Наука и Образование
МГТУ им. Н.Э. Баумана
Сетевое научное издание
ISSN 1994-0408

Наука и Образование. МГТУ им. Н.Э. Баумана.
Электрон. журн. 2016. № 09. С. 60–73.

DOI: **10.7463/0916.0845015**

Представлена в редакцию: 04.08.2016
Исправлена: 18.08.2016

© МГТУ им. Н.Э. Баумана

УДК 519.688

Оценка прогнозируемости динамических показателей на основе коэффициента ранговой корреляции

Краковский Ю. М.[1], **Лузгин А. Н.**[2,*] *alexln@mail.ru

[1]Иркутский государственный университет путей сообщения, Иркутск, Россия
[2]Администрация города Иркутска, Иркутск, Россия

Предложен и протестирован алгоритм расчета коэффициента интервальной прогнозируемости динамического показателя на основе коэффициента ранговой корреляции Спирмена. Экспериментально показано, что значение коэффициента интервальной прогнозируемости, рассчитанное по предыстории динамического ряда, позволяет количественно оценить, насколько целесообразно проводить интервальное прогнозирование динамического показателя на основе кластерных или нейронных моделей, исходя из его статистических свойств. Интервальное прогнозирование заключается в оценке прогнозных значений динамического показателя на основе вероятностей их принадлежности введённым интервалам. Так как при таком прогнозировании оценивается не само будущее значение показателя, а то, в каком интервале оно будет находиться, такое прогнозирование названо интервальным, а соответствующие вероятности интервальными. Для тестирования интервального прогнозирования использовался программный комплекс, реализованный на языке программирования для статистической обработки данных с открытым исходным кодом «R».

Ключевые слова: интервальное прогнозирование, оценка прогнозируемости, динамический показатель, ранговая корреляция, точность прогнозирования

Введение

Большинство современных организаций и предприятий осуществляют свою деятельность в условиях неопределённости, когда последствия и эффективность принятия управленческих решений напрямую зависят от точности прогнозирования базовых динамических показателей, являющихся по своей природе случайными величинами. К наиболее перспективным методам прогнозирования таких показателей следует отнести кластерные и нейронные методы [1-14].

Ранее авторами данной статьи был предложен подход интервального прогнозирования (ИП) динамических показателей (ДП) на основе адаптивной вероятностно-статистической кластерной модели (АВСКМ) [15] и модели вероятностной нейронной сети (ВНС) [16] суть которого состоит в следующем.

Формализуем ДП в виде временного ряда:

$$\mathbf{Q} = \{q_t : t \in \mathbf{T}^*\}. \quad (1)$$

Здесь q_t – значения ДП, доступные в дискретные моменты времени t, t принимает значения из множества $\mathbf{T}^* = \{0,...,m-1\}$, m – количество доступных значений ДП.

Введем интервал возможных значений ДП $(c_1; c_2)$, где $c_1 > 0$, $c_2 < \infty$, и внутреннюю точку c : $c_1 < c < c_2$. Это позволяет создать два интервала:

$$\mathrm{I}^{\downarrow} = (c_1; c], \mathrm{I}^{\uparrow} = (c; c_2). \quad (2)$$

Интервальное прогнозирование (ИП) ДП заключается в оценке их прогнозных значений на основе вероятностей их принадлежности интервалам $\mathrm{I}^{\uparrow}$ и $\mathrm{I}^{\downarrow}$ (2). Так как при таком прогнозировании оценивается не само будущее значение ДП, а то, в каком интервале оно будет находиться, такое прогнозирование названо интервальным, а соответствующие вероятности интервальными.

Введем величину Δ, рассчитывать которую будем так:

$$\Delta = \alpha \cdot \bar{q}, \quad (3)$$

где $\alpha \in [-1;1]$ – коэффициент, задается заранее, $\bar{q}$ – определяется согласно (4).

$$\bar{q} = \left(\sum_{t=1}^{m-1} |q_t - q_{t-1}| \right) / (m-1). \quad (4)$$

При ИП ДП (1) в момент времени $t = m-1$ необходимо провести оценку интервальной вероятности ρ_{t+p}^{+} того, что будущее значение $q_{t+p} \in \mathrm{I}^{\uparrow}$ или оценку интервальной вероятности ρ_{t+p}^{-} того, что будущее значение $q_{t+p} \in \mathrm{I}^{\downarrow}$, где $\mathrm{I}^{\uparrow}$ и $\mathrm{I}^{\downarrow}$ определяется по формуле (2), $p = 1,...,r$ есть время упреждения, а $\rho_{t+p}^{+} + \rho_{t+p}^{-} = 1$. Если оценки интервальных вероятностей $\rho_{t+p}^{+} = \rho_{t+p}^{-} = 1/2$ (ситуация неопределённости), то прогнозирование не делается. Величина $c = (q_t + \Delta)$ – разделительная граница интервалов, а Δ (3) – смещение относительно значения q_t.

Перед проведением интервального прогнозирования и оценкой интервальных вероятностей, необходимо, в соответствии с описанными в статьях [15,16] алгоритмами, построить АВСКМ, либо ВНС. При построении таких моделей и расчете их параметров используется вся доступная предыстория значений ДП, которая непосредственно влияет на качество построенной модели и, как следствие, на точность интервального прогнозирования в будущий момент времени. Возникает вопрос: а можно ли по предыстории ДП количественно оценить возможность осуществления интервального прогнозирования на основе АВСКМ или ВНС, не осуществляя само прогнозирование?

В данной статье предлагается оценивать возможность осуществления интервального прогнозирования выбранного ДП с помощью коэффициента интервальной прогнозируемости (КИП), для вычисления которого используется модифицированный ранговый ко-

эффициент корреляции. Алгоритм расчета и название данного коэффициента предложено авторами данной статьи.

1. Исходные данные и определения

Предварительные эксперименты показывают, что для более точных оценок КИП необходимо исключить из ДП (1) трендовые составляющие. Для этого применяется метод конечных разностей первого порядка:

$$s_t = q_t - q_{t-1}, \tag{5}$$

где s_t – преобразованные значения ДП, q_t – исходные значения ДП (1), $t \in [1;m-1]$. После проведения процедуры преобразования запишем ДП так:

$$\mathbf{S} = \{s_t : t \in \mathbf{T}\}. \tag{6}$$

Здесь t принимает значения из множества $\mathbf{T} = \{0,...,n-1\}$, n – количество доступных значений преобразованного ДП.

Под кластером $\mathbf{S_i^f} = \{s_i,...,s_{i+f-1}\}$ будем понимать выборку последовательных значений из (6) с позиции $i \in \mathbf{T}$ и с количеством значений $f = 1,...,n$, при этом $(i+f-1) \in \mathbf{T}$. Осуществим ранжирование элементов кластера $\mathbf{S_i^f}$ по возрастанию (нескольким одинаковым значениям элементов кластера присваивается среднее значение их рангов). Тогда $\mathbf{R_i^f} = \{r_i,...,r_{i+f-1}\}$ – множество рангов, где r_t – значения рангов элементов кластера $\mathbf{S_i^f}$.

2. Алгоритм расчета коэффициента интервальной прогнозируемости

Применение КИП основывается на следующей предпосылке: если количественно оценить множественную взаимосвязь между базовым кластером и другими кластерами предыстории ДП, то можно дать рекомендацию о целесообразности или нецелесообразности интервального прогнозирования ДП на основе кластерных и нейронных моделей.

Для определения взаимосвязи между парой кластеров предлагается использовать модифицированный авторами коэффициент ранговой корреляции Спирмена. Выбор данного коэффициента обусловлен его независимостью от закона распределения вероятностей случайных величин.

Выделим из (6) два кластера $\mathbf{S_k^f} = \{s_k,...,s_{k+f-1}\}$ и $\mathbf{S_j^f} = \{s_j,...,s_{j+f-1}\}$, где $k \neq j$. Определим для выделенных кластеров два множества рангов $\mathbf{R_j^f}$ и $\mathbf{R_k^f}$. Тогда расчет коэффициента ранговой корреляции Спирмена (КРК) будем осуществлять по формуле:

$$d_{j,k}^{f}(\mathbf{R_j^f}, \mathbf{R_k^f}) = \begin{cases} 1 - \dfrac{6 \cdot \sum\limits_{\xi=0}^{f-1} \left(r_{j+\xi} - r_{k+\xi}\right)^2}{f \cdot \left(f^2 - 1\right)}, f \neq 1, \\ 1, f = 1. \end{cases} \tag{7}$$

Данная формула отличается от общеизвестной [17] тем, что содержит в себе дополнительные условия на случай, когда производится расчет значения КРК для кластеров, состоящих из единственного значения.

Выделим из (6) кластер $\mathbf{S_i^f} = \{s_i,...,s_{i+f-1}\}$ при $i = n - f$ и назовем его базовым кластером, где $f \in [1;n-1]$.

Для фиксированного f и всех значений $k \in [0, i-1]$ рассчитаем множество значений КРК (7) между базовым кластером $\mathbf{S_i^f} = \{s_i,...,s_{i+f-1}\}$ и кластерами $\mathbf{S_k^f} = \{s_k,...,s_{k+f-1}\}$, среди которых найдем минимальное:

$$d_{\min}^{f} = \min\left(\mathbf{D^f}\right). \tag{8}$$

Здесь $\mathbf{D^f} = \{d_{i,1}^{f},..., d_{i,i-1}^{f}\}$ – множество значений КРК между базовым кластером $\mathbf{S_i^f}$ и кластерами $\mathbf{S_k^f}$. Величины (8) для различных f образуют множество $\mathbf{D} = \{d_{\min}^{1},..., d_{\min}^{n-1}\}$. Тогда КИП, который измеряет множественную взаимосвязь между кластерами, предлагается рассчитывать по формуле:

$$K_{n-1} = \left(\sum_{f=1}^{n-1} d_{\min}^{f}\right) / (n-1). \tag{9}$$

С учетом выше изложенного, алгоритм оценки коэффициента интервальной прогнозируемости ДП содержит следующие этапы:

1) Подготовка исходных данных (1);
2) Исключение тренда из исходных данных методом конечных разностей (5) для получения (6);
3) Задание $f = 1$, $i = n - f$, $\mathbf{D} = \{\}$;
4) Задание $k = 0$;
5) Выделение из (6) базового кластера $\mathbf{S_i^f} = \{s_i,..., s_{i+f-1}\}$, $\mathbf{D^f} = \{\}$;
6) Выделение из (6) кластера $\mathbf{S_k^f} = \{s_k,..., s_{k+f-1}\}$;
7) Определение для кластеров $\mathbf{S_i^f}$ и $\mathbf{S_k^f}$ двух множеств рангов $\mathbf{R_i^f}$ и $\mathbf{R_k^f}$;
8) Расчет КРК $d_{j,k}^{f}$ (7) и добавление его во множество $\mathbf{D^f}$;
9) Если $k < i - 1$, то $k = k + 1$ и возвращаемся на шаг 6; иначе шаг 10;
10) Расчет значения $d_{\min}^{f}$ (8), добавление его во множество $\mathbf{D}$;
11) Если $f < n - 1$, то $f = f + 1$ и возвращаемся на шаг 5; иначе шаг 12;
12) Расчет K_{n-1} (9).

3. Тестирование алгоритма расчета коэффициента интервальной прогнозируемости

Учитывая коммерческий характер производственно-финансовых показателей организаций, в качестве подходящих и общедоступных примеров ДП при тестировании алгоритма расчета КИП были выбраны ежедневный курс евро в рублях и ежедневный курс доллара США в рублях за 2015 год, предварительно сглаженные простым скользящим средним первого (то есть сглаживание как таковое не проводилось), третьего и пятого порядка. Сглаживание влияет на статистические свойства ДП, которые, в свою очередь, влияют на точность прогнозирования. Алгоритм расчета КИП реализован на свободно распространяемом языке программирования для статистической обработки данных с открытым исходным кодом «R» [18,19]. Количество значений в выбранных ДП $n = 250$, интервал тестирования $w = 50$ (используется 50 последних значений ДП для последовательного расчета КИП).

Введем условные обозначения выбранных для тестирования ДП: EUR/RUR (1), EUR/RUR (3), EUR/RUR (5) – ежедневный курс евро к рублю, сглаженный простым скользящим средним первого, третьего и пятого порядка соответственно; USD/RUR (1), USD/RUR (3), USD/RUR (5) – ежедневный курс доллара к рублю, сглаженный простым скользящим средним первого, третьего и пятого порядка соответственно.

На рисунках 1-2 представлены результаты расчета КИП по ДП EUR/RUR (1) и USD/RUR (1). Значения КИП, полученные на интервале тестирования ($w = 50$) невысокие, в среднем около 0,3. В данном случае не стоит ожидать высокую точность интервального прогнозирования на всем интервале тестирования.

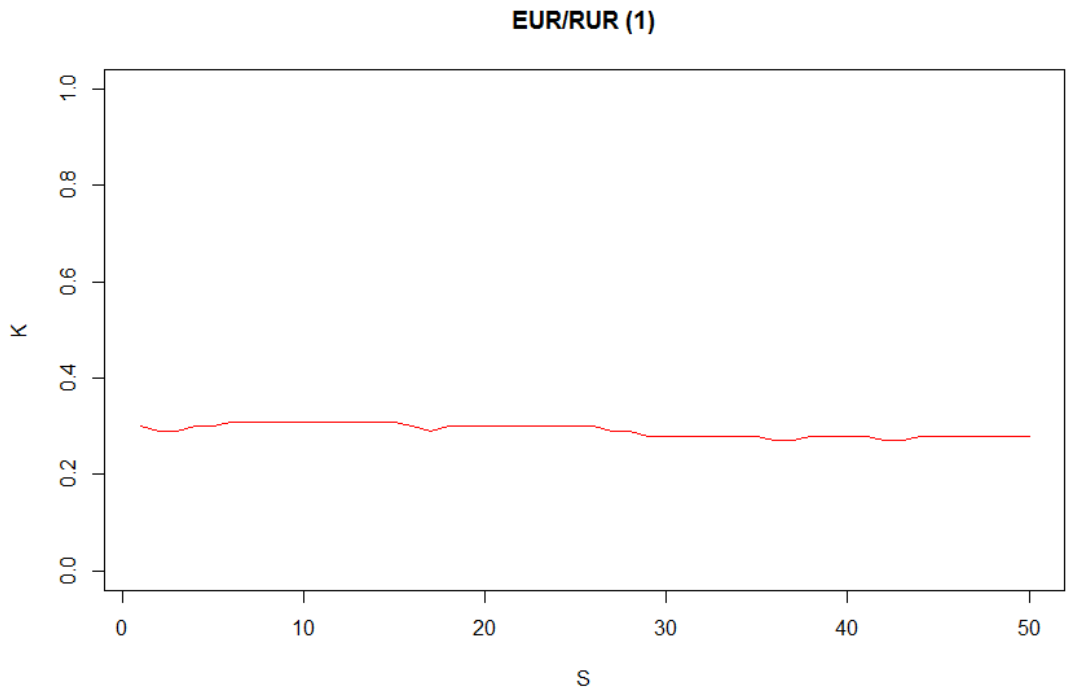

Рис. 1. Результаты расчета КИП по ДП EUR/RUR (1)

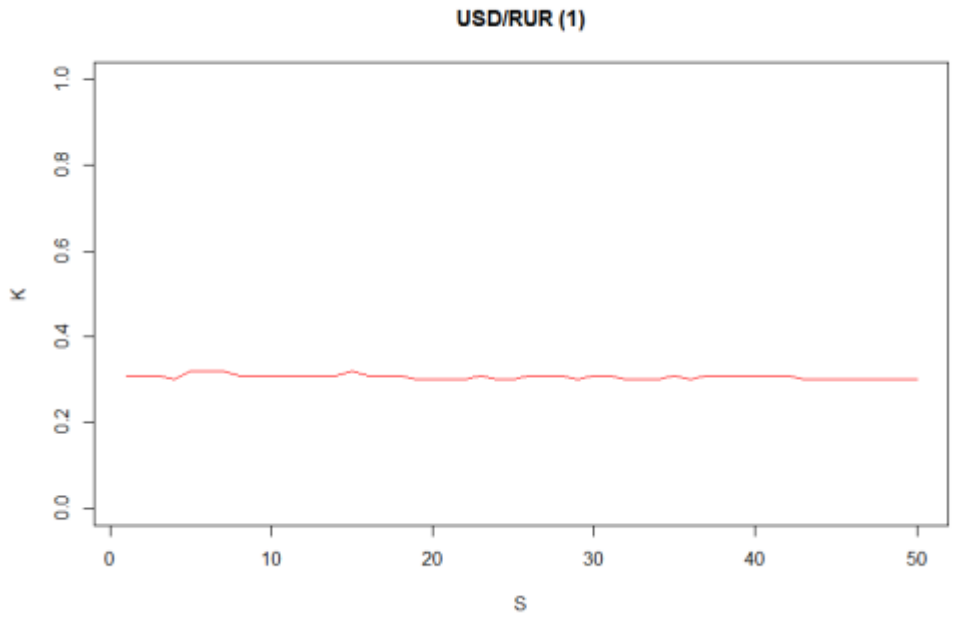

Рис. 2. Результаты расчета КИП по ДП USD/RUR (1)

На рисунках 3-4 представлены результаты расчета КИП по ДП EUR/RUR (3) и USD/RUR (3). Полученные значения КИП, в отличие от предыдущего случая, больше и составляют в среднем около 0,6. Достигается это за счет сглаживания исходного ДП простым скользящим средним третьего порядка и изменением их статистических свойств (уменьшаются нелинейные динамически изменяющиеся взаимосвязи). Точность интервального прогнозирования в этом случае должна быть выше, чем в предыдущем случае на всем интервале тестирования.

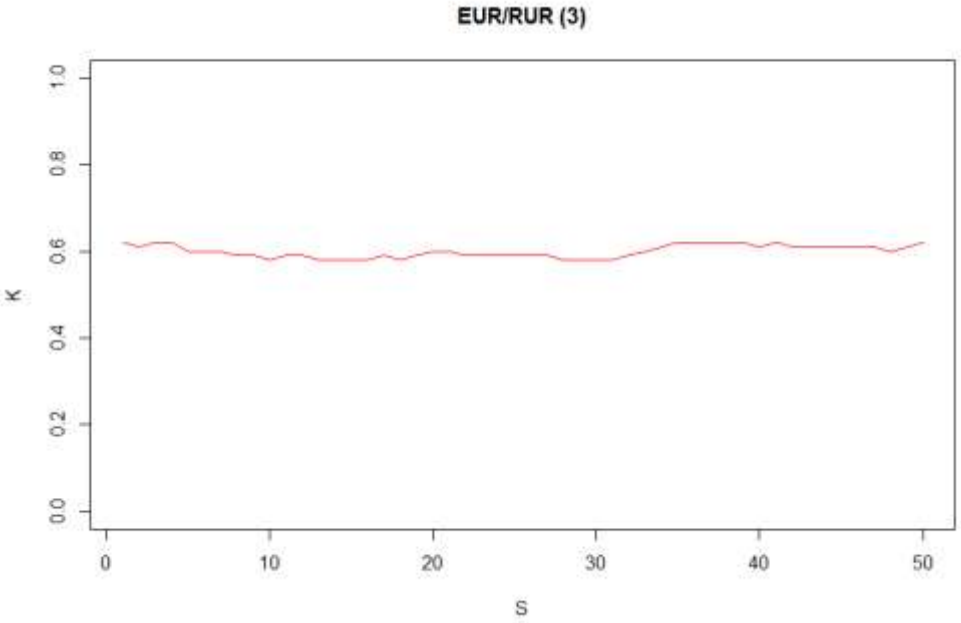

Рис. 3. Результаты расчета КИП по ДП EUR/RUR (3)

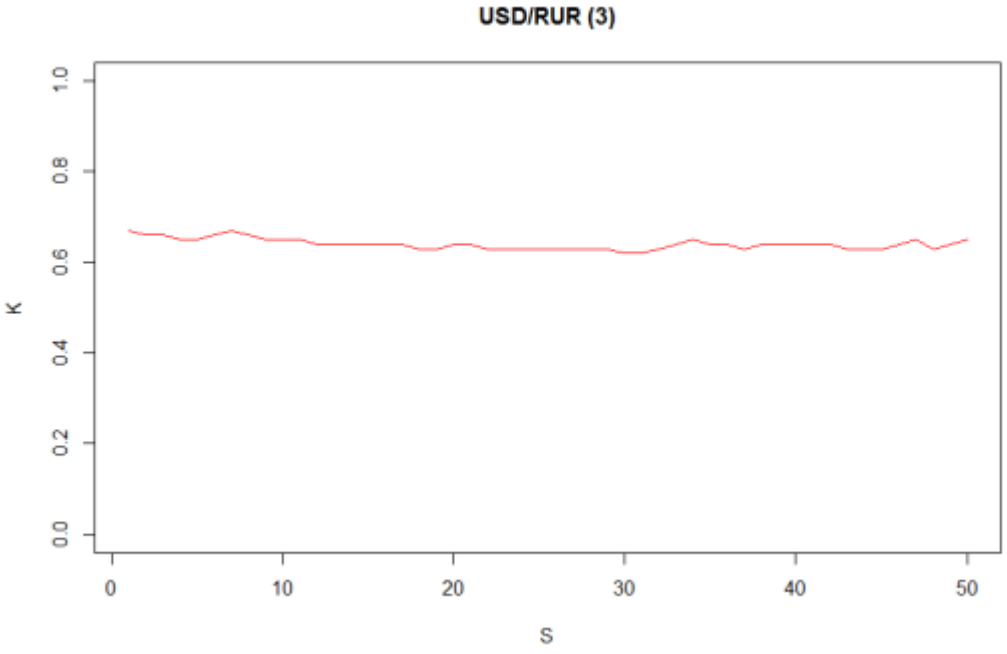

Рис. 4. Результаты расчета КИП по ДП USD/RUR (3)

На рисунках 5-6 представлены результаты расчета КИП по ДП EUR/RUR (5) и USD/RUR (5). Для этого случая полученные значения КИП максимальны и составляют в среднем около 0,8. Это связано с увеличением порядка сглаживания ДП и еще большим уменьшением нелинейных динамически изменяющихся взаимосвязей. Точность интервального прогнозирования на всем интервале тестирования должна быть максимальной, по сравнению со всеми предыдущими случаями.

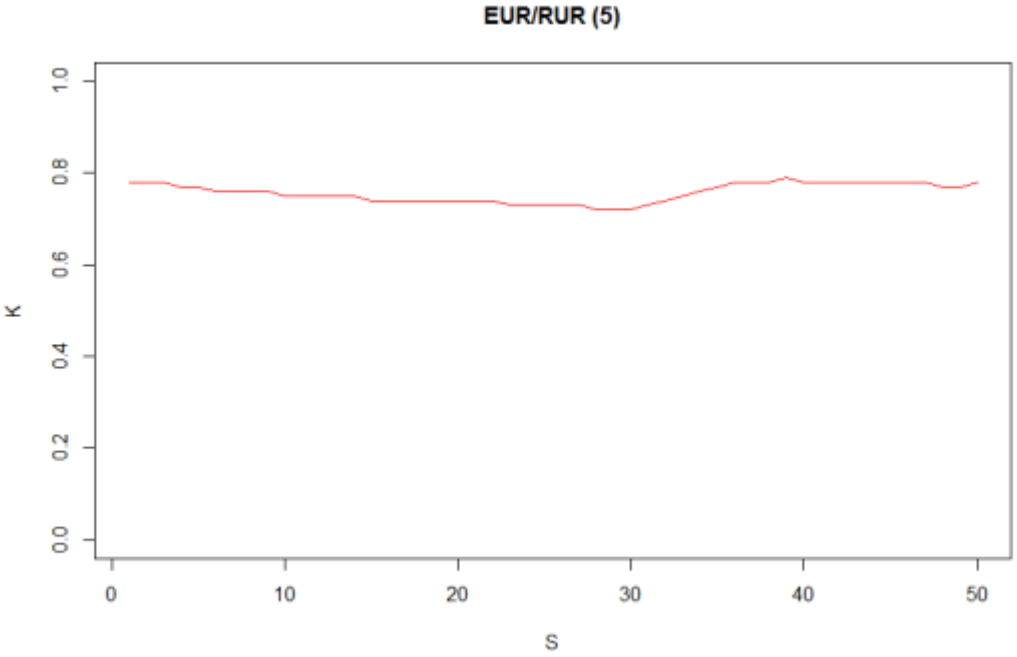

Рис. 5. Результаты расчета КИП по ДП EUR/RUR (5)

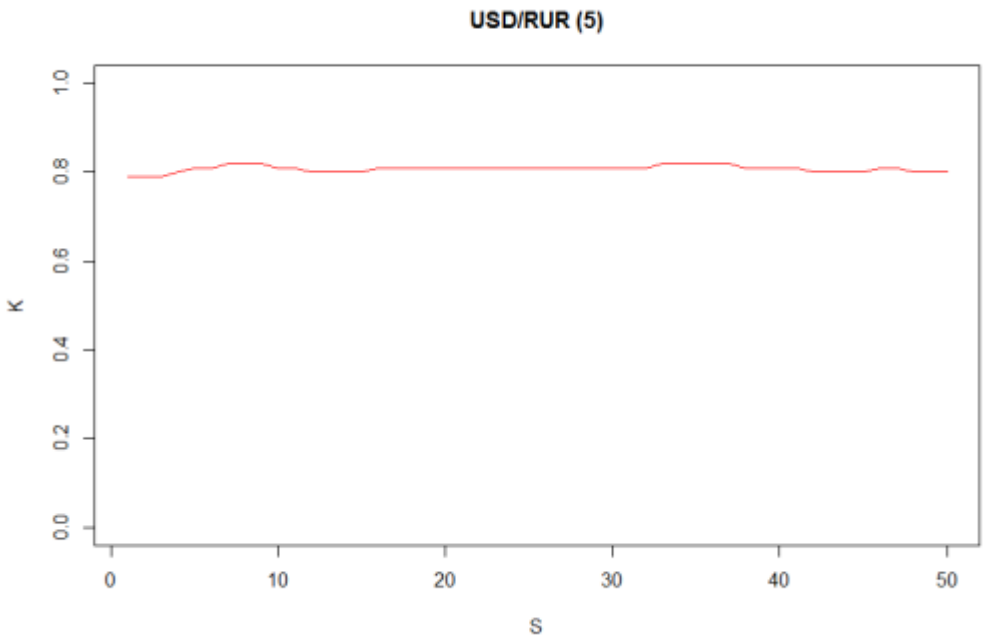

Рис. 6. Результаты расчета КИП по ДП USD/RUR (5)

По результатам, представленным на рисунках 1-6, видно, что с увеличением порядка сглаживания ДП и изменением их статистических свойств, происходит рост значений КИП (6) во всем диапазоне тестирования.

Для проверки сформулированной предпосылки, что по значению КИП можно рекомендовать или не рекомендовать интервальное прогнозирование ДП, проведем дополнительное тестирование. Покажем связь между рассчитанными значениями КИП и точностью интервального прогнозирования на выбранном интервале тестирования.

Введем формулу среднего значения КИП на интервале тестирования:

$$\overline{K} = \left(\sum_{s=1}^{w} K_{s+n-w-1} \right) / w, \tag{10}$$

где $K_{s+n-w-1}$ определяются по формуле (9).

Для тестирования интервального прогнозирования использовался программный комплекс «Интервальное прогнозирование нестационарных динамических показателей» [20] с рекомендованными параметрами моделей [15, 16]. В таблице 1 приведены средние значения КИП (10), рассчитанные на интервале тестирования и процент оправдавшихся прогнозов (PL) на основе АВСКМ и ВНС.

Таблица 1. Средние значения КИП, рассчитанные на интервале тестирования и процент оправдавшихся прогнозов (PL) на основе АВСКМ и ВНС

ДП	Среднее значение КИП	PL (АВСКМ)	PL (ВНС)
EUR/RUR (1)	0,29	58,3	62,0
USD/RUR (1)	0,31	46,0	54,0
EUR/RUR (3)	0,60	68,0	72,0
USD/RUR (3)	0,64	78,0	78,0
EUR/RUR (5)	0,76	74,0	74,0
USD/RUR (5)	0,80	80,0	82,0

По данным таблицы 1 видно, что с увеличением среднего значения КИП точность интервального прогнозирования на основе АВСКМ и ВНС повышается. А это позволяет предложить КИП в качестве критерия для проверки целесообразности или нецелесообразности интервального прогнозирования ДП на основе кластерных или нейронных моделей. Рекомендация заключается в том, что этот коэффициент должен быть не менее 0,6.

Заключение

1) Предложен алгоритм расчета коэффициента интервальной прогнозируемости динамического показателя на основе коэффициента ранговой корреляции Спирмена;

2) Экспериментально показано, что значение коэффициента интервальной прогнозируемости, рассчитанное по предыстории динамического ряда, позволяет количественно оценить, насколько целесообразно проводить интервальное прогнозирование динамического показателя на основе кластерных или нейронных моделей, исходя из его статистических свойств;

3) Рекомендовано осуществлять интервальное прогнозирование динамического показателя в текущий момент времени только в том случае, если рассчитанное по имеющейся выборке значение коэффициента интервальной прогнозируемости (9) не меньше 0,6.

Список литературы

1. Чучуева И.А., Павлов Ю.Н. Экстраполяция псевдослучайных процессов по максимуму подобия // Наука и образование. МГТУ им. Н.Э. Баумана. Электрон. журн. 2009. №7. Режим доступа: http://technomag.neicon.ru/doc/129712.html (дата обращения 12.05.2016).
2. Васильев Д.А., Иващенко В.А. Прогнозирование активных нагрузок промышленных предприятий на основе кластеризации данных // Вестник СГТУ. 2009. №4. С. 96-98.
3. Чернецов С.А., Чучуева И.А. Прогнозирование уровня глюкозы в крови больных инсулинозависимым диабетом нейронными сетями и методом экстраполяции по выборке максимального подобия // Наука и образование. МГТУ им. Н.Э. Баумана. Электрон. журн. 2010. № 11. С. 1-9. Режим доступа: http://technomag.neicon.ru/doc/162847.html (дата обращения 18.05.2016).
4. Mitrea C.A., Lee K.M., Wu Z. Comparison between Neural Networks and Traditional Forecasting Methods: A Case Study // International Journal of Engineering Business Management. 2009. Vol. 1, no. 2. Pp. 19-24. DOI: 10.5772/6777
5. Gosasang V., Chandraprakaikul W., Kiattisin S. A Comparison of Traditional and Neural Networks Forecasting Techniques for Container Throughput at Bangkok Port // The Asian Journal of Shipping and Logistics. 2011. Vol. 27, no. 3. Pp. 463-482. DOI: 10.1016/s2092-5212(11)80022-2

6. Surajit C., Deepak J., Goutami C. Trend estimation and univariate forecast of the sunspot numbers: development and comparison of ARMA, ARIMA and autoregressive neural network models // Comptes Rendus Geoscience. 2011. Vol. 343. Pp. 433-442. DOI: 10.1016/j.crte.2011.07.008
7. Flores J., Graff M., Rