) wykazało z kolei przewagę funkcji gaussowskiej i trójkątnej nad pozostałymi. Należy zaznaczyć, że funkcja gaussowska i trójkątna poprzez stosunkowo zbliżony kształt osiągają często zbliżone wyniki, a trójkątna funkcja przynależności przy dużej liczbie danych potrzebuje mniejszej mocy obliczeniowej.

Podsumowując liczne artykuły dotyczące doboru funkcji przynależności można przyjąć, że jeżeli wiedza ekspercka w danym zakresie nie wskazuje na konieczność korzystania ze specyficznych dla danego zagadnienia funkcji przynależności, to trójkątna oraz trapezoidalna funkcja przynależności wykazują pewnego rodzaju uniwersalność oraz poprzez prostotę implementacji są efektywnie stosowane w wielu dziedzinach. Na podstawie przedstawionych powyżej prac, w niniejszej rozprawie zdecydowałem się przeprowadzić badanie empiryczne dla trójkątnej i trapezoidalnej liczby rozmytej. Dla obu wskazanych funkcji przynależności rozważanych będzie wiele metod ich tworzenia poprzez różnorodny dobór jądra zbioru.

3. Logika rozmyta

Zgodnie z definicją przytoczoną we wstępie, za logikę rozmytą należy uznać uogólnienie klasycznej logiki dwuwartościowej (nierozmytej). Logika rozmyta znalazła swoje zastosowanie w dziedzinach nauki, w których logika przyjmująca tylko dwie wartości prawda/fałsz była niewystarczająca (na przykład elektroniczne systemy sterowania).

Działanie logiki rozmytej można przedstawić na przykładzie wysokości stopy zwrotu z inwestycji. Załóżmy, że zaprognozowano, iż cena instrumentu wzrośnie. Inwestorzy przypisują przyszłej stopie zwrotu z tej inwestycji trzy możliwe stany: mały zysk, średni zysk i duży zysk. Graficznie można tę sytuację przedstawić za pomocą wykresu (Rysunek 33). Wszyscy eksperci uznają zysk za mały, jeśli cena nie przekroczy wartości x_1 , dlatego stwierdzenie „inwestycja przyniesie mały zysk” można opisać liczbą rozmytą, której funkcja przynależności wynosi 1 dla ceny z przedziału od 0 do x_1 , a następnie maleje liniowo, aby osiągnąć zero w punkcie x_3 (Rysunek 33). Przedział między x_1 a x_3 wiąże się ze stwierdzeniami takimi jak „prawie mały zysk”, „mniej więcej mały zysk”. Wynika to z niepełnej przynależności wartości z tego przedziału do zbioru „mały zysk”. Zatem zysk w przedziale od x_2 do x_3 interpretujemy jako „trochę mały, a trochę średni zysk”. Analogicznie możemy opisać stwierdzenie: „inwestycja przyniesie duży zysk” – jako liczbę rozmytą, której funkcja przynależności wynosi 1 dla ceny wyższej niż x_6 , natomiast rośnie liniowo w przedziale od x_4 do x_6 (Rysunek 33). Zysk określony został jako „średni” na przedziale od x_2 do x_5 , a stwierdzenie „inwestycja przyniesie średni zysk” zostało na rysunku 33. opisane liczbą trójkątną.



Rysunek 33. Przykład działania logiki rozmytej

Prognozy obarczone są pewnym ryzykiem. W związku z powyższym, jeden inwestor może interpretować prognozę pomiędzy x_2 a x_3 , jako sygnał o inwestycji, która może przynieść mały

zysk, natomiast dla innego inwestora, ta sama prognoza może oznaczać możliwość osiągnięcia średniego zysku. Różnica ta wynika ze stopnia przynależności do zbioru „mały zysk” oraz „średni zysk”, który może być różnie interpretowany przez różnych inwestorów.

Wnioskowanie rozmyte jest dokonywane w następujących czterech krokach (Russo, Jain, 2000):

- Rozmywanie – czyli przekształcenia ilościowych sygnałów wejściowych za pomocą funkcji przynależności na lingwistyczne, reprezentowane przez zbiory rozmyte. Przedstawiony przykład prezentuje sytuację, w której system dostaje informacje, że prognozowany jest wzrost danego instrumentu, a inwestora interesuje jak duży będzie zysk. Określenia wielkości prognozowanego zysku dokonuje się za pomocą prognozowanej ceny lub stopy zwrotu i cena ta jest zmienną ilościową. Zmienna ilościowa musi zostać przekształcona na zmienną lingwistyczną przedstawioną w sposób jakościowy – mały zysk, średni zysk, duży zysk.
- Baza reguł – to reprezentacja wiedzy jakościowej za pomocą reguł: *jeśli-to*. W podanym przypadku reguły te opierałyby się na wysokości prognozowanej zmiany. Przykładowo, jeśli prognozowany jest wzrost o więcej niż 3% to osiągamy duży zysk, a jeśli prognozowany jest wzrost o mniej niż 0,5% to mały zysk.
- Wnioskowanie rozmyte – oznacza podjęcie decyzji o wartości wyjścia za pomocą reguł rozmytych. Dla podanego przykładu i opierając się wartościach pomiędzy x_2 a x_3 , na rysunku 33., wnioskowanie rozmyte musiałyby podjąć decyzje między małym a średnim zyskiem.
- Defuzyfikacja – przekształcenie sygnałów wyjściowych rozmytych na ilościowe.

4. Zbiory rozmyte w inwestowaniu

W literaturze można spotkać się z wieloma zastosowaniami zbiorów rozmytych. Zastosowania te dotyczą różnych dziedzin zarówno przemysłu, jak i nauki. (Kahraman i inni, 2016) przeprowadzili przegląd literatury, w którym wskazali na najpopularniejsze dziedziny nauki, w jakich publikowane były artykuły wykorzystujące teorię zbiorów rozmytych w okresie 1956-2016. Do tych dziedzin należy zaliczyć:

- Inżynieria – 71 928 artykułów i 355 patentów,
- Informatyka – 67 898 artykułów i 1 241 patentów,

- Matematyka – 31 073 artykułów i 855 patentów,
- Nauki o podejmowaniu decyzji – 10 273 artykułów i 6 patentów.

Wyszczególniono również inne dziedziny, w których opublikowano mniej niż 10 tysięcy artykułów – były to nauki o życiu, nauki fizyczne, nauki o zdrowiu oraz nauki społeczne i humanistyczne. Mimo, że badanie obejmuje lata od powstania teorii zbiorów rozmytych, to największy przyrost publikacji z wykorzystaniem teorii zbiorów rozmytych przypada na rok 1990. W 1996 roku pierwszy raz liczba publikacji przekroczyła 2 tysiące rocznie, po kolejnych 10 latach, w 2006 roku, przekroczyła pierwszy raz 4 tysiące rocznie, by w szczyt i względną stabilizacją na poziomie 10 tysięcy osiągnąć w latach 2010-2016. Liczba artykułów dotycząca niniejszego tematu rośnie z roku na roku, co świadczy o popularności oraz obiecujących wynikach, jakie udaje się uzyskać przy stosowaniu logiki rozmytej w różnych dziedzinach nauki. Liczba publikacji w 2021 roku w porównaniu do roku 2016, na którym kończy się wspomniany powyżej przegląd, wzrosła prawie dwukrotnie. Z punktu widzenia niniejszej rozprawy, szczególnie istotne są prace dotyczące zastosowania logiki rozmytej do konstrukcji optymalnego portfela inwestycji oraz wspomaganie decyzji inwestycyjnych. W związku z tym przedstawione zostaną wyniki najnowszych artykułów dotyczących wyboru portfela inwestycyjnego.

Jedną z propozycji jest podejście dwukryterialne, zdefiniowane w oparciu o rozmyte ryzyko i zwrot z portfela (Dymova, Kaczmarek, Sevastjanov, 2021) lub podejście stosujące logikę rozmytą do opisu przyszłych stóp zwrotu i nastrojów inwestorów (Gong, Min, Yu, 2022). Inni naukowcy konstruują efektywny portfel inwestycji, łącząc podejście rozmyte z analizą behawioralną (Tsaur, 2013). (Zhang, Liu, Yang, 2022) prezentują automatyczny system rozmyty, którego zadaniem jest eliminacja z portfela ryzykownych aktywów w momencie osiągnięcia przez nie zadanych progów cenowych. Podejmowanie decyzji może odbywać się ze względu na wiele zmiennych. Przykładowo, porównania oczekiwanego czynnika dyskontowego jako narzędzia do analizy zysków, z oczekiwaną stopą zwrotu na podstawie szacowania wartości bieżącej z wykorzystaniem trójkątnej liczby rozmytej dokonali (Piasecki, Siwek, 2018). Zaproponowana metoda została wykorzystana do wspomaganie podejmowania decyzji inwestycyjnych. Innym przykładem zastosowania logiki rozmytej w analizie rynków finansowych jest publikacja (Pahade, Jha, 2021), w której autorzy modelują stopy zwrotu z ryzykownych akcji jako trapezoidalne zmienne rozmyte. Przykładami na zastosowanie logiki rozmytej w wspomaganie decyzji z wykorzystaniem modelu Blacka-Littermana są również

artykuły (Rutkowska, Bartkowiak, 2019) oraz (Bartkowiak, Rutkowska, 2020). Z kolei (Wu i inni, 2021) proponują metody grupowego wielokryterialnego podejmowania decyzji z uwzględnieniem procesu dochodzenia do konsensusu w interwałowym środowisku rozmytym. W badaniu empirycznym autorzy wykorzystują tę metodę do alokacji portfela inwestycyjnego stosując dwa kryteria – minimalizacji ryzyka oraz maksymalizacji zysku. (Akbaş, Dalkiliç, 2021) proponują dwuetapowy proces konstrukcji portfela, w oparciu o wskazania algorytmów (pierwszy etap) oraz opinie ekspertów (drugi etap). Zastosowany przez nich algorytm rozmyty wykorzystuje trapezoidalne funkcje przynależności. W podejmowaniu decyzji inwestycyjnych łączone mogą być też metody stosowane w analizie technicznej (na przykład japońskie świece) z rozmytością. (Naranjo, Santos, 2019), korzystając z takiej metody hybrydowej, uzyskali obiecujące wyniki i potwierdzili, że zaproponowany przez nich system może służyć jako pomocne narzędzie dla inwestorów. Skuteczność stosowania systemów rozmytych w finansach potwierdzili również (Gandhmal, Kumar, 2019) oraz (Kumbure i inni 2022), którzy w przeglądzie sposobów uczenia maszynowego do prognozowania rynku akcji wskazali na znaczący udział technik z wykorzystaniem logiki rozmytej.

Mnogość artykułów z zastosowaniem logiki rozmytej w prognozowaniu, podejmowaniu decyzji inwestycyjnych i optymalizacji portfela oraz obiecujące wyniki empiryczne przedstawiane w pracach naukowych sugerują, że odejście od wskazań punktowych na rzecz rozmytych może przynieść wymierne korzyści z inwestycji.

5. Metoda neuronowo-rozmyta

Wnioski płynące z badań literaturowych, sugerujące możliwość poprawy prognoz – z jednej strony poprzez wykorzystanie sieci neuronowych, a z drugiej – poprzez ich rozmywanie, zainspirowały mnie do wykorzystania zalet obu podejść i stworzenia własnej propozycji metody prognostycznej. W moim badaniu wykorzystuję trzy sieci neuronowe: MLP, ELM i LSTM, szczegółowo opisane w rozdziale II. Stosując różną hiperparametryzację każdej sieci, stawiam prognozy tego samego kursu walutowego, a następnie rozmywam je.

W metodzie wyróżniam trzy kroki:

1. Prognozuję kurs walutowy na dany dzień z wykorzystaniem różnych sieci neuronowych. Prognozy stawiam niezależnie od siebie.
2. Agreguję prognozy w jedną liczbę rozmytą.

3. Stawiam prognozę kierunku zmian kursu na podstawie liczby rozmytej i bieżącego kursu.

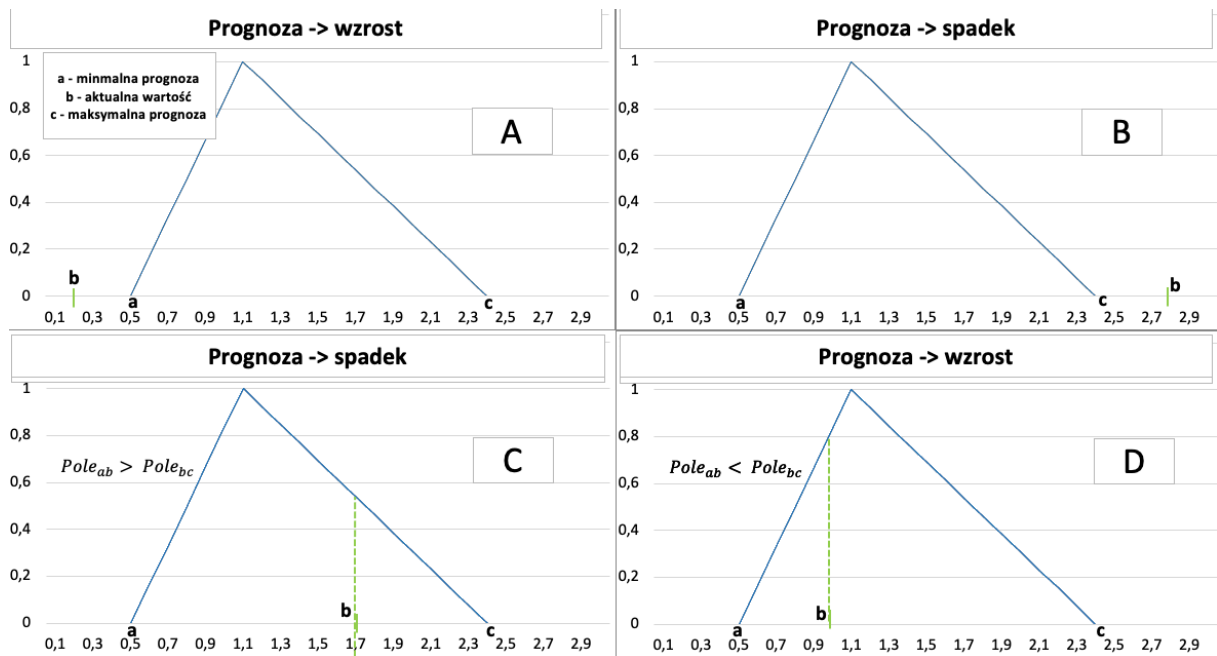
Dla kroku trzeciego możliwe są dwa przypadki:

- Przypadek A – dla wartości kursu w dniu stawiania prognozy funkcja przynależności przyjmuje wartość równą 0 – kurs jest mniejszy od a lub większy od c - rysunek 34. A i B.
- przypadek B – dla kursu w dniu stawiania prognozy funkcja przynależności przyjmuje wartość różną od 0 – kurs znajduje się między a i c - rysunek 34. C i D.

W przypadku A – jeżeli cena z dnia podejmowania decyzji jest mniejsza niż minimalna wartość nośnika (Rysunek 34. A) to prognozowany jest wzrost, natomiast jeżeli jest większa niż maksymalna wartość nośnika, to prognozowany jest spadek (Rysunek 34. B).

W przypadku B, gdy cena w dniu podejmowania decyzji znajduje się na nośniku liczby rozmytej, kierunek prognozy ustalany jest na podstawie pola powierzchni pod figurą utworzoną przez funkcję przynależności. Jeżeli większe jest pole po lewej stronie od kursu w dniu stawiania prognozy – metoda neuronowo-rozmyta prognozuje jego spadek (Rysunek 34. C), jeżeli po prawej – wzrost (Rysunek 34. D).

W celu zobrazowania wszystkich możliwych wariantów, na rysunku 34. przedstawiono możliwe sytuacje wraz z prognozą stawianą w metodzie neuronowo-rozmytej. W przykładzie użyto trójkątnej funkcji przynależności. Zielonym kolorem zaznaczono teoretyczną cenę z dnia podejmowania decyzji (b), a figura zaznaczona niebieskim konturem odpowiada kształtowi trójkątnej funkcji przynależności o podstawie ac , gdzie a (c) to minimalna (maksymalna) prognozowana cena przez sieci neuronowe.



Rysunek 34. Schemat działania podejmowania decyzji z wykorzystaniem logiki rozmytej

Źródło: opracowanie własne

Zwracam uwagę na to, że w moim podejściu wykorzystuję trzy typy sieci, z których tylko jeden stosowany jest w praktyce z powodzeniem do prognozowania szeregów czasowych. Zdecydowałem się uwzględnić też prostsze typy sieci, żeby zweryfikować, czy agregacja ich prognoz pozwoli na uzyskanie trafniejszych wyników, przy jednoczesnej oszczędności mocy obliczeniowej. Zaproponowane podejście wpisuje się w tak zwany nurt uczenia zespołowego (ang. *ensemble learning*), polegający na łączeniu podstawowych modeli w celu stworzenia jednego optymalnego modelu predykcyjnego.

6. Metoda neuronowo-rozmyta a inne podejścia łączące sieci neuronowe i zbiory rozmyte

Należy w tym przypadku zauważyć, że w literaturze istnieją już inne metody łączące sieci neuronowe i zbiory rozmyte. Najczęściej spotykanym jest podejście hybrydowe łączące sieci neuronowe z zbiorami rozmytymi w rozmyte sieci neuronowe. Obszernego przeglądu literatury w tym obszarze dokonał (de Campos Souza, 2020) przedstawiając ewolucję tego podejście od początków jego istnienia do najnowszych publikacji. (Aliev i inni, 2009) podkreśla istnienie dwóch różnych strategii innych niż rozmyte sieci neuronowe:

- systemy neuronowo-rozmyte (ang. *neuro-fuzzy systems*) – których głównym zadaniem jest przetwarzanie zależności liczbowych,

- rozmyte systemy neuronowe (ang. *fuzzy neural systems*) – które przetwarzają zarówno informacje numeryczne, jak i dane oparte na wiedzy, reprezentowane jako liczby rozmyte.

Działanie systemu neuronowo-rozmytego przedstawione zostało między innymi w pracy (Lee, Teng, 2000). Autorzy wykorzystali rekurencyjną wielowarstwową sieć neuronową (RFNN ang. *recurrent fuzzy neural network*) do wnioskowania rozmytego z zastosowaniem dynamicznych reguł rozmytych. Metoda ta może być stosowana do identyfikacji i sterowania nieliniowymi systemami dynamicznymi. Natomiast przykładem wykorzystania rozmytego systemu neuronowego jest praca (Hayashi, Buckley, Czogala, 1993), w której autorzy zastosowali w sieci neuronowej sygnały oraz wagi będące zbiorami rozmytymi.

(Nauck, Klawonn, Kruse, 1997) wskazują na trzy typy systemów neuronowo-rozmytych.

1. Kooperacyjny system neuronowo-rozmyty – podzielony jest na fazy, w których zarówno sztuczna sieć neuronowa, jak i system rozmyty, działają niezależnie od siebie. System taki może działać następująco – w pierwszej fazie sieć neuronowa uczy się zbioru rozmytego na podstawie danych treningowych. Zazwyczaj odbywa się to przez dopasowanie funkcji przynależności do sieci neuronowej. Następnie wyznaczane są zbiory rozmyte, które wykorzystuje się do tworzenia systemu neuronowo-rozmytego.
2. Konkurencyjny system neuronowo-rozmyty – sieć neuronowa i system rozmyty pracują razem w sposób ciągły.
3. Hybrydowy system neuronowo-rozmyty – sieć neuronowa jest wykorzystywana do uczenia się tylko niektórych parametrów systemu rozmytego w sposób iteracyjny.

Podsumowując, systemy neuronowo-rozmyte łączą ze sobą dwa podejścia – neuronowe oraz rozmyte – w celu uzyskania informacji ostrej, natomiast rozmyte systemy neuronowe łączą ze sobą te same dwa podejścia, aby odwzorować dane wejściowe na dane wyjściowe w sposób rozmyty.

Rozmyte sieci neuronowe (FNN ang. *fuzzy neural networks*) działają na zasadach współpracy sieci neuronowych odpowiedzialnych za prognozowanie oraz logiki rozmytej stosowanej w celu ułatwienia interpretowalności uzyskanych wyników. (Pedrycz, 1991) główną zaletę tych sieci upatruje w zdolnościach uczenia się (sieci neuronowe) oraz umiejętności interpretowania niepewności (logika rozmyta). Hybrydowe podejście łączące sieci neuronowe i logikę rozmytą ma na celu niwelowanie wad oraz korzystanie z zalet obu tych podejść złączonych w jeden system. W związku z tym, odnosząc się do podziału powyżej, sieci FNN można uznać za system

rozmyty, którego trenowanie odbywa się z wykorzystaniem sieci neuronowej. Przy tym w FNN neurony wewnątrz sieci są neuronami rozmytymi.

Stosowanie FNN w dziedzinie prognozowania danych finansowych jest bardzo popularne. (Vlasenko i inni, 2018) prognozowali logarytmiczne stopy zwrotu dla indeksów IBM oraz S&P 500 uzyskując wyższą dokładność i wydajność obliczeniową niż w przypadku konkurencyjnych modeli. Zaproponowane w tym badaniu podejście charakteryzuje się wykorzystaniem wielowariantowego modelu neuronowo-rozmytego, składającego się z 5 warstw, wykorzystujących logikę rozmytą do generowania wyników. W FNN stosowane mogą być różne typy sieci neuronowych. Przykładowo, (Huang, Oh, Pedrycz, 2017) zastosowali połączenie wielomianowych sieci neuronowych (PNN – ang. *polynomial neural networks*) i neuronów falkowych opartych na wnioskowaniu rozmytym (FIWN – ang. *fuzzy inference-based wavelet neurons*). Autorzy badania wykazali skuteczność tej metody na przykładzie danych finansowych, poprzez porównanie jej możliwości prognostycznych z innymi modelami. (Garcia i inni, 2018) wykorzystali hybrydowe sieci neuronowe do prognozowania niemieckiego indeksu DAX30. Model stosowany w tym badaniu to HyFIS (ang. *Hybrid Neural Fuzzy Inference System*), który wykorzystuje zmienne lingwistyczne. Uczenie w tym modelu składa się z dwóch faz: fazy generowania reguł na podstawie danych oraz fazy dostrajania reguł za pomocą schematu uczenia się z wsteczną propagacją błędów dla neuronowego systemu rozmytego. O skuteczności metody FNN świadczą przeglądy literatury, takie jak: (Mohd Adnan i inni, 2015), (Murmu, Biswas, 2015), (Zahedi i inni, 2014) lub (Knezevic i inni, 2018).

Porównując metodę neuronowo-rozmytą stworzoną i wykorzystaną w niniejszej rozprawie z FNN można wskazać, że moja metoda neuronowo-rozmyta stosuje logikę rozmytą poza siecią neuronową. Dodatkowo, korzystam z podejścia wynikającego z nurtu *ensemble learning*. W tym badaniu działanie to polega na łączeniu ze sobą różnych modeli (zaprognozowanych kierunków zmian za pomocą różnych typów sieci neuronowych o różnych kombinacjach parametrów) w celu stworzenia (dzięki logice rozmytej) jednej optymalnej prognozy kierunku zmiany.

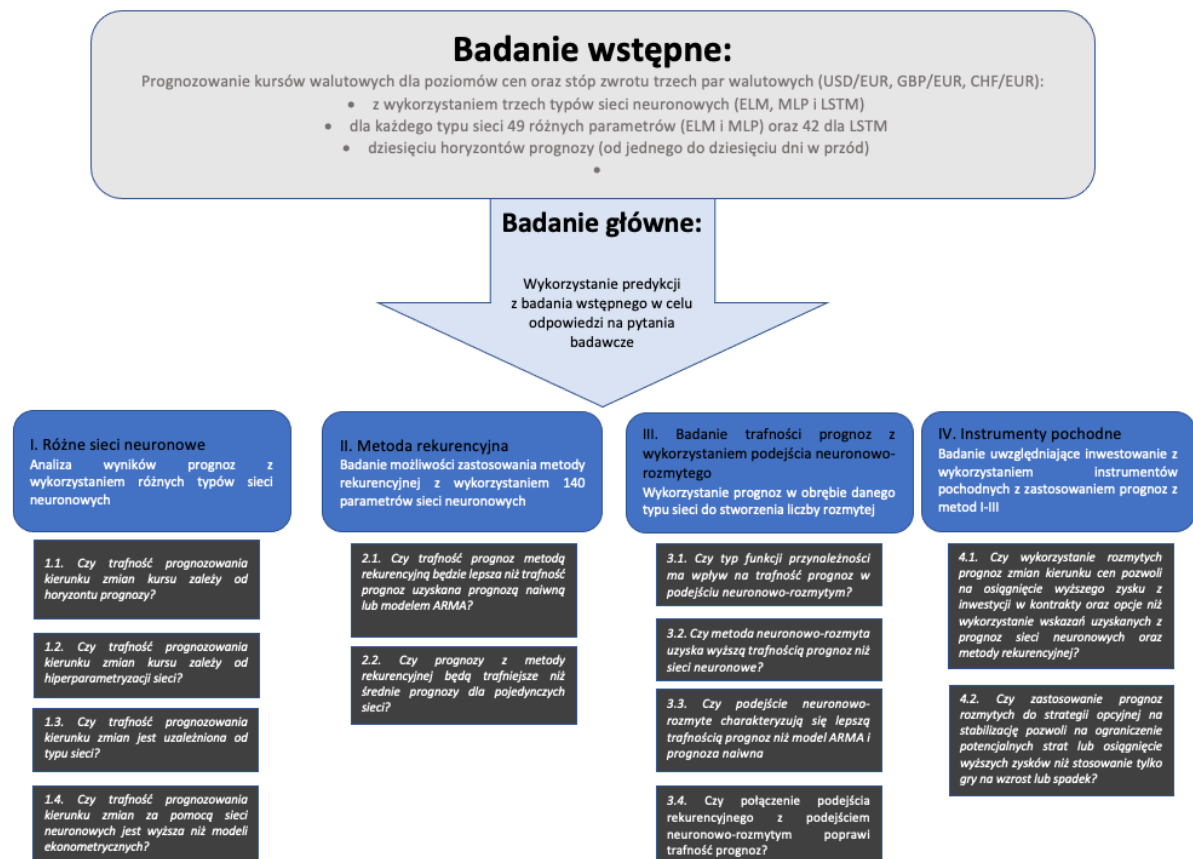
Rozdział IV. Badanie możliwości poprawy trafności prognoz zmian kursów walutowych z wykorzystaniem podejścia neuronowo-rozmytego

Głównym celem mojej pracy jest zbadanie możliwości uzyskania ponadprzeciętnej trafności prognoz kierunku zmian kursów walutowych z autorskiego podejścia neuronowo-rozmytego, a w kolejnym etapie - ponadprzeciętnych zysków z inwestycji w strategię opcyjnie z wykorzystaniem tego podejścia. W tym rozdziale koncentruję się na możliwości uzyskania jak najlepszej jakości prognoz, przy czym interesuje mnie nie tyle ich dokładna wartość, ile poprawnie wyznaczony kierunek zmiany. Jako punkt odniesienia (benchmark) do prognoz uzyskanych za pomocą sieci neuronowych i podejścia neuronowo-rozmytego, przyjąłem prognozy uzyskane z modeli ekonometrycznych typu ARMA oraz prognozy naiwne.

Jak już wspominałem, skupiam się na dwóch metodach oceny jakości proponowanego podejścia:

- W pierwszej części (Rozdział IV) ocenie podlega trafność kierunku prognoz. Trafność ta rozumiana jest jako procentowy udział poprawnych prognoz w ogólnej liczbie postawionych, dla danego szeregu i przy danych parametrach sieci.
- W drugiej części (Rozdział V) oceniam czy mogę osiągnąć ponadprzeciętny zysk z inwestycji w określoną strategię opcyjną, jeśli będę kierował się prognozami uzyskanymi w części pierwszej badania empirycznego. Jeżeli metoda prognozuje wzrost (spadek) ceny danej pary walutowej w stosunku do ceny z dnia, w którym stawiam prognozę, to podejmowaną decyzją jest inwestycja we wzrost (spadek). Następnie rozszerzam zakres dopuszczalnych decyzji o możliwość inwestowania w stabilizację przy prognozowaniu „małego wzrostu” lub „małego spadku”. Celem badań przedstawionych w drugiej części pracy jest sprawdzenie czy podejmowanie decyzji na podstawie prognoz uzyskanych z podejścia neuronowo-rozmytego oraz rekurencyjnego daje wyższy zysk, niż wykorzystanie prognoz samych sieci neuronowych.

Koncepcja oraz poszczególne etapy badania wraz z pytaniami badawczymi zaprezentowane są na rysunku 35. natomiast opis poszczególnych metod znajduje się w tabeli 3.



Rysunek 35. Opis badania wraz z pytaniami badawczymi

Źródło: opracowanie własne

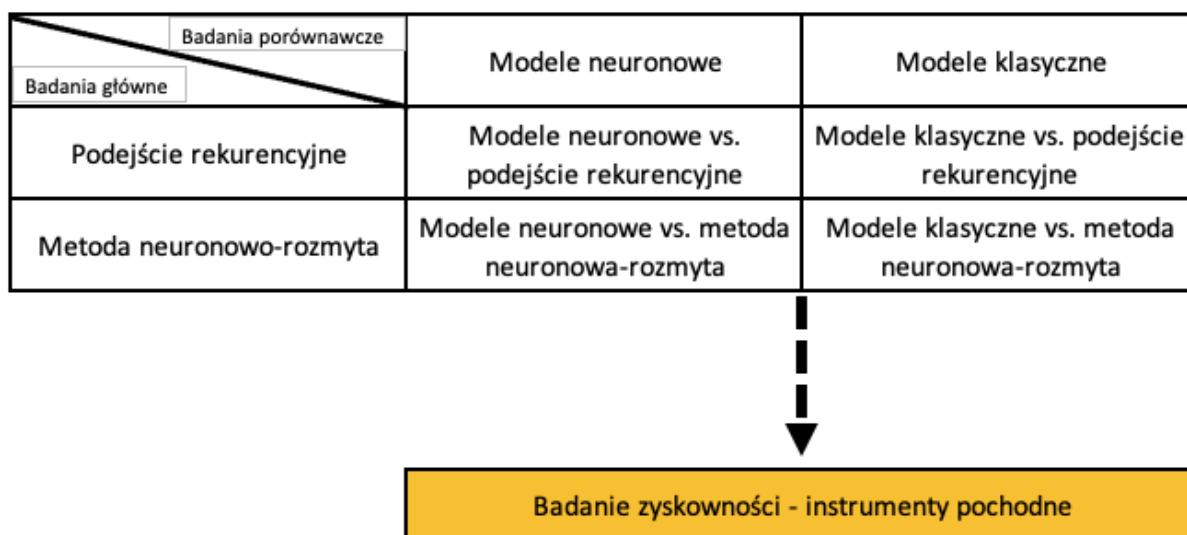
Tabela 3. Opis stosowanych metod w badaniu empirycznym

Nazwa metody		Opis
Prognozowania sieciami		Prognozowanie z wykorzystaniem trzech typów sieci – ELM, MLP oraz LSTM do prognozowania na horyzont od 1 do 10 dni z wykorzystaniem w sumie 140 różnych parametrów sieci neuronowych.
Metoda rekurencyjna	Typ 1	W tej metodzie dzielę próbę uczącą na 11 równych interwałach, co oznacza, że każdy z nich składa się z 131 dni. Następnie oceniam trafność prognoz policzonych dla pierwszej podpróby, a następnie (w kolejnych podpróbach) wykorzystuję tylko sieci o wybranych hiperparametrach, które w poprzednim okresie stawiały najtrafniejsze prognozy.
	Typ 2	Typ 2 metody rekurencyjnej polega na jednokrotnym wyborze parametrów, które uzyskały najlepszą trafność w pierwszym okresie.
Metoda neuronowo-rozmyta		Autorskie podejście do poprawy jakości prognoz poprzez ich rozmycie. Wykorzystanie wszystkich lub niektórych z 140 prognoz uzyskanych za pomocą sieci neuronowych o różnych hiperparametrach w celu wygenerowania jednej prognozę.

1. Schemat badania oraz pytania badawcze

Do każdego etapu badania empirycznego przypisano odpowiednie pytania badawcze, przedstawione we wstępie. Przytaczam je w odpowiednich podrozdziałach, dotyczących poszczególnych składowych badania.

W celu wskazania wszystkich powiązań między kolejnymi etapami badania oraz ich chronologią, na rysunku 36. przedstawiam schemat procesu badawczego. W pierwszym wierszu wymieniam metody stanowiące benchmark, czyli modele klasyczne oraz prognozowanie z wykorzystaniem sieci neuronowych (krok 1). Pierwsza kolumna odnosi się do drugiego kroku badania, w którym prezentuję dwa kolejne podejścia do stawiania prognoz kierunku zmian kursu: podejście rekurencyjne oraz autorską metodę neuronowo-rozmytą. tabelę z rysunku 36. należy interpretować jako macierz, gdzie na przecięciu wierszy oraz kolumn zaprezentowano badania porównawcze między danymi metodami (krok 3). Wyjście z tabeli do pomarańczowego elementu stanowi 4 krok badania, którym jest badanie zyskowności dla wszystkich metod zawartych w macierzy.



Rysunek 36. Schemat badania

Źródło: opracowanie własne

1.1. Badanie wpływu ustawień sieci neuronowych na jakość prognoz kierunku zmian kursu walutowego

W pierwszej części badania (lewa skrajna kolumna na rysunku 36) wykorzystuję do prognozowania kierunku zmian kursów walutowych trzy różne typy sieci neuronowych

opisane szczegółowo w rozdziale III – są nimi ELM, MLP oraz LSTM. Prognozy stawiam na dziesięć różnych horyzontów (od 1 do 10 dni), przy czym dla każdego horyzontu prognozy porównuję wyniki uzyskane dla sieci o różnych hiperparametrach (różnej liczbie warstw ukrytych i różnej liczbie opóźnień). W efekcie dla każdego dnia stawiam prognozę wykorzystując 140 różnych ustawień trzech różnych typów sieci neuronowych: dla sieci ELM i MLP otrzymuję kombinację 49 prognoz, a dla LSTM – 42.

Jako prognozę rozumiem wskazanie kierunku dalszych zmian kursu walutowego: wzrost, spadek lub stabilizację. Prognozy kierunku zmian, uzyskane w ten sposób, posłużą za punkt wyjścia do dalszych badań.

Pytania badawcze, na które poszukuję odpowiedzi w tej części badania to:

- 1.1. Czy trafność prognozowania kierunku zmian kursu zależy od horyzontu prognozy?
- 1.2. Czy trafność prognozowania kierunku zmian kursu zależy od hiperparametryzacji sieci?
- 1.3. Czy trafność prognozowania kierunku zmian kursu jest uzależniona od typu sieci?
- 1.4. Czy trafność prognozowania kierunku zmian kursu za pomocą sieci neuronowych jest wyższa niż modeli ekonometrycznych?

1.2. Badanie możliwości poprawy jakości prognoz z wykorzystaniem metody rekurencyjnej

W drugim etapie badania (wiersz pierwszy na rysunku 36.) sprawdzam trafność prognoz z wykorzystaniem metody rekurencyjnej. W tej metodzie dzielę próbę uczącą na 11 równych interwałów, co oznacza, że każdy z nich składa się z 131 dni. Następnie oceniam trafność prognoz policzonych dla pierwszej podpróby, a następnie (w kolejnych podpróbach) wykorzystuję tylko sieci o wybranych hiperparametrach, które w poprzednim okresie stawały najtrafniejsze prognozy. Celem tego badania jest znalezienie odpowiedzi na pytanie, czy można wskazać uniwersalne ustawienia sieci, dające najlepsze wyniki prognoz kierunku zmian kursów walutowych, niezależnie od sytuacji panującej na rynku.

W badaniu uwzględniam dwa scenariusze. W pierwszym wybieram najlepsze ustawienia na podstawie wyników uzyskanych w pierwszej podpróbie i w kolejnych okresach prognozuję tylko z wykorzystaniem wskazanych typów i parametrów sieci. W drugim scenariuszu wybór najlepszych hiperparametrów następuje w każdym interwale, zawsze na podstawie wyników prognoz z poprzedniego interwału. Dzięki takiemu działaniu w kolejnym okresie t_3 wybrane

mogą zostać sieci o innych parametrach, to jest te, które osiągnęły najlepsze wyniki w okresie t_2 .

Na tym etapie badania poszukuję odpowiedzi na następujące pytania badawcze:

2.1. Czy trafność prognoz uzyskanych metodą rekurencyjną będzie lepsza niż trafność prognoz uzyskana prognozą naiwną lub modelem ARMA?

2.2. Czy prognozy z metody rekurencyjnej będą trafniejsze niż średnie prognozy dla pojedynczych sieci?

1.3. Badanie możliwości poprawy jakości prognoz z wykorzystaniem logiki rozmytej

W trzecim etapie badania (wiersz drugi na rysunku 36.) proponuję autorskie podejście do poprawy jakości prognoz poprzez ich rozmycie. Ze 140 prognoz uzyskanych za pomocą sieci neuronowych o różnych hiperparametrach, tworzę jedną prognozę rozmytą.

W etapie trzecim poszukuję odpowiedzi na następujące pytania badawcze:

3.1. Czy typ funkcji przynależności ma wpływ na trafność prognoz w podejściu neuronowo-rozmytym?

3.2. Czy metoda neuronowo-rozmyta cechuje się wyższą trafnością prognoz niż sieci neuronowe?

3.3. Czy metoda neuronowo-rozmyta charakteryzuje się wyższą trafnością prognoz niż model ARMA i prognoza naiwna?

3.4. Czy połączenie podejścia rekurencyjnego z podejściem neuronowo-rozmytym poprawi trafność prognoz?

2. Opis oraz charakterystyka danych

W badaniu empirycznym analizuję trzy różne pary walutowe. Walutą odniesienia jest euro (EUR), natomiast walutami kwotowanymi są frank szwajcarski (CHF), funt brytyjski (GBP) oraz dolar amerykański (USD). Zakres czasowy badania obejmuje lata 1.01.2014-31.12.2019³. Dane są kwotowane w częstotliwości dziennej, co daje mi łącznie 1440 obserwacji na jedną parę walutową. Tak dobrany okres analizy obejmuje dla każdej waluty momenty wzrostowe, spadkowe oraz charakteryzujące się względną stabilizacją. Istotne z punktu widzenia

³ W badaniu z wykorzystaniem instrumentów pochodnych, zbiór danych został powiększony o jeden rok, w związku z koniecznością wyliczenia zmienności na podstawie danych historycznych, niezbędnej w modelu Blacka-Scholesa.

prognozowania są również nagłe gwałtowne zmiany kursu walutowego spowodowane sytuacją gospodarczą, polityczną lub innymi czynnikami.

W przypadku funta brytyjskiego okres ten obejmuje lata, w których decyzje polityczni w Wielkiej Brytanii przygotowywali się do opuszczenia Unii Europejskiej (Brexit) oraz moment, w którym Wielka Brytania ostatecznie opuściła Unię Europejską. Okres ten nie obejmuje bezpośrednio dnia opuszczenia Unii przez Wielką Brytanię (31.01.2020 r.), ale podjęcie decyzji o opuszczeniu Unii oraz sam proces jej opuszczania wiązał się z niepewnością, która generowała wahania na kursie walutowym GBP/EUR.

Dla waluty CHF/EUR istotnym momentem jest gwałtowna zmiana z dnia 15.01.2015 r. – kurs zamknięcia dnia 14.01.2015 r. wynosił 0,833 a w dniu 15.01.2015 1,001 co daje zmianę na poziomie ok. 20%. Dzień ten nazywany jest czarnym czwartkiem, a tak gwałtowna zmiana kursu była wynikiem ogłoszenia przez Szwajcarski Bank Narodowy zaprzestania stosowania polityki obrony minimalnego kursu wymiany euro na franka szwajcarskiego. Frank szwajcarski uznawany był za bezpieczną walutę w okresie kryzysu, przez co Szwajcarski Bank Centralny postanowił usztywnić swój kurs w stosunku do euro w 2011 roku. Zaprzestanie prowadzenia tej polityki spowodowało panikę na rynkach i duże wahania kursów wielu par walutowych.


Za walutę o najmniejszych wahaniami należy uznać USD/EUR. Dodatkowo, wybrane kursy różnią się między sobą częstością występowania skoków, które stanowią wyzwanie dla tradycyjnie używanych modeli ekonometrycznych. Badanie empiryczne przeprowadzam zarówno dla cen (poziomów), jak i dla stacjonarnych zwrotów logarytmicznych. W tabeli 4. przedstawiam charakterystyki badanych szeregów. Szczególną uwagę zwraca bardzo wysoka kurtoza dla GBP/EUR co świadczy o występowaniu licznych skoków w tym szeregu.

Tabela 4. Charakterystyka danych par walutowych

Para walutowa	Średnia arytmetyczna	Odchylenie standardowe	Skośność	Kurtoza
CHF/EUR	-0,00011	0,00492	0,07852	2,38802
GBP/EUR	-0,00007	0,00558	-1,26697	15,24767
USD/EUR	0,00006	0,00515	-0,02394	2,70457

Uwaga: wybrane charakterystyki wyliczone zostały dla stóp zwrotu. Skośność, gdy przyjmuje wartość bliską 0, świadczy o braku asymetrii rozkładu, powyżej 0 świadczy o prawostronnej asymetrii, a wyniki poniżej 0 o lewostronnej asymetrii rozkładu. Przedstawiona kurtoza jest kurtozą nadwyżkową. W każdym przypadku kurtoza jest wyższa od kurtozy rozkładu normalnego, a zdecydowanie najwyższy wynik został osiągnięty dla kursu GBP.

Na wykresie 37. prezentuję kształtowanie się kursów walutowych dla wszystkich trzech par walutowych badanym okresie.



Rysunek 37. Kształtowanie się kursów walutowych w latach 2014-2019


Zauważamy, że (jak wspomniano powyżej):

- wszystkie pary walutowe posiadają okresy wzrostowe i spadkowe oraz takie, które charakteryzują się względną stabilnością. Obserwujemy na przykład:
 - tendencję wzrostową w pierwszym roku badania dla USD/EUR (ok. 20 centów w ciągu roku – co przekłada się na wzrost rzędu 12%) oraz GBP/EUR (ponad 20 centów od początku 2014 roku do połowy 2015 roku – zmiana o prawie 20%),
 - tendencję spadkową pary CHF/EUR, do 15.01.2015 r.,
 - powrót kursu CHF/USD do wartości zbliżonych do tych występujących przed czarnym czwartkiem 2015 roku, zaledwie w ciągu kilku tygodnie po korekcie w dniu 15.01.2015 r.,
 - wyraźny okres spadkowy dla GBP/EUR od kursu 1,4 do kursu poniżej 1,1 między połową 2015 a początkiem 2017 roku,
 - względną stabilizację na rynkach dla wszystkich par walutowych w roku 2019.
- na wykresie przedstawiającym kurs CHF/EUR bardzo widoczna jest gwałtowna zmiana ceny na początku 2015 roku.


Na wykresach 38-40 przedstawiam kształtowanie się logarymicznych stóp zwrotu z jednodniowych cen zamknięcia, zgodnie ze wzorem:

$$r_t = \ln \frac{p_t}{p_{t-1}} \cdot 100,$$


gdzie r_t to logarymiczna stopa zwrotu w chwili t , a p_t to kurs pary walutowej w chwili t .



Rysunek 38. Logarymiczne stopy zwrotu dla CHF/EUR w latach 2014-2019



Rysunek 39. Logarymiczne stopy zwrotu dla GBP/EUR w latach 2014-2019



Rysunek 40. Logarytmiczne stopy zwrotu dla USD/EUR w latach 2014-2019

3. Prognozowanie kierunku zmian kursu walutowego z wykorzystaniem sieci MLP, ELM i LTSM

W tym podrozdziale przedstawione zostaną wyniki badań empirycznych, zgodnie ze schematem z rysunku 36. Przedstawiam kolejne etapy badania empirycznego, a następnie dokonuję porównań do benchmarku (ARMA oraz prognoza naiwna) oraz do innych metod będących podstawą niniejszej rozprawy (zgodnie z rysunkiem 36.).

3.1. Oznaczenia i kluczowe pojęcia

W podrozdziałach opisujących wyniki badań przyjęto następujące oznaczenia dla ustawień sieci neuronowych:

$$hd_a lags_b \text{ dla } a \in (1,7) \text{ i } b \in (1,7),$$

gdzie:

- hd_a (ang. *number of hidden nodes*) oznacza liczbę węzłów ukrytych i przyjmuje wartości (2,5,10,15,20,25,50),
- $lags_b$ (ang. *number of lags*) oznacza liczbę opóźnień zastosowanych w sieci neuronowej i przejmuje wartości (1,2,3,4,5,6,7),
- a i b opisują kombinacje możliwych ustawień analizowanej sieci neuronowej.

Liczba węzłów ukrytych nie jest ciągiem kolejnych liczb naturalnych, ale wzrasta o 5 (a w ostatnim przypadku o 25). Takie podejście ma na celu znalezienie optymalnej liczby węzłów i zbadanie zależności wyników prognozy od tego parametru. Dzięki takim ustawieniom, w

pracy udzielono odpowiedzi na pytanie, czy zwiększanie liczby węzłów ukrytych ma pozytywny wpływ na wyniki sieci neuronowych, a jeśli tak, to do jakiego poziomu optaca się je zwiększać, aby korzyści z poprawy wyników były większe niż wzrost obciążenia obliczeniowego. Stosowanie liczby opóźnień w zakresie od jednego do siedmiu wynika z charakteru badań nad rynkami finansowymi – zob. na przykład (Walczak, 2001).

Prognoz sieciami neuronowymi dokonano zarówno na logarytmicznych stopach zwrotu jak i poziomach kursów dla wszystkich trzech par walutowych w dziesięciu różnych horyzontach czasu i dla wszystkich (w sumie 140) ustawień sieci neuronowych (49 ELM i MLP oraz 42 LSTM). W pierwszej fazie badania sprawdzono i porównano ze sobą trafność prognozowania dla sieci neuronowych uczących się na stopach zwrotu oraz poziomach cen. Trafność prognoz opisywana jest jako procentowy udział poprawnych prognoz kierunku zmiany kursu paru walutowej do ogólnej liczby prognoz dla danego ustawienia sieci neuronowej.

3.2. Wpływ ustawień sieci neuronowych na trafność prognozowania kierunku zmiany kursu walutowego

Podrozdział ten przedstawia wyniki ukazujące szczegółowo, jaki poziom trafności uzyskały badane metody wykorzystujące poszczególne ustawienia parametrów sieci neuronowych z podziałem na pary walutowe oraz horyzont inwestycji. W dziewięciu tabelach przedstawiono wyniki trafności prognoz dla trzech par walutowych CHF/EUR, GBP/EUR i USD/EUR i trzech rodzajów sieci ELM, MLP oraz LSTM. Tabele zawierają 49 kombinacji ustawień dla sieci ELM i MLP oraz 42 dla LSTM oraz 10 różnych horyzontów na jakie prognozy zostały sporządzone.

W tabelach 5-7 przedstawiono trafność prognoz dla sieci ELM prognozującej na poziomach cen dla wszystkich par walutowych. We wszystkich tabelach w tych podrozdziale zaznaczono niebieską czcionką wartości powyżej 50%. Wartość maksymalna w danej kolumnie została wypełniona kolorem zielonym, a minimalna kolorem czerwonym.

Tabela 5. Wyniki trafności prognoz dla sieci ELM i pary walutowej GBP/EUR na poziomach cen

	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10
hd1lags1	49,79%	48,75%	48,34%	48,27%	47,09%	47,71%	46,05%	46,53%	46,53%	45,91%
hd1lags2	49,51%	48,54%	48,54%	47,92%	47,50%	47,36%	47,23%	46,19%	46,67%	45,70%
hd1lags3	49,38%	49,03%	47,92%	47,43%	47,99%	47,85%	46,95%	47,64%	46,39%	46,26%

hd1lags4	49,51%	47,30%	48,47%	47,30%	46,74%	47,16%	46,88%	46,53%	46,26%	45,77%
hd1lags5	49,10%	47,57%	47,50%	48,75%	46,81%	47,36%	46,60%	46,60%	46,26%	45,63%
hd1lags6	49,03%	47,57%	47,57%	47,64%	48,47%	47,78%	46,74%	46,32%	45,63%	45,70%
hd1lags7	49,51%	47,36%	47,85%	48,06%	47,71%	48,68%	46,74%	47,36%	46,60%	45,84%
hd2lags1	49,86%	48,89%	48,54%	48,61%	47,43%	47,78%	46,67%	46,74%	46,67%	46,39%
hd2lags2	49,79%	48,68%	48,96%	48,40%	47,99%	47,71%	47,23%	46,53%	46,74%	46,32%
hd2lags3	49,72%	48,96%	48,13%	47,71%	47,92%	47,92%	47,02%	47,50%	46,81%	46,53%
hd2lags4	49,93%	47,16%	48,54%	47,64%	46,88%	47,64%	47,02%	46,46%	46,39%	46,32%
hd2lags5	48,75%	47,78%	47,57%	48,89%	46,81%	46,95%	46,46%	46,60%	45,49%	45,63%
hd2lags6	49,24%	47,16%	47,99%	47,92%	48,40%	47,57%	46,88%	46,26%	45,63%	45,70%
hd2lags7	49,31%	47,16%	47,43%	47,36%	47,30%	47,99%	46,95%	47,09%	46,39%	45,56%
hd3lags1	49,79%	48,96%	48,47%	48,54%	47,50%	47,57%	46,46%	46,81%	46,60%	46,60%
hd3lags2	49,38%	48,89%	49,03%	48,20%	48,27%	47,92%	47,30%	46,88%	46,26%	46,67%
hd3lags3	49,51%	48,47%	48,27%	47,78%	48,47%	48,13%	47,09%	47,09%	47,02%	46,39%
hd3lags4	49,93%	47,57%	48,82%	48,20%	47,71%	47,78%	47,36%	46,88%	46,67%	46,39%
hd3lags5	48,61%	47,36%	48,34%	48,75%	46,88%	47,23%	47,02%	46,88%	45,70%	45,77%
hd3lags6	49,24%	47,36%	47,64%	47,64%	48,27%	47,02%	46,81%	46,32%	46,26%	45,91%
hd3lags7	49,51%	47,30%	47,50%	47,09%	47,50%	48,75%	47,23%	47,57%	46,88%	46,26%
hd4lags1	49,93%	48,96%	48,75%	48,54%	47,78%	47,71%	46,60%	46,95%	46,88%	46,88%
hd4lags2	49,45%	48,96%	49,51%	48,27%	48,54%	47,57%	47,23%	46,95%	46,39%	46,74%
hd4lags3	49,45%	48,61%	48,27%	48,34%	48,40%	48,20%	47,02%	46,88%	47,09%	46,46%
hd4lags4	49,72%	47,57%	48,89%	47,99%	47,57%	47,99%	47,30%	47,23%	46,67%	46,26%
hd4lags5	48,96%	47,30%	48,34%	48,47%	47,09%	47,50%	47,16%	46,74%	45,49%	46,19%
hd4lags6	49,58%	47,30%	47,36%	47,78%	48,27%	47,09%	47,02%	46,39%	46,19%	45,98%
hd4lags7	49,79%	47,09%	47,30%	47,09%	47,36%	49,10%	47,50%	47,92%	47,30%	46,67%
hd5lags1	49,72%	49,03%	48,96%	48,89%	47,71%	47,64%	46,95%	47,02%	46,95%	46,95%
hd5lags2	49,58%	49,24%	49,58%	48,27%	48,54%	47,85%	47,30%	47,09%	46,53%	46,74%
hd5lags3	49,65%	48,40%	48,54%	48,13%	48,40%	48,34%	46,95%	47,02%	47,09%	46,39%
hd5lags4	49,58%	47,78%	49,31%	48,40%	47,78%	48,27%	47,71%	47,16%	46,88%	46,53%
hd5lags5	49,03%	47,43%	48,13%	48,47%	46,95%	47,50%	47,02%	46,88%	45,84%	45,84%
hd5lags6	49,65%	47,30%	47,09%	47,78%	48,47%	46,88%	47,30%	46,39%	46,12%	45,84%
hd5lags7	49,31%	47,43%	47,16%	47,23%	47,36%	48,96%	47,50%	47,92%	47,43%	46,53%
hd6lags1	49,65%	48,82%	49,03%	48,68%	47,78%	47,85%	47,16%	47,36%	47,30%	47,16%
hd6lags2	49,65%	48,89%	49,45%	48,20%	48,61%	47,64%	46,95%	47,02%	46,74%	46,81%
hd6lags3	49,51%	48,82%	48,54%	48,20%	48,27%	48,47%	47,09%	47,02%	47,09%	46,53%
hd6lags4	49,65%	47,64%	49,17%	48,20%	47,50%	48,34%	47,43%	47,23%	46,81%	46,32%
hd6lags5	48,75%	47,50%	48,27%	48,13%	46,74%	47,64%	46,74%	46,81%	45,42%	45,98%
hd6lags6	49,65%	47,23%	47,09%	47,78%	48,40%	46,95%	47,02%	46,53%	46,32%	45,84%
hd6lags7	49,24%	47,43%	47,16%	46,81%	47,64%	48,54%	47,09%	47,78%	47,43%	46,39%
hd7lags1	49,93%	48,96%	49,31%	48,68%	47,92%	47,99%	47,30%	47,64%	47,43%	47,43%

hd7lags2	49,79%	49,17%	49,31%	47,92%	48,68%	47,92%	47,30%	47,43%	47,02%	46,95%
hd7lags3	49,86%	48,61%	48,68%	48,89%	48,54%	48,61%	47,43%	47,16%	47,23%	46,81%
hd7lags4	49,79%	47,57%	49,24%	48,34%	47,71%	48,27%	47,71%	47,02%	46,67%	46,32%
hd7lags5	49,03%	47,30%	48,54%	48,75%	46,67%	47,78%	46,60%	46,60%	45,84%	45,77%
hd7lags6	49,58%	47,50%	47,09%	47,36%	48,13%	46,19%	47,02%	46,74%	46,46%	46,12%
hd7lags7	49,24%	47,50%	47,43%	47,02%	47,36%	48,75%	46,74%	47,64%	47,30%	46,39%

Tabela 6. Wyniki trafności prognoz dla sieci ELM i pary walutowej CHF/EUR na poziomach cen

	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10
hd1lags1	51,04%	50,49%	52,08%	52,77%	53,33%	54,85%	54,37%	54,58%	54,09%	53,95%
hd1lags2	52,29%	50,42%	51,94%	52,43%	54,30%	54,51%	54,85%	54,23%	54,23%	53,61%
hd1lags3	51,46%	50,69%	51,87%	54,09%	54,51%	54,65%	54,23%	54,72%	54,09%	53,61%
hd1lags4	51,66%	49,72%	52,01%	52,64%	53,81%	54,99%	54,51%	54,16%	54,16%	53,68%
hd1lags5	52,77%	51,73%	53,19%	54,37%	53,12%	55,69%	55,20%	54,58%	54,30%	53,61%
hd1lags6	51,53%	52,43%	52,84%	53,74%	53,74%	54,16%	53,95%	54,23%	54,30%	53,54%
hd1lags7	51,87%	51,60%	53,19%	53,81%	54,09%	54,16%	53,88%	53,33%	54,09%	53,88%
hd2lags1	50,97%	50,69%	52,29%	53,12%	53,54%	54,92%	54,44%	54,51%	53,88%	53,47%
hd2lags2	52,15%	50,69%	51,94%	52,98%	54,16%	54,65%	54,58%	54,09%	53,88%	53,33%
hd2lags3	51,53%	50,90%	52,57%	54,23%	54,79%	55,20%	54,85%	54,58%	54,16%	53,88%
hd2lags4	51,39%	49,58%	51,39%	53,40%	53,40%	54,65%	53,88%	53,81%	53,47%	53,33%
hd2lags5	52,22%	51,60%	52,43%	53,74%	53,54%	54,30%	54,37%	53,95%	53,88%	53,12%
hd2lags6	51,18%	51,73%	52,29%	52,43%	53,47%	53,40%	53,19%	53,05%	53,74%	52,70%
hd2lags7	52,01%	50,90%	52,57%	53,19%	53,40%	53,40%	53,54%	52,98%	53,47%	53,47%
hd3lags1	51,04%	50,76%	52,36%	53,19%	53,47%	54,85%	54,37%	54,44%	53,81%	53,40%
hd3lags2	52,70%	50,69%	52,29%	52,98%	54,23%	54,79%	54,51%	54,09%	53,95%	53,05%
hd3lags3	51,73%	51,46%	52,70%	53,95%	54,37%	55,34%	55,06%	54,51%	54,16%	53,81%
hd3lags4	51,87%	50,14%	51,32%	52,84%	53,33%	54,23%	53,74%	52,84%	52,98%	53,05%
hd3lags5	52,36%	51,87%	52,57%	53,74%	53,68%	54,23%	53,88%	54,23%	54,23%	53,47%
hd3lags6	51,39%	51,32%	52,29%	52,84%	53,47%	53,54%	52,77%	52,64%	53,54%	52,29%
hd3lags7	52,22%	50,62%	51,80%	52,98%	52,91%	53,19%	53,26%	53,05%	53,81%	53,40%
hd4lags1	50,97%	50,83%	52,43%	53,26%	53,40%	54,79%	54,30%	54,37%	53,88%	53,47%
hd4lags2	52,84%	50,90%	51,87%	53,05%	54,37%	54,58%	54,58%	54,16%	53,61%	53,12%
hd4lags3	51,60%	51,39%	53,12%	54,09%	54,44%	55,20%	55,41%	54,72%	54,16%	53,61%
hd4lags4	51,94%	50,21%	51,18%	53,26%	53,33%	54,09%	54,09%	53,12%	53,26%	53,33%
hd4lags5	52,15%	51,87%	52,57%	53,81%	53,88%	54,23%	54,30%	53,74%	53,95%	53,54%
hd4lags6	51,46%	51,53%	52,50%	52,01%	53,19%	53,61%	52,77%	52,57%	53,61%	52,36%
hd4lags7	52,01%	50,42%	52,29%	52,91%	52,91%	53,26%	53,33%	53,47%	53,74%	53,47%
hd5lags1	51,11%	50,97%	52,43%	53,12%	53,26%	54,51%	54,16%	54,23%	54,02%	53,47%
hd5lags2	52,43%	50,83%	51,94%	53,26%	54,58%	54,92%	54,51%	54,37%	53,40%	53,19%

hd5lags3	52,08%	51,53%	52,98%	54,30%	54,72%	55,06%	55,13%	54,65%	54,30%	53,88%
hd5lags4	52,15%	49,93%	51,60%	53,54%	52,98%	53,68%	53,74%	53,26%	53,19%	53,19%
hd5lags5	52,57%	51,73%	52,64%	53,61%	54,09%	53,88%	54,37%	53,40%	53,88%	53,74%
hd5lags6	51,32%	50,97%	51,94%	52,57%	52,77%	53,12%	52,08%	52,01%	52,77%	51,11%
hd5lags7	52,08%	50,07%	51,87%	52,57%	52,98%	53,12%	53,40%	53,12%	53,81%	53,05%
hd6lags1	50,97%	50,83%	52,29%	52,98%	53,26%	54,65%	54,16%	54,51%	54,02%	53,61%
hd6lags2	53,05%	51,11%	51,94%	53,12%	54,58%	54,92%	54,65%	54,09%	53,68%	53,05%
hd6lags3	51,53%	51,60%	52,70%	54,02%	54,16%	54,79%	54,65%	54,02%	54,16%	53,81%
hd6lags4	52,22%	50,00%	51,46%	53,47%	53,05%	53,95%	53,95%	53,33%	53,61%	53,26%
hd6lags5	52,29%	51,60%	52,15%	53,26%	54,16%	53,95%	53,68%	52,70%	53,68%	53,54%
hd6lags6	51,60%	51,32%	52,01%	52,36%	52,91%	53,05%	52,29%	52,22%	53,19%	51,60%
hd6lags7	51,94%	50,55%	51,53%	53,05%	52,70%	52,98%	52,98%	53,05%	53,88%	53,12%
hd7lags1	51,11%	50,83%	52,43%	52,70%	53,12%	54,37%	53,88%	54,09%	53,88%	53,33%
hd7lags2	52,77%	51,18%	51,87%	53,33%	54,51%	54,99%	54,44%	54,44%	53,61%	53,40%
hd7lags3	52,15%	51,66%	53,12%	54,30%	54,65%	55,06%	54,85%	54,23%	54,44%	54,23%
hd7lags4	52,15%	50,14%	51,53%	53,74%	53,26%	53,68%	53,88%	53,47%	53,47%	52,98%
hd7lags5	51,73%	51,60%	52,08%	52,77%	53,26%	53,40%	53,47%	52,01%	53,12%	52,64%
hd7lags6	51,73%	50,76%	51,94%	51,73%	52,08%	52,43%	51,87%	51,11%	52,01%	50,62%
hd7lags7	51,39%	50,35%	51,94%	51,94%	51,87%	52,50%	53,12%	52,15%	53,68%	52,84%

Tabela 7. Wyniki trafności prognoz dla sieci ELM i pary walutowej USD/EUR na poziomach cen

	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10
hd1lags1	52,22%	52,22%	54,09%	54,65%	54,85%	55,76%	54,92%	54,58%	54,23%	53,26%
hd1lags2	51,80%	51,94%	54,02%	54,51%	54,79%	55,76%	55,06%	54,99%	54,23%	53,54%
hd1lags3	52,98%	52,22%	54,30%	53,81%	54,65%	55,83%	54,99%	54,51%	54,30%	53,26%
hd1lags4	52,91%	52,57%	53,81%	54,44%	54,44%	54,92%	54,99%	54,65%	54,30%	53,33%
hd1lags5	52,36%	51,39%	54,79%	53,81%	55,34%	55,83%	54,72%	55,27%	55,06%	53,74%
hd1lags6	52,91%	52,08%	54,72%	54,23%	54,85%	56,31%	55,69%	55,34%	55,62%	54,16%
hd1lags7	52,77%	52,70%	54,85%	53,54%	54,65%	55,62%	55,27%	56,24%	56,38%	54,51%
hd2lags1	52,36%	52,50%	54,09%	54,65%	54,99%	55,89%	55,20%	54,99%	54,65%	53,81%
hd2lags2	51,73%	52,29%	54,09%	54,85%	54,65%	56,10%	55,20%	55,20%	54,37%	54,02%
hd2lags3	53,05%	52,29%	54,02%	53,68%	54,65%	56,24%	54,85%	54,51%	55,13%	53,54%
hd2lags4	52,77%	52,98%	53,81%	54,09%	54,79%	54,79%	55,48%	54,58%	54,37%	53,40%
hd2lags5	52,15%	51,80%	55,13%	54,02%	55,06%	55,76%	55,62%	55,27%	55,34%	53,74%
hd2lags6	52,91%	52,22%	54,85%	54,37%	55,06%	56,38%	55,76%	55,76%	56,10%	54,72%
hd2lags7	53,33%	52,29%	55,34%	54,23%	54,85%	56,31%	55,27%	56,66%	56,66%	55,06%
hd3lags1	52,08%	52,08%	53,95%	54,23%	54,72%	55,76%	55,06%	54,85%	54,51%	53,54%
hd3lags2	52,22%	51,94%	54,16%	54,51%	54,79%	55,89%	55,48%	55,13%	54,51%	54,09%
hd3lags3	52,98%	52,15%	53,54%	53,68%	54,51%	55,89%	55,06%	54,65%	54,85%	53,40%

hd3lags4	52,29%	52,91%	53,40%	54,09%	54,79%	55,06%	55,96%	54,72%	54,72%	53,68%
hd3lags5	52,01%	51,94%	55,06%	53,88%	55,83%	55,89%	55,69%	55,69%	55,69%	54,09%
hd3lags6	52,84%	52,15%	54,92%	54,85%	55,20%	56,66%	56,45%	56,52%	56,66%	55,41%
hd3lags7	53,81%	52,64%	55,20%	54,58%	54,72%	56,93%	56,03%	56,87%	57,49%	55,62%
hd4lags1	51,94%	52,36%	54,09%	54,51%	54,99%	56,03%	55,34%	55,13%	54,79%	53,81%
hd4lags2	51,94%	51,94%	54,02%	54,65%	54,65%	56,03%	54,99%	55,13%	54,37%	54,09%
hd4lags3	52,98%	51,73%	53,81%	54,23%	54,85%	55,89%	54,99%	54,58%	54,79%	53,68%
hd4lags4	52,57%	53,05%	53,81%	54,23%	54,99%	54,85%	55,55%	54,72%	54,92%	53,74%
hd4lags5	52,22%	52,08%	55,34%	54,02%	55,69%	55,83%	55,62%	55,76%	55,48%	54,37%
hd4lags6	53,19%	52,70%	55,41%	54,79%	54,99%	56,66%	56,59%	56,73%	56,93%	55,13%
hd4lags7	53,54%	52,98%	55,55%	54,99%	55,20%	57,00%	56,17%	57,00%	57,21%	56,03%
hd5lags1	52,29%	52,43%	54,30%	54,72%	55,20%	56,10%	55,41%	55,20%	54,85%	53,74%
hd5lags2	52,29%	51,94%	53,74%	54,51%	54,79%	55,89%	55,55%	55,27%	54,51%	54,23%
hd5lags3	52,70%	52,08%	53,74%	53,95%	54,79%	55,96%	55,13%	54,85%	54,99%	53,40%
hd5lags4	52,36%	53,05%	53,81%	54,09%	54,58%	54,92%	55,83%	54,99%	55,34%	53,95%
hd5lags5	52,36%	52,01%	54,92%	54,30%	55,55%	56,31%	55,89%	56,24%	56,10%	54,51%
hd5lags6	53,33%	52,64%	55,34%	55,06%	55,27%	57,42%	56,31%	57,14%	57,21%	55,76%
hd5lags7	54,30%	53,26%	55,55%	54,65%	55,06%	56,80%	56,31%	57,35%	57,28%	56,03%
hd6lags1	52,15%	52,43%	54,16%	54,58%	54,92%	55,96%	55,41%	55,20%	54,85%	53,88%
hd6lags2	52,70%	51,73%	54,09%	54,44%	54,79%	55,83%	55,62%	55,20%	54,30%	54,02%
hd6lags3	52,70%	52,01%	54,30%	54,09%	54,79%	56,10%	54,99%	54,72%	55,13%	53,88%
hd6lags4	52,29%	52,91%	53,54%	54,16%	54,85%	54,92%	55,69%	55,06%	55,41%	53,74%
hd6lags5	52,36%	52,01%	55,48%	54,44%	56,10%	56,45%	55,89%	56,31%	56,03%	54,79%
hd6lags6	52,98%	52,84%	55,34%	54,99%	55,06%	57,35%	56,93%	57,00%	57,14%	55,83%
hd6lags7	53,88%	53,19%	55,83%	54,92%	55,41%	57,07%	56,73%	57,07%	57,28%	55,89%
hd7lags1	52,01%	52,43%	54,30%	54,72%	55,20%	56,24%	55,69%	55,48%	55,13%	54,02%
hd7lags2	52,36%	51,94%	53,74%	54,51%	54,58%	55,76%	55,41%	55,13%	54,44%	54,09%
hd7lags3	52,91%	51,94%	54,30%	54,37%	54,65%	55,96%	55,13%	54,99%	54,99%	53,68%
hd7lags4	52,29%	52,84%	53,54%	54,30%	54,92%	55,06%	55,62%	55,34%	55,76%	53,95%
hd7lags5	52,43%	52,36%	54,99%	54,65%	55,27%	56,38%	55,96%	56,52%	56,38%	54,92%
hd7lags6	53,40%	52,98%	55,48%	54,92%	55,27%	57,00%	57,28%	57,56%	57,35%	55,76%
hd7lags7	53,74%	53,33%	55,83%	54,92%	55,34%	56,87%	56,59%	57,00%	57,42%	55,96%

Na podstawie tabel możemy sformułować następujące wnioski dla prognoz uzyskanych siecią ELM:

- Dla CHF/EUR i USD/EUR prognozy sieci ze wszystkimi parametrami uzyskały trafność na poziomie ponad 50%, natomiast dla GBP/EUR ani razu nie osiągnięto trafności 50%.

- Dla par walutowych, które osiągnęły dobre rezultaty (CHF/EUR i USD/EUR), wyższą trafność uzyskano dla prognoz w horyzoncie 4-9 dni (maksimum dla prognozy na 6 dni w przód) a najgorszą na 1-3 dni. W przypadku USD/EUR, gdzie wyniki są gorsze, tendencja ta jest odwrócona i to prognozy na krótszy okres są trafniejsze.
- Można zauważyć znaczące różnice wyników w obrębie tego samego horyzontu prognozy, ale dla różnych ustawień sieci, jednak w przypadku sieci ELM trudne jest wskazanie zależności między liczbą węzłów ukrytych oraz opóźnień, a wynikami.
- Nie można wykazać związku między wzrostem liczby węzłów ukrytych, a poprawą trafności prognoz dla analizowanych par walutowych prognozowanych za pomocą sieci ELM.

Tabele 8-10 przedstawiają wyniki dla sieci MLP. W przypadku tej sieci wyniki mają inną charakterystykę niż w przypadku sieci ELM. Dla USD/EUR, dla wszystkich ustawień oraz horyzontów prognozy trafność przekracza 50%, dla CHF/EUR znacząca większość jest poniżej 50%, natomiast dla GBP/EUR wyniki oscylują w granicy 50%.

Tabela 8. Wyniki trafności prognoz dla sieci MLP i pary walutowej GBP/EUR na poziomach cen

	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10
hd1lags1	50,00%	50,76%	51,94%	51,73%	50,69%	49,79%	50,14%	51,18%	51,46%	52,01%
hd1lags2	50,49%	49,24%	48,89%	50,83%	50,28%	48,68%	48,06%	49,65%	49,31%	50,35%
hd1lags3	50,14%	49,10%	50,76%	50,21%	49,86%	48,82%	49,03%	48,82%	49,51%	48,89%
hd1lags4	50,76%	50,14%	48,13%	50,21%	48,06%	47,85%	48,34%	49,17%	49,31%	49,10%
hd1lags5	51,11%	49,10%	50,14%	49,24%	50,35%	49,58%	48,89%	50,42%	50,14%	51,39%
hd1lags6	50,76%	49,51%	48,89%	49,38%	50,42%	49,58%	49,38%	50,21%	49,93%	49,72%
hd1lags7	49,93%	49,31%	49,10%	49,65%	49,24%	50,97%	49,51%	49,79%	49,93%	49,79%
hd2lags1	50,07%	50,28%	52,15%	51,80%	50,62%	49,31%	49,86%	50,55%	51,46%	51,73%
hd2lags2	50,14%	49,58%	48,96%	49,79%	50,21%	48,20%	48,06%	49,17%	49,03%	49,45%
hd2lags3	50,21%	50,07%	51,53%	50,69%	50,55%	48,82%	49,65%	49,03%	50,14%	49,51%
hd2lags4	50,62%	50,07%	49,38%	51,11%	48,89%	48,47%	48,89%	49,65%	50,07%	49,24%
hd2lags5	51,46%	49,24%	49,93%	49,31%	50,00%	49,72%	49,10%	49,93%	49,86%	50,83%
hd2lags6	50,62%	49,45%	48,96%	49,79%	49,93%	50,00%	49,31%	50,35%	50,07%	49,17%
hd2lags7	50,28%	49,58%	49,45%	49,38%	49,65%	50,76%	49,93%	49,58%	49,45%	49,38%
hd3lags1	49,45%	49,10%	50,62%	50,69%	49,79%	49,03%	49,10%	49,86%	51,32%	50,90%
hd3lags2	49,79%	49,31%	48,34%	49,45%	49,03%	47,64%	47,71%	48,89%	49,10%	49,31%
hd3lags3	50,76%	50,35%	52,08%	51,46%	50,76%	50,00%	49,93%	49,24%	50,07%	49,45%

hd3lags4	50,83%	50,97%	49,24%	51,66%	49,79%	48,75%	49,93%	50,28%	50,28%	49,45%
hd3lags5	51,11%	49,45%	49,45%	49,45%	50,42%	49,17%	49,31%	49,79%	50,28%	51,18%
hd3lags6	50,76%	50,21%	49,03%	49,72%	49,79%	49,51%	49,65%	50,49%	50,21%	49,51%
hd3lags7	50,55%	50,28%	48,89%	49,45%	49,72%	50,90%	49,58%	50,14%	49,72%	48,96%
hd4lags1	50,42%	50,00%	51,73%	51,46%	49,86%	48,82%	49,17%	49,58%	50,62%	50,90%
hd4lags2	50,42%	49,10%	48,34%	49,79%	49,31%	47,50%	47,71%	48,40%	48,96%	49,31%
hd4lags3	50,49%	49,79%	52,08%	51,60%	50,69%	50,28%	50,21%	49,45%	50,49%	50,00%
hd4lags4	50,55%	50,55%	48,89%	51,25%	49,31%	48,68%	49,24%	49,79%	49,86%	49,31%
hd4lags5	51,32%	49,65%	49,65%	49,58%	49,93%	49,58%	49,10%	49,45%	49,79%	51,04%
hd4lags6	50,90%	49,65%	48,61%	49,51%	49,86%	49,03%	48,96%	50,55%	49,93%	49,17%
hd4lags7	50,00%	49,58%	49,10%	49,03%	49,31%	50,28%	49,58%	49,45%	49,24%	49,24%
hd5lags1	50,35%	50,07%	51,11%	50,90%	50,21%	49,24%	49,03%	49,58%	50,97%	50,49%
hd5lags2	50,21%	49,24%	48,61%	50,14%	49,17%	47,85%	48,06%	48,82%	49,24%	49,72%
hd5lags3	50,42%	49,86%	51,46%	51,25%	50,55%	49,65%	49,10%	48,96%	49,45%	49,17%
hd5lags4	50,97%	50,49%	48,82%	51,32%	49,17%	48,34%	48,82%	49,72%	49,65%	49,24%
hd5lags5	51,11%	49,24%	49,65%	49,86%	49,58%	49,03%	48,96%	49,24%	49,65%	50,69%
hd5lags6	51,39%	50,21%	49,86%	50,00%	49,86%	49,86%	49,17%	49,86%	49,51%	48,82%
hd5lags7	49,86%	50,28%	49,51%	50,21%	49,65%	50,62%	49,79%	50,14%	49,72%	49,45%
hd6lags1	50,07%	50,21%	51,60%	51,18%	49,45%	48,13%	48,13%	48,75%	49,93%	50,00%
hd6lags2	49,72%	49,45%	48,89%	50,14%	48,82%	47,85%	47,36%	48,75%	48,54%	49,17%
hd6lags3	50,62%	50,14%	51,53%	50,90%	50,07%	49,31%	49,72%	48,82%	49,79%	49,45%
hd6lags4	50,83%	50,97%	49,10%	51,04%	48,96%	48,06%	48,68%	49,38%	49,58%	48,75%
hd6lags5	51,11%	49,03%	49,51%	49,45%	50,07%	48,96%	48,47%	49,10%	49,51%	50,49%
hd6lags6	51,25%	50,42%	49,17%	49,45%	49,45%	49,10%	48,96%	50,21%	50,00%	49,45%
hd6lags7	49,79%	50,21%	49,38%	49,38%	49,31%	50,97%	49,45%	49,79%	49,79%	49,51%
hd7lags1	49,79%	50,07%	51,39%	51,04%	49,79%	47,78%	47,71%	48,20%	49,58%	49,51%
hd7lags2	50,35%	48,89%	48,61%	49,86%	49,24%	47,71%	47,30%	48,34%	48,68%	49,17%
hd7lags3	50,90%	50,97%	51,73%	51,32%	50,35%	49,45%	49,72%	48,89%	50,14%	49,03%
hd7lags4	50,90%	51,04%	49,93%	51,53%	49,03%	48,40%	48,89%	49,65%	49,51%	48,96%
hd7lags5	50,69%	49,10%	49,72%	49,24%	49,65%	49,24%	48,34%	48,61%	49,24%	50,35%
hd7lags6	50,49%	49,86%	48,82%	49,72%	49,03%	48,47%	48,61%	49,79%	49,51%	49,31%
hd7lags7	50,14%	50,35%	48,68%	49,17%	49,65%	50,35%	48,89%	49,93%	50,07%	49,10%

Tabela 9. Wyniki trafności prognoz dla sieci MLP i pary walutowej CHF/EUR na poziomach cen

	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10
hd1lags1	50,49%	47,85%	47,92%	48,61%	48,27%	49,79%	50,42%	50,07%	51,46%	50,42%
hd1lags2	51,11%	48,96%	48,27%	50,00%	50,07%	50,55%	50,97%	50,62%	51,60%	51,04%
hd1lags3	49,51%	48,06%	47,78%	48,34%	48,13%	50,07%	50,49%	50,28%	51,32%	50,00%

hd1lags4	50,35%	47,64%	47,78%	48,13%	47,78%	49,45%	49,93%	49,58%	50,69%	49,65%
hd1lags5	50,07%	48,13%	48,06%	48,75%	48,54%	50,28%	51,04%	50,83%	51,80%	50,62%
hd1lags6	49,79%	47,78%	47,92%	48,20%	47,92%	49,65%	50,28%	49,93%	51,04%	50,28%
hd1lags7	48,82%	47,43%	46,88%	47,50%	47,36%	48,47%	49,51%	49,03%	50,69%	49,17%
hd2lags1	48,20%	47,09%	46,67%	47,71%	47,85%	48,82%	49,86%	49,51%	50,69%	48,96%
hd2lags2	48,82%	47,02%	46,81%	47,71%	47,09%	47,92%	48,96%	47,92%	49,17%	47,57%
hd2lags3	49,17%	48,40%	47,36%	48,61%	47,71%	49,03%	49,79%	49,24%	50,35%	48,54%
hd2lags4	49,03%	47,57%	46,81%	47,78%	47,57%	48,06%	48,96%	48,40%	49,51%	47,78%
hd2lags5	49,03%	47,78%	47,71%	48,20%	47,43%	48,13%	49,38%	48,68%	49,93%	48,34%
hd2lags6	49,03%	48,06%	47,43%	48,54%	48,06%	48,61%	49,10%	48,75%	50,21%	48,40%
hd2lags7	48,54%	47,64%	46,67%	46,81%	46,74%	47,64%	48,47%	47,78%	49,24%	47,36%
hd3lags1	48,89%	47,23%	46,32%	47,99%	47,71%	48,82%	49,72%	48,68%	50,49%	49,10%
hd3lags2	48,89%	47,30%	46,60%	47,71%	46,95%	47,85%	48,75%	47,71%	49,17%	47,23%
hd3lags3	48,54%	47,43%	47,36%	48,34%	48,27%	48,61%	49,58%	48,89%	50,00%	48,47%
hd3lags4	49,24%	48,27%	47,71%	48,27%	47,71%	48,54%	49,31%	48,40%	49,72%	47,92%
hd3lags5	49,17%	48,40%	47,50%	48,06%	47,43%	48,27%	49,86%	49,38%	50,14%	48,75%
hd3lags6	48,82%	47,36%	47,23%	48,27%	47,85%	48,20%	49,51%	48,89%	49,79%	48,13%
hd3lags7	49,17%	47,64%	47,64%	48,20%	47,92%	48,82%	49,65%	49,17%	50,21%	48,27%
hd4lags1	48,61%	47,78%	47,23%	48,34%	47,71%	48,13%	49,17%	48,34%	49,72%	48,13%
hd4lags2	48,34%	47,78%	47,43%	48,20%	47,43%	48,13%	48,89%	48,68%	50,14%	48,20%
hd4lags3	49,58%	48,54%	47,99%	48,89%	48,06%	48,75%	49,38%	48,75%	50,28%	48,61%
hd4lags4	49,45%	48,47%	48,40%	48,47%	48,54%	48,68%	49,45%	48,96%	50,42%	48,75%
hd4lags5	48,96%	47,36%	46,67%	47,92%	47,23%	47,92%	48,68%	48,06%	49,45%	47,64%
hd4lags6	49,03%	47,64%	46,88%	48,13%	47,85%	48,40%	49,03%	48,54%	50,00%	48,20%
hd4lags7	48,68%	47,43%	46,88%	47,64%	47,16%	48,06%	48,68%	48,34%	49,38%	47,85%
hd5lags1	48,96%	47,99%	47,50%	48,82%	48,06%	48,75%	49,24%	48,47%	49,93%	48,40%
hd5lags2	48,96%	47,92%	47,78%	48,54%	47,78%	48,20%	49,24%	48,34%	49,79%	48,27%
hd5lags3	48,75%	47,78%	47,57%	48,34%	47,57%	48,34%	49,03%	48,47%	50,00%	48,40%
hd5lags4	48,89%	47,50%	47,02%	47,71%	47,16%	47,71%	48,89%	48,40%	49,58%	48,13%
hd5lags5	48,34%	46,95%	46,12%	47,36%	46,74%	47,71%	48,75%	47,71%	49,17%	47,64%
hd5lags6	49,24%	47,92%	47,57%	48,82%	47,78%	48,61%	48,82%	48,61%	49,79%	48,20%
hd5lags7	48,54%	47,71%	46,95%	48,13%	47,43%	47,99%	48,89%	48,54%	49,72%	47,78%
hd6lags1	49,03%	48,27%	47,50%	48,40%	47,50%	48,47%	49,10%	48,89%	50,35%	48,68%
hd6lags2	49,51%	47,99%	47,23%	48,34%	47,64%	48,34%	49,24%	48,61%	49,93%	47,85%
hd6lags3	49,17%	47,99%	47,30%	48,13%	47,57%	48,13%	48,89%	48,40%	49,72%	48,20%
hd6lags4	48,96%	47,78%	47,02%	48,34%	47,92%	48,61%	49,03%	48,68%	50,14%	48,47%
hd6lags5	48,61%	47,23%	46,60%	47,78%	47,43%	48,27%	49,03%	48,54%	49,72%	48,06%
hd6lags6	49,03%	47,23%	46,60%	47,78%	47,36%	47,92%	48,96%	48,20%	49,38%	47,71%
hd6lags7	49,24%	47,99%	47,36%	48,13%	47,57%	48,27%	49,03%	48,54%	49,58%	47,92%

hd7lags1	48,61%	47,78%	47,92%	48,61%	48,20%	48,40%	49,51%	48,54%	50,14%	48,61%
hd7lags2	48,61%	46,95%	47,23%	47,64%	47,36%	47,78%	48,82%	48,27%	49,17%	47,64%
hd7lags3	49,10%	47,92%	47,64%	48,40%	47,85%	48,54%	49,17%	48,54%	49,72%	48,20%
hd7lags4	49,38%	47,99%	48,20%	48,68%	48,61%	49,17%	49,79%	49,03%	50,21%	48,75%
hd7lags5	48,96%	47,99%	47,78%	48,06%	47,71%	48,06%	48,82%	48,27%	49,65%	48,13%
hd7lags6	48,75%	47,43%	47,50%	48,27%	47,78%	48,54%	49,31%	48,75%	50,28%	48,75%
hd7lags7	48,96%	47,78%	47,78%	48,06%	47,85%	48,54%	49,51%	48,96%	50,35%	48,89%

Tabela 10. Wyniki trafności prognoz dla sieci MLP i pary walutowej USD/EUR na poziomach cen

	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10
hd1lags1	53,19%	53,95%	54,51%	53,12%	53,95%	55,96%	55,96%	55,48%	55,76%	55,27%
hd1lags2	53,33%	54,58%	53,40%	53,68%	53,95%	56,10%	57,07%	56,10%	57,07%	55,62%
hd1lags3	52,29%	52,22%	54,79%	53,47%	54,16%	56,87%	56,73%	56,24%	57,77%	56,31%
hd1lags4	54,79%	52,70%	53,05%	53,54%	54,44%	55,41%	56,38%	56,31%	56,66%	55,96%
hd1lags5	53,19%	53,68%	54,44%	54,23%	56,03%	56,17%	56,45%	56,17%	57,14%	56,03%
hd1lags6	53,68%	53,95%	55,48%	54,37%	55,06%	57,07%	56,31%	55,96%	57,21%	56,03%
hd1lags7	53,68%	53,95%	54,09%	53,88%	54,92%	56,59%	56,80%	56,24%	57,98%	56,17%
hd2lags1	53,74%	54,37%	54,85%	53,61%	54,23%	55,96%	56,38%	56,38%	56,59%	55,48%
hd2lags2	53,68%	54,99%	52,84%	54,16%	54,44%	56,73%	57,28%	56,80%	57,77%	56,03%
hd2lags3	52,98%	52,98%	54,44%	53,95%	54,79%	56,80%	57,14%	57,49%	57,63%	56,87%
hd2lags4	55,20%	53,88%	53,47%	54,37%	54,65%	56,38%	57,42%	56,87%	58,04%	56,87%
hd2lags5	53,47%	54,16%	54,44%	55,20%	56,24%	55,89%	56,59%	56,10%	57,91%	56,73%
hd2lags6	53,74%	53,81%	55,20%	55,76%	55,83%	57,84%	56,24%	56,03%	57,63%	56,52%
hd2lags7	53,81%	54,16%	55,20%	54,65%	55,62%	57,49%	57,35%	56,59%	57,63%	55,76%
hd3lags1	54,44%	54,37%	55,13%	54,02%	54,30%	55,83%	56,17%	55,76%	56,17%	55,13%
hd3lags2	54,02%	55,20%	53,19%	54,09%	54,72%	56,45%	57,70%	56,73%	57,42%	56,31%
hd3lags3	53,26%	53,05%	54,92%	53,68%	54,02%	55,96%	56,59%	57,00%	57,21%	56,17%
hd3lags4	54,85%	53,40%	54,09%	54,99%	54,23%	55,27%	57,56%	56,10%	57,42%	56,87%
hd3lags5	54,09%	54,16%	54,44%	56,31%	56,45%	55,27%	56,59%	55,96%	57,07%	55,62%
hd3lags6	53,54%	53,68%	55,20%	55,76%	56,03%	58,46%	56,17%	56,52%	57,77%	57,07%
hd3lags7	53,68%	53,40%	54,92%	54,72%	55,62%	57,00%	57,63%	56,24%	57,77%	56,17%
hd4lags1	54,02%	54,51%	54,85%	54,30%	54,85%	55,76%	56,52%	55,76%	56,38%	55,20%
hd4lags2	53,12%	55,41%	53,12%	54,51%	54,79%	57,00%	57,63%	57,00%	57,63%	56,80%
hd4lags3	53,61%	52,64%	54,16%	53,95%	54,02%	56,24%	56,87%	57,07%	57,07%	56,24%
hd4lags4	54,85%	54,09%	54,23%	55,41%	54,58%	55,69%	57,35%	56,59%	57,63%	56,52%
hd4lags5	53,88%	54,09%	54,30%	55,96%	56,80%	55,83%	56,93%	56,17%	57,42%	55,62%
hd4lags6	52,98%	53,68%	54,72%	55,41%	56,03%	58,32%	56,59%	56,93%	57,91%	56,93%
hd4lags7	53,68%	53,74%	54,92%	54,37%	55,62%	57,21%	57,77%	56,31%	57,91%	56,03%

hd5lags1	53,95%	54,37%	55,27%	54,37%	54,92%	56,45%	56,93%	56,31%	57,07%	55,89%
hd5lags2	53,74%	54,72%	53,19%	54,51%	54,92%	56,73%	57,63%	56,45%	57,28%	56,31%
hd5lags3	52,98%	52,29%	54,44%	53,88%	53,81%	56,38%	57,21%	56,73%	57,42%	56,59%
hd5lags4	55,06%	53,54%	53,88%	54,99%	54,44%	55,27%	57,63%	56,80%	57,91%	56,24%
hd5lags5	54,44%	54,30%	54,30%	55,69%	56,73%	55,76%	56,73%	56,03%	57,21%	56,03%
hd5lags6	53,12%	53,61%	54,65%	54,85%	56,10%	58,11%	55,83%	56,31%	57,28%	57,00%
hd5lags7	53,47%	53,68%	55,62%	54,79%	56,17%	57,84%	58,04%	56,73%	57,56%	56,24%
hd6lags1	54,16%	54,58%	55,20%	54,16%	55,13%	56,24%	56,87%	56,17%	57,07%	56,17%
hd6lags2	53,40%	55,06%	53,26%	54,65%	55,06%	56,87%	57,56%	56,66%	56,93%	56,38%
hd6lags3	52,91%	52,70%	54,30%	53,81%	53,68%	55,69%	56,66%	56,73%	56,45%	56,38%
hd6lags4	54,79%	53,61%	54,16%	55,34%	54,58%	55,13%	57,35%	56,80%	57,84%	56,31%
hd6lags5	53,95%	54,16%	54,79%	55,62%	57,00%	55,89%	56,31%	56,52%	57,77%	56,45%
hd6lags6	53,47%	53,33%	54,72%	54,92%	55,76%	58,60%	56,59%	56,31%	57,70%	56,87%
hd6lags7	53,61%	53,95%	55,06%	54,37%	55,62%	57,21%	57,70%	56,52%	57,28%	56,24%
hd7lags1	53,95%	55,06%	55,55%	55,20%	55,34%	56,59%	57,63%	56,80%	57,14%	56,03%
hd7lags2	53,19%	53,95%	53,33%	53,74%	54,16%	55,96%	56,52%	56,24%	56,59%	55,55%
hd7lags3	52,91%	52,50%	54,23%	53,40%	53,81%	55,69%	56,45%	56,45%	56,17%	55,96%
hd7lags4	54,79%	53,81%	54,09%	55,96%	54,58%	54,99%	57,56%	57,00%	57,42%	55,83%
hd7lags5	53,88%	54,44%	54,92%	55,62%	56,87%	55,76%	56,17%	56,17%	56,93%	56,38%
hd7lags6	52,91%	52,84%	53,88%	54,79%	55,62%	58,67%	56,45%	56,45%	57,84%	56,73%
hd7lags7	53,68%	53,40%	54,92%	54,16%	55,55%	57,49%	58,46%	56,80%	57,49%	56,45%

MLP najlepsze wyniki uzyskała dla pary walutowej USD/EUR (Tabela 10.). Można zauważyć podobne zależności jak w przypadku sieci ELM, które uzyskiwały stosunkowo dobre rezultaty. Najgorsze wyniki dla USD/EUR przy prognozowaniu siecią MLP uzyskano dla horyzontu prognozy 1-3 dni, a najlepsze dla horyzontu 6-8 dni. Dla sieci MLP oraz pary walutowej USD/EUR można również zauważyć wpływ ustawień parametrów sieci na trafność. W wielu

przypadkach sieci zachowują się analogicznie, niezależnie od horyzontu. Najbardziej widocznymi przykładami na rysunku 41. są:

- poprawa wyników dla sieci MLP z ustawieniami: dwa węzły ukryte oraz dwa opóźnienia (hd1lags2) w stosunku do wyników z tą samą liczbą węzłów ukrytych, ale dla opóźnień równych jeden (hd1lags1) oraz trzy (hd1lags3),
- poprawa wyników dla sieci MLP z ustawieniami: dwa węzły ukryte oraz pięć opóźnień (hd1lags5) w stosunku do wyników z tą samą liczbą węzłów ukrytych, ale dla opóźnień równych cztery (hd1lags4) oraz sześć (hd1lags6),
- poprawa wyników dla sieci MLP z ustawieniami: pięć węzłów ukrytych oraz trzy opóźnienia (hd2lags3) w stosunku do wyników z tą samą liczbą węzłów ukrytych, ale dla opóźnień równych dwa (hd2lags2) oraz cztery (hd2lags4),
- poprawa wyników dla sieci MLP z ustawieniami: dziesięć węzłów ukrytych oraz jedno opóźnienie (hd3lags2) w stosunku do wyników z tą samą liczbą węzłów ukrytych, ale dla opóźnień równych dwa (hd3lags2) oraz w stosunku do ustawień z pięcioma węzłami ukrytymi oraz siedmioma opóźnieniami (hd2lags7).

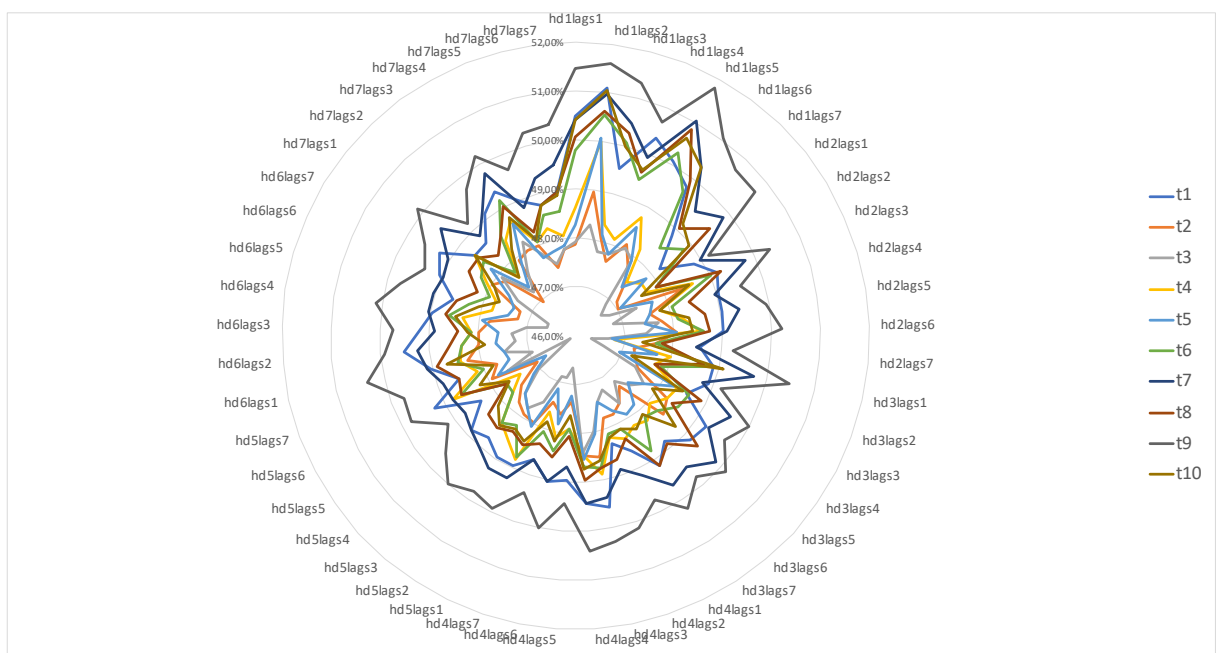
Powyższe zależności bardzo dobrze widać na wykresie radarowym - rysunku 41. Wykres ten przedstawia trafność prognoz w zależności od ustawień sieci MLP. Widać wyraźne „podążanie” poszczególnych horyzontów prognozy w tym samym kierunku dla tych samych ustawień sieci neuronowej.

Analizując trafność prognoz pary walutowej CHF/EUR (Rysunek 42.) za pomocą sieci MLP można sformułować następujące wnioski:

- sieci o ustawieniach z dwoma opóźnieniami uzyskiwały najlepsze trafności dla horyzontu prognoz: dwa dni,
- sieci o ustawieniach z pięcioma opóźnieniami uzyskiwały najlepsze trafności dla prognoz na za pięć dni oraz na cztery dni, ale dla liczby węzłów ukrytych większych niż trzy,
- sieci o ustawieniach z sześcioma opóźnieniami uzyskiwały najlepsze trafności dla prognoz na za sześć dni.


Nie zawsze sieci z liczbą opóźnień równą horyzontowi prognozy dają najlepsze wyniki. Takim przykładem jest prognozowanie na jeden dzień w przód, gdzie najlepsze wyniki uzyskiwano

dla waluty CHF/EUR przy ustawieniach lags4. Można również znaleźć przypadki, w których przy danym ustawieniu opóźnień i niezależnie od ustawień liczby węzłów ukrytych sieć uzyskiwała najgorsze wyniki w porównaniu z innymi ustawieniami opóźnień przy takiej samej liczbie węzłów ukrytych. Przykładem takim jest prognozowanie na dwa dni: najgorsze wyniki dla tej sieci osiągnięto przy ustawieniach z trzema opóźnieniami.



Rysunek 41. Wyniki trafności dla sieci MLP i pary walutowej USD/EUR – wykres radarowy

Uwaga: Na wykresie radarowym na okręgu rozmieszczono ustawienia sieci a odległość wykresu od środka określa trafność uzyskaną przez daną sieć



Rysunek 42. Wyniki trafności dla sieci MLP i pary walutowej CHF/EUR – wykres radarowy

Uwaga: Na wykresie radarowym na okręgu rozmieszczono ustawienia sieci a odległość wykresu od środka określa trafność uzyskaną przez daną sieć

Siecią, która uzyskała najlepsze wyniki, jest sieć LSTM – tabele 11-13. Średnie wyniki dla wszystkich par walutowych, horyzontów prognozy oraz hiperparametrów sieci neuronowej są wyższe w porównaniu do trafności przy prognozowaniu inną, bardziej podstawową, siecią. W związku z tym, z całą pewnością należy zauważyć przewagę sieci LSTM nad pozostałymi dwoma sieciami. Przewaga ta wynika z własności sieci LSTM opisanych w rozdziale II, a w szczególności z zachowywania informacji o poprzednich stanach, co jest kluczowe w przypadku szeregów czasowych. Dla sieci ELM i MLP trudne było zauważenie związku między wzrostem liczby węzłów ukrytych a wzrostem trafności prognoz (złożoność w obrębie tego samego typu sieci neuronowej).

Dla wyników trafności CHF/EUR prognozowanych LSTM sporządzono wykres radarowy dla wszystkich możliwych kombinacji parametrów sieci. Można na nim zauważyć (z wyjątkiem prognozowania na 1-2 dni), że LSTM najlepsze wyniki osiąga dla wszystkich ustawień z liczbą opóźnień 1; następnie, przy zwiększaniu liczby opóźnień, trafność spada – sytuacja wygląda tak samo dla wszystkich ustawień sieci, niezależnie od liczby warstw ukrytych zastosowanych w sieci. Dla ustawień z dwoma węzłami ukrytymi (hd1), sieć LSTM uzyskała ponad 70% trafności dla prognoz na 10 dni do przodu – co bardzo dobrze widać na wykresie radarowym – rysunek 43.

