

Adam Kucharski

Krótkookresowe prognozy notowań - implementacja średniej ruchomej ze zmiennym efektem wygładzania w algorytmie genetycznym

Studia i Prace Wydziału Nauk Ekonomicznych i Zarządzania 9, 663-671

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.

ADAM KUCHARSKI

KRÓTKOOKRESOWE PROGNOZY NOTOWAŃ – IMPLEMENTACJA ŚREDNIEJ RUCHOMEJ ZE ZMIENNYM EFEKTEM WYGŁADZANIA W ALGORYTMIE GENETYCZNYM

Wstęp

Średnia ruchoma zalicza się do grupy najpopularniejszych narzędzi wspomagających podejmowanie decyzji w praktyce inwestycyjnej. Zwykle wykorzystuje się ją do wskazania momentu otwarcia lub zamknięcia pozycji¹. Warto jednak pamiętać również o korzeniach tej metody, czyli o tworzeniu prognoz na podstawie szeregów czasowych. Średnia ruchoma w tym charakterze jest wciąż stosowana, mimo opracowanych innych, zazwyczaj o wiele bardziej skomplikowanych metod analizy danych giełdowych².

Zachowanie szeregów wygładzanych za pomocą średniej ruchomej determinuje stała wygładzania. Wraz z jej wzrostem rośnie efekt wygładzenia, eliminując wpływ przynajmniej części wahań przypadkowych z przeszłości. Prowadzi to wszakże do nasilenia się kompensacji reszt z prognozy *ex post* bądź tworzenia się serii błędów systematycznych. Tym samym prognozy *ex ante* mogą utracić swą wiarygodność. Zmienna wartość stałej wygładzania pozwoliłaby na lepszą adaptację prognoz do danych, zmniejszając presję, jaką na wyniki wywierają poszczególne elementy dekompozycji.

W tym artykule zajmiemy się przypadkiem średniej ruchomej prostej, w której stała wygładzania przyjmuje dowolną wartość z pewnego, zadanego przedziału. Nie wymagamy przy tym, aby w kolejnych okresach utrzymywać

¹ Tarczyński [1997]

² Mamy tu na myśli prognozy krótkookresowe. Średnia ruchoma, zaliczana do tzw. metod mechanicznych, najlepiej nadaje właśnie się do tego typu prognoz.

jednakową wartość tego parametru. Łatwo dojść w tym miejscu do wniosku, że zaproponowana swoboda doprowadzić musi do wyboru między dużą ilością potencjalnych prognoz. Aby wybrać tę najbardziej odpowiednią z punktu widzenia przyjętego kryterium, sięgniemy po pomoc algorytmu genetycznego, zaprojektowanego do tego celu. Otrzymane wyniki pozwolą ocenić przydatność średniej ruchomej i algorytmu genetycznego we wspomnianym zakresie zastosowań. Prezentujemy jedną z możliwości jaką dają badania operacyjne na obszarze inżynierii finansowej.

Należałoby jeszcze wspomnieć, że artykuł ten jest kontynuacją wcześniejszych badań³ i stanowi rezultat przeprowadzonej przy okazji prezentacji wyników dyskusji.

Mechanizm tworzenia prognoz

W klasycznej, podręcznikowej wersji średniej ruchomej prostej występuje parametr zwany stałą wygładzania (oznaczymy ją przez k). Określa ona z ilu elementów korzysta się podczas obliczania prognozy na dany okres i pozostaje stała podczas całego postępowania⁴.

Podstawą prognoz w naszym artykule jest parametr t_m , który zdefiniujemy jako maksymalny, dopuszczalny numer opóźnienia danej rzeczywistej wykorzystywanej do otrzymywania prognoz na bieżący okres. Parametr ów ustala się na z góry zadany poziom przed rozpoczęciem obliczeń i do ich końca pozostaje on niezmienny. Zakładamy, że stała wygładzania nie może przekroczyć wartości t_m . Stąd wynika, że zachodzi zależność: $1 \leq k \leq t_m$. Przyjęcie akurat takich granic przedziału podyktowała chęć zapewnienia algorytmowi jak największej swobody w doborze parametrów. W dalszej części pracy prześledzimy przypadek zmniejszenia wspomnianego wcześniej przedziału poprzez dodatkowe ograniczenie go z dołu.

Założmy, że dysponujemy szeregiem czasowym y_t złożonym z sześciu obserwacji zaś $t_m=3$. Pierwszą prognozę *ex post* wyznaczymy dla czwartego okresu. Przy stałej wygładzania równej 2 obliczymy średnią arytmetyczną z obserwacji y_2 i y_3 . Jest to wszakże tylko jedna z możliwości, ponieważ k może być równe 3 lub nawet 1. Sytuacja powtórzy się w każdym z kolejnych okresów.

³ Kucharski [2005] oraz Kucharski [2007]

⁴ Cieślak M. [2001], Gajda J. [2001].

Przypomnijmy w tym miejscu, że nasz cel to uzmiennienie wartości k tak, aby szereg prognoz adaptował się do szeregu danych. Efektem przyjętych założeń staje się lawinowy wzrost ilości wariantów prognostycznych, które należy przeanalizować, żeby znaleźć ten o najlepszym przystosowaniu z punktu widzenia przyjętego kryterium, którym może być jeden z błędów prognoz *ex post*. W ten sposób otwiera się pole do popisu dla algorytmu genetycznego.

W latach sześćdziesiątych ubiegłego wieku J. H. Holland stworzył model matematyczny opisujący ewolucyjne i adaptacyjne zjawiska zachodzące w przyrodzie. Z czasem okazało się, że zasugerowane przez badacza rozwiązania mogą znaleźć szereg zastosowań w najróżniejszych dziedzinach. Zaproponowany przez Hollanda model nosi dziś nazwę klasycznego algorytmu genetycznego (KAG). Spuścizną po biologicznych korzeniach jest stosowana w tej dziedzinie do dziś nomenklatura⁵.

W klasycznym algorytmie genetycznym operuje się na zbiorach łańcuchów, które mają stałą długość a składają się z ciągów zer i jedynek. Łańcuchy te noszą nazwę chromosomów, a pojedyncze bity przyjmujące wartość „0” lub „1” nazywa się genami. Zbiór wszystkich chromosomów, które zostały utworzone w celu znalezienia rozwiązania problemu nazywa się populacją. Ponieważ algorytmy genetyczne skonstruowano z myślą o zagadnieniach optymalizacyjnych, występuje w nich oczywiście funkcja celu zwana tu najczęściej (za naukami biologicznymi) funkcją przystosowania.

KAG został zaadaptowany do naszych potrzeb. Pojedynczy chromosom odpowiada jednej z możliwych prognoz *ex post*. Zastosowaliśmy w nim kodowanie rzeczywiste, co oznacza, że gen przechowuje wartość stałej wygładzania dla danego okresu. Wszystkie chromosomy tworzące populację mają stałą długość (liczbę genów) i wynosi ona $n-t_m$ gdzie n oznacza liczbę obserwacji.

Funkcję przystosowania, a więc kryterium oceny jakości prognoz *ex post*, stanowił błąd RMSPE:

$$\text{RMSPE} = \sqrt{\frac{1}{S} \sum_{i=1}^S \left(\frac{y_i - y_i^*}{y_i} \right)^2}, \quad (1)$$

gdzie:

- y_i – wartość rzeczywista zmiennej y w okresie i ;
- y_i^* – prognoza *ex post* zmiennej y w okresie i .

⁵ Michalewicz [1996].

Funkcja przystosowania była minimalizowana.

Selekcja chromosomów do reprodukcji odbywała się metodą elitarną i wartości oczekiwanej⁶. Kiedy już wybrane chromosomy zostały dobrane w pary wymiana genów dokonywała się w sposób analogiczny jak w przypadku reprezentacji binarnej. Chromosomy potomków powstawały poprzez wymianę genów rodziców za punktem krzyżowania. W operatorze mutacji należało uwzględnić użycie parametru t_m . Wylosowane i zamieniane miejscami dwa geny nie mogło dzielić w czasie więcej niż t_m okresów.

Dodatkowo, sugerując się wynikami wcześniejszych badań⁷, w algorytmie zastosowano mechanizm preselekcji polegający na tym, że potomek o lepszym przystosowaniu zastępuje w nowo tworzonej populacji rodzica o gorszym przystosowaniu. W przeciwnym wypadku to potomek jest kasowany, a jego miejsce zajmuje rodzic.

Po zakończeniu obliczeń chromosomy należy odkodować, czyli na podstawie wartości genów obliczyć prognozy *ex post*. Prognozy *ex ante* otrzymamy w sposób typowy dla średniej ruchomej z jedną różnicą: dla wybranego chromosomu dysponujemy w rzeczywistości zestawem różnych wartości stałej wygładzania. Sugerujemy, aby wykorzystać medianę szeregu stałych i w oparciu o nią utworzyć prognozy *ex ante*.

Prognozy dla wybranych spółek

Jakość prognoz otrzymywanych przy pomocy średniej ruchomej, poddanej powyżej opisanym modyfikacjom, zweryfikujemy w oparciu o dane giełdowe dla dziewięciu spółek oraz indeksu WIG20. Niektóre z wybranych firm mają znaczący udział w WIG20. Generalnie jednak zapewniają różnorodną dekompozycję szeregów. Część spośród nich celowo wybrano ze względu na obecność trendu, aby przetestować zachowanie się algorytmu w takich warunkach. Do obliczeń wykorzystano kursy zamknięcia 26 kolejnych notowań z okresu od 5 lutego do 11 marca 2008 roku.

Jeśli chodzi o parametry algorytmu, to przyjęły one następujące wartości:

$$t_m = 5 \text{ (stał } k \in \langle 1, 5 \rangle \text{);}$$

- populację tworzyło 1000 chromosomów (składających się z 21 genów);

⁶ Gwiazda [1995]

⁷ Kucharski [2007]

- liczba pokoleń równała się 50;
- prawdopodobieństwo krzyżowania wyniosło 0,3 zaś mutacji 0,1.


Dokonyjmy zebrania wartości RMSPE dla analizowanych spółek (tabela 1). Kursy PKO BP i Budimexu charakteryzowały się w badanym okresie zmianą kierunku trendu, która potem przerodziła się w stały poziom zmiennej. KGHM i Mostostal Warszawa prezentowały w tym samym czasie tendencję wzrostową, podczas gdy Agora oraz Bank Millennium spadkową. Dla CCC, Comarchu, TP S.A. i WIG20 wystąpił stały poziom zmiennej z dużymi wahaniami losowymi.

Tabela 1. Błąd RMSPE prognoz średnią ruchomą o $k \in \langle 1, 5 \rangle$

Spółka	RMSPE [%]	Spółka	RMSPE [%]
Agora	1,74	Millennium	2,01
Budimex	1,92	Mostostal War.	2,29
CCC	3,14	PKO BP	1,98
Comarch	1,30	TP S.A.	1,50
KGHM	1,56	WIG20	1,49

Źródło: obliczenia własne

Jakość prognoz *ex post* należy uznać za zadowalającą, ponieważ wszystkie wartości RMSPE znalazły się znacznie poniżej umownej granicy 5%. Dla prognoz wyznaczanych klasycznym podejściem (stała wygładzania równa 5) otrzymujemy błędy niemal dwukrotnie wyższe. Wprawdzie nadal są to dobre prognozy, lecz nam udało się je poprawić.



Rys. 1. Wartości wygładzone przy $k \in \langle 1, 5 \rangle$ a dane rzeczywiste dla notowań PKO BP
 Źródło: opracowanie własne


Jeśli chodzi o prognozy *ex ante*, to najczęstszym z przypadków okazała się mediana równa 2 okresom. Oznacza to, iż pierwsza prognoza *ex ante* powstaje jako średnia arytmetyczna z przedostatniej i ostatniej obserwacji. Znajdujący się

poniżej wykres przedstawia zestawienie danych rzeczywistych wraz z wygładzonym szeregiem prognoz.

Cechą charakterystyczną wszystkich chromosomów był fakt, iż w sytuacji układania się obserwacji w serie zawierające w sobie trend dochodziło do preferowania wartości z okresu bezpośrednio poprzedzającego. Prowadziło to w konsekwencji do otrzymywania serii wyników tożsamyh z tymi, jakie uzyskalibyśmy stosując metodę naiwną prostą. Na przytoczonym wykresie przejawia się to przez systematyczne niedoszacowanie lub przeszacowanie wyników predykcji. W ten sposób dochodziło do zaadaptowania się metody do zróżnicowanej dekompozycji szeregu, co doprowadziło do niższych niż w klasycznym podejściu wartości uśrednionych błędów prognoz.

Rodzi się w tym miejscu pytanie o wpływ rozpiętości przedziału, z którego pochodzi stała wygładzania na sam efekt wygładzenia. Preferowanie bowiem niskich jej wartości oznacza silniejszy wpływ niedawnych wahań przypadkowych.

Aby to sprawdzić podwyższyliśmy lewy kraniec przedziału, w efekcie czego otrzymaliśmy: $k \in \langle 3, 5 \rangle$. W naszych warunkach odpowiada to wymuszeniu znacznie silniejszego wygładzenia niż poprzednio. Oceńmy efekty przy pomocy kolejnego wykresu ponownie dla PKO BP.



Rys. 2. Wartości wygładzone przy $k \in \langle 3, 5 \rangle$ a dane rzeczywiste dla notowań PKO BP
Źródło: opracowanie własne

Zgodnie z oczekiwaniami (i własnościami średniej ruchomej) otrzymany szereg prognoz jest praktycznie pozbawiony krótkookresowych wahań przypadkowych. W tabeli 2 znajdują się wartości RMSPE dla przypadku silniejszego wygładzenia. Nadal są to wartości zadowalające, choć wyższe niż poprzednio. Należało się tego spodziewać, ponieważ poważnie ograniczyliśmy swobo-

dę algorytmu w doborze parametrów. Jedna rzecz zasługuje jeszcze na uwagę. Otóż cechą charakterystyczną średniej ruchomej stanowi utrata części obserwacji z początku szeregu potrzebnych do obliczenia pierwszej prognozy *ex post*. Aby uzyskać podobny efekt wygładzenia w klasyczny sposób, konieczne byłoby zwiększenie stałej wygładzania co wiąże się z utratą dodatkowych informacji z okresów początkowych. W przypadku szeregów krótszych pojawia się konflikt pomiędzy dążeniem do pomniejszenia wpływu wahań przypadkowych a rezygnacją z części zawartych w nich danych. Prezentowane podejście pozwala rozwiązać ten problem. Zwróćmy bowiem uwagę, że silniejsze wygładzenie nie spowodowało skrócenia szeregu wygładzonego.

Tabela 2. Błąd RMSPE prognoz średnią ruchomą o $k \in \langle 3, 5 \rangle$

Spółka	RMSPE [%]	Spółka	RMSPE [%]
Agora	2,69	Millennium	2,67
Budimex	2,99	Mostostal War.	3,18
CCC	4,92	PKO BP	2,77
Comarch	2,01	TP S.A.	2,02
KGHM	2,34	WIG20	2,10

Źródło: obliczenia własne.

Wnioski

Na podstawie spisanych wcześniej uwag co do wyników obliczeń możemy stwierdzić, że zmodyfikowana średnia ruchoma prezentuje się dość obiecująco jako narzędzie prognostyczne. Uzyskaliśmy efekt adaptowania się średniej do szeregu co łagodzi ograniczenia nakładane przez dekompozycję szeregu. Niskie błędy predykcji uzyskujemy nawet w przypadku występowania w szeregu trendu, który stanowi mankament w podejściu klasycznym. Obiektywnie trzeba jednak przyznać, że w wymienionej sytuacji nadal dochodzi do systematycznego przeszacowania lub niedoszacowania prognoz.

Kolejną zaletą jest możliwość silniejszego wygładzania szeregu bez konieczności rezygnacji z części informacji z początkowych okresów. Ma to szczególne znaczenie jeśli dysponujemy niezbyt dużymi ilościami danych.

W świetle powyższych uwag wydaje się, że dalszym kierunkiem badań należałoby uczynić wykorzystanie średniej ruchomej o zmiennej wartości stałej wygładzania do przewidywania trendów w szeregach danych giełdowych.

Literatura

1. Cieślak M. (red), *Prognozowanie gospodarcze. Metody i zastosowania*, PWN, 2001.
2. Gajda J.B., *Prognozowanie i symulacje a decyzje gospodarcze*, C.H. Beck 2001.
3. Gwiazda T., *Algorytmy genetyczne – wstęp do teorii*, T.D.G. S. cyw., Warszawa 1995.
4. Kucharski A., *O pewnym zastosowaniu algorytmów genetycznych do prognozowania szeregów czasowych*, Prace Naukowe AE we Wrocławiu, Wrocław 2007, s. 143-153.
5. Kucharski A., *Wykorzystanie algorytmów genetycznych do krótkookresowych prognoz na giełdzie papierów wartościowych*, konferencja naukowa Rynek kapitałowy – Skuteczne inwestowanie, Wydawnictwo Naukowe Uniwersytetu Szczecińskiego, Szczecin 2007, s. 135-145.
6. Michalewicz Z., *Algorytmy genetyczne + struktury danych = programy ewolucyjne*, WNT, Warszawa 1996.
7. Tarczyński W., *Rynki kapitałowe. Metody ilościowe*. Agencja Wydawnicza Placet, Warszawa 1997.

STRESZCZENIE

W artykule przedstawiliśmy nowe spojrzenie na średnią ruchomą jako narzędzie prognostyczne. Odeszliśmy od założenia mówiącego, że wartość stałej wygładzania dla pewnego szeregu nie ulega zmianie w kolejnych okresach. Zamiast tego przyjęliśmy, że przyjmuje ona dowolną wartość z pewnego, zadanego przedziału. Nie wymagaliśmy przy tym, aby w kolejnych okresach utrzymywać jednakową wartość tego parametru. Staaliśmy tym samym przed koniecznością dokonania wyboru najlepszej prognozy spośród dużej ich ilości. Aby temu podolać, wykorzystaliśmy algorytm genetyczny, który został specjalnie przystosowany do naszych celów.

Otrzymane wyniki charakteryzowały się niskimi błędami prognoz *ex post*. Można również powiedzieć, że średnia ruchoma zyskała możliwość adaptacji do zachowania szeregu. Dodatkową korzyścią jest to, iż możliwym stało się silniejsze wygładzanie szeregu bez konieczności rezygnacji z większej liczby początkowych obserwacji.

**SHORT-TERM FORECASTS OF STOCK QUOTATION –
IMPLEMENTATION OF THE MOVING AVERAGE WITH
CHANGEABLE EFFECT OF SMOOTHING IN THE GENETIC
ALGORITHM**

SUMMARY

In the article we presented a new look at the moving average as the prognostic tool. We walked away from the assumption that value of smoothing constant for the certain series isn't changing in consecutive periods. Instead of it we assumed that it can be taken from a certain, known range. We didn't demand in addition to keep identical value of this parameter in consecutive periods. We stood up in the process before the need to make choice of the best forecast out of big their amounts. In order to cope with it, we used the genetic algorithm which specially was adapted at our targets.

Received scores were characterized by low errors of ex post forecasts. We can also say that moving average gained the possibility of the adaptation to the behaviour of data. It is fringe benefits, that stronger smoothing became possible without necessities of resignations from a large number of initial observation.

Translated by A. Kucharski

Dr Adam Kucharski
Uniwersytet Łódzki
adamk@uni.lodz.pl