



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

Dodatek A.

Analiza struktury modelu predykcyjnego w czwartej warstwie sieci

Z założeń postawionych dla rozpatrywanego algorytmu kombinatorycznego GMDH modele generowane w **czwartej** warstwie sieci obliczeniowej (trzy warstwy o niższej złożoności omówione były w rozdziale 2) mają postać:

$$u = [\mathbf{1} \ x_i \ x_j \ z_{ii} \ z_{jj} \ w_{iii} \ w_{jjj} \ v_{iiii} \ v_{jjjj}]^* A_{4opt}^T \quad (1)$$

gdzie macierz w nawiasie ma wymiary $[n_u \times 9]$, wektor współczynników A ma wymiar $[9 \times 1]$, a model u ma wymiar $[n_u \times 1]$. Wymiar „9” jest charakterystyczną liczbą współczynników w równaniu regresji czwartej warstwy.

Każda z kolumn macierzy $[\mathbf{1}, x_i, x_j, \dots]$ jest więc wektorem $[n_u \times 1]$, gdzie n_u to liczba elementów wektora danych (wielkość okna czasowego np. L_w).

Parametry równania (1) są zapamiętywane w omówionej implementacji w pewnej strukturze (macierzy komórkowej) o postaci:

$$A_{k4} = [K_4 \ i \ j \ ii \ jj \ iii \ jjj \ iiii \ jjjj \ A_{kn}^T \ \hat{u}_{kn}] \quad (2)$$

Struktury (2) są generowane kolejno w wielokrotnie zagnieżdżonej pętli czwartej warstwy, a k_4 jest indeksem kolejnych struktur takich, dla których kryterium jakości K_4 jest mniejsze od ustalonego progu selekcji CR_4 .

Wszystkie wyselekcjonowane w ten sposób struktury są po zakończeniu obliczeń w pętlach 4 warstwy, sortowane wg kryterium K_4 i najlepsze, ułożone wg rosnącego kryterium, będą nazywane B_{4opt} . Najlepsza struktura ze zbioru $\{B_{4opt}\}$ staje się podstawą do wykonania prognozy po zakończeniu obliczeń w czwartej warstwie. To oczywiście pewna hipoteza wymagająca weryfikacji co do jej zasadności i efektywności.

Prognozę tę wykonuje się przy założeniu, że optymalny model czwartej warstwy (umieszczony w strukturze B_{4opt} na pierwszym miej-

scu) zbudowany na znanych w danej chwili danych cofniętych o h_p kroków wstecz, będzie poprawnie odwzorowywał zmienną wyjściową także h_p okresów wprzód (po uwzględnieniu wszystkich danych wejściowych znanych do chwili bieżącej). Hipoteza ta nie musi być słuszna zwłaszcza dla dużych h_p , jest jednak jedynym sposobem weryfikacji rozpatrywanego algorytmu.

Tak więc najlepsza struktura (2) zapamiętana po sortowaniu jako $B_{4opt}(1, :)$, gdzie:

- indeks 1 oznacza pierwsze miejsce po sortowaniu struktur;
- A zawiera informacje o indeksach modeli poprzednich warstw składających się na model \hat{u}_{pr} – predykcyjny;
- operator “:” oznacza wszystkie kolumny macierzy B_{4opt} .

Poszczególne indeksy w (2) dla wariantu B_{4opt} kolejno oznaczają:

i – $B_{4opt}(1,2)$ to numer zmiennej wejściowej x_i ze zbioru X (danych surowych) wchodzącej w skład optymalnego modelu B_{4opt} . Przy poszukiwaniu najlepszego modelu rozpatrywany był wektor danych $x_i(1:n_u - h_p)$, a więc nie do chwili bieżącej występującej na pozycji n_u , lecz h_p okresów krótszy. W chwili określania prognozy w tym samym miejscu podstawiany będzie wektor tej samej danej x_i , lecz przesunięty wprzód do chwili bieżącej, czyli $x_i(1+h_p:n_u)$. Przy założeniu, że opisywana zmienna wyjściowa y , jest o h_p przesunięta do przodu, pozwoli to na wykonanie prognozy właśnie o horyzoncie h_p kroków.

j – $B_{4opt}(1,3)$ to druga zmienna x_j podstawiona podobnie w chwili wykonywania prognozy jako $x_j(1+h_p:n_u)$.

ii – $B_{4opt}(1,4)$ to indeks oznaczający numer kolejny modelu wśród najlepszych po pierwszej warstwie, czyli:

$$\hat{z}_{ii} = [1x_{ii}^1 x_{ii}^2] * B_{1opt}((B_{4opt}(1,4), 4:6)) \quad (3)$$

gdzie:

$B_{1opt}((B_{4opt}(1,4), 4:6))$ to współczynnik równania regresji, nie najlepszego po pierwszej warstwie, lecz umieszczonego właśnie na ii-tym miejscu, czyli na miejscu określonym przez $B_{4opt}(1,4)$;

x_{ii}^1 to wektor zmiennej wejściowej przesunięty do chwili bieżącej. Zmienna ta ma indeks wynikający z wartości ii czyli,

jest to indeks $B_{1opt}(B_{4opt}(1,4), 2)$, a cały wektor będzie miał postać: $x_{ii}^1 = x_{ii}^1 (1 + h_p : n_u)$, czyli będzie to:

$$x(1 + h_p : n_u, B_{1opt}(B_{4opt}(1,4), 2)).$$

x_{ii}^2 – podobnie, tylko będzie to drugi indeks z pary zmiennych użytych w pierwszej warstwie, czyli występujący na pozycji $B_{1opt}(B_{4opt}(1,4), 3)$, a cała zmienna będzie zapisana jak:

$$x(1 + h_p : n_u, B_{1opt}(B_{4opt}(1,4), 3)).$$

jj – $B_{4opt}(1,5)$ to indeks określający model:

$$\hat{z}_{jj} = [1x_{jj}^1 x_{jj}^2] * B_{1opt}(B_{4opt}(1,5), 4 : 6) \quad (4)$$

gdzie, podobnie jak poprzednio x_{jj}^1 i x_{jj}^2 będą odpowiednio:

$$x(1 + h_p : n_u, B_{1opt}(B_{4opt}(1,5), 2))$$

$$x(1 + h_p : n_u, B_{1opt}(B_{4opt}(1,5), 3))$$

iii – $B_{4opt}(1,6)$ to indeks określający model w drugiej warstwie sieci składającej się na wektor w_{iii} w (1). Wektor ten ma postać:

$$\hat{w}_{iii} = [1x_{iii}^1 x_{iii}^2 z_{iii}^1 z_{iii}^2] * B_{2opt}(B_{4opt}(1,6), 6 : 10) \quad (5)$$

gdzie x_{iii}^1 – to wektor zmiennej wejściowej określony w modelach drugiej warstwy na pozycji $B_{2opt}(B_{4opt}(1,6), 2)$, a x_{iii}^2 podobnie, lecz na pozycji 3: $B_{2opt}(B_{4opt}(1,6), 5)$. Stąd wektory te mają postać:

$$x(1 + h_p : n_u, B_{2opt}(B_{4opt}(1,6), 2))$$

$$x(1 + h_p : n_u, B_{2opt}(B_{4opt}(1,6), 5))$$

Wyrazy z_{iii}^1 i z_{iii}^2 określone są przez modele:

$$\hat{z}_{iii}^1 = [1x_{iii}^3 x_{iii}^4] * B_{1opt} B_{2opt}(B_{4opt}(1,6), 4), 4:6) \quad (6)$$

$$\hat{z}_{iii}^2 = [1x_{iii}^5 x_{iii}^6] * B_{1opt} B_{2opt}(B_{4opt}(1,6), 5), 4:6) \quad (7)$$

gdzie:

$$x_{iii}^3 - B_{1opt}(B_{2opt}(B_{4opt}(1,6), 4), 2)$$

$$x_{iii}^4 - B_{1opt}(B_{2opt}(B_{4opt}(1,6), 4), 3)$$

$$x_{iii}^5 - B_{1opt}(B_{2opt}(B_{4opt}(1,6), 5), 2)$$

$$x_{iii}^6 - B_{1opt}(B_{2opt}(B_{4opt}(1,6), 5), 3)$$

a dokładniej:

$$x(1+h_p:n_u, B_{1opt}(B_{2opt}(B_{4opt}(1,6), 4), 2))$$

jjj – B_{4opt} m.(1,7) podobnie w drugiej warstwie:

$$\hat{w}_{jjj} = [1 x_{jjj}^1 x_{jjj}^2 z_{jjj}^1 z_{jjj}^2] * B_{2opt}(B_{4opt}(1,7), 6:10) \quad (8)$$

gdzie:

x_{jjj}^1 to wektor na pozycji $B_{2opt}(B_{4opt}(1,7),$

$x_{jjj}^2 - B_{2opt}(B_{4opt}(1,7), 3).$

Podobnie na podstawie (6) i (7):

$$z_{jjj}^1 = [1 x_{jjj}^3 x_{jjj}^4] * B_{1opt}(B_{2opt}(B_{4opt}(1,7) 4), 4:6) \quad (9)$$

$$z_{jjj}^2 = [1 x_{jjj}^5 x_{jjj}^6] * B_{1opt}(B_{2opt}(B_{4opt}(1,7) 5), 4:6) \quad (10)$$

a $x_{jjj}^3 - B_{1opt}(B_{2opt}(B_{4opt}(1,7) 4), 2)$ itd. wszystko dla $B_{4opt}(1,7).$

iiii – $B_{4opt}(1,8)$ to indeks określający pozycję modelu trzeciej warstwy składającego się na optymalny model B_{4opt} . Model trzeciej warstwy ma postać:

$$*B_{3opt}(B_{4opt}(1,8), 8:14) \quad (11)$$

W macierzy tej kolejno występują wektory:

x_{iiii}^1 to wektor zmiennej wejściowej o numerze

$B_{3opt}(B_{4opt}(1,8), 2)$, gdzie ($B_{4opt}(1,8)$) określa na, której kolejnej pozycji po sortowaniu jest model z warstwy trzeciej B_{3opt} , z którego wzięta została 2 wartość;

x_{iiii}^2 – podobnie dla trzeciej wartości w strukturze B_{3opt} czyli, wektory wchodzące do (11) będą miały pełną postać:

$$x(1+h_p :zagr, B_{3opt}(B_{4opt}(1,8), 2)$$

$$x(1+h_p :zagr, B_{3opt}(B_{4opt}(1,8), 3)$$

z_{iiii}^1 to wektor o tradycyjnej strukturze:

$$\hat{z}_{iiii}^1 = [1x_{iiii}^3 x_{iiii}^4] * B_{3opt}(B_{4opt}(1,8) 5), 8:14) \quad (12)$$

$$z_{iiii}^2 = [1 x_{iiii}^5 x_{iiii}^6] * B_{1opt}(B_{3opt}(B_{4opt}(1,8) 5), 4:6) \quad (13)$$

gdzie:

x_{iiii}^3 to wektor wyznaczony przez drugą pozycję w pierwszej warstwie, czwartą pozycję kolejno w trzeciej warstwie i szóstą w czwartej czyli:

$$B_{1opt}(B_{3opt}(B_{4opt}(1,8), 4), 2),$$

oraz:

$$x_{iiii}^4 - B_{1opt}(B_{3opt}(B_{4opt}(1,8), 4), 3)$$

$$x_{iiii}^5 - B_{1opt}(B_{3opt}(B_{4opt}(1,8), 5), 2)$$

$$x_{iiii}^6 - B_{1opt}(B_{3opt}(B_{4opt}(1,8), 5), 3)$$

Formalnie każdy z tych wektorów x_{iiii} byłby zaimplementowany jako:

$x(1+h_p :zagr, B_{1opt}(B_{3opt}(B_{4opt}(1,6),4), 2 itd.$

w_{iiii}^1 to wektor określony w trzeciej warstwie przez indeks w $B_{4opt}(1,8)$ – na ósmej pozycji w warstwie czwartej. Model ten jak poprzednie ma postać:

$$w_{iiii}^1 = [1 x_{iiii}^7 x_{iiii}^8 z_{iiii}^3 z_{iiii}^4] * B_{2opt}(B_{3opt}(B_{4opt}(1,8), 6), 6:10) \quad (14)$$

gdzie:

$$x_{iiii}^7 - B_{1opt}(B_{3opt}(B_{4opt}(1,8), 6), 2) \quad (15)$$

$$x_{iiii}^8 - B_{1opt}(B_{3opt}(B_{4opt}(1,8), 6), 3) \quad (16)$$

$$z_{iiii}^3 = [1 x_{iiii}^9 x_{iiii}^{10}] * B_{1opt}(B_{2opt}(B_{4opt}(1,8), 4), 4:6)$$

oraz

$$z_{iiii}^3 = [1 x_{iiii}^{11} x_{iiii}^{12}] * B_{1opt}(B_{2opt}(B_{4opt}(1,8), 5), 4:6)$$

gdzie:

$$x_{iiii}^9 - B_{1opt}(B_{2opt}(B_{3opt}(B_{4opt}(1,8), 6), 4), 2) \quad (17)$$

$$x_{iiii}^{10} - B_{1opt}(B_{2opt}(B_{3opt}(B_{4opt}(1,8), 6), 4), 3) \quad (18)$$

$$x_{iiii}^{11} - B_{1opt}(B_{2opt}(B_{3opt}(B_{4opt}(1,8), 6), 5), 2) \quad (19)$$

$$x_{iiii}^{12} - B_{1opt}(B_{2opt}(B_{3opt}(B_{4opt}(1,8), 6), 5), 3) \quad (20)$$

$jjjj - B_{4opt}(1,9)$ to indeks określający pozycję w modelu trzeciej warstwy na ostatnim (dziewiątym) miejscu w wektorze współczynników równania regresji. Podobnie jak (11) model ten ma postać:

$$\hat{v}_{jjj} = [1x_{jjj}^1 x_{jjj}^2 z_{jjj}^1 z_{jjj}^2 w_{jjj}^2] * B_{3opt}(B_{4opt}(1,8), 8:14) \quad (21)$$

Wszystkie pozostałe elementy tego równania są identycznie rozwijane jak elementy równania (11) z tą różnicą, że zamiast indeksu (1,8) występować tu będzie indeks (1,9).

Uważna analiza tego dodatku, wraz z poprzedzającym go rozdziałem drugim, powinna umożliwić implementację algorytmu liniowego GMDH w dowolnym środowisku programistycznym.

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