Tabela 11. Wyniki trafności prognoz dla sieci LSTM i pary walutowej GBP/EUR na poziomach cen

	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10
hd1lags1	49,93%	57,98%	61,51%	64,63%	65,53%	64,42%	68,17%	69,21%	70,39%	72,19%
hd1lags2	49,93%	49,38%	55,06%	57,00%	58,95%	59,15%	60,40%	61,65%	63,66%	61,44%
hd1lags3	51,04%	49,24%	49,24%	53,95%	54,02%	54,51%	55,48%	59,71%	59,02%	58,74%
hd1lags4	50,83%	49,51%	50,14%	49,51%	50,97%	51,66%	53,61%	54,92%	55,34%	55,89%
hd1lags5	51,18%	47,92%	48,47%	47,71%	48,34%	50,69%	51,04%	52,43%	53,26%	52,64%
hd1lags6	51,66%	49,38%	49,65%	48,82%	48,20%	48,82%	49,79%	51,25%	51,66%	51,04%
hd1lags7	50,76%	50,00%	48,61%	49,86%	49,51%	49,86%	48,20%	50,83%	50,14%	50,90%
hd2lags1	51,32%	59,29%	62,97%	67,41%	67,34%	68,86%	71,50%	72,26%	73,51%	73,65%
hd2lags2	51,25%	49,72%	56,52%	58,67%	60,82%	60,06%	63,45%	65,40%	66,37%	66,85%
hd2lags3	50,83%	49,31%	49,65%	53,19%	54,23%	55,34%	56,73%	60,19%	62,00%	61,79%
hd2lags4	51,18%	50,07%	48,68%	48,82%	50,55%	52,15%	54,02%	55,69%	57,63%	57,14%
hd2lags5	51,39%	49,51%	49,65%	48,40%	48,47%	49,65%	52,22%	53,54%	54,65%	53,95%
hd2lags6	51,46%	49,24%	49,93%	47,78%	49,79%	49,72%	51,25%	50,90%	51,87%	52,29%
hd2lags7	50,28%	49,86%	50,49%	51,25%	51,32%	51,60%	51,11%	51,94%	52,15%	52,77%
hd3lags1	50,07%	59,85%	63,52%	66,37%	68,86%	68,65%	70,25%	72,82%	74,13%	75,38%
hd3lags2	49,51%	48,82%	56,03%	57,00%	60,26%	60,68%	64,42%	64,49%	67,75%	67,34%
hd3lags3	50,97%	49,86%	49,86%	54,44%	54,37%	54,65%	57,63%	59,57%	61,86%	61,72%
hd3lags4	50,97%	48,40%	49,65%	48,20%	51,39%	52,29%	54,44%	55,34%	57,56%	57,98%
hd3lags5	51,25%	49,79%	48,82%	48,34%	49,24%	50,49%	51,53%	53,88%	53,54%	53,88%
hd3lags6	51,39%	50,76%	50,35%	50,00%	48,34%	48,89%	51,73%	51,39%	53,12%	52,08%
hd3lags7	51,04%	49,45%	49,65%	50,49%	49,51%	50,35%	49,38%	50,55%	52,36%	52,64%
hd4lags1	51,11%	58,04%	63,11%	66,50%	68,86%	69,56%	70,74%	71,15%	73,99%	74,76%
hd4lags2	51,66%	48,40%	55,20%	57,28%	59,92%	61,58%	64,49%	66,30%	66,71%	67,61%
hd4lags3	50,00%	50,62%	49,58%	54,16%	54,85%	53,95%	56,87%	58,95%	61,03%	61,10%
hd4lags4	50,90%	48,54%	48,89%	47,57%	51,11%	51,87%	55,06%	55,55%	57,98%	58,67%
hd4lags5	50,83%	48,40%	48,75%	48,06%	47,99%	49,38%	51,32%	53,54%	53,19%	53,88%
hd4lags6	50,97%	50,76%	49,03%	48,82%	49,38%	49,93%	50,14%	52,08%	52,50%	52,70%
hd4lags7	50,35%	50,97%	49,51%	50,21%	50,07%	50,07%	48,68%	51,32%	52,43%	53,05%
hd5lags1	51,53%	56,80%	63,31%	66,44%	68,79%	68,72%	70,11%	71,78%	72,05%	74,20%
hd5lags2	50,55%	49,86%	55,55%	58,32%	59,78%	61,65%	63,59%	65,53%	66,64%	67,20%
hd5lags3	49,65%	49,86%	49,51%	53,47%	54,51%	55,69%	58,46%	60,19%	62,07%	61,44%
hd5lags4	50,14%	48,61%	46,95%	48,20%	50,83%	51,60%	54,30%	54,79%	56,66%	56,87%
hd5lags5	50,28%	49,51%	47,78%	47,92%	48,47%	50,21%	52,15%	54,09%	54,51%	53,95%
hd5lags6	51,32%	50,00%	48,75%	49,03%	48,96%	48,47%	50,42%	52,36%	51,53%	52,29%
hd5lags7	50,83%	51,32%	50,55%	50,55%	50,90%	51,32%	49,72%	51,18%	52,01%	52,22%
hd6lags1	51,53%	57,49%	62,97%	65,88%	68,10%	69,49%	70,46%	72,82%	75,17%	72,95%

hd6lags2	49,10%	50,28%	55,83%	57,70%	60,26%	59,92%	63,11%	64,63%	66,64%	67,13%
hd6lags3	50,83%	50,28%	50,28%	54,72%	55,48%	56,10%	58,18%	59,64%	62,07%	62,62%
hd6lags4	49,86%	48,06%	49,03%	48,68%	51,25%	51,46%	53,88%	55,41%	57,35%	58,39%
hd6lags5	50,28%	50,28%	48,68%	48,34%	49,51%	49,86%	52,43%	53,05%	54,16%	54,02%
hd6lags6	51,53%	50,69%	49,10%	48,34%	48,82%	49,93%	49,10%	52,22%	52,84%	53,81%
hd6lags7	50,07%	49,51%	49,86%	50,83%	50,00%	49,38%	49,93%	50,90%	51,25%	51,39%
hd7lags1	53,95%	55,06%	55,55%	55,20%	55,34%	56,59%	57,63%	56,80%	57,14%	56,03%
hd7lags2	53,19%	53,95%	53,33%	53,74%	54,16%	55,96%	56,52%	56,24%	56,59%	55,55%
hd7lags3	52,91%	52,50%	54,23%	53,40%	53,81%	55,69%	56,45%	56,45%	56,17%	55,96%
hd7lags4	54,79%	53,81%	54,09%	55,96%	54,58%	54,99%	57,56%	57,00%	57,42%	55,83%
hd7lags5	53,88%	54,44%	54,92%	55,62%	56,87%	55,76%	56,17%	56,17%	56,93%	56,38%
hd7lags6	52,91%	52,84%	53,88%	54,79%	55,62%	58,67%	56,45%	56,45%	57,84%	56,73%
hd7lags7	53,68%	53,40%	54,92%	54,16%	55,55%	57,49%	58,46%	56,80%	57,49%	56,45%

Tabela 12. Wyniki trafności prognoz dla sieci LSTM i pary walutowej CHF/EUR na poziomach cen

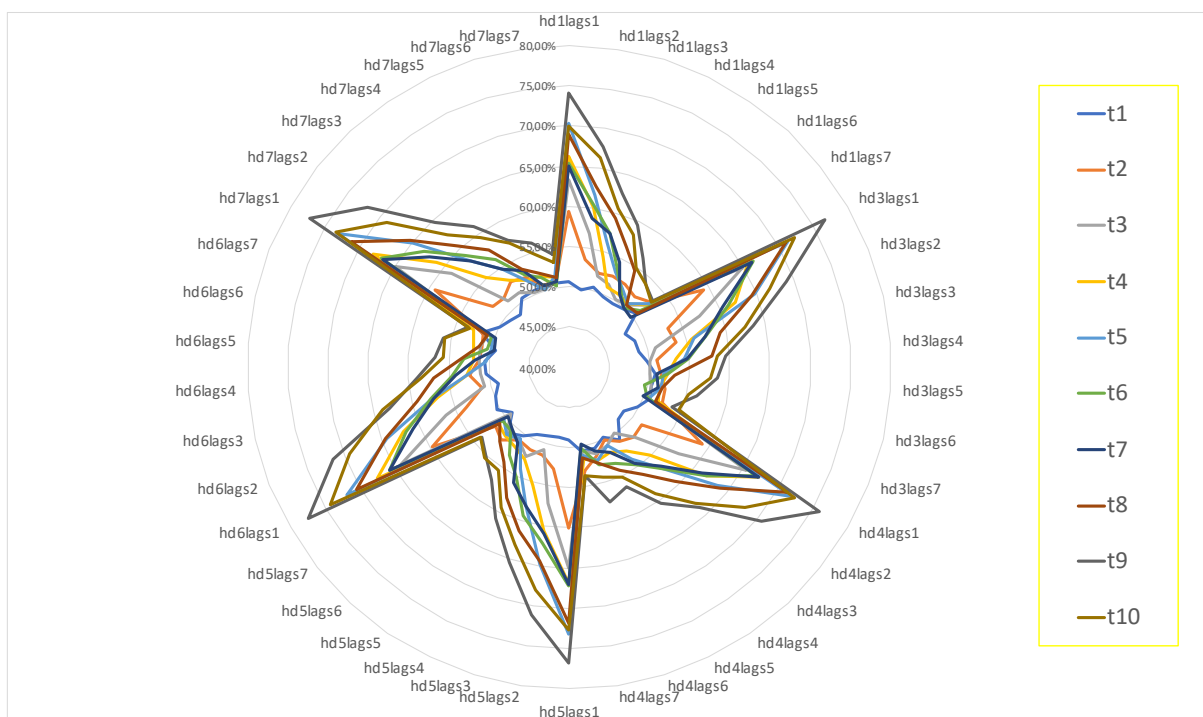
	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10
hd1lags1	50,62%	59,36%	63,31%	66,30%	70,25%	65,40%	64,98%	69,00%	74,13%	69,97%
hd1lags2	49,65%	53,54%	56,87%	60,19%	61,65%	60,47%	58,81%	62,62%	67,75%	66,30%
hd1lags3	50,42%	52,29%	51,80%	54,37%	56,17%	57,42%	57,35%	59,36%	62,55%	60,61%
hd1lags4	49,65%	52,64%	51,39%	50,97%	53,12%	53,81%	54,44%	56,59%	59,64%	58,25%
hd1lags5	49,58%	52,43%	50,21%	50,97%	51,87%	51,46%	51,11%	54,44%	56,38%	54,85%
hd1lags6	49,93%	51,87%	50,62%	50,83%	50,76%	50,07%	50,00%	50,55%	54,02%	53,95%
hd1lags7	50,69%	53,05%	52,36%	52,36%	52,70%	51,25%	49,79%	50,83%	53,26%	53,05%
hd2lags1	48,13%	59,29%	64,77%	65,60%	71,29%	66,50%	66,23%	71,22%	76,63%	72,26%
hd2lags2	48,75%	53,19%	57,49%	62,21%	64,77%	61,30%	60,47%	64,49%	69,07%	66,85%
hd2lags3	48,82%	53,61%	51,04%	55,55%	55,96%	57,42%	57,28%	59,22%	63,52%	62,34%
hd2lags4	49,72%	50,90%	50,14%	53,40%	54,30%	54,85%	54,65%	57,84%	59,43%	58,53%
hd2lags5	50,69%	51,46%	50,07%	52,29%	51,73%	52,22%	50,90%	53,12%	58,46%	57,56%
hd2lags6	50,42%	52,22%	50,49%	51,46%	51,66%	49,65%	51,39%	51,80%	56,24%	55,27%
hd2lags7	50,76%	52,36%	50,62%	51,80%	50,62%	50,35%	49,79%	51,60%	53,74%	54,58%
hd3lags1	49,86%	59,08%	65,53%	67,27%	72,05%	66,85%	67,27%	71,29%	75,87%	72,33%
hd3lags2	48,68%	51,53%	57,35%	61,72%	63,52%	61,72%	61,10%	64,01%	70,67%	67,96%
hd3lags3	48,96%	51,80%	51,87%	54,85%	57,28%	57,28%	56,80%	59,29%	63,80%	63,11%
hd3lags4	51,04%	51,25%	49,86%	52,57%	53,81%	54,79%	54,44%	56,17%	60,40%	58,95%
hd3lags5	49,65%	50,07%	50,90%	51,80%	50,90%	53,33%	51,73%	54,30%	56,45%	55,20%
hd3lags6	50,55%	51,60%	51,32%	52,08%	52,15%	52,77%	50,83%	52,50%	57,49%	54,23%
hd3lags7	50,49%	52,91%	50,62%	51,66%	51,04%	50,14%	49,65%	51,39%	53,74%	53,74%
hd4lags1	49,03%	59,99%	65,05%	66,78%	73,16%	67,27%	67,06%	71,84%	76,84%	72,61%
hd4lags2	48,75%	52,77%	57,21%	60,54%	64,70%	62,07%	60,89%	64,42%	71,08%	68,10%

hd4lags3	48,89%	51,53%	50,76%	55,41%	58,04%	59,29%	58,04%	61,37%	65,40%	63,04%
hd4lags4	49,38%	51,32%	52,43%	52,77%	53,95%	55,20%	56,03%	57,98%	60,89%	59,43%
hd4lags5	50,28%	50,90%	50,90%	52,08%	50,83%	53,19%	51,39%	54,37%	57,07%	55,62%
hd4lags6	51,25%	52,36%	51,53%	51,60%	51,32%	50,76%	50,49%	52,57%	55,20%	55,34%
hd4lags7	49,10%	51,73%	49,31%	51,18%	50,35%	50,69%	49,72%	51,11%	53,95%	54,09%
hd5lags1	50,42%	59,71%	64,15%	67,61%	71,98%	65,81%	65,81%	70,53%	77,53%	74,20%
hd5lags2	49,79%	53,61%	56,38%	62,07%	64,29%	61,79%	60,89%	64,49%	71,50%	69,35%
hd5lags3	49,03%	51,11%	50,76%	56,73%	57,42%	57,56%	57,35%	59,36%	62,97%	63,80%
hd5lags4	50,35%	52,36%	50,97%	52,70%	52,70%	54,72%	54,16%	56,93%	58,95%	58,39%
hd5lags5	50,49%	51,25%	51,18%	51,87%	50,35%	53,12%	51,80%	53,47%	56,73%	55,76%
hd5lags6	49,31%	51,18%	51,25%	52,15%	49,86%	50,35%	49,51%	51,53%	55,96%	55,89%
hd5lags7	51,60%	51,46%	50,83%	52,77%	50,14%	50,28%	49,86%	50,90%	53,47%	53,26%
hd6lags1	49,86%	59,15%	64,91%	68,10%	73,30%	66,99%	66,85%	71,36%	77,18%	73,44%
hd6lags2	49,31%	52,08%	58,60%	61,03%	64,84%	63,04%	62,14%	65,33%	71,98%	69,00%
hd6lags3	48,89%	51,80%	51,18%	55,13%	57,98%	58,88%	57,98%	60,54%	64,49%	62,34%
hd6lags4	50,42%	52,77%	51,18%	53,12%	54,79%	56,10%	54,72%	57,63%	61,10%	59,43%
hd6lags5	50,49%	52,29%	50,21%	52,08%	51,73%	52,77%	53,33%	53,47%	57,56%	57,14%
hd6lags6	50,62%	50,55%	50,28%	51,87%	50,14%	51,66%	50,55%	52,29%	56,17%	54,72%
hd6lags7	50,62%	51,11%	50,69%	51,32%	51,39%	50,21%	50,69%	51,32%	54,30%	53,19%
hd7lags1	53,95%	55,06%	55,55%	55,20%	55,34%	56,59%	57,63%	56,80%	57,14%	56,03%
hd7lags2	53,19%	53,95%	53,33%	53,74%	54,16%	55,96%	56,52%	56,24%	56,59%	55,55%
hd7lags3	52,91%	52,50%	54,23%	53,40%	53,81%	55,69%	56,45%	56,45%	56,17%	55,96%
hd7lags4	54,79%	53,81%	54,09%	55,96%	54,58%	54,99%	57,56%	57,00%	57,42%	55,83%
hd7lags5	53,88%	54,44%	54,92%	55,62%	56,87%	55,76%	56,17%	56,17%	56,93%	56,38%
hd7lags6	52,91%	52,84%	53,88%	54,79%	55,62%	58,67%	56,45%	56,45%	57,84%	56,73%
hd7lags7	53,68%	53,40%	54,92%	54,16%	55,55%	57,49%	58,46%	56,80%	57,49%	56,45%

Tabela 13. Wyniki trafności prognoz dla sieci LSTM i pary walutowej USD/EUR na poziomach cen

	t1	t2	t3	t4	t5	t6	t7	t8	t9	t10
hd1lags1	49,65%	56,93%	60,12%	63,25%	63,11%	66,02%	66,44%	69,97%	70,18%	71,50%
hd1lags2	50,76%	51,18%	55,13%	57,63%	58,32%	60,89%	61,30%	62,83%	63,45%	63,87%
hd1lags3	50,69%	51,53%	50,83%	53,74%	54,51%	56,59%	58,04%	58,81%	59,85%	59,64%
hd1lags4	50,76%	49,51%	51,25%	50,97%	53,61%	54,58%	55,06%	55,96%	58,04%	55,96%
hd1lags5	50,76%	50,14%	52,22%	51,73%	50,90%	52,77%	53,88%	55,62%	56,17%	55,96%
hd1lags6	50,49%	49,17%	51,32%	51,80%	51,32%	51,18%	52,01%	52,84%	54,09%	53,88%
hd1lags7	50,21%	49,93%	52,08%	51,39%	51,18%	50,76%	52,22%	53,33%	53,61%	54,65%
hd2lags1	49,45%	57,28%	60,61%	65,46%	66,64%	66,92%	70,53%	72,40%	73,65%	73,16%
hd2lags2	50,62%	51,32%	56,38%	58,88%	60,06%	63,52%	64,01%	64,77%	67,20%	68,24%
hd2lags3	51,11%	51,18%	50,28%	55,83%	56,17%	60,47%	61,65%	61,72%	62,55%	63,87%

hd2lags4	50,76%	50,69%	51,53%	52,50%	53,68%	56,45%	57,77%	59,36%	59,57%	59,92%
hd2lags5	50,83%	50,21%	52,22%	53,05%	52,64%	54,99%	55,69%	57,07%	57,70%	60,54%
hd2lags6	51,25%	51,11%	52,36%	52,36%	52,36%	53,26%	53,40%	54,99%	55,34%	56,80%
hd2lags7	49,72%	50,42%	52,98%	52,57%	51,53%	51,73%	53,95%	54,09%	55,48%	57,14%
hd3lags1	50,62%	58,88%	62,55%	67,06%	67,89%	69,63%	71,22%	72,82%	75,10%	74,76%
hd3lags2	51,04%	49,93%	56,80%	60,54%	60,06%	64,22%	64,08%	66,57%	68,17%	69,07%
hd3lags3	50,07%	50,28%	50,90%	56,31%	56,03%	60,12%	62,00%	62,83%	63,73%	63,87%
hd3lags4	50,90%	50,69%	51,73%	53,61%	54,44%	58,53%	58,46%	61,17%	62,34%	62,07%
hd3lags5	49,79%	49,45%	50,49%	52,43%	51,66%	54,51%	55,96%	57,98%	59,78%	60,26%
hd3lags6	51,04%	50,21%	51,73%	52,77%	51,46%	52,91%	53,54%	54,51%	55,76%	56,10%
hd3lags7	49,72%	50,97%	53,12%	52,64%	51,94%	53,95%	54,09%	54,16%	55,62%	57,21%
hd4lags1	48,89%	59,22%	61,37%	66,71%	66,99%	69,56%	70,25%	72,68%	74,90%	74,41%
hd4lags2	51,18%	49,93%	56,31%	60,12%	60,68%	62,41%	64,70%	66,30%	69,35%	67,13%
hd4lags3	50,07%	52,15%	51,25%	57,14%	56,24%	60,12%	61,79%	62,55%	63,11%	63,38%
hd4lags4	50,90%	51,80%	51,94%	52,77%	54,44%	57,77%	57,56%	58,39%	60,26%	60,61%
hd4lags5	51,53%	49,79%	52,22%	53,68%	53,26%	55,96%	56,52%	57,63%	60,06%	58,32%
hd4lags6	51,46%	51,80%	51,39%	52,22%	51,80%	52,84%	51,66%	54,99%	56,24%	55,34%
hd4lags7	51,18%	51,11%	52,91%	52,15%	52,64%	53,05%	53,19%	54,58%	55,62%	54,99%
hd5lags1	50,21%	57,77%	61,93%	65,88%	67,75%	68,45%	69,69%	72,40%	73,99%	73,65%
hd5lags2	50,28%	51,18%	55,27%	59,71%	60,12%	63,80%	62,90%	66,09%	67,34%	68,17%
hd5lags3	50,42%	52,84%	51,80%	56,52%	57,35%	60,54%	61,58%	62,14%	64,08%	64,36%
hd5lags4	52,15%	50,62%	52,15%	54,30%	55,55%	57,07%	58,04%	59,29%	61,23%	62,55%
hd5lags5	49,31%	50,90%	51,80%	53,68%	52,98%	55,76%	55,55%	57,70%	59,29%	60,06%
hd5lags6	50,83%	51,25%	51,32%	53,33%	51,87%	54,79%	53,95%	55,13%	56,66%	57,35%
hd5lags7	49,58%	51,46%	52,70%	52,15%	52,70%	53,54%	53,95%	54,30%	55,41%	56,80%
hd6lags1	49,31%	59,15%	62,76%	66,57%	66,71%	67,89%	69,49%	73,16%	73,99%	73,02%
hd6lags2	50,14%	51,39%	56,80%	60,82%	61,10%	63,04%	64,56%	65,40%	67,34%	69,63%
hd6lags3	49,93%	53,05%	50,83%	56,17%	55,34%	60,26%	60,89%	62,76%	63,52%	64,29%
hd6lags4	50,62%	51,39%	51,18%	53,81%	54,58%	56,87%	58,88%	59,99%	60,89%	61,65%
hd6lags5	51,87%	51,25%	52,91%	53,26%	51,80%	54,79%	56,59%	57,98%	59,02%	59,15%
hd6lags6	51,04%	50,55%	52,84%	53,47%	52,15%	52,50%	53,33%	55,41%	55,89%	56,45%
hd6lags7	51,80%	51,53%	52,57%	52,77%	53,47%	54,85%	53,05%	54,85%	56,45%	57,07%
hd7lags1	53,95%	55,06%	55,55%	55,20%	55,34%	56,59%	57,63%	56,80%	57,14%	56,03%
hd7lags2	53,19%	53,95%	53,33%	53,74%	54,16%	55,96%	56,52%	56,24%	56,59%	55,55%
hd7lags3	52,91%	52,50%	54,23%	53,40%	53,81%	55,69%	56,45%	56,45%	56,17%	55,96%
hd7lags4	54,79%	53,81%	54,09%	55,96%	54,58%	54,99%	57,56%	57,00%	57,42%	55,83%
hd7lags5	53,88%	54,44%	54,92%	55,62%	56,87%	55,76%	56,17%	56,17%	56,93%	56,38%
hd7lags6	52,91%	52,84%	53,88%	54,79%	55,62%	58,67%	56,45%	56,45%	57,84%	56,73%
hd7lags7	53,68%	53,40%	54,92%	54,16%	55,55%	57,49%	58,46%	56,80%	57,49%	56,45%



Rysunek 43. Wyniki trafności dla sieci LSTM i pary walutowej CHF/EUR – wykres radarowy

Uwaga: Na wykresie radarowym na okręgu rozmieszczono ustawienia sieci a odległość wykresu od środka określa trafność uzyskaną przez daną sieć

Podsumowując wnioski uzyskane dla wszystkich typów sieci neuronowych, przede wszystkim należy wskazać na najwyższy odsetek poprawnie zaprognozowanych kierunków zmian przez sieć LSTM, szczególnie dla ustawień o dwóch węzłach ukrytych (hd1). Przy prognozowaniu siecią MLP, w przypadku części badanych walut oraz horyzontów prognoz można zauważyć poprawę trafności, kiedy liczba opóźnień stosowana w ustawieniach tej sieci jest równa prognozowanemu horyzontowi. Dla sieci MLP zauważono również unikatowe ustawienia, dla których sieć dawała trafniejsze prognozy niż przy wszystkich innych ustawieniach, niezależnie od horyzontu prognozy. Dla sieci ELM najtrudniej było określić zależności między trafnością prognoz i ustawieniami sieci, a horyzontem prognozy czy prognozowaną parą walutową.

3.3. Badanie porównawcze trafności sieci neuronowych o różnych ustawieniach z klasycznymi modelami ekonometrycznymi

Celem tego badania było uzyskanie informacji o jakości prognoz klasycznymi modelami ekonometrycznymi (ARMA) i podejściem naiwnym. Opis metody, jaką zastosowano w celu uzyskania wyników dla prognozowania naiwnego oraz z wykorzystaniem modelu ARMA, został przedstawiony w rozdziale II. Wyniki modeli klasycznych będą stanowić bazę dla porównań

wyników uzyskiwanych przez inne modele. W tabeli 14. przedstawiono procentowe wartości poprawnych prognoz kierunku zmian kursów uzyskane prognozą naiwną. Zauważamy, że trafność oscyluje w granicach 50%, przy czym zdecydowanie najniższa została uzyskana dla pary walutowej USD/EUR. Dla par walutowych CHF/EUR oraz GBP/EUR można zauważyć najlepszą trafność dla horyzontów prognozy na od 4 do 8 dni.

Tabela 14. Trafność prognozowania uzyskana z zastosowaniem metody naiwnej dla CHF/EUR, GBP/EUR oraz USD/EUR w latach 2014-2019

Para walutowa	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
CHF/EUR	47,74%	49,65%	50,80%	50,21%	49,34%	51,18%	51,08%	50,49%	48,29%	48,53%
GBP/EUR	49,13%	49,72%	49,55%	50,90%	50,87%	51,60%	51,22%	51,95%	50,10%	46,71%
USD/EUR	47,05%	49,09%	48,23%	49,30%	48,30%	48,19%	46,20%	45,88%	44,59%	44,62%

Uwaga: t+i oznacza prognozę na i dni do przodu

W przypadku modelu ARMA, na początku automatycznie dopasowałem najlepszy model korzystając z pakietu R *forecast* (Hyndman i inni, 2021). Wykorzystana funkcja zwraca 5 najlepiej dopasowanych modeli, wybranych poprzez minimalizację kryteriów informacyjnych. W celu wybrania najkorzystniejszego modelu z pięciu zaproponowanych przez bibliotekę, zastosowano następujący schemat:

- Wybór odpowiedniego modelu, dla każdej pary walutowej innego, na podstawie minimalizacji kryteriów informacyjnych AIC i BIC (opisane w II.1.2.1) – z wykorzystaniem pakietu *forecast* (Hyndman, Khandakar, 2008).
- Dla zwróconych modeli ARMA sprawdzenie trafności prognoz dla trzech par walutowych CHF/EUR, GBP/EUR oraz USD/EUR.
- Wybór modelu ARMA, który dla danej pary walutowej charakteryzował się najlepszą trafnością, jako modelu do porównań.

Trafność prognoz z modeli ARMA przedstawiono w tabeli 15.

Tabela 15. Trafność prognozowania uzyskana z zastosowaniem modelu ARMA dla CHF/EUR, GBP/EUR oraz USD/EUR w latach 2014-2019

Para walutowa	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
CHF/EUR	53,26%	54,30%	53,88%	54,44%	53,81%	54,44%	56,17%	55,20%	55,27%	54,58%
GBP/EUR	48,54%	49,24%	50,21%	50,00%	51,04%	49,31%	49,24%	50,00%	50,35%	51,25%
USD/EUR	49,10%	47,02%	46,26%	46,46%	46,19%	46,05%	45,98%	46,12%	46,19%	45,63%

Uwaga: t+i oznacza prognozę na i dni do przodu

Na podstawie wyników w tabeli 14. oraz 15. możemy stwierdzić, że prognozy kierunku zmian uzyskane z modelu ARMA były lepsze niż prognoza naiwna w 18 na 30 przypadków. Przy tym, dla pary CHF/EUR model ARMA zawsze charakteryzował się wyższą skutecznością niż prognoza naiwna, natomiast dla GBP/EUR oraz USD/EUR model ARMA uzyskał cztery razy lepszą trafność (prognoza na $t+9$ oraz $t+10$ dla obu par walutowych oraz dodatkowo dla GBP/EUR $t+3$ i $t+5$ a dla USD/EUR $t+1$ i $t+8$), a sześciokrotnie lepsza była prognoza naiwna. Różnice w trafności prognoz modelem ARMA i prognozy naiwnej najbardziej widoczne są dla pary CHF/EUR (maksymalna różnica 6,98% dla $t+9$ a minimalna 3,08% dla $t+3$).

Zgodnie z wcześniejszymi założeniami, porównane zostały wyniki sieci neuronowych i modeli klasycznych. W celu porównania wyników zastosowano średni wynik, jaki uzyskiwała każda z sieci neuronowych dla danej waluty i danego horyzontu prognozy. Wyniki te przedstawiam w tabelach 16-19. W tabeli 16. oraz 18. słowo: „sieci” oznacza, że dla danych parametrów lepsze wyniki uzyskała sieć neuronowa w porównaniu do prognozy naiwnej lub ARMA, natomiast „naiwna” lub „ARMA” oznacza, że trafność prognoz uzyskanych z wykorzystaniem odpowiednich modeli klasycznych była wyższa. W tabeli 17. widoczna jest przewaga sieci neuronowych nad prognozą naiwną. Ich trafność była lepsza w 121 na 180 przypadków. Prognoza naiwna okazała się trafniejsza 59 razy, z czego aż 37 z tych 59 dotyczy pary walutowej CHF/EUR, gdy prognozy sieciami były dokonywane na zwrotach logarytmicznych.

W opisywanej części rozdziału przedstawiam wyniki kilkunastu badań porównawczych mających na celu zestawienie ze sobą trafności prognozowania uzyskiwanych przez różne metody. W celu sprawdzenia statystycznej istotności różnic między wynikami, dla każdego badania porównawczego zostanie wykonany Test Z dla dwóch niezależnych proporcji. Statystyka testowa ma postać:

$$Z = \frac{p_1 - p_2}{\sqrt{p(1-p)\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \quad (27)$$

gdzie:

- p_1 oraz p_2 , to trafność prognoz dla porównywanych metod,
- n_1 oraz n_2 , liczebność prób (tu: liczba prognoz),

- $p = \frac{m_1+m_2}{n_1+n_2}$, gdzie m_1 oraz m_2 to liczba poprawnie zaprognozowanych kierunków przez daną metodę.

Hipotezę weryfikuję analizując trzy poziomy istotności: 0,01 (oznaczane w tabelach „***”), 0,05 (oznaczane w tabelach „**”), 0,1 (oznaczane w tabelach „*”). Wartości powyżej 0,1 zakładają brak podstaw do odrzucenia hipotezy zerowej o braku statystycznie istotnej różnicy między trafnościami prognoz.

Tabela 16. Porównanie wyników sieci neuronowych i prognozy naiwnej

Para walutowa	Typ danych	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10	
CHF/EUR	Poziomy cen	ELM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	
		MLP	sieci	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	sieci	naiwna
		LSTM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci
	Zwroty	ELM	sieci	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna
		MLP	sieci	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna
		LSTM	sieci	naiwna	naiwna	naiwna	sieci	naiwna	naiwna	naiwna	naiwna	sieci	sieci
GBP/EUR	Poziomy cen	ELM	sieci	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	
		MLP	sieci	sieci	sieci	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	sieci	
		LSTM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	
	Zwroty	ELM	sieci	sieci	naiwna	naiwna	sieci	naiwna	sieci	naiwna	sieci	sieci	sieci
		MLP	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci
		LSTM	sieci	sieci	sieci	naiwna	naiwna	naiwna	naiwna	naiwna	naiwna	sieci	sieci
USD/EUR	Poziomy cen	ELM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	
		MLP	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	
		LSTM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	
	Zwroty	ELM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci
		MLP	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci
		LSTM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci

Uwaga: „sieci” oznacza, że dla danych parametrów lepsze wyniki uzyskała sieć neuronowa w porównaniu do prognozy naiwnej, natomiast „naiwna” oznacza, że prognoza naiwna uzyskała wyższe trafności prognoz niż sieci neuronowe. Przez lepsze wyniki rozumie się większą liczbę poprawie zaprognozowanych kierunków zmian.

Tabelach 17. i 19. przedstawiam różnice między wynikami trafności prognoz sieci neuronowych porównywanych do nich modeli klasycznych. W związku z tym, wyniki dodatnie są tożsame z przewagą trafności sieci neuronowych nad modelami klasycznymi, a wyniki ujemne oznaczają przewagę trafności modeli klasycznych. Kolorem czerwonym zaznaczono wartości ujemne, czyli te, dla których wyższy poziom trafności uzyskały modele klasyczne.

Tabela 17. Porównanie wyników sieci neuronowych i prognozy naiwnej – różnice procentowe między trafnościami prognozowania

Para walutowa	Typ danych	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
CHF/EUR	Poziomy	ELM	4,11%**	1,30%	1,41%	3,01%*	4,27%**	3,03%*	2,91%*	3,17%**	5,47%***	4,70%***
		MLP	1,34%	-1,89%	-3,45%**	-2,01%	-1,60%	-2,65%*	-1,74%	-1,71%	1,77%	-0,04%
		LSTM	2,14%*	3,38%**	2,97%***	5,72%***	7,82%***	5,27%***	4,83%***	7,95%***	14,18%***	12,38%***
	Zwroty	ELM	0,63%	-2,77%**	-4,85%***	-4,55%***	-3,51%**	-6,85%***	-6,52%***	-5,52%***	-3,00%*	-3,20%**
		MLP	1,91%	-0,06%	-3,18%**	-2,35%	-2,42%*	-4,67%***	-4,65%***	-3,65%**	-1,90%	-2,24%
		LSTM	1,82%	-0,53%	-0,52%	-0,66%	0,42%	-1,78%	-3,00%*	-1,79%	0,28%	0,72%
GBP/EUR	Poziomy	ELM	0,36%	-1,70%	-1,25%	-2,84%*	-3,12%**	-3,78%**	-4,18%**	-4,98%***	-3,53%**	-0,42%
		MLP	1,38%	0,15%	0,27%	-0,61%	-1,13%	-2,45%*	-2,23%	-2,41%*	-0,27%	3,05%*
		LSTM	1,62%	1,13%	2,61%*	2,50%*	3,60%**	3,46%**	5,43%***	6,27%***	9,30%***	12,87%***
	Zwroty	ELM	0,16%	0,54%	-0,20%	-0,88%	0,26%	-0,87%	0,51%	-0,09%	1,88%	6,14%***
		MLP	0,21%	0,87%	0,98%	0,03%	0,76%	0,34%	0,98%	0,49%	2,40%*	6,30%***
		LSTM	0,67%	0,70%	0,21%	-1,44%	-1,19%	-0,85%	-0,54%	-3,14%**	0,26%	4,05%**
USD/EUR	Poziomy	ELM	5,62%***	3,29%**	6,27%***	5,10%***	6,68%***	7,86%***	9,42%***	9,70%***	10,91%***	9,68%***
		MLP	6,69%***	4,76%***	6,18%***	5,28%***	6,81%***	8,32%***	10,75%***	10,57%***	12,71%***	11,59%***
		LSTM	3,50%**	2,84%**	5,60%***	6,74%***	7,87%***	10,14%***	12,93%***	14,77%***	17,36%***	17,69%***
	Zwroty	ELM	3,46%**	3,28%**	3,41%**	1,84%	3,80%**	4,17%**	7,73%***	9,70%***	10,99%***	11,18%***
		MLP	3,31%**	2,59%*	1,51%	0,01%	1,56%	1,43%	4,72%	6,93%***	8,51%***	9,36%***
		LSTM	4,94%***	1,57%	3,14%**	1,37%	3,48%**	3,44%**	5,72%***	5,67%***	6,72%***	5,63%***

Uwaga: W tabeli zaprezentowano różnice między średnią trafnością dla typów sieci neuronowych a trafnością prognozy naiwnej. W tabeli dodatnie wartości są tożsame z przewagą prognozy sieciami neuronowymi nad prognozą naiwną a wyniki ujemne przewagą modeli klasycznych. Kolorem czerwonym zaznaczono wartości ujemne, czyli te dla których wyższy poziom trafności uzyskała prognoza naiwna. W badaniu przyjęto trzy poziomy istotności dla testu na istotną różnicę między porównywanymi zmiennymi: 0,01 - ***, 0,05 - **, 0,1 - *

W tabeli 17. 110 różnic zostało uznanych za istotne i aż 63 z nich przy najbardziej restrykcyjnym poziomie istotności. Pozostałe 70 różnic, które nie zostały uznane za istotne, dotyczy głównie pary walutowej GBP/EUR. W przypadku dwóch pozostałych par walutowych, prognozy nieistotnie różne od prognoz naiwnych zostały postawione przez sieci uczące się na zwrotach. W tabeli 18. przedstawiono analogiczne porównanie wyników modelu ARMA z wynikami sieci neuronowych. Modele ARMA wykazały się lepszą trafnością w 76 razy na 180 możliwości, co daje przewagę sieci neuronowych w stosunku 104 do 76 na korzyść prognozowania sieciami neuronowymi.

Tabela 18. Porównanie wyników sieci neuronowych i prognozy naiwnej

Para walutowa	Typ danych	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10	
CHF/EUR	Poziomy cen	ELM	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	
		MLP	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	
		LSTM	ARMA	ARMA	ARMA	sieci	sieci	sieci	ARMA	sieci	sieci	sieci	
	Zwroty	ELM	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA
		MLP	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA
		LSTM	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA
GBP/EUR	Poziomy cen	ELM	sieci	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	
		MLP	sieci	sieci	ARMA	sieci	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	
		LSTM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	
	Zwroty	ELM	sieci	sieci	ARMA	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci
		MLP	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci
		LSTM	sieci	sieci	ARMA	ARMA	ARMA	sieci	sieci	ARMA	sieci	ARMA	
USD/EUR	Poziomy cen	ELM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	
		MLP	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	
		LSTM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	
	Zwroty	ELM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci
		MLP	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci
		LSTM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci

Uwaga: „sieci” oznacza, że dla danych parametrów lepsze wyniki uzyskała sieć neuronowa w porównaniu do prognozy modelem ARMA, natomiast „ARMA” oznacza, że model ARMA uzyskał wyższe trafności prognoz niż sieci neuronowe. Przez lepsze wyniki rozumie się większą liczbę poprawie zaprognozowanych kierunków zmian.

Tabela 19. Porównanie wyników sieci neuronowych i modelu ARMA – różnice procentowe między trafnościami prognozowania

Para walutowa	Typ danych	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
CHF/EUR	Poziomy	ELM	-1,41%	-3,35%***	-1,67%	-1,22%	-0,20%	-0,23%	-2,18%	-1,54%	-1,51%	-1,35%
		MLP	-4,18%**	-6,54%***	-6,53%***	-6,24%***	-6,07%***	-5,91%***	-6,83%***	-6,42%***	-5,21%***	-6,09%***
		LSTM	-3,38%*	-1,26%	-0,11%	1,49%	3,35%**	2,01%	-0,26%	3,24%*	7,20%***	6,33%***
	Zwroty	ELM	-4,89%***	-7,42%***	-7,94%***	-8,78%***	-7,98%***	-10,11%***	-11,61%***	-10,23%***	-9,98%***	-9,25%***
		MLP	-3,61%**	-4,71%***	-6,27%***	-6,57%***	-6,89%***	-7,93%***	-9,74%***	-8,36%***	-8,88%***	-8,29%***
		LSTM	-3,70%**	-5,18%***	-3,60%**	-4,89%***	-4,05%***	-5,04%***	-8,09%***	-6,51%***	-6,70%***	-5,33%***
GBP/EUR	Poziomy	ELM	0,95%	-1,21%	-1,90%	-1,94%	-3,29%**	-1,48%	-2,20%	-3,03%*	-3,78%**	-4,96%***
		MLP	1,96%	0,63%	-0,38%	0,29%	-1,30%	-0,16%	-0,25%	-0,46%	-0,52%	-1,49%
		LSTM	2,21%*	1,61%	1,95%	3,40%**	3,43%**	5,76%***	7,42%***	8,22%***	9,05%***	8,34%***
	Zwroty	ELM	0,75%	1,02%	-0,86%	0,02%	0,09%	1,42%	2,49%*	1,86%	1,63%	1,60%
		MLP	0,80%	1,35%	0,32%	0,93%	0,59%	2,64%*	2,97%*	2,44%*	2,16%	1,76%
		LSTM	1,26%	1,19%	-0,45%	-0,54%	-1,36%	1,45%	1,44%	-1,19%	0,01%	-0,49%
USD/EUR	Poziomy	ELM	3,57%**	5,36%***	8,25%***	7,93%***	8,79%***	10,00%***	9,64%***	9,47%***	9,32%***	8,67%***
		MLP	4,64%***	6,83%***	8,16%***	8,11%***	8,92%***	10,46%***	10,97%***	10,33%***	11,12%***	10,58%***
		LSTM	1,45%	4,91%***	7,58%***	9,58%***	9,98%***	12,28%***	13,15%***	14,54%***	15,77%***	16,67%***
	Zwroty	ELM	1,41%	5,35%***	5,39%***	4,67%***	5,91%***	6,31%***	7,95%***	9,46%***	9,39%***	10,17%***
		MLP	1,27%	4,66%***	3,48%**	2,85%*	3,67%**	3,57%**	4,94%***	6,69%***	6,92%***	8,35%***
		LSTM	2,89%**	3,65%**	5,11%***	4,21%**	5,60%***	5,58%***	5,94%***	5,43%***	5,12%***	4,62%**

*Uwaga: W tabeli dodatnie wartości są tożsame z przewagą prognozy sieciami neuronowymi nad prognozą modelem ARMA a wyniki ujemne przewagą modeli klasycznych. Kolorem czerwonym zaznaczono wartości ujemne, czyli te dla których wyższy poziom trafności uzyskała prognoza modelem ARMA. W badaniu przyjęto trzy poziomy istotności dla testu na istotną różnicę między porównywanymi zmiennymi: 0,01 - ***, 0,05 - **, 0,1 - *.*

Dla pary walutowej CHF/EUR, prognozy z modelu ARMA cechowały się stosunkowo dobrą trafnością (między 53 a 56%), dlatego okazały się lepsze niż średnie wyniki sieci dla tej pary walutowej. Większość z różnic jest istotna statystycznie. Dla tej samej pary walutowej prognoza naiwna także charakteryzowała się wysoką trafnością. Również dla pary walutowej GBP/EUR w kilku przypadkach uzyskano lepsze wyniki kierując się prognozą naiwną. Ponownie, najmniej istotnych statystycznie różnic w trafnościach odnotowano dla pary GBP/EUR, dla której trafność modeli ARMA oraz sieci neuronowych różnią się tylko nieznacznie. Warto zauważyć, że dla USD/EUR ani razu nie uzyskano lepszej trafności kierując się prognozą naiwną i wskazaniem ARMA w porównaniu do średniej trafności sieci neuronowych. Należy tu podkreślić, że para walutowa USD/EUR w badanym okresie charakteryzowała się najniższą kurtozą co mogło ułatwić prognozowanie z wykorzystaniem prostszych modeli oraz doprowadzić do przeuczenia sieci. Zestawienie trafności modeli klasycznych ze średnimi wynikami sieci stanowi dobry punkt odniesienia do dalszych badań mających na celu poprawę trafności prognoz.

3.4 Trafność prognozowania kierunku zmiany kursu – porównanie wyników dla sieci uczonych na cenach i zwrotach

W niniejszym podrozdziale przedstawione zostaną zbiorcze wyniki trafności prognoz przedstawionych w podrozdziale 5.2. Porównano trafność prognoz sieci o tych samych ustawieniach. tabela 20. przedstawia procentowy udział przypadków, w których lepsza okazała się trafność prognoz sieci, których uczenie odbywało się na poziomach cen. Taki sposób prezentacji wyników ma na celu ukazanie, która metoda okazała się lepsza, a nie o ile lepsza. Wyniki porównano ze względu na walutę oraz rodzaj sieci neuronowej. Dla CHF/EUR i sieci ELM 100% oznacza, że we wszystkich 490 przypadkach lepsze wyniki uzyskały sieci uczące się na poziomach cen (490, ze względu na 49 różnych ustawień sieci i 10 różnych horyzontów inwestycji).

Tabela 20. Procentowy udział ustawień sieci, dla których lepsze wyniki generowane były dla uczenia na poziomach cen

Para walutowa	ELM	MLP	LSTM
CHF/EUR	100%	64,49%	92,38%
GBP/EUR	7,96%	16,73%	74,29%
USD/EUR	73,06%	99,39%	81,19%

W związku z dużą ogólnością powyższej tabeli, w tabeli 21. pokazuję dodatkowo podział ze względu na horyzont inwestycji. W tabeli 21. *P* oznacza przewagę prognoz dokonywanych sieciami uczącymi się na poziomach cen, natomiast *Z* na stopach zwrotu. Natomiast w tabeli 21. przedstawiono procentową przewagę, jaką uzyskała metoda uczenia na poziomach, nad metodą uczenia na stopach zwrotu. Czerwonym kolorem zaznaczono wartości ujemne, czyli sytuacje, w której to ta druga okazała się lepsza (por. też: tabela 21.). W tabeli 21. możemy zauważyć, że porównując średnią trafność dla danego typu sieci neuronowej aż w 4 przypadkach na 9 (CHF/EUR – ELM i LSTM, GBP/EUR – LSTM oraz USD/EUR – MLP) we wszystkich 10 horyzontach prognozy lepsze były średnie trafności dla prognoz na poziomach niż na zwrotach.

Tabela 21. Porównanie wyników uczenia sieci neuronowej na poziomach cen i logarytmicznych stopach zwrotu

Para walutowa	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
CHF/EUR	ELM	P	P	P	P	P	P	P	P	P	P
	MLP	Z	Z	Z	P	P	P	P	P	P	P
	LSTM	P	P	P	P	P	P	P	P	P	P
GBP/EUR	ELM	P	Z	Z	Z	Z	Z	Z	Z	Z	Z
	MLP	P	Z	Z	Z	Z	Z	Z	Z	Z	Z
	LSTM	P	P	P	P	P	P	P	P	P	P
USD/EUR	ELM	P	P	P	P	P	P	P	P	Z	Z
	MLP	P	P	P	P	P	P	P	P	P	P
	LSTM	Z	P	P	P	P	P	P	P	P	P

Uwaga: „Z” oznacza sytuacje dla której dla danej pary walutowej i przy danym horyzontie prognozy trafniejsze prognozy uzyskały sieci prognozujące na zwrotach logarytmicznych natomiast „P” gdy prognozują na poziomach cen

Tabela 22. Procentowa różnica trafności sieci neuronowej na poziomach cen i logarytmicznych stopach zwrotu

Para walutowa	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
CHF/EUR	ELM	3,49%**	4,07%***	6,26%***	7,56%***	7,78%***	9,88%***	9,43%***	8,69%***	8,47%***	7,90%***
	MLP	-0,57%	-1,83%	-0,27%	0,33%	0,82%	2,02%	2,92%*	1,94%	3,67%**	2,20%
	LSTM	0,32%	3,92%**	3,49%***	6,38%***	7,40%***	7,05%***	7,83%***	9,74%***	13,90%***	11,66%***
GBP/EUR	ELM	0,20%	-2,23%	-1,04%	-1,96%	-3,38%**	-2,90%*	-4,69%***	-4,89%***	-5,41%***	-6,57%***
	MLP	1,17%	-0,72%	-0,71%	-0,64%	-1,89%	-2,80%**	-3,21%**	-2,91%*	-2,67%*	-3,25%**
	LSTM	0,95%	0,43%	2,40%*	3,94%***	4,79%***	4,31%**	5,97%***	9,42%***	9,04%***	8,82%***
USD/EUR	ELM	2,16%	0,01%	2,86%*	3,26%**	2,88%*	3,69%**	1,69%	0,01%	-0,08%	-1,50%
	MLP	3,37%**	2,17%	4,67%***	5,27%***	5,25%***	6,89%***	6,03%***	3,64%**	4,20%**	2,23%
	LSTM	-1,44%	1,27%	2,46%*	5,37%***	4,38%***	6,71%***	7,21%***	9,11%***	10,64%***	12,06%***

*Uwaga: Wartości dodatnie w tabeli oznaczają sytuacje, dla której dla danej pary walutowej i przy danym horyzoncie prognozy trafniejsze prognozy uzyskały sieci prognozujące na poziomach cen a wartości oznaczają różnice między prognozą na poziomach cen a prognozą na logarytmicznych stopach zwrotu. Ujemne wartości zaznaczono kolorem czerwonym i oznaczają lepszą trafność prognoz na stopach zwrotu. W badaniu przyjęto trzy poziomy istotności dla testu na istotną różnicę między porównywanymi zmiennymi: mniejszą od 0,01 - ***, 0,05 - **, 0,1 - **

Na podstawie tabeli 21. stwierdzam, iż trafność prognoz sieci uczących się na logarytmicznych stopach zwrotu była wyższa niż tych uczących się na poziomach cen 24 razy, z czego tylko 11 takich przypadków zostało uznanych za statystycznie istotne. Dla sieci uczących się na poziomach cen trafność prognoz była lepsza w 66 przypadkach, przy czym dla 49 z nich były to różnice istotne statystycznie. W związku z powyższymi wynikami, w dalszych badaniach stosowane będą prognozy dokonywane na poziomach cen, zarówno w badaniach nad metodami mającymi na celu poprawę wyników jak i jako punkt odniesienia służący do porównywania tych metod do trafności samych sieci neuronowych.

W tabeli 23. zaprezentowano zbiorcze odpowiedzi na pytania badawcze analizowane w podrozdziałach 3.1.-3.4.

Tabela 23. Odpowiedzi na pytania badawcze z I etapu rozprawy doktorskiej - prognozowanie z wykorzystaniem sieci neuronowych

Numer pytania	Treść pytania	Odpowiedź
1.1.	Czy trafność prognozowania kierunku zmian kursu zależy od horyzontu prognozy?	Odpowiedź na to pytanie zależy od typu sieci neuronowej. LSTM osiągnęła wyższą trafność dla prognoz o dłuższym horyzoncie, a dla pozostałych sieci jednoznaczne zależności nie istnieją. Przykładowo, dla sieci ELM prognozującej parę walutową CHF/EUR wraz ze wzrostem horyzontu trafność maleje, a dla tej samej sieci prognozującej parę GBP/EUR trafność prognoz rośnie wraz ze wzrostem horyzontu prognozy.
1.2.	Czy trafność prognozowania kierunku zmian kursu zależy od hiperparametryzacji sieci?	Wnioski zależą od typu sieci. W przypadku sieci LSTM i MLP trafność prognozowania zależy od parametrów sieci. Sieć LSTM uzyskiwała najwyższą trafność przy

		ustawieniach z dwoma węzłami ukrytymi. Sieć MLP w wielu przypadkach uzyskiwała trafniejsze prognozy, gdy liczba opóźnień w sieci była równa długości horyzontu prognozy. W przypadku sieci ELM nie stwierdzono istnienia wyraźnych wzorców.
1.3.	Czy trafność prognozowania kierunku zmian jest uzależniona od typu sieci?	Najwyższą trafnością prognoz kierunków zmian charakteryzowała się sieć LSTM, szczególnie dla ustawień o dwóch węzłach ukrytych. Wniosek z pytania badawczego 1.3. jest wynikiem zgodnym z wynikiem oczekiwanym przy wyborze typów sieci neuronowych do badania i wynika z specyficznej budowy sieci LSTM wykazującej lepszą trafność prognozowania szeregów czasowych.
1.4.	Czy trafność prognozowania kierunku zmian za pomocą sieci neuronowych jest wyższa niż modeli ekonometrycznych?	Wyniki badania potwierdzają, że dla większości badanych szeregów sieci neuronowe uzyskują wyższą trafność niż modele klasyczne, jednak uzależnione to jest od badanego szeregu. Sieci neuronowe a model ARMA: Dla pary walutowej USD/EUR sieci neuronowe uzyskały lepszą trafność prognoz niż modele ARMA we wszystkich przypadkach. Dla pary GBP/EUR, w większości przypadków sieci neuronowe uzyskały wyższą trafność niż ARMA (za wyjątkiem ELM i MLP uczących się na poziomach cen). Dla pary CHF/EUR prognozy z modelu ARMA charakteryzowały się wyższą trafnością niż prognozy sieci MLP i

		<p>ELM, natomiast LSTM ucząca się na poziomach cen osiągnęła wyższą trafność niż ARMA</p> <p>Sieci neuronowe a prognoza naiwna</p> <p>Dla pary walutowej USD/EUR wszystkie typy sieci okazały się lepsze niż prognozowanie naiwne. Dla pary walutowej GBP/EUR sieci ELM i MLP ucząca się na poziomach cen uzyskały niższą trafność niż prognozowanie naiwne. Dla pary walutowej CHF/EUR tylko ELM i LSTM uczące się na poziomach cen osiągnęły wyższą trafność niż prognozowanie naiwne.</p>
--	--	---

4. Trafność prognozowania kierunku zmiany kursu walutowego metodą rekurencyjną

Badanie dotyczące prognoz wszystkimi sieciami wykazało, że istnieją typy sieci lub określona hiperparametryzacja, przy której, dla danych par walutowych lub horyzontów inwestycji, sieci prognozują trafniej. W związku z tym, w tym etapie badania konstruuje prognozy z wykorzystaniem sieci o najlepszych ustawieniach uzyskanych w próbie testowej i porównuje ich trafność z benchmarkami stosowanymi w poprzednim badaniu oraz ze średnią trafnością sieci. Ściślej, w tym rozdziale poszukuję odpowiedzi na pytania badawcze:

- 2.1. Czy trafność prognoz uzyskanych metodą rekurencyjną będzie lepsza niż trafność uzyskana prognozą naiwną lub modelem ARMA?
- 2.2. Czy prognozy z metody rekurencyjnej będą trafniejsze niż średnie prognozy pojedynczych sieci?

Ten etap badania podzielony jest na dwa warianty:

- **Wariant 1** horyzont badania został podzielony na 11 równych okresów o długości 131 dni. W pierwszym okresie stawiam prognozę od 1 do 10 dni naprzód. Pod koniec okresu badam trafność kierunków prognoz w tym okresie. Na podstawie uzyskanej

trafności wybieram 20 najlepszych ustawień sieci w tym okresie (ze 140 możliwych)⁴. Z wykorzystaniem wybranych najlepszych ustawień sieci neuronowych, dokonywana jest prognoza na kolejny okres, a jej trafność oceniam tylko na podstawie ich wyników. Jednocześnie pozostałe sieci, odrzucone w okresie poprzednim, dokonują również prognoz na okres kolejny i zostają włączone do rankingu za ten okres. W związku z tym, inwestycja na okres $t + 1$ jest dokonywana na podstawie ustawień sieci neuronowych, które uzyskały najlepsze wyniki w okresie t , inwestycja na okres $t + 2$ jest dokonywana na podstawie prognoz najlepszych sieci z okresu $t + 1$ itd.

- **Wariant 2** charakteryzuje się mniejszą złożonością niż wariant 1. Zakłada on inwestowanie w okresach od $t + 1$ do $t + 10$ na podstawie prognoz dokonanych przez sieci neuronowe o ustawieniach, które uzyskały najlepsze wyniki w pierwszym okresie testowym.

W tabelach przedstawiam wyniki porównawcze dla niniejszego badania. W tabeli 24. prezentuję porównanie średniej trafności przy użyciu pierwszego wariantu rankingu ze średnią trafnością wszystkich 140 ustawień sieci neuronowych. W tabeli „PRAWDA” oznacza, że metoda rankingu poprawiła średnią trafność w stosunku do tej uzyskanej przez wszystkie sieci. W tabeli w nagłówku poprzez $1i, 2i, \dots, 10i$ oznaczono kolejne okresy, na które podzielona została badana próba.

Tabela 24. Porównanie metody rekurencyjne z aktualizacją parametrów sieci (Wariant 1) z średnią trafnością dla wszystkich sieci

Para walutowa	Horyzont prognozy	1i	2i	3i	4i	5i	6i	7i	8i	9i	10i
CHF/EUR	t+1	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA
	t+2	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+3	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+4	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+5	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+6	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+7	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+8	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+9	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+10	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA
GBP/EUR	t+1	FAŁSZ	PRAWDA	FAŁSZ	FAŁSZ	FAŁSZ	FAŁSZ	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA
	t+2	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+3	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+4	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA

⁴ Jeżeli w danym okresie ustawienia sieci z dwudziestego miejsca i kolejnych charakteryzują się takim samym poziomem trafności, wszystkie są brane pod uwagę w dalszym etapie. Oznacza to, że może być brane pod uwagę więcej niż 20 ustawień sieci.

	t+5	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+6	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+7	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+8	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+9	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+10	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
USD/EUR	t+1	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+2	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+3	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ
	t+4	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+5	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+6	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+7	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+8	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+9	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
t+10	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	
Podsumowanie	PRAWDA	23	29	28	29	21	27	29	29	28	17
	FAŁSZ	7	1	2	1	9	3	1	1	2	13

Uwaga: „PRAWDA” oznacza, że metoda rekurencyjna okazała się trafniejsza niż średnia trafności uzyskana ze wszystkich sieci, „FAŁSZ” oznacza sytuację odwrotną.

Wyniki przedstawione w tabeli 24. wykazują przewagę metody eliminującej ustawienia sieci uzyskujące gorsze wyniki trafności w okresie poprzednim (metoda rekurencyjna) w porównaniu do średniej trafności wszystkich sieci. W tabeli 25. przedstawiono różnice procentowe między trafnością uzyskaną w badaniu tymi dwiema metodami. Kolorem niebieskim zaznaczono przewagę metody eliminującej. Można zauważyć znaczącą poprawę wyników we wszystkich dziesięciu podokresach oraz dla wszystkich horyzontów inwestycji i par walutowych. Najmniejszą poprawę zanotowano dla horyzontu t+1 (czyli prognoz na dzień następny) dla wszystkich par walutowych. Dla CHF/EUR oraz GBP/EUR można zauważyć tendencje wskazującą na wzrost przewagi metody rekurencyjnej nad średnią z wszystkich sieci, wraz ze wzrostem długości horyzontu prognozy. Ostatni wiersz tabeli jest średnią z danej kolumny. W tabelach 25, 27, 29 oraz 31 zaznaczono istotność różnic między porównywanymi metodami, zgodnie z wcześniej przyjętymi założeniami, a w tabeli 32. przedstawiono podsumowanie testu istotności dla porównania metody rekurencyjnej z sieciami neuronowymi.

Tabela 25. Porównanie metody rekurencyjnej do średniej wszystkich sieci (wariant 1) – procentowe różnice między trafnościami prognozowania

Para walutowa	Horyzont prognozy	1i	2i	3i	4i	5i	6i	7i	8i	9i	10i
CHF/EUR	t+1	1,55%	0,78%	2,05%	1,35%	-2,51%*	-0,34%	1,56%	2,88%**	-1,09%	2,11%
	t+2	-0,44%	4,90%***	9,17%***	2,83%*	-0,89%	-2,63%*	2,85%*	1,83%	2,04%	5,48%***
	t+3	-1,95%	6,69%***	12,78%***	2,29%	1,11%	3,66%**	5,61%***	5,11%***	4,28%**	7,03%***

	t+4	7,22%***	9,90%***	13,43%***	5,64%***	2,15%	5,62%***	5,33%***	4,12%**	7,63%***	-1,43%
	t+5	6,32%***	10,22%***	18,33%***	7,61%***	4,95%***	13,46%***	7,88%***	7,70%***	8,09%***	-1,71%
	t+6	-5,01%***	8,71%***	10,58%***	7,53%***	-2,27%	11,95%***	6,02%***	4,71%***	6,20%***	3,50%**
	t+7	-4,02%**	11,36%***	11,59%***	8,45%***	0,76%	12,52%***	6,14%***	4,11%**	7,12%***	-7,42%***
	t+8	3,60%**	12,80%***	13,23%***	9,45%***	4,99%***	14,99%***	9,67%***	4,09%**	8,48%***	-7,39%***
	t+9	10,47%***	22,12%***	19,62%***	6,13%***	-3,72%**	17,58%***	6,79%***	6,12%***	14,20%***	-3,59%**
	t+10	9,58%***	24,99%***	18,31%***	5,86%***	-3,08%**	12,82%***	7,18%***	6,30%***	10,73%***	-4,22%**
GBP/EUR	t+1	-0,06%	0,01%	-1,37%	-0,90%	-0,60%	-1,02%	0,20%	-0,54%	-0,44%	0,56%
	t+2	2,70%*	3,66%**	2,92%*	3,30%**	2,39%*	0,95%	2,10%	0,56%	1,34%	-0,75%
	t+3	5,29%***	0,38%	4,33%***	9,27%***	6,22%***	4,71%***	4,01%**	2,91%	1,15%	-3,27%**
	t+4	7,90%***	5,33%***	7,73%***	7,41%***	6,84%***	3,70%**	6,31%***	6,03%***	5,64%***	3,76%**
	t+5	8,65%***	6,11%***	9,84%***	9,84%***	9,79%***	2,79%**	5,74%***	7,62%***	6,11%***	8,49%***
	t+6	7,74%***	7,95%***	10,64%***	11,43%***	13,85%***	6,38%***	5,58%***	8,81%***	6,38%***	13,98%***
	t+7	12,17%***	6,76%***	10,74%***	13,35%***	14,33%***	7,77%***	10,12%***	9,57%***	5,36%***	15,40%***
	t+8	12,54%***	6,48%***	10,54%***	13,69%***	17,77%***	9,25%***	8,72%***	8,95%***	7,42%***	20,04%***
	t+9	15,59%***	10,86%***	13,97%***	14,36%***	22,14%***	7,47%***	8,38%***	9,37%***	8,72%***	24,96%***
	t+10	12,90%***	8,72%***	11,88%***	16,11%***	18,64%***	11,26%***	13,85%***	12,77%***	11,69%***	26,10%***
USD/EUR	t+1	1,14%	-0,32%	-0,69%	0,42%	-1,44%	0,22%	1,97%	1,85%	0,81%	-1,47%
	t+2	2,07%	1,38%	0,72%	1,56%	-2,34%	0,09%	1,66%	0,84%	2,73%*	-1,83%
	t+3	2,17%	4,13%**	1,38%	7,19%***	-0,62%	5,85%***	-1,12%	0,06%	2,95%*	-0,17%
	t+4	2,02%	3,63%**	4,74%***	6,35%***	1,08%	4,98%***	2,14%	2,96%	6,86%	0,48%
	t+5	-0,35%	2,04%	1,36%	8,49%***	0,01%	4,40%***	0,90%	3,09%	6,03%	-5,68%***
	t+6	-0,51%	1,84%	5,11%***	8,98%***	4,79%***	7,16%***	4,19%**	1,71%	10,14%***	-5,25%***
	t+7	6,23%***	9,21%***	11,70%***	7,88%***	16,29%***	7,78%***	7,40%***	6,76%	10,81%***	1,00%
	t+8	0,97%	2,33%	7,15%***	7,52%***	6,03%***	7,60%***	2,83%*	2,19%	10,97%***	1,16%
	t+9	0,95%	3,40%**	6,32%***	8,66%***	15,14%***	4,75%***	6,06%***	3,36%	14,02%***	5,00%***
	t+10	1,51%	3,15%**	11,25%***	8,26%***	6,52%***	8,87%***	4,14%**	3,90%	15,95%***	5,07%***
	Średnia poprawa	4,30%	6,65%	8,65%	7,34%	5,28%	6,49%	5,14%	4,66%	6,74%	3,33%

Uwaga: Kolorem niebieskim zaznaczono sytuację, w której stosowana metoda uzyskała lepszą trafność niż średnia trafność dla wszystkich sieci. W kolumnach zaznaczone są kolejne okresy prognozy – w każdym okresie trafność pochodzi z 20 najlepszych sieci z okresu poprzedniego. W badaniu przyjęto trzy poziomy istotności dla testu na istotną różnicę między porównywanymi zmiennymi: 0,01 - ***, 0,05 - **, 0,1 - *.

W kolejnych sześciu tabelach (26-31) przedstawione zostaną wyniki metody rekurencyjnej zestawione ze średnią trafnością prognoz uzyskanych tylko przy prognozowaniu każdą z trzech typów sieci - ELM (pierwsze dwie tabele), MLP (kolejne dwie) i LSTM (ostatnie dwie). Dla ELM można zauważyć, że bardzo często metoda rekurencyjna poprawia wyniki średniej trafności prognoz. Należy jednak zwrócić szczególną uwagę na wiersze t_1 dla wszystkich par walutowych. Dla CHF/EUR i GBP/EUR aż dla 7 podokresów lepsze wyniki uzyskują sieci ELM, niż metoda rekurencyjna z wszystkich 140 ustawień 3 różnych sieci. Może to charakteryzować ELM jako sieć, która lepiej radzi sobie z prognozowaniem na krótki okres. Horyzonty prognozy, w którym średnia trafność sieci ELM jak i metody rekurencyjnej była lepsza jednakową liczbą razy (5) to $t + 1$ dla USD/EUR i $t + 2$ dla CHF/EUR

Tabela 26. Porównanie metody rekurencyjnej do średniej ELM (wariant 1)

Para walutowa	Horyzont prognozy	1i	2i	3i	4i	5i	6i	7i	8i	9i	10i
CHF/EUR	t+1	FAŁSZ	FAŁSZ	PRAWDA	FAŁSZ	FAŁSZ	FAŁSZ	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA
	t+2	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	FAŁSZ	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	PRAWDA
	t+3	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+4	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+5	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+6	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+7	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+8	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+9	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+10	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
GBP/EUR	t+1	PRAWDA	PRAWDA	FAŁSZ	FAŁSZ	FAŁSZ	FAŁSZ	FAŁSZ	FAŁSZ	FAŁSZ	PRAWDA
	t+2	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+3	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+4	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+5	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+6	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+7	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+8	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+9	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+10	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
USD/EUR	t+1	PRAWDA	PRAWDA	FAŁSZ	FAŁSZ	FAŁSZ	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+2	FAŁSZ	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+3	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ
	t+4	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+5	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+6	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+7	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+8	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+9	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+10	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
Udział	PRAWDA	19	29	25	20	26	25	27	28	27	23
	FAŁSZ	11	1	5	10	4	5	3	2	3	7

Uwaga: PRAWDA” oznacza, że metoda rekurencyjna okazała się trafniejsza niż średnia trafności uzyskana z sieci ELM, „FAŁSZ” oznacza sytuację odwrotną.

Tabela 27. Porównanie metody rekurencyjnej do średniej ELM (wariant 1) - procentowe różnice między trafnościami prognozowania

Para walutowa	Horyzont prognozy	1i	2i	3i	4i	5i	6i	7i	8i	9i	10i
CHF/EUR	t+1	-2,40%*	-0,04%	1,40%	-3,59%**	-0,04%	-0,16%	-2,42%*	0,68%	-2,03%	1,30%
	t+2	-3,48%**	5,73%***	10,16%***	-0,86%	-2,04%	-2,69%*	1,55%	-0,16%	1,54%	12,09%***
	t+3	-3,78%**	6,84%***	15,22%***	-4,53%***	3,13%**	4,28%**	0,39%	2,06%	1,90%	11,36%***

	t+4	5,25%***	9,39%***	14,44%***	-1,89%	1,98%	5,84%***	0,98%	3,05%**	7,22%***	7,04%***
	t+5	4,34%***	9,36%***	18,78%***	0,68%	9,16%***	11,84%***	2,54%*	4,82%***	8,68%***	6,17%***
	t+6	-6,75%***	7,38%***	9,69%***	-1,18%	4,23%**	8,69%***	2,92%*	1,40%	3,16%**	11,87%***
	t+7	-4,91%***	9,80%***	11,41%***	1,88%	7,94%***	11,45%***	4,84%***	0,31%	1,25%	1,30%
	t+8	3,78%**	11,61%***	14,86%***	4,08%***	11,97%***	13,11%***	9,77%***	0,98%	3,88%**	2,22%
	t+9	10,90%***	24,16%***	22,86%***	-1,31%	4,70%***	14,92%***	6,92%***	7,48%***	11,72%***	3,28%**
	t+10	10,05%***	28,32%***	21,85%***	-2,13%	2,15%	8,66%***	10,58%***	5,53%***	5,87%***	-3,36%**
GBP/EUR	t+1	0,91%	2,90%*	-1,35%	-0,73%	-0,18%	-0,23%	-0,57%	-0,66%	-0,40%	5,50%***
	t+2	5,81%***	5,05%***	4,01%**	8,03%***	5,94%***	-0,67%	2,94%*	0,09%	1,69%	4,46%***
	t+3	8,67%***	1,77%	4,94%***	14,07%***	11,42%***	4,47%***	3,71%**	3,76%**	-0,74%	10,02%***
	t+4	12,08%***	7,78%**	9,63%***	13,70%***	11,71%***	2,04%	6,42%***	6,89%***	6,24%***	22,55%***
	t+5	12,86%***	10,57%***	15,22%***	15,76%***	14,88%***	1,90%	4,34%***	7,66%***	6,42%***	27,24%***
	t+6	13,95%***	12,59%***	12,97%***	17,08%***	19,24%***	3,94%**	5,13%***	7,90%***	5,00%***	38,98%***
	t+7	19,64%***	11,46%***	15,07%***	17,38%***	20,24%***	7,52%***	10,16%***	9,89%***	5,77%***	39,85%***
	t+8	21,84%***	11,53%***	16,72%***	16,92%***	25,13%***	8,62%***	9,51%***	9,57%***	9,17%***	44,96%***
	t+9	25,55%***	16,48%***	19,86%***	19,13%***	31,01%***	8,13%***	7,55%***	11,09%***	10,99%***	54,76%***
	t+10	22,37%***	13,92%***	18,16%***	21,62%***	26,41%***	14,09%***	13,22%***	15,00%***	13,37%***	55,04%***
USD/EUR	t+1	1,30%	0,12%	-1,82%	-1,57%	-0,70%	-1,87%	1,72%	2,16%	1,92%	-3,58%**
	t+2	-0,71%	1,44%	-0,15%	-2,38%**	1,89%	0,25%	3,27%**	4,50%***	3,96%**	-2,23%
	t+3	1,18%	3,98%**	-0,48%	1,61%	2,60%*	6,38%***	-0,90%	4,68%***	1,58%	-1,12%
	t+4	1,33%	4,27%**	2,66%*	0,64%	5,33%***	6,47%***	4,24%**	9,15%***	6,28%***	-0,61%
	t+5	-1,47%	3,49%**	-1,15%	1,11%	4,46%***	4,60%***	2,93%*	8,60%***	5,02%***	-7,60%***
	t+6	-3,34%**	3,28%**	4,62%***	3,83%**	8,54%***	8,74%***	7,72%***	4,09%**	10,30%***	-4,32%***
	t+7	4,44%***	12,85%***	9,67%***	1,94%	25,45%***	9,94%***	9,23%***	9,51%***	11,81%***	2,58%*
	t+8	-2,39%*	3,57%**	7,44%***	2,43%*	14,72%***	9,73%***	6,64%***	5,98%***	12,68%***	3,22%**
	t+9	-1,68%	6,53%***	8,14%***	6,25%***	25,61%***	4,15%**	10,22%***	5,47%***	17,18%***	8,31%***
	t+10	-1,12%	6,66%***	12,60%***	5,46%***	19,22%***	10,47%***	8,13%***	7,54%***	19,52%***	6,44%***
	Średnia poprawa	5,14%	8,43%	9,91%	5,12%	10,54%	6,15%	5,12%	5,30%	6,37%	11,92%

Uwaga: Kolorem niebieskim zaznaczono sytuację, w której stosowana metoda uzyskała lepszą trafność niż średnia trafność dla sieci ELM. W kolumnach zaznaczone są kolejne okresy prognozy – w każdym okresie prognoza dokonywana jest za pomocą 20 najlepszych sieci z okresu poprzedniego. W badaniu przyjęto trzy poziomy istotności dla testu na istotną różnicę między porównywanymi zmiennymi: 0,01 - ***, 0,05 - **, 0,1 - *.

Tabela 28. Porównanie metody rekurencyjnej do średniej MLP (wariant 1)

Para walutowa	Horyzont prognozy	1i	2i	3i	4i	5i	6i	7i	8i	9i	10i
CHF/EUR	t+1	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+2	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+3	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+4	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+5	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+6	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+7	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+8	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+9	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+10	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA
GBP/EUR	t+1	FAŁSZ	FAŁSZ	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	FAŁSZ
	t+2	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+3	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+4	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+5	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+6	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+7	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+8	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+9	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+10	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
USD/EUR	t+1	FAŁSZ	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	FAŁSZ
	t+2	FAŁSZ	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ
	t+3	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ
	t+4	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ
	t+5	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ
	t+6	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ
	t+7	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+8	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ
	t+9	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+10	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA
Udział	PRAWDA	25	26	30	29	21	28	23	28	30	11
	FAŁSZ	5	4	0	1	9	2	7	2	0	19

Uwaga: „PRAWDA” oznacza, że metoda rekurencyjna okazała się trafniejsza niż średnia trafności uzyskana z sieci MLP, „FAŁSZ” oznacza sytuację odwrotną.

Tabela 29. Porównanie metody rekurencyjnej do średniej MLP (wariant 1) - procentowe różnice między trafnościami prognozowania

Para walutowa	Horyzont prognozy	1i	2i	3i	4i	5i	6i	7i	8i	9i	10i
CHF/EUR	t+1	2,13%	3,21%***	4,73%***	5,74%***	-7,40%***	-0,29%	5,00%***	3,15%**	0,40%	4,29%**
	t+2	0,67%	10,12%***	14,43%***	7,91%***	-1,18%	0,22%	5,31%***	4,78%***	6,75%***	2,93%*
	t+3	1,51%	11,93%***	17,15%***	8,97%***	0,94%	7,56%***	13,67%***	9,13%***	9,40%***	7,33%***
	t+4	11,46%***	18,30%***	19,71%***	14,16%***	3,40%**	9,12%***	10,68%***	7,64%***	12,86%***	-10,71%***

	t+5	10,51%***	18,28%***	26,33%***	16,34%***	7,47%***	19,89%***	12,00%***	13,37%***	14,09%***	-11,30%***
	t+6	0,14%	14,64%***	15,28%***	17,89%***	-2,47%*	21,49%***	10,31%***	9,52%***	14,18%***	-4,22%***
	t+7	-0,05%	17,74%***	14,93%***	17,72%***	0,55%	20,51%***	8,41%***	8,51%***	14,98%***	-14,79%***
	t+8	8,30%***	19,76%***	15,52%***	18,99%***	6,59%***	24,28%***	12,99%***	8,55%***	18,88%***	-13,92%***
	t+9	15,26%***	32,07%***	25,88%***	14,60%***	-4,22%**	27,13%***	6,96%***	9,04%***	25,13%***	-8,30%***
	t+10	14,30%***	35,85%***	25,43%***	14,29%***	-3,12%**	22,47%***	5,79%***	10,56%***	22,10%***	-12,10%***
GBP/EUR	t+1	-0,91%	-3,40%**	0,43%	-1,93%	-1,97%	0,50%	1,45%	-1,70%	1,07%	-3,71%**
	t+2	1,70%	0,60%	2,50%*	0,14%	0,82%	4,15%**	3,48%**	0,74%	2,86%*	-4,79%***
	t+3	6,33%***	-3,31%**	4,55%***	7,32%***	6,91%***	7,44%***	5,78%***	2,19%	3,55%**	-9,25%***
	t+4	7,34%***	0,77%	8,13%***	5,70%***	7,89%***	6,07%***	9,35%***	6,24%***	6,56%***	-5,17%***
	t+5	8,72%***	2,16%	9,56%***	8,51%***	10,07%***	4,93%***	9,11%***	9,27%***	8,83%***	1,19%
	t+6	6,23%***	3,57%**	12,91%***	12,01%***	15,55%***	10,38%***	8,22%***	11,22%***	11,27%***	2,10%
	t+7	11,37%***	2,91%*	13,00%***	15,09%***	16,35%***	12,22%***	14,27%***	11,22%***	7,55%***	8,48%***
	t+8	10,83%***	2,75%*	12,82%***	16,93%***	20,44%***	14,55%***	12,97%***	10,03%***	9,86%***	10,41%***
	t+9	14,58%***	7,78%***	16,05%***	17,12%***	26,53%***	11,21%***	12,52%***	9,56%***	11,88%***	12,28%***
	t+10	11,17%***	4,17%**	13,99%***	19,10%***	23,30%***	14,57%***	18,92%***	14,20%***	16,93%***	15,88%***
USD/EUR	t+1	-0,64%	-0,95%	0,38%	0,02%	-2,58%*	-1,39%	0,27%	-0,29%	0,49%	-3,72%**
	t+2	-0,04%	-0,24%	2,45%*	4,11%**	-4,73%***	0,72%	-5,32%***	0,70%	4,30%**	-2,90%*
	t+3	0,66%	2,34%	4,01%**	11,26%***	-0,75%	8,27%***	-5,80%***	0,20%	6,13%***	-2,31%
	t+4	0,70%	3,65%**	10,47%***	11,72%***	0,71%	5,75%***	-2,43%*	3,59%**	10,67%***	-0,79%
	t+5	-0,60%	0,73%	6,28%***	13,97%***	0,54%	5,49%***	-1,79%	2,23%	9,63%***	-9,69%***
	t+6	0,27%	0,26%	10,26%***	16,50%***	6,22%***	7,75%***	-0,64%	2,11%	14,08%***	-12,96%***
	t+7	7,79%***	5,57%***	18,49%***	13,61%***	16,75%***	7,51%***	2,86%*	7,02%***	14,17%***	-4,30%***
	t+8	2,45%*	1,24%	14,42%***	14,43%***	5,66%***	9,62%***	-1,87%	4,20%**	14,32%***	-3,47%**
	t+9	2,58%*	1,50%	13,72%***	14,08%***	14,87%***	6,67%***	1,15%	5,62%***	17,44%***	3,28%**
	t+10	3,57%**	1,89%	20,28%***	13,70%***	4,69%***	11,58%***	-0,18%	4,97%***	20,79%***	5,77%***
	Średnia poprawa	5,28%	7,20%	12,47%	11,67%	5,59%	10,01%	5,78%	6,25%	11,04%	-2,15%

Uwaga: Kolorem niebieskim zaznaczono sytuację, w której stosowana metoda uzyskała lepszą trafność niż średnia trafność dla sieci MLP. W kolumnach zaznaczone są kolejne okresy prognozy – w każdym okresie prognoza pochodzi z 20 najlepszych sieci z okresu poprzedniego. W badaniu przyjęto trzy poziomy istotności dla testu na istotną różnicę między porównywanymi zmiennymi: 0,01 - ***, 0,05 - **, 0,1 - *.

Dla MLP, podobnie jak dla ELM, „FAŁSZ” pojawia się częściej tylko w wierszach charakteryzujących się krótszym horyzontem prognozy – z tą różnicą, że dla GBP/EUR i USD/EUR średnia wyników sieci MLP w danym podokresie okazywała się lepsza, niż średnia wynikająca z wyboru sieci metodą rekurencyjną i o jednodniowym horyzoncie inwestycji. Dla USD/EUR i horyzontu prognozy dwa dni obie metody były równie dobre. Bardzo interesujący okazał się podokres dziesiąty, dla którego aż w 19 na 30 przypadków (dla wszystkich sieci oraz horyzontów prognozy) lepszą trafność uzyskała średnia prognoza sieci MLP niż metoda rekurencyjna – przy czym dla CHF/EUR ta ostatnia charakteryzowała się lepszą trafnością tylko dla $t + 1, t + 2$ i $t + 3$, a dla USD/EUR tylko dla $t + 9$ i $t + 10$. Oznacza to, że danym

podokresie sieci wybrane w podokresie wcześniejszym uzyskiwały średnio gorsze wyniki od wyników średnio uzyskiwanych tylko przez sieć MLP, a różnice te często były wyższe niż 10% (Tabela 29.).

Tabela 30. Porównanie metody rekurencyjnej do średniej LSTM (wariant 1)

Para walutowa	Horyzont prognozy	1i	2i	3i	4i	5i	6i	7i	8i	9i	10i
CHF/EUR	t+1	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA
	t+2	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA
	t+3	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+4	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+5	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+6	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+7	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+8	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+9	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+10	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
GBP/EUR	t+1	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	FAŁSZ	FAŁSZ
	t+2	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	FAŁSZ	FAŁSZ
	t+3	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+4	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+5	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+6	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+7	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ
	t+8	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+9	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+10	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
USD/EUR	t+1	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA
	t+2	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	FAŁSZ	FAŁSZ	PRAWDA	FAŁSZ	FAŁSZ	FAŁSZ
	t+3	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA
	t+4	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA
	t+5	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA
	t+6	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA
	t+7	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA	PRAWDA
	t+8	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA
	t+9	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA
	t+10	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	FAŁSZ	PRAWDA	PRAWDA	FAŁSZ	PRAWDA	PRAWDA
Udział	PRAWDA	25	27	21	30	13	24	28	22	24	18
	FAŁSZ	5	3	9	0	17	6	2	8	6	12

Uwaga: „PRAWDA” oznacza, że metoda rekurencyjnej okazała się trafniejsza niż średnia trafności uzyskana z sieci LSTM, „FAŁSZ” oznacza sytuację odwrotną.

Tabela 31. Porównanie metody rekurencyjnej do średniej LSTM (wariant 1) - procentowe różnice między trafnościami prognozowania

Para walutowa	Horyzont prognozy	1i	2i	3i	4i	5i	6i	7i	8i	9i	10i
CHF/EUR	t+1	5,49%***	-1,09%	-0,31%	1,99%	0,31%	-0,61%	2,20%	5,13%***	-1,72%	0,51%
	t+2	1,80%	-2,16%	1,87%	1,21%	0,79%	-5,89%***	1,51%	0,73%	-2,86%*	0,76%
	t+3	-3,87%**	0,39%	4,84%***	2,47%*	-1,04%	-1,60%	2,30%	3,98%**	1,07%	1,64%
	t+4	4,60%***	0,71%	4,93%***	4,49%***	0,90%	1,27%	4,15%**	1,25%	2,00%	-0,48%
	t+5	3,75%**	1,83%	8,48%***	5,51%***	-2,91%*	7,86%***	9,30%***	4,44%***	0,41%	0,28%
	t+6	-8,99%***	3,36%**	6,15%***	5,60%***	-9,62%***	4,63%***	4,63%***	2,96%*	0,44%	2,75%*
	t+7	-7,60%***	5,72%***	7,89%***	5,31%***	-7,39%***	4,43%***	5,03%***	3,42%**	4,79%***	-8,98%***
	t+8	-2,08%	6,06%***	8,66%***	4,58%***	-5,00%***	6,34%***	5,68%***	2,51%*	1,72%	-10,99%***
	t+9	4,39%***	8,15%***	8,53%***	4,92%***	-12,96%***	9,54%***	6,43%***	1,11%	4,36%***	-6,10%***
	t+10	3,53%**	8,45%***	5,88%***	5,35%***	-9,14%***	6,40%***	4,83%***	2,21%	3,15%**	3,97%**
GBP/EUR	t+1	-0,20%	0,61%	-3,49%**	0,10%	0,50%	-3,71%**	-0,36%	0,94%	-2,24%	-0,20%
	t+2	0,23%	5,61%***	2,15%	1,47%	0,09%	-0,91%	-0,49%	0,88%	-0,83%	-2,10%
	t+3	0,12%	3,05%*	3,37%**	5,95%***	-0,65%	1,82%	2,30%	2,74%*	0,56%	-11,81%***
	t+4	3,69%**	7,79%***	5,06%***	2,08%	-0,07%	2,87%*	2,64%*	4,77%***	3,88%**	-7,74%***
	t+5	3,66%**	5,51%***	3,88%**	4,49%***	3,52%**	1,34%	3,44%**	5,65%***	2,59%*	-4,87%***
	t+6	2,24%	7,65%***	5,28%***	4,15%**	5,57%***	4,55%***	3,03%*	7,06%***	2,28%	-1,33%
	t+7	4,40%***	5,77%***	3,07%**	6,62%***	5,09%***	2,85%*	5,22%***	7,28%***	2,33%	-5,05%***
	t+8	3,69%**	4,95%***	0,68%	6,15%***	6,07%***	3,79%**	2,83%*	6,96%***	2,52%*	2,21%
	t+9	5,15%***	7,91%***	4,68%***	5,55%***	6,68%***	2,33%*	4,52%***	7,15%***	2,40%*	4,98%***
	t+10	3,87%**	7,96%***	2,10%	6,19%***	4,13%**	4,09%***	8,66%***	8,51%***	3,62%**	4,26%***
USD/EUR	t+1	3,03%*	-0,11%	-0,62%	3,21%**	-0,96%	4,54%***	4,26%**	4,00%**	-0,13%	3,60%**
	t+2	7,78%***	3,21%**	-0,27%	3,17%**	-4,49%***	-0,85%	7,94%***	-3,27%**	-0,53%	-0,12%
	t+3	5,10%***	6,40%***	0,47%	8,95%***	-4,21%**	2,40%*	4,09%**	-5,50%***	0,83%	3,43%**
	t+4	4,37%***	2,86%*	0,50%	6,76%***	-3,47%**	2,34%	5,04%**	-5,01%***	3,10%**	3,24%**
	t+5	1,26%	1,87%	-1,46%	10,69%***	-5,80%***	2,90%*	1,65%	-2,33%*	3,00%**	1,26%
	t+6	1,87%	2,00%	-0,34%	6,21%***	-1,27%	4,64%***	5,71%***	-1,54%	5,35%***	2,66%*
	t+7	6,51%***	9,22%***	6,15%***	8,12%***	5,05%***	5,57%***	10,58%***	3,23%**	5,73%***	5,32%***
	t+8	3,16%**	2,16%	-1,68%	5,39%***	-3,69%**	2,75%*	3,87%**	-4,59%***	5,08%***	4,17%***
	t+9	2,12%	1,95%	-4,45%***	5,15%***	3,26%**	3,20%*	6,93%***	-1,74%	6,33%***	3,14%**
	t+10	2,17%	0,51%	-0,85%	5,17%***	-6,17%***	3,84%**	4,51%***	-1,59%	6,12%***	2,66%*
	Średnia poprawa	2,18%	3,94%	2,71%	4,90%	-1,23%	2,76%	4,41%	2,05%	2,18%	-0,30%

Uwaga: Kolorem niebieskim zaznaczono sytuację, w której stosowana metoda uzyskała lepszą trafność niż średnia trafność dla sieci. W kolumnach zaznaczone są kolejne okresy prognozy – w każdym okresie trafność pochodzi z 20 najlepszych sieci z okresu poprzedniego. W badaniu przyjęto trzy poziomy istotności dla testu na istotną różnicę między porównywanymi zmiennymi: 0,01 - ***, 0,05 - **, 0,1 - *.

W związku z faktem, iż sieć LSTM charakteryzowała się najtrafniejszymi wynikami prognoz, tabele 30. oraz 31. wskazują na mniejszą przewagę metody rekurencyjnej nad stosowaniem tylko i wyłącznie sieci LSTM. Mimo to, wyniki uzyskiwane przez metodę rekurencyjną w większości są trafniejsze niż średnie wyniki dla sieci LSTM. W tabeli 31. można zauważyć dwa (z trzech wcześniej wspomnianych) przypadków, dla których średnia różnica

trafności między metodą rekurencyjną a LSTM jest ujemna, co świadczy o lepszej trafności LSTM. Podokresy, o których mowa to 5 i 10 podokres, dla których LSTM uzyskało trafniejsze prognozy odpowiednio o 1,2294% i 0,2987% i różnice te nie były istotne statystycznie.

W tabeli 32. zamieszczam zbiorcze wyniki testów na istotność różnic trafności prognoz tych dwóch metod.

Tabela 32. Zbiorcze wyniki testów na istotność różnicy trafności prognoz metodą rekurencyjną oraz sieciami neuronowymi

Porównanie trafności metody rekurencyjnej do	Istotność			Nieistotne
	0,01	0,05	0,1	
średniej trafności wszystkich sieci	59% (177)	68,33% (205)	73% (229)	27% (81)
ELM	50% (150)	56,67% (170)	59,67% (179)	40,33% (121)
MLP	43,33% (130)	50% (150)	53% (159)	47% (141)
LSTM	38% (114)	42,67% (128)	44,67% (134)	55,33% (166)

Opis: W tabeli wartości procentowe oznaczają procentowy udział danego wyniku a w nawiasach podają liczbę wystąpień.

Wersja II metody rekurencyjnej ograniczała wybór typów sieci tylko do pierwszego okresu, a wybrane ustawienia stosowane były już przez cały okres badania. Wyniki uzyskane tą metodą przedstawiono w tabeli 33. W pierwszej kolumnie zaprezentowano horyzont prognozy a w kolejnej trafność drugiego podejścia do metody rekurencyjnej z podziałem na odpowiednie pary walutowe.

Tabela 33. Procentowy udział trafnych prognoz w metodzie rekurencyjnej - dla sieci o ustawieniach, które uzyskały najlepsze wyniki w pierwszym okresie testowym t

Horyzont prognozy	CHF/EUR	GBP/EUR	USD/EUR
t+1	51,55%	50,35%	53,58%
t+2	53,92%	51,90%	53,56%
t+3	51,92%	53,99%	50,78%
t+4	57,13%	57,58%	53,46%
t+5	58,35%	58,31%	54,11%
t+6	53,88%	56,56%	55,53%
t+7	53,56%	59,48%	62,44%
t+8	58,55%	61,71%	59,59%
t+9	65,44%	63,19%	60,02%
t+10	63,06%	64,55%	60,22%

Porównanie metody I i II przedstawiam w tabeli 34. Obliczam średnią trafność dla wszystkich podokresów przy danym horyzoncie inwestycji i dla danej pary walutowej i wyniki te zestawiam z wynikami z tabeli 33. W tabeli 34. „Wariant I” oznacza, iż lepsze wyniki uzyskała metoda I, natomiast „Wariant II”, że lepszą była metoda II. Ostatnia kolumna przedstawia różnice między metodą II a metodą I. Mimo, iż „Wariant I” okazał się lepszy 19 razy a „Wariant II” 11 razy, wydanie jednoznacznego osądu dotyczącego tych metod może być trudne. Metoda II zyskała najwięcej dzięki parze walutowej GBP/EUR, dla której charakteryzowała się wyższą trafnością aż w 9 na 10 przypadków. Natomiast jeśli porównamy tylko CHF/EUR i GBP/EUR, trafność metody I jest lepsza niż trafność metody II. Przewaga metody I nad metodą II może wynikać z tego, że w wariacie II możliwy jest wybór takich ustawień w okresie testowym, które okażą się mało skuteczne w przyszłości, na przykład w wyniku zmiany tendencji czy dynamiki kursu walutowego. Można w ten sposób zauważyć przewagę podejścia z aktualizacją ustawień charakteryzujących się lepszą trafnością prognoz jedynie w okresie poprzednim. Należy zwrócić szczególną uwagę na wyniki testu istotności dla różnic w trafności między metodą rekurencyjną typu I oraz typu II. Za istotne należy uznać tylko różnice na korzyść metody rekurencyjnej typu I (Wariant I). Jest ich 13 – dla kursu CHF/EUR prognozy na okres $t + 3$, od $t + 5$ do $t + 8$ oraz dla kursu USD/EUR od $t + 3$ do $t + 10$. W pozostałych przypadkach dla CHF/EUR i USD/EUR oraz we wszystkich przypadkach dla GBP/EUR różnice między metodami zostały uznane za statystycznie nieistotne. W kolejnych badaniach metoda I, uwzględniająca aktualizacja parametrów, zostanie zestawiona z metodą neuronowo-rozmytą.

Tabela 34. Porównanie metody rekurencyjnej typu I oraz typu II oraz procentowe różnice między nimi

Para walutowa	Horyzont Prognozy	Lepsza metoda	Różnica procentowa
CHF/EUR	t+1	Wariant II	-0,4908%
	t+2	Wariant II	-0,2227%
	t+3	Wariant I	3,9183%**
	t+4	Wariant I	1,1430%
	t+5	Wariant I	3,2579%**
	t+6	Wariant I	5,8103%***
	t+7	Wariant I	5,7826%***
	t+8	Wariant I	3,2063%**
	t+9	Wariant II	-0,6885%
	t+10	Wariant II	-0,2956%

GBP/EUR	t+1	Wariant II	-0,7057%
	t+2	Wariant II	-0,7127%
	t+3	Wariant II	-1,1374%
	t+4	Wariant II	-1,9016%
	t+5	Wariant II	-1,1876%
	t+6	Wariant I	1,9774%
	t+7	Wariant I	0,4507%
	t+8	Wariant II	-0,0315%
	t+9	Wariant I	1,1101%
	t+10	Wariant I	0,4834%
USD/EUR	t+1	Wariant II	-0,8188%
	t+2	Wariant I	0,0154%
	t+3	Wariant I	6,1169%***
	t+4	Wariant I	5,5334%***
	t+5	Wariant I	3,9963%**
	t+6	Wariant I	5,9395%***
	t+7	Wariant I	3,7173%***
	t+8	Wariant I	3,6975%***
	t+9	Wariant I	5,3371%***
	t+10	Wariant I	4,3602%***

*Uwaga: Różnice procentowe zawarte w ostatniej kolumnie to różnica między trafnością uzyskaną przy zastosowaniu metody I a trafnością z metody II. W związku z tym dodatnie wartości (na czarno) to sytuacja, w której lepsze prognozy uzyskiwała bardziej złożona metoda – eliminacja wariant 1. W badaniu przyjęto trzy poziomy istotności dla testu na istotną różnicę między porównywanymi zmiennymi: 0,01 - ***, 0,05 - **, 0,1 - *.*

W tabeli 35. zaprezentowano zbiorcze odpowiedzi na pytania badawcze postawione w podrozdziale 4.

Tabela 35. Odpowiedzi na pytania badawcze z I etapu rozprawy doktorskiej - prognozowanie z wykorzystaniem metody rekurencyjnej

Numer pytania	Treść pytania	Odpowiedź
2.1.	Czy trafność prognoz metodą rekurencyjną będzie lepsza niż trafność prognoz uzyskana prognozą naiwną lub modelem ARMA?	Prognoza naiwna była gorsza od metody rekurencyjnej. ARMA okazała się lepsza tylko dla pary walutowej CHF/EUR i horyzontu prognozy 1,2,3,6 oraz 7 dni. W przeważającej większości przypadków metoda rekurencyjna poprawia wyniki

		prognozowania względem prognozowania sieciami neuronowymi.
2.2.	Czy metoda rekurencyjna będzie uzyskiwała trafniejsze prognozy niż średnie prognozy dla pojedynczych sieci?	W znaczącej większości przypadków dla wszystkich sieci neuronowych oraz wszystkich horyzontów prognozy metoda neuronowo-rozmyta uzyskiwała wyższą trafność niż średnie wyniki trafności dla pojedynczych typów sieci.

5. Metoda neuronowo-rozmyta

Zgodnie z założeniami opisanymi na początku tego rozdziału (por. rysunek 36.), w III etapie badania prezentuję wyniki prognoz uzyskane z autorskiego podejścia neuronowo-rozmytego. Wyniki uzyskiwane za pomocą metody z zastosowaniem logiki rozmytej będą porównywane do średnich wyników sieci neuronowych oraz metody rekurencyjnej, a w ostatnim podrozdziale metoda rekurencyjnej zostanie połączona z metodą neuronowo-rozmytą.

Ideą podejścia neuronowo-rozmytego, jest wykorzystanie 49 prognoz zwracanych każdorazowo przez zestaw trzech sieci do stworzenia prognozy rozmytej. Na podstawie zwracanych wyników tworzę liczbę rozmytą. Nośnik liczby rozmytej jest przedziałem ograniczonym z lewej strony minimalną wartością prognozowaną, natomiast z prawej strony maksymalną wartością prognozowaną. Kiedy cena z dnia, w którym stawiamy prognozę, jest mniejsza niż minimum lub większa niż maksimum, w metodzie tej wnioskujemy odpowiednio o przyszłym wzroście lub spadku ceny (mechanizm ten przedstawiono we wstępie do rozdziału IV). Jeżeli cena z dnia podejmowania decyzji znajduje się pomiędzy maksymalną a minimalną wartością prognozowaną, prognoza stawiana jest na podstawie pola powierzchni (por. rysunek 34. w rozdziale III).

5.1. Trafność prognoz zmian kursu walutowego uzyskanych metodą neuronowo-rozmytą

W tym podrozdziale badam wpływ zmiany kształtu funkcji przynależności, jak i sposobu doboru jądra zbioru, na trafność prognoz. W badaniu wzięto pod uwagę dwie możliwe funkcje przynależności (trójkątna i trapezoidalna) oraz sześć sposobów dobierania wartości, dla której trójkątna funkcja przynależności jest równa 1 (średnia, mediana, średnia bez wartości skrajnych, mediana bez wartości skrajnych oraz średnia winsorowska obejmująca 25% i 50%

prognozowanych cen przez sieci neuronowe). Natomiast dla trapezoidalnej funkcji przynależności przyjęto 10% środkowych wartości za wartości przyjmujące przynależność równą 1, według wzoru:

$$(maks. prognozowana\ cena - min. prognozowana\ cena) \cdot 0,1$$

W tabeli 36. oraz 37. przedstawiono wyniki, jakie uzyskano za pomocą tej metody dla pary walutowej CHF/EUR, której prognozy były dokonywane na poziomach cen przy użyciu sieci ELM. Mimo, że są to tylko przykłady jednej sieci oraz jednej pary walutowej, zależności w nich zawarte można rozciągnąć również na pozostałe pary walutowe oraz typy sieci neuronowych. Zatem, wpływ doboru wartości stanowiącej wartość dla wysokości zbioru rozmytego, ma niewielki wpływ na poprawę trafności prognoz w obrębie tej samej funkcji przynależności. Należy również zauważyć, że różnice dla wybranej sieci oraz pary walutowej między funkcją trójkątną a trapezoidalną są znaczące, jednak nie dla wszystkich badanych sieci są one aż tak widoczne.

