

Paweł Rośczał

Uniwersytet Łódzki

**WYKORZYSTANIE ALGORYTMU GENETYCZNEGO
W GENEROWANIU DECYZJI INWESTYCYJNYCH
NA RYNKU WALUT**

Streszczenie: W artykule zaprezentowano implementację i przykład praktyczny generatora decyzji inwestycyjnych na rynku walut. Generator wykorzystuje sieć neuronową oraz algorytm genetyczny jako mechanizm wyznaczania wartości wag sieci. Połączenie obydwu metod pozwala na użycie bardziej dopasowanej do problemu funkcji kryterialnej w postaci miary zysku z inwestycji.

Słowa kluczowe: algorytmy genetyczne, rynek walutowy, prognozowanie kursu walut

1. Wstęp

Celem badania jest zbudowanie i przetestowanie w praktyce systemu transakcyjnego, czyli generatora decyzji inwestycyjnych na rynku walut. W analizie rynku walut wyróżnia się dwa podejścia. Pierwsze to analiza fundamentalna, która interpretuje kształtowanie się kursu waluty na podstawie sytuacji ekonomicznej kraju. Drugie to analiza techniczna, czyli przewidywanie możliwych scenariuszy kształtowania się kursu na podstawie informacji zawartych w dawniejszych cenach waluty.

Problem przewidywania przyszłych cen waluty na podstawie kształtowania się kursu tej samej waluty w przeszłości można rozwiązać za pomocą modelu prognostycznego, np. modelu autoregresyjnego. Model prognostyczny nie jest jednak dopasowany do specyfiki problemu, jakim jest skuteczne inwestowanie na rynku walut. Kryterium wyznaczania parametrów modelu prognostycznego jest miarą odchylenia wartości empirycznych od wartości teoretycznych (np. błąd średniokwadratowy). Tymczasem ostatecznym kryterium oceny decyzji inwestycyjnych jest zrealizowany zysk lub strata. Każdy model prognostyczny opisujący zagadnienia ekonomiczne generuje prognozy z pewną możliwą do oszacowania dokładnością. Dla inwestora, który potrzebuje wskazówki dotyczącej momentu zamknięcia pozycji, błąd prognozy polegający na wygenerowaniu zbyt wysokiej wartości kursu może mieć zupełnie inną wagę niż błąd polegający na wyznaczeniu zbyt niskiej

wartości kursu. Odchylenie prognozy w jedną stronę może prowadzić do nieznacznie mniejszego zysku, podczas gdy odchylenie prognozy w drugą może oznaczać całkowitą utratę szansy na korzystne zamknięcie pozycji.

Zamiast modelu prognostycznego, którego parametry są szacowane na podstawie miary błędu, inwestor bardziej potrzebuje generatora decyzji inwestycyjnych, którego parametry są wyznaczane na podstawie miary zysku. Zamiast prognozy możliwie najlepiej dopasowanej do danych empirycznych, inwestor bardziej potrzebuje decyzji inwestycyjnej, która będzie generowana pod kątem osiągnięcia możliwie największego zysku.

2. Metoda inwestowania

Eksperyment koncentruje się na kontraktach różnic kursowych dla pary walut EUR/USD. Inwestowanie oparte na wygenerowanych sygnałach przebiega w systemie *day-trading*, co oznacza że inwestycja jest otwierana i zamykana w ciągu 24 godzin obejmujących jeden dzień.

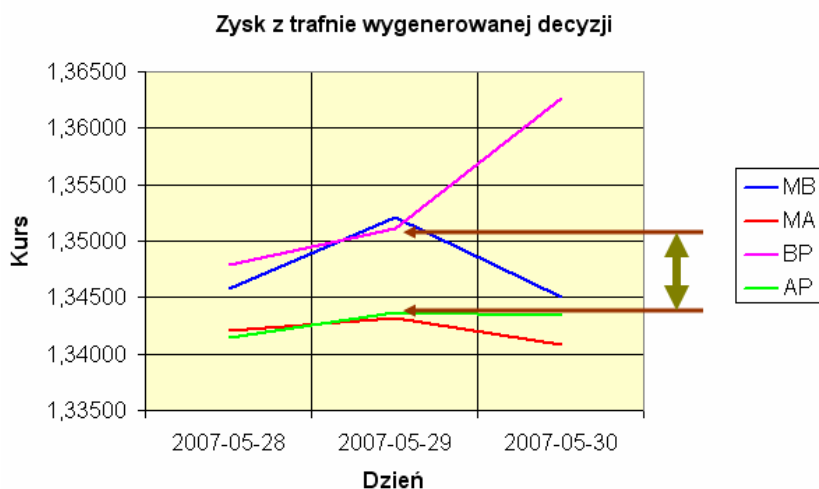
Dla każdego dnia system generuje dwie wartości:

- Sygnał sprzedaży (BP), czyli kurs, po którego osiągnięciu dochodzi do automatycznej sprzedaży pary walut.
- Sygnał kupna (AP), czyli kurs, po którego osiągnięciu dochodzi do automatycznego zakupu pary walut.

W momencie, gdy aktualny kurs zbliża się do maksymalnej dziennej ceny sprzedaży, czyli osiąga poziom sygnału sprzedaży BP, inwestor sprzedaje parę walut, licząc na spadek jej kursu. Jeśli następnie kurs spadnie zgodnie z oczekiwaniami do poziomu ceny minimalnej, czyli osiąga sygnał kupna AP, inwestor zamyka pozycję, czyli odkupuje wcześniej sprzedaną parę walut. Różnica pomiędzy poziomem sprzedaży, czyli najlepiej maksymalną ceną sprzedaży, a poziomem kupna, czyli najlepiej minimalną ceną zakupu, określa zrealizowany zysk z inwestycji. Jeśli bieżący kurs nie spadnie w ciągu dnia do założonego poziomu AP, inwestor odkupuje wcześniej sprzedaną parę walut po cenie zamknięcia z końca dnia. Różnica pomiędzy ceną sprzedaży BP a ceną zakupu na koniec dnia określa zrealizowany zysk lub stratę z inwestycji.

Jeżeli w ciągu dnia kurs najpierw przekroczy od góry sygnał kupna AP, dochodzi do sytuacji przeciwnej w stosunku do opisanej wyżej. W momencie, gdy aktualny kurs zbliża się do minimalnej dziennej ceny kupna, czyli osiąga poziom sygnału kupna AP, inwestor kupuje parę walut, licząc na wzrost jej kursu. Jeśli następnie kurs wzrośnie zgodnie z oczekiwaniami do poziomu ceny maksymalnej, czyli osiąga sygnał sprzedaży MB, inwestor zamyka pozycję, czyli odsprzedaje wcześniej zakupioną parę walut. Podobnie różnica pomiędzy poziomem sprzedaży, czyli najlepiej maksymalną ceną sprzedaży, a poziomem kupna, czyli najlepiej minimalną ceną zakupu, określa zrealizowany zysk z inwestycji. W przypadku, gdy

biejący kurs nie wzrośnie w ciągu dnia do założonego poziomu BP, inwestor odsprzedaje wcześniej zakupioną parę walut po cenie zamknięcia z końca dnia. Analogicznie różnica pomiędzy ceną sprzedaży na koniec dnia a ceną kupna AP określa zrealizowany zysk lub stratę z inwestycji. Przykład trafnie wygenerowanej decyzji przedstawiono na rys. 1.



Rys. 1. Przykład trafnie wygenerowanego zestawu sygnałów inwestycyjnych

Źródło: opracowanie własne.

W sytuacji, gdy w ciągu dnia kurs nie wzrośnie do poziomu MB oraz nie spadnie do wartości MA, inwestor nie wykonuje tego dnia żadnej transakcji. Należy także liczyć się z możliwością, że system wygeneruje taką parę sygnałów, w której minimalna cena kupna będzie większa od maksymalnej ceny sprzedaży. Taki zestaw sygnałów jest błędny i ignorowany przez inwestora.

System transakcyjny generuje sygnały na podstawie danych wejściowych, do których należą przeszłe wartości MB oraz MA, rozszerzone o informacje identyfikujące dzień tygodnia. Tak przedstawiony generator decyzji inwestycyjnych jest funkcją, która na bazie zmiennych wejściowych wyznacza zmienne wyjściowe, czyli sygnały inwestycyjne. Problem sprowadza się do określenia postaci funkcji, metody wyznaczania jej parametrów oraz kryterium oceny generowanych wyników.

3. Generator decyzji

Generator decyzji inwestycyjnych to sztuczna sieć neuronowa. W badaniu wykorzystano jednowarstwową, jednokierunkową, liniową sieć neuronową, czyli strukturę składającą się z jednej warstwy neuronów, wykonującej jednokrotne, linowe

przekształcenie zmiennych wejściowych na zmienne wyjściowe. Wszystkie przykłady praktyczne związane z wykorzystaniem symulatora sztucznych sieci neuronowych oraz algorytmów uczenia wykonano przy użyciu oprogramowania napisanego w języku Java przez autora artykułu (pakiet rosczak.com wersja 05.06.09)¹.

Wykorzystana sieć neuronowa posiada 14 wejść oraz 2 wyjścia. Oznacza to, że jej struktura składa się z dwóch neuronów i w sensie matematycznym jest parą równań liniowych. Zależności ekonomiczne, a szczególnie mechanizmy rynku walut, mają charakter złożony i prawdopodobnie nieliniowy. Można podejrzewać, że wykorzystanie nieliniowej sieci neuronowej, złożonej z więcej niż jednej warstwy, byłoby bardziej dopasowane do specyfiki problemu i mogłoby przynieść lepsze rezultaty. Niestety wstępne eksperymenty polegające na trenowaniu dwuwarstwowej sieci neuronowej z nieliniową funkcją aktywacji nie doprowadziły do uzyskania rozwiązania w wyznaczonym maksymalnym horyzoncie czasu. Wraz ze wzrostem komplikacji sieci neuronowej wzrasta liczba obliczeń potrzebnych do wyznaczenia jej wag. Wykorzystany w eksperymencie sprzęt w postaci komputera PC z procesorem dwurdzeniowym o częstotliwości taktowania 3.0 GHz nie dostarcza odpowiednich mocy obliczeniowych.

Z podanych wyżej powodów w badaniu wykorzystano linową sieć neuronową. W przyszłości, wraz z uzyskaniem dostępu do większych mocy obliczeniowych, może zaistnieć możliwość skutecznego kontynuowania eksperymentów nad sieciami nieliniowymi.

4. Wykorzystane zmienne

Generator sygnałów inwestycyjnych wymaga wektora zmiennych wejściowych oraz wektora dodatkowych zmiennych wykorzystywanych przy wyznaczaniu wag sieci maksymalizujących miarę zysku. Dodatkowe zmienne są wymagane w formułach związanych z wyznaczaniem miary zysku.

Zmienne wykorzystane w wektorze wejść:

MB_{t-n} – (*maximum bid price*) maksymalna cena sprzedaży pary walut w dniu $t-n$, gdzie n jest opóźnieniem.

MA_{t-n} – (*minimum ask price*) minimalna cena zakupu pary walut w dniu $t-n$, gdzie n jest opóźnieniem.

SU_t – (*sunday*) zmienna zero-jedynkowa przyjmująca wartość 1 w niedzielę i zero w pozostałe dni.

MO_t – (*monday*) zmienna zero-jedynkowa przyjmująca wartość 1 w poniedziałek i zero w pozostałe dni.

¹ Więcej informacji na temat użytego oprogramowania można uzyskać, pisząc pod adres autora: pawel@rosczak.com.

TU_t – (*tuesday*) zmienna zero-jedynkowa przyjmująca wartość 1 we wtorek i zero w pozostałe dni.

WE_t – (*wednesday*) zmienna zero-jedynkowa przyjmująca wartość 1 w środę i zero w pozostałe dni.

TH_t – (*thursday*) zmienna zero-jedynkowa przyjmująca wartość 1 w czwartek i zero w pozostałe dni.

FR_t – (*friday*) zmienna zero-jedynkowa przyjmująca wartość 1 w piątek i zero w pozostałe dni.

Międzynarodowy rynek walut rozpoczyna działanie w niedzielę wieczorem, a kończy aktywność w piątek wieczorem. Sobota jest dniem bez transakcji z zachowaniem stałego kursu i dlatego została pominięta w zestawie zmiennych zerojedynkowych.

Dodatkowe zmienne i parametry wykorzystywane przy wyznaczaniu wag:

CB_t – (*close bid price*) cena sprzedaży pary walut na koniec dnia t (cena zamknięcia).

CA_t – (*close ask price*) cena zakupu pary walut na koniec dnia t (cena zamknięcia).

SL – (*stop-loss*) współczynnik zabezpieczenia przed stratą, wartość określająca poziom akceptowalnej straty.

Zmienne wyjściowe:

BP_t – (*bid price*) poziom (sygnał) sprzedaży, cena, po której osiągnięciu należy sprzedać parę walut w dniu t .

AP_t – (*ask price*) poziom (sygnał) kupna, cena, po której osiągnięciu należy kupić parę walut w dniu t .

5. Sieć neuronowa

Sieć neuronową wykorzystaną w badaniu można zapisać w postaci następującego układu równań liniowych:

$$\begin{aligned} \Delta BP_t &= a_{1,1} \Delta MB_{t-1} + a_{1,2} \Delta MB_{t-2} + a_{1,3} \Delta MB_{t-3} + a_{1,4} \Delta MB_{t-4} \\ &+ a_{1,5} \Delta MA_{t-1} + a_{1,6} \Delta MA_{t-2} + a_{1,7} \Delta MA_{t-3} + a_{1,8} \Delta MA_{t-4} \\ &+ a_{1,9} SU_t + a_{1,10} MO_t + a_{1,11} TU_t + a_{1,12} WE_t + a_{1,13} TH_t + a_{1,14} FR_t \end{aligned}$$

$$\begin{aligned} \Delta AP_t &= a_{2,1} \Delta MB_{t-1} + a_{2,2} \Delta MB_{t-2} + a_{2,3} \Delta MB_{t-3} + a_{2,4} \Delta MB_{t-4} \\ &+ a_{2,5} \Delta MA_{t-1} + a_{2,6} \Delta MA_{t-2} + a_{2,7} \Delta MA_{t-3} + a_{2,8} \Delta MA_{t-4} \\ &+ a_{2,9} SU_t + a_{2,10} MO_t + a_{2,11} TU_t + a_{2,12} WE_t + a_{2,13} TH_t + a_{2,14} FR_t \end{aligned}$$

gdzie $\Delta X_t = X_t - X_{t-1}$.

System generuje sygnały inwestycyjne na bazie przeszłych obserwacji maksymalnej dziennej ceny sprzedaży i minimalnej dziennej ceny kupna. Sygnał sprzedaży w dniu t powinien być zbliżony do nieznanej, maksymalnej, dziennej ceny sprzedaży. Sygnał kupna w dniu t powinien być zbliżony do nieznanej, minimalnej, dziennej ceny

kupna. Jednak w odróżnieniu od modelu autoregresyjnego odchylenia dodatnie i ujemne od wartości empirycznej mają odmienny wpływ na wartość funkcji kryterialnej. Dodatkowo przyjęto założenie o istnieniu zależności pomiędzy dniem tygodnia a kształtowaniem się ceny pary walut. Wektor wejść obejmuje empiryczne poziomy kursów przekształcone do postaci pierwszych różnic. Opóźnienie wynoszące 4 obserwacje w przeszłości zostało dobrane metodą prób i błędów w trakcie eksperymentów wstępnych.

6. Kryterium wyznaczania wag

Wartości wag typowej jednokierunkowej, wielowarstwowej sieci neuronowej są wyznaczane na podstawie błędu średniokwadratowego za pomocą iteracyjnego algorytmu wykorzystującego gradient funkcji błędu. Wagi sieci neuronowej stanowiącej generator decyzji inwestycyjnych są wyznaczane według innego kryterium, które można określić jako suma dziennych uśrednionych różnic kursowych. Proces trenowania zakłada odmienny kierunek optymalizacji. Zamiast minimalizowania wartości funkcji błędu, wagi generatora decyzji inwestycyjnych maksymalizują funkcję zysku z inwestycji.

Funkcja kryterialna jest wyrażona wzorem:

$$SDP_t = \begin{cases} 0, & \text{if } BP_t > MB_t \\ -SL, & \text{if } (BP_t \leq MB_t) \cap (BP_t + SL \leq MB_t) \\ BP_t - CA_t, & \text{if } (BP_t \leq MB_t) \cap (BP_t + SL > MB_t) \cap (AP_t < MA_t) \\ BP_t - AP_t, & \text{if } (BP_t \leq MB_t) \cap (BP_t + SL > MB_t) \cap (AP_t \geq MA_t) \end{cases}$$

$$BDP_t = \begin{cases} 0, & \text{if } AP_t < MA_t \\ -SL, & \text{if } (AP_t \geq MA_t) \cap (AP_t - SL \geq MB_t) \\ CB_t - AP_t, & \text{if } (AP_t \geq MA_t) \cap (AP_t - SL < MB_t) \cap (BP_t > MB_t) \\ BP_t - AP_t, & \text{if } (AP_t \geq MA_t) \cap (AP_t - SL < MB_t) \cap (BP_t \leq MB_t) \end{cases}$$

$$P = \frac{1}{2} \sum_{t=1}^T (SDP_t + BDP_t)$$

- gdzie: T – liczba obserwacji,
SDPt – (*sell day profit*) różnica kursowa wyrażona w walucie kwotowanej w przypadku sprzedaży i późniejszego odkupienia pary walut w dniu *t* (dzienna miara zysku z zajęcia pozycji długiej),
BDPt – (*buy day profit*) różnica kursowa wyrażona w walucie kwotowanej w przypadku zakupu i późniejszego odsprzedania pary walut w dniu *t* (dzienna miara zysku z zajęcia pozycji krótkiej),
P – (*profit*) miara zysku z inwestycji zgodnych z decyzjami generowanymi przez system (suma dziennych uśrednionych różnic kursowych).

Funkcja kryterialna opisuje za pomocą operatorów matematycznych oraz logicznych przyjętą metodę inwestowania i jej rezultaty. Mimo że wykorzystywana sieć neuronowa jest stosunkowo prostym układem równań linowych, nie ma możliwości wyznaczenia jej wag za pomocą typowych metod, takich jak np. metoda najmniejszych kwadratów lub algorytm wstecznej propagacji błędu. Funkcja opisująca kryterium jest nieciągła i nieróżniczkowalna, co oznacza, że metody optymalizacji wykorzystujące pochodne funkcji kryterialnej nie mają w tym przypadku zastosowania.

7. Metoda wyznaczania wag

Do wyznaczania wartości wag systemu generowania decyzji inwestycyjnych wykorzystano hybrydowy algorytm genetyczny². Algorytm genetyczny nie nakłada ograniczeń na postać funkcyjną formuły kryterialnej i dlatego może skutecznie optymalizować funkcje nieciągłe, takie jak opisana wyżej miara zysku z inwestycji.

Punktem wyjścia jest podstawowy algorytm genetyczny z rzeczywistym kodowaniem genotypu, który został zmodyfikowany przez autora w celu poprawy szybkości działania i precyzji uzyskiwanych rozwiązań. Optymalizacja startuje z losowo dobraną populacją. Każda generacja składa się z wykonania operatora selekcji, krzyżowania oraz mutacji. Algorytm opiera się na typowych rozwiązaniach oraz najczęściej zalecanych wartościach współczynników [Mitchell 1999, s. 130-132].

Operator selekcji wykorzystuje regułę turnieju. Ogólną wyższość reguły turnieju nad zasadą ruletki wykazali m.in. Kenneth De Jong oraz Anne Brindle [Goldbert 1998, s. 136-137].

Przestrzeń rozwiązań, do której może należeć genotyp, jest ograniczona wartościami minimalnymi oraz maksymalnymi. Mimo że genotyp ma postać zmiennych rzeczywistych, przyjmuje się ustaloną precyzję rozwiązania, czyli maksymalną zmianę wartości zmiennej, jaka może nastąpić w wyniku działania operatora mutacji.

Operatory krzyżowania oraz mutacji najpierw tworzą kopię oryginalnego rozwiązania, a następnie modyfikują uzyskany klon genotypu. Rozszerzana w ten sposób liczebność populacji jest następnie redukowana do pierwotnego rozmiaru przez operator selekcji. Użycie populacji o zmiennej liczebności umożliwia osobnikom potomnym rywalizowanie z osobnikami rodzicielskimi i daje gwarancję, że żaden z dobrze dopasowanych genotypów rodzicielskich nie zostanie usunięty podczas mutacji lub krzyżowania³.

Operator mutacji posiada powiększony zestaw parametrów, które pozwalają osobno kontrolować intensywność mutacji w populacji oraz intensywność mutacji w obrębie pojedynczego genotypu.

² Więcej na temat uczenia sieci neuronowej przy użyciu algorytmu genetycznego zob. [Roścak 2006].

³ Więcej na temat algorytmu genetycznego o zmiennej wielkości populacji zob. [Roścak 2008a].

Standardowy operator selekcji został rozszerzony o mechanizm bazujący na koncepcji strategii elitarniej. Strategia elitarna wyłącza najlepszego osobnika z działania operatorów genetycznych i dzięki temu zapobiega utracie najlepszego odszukanego rozwiązania [Rutkowski, Rutkowski, Piliński 1999, s. 168-169]. Dodatkowo najlepszy osobnik w bieżącej generacji oraz najlepszy osobnik w całej populacji są osobno optymalizowane przy użyciu algorytmu przeszukiwania lokalnego. Hybrydyzacja algorytmu genetycznego z przeszukiwaniem lokalnym usuwa słaby punkt metod ewolucyjnych, jakim jest mała efektywność w odszukiwaniu dokładnego lub prawie dokładnego rozwiązania. Połączenie algorytmu genetycznego i przeszukiwania lokalnego powoduje, że uzyskany algorytm hybrydowy jest efektywny zarówno we wstępnym przeszukiwaniu całej przestrzeni rozwiązań, jak i w końcowym wyznaczeniu dokładnego punktu stanowiącego ekstremum⁴.

Operator selekcji korzysta także z mechanizmu zróżnicowania populacji przez unikanie konfrontowania osobników bardzo różniących się od siebie pod względem genotypów.

8. Wyniki uzyskane dla danych empirycznych

Przedstawiony system generowania decyzji inwestycyjnych dla pary walut EUR/USD został przetestowany przy użyciu rzeczywistych danych empirycznych. Wartości kursów zostały pobrane z internetowej platformy transakcyjnej OANDA FXTrade (www.oanda.com).

Próba obejmowała dane dzienne dla miesięcy od stycznia do czerwca 2007 roku. Zestaw danych został podzielony na dwa zbiory:

- zbiór treningowy obejmujący 120 obserwacji dziennych (20 tygodni), które zostały wykorzystane do wyznaczenia wag sieci neuronowej,
- zbiór walidacyjny obejmujący 12 obserwacji dziennych (2 ostatnie tygodnie), które nie brały udziału w uczeniu sieci i zostały użyte do oceny właściwości systemu.

Podsumowanie wyników eksperymentu zawiera tab. 1.

Tabela 1. Przykłady wyników zastosowania systemu generowania decyzji inwestycyjnych dla danych empirycznych (OANDA FXTrade, styczeń – czerwiec 2007)


Parametr	Wyniki dla zbioru treningowego	Wyniki dla zbioru walidacyjnego
Miara zysku (P)	0,099851	0,005975
Średnia dzienna miara zysku (P/T)	0,000832	0,000498

Źródło: opracowanie własne.

⁴ Więcej na temat hybrydy algorytmu genetycznego i przeszukiwania lokalnego zob. [Rośczał 2008b].

Proces uczenia i testowania systemu w przypadku sieci liniowej trwał poniżej 10 s. Uzyskane wyniki potwierdzają skuteczność użytego algorytmu genetycznego w trenowaniu sieci neuronowej. Ponadto dodatnie wartości miar zysku dla zbioru walidacyjnego sugerują, że sieć posiada zdolność do generalizacji aproksymowanych zależności, wskazują także na możliwość uzyskania dodatniego zysku dla przyszłych inwestycji. Wielokrotne uruchamianie algorytmu uczenia i testowania prowadzi do uzyskania bardzo zbliżonych lub identycznych wartości miar zysku dla zbioru treningowego oraz rozbieżnych, w tym ujemnych wartości miar zysku dla zbioru walidacyjnego. Mimo że system działa zgodnie z przyjętymi założeniami dotyczącymi lepszego dopasowania do specyfiki problemu, wyniki uzyskane dla zbioru walidacyjnego nie są stabilne i nie pozwalają jednoznacznie ocenić jego możliwości.

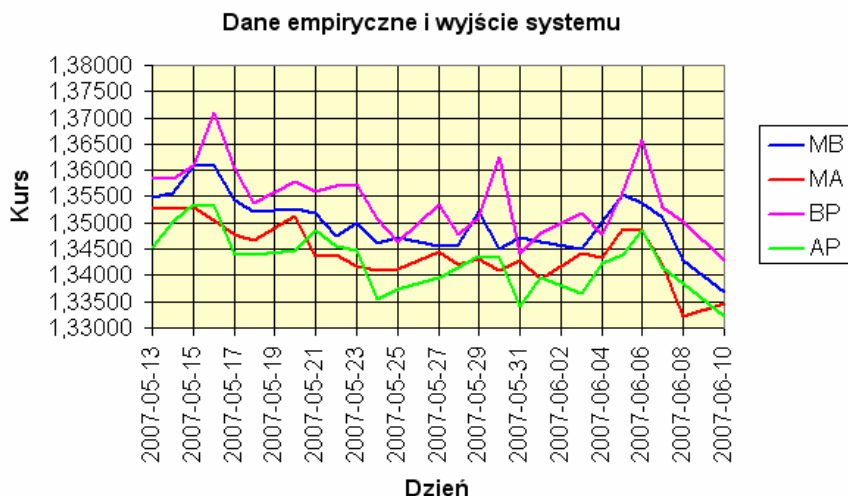
Specyficzne właściwości sygnałów generowanych przez sieć neuronową można zaobserwować na wykresach prezentujących wyjścia systemu zestawione z maksymalną ceną sprzedaży i minimalną ceną zakupu (rys. 2 i 3).



Rys. 2. Dane empiryczne i wyjścia generatora decyzji inwestycyjnych na przestrzeni całej próby

Źródło: opracowanie własne.

W odróżnieniu od typowego wykresu prognozującego skrajne dzienne ceny sprzedaży i kupna, wyjścia generatora decyzji inwestycyjnych nie oscylują wokół wartości empirycznych, ale ich wykresy są częściej na zewnątrz pasa tworzonego przez zaobserwowaną, maksymalną cenę sprzedaży i zaobserwowaną minimalną cenę zakupu.



Rys. 3. Dane empiryczne i wyjścia generatora decyzji inwestycyjnych dla obserwacji z ostatniego miesiąca próby

Źródło: opracowanie własne.

9. Podsumowanie

Kryterium wyznaczania wartości wag dla systemu generowania decyzji inwestycyjnych jest wyrażeniem składającym się z operatorów matematycznych i logicznych, co oznacza brak możliwości stosowania typowych metod uczenia sieci neuronowych, w tym algorytmu wstecznej propagacji błędów.

Zastosowanie hybrydowego algorytmu genetycznego pozwala na wyznaczanie wag sieci neuronowej według kryterium najlepiej dopasowanego do specyfiki problemu.

Wyniki uzyskane przez nauczoną sieć neuronową wskazują na możliwość osiągnięcia zysku dla danych z próby treningowej oraz dla danych pozostających poza próbą treningową. Wyniki uzyskiwane w procesie optymalizacji wartości wag nie są stabilne. Sieć neuronowa trenowana wielokrotnie wykazuje zmienność wartości kryterialnej (w tym stratę) dla zbioru danych walidacyjnych.

Generator decyzji inwestycyjnych jest algorytmem ściśle dopasowanym do specyfiki inwestowania na rynku walut, niestety ostateczna ocena jego właściwości wymaga dalszych badań, w tym np. wykorzystania nieliniowych sieci neuronowych złożonych z więcej niż jednej warstwy.

Literatura

- Goldberg D. E., *Algorytmy genetyczne i ich zastosowanie*, tłum. K. Grygiel, wyd. 2, Wydawnictwo Naukowo-Techniczne, Warszawa 1998.
- Mitchell M., *An Introduction to Genetic Algorithms*, The MIT Press, London 1999.
- Rośczał P., *Algorytm genetyczny o zmiennej wielkości populacji*, [w:] *Zarządzanie. Transport. Informatyka. Nowoczesne technologie i trendy 2008a* (w druku).
- Rośczał P., *Genetic algorithm with local search*, [w:] *4th Polish and International PD Forum-Conferences on Computer Science 2008b* (w druku).
- Rośczał P., *Stabilność wyników uczenia sieci neuronowej za pomocą algorytmów ewolucyjnych*, [w:] *Metody i zastosowania badań operacyjnych 2006* (w druku).
- Rutkowska D., Rutkowski L., Piliński M., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, Wydawnictwo Naukowe PWN, Warszawa 1999.

THE GENETIC ALGORITHM APPLICATION IN THE GENERATION OF INVESTMENT DECISIONS IN THE FOREIGN EXCHANGE MARKET

The article presents the implementation and application of investment decisions generator in the foreign exchange market. Generator uses neural network and genetic algorithm to determinate networks weights. This combination of methods allows to apply more problem-specific criterion function in the form of profit measure from investment.