

С.В. ЕНДИЯРОВ

**Построение системы
автоматической идентификации
периодических составляющих
временного ряда с применением
теории нечетких множеств.
Нечеткий периодический
коэффициент корреляции.**

УДК 004.9

Уральский государствен-
ный горный университет,
г. Екатеринбург

В статье дается краткое описание классических и современных методов идентификации периодических составляющих временных рядов. Рассматриваются процедуры необходимые для построения системы автоматической идентификации периодических составляющих. Особое внимание уделяется вопросу агрегации информации получаемой от различных методов. Предложен подход, основанный на теории нечетких множеств, разработано нечеткое отношение сходства периодических составляющих. Во второй части статьи вводится понятие нечеткого периодического коэффициента корреляции позволяющего оценивать «периодическую» связь между временными рядами.

In this article we briefly describe different methods of periodicities analysis we consider different procedures which can be useful for automatic identification of periodicities of time series. We pay close attention to the problem of information aggregation which is come from different methods. Approach utilizing fuzzy set theory is proposed. In the second part of the ar-

ticle we introduce the concept of fuzzy periodic correlation coefficient.

Введение

Временной ряд обычно колеблется вокруг тренда, причем отклонения от тренда часто обнаруживают правильность. Часто это связано с естественной или назначенной периодичностью, например, сезонной или недельной, месячной или квартальной. Иногда наличие периодичности и тем более ее причины неясны, и задача исследователя - выяснить, действительно ли имеется периодичность. В широком понимании к периодическим относят все явления, которые обнаруживают в своем развитии отчетливо выраженную закономерность внутригодичных изменений, т.е. более или менее устойчиво повторяющиеся из года в год колебания уровней. Часто эти колебания могут быть не связаны со сменой времен года. Как бы ни проявлялась периодичность, она наносит большой ущерб национальной экономике, связанный с неравномерным использованием оборудования и рабочей силы, с неравномерной загрузкой транспорта, необходимостью создания резервов мощностей и т.д. Для задачи поиска периодичностей существенными являются частичная потеря полезного сигнала, априорная неопределенность относительно частоты и фазы исследуемого сигнала, что в итоге дополняет проблемную ситуацию в области объекта исследования, затрудняя создание универсальных методов для решения рассматриваемой задачи.

1. Обзор существующих методов идентификации периодичностей

Проведем краткий анализ классических и современных средств и методов поиска скрытых периодичностей. Одним из классических методов анализа периодических составляющих является построение спектра рассматриваемого временного ряда [1]:

$$R_{xx}(f) = 2 \left[1 + 2 \sum_{k=1}^{L-1} r_{xx}(k) w(k) \cos 2\pi fk \right], 0 \leq f \leq 1/2 \quad (1)$$

где $r_{xx}(k)$ – автокорреляционная функция временного ряда, а $w(k)$ – корреляционное окно. Наличие периодической составляющей в сигнале определяется путем исследования локальных макси-

мумов графика функции $R_{xx}(f)$. Таким образом, спектр сигнала есть косинус преобразование его корреляционной функции.

Корреляционное окно используется для сглаживания исходного спектра сигнала и служит для улучшения определения периодических составляющих в сигнале по средствам удаления «шума».

Например, корреляционное окно Тьюки имеет вид:

$$w(u) = \begin{cases} \frac{1}{2} \left(1 + \cos \frac{\pi u}{M}\right), & u \leq M \\ 0, & u > M \end{cases} \quad (2)$$

Однако стоит помнить, что чем сильнее сглаживание, тем меньше дисперсия оценки, однако при этом возрастает смещение, или систематическое искажение. Поэтому стоит выбирать некоторый компромисс между смещением и дисперсией. На рисунке 1 представлен спектр сигнала Fe, данный временной ряд характеризует содержание железа в потоке шихты поступающей на агломерацию.




Рис. 1. Спектр сигнала Fe с использованием окна Тьюки разных размеров.

Как видно из рисунка, выбор окна задача не тривиальная, чем больше размер окна, тем меньше полезной информации будет удалено при сглаживании.

Кроме значительных сложностей связанных с использованием корреляционных окон и выбором оптимального размера окна стоит так же отметить, что частотное представление сигнала обладает еще рядом недостатков таким, например, как эффект размывания, утечки и наложения.

Другой подход связан с анализом автокорреляционной функции временного ряда. Выражение для автокорреляционной функции имеет вид (3).

$$r_{xx}(k) = \frac{\sum_{t=1}^{n-k} (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sqrt{\sum_{t=1}^{n-k} (y_t - \bar{y})^2 \sum_{t=1}^{n-k} (y_{t-k} - \bar{y})^2}} \quad (3)$$

По корреляционной функции так же можно в некоторых случаях определить наличие периодических составляющих, а так же период этих колебаний. Если сигнал содержит периодическую составляющую, то автокорреляционная функция будет иметь вид затухающей синусоидальной волны [2]. Пример автокорреляционной функции отражающей периодические составляющие показан на рисунке 2.




Рис. 2. Автокорреляционная функция сигнала Fe.

За последние годы резко возросло число работ, посвященных исследованию временных рядов с помощью, так называемого мето-

да нормированного размаха или R/S статистики. Наличие периодических составляющих определяется по изломам графика $\log(R/S)$ [3].

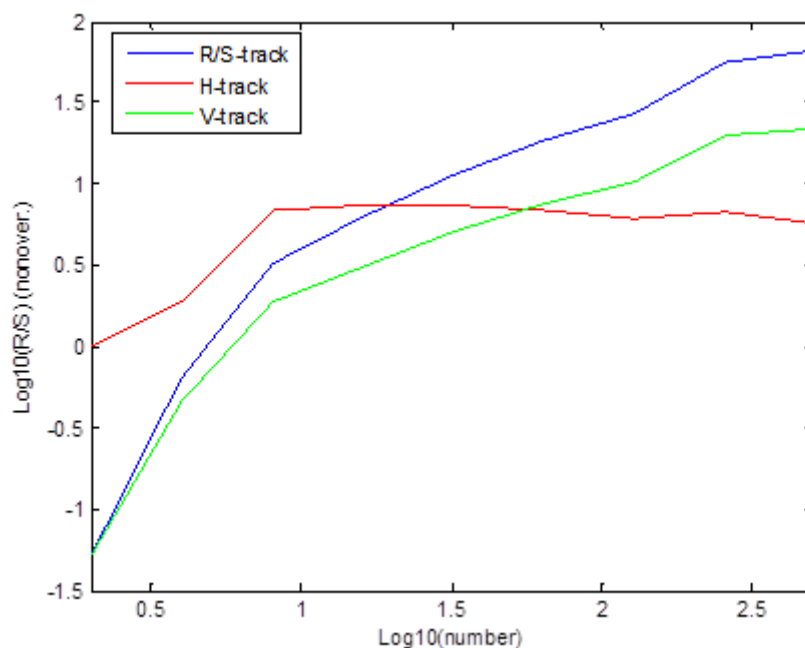


Рис. 3. R/S статистика для ряда Fe.

Пример построения нормированного размаха показан на рисунке 3. Изучая данную статистику (ее изломы), можно получить приближенные значения периодов циклических составляющих временного ряда. В общем случае для выявления периодичностей удобнее пользоваться V статистикой (4).

$$V = \frac{R/S}{\sqrt{n}} \quad (4)$$

Значение нормированного размаха в точках излома рассматривается совместно со спектром сигнала. По результатам сопоставления этих двух методов делаются выводы о наличии периодических и непериодических циклов. Стоит так же заметить, что представленный метод расчета R/S статистики не является единственным.

В арсенале современных методов анализа временных рядов возрастающее значение приобретает такой подход, как построение фазовых портретов [3]. В качестве фазового пространства используется простейший вариант вида $\Phi(x) = \{x(t), x(t+1)\}$. При этом нали-

чие периодических составляющих и их характеристики определяются по результатам анализа «квазициклов» [3]. Определение квазицикла в определенном смысле близко к определению цикла. Различие между этими двумя понятиями состоит в том, что начальная и конечная точки квазицикла не обязательно должны совпадать. Анализируя квазициклы, полученные после анализа фазового портрета, в общем случае, можно сделать вывод о наличии циклической составляющей в сигнале, а так же определить величину ее периода. Пример фазового портрета построенного по данным ряда Fe можно увидеть на рисунке 4.




Рис. 4. Фазовый портрет для ряда Fe.

Еще к одному часто используемому методу можно отнести так называемый спектральный анализ методом наименьших квадратов (Least-squares spectral analysis (LSSA)). Идея метода, в общем, заключается в переборе частот в заданном диапазоне $f \in [a, b]$ с заданным шагом Δ .

На каждом шаге исходные данные представляются набором синусов и косинусов:

$$f(t) = \sum_{i=0}^{m-1} a_i \phi_i(t) = a_0 + \sum_{j=1}^{\frac{m-1}{2}} [a_{2,j-1} \cos \frac{2\pi j}{m} t + a_{2,j} \sin \frac{2\pi j}{m} t] + \varepsilon_i \quad (5)$$

При этом коэффициенты a_i определяются методом наименьших квадратов. После чего рассчитываются среднеквадратические остатки:

$$e_i^2 = \frac{\sum_{t=1}^N (x(t) - f(t))^2}{N} \quad (6)$$

В результате получается множество остатков $e^2 \in (e_1^2, \dots, e_i^2, \dots, e_r^2)$. Затем построив график остатков, возможно, сделать заключение о наличии цикла на частоте на которой $e^2 \rightarrow \min$.

Все рассмотренные выше методы, как правило, используются совместно, так как ни один из них нельзя назвать «идеальным». Каждый метод обладает преимуществами и недостатками. После проведения анализа каждым из этих методов исследователю предоставляется большой массив информации, который необходимо проанализировать. Если необходимо проанализировать поведение объекта характеризуемого множеством временных рядов задача анализа становится нетривиальной.

В данной работе мы предлагаем метод автоматической идентификации периодических составляющих, позволяющий выявить основные периодические зависимости, используя все вышеперечисленные методы в совокупности. Для агрегации информации предлагается использовать теорию нечетких множеств.

2. Автоматическая обработка данных получаемых от различных методов идентификации периодичностей

2.1 Поиск локальных максимумов

Определение позиций пиков связано с теорией применения дифференциального исчисления к исследованию функций и необходимо для анализа информации порождаемой в ходе проведения спектрального анализа, R/S анализа, анализа методом LSSA. Для определения пиков необходимо использовать достаточный признак экстремума, который для точки максимума можно записать так:

$$\begin{cases} \frac{\partial f(x)}{\partial x} > 0, x < x^* \\ \frac{\partial f(x)}{\partial x} < 0, x > x^* \end{cases} \quad (7)$$

где x^* – есть точка максимума. По аналогии можно записать условия и для точки минимума.

2.2 Определение изломов R/S статистики

Изломы R/S статистики, вообще говоря, не являются экстремумами, а представляют собой отклонения графиков $\log(R/S)$ или $\log(V)$ от прямой линии вида $y = ax + b$. Используя соотношение линейной алгебры для определения угла между векторами, можно записать условие для определения мест изломов:

$$\cos \psi = \frac{\langle x, y \rangle}{|x| \cdot |y|} \quad (8)$$

Выражение (8) есть угол между векторами x и y . Полагая $x(t)$ значение временного ряда в момент времени t , определение точки излома можно записать в виде:

$$\psi = \arccos \frac{\langle x(t-1) - x(t), x(t+1) - x(t) \rangle}{|x(t-1) - x(t)| \cdot |x(t+1) - x(t)|} \neq 180^\circ \quad (9)$$

Таким образом, отклонения от 180° градусов можно считать изломом. Выражение (9) есть угол между векторами $x(t-1) - x(t)$ и $x(t+1) - x(t)$.

2.3 Отбраковка незначительных пиков

Метод обнаружения локальных экстремумов временного ряда применяется для анализа R/S статистики рассчитанной по методу перекрывающихся интервалов, анализа спектра и метода спектрального анализа методом наименьших квадратов. Для отбраковки незначительных пиков при анализе спектра использовалось выражение:

$$P\left\{\chi^2\left(\frac{\alpha}{2}\right) < \frac{\nu C_{xx}(f)}{\Gamma_{xx}(f)} \leq \chi^2\left(1 - \frac{\alpha}{2}\right)\right\} = 1 - \alpha \quad (10)$$

где $C_{xx}(f)$ – автоковариационная функция, а ν – число степеней свободы, которое определяется корреляционным окном. Если корреляционное окно не используется то $\nu = 2$.

Для рассмотренного выше окна Тьюки число степеней свободы определяется из выражения:

$$v = 2.667 \frac{N}{M} \quad (11)$$

При этом отбираются только пики, величина которых h , удовлетворяет условию:

$$h \geq \max\left(\frac{v C_{xx}(f)}{\chi^2\left(\frac{\alpha}{2}\right)}\right) \quad (12)$$

При анализе автокорреляционной функции можно использовать следующее выражение:

$$-n \frac{1}{\sqrt{N}} \leq r_{xx}(k) \leq n \frac{1}{\sqrt{N}} \quad (13)$$

Для отбраковки незначимых пиков при использовании метода спектрального анализа методом наименьших квадратов в виду характера функции распределения e^2 используется выражение:

$$h \leq E[e^2] \quad (14)$$

На рисунке 5 приведен пример использования выражения (12) для выделения значимых пиков спектра.




Рис. 5. Выделение значимых пиков спектра.

3. Агрегация полученных результатов

Важным вопросом при построении системы автоматического обнаружения периодических составляющих является вопросы локальной и глобальной агрегации информации полученной из различных источников. Причем под локальной агрегацией понимается обобщение информации полученной от какого-либо одного метода выделения периодичностей, полученной с использованием различных параметров метода или же его другой реализации (например, анализ спектра сигнала для различных значений ширина окна или, совсем без окна).

Под глобальной агрегацией будем понимать обобщение информации различных методов для получения конечного результата в виде нечеткого множества $\Lambda = (\frac{\mu(\lambda_1)}{\lambda_1}, \dots, \frac{\mu(\lambda_j)}{\lambda_j}, \dots, \frac{\mu(\lambda_n)}{\lambda_n})$ содержащее конечное число периодов обнаруженных в сигнале. В виду специфики рассмотренной задачи в качестве информации порождаемую методами выделения периодичностей предлагается использовать дискретные нечеткие множества:

$$A = \sum_{i=1}^n \frac{\mu(x_i)}{x_i} \quad (15)$$

Таким образом, информация от k 'ой реализации метода $D \in Q$ (где Q – конечное множество методов решения поставленной задачи) агрегируется следующим образом:

$$\mu^k(x_i) = z_i^k \quad (16)$$

где z_i^k – некоторое число, сопоставленное со значением периода x_i k 'ой реализации метода D . После получения значений функции принадлежности по выражению (16), необходимо провести нормирование данного нечеткого множества:

$$\mu_{A_n} = \frac{\mu_A(x)}{\sup_x \mu_A(x)} \quad (17)$$

В результате для N реализаций метода D получаем множество нечетких множеств $Y = (A_1, \dots, A_N)$. Поскольку как правило различные реализации одного и того же метода дают близкие результаты для локальной агрегации предложено использовать оператор нечеткой

логики $MEAN$ [6]. В результате чего получаем локальное нечеткое решение Θ_k в виде:

$$\Theta_k = MEAN(Y) = MEAN_{f=x_j}(\mu_{A_1}(f), \mu_{A_2}(f), \dots, \mu_{A_N}(f)) \quad (18)$$

В результате работы получим множество нечетких локальных решений $Z = (\Theta_1, \dots, \Theta_G)$. Пример локальных нечетких решений $Z = (\Theta_1, \dots, \Theta_G)$ для ряда Fe приведен на рисунке . 6.




Рис. 6. Локальные решения $Z = (\Theta_1, \dots, \Theta_G)$ в виде нечетких множеств для ряда Fe.

Для отбраковки незначительных периодических составляющих и в то же время для сохранения «уникальных» периодичностей выделенных лишь несколькими из используемых методов $D \in \square$, предлагается использовать оператор $softMIN$ [6]:

$$softMIN(\mu(x_1), \dots, \mu(x_n)) = \frac{\sum_{i=1}^n \mu(x_i) \cdot e^{-k\mu(x_i)}}{\sum_{i=1}^n e^{-k\mu(x_i)}} \quad (19)$$

где k – настроечный параметр (при $k \rightarrow \infty$ оператор $softMIN$ приближается к «жесткой» форме MIN).

Таким образом, получаем глобальное решение Λ , применив оператор $softMIN$ к множеству локальных решений $Z = (\Theta_1, \dots, \Theta_G)$:

$$\Lambda = \underset{f=x_j}{\text{softMIN}}(\Theta_1, \dots, \Theta_G) = \frac{\sum_{i=1}^G \mu_{\Theta_i}(f) \cdot e^{-k\mu_{\Theta_i}(f)}}{\sum_{i=1}^G e^{-k\mu_{\Theta_i}(f)}} \quad (20)$$

