



Michał Dominik Stasiak

Uniwersytet Ekonomiczny w Poznaniu
Wydział Zarządzania
Katedra Inwestycji i Nieruchomości
michal.stasiak@ue.poznan.pl

MODELOWANIE KURSU WALUTOWEGO W REPREZENTACJI BINARNEJ Z WYKORZYSTANIEM ZALEŻNOŚCI FALOWYCH

Streszczenie: Kurs pary walutowej może zostać przedstawiony w postaci reprezentacji binarnej. W pracy zaproponowano stanowy model kursu walutowego w reprezentacji binarnej z wykorzystaniem zależności falowych. W modelu zdefiniowano stany odpowiadające danym wzorcom zmian ceny oraz wzorcom przynależności do fal danego rodzaju. Proces wykrywania fal oraz wyznaczania ich parametrów wykorzystuje zaproponowane przez autora algorytmy detekcji fal w reprezentacji binarnej. Przedstawiono również przykładowe efekty modelowania kursu walutowego AUD/NZD z wykorzystaniem zaproponowanego w pracy modelu dla danych historycznych z okresu 2011-2016 wraz ze statystyczną analizą otrzymanych rezultatów.

Słowa kluczowe: Forex, analiza techniczna, modelowanie kursów, analiza falowa.

JEL Classification: G19.

Wprowadzenie

Dominującą metodą prezentacji kursu par walutowych ze względu na dużą zmienność w czasie jest reprezentacja świecowa [Murphy, 1999; Schlossberg, 2006; Burgess, 2010]. Reprezentacja świecowa (w której parametry świec są zależne od narzuconego interwału czasowego) prowadzi do pominięcia informacji o dynamice i zasięgu poszczególnych zmian „wewnątrz” świecy. Fakt ten powoduje stratę pewnych informacji, które można by wykorzystać do dokładniejszej predykcji kursu. Z tego powodu w artykule wykorzystano reprezentację binarną opartą na zmianie bezwzględnej wartości ceny [Stasiak, 2015].

W celu zwiększenia dokładności modelowania kursu walutowego w reprezentacji binarnej wykorzystano założenie o falowej strukturze rynku. Według teorii falowych [Bickford, 2007], np. teorii Eliotta [Frost i Prechter, 2005], kierunek przyszłej zmiany ceny zależy od kierunku oraz zasięgu aktualnej fali. W artykule omówiono dwa algorytmy pozwalające na detekcję fal kursu w reprezentacji binarnej oraz przedstawiono sposób konstrukcji reprezentacji binarno-falowej [Stasiak, 2016a]. Jest ona podstawą zaprezentowanej w artykule nowej metody modelowania kursu z wykorzystaniem reprezentacji binarno-falowej. Zapropozowany model stanowy reprezentacji binarnej-falowej (MSRBF) pozwala na aproksymację, z dużą dokładnością, prawdopodobieństwa kierunku przyszłych zmian kursu.

Wszystkie badania zostały przeprowadzone na podstawie pięcioletnich danych tickowych kursu walutowego AUD/NZD, pochodzących od brokera Duca-scopy z okresu 1.01.2011-1.01.2016.


1. Reprezentacja binarna kursu walutowego

Kurs walutowy zwykle jest przedstawiany w formie wykresu świecowego dla danego interwału czasowego. Taka reprezentacja jest powszechnie wykorzystywana przez wszystkie platformy brokerskie (MetaTrader, JForex) do wizualizacji zmian kursu. Również wskaźniki analizy technicznej (np. MACD [Yazdi i Lashkari, 2013]) są wyznaczane na podstawie wybranych parametrów świec.

Właściwości kursu przedstawionego w reprezentacji świecowej zależą od interwału czasowego, a nie zależą od dynamiki zmian kursu. Amplituda zmian świec nocnych może być nawet kilkadziesiąt razy mniejsza niż amplituda zmian świec w okresie np. prezentacji ważnych danych makroekonomicznych. Z tego powodu stosowanie reprezentacji świecowej prowadzi do straty cennych informacji dotyczących częstotliwości oraz kierunku mniejszych zmian „wewnątrz świecy”, co przekłada się na mniejszą efektywność analizy technicznej. Na rys. 1 przedstawiono różne przebiegi zmian wewnątrz tej samej świecy.

Analiza nieprzetworzonych danych tickowych jest również mało efektywna, ponieważ prowadzi do rejestracji parametrów niemających realnego znaczenia. Kurs zmienia się średnio co sekundę, większość wahań o minimalnym zasięgu rzędu np. 1-3 pipsów ma charakter losowych fluktuacji [Logue i Sweeney, 1977; Nelly i Weller, 2011]. Reprezentacja binarna polega na dyskretyzacji kursu walutowego na podstawie zadanej jednostki dyskretyzacji. Na rys. 1 przedstawiono przykład działania algorytmu dyskretyzacji. Algorytm ten przypisuje wartość „0”, gdy kurs spada o wartość określoną przez jednostkę dyskretyzacji

wartość, lub „1” w przypadku wzrostu kursu o tę wartość. W efekcie działania algorytmu można przedstawić kurs w postaci ciągu binarnego [Stasiak, 2015]. Takie podejście eliminuje okresy braku zmienności, np. noce, a jednocześnie zachowuje kluczowe dla inwestora informacje o kierunku i wielkości zmian kursu.



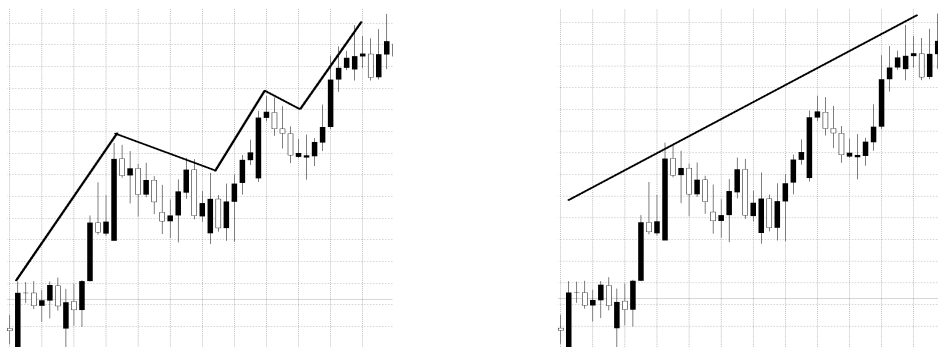
Rys. 1. Dwa różne przebiegi zmian kursu „wewnątrz” tej samej świecy

Podstawowym elementem właściwej konstrukcji reprezentacji binarnej jest dobór odpowiedniej jednostki dyskretyzacji. Przyjęta wartość jednostki dyskretyzacji powinna być jak najmniejsza, aby możliwie najdokładniej oddać charakter zmian. Równocześnie na tyle duża, aby wyeliminować fluktuacje o charakterze losowym. W artykule przyjęto 20-pipsową jednostkę dyskretyzacji dla badanej pary walutowej. W celu potwierdzenia możliwości istnienia zależności pomiędzy zmianami historycznymi i aktualnymi zmianami kurs badanej pary został poddany analizie statystycznej z wykorzystaniem testów rekomendowanych przez NIST (National Institute of Standards and Technology) do testowania generatorów liczb pseudolosowych w modułach kryptograficznych [Rukhin i in., 2010] (dokładny wybór oraz strukturę testów przedstawiono w pracy Stasiaka [2015]). Przy założonym poziomie istotności równym 0.05, dla jednostki dyskretyzacji równej 20 pipsów potwierdzono istnienie możliwych zależności pomiędzy aktualnymi i historycznymi zmianami kursu.

2. Struktura falowa kursu walutowego

Większość wizualnych metod analizy technicznej zakłada falową strukturę notowań. Strukturę falową na rynku walutowym można uzasadnić np. psychologią inwestorów [Oberlechner, 2005]. Po publikacji ważnych wskaźników makroekonomicznych lub na skutek wydarzeń geopolitycznych jeszcze przez pe-

wien czas inwestorzy przy odejmowaniu decyzji inwestycyjnych kierują się tymi wydarzeniami. Przykładowo, po ogłoszeniu wyników ostatnich wyborów prezydenckich w USA dolar umacniał się przez kilkanaście dni. W analizie technicznej fale są wykorzystywane np. w analizie formacji [Murphy, 1999; Burgess, 2010]. Powszechnie stosowana jest przez analityków teoria Elliotta [Frost i Prechter, 2005]. Techniki te jednak opierają się na subiektywnym wyznaczaniu fal przez analityków.



Rys. 2. Dwie możliwości wyznaczenia fal dla tego samego kursu

Na rys. 2 przedstawiono dwa sposoby wyznaczenia fali dla tego samego kursu. Brak sformalizowanych zasad pozwalających na zalgorytmizowanie detekcji fal prowadzi w konsekwencji do braku możliwości statystycznej weryfikacji związków pomiędzy parametrami kolejnych fal. Z tego powodu w pracy Stasiaka [2016a] zaproponowano dwa algorytmy detekcji fal w reprezentacji binarnej.

3. Algorytmy detekcji fal w reprezentacji binarnej kursu walutowego

Algorytmy detekcji fal w reprezentacji binarnej polegają na analizie liczby wzrostów/spadków kursu w zadanym okresie. Przekroczenie określonych poziomów wyznacza początek lub koniec danej fali.

Pierwszy algorytm – algorytm detekcji fal w reprezentacji binarnej (ADFRB) pozwala na identyfikację dwóch rodzajów fal: wzrostowej oraz spadkowej. Ponieważ koniec fali wzrostowej jest jednocześnie początkiem fali wzrostowej i na odwrót, więc kurs zawsze można przypisać do danego rodzaju fali. Analogiczne podejście wykorzystuje teoria Elliotta. Algorytm ADFRB wymaga zdefiniowania 2 parametrów: m – liczba zmian historycznych analizowanych przez algorytm oraz p – próg średniej liczby wzrostów/spadków w m poprzedzających zmianach

kursu, po którego przekroczeniu rozpoczyna się dana fala ($p \geq 0.5$). Algorytm ADFRB można zapisać w następującej formie [Stasiak, 2016a]:

- 1) Wyznaczenie średniej liczby wzrostów w oraz spadków s w m poprzedzających zmianach:

$$w = \frac{\sum_{i=1}^m x_i}{m}, \quad (1)$$

$$s = \frac{\sum_{i=1}^m |x_i - 1|}{m}. \quad (2)$$

gdzie x_i to i -ta poprzednia zmiana (aktualna zmiana $i=0$) kursu w reprezentacji binarnej.

- 2) Identyfikacja rodzaju fali następuje według reguł:
 - spełnienie warunku $w > p$ w trakcie trwania fali spadkowej oznacza początek fali wzrostowej,
 - spełnienie warunku $s > p$ w trakcie trwania fali spadkowej oznacza początek fali spadkowej,
 - spełnienie warunków $w < p$ i $s < p$ oznacza kontynuację bieżącej fali.

Dobór parametrów wejściowych algorytmu (m , p) określa dokładność detekcji fal. Od doboru tych parametrów zależy także charakter zależności pomiędzy kolejnymi falami.

Drugi zaproponowany algorytm to algorytm detekcji fal w reprezentacji binarnej z uwzględnieniem okresów konsolidacji (ADFRBK), pozwala on na detekcję trzech rodzajów fal: wzrostowej, spadkowej oraz neutralnej. Falę neutralną wprowadzono w celu detekcji okresów konsolidacji na rynku. Zastosowanie takiego podejścia zwiększa dokładność analizy falowej kursu. Algorytm ADFRBK wymaga zdefiniowania trzech parametrów wejściowych: m – liczba analizowanych, poprzedzających zmian kursu, n – poziom średniej liczby wzrostów/spadków w m poprzedzających zmianach kursu rozpoczynających falę neutralną, oraz trzeciego parametru: p – poziom średniej liczby wzrostów/spadków w m poprzedzających zmianach kursu rozpoczynających daną falę.

Algorytm ADFRBK można zapisać w następującej postaci [Stasiak, 2016a]:

- 1) Wyznaczenie średniej liczby wzrostów w oraz spadków s w m poprzedzających zmianach z wykorzystaniem wzorów 1 i 2.
- 2) Identyfikacja rodzaju fali następuje według reguł:
 - spełnienie warunku $w > p$ w trakcie trwania fali spadkowej lub neutralnej oznacza początek fali wzrostowej,

- spełnienie warunku $s > p$ w trakcie trwania fali spadkowej lub neutralnej oznacza początek fali spadkowej,
- spełnienie warunków $w < p$ i $s < p$ to kontynuacja bieżącej fali,
- spełnienie warunków $w < n$ i $s < p$ gdy trwa fala wzrostowa, oznacza początek fali neutralnej,
- spełnienie warunków $s < n$ i $w < p$, gdy trwa fala spadkowa, oznacza początek fali neutralnej,
- w pozostałych przypadkach kontynuacja bieżącej fali.

Od doboru parametrów wejściowych algorytmu zależy dokładność modelu oraz precyzja określenia przyszłych zależności pomiędzy kolejnymi falami.

Przedstawione algorytmy pozwalają na jednoznaczną – niezależną od analityka – detekcję fal w reprezentacji binarnej, a zależności pomiędzy falami wyznaczonymi na podstawie działania algorytmów ADFRB i ADFRBK mogą być zweryfikowane statystycznie.

4. Reprezentacja binarno-falowa kursu walutowego

Reprezentacja binarno-falowa polega na przypisaniu każdej zmianie kursu o jednostkę dyskretyzacji dwóch parametrów: wartości binarnej reprezentującej kierunek zmian kursu oraz rodzaju aktualnej fali [Stasiak, 2016a]. Reprezentacja binarno-falowa jest konstruowana na podstawie działania wybranego algorytmu detekcji fal (ADFRB lub ADFRBK). Każdej zmianie kursu przypisujemy rodzaj danej fali: fala wzrostowa (1) i fala spadkowa (0) dla algorytmu ADFRB lub fala wzrostowa (1), fala spadkowa (0) i fala neutralna (2) dla algorytmu ADFRBK. Właściwości oraz charakter reprezentacji binarno-falowej zależą od doboru jednostki dyskretyzacji oraz od parametrów wejściowych algorytmu detekcji fal.


5. Model stanowy reprezentacji binarno-falowej

Model stanowy reprezentacji binarno-falowej (MSRBF) powstał jako rozszerzenie modelu stanowego reprezentacji binarnej (MSRB), szerzej opisanego w pracy Stasiaka [2016b], model ten wykorzystuje zależności pomiędzy historycznymi zmianami kursu oraz wpływ rodzaju zarejestrowanych fal na prawdopodobieństwo kierunku przyszłej zmiany kursu. Model wykorzystuje wybrany algorytm detekcji fali i jest opisany następującymi parametrami:

m – liczba analizowanych, poprzedzających zmian kursu,

n – liczba zmian, w których analizujemy rodzaj fali.

Stan w MSRBF został zdefiniowany jako para dwóch elementów: pierwszy definiowany jest jako wzorzec określony przez m ostatnich zmian kursu. Drugim elementem jest rodzaj fal zarejestrowany w n ostatnich zmianach kursu w zależności od przyjętego algorytmu detekcji fal: dla algorytmu ADFRB – 0 (fala spadkowa) lub 1 (fala wzrostowa), a dla algorytmu ADFRBK – 0 (fala spadkowa), 1 (fala wzrostowa) lub 2 (fala neutralna). Przykładowo w modelu o parametrach $m=1, n=1$ z zastosowanym algorytmem ADFRB o dowolnych parametrach stan (1,1) oznacza, że kurs wzrósł o jednostkę dyskretyzacji (pierwsza jedynka) oraz że kurs aktualnie znajduje się w fali wzrostowej (druga jedynka).




Rys. 3. Diagram stanów modelu stanowego reprezentacji binarnej-falowej o parametrach $m=1, n=1, ADFRBK (7,0.6,0.5)$.

Na rys. 3 przedstawiono diagram stanów modelu określonego parametrami $m=1, n=1$ z zastosowaniem algorytmu ADFRBK (7,0.6,0.5). W modelu uwzględnia się ostatnią zmianę i rodzaj aktualnej fali. Diagram przedstawia wszystkie stany oraz możliwe przejścia pomiędzy nimi. Przestrzeń stanów w modelu MSRBF można wyznaczyć za pomocą wzoru:

$$S = 2^{m+n} \quad - \text{dla algorytmu ADFRB}, \quad (3)$$

$$S = 2^m * 3^n \quad - \text{dla algorytmu ADFRBK}. \quad (4)$$

Najważniejszym parametrem charakteryzującym model dla danej pary walutowej są odpowiednie wartości prawdopodobieństwa przejść pomiędzy stanami. Prawdopodobieństwa przejść można wyznaczyć heurystycznie na podstawie danych historycznych. W modelu częstości wzrostów/spadków są rozpatrywane jako estymatory prawdopodobieństwa.



Rys. 4. Przykład możliwych przejść ze stanu (00,0) po wzroście, w modelu MSBRF o parametrach $m=2$, $n=1$, ADFRB (7,06).

Dla inwestora (lub algorytmu handlu automatycznego) najważniejsza jest ocena prawdopodobieństwa kierunku dalszych zmian. Aktualnie panująca na rynku fala pełni jedynie rolę wskaźnika przy wyznaczaniu prawdopodobieństwa kierunku przyszłej zmiany. Kurs może wzrosnąć lub zmaleć w fali wzrostowej lub spadkowej. Z tego powodu prawdopodobieństwo wzrostu/spadku ceny jest sumą prawdopodobieństw przejść do odpowiednich stanów (na rys. 4 zaznaczono przejścia określające wzrost kursu dla stanu (00,0)). Zatem prawdopodobieństwo wzrostu $P_{wzrost}(00,0)$ można zapisać następująco:

$$P_{wzrost}(00,0) = P[(00,0) \rightarrow (01,0)] + P[(00,0) \rightarrow (01,1)], \quad (5)$$

Analogicznie prawdopodobieństwo spadku w stanie (00,0) wynosi:


$$P_{spadek}(00,0) = P[(00,0) \rightarrow (00,0)] + P[(00,0) \rightarrow (00,1)]. \quad (6)$$

Suma wszystkich prawdopodobieństw wyjściowych z danego stanu jest równa jedności, więc:

$$P_{wzrost}(00,0) + P_{spadek}(00,0) = 1. \quad (7)$$

Rozważmy MSBRF o parametrach ($m=2$, $n=1$) dla badanych notowań. Wartości prawdopodobieństw zostały wyznaczone empirycznie dla danych historycznych w reprezentacji binarno-falowej dla 20-pipsowej jednostki dyskretyzacji. Rezultaty modelowania są zależne od wyboru oraz parametrów algorytmu detekcji fal – z tego powodu wykorzystano podejście znane z testowania algorytmów opartych na sieciach neuronowych [Yao i Tan, 2000]. Rozpatrywany w artykule okres 5 lat podzielono na 2-letni okres „uczący” oraz trzyletni okres testowy. W celu uzyskania optymalnych rezultatów modelowania dla zadanych parametrów n i m za pomocą dedykowanego oprogramowania, napisa-

nego w języku C++, przetestowano wszystkie kombinacje parametrów oraz wybrano kombinację, dla której uzyskano najlepsze wyniki w przeciągu pierwszych 2 lat. Najlepsze rezultaty uzyskano dla parametrów: (7,0.6) dla ADFRB oraz (9,0.6,0.5) dla algorytmu ADFRBK. Następnie zweryfikowano rezultat na podstawie okresu testowego.



Rys. 5. Przykładowe rezultaty modelowania stanowego

Na rys. 5 przedstawiono przykładowe prawdopodobieństwa kierunku przyszłych zmian kursu w stanie (01,1). Rys. 5a prezentuje rezultat działania modelu MSRB, rys. 5b – model MSRBF z zastosowanym algorytmem ADFRB z optymalnymi parametrami wyznaczonymi w okresie uczącym, a rys. 5c przedstawia wyniki działania modelu MSRBF z zastosowanym algorytmem ADFRBK z optymalnymi parametrami wyznaczonymi w okresie uczącym.

Prawdopodobieństwa przejść powinny charakteryzować się możliwie niezmiennymi wartościami w czasie. Jest to warunek prawidłowego działania modelu w kontekście zastosowań praktycznych (duże wahania prawdopodobieństwa mogą przekładać się na duże wahania salda inwestora) [Aldrige, 2009], z tego powodu przeprowadzono analizę wpływu trendów nadrzędnych na działanie modelu. Cały badany okres został podzielony na 10 serii, następnie na podstawie rezultatów otrzymanych w każdej serii oraz rozkładu T-Studenta wyznaczono 95% przedział ufności (szczegółowy opis analizy znajduje się w pracy [Stasiak 2016b]). Otrzymane przedziały ufności dla wszystkich stanów badanego modelu są podobne i nie przekraczają 0.05. Rezultaty świadczą o małym wpływie trendów nadrzędnych na działanie modelu, co w konsekwencji potwierdza zasadność praktycznej implementacji modelu MSRBF w algorytmach wspomagania decyzji.

Podsumowanie

W artykule zaproponowano nowy model stanowy reprezentacji binarno-falowej (MSRBF). Na podstawie przedstawionych rezultatów na przykładzie pary AUD/NZD można stwierdzić, że aktualnie panująca na rynku fala ma wpływ na wartość prawdopodobieństwa kierunku przyszłej zmiany. Wprowadzenie zależności falowych w modelu stanowym spowodowało wzrost dokładności oszacowania prawdopodobieństwa kierunku zmiany o ok. 4%. Otrzymane wartości charakteryzują się więc dużą dokładnością i stabilnością. Proponowany model oferuje zatem inwestorowi większą efektywność modelowania rynku niż model stanowy reprezentacji binarnej MSRB oraz podobną skuteczność predykcji jak model stanowy reprezentacji binarno-czasowej [Stasiak, 2016c] wykorzystujący zależności czasowe w reprezentacji binarnej, ale generuje ponad 2 razy więcej sygnałów w porównaniu do modelu reprezentacji binarno-czasowej. Otrzymane rezultaty wskazują na zasadność wykorzystania modelu MSRBF do budowy algorytmów wspomagania decyzji inwestycyjnych.

Literatura

- Aldridge I. (2009), *High-frequency trading: a practical guide to algorithmic strategies and trading systems*, John Wiley and Sons.
- Bickford J.L. (2007), *Forex wave theory: a technical analysis for spot and futures currency traders*, The McGraw-Hill Companies, New York.
- Burgess G. (2010), *Trading and investing in the Forex markets using chart techniques*, John Wiley and Sons.
- Frost A.J., Prechter R.R. (2005), *Elliott wave principle: key to market behaviour*, Elliott Wave International.
- Logue D.E., Sweeney R.J. (1977), *White noise in imperfect markets: the case of the franc/dollar exchange rates*, „The Journal of Finance”, Vol. 32, Issue 3, s. 761-768.
- Murphy J. (1999), *Analiza techniczna rynków finansowych*, WIG PRESS, Warszawa.
- Neely C.J., Weller P.A. (2011), *Technical analysis in the foreign exchange market*, Working Paper 2011-001B, Federal Reserve Bank of St. Louis, St. Louis.
- Oberlechner T. (2005), *The psychology of the foreign exchange market*, John Wiley and Sons.
- Rukhin A., Soto J., Nechvatal J., Smid M., Barker E., Leigh S., Levenson M., Vangel M., Banks D., Heckert A., Dray J., Vo S. (2010), *A statistical test suite for random and pseudorandom number generators for cryptographic applications*, NIST Special Publication 800-22.
- Schlossberg B. (2006), *Technical analysis of the currency market*, John Wiley and Sons.

- Stasiak M.D. (2015), *Kurs USD/PLN w ujęciu binarnym*, „Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach” (przyjęty do publikacji).
- Stasiak M.D. (2016a), *Falowa analiza kursu USD/PLN w reprezentacji binarnej*, „Optimum. Studia Ekonomiczne” (przyjęty do publikacji).
- Stasiak M.D. (2016b), *Modelling of currency exchange rates using a binary representation*, Information Systems Architecture and Technology: Proceedings of 37th International Conference on Information Systems Architecture and Technology – ISAT 2016, Springer, Berlin-Heidelberg.
- Stasiak M.D. (2016c), *Modelling of currency exchange rates using a binary-temporal representation*, Proceedings of International Conference on Accounting Finance and Financial Institution: Theory meets Practice ICAFFI 2016, Springer, Berlin-Heidelberg (przyjęty do publikacji).
- Yao J., Tan C.L. (2000), *A case study on using neural networks to perform technical forecasting of Forex*, „Neurocomputing”, Vol. 34, Issue 1, s. 79-98.
- Yazdi S.H.M., Lashkari Z.H. (2013), *Technical analysis of Forex by MACD indicator*, „International Journal of Humanities and Management Sciences (IJHMS)”, Vol. 1, Issue 2, s. 159-165.

EXCHANGE RATE MODELLING IN BINARY REPRESENTATION WITH USE OF WAVE DEPENDENCES

Summary: The exchange rate trajectory can be visualized in a binary representation. The binarization algorithm transforms a course trajectory given by tick data into respective binary string. In this article author introduces a new state model for an exchange rate in a binary representation with use of wave dependences. The model describes states corresponding to given price change patterns and wave membership patterns of particular parameters. The process of wave detection and appointing wave parameters uses wave detection algorithms in binary representation, created by the author. In addition, author presents exemplary results of modelling AUD/NZD exchange rate with use of abovementioned model, calculated for historical data from 2011-2016 as well as a statistical analysis of obtained results.

Keywords: Forex, technical analysis, currency market investment decision support, exchange rate modelling, wave analysis.