

Monika Dyduch

Akademia Ekonomiczna w Katowicach

ALTERNATYWNY SPOSÓB TRANSFORMACJI SZEREGU CZASOWEGO W PROGNOZOWANIU KURSU WYMIANY EURO

Streszczenie: W pracy zaprezentowano prognozę dla szeregu o wysokiej częstotliwości otrzymanej na podstawie modelu, który jest zintegrowany z transformatą falkową, siecią neuronową i algorytmem genetycznym. Prognoza jest wykonana w skali jednego dnia i siedmiu dni dla kursu wymiany euro.

Słowa kluczowe: sieci neuronowe, predykcja, transformata falkowa.

1. Wstęp

Jednym z kluczowych elementów każdego systemu gospodarczego jest jego rynek finansowy, którego istotnym warunkiem rozwoju jest umiejętność przewidywania kierunków i ilościowych zmian zarówno samego rynku, jak i jego otoczenia. Wpływa to na podejmowanie na tej podstawie prawidłowych decyzji gospodarczych.

W związku z tym istotne są metody pozwalające na efektywne przewidywanie zmian na rynkach finansowych.

2. Architektura modelu

W artykule dokonano prognozy szeregu czasowego prezentującego kurs wymiany euro na podstawie modelu scalającego w jednym algorytmie analizę falkową, algorytm genetyczny i sieci neuronowe (rys. 1).

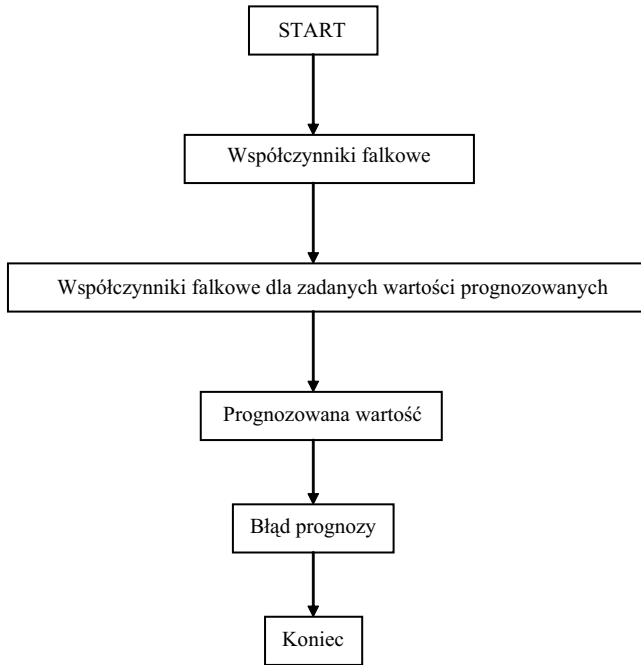
Połączenia analizy falkowej i sztucznych sieci neuronowych dokonujemy poprzez scalenie dwóch metod:

- I metody – polegającej na użyciu czasu jako punktu odniesienia, czyli użyciu współczynników falkowych różnych skal w tym samym czasie w charakterze wektora wejścia w sieci neuronowej do predykcji przyszłych danych,
- II metody – polegającej na użyciu skali jako punktu odniesienia, czyli użyciu współczynników falkowych o różnych czasach w tej samej skali w charakterze wektora wejścia w sieci neuronowej do predykcji przyszłych danych.

Zintegrowanie tych dwóch metod powoduje, że wektor wejścia sieci neuronowej zawiera w sobie nie tylko współczynniki analizy falkowej różnych skal w tym samym czasie, ale także współczynniki falkowe różnych momentów w tej samej skali.

Algorytm genetyczny wykorzystujemy do wyznaczenia najlepszych długości współczynników falkowych.

Postać modelu, na podstawie którego wykonujemy prognozę szeregu czasowego, przedstawia rys. 1.



Rys. 1. Architektura modelu prognostycznego

Źródło: opracowanie własne.

Transformatę falkową wykonujemy falką Daubechies, czyli falką skonstruowaną przez Ingrid Daubechies, która sformułowała, a następnie udowodniła następujące twierdzenie:

Twierdzenie. Istnieje dokładnie jedna funkcja $\varphi: D \rightarrow R$ spełniająca następujące trzy warunki:

$$\varphi(r) = \frac{1 + \sqrt{3}}{4} \varphi(2r) + \frac{3 + \sqrt{3}}{4} \varphi(2r - 1) + \frac{3 - \sqrt{3}}{4} \varphi(2r - 2) + \frac{1 - \sqrt{3}}{4} \varphi(2r - 3), \tag{1}$$

$$\sum_{k \in \mathbb{Z}} \varphi(k) = 1, \quad (2)$$

$$\varphi(r) = 0 \text{ dla } r \leq 0 \vee r \geq 3, \quad (3)$$

gdzie:

$$D_j = \{k2^j : k \in \mathbb{Z}\}, \quad D = \bigcup_{j \in \mathbb{Z}} D_j = \bigcup_{j=0}^{\infty} D_j. \quad (4)$$

Ingrid Daubechies nie tylko udowodniła, że funkcja φ istnieje, ale że również nie można jej przedstawić w postaci funkcji elementarnych, czyli nie należy do funkcji wielomianowej, trygonometrycznej, wykładniczej, eliptycznej, mimo że spełnia pewne zależności określone w cytowanym twierdzeniu.


Związana z funkcją skalującą φ falka ψ zadana jest wzorem:

$$\psi(r) = -\frac{1+\sqrt{3}}{4}\varphi(2r-1) + \frac{3+\sqrt{3}}{4}\varphi(2r) - \frac{3-\sqrt{3}}{4}\varphi(2r+1) + \frac{1-\sqrt{3}}{4}\varphi(2r+2) \quad (5)$$

$$\psi(r) = 0 \text{ dla } r < -1 \text{ lub } r > 2.$$

3. Zastosowanie modelu – wyniki analizy

W artykule dokonano prognozy szeregu czasowego reprezentującego kurs wymiany euro. Dane dotyczą notowań dziennych z wyjątkiem weekendów w okresie 25.09.2006-15.09.2009 (rys. 2).




Rys. 2. Rzeczywisty szereg czasowy

3.1. Analiza falkowa


Zgodnie z przedstawioną architekturą modelu szereg czasowy w pierwszej kolejności poddamy transformacji falkowej.

Używając algorytmu zaprezentowanego w punkcie drugim, dokonujemy pięciopoziomowej dekompozycji oryginalnego szeregu czasowego falką Daubechies. Ponieważ próbka poddana transformacji falkowej musi zawierać liczbę obserwacji równą całkowitej potędze liczby 2, ograniczamy rzeczywisty szereg czasowy do 512 obserwacji. Postać szeregu poddanego transformacji prezentuje rys. 3.



Rys. 3. Szereg czasowy poddany transformacji falkowej

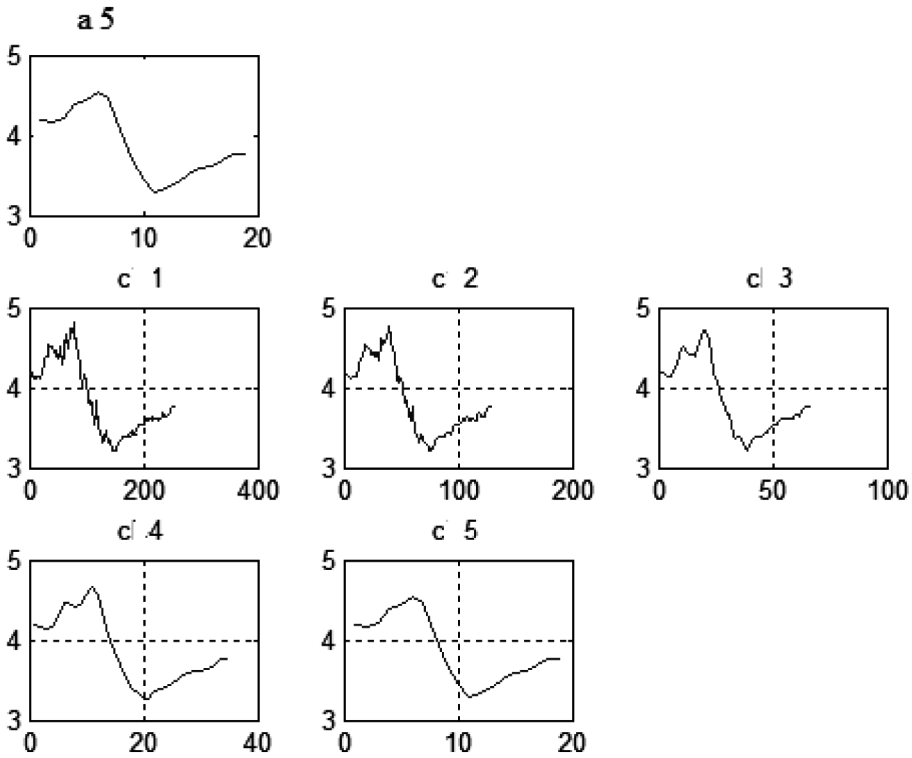
Otrzymany szereg czasowy po dekompozycji falkowej przedstawiony jest na rys. 4.



Rys. 4. Szereg czasowy po transformacji falkowej

Dyskretna transformata falkowa pozwala przedstawić sygnał w postaci liniowej kombinacji współczynników $a_p(t)$, $c_p(t)$. Zatem oryginalny szereg jest złożony z współczynników: $a_5, c_1, c_2, c_3, c_4, c_5$ na różnych poziomach. Otrzymane z transformaty falkowej współczynniki prezentuje rys. 4.

Ponieważ falka ma charakter pasmowoprzepustowy, współczynniki c_k zawierają informacje o wyższych częstotliwościach, tzn. szczegóły. Natomiast współczynniki a_k zawierają informację dolnoprzepustową wraz ze składową stałą.



Rys. 5. Współczynniki analizy falkowej $a_5, c_1, c_2, c_3, c_4, c_5$

3.2. Parametry sieci neuronowej

Zgodnie z przyjętym modelem predykcji otrzymane współczynniki są poddawane działaniu algorytmu genetycznego. W efekcie otrzymujemy komplet wartości współczynników falkowych dla każdej rozpatrywanej chwili czasowej.

Dysponując wartościami współczynników falkowych dla wszystkich chwil czasowych, uruchamiamy sztuczną sieć neuronową, przyjmując jako zbiór uczący otrzymane komplety współczynników i szereg 512-elementowy. Wyjściem sieci będą współczynniki falkowe dla okresu prognozowanego, czyli prognozy na jeden dzień i siedem dni. Otrzymane wartości współczynników prezentuje tab. 1.

Na podstawie otrzymanych współczynników konstruujemy wartość szeregu empirycznego w dniu prognozy. Krok ten wykonujemy za pomocą odwrotnej transformaty falkowej. Wygenerowany przez falkę (IDWT) szereg porównujemy z szeregiem empirycznym – rzeczywistym, i otrzymujemy błąd testowy. Wyniki zawiera tab. 1.

Tabela 1. Współczynniki falkowe – parametry sieci

Horyzont prognozy	Współczynniki falkowe				
	a_5	c_1	c_2	c_3	c_5
1	3,75	3,77	3,76	3,76	3,75
7	3,76	3,76	3,73	3,76	3,76

Źródło: opracowanie własne.

Tabela 2. Błędy prognozy (w %)

Skala	1 dzień	7 dni
Błąd treningu	6	6,8
Błąd testowy	10	9,6

Źródło: opracowanie własne na podstawie uzyskanych wyników.

Błąd treningu sieci oscyluje pomiędzy 6-7%, natomiast błąd testowy sieci – pomiędzy 9-10%.

Otrzymane wyniki pokazują, że proponowany model może być modelem predykcji w skali jednego dnia lub siedmiu dni.

4. Zakończenie

Zaprezentowane wyniki pokazują, że zastosowanie modelu opartego na analizie falkowej, sieciach neuronowych i algorytmie genetycznym jest uzasadnione w świetle analizowanych danych. Można stwierdzić, że model może być skutecznym narzędziem prognozowania kursów walut.

Przewidywanie kursów jest bardzo trudne ze względu na złożoność mechanizmu cenowego tego rynku, a zwłaszcza czynników oddziałujących na ten rynek.

Literatura

- Coakley J., Fuertes A.M., *Nonparametric cointegration analysis of real exchange rate*, „Applied Financial Economics” 2001.
- Katsuragi H., *Evidence of multi-affinity in the Japanese Stock market*, „Physica A” 2000.

AN ALTERNATIVE METHOD OF TIME SERIES TRANSFORMATION IN EXCHANGE RATE FORECASTING

Summary: The paper describes a hybrid model which integrates the wavelet neural network with genetic algorithm and can predict exchange rate. The proposed model predicts exchange rate within one day and seven days scales.