

BADANIA EFEKTYWNOŚCI PREDYKCYJNEJ MODELU KLASY GMDH OPARTEGO NA ZACHOWANIU UCZESTNIKÓW RYNKU WALUTOWEGO

Antoni Wiliński

Wydział Informatyki, ZUT
e-mail: awilinski@wi.zut.edu.pl

Streszczenie: W pracy przedstawiono wyniki eksperymentu przeprowadzonego w celu predykcyjnym na rynku walutowym. Założono, że rynek nie jest efektywny i daje się z przeszłości wyekstrahować wiedzę o błędach popełnionych przez uczestników wybranej platformy brokerskiej. Dla wykonania predykcji wykorzystano zmodyfikowaną metodę GMDH (Group Method of Data Handling) umożliwiającą sukcesywny wybór nieliniowego modelu wielomianowego najlepiej w danym kroku opisującego rynek. Przedstawiono interesujące wyniki eksperymentu na danych historycznych potwierdzające użyteczność metody. Danymi wejściowymi były zarejestrowane na platformie zachowania inwestorów – rozkład otwartych pozycji i złożonych zleceń. Stąd – rozpatrywane podejście można zaliczyć do modelowania behawioralnego.

Słowa kluczowe: zachowanie inwestorów, finanse behawioralne, modele regresyjne, GMDH, platformy brokerskie, rynek efektywny

WPROWADZENIE

Wśród zagorzałych zwolenników analizy technicznej powszechne jest przekonanie, że każdy obserwowany rynek pozwala przewidzieć jego zmiany na podstawie bogatego arsenału środków umożliwiających wydobycia sugestii zmian z przeszłości. Na drugim biegunie poglądów lokują się hipotezy Fama'y [Fama E.F. 1998] o rynku efektywnym niemożliwym lub prawie niemożliwym do prognozowania wskutek pełnego i natychmiastowego dostępu do informacji przez wszystkich uczestników rynku. Problematyką kojarzenia wszelkich informacji, pochodzących z różnych niezależnych źródeł i mających często heterogeniczną, nieporównywalną naturę zajmowało się wielu analityków. Z pewnością najważniejszym jest

niedawny kandydat do nagrody Nobla wspomniany prof. Eugene Fama, ale także kontestujący jego prace noblista Joseph Stiglitz, czy zwolennicy finansów behawioralnych R.Barberis [Barberis N i in. 1998], R. Thaler, W. DeBondt [DeBondt W. i in. 1985] i J.Piper [Piper J. 2006].

Dość powszechne są także ostatnio poglądy, że najlepsze prawdopodobnie wyniki predykcyjne na poziomie zapewniającym ich praktyczną użyteczność inwestycyjną uzyska się poprzez kojarzenie elementów analizy technicznej i fundamentalnej. Sposobem na osiągnięcie tego celu jest hybrydyzacja metod o różnym charakterze modeli opisujących rzeczywistość związaną z danym rynkiem i różnych technik wykonania decyzji rekomendowanych przez te modele. Sheng-Hsun Hsu [Sheng-Hsun Hsu i in. 2009] i Zhang Yudong [Zhang Yudong i in. 2009] łącząc modelowanie za pomocą sztucznych sieci neuronowych z teorią zbiorów przybliżonych uważają, że to najbardziej perspektywiczny kierunek opanowywania niestacjonarnych procesów, a Hia Jong Teoh [Hia Jong Teoh i in. 2009] przedstawia metodę łączącą sieci neuronowe z GMDH (*Group Method of Data Handling*). S. Dehuri i S. Cho [Dehuri S. 2009] łączą techniki regresyjne z optymalizacją rojem cząstek.

Na tym tle zaprezentowana jest metoda o podobnej próbie połączenia metody GMDH [Ivakhnenko A. i in. 1999, Ivakhnenko A. i in. 2000] z danymi o charakterze behawioralnym wyekstrahowanymi z przestrzeni zachowań uczestników rynku do tablicy przypominającej tablicę informacyjną w teorii zbiorów przybliżonych. Interesujące może być rozpatrywanie bieżących zachowań tych uczestników, nie poprzez obserwację kursu waluty (zresztą to niemożliwe), lecz poprzez badanie przyczyn zmian tego kursu wynikających ze złożonych zleceń i otwartych pozycji na rynku spot. W artykule rozpatrywana jest koncepcja systemu wykorzystującego statystyczne dane o rozkładzie preferencji użytkowników przetworzone następnie w modelu regresyjnym zbudowanym wg zasad GMDH.

CHARAKTERYSTYKA DANYCH

Przykładem platformy prezentującej behawioryzm jej użytkowników jest aplikacja Small Speculant Sentiment Analyzer [Oanda 2008, Wanadoo 2008] przedstawiająca intencje wybranej części użytkowników znanej platformy brokerskiej Oanda.com [Oanda 2008]. Wspomniana aplikacja wizualizuje zamiary kilkudziesięciu tysięcy użytkowników w formie dwóch diagramów, z których górny przedstawia rozkład otwartych pozycji rynku spot, a dolny rozkład zleceń (rys.1). Każdy kwadrant diagramu (krzywa na nim przedstawiona) może być zinterpretowany jako suma liczby decyzji (otwartych pozycji lub zleceń) w funkcji odległości od bieżącej wartości rozpatrywanego instrumentu finansowego - na przedstawionym wykresie na przykładzie eurodolara.

Kolejno, np. diagram w górnej prawej ćwiartce (kwadrancie) oznacza narastającą liczbę (względna, wyrażoną w procentach) pozycji długich otwartych powyżej bieżącej wartości kursu. Wykres przedstawia sytuację na rynku EUR/USD

przy wartości bieżącej kursu $C = 1,5305$. Każda wartość (w %) pozycji długich otwartych w przedziale $\langle x_b, x_b + \delta \rangle$ w całkowitej liczbie wszystkich otwartych pozycji (długich i krótkich). Niech δ oznacza pewną, racjonalnie wybraną, stałą wielkość rozpatrywanego przedziału (np. 100, 200 lub więcej pipsów). Zmienna ta winna umożliwić w miarę dokładne odczytanie udziału otwartych pozycji z wykresu (rys.1).

Przez analogię, odpowiednio (rys. 2):

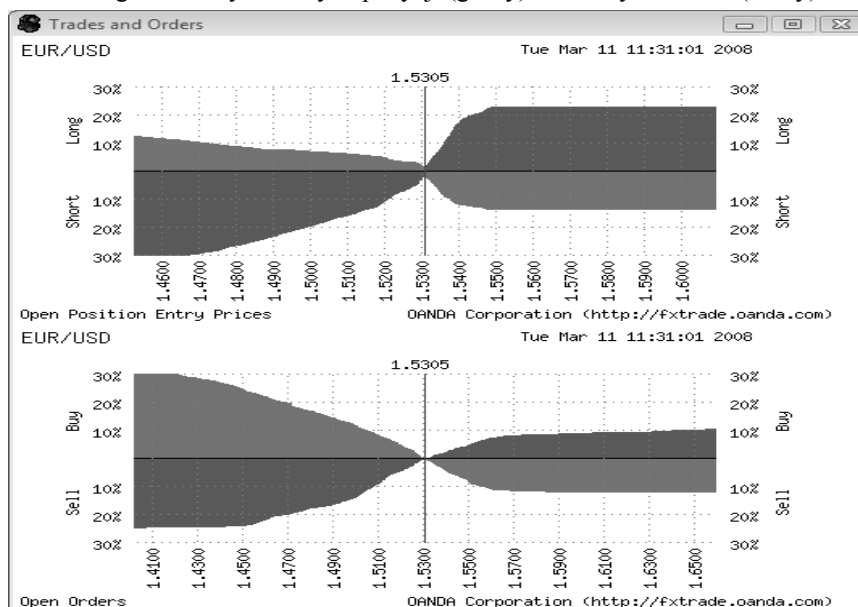
$G_2(x_b, x_b + \delta)$ - oznaczać będzie udział pozycji krótkich otwartych powyżej wartości bieżącej kursu w przedziale $\langle x_b, x_b + \delta \rangle$;

$G_3(x_b - \delta, x_b)$ - oznaczać będzie udział pozycji krótkich otwartych poniżej wartości bieżącej kursu w przedziale $\langle x_b - \delta, x_b \rangle$;

$G_4(x_b - \delta, x_b)$ - oznaczać będzie udział pozycji długich otwartych w przedziale $\langle x_b - \delta, x_b \rangle$, czyli poniżej wartości bieżącej kursu.

Wprowadzenie parametru δ powoduje, że suma czterech rozpatrzonych sum G_1 do G_4 nie będzie równa 100%, lecz pozwoli na powtarzalność obliczeń pól w tych samych warunkach.

Rysunek 1. Diagram liczby otwartych pozycji (górny) i złożonych zleceń (dolny)



Źródło: Oanda, www.oanda.com

Podobnie dla nierozpatrywanego do tej pory diagramu dolnego na rys. 1 niech odpowiednio:

$G_5(x_b, x_b + \delta)$ - oznacza udział zleceń kupna złożonych z limitem położonym w przedziale $\langle x_b, x_b + \delta \rangle$. Zlecenia te mogą wynikać z zamian otwarcia pozycji długiej powyżej bieżącej wartości kursu (są to tzw. zlecenia Buy Stop), lub z zamiaru zamknięcia przegrywającej pozycji krótkiej (zlecenie Stop Loss). Oba te przypadki są rezultatem takiej samej postawy inwestora – jego przekonania, że kurs waluty wzrośnie. W pierwszym przypadku otwarcie pozycji długiej następuje w nadziei dalszego wzrostu, w drugim przypadku zamknięcie pozycji krótkiej (technicznie tożsame z otwarciem pozycji długiej) następuje w obawie także przed dalszym wzrostem kursu i powiększaniem straty.

$G_6(x_b, x_b + \delta)$ - oznacza udział zleceń sprzedaży złożonych z limitem położonym powyżej bieżącej wartości kursu. Są to zlecenia wynikające z zamiaru zamknięcia pozycji długiej wygrywającej (Take Profit) lub otwarcia pozycji krótkiej. Oba wynikają z takiego samego przekonania inwestorów o spadku kursu (po osiągnięciu poziomu wyznaczonego w zleceniu). Inwestor w przypadku posiadania pozycji długiej składa zlecenie typu Take Profit lokując je powyżej bieżącej wartości kursu w przekonaniu że kurs dalej nie będzie rósł. Inny inwestor składa zlecenie otwarcia pozycji krótkiej Sell Limit także w przekonaniu, że kurs po osiągnięciu poziomu określonego w zleceniu zacznie spadać.

$G_7(x_b - \delta, x_b)$ - to udział zleceń sprzedaży złożonych poniżej wartości bieżącej kursu. Zlecenia te wynikają z zamiaru inwestora otwarcia pozycji krótkiej (Sell Stop) lub zamknięcia przerywającej pozycji długiej (Stop Loss). Oba więc wynikają z przekonania, że kurs będzie spadał.

$G_8(x_b - \delta, x_b)$ - to udział zleceń kupna złożonych poniżej wartości bieżącej kursu. Zlecenia takie są składane przez inwestora w celu otwarcia w celu otwarcia pozycji długiej (Buy Limit) lub dla zamknięcia krótkiej pozycji wygrywającej (Take Profit). Oba typy zleceń wynikają z tego samego przekonania inwestorów, że kurs po osiągnięciu poziomu wyznaczonego przez zlecenie, będzie następnie rósł.

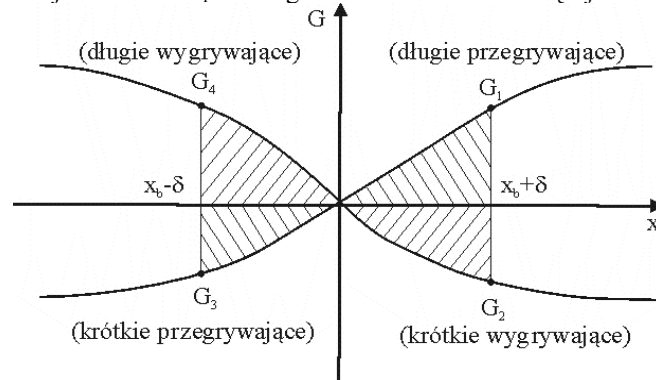
Całki G_5 do G_8 dotyczące zleceń przedstawione są na rys. 3. Przedział δ (odległość od wartości bieżącej kursu) może być oczywiście inny niż na rys.2.

Jeżeli w powyższych definicjach G_i oraz δ wprowadzić pojęcie małego np. kilkupipsowego przyrostu kursu d_x nie mniejszego jednak niż 1 pips oraz pojęcie rozkładu liczby zdarzeń g_j w każdym j -tym przedziale wyznaczonym przez kolejne przyrosty kursu (zdarzenie to zlecenie lub otwarcie pozycji), to ogólna definicja sumy G_i będzie:

$$G_i = \sum_j^k g_j \quad (1)$$

gdzie $k = \delta / d_x$ dla $i = 1, 2, \dots, 8$; dla $\delta = 100, 200, 300, \dots$ pipsów.

Każdy indeks i oznacza zupełnie inną funkcjonalność, inny świat - zwycięstw lub porażek, optymizmu lub pesymizmu.

Rysunek 2. Definicja udziałów G_i w odległości δ od wartości bieżącej kursu x_b 

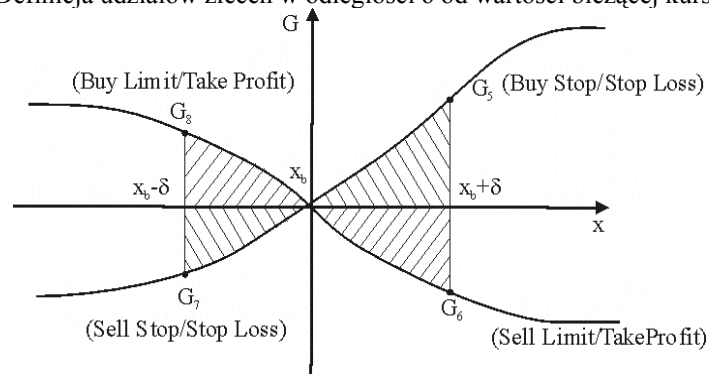
Źródło: Opracowanie własne

Dla pewnego ustalonego arbitralnie, aczkolwiek rozsądnie δ , można przeprowadzić normalizację sum G_i w dwóch grupach - dla $i \in \{1,2,3,4\}$ oraz $i \in \{5,6,7,8\}$, taką, że

$$G_i^n = \frac{G_i}{\sum_1^4 G_i}, \text{ dla } i = 1, 2 \dots 4 \quad (2)$$

$$G_i^n = \frac{G_i}{\sum_5^8 G_i}, \text{ dla } i = 5, 6 \dots 8 \quad (3)$$

Zabiegi powyższe mają na celu wyodrębnienie takiego fragmentu obrazu (rys.1), który w sposób powtarzalny, dla wielu tysięcy pobrań z serwera, zapewni zawsze tę samą procedurę znajdowania proporcji pomiędzy otwartymi pozycjami

Rysunek 3. Definicja udziałów zleceń w odległości δ od wartości bieżącej kursu x_b 

Źródło: Opracowanie własne

w czterech kwadrantach górnej części rys.1 oraz złożonych zleceń w dolnej części tego rysunku a dodatkowo zapewni stałą wartość czterech sum.

Po przeprowadzeniu normalizacji wg (2) i (3) przygotowano do dalszego przetwarzania macierzy danych obserwowanych $X_{M \times N}$ o następującej strukturze:

M - liczba wierszy (pomiarów, obserwacji – tu świec obserwowanych w cyklu jednogodzinnym);

N - liczba kolumn; tu $N = 10$.

W kolumnach macierzy X zapisano odpowiednio:

X_1 - kurs badanej co godzinę pary walutowej EUR/USD;

$X_2 \div X_5$ - kolejno obserwowane na podstawie górnego diagramu (rys.1) i przetworzone zgodnie z (2) wartości udziałów $G_1^4 + G_4^4$, oznaczające względną liczbę pozycji otwartych w rozpatrywanych kwadrantach układu rys.2;

$X_6 \div X_9$ - obserwowane na podstawie dolnego diagramu (rys. 1) i przetworzone wg (3) wartości udziałów złożonych zleceń $G_5^4 + G_6^4$, oznaczające względną liczbę w kwadrantach rys.3.

$X_{10} \equiv Y$ – obserwowana zmienna wyjściowa - różnica pomiędzy bieżącą a poprzednią wartością kursu, stanowiąca podstawę do rozważań predykcyjnych.

Formalnie, $X_{i,10} = X_{i+1,1} - X_{i,1}$. Tabele te (macierz danych X) są bazą dla dalszych rozważań i zbudowania modelu predykcyjnego.

SFORMUŁOWANIE PROBLEMU BADAWCZEGO

Przedstawiona aplikacja internetowa jest, zgodnie z jej sugerowaną nazwą (Small Speculant), źródłem wielu pomysłowych rozwiązań i miejscem ścierania się różnych poglądów spontanicznie powstającej wokół niej społeczności. Wiele z nich koncentruje się, jak to wynika z dyskusji na forum, na próbie realizacji tezy, że skoro ok. 95 % wszystkich drobnych inwestorów przegrywa, to należy poszukiwać wzorca rozkładu udziałów $G_1 \div G_8$ takiego, że prawdopodobna i możliwa będzie porażka tak znacznej części populacji inwestorów reprezentowanych poprzez bieżący rozkład otwartych pozycji i zleceń.

Rozpatrywana tu autorska koncepcja jest całkowicie odmienna od wyżej przedstawionej. Zbieżne są one jedynie w aspekcie założenia, że istnieją pewne wzorce wyrażane poprzez konfiguracje danych, których rozpoznanie umożliwi lub uprawdopodobni skuteczność prognozy. W przypadku, opisanym jako popularny sposób zachowania się większości inwestorów, wzorcem takim mogłaby być sytuacja na diagramie rys.1 – jako informacja wejściowa dla znalezienia odpowiedzi na pytanie, jaka możliwa najbliższa zmiana rynku spowodowałaby porażkę większości graczy. Na diagramie tym dla większości inwestorów gorszy byłby wzrost kursu – spowodowałby on pogłębienie się strat ok. 35% populacji z tytułu otwartych pozycji krótkich i poprawiałby sytuacje ok. 24% przegrywających długich pozycji. W diagramie złożonych zleceń ruch byłby o wiele mniejszy niż dla przypadku otwartych pozycji.

Ponieważ historycznie dzieje się tak, że większość przegrywa, to logicznym (w sensie myślenia indukcyjnego, a nie logicznego) ruchem byłoby wykonanie operacji (np. otwarcie pozycji), wygrywającej przy równoczesnej porażce większości. Na zasadzie przekory należałoby więc otworzyć tu pozycję długą.

W rozpatrywanym modelu zakłada się także występowanie wzorców uzasadniających postawienie następującej tezy. Jeżeli wielokrotnie weryfikowana konfiguracja zmiennych wejściowych $X_2 \div X_9$ pozwala na zbudowanie modelu regresyjnego (niekoniecznie liniowego) takiego, że wg ustalonego kryterium akceptowalne mogą być błędy uczestników wynikające z zastosowania tego modelu na odcinku predykcyjnym w fazie uczenia, to oznaczać to może, że znaleziono wzorzec (model regresyjny), na podstawie którego można zbudować system transakcyjny (oparty na koncepcji prognozy).

Jak zwykle, ważne jest rozróżnienie modelu predykcyjnego od modelu systemu transakcyjnego (inwestycyjnego). Pierwszy jest wyrazem zastosowania wyrafinowanych metod analizy technicznej (badania skutków zmian rynku) w celu prognostycznym, a drugi jest zastosowaniem (wykorzystaniem) wyników pierwszego modelu w warunkach proponowanych przez konkretną platformę inwestycyjną.

Podobnie jak w pracach [6,15,16] do rozwiązania zadań prognostycznych użyta była metoda GMDH. Zastosowany był tu algorytm oparty na nieliniowej regresji [Wilinski A. 2008], w której zmienną obserwowaną był zwrot po zakończeniu kolejnej świecy a zmiennymi wejściowymi kurs waluty i osiem opisanych sum G_i , $i = 1, 2, \dots, 8$.

Przez zwrot rozumie się tu różnice (w pipsach) pomiędzy wartościami kursu w chwili bieżącej i poprzedniej, oddalonymi o okres jednej świecy.

Zanim przystąpiono do zbudowania modelu regresyjnego rozszerzona została macierz danych wejściowych poprzez konkatenację horyzontalną. Macierz dodana z prawej strony macierzy pierwotnej utworzona została z nowych kolumn o długości N , z których każda jest iloczynem wartości w kolumnach z danymi pierwotnymi. Tych kolumn z danymi pierwotnymi uwzględniono 8, gdyż rozważano tylko kolumny reprezentujące sumy G_1 do G_8 .

W związku z tym kolejne kolumny o indeksie większym o liczbę k od dotychczasowej liczby kolumn N kolejno zawierały:

$$X_{N+k} = X_i * X_j, \text{ dla } k = 1, 2, \dots, i = 2, 3 \dots 9, j = i+1, i+2, \dots, 9, \quad (4)$$

gdzie operator „*” oznacza mnożenie tablicowe wektorów wyraz po wyrazie, tzn. wynikiem mnożenia jest kolejny wektor o takim samym wymiarze, którego wyrazy są iloczynami odpowiednich wyrazów dwóch kolumn wejściowych (kolejno dodawanymi iloczynami Hadamarda dwóch kolumn macierzy pierwotnej).

Liczba dodatkowych kolumn wg (4) z uwzględnieniem kwadratów wartości kolumn pierwotnych wyrazów $N_d = N(N-1)/2 + N$. Razem po konkatenacji macierz danych ma wymiar $M \times (N + N_d)$.

Dla zbudowania modeli prognostycznych na podstawie tak przetworzonych danych pierwsza kolumnę (X_1) traktuje się jako zmienną obserwowaną Y (odnosi się ona do zwrotu po kolejnym kroku) a wszystkie pozostałe kolumny - jako zmienne wejściowe (objaśniające). W ten sposób ostateczny model opisujący np. K wierszy zmiennej wyjściowej miał postać formalnie liniową (w rzeczywistości – kwadratową):

$$\hat{y}_{t+1} = \mathbf{X}_t * \mathbf{A}_{i+1} \quad (5)$$

$_{[1 \times 1]} \quad \cdot \quad _{[1 \times (L+1)]} \quad \cdot \quad _{[(L+1) \times 1]}$

dla $L = 3, 4, 5, \dots$ $i = 1, 2, \dots$

W modelu tym zmienna \hat{y}_{t+1} oznacza predykcyjną modelowaną wartość zmiennej obserwowanej, która w chwili bieżącej wynosi y_i . \mathbf{X}_i jest wektorem $(L+1)$ zmiennych wejściowych wybranym wg opisanego dalej algorytmu spośród N_d zmiennych rozszerzonej o wyrazy kwadratowe macierzy \mathbf{X} zaobserwowanym w chwili bieżącej i . Wektor \mathbf{A}_{i+1} jest zestawem $(L+1)$ współczynników równania liniowego

$$\mathbf{A}_{i+1} = [\mathbf{a}_{i+1}^0 \quad \mathbf{a}_{i+1}^1 \quad \mathbf{a}_{i+1}^2 \quad \dots \quad \mathbf{a}_{i+1}^L] \quad (6)$$

obliczonym w przeszłości na podstawie dostępnych danych historycznych dla wierszy danych rozpoczynających się w chwili $i-K-1$ a kończących się w chwili $i-1$.

Ponieważ zakłada się, że jest dana informacja do chwili i -tej to wykorzystując dane wejściowe do chwili $i-1$ a zmienną obserwowaną do chwili i -tej uzyskuje się możliwość wykonania prognozy o jeden krok wprzód. Liczba K obserwowanych wierszy jest (na razie) przyjmowana arbitralnie i może być także przedmiotem dalszej optymalizacji. Wektor \mathbf{A}_{i+1} obliczany jest z równania regresji wykonanej na K wierszach i L kolumnach.

Niewiadomą w tych rozważaniach jest liczba L współczynników równania jak i struktura modelu (czy do równania wchodzi tylko wyrazy liniowe, kwadratowe czy model jest mieszaniną tych wyrazów).

Problem ten rozwiązuje algorytm oparty na idei Group Method of Data Handling [6,15] dokonujący dla każdego i -tego kroku wielokrotnego wyboru L wyrazów dla $L=3,4,5,\dots,N_d$

Dla każdego obliczanego modelu rozpatrywane jest kryterium dokładności odtworzenia przebiegu zmiennej obserwowanej jako:

$$K_{iL}^J = \frac{1}{K} \sum \|\hat{Y}_t - Y_t\|^2 \rightarrow \min \quad (7)$$

Indeksy w kryterium K_{iL} oznaczają:

L - jest to indeks wskazujący liczbę wyrazów w modelu - dla modelu zawierającego $(L+1)$ wyrazów (L kolumn danych oraz wektor jedynek przeznaczony w modelu do obliczenia wyrazu wolnego równania regresji);

$J = \{j_1, j_2, \dots, j_L\}$ - określa zbiór indeksów kolumn włączonych do macierzy informacyjnej tworzącej wejścia dla obliczenia modelu \hat{Y}_i .

W ten sposób obliczając L_{1L}^J dla wszystkich kombinacji C_{Nd}^L dla każdego $L = 3, 4, 5, \dots$ znajdujemy K_{1Lmin}^J z odpowiadającym mu wektorem L indeksów kolumn $\{j_1, j_2, \dots, j_L\}$.

Tak znaleziony model użyty jest do wykonania predykcji (5). Jest to predykcja wykonana jeden krok wprzód przy założeniu, że model \hat{Y}_i uznany za najlepszy wg kryterium (11), będzie skuteczny jeszcze jeden krok wprzód i da satysfakcjonujące przybliżenie \hat{y}_{i+1} wg (5). Gdy upłynie czas trwania jednego kroku, będzie można sprawdzić, czy wartość y_{i+1} (której w danej chwili jeszcze nie ma) będzie bliska modelowi \hat{y}_{i+1} .

Wielokrotne powtarzanie tej procedury i ocena jakości modeli \hat{y}_{i+1} była przedmiotem badań.

Należy przy tym zauważyć, że w każdym kroku model \hat{Y}_i budowany jest z użyciem innych zmiennych i z zastosowaniem różnej struktury modelu. Posiada także, co oczywiste, zupełnie inny zestaw współczynników A_{i+1} .

W identyczny sposób można zbudować model (modele) umożliwiające predykcję na dwa kroki wprzód (także więcej). Jeżeli bowiem w jakiejś chwili t_i wykonana jest predykcja na dwa kroki wprzód, czyli dla chwili t_{i+1} i t_{i+2} to również w tej samej chwili znana jest predykcja z poprzedniego kroku dotycząca chwili t_i oraz t_{i+1} . Tak więc w chwili t_i istnieją dwie predykcje dla chwili t_{i+1} . Niech będą one oznaczone odpowiednio p_{i+1}^i i p_{i+1}^{i-1} , gdzie indeks dolny oznacza, dla której chwili predykcja jest wykonana a indeks górny, w której chwili została wykonana. Z różnicy indeksów widać, że pierwsza predykcja p_{i+1}^i to predykcja jeden krok wprzód a predykcja p_{i+1}^{i-1} wykonana jest dwa kroki wprzód.

Przez predykcję niech będzie rozumiane odchylenie zmiennej obserwowanej od wartości w kroku poprzednim np.

$$p_{i+1}^i = \hat{y}_{i+1} - y_i$$

$$p_{i+1}^{i-1} = \hat{y}_{i+1} - \hat{y}_i \quad (8)$$

lecz także

$$p_{i+1}^{i-1} = \hat{y}_i - y_{i-1} \quad (9)$$

Ponieważ w systemach transakcyjnych najważniejsza jest trafność kierunku zmian zmiennej obserwowanej, a nie dokładne określenie jej wartości, to w dalszych rozważaniach istotne będzie, czy zachodzi warunek równości znaków:

$$\text{sign}(p_{i+1}^i) = \text{sign}(p_{i+1}^{i-1}) \quad (10)$$

Jeżeli warunek (10) zachodzi, to interesująca staje się wartość znaku.

Jeżeli $\text{sign}(p_{i+1}^i) = 1$, oznacza to, że prognozowany jest wzrost rozpatrywanego kursu (tu ceny pary walutowej EUR/USD) i należy otworzyć pozycję długą, a gdy $\text{sign}(p_{i+1}^i) = -1$, należy otworzyć pozycję krótką. Jeżeli warunek (16) nie był spełniony, nie wykonywano żadnej operacji.

WYNIKI BADAŃ

Dla tak zdefiniowanej strategii z użyciem modelu GMDH przeprowadzono badania z wykorzystaniem danych zgromadzonych w wyniki dwumiesięcznego automatycznego monitoringu platformy [Wanadoo 2008]. Każda otwarta pozycja była zamykana po jednym kroku. Przyjęto, że spread wynosi 0.0002 (dwa pipsy).

Wykonano wiele eksperymentów dla różnych wartości K (liczby wierszy rozpatrywanych wstecz w modelu regresyjnym), SL (Stop Loss wyrażanego w pipsach dla ograniczenia strat) i różnych horyzontów czasowych. Rozpatrywano także różną liczbę okresów predykcji (od 1 do 3). Jakość systemu transakcyjnego (poprawność doboru parametrów) szacowano za pomocą uproszczonego wskaźnika Sharpe'a (pozbawionego członu odpowiedzialnego za stopę zwrotu wolną od ryzyka).

Niemal zawsze uzyskiwane były wyniki mające praktyczną wartość transakcyjną. Na wykresie przedstawiono wyniki jednej spośród tych symulacji. Wybrano warunki trudne – $SL=0.0050$, co dla świec jednogodzinnych na EUR/USD jest poziomem trudnym do osiągnięcia, ale osiąganym (tu 16 razy). Liczba członów modelu nieliniowego L wahała się od 3 do 4. Dla obliczenia współczynników modelu aproksymującego wg GMDH rozpatrywano $K=45$ wierszy wstecz od chwili bieżącej.

Dla 800 kolejnych kroków uzyskano modelowaną zgodność predykcji w pierwszym i drugim kroku w 429 przypadkach, spośród których 237 (55,2%) otwartych pozycji dało sukces a 192 porażkę.

Po każdym k kroku mierzono zwrot (w pipsach).

$$z_k = (y_k - y_{k-1}) \cdot \text{sign}(p_k^{k-1}) \quad (11)$$

Zapis (11) oznacza, że wartość dodatnią (sukces) osiągnano wówczas, gdy przy otwartej pozycji długiej ($\text{sign}(p_k^{k-1}=1)$) nastąpił wzrost kursu lub przy otwartej pozycji krótkiej ($\text{sign}(p_k^{k-1} = -1)$) nastąpił spadek.

Przedstawiony na rys 4. wykres skumulowanej wartości z_k po s krokach:

$$z_k(s) = \sum_{i=1}^k z_i \quad (12)$$


osiąga wartość wskaźnika Sharpe'a równą 0.1443.

Wskaźnik Sharpe'a obliczany był jako:

$$SR = z(k) / \text{std}(z) / k \quad (13)$$

gdzie $z(k)$ – zwrot po k kroku; $\text{std}(z_k)$ – odchylenie standardowe w szeregu czasowym ze zwrotów.

Rysunek 4. Wyniki symulacji – zysk skumulowany dla 800 transakcji



Źródło: Opracowanie własne

To uproszczone formuły, nie uwzględniające stopy zwrotu wolnej od ryzyka, ale tak zdefiniowane używane są tylko w obrębie pracy, dla porównania różnych wariantów symulacji. Wykres narastaniu kapitału z rys. 4 wykazuje wyraźną stabilną tendencję wzrostu wyrażoną ilościowo przez wskaźnik Sharpe'a.

KONKLUZJE

Należy zwrócić uwagę na dobre wyniki wszystkich symulacji (także tych, z uwagi na objętość artykułu, tu niepublikowanych) pomimo niewielkiej przewagi prognoz poprawnych, co do kierunku zmiany ceny, nad błędnymi. Doszukiwać się w tym sukcesie należy pozytywnego wpływu istoty metody – prognozuje ona nie tyle kierunek zmian, ile rzeczywiste wartości kursu po jednym lub dwu krokach. Stąd zapewne błędy (co do kierunku) mają zdecydowanie mniejszy wpływ negatywny na wynik końcowy, niż pozytywny wpływ poprawnych predykcji. Te liczne przegrane są po prostu średnio mniejsze, niż liczne wygrane. Np. dla badań przedstawionych na rys. 4 średnia przegrana wynosiła 6 pipsów a średnia wygrana aż 14 pipsów. Sytuacje te można interpretować jako dobrą ekstrakcję tendencji rynku na

podstawie kontekstu behawioralnego. Zamiary uczestników rynku dają się często poprawnie odwzorować poprzez złożone nieliniowe modele wielomianowe.

Podsumowując wyniki przeprowadzonych symulacji, należy uznać je za bardzo obiecujące. Uzyskane są na największym pod względem obrotów światowym rynku, na najbardziej płynnej parze walutowej. Zagrożeniem dla ewentualnego handlu automatycznego zbudowanego na zaprezentowanej koncepcji może być jedynie stabilność dostępu do danych o zachowaniach inwestorów, zależna wyłącznie od woli zarządzających platformą brokerską.

BIBLIOGRAFIA

- Barberis N., Shleifer A. Vishny R. A model of investor sentiment. *Journal of Financial Economics* 49 (1998), str.307-343
- DeBontd W., Thaler R. Does the stock market overreact? *Finance of Journal* 40(3) 1985, str.793-805
- Dehuri S., Cho S.-B. Multicriterion Pareto based particle swarm optimized polynomial neural network for classification: A review and state-of-the-art. *Computer Science Review* 3(2009) str.19-40.
- Fama E.F. Market efficiency, long-term returns, and behavioral finance. *Journal of Financial Economics* 49 (1998) str.283-306
- Hia Jong Teoh, Tai Liang Chen, Ching Hsue Cheng, Hsing Hui Chu. A hybrid multi-order fuzzy time series for forecasting stock markets. *Expert Systems with Applications* 36 (2009) str. 7888-7897
- Ivakhnenko A., Ivakhnenko G., Mueller J. Self- organization of Neural Network with Active Neurons. *Pattern Recognition and Image Analysis* 1999 v.4/2 str.185-196
- Ivakhnenko A., Ivakhnenko G., Problems of Further Development of the Group Method of Data Handling Algorithms. Part I. *Pattern Recognition and Image Analysis* vol.10 No.2, 2000, str.. 187-194
- Lemke F., Mueller J. A. Self- Self- Organizing Data Mining A Portfolio Trading System. *Journal of Computational Intelligence in Finance*, 1997/05 str. 12-26
- Madala H.R, Ivakhnenko A., *Inductive Learning Algorithms for Complex Systems Modeling*. CRC Press, 1994.
- Park B.J., Oh S.K., Ahn T.C., Pedrycz W. A study on multilayer fuzzy polynomial interference system based on an extended GMDH algorithm. *Proc. 8th IEEE Inf. Conference on Fuzzy Systems*, Seoul 1999.
- Piper J. *The Way to Trade*, Harriman Modern Classic, 2006.
- Sheng-Hsun Hsu, Po-An Hsieh, Ting-Chih Chih, Kuei-Chu Hsu. A two-stage architecture for stock price forecasting by integrating self-organizing map and support vector regression. *Expert Systems with Applications* 36(2009) 7947-7951
- Shleifer A. *An inefficient market: An introduction to behavioral finance*. Clarendon Lectures. Oxford University Press 2000.

Sung-Kwun Oh, Pedrycz W. The design of self-organizing Polynomial Neural Networks. *Information Sciences*, 141 (2002) str. 237-258

Wilinski A. GMDH Based Computational Intelligence Method for Prediction of Financial Markets. "Intellectual Systems of Decision Making and The Problems of Computational Intelligence (ISDMCI'2008)", Eupatoria, Tom 1 cz.1, 2008.

Wiliński A., Czapiewski P. GMDH-based Multiple Prediction of Financial Markets. *Polish Journal of Environmental Studies* vol.18 No 4a, 2008.

Zhang Yudong, Wu Lenan. Stock market prediction of S&P 500 via combination of improved BCO approach and BP neural network. *Expert Systems with Applications* 36(2009) str. 8849-8854.

Oanda, www.oanda.com dostęp kwiecień – listopad 2008.

Wanadoo, www.wanadoo.com dostęp lipiec 2008.

Prediction efficiency investigation of GMDH-class model based on behaviour of currency market users.

Abstract: The paper presents the results of an experiment concerning prediction of the foreign exchange market. It was assumed, that the market is not efficient and that it is possible to extract from the past the knowledge regarding traders' mistakes. A modified version of GMDH method was used for prediction, which allows for successive selection of such nonlinear polynomial model, that describes the market most adequately at a particular moment. Presented results confirm usefulness of the proposed method. Input data was comprised of the information on traders behaviour, registered by the brokerage platform, regarding open positions and orders. Hence, such a solution can be thought of as behavioural modelling.

Keywords: investors' behaviour, behavioural finance, regression models, GMDH, brokerage platforms, efficient market