Tabela 36. Wyniki dla CHF/EUR prognozowanych siecią ELM uczącej się na poziomach cen – dla trójkątne oraz trapezoidalnej funkcji przynależności

Typ funkcji przynależności	Jądro	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
Trójkąt	A	51,8031%	51,7337%	53,1900%	54,7157%	54,2996%	54,4383%	54,0915%	54,0915%	54,3689%	54,1609%
	B	51,1096%	51,8031%	52,8433%	54,5076%	54,3689%	54,5770%	54,5076%	54,2302%	54,3689%	53,6061%
	C	51,1096%	51,6644%	52,6352%	54,0222%	54,3689%	54,6463%	54,1609%	54,0222%	54,0222%	53,8141%
	D	51,8031%	51,3870%	53,1207%	54,0915%	54,7157%	54,9237%	54,0915%	54,0915%	54,0915%	54,2302%
	E	51,8031%	51,5950%	53,0513%	54,0222%	54,5076%	54,7850%	54,0915%	54,5770%	54,0915%	54,0915%
	F	51,8031%	51,8031%	53,2594%	54,2302%	54,7850%	54,9931%	54,0915%	54,5076%	54,0915%	54,1609%
Trapez	A	49,7226%	47,5728%	48,9598%	48,9598%	49,8613%	51,9417%	51,0402%	50,9015%	51,1096%	50,4854%
	B	49,1678%	47,5728%	48,4743%	48,8904%	50,0693%	51,8031%	51,3870%	50,9015%	51,4563%	50,7628%
	C	50,7628%	48,6824%	50,5548%	51,6644%	52,4965%	53,7448%	53,1207%	52,3578%	52,8433%	51,9417%
	D	51,1789%	48,6824%	50,8322%	52,0111%	52,2885%	52,9820%	53,2594%	52,2191%	52,7739%	51,6644%
	E	51,4563%	51,1096%	52,1498%	53,3981%	53,8141%	54,5076%	54,4383%	53,7448%	53,4674%	53,1207%
	F	51,3870%	49,5146%	51,3870%	52,9126%	53,3287%	54,0915%	53,7448%	53,5368%	53,6061%	52,9126%

Uwaga: Pierwsza kolumna wskazuje na typ funkcji przynależności (trójkątna lub trapezoidalna). Druga kolumna wskazuje na sposób doboru jądra zbioru zgodnie z metodami opisami w tym podrozdziale, przyjęto następujące oznaczenia: A – średnia, B – mediana, C – średnia bez wartości skrajnych, D – mediana bez wartości skrajnych, E i F – średnie winsorowskie odpowiednio uwzględniające 25% i 50% danych. Kolorem żółtym zaznaczono najlepszą metodę dla danego horyzontu prognozy.

Kolorem żółtym w tabeli 34. (w celu wyróżnienia) zaznaczono najlepszy z wyników dla danego horyzontu prognozy. Stosowanie metody tworzenia liczby rozmytej można uznać za uzasadnione w przypadku, gdy lepsze wyniki będzie osiągać ta metoda w porównaniu do metody większości i średniej trafności dla wszystkich ustawień danej sieci. W tabeli 35. przedstawiono najlepsze z metod uwzględniające tylko sposób doboru jądra zbioru i funkcję przynależności, natomiast w tabeli 36. uwzględniono również metodę większości i średnią sieci. Zarówno w tabeli 35., jak i 39. prezentuję metodę, która okazała się najlepszą. Zdarzają się przypadki, że więcej niż jedna metoda okazała się najlepsza (uzyskała taką samą trafność prognoz)

Tabela 37. Zbiornicze zestawienie najtrafniejszego sposobu doboru jądra zbioru oraz doboru funkcji przynależności ze względu na parę walutową, typ sieci neuronowej oraz horyzont prognozy

Para walutowa	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
CHF/EUR	ELM	Trójkąt A	Trójkąt B	Trójkąt F	Trójkąt A	Trójkąt F	Trójkąt F	Trójkąt B	Trójkąt E	Trójkąt A i B	Trójkąt D
	MLP	Trójkąt A i B	Trapez B	Trapez A	Trójkąt A i F	Trapez A i B	Trójkąt A	Trójkąt A	Trójkąt A	Trójkąt A	Trapez B
	LSTM	Trójkąt A	Trapez D	Trapez D	Trapez A	Trapez A	Trapez B	Trapez B	Trapez B	Trapez D	Trapez D
GBP/EUR	ELM	Trapez B	Trapez B	Trapez B	Trapez A	Trapez A	Trapez A	Trapez A	Trapez A i B	Trapez B	Trapez A
	MLP	Trapez B	Trapez A	Trapez B	Trapez C i D	Trapez B	Trapez C	Trapez A	Trapez A i B	Trapez D	Trapez D
	LSTM	Trójkąt C	Trójkąt F	Trójkąt F	Trójkąt A	Trójkąt D	Trójkąt B	Trójkąt C	Trójkąt C	Trójkąt E	Trójkąt E
USD/EUR	ELM	Trapez C	Trapez E	Trapez D	Trapez D	Trapez E i F	Trapez A, B i C	Trapez F	Trapez D	Trapez B i C	Trapez D i F
	MLP	Trójkąt B i C	Trapez E	Trójkąt D	Trójkąt B	Trapez F	Trapez D	Trójkąt B	Trójkąt B	Trójkąt A	Trójkąt B
	LSTM	Trójkąt A	Trójkąt A	Trójkąt E	Trójkąt F	Trójkąt F	Trójkąt A	Trójkąt E	Trójkąt D, E i F	Trójkąt C	Trójkąt E

Uwaga: W tabeli zaprezentowano metodę o najtrafniejszych prognozach, gdzie wskazano na trójkątną lub trapezoidalną funkcję przynależności oraz sposób doboru jądra zbioru zgodnie z opisem sposobu doboru jądra zbioru: A – średnia, B – mediana, C – średnia bez wartości skrajnych, D – mediana bez wartości skrajnych, E i F – średnie winsorowskie odpowiednio uwzględniające 25% i 50% danych. Kolorem żółtym zaznaczono najlepszą metodę dla danego horyzontu prognozy.

Można zauważyć (Tabela 37.), iż dla sieci ELM istnieją sytuacje, gdzie więcej niż jeden sposób tworzenia liczby rozmytej uzyskał taką samą trafność. Mimo to, dla wszystkich trzech par walutowych i wszystkich horyzontów prognozy zawsze najlepsza okazywała się metoda pochodząca tylko z jednej funkcji przynależności – dla CHF/EUR jest to trójkątna funkcja przynależności, natomiast dla GBP/EUR i USD/EUR jest to trapezoidalna funkcja przynależności. Fakt ten może wskazywać na to, że większe znaczenie dla trafności prognoz na typ funkcji przynależności, niż sposób doboru jądra zbioru. Sytuacja taka nie miała miejsca w przypadku sieci MLP, gdzie np. dla pary walutowej CHF/EUR zarówno funkcja trójkątna jak i trapezoidalna okazywała się lepsza dla poszczególnych horyzontów prognozy.

5.2. Badanie porównawcze trafności prognoz metodą neuronowo-rozmytą z klasycznymi modelami ekonometrycznymi

Również w przypadku metody neuronowo-rozmytej, porównano jej trafność do trafności jakie uzyskiwały klasyczne modele – ARMA oraz prognozowanie naiwne. tabela 38. przedstawia wyniki tego porównania. Wnioski są podobne do uzyskanych w poprzednim badaniu, tj. metoda neuronowo-rozmyta dla USD/EUR i wszystkich typów sieci neuronowych oraz GBP/EUR i większości typów sieci neuronowych uzyskały lepsze wyniki niż klasyczne metody prognozowania. Dla pary walutowej CHF/EUR podstawowe sieci neuronowe (ELM i MLP), nawet z zastosowaniem metody neuronowo-rozmytej, charakteryzowały się gorszymi wynikami trafności niż metoda ARMA, która dla tej pary walutowej uzyskała bardzo dobre wyniki. Jednak w przypadku sieci bardziej złożonej (LSTM) i zastosowaniu metody neuronowo-rozmytej dla wszystkich dziesięciu horyzontów inwestycji uzyskano lepsze wyniki niż ARMA i metoda naiwna.

Tabela 38. Porównanie trafności metody naiwnej i ARMA do metody neuronowo-rozmytej

Para walutowa	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
CHF/EUR	ELM	ARMA	Rozmytość	Rozmytość	Rozmytość	Rozmytość	ARMA	ARMA	ARMA	ARMA	ARMA
	MLP	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA	ARMA
	LSTM	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość
GBP/EUR	ELM	Naiwna	Naiwna	Rozmytość	Naiwna	ARMA	Naiwna	Naiwna	Naiwna	ARMA	ARMA
	MLP	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Naiwna	Naiwna	Rozmytość	ARMA
	LSTM	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość
USD/EUR	ELM	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość
	MLP	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość
	LSTM	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość	Rozmytość

5.3. Badanie porównawcze trafności prognoz uzyskanych metodą neuronowo-rozmytą z metodą wyboru prognozy na podstawie wskazań większości sieci

Celem niniejszego badania jest porównanie metody neuronowo-rozmytej do metody wyboru prognozy na podstawie wskazań większości sieci. Ponieważ wykazałem, że lepsze trafności kierunku zmian uzyskuję po wprowadzeniu do sieci neuronowej cen, a nie zwrotów, to w dalszej części badania będę wykorzystywał już tylko to podejście. Sieci neuronowe prognozują cenę, na podstawie której można określić czy dla danego dnia sieć neuronowa prognozuje wzrost czy spadek kursu walutowego. Dla każdej takiej prognozy w obrębie jednej sieci mamy 49 (lub 42 dla LSTM) zaprognozowanych cen a co za tym idzie - kierunków. Podejmowanie decyzji na podstawie wskazań większości sieci oznacza sprawdzenie, czy więcej z tych 49 (42) sieci neuronowych prognozowało wzrost czy spadek i ostateczne podjęcie decyzji zgodnej z większością. Badanie ma wykazać, czy potrzebne jest budowanie liczby rozmytej, czy też podobną poprawę wyników można uzyskać za pomocą podejmowania decyzji zgodnie z większością wskazań sieci. Podobnie jak w poprzednich tabelach, słowo „sieci” w danej komórce oznacza przewagę średniej trafności sieci neuronowej natomiast „większość” oznacza uzyskanie lepszej procentowej trafności przy podejmowaniu decyzji inwestycyjnej na podstawie większości sieci niż średni poziom trafności sieci neuronowej.

Tabela 39. Procentowy udział trafnie zaprognozowanych kierunków zmian kursu – metoda większości sieci

Para walutowa	Typ danych	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
CHF/EUR	Poziomy cen	ELM	50,69%	50,55%	52,01%	53,26%	53,81%	54,37%	54,23%	53,47%	53,68%	52,84%
		MLP	48,61%	47,64%	47,16%	48,40%	47,64%	48,20%	49,24%	48,75%	49,93%	48,20%
		LSTM	49,65%	52,64%	52,01%	54,44%	55,83%	56,80%	56,03%	58,74%	62,00%	60,19%
	Zwroty	ELM	48,27%	46,81%	46,05%	45,56%	45,91%	44,45%	44,52%	45,08%	45,42%	45,56%
		MLP	49,24%	48,61%	47,16%	47,78%	47,02%	46,60%	46,67%	47,16%	46,81%	46,53%
		LSTM	44,31%	43,55%	49,45%	48,20%	48,89%	48,68%	46,46%	46,46%	47,71%	47,43%
GBP/EUR	Poziomy cen	ELM	47,99%	47,30%	47,43%	47,92%	47,92%	49,10%	47,64%	47,43%	46,88%	46,88%
		MLP	49,38%	48,54%	48,75%	49,10%	47,99%	46,88%	47,99%	48,54%	49,17%	49,03%
		LSTM	49,93%	49,45%	50,35%	50,97%	52,70%	52,98%	56,10%	57,49%	58,88%	58,67%
	Zwroty	ELM	49,17%	50,00%	48,96%	49,93%	51,04%	50,69%	51,80%	52,01%	52,29%	53,12%
		MLP	48,54%	50,42%	51,18%	51,11%	51,87%	52,77%	52,22%	53,61%	53,26%	53,33%
		LSTM	49,86%	50,42%	49,79%	49,45%	49,72%	50,83%	50,69%	48,82%	50,42%	50,76%
USD/EUR	Poziomy cen	ELM	52,36%	52,22%	54,30%	53,81%	55,06%	55,96%	55,69%	55,13%	55,13%	54,16%
		MLP	52,77%	53,68%	54,16%	54,65%	54,99%	56,87%	56,80%	56,24%	57,49%	56,10%
		LSTM	49,51%	50,62%	52,98%	55,13%	54,85%	58,25%	58,46%	60,47%	61,72%	62,41%
	Zwroty	ELM	50,49%	52,43%	51,66%	51,18%	52,22%	52,50%	54,09%	55,76%	55,69%	55,96%
		MLP	51,11%	51,32%	50,55%	49,51%	49,79%	49,58%	51,04%	52,77%	53,12%	53,95%
		LSTM	52,01%	50,21%	50,83%	50,69%	51,87%	51,53%	51,87%	51,46%	51,32%	49,65%

Dla większości prognoz kierunku zmian kursu pary walutowej USD/EUR uzyskano trafność prognoz powyżej 50% (Tabela 39.) bez względu na typ sieci neuronowej. Metoda większości sieci uzyskała trafność prognoz powyżej 50% dla pary GBP/EUR i sieci LSTM uczącej się na poziomach cen oraz ELM i MLP na logarytmicznych stopach zwrotu. Dla pary CHF/EUR metoda większości sieci uzyskiwała wyniki powyżej 50% tylko dla ELM i LSTM uczących się na poziomach cen.

Metoda większości sieci zdolna jest do niwelowania błędnych decyzji pojedynczego typu sieci, który przekłada się na niższą trafność tej sieci. W takich przypadkach, trafność prognoz uzyskanych tą metodą jest wyższa niż trafność prognoz uzyskanych z pojedynczych sieci.

Porównanie trafności prognoz metodą większości sieci oraz średniej trafności dla danego typu sieci neuronowej przedstawiono w tabeli 40. W większości przypadków (109) średnia trafność sieci w obrębie danego typu sieci neuronowych była wyższa. Metoda większości wykazywała nieznacznie wyższą trafność prognoz w długim horyzoncie. Dla horyzontu prognoz od $t + 6$ do $t + 10$ metoda większości była lepsza w 46 przypadkach, a średnia trafność sieci w 44 przypadkach.

Tabela 40. Porównanie procentowego udziału trafnie zaprognozowanych kierunków zmian kursu – metoda większości sieci i średnia dla sieci

Para walutowa	Typ danych	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10	
CHF/EUR	Poziomy cen	ELM	sieci	sieci	sieci	większość	większość	większość	większość	sieci	sieci	sieci	
		MLP	sieci	sieci	sieci	większość	sieci	sieci	sieci	sieci	sieci	sieci	
		LSTM	sieci	sieci	sieci	sieci	sieci	większość	większość	większość	większość	sieci	
	Zwroty	ELM	sieci	sieci	większość	sieci	większość	większość	sieci	większość	większość	większość	
		MLP	sieci	sieci	sieci	sieci	większość	większość	większość	większość	większość	większość	
		LSTM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	
GBP/EUR	Poziomy cen	ELM	sieci	sieci	sieci	sieci	większość	większość	większość	większość	większość	większość	
		MLP	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	
		LSTM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	
	Zwroty	ELM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	większość	większość	większość	większość
		MLP	sieci	sieci	większość	większość	większość	większość	większość	większość	większość	większość	
		LSTM	większość	sieci	większość	sieci	większość	większość	większość	większość	większość	większość	
USD/EUR	Poziomy cen	ELM	sieci	sieci	sieci	sieci	większość	sieci	większość	sieci	sieci	sieci	
		MLP	sieci	sieci	sieci	większość	sieci	większość	sieci	sieci	większość	sieci	
		LSTM	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	sieci	większość	
	Zwroty	ELM	sieci	większość	większość	większość	większość	większość	większość	większość	większość	większość	
		MLP	większość	sieci	większość	większość	sieci	sieci	większość	sieci	większość	sieci	
		LSTM	większość	sieci	sieci	większość	większość	sieci	sieci	sieci	sieci	większość	

Uwaga: „sieci” oznacza sytuację, w której wyższą trafność prognoz uzyskała średnia trafność sieci niż metoda większości sieci, natomiast „większość” oznacza sytuację odwrotną.

Kolejnym krokiem badania jest porównanie wyników z tabeli 36. z metodą większości oraz średnią trafnością dla danego typu sieci neuronowej. Wyniki te przedstawiono w tabeli 41., gdzie kolorem jasnoszarym zaznaczono przypadki, dla których metoda neuronowa-rozmyta uzyskała gorszą trafność prognoz od przedstawionych dla tego etapu badania benchmarków.

Tabela 41. Zbiorcze porównanie metody neuronowo-rozmytej z metodą większości oraz średnią trafnością dla danego typu sieci

Para walutowa	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
CHF/EUR	ELM	Średnia	Trójkąt B	Trójkąt F	Trójkąt A	Trójkąt F	Trójkąt F	Trójkąt B	Trójkąt E	Trójkąt A i B	Trójkąt D
	MLP	Średnia	Średnia	Średnia	Większość	Większość	Większość	Większość	Średnia	Średnia	Średnia
	LSTM	Średnia	Trapez D	Trapez D	Trapez A	Trapez A	Trapez B	Trapez B	Trapez B	Trapez D	Trapez D
GBP/EUR	ELM	Trapez B	Trapez B	Trapez B	Trapez A	Trapez A	Trapez A	Trapez A	Trapez A i B	Trapez B	Trapez A
	MLP	Trapez B	Trapez A	Trapez B	Trapez C i D	Trapez B	Trapez C	Trapez A	Trapez A i B	Trapez D	Trapez D
	LSTM	Trójkąt C	Trójkąt F	Trójkąt F	Trójkąt A	Trójkąt D	Trójkąt B	Trójkąt C	Trójkąt C	Trójkąt E	Trójkąt E
USD/EUR	ELM	Trapez C	Trapez E	Trapez D	Trapez D	Trapez E i F	Trapez A, B i C	Trapez F	Trapez D	Trapez B i C	Trapez D i F
	MLP	Trójkąt B i C	Trapez E	Trójkąt D	Trójkąt B	Trapez F	Trapez D	Trójkąt B	Trójkąt B	Trójkąt A	Trójkąt B
	LSTM	Średnia	Średnia	Trójkąt E	Większość	Średnia	Większość	Średnia	Średnia	Trójkąt C	Trójkąt E

Uwaga: W niniejszej tabeli zastosowano takie same oznaczenia dla metody neuronowo-rozmytej natomiast benchmarki oznaczone w tabeli jako „Średnia” i „Większość” oznaczają średnia trafność dla danego typu sieci oraz metodę większości

Na podstawie tabeli 41. można sporządzić zestawienie metody, która okazywała się najlepsza:

Lp.	Metoda	Procentowy udział
1.	Metoda neuronowo rozmyta w przypadku, gdy jądro zbioru rozmytego zbudowane było na podstawie mediany, a funkcja przynależności miała kształt	16%
2.	Średnie trafności sieci	14%
3.	Metoda neuronowo rozmyta w przypadku, gdy jądro zbioru rozmytego zbudowane na podstawie mediany dla trójkątnej funkcji przynależności	13%
4.	Metoda neuronowo rozmyta w przypadku, gdy jądro zbioru rozmytego zbudowane na podstawie mediany dla trójkątnej funkcji przynależności	10%
5.	Metoda większości	7%

6.	Metoda neuronowo rozmyta w przypadku, gdy jądro zbioru rozmytego zbudowane na średniej winsorowskiej zawierającej 25% i 50% danych dla trójkątnej funkcji przynależności oraz na średniej bez wartości skrajnych dla trójkątnej oraz trapezoidalnej funkcji przynależności	6%
----	--	----

Pozostałe metody występowały mniej niż w 5% przypadków. Przedstawiony ranking mogłyby wskazywać niewielką różnicę między metodą neuronowo-rozmytą a średnimi wynikami dla sieci neuronowych. Jednak, jak zauważono wcześniej, różnice między wynikami dla tej samej funkcji przynależności, ale przy różnym sposobie jej tworzenia, są nieznaczne. Dlatego porównując skuteczność metody neuronowo-rozmytej ze względu na sposób rozmywania prognozy można stworzyć następujący ranking:

1. Rozmywanie prognozy okazało się skuteczniejsze w 81,82 % przy czym
 - a. 50 razy (50,51%), gdy zastosowano trapezoidalną funkcję przynależności,
 - b. 31 razy (31,31%), gdy zastosowano trójkątną funkcję przynależności,
2. Średnie wyniki sieci neuronowych okazały się najskuteczniejsze dla 12,12% przypadków,
3. Większość sieci okazała się najskuteczniejsza w 6,06% przypadków.

W powyższym rankingu uwzględniono powtórzenia wynikające z równej trafności prognoz z użyciem więcej niż jednej metody neuronowo-rozmytej. Pomijając te powtórzenia i porównując te trzy metody między sobą mogę stwierdzić, że większość sieci wykazywała lepszą trafność w 6,67% przypadków (6 razy), średnie wyniki sieci neuronowych 13,33% (12 razy) a metoda neuronowo-rozmyta 80% (72 razy). Wyniki wewnątrz metody neuronowo-rozmytej wykazują przewagę trapezoidalnej funkcji przynależności w stosunku 61,73% do 38,27% dla trójkątnej funkcji przynależności.

5.4 Badanie porównawcze trafności prognoz metodą neuronowo-rozmytą z trafnością prognoz uzyskanych metodą rekurencyjną

Niniejszy podrozdział jest próbą odpowiedzi na pytanie, czy skuteczniejsza w prognozowaniu jest metoda rekurencyjna, czy metoda neuronowo-rozmyta (badanie porównawcze). W tym celu zestawiono ze sobą w tabelach 42. i 43. trafność najlepszej metody doboru jądra zbioru rozmytego z metody neuronowo-rozmytej z metodą rekurencyjną w wariancie I (z aktualizacją

ustawień - tabela 42.) oraz metodą rekurencyjną w wariancie II (bez aktualizacji ustawień - tabela 43.). W obu tabelach kolorem jasnożółtym zaznaczono pary walutowe oraz horyzonty prognozy, dla których lepszą trafność uzyskała metoda neuronowo-rozmyta, korzystająca z prognoz zadanego typu sieci.

Tabela 42. Zestawienie metody neuronowo-rozmytej z metodą rekurencyjnej typu I ze wskazaniem metody uzyskującej wyższą trafność prognoz

Para walutowa	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
CHF/EUR	ELM	Wariant I	Wariant I	NR	Wariant I	Wariant I	NR	NR	Wariant I	Wariant I	Wariant I
	MLP	Wariant I	Wariant I	Wariant I	Wariant I	Wariant I	NR	NR	Wariant I	Wariant I	Wariant I
	LSTM	Wariant I	NR	NR	NR	NR	NR	NR	NR	Wariant I	Wariant I
GBP/EUR	ELM	Wariant I	Wariant I	Wariant I	Wariant I	Wariant I	Wariant I	Wariant I	Wariant I	NR	NR
	MLP	NR	Wariant I	Wariant I	Wariant I	Wariant I	Wariant I	Wariant I	Wariant I	Wariant I	Wariant I
	LSTM	NR	Wariant I	Wariant I	Wariant I	Wariant I	NR	Wariant I	Wariant I	Wariant I	Wariant I
USD/EUR	ELM	Wariant I	Wariant I	NR	NR	NR	NR	Wariant I	NR	NR	Wariant I
	MLP	Wariant I	NR	NR	NR	NR	NR	Wariant I	NR	NR	NR
	LSTM	Wariant I	Wariant I	NR	NR	NR	NR	Wariant I	Wariant I	NR	Wariant I

Uwaga: W tabeli „NR” oznacza, że dla danej pary walutowej oraz typu sieci neuronowej i przy danym horyzoncie prognozy wyższą trafność prognoz uzyskała metoda neuronowo-rozmyta, natomiast „Wariant I” oznacza wyższą trafność prognoz uzyskaną dzięki zastosowaniu metody rekurencyjnej typu I czyli uwzględniającej zmianę stosowanych ustawień sieci neuronowych w kolejnych etapach

Tabela 43. Zestawienie metody neuronowo-rozmytej z metodą eliminacja typu II ze wskazaniem metody uzyskującej wyższą trafność prognoz

Para walutowa	Typ sieci	t+1	t+2	t+3	t+4	t+5	t+6	t+7	t+8	t+9	t+10
CHF/EUR	ELM	NR	Wariant II	NR	Wariant II	Wariant II	NR	NR	Wariant II	Wariant II	Wariant II
	MLP	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II
	LSTM	Wariant II	NR	NR	Wariant II	Wariant II	NR	NR	NR	Wariant II	Wariant II
GBP/EUR	ELM	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II
	MLP	NR	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II
	LSTM	NR	Wariant II	Wariant II	Wariant II	Wariant II	NR	Wariant II	Wariant II	Wariant II	Wariant II
USD/EUR	ELM	Wariant II	Wariant II	NR	NR	NR	NR	Wariant II	Wariant II	Wariant II	Wariant II
	MLP	Wariant II	NR	NR	NR	NR	NR	Wariant II	Wariant II	Wariant II	Wariant II
	LSTM	NR	Wariant II	NR	NR	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II	Wariant II

Uwaga: W tabeli „NR” oznacza, że dla danej pary walutowej oraz typu sieci neuronowej i przy danym horyzoncie prognozy wyższą trafność prognoz uzyskała metoda neuronowo-rozmyta, natomiast „Wariant II” oznacza wyższą trafność prognoz uzyskaną dzięki zastosowaniu metody rekurencyjnej typu II, czyli bez uwzględnienia zmiany ustawień w trakcie badania

Przeprowadzone badanie wskazuje na przewagę metody rekurencyjnej nad metodą neuronowo-rozmytą. Dokonując porównania metody rekurencyjnej typu I z metodą neuronowo-rozmytą stwierdzam, że metoda rekurencyjna typu I uzyskała wyższą trafność prognoz dla 54 przypadków (60%) a metoda neuronowo-rozmyta dla 36 (40%). Jeśli natomiast porównamy metodę rekurencyjną typu II z metodą neuronowo-rozmytą, to ta pierwsza uzyskała wyższą trafność prognoz dla 66 (73,33%) przypadków a druga dla 24 (26,66%).

W związku z faktem, że metoda rekurencyjna, zarówno typu I jak i II, częściej uzyskiwała wyższą trafność prognoz niż metoda neuronowo rozmyta, ale także, że istnieje wiele przypadków, dla których to metoda neuronowo-rozmyta uzyskiwała trafniejsze prognozy, zdecydowałem się na przeprowadzenie badania łączącego obie te metody. Polega ona na wyeliminowaniu ustawień sieci uzyskujących niższą trafność prognoz, a później zbudowaniu liczby rozmytej na ustawieniach o wyższej trafności prognoz

5.5. Połączenie metody neuronowo-rozmytej z metodą rekurencyjną

Metoda rekurencyjna bazuje na wszystkich 140 ustawieniach sieci uwzględnionych w badaniu empirycznym. W tym podrozdziale przedstawione zostanie badanie tworzące prognozę rozmytą na podstawie wybranych w metodzie rekurencyjnej parametrów sieci neuronowych. Wyniki te zostaną zestawione z wynikami, jakie uzyskała tylko metoda rekurencyjna, bez uwzględnienia metody neuronowo-rozmytej. W związku z wykazaniem przewagi metody rekurencyjnej, aktualizującej najlepsze parametry sieci nad metodą rekurencyjną z jednokrotnym wyborem w badaniu, w niniejszym podrozdziale metoda łącząca metodą neuronowo-rozmytą z metodą rekurencyjną zostanie przeprowadzona tylko dla metody rekurencyjnej z aktualizacją parametrów. W tabeli 44. przedstawiam procentową trafność prognoz uzyskanych metodą neuronowo-rozmytą w połączeniu z metodą rekurencyjną. Kolorem niebieskim zaznaczono wartości trafności najlepszej metody, spośród czterech wskazanych, dla danej pary walutowej i horyzontu prognozy. Komórki wypełnione kolorem zielonym to przypadki najwyższej trafności dla danej pary walutowej. Ostatecznie, kolor czerwony oznacza najniższą trafność dla danej pary walutowej.

Tabela 44. Trafność prognoz metodą neuronowo-rozmytą w połączeniu z metodą rekurencyjną

Para walutowa	Horyzont	Trójkąt A	Trójkąt B	Trapez A	Trapez B
CHF/EUR	t+1	50,6935%	50,6935%	49,7920%	49,2372%
	t+2	54,9931%	55,1318%	48,6824%	47,9196%
	t+3	56,8655%	56,7961%	48,2663%	47,5035%
	t+4	59,9168%	59,3620%	50,6241%	50,5548%
	t+5	60,8877%	60,3329%	51,0402%	49,7226%
	t+6	50,9709%	50,8322%	46,6019%	46,7406%
	t+7	51,3176%	51,3870%	47,3648%	47,9889%
	t+8	62,8988%	61,3037%	51,5257%	47,5728%
	t+9	65,8114%	66,6436%	61,5118%	60,2635%
	t+10	65,3259%	64,2164%	60,6796%	61,5118%
GBP/EUR	t+1	50,7628%	50,6241%	51,4563%	50,8322%
	t+2	53,1207%	52,8433%	51,7337%	54,0222%
	t+3	53,4674%	53,9528%	56,0333%	55,4785%
	t+4	55,3398%	56,0333%	58,6685%	58,0444%
	t+5	56,5881%	57,4896%	56,8655%	56,8655%
	t+6	57,1429%	57,4202%	58,8072%	58,3911%
	t+7	59,2926%	60,4716%	59,3620%	58,6685%
	t+8	60,1942%	60,8183%	60,9570%	60,3329%
	t+9	61,9972%	62,8988%	60,6796%	59,3620%
	t+10	62,6214%	63,1068%	62,8294%	61,2344%
USD/EUR	t+1	64,2857%	64,3551%	59,1540%	58,3911%
	t+2	60,9570%	61,0957%	57,8363%	57,1429%
	t+3	61,0957%	60,6796%	60,2635%	59,2926%
	t+4	63,4535%	64,0083%	61,3731%	60,1942%
	t+5	65,1179%	65,0485%	62,8988%	62,8294%
	t+6	65,0485%	64,7712%	62,9681%	62,5520%
	t+7	71,7060%	71,0818%	59,8474%	59,7087%
	t+8	75,5201%	75,1040%	60,8183%	60,0555%
	t+9	74,4799%	73,8558%	61,3731%	60,9570%
	t+10	76,1442%	75,3814%	60,6103%	60,4022%

Na podstawie informacji zawartych w tabeli 44., można zauważyć, że dla pary CHF/EUR i USD/EUR najlepsze wyniki dało zastosowanie metody opartej na budowaniu jądra zbioru na średniej arytmetycznej i z wykorzystaniem trójkątnej funkcji przynależności. Dla tych dwóch par walutowych ani razu najlepszą trafnością dla danego horyzontu prognozy nie charakteryzowała się prognoza rozmyta utworzona z wykorzystaniem funkcji trapezoidalnej. Odmienna sytuacja występuje dla pary GBP/EUR, gdzie najlepsze wyniki osiągnięto stosując

funkcję trapezoidalną, która miała wyższą trafność niż trójkątna funkcja przynależności w 7 przypadkach na 10.

W kolejnych tabelach zostanie przedstawione porównanie wyników trafności metody neuronowo-rozmytej z wykorzystaniem prognoz sieci ELM (NR ELM), MLP (NR MLP), LSTM (NR LSTM) oraz metody rekurencyjnej do metody opisanej w niniejszym podrozdziale, bazującej na trójkątnej funkcji przynależności o jądrze zbioru budowanym na: średniej arytmetycznej (Tabela 45.) i medianie (Tabela 46.) oraz trapezoidalnej funkcji przynależności i jądrze zbioru opartym na średniej arytmetycznej (Tabela 47.) oraz medianie (Tabela 48.). W tabelach 45-48 kolorem niebieskim zaznaczono dodatnie różnice w trafności prognoz. Dodatnie różnice oznaczają, iż wyższą trafnością charakteryzowała się metoda łącząca metodę rekurencyjną z metodą neuronowo-rozmytą niż poszczególne metody wskazane w kolumnach.

Tabela 45. Porównanie trafności prognoz połączoną metodą rekurencyjną i neuronowo-rozmytą dla trójkątnej funkcji przynależności i jądrze zbioru równym średniej arytmetycznej z innymi metodami

Para walutowa	Horyzont	NR ELM	NR MLP	NR LSTM	Rekurencja I	Rekurencja II
CHF/EUR	t+1	-1,1096%	0,9709%	-2,5659%*	-0,3657%	-0,8565%
	t+2	3,1900%**	5,6172%***	1,6644%	1,2958%	1,0731%
	t+3	3,6061%**	7,4202%***	1,2483%	1,0272%	4,9455%***
	t+4	5,2011%***	10,6103%***	4,5770%***	1,6438%	2,7868%*
	t+5	6,1026%***	10,4716%***	5,4785%***	-0,7202%	2,5377%*
	t+6	-4,0222%**	1,5257%	-5,5479%***	-8,7194%***	-2,9091%*
	t+7	-3,1900%**	1,6644%	-4,9931%***	-8,0250%***	-2,2424%
	t+8	8,3218%***	13,9390%***	6,5187%***	1,1425%	4,3488%***
	t+9	11,4424%***	16,6436%***	9,5700%***	1,0599%	0,3714%
	t+10	11,0957%***	17,1983%***	10,6796%***	2,5615%*	2,2659%
GBP/EUR	t+1	-0,6241%	-1,3870%	-2,7739%*	1,1185%	0,4128%
	t+2	4,9931%***	1,8724%	-2,1498%	1,9334%	1,2207%
	t+3	5,4785%***	2,7046%	-1,6644%	0,6148%	-0,5226%
	t+4	6,8655%***	3,0513%*	0,2774%	-0,3386%	-2,2402%
	t+5	8,1137%***	4,8544%*	0,4161%	-0,5343%	-1,7219%
	t+6	8,5992%***	5,8252%***	-0,2080%	-1,3945%	0,5829%
	t+7	9,0153%***	6,7268%***	1,8031%	-0,6381%	-0,1874%
	t+8	11,0957%***	8,4605%***	3,3287%**	-1,4843%	-1,5158%
	t+9	11,3037%***	10,1248%***	3,1900%**	-2,3029%*	-1,1928%
	t+10	13,8696%***	10,8877%***	5,5479%***	-2,4120%*	-1,9286%
USD/EUR	t+1	10,7490%***	13,4535%***	12,8988%***	11,5245%***	10,7057%***
	t+2	5,6865%***	6,6574%***	9,1540%***	7,3816%***	7,3970%***

	t+3	5,9639%***	6,7961%***	8,3911%***	4,1988%**	10,3157%***
	t+4	8,3911%***	7,4202%***	7,9057%***	4,4601%***	9,9935%***
	t+5	8,9459%***	7,4202%***	9,0846%***	7,0116%***	11,0079%***
	t+6	7,6976%***	7,7670%***	7,8363%***	3,5790%**	9,5185%***
	t+7	14,2164%***	14,8405%***	13,3842%***	5,5487%***	9,2660%***
	t+8	18,6546%***	16,5742%***	15,9501%***	12,2326%***	15,9301%***
	t+9	15,6727%***	11,2344%***	14,5631%***	9,1228%***	14,4599%***
	t+10	19,0707%***	13,5922%***	15,6033%***	11,5640%***	15,9242%***

Opis: W badaniu przyjęto trzy poziomy istotności dla testu na istotną różnicę między porównywanymi zmiennymi: 0,01 - ***, 0,05 - **, 0,1 - *.

Tabela 46. Porównanie trafności prognoz połączoną metodą rekurencyjną i neuronowo-rozmytą dla trójkątnej funkcji przynależności i jądrze zbioru równym medianie z innymi metodami

Para walutowa	Horyzont	NR ELM	NR MLP	NR LSTM	Rekurencja I	Rekurencja II
CHF/EUR	t+1	-1,1096%	0,9709%	-2,5659%*	-0,3657%	-0,8565%
	t+2	3,3287%**	5,7559%***	1,8031%	1,4345%	1,2118%
	t+3	3,5368%**	7,3509%***	1,1789%	0,9578%	4,8761%***
	t+4	4,6463%***	10,0555%***	4,0222%**	1,0890%	2,2320%*
	t+5	5,5479%***	9,9168%***	4,9237%**	-1,2750%	1,9829%
	t+6	-4,1609%**	1,3870%	-5,6865%***	-8,8581%***	-3,0478%*
	t+7	-3,1207%**	1,7337%	-4,9237%***	-7,9556%***	-2,1730%
	t+8	6,7268%***	12,3440%***	4,9237%***	-0,4526%	2,7537%
	t+9	12,2746%***	17,4757%***	10,4022%***	1,8921%	1,2036%
	t+10	9,9861%***	16,0888%***	9,5700%***	1,4520%	1,1564%
GBP/EUR	t+1	-0,7628%	-1,5257%	-2,9126%*	0,9798%	0,2741%
	t+2	4,7157%***	1,5950%	-2,4272%*	1,6560%	0,9433%
	t+3	5,9639%***	3,1900%**	-1,1789%	1,1002%	-0,0372%
	t+4	7,5589%***	3,7448%**	0,9709%	0,3549%	-1,5467%
	t+5	9,0153%***	5,7559%***	1,3176%	0,3672%	-0,8204%
	t+6	8,8766%***	6,1026%***	0,0693%	-1,1172%	0,8602%
	t+7	10,1942%***	7,9057%***	2,9820%*	0,5409%	0,9916%
	t+8	11,7198%***	9,0846%***	3,9528%**	-0,8602%	-0,8917%
	t+9	12,2053%***	11,0264%***	4,0915%**	-1,4013%	-0,2912%
	t+10	14,3551%***	11,3731%***	6,0333%***	-1,9266%	-1,4432%
USD/EUR	t+1	10,8183%***	13,5229%***	12,9681%***	11,5939%***	10,7751%***
	t+2	5,8252%***	6,7961%***	9,2926%***	7,5203%***	7,5357%***
	t+3	5,5479%***	6,3800%***	7,9750%***	3,7827%**	9,8996%***
	t+4	8,9459%***	7,9750%***	8,4605%***	5,0149%**	10,5483%***
	t+5	8,8766%***	7,3509%***	9,0153%***	6,9422%***	10,9385%***
	t+6	7,4202%***	7,4896%***	7,5589%***	3,3017%**	9,2412%***

	t+7	13,5922%***	14,2164%***	12,7601%***	4,9245%***	8,6418%***
	t+8	18,2386%***	16,1581%***	15,5340%***	11,8165%***	15,5140%***
	t+9	15,0485%***	10,6103%***	13,9390%***	8,4987%***	13,8358%***
	t+10	18,3079%***	12,8294%***	14,8405%***	10,8012%***	15,1614%***

Opis: W badaniu przyjęto trzy poziomy istotności dla testu na istotną różnicę między porównywanymi zmiennymi: 0,01 - ***, 0,05 - **, 0,1 - *

Tabela 47. Porównanie trafności prognoz połączoną metodą rekurencyjną i neuronowo-rozmytą dla trapezoidalnej funkcji przynależności i jądrze zbioru budowanym na średniej arytmetycznej z innymi metodami

Para walutowa	Horyzont	NR ELM	NR MLP	NR LSTM	Rekurencja I	Rekurencja II
CHF/EUR	t+1	-2,0111%	0,0693%	-3,4674%**	-1,2672%	-1,7580%
	t+2	-3,1207%**	-0,6935%	-4,6463%***	-5,0149%***	-5,2376%***
	t+3	-4,9931%***	-1,1789%	-7,3509%***	-7,5720%***	-3,6537%**
	t+4	-4,0915%**	1,3176%	-4,7157%***	-7,6489%***	-6,5059%***
	t+5	-3,7448%**	0,6241%	-4,3689%***	-10,5677%***	-7,3098%***
	t+6	-8,3911%***	-2,8433%*	-9,9168%***	-13,0884%***	-7,2781%***
	t+7	-7,1429%***	-2,2885%	-8,9459%***	-11,9778%***	-6,1952%***
	t+8	-3,0513%*	2,5659%*	-4,8544%***	-10,2306%***	-7,0243%***
	t+9	7,1429%***	12,3440%***	5,2705%***	-3,2397%**	-3,9282%**
	t+10	6,4494%***	12,5520%***	6,0333%***	-2,0848%	-2,3804%*
GBP/EUR	t+1	0,0693%	-0,6935%	-2,0804%	1,8120%	1,1063%
	t+2	3,6061%**	0,4854%	-3,5368%**	0,5464%	-0,1663%
	t+3	8,0444%***	5,2705%***	0,9015%	3,1807%**	2,0433%
	t+4	10,1942%***	6,3800%***	3,6061%**	2,9901%*	1,0885%
	t+5	8,3911%***	5,1318%***	0,6935%	-0,2569%	-1,4445%
	t+6	10,2635%***	7,4896%***	1,4563%	0,2698%	2,2472%
	t+7	9,0846%***	6,7961%***	1,8724%	-0,5687%	-0,1180%
	t+8	11,8585%***	9,2233%***	4,0915%**	-0,7215%	-0,7530%
	t+9	9,9861%***	8,8072%***	1,8724%	-3,6205%**	-2,5104%*
	t+10	14,0777%***	11,0957%***	5,7559%***	-2,2040%	-1,7206%
USD/EUR	t+1	5,6172%***	8,3218%***	7,7670%***	6,3928%***	5,5740%***
	t+2	2,5659%*	3,5368%**	6,0333%***	4,2609%**	4,2763%**
	t+3	5,1318%***	5,9639%***	7,5589%***	3,3666%**	9,4835%***
	t+4	6,3107%***	5,3398%***	5,8252%***	2,3797%*	7,9131%***
	t+5	6,7268%***	5,2011%***	6,8655%***	4,7925%***	8,7888%***
	t+6	5,6172%***	5,6865%***	5,7559%***	1,4986%	7,4381%***
	t+7	2,3578%*	2,9820%*	1,5257%	-6,3099%***	-2,5926%*
	t+8	3,9528%**	1,8724%	1,2483%	-2,4692%*	1,2283%
	t+9	2,5659%*	-1,8724%	1,4563%	-3,9840%**	1,3531%
	t+10	3,5368%**	-1,9417%	0,0693%	-3,9699%**	0,3903%

Opis: W badaniu przyjęto trzy poziomy istotności dla testu na istotną różnicę między porównywanymi zmiennymi: 0,01 - ***, 0,05 - **, 0,1 - *

Tabela 48. Porównanie trafności prognoz połączoną metodą rekurencyjną i neuronowo-rozmytą dla trapezoidalnej funkcji przynależności i jądrze zbioru budowanym na medianie z innymi metodami

Para walutowa	Horyzont	NR ELM	NR MLP	NR LSTM	Rekurencja I	Rekurencja II
CHF/EUR	t+1	-2,5659%*	-0,4854%	-4,0222%***	-1,8220%	-2,3128%
	t+2	-3,8835%**	-1,4563%	-5,4092%***	-5,7777%***	-6,0004%***
	t+3	-5,7559%***	-1,9417%	-8,1137%***	-8,3348%***	-4,4165%***
	t+4	-4,1609%**	1,2483%	-4,7850%***	-7,7182%***	-6,5752%***
	t+5	-5,0624%***	-0,6935%	-5,6865%***	-11,8853%***	-8,6274%***
	t+6	-8,2524%***	-2,7046%*	-9,7781%***	-12,9497%***	-7,1394%***
	t+7	-6,5187%***	-1,6644%	-8,3218%***	-11,3537%***	-5,5711%***
	t+8	-7,0042%***	-1,3870%	-8,8072%***	-14,1835%***	-10,9772%***
	t+9	5,8946%***	11,0957%***	4,0222%**	-4,4880%***	-5,1765%***
	t+10	7,2816%***	13,3842%***	6,8655%***	-1,2526%	-1,5482%
GBP/EUR	t+1	-0,5548%	-1,3176%	-2,7046%*	1,1879%	0,4822%
	t+2	5,8946%***	2,7739%*	-1,2483%	2,8349%*	2,1222%
	t+3	7,4896%***	4,7157%***	0,3467%	2,6259%*	1,4885%
	t+4	9,5700%***	5,7559%***	2,9820%*	2,3660%*	0,4644%
	t+5	8,3911%***	5,1318%***	0,6935%	-0,2569%	-1,4445%
	t+6	9,8474%***	7,0735%***	1,0402%	-0,1463%	1,8311%
	t+7	8,3911%***	6,1026%***	1,1789%	-1,2622%	-0,8115%
	t+8	11,2344%***	8,5992%***	3,4674%**	-1,3456%	-1,3771%
	t+9	8,6685%***	7,4896%***	0,5548%	-4,9381%***	-3,8280%**
	t+10	12,4827%***	9,5007%***	4,1609%**	-3,7990%**	-3,3156%**
USD/EUR	t+1	4,8544%***	7,5589%***	7,0042%***	5,6299%***	4,8111%***
	t+2	1,8724%	2,8433%*	5,3398%***	3,5675%**	3,5829%**
	t+3	4,1609%**	4,9931%***	6,5881%***	2,3957%*	8,5126%***
	t+4	5,1318%***	4,1609%**	4,6463%***	1,2008%	6,7342%***
	t+5	6,6574%***	5,1318%***	6,7961%***	4,7231%***	8,7194%***
	t+6	5,2011%***	5,2705%***	5,3398%***	1,0825%	7,0220%***
	t+7	2,2191%	2,8433%*	1,3870%	-6,4486%***	-2,7313%**
	t+8	3,1900%**	1,1096%	0,4854%	-3,2320%**	0,4655%
	t+9	2,1498%	-2,2885%	1,0402%	-4,4001%***	0,9370%
	t+10	3,3287%**	-2,1498%	-0,1387%	-4,1780%**	0,1822%

Opis: W badaniu przyjęto trzy poziomy istotności dla testu na istotną różnicę między porównywanymi zmiennymi: 0,01 - ***, 0,05 - **, 0,1 - *.

Na podstawie danych z tabel 45-48 można zauważyć, że dla wielu par walutowych oraz horyzontów prognozy, metoda łącząca metodę rekurencyjną z metodą neuronowo-rozmytą charakteryzowała się lepszą trafnością niż poszczególne metody stosowane w niniejszej

rozprawie doktorskiej. Analizując statystyczną istotność różnic zauważam, że gdy wykorzystywana jest trójkątna funkcja przynależności (Tabele 45-46) istotne różnice na korzyść innych metod niż metody neuronowo-rozmyta w połączeniu z metodą rekurencyjną zdarzają się sporadycznie. W przypadku trapezoidalnej funkcji przynależności znacznie częściej różnice na korzyść innych metod są istotne.

W tabeli 49. zaprezentowano zbiorcze odpowiedzi na pytania badawcze dotyczące etapu 3 badania empirycznego.

Tabela 49. Odpowiedzi na pytania badawcze z I etapu rozprawy doktorskiej - prognozowanie z wykorzystaniem metody neuronowo-rozmytej

Numer pytania	Treść pytania	Odpowiedź
3.1.	Czy typ funkcji przynależności ma wpływ na trafność prognoz w podejściu neuronowo-rozmytym?	Dla trafności prognoz bardziej istotny jest dobór odpowiedniej funkcji przynależności niż modyfikacja sposobu doboru jądra zbioru. Nie można było jednoznacznie wskazać funkcji przynależności najlepszej dla wszystkich trzech par walutowych. Dla pary walutowej CHF/EUR trójkątna funkcja przynależności uzyskała najwyższą trafność, natomiast dla GBP/EUR i USD/EUR - trapezoidalna funkcja przynależności
3.2.	Czy prognozowanie z wykorzystaniem podejścia neuronowo-rozmytego będzie skuteczniejsze niż prognozowanie w oparciu tylko o sieci neuronowe?	Tak, wykazano znaczącą przewagę między prognozowaniem metodą neuronowo-rozmytą a w oparciu tylko o sieci neuronowe. Średnia trafność sieci była wyższa od metody neuronowo-rozmytej tylko w 13 na 90 przypadków.
3.3.	Czy podejście neuronowo-rozmyte charakteryzuje się lepszą trafnością prognoz, niż prognozy na podstawie	Porównując trafność metody neuronowo-rozmytej z metodą większości, w 80% przypadków wyższą trafność uzyskano z

	większości w obrębie sieci oraz prognozy naiwne i ARMA?	metody neuronowo-rozmytej oraz w 69% w porównaniu z prognozą naiwną oraz ARMA.
3.4.	Czy połączenie podejścia rekurencyjnego z podejściem neuronowo-rozmytym poprawi trafność prognoz?	Dla większości badanych par walutowych oraz horyzontów prognoz metoda łącząca metodę rekurencyjną i neuronowo-rozmytą uzyskała wyższą trafność niż metody te stosowane osobno.

6. Podsumowanie wyników

W pierwszym etapie badania wskazano, iż najwyższą trafnością prognoz kierunków zmian charakteryzowała się sieć LSTM, szczególnie dla ustawień o dwóch węzłach ukrytych. Dla sieci LSTM i MLP trafność prognozowania zależy od parametrów sieci. Sieć LSTM uzyskiwała najwyższą trafność przy ustawieniach z dwoma węzłami ukrytymi. Sieć MLP w wielu przypadkach uzyskiwała trafniejsze prognozy, gdy liczba opóźnień w sieci była równa długości horyzontu prognozy. W przypadku sieci ELM nie stwierdzono istnienia wyraźnych wzorców. Trafność prognozowania zależy też od horyzontu prognozy, przy czym LSTM miała wyższą trafność dla prognoz o dłuższym horyzoncie, a dla pozostałych sieci jednoznaczne zależności nie istnieją. Przykładowo, dla sieci ELM prognozującej parę walutową CHF/EUR wraz ze wzrostem horyzontu trafność maleje, a dla tej samej sieci prognozującej parę GBP/EUR trafność prognoz rośnie wraz ze wzrostem horyzontu prognozy. Dla pary walutowej USD/EUR sieci neuronowe uzyskały lepszą trafność prognoz niż modele ARMA we wszystkich przypadkach. Dla pary GBP/EUR w większości przypadków sieci neuronowe uzyskały wyższą trafność niż ARMA za wyjątkiem ELM i MLP uczących się na poziomach cen. Dla pary CHF/EUR prognozy z modelu ARMA charakteryzowały się wyższą trafnością niż prognozy sieci MLP i ELM, natomiast LSTM ucząca się na poziomach cen osiągnęła wyższą trafność niż ARMA. Dla pary walutowej USD/EUR wszystkie typy sieci okazały się lepsze niż prognozowanie naiwne. Dla pary walutowej GBP/EUR sieci ELM i MLP ucząca się na poziomach cen uzyskały niższą trafność niż prognozowanie naiwne. Dla pary walutowej CHF/EUR tylko ELM i LSTM uczące się na poziomach cen osiągnęły wyższą trafność niż prognozowanie naiwne. Porównując podejście rekurencyjne z prognozowaniem tylko sieciami można zauważyć przewagę podejścia rekurencyjnego na podstawie porównań do ARMA i prognozy naiwnej.

Dla każdego z możliwych wariantów prognoza naiwna była gorsza od metody rekurencyjnej, natomiast ARMA okazała się lepsza tylko dla pary walutowej CHF/EUR i horyzontu prognozy 1,2,3,6 oraz 7 dni. Dla wariantu I metody rekurencyjnej wnioski są takie same jak dla wariantu II – metoda rekurencyjna poprawia wyniki prognozowania względem prognozowania sieciami neuronowymi. W znaczącej większości przypadków dla wszystkich sieci neuronowych oraz wszystkich horyzontów prognozy metoda neuronowo-rozmyta uzyskiwała wyższą trafność niż średnie wyniki trafności dla pojedynczych typów sieci.

W etapie trzecim badania wykazano, iż dla trafności prognoz bardziej istotny jest dobór odpowiedniej funkcji przynależności niż modyfikacja sposobu doboru jądra zbioru. Nie można było jednoznacznie wskazać funkcji przynależności najlepszej dla wszystkich trzech par walutowych. Dla pary walutowej CHF/EUR trójkątna funkcja przynależności uzyskała najwyższą trafność, natomiast dla GBP/EUR i USD/EUR -trapezoidalna funkcja przynależności. W badaniach porównawczych wskazano również na przewagę metody neuronowo-rozmytej nad benchmarkiem (ponad 80%) oraz tylko sieciami neuronowymi dla większości przypadków. Dla większości badanych par walutowych oraz horyzontów prognoz metoda łącząca metodę rekurencyjną i neuronowo-rozmytą uzyskała wyższą trafność niż metody te stosowane osobno.

Rozdział V. Zastosowanie metody neuronowo-rozmytej do inwestycji w instrumenty pochodne

W tym rozdziale badam zyskowność inwestycji dokonywanych na podstawie prognoz uzyskanych ze wszystkich metod opisanych w rozdziale IV. W badaniu uwzględniłam prostą inwestycję w kontrakty kupna i sprzedaży oraz konstruuje odpowiednie strategie opcyjne: gra na wzrost i spadek oraz gra na stabilizację (krótki stelaż). Jeśli prognoza wskazuje na wzrost kursu, to zajmuję długą pozycję w opcji kupna, jeśli na spadek - to długą pozycję w opcji sprzedaży, a jeśli na stabilizację - to stosuję strategię stelaża.

W niniejszym rozdziale poszukuję odpowiedzi na pytanie, czy wykorzystanie prognoz z rozdziału IV pozwoli na generowanie ponadprzeciętnych zysków. Konkretnie pytania badawcze, na które odpowiadam w tym rozdziale, są następujące:

- 4.1. Czy wykorzystanie rozmytych prognoz zmian kierunku cen pozwoli na osiągnięcie wyższego zysku z inwestycji w kontrakty oraz opcje niż wykorzystanie wskazań uzyskanych z prognoz sieci neuronowych oraz metody rekurencyjnej?
- 4.2. Czy zastosowanie prognoz rozmytych do strategii opcyjnej na stabilizację pozwoli na ograniczenie potencjalnych strat lub osiągnięcie wyższych zysków niż stosowanie tylko gry na wzrost lub spadek?


W badaniu empirycznym przyjąłem założenie, że każdego dnia, na który postawiona została prognoza, dokonywana jest inwestycja zgodnie z prognozowanym kierunkiem zmiany. Wielkość inwestycji wynosi każdorazowo 100 euro. Porównywane ze sobą będą trzy sposoby inwestycji, które przedstawiam w tabeli 50.

Tabela 50. Opis inwestycji i sposób ich rozliczenia

Sposób inwestycji	Instrumenty finansowe	Sposób rozliczenia
Kontrakt	Kontrakt kupna i sprzedaży	Różnice kursowe między ceną z dnia zawarcia transakcji, a ceną z nią wykonania kontraktu. $Zysk_k = (P_t - P_{t-x}) \cdot \frac{100}{P_{t-x}}$ $Zysk_s = (P_{t-x} - P_t) \cdot \frac{100}{P_{t-x}}$

		gdzie P_t – cena pary walutowej w dniu wykonania kontraktu, P_{t-x} cena pary walutowej w dniu zawarcia kontraktu. $Zysk_k$ to zysk (strata) dla kontraktu w długiej pozycji a $Zysk_s$ w krótkiej pozycji.
Opcje	Europejska opcja kupna i sprzedaży	Różnice między cenami opcji wynikającymi z modelu Blacka-Scholesa. Cena zawarcia transakcji to cena wynikająca z modelu Blacka-Scholesa dla opcji miesięcznej a cena, po której opcje są rozliczane, to cena tej samej opcji z terminem wygaśnięcia krótszym o odpowiedni horyzont inwestycji. $Zysk = (BS_t - BS_{t-x}) \cdot \frac{100}{BS_{t-x}}$ gdzie BS_t – cena z modelu Blacka-Scholesa w dniu wykonania kontraktu, BS_{t-x} cena z modelu Blacka-Scholesa w dniu zawarcia kontraktu. W przypadku opcji cena z modelu Blacka-Scholesa (premia opcyjna) uwzględnia aktualną sytuację rynkową. W związku z tym, jeżeli koszt premii opcyjnej wzrasta, to rośnie prawdopodobieństwo zrealizowania sytuacji, na którą wystawiona jest dana opcja. Ten sam wzór stosowany jest w modelu opcja + strategia opcyjna.
Opcje + strategia opcyjna	Opcja kupna i sprzedaży oraz strategia krótkiego stelaża	Różnice między cenami opcji wynikającymi z modelu Blacka-Scholesa. Cena zawarcia transakcji to cena wynikająca z modelu Blacka-Scholesa dla opcji miesięcznej. Cena, po której opcje są rozliczane, to cena tej samej opcji z terminem wygaśnięcia krótszym o odpowiedni horyzont inwestycji. Wzór na zyski dla tej metody jest taki sam jak dla metody powyżej – zysk jest różnicą między kosztami premii opcyjnych potrzebnych do skonstruowania strategii.

Strategia stelaża wykorzystywana jest w przypadku, kiedy uzyskaną prognozą jest prognoza małego wzrostu lub spadku. Gdy prognozowana jest mała zmiana, prawdopodobieństwo błędnie zaprognozowanego kierunku jest duże. Gra na stabilizację ma zapobiec takim błędom. Dla przypomnienia działania tej strategii, opisanej w rozdziale I, zamieszczam poniżej jej profil wpłaty. W strategii krótkiego stelaża zysk osiąga się wtedy, gdy cena instrumentu utrzyma się w pewnych widełkach.



Rysunek 44. Strategia krótkiego stelaża

Na rynku bardzo rzadko pojawiają się opcje jednodniowe, dlatego w badaniu empirycznym założyłem, że w dniu podejmowania decyzji zajmuję długą pozycję w odpowiedniej opcji miesięcznej po cenie określonej modelem Blacka-Scholesa, a po upływie czasu równego horyzontowi prognozy sprzedaję tę opcję, również po cenie wynikającej z tego modelu. Oznacza to, że rozliczenie zysku odbywa się na podstawie różnicy między ceną zakupu (sprzedaży) odpowiedniej opcji a ceną wynikającą z modelu.

Podstawową różnicą między inwestycją w kontrakty, a inwestycją w opcje jest uwzględnienie dźwigni finansowej w opcjach a w kontraktach inwestuję bezpośrednio w walutę po cenie rynkowej. W przypadku stosowanego kontraktu, cena, którą płaci inwestor za zakup waluty jest wyższy niż cena jaką trzeba zapłacić za opcję – ceną tą jest premia opcyjna. Stąd, inwestor ma możliwość zakupu większej liczby opcji.

Celem tego badania jest porównanie zysku, jaki osiąga inwestor kierując się prognozami uzyskanymi z wykorzystaniem różnych metod przedstawionych w poprzednim rozdziale. Na początku przedstawiam zysk uzyskany na podstawie prognoz tylko sieciami neuronowymi, następnie metodą rekurencyjną, metodą neuronowo-rozmytą oraz metodą wynikającą

z połączenia tych dwóch ostatnich. Każdorazowo porównuję wysokość zysku uzyskanego dla różnych metod.

1. Zysk z inwestycji uzyskanych na podstawie prognoz sieci neuronowych

W tym podrozdziale przedstawiam zysk z inwestycji, jaki osiągnąłby inwestor, który kierowałby się wskazaniem poszczególnych metod – sieci neuronowych, metody rekurencyjnej oraz metody neuronowo-rozmytej. Wyniki przedstawiam osobno dla każdej pary walutowej i dla poszczególnych inwestycji: w kontrakty, opcje oraz opcje połączone ze strategią stelaża. W tabelach w niniejszym rozdziale prezentuję wartości minimalne, maksymalne oraz średnią dla danej metody, pary walutowej i horyzontu prognozy. Oznacza to, że jeżeli w tabeli przedstawiam maksymalną, minimalną oraz średnią wartość zysku dla prognozy na 1 dzień do przodu wykorzystaniem inwestycji w kontrakty na parę walutową CHF/EUR i podejmując decyzje na podstawie sieci ELM to w badaniu uzyskałem 49 (tyle było parametrów dla sieci ELM) różnych zysków, ale dla przejrzystości pracy prezentuję tylko wartość minimalną, maksymalną oraz średnią z tych 49 wartości. W tabelach czerwoną czcionką zaznaczam wartości ujemne.

1.1. Inwestycja w kontrakty

Stopy zwrotu z inwestycji w kontrakty wykorzystującej prognozy sieci neuronowych są niskie. W związku z tym, w tabelach 51-68 przedstawiam tylko minimalną, maksymalną oraz średnią stopę zwrotu dla danej pary walutowej. Wartości te liczone są dla wszystkich parametrów danej sieci, czyli jest to wartość maksymalna, minimalna oraz średnia dla 49 parametrów (ELM i MLP) lub 42 parametrów (LSTM). W tabeli 51. przedstawiam statystyki stóp zwrotu dla pary walutowej CHF/EUR, w tabeli 52. – dla pary GBP/EUR, a w tabeli 53. – dla pary USD/EUR przy inwestycji w kontrakty

Tabela 51. Statystyki stóp zwrotu dla pary walutowej CHF/EUR przy inwestycji w kontrakty z wykorzystaniem prognoz sieci neuronowych

Para walutowa	Horyzont inwestycji	Stopa zwrotu z inwestycji			
			max	min	średnia
CHF/EUR	t+1	ELM	0,0222%	0,0078%	0,0131%
		MLP	-0,0040%	-0,0285%	-0,0218%
		LSTM	0,0275%	-0,0192%	0,0110%

t+2	ELM	0,0339%	0,0132%	0,0230%
	MLP	-0,0120%	-0,0333%	-0,0263%
	LSTM	0,1713%	-0,0130%	0,0411%
t+3	ELM	0,0472%	0,0329%	0,0393%
	MLP	-0,0105%	-0,0438%	-0,0314%
	LSTM	0,3468%	-0,0103%	0,1170%
t+4	ELM	0,0700%	0,0452%	0,0559%
	MLP	-0,0016%	-0,0543%	-0,0316%
	LSTM	0,4627%	-0,0025%	0,1393%
t+5	ELM	0,0815%	0,0674%	0,0747%
	MLP	0,0052%	-0,0535%	-0,0283%
	LSTM	0,6451%	-0,0002%	0,2285%
t+6	ELM	0,1068%	0,0662%	0,0838%
	MLP	0,0083%	-0,0513%	-0,0234%
	LSTM	0,5891%	0,0106%	0,2661%
t+7	ELM	0,1155%	0,0752%	0,1011%
	MLP	0,0315%	-0,0414%	-0,0114%
	LSTM	0,6338%	0,0179%	0,3046%
t+8	ELM	0,1259%	0,0968%	0,1111%
	MLP	0,0224%	-0,0441%	-0,0114%
	LSTM	0,7902%	0,0734%	0,3827%
t+9	ELM	0,1413%	0,1263%	0,1325%
	MLP	0,0384%	-0,0344%	-0,0034%
	LSTM	0,9163%	0,1271%	0,4824%
t+10	ELM	0,1365%	0,1151%	0,1278%
	MLP	0,0152%	-0,0487%	-0,0146%
	LSTM	0,8922%	0,1390%	0,4702%

Tabela 52. Statystyki stóp zwrotu dla pary walutowej GBP/EUR przy inwestycji w kontrakty z wykorzystaniem prognoz sieci neuronowych

Para walutowa	Horyzont inwestycji	Stopa zwrotu z inwestycji			
			max	min	średnia
GBP/EUR	t+1	ELM	-0,0027%	-0,0128%	-0,0081%
		MLP	0,0039%	-0,0010%	0,0013%
		LSTM	0,0261%	-0,0044%	0,0089%
	t+2	ELM	-0,0003%	-0,0149%	-0,0062%
		MLP	0,0355%	0,0028%	0,0174%
		LSTM	0,1922%	-0,0185%	0,0324%
	t+3	ELM	0,0054%	-0,0165%	-0,0051%
		MLP	0,0567%	0,0137%	0,0350%
		LSTM	0,2842%	-0,0241%	0,0732%

t+4	ELM	0,0018%	-0,0330%	-0,0171%
	MLP	0,0547%	0,0201%	0,0342%
	LSTM	0,3981%	-0,0375%	0,1016%
t+5	ELM	-0,0038%	-0,0464%	-0,0214%
	MLP	0,0535%	0,0166%	0,0382%
	LSTM	0,4917%	-0,0211%	0,1454%
t+6	ELM	-0,0100%	-0,0420%	-0,0350%
	MLP	0,0560%	0,0029%	0,0285%
	LSTM	0,5577%	-0,0297%	0,1725%
t+7	ELM	-0,0280%	-0,0624%	-0,0458%
	MLP	0,0363%	0,0077%	0,0246%
	LSTM	0,6417%	-0,0385%	0,2135%
t+8	ELM	-0,0300%	-0,0629%	-0,0522%
	MLP	0,0452%	0,0134%	0,0289%
	LSTM	0,7225%	0,0313%	0,2842%
t+9	ELM	-0,0383%	-0,0746%	-0,0512%
	MLP	0,0499%	0,0132%	0,0308%
	LSTM	0,8485%	0,0662%	0,3753%
t+10	ELM	-0,0340%	-0,0626%	-0,0499%
	MLP	0,0821%	0,0359%	0,0553%
	LSTM	0,8527%	0,0645%	0,3751%

Tabela 53. Statystyki stóp zwrotu dla pary walutowej USD/EUR przy inwestycji w kontrakty z wykorzystaniem prognoz sieci neuronowych

Para walutowa	Horyzont inwestycji	Stopa zwrotu z inwestycji			
			max	min	średnia
USD/EUR	t+1	ELM	0,0338%	0,0216%	0,0274%
		MLP	0,0334%	0,0112%	0,0259%
		LSTM	0,0165%	-0,0167%	-0,0005%
	t+2	ELM	0,0558%	0,0382%	0,0492%
		MLP	0,0694%	0,0418%	0,0493%
		LSTM	0,1586%	-0,0277%	0,0202%
	t+3	ELM	0,0920%	0,0802%	0,0869%
		MLP	0,0851%	0,0607%	0,0736%
		LSTM	0,2518%	-0,0156%	0,0612%
	t+4	ELM	0,1196%	0,0995%	0,1103%
		MLP	0,1022%	0,0865%	0,0956%
		LSTM	0,3733%	0,0087%	0,1215%

t+5	ELM	0,1422%	0,1181%	0,1293%
	MLP	0,1338%	0,1117%	0,1234%
	LSTM	0,4343%	0,0114%	0,1489%
t+6	ELM	0,1612%	0,1348%	0,1512%
	MLP	0,1635%	0,1341%	0,1486%
	LSTM	0,4989%	-0,0172%	0,1994%
t+7	ELM	0,1838%	0,1618%	0,1715%
	MLP	0,1899%	0,1511%	0,1686%
	LSTM	0,5767%	0,0421%	0,2469%
t+8	ELM	0,2078%	0,1806%	0,1946%
	MLP	0,2010%	0,1483%	0,1747%
	LSTM	0,6582%	0,0663%	0,2944%
t+9	ELM	0,2182%	0,1820%	0,1981%
	MLP	0,2268%	0,1661%	0,1934%
	LSTM	0,7680%	0,0991%	0,3708%
t+10	ELM	0,2208%	0,2010%	0,2129%
	MLP	0,2246%	0,1611%	0,1975%
	LSTM	0,7611%	0,0927%	0,3698%

Zyski osiągnięte przy inwestycji w kontrakty można określić jako bardzo niskie. Fakt ten wynika z dwóch czynników. Pierwszym z nich jest poziom trafności, jakie osiągają sieci neuronowe. Przy poziomie trafności zbliżonym do 50%, generowane zyski są bliskie 0. Przy wyższej trafności zyski są wyższe. W przypadku kursu USD/EUR (Tabela 53.), dla sieci o wyższej trafności prognoz (np. LSTM) zysk jest wyższy aż trzy- czterokrotnie (w porównaniu z pozostałymi sieciami), szczególnie dla prognoz o dłuższym horyzoncie. Straty zaznaczone w tabeli kolorem czerwonym najczęściej są spotykane przy inwestowaniu z wykorzystaniem prognoz sieci, które uzyskały trafność poniżej 50%. Najbardziej widoczne jest to w przypadku sieci ELM i pary walutowej GBP/EUR w tabeli 52., gdzie i nawet maksymalna wartość zysku jest ujemna dla horyzontów prognozy 1-2 i 5-10 dni. Przywołując wyniki z rozdziału IV – trafność prognoz dla tej sieci była często najniższa.

Drugim czynnikiem wpływającym na wysokość zysku jest sposób konstrukcji inwestycji. W tym badaniu inwestuję w kontrakty i zarabiam jedynie na różnicach kursów odpowiednich par walutowych. W kolejnych tabelach przedstawiam, w jaki sposób mogę zwiększyć zysk, inwestując w opcje.

1.2. Inwestycja w opcje kupna i sprzedaży

W tabelach 54-56 przedstawiam statystyki stóp zwrotu z inwestycji w opcje dla poszczególnych par walutowych: CHF/EUR (Tabela 54.), GBP/EUR (Tabela 55.) oraz USD/EUR (Tabela 56.). W niniejszych tabelach można zauważyć, iż zysk z inwestycji wzrasta w stosunku do inwestycji w kontrakty.

Tabela 54. Statystyki stóp zwrotu dla pary walutowej CHF/EUR przy inwestycji w opcje z wykorzystaniem prognoz sieci neuronowych

Para walutowa	Horyzont prognozy	Stopa zwrotu z inwestycji			
		Sieć	max	min	średnia
CHF/EUR	t+1	ELM	1,9965%	1,1367%	1,4904%
		MLP	0,6229%	-0,4414%	0,0088%
		LSTM	2,3586%	-0,6682%	1,0048%
	t+2	ELM	3,4825%	1,8614%	2,8177%
		MLP	0,6618%	-1,0901%	-0,3671%
		LSTM	3,5272%	-0,4027%	1,2339%
	t+3	ELM	4,6223%	1,3082%	3,5210%
		MLP	1,9111%	-1,2807%	-0,0485%
		LSTM	4,4346%	-2,0480%	1,8665%
	t+4	ELM	6,0345%	2,8377%	4,7533%
		MLP	2,1317%	-1,2518%	-0,0605%
		LSTM	7,5797%	0,7870%	4,8365%
	t+5	ELM	7,2169%	3,7922%	5,8702%
		MLP	3,5945%	-0,9177%	0,2563%
		LSTM	7,5566%	0,6303%	4,5794%
	t+6	ELM	8,1385%	3,5389%	6,5308%
		MLP	2,5980%	-1,3947%	0,0045%
		LSTM	5,3576%	1,1818%	3,4523%
	t+7	ELM	8,7149%	3,9186%	6,8725%
		MLP	2,1914%	-1,9052%	-0,5956%
		LSTM	5,9418%	-0,2851%	3,3452%
	t+8	ELM	10,0010%	4,1543%	7,8680%
		MLP	2,0584%	-2,2203%	-0,6845%
		LSTM	7,4866%	0,0179%	4,0506%
	t+9	ELM	12,7476%	5,8428%	9,4550%
		MLP	1,9224%	-4,1123%	-2,4317%
		LSTM	12,5002%	1,9037%	6,2317%
	t+10	ELM	11,7975%	3,9177%	9,1576%
		MLP	0,8711%	-4,1123%	-2,4461%
		LSTM	12,5002%	1,9037%	6,2317%

Tabela 55. Statystyki stóp zwrotu dla pary walutowej GBP/EUR przy inwestycji w opcje z wykorzystaniem prognoz sieci neuronowych

Para walutowa	Horyzont prognozy	Stopa zwrotu z inwestycji			
			max	min	średnia
GBP/EUR	t+1	ELM	-0,2628%	-1,1429%	-0,5887%
		MLP	0,6106%	-1,0321%	-0,1704%
		LSTM	0,5322%	-1,2076%	-0,2863%
	t+2	ELM	0,2508%	-1,0855%	-0,6483%
		MLP	1,2398%	-1,0978%	0,2191%
		LSTM	1,2521%	-1,7808%	-0,2070%
	t+3	ELM	-0,1657%	-1,3479%	-0,6482%
		MLP	1,8520%	-0,3411%	0,7750%
		LSTM	2,0992%	-1,9249%	-0,1751%
	t+4	ELM	0,2945%	-1,3960%	-0,6181%
		MLP	2,8668%	-0,2926%	1,4333%
		LSTM	2,5401%	-3,1672%	-0,2762%
	t+5	ELM	0,2319%	-1,8093%	-0,8665%
		MLP	3,6860%	0,1255%	1,7894%
		LSTM	2,9001%	-2,2726%	0,3294%
	t+6	ELM	-0,1160%	-2,7104%	-1,1170%
		MLP	4,0221%	0,6368%	1,9185%
		LSTM	1,6842%	-2,5345%	-0,5914%
	t+7	ELM	-1,1648%	-3,5248%	-2,2482%
		MLP	3,4140%	-0,6387%	1,3664%
		LSTM	1,4385%	-3,9470%	-1,4635%
	t+8	ELM	-1,7119%	-4,2129%	-2,7978%
		MLP	2,1675%	-0,9442%	0,5043%
		LSTM	11,2107%	-3,9601%	0,9586%
	t+9	ELM	-2,5572%	-5,5203%	-3,8110%
		MLP	1,6839%	-1,6322%	0,1858%
		LSTM	27,1245%	-3,6181%	8,0768%
	t+10	ELM	-2,7220%	-5,2918%	-3,9413%
		MLP	1,8044%	-1,6423%	0,1434%
		LSTM	27,1245%	-3,6181%	8,0768%

Tabela 56. Statystyki stóp zwrotu dla pary walutowej USD/EUR przy inwestycji w opcje z wykorzystaniem prognoz sieci neuronowych

Para walutowa	Horyzont prognozy	Stopa zwrotu z inwestycji			
			max	min	średnia
USD/EUR	t+1	ELM	1,8736%	1,0029%	1,4946%
		MLP	1,8090%	0,3749%	1,1613%
		LSTM	0,4935%	-1,3763%	-0,3955%
	t+2	ELM	1,4247%	0,5366%	0,9612%
		MLP	2,4771%	-0,1517%	1,1249%
		LSTM	0,6504%	-2,3562%	-1,0474%
	t+3	ELM	1,5965%	0,4521%	1,0225%
		MLP	2,2604%	0,4504%	1,3544%
		LSTM	1,8602%	-1,6582%	0,0698%
	t+4	ELM	1,8904%	-0,1167%	1,0318%
		MLP	2,2848%	-0,2517%	0,9240%
		LSTM	2,9495%	-2,1921%	0,5586%
	t+5	ELM	2,4472%	1,0447%	1,7005%
		MLP	3,5972%	-0,0315%	1,7700%
		LSTM	4,6160%	-2,3254%	1,7935%
	t+6	ELM	3,2359%	1,4554%	2,3030%
		MLP	4,7897%	0,9465%	2,3398%
		LSTM	5,2178%	-3,5266%	1,5933%
	t+7	ELM	4,6011%	2,4642%	3,3900%
		MLP	6,0912%	1,4186%	4,1010%
		LSTM	4,8282%	-3,1050%	1,5371%
	t+8	ELM	5,0324%	2,7919%	3,7743%
		MLP	6,7261%	2,4873%	4,6381%
		LSTM	10,8048%	-1,5580%	3,7224%
	t+9	ELM	7,1342%	4,5679%	5,5072%
		MLP	8,8998%	3,7150%	6,5602%
		LSTM	25,5792%	-2,0529%	9,9362%
	t+10	ELM	6,4302%	4,5679%	5,5382%
		MLP	8,8464%	3,7150%	6,2959%
		LSTM	25,5792%	-2,0529%	9,9362%

Możemy zauważyć większe rozbieżności między wartościami minimalnymi i maksymalnymi w obrębie jednej sieci – nawet do 30% przy inwestycji sieciami LSTM w dłuższym horyzoncie. Różnice te wynikają bezpośrednio z trafności prognoz, ponieważ wśród sieci LSTM, zależnie od parametryzacji, uzyskiwano trafność pomiędzy 50% a 70%. W ogólności, wysokość zysku zależy od trafności prognoz sieci, ale w niektórych przypadkach

inwestycje podjęte na podstawie mniej trafnych sieci przyniosły wyższy zysk. Wynika to z faktu, iż trafność liczę jako liczbę poprawnie zaprognozowanych zmian kierunku, natomiast każdą jednostkową poprawną (lub błędną) decyzję charakteryzują inne zyski (straty).

W celu zobrazowania takiego przykładu, w tabeli 57. sporządziłem zestawienie trafności prognoz sieci LSTM prognozującej na 10 dni do przodu z osiąganym zyskiem dla wszystkich trzech par walutowych i przy różnej hiperparametryzacji. Wartości w nawiasach zwykłych oznaczają zysk w euro dla inwestycji w kontrakty, a w nawiasach kwadratowych - zysk w euro dla inwestycji w opcje. Przedstawiam zysk, a nie zwrot z inwestycji, w celu wskazania na rząd wielkości oraz dla klarowności porównań.

Tabela 57. Zestawienie trafności prognoz oraz zysków dla kontraktów i opcji dla sieci LSTM o określonych parametrach

Parametry sieci	GBP/EUR	CHF/EUR	USD/EUR
hd6lags1	72,95% (1 229,56) (39 113,50)	73,44% (1 286,58) (7 417,52)	73,02% (1 037,71) (35 328,00)
hd6lags2	67,13% (922,09) (26 387,44)	69,00% (1 078,79) (9 677,73)	69,63% (803,54) (25 846,22)
hd6lags3	62,62% (699,74) (16 144,42)	62,34% (789,63) (4 589,80)	64,29% (615,64) (15 957,04)
hd6lags4	58,39% (422,92) (11 477,51)	59,43% (579,59) (9 689,34)	61,65% (529,30) (14 596,52)
hd6lags5	54,02% (291,64) (2 898,09)	57,14% (369,86) (12 501,84)	59,15% (455,00) (8 404,14)
hd6lags6	53,81% (159,15) (-3 279,78)	54,72% (310,63) (6 159,86)	56,45% (288,89) (7 010,90)
hd6lags7	51,39% (136,54) (-5 217,25)	53,19% (241,65) (10 798,52)	57,07% (244,86) (6 016,42)
hd7lags1	56,03% (1 167,52) (36 551,75)	56,03% (1 267,33) (7 019,50)	56,03% (1024,01) (36 410,66)
hd7lags2	55,55% (919,92) (26 116,57)	55,55% (1 053,98) (3 023,01)	55,55% (854,22) (27 897,28)
hd7lags3	55,96% (713,78) (17 111,96)	55,96% (789,72) (6 972,50)	55,96% (621,47) (17 814,18)
hd7lags4	55,83% (466,82) (9 940,49)	55,83% (642,60) (10 140,51)	55,83% (528,97) (13 444,14)
hd7lags5	56,38% (278,29) (679,57)	56,38% (443,85) (12 479,84)	56,38% (411,95) (9 628,97)
hd7lags6	56,73% (211,68) (-2 553,16)	56,73% (325,02) (14 003,55)	56,73% (271,75) (7 955,38)
hd7lags7	56,45% (106,21) (-4 484,57)	56,45% (200,50) (12 149,03)	56,45% (309,12) (6 731,80)

Opis: W tabeli podano trafność dla danych parametrów i pary walutowej, w nawiasach () podano zysk dla inwestycji w kontrakty, natomiast w () zysk dla inwestycji za pomocą opcji.

Przed sformułowaniem najważniejszych wniosków, które mogą być uogólnione na całe badanie, chciałbym zwrócić szczególną uwagę, na sytuacje nietypowe, które w tabeli zaznaczono kolorami.

1. Dla pary walutowej GBP/EUR przy trafności prognoz rzędu 54,02% osiągnięto zysk na poziomie 2898,09 euro a dla trafności 53,81% stratę -3279,78 (kolor żółty). W związku z tym, że w badaniu postawiono 1442 prognozy oznacza to, że sieć, która na tej samej parze walutowej pomyliła się tylko 3 razy więcej, uzyskała wynik aż o ok. 6 tysięcy euro gorszy. W przypadku inwestycji w kontrakty, różnica również jest na korzyść sieci lepiej

prognozującej, ale wykorzystanie prognoz drugiej sieci także przynosi zysk. Ten przykład pokazuje, że niewielkie różnice w trafności mogą prowadzić do generowania znacząco różnych przychodów ze względu na zyskowność decyzji.

2. **Kolorem czerwonym** zazaczyłem przypadek, w którym sieć o minimalnie gorszej trafności generuje zysk na opcjach, a sieć o minimalnie lepszej trafności generuje stratę.
3. **Kolorem Niebieskim** zazaczyłem sytuację, w którym zysk nie zależał od trafności sieci. Sieć LSTM o parametrach: 25 węzłów ukrytych i 1 opóźnienie (hd6lags1) miała dużo wyższą trafność, niż a LSTM o parametrach: 50 węzłów ukrytych i 1 opóźnienie (hd7lags1).
4. **Kolorem Zielonym** zazaczyłem przypadek podobny do przykładu niebieskiego, przy czym sieć o znacząco niższej trafności generuje tu znacząco wyższe zyski.

Tak jak już zauważono wcześniej, zazwyczaj wyższa trafność przekłada się na wyższy zysk. Powyższe przykłady obrazują jednak, że nie należy utożsamiać trafności prognoz kierunku zmian z zyskownością. Istnieje wysokie prawdopodobieństwo, że trafniejsze prognozy kierunku zmian będą się przekładały na wysokie zyski, jednak ważny jest też moment, w których stawiamy prognozę i moment, w którym stawiana prognoza jest błędna, ponieważ każdy w każdym przypadku możemy osiągnąć inny zysk (stratę). W kolejnym etapie przedstawię wyniki przy uwzględnieniu możliwości inwestowania w stabilizację poprzez wykorzystanie strategii krótkiego stelaża.

1.3. Inwestycja w opcje kupna i sprzedaży lub strategię stelaża

W tabelach 58-60 przedstawiam zyskowność inwestycji w opcje i strategię stelaża. Podobnie, jak w poprzednich podrozdziałach, na początku pokazuję wyniki z inwestycji w CHF/EUR (Tabela 58.), następnie w GBP/EUR (Tabela 59.) i ostatecznie w USD/EUR (Tabela 60.). Wyniki tego podejścia są bardziej zbliżone do wyników uzyskiwanych z wykorzystaniem do inwestycji tylko opcji niż kontraktów. Jednak mimo podobieństw można zauważyć różnice, np. w liczbie ujemnych stóp zwrotu w kolumnie z maksymalnym zyskiem. W przypadku opcji mam takich sytuacji 7, a gdy uwzględnimy strategię na stabilizację, to tylko 4 – wszystkie dla sieci ELM oraz GBP/EUR prognozującej na 8-10 dni i USD/EUR dla prognozy na 2 dni. Różnica występuje również w kolumnie z minimalnymi wartościami zysku. Przy inwestowaniu tylko w opcje

w większości przypadków trafia się na takie ustawienie parametrów sieci, które przynosi stratę w danym horyzoncie, natomiast po dodaniu strategii stelaża, liczba ta spada.

Tabela 58. Statystyki stóp zwrotu dla pary walutowej CHF/EUR przy inwestycji w opcje z uwzględnieniem strategii stelaża z wykorzystaniem prognoz sieci neuronowych

Para walutowa	Horyzont prognozy	Stopa zwrotu z inwestycji			
			max	min	średnia
CHF/EUR	t+1	ELM	1,4843%	0,4283%	0,8625%
		MLP	2,1385%	0,9765%	1,9539%
		LSTM	2,0442%	-0,8882%	0,9746%
	t+2	ELM	1,8682%	0,5006%	1,2877%
		MLP	2,3190%	1,6716%	1,8813%
		LSTM	3,5478%	0,0000%	1,4137%
	t+3	ELM	4,0593%	1,1507%	2,9571%
		MLP	2,9083%	1,3532%	2,4452%
		LSTM	4,4491%	-1,1480%	1,8963%
	t+4	ELM	5,7251%	2,7222%	4,5637%
		MLP	3,5726%	2,2379%	3,0615%
		LSTM	7,7452%	0,9066%	4,5289%
	t+5	ELM	6,4590%	3,7362%	5,7622%
		MLP	4,0143%	2,2485%	3,3577%
		LSTM	6,6559%	0,4699%	4,1634%
	t+6	ELM	7,8963%	2,9873%	6,4513%
		MLP	5,1049%	2,8036%	3,5611%
		LSTM	6,8566%	0,4644%	3,3707%
	t+7	ELM	8,5405%	3,7050%	6,7828%
		MLP	3,5588%	1,7006%	2,6544%
		LSTM	6,8362%	-0,7379%	3,5048%
	t+8	ELM	9,6678%	4,1532%	7,4804%
		MLP	4,2342%	1,4810%	2,4438%
		LSTM	7,7387%	0,7712%	3,8260%
	t+9	ELM	11,4599%	4,9942%	9,0287%
		MLP	3,1464%	0,6738%	1,7223%
		LSTM	9,5776%	0,3257%	5,1276%
	t+10	ELM	11,7406%	4,7617%	8,9220%
		MLP	2,8965%	0,1648%	1,3689%
		LSTM	11,6559%	1,5447%	5,8538%

Tabela 59. Stopy zwrotu dla pary walutowej GBP/EUR przy inwestycji w opcje z uwzględnieniem strategii stelaża z wykorzystaniem prognoz sieci neuronowych

Para walutowa	Horyzont prognozy	Stopa zwrotu z inwestycji			
			max	min	średnia
GBP/EUR	t+1	ELM	0,3775%	-0,3568%	-0,0166%
		MLP	1,5247%	0,1740%	0,5785%
		LSTM	1,0017%	-0,5824%	0,0246%
	t+2	ELM	0,2984%	-0,7513%	-0,3488%
		MLP	1,8930%	0,2133%	0,8677%
		LSTM	0,9165%	-1,4661%	-0,1894%
	t+3	ELM	0,3612%	-0,9421%	-0,3481%
		MLP	1,8993%	0,4517%	1,0616%
		LSTM	1,7003%	-1,9055%	0,0356%
	t+4	ELM	0,5926%	-1,0457%	-0,2452%
		MLP	2,6299%	0,5793%	1,4894%
		LSTM	2,2025%	-2,2298%	0,0927%
	t+5	ELM	0,6696%	-1,5112%	-0,1768%
		MLP	3,5303%	0,7582%	2,0038%
		LSTM	2,3072%	-2,3151%	0,3090%
	t+6	ELM	0,1428%	-2,3150%	-1,3288%
		MLP	3,4138%	-0,7989%	1,4897%
		LSTM	1,5050%	-3,0817%	-1,0102%
	t+7	ELM	0,1428%	-2,3150%	-1,3288%
		MLP	3,4138%	-0,7989%	1,4897%
		LSTM	1,5050%	-3,0817%	-1,0102%
	t+8	ELM	-0,8758%	-3,2667%	-1,9115%
		MLP	2,9466%	-0,5109%	1,1875%
		LSTM	9,2089%	-3,0028%	1,1321%
	t+9	ELM	-0,8956%	-3,4183%	-2,0373%
		MLP	2,2428%	-1,3272%	0,4772%
		LSTM	24,0957%	-3,1311%	6,4418%
	t+10	ELM	-0,9603%	-3,7355%	-2,0812%
		MLP	2,0817%	-1,7426%	0,3230%
		LSTM	26,4501%	-3,0159%	7,6317%

Tabela 60. Stopy zwrotu dla pary walutowej USD/EUR przy inwestycji w opcje z uwzględnieniem strategii stelaża z wykorzystaniem prognoz sieci neuronowych

Para walutowa	Horyzont prognozy	Stopa zwrotu z inwestycji			
			max	min	średnia
USD/EUR	t+1	ELM	0,7063%	0,0176%	0,4071%
		MLP	1,5390%	0,1422%	0,8101%
		LSTM	0,7463%	-1,2784%	-0,2012%
	t+2	ELM	-0,1340%	-0,9901%	-0,5285%
		MLP	1,8759%	0,5559%	1,1064%
		LSTM	1,0623%	-1,8461%	-0,5988%
	t+3	ELM	1,3881%	0,3606%	0,8559%
		MLP	2,6024%	0,4633%	1,5376%
		LSTM	1,8383%	-1,6688%	0,2356%
	t+4	ELM	1,4843%	0,1056%	0,8953%
		MLP	2,9829%	-0,0724%	1,3973%
		LSTM	3,1594%	-2,3939%	0,6402%
	t+5	ELM	2,4583%	0,3410%	1,4827%
		MLP	3,6162%	-0,1811%	1,7533%
		LSTM	4,9694%	-1,9297%	2,1689%
	t+6	ELM	3,8713%	1,2395%	2,4723%
		MLP	4,8132%	0,9642%	2,8580%
		LSTM	4,9288%	-2,0889%	2,0417%
	t+7	ELM	4,7073%	2,1267%	2,9961%
		MLP	5,7394%	3,2134%	4,5044%
		LSTM	5,0821%	-3,6016%	1,8782%
	t+8	ELM	4,4995%	2,6074%	3,5413%
		MLP	7,1549%	3,8627%	5,3242%
		LSTM	11,2136%	-2,0554%	3,7493%
	t+9	ELM	7,2290%	4,7444%	5,8216%
		MLP	9,6722%	5,9785%	7,7488%
		LSTM	22,3349%	-0,1550%	8,4439%
	t+10	ELM	6,8838%	4,8481%	5,7787%
		MLP	9,5447%	5,4161%	7,6232%
		LSTM	26,1811%	-1,0619%	10,4613%

1.4. Porównanie inwestycji w opcje oraz w strategię stelaża

W celu porównania obu podejść sporządziłem tabelę 61. W celu ukazania przewagi jednego sposobu inwestycji nad drugim, porównałem stopy zwrotu dla każdej z sieci neuronowych oraz par walutowych. „0” oznacza, że dla danego horyzontu inwestycji, sieci neuronowej oraz pary

walutowej wyższą stopę zwrotu otrzymano inwestując tylko w opcję kupna i sprzedaży, natomiast „O+” w opcję kupna i sprzedaży lub strategię stelaża. W celu podsumowania, w ostatnim wierszu tabeli umieszczono procentowy udział w danej kolumnie wskaźników na „O+”.

Tabela 61. Porównanie stopy zwrotu dla inwestycji w opcje oraz w opcję i strategię stelaża przy prognozowaniu sieciami neuronowymi

Horyzont prognozy	Sieć neuronowa	CHF/EUR			GBP/EUR			USD/EUR		
		max	min	średnia	max	min	średnia	max	min	średnia
t+1	ELM	O	O	O	O+	O+	O+	O	O	O
	MLP	O+	O+	O+	O+	O+	O+	O	O	O
	LSTM	O	O	O	O+	O+	O+	O+	O+	O+
t+2	ELM	O	O	O	O+	O+	O+	O	O	O
	MLP	O+	O+	O+	O+	O+	O+	O	O+	O
	LSTM	O+	O+	O+	O	O+	O+	O+	O+	O+
t+3	ELM	O	O	O	O+	O+	O+	O	O	O
	MLP	O+	O+	O+	O+	O+	O+	O+	O+	O+
	LSTM	O+	O+	O+	O	O+	O+	O	O	O+
t+4	ELM	O	O	O	O+	O+	O+	O	O+	O
	MLP	O+	O+	O+	O	O+	O+	O+	O+	O+
	LSTM	O+	O+	O	O	O+	O+	O+	O	O+
t+5	ELM	O	O	O	O+	O+	O+	O+	O	O
	MLP	O+	O+	O+	O	O+	O+	O+	O	O
	LSTM	O	O	O	O	O	O	O+	O+	O+
t+6	ELM	O	O	O	O+	O+	O	O+	O	O+
	MLP	O+	O+	O+	O	O	O	O+	O+	O+
	LSTM	O+	O	O	O	O	O	O	O+	O+
t+7	ELM	O	O	O	O+	O+	O+	O+	O	O
	MLP	O+	O+	O+	O	O	O+	O	O+	O+
	LSTM	O+	O	O+	O+	O+	O+	O+	O	O+
t+8	ELM	O	O	O	O+	O+	O+	O	O	O
	MLP	O+	O+	O+	O+	O+	O+	O+	O+	O+
	LSTM	O+	O+	O	O	O+	O+	O+	O	O+
t+9	ELM	O	O	O	O+	O+	O+	O+	O+	O+
	MLP	O+	O+	O+	O+	O+	O+	O+	O+	O+
	LSTM	O	O	O	O	O+	O	O	O+	O
t+10	ELM	O	O+	O	O+	O+	O+	O+	O+	O+
	MLP	O+	O+	O+	O+	O	O+	O+	O+	O+
	LSTM	O	O	O	O	O+	O	O+	O+	O+
Udział opcja + strategia stelaża		53%	50%	43%	60%	83%	80%	63%	57%	63%

Jeśli weźmiemy pod uwagę maksymalną stopę zwrotu dla danej sieci neuronowej i horyzontu prognozy, to dla każdej z sieci przewagę uzyskiwało inwestowanie w opcje i strategię stelaża (Tabela 61.). W kolejnych trzech rozdziałach przedstawione zostaną zyski osiągnięte dla inwestycji, w której inwestor kierowałby się jedną z pozostałych trzech innych metod wykorzystanych w rozprawie.

2. Zyskowość inwestycji przy wykorzystaniu wskazań metody rekurencyjnej

Zgodnie z wnioskami z rozdziału IV, mówiącymi o istotnych różnicach między metodą rekurencyjną typu I a II na korzyść tej, w której parametry wybranych sieci są aktualizowane co okres, w rozdziale V zastosowana zostanie jedynie ta metoda. Sposób prezentacji wyników odbędzie się w ten sam sposób, jak dla sieci neuronowych – w tabeli 62. i 63. przedstawiono stopy zwrotu z inwestycji dla metody rekurencyjnej, wskazując na ich maksymalną, minimalną oraz średnią wartość w obrębie danej pary walutowej i horyzontu inwestycji.

2.1. Inwestycja w kontrakty

W tabeli 62. przedstawiam stopy zwrotu, jakie osiągnąłby inwestor, gdyby inwestując w kontrakty, kierował się wskazaniem metody rekurencyjnej.

Tabela 62. Stopy zwrotu dla CHF/EUR, GBP/EUR oraz USD/EUR przy inwestycji w kontrakty z wykorzystaniem prognoz metody rekurencyjnej

Para walutowa	Stopa zwrotu z inwestycji			
	Horyzont inwestycji	max	min	średnia
CHF/EUR	t+1	0,0275%	-0,0040%	0,0117%
	t+2	0,1713%	-0,0311%	0,0513%
	t+3	0,3468%	-0,0548%	-0,0079%
	t+4	0,4627%	-0,0596%	0,1908%
	t+5	0,6451%	-0,0537%	0,2431%
	t+6	0,0581%	-0,0724%	-0,0498%
	t+7	0,0751%	-0,0725%	-0,0447%
	t+8	0,7902%	-0,0675%	0,2234%
	t+9	0,9308%	0,0861%	0,5708%
	t+10	0,8922%	0,1599%	0,5564%
GBP/EUR	t+1	0,0223%	-0,0083%	0,0073%
	t+2	0,1922%	0,0004%	0,0595%
	t+3	0,2842%	-0,0082%	0,1109%
	t+4	-0,0075%	-0,8006%	-0,7629%

	t+5	0,4917%	-0,0382%	0,2340%
	t+6	0,5577%	-0,0297%	0,2352%
	t+7	0,6417%	-0,0385%	0,3256%
	t+8	0,7225%	0,0580%	0,4128%
	t+9	0,8219%	0,0470%	0,4779%
	t+10	0,8527%	0,2022%	0,5583%
USD/EUR	t+1	0,0373%	0,0112%	0,0254%
	t+2	0,0683%	0,0356%	0,0523%
	t+3	0,0846%	0,0557%	0,0742%
	t+4	0,1015%	0,0760%	0,0901%
	t+5	0,1406%	0,0829%	0,1132%
	t+6	0,1778%	0,0952%	0,1397%
	t+7	0,5767%	0,1396%	0,1991%
	t+8	0,6582%	0,1459%	0,2577%
	t+9	0,7222%	0,1381%	0,2779%
	t+10	0,7611%	0,1567%	0,3339%

Tabela 63. Porównanie maksymalnej stopy zwrotu inwestując w kontrakty z wykorzystaniem metody rekurencyjnej z maksymalną stopą zwrotu dla sieci neuronowych.

Horizont prognozy	Typ sieci	CHF/EUR	GBP/EUR	USD/EUR
t+1	ELM	+	+	-
	MLP	+	+	-
	LSTM	+	-	+
t+2	ELM	+	+	+
	MLP	+	+	+
	LSTM	+	-	+
t+3	ELM	+	+	+
	MLP	+	+	+
	LSTM	+	-	+
t+4	ELM	+	+	+
	MLP	+	+	+
	LSTM	-	-	-
t+5	ELM	+	+	+
	MLP	+	-	+
	LSTM	+	-	-
t+6	ELM	+	+	+
	MLP	+	+	+
	LSTM	+	-	-
t+7	ELM	+	+	+
	MLP	+	+	-
	LSTM	+	-	+

t+8	ELM	+	+	+
	MLP	+	+	+
	LSTM	+	-	-
t+9	ELM	+	+	+
	MLP	+	+	+
	LSTM	-	-	-
t+10	ELM	+	+	+
	MLP	+	+	+
	LSTM	-	-	-

Opis: „+” oznacza, że dla danego typu sieci i horyzontu inwestycji metoda rekurencyjna uzyskała wyższy maksymalny poziom stopy zwrotu niż sieci neuronowe, „-” oznacza przewagę sieci neuronowych.

Dla pary walutowej CHF/EUR w 90% przypadków (27 na 30 wystąpień) maksymalna stopa zwrotu dla metody rekurencyjnej była wyższa, niż dla pojedynczych sieci neuronowych. Dla pary walutowej GBP/EUR analogiczna wielkość wyniosła 63,33% (19 na 30 wystąpień) a dla USD/EUR 70% (21 na 30 wystąpień). Oznacza to, że metoda rekurencyjna pozwala w wielu przypadkach na osiągnięcie stóp zwrotu wyższych niż maksymalna stopa zwrotu osiągnięta przez wykorzystanie sieci o najlepszej parametryzacji w obrębie określonego typu. W kolejnych podrozdziałach przedstawiam analogiczne porównania dla średniej stopy zwrotu uzyskiwanej na podstawie prognoz postawionych metodą rekurencyjną oraz przy prognozowaniu tylko sieciami neuronowymi dla inwestycji w opcje.

2.2. Inwestycja w opcje kupna i sprzedaży

W tabeli 64. przedstawiam statystyki stóp zwrotu dla inwestycji w opcje z wykorzystaniem metody rekurencyjnej.

Tabela 64. Stopy zwrotu dla CHF/EUR, GBP/EUR oraz USD/EUR przy inwestycji w opcje z wykorzystaniem prognoz metody rekurencyjnej

Para walutowa	Stopa zwrotu z inwestycji			
	Horyzont inwestycji	max	min	średnia
CHF/EUR	t+1	3,2374%	0,8207%	1,9603%
	t+2	5,4582%	1,1052%	2,9947%
	t+3	5,3176%	2,0076%	3,5499%
	t+4	7,0766%	1,2651%	3,4729%
	t+5	8,4862%	2,7553%	4,9813%
	t+6	8,4406%	3,2916%	4,8757%
	t+7	10,3806%	3,4336%	5,2423%

	t+8	40,3986%	3,9260%	12,1898%
	t+9	53,1034%	4,9075%	32,4736%
	t+10	51,6739%	9,3266%	32,1870%
GBP/EUR	t+1	1,1842%	-0,2037%	0,5187%
	t+2	1,5343%	0,0187%	0,8223%
	t+3	2,9080%	-1,3512%	0,7742%
	t+4	2,2607%	-1,2554%	0,3261%
	t+5	1,2867%	-2,2252%	-0,4991%
	t+6	11,5615%	-4,2096%	2,3408%
	t+7	22,8741%	-2,2497%	10,8197%
	t+8	32,7864%	0,2362%	17,3923%
	t+9	39,3644%	-0,2755%	20,8509%
	t+10	40,1746%	4,5410%	23,4597%
USD/EUR	t+1	1,3986%	0,6384%	1,1372%
	t+2	2,4397%	0,5595%	1,3702%
	t+3	2,1266%	0,7269%	1,3769%
	t+4	2,2712%	-0,2354%	1,1272%
	t+5	3,5697%	0,4179%	2,2065%
	t+6	4,7469%	1,4708%	2,6970%
	t+7	6,0745%	3,0246%	4,7131%
	t+8	10,8493%	3,6039%	5,6543%
	t+9	20,7145%	4,8490%	8,3448%
	t+10	35,5710%	15,3855%	6,5751%

Ponownie, gdy inwestujemy w kontrakty, osiągamy niewielki zysk, natomiast wartość stopy zwrotu rośnie znacząco przy wykorzystaniu opcji. Efekt ten wynika ze wspomnianej dźwigni finansowej. W analizie metody rekurencyjnej interesują mnie dwa aspekty:

- Istotne jest to, czy maksymalne stopy zwrotu dla danego horyzontu inwestycji i pary walutowej uzyskane na podstawie prognoz metodą rekurencyjną są wyższe od analogicznych wielkości uzyskanych na podstawie prognoz sieci. Jeżeli uda się przy pomocy metody rekurencyjnej uzyskać wyższą maksymalną stopę zwrotu, niż dla pojedynczej sieci, świadczyć to będzie o poprawnie dokonywanych wyborach parametrów przez metodę.
- Na wartość średnią dla danego typu sieci składają się stopy zwrotu wszystkich 49 możliwych kombinacji parametrów, natomiast na średnią dla metody rekurencyjnej składają się stopy zwrotu z 20 najlepszych kombinacji. Wyższa średnia dla metody

rekurencyjnej świadczy o poprawnych doborach parametrów przy jednoczesnej minimalizacji parametrów branych pod uwagę w badaniu.

Tabela 65. Porównanie maksymalnych stóp zwrotu z inwestycji w opcje z wykorzystaniem metody rekurencyjnej oraz sieci neuronowych.

Horyzont prognozy	Typ sieci	CHF/EUR	GBP/EUR	USD/EUR
t+1	ELM	+	+	-
	MLP	+	+	-
	LSTM	+	-	+
t+2	ELM	+	+	+
	MLP	+	+	+
	LSTM	+	-	+
t+3	ELM	+	+	+
	MLP	+	+	+
	LSTM	+	-	+
t+4	ELM	-	+	+
	MLP	+	-	+
	LSTM	+	-	+
t+5	ELM	-	+	+
	MLP	+	-	+
	LSTM	+	-	+
t+6	ELM	-	+	+
	MLP	+	+	+
	LSTM	+	-	+
t+7	ELM	-	+	+
	MLP	+	+	-
	LSTM	+	-	+
t+8	ELM	+	+	+
	MLP	+	+	+
	LSTM	+	-	+
t+9	ELM	+	+	+
	MLP	+	+	+
	LSTM	+	-	-
t+10	ELM	+	+	+
	MLP	+	+	+
	LSTM	-	-	-

Opis: „+” oznacza, że dla danego typu sieci i horyzontu inwestycji metoda rekurencyjna uzyskała wyższy maksymalny poziom stopy zwrotu niż sieci neuronowe, „-” oznacza przewagę sieci neuronowych.

Dokonując analizy tabeli 65. zauważam, że dla pary walutowej CHF/EUR i USD/EUR średni poziom zysku osiągnięty na podstawie prognoz metodą rekurencyjną był wyższy, niż średni

zysk na podstawie prognoz samych sieci w 83,33% (czyli w 25 przypadkach na 30 w obrębie danej sieci). Dla pary GBP/EUR współczynnik ten wynosi 60% czyli w 18 na 30 sytuacji. Wnioskuje zatem, że metoda rekurencyjna jest zdolna do poprawiania zarówno trafności prognoz, co wykazano w rozdziale IV, jak i zyskowności w porównaniu do metody stosującej tylko sieci neuronowe.

2.3. Inwestycja w opcje kupna i sprzedaży lub strategię stelaża

W tabeli 66. przedstawiam stopy zwrotu, jakie osiągnąłby inwestor, gdyby inwestując w opcje z uwzględnieniem strategii na stabilizację, kierował się wskazaniem metody rekurencyjnej.

Tabela 66. Stopy zwrotu dla CHF/EUR, GBP/EUR oraz USD/EUR przy inwestycji w opcje z uwzględnieniem strategii stelaża i z wykorzystaniem prognoz metody rekurencyjnej

Para walutowa	Stopa zwrotu z inwestycji			
	Horyzont inwestycji	max	min	średnia
CHF/EUR	t+1	4,72%	-1,85%	2,31%
	t+2	11,15%	1,49%	3,19%
	t+3	10,77%	3,42%	6,35%
	t+4	14,26%	-0,99%	0,18%
	t+5	15,85%	1,51%	5,26%
	t+6	20,64%	3,09%	7,11%
	t+7	21,86%	1,74%	0,95%
	t+8	29,27%	-1,45%	5,25%
	t+9	30,59%	-1,78%	3,24%
	t+10	31,03%	-2,57%	1,41%
GBP/EUR	t+1	8,45%	3,49%	5,45%
	t+2	3,52%	-0,94%	0,10%
	t+3	6,37%	0,07%	0,96%
	t+4	8,63%	1,00%	2,67%
	t+5	5,07%	-2,58%	3,01%
	t+6	23,14%	-1,65%	2,15%
	t+7	22,23%	0,08%	4,59%
	t+8	33,75%	-3,78%	9,54%
	t+9	37,01%	-3,88%	0,00%
	t+10	39,09%	-3,68%	4,32%
USD/EUR	t+1	2,73%	0,54%	1,17%
	t+2	4,53%	-0,31%	1,11%
	t+3	12,98%	0,33%	2,73%
	t+4	14,82%	-0,21%	2,56%
	t+5	19,67%	0,01%	3,61%

	t+6	23,73%	2,77%	7,27%
	t+7	31,48%	4,76%	10,50%
	t+8	35,37%	5,60%	11,43%
	t+9	30,95%	5,06%	10,16%
	t+10	32,62%	6,57%	12,57%

W tabeli 66. można zauważyć większe podobieństwo stóp zwrotu dla inwestycji w opcje kupna, sprzedaży oraz strategii stelaża, ze względu na ich wysokość, do inwestycji tylko w opcję kupna i sprzedaży niż przy inwestowaniu w kontrakty. Przy dodaniu strategii stelaża parametry sieci wybrane za pomocą metody rekurencyjne częściej uzyskiwały ujemne stopy zwrotu (minimalna wartość dla inwestycji tylko w opcje była ujemna 6-krotnie na 30 możliwości a po uwzględnieniu strategii stelaża wzrosła do aż 13). Świadczy to o większym ryzyku związanym z inwestowaniem w strategię stelaża. Jednak należy zauważyć, że dla tej strategii ani razu średnia stopa zwrotu nie była ujemna – oznacza to, że przy wysokiej trafności prognoz uwzględnieniem strategii na stabilizację pozwala ona na generowanie wyższych zysków niż w przypadku inwestycji tylko w opcję kupna i sprzedaży.

3. Zyski z inwestycji na podstawie prognoz uzyskanych z metody neuronowo-rozmytej

W rozdziale IV przedstawiono wiele podejść do metody neuronowo-rozmytej: uwzględniono dwa kształty funkcji przynależności oraz osiem sposobów wyznaczania jądra zbioru dla każdej z funkcji przynależności. Z moich badań z rozdziału IV, wynika, iż, różnice w trafności prognoz były bardzo często nieistotne w ramach jednego typu funkcji przynależności oraz że istotne różnice występowały między innymi funkcjami przynależności. Wobec tego, w badaniu zyskowności inwestycji zredukowałem liczbę możliwych sposobów rozmywania prognozy. Uwzględniłem jedynie trójkątną oraz trapezoidalną funkcję przynależności z jądrem zbioru równym średniej oraz medianie prognoz na dany dzień.

3.1. Inwestycja w kontrakty

W tabeli 67. przedstawiam stopę zwrotu z inwestycji, jaką osiągnąłby uczestnik rynku kierujący się prognozami z metody neuronowo-rozmytej, inwestując w kontrakty wystawiane na każdą walutę. Zauważam, że średni poziom zysku przy inwestycji w kontrakty jest zbliżony do osiągniętego z wykorzystaniem prognoz uzyskanych z poprzednich metod. Ponownie

najwięcej sytuacji, w których dla żadnej kombinacja parametrów sieci nie uzyskano dodatniego zysku, jest USD/EUR –w kolumnie odpowiadającej za minimalną stopę zwrotu z inwestycji uzyskaną tą metodą pojawiają się tylko dwie ujemne wartości.

Tabela 67. Stopy zwrotu dla CHF/EUR, GBP/EUR oraz USD/EUR przy inwestycji w kontrakty z wykorzystaniem prognoz metody neuronowo-rozmytej

Para walutowa	Stopa zwrotu z inwestycji			
	Horyzont inwestycji	max	min	średnia
CHF/EUR	t+1	0,0163%	-0,0373%	-0,0024%
	t+2	0,0839%	-0,0439%	0,0104%
	t+3	0,1655%	-0,0571%	0,0338%
	t+4	0,2120%	-0,0761%	0,0546%
	t+5	0,3023%	-0,0722%	0,0884%
	t+6	0,3333%	-0,0869%	0,0898%
	t+7	0,3712%	-0,0730%	0,1124%
	t+8	0,4580%	-0,0794%	0,1329%
	t+9	0,5620%	-0,0850%	0,1810%
	t+10	0,5729%	-0,1023%	0,1783%
GBP/EUR	t+1	0,0200%	-0,0155%	0,0017%
	t+2	0,0482%	-0,0137%	0,0170%
	t+3	0,0818%	-0,0127%	0,0353%
	t+4	0,1155%	-0,0179%	0,0449%
	t+5	0,1798%	-0,0198%	0,0605%
	t+6	0,2007%	-0,0315%	0,0626%
	t+7	0,2411%	-0,0481%	0,0798%
	t+8	0,3187%	-0,0490%	0,0936%
	t+9	0,3686%	-0,0565%	0,1177%
	t+10	0,4330%	-0,0410%	0,1366%
USD/EUR	t+1	0,0362%	-0,0108%	0,0200%
	t+2	0,0681%	-0,0054%	0,0394%
	t+3	0,1075%	0,0473%	0,0756%
	t+4	0,1459%	0,0629%	0,1108%
	t+5	0,1615%	0,1126%	0,1345%
	t+6	0,2202%	0,1103%	0,1680%
	t+7	0,2924%	0,1374%	0,1972%
	t+8	0,3215%	0,1448%	0,2251%
	t+9	0,3955%	0,1779%	0,2477%
	t+10	0,4285%	0,1752%	0,2686%

3.2. Inwestycja w opcje kupna i sprzedaży

W tabeli 68. przedstawiam stopę zwrotu, jaką osiągnąłby inwestor kierujący się prognozami z metody neuronowo-rozmytej inwestując w opcje wystawiane na każdą z walut. Ponownie obserwujemy wzrost zyskowności inwestycji, w porównaniu z inwestycją w kontrakty. W kolumnie z minimalną wartością zysku pojawia się więcej wartości ujemnych dla pary USD/EUR. Ponownie, największe różnice w stopach zwrotu widać dla pary GBP/EUR: stopy zwrotu dla tej pary są mniejsze niż dla pozostałych dwóch, co wynika z niskiej trafności prognoz.

Tabela 68. Stopy zwrotu dla CHF/EUR, GBP/EUR oraz USD/EUR przy inwestycji w opcje z wykorzystaniem prognoz metody neuronowo-rozmytej

Para walutowa	Stopa zwrotu z inwestycji			
	Horyzont inwestycji	max	min	średnia
CHF/EUR	t+1	2,2522%	-0,2213%	1,4055%
	t+2	4,0286%	0,8885%	2,6152%
	t+3	5,6182%	-1,1048%	3,4789%
	t+4	7,5154%	1,7868%	4,2166%
	t+5	8,6589%	1,7558%	5,3019%
	t+6	10,1451%	-0,2197%	6,2346%
	t+7	16,0324%	1,3889%	8,7681%
	t+8	23,9130%	3,9852%	11,4733%
	t+9	28,0620%	-0,7622%	11,1007%
	t+10	29,2594%	-0,7324%	11,6874%
GBP/EUR	t+1	1,7357%	0,1892%	0,6908%
	t+2	2,1495%	-0,5960%	1,0356%
	t+3	2,8936%	-0,9031%	0,4865%
	t+4	3,8012%	-2,0457%	0,4530%
	t+5	2,9652%	-2,0087%	0,1991%
	t+6	4,1313%	-2,0490%	0,5127%
	t+7	8,5969%	-2,4755%	2,5713%
	t+8	13,5129%	-2,5760%	4,2095%
	t+9	14,2458%	-10,2530%	-0,4715%
	t+10	16,5714%	-9,3631%	0,4112%
USD/EUR	t+1	1,1129%	-1,2386%	-0,1873%
	t+2	1,2385%	-0,9642%	0,4727%
	t+3	3,2716%	-0,5214%	1,4870%
	t+4	4,2919%	-1,3289%	2,1710%

	t+5	5,5748%	-0,4359%	3,2596%
	t+6	6,5642%	-0,2396%	4,0799%
	t+7	7,9813%	3,5161%	5,9875%
	t+8	12,5378%	6,5020%	8,2595%
	t+9	19,9908%	8,5888%	12,1250%
	t+10	22,6211%	8,5783%	12,8624%

3.3. Inwestycja w opcje kupna i sprzedaży lub strategię stelaża

Ostatecznie, w tabeli 69. przedstawiam statystyki stóp zwrotu z inwestycji w opcje i strategię stelaża, przy założeniu, że inwestor kieruje się prognozami z metody neuronowo-rozmytej.

Tabela 69. Stopy zwrotu dla CHF/EUR, GBP/EUR oraz USD/EUR przy inwestycji w opcje i strategię stelaża z wykorzystaniem prognoz metody neuronowo-rozmytej

Para walutowa	Stopa zwrotu z inwestycji			
	Horyzont inwestycji	max	min	średnia
CHF/EUR	t+1	3,7243%	0,1494%	0,8560%
	t+2	8,0017%	0,4897%	1,7792%
	t+3	10,7399%	0,2092%	1,8059%
	t+4	12,3600%	0,2402%	1,9170%
	t+5	15,7451%	-0,8054%	1,9932%
	t+6	18,7945%	-0,0273%	2,7040%
	t+7	20,8589%	0,4272%	2,8061%
	t+8	26,9299%	-0,2233%	3,5122%
	t+9	29,1730%	-1,8160%	3,1929%
	t+10	27,9115%	-1,3431%	3,1538%
GBP/EUR	t+1	4,3520%	0,3719%	1,0395%
	t+2	5,5183%	0,2873%	1,2871%
	t+3	6,4979%	0,2784%	1,2633%
	t+4	5,5129%	-0,2137%	0,9593%
	t+5	7,1724%	-0,2720%	1,0073%
	t+6	21,0008%	-0,4235%	3,8878%
	t+7	21,0008%	-0,4235%	3,8878%
	t+8	32,4330%	-0,6570%	5,1355%
	t+9	32,8857%	-2,6501%	1,7204%
	t+10	37,7826%	-2,3631%	2,4498%
USD/EUR	t+1	4,8549%	0,5043%	1,2172%
	t+2	6,8478%	-0,1693%	1,3127%
	t+3	9,7825%	0,1166%	2,4259%
	t+4	12,6902%	-0,1384%	2,6581%
	t+5	16,5461%	0,0342%	3,6427%

	t+6	21,7261%	1,5365%	5,5265%
	t+7	28,2677%	2,6267%	7,4848%
	t+8	33,2453%	4,4816%	9,8404%
	t+9	27,7198%	3,8255%	8,4222%
	t+10	31,6158%	3,9374%	8,8575%

Interpretacja wyników metody neuronowo-rozmytej jest zbliżona do metody rekurencyjnej. W obu metodach osiągam wyższe stopy zwrotu przy inwestowaniu na dłuższy horyzont. W przypadku średnich stóp zwrotu dla metody rekurencyjnej odnotowano cztery razy ujemną stopę zwrotu (CHF/EUR w horyzoncie inwestycji 3, 6 oraz 7 dni oraz GBP/EUR przy inwestycji na 4 dni). Dla metody neuronowo-rozmytej odnotowaną taką sytuację dwa razy (GBP/EUR dla horyzontu 9 dni oraz USD/EUR dla horyzontu 1 dzień). Wyniki te świadczą o tym, że metody te są wrażliwe na zmianę horyzontu inwestycji. W celu zbiorczego porównania zyskowności obu metod sporządziłem tabelę 70., zawierającą informację, która z metod osiągnęła wyższą maksymalną, minimalną oraz średnią zyskowność dla danej pary walutowej oraz horyzontu inwestycji.

3.4. Porównanie metody rekurencyjnej z neuronowo-rozmytą dla inwestycji w opcje

W tabeli 70. przedstawiam zbiorcze porównanie metody neuronowo-rozmytej z metodą rekurencyjną dla inwestycji w opcje kupna i sprzedaży. W tabeli symbolem „R” oznaczam wyższą stopę zwrotu dla danego horyzontu prognozy oraz pary walutowej uzyskaną przez metodę rekurencyjną, natomiast „NR” - przez metodę neuronowo-rozmytą. Liczba wystąpień obu symboli jest zbliżona. Inwestor stosując metodę rekurencyjną uzyskałby wyższe stopy zwrotu w 55,56% przypadków, a neuronowo-rozmytą w 44,44%. Przeprowadzając analizę bardziej szczegółową zauważam, iż dla pary walutowej CHF/EUR i GBP/EUR również częściej występuje przewaga metody rekurencyjnej, odpowiednio 63,33% do 36,67% oraz 60% do 40%. Dla pary walutowej USD/EUR odnotowano natomiast przewagę metody neuronowo-rozmytej w stosunku 56,67% do 43,33%.

Drugim kryterium, na podstawie którego można dokonać porównania, są wartości minimalne, maksymalne i średnie. W zbiorze minimalnych wartości częściej wyższą stopę zwrotu uzyskujemy stosując metodę rekurencyjną (70% do 30%). Może to świadczyć o tym, że metoda ta lepiej radzi sobie z minimalizowaniem strat w inwestycjach. Natomiast w zbiorze wartości maksymalnych między metodą rekurencyjną a neuronowo-rozmytą występuje

równowaga – po 50% wskazań. Wyższymi średnimi stopami zwrotu dla danego horyzontu charakteryzuje się metoda neuronowo-rozmyta, która uzyskała wyższe średnie stopy zwrotu w 70% przypadków (rekurencyjna w 30%).

Tabela 70. Porównanie metody rekurencyjnej z metodą neuronowo-rozmytą dla inwestycji w opcje

Para walutowa	Kontrakty – metoda neuronowo-rozmyta			
	Horyzont inwestycji	max	min	średnia
CHF/EUR	t+1	R	R	R
	t+2	R	R	R
	t+3	NR	R	R
	t+4	NR	NR	NR
	t+5	NR	R	NR
	t+6	NR	R	NR
	t+7	NR	R	NR
	t+8	R	NR	R
	t+9	R	R	R
	t+10	R	R	R
GBP/EUR	t+1	NR	NR	NR
	t+2	NR	R	NR
	t+3	R	NR	R
	t+4	NR	R	NR
	t+5	NR	NR	NR
	t+6	R	NR	R
	t+7	R	R	R
	t+8	R	R	R
	t+9	R	R	R
	t+10	R	R	R
USD/EUR	t+1	R	R	R
	t+2	R	R	R
	t+3	NR	R	NR
	t+4	NR	R	NR
	t+5	NR	R	NR
	t+6	NR	R	NR
	t+7	NR	NR	NR
	t+8	NR	NR	NR
	t+9	R	NR	NR
	t+10	R	R	NR

Opis: „R” w tabeli oznacza wyższą stopę zwrotu uzyskaną przez metodę rekurencyjną, natomiast „NR” przez metodę neuronowo rozmytą

3.5. Porównanie metody rekurencyjnej z neuronowo-rozmytą dla inwestycji w opcje lub strategię stelaża

Tabela 71. Porównanie metody rekurencyjnej z metodą neuronowo-rozmytą dla inwestowania w opcje i strategię stelaża

Para walutowa	Kontrakty – metoda neuronowo-rozmyta			
	Horyzont inwestycji	max	min	średnia
CHF/EUR	t+1	NR	R	R
	t+2	NR	NR	NR
	t+3	NR	NR	NR
	t+4	NR	R	R
	t+5	NR	NR	NR
	t+6	NR	NR	NR
	t+7	NR	R	R
	t+8	NR	NR	NR
	t+9	NR	NR	NR
	t+10	NR	R	R
GBP/EUR	t+1	NR	NR	NR
	t+2	R	R	R
	t+3	R	R	R
	t+4	NR	NR	NR
	t+5	R	R	R
	t+6	NR	R	R
	t+7	NR	NR	NR
	t+8	NR	R	NR
	t+9	NR	R	R
	t+10	NR	R	NR
USD/EUR	t+1	R	NR	R
	t+2	R	R	R
	t+3	NR	NR	NR
	t+4	NR	R	R
	t+5	NR	R	R
	t+6	NR	NR	NR
	t+7	NR	NR	NR
	t+8	NR	NR	NR
	t+9	NR	NR	NR
	t+10	NR	NR	NR

W tabeli 71. przedstawiam zbiorcze porównanie metody neuronowo-rozmytej z metodą rekurencyjną dla inwestowania w opcje kupna, sprzedaży oraz strategii nastawionej na stabilizację. Wyniki dla minimalnych oraz średnich wartości stopy zwrotu dla inwestowania z wykorzystaniem strategii na stabilizację są zbliżone do badania nieuwzględniającego tej metody. Znaczącą różnicę widać w przypadku wartości maksymalnych. Stosując metodę neuronowo-rozmytą uzyskujemy wyższą maksymalną stopę zwrotu w porównaniu do metody rekurencyjnej aż w 83,3% przypadków (25 z 30). Sytuacja ta może wskazywać, że dodanie możliwości inwestowania w stabilizację połączone z wysoką trafnością prognoz może prowadzić do osiągnięcia wyższych zysków, niż inwestycje tylko w opcje kupna oraz sprzedaży.

Bardzo zbliżone wyniki zyskowności dla obu tych metod, przy jednoczesnym wskazaniu ich przewagi nad inwestowaniem z wykorzystaniem tylko sieci neuronowych, są argumentem dla stosowania metody łączącej metodę rekurencyjną z metodą neuronowo-rozmytą. Można też zauważyć, iż inwestowanie w opcje oraz w strategię stelaża daje potencjalną możliwość uzyskiwania wyższego zysku niż w przypadku inwestowania tylko w opcje, niezależnie od wyboru metody progностycznej.

Ten wynik świadczy na korzyść metody krótkiego stelażu. Jeżeli sieci neuronowe prognozują niewielki wzrost lub spadek, to istnieje większe prawdopodobieństwo, że się pomylą. Wówczas inwestor, stosując tylko opcje kupna lub sprzedaży, popełni błąd i poniesie stratę. Zastosowanie strategii na stabilizację umożliwia osiągnięcie wyższych zysków przy trafnych prognozach. Z drugiej strony, strategia ta niesie ze sobą ryzyko, ponieważ charakterystyczną cechą strategii krótkiego stelaża jest możliwość poniesienia nieograniczonej straty przy dużych wahaniami kursów. W związku z tym, uwzględnienie strategii stabilizacji umożliwia zwiększenie potencjalnego zysku kosztem większej straty w przypadku złych prognoz.

4. Porównanie przeciętnego zysku osiąganego z zastosowaniem prognoz uzyskanych różnymi metodami

Ostatecznie, porównałem średnią zyskowność inwestycji z wykorzystaniem wskaźników wszystkich metod progностycznych. Osobno zbadałem inwestycje w kontrakty, opcje i opcje ze strategią opcyjną. Porównania zawsze dokonuję w stosunku do metody pojawiającej się w pracy chronologicznie wcześniej, tzn. metodę rekurencyjną porównuję do sieci a metodę neuronowo-rozmytą do sieci i do metody rekurencyjnej.

W celu zbadania istotności różnic między przeciętnymi stopami zwrotu przy użyciu prognoz z różnych metod, w pierwszej kolejności wykonałem test na równość wariancji. W zależności od wyników tego testu przeprowadziłem test na równość średnich. W przypadku równych wariancji statystyka testowa ma rozkład t Studenta; w przeciwnym stosuje się poprawkę Welcha na liczbę stopni swobody (Welch, 1947). Hipoteza zerowa teście zakłada równość średnich. W tabeli 72. prezentuję p -wartości dla przeprowadzonych testów. We wszystkich przypadkach odrzuciłem hipotezę zerową dotyczącą równości wariancji, w związku z tym wykonuję test z poprawką Welcha.

Tabela 72. Wartości statystyki z próby dla testu na równość wariancji

Hipoteza zerowa	Kontrakty	Opcje	Opcje + strategia stelaża
$\sigma^2_{NR} = \sigma^2_R$	0,000000036	0,00008655	0,000000064
$\sigma^2_{NR} = \sigma^2_{Sieci}$	0,0362	0,0000587	0,03253
$\sigma^2_R = \sigma^2_{Sieci}$	0,00002941	0,00000006	0,000000008

W tabeli 73. przedstawiam p -wartości dla tego badania. Jeżeli odrzuciłem hipotezę zerową o równości średniego zysku na korzyść hipotezy alternatywnej, że zysk z danej metody jest wyższy, niż z konkurencyjnej to w tabeli p -wartość zaznaczono pogrubioną czcionką.

Tabela 73. Wartości statystyki z próby dla testu na równość średniego zysku

Hipoteza alternatywna	Kontrakty	Opcje	Opcje + strategia stelaża
$\mu_{NR} > \mu_R$	0.0614	0.0279	0.0201
$\mu_{NR} > \mu_{Sieci}$	0.5349	0.0039	0.0078
$\mu_R > \mu_{Sieci}$	0.0958	0.0026	0.0068

Opis: NR oznacza metodę neuronowo-rozmytą, R metodę rekurencyjną a sieci rozumiem jako trafność dla prognozowania z wykorzystaniem tylko sieci neuronowych

Wniosuję, iż średni zysk przy inwestycji w kontrakty nie zmienia się, niezależnie od metody (p -wartość jest wyższa niż 0,05). W przypadku inwestycji w opcje i opcję z uwzględnieniem strategii stelaża średni zysk jest wyższy, jeśli kierujemy się prognozami z metody rekurencyjnej oraz z metody neuronowo-rozmytej, niż prognozami sieci. Ostatecznie, ponieważ średni poziom zysku jest wyższy, gdy kierujemy się prognozami metody neuronowo-rozmytej, niż wskazaniemi metody rekurencyjnej, można przyjąć, że

wykorzystanie metody neuronowo-rozmytej pozwala na osiągnięcie najwyższych zysków z inwestycji w opcje oraz opcje i strategie opcyjne.

W tabeli 74. zamieszczam pytania badawcze, na które poszukiwałem odpowiedzi w tym rozdziale, wraz z wnioskami wynikającymi z badania empirycznego.

Tabela 74. Odpowiedzi na pytania badawcze z II etapy rozprawy doktorskiej, dotyczące możliwości generowania zysków z wykorzystaniem instrumentów pochodnych.

4.1.	Czy wykorzystanie rozmytych prognoz zmian kierunku cen pozwoli na osiągnięcie wyższego zysku z inwestycji w kontrakty oraz opcje, niż wykorzystanie wskazań uzyskanych z prognoz sieci neruonowych oraz metody rekurencyjnej?	Przy inwestycji w kontrakty uzyskano bardzo niskie stopy zwrotu, zatem różnice między metodami można uznać za pomijalne. Wykorzystanie wskazań metody neuronowo-rozmytej do inwestycji w opcje oraz opcje ze strategią opcyjną w większości przypadków przynosiło wyższy zysk, niż kierowanie się wskazaniem pojedynczych sieci neuronowych oraz metodą rekurencyjną.
4.2.	Czy zastosowanie prognoz rozmytych przy strategii opcyjnej na stabilizację pozwoli na ograniczenie potencjalnych strat lub generowanie wyższych zysków niż stosowanie tylko gry na wzrost lub spadek?	Wnioski zależą od doboru strategii opcyjnej. Wykazano, że przy wysokiej trafności prognoz wykorzystanie strategii krótkiego stelaża oraz gry na stabilizację zwiększa zyski, natomiast przy niskiej trafności prognoz może generować wyższe straty. Wynika to z możliwości ponoszenia nieograniczonych strat przy inwestycji w strategię krótkiego stelaża. Natomiast zastosowanie strategii opcyjnej na stabilizację opartej na rozmytych prognozach pozwala na osiągnięcie wyższych zysków niż przy inwestowaniu tylko w opcje kupna i sprzedaży. Przypadek ograniczania potencjalnych strat nie istnieje dla metody

		neuronowo-rozmytej, ponieważ osiąga ona wysokie trafności prognoz i nie odnotowano wysokich strat.
--	--	--

Podsumowując, wykorzystanie wskazań metody neuronowo-rozmytej do strategii krótkiego stelaża umożliwia osiągnięcie wyższego zysku z inwestycji w porównaniu do stosowania tylko opcji kupna oraz sprzedaży. Należy jednak zauważyć, że osiąganie wyższego zysku możliwe jest dzięki wysokiemu poziomowi trafności uzyskiwanymi przez metodę neuronowo-rozmytą. W badaniu skoncentrowałem się jedynie na zyskowności, pomijając ryzyko inwestycji – badanie należałoby w przyszłości rozszerzyć o bardziej bezpieczne strategie opcyjne.

Zakończenie

Celem niniejszej rozprawy doktorskiej było skonstruowanie autorskiej metody neuronowo-rozmytej do prognozowania kierunku zmian kursów walutowych i późniejszego wykorzystania tych prognoz do konstrukcji strategii opcyjnych – innych w przypadku gry na wzrost, spadek i stabilizację. Metoda neuronowo-rozmyta była inspirowana podejściem *ensemble learning*, którego ideą jest łączenie wyników wielu prostych algorytmów uczenia maszynowego w celu uzyskania optymalnego rezultatu.

Przedmiotem badania były trzy pary walutowe CHF/EUR, GBP/EUR oraz USD/EUR analizowane w okresie 1.01.2014-31.12.2019. Realizacja celu rozprawy odbyła się w czterech etapach.

W pierwszym etapie zbadałem możliwości prognozowania zmian cen kursów walutowych z wykorzystaniem sieci ELM, MLP oraz LSTM o różnych hiperparametrach. Każda z sieci neuronowych dokonywała prognoz zmian kursu w horyzoncie od 1 do 10 dni. Trafność prognoz porównano z modelami ARMA oraz prognozą naiwną.

Uzyskane w etapie pierwszym prognozy wykorzystałem następnie w metodzie rekurencyjnej (etap drugi), neuronowo-rozmytej (etap trzeci) i w ostatecznie w metodzie łączącej metodę rekurencyjną z neuronowo-rozmytą. Metoda rekurencyjna polegała na prognozowaniu za pomocą zawężonego podzbioru dwudziestu sieci o różnych hiperparametrach, które okazały się najlepsze w okresie poprzedzającym moment stawiania nowej prognozy. Celem tego kroku badawczego było zweryfikowanie, czy można wskazać na konkretne hiperparametry lub typy sieci, które charakteryzują się najwyższą trafnością prognoz niezależnie od badanej pary walutowej, czy horyzontu prognozy.

W metodzie neuronowo-rozmytej rozmywałem prognozę ilościową, korzystając albo z prognoz wszystkich sieci, albo z ich podzbioru (połączenie metody rekurencyjnej i neuronowo-rozmytej). W tym ostatnim przypadku, korzystając z metody rekurencyjnej wybierałem sieci o najwyższej trafności prognostycznej w danym okresie i rozmytą prognozę na nowy okres stawiałem tylko z wykorzystaniem wskazań sieci o najlepszych hiperparametrach.

W poniższej tabeli przedstawiam zestawienie wszystkich pytań badawczych postawionych w rozprawie, razem z odpowiedziami.

Tabela 75. Odpowiedzi na pytania badawcze

Numer pytania	Treść pytania	Odpowiedź
1.1	Czy trafność prognozowania kierunku zmian kursu zależy od horyzontu prognozy?	Odpowiedź na to pytanie zależy od typu sieci neuronowej. LSTM osiągnęła wyższą trafność dla prognoz o dłuższym horyzoncie, a dla pozostałych sieci jednoznaczne zależności nie istnieją. Przykładowo, dla sieci ELM prognozującej parę walutową CHF/EUR wraz ze wzrostem horyzontu trafność maleje, a dla tej samej sieci prognozującej parę GBP/EUR trafność prognoz rośnie wraz ze wzrostem horyzontu prognozy.
1.2.	Czy trafność prognozowania kierunku zmian kursu zależy od hiperparametryzacji sieci?	Wnioski zależą od typu sieci. W przypadku sieci LSTM i MLP trafność prognozowania zależy od parametrów sieci. Sieć LSTM uzyskiwała najwyższą trafność przy ustawieniach z dwoma węzłami ukrytymi. Sieć MLP w wielu przypadkach uzyskiwała trafniejsze prognozy, gdy liczba opóźnień w sieci była równa długości horyzontu prognozy. W przypadku sieci ELM nie stwierdzono istnienia wyraźnych wzorców.
1.3.	Czy trafność prognozowania kierunku zmian jest uzależniona od typu sieci?	Najwyższą trafnością prognoz kierunków zmian charakteryzowała się sieć LSTM, szczególnie dla ustawień o dwóch węzłach ukrytych. Wniosek z pytania badawczego 1.3. jest wynikiem zgodnym z wynikiem oczekiwanym przy wyborze typów sieci neuronowych do badania i wynika z

		specyficznej budowy sieci LSTM wykazującej lepszą trafność prognozowania szeregów czasowych.
1.4.	Czy trafność prognozowania kierunku zmian za pomocą sieci neuronowych jest wyższa niż modeli ekonometrycznych?	<p>Wyniki badania potwierdzają, że dla większości badanych szeregów sieci neuronowe uzyskują wyższą trafność niż modele klasyczne, jednak uzależnione to jest od badanego szeregu.</p> <p>Sieci neuronowe a model ARMA:</p> <p>Dla pary walutowej USD/EUR sieci neuronowe uzyskały lepszą trafność prognoz niż modele ARMA we wszystkich przypadkach. Dla pary GBP/EUR, w większości przypadków sieci neuronowe uzyskały wyższą trafność niż ARMA (za wyjątkiem ELM i MLP uczących się na poziomach cen). Dla pary CHF/EUR prognozy z modelu ARMA charakteryzowały się wyższą trafnością niż prognozy sieci MLP i ELM, natomiast LSTM ucząca się na poziomach cen osiągnęła wyższą trafność niż ARMA</p> <p>Sieci neuronowe a prognoza naiwna</p> <p>Dla pary walutowej USD/EUR wszystkie typy sieci okazały się lepsze niż prognozowanie naiwne. Dla pary walutowej GBP/EUR sieci ELM i MLP ucząca się na poziomach cen uzyskały niższą trafność niż prognozowanie naiwne. Dla pary walutowej CHF/EUR tylko ELM i LSTM uczące się na poziomach cen osiągnęły wyższą trafność niż prognozowanie naiwne.</p>

2.1.	Czy trafność prognoz metodą rekurencyjną będzie lepsza niż trafność prognoz uzyskana prognozą naiwną lub modelem ARMA?	Prognoza naiwna była gorsza od metody rekurencyjnej. ARMA okazała się lepsza tylko dla pary walutowej CHF/EUR i horyzontu prognozy 1,2,3,6 oraz 7 dni. W przeważającej większości przypadków metoda rekurencyjna poprawia wyniki prognozowania względem prognozowania sieciami neuronowymi.
2.2.	Czy metoda rekurencyjna będzie uzyskiwała trafniejsze prognozy niż średnie prognozy dla pojedynczych sieci?	W znaczącej większości przypadków dla wszystkich sieci neuronowych oraz wszystkich horyzontów prognozy metoda neuronowo-rozmyta uzyskiwała wyższą trafność niż średnie wyniki trafności dla pojedynczych typów sieci.
3.1.	Czy typ funkcji przynależności ma wpływ na trafność prognoz w podejściu neuronowo-rozmytym?	Dla trafności prognoz bardziej istotny jest dobór odpowiedniej funkcji przynależności niż modyfikacja sposobu doboru jądra zbioru. Nie można było jednoznacznie wskazać funkcji przynależności najlepszej dla wszystkich trzech par walutowych. Dla pary walutowej CHF/EUR trójkątna funkcja przynależności uzyskała najwyższą trafność, natomiast dla GBP/EUR i USD/EUR - trapezoidalna funkcja przynależności
3.2.	Czy prognozowanie z wykorzystaniem podejścia neuronowo-rozmytego będzie skuteczniejsze niż prognozowanie w oparciu tylko o sieci neuronowe?	Tak, wykazano znaczącą przewagę między prognozowaniem metodą neuronowo-rozmytą a w oparciu tylko o sieci neuronowe. Średnia trafność sieci była wyższa od metody neuronowo-rozmytej tylko w 13 na 90 przypadków.

3.3.	Czy podejście neuronowo-rozmyte charakteryzuje się lepszą trafnością prognoz, niż prognozy na podstawie większości w obrębie sieci oraz prognozy naiwne i ARMA?	Porównując trafność metody neuronowo-rozmytej z metodą większości, w 80% przypadków wyższą trafność uzyskano z metody neuronowo-rozmytej oraz w 69% w porównaniu z prognozą naiwną oraz ARMA.
3.4.	Czy połączenie podejścia rekurencyjnego z podejściem neuronowo-rozmytym poprawi trafność prognoz?	Dla większości badanych par walutowych oraz horyzontów prognoz metoda łącząca metodę rekurencyjną i neuronowo-rozmytą uzyskała wyższą trafność niż metody te stosowane osobno.
4.1.	Czy wykorzystanie rozmytych prognoz zmian kierunku cen pozwoli na osiągnięcie wyższego zysku z inwestycji w kontrakty oraz opcje, niż wykorzystanie wskazań uzyskanych z prognoz sieci neruonowych oraz metody rekurencyjnej?	Przy inwestycji w kontrakty uzyskano bardzo niskie stopy zwrotu, zatem różnice między metodami można uznać za pomijalne. Wykorzystanie wskazań metody neuronowo-rozmytej do inwestycji w opcje oraz opcje ze strategią opcyjną w większości przypadków przynosiło wyższy zysk, niż kierowanie się wskazaniem pojedynczych sieci neuronowych oraz metodą rekurencyjną.
4.2.	Czy zastosowanie prognoz rozmytych przy strategii opcyjnej na stabilizację pozwoli na ograniczenie potencjalnych strat lub generowanie wyższych zysków niż stosowanie tylko gry na wzrost lub spadek?	Wnioski zależą od doboru strategii opcyjnej. Wykazano, że przy wysokiej trafności prognoz wykorzystanie strategii krótkiego stelaża oraz gry na stabilizację zwiększa zyski, natomiast przy niskiej trafności prognoz może generować wyższe straty. Wynika to z możliwości ponoszenia nieograniczonych strat przy inwestycji w strategię krótkiego stelaża. Natomiast zastosowanie strategii opcyjnej na stabilizację opartej na rozmytych prognozach

		<p>pozwała na osiąganie wyższych zysków niż przy inwestowaniu tylko w opcje kupna i sprzedaży. Przypadek ograniczania potencjalnych strat nie istnieje dla metody neuronowo-rozmytej, ponieważ osiąga ona wysokie trafności prognoz i nie odnotowano wysokich strat.</p>
--	--	--

Podsumowując, w etapie pierwszym badania wykazano (zgodnie z oczekiwaniami), że sieci neuronowe typu LSTM charakteryzują się najwyższą średnią trafnością prognoz zmian kierunku cen dla wszystkich par walutowych (pytanie badawcze 1.3.). Zauważono również, że trafność ta osiąga najwyższy poziom dla hiperparametryzacji z jednym opóźnieniem i nie jest zależna od liczby węzłów ukrytych (pytanie badawcze 1.2.). LSTM jest również siecią charakteryzującą się lepszą trafnością prognoz dla dłuższego (powyżej 5 dni) horyzontu prognoz (pytanie badawcze 1.1.).

Wniosek ten został potwierdzony w drugim etapie badania, gdzie spośród 140 różnych hiperparametrów sieci wybierano metodą rekurencyjną dwadzieścia sieci charakteryzujących się najlepszą trafnością. Dla krótszych horyzontów prognoz, wśród dwudziestu wybieranych sieci, odnotowano częste występowanie sieci MLP, natomiast dla dłuższych horyzontów znacząca jest przewaga sieci LSTM z różnymi hiperparametrami. W metodzie tej sporadycznie wybierana jest sieć ELM (niezależnie od hiperparametrów), co świadczy o najgorszej jakości prognoz dokonywanych za pomocą tej sieci neuronowej (pytanie badawcze 1.2.).

Zarówno pierwszy, jak i drugi etap wskazał na możliwość generowania trafniejszych prognoz zmian kierunku cen niż metody klasyczne. W porównaniu z metodami klasycznymi, sieć LSTM dla wszystkich par walutowych wykazywała wyższą trafność, natomiast dla CHF/EUR sieci ELM i MLP wykazywała gorszą trafność niż model ARMA. Dla GBP/EUR wyniki te były zależne od horyzontu prognozy, lecz dla większej liczby przypadków trafniejsze prognozy wykazał model ARMA (pytanie badawcze 1.3. oraz 2.1.). W drugim etapie badania wykazano zdolność do poprawy trafności prognoz poprzez zastosowanie metody rekurencyjnej (pytanie badawcze 2.2.).

Zastosowanie metody neuronowo-rozmytej znacząco poprawiło wyniki dla pary walutowej GBP/EUR oraz utrzymało status quo dla pary walutowej USD/EUR. Dla pary

walutowej CHF/EUR metoda rekurencyjna oraz metoda neuronowo-rozmyta poprawiała wyniki uzyskiwane z użyciem tylko sieci neuronowych, lecz w wielu przypadkach nie wystarczyło to do przewyższenia trafnością metody ARMA dla tej pary walutowej (pytanie badawcze 3.3). W związku z tym, przedstawiona w niniejszej rozprawie doktorskiej metoda neuronowo-rozmyta poprawia trafność prognozowania sieciami neuronowymi, a rozmiar tej poprawy skorelowany jest z trafnością prognoz sieci neuronowych (pytanie badawcze 3.2.). Wnioskuje zatem, iż dla pary walutowej, dla której sieci neuronowe osiągnęły najniższą trafność (tj. CHF/EEUR), zastosowanie podejścia neuronowo-rozmytego pozwoliło poprawić trafność, ale nie w takim stopniu, aby okazała się ona lepsza niż trafność z modelu ARMA. Natomiast dla pary GBP/EUR i USD/EUR większą poprawę trafności dzięki zastosowaniu podejścia neuronowo-rozmytego uzyskano dla pary GBP/EUR, przy czym prognozy sieciami neuronowymi dla GBP/EUR charakteryzowały się niższą trafnością niż dla USD/EUR. Zauważono również, że większy wpływ na poprawę trafności prognoz ma odpowiedni dobór funkcji przynależności, niż sposób doboru jądra zbioru rozmytego (pytanie badawcze 3.1.). Ostatecznie wykazano, że metoda łącząca podejście neuronowo-rozmyte z rekurencyjnym uzyskuje dla większości przypadków najwyższą trafność.

W niniejszej rozprawie udało się wykazać, że autorska metoda neuronowo-rozmyta zdolna jest do polepszenia prognozowania zmian kierunków kursów walutowych w porównaniu z metodami klasycznymi. W większości przypadków dawała ona trafność prognoz wyższą niż stosowanie samych sieci neuronowych, metody rekurencyjnej i metody większości sieci.

W badaniu empirycznym dotyczącym zyskowności pokazałem, że wykorzystanie wskazań metody neuronowo-rozmytej pozwala na osiągnięcie wyższych zysków z inwestycji w opcje kupna oraz sprzedaży, niż gdyby kierować się wskazaniem innych metod. W ostatnim kroku wprowadziłem możliwość gry na stabilizację wykorzystując strategię krótkiego stelaża. Strategia krótkiego stelaża jest strategią ryzykowną, gdyż przy błędnej decyzji potencjalne straty są nieograniczone. Również i w tym przypadku zyski osiągnięte z tego typu inwestycji okazały się najwyższe w przypadku, gdy do inwestowania wykorzystywałem wskazania metody neuronowo-rozmytej. Taki wynik był skutkiem wysokiej trafności prognoz. W przypadku niskiej trafności prognoz zastosowanie tej strategii należałoby uznać za ryzykowne.

Słabością przedstawionego badania jest niewątpliwie ograniczenie próby badawczej do trzech walut. Przetestowanie proponowanego narzędzia na większej liczbie szeregów,

obejmującego również kursy walut krajów rozwijających się, umożliwiłoby generalizację wniosków dotyczących poszukiwania najlepszej hiperparametryzacji sieci oraz skuteczności metody neuronowo-rozmytej. W rozprawie nie uzyskałem jednoznacznej odpowiedzi na część postawionych pytań, natomiast niewątpliwie uzyskane przeze mnie wyniki otwierają możliwości postawienia kolejnych oraz inspirują do dalszych badań, na przykład, jakie własności szeregów czasowych sprawiają, że dana sieć generuje na podstawie jego historii lepsze prognozy niż inna. Kontynuując badania rozpoczęte w tej rozprawie, planuję przetestować działanie metody na innych parach walutowych. Ponadto, planuję rozszerzyć zbiór stosowanych instrumentów pochodnych. W rozprawie porównuję możliwości osiągnięcia zysku z trzech strategii: gry na zmianę kursu (wówczas zysk jest równy różnicy między kursem z dnia zawarcia kontraktu a kursem wykonania), gry na zmianę kursu z wykorzystaniem opcji kupna i sprzedaży (wówczas zysk wynika z działania dźwigni finansowej poprzez zastosowanie opcji kupna oraz sprzedaży) oraz gry na stabilizację (alternatywa inwestycyjna w przypadku prognozy małego wzrostu lub spadku; zysk wynika z działania dźwigni finansowej). W dalszych etapach badań planuję przeanalizować możliwości osiągnięcia zysku między innymi z wykorzystaniem wspomnianych w pierwszym rozdziale opcji binarnych.

Bibliografia

1. Abdel-Hamid, O., Mohamed, A. R., Jiang, H., Deng, L., Penn, G., & Yu, D. (2014). Convolutional neural networks for speech recognition. *IEEE/ACM Transactions on audio, speech, and language processing*, 22(10), 1533-1545.
2. Abirami, S., & Chitra, P. (2020). Energy-efficient edge based real-time healthcare support system. In *Advances in Computers* (Vol. 117, No. 1, pp. 339-368). Elsevier.
3. Adhikari, R., & Agrawal, R. K. (2014). A combination of artificial neural network and random walk models for financial time series forecasting. *Neural Computing and Applications*, 24(6), 1441-1449.
4. Akbaş, S., & Dalkılıç, T. E. (2021). A hybrid algorithm for portfolio selection: An application on the Dow Jones Index (DJI). *Journal of Computational and Applied Mathematics*, 398, 113678.
5. Akhras, G., & Li, W. (2005). Static and free vibration analysis of composite plates using spline finite strips with higher-order shear deformation. *Composites Part B: Engineering*, 36(6-7), 496-503.
6. Aliev, R. A., Guirimov, B. G., Fazlollahi, B., & Aliev, R. R. (2009). Evolutionary algorithm-based learning of fuzzy neural networks. Part 2: Recurrent fuzzy neural networks. *Fuzzy sets and systems*, 160(17), 2553-2566.
7. Althelaya, K. A., El-Alfy, E. S. M., & Mohammed, S. (2018, April). Stock market forecast using multivariate analysis with bidirectional and stacked (LSTM, GRU). In *2018 21st Saudi Computer Society National Computer Conference (NCC)* (pp. 1-7). IEEE.
8. Andina, D., & Pham, D. T. (Eds.). (2007). *Computational intelligence: For engineering and manufacturing*. Springer Science & Business Media,
9. Bartkowiak, M., & Echaust, K. (2014). *Instrumenty pochodne. Wprowadzenie do inżynierii finansowej*, Wyd. Uniwersytetu Ekonomicznego w Poznaniu, Poznań.
10. Bartkowiak, M., & Rutkowska, A. (2020). Vague expert information/recommendation in portfolio optimization-an empirical study. *Axioms*, 9(2), 38.
11. Bisoi, R., Dash, P. K., & Mishra, S. P. (2019). Model decomposition method in fusion with robust random vector functional link network for crude oil price forecasting. *Applied Soft Computing*, 80, 475-493.

12. Black, F. i Scholes, M. (2019). The pricing of options and corporate liabilities. In World Scientific Reference on Contingent Claims Analysis in Corporate Finance: Volume 1: Foundations of CCA and Equity Valuation (pp. 3-21).
13. Cao, J., Zhao, T., Wang, J., Wang, R., & Chen, Y. (2017). Excavation equipment classification based on improved MFCC features and ELM. *Neurocomputing*, 261, 231-241.
14. Carpenter, G. A., i Grossberg, S. (2010). Adaptive resonance theory.
15. Chen, A. S., & Leung, M. T. (2004). Regression neural network for error correction in foreign exchange forecasting and trading. *Computers & Operations Research*, 31(7), 1049-1068.
16. Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1251-1258).
17. Czekaj, J., Bolisęga, M., Czekaj, K., Czupryna, M., Kosidłowska, A., Kubińska, E., & Zyguła, A. (2017). *Rynki, instrumenty i instytucje finansowe*. Wydawnictwo Naukowe PWN.
18. Das, S. R., Mishra, D., & Rout, M. (2017). A Survey on Impact of Bio-inspired Computation on Stock Market Prediction. *Journal of Engineering Science & Technology Review*, 10(3).
19. Dash, R., Dash, P. K., & Bisoi, R. (2014). A self adaptive differential harmony search based optimized extreme learning machine for financial time series prediction. *Swarm and Evolutionary Computation*, 19, 25-42.
20. de Campos Souza, P. V. (2020). Fuzzy neural networks and neuro-fuzzy networks: A review the main techniques and applications used in the literature. *Applied soft computing*, 92, 106275.
21. Doman, M., & Doman, R. (2009). *Modelowanie zmienności i ryzyka: metody ekonometrii finansowej*. Oficyna a Wolters Kluwer business.
22. Dudek, G. (2016). Extreme learning machine as a function approximator: Initialization of input weights and biases. In Proceedings of the 9th International Conference on Computer Recognition Systems CORES 2015 (pp. 59-69). Springer, Cham.

23. Dymova, L., Kaczmarek, K., & Sevastjanov, P. (2021). A new approach to the bi-criteria multi-period fuzzy portfolio selection. *Knowledge-Based Systems*, 234, 107582.
24. Dziawgo, D., & Dziawgo, L. (2013). Ryzyko instrumentów pochodnych w obrocie gospodarczym na przykładzie " opcji toksycznych". *Zeszyty Naukowe Uniwersytetu Szczecińskiego. Ekonomiczne Problemy Usług*, (102 Uwarunkowania rynkowe rozwoju mikro, małych i średnich przedsiębiorstw-Mikrofirma 2013), 483-491.
25. Egmont-Petersen, M., de Ridder, D., & Handels, H. (2002). Image processing with neural networks—a review. *Pattern recognition*, 35(10), 2279-2301.
26. Enders, C. K. (2010). *Applied missing data analysis*. Guilford press.
27. Esenyel, N. M., & Akin, M. (2017). Comparing Accuracy Performance of ELM, ARMA and ARMA-GARCH Model In Predicting Exchange Rate Return. *Alphanumeric Journal*, 5(1), 1-14.
28. Galeshchuk, S. (2016). Neural networks performance in exchange rate prediction. *Neurocomputing*, 172, 446-452.
29. Gandhmal, D. P., & Kumar, K. (2019). Systematic analysis and review of stock market prediction techniques. *Computer Science Review*, 34, 100190.
30. Garcia, F., Guijarro, F., Oliver, J., & Tamošiūnienė, R. (2018). Hybrid fuzzy neural network to predict price direction in the German DAX-30 index. *Technological and Economic Development of Economy*, 24(6), 2161-2178.
31. Gong, X., Min, L., & Yu, C. (2022). Multi-period portfolio selection under the coherent fuzzy environment with dynamic risk-tolerance and expected-return levels. *Applied Soft Computing*, 114, 108104.
32. Habib, R., & Afzal, M. T. (2019). Sections-based bibliographic coupling for research paper recommendation. *Scientometrics*, 119(2), 643-656.
33. Hao, Y., & Gao, Q. (2020). Predicting the trend of stock market index using the hybrid neural network based on multiple time scale feature learning. *Applied Sciences*, 10(11), 3961.
34. Hayashi, Y., Buckley, J. J., & Czogala, E. (1993). Fuzzy neural network with fuzzy signals and weights. *International Journal of Intelligent Systems*, 8(4), 527-537.

35. He, K., Chen, Y., & Tso, G. K. (2018). Forecasting exchange rate using Variational Mode Decomposition and entropy theory. *Physica A: statistical mechanics and its applications*, 510, 15-25.
36. Hebb, D. O. (1949). The first stage of perception: growth of the assembly. *The Organization of Behavior*, 4, 60-78.
37. Hota, H. S., Handa, R. i Shrivastava, A. K. (2017). Time series data prediction using sliding window based RBF neural network. *International Journal of Computational Intelligence Research*, 13(5), 1145-1156.
38. Hsieh, W. W. i Tang, B. (1998). Applying neural network models to prediction and data analysis in meteorology and oceanography. *Bulletin of the American Meteorological Society*, 79(9), 1855-1870.
39. Huang, G. B., Li, M. B., Chen, L., & Siew, C. K. (2008). Incremental extreme learning machine with fully complex hidden nodes. *Neurocomputing*, 71(4-6), 576-583.
40. Huang, G. B., Zhu, Q. Y. i Siew, C. K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1-3), 489-501.
41. Huang, W., Oh, S. K., & Pedrycz, W. (2017). Hybrid fuzzy wavelet neural networks architecture based on polynomial neural networks and fuzzy set/relation inference-based wavelet neurons. *IEEE transactions on neural networks and learning systems*, 29(8), 3452-3462.
42. Hull, J. C. (2003). *Options futures and other derivatives*. Pearson Education India.
43. Hull, J., Dąbrowski, P., & Sobkowiak, J. (1997). *Kontrakty terminowe i opcje wprowadzenie*. Wig-Press.
44. Hüllermeier, E. (2011). Fuzzy sets in machine learning and data mining. *Applied Soft Computing*, 11(2), 1493-1505.
45. Hyndman RJ, Khandakar Y (2008). "Automatic time series forecasting: the forecast package for R." *Journal of Statistical Software*, 26(3), 1–22. doi: 10.18637/jss.
46. Ince, H., & Trafalis, T. B. (2006). A hybrid model for exchange rate prediction. *Decision Support Systems*, 42(2), 1054-1062.
47. Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
48. Jakubowski, J., Palczewski, A., Rutkowski, M., & Stettner, Ł. (2003). *Matematyka finansowa. Instrumenty pochodne*, WNT, Warszawa.

49. Jastrzębski, M., Kabziński, J., Wasiak, G., & Zawiślak, R. (2015). Ocena efektywności techniki Extreme Learning Machine (ELM) do modelowania dwuwymiarowych nieliniowości w układach napędowych. *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej. Studia i Materiały*, 71(35).
50. Jurek, W. (2001). *Konstrukcja i analiza portfela papierów wartościowych o zmiennym dochodzie*. Wydaw. AE.
51. Kahraman, C., Öztayşi, B., & Çevik Onar, S. (2016). A comprehensive literature review of 50 years of fuzzy set theory. *International Journal of Computational Intelligence Systems*, 9(sup1), 3-24.
52. Khare, K., Darekar, O., Gupta, P., and Attar, V. (2017). Short term stock price prediction using deep learning. In *2017 2nd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)*, pages 482–486. IEEE.
53. Kiiskinen, E. (2016). *Risks vs Return with Binary Option Trading*.
54. Knezevic, M., Cvetkovska, M., Hanák, T., Braganca, L., & Soltesz, A. (2018). Artificial neural networks and fuzzy neural networks for solving civil engineering problems. *Complexity*, 2018.
55. Kochan, K. (2006). *Forex w praktyce: vademecum inwestora walutowego*. Helion.
56. Kohonen, T. (1990). The self-organizing map. *Proceedings of the IEEE*, 78(9), 1464-1480.
57. Kolková, A., & Lenertová, L. (2016). *Binary Options As A Modern Fenomenon Of Financial Business*.
58. Kourentzes, N., Barrow, D. K., & Crone, S. F. (2014). Neural network ensemble operators for time series forecasting. *Expert Systems with Applications*, 41(9), 4235-4244.
59. Koutroumbas, K. i Kalouptsidis, N. (2005). Generalized Hamming networks and applications. *Neural Networks*, 18(7), 896-913.
60. Kumbure, M. M., Lohrmann, C., Luukka, P., & Porras, J. (2022). Machine learning techniques and data for stock market forecasting: a literature review. *Expert Systems with Applications*, 116659.
61. Kurzajewski, M. i Nowalińska, D. (2017). *Zysk a ryzyko na rynku Forex*. Komisja Nadzoru Finansowego.

62. Laengle, Sigifredo, et al. "Forty years of the European Journal of Operational Research: A bibliometric overview." *European Journal of Operational Research* 262.3 (2017): 803-816.
63. Lahmiri, S. (2016). A variational mode decomposition approach for analysis and forecasting of economic and financial time series. *Expert Systems with Applications*, 55, 268-273.
64. Lazzerini, B., Jain, L. C., & Dumitrescu, D. (2000). *Fuzzy Sets & their Application to Clustering & Training*. CRC Press.
65. Lee, C. H., & Teng, C. C. (2000). Identification and control of dynamic systems using recurrent fuzzy neural networks. *IEEE Transactions on fuzzy systems*, 8(4), 349-366.
66. Leijnen, S., & Veen, F. V. (2020). The neural network zoo. In *Multidisciplinary Digital Publishing Institute Proceedings* (Vol. 47, No. 1, p. 9).
67. Leijnen, S., & Veen, F. V. (2020). The neural network zoo. In *Multidisciplinary Digital Publishing Institute Proceedings* (Vol. 47, No. 1, p. 9).
68. Liu, Y., Sun, Y., Xue, B., Zhang, M., Yen, G. G., & Tan, K. C. (2021). A survey on evolutionary neural architecture search. *IEEE transactions on neural networks and learning systems*. oraz
69. Majewska, A. (2006). Wybrane strategie rozpiętościowe wykorzystujące opcje na akcje. *Prace Naukowe Akademii Ekonomicznej we Wrocławiu, (1133 Inwestycje finansowe i ubezpieczenia-tendencje światowe a polski rynek)*, 313-320.
70. Majhi, B., Rout, M., Majhi, R., Panda, G., & Fleming, P. J. (2012). New robust forecasting models for exchange rates prediction. *Expert Systems with Applications*, 39(16), 12658-12670.
71. Markova, M. (2019, October). Foreign exchange rate forecasting by artificial neural networks. In *AIP Conference Proceedings* (Vol. 2164, No. 1, p. 060010). AIP Publishing LLC.
72. Meng, F., Lu, Z., Wang, M., Li, H., Jiang, W., & Liu, Q. (2015). Encoding source language with convolutional neural network for machine translation. *arXiv preprint arXiv:1503.01838*.
73. Michańków, J., Sakowski, P., & Ślepaczuk, R. (2022). LSTM in Algorithmic Investment Strategies on BTC and S&P500 Index. *Sensors*, 22(3), 917.

74. Milewski, M. (2012). *Forex: rynek walutowy dla początkujących inwestorów*. Wydawnictwo Edgard.
75. Mitaim, S., & Kosko, B. (1996, September). What is the best shape for a fuzzy set in function approximation?. In *Proceedings of IEEE 5th International Fuzzy Systems (Vol. 2, pp. 1237-1243)*. IEEE.
76. Moghar, A., & Hamiche, M. (2020). Stock market prediction using LSTM recurrent neural network. *Procedia Computer Science*, 170, 1168-1173.
77. Mohd Adnan, M. R. H., Sarkheyli, A., Mohd Zain, A., & Haron, H. (2015). Fuzzy logic for modeling machining process: a review. *Artificial Intelligence Review*, 43(3), 345-379.
78. Morawski, W. (2002). *Zarys powszechnej historii pieniądza i bankowości*. Wydaw. Trio.
79. Morkowski, J. (2022). W druku. Przegląd stosowanych typów sieci neuronowych w prognozowaniu cen instrumentów finansowych. In *SLR w naukach ekonomicznych*.
80. Murmu, S., & Biswas, S. (2015). Application of fuzzy logic and neural network in crop classification: a review. *Aquatic Procedia*, 4, 1203-1210.
81. Naranjo, R., & Santos, M. (2019). A fuzzy decision system for money investment in stock markets based on fuzzy candlesticks pattern recognition. *Expert Systems with Applications*, 133, 34-48.
82. Nauck, D., Klawonn, F., & Kruse, R. (1997). *Foundations of neuro-fuzzy systems*. John Wiley & Sons, Inc..
83. Nayak, N. R., Dash, P. K., & Bisoi, R. (2019). A hybrid time frequency response and fuzzy decision tree for non-stationary signal analysis and pattern recognition. *International Journal of Automation and Computing*, 16(3), 398-412.
84. Nielsen, T. D., Hasselbalch, J., Holmberg, K., & Stripple, J. (2020). Politics and the plastic crisis: A review throughout the plastic life cycle. *Wiley Interdisciplinary Reviews: Energy and Environment*, 9(1), e360.
85. Obthong, M., Tantisantiwong, N., Jeamwatthanachai, W., & Wills, G. B. (2020, May). A Survey on Machine Learning for Stock Price Prediction: Algorithms and Techniques. In *FEMIB (pp. 63-71)*.
86. Osowski, S. (1996). *Sieci neuronowe w ujęciu algorytmicznym*. Wydawnictwa Naukowo-Techniczne.

87. Osowski, S. (2018). Głębokie sieci neuronowe i ich zastosowania w eksploracji danych. Przegląd Telekomunikacyjny+ Wiadomości Telekomunikacyjne.
88. Pahade, J. K., & Jha, M. (2021). Credibilistic variance and skewness of trapezoidal fuzzy variable and mean–variance–skewness model for portfolio selection. *Results in Applied Mathematics*, 11, 100159.
89. Panda, C., & Narasimhan, V. (2007). Forecasting exchange rate better with artificial neural network. *Journal of Policy Modeling*, 29(2), 227-236.
90. Parot, A., Michell, K., & Kristjanpoller, W. D. (2019). Using Artificial Neural Networks to forecast Exchange Rate, including VAR-VECM residual analysis and prediction linear combination. *Intelligent Systems in Accounting, Finance and Management*, 26(1), 3-15.
91. Pedrycz, W. (1991). Neurocomputations in relational systems. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 13(03), 289-297.
92. Pedrycz, W. (1994). Why triangular membership functions?. *Fuzzy sets and Systems*, 64(1), 21-30.
93. Pedrycz, W. (Ed.). (1996). *Fuzzy modelling: paradigms and practice* (No. 7). Springer Science & Business Media.
94. Pedrycz, W., & Gomide, F. (1998). *An introduction to fuzzy sets: analysis and design*. MIT press.
95. Pedrycz, W., & Gomide, F. (1998). *An introduction to fuzzy sets: analysis and design*. MIT press.
96. Piasecki, K., & Siwek, J. (2018). Multi-asset portfolio with trapezoidal fuzzy present values. *Stat. Rev*, 64, 183-199.
97. Piegat, A. (2013). *Fuzzy modeling and control* (Vol. 69). Physica.
98. Piegat, A., & Pluciński, M. (2015). Fuzzy number addition with the application of horizontal membership functions. *The Scientific World Journal*, 2015.
99. Qin, Y., & Duan, H. (2020). Single-Neuron adaptive hysteresis compensation of piezoelectric actuator based on hebb learning rules. *Micromachines*, 11(1), 84.
100. Qin, Y., & Duan, H. (2020). Single-Neuron adaptive hysteresis compensation of piezoelectric actuator based on hebb learning rules. *Micromachines*, 11(1), 84.

101. Robinson-Garcia, N., Mongeon, P., Jeng, W., & Costas, R. (2017). DataCite as a novel bibliometric source: Coverage, strengths and limitations. *Journal of Informetrics*, 11(3), 841-854.
102. Roncoroni, A., Fusai, G., and Cummins, M. (2015). *Handbook of multi-commodity markets and products: structuring, trading and risk management*. John Wiley & Sons.
103. Roondiwala, M., Patel, H., & Varma, S. (2017). Predicting stock prices using LSTM. *International Journal of Science and Research (IJSR)*, 6(4), 1754-1756.
104. Rout, A. K., Dash, P. K., Dash, R., & Bisoi, R. (2017). Forecasting financial time series using a low complexity recurrent neural network and evolutionary learning approach. *Journal of King Saud University-Computer and Information Sciences*, 29(4), 536-552.
105. Rout, A. K., Dash, P. K., Dash, R., & Bisoi, R. (2017). Forecasting financial time series using a low complexity recurrent neural network and evolutionary learning approach. *Journal of King Saud University-Computer and Information Sciences*, 29(4), 536-552.
106. Rusiecki, A. (2007, June). Robust LTS backpropagation learning algorithm. In *International Work-Conference on Artificial Neural Networks* (pp. 102-109). Springer, Berlin, Heidelberg.
107. Russo, M., & Jain, L. C. (2000). *Fuzzy learning and applications*. CRC press.
108. Rutkowska, A. (2016). Influence of membership function's shape on portfolio optimization results. *Journal of Artificial Intelligence and Soft Computing Research*, 6(1), 45-54.
109. Rutkowska, A., & Bartkowiak, M. (2019, August). Experton approach to vague information in portfolio selection problem with many views. In *EUSFLAT Conf.*
110. Sadollah, A. (2018). Introductory chapter: which membership function is appropriate in fuzzy system?. *IntechOpen*.
111. Sarangi, P. K., Chawla, M., Ghosh, P., Singh, S., & Singh, P. K. (2022). FOREX trend analysis using machine learning techniques: INR vs USD currency exchange rate using ANN-GA hybrid approach. *Materials Today: Proceedings*, 49, 3170-3176.
112. Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.

- 113.Schrimpf, A., & Sushko, V. (2019). Sizing up global foreign exchange markets. *BIS Quarterly Review*, December.
- 114.Schwarz, G. (1978). Estimating the dimension of a model. *The annals of statistics*, 461-464.
- 115.Selvin, S., Vinayakumar, R., Gopalakrishnan, E., Menon, V. K., and Soman, K. (2017). Stock price prediction using LSTM, RNN and CNN-sliding window model. In *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, pages 1643–1647. IEEE.
- 116.Sen, S. (2015). A survey of intrusion detection systems using evolutionary computation. In *Bio-inspired computation in telecommunications* (pp. 73-94). Morgan Kaufmann.
- 117.Siwiek, K., Baranowski, M., & Grzywacz, T. (2018). Prognozowanie zawartości PM2, 5 w powietrzu atmosferycznym przy użyciu sieci ELM. *Poznan University of Technology Academic Journals. Electrical Engineering*.
- 118.Smagulova, K., & James, A. P. (2019). A survey on LSTM memristive neural network architectures and applications. *The European Physical Journal Special Topics*, 228(10), 2313-2324.
- 119.Strader, T. J., Rozycki, J. J., Root, T. H., & Huang, Y. H. J. (2020). Machine learning stock market prediction studies: Review and research directions. *Journal of International Technology and Information Management*, 28(4), 63-83.
- 120.Sundaram, R. K., & Das, S. R. (2011). *Derivatives: principles and practice*. New York, NY: McGraw-Hill Irwin.
- 121.Suresh, A. S. (2015). Analysis of Option Combination Strategies. *Management Insight*, 11(1), 31-40.
- 122.Szymonik, J. (2013). Sztuczne sieci neuronowe o radialnych funkcjach bazowych do śledzenia obiektów w obrazach wideo. *Biuletyn Instytutu Systemów Informatycznych*, 33-39.
- 123.Tadeusiewicz, R. (1993). *Sieci neuronowe* (Vol. 110). Warszawa: Akademicka Oficyna Wydawnicza RM.
- 124.Tadeusiewicz, R., & Szaleniec, M. (2015). *Leksykon sieci neuronowych*. Projekt Nauka. Fundacja na rzecz promocji nauki polskiej.

125. Talpur, N., Salleh, M. N. M., & Hussain, K. (2017, August). An investigation of membership functions on performance of ANFIS for solving classification problems. In IOP Conference Series: Materials Science and Engineering (Vol. 226, No. 1, p. 012103). IOP Publishing.
126. Tarczyński, W. (2001). Podstawowe strategie inwestycyjne na rynku kapitałowym. *Prace Naukowe Akademii Ekonomicznej we Wrocławiu* (890, t. 1 Inwestycje finansowe i ubezpieczenia-tendencje światowe a polski rynek), 42-60.
127. Tarczyński, W. (2003). Instrumenty pochodne na rynku kapitałowym. *Polskie Wydaw. Ekonomiczne*.
128. Tsaur, R. C. (2013). Fuzzy portfolio model with different investor risk attitudes. *European Journal of Operational Research*, 227(2), 385-390.
129. Tsay, R. S. (2016). *Analysis of financial time series* (Vol. 543). John Wiley & Sons.
130. Valdez, S., & Molyneux, P. (2015). *An introduction to global financial markets*. Macmillan International Higher Education.
131. Van Houdt, G., Mosquera, C., & Nápoles, G. (2020). A review on the long short-term memory model. *Artificial Intelligence Review*, 53(8), 5929-5955.
132. Vlasenko, A., Vlasenko, N., Vynokurova, O., & Peleshko, D. (2018). A novel neuro-fuzzy model for multivariate time-series prediction. *Data*, 3(4), 62.
133. Walczak, S. (2001). An empirical analysis of data requirements for financial forecasting with neural networks. *Journal of management information systems*, 17(4), 203-222.
134. Waltman, L. (2016). A review of the literature on citation impact indicators. *Journal of informetrics*, 10(2), 365-391.
135. Welch, B. L. (1947). The generalization of 'STUDENT'S' problem when several different population variances are involved. *Biometrika*, 34(1-2), 28-35.
136. Widrow, B. (1960, July). Adaptive sampled-data systems. In *Proceedings of the First International Congress of the International Federation of Automatic Control* (pp. 406-411).
137. Witkowska, D. (2002). *Sztuczne sieci neuronowe i metody statystyczne: wybrane zagadnienia finansowe*. CH Beck.

138. Wu, D. (2012, June). Twelve considerations in choosing between Gaussian and trapezoidal membership functions in interval type-2 fuzzy logic controllers. In 2012 IEEE International Conference on Fuzzy Systems (pp. 1-8). IEEE.
139. Wu, Q., Liu, X., Qin, J., & Zhou, L. (2021). Multi-criteria group decision-making for portfolio allocation with consensus reaching process under interval type-2 fuzzy environment. *Information Sciences*, 570, 668-688.
140. Xu, L., Ren, J. S., Liu, C., & Jia, J. (2014). Deep convolutional neural network for image deconvolution. *Advances in neural information processing systems*, 27.
141. Yang, H. L., & Lin, H. C. (2017). Applying the hybrid model of EMD, PSR, and ELM to exchange rates forecasting. *Computational Economics*, 49(1), 99-116.
142. Yao, J., & Tan, C. L. (2000). A case study on using neural networks to perform technical forecasting of forex. *Neurocomputing*, 34(1-4), 79-98.
143. Yildirim, H., & Özkale, M. R. (2019). The performance of ELM based ridge regression via the regularization parameters. *Expert Systems with Applications*, 134, 225-233.
144. Zadeh, L. A. (1965). Information and control. *Fuzzy sets*, 8(3), 338-353.
145. Zahedi, G., Saba, S., Elkamel, A., & Bahadori, A. (2014). Ozone pollution prediction around industrial areas using fuzzy neural network approach. *CLEAN—Soil, Air, Water*, 42(7), 871-879.
146. Zalewski, G. (2010). *Kontrakty terminowe i forex: teoria i praktyka*. Linia sc.
147. Zhang, G. P., & Berardi, V. L. (2001). Time series forecasting with neural network ensembles: an application for exchange rate prediction. *Journal of the operational research society*, 52(6), 652-664.
148. Zhang, G., & Hu, M. Y. (1998). Neural network forecasting of the British pound/US dollar exchange rate. *Omega*, 26(4), 495-506.
149. Zhang, Y. Q., & Wan, X. (2007). Statistical fuzzy interval neural networks for currency exchange rate time series prediction. *Applied Soft Computing*, 7(4), 1149-1156.
150. Zhang, Y., Liu, W., & Yang, X. (2022). An automatic trading system for fuzzy portfolio optimization problem with sell orders. *Expert Systems with Applications*, 187, 115822.
151. Zhao, J., & Bose, B. K. (2002, November). Evaluation of membership functions for fuzzy logic controlled induction motor drive. In *IEEE 2002 28th Annual Conference of the Industrial Electronics Society. IECON 02 (Vol. 1, pp. 229-234)*. IEEE.

152. Zhou, Z. H., Wu, J., & Tang, W. (2002). Ensembling neural networks: many could be better than all. *Artificial intelligence*, 137(1-2), 239-263.
153. Ziętek-Kwaśniewska, K. (2009). Charakterystyka wybranych strategii opcyjnych. *Roczniki Ekonomii i Zarządzania*, (37), 113-128.

Wykaz rysunków

RYSUNEK 1. PROCENTOWY UDZIAŁ DANEJ WALUTY W TRANSAKCJACH NA RYNKU FOREX STAN NA MAJ 2022.....	11
RYSUNEK 2. POPULARNOŚĆ KONTRAKTÓW TERMINOWYCH WEDŁUG ZASTOSOWANYCH INSTRUMENTÓW NA RYNKU GLOBALNYM, WEDŁUG WARTOŚCI ZAWIERANYCH KONTRAKTÓW PODANYCH W MILIARDACH DOLARÓW AMERYKAŃSKICH	16
RYSUNEK 3. POPULARNOŚĆ KONTRAKTÓW DEWIZOWYCH WEDŁUG WALUTY NA RYNKU GLOBALNYM, WEDŁUG WARTOŚCI ZAWIERANYCH KONTRAKTÓW W MILIARDACH DOLARÓW AMERYKAŃSKICH	16
RYSUNEK 4. PROFIL WYPŁATY Z POZYCJI DŁUGIEJ NA KONTRAKCIE TERMINOWYM	19
RYSUNEK 5. PROFIL WYPŁATY Z POZYCJI KRÓTKIEJ NA KONTRAKCIE TERMINOWYM.....	20
RYSUNEK 6. PROFIL WYPŁATY Z POZYCJI DŁUGIEJ NA OPCJI KUPNA.....	22
RYSUNEK 7. PROFIL WYPŁATY Z POZYCJI KRÓTKIEJ NA OPCJI KUPNA	23
RYSUNEK 8. PROFIL WYPŁATY Z POZYCJI DŁUGIEJ NA OPCJI SPRZEDAŻY	24
RYSUNEK 9. PROFIL WYPŁATY Z POZYCJI KRÓTKIEJ NA OPCJI SPRZEDAŻY	25
RYSUNEK 10. PROFIL WYPŁATY DLA OPCJI BINARNEJ O WYPŁACIE, GDY CENA INSTRUMENTU BAZOWEGO UTRZYMA SIĘ W PRZEDZIALE MIĘDZY 1 A 1,1.	27
RYSUNEK 11. OPCJA OSŁONIĘTA TYP I.....	28
RYSUNEK 12. OPCJA OSŁONIĘTA TYP II.....	29
RYSUNEK 13. OPCJA OSŁONIĘTA TYP III.....	30
RYSUNEK 14. OPCJA OSŁONIĘTA TYP IV	31
RYSUNEK 15. STRATEGIA BYKA.....	33
RYSUNEK 16. STRATEGIA NIEDŹWIEDZIA	34
RYSUNEK 17. STRATEGIA MOTYLA	35
RYSUNEK 18. STRATEGIA KRÓTKIEGO STELAŻA	36
RYSUNEK 19. STRATEGIA KRÓTKIEGO ROZSZERZONEGO STELAŻA	37
RYSUNEK 20. STRATEGIA DŁUGIEGO STELAŻA	38
RYSUNEK 21. STRATEGIA DŁUGIEGO ROZSZERZONEGO STELAŻA.....	38
RYSUNEK 22. KLASYFIKACJA SIECI NEURONOWYCH	51
RYSUNEK 23. PERCEPTRON JEDNOWARSTWOWY	52
RYSUNEK 24. SIEĆ NEURONOWA JEDNOKIERUNKOWA DWUWARSTWOWA	53
RYSUNEK 25. SIEĆ HOPFIELDA	54
RYSUNEK 26. DIAGRAM OBRAZUJĄCY DZIAŁANIE LSTM	59
RYSUNEK 27. DZIAŁANIE LSTM	61
RYSUNEK 28. ROCZNY TREND CYTOWAŃ ORAZ ILOŚCI OPUBLIKOWANYCH ARTYKUŁÓW NA TEMAT WYKORZYSTANIA SIECI NEURONOWYCH DO PROGNOZOWANIA CEN WALUT.....	63
RYSUNEK 29. WIZUALIZACJA PRZYKŁADOWEGO ZBIORU ROZMYTEGO	65
RYSUNEK 30. TRÓJKĄTNA FUNKCJA PRZYNALEŻNOŚCI – PRZYKŁAD GRAFICZNY.....	67
RYSUNEK 31. TRAPEZOIDALNA FUNKCJA PRZYNALEŻNOŚCI – PRZYKŁAD GRAFICZNY	68
RYSUNEK 32. GAUSOWSKA FUNKCJA PRZYNALEŻNOŚCI – PRZYKŁAD GRAFICZNY.....	69
RYSUNEK 33. PRZYKŁAD DZIAŁANIA LOGIKI ROZMYTEJ	71
RYSUNEK 34. SCHEMAT DZIAŁANIA PODEJMOWANIA DECYZJI Z WYKORZYSTANIEM LOGIKI ROZMYTEJ	76
RYSUNEK 35. OPIS BADAŃ WRAZ Z PYTANIAMI BADAWCZYMI.....	80
RYSUNEK 36. SCHEMAT BADAŃA	81
RYSUNEK 37. KSZTAŁTOWANIE SIĘ KURSÓW WALUTOWYCH W LATACH 2014-2019.....	85
RYSUNEK 38. LOGARYTMICZNE STOPY ZWROTU DLA CHF/EUR W LATACH 2014-2019	86
RYSUNEK 39. LOGARYTMICZNE STOPY ZWROTU DLA GBP/EUR W LATACH 2014-2019	86
RYSUNEK 40. LOGARYTMICZNE STOPY ZWROTU DLA USD/EUR W LATACH 2014-2019	87
RYSUNEK 41. WYNIKI TRAFNOŚCI DLA SIECI MLP I PARY WALUTOWEJ USD/EUR – WYKRES RADAROWY	99
RYSUNEK 42. WYNIKI TRAFNOŚCI DLA SIECI MLP I PARY WALUTOWEJ CHF/EUR – WYKRES RADAROWY	100
RYSUNEK 43. WYNIKI TRAFNOŚCI DLA SIECI LSTM I PARY WALUTOWEJ CHF/EUR – WYKRES RADAROWY.....	105
RYSUNEK 44. STRATEGIA KRÓTKIEGO STELAŻA	148

Wykaz tabel

TABELA 1. RÓŻNICE MIĘDZY KONTRAKTAMI FORWARD I FUTURES	18
TABELA 2. CZYNNIKI KSZTAŁTUJĄCE WARTOŚĆ OPCJI	40
TABELA 3. OPIS STOSOWANYCH METOD W BADANIU EMPIRYCZNYM	80
TABELA 4. CHARAKTERYSTYKA DANYCH PAR WALUTOWYCH.....	84
TABELA 5. WYNIKI TRAFNOŚCI PROGNOZ DLA SIECI ELM I PARY WALUTOWEJ GBP/EUR NA POZIOMACH CEN	88
TABELA 6. WYNIKI TRAFNOŚCI PROGNOZ DLA SIECI ELM I PARY WALUTOWEJ CHF/EUR NA POZIOMACH CEN.....	90
TABELA 7. WYNIKI TRAFNOŚCI PROGNOZ DLA SIECI ELM I PARY WALUTOWEJ USD/EUR NA POZIOMACH CEN	91
TABELA 8. WYNIKI TRAFNOŚCI PROGNOZ DLA SIECI MLP I PARY WALUTOWEJ GBP/EUR NA POZIOMACH CEN	93
TABELA 9. WYNIKI TRAFNOŚCI PROGNOZ DLA SIECI MLP I PARY WALUTOWEJ CHF/EUR NA POZIOMACH CEN.....	94
TABELA 10. WYNIKI TRAFNOŚCI PROGNOZ DLA SIECI MLP I PARY WALUTOWEJ USD/EUR NA POZIOMACH CEN	96
TABELA 11. WYNIKI TRAFNOŚCI PROGNOZ DLA SIECI LSTM I PARY WALUTOWEJ GBP/EUR NA POZIOMACH CEN.....	101
TABELA 12. WYNIKI TRAFNOŚCI PROGNOZ DLA SIECI LSTM I PARY WALUTOWEJ CHF/EUR NA POZIOMACH CEN	102
TABELA 13. WYNIKI TRAFNOŚCI PROGNOZ DLA SIECI LSTM I PARY WALUTOWEJ USD/EUR NA POZIOMACH CEN	103
TABELA 14. TRAFNOŚĆ PROGNOZOWANIA UZYSKANA Z ZASTOSOWANIEM METODY NAIWNEJ DLA CHF/EUR, GBP/EUR ORAZ USD/EUR W LATACH 2014-2019	106
TABELA 15. TRAFNOŚĆ PROGNOZOWANIA UZYSKANA Z ZASTOSOWANIEM MODELU ARMA DLA CHF/EUR, GBP/EUR ORAZ USD/EUR W LATACH 2014-2019	106
TABELA 16. PORÓWNANIE WYNIKÓW SIECI NEURONOWYCH I PROGNOZY NAIWNEJ.....	108
TABELA 17. PORÓWNANIE WYNIKÓW SIECI NEURONOWYCH I PROGNOZY NAIWNEJ – RÓŻNICE PROCENTOWE MIĘDZY TRAFNOŚCIAMI PROGNOZOWANIA	109
TABELA 18. PORÓWNANIE WYNIKÓW SIECI NEURONOWYCH I PROGNOZY NAIWNEJ.....	110
TABELA 19. PORÓWNANIE WYNIKÓW SIECI NEURONOWYCH I MODELU ARMA – RÓŻNICE PROCENTOWE MIĘDZY TRAFNOŚCIAMI PROGNOZOWANIA	110
TABELA 20. PROCENTOWY UDZIAŁ USTAWIEŃ SIECI, DLA KTÓRYCH LEPSZE WYNIKI GENEROWANE BYŁY DLA UCZENIA NA POZIOMACH CEN	112
TABELA 21. PORÓWNANIE WYNIKÓW UCZENIA SIECI NEURONOWEJ NA POZIOMACH CEN I LOGARYTMICZNYCH STOPACH ZWROTU..	112
TABELA 22. PROCENTOWA RÓŻNICA TRAFNOŚCI SIECI NEURONOWEJ NA POZIOMACH CEN I LOGARYTMICZNYCH STOPACH ZWROTU	112
TABELA 23. ODPOWIEDZI NA PYTANIA BADAWCZE Z I ETAPU ROZPRAWY DOKTORSKIEJ - PROGNOZOWANIE Z WYKORZYSTANIEM SIECI NEURONOWYCH.....	113
TABELA 24. PORÓWNANIE METODY REKURENCYJNE Z AKTUALIZACJĄ PARAMETRÓW SIECI (WARIANT 1) Z ŚREDNIĄ TRAFNOŚCIĄ DLA WSZYSTKICH SIECI	116
TABELA 25. PORÓWNANIE METODY REKURENCYJNEJ DO ŚREDNIEJ WSZYSTKICH SIECI (WARIANT 1) – PROCENTOWE RÓŻNICE MIĘDZY TRAFNOŚCIAMI PROGNOZOWANIA	117
TABELA 26. PORÓWNANIE METODY REKURENCYJNEJ DO ŚREDNIEJ ELM (WARIANT 1).....	119
TABELA 27. PORÓWNANIE METODY REKURENCYJNEJ DO ŚREDNIEJ ELM (WARIANT 1) - PROCENTOWE RÓŻNICE MIĘDZY TRAFNOŚCIAMI PROGNOZOWANIA	119
TABELA 28. PORÓWNANIE METODY REKURENCYJNEJ DO ŚREDNIEJ MLP (WARIANT 1).....	121
TABELA 29. PORÓWNANIE METODY REKURENCYJNEJ DO ŚREDNIEJ MLP (WARIANT 1) - PROCENTOWE RÓŻNICE MIĘDZY TRAFNOŚCIAMI PROGNOZOWANIA	121
TABELA 30. PORÓWNANIE METODY REKURENCYJNEJ DO ŚREDNIEJ LSTM (WARIANT 1).....	123
TABELA 31. PORÓWNANIE METODY REKURENCYJNEJ DO ŚREDNIEJ LSTM (WARIANT 1) - PROCENTOWE RÓŻNICE MIĘDZY TRAFNOŚCIAMI PROGNOZOWANIA	124
TABELA 32. ZBIORCZE WYNIKI TESTÓW NA ISTOTNOŚĆ RÓŻNICY TRAFNOŚCI PROGNOZ METODĄ REKURENCYJNĄ ORAZ SIECIAMI NEURONOWYMI	125
TABELA 33. PROCENTOWY UDZIAŁ TRAFNYCH PROGNOZ W METODZIE REKURENCYJNEJ - DLA SIECI O USTAWIENIACH, KTÓRE UZYSKAŁY NAJLEPSZE WYNIKI W PIERWSZYM OKRESIE TESTOWYM T	125
TABELA 34. PORÓWNANIE METODY REKURENCYJNEJ TYPU I ORAZ TYPU II ORAZ PROCENTOWE RÓŻNICE MIĘDZY NIMI	126
TABELA 35. ODPOWIEDZI NA PYTANIA BADAWCZE Z I ETAPU ROZPRAWY DOKTORSKIEJ - PROGNOZOWANIE Z WYKORZYSTANIEM METODY REKURENCYJNEJ	127
TABELA 36. WYNIKI DLA CHF/EUR PROGNOZOWANYCH SIECIĄ ELM UCZĄCEJ SIĘ NA POZIOMACH CEN – DLA TRÓJKĄTNE ORAZ TRAPEZOIDALNEJ FUNKCJI PRZYNALEŻNOŚCI	129
TABELA 37. ZBIORCZE ZESTAWIENIE NAJTRAFNIEJSZEGO SPOSOBU DOBORU JĄDRA ZBIORU ORAZ DOBORU FUNKCJI PRZYNALEŻNOŚCI ZE WZGLĘDU NA PARĘ WALUTOWĄ, TYP SIECI NEURONOWEJ ORAZ HORYZONT PROGNOZY.....	130
TABELA 38. PORÓWNANIE TRAFNOŚCI METODY NAIWNEJ I ARMA DO METODY NEURONOWO-ROZMYTEJ.....	131
TABELA 39. PROCENTOWY UDZIAŁ TRAFNIE ZAPROGNOZOWANYCH KIERUNKÓW ZMIAN KURSU – METODA WIĘKSZOŚCI SIECI	132

TABELA 40. PORÓWNANIE PROCENTOWEGO UDZIAŁ TRAFNIE ZAPROGNOZOWANYCH KIERUNKÓW ZMIAN KURSU – METODA WIĘKSZOŚCI SIECI I ŚREDNIA DLA SIECI	133
TABELA 41. ZBIORCZE PORÓWNANIE METODY NEURONOWO-ROZMYTEJ Z METODĄ WIĘKSZOŚCI ORAZ ŚREDNIĄ TRAFNOŚCIĄ DLA DANEGO TYPU SIECI.....	134
TABELA 42. ZESTAWIENIE METODY NEURONOWO-ROZMYTEJ Z METODĄ REKURENCYJNEJ TYPU I ZE WSKAZANIEM METODY UZYSKUJĄCEJ WYŻSZĄ TRAFNOŚĆ PROGNOZ	136
TABELA 43. ZESTAWIENIE METODY NEURONOWO-ROZMYTEJ Z METODĄ ELIMINACJA TYPU II ZE WSKAZANIEM METODY UZYSKUJĄCEJ WYŻSZĄ TRAFNOŚĆ PROGNOZ	136
TABELA 44. TRAFNOŚĆ PROGNOZ MEOTODĄ NEURONOWO-ROZMYTĄ W POŁĄCZENIU Z METODĄ REKURENCYJNĄ	138
TABELA 45. PORÓWNANIE TRAFNOŚCI PROGNOZ POŁĄCZONĄ METODĄ REKURENCYJNĄ I NEURONOWO-ROZMYTĄ DLA TRÓJKĄTNEJ FUNKCJI PRZYNALEŻNOŚCI I JĄDRZE ZBIORU RÓWNYM ŚREDNIEJ ARYTMETYCZNEJ Z INNYMI METODAMI	139
TABELA 46. PORÓWNANIE TRAFNOŚCI PROGNOZ POŁĄCZONĄ METODĄ REKURENCYJNĄ I NEURONOWO-ROZMYTĄ DLA TRÓJKĄTNEJ FUNKCJI PRZYNALEŻNOŚCI I JĄDRZE ZBIORU RÓWNYM MEDIANIE Z INNYMI METODAMI.....	140
TABELA 47. PORÓWNANIE TRAFNOŚCI PROGNOZ POĄCZONĄ METODĄ REKURENCYJNĄ I NEURONOWO-ROZMYTĄ DLA TRAPEZOIDALNEJ FUNKCJI PRZYNALEŻNOŚCI I JĄDRZE ZBIORU BUDOWANYM NA ŚREDNIEJ ARYTMETYCZNEJ Z INNYMI METODAMI	141
TABELA 48. PORÓWNANIE TRAFNOŚCI PROGNOZ POŁĄCZONĄ METODĄ REKURENCYJNĄ I NEURONOWO-ROZMYTĄ DLA TRAPEZOIDALNEJ FUNKCJI PRZYNALEŻNOŚCI I JĄDRZE ZBIORU BUDOWANYM NA MEDIANIE Z INNYMI METODAMI	142
TABELA 49. ODPOWIEDZI NA PYTANIA BADAWCZE Z I ETAPU ROZPRAWY DOKTORSKIEJ - PROGNOZOWANIE Z WYKORZYSTANIEM METODY NEURONOWO-ROZMYTEJ	143
TABELA 50. OPIS INWESTYCJI I SPOSÓB ICH ROZLICZENIA	146
TABELA 51. STATYSTYKI STÓP ZWROTU DLA PARY WALUTOWEJ CHF/EUR PRZY INWESTYCJI W KONTRAKTY Z WYKORZYSTANIEM PROGNOZ SIECI NEURONOWYCH	149
TABELA 52. STATYSTYKI STÓP ZWROTU DLA PARY WALUTOWEJ GBP/EUR PRZY INWESTYCJI W KONTRAKTY Z WYKORZYSTANIEM PROGNOZ SIECI NEURONOWYCH	150
TABELA 53. STATYSTYKI STÓP ZWROTU DLA PARY WALUTOWEJ USD/EUR PRZY INWESTYCJI W KONTRAKTY Z WYKORZYSTANIEM PROGNOZ SIECI NEURONOWYCH	151
TABELA 54. STATYSTYKI STÓP ZWROTU DLA PARY WALUTOWEJ CHF/EUR PRZY INWESTYCJI W OPCJE Z WYKORZYSTANIEM PROGNOZ SIECI NEURONOWYCH.....	153
TABELA 55. STATYSTYKI STÓP ZWROTU DLA PARY WALUTOWEJ GBP/EUR PRZY INWESTYCJI W OPCJE Z WYKORZYSTANIEM PROGNOZ SIECI NEURONOWYCH.....	154
TABELA 56. STATYSTYKI STÓP ZWROTU DLA PARY WALUTOWEJ USD/EUR PRZY INWESTYCJI W OPCJE Z WYKORZYSTANIEM PROGNOZ SIECI NEURONOWYCH.....	155
TABELA 57. ZESTAWIENIE TRAFNOŚCI PROGNOZ ORAZ ZYSKÓW DLA KONTRAKTÓW I OPCJI DLA SIECI LSTM O OKREŚLONYCH PARAMETRACH	156
TABELA 58. STATYSTYKI STÓP ZWROTU DLA PARY WALUTOWEJ CHF/EUR PRZY INWESTYCJI W OPCJE Z UWZGLĘDNIENIEM STRATEGII STELAŻA Z WYKORZYSTANIEM PROGNOZ SIECI NEURONOWYCH.....	158
TABELA 59. STOPY ZWROTU DLA PARY WALUTOWEJ GBP/EUR PRZY INWESTYCJI W OPCJE Z UWZGLĘDNIENIEM STRATEGII STELAŻA Z WYKORZYSTANIEM PROGNOZ SIECI NEURONOWYCH.....	159
TABELA 60. STOPY ZWROTU DLA PARY WALUTOWEJ USD/EUR PRZY INWESTYCJI W OPCJE Z UWZGLĘDNIENIEM STRATEGII STELAŻA Z WYKORZYSTANIEM PROGNOZ SIECI NEURONOWYCH.....	160
TABELA 61. PORÓWNANIE STOPY ZWROTU DLA INWESTYCJI W OPCJE ORAZ W OPCJĘ I STRATEGIE STELAŻA PRZY PROGNOZOWANIU SIECIAMI NEURONOWYMI.....	161
TABELA 62. STOPY ZWROTU DLA CHF/EUR, GBP/EUR ORAZ USD/EUR PRZY INWESTYCJI W KONTRAKTY Z WYKORZYSTANIEM PROGNOZ METODY REKURENCYJNEJ	162
TABELA 63. PORÓWNANIE MAKSYMALNEJ STOPY ZWROTU INWESTUJĄC W KONTRAKTY Z WYKORZYSTANIEM METODY REKURENCYJNEJ Z MAKSYMALNĄ STOPĄ ZWROTU DLA SIECI NEURONOWYCH.....	163
TABELA 64. STOPY ZWROTU DLA CHF/EUR, GBP/EUR ORAZ USD/EUR PRZY INWESTYCJI W OPCJE Z WYKORZYSTANIEM PROGNOZ METODY REKURENCYJNEJ	164
TABELA 65. PORÓWNANIE MAKSYMALNYCH STÓP ZWROTU Z INWESTYCJI W OPCJE Z WYKORZYSTANIEM METODY REKURENCYJNEJ ORAZ SIECI NEURONOWYCH.....	166
TABELA 66. STOPY ZWROTU DLA CHF/EUR, GBP/EUR ORAZ USD/EUR PRZY INWESTYCJI W OPCJE Z UWZGLĘDNIENIEM STRATEGII STELAŻA I Z WYKORZYSTANIEM PROGNOZ METODY REKURENCYJNEJ	167
TABELA 67. STOPY ZWROTU DLA CHF/EUR, GBP/EUR ORAZ USD/EUR PRZY INWESTYCJI W KONTRAKTY Z WYKORZYSTANIEM PROGNOZ METODY NEURONOWO-ROZMYTEJ	169
TABELA 68. STOPY ZWROTU DLA CHF/EUR, GBP/EUR ORAZ USD/EUR PRZY INWESTYCJI W OPCJE Z WYKORZYSTANIEM PROGNOZ METODY NEURONOWO-ROZMYTEJ	170

TABELA 69. STOPY ZWROTU DLA CHF/EUR, GBP/EUR ORAZ USD/EUR PRZY INWESTYCJI W OPCJE I STRATEGIE STELAŻA Z WYKORZYSTANIEM PROGNOZ METODY NEURONOWO-ROZMYTEJ	171
TABELA 70. PORÓWNANIE METODY REKURENCYJNEJ Z METODĄ NEURONOWO-ROZMYTĄ DLA INWESTYCJI W OPCJE	173
TABELA 71. PORÓWNANIE METODY REKURENCYJNEJ Z METODĄ NEURONOWO-ROZMYTĄ DLA INWESTOWANIA W OPCJE I STRATEGIE STELAŻA	174
TABELA 72. WARTOŚCI STATYSTYKI Z PRÓBY DLA TESTU NA RÓWNOŚĆ WARIANCJI	176
TABELA 73. WARTOŚCI STATYSTYKI Z PRÓBY DLA TESTU NA RÓWNOŚĆ ŚREDNIEGO ZYSKU	176
TABELA 74. ODPOWIEDZI NA PYTANIA BADAWCZE Z II ETAPY ROZPRAWY DOKTORSKIEJ, DOTYCZĄCE MOŻLIWOŚCI GENEROWANIA ZYSKÓW Z WYKORZYSTANIEM INSTRUMENTÓW POCHODNYCH.	177
TABELA 75. ODPOWIEDZI NA PYTANIA BADAWCZE	180