

**Paweł Sewastjanow, Ludmiła
Dymowa, Paweł Bartosiewicz**

**System informatyczny symulujący
proces decyzyjny na rynku
kapitałowym za pomocą syntezy
logiki rozmytej i teorii świadectw**

Studia i Prace Wydziału Nauk Ekonomicznych i Zarządzania 9, 108-119

2008

Artykuł został opracowany do udostępnienia w internecie przez Muzeum Historii Polski w ramach prac podejmowanych na rzecz zapewnienia otwartego, powszechnego i trwałego dostępu do polskiego dorobku naukowego i kulturalnego. Artykuł jest umieszczony w kolekcji cyfrowej bazhum.muzhp.pl, gromadzącej zawartość polskich czasopism humanistycznych i społecznych.

Tekst jest udostępniony do wykorzystania w ramach
dozwolonego użytku.

PAWEŁ SEWASTJANOW
LUDMIŁA DYMOWA
PAWEŁ BARTOSIEWICZ

SYSTEM INFORMATYCZNY SYMULUJĄCY PROCES DECYZYJNY NA RYNKU KAPITAŁOWYM ZA POMOCĄ SYNTEZY LOGIKI ROZMYTEJ I TEORII ŚWIADECTW

Wstęp

Podejmowanie decyzji podczas inwestowania na rynku kapitałowym jest bardzo złożonym problemem. Trader w oparciu o pewne wskaźniki musi zdecydować kiedy otworzyć i zamknąć pozycję. Ze względu na liczbę analizowanych parametrów rynku, ciągle ich zmiany oraz dodatkowo przeszkadzające emocje i zmęczenie wzrosło zainteresowanie komputerowymi systemami wspomagającymi podejmowanie decyzji traderskich. Eliminują one negatywny wpływ emocji oraz konsekwentnie realizują założoną strategię. Jednak w tym przypadku przeniesienie sposobu myślenia z człowieka na maszynę stanowi dodatkowy problem. Do tej pory nie odkryto technologii, która w sposób idealny rozwiązywałaby ten problem, ale powstało szereg podejść opartych na metodach sztucznej inteligencji dających się zastosować w tej dziedzinie. Jako najbardziej popularne można wymienić podejścia oparte na systemach neuronowych [1], algorytmach ewolucyjnych [8,10] oraz na syntezie tych metod [6,7].

Obiecujące są pierwsze próby zastosowania elementów teorii zbiorów przybliżonych [11] w budowaniu systemów wspomagających podejmowanie decyzji traderskich [13].

Jednak mimo zastosowania czasami bardzo skomplikowanych systemów traderskich rezultaty praktyczne otrzymane za ich pomocą są raczej niezadowalające [6]. Główną tego przyczyną jest nieuwzględnienie w nich (wykluczenie z analizy) rzeczywistej logiki traderów w procesie podejmowania decyzji [4]. W

celu bardziej przejrzystego odzwierciedlenia ludzkiego wnioskowania podczas podejmowania decyzji w niniejszej pracy został zaproponowany system, który jest syntezą logiki rozmytej [9] i Teorii Świadectw Dempstera-Shafera (DST).

Połączenie tych metod pozwala uniknąć użycia sterownika rozmytego, a w wyniku tego przedstawić proces podejmowania decyzji traderskich w sposób bardziej naturalny, czyli w postaci wskaźników *Buy*, *Sell* i *Hold*.

Reguły wnioskowania rozmytego na podstawie wskaźników analizy technicznej

Wiadomo, że najbardziej istotnymi parametrami dla podejmowania decyzji na rynku kapitałowym i na podstawie których analitycy rynkowi obliczają wskaźniki analizy technicznej są ceny zamknięcia kolejnych barów, zmiana cen na kolejnych barach w ujęciu przedziałowym, tzn. z uwzględnieniem całych zakresów wahań cen w ciągu poszczególnych barów, wielkość obrotu (wolumenu) na kolejnych barach.

Dlatego kryteria lokalne podejmowania decyzji zbudowano na podstawie trzech głównych parametrów:

- Różnica cen zamknięcia $\Delta C = C_0 - C_1$, gdzie: C_0 to cena zamknięcia ostatniego baru, C_1 to cena zamknięcia poprzedniego baru.
- Różnica cen w ujęciu przedziałowym

$$\Delta B = B_0 - B_1 = [L_0, H_0] - [L_1, H_1] = [L_0 - H_1, H_0 - L_1],$$

gdzie: B_0 to przedział $[L_0, H_0]$ ograniczony cenami minimalną i maksymalną ostatniego baru, B_1 to przedział $[L_1, H_1]$ ograniczony cenami minimalną i maksymalną poprzedniego baru. Ponieważ użycie przedziału ΔB jako parametru jakości jest dość utrudnione, zamiast niego w systemie zastosowano centrum przedziału ΔB :

$$\varepsilon = \frac{L_0 - H_1 + H_0 - L_1}{2}.$$


- Różnica wielkości obrotu $\Delta V = V_0 - V_1$, gdzie: V_0 to wielkość obrotu ostatniego baru, V_1 to wielkość obrotu poprzedniego baru.

Trader podejmując decyzje zwraca uwagę na wielkości opisanych powyżej parametrów. W porównaniu do ich poprzednich wartości określa czy są one wysokie, niskie, umiarkowane. Następnie według własnego schematu reaguje na zaistniałe sytuacje. Przykładowo: „jeśli ΔC jest duże i ΔV jest duże to kupuj”. Przy pomocy logiki rozmytej możemy określić lingwistyczne „mały”,

„średni”, „duży” przedstawić w formie matematycznej. W tym celu wykorzystuje się funkcje przynależności, które odwzorowują wartości wejściowe na wartości z przedziału $[0,1]$. Odwzorowanie reprezentuje stopień przynależności wartości wejściowej do określenia lingwistycznego, które przedstawia funkcja.

Dla każdego z przedstawionych parametrów zaproponowano trzy oceny lingwistyczne: Low, Medium i Big. Dodatkowo dla wskaźników ΔC i ε zdecydowano się odróżnić, czy wartość wskaźnika przedstawia spadek czy wzrost cen, dlatego dla tych wskaźników ustalono pary określeń lingwistycznych w zależności od znaku wartości wejściowej. Dla $\Delta C > 0$ są to: Low_B , $Medium_B$, Big_B , a dla $\Delta C < 0$: Low_S , $Medium_S$, Big_S .

Jako przykład, na rys. 1 przedstawiono funkcje przynależności dla ocen lingwistycznych wartości wskaźnika ΔC . Analogiczne zbudowano funkcje przynależności dla wskaźników ε i ΔV .



Rys. 1. Funkcje przynależności dla „ ΔC jest Low_B ”, itd.

Jak widać, w systemie zastosowano trójkątne funkcje przynależności, co związane z dodatkowym problemem oszacowania wartości granicznych ΔC_{min} , ΔC_{max} (oraz ε_{min} , ε_{max} , ΔV_{min} , ΔV_{max}). Ze względu na zmienność rynku wykorzystano wartości zmieniające się w czasie – minimalne i maksymalne wartości wskaźników z ostatnich k barów, gdzie k to parametr systemu wymagający optymalizacji.

Po ustaleniu funkcji przynależności należy zbudować reguły, na podstawie których będzie możliwe określenie, czy sytuacja przemawia za podjęciem decyzji kupna (*Buy*), sprzedaży (*Sell*), czy wstrzymaniem się od jakichkolwiek działań (*Hold*). W praktyce sytuacja jest jednak bardziej skomplikowana. W różnych przypadkach trader może wahać się pomiędzy decyzją *Buy/Sell* a wstrzymaniem się – *Hold*. Takie sytuacje będą oznaczone jako *Buy i Hold* oraz *Sell i Hold*.

Dlatego utworzono zbiór 36 reguł (R_1 - R_{36}) wnioskowania rozmytego. Przykładowo reguły R_1 , R_3 , R_{20} , R_{21} zostały zdefiniowane następująco:

R_1 : jeśli ΔC jest Big_B^C i ΔV jest Big^V to Buy,

R_3 : jeśli ΔC jest Big_B^C i ΔV jest Low^V to (Buy i Hold),

R_{20} : jeśli ΔC jest Big_S^C i ΔV jest $Medium^V$ to Sell,

R_{21} : jeśli ΔC jest Big_S^C i ΔV jest Low^V to (Sell i Hold).

Metoda budowania reguł odzwierciedla proste rozumowanie: jeśli ΔC lub ε przedstawiają wzrost cen (są większe od 0) i są duże to kupujemy, jeśli ΔC lub ε wskazują na spadek cen (są mniejsze od 0) i są duże to sprzedajemy, ale zawsze patrzymy na wielkość ΔV , która weryfikuje siły sygnałów ΔC lub ε . Gdy ΔC lub ε zbliżają się do wartości 0, bądź gdy ΔV zbliża się do wartości minimalnej to zaczynamy się coraz bardziej wahać, a nawet wstrzymujemy się od podjęcia jakichkolwiek decyzji kupna bądź sprzedaży.

W zgodności z ogólnymi zasadami logiki rozmytej określimy operator „i” jako funkcję *min*.

Reprezentacja reguł wnioskowania rozmytego w duchu teorii świadectw Dempstera-Shafera

Z analizy merytorycznej systemu reguł R_1 - R_{36} wynika, że wartości poprzedników (części „jeśli”) mogą być w sposób naturalny potraktowane jako moce świadectw na korzyść decyzji *Buy*, *Sell*, *Hold*, lub jako prawdopodobieństwa trafności (słuszności) tych decyzji. Innymi słowy, mogą one być potraktowane w ramach teorii świadectw Dempstera-Shafera (*DST*) jako elementy bazowego rozkładu prawdopodobieństwa (*basic probability assignment-bpa*). Takie podejście daje dodatkowe możliwości analityczne dla rozwiązywania sformułowanego problemu rozmytego wnioskowania w procesie podejmowania decyzji kupna i sprzedaży, np. w odróżnieniu od klasycznej teorii prawdopodobieństwa, w *DST* elementy *bpa* mogą być przypisane zarówno pojedynczym zdarzeniom (*Buy*, *Sell*, *Hold*), jak i grupom zdarzeń (*Buy* i *Hold*, *Sell* i *Hold*).

Opiszemy pokrótce niektóre podstawowe pojęcia *DST* potrzebne w dalszej analizie [2,3,12].

Teoria Dempstera-Shafera może być traktowana jako uogólnienie teorii prawdopodobieństwa Bayesa i jednocześnie teorii możliwości Zadeha. W teorii *DST* stopnie pewności oraz możliwości można przypisywać zarówno pojedynczym zdarzeniom jak i grupom zdarzeń. Prawdopodobieństwo grupy może być nawet niższe od prawdopodobieństwa jednego zdarzenia.

Podstawowe pojęcia DST:

Przestrzeń rozważań Θ (*frame of discernment*) jest zbiorem wszystkich hipotez. $\Theta = \{h_1, h_2, \dots\}$

Podstawowe przyporządkowanie prawdopodobieństwa (*bpa - basic probability assignment*) dla Θ jest funkcją $m: 2^\Theta \rightarrow [0,1]$ taką, że $m(\emptyset) = 0$, $\sum_{x \in 2^\Theta} m(x) = 1$, gdzie \emptyset jest zbiorem pustym.

Elementy ogniskowe (*focal elements*) są to takie podzbiory Θ , dla których podstawowe przyporządkowanie prawdopodobieństwa ma wartość większą od 0, $m(A) > 0$.

Funkcja pewności jest miarą wiarygodności poszlak przemawiających na rzecz B. Dla każdego $B \subseteq \Theta$:

$$Bel(B) = \sum_{i=1}^n m(A_i), A_i \subseteq B, i=1, \dots, n, Bel(\emptyset) = 0, Bel(\Theta) = 1.$$

Funkcja możliwości jest miarą wiarygodności poszlak przemawiających nie przeciwko B.

Dla każdego $B \subseteq \Theta$:

$$Pl(B) = \sum_{i=1}^n m(A_i), A_i \cap B \neq \emptyset, i=1, \dots, n, Pl(\emptyset) = 1, Pl(\Theta) = 1.$$

Z definicji wynika, że $0 \leq Bel \leq Pl \leq 1$.

Przedział pewności (*belief interval*) reprezentuje pewność (niepewność) danego zdania $[Bel(A), Pl(A)]$. Przedział ten odpowiada pewności wiedzy o stopniu prawdziwości danego zdania. Jeżeli nie posiadamy żadnych informacji na temat jakiegoś zdania A, to przedział jest równy $[0,1]$. Im więcej będziemy mieli informacji na jego temat, tym węższy będzie przedział.

Nietrudno zauważyć, że w naszym przypadku przestrzeń rozważań składa się z pięciu hipotez (możliwych decyzji): *Buy, Sell, Buy i Hold, Sell i Hold, Hold*.

Używając metodologii i podstawowych pojęć DST reguły R_1 - R_{36} możemy przedstawić w formie podstawowego przyporządkowania prawdopodobieństwa. Na przykład, regułem R_1, R_3, R_{20}, R_{21} zostały przekształcone w formę:

$$m_{1BUY} = \min(\mu_{BIG_B}^C, \mu_{BIG}^V), m_{3BUY i HOLD} = \min(\mu_{BIG_B}^C, \mu_{LOW}^V),$$

$$m_{20SELL} = \min(\mu_{BIG_S}^C, \mu_{MEDIUM}^V), m_{21SELL i HOLD} = \min(\mu_{BIG_S}^C, \mu_{LOW}^V).$$

Oczywiście ostateczne moce świadectw na korzyść decyzji *Buy*, *Sell*, *Buy i Hold*, *Sell i Hold*, *Hold* możemy obliczyć jako sumy odpowiednich lokalnych świadectw. Przy tym sumujemy wartości świadectw opartych na różnicy cen zamknięcia i różnicy cen w ujęciu przedziałowym. Jednak w praktyce świadectwa oparte na różnicy cen zamknięcia i na różnicy cen w ujęciu przedziałowym mogą okazać się nierównoważne dla różnych traderów. Dlatego zastosowaliśmy metodę agregacji świadectw pochodzących z różnych źródeł [5], w zgodności z którą, w obliczeniach sumarycznych świadectw wprowadziliśmy dodatkowy parametr α ($0 \leq \alpha \leq 2$), który podlega optymalizacji i odzwierciedla względną ważność świadectw opartych na ΔC i ε . W ten sposób otrzymano $m(\text{Buy})$, $m(\text{Sell})$, $m(\text{Buy i Hold})$, $m(\text{Sell i Hold})$. Ponieważ wartości $m(\text{Buy})$, $m(\text{Sell})$, $m(\text{Buy i Hold})$, $m(\text{Sell i Hold})$ generalnie nie spełniają podstawowego dla *bpa* warunku $\sum_{x \in 2^\Theta} m(x) = 1$, użyliśmy dodatkowej procedury skalowania pozwalają-

cej wykorzystać reguły logiki rozmytej w duchu *DST*.

Na podstawie przedstawionych wcześniej wzorów i podstawowych definicji *DST* otrzymujemy miary pewności i możliwości dla decyzji *Buy*, *Sell* i *Hold*:

$$\begin{aligned} Bel(\text{Buy}) &= m(\text{Buy}), \quad Pl(\text{Buy}) = m(\text{Buy}) + m(\text{Buy i Hold}), \\ Bel(\text{Sell}) &= m(\text{Sell}), \quad Pl(\text{Sell}) = m(\text{Sell}) + m(\text{Sell i Hold}), \\ Bel(\text{Hold}) &= m(\text{Hold}), \\ Pl(\text{Hold}) &= m(\text{Hold}) + m(\text{Buy i Hold}) + m(\text{Sell i Hold}). \end{aligned}$$

Otrzymaliśmy zatem po dwie różne przesłanki mówiące o mocy decyzji *Buy*, *Sell* i *Hold*. W celu otrzymania łatwiejszych w interpretacji wskaźników postanowiliśmy zagregować wartości funkcji pewności i możliwości z uwzględnieniem ich względnej ważności:

$$\begin{aligned} Buy &= \beta \cdot Bel(\text{Buy}) + (1 - \beta) \cdot Pl(\text{Buy}), \\ Sell &= \beta \cdot Bel(\text{Sell}) + (1 - \beta) \cdot Pl(\text{Sell}), \\ Hold &= \beta \cdot Bel(\text{Hold}) + (1 - \beta) \cdot Pl(\text{Hold}), \end{aligned}$$

gdzie β ($0 \leq \beta \leq 1$) to dodatkowy parametr systemu, który podlega optymalizacji.

Kolejnym krokiem przygotowania systemu było określenie metody decydowania o zakupie i sprzedaży na podstawie otrzymanych wskaźników *Buy*, *Sell* i *Hold*. Na podstawie wstępnej analizy zdecydowaliśmy się na sposób wy-

korzystający dwie średnie kroczące: n -okresową krótkoterminową i m -okresową długoterminową ($1 < n < m$) obliczane dla naszych wskaźników. Średnie kroczące obliczamy ze wzorów:

$$\begin{aligned} Buy_{sr}^n &= \frac{\sum_{i=1}^n Buy_i}{\sum_{i=1}^n Buy_i + \sum_{i=1}^n Sell_i + \sum_{i=1}^n Hold_i}, & Buy_{sr}^m &= \frac{\sum_{i=1}^m Buy_i}{\sum_{i=1}^m Buy_i + \sum_{i=1}^m Sell_i + \sum_{i=1}^m Hold_i}, \\ Sell_{sr}^n &= \frac{\sum_{i=1}^n Sell_i}{\sum_{i=1}^n Buy_i + \sum_{i=1}^n Sell_i + \sum_{i=1}^n Hold_i}, & Sell_{sr}^m &= \frac{\sum_{i=1}^m Sell_i}{\sum_{i=1}^m Buy_i + \sum_{i=1}^m Sell_i + \sum_{i=1}^m Hold_i}, \\ Hold_{sr}^n &= \frac{\sum_{i=1}^n Hold_i}{\sum_{i=1}^n Buy_i + \sum_{i=1}^n Sell_i + \sum_{i=1}^n Hold_i}, & Hold_{sr}^m &= \frac{\sum_{i=1}^m Hold_i}{\sum_{i=1}^m Buy_i + \sum_{i=1}^m Sell_i + \sum_{i=1}^m Hold_i}. \end{aligned}$$

Decyzję kupna (otwarcie długiej pozycji) podejmujemy, gdy wskaźniki Buy_{sr}^n i Buy_{sr}^m rosną oraz jest to poparte wzrostem ceny zamknięcia ($\Delta C > 0$). Dodatkowym warunkiem otwarcia pozycji jest, aby różnica ceny maksymalnej i ceny minimalnej baru nie przekroczyła 70% szerokości l -okresowej Wstęgi Bollingera. Długość okresu l stała się parametrem systemu i podlega optymalizacji. Pozycję zamykamy w przypadkach:

- Buy_{sr}^n przecięła od góry Buy_{sr}^m ,
- Buy_{sr}^n stała się mniejsza od wartości granicznej obliczonej w momencie otwarcia pozycji ze wzoru: $Buy_{gr}^n = Buy_{sr1}^n - (Buy_{sr0}^n - Buy_{sr1}^n)$, gdzie: Buy_{sr0}^n to wartość krótkoterminowej średniej kroczącej wskaźnika Buy ostatniego baru, Buy_{sr1}^n to wartość krótkoterminowej średniej kroczącej wskaźnika Buy poprzedniego baru,
- cena spadła poniżej wartości zwykłego stopu startowego SL (*Stop Loss*), bądź stopu kroczącego TS (*Trailing Stop*), gdzie: $SL = TS = C_0 - stop$. Wartość $stop$ to parametr systemu i podlega optymalizacji,
- cena zamknięcia przekroczyła wartość zysku TP (*Take Profit*), gdzie: $TP = C_0 + take$. Podobnie wartość $take$ jest parametrem systemu i podlega optymalizacji,

- różnica ceny maksymalnej i ceny minimalnej baru przekroczyła wartość graniczną *rozp* oraz cena zamknięcia uległa spadkowi. Wartość *rozp* również jest parametrem systemu i podlega optymalizacji.

Sposób otwierania i zamykania pozycji krótkiej (sprzedaży) jest analogiczny.

Optymalizacja i testowanie systemu

Do optymalizacji i testowania systemu wykorzystano system *WealthLab* wyposażony w rzeczywiste dane historyczne notowań kontraktu terminowego na indeks WIG20 Giełdy Papierów Wartościowych w Warszawie. Jako kryterium optymalizacji przyjęto zysk w punktach, jaki zarabiałby jeden kontrakt. Optymalizowanymi parametrami systemu były: k – głębokość poszukiwania minimalnych i maksymalnych wartości wskaźników; α – względna ważność świadectw opartych na różnicy cen zamknięcia i na różnicy cen w ujęciu przedziałowym; β – względna ważność miary pewności i miary możliwości; n – okres krótkoterminowych średnich kroczących wskaźników *Buy*, *Sell* i *Hold*; m – okres długoterminowych średnich kroczących wskaźników *Buy*, *Sell* i *Hold*; l – okres Wstęgi Bollingera; *stop* – wartość ograniczenia ryzyka zleceń *Stop Loss*, *Trailing Stop*; *take* – wartość zysku zlecenia *Take Profit*; *rozp* – graniczna rozpiętość cen pojedynczego baru.

Pierwszą fazę testu przeprowadzono na horyzoncie 30 minutowym (czas, który obejmuje pojedynczy bar). Długość okresu optymalizacyjnego dobrano tak, aby liczba przeprowadzonych w nim transakcji przez system była około 100. Czasem takim okazało się 9 tygodni. Jako procedurę optymalizacji wybrano metodę Monte Carlo, której zadaniem było znaleźć takie parametry systemu, aby zmaksymalizować kryterium optymalizacji. W praktyce rynek zmienia się gwałtownie, ponieważ schematy zachowań animatorów rynku często ulegają zmianie, dlatego okres testujący musi być zdecydowanie krótszy – przyjęliśmy 2 tygodnie. Z tego względu przeprowadzono kilka optymalizacji i testów w następujący sposób: wybrano 9 tygodni danych historycznych jako okres uczący; przetestowano na następujących po nich 2 tygodniach; następny okres optymalizacyjny zbudowano z 7 ostatnich tygodni poprzedniego okresu uczącego i dodano do nich cały poprzedni okres testujący (2 tygodnie), kolejny okres testujący to następne 2 tygodnie danych historycznych. Tą procedurę powtarzano, aby budować kolejne okresy uczące i testujące.

Wyniki pierwszej fazy testowania przedstawiono w tabeli 1. Wyniki wskazują, że system po optymalizacji jest w stanie przynosić dochody. Niestety w dwóch okresach testujących przyniósł straty. Przyczyny mogą być różne: we wspomnianych okresach rynek stał się nieprzewidywalny (zawodził wszystkie systemy), diametralnie zmieniła się sytuacja w stosunku do okresu uczącego, bądź nie odnaleziono maksimum globalnego w drodze optymalizacji Monte Carlo.

Tabela 1. Wyniki działania systemu w okresach testujących dla 30 minutowego horyzontu czasowego.

Okres Testujący	03.12.2007	17.12.2007	31.12.2007	14.01.2008	28.01.2008
	14.12.2007	28.12.2007	11.01.2008	25.01.2008	08.02.2008
Zysk, zł	203	-340	-60	124	199
Liczba Transakcji	24	18	17	33	27
Skuteczność, %	62,5	22,22	47,05	45,45	66,67

Źródło: opracowanie własne.

Oznacza to, że w przypadku „rzeczywistej gry” na giełdzie należy mieć przygotowane odpowiednie procedury postępowania na wypadek, gdy system zawodzi. Można na przykład obserwować liczbę następujących po sobie błędnych transakcji i wstrzymać działanie systemu, gdy zostanie przekroczona założona wartość graniczna.

Drugi etap testowania przeprowadzono na horyzoncie 15 minutowym. Zastosowano dokładnie taką samą metodę optymalizacji i testowania. Skrócono tylko długość okresu uczącego z 9 do 6 tygodni, ponieważ w takim czasie system generował około 100 transakcji. Wyniki tej fazy testów przedstawiono w tabeli 2.

Tabela 2. Wyniki działania systemu w okresach testujących dla 15 minutowego horyzontu czasowego.

Okres Testujący	03.12.2007	17.12.2007	31.12.2007	14.01.2008	28.01.2008
	14.12.2007	28.12.2007	11.01.2008	25.01.2008	08.02.2008
Zysk, zł	64	-61	-91	-116	116
Liczba Transakcji	37	42	43	51	50
Skuteczność, %	54,05	42,86	48,84	37,25	52

Źródło: opracowanie własne.

Wyniki testowania systemu na horyzoncie 15 minutowym w porównaniu do wyników z poprzedniej próby wskazują, że do obecnej sytuacji na rynku

bardziej pasują 30 minutowe bary. Mimo to korzystne jest sprawdzanie, czy optymalizacja na tym horyzoncie czasowym daje oczekiwane wyniki, ponieważ rynek może się zmienić. Daje to także możliwość dywersyfikacji kapitału (można grać wykorzystując dwa, bądź więcej, wariantów systemu).

Zadaniem kolejnego testu było odpowiedzieć na pytanie, czy system zwracający najwyższy zysk w okresie uczącym będzie najlepiej spisywał się w okresie testującym. W tym celu wykonano kilkakrotnie optymalizację parametrów systemu na okresie od 01.10.2007 do 30.11.2007 i porównano ze sobą uzyskane w ten sposób „warianty systemu” w czasie od 03.12.2007-14.12.2007. Zastosowany horyzont czasowy to 30 minut. Wyniki przedstawiono w tabeli 3:

Tabela 3. Wyniki działania systemu z różnymi zestawami parametrów w okresie testującym od 03.12.2007 do 14.12.2007.

	Wariant 1	Wariant 2	Wariant 3	Wariant 4	Wariant 5
Zysk w okresie uczącym, zł	945	724	673	725	825
Zysk w okresie testującym, zł	203	-21	-16	120	105
Liczba Transakcji	24	16	18	20	18
Skuteczność, %	62,5	56,25	50	60	61,11

Zródło: opracowanie własne.

Wariant systemu, który w okresie uczącym osiągnął najwyższy zysk, okazał się w tym przypadku najlepszym również w okresie testującym. Wskazuje to, że warto poszukiwać maksimum globalnego, pomimo dużej ilości parametrów optymalizacji.

Podsumowanie

W oparciu o logikę rozmytą i teorię Dempstera-Shafera utworzony został system, który na wyjściu generuje trzy sygnały *Buy*, *Sell* i *Hold*. Poprzez krótkoterminowe i długoterminowe wygładzenie tych sygnałów opracowano taktykę podejmowania decyzji kupna i sprzedaży. Niewątpliwą zaletą systemu jest możliwość optymalizacji na danych historycznych, co pozwala dostosować go do specyfiki danego rynku. W przeprowadzonych testach system pokazał, że jest w stanie przynosić znaczne dochody. Jednak testy wykazały także jego wady: wrażliwość na zmiany sytuacji na rynku oraz wrażliwość na zmiany parametrów systemu, co wymusza na traderze ciągłego nadzorowania systemu.

Literatura

1. Baba N., Kozaki M., An intelligent forecasting system of stock price using neural networks. Proceedings of IJCNN'92, 1992.
2. Dempster A. P., *A generalization of Bayesian inference* (with discussion). J. Roy. Stat. Soc. 30, 1968.
3. Dempster A. P., Upper and lower probabilities induced by a multi-valued mapping. Ann. Math. Stat. 38, 1967.
4. Dourra H., Siy P., *Investment using technical analysis and fuzzy logic*. Fuzzy Sets and Systems, 2002, 127.
5. Ferson S., Sentz K., Combination of Evidence in Dempster-Shafer Theory. SANDIA Report, 2002, 25.
6. Kim K. J., Han I., Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index. Expert Systems with Applications, 2000, 19.
7. Kuo R. J., Chen C. H., Hwang Y. C., An intelligent stock trading decision support system through integration of genetic algorithm based fuzzy neural network and artificial neural network. Fuzzy Sets and Systems, 2001, 118.
8. Mahfoud S., Mani G., Financial forecasting using genetic algorithms. Applications of Artificial Intelligence, 1996, 10.
9. Mamdani E., Assilian S., An experiment in linguistic synthesis with a fuzzy logic controller. Int. J. Mach. Studies, 1975, 1.
10. Mehta K., Bhattacharyy S., Adequacy of training data for evolutionary mining of trading rules. Decision Support Systems, 2004, 37.
11. Pawlak Z., Rough Sets. International Journal of Information and Computer Science, 1982, 11.
12. Shafer G., *A mathematical theory of evidence*, Princeton University Press, 1976.
13. Shen L., Loh H. T., *Applying rough sets to market timing decisions*, Decision Support Systems, 2004, 37.

STRESZCZENIE

Przedstawiono system informatyczny symulujący zoptymalizowany proces podjęcia decyzji na rynku kapitałowym. W opracowaniu systemu użyto syntezy różnych metod: tradycyjnych wskaźników analizy technicznej, metod wielokryterialnych, metod logiki rozmytej oraz teorii świadczeń Dempstera–Shafera. Zastosowanie takiej syntezy metod pozwala zbudować system optymalizujący podjęcie decyzji kupna i sprzedaży

aktywów w sposób najbardziej naturalnie odzwierciedlający charakter myślenia osób zajmujących się profesjonalną działalnością na giełdzie papierów wartościowych. Ostateczne zagadnienie sformułowane zostało jako problem optymalizacji w warunkach niepewności. Efektywność opracowanego systemu sprawdzona została na rzeczywistych danych. W tym celu wykorzystano notowania kontraktu terminowego na indeks WIG20 Giełdy Papierów Wartościowych w Warszawie. Do optymalizacji i testowania systemu wykorzystano dane z okresu od października 2007 r. do lutego 2008 r.

**A COMPUTER BASED SYSTEM SIMULATING DECISION MAKING
PROCESS IN THE STOCK MARKET WITH USE OF THE SYNTHESIS
OF FUZZY LOGIC AND DEMPSTER-SHAFER THEORY OF
EVIDENCE**

SUMMARY

A computer based system simulating optimized decision making process in the stock market is presented. The synthesis of different methods such as technical analysis, multiple-criteria decision making, fuzzy logic and Dempster–Shafer theory of evidence is used. This synthesis allows to build a system which optimizes the trading decisions reflecting the trader’s type of reasoning in a natural way. Finally, the problem is formulated as the task of optimization under uncertainty conditions. The efficacy of the elaborated system is proved using the real quotation of futures on index WIG20 of the Warsaw Stock Exchange. The data from November of 2007 to February of 2008 have been used for optimization and testing of the system.

Translated by P. Sewastjanow

Prof. dr hab. inż. Paweł Sewastjanow
Politechnika Częstochowska
sevast@icis.pcz.pl

Dr hab. inż. prof. P. Cz. Ludmiła Dymowa
Politechnika Częstochowska
dymowa@gmail.com

Mgr inż. Paweł Bartosiewicz
Politechnika Częstochowska