



Instytut Badań Systemowych

Polskiej Akademii Nauk

Seria:

BADANIA SYSTEMOWE

TOM 65

Redaktor Naukowy

Prof. dr hab. inż. Jakub Gutenbaum

Rada Redakcyjna:

1. Prof. dr hab. inż. Olgierd Hryniewicz – *przewodniczący*
2. Prof. dr hab. inż. Jakub Gutenbaum – *redaktor naukowy*
3. Prof. dr hab. inż. Janusz Kacprzyk
4. Prof. dr hab. inż. Tadeusz Kaczorek
5. Prof. dr hab. inż. Roman Kulikowski
6. Doc. dr hab. inż. Marek Libura
7. Prof. dr hab. inż. Krzysztof Malinowski
8. Prof. dr hab. inż. Zbigniew Nahorski
9. Dr. hab. inż. Marek Niezgódka, prof. UW
10. Prof. dr hab. inż. Roman Słowiński
11. Doc. dr hab. inż. Jan Studziński
12. Prof. dr hab. inż. Stanisław Walukiewicz
13. Prof. dr hab. inż. Andrzej Weryński
14. Doc. dr hab. inż. Antoni Żochowski



Instytut Badań Systemowych
Polskiej Akademii Nauk

Antoni Wiliński

**GMDH – metoda grupowania argumentów
w zadaniach zautomatyzowanej predykcji
zachowań rynków finansowych**

Warszawa - Szczecin

Copyright © by Instytut Badań Systemowych PAN
Warszawa 2009

*Dr hab. inż. Antoni Wiliński – prof. nadzw.
Zachodniopomorski Uniwersytet Technologiczny w Szczecinie
Wydział Informatyki
Ul. Żołnierska 49, Szczecin 71-210
Tel. 091- 449 5660 ; fax 091-449 5540*

Autor jest profesorem Zachodniopomorskiego Uniwersytetu Technologicznego, poprzednio Politechniki Szczecińskiej. Habilitację uzyskał na Politechnice Warszawskiej w zakresie automatyki i robotyki. W obecnej kadencji jest dziekanem Wydziału Informatyki ZUT. Od lat zajmuje się problematyką inteligencji obliczeniowej i rozpoznawania wzorców w szeregach czasowych w celach predykcyjnych lub modelowania rzeczywistości. W Katedrze Systemów Multimedialnych, której jest kierownikiem, prowadzone są badania nad webowym systemem handlu automatycznego. Rozważane są rozmaite strategie analizy technicznej specyficzne dla decyzji podejmowanych z wysoką częstotliwością przez infoboty. Wśród tych strategii istotną rolę odgrywają omawiane tu algorytmy oparte na GMDH (Group Method of Data Handling). Praca przeznaczona jest raczej dla specjalistów będących zwolennikami analizy technicznej.

Recenzenci:

Prof. dr hab. inż. Zbigniew Banaszak
Doc. dr hab. inż. Maciej Krawczak

Redaktor techniczny:

Dr inż. Anna Samborska-Owczarek

Powyższej książki w całości lub części nie wolno powielać ani przekazywać w żaden sposób, nawet za pomocą nośników mechanicznych i elektronicznych (np. zapis magnetyczny), w tym też umieszczać ani rozpowszechniać w postaci cyfrowej zarówno w Internecie, jak i w sieciach lokalnych, bez uzyskania pisemnej zgody posiadacza praw autorskich.

ISBN 9788389475237
ISSN 0208-8029

Spis rysunków

Rys. 1. Schemat blokowy procesu powstawania hipotez badawczych dotyczących koncepcji strategii inwestycyjnych. Źródło: opracowanie własne.

Rys. 104. Schemat blokowy procesu opracowywania wymagań dla systemu tradingu automatycznego. Źródło: opracowanie własne.

Rys. 3. Okno „przesuwane” po macierzy danych historycznych X i Y . Źródło: opracowanie własne.

Rys. 4. Wzajemne ułożenie wektorów zmiennych x_i przesuniętych o $k=1,2, \dots, k$ oraz wektora wyników $y_j, j = t-k, \dots, t$. Źródło: opracowanie własne.

Rys. 5. Przykład wzajemnego rozmieszczenia w macierzy danych nieprzesuniętego wektora zmiennej obserwowanej y i wybranych wektorów argumentów. Źródło: opracowanie własne.

Rys. 6. Wybrane wektory argumentów na tle całej dostępnej przestrzeni danych X . Możliwy do prognozowania jest tylko jeden okres zmiennej obserwowanej y . Źródło: opracowanie własne.

Rys. 7. Przebieg rzeczywistych zmian zmiennej rzeczywistej y oraz jej modelu \hat{y} dla sytuacji prognozy jeden krok wprzód (a) oraz po weryfikacji rzeczywistego odchylenia Δy (b). Źródło: opracowanie własne.

Rys. 8. Przebieg rzeczywistych y i modelowanych \hat{y} wartości zmiennej wyjściowej z zaznaczonym horyzontem predykcyjnym $hp = 2$. Źródło: opracowanie własne.

Rys. 9. Ogólny schemat sieci neuronowej generującej kolejne modele o rosnącej złożoności w kolejnych warstwach. Źródło: opracowanie własne.

Rys. 105. Schemat algorytmu kombinatorycznego GMDH z trzema warstwami neuronowymi i zbiorami modeli o licznosciach kolejno F_z, F_u, F_v jako wejściami do kolejnych warstw. Źródło: opracowanie własne.

Rys. 11. Schemat kojarzenie wejść do neuronów kolejnej warstwy oraz selekcji i sortowania modeli w warstwie wg lokalnego kryterium selekcji CR_k (k – numer warstwy). Na rysunku widać pozostawione po sortowaniu najlepsze (czarne) neurony jako wejścia do kolejnej warstwy. Źródło: opracowanie własne.

Rys. 106. Ogólny schemat jednokierunkowej wielowarstwowej sieci neuronowej, której wyjściem jest wskazanie stopnia złożoności modelu predykcyjnego. Na wejściach kolejnych warstw występują wyjścia wszystkich warstw poprzednich tak długo, aż wystąpi akceptowalna zgodność modelu (na wyjściu z ostatniego perceptronu pojawi się 1). Ten warunek na schemacie spełnia przedostatni neuron. Źródło: opracowanie własne.

Rys. 107. Schemat objaśniający kolejność obliczania modelu prognostycznego \hat{y} na podstawie współczynników A wielomianu obliczonych w pierwszym kroku i wykorzystanych w równaniu predykcji z nowymi danymi x_i i x_j . Źródło: opracowanie własne.

Rys. 108. Schemat objaśniający sposób obliczania prognozy wg algorytmu CL2. Współczynniki A_{opt} wielomianu prognostycznego obliczone są na podstawie znanych danych pierwszej warstwy oraz danych przetworzonych kolejnych warstw. Źródło: opracowanie własne.

Rys. 109. Rzeczywiste (krzywe ciągłe) i prognozowane (krzywe z punktami) w pierwszej warstwie przebiegi zmiennej wyjściowej dla horyzontu prognostycznego $h_p = 3$. Źródło: niepublikowany skrypt autora gmdhreg9pd (zagr=20, hp=3, i=800:5:805).

Rys. 16. Rzeczywiste (krzywe ciągłe wewnętrzne) i prognozowane (krzywe z punktami) przebiegi zmiennej wyjściowej przedstawione w układzie rzeczywistych (nie znormalizowanych) wartości kursu EUR/USD dla pierwszej warstwy sieci neuronowej. Źródło: niepublikowany skrypt autora gmdhreg9pd (zagr=20, hp=3, i=800:5:805).

Rys. 110. Rzeczywiste i modelowane przebiegi zmiennej wyjściowej na odcinku predykcyjnym. Widoczne są niewielkie rozbieżności w porównaniu do rys. 16. Źródło: niepublikowany skrypt autora gmdhreg9pd (zagr=20, hp=3, i=800:5:805).

Rys. 111. Rzeczywiste (ciągłe) i symulowane (przerwane) przebiegi zmiennej wyjściowej w piątej warstwie sieci neuronowej. Widać dużą zbieżność krzywych odzwierciedlających modelowane zmiany kursu z przebiegami rzeczywistymi. Źródło: niepublikowany skrypt autora gmdhreg9pd (zagr=20, hp=4, i=800:10:860).

Rys. 112. Struktura najlepszych modeli piątej warstwy sieci neuronowej dla sześciu kolejnych przypadków predykcji wykonanej co 10 okresów w szeregu czasowym świec 15 min dla pary EUR/USD. Źródło: niepublikowany skrypt autora gmdhreg9pd (zagr=20, hp=4, i=800:10:860).

Rys. 20. Schemat sieci obliczeniowej z ujawnionymi wejściami do szóstej warstwy z neuronów poprzednich warstw i także z warstwy wejściowej. Źródło: opracowanie własne.

Rys. 21. Różnicowanie struktur najlepszych modeli piątej warstwy badane co jeden krok. Źródło: niepublikowany skrypt autora gmdhreg9pd (zakr=20, hp=4, i=800:809).

Rys. 22. Badanie rozbieżności pomiędzy rzeczywistym przebiegiem zmiennej wyjściowej i prognozowanymi odcinkami o długości $hp=4$ okresy – w czwartej warstwie sieci neuronowej. Źródło: niepublikowany skrypt autora gmdhreg9pd (zakr=20, hp=4, i=1000:5:1015).

Rys. 23. Badanie rozbieżności w szóstej warstwie w dziedzinie zmiennej wyjściowej znormalizowanej (przebiegi rzeczywiste – krzywe ciągłe, przebiegi symulowane – krzywe przerywane). Źródło: niepublikowany skrypt autora gmdhreg9pd (zakr=20, hp=4, i=1000:5:1015).

Rys. 24. Wzajemnie potwierdzające się kolejne prognozy wykonywane sekwencja jedna tuż za drugą, w czwartej warstwie, na tle przebiegu rzeczywistego. Źródło: niepublikowany skrypt autora gmdhreg9pd (zakr=20, hp=4, i=1000:1005).

Rys. 25. Przebiegi średnich dokładności ΔS_s dla $S=1,2,\dots,6$ obliczone w różnych miejscach przestrzeni danych. Każda krzywa oznacza wyniki obliczone dla innej świecy początkowej. Źródło: niepublikowany skrypt autora gmdhreg9pd (zakr=20, hp=4, i=1000:1005).

Rys. 26. Najlepsze wyniki dokładności predykcji w różnych miejscach przestrzeni danych wg kryterium (2). Źródło: niepublikowany skrypt autora gmdhreg9pd (zakr=20, hp=4, i=1000:1005).

Rys. 27. Rezultaty prognozowania przebiegu zmiennej EUR/USD wykonanego za pomocą najprostszego modelu liniowego zawierającego tylko dwa najlepsze wyselekcjonowane czynniki modelu (zmienne wejściowe). Źródło: niepublikowany skrypt autora gmdhreg9sd11 (zakr=30, hp=2, i=1000:1029).

Rys. 28. Rezultaty modelowania w drugiej warstwie sieci neuronowej (za pomocą modeli zawierających 4 wyselekcjonowane czynniki). Rzeczywisty przebieg zmiennej wyjściowej to krzywa bez nieciągłości. Źródło: niepublikowany skrypt autora gmdhreg9sd11 (zakr=30, hp=2, i=1000:1029).

Rys. 29. Rezultaty modelowania w trzeciej warstwie sieci neuronowej. Rzeczywisty przebieg zmiennej wyjściowej – to czarna ciągła krzywa,

aproxymacja kilku okresów – krzywe przerywane, prognoza – krzywe żółte.

Źródło: niepublikowany skrypt autora gmdhreg9sd11 (zakr=30, hp=2, i=1000:1029).

Rys. 113. Rezultaty modelowania w czwartej warstwie. Odcinki ciągłe to rzeczywiste przebiegi, przerywane to rezultaty najlepszych aproxymacji, pojedyncze oddalone odcinki, to predykcje jeden odcinek wprzód. Źródło: niepublikowany skrypt autora gmdhreg9sd11 (zakr=30, hp=2, i=1000:1029).

Rys. 31. Wyniki symulacji w czterech warstwach sieci naniesione równocześnie na wspólny wykres. Źródło: niepublikowany skrypt autora gmdhreg9sd11 (zakr=30, hp=2, i=1000:1029).

Rys. 32. Najlepsze dwuodcinkowe przebiegi modeli trzeciej i czwartej warstwy. Źródło: niepublikowany skrypt autora gmdhreg9sd11 (zakr=30, hp=2, i=1000:1029).

Rys. 33. Średnia dokładność aproxymacji w poszczególnych warstwach sieci (1 do 4). Każda krzywa to średnia dokładność najlepszych modeli rozpoczynających się w różnych punktach przestrzeni danych. Źródło: niepublikowany skrypt autora gmdhreg9sd11 (zakr=30, hp=2, i=1000:1029).

Rys. 34. Diagram ilustrujący zmienność struktury modeli w czwartej warstwie. Źródło: niepublikowany skrypt autora gmdhreg9sd11 (zakr=30, hp=2, i=1000:1029).

Rys. 35. Wykres błędów predykcyjnych popełnionych w poszczególnych warstwach sieci (wartości absolutne). Źródło: niepublikowany skrypt autora gmdhreg9sd11 (zakr=30, hp=2, i=1000:1029).

Rys. 36. Diagram poprawności predykcji w aspekcie zgodności pierwszej pochodnej zmiennej obserwowanej y i modeli \hat{y} w każdej z 4 warstw. Źródło: niepublikowany skrypt autora gmdhreg9sd11 (zakr=30, hp=2, i=1000:1029).

Rys. 37. Diagram zmienności struktury modeli prognostycznych czwartej warstwy w badaniach z zastosowaniem kryterium opartego na odcinku predykcyjnym. Źródło: niepublikowany skrypt autora gmdhreg9sd21 (zakr=6, hp=2, i=1000:1029).

Rys. 114. Wykres błędów predykcyjnych popełnionych w symulacjach z zastosowaniem kryterium ΔS_2 . Źródło: niepublikowany skrypt autora gmdhreg9sd21 (zakr=6, hp=2, i=1000:1029).

Rys. 39. Diagram poprawności predykcji wg zgodności pierwszych pochodnych y i \hat{y} dla kryterium ΔS_2 . Źródło: niepublikowany skrypt autora gmdhregr9sd21 (zakr=6, hp=2, i=1000:1029).

Rys. 115. Struktura najlepszych modeli z kryterium minimaxowym dla 10 kolejnych przypadków. Źródło: niepublikowany skrypt autora gmdhregr9sd31 (zakr=20, hp=2, i=1000:1029).

Rys. 41. Błędy predykcji popełnione w różnych warstwach sieci obliczeniowej dla kryterium opartego na zasadzie minimalizacji maksymalnego odchylenia w odcinku uczącym. Źródło: niepublikowany skrypt autora gmdhregr9sd31 (zakr=20, hp=2, i=1000:1029).

Rys. 42. Diagram zgodności pierwszej pochodnej przebiegu rzeczywistego i modelowanego z kryterium minimaxowym. Źródło: niepublikowany skrypt autora gmdhregr9sd31 (zakr=20, hp=2, i=1000:1029).

Rys. 116. Wykresy narastania kapitału w strategii tradingowej (dla czterech warstw sieci obliczeniowej) zbudowanej z zastosowaniem kryterium ΔS_1 dla wariantu bez mechanizmu Stop Loss (lewy wykres) i z mechanizmem Stop Loss równym 0.010 (100 pipsów). Źródło: niepublikowany skrypt autora gmdhregr9sd11a.

Rys. 44. Wykresy narastania kapitału w strategii tradingowej (dla czterech warstw sieci obliczeniowej) zbudowanej z zastosowaniem kryterium ΔS_2 dla wariantu bez mechanizmu Stop Loss (lewy wykres) i z mechanizmem Stop Loss równym 0.010 (100 pipsów). Źródło: niepublikowany skrypt autora gmdhregr9sd21a.

Rys. 45. Wykresy narastania kapitału w strategii tradingowej (dla czterech warstw sieci obliczeniowej) zbudowanej z zastosowaniem kryterium ΔS_3 dla wariantu bez mechanizmu Stop Loss (lewy wykres) i z mechanizmem Stop Loss równym 0.010 (100 pipsów). Źródło: niepublikowany skrypt autora gmdhregr9sd31a.

Rys. 46. Wyniki symulacji w przestrzeni zmiennej skośności (1:6) i kurtozy (1:15). Rezultat – wynik końcowy (w skrypcie nazywany wynik) od zamknięć na barierach SL i TP oraz dopuszczalnego czasu otwarcia pozycji. Źródło: niepublikowany skrypt autora irla3k141c.

Rys. 47. Wyniki symulacji w przestrzeni zmiennej skośności (1:6) i kurtozy (1:15). Rezultat – wynik końcowy poprawiony (wynpopr) od zamknięć na barierach SL i

TP z uwzględnieniem zamknięć wskutek upływu zadanego czasu otwarcia pozycji. Źródło: niepublikowany skrypt autora irla3k141c.

Rys. 48. Wyniki symulacji w przestrzeni zmiennej skośności (1:6) i kurtozy (1:15). Rezultat – wielkości maksymalnych obsunięć (obsm). Źródło: niepublikowany skrypt autora irla3k141c.

Rys. 49. Wyniki wynik (nieb) i wynpopr (ziel) oraz obsunięcie w funkcji indykatora Lane'a dla wartości indykatora od 5 do 100. Źródło: niepublikowany skrypt autora irla3k142c.

Rys. 50. Kryteria K10 (niebieski) i K20 (cyjan) w funkcji indykatora Stochastic Oscillator Lane'a zmieniającego się od 5 do 100. Maksimum występuje dla obu kryteriów przy wartości Lane=50 (10x5). Źródło: niepublikowany skrypt autora irla3k142c.

Rys. 51. Hipotetyczny rozkład normalny ostatnich S_d odchyleń zamknięć od średniej m_d . Źródło: opracowanie własne.

Rys. 52. Podział rozkładu gęstości odchyleń na klasy rekomendujące decyzje o otwarciu pozycji. Źródło: opracowanie własne.

Rys. 53. Wykres przedstawia wynik w przestrzeni rzędów kwantyli k_{lg1} x k_{lg2} . Maksimum występuje dla maksymalnych wartości obu parametrów. Źródło: niepublikowany skrypt autora irla3k143c.

Rys. 54. Wykres przedstawia wynpopr w przestrzeni rzędów kwantyli k_{lg1} x k_{lg2} . Maksimum występuje dla minimalnej wartości k_{lg1} (k_{lg1} obliczane jest poprzez odejmowanie od k_{lg2}) oraz dla k_{lg2} rzędu 0.99. Źródło: niepublikowany skrypt autora irla3k143c.

Rys. 55. Wykres obsunięć w przestrzeni k_{lg1} x k_{lg2} . Widać wyraźnie korzystniejszy obszar dla mniejszych wartości k_{lg2} . Źródło: niepublikowany skrypt autora irla3k143c.

Rys. 56. Wykres kryterium K10 w przestrzeni rzędów kwantyli k_{lg1} x k_{lg2} . Maksimum występuje przy wartości $k_{lg2}=0.99$ i największej wartości k_{lg1} . Źródło: niepublikowany skrypt autora irla3k143c.

Rys. 57. Wykres wyniku niepoprawionego w przestrzeni $SL \times TP$, gdzie SL zmienia się od 1:7 a TP – 2:12. Najwyższe wartości widać w obszarze $SL=120-160$ pipsów i $TP=40-55$ pipsów. Źródło: niepublikowany skrypt autora irla3k145c.

Rys. 58. Wykres wynpopr w przestrzeni $SL \times TP$, gdzie SL zmienia się od 1:8. Najwyższe wartości widać podobnie jak poprzednio w obszarze najwyższych wartości SL oraz dla TP w obszarze 35-55 pipsów. Źródło: niepublikowany skrypt autora irla3k145c.

Rys. 59. Wykres obsunięć w przestrzeni $SL \times TP$, gdzie SL zmienia się od 1:8. Najwyższe wartości widać dla początkowych wartości SL i dużych wartości TP . Źródło: niepublikowany skrypt autora irla3k145c.

Rys. 60. Wykres k_{10} w przestrzeni $SL \times TP$, gdzie SL zmienia się od 1:8. Najwyższe wartości widać podobnie jak poprzednio w obszarze najwyższych rozpatrywanych wartości SL i $TP=40$ pipsów. Źródło: niepublikowany skrypt autora irla3k145c.

Rys. 61. Wyniki badań wpływu liczności okna diagnostycznego na jakość kryteriów. Przedstawiono wynik (niebieski), wynik poprawiony (zielony) i obsunięcia (czerwony). Optymalna wielkość zbioru występuje dla $i=3$, co oznacza licznosc $200+i*100=500$ świec. Źródło: niepublikowany skrypt autora irla3k146c.

Rys. 62. Zmiany podstawowych wyników w zależności od liczby świec, po której następuje zamknięcie pozycji niezamkniętych przez bariery TP i SL . T_{dop} zmienia się od 10 do 200 świec. Maksimum występuje przy 16 cyklu obliczeń, czyli dla wartości $T_{dop}=160$. Wyniki to wynik (niebieski), wynpopr (zielony) i obsm – obsunięcie maksymalne (czerwony). Źródło: niepublikowany skrypt autora irla3k146d.

Rys. 63. Schemat graficzny objaśniający wykorzystanie algorytmu A^1 . Źródło: opracowanie własne.

Rys. 64. Schemat graficzny algorytmu A^2 . Składa się on z kolejno wykonywanych, przesuniętych o jedna świecę algorytmów A^1 . Źródło: opracowanie własne.

Rys. 65. Schemat organizacji obliczeń symulacyjnych. Wskazany inkrement L_s świec powoduje pełne wykorzystanie wszystkich danych z przeszłości. Źródło: opracowanie własne.

Rys. 66. Wykres narastania kapitału w trakcie wykonywania algorytmu A^4 złożonego z 1000 realizacji A^2 po 10 świec z jednoczesnym badaniem optymalnej liczby otwieranych pozycji. Źródło: niepublikowany skrypt autora czapirla16 wraz ze skryptem czapirlagg16 i plikiem danych cms15m0604.

Rys. 67. Liczby otwartych jednocześnie długich (zielone) i krótkich (czerwone) pozycji. Źródło: niepublikowany skrypt autora czapirla16 wraz ze skryptem czapirlagg16 i plikiem danych cms15m0604.

Rys. 68. Wykres narastania kapitału dla algorytmu A^4 wykonanego przy zastosowaniu ograniczenia liczby jednocześnie otwartych pozycji obliczonej jako najlepszej w poprzednim kroku. Źródło: niepublikowany skrypt autora czapirla16 wraz ze skrytem czapirlagg16pred i plikami danych cms15m0604, igranlopt i igranlopts.

Rys. 69. Wyniki uzyskane w czasie badania algorytmu A^4 z wykresu 68. Na wykresie przedstawione są najlepsze obliczone w czasie symulacji liczby jednocześnie otwartych pozycji długich (niebieskie) i krótkich (czerwone). Źródło: niepublikowany skrypt autora czapirla16 wraz ze skrytem czapirlagg16pred i plikami danych cms15m0604, igranlopt i igranlopts.

Rys. 70. Narastanie kapitału w modelu predykcyjnym zbudowanym na wynikach symulacji określających najlepsze liczby jednoczenie otwartych pozycji w nierozpatrywanym do tej pory fragmencie szeregu czasowego. Źródło: niepublikowany skrypt autora czapirla16 wraz ze skrytem czapirlagg16pred i plikami danych cms15m0604, igranlopt i igranlopts.

Rys. 71. Wizualizacja macierzy współczynników korelacji liniowej. Źródło: niepublikowany skrypt autora gielda0.

Rys. 72. Badania zmienności własnej czynników rozpatrywanych w macierzy danych – papierów wartościowych. Źródło: niepublikowany skrypt autora gielda3de.

Rys. 73. Przesunięcie $M-1$ (z wyjątkiem x_s) szeregów czasowych o h_p wstecz (a) oraz przesunięcie ich do chwili bieżącej t_0 dla obliczenia predykcji zmiennej x_s . Źródło: opracowanie własne.

Rys. 74. Symulacja dokładności odwzorowania szeregów czasowych dla kolejnych 200 przypadków. Źródło: niepublikowany skrypt autora gielda3d.

Rys. 75. Symulacja narastania kapitału w systemie tradingowym opartym na predykcji krótkoterminowej indeksu WIG20. Źródło: niepublikowany skrypt autora gielda3d.

Rys. 76. Przebiegi rzeczywiste (y) i modelowane \hat{y} zmiennej obserwowanej. Odcinek y_1^k oznacza pierwszy odcinek horyzontu prognostycznego, a y_2^k – drugi. Źródło: opracowanie własne.

Rys. 77. Skumulowane stopy zwrotu dla kolejno rozpatrywanych 200 szeregów czasowych dla kolejno rozpatrywanych 12 zmiennych obserwowanych. Źródło: niepublikowany skrypt autora gielda3de.

Rys. 78. Końcowe rezultaty symulacji skumulowanej stopy zwrotu kolejnych zmiennych traktowanych jako zmienne objaśniane przez pozostałe. Źródło: niepublikowany skrypt autora gielda3de.

Rys. 79. Względna niezawodność poszczególnych zmiennych objaśnianych wyrażona poprzez równoczesne uwzględnienia położenia (średniej stopy zwrotu) i ryzyka (średniego odchylenia standardowego). Źródło: niepublikowany skrypt autora gielda3de.

Rys. 80. Skumulowane stopy zwrotu 12 rozpatrywanych zmiennych opisywanych każdorazowo przez pozostałe 11 zmiennych z przesunięciami wstecz od chwili bieżącej. Źródło: niepublikowany skrypt autora gielda6a.

Rys. 81. Wyniki końcowe skumulowanej stopy zwrotu poszczególnych zmiennych objaśnianych uzyskane w warunkach modelowania zmiennej objaśnianej za pomocą przesuniętych w czasie wektorów zmiennych objaśniających. Źródło: niepublikowany skrypt autora gielda6a.

Rys. 82. Skumulowane stopy zwrotu 12 rozpatrywanych zmiennych dla dwóch różnych parametrów Stop Loss symulacji. Na lewym rysunku SL jest 1/200 wartości maksymalnej rozpatrywanej zmiennej a na prawym 1/25 tej wartości. Źródło: niepublikowany skrypt autora gielda6a.

Rys. 83. Symulacja narastania kapitału w strategii inwestycyjnej zbudowanej na nieliniowym modelu dla WIG20.

Rys. 117. Struktura najlepszych modeli nieliniowych rozpatrywanych w kolejnych 200 szeregach czasowych.

Rys. 85. Skumulowana stopa zwrotu różnych zmiennych w modelach nieliniowych. Źródło: niepublikowany skrypt autora gielda3den.

Rys. 86. Znormalizowana stopa zwrotu poszczególnych zmiennych badana w okresie 200 kroków. Źródło: niepublikowany skrypt autora gielda3den.

Rys. 87. Diagram liczby otwartych pozycji i złożonych zleceń. Źródło: oanda.com.

Rys. 88. Definicja udziałów G_i w odległości δ od wartości bieżącej kursu x_b . Źródło: opracowanie własne.

Rys. 89. Definicja udziałów zleceń w odległości δ od wartości bieżącej kursu x_b . Źródło: opracowanie własne.

Rys. 90. Skumulowany zwrot po 800 krokach systemu transakcyjnego z horyzontem predykcyjnym $h_p=2$ kroki wprzód. Wskaźnik Sharpe'a równy 0.0882. Źródło: niepublikowany skrypt autora oanda3d.

Rys. 91. Skumulowany zwrot po 800 krokach systemu transakcyjnego z horyzontem predykcyjnym $h_p=3$ kroki wprzód. Wskaźnik Sharpe'a równy 0.1291. Źródło: niepublikowany skrypt autora oanda3e.

Rys. 92. Skumulowany zwrot po 800 krokach systemu transakcyjnego z horyzontem predykcyjnym $h_p=3$ kroki wprzód i zmniejszonym SL. Wskaźnik Sharpe'a równy 0.2056. Źródło: niepublikowany skrypt autora oanda3e.

Rys. 93. Skumulowany zwrot po 801 krokach systemu transakcyjnego realizowanego wg klasycznej analizy technicznej przez Liviu Flesara [112]. Wskaźnik Sharpe'a równy 0.2312. Źródło: e-forex.ro.

Rys. 94. Wykres narastania kapitału dla strategii z pojedynczą akcją (tu nr 13 o wartości początkowej 102,00 PLN). Krzywa niebieska to wynik dla strategii umożliwiającej otwieranie pozycji w obu kierunkach, zielona – tylko dla pozycji długich. Źródło: niepublikowany skrypt autora gielda3dBp.

Rys. 95. Mapa zmienności modeli regresyjnych w symulacji systemu transakcyjnego z jedną zmienną objaśnianą i czterema zmiennymi objaśniającymi (w każdej chwili na wykresie wskazane są 4 numery zmiennych wejściowych). Źródło: niepublikowany skrypt autora gielda3dBp.

Rys. 96. Błąd względny dokładności aproksymacji w kolejnych modelach regresyjnych. Źródło: niepublikowany skrypt autora gielda3dBp.

Rys. 97. Wykresy narastania kapitału dla poszczególnych akcji w kolejnych 10 portfelach inwestycyjnych. W serii 10 kolejnych badań symulacyjnych otwieranych co 10 świec i obserwowanych przez 15 świec. Ponieważ w każdym portfelu jest 5 akcji więc na wykresie obserwuje się ogólny obraz 50 przebiegów. Źródło: niepublikowany skrypt autora gielda3deBlin5normLs poprzedzony przygotowaniem danych w skrypcie gielda3deBlinlagS.

Rys. 98. Krzywa narastania kapitału – 5 akcji w portfelu, od 70 poczynając, 10 symulacji każda na 15 świecach. Źródło: niepublikowany skrypt autora gielda3deBlin5normLs poprzedzony przygotowaniem danych w skrypcie gielda3deBlinlagS.

Rys. 99. Wyniki symulacji dla portfela 5 akcji dla kolejnych 10 realizacji co 10 świec, z okresem symulacji wynoszącym 15 świec od 170 poczynając, Źródło:

niepublikowany skrypt autora gielda3deBlin5normLs poprzedzony przygotowaniem danych w skrypcie gielda3deBlinlagS.

Rys. 100. Krzywa narastania kapitału dla drugiego okresu testowania – 5 akcji w portfelu, 10 realizacji po 15 świec w każdej, od 170 poczynając. Wynik jest zdecydowanie najgorszy. Źródło: niepublikowany skrypt autora gielda3deBlin5normLs poprzedzony przygotowaniem danych w skrypcie gielda3deBlinlagS.

Rys. 118. Wyniki symulacji dla portfela 5 akcji dla kolejnych 10 realizacji co 10 świec, z okresem symulacji wynoszącym 15 świec od 270 poczynając. Źródło: niepublikowany skrypt autora gielda3deBlin5normLs poprzedzony przygotowaniem danych w skrypcie gielda3deBlinlagS.

Rys. 119. Krzywa narastania kapitału dla danych – 5 akcji w portfelu, 10 realizacji po 15 świec w każdej, od 270 poczynając. Źródło: niepublikowany skrypt autora gielda3deBlin5normLs poprzedzony przygotowaniem danych w skrypcie gielda3deBlinlagS.

Rys. 120. Wykres narastania kapitału w całym okresie symulacji, od świecy nr 70 do 370, z inkrementem przeszukiwania modeli $kr=6$, z każdorazowym rozpatrywaniem 15 kroków wprzód, uruchamianych co 10 kroków. Każda jednostka na osi zmiennej niezależnej oznacza 10 świec dobowych, czyli 10 dni. Źródło: niepublikowany skrypt autora gielda3deBlin5normLsall poprzedzony przygotowaniem danych w skrypcie gielda3deBlinlagS.

Zasadniczym celem niniejszej monografii jest potwierdzenie tezy autora, że fuzja matematyki i technologii egzemplifikowana powiązaniem metod predykcji ze strategią inwestycyjną opartą na mechanizmach technologicznych platform brokerskich daje nową synergetyczną wartość.

Praca koncentruje się na pragmatycznym powiązaniu predykcji z możliwościami jej internetowej (automatycznej) realizacji. Wymagało to uwzględnienia szeregu niespodziewanych ograniczeń natury technologicznej. W pracy przedstawiono wyniki wielu eksperymentów w przestrzeniach historycznych różnych instrumentów finansowych.

ISSN 0208-8029

ISBN 9788389475237

Instytut Badań Systemowych PAN

Tel. Centrala 022-38 10 100 / fax 022-38 10 105 e-mail: ibs@ibspan.waw.pl