Более точное решение получается, если использовать для локальных решений разработанное автором статьи нечеткое отношение:

$$\mu_R(x, y) = \begin{cases} \mu_R^*(x^*, y^*, \Delta\psi), \\ \text{if } x^* = \text{MIN}(x, y), \\ y^* = \text{MAX}(x, y), \\ \Delta\psi = y^* - x^*. \end{cases} \quad (21)$$

где $\mu_R^*(x^*, y^*, \Delta\psi)$ определяется следующим образом:

$$\mu_R^*(x^*, y^*, \Delta\psi) = \text{MIN}\left(\frac{x^*}{y^*}, \text{MEAN}(\Phi(x^*, \Delta\psi), \Phi(y^*, \Delta\psi))\right) \quad (22)$$

А выражения для $\Phi(x, \Delta\psi)$ и для $R(x, \Delta\psi)$ имеют вид:

$$\Phi(x, \Delta\psi) = \begin{cases} 1, \text{ when } R(x, \Delta\psi) < 0 \text{ or } R(x, \Delta\psi) = -\infty, \\ 1 - R(x, \Delta\psi), \text{ otherwise.} \end{cases} \quad (23)$$

$$R(x, \Delta\psi) = \begin{cases} 1, \text{ when } \frac{\log_2 \Delta\psi}{\log_2 x} > 1, \\ \frac{\log_2 \Delta\psi}{\log_2 x}, \text{ otherwise.} \end{cases} \quad (24)$$

Тогда преобразование выражения (21) в классическое или бинарное отношение запишется следующим образом:

$$R(x, y) = \begin{cases} 1, \text{ if } \mu_R(x, y) \geq \delta \\ 0, \text{ otherwise} \end{cases} \quad (25)$$

где δ – коэффициент оптимизма.

Используя выражение (25), получается, построить глобальное решение Λ в виде «нечеткой» гистограммы частот. Если требуется более тонкая настройка, то выражение (22) можно записать в виде:

$$\mu_R^*(x^*, y^*, \Delta\psi, k_1, k_2) = \text{softMIN}\left(\frac{x^*}{y^*}, \text{softMIN}(\Phi(x^*, \Delta\psi), \Phi(y^*, \Delta\psi), k_2), k_1\right) \quad (26)$$

При использовании выражения (26) требуется задание уже трех параметров: k_1, k_2 и δ . Изображение нечеткого отношения $\mu_R^*(x^*, y^*, \Delta\psi)$ представлено на рисунке 7.




Рис. 7. Нечеткое отношение сходства $\mu_R^*(x^*, y^*, \Delta\psi)$.

Из рисунка видно, что наше доверие к разнице между периодами растет с ростом порядка сравниваемых периодических составляющих. Поведение предлагаемого нечеткого отношения (22) при изменении коэффициента оптимизма представлено на рисунке 8.




Рис. 8. Изменение нечеткого отношения сходства $\mu_R^*(x^*, y^*, \Delta\psi)$ при различных значениях параметра δ .

Окончательно применяя к множеству Λ , оператор альфа среза, получим решение в виде:

$$\Lambda^{\geq\alpha} = \{\lambda : \lambda \in \Lambda, \mu(\lambda) \geq \alpha\} \quad (27)$$

4. Периодический коэффициент корреляции

После того как решение Λ для некоторого ряда j получено, может возникнуть задача сравнения различных временных рядов между собой по периодическим составляющим. Например, возможность производить сравнение может быть полезной при анализе большого числа временных рядов, когда необходимо построение их моделей. В результате сравнения аналитик сможет понять, какие временные ряды стоит рассматривать отдельно, а какие имеют схожие характеристики, а значит, будут иметь и схожие модели. Кроме того сопоставление рядов может рассматриваться как средство диагностики например получение решения Λ для одного и того же ряда на различных интервалах Λ^t и Λ^{t+1} может, позволит сделать определенные выводы о качестве управления. Может использоваться в имитационных моделях для оценки действий человека обучающегося управлению, какого-либо объекта и многое другое.

Таким образом, задачу сопоставления рядов можно записать следующим образом: дано конечное множество $\Omega = (\Lambda_1, \dots, \Lambda_m)$, характеризующее периодические составляющие m временных рядов. Тогда матрица H есть матрица периодической близости рядов между собой, и элемент матрицы φ_{ij} есть периодический коэффициент корреляции между решениями Λ_i и Λ_j :

$$H = \begin{bmatrix} 1 & \varphi_{12} & \dots & \varphi_{1m} \\ \varphi_{21} & 1 & \dots & \varphi_{2m} \\ \dots & \dots & \varphi_{jk} & \dots \\ \varphi_{m1} & \varphi_{m2} & \dots & 1 \end{bmatrix} \quad (28)$$

Сравнение решений Λ_i и Λ_j представляет собой сравнение двух нечетких множеств представляемых соответствующие решения.

Классический критерий сравнения нечетких множеств может быть записан в виде:

$$\varphi(x, y) = \frac{\sum_{k=1}^m \text{MIN}(\mu_k(x), \mu_k(y))}{\sum_{k=1}^m \text{MAX}(\mu_k(x), \mu_k(y))} \quad (29)$$

где $\varphi(x, y)$ – коэффициент лингвистической корреляции элементов $x, y \in X$.

Однако применения данного критерия не дает удовлетворительного результата, так как сравнение множеств происходит с использованием «жестких» операторов MIN и MAX , кроме того сравнение происходит для элементов множества когда x строго равно y то есть $x = y$. В результате сравнивая временные ряды, например, содержащие периоды 49.99 и 50, получим коэффициент лингвистической корреляции $\varphi(x, y) = 0$.

В результате рассмотренных недостатков меры (29) необходимо создание другой нечеткой меры схожести множеств.

Для адекватного сравнения множеств предлагается использовать методы самоорганизации, то есть методы обучения без учителя.

С целью сравнения одно из множеств Λ_i и Λ_j разбивается на функции принадлежности с помощью метода кластеризации Fuzzy c-means (FCM).

Метод FCM позволяет построить оптимальное разбиение пространства с целью сравнения двух временных рядов Λ_i и Λ_j так как он минимизирует взвешенную сумму квадратов евклидовых расстояний между элементами j и кластерами i , которая выражается в виде:

$$Q = \sum_{i=1}^c \sum_{j=1}^N (\mu_{ij})^q \|x_j - m_i\|^2 \rightarrow \min_{m_1, \dots, m_c} \quad (30)$$

Таким образом, получается «натуральное» разбиение исходного множества.

После проведения кластеризации исходные множества Λ_i и Λ_j могут быть сравнены с использованием модифицированной меры связи – периодического коэффициента корреляции:

$$\eta(x, y) = \sum_{k=1}^m \text{MIN}(\mu(y), \omega_k(y)) / m \quad (31)$$

где $\omega_k(y)$ – максимальная принадлежность множества y к одной из функций принадлежности x , найденных методом FCM. При этом вводится коэффициент оптимизма δ , в результате чего выражение для $\omega_k(y)$ примет вид:

$$\omega_k(y) = \begin{cases} \omega_k(y), & \omega_k(y) \geq \delta \\ 0, & \omega_k(y) < \delta \end{cases} \quad (32)$$

Полученная таким образом мера связи удовлетворяет неравенству:

$$0 \leq \eta(x, y) \leq 1 \quad (33)$$

Данная мера затем может быть преобразована в лингвистическую переменную для, более простой трактовки по средствам следующих правил (34).

$$\left\{ \begin{array}{l} \text{IF } \eta(x, y) = \text{VERY SMALL THEN TIME SERIES} = \text{VERY DIFFERENT} \\ \dots \\ \text{IF } \eta(x, y) = \text{CLOSE TO ONE THEN TIME SERIER} = \text{SIMILAR} \end{array} \right. \quad (34)$$

Для классификации рядов был использован алгоритм вывода Мамдани. Нечеткие функции принадлежности выхода представлены на рисунке 9.

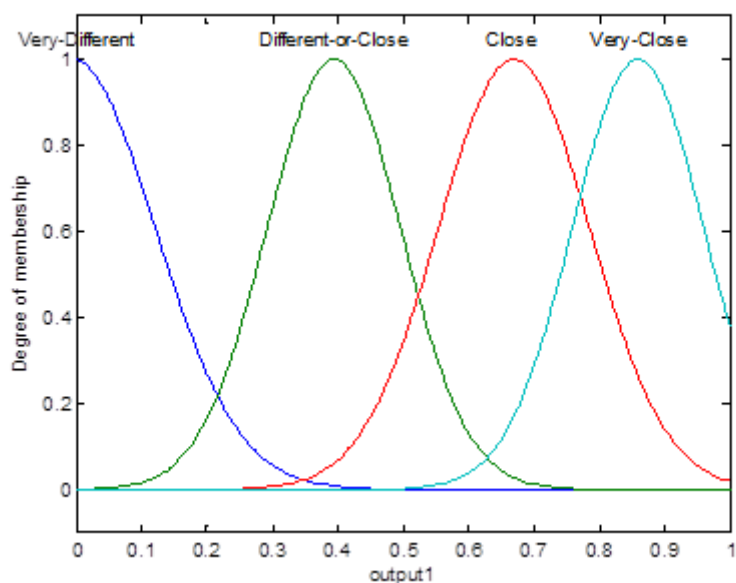


Рис. 9. Функции принадлежности выходов.

Каждой функции принадлежности в соответствие были сопоставлены следующие цвета: белый – нет периодической связи, желтый – слабая периодическая связь, фиолетовый – средняя периодическая связь и красный – сильная периодическая связь. Результаты работы алгоритма для сравнения рядов по железу (Fe), кальцию (CaO), кремнию (SiO) и оксиду железа (FeO), представлены на рисунке 10.




Рис. 10. Матрица периодической корреляционной связи между временными рядами.

Из рисунка 10 видно, что ряды Fe и CaO и SiO₂ обладают слабой периодической связью и совершенно отсутствует периодическая связь данных рядов с FeO. Используя результаты, полученные после агрегации информации, получим следующие решения для вышеперечисленных рядов: $\Lambda^{Fe} = (\frac{50}{0.8}, \frac{240}{0.73})$, $\Lambda^{CaO} = (\frac{8}{0.7}, \frac{10}{0.4}, \frac{50}{0.66})$, $\Lambda^{SiO_2} = (\frac{8}{0.6}, \frac{49}{0.58}, \frac{128}{0.72})$, $\Lambda^{FeO} = (\frac{32}{0.4}, \frac{47}{0.33}, \frac{128}{0.51}, \frac{230}{0.32}, \frac{395}{0.22})$. Видно, что рисунок 10 достоверно отражает связь между временными рядами по периодическим компонентам. Как видно из приведенного анализа наиболее «трудным» в плане анализа является ряд FeO так как для данного ряда процедура автоматического выделения идентифицировала слишком много периодических составляющих. Причиной может являться отсутствие периодических составляющих в ряде FeO как таковых, в результате чего разные методы выделил совершенно разные периодические компоненты.

Выводы

Использование процедуры автоматической идентификации периодических составляющих временных рядов показывает, что ее применение позволяет эффективно выделять существующие в сигнале периодические сигналы, что может существенно облегчить работу по анализу объектов описываемых множеством временных рядов. Автоматизированная процедура идентификации периодичностей позволяет снизить количество ошибок и значительно ускорить процесс работы аналитика. Введение понятия периодического коэффициента корреляции может быть полезной при анализе большого числа временных рядов, когда необходимо построение их моделей. В результате сравнения аналитик сможет понять, какие временные ряды стоит рассматривать отдельно, а какие имеют схожие характеристики, а значит, будут иметь и схожие модели. Кроме того сопоставление рядов может рассматриваться как средство диагностики исследуемого процесса.

Литература

1. Бокс Дж., Дженкинс Г. Анализ временных рядов: прогноз и управление. Выпуск 1. М.: Мир, 1974. – 390 с.
2. Дженкинс Г., Ваттс Д. Спектральный анализ и его приложения: В 2 т./ Пер. с англ. Ф. М. Писаренко с предисловием А. М. Яглома - М.: Мир, 1971. – 158 с.
3. Петерс Э. Хаос и порядок на рынках капитала. Новый аналитический взгляд на циклы, цены и изменчивость рынка. – М.: Мир, 2000. – 333 с.
4. Craymer M. R. The least squares spectrum, its inverse transform and autocorrelation function: theory and some applications in geodesy. Ph.D. Dissertation, University of Toronto, Canada, 1998. – 159 p.
5. Отнес Р., Эноксон Л. Прикладной анализ временных рядов. Основные методы: — М.: Мир, 1982. – 428 с.
6. Пегат А. Нечеткое моделирование и управление / А. Пегат ; пер. с англ. — М. : БИНОМ. Лаборатория знаний, 2009. — 798 с. :ил. — (Адаптивные и интеллектуальные системы).

E-MAIL: ENDEYAROV@OLYMPUS.RU

НАУЧНЫЙ РУКОВОДИТЕЛЬ:
Д.Т.Н. ЗОБНИН Б.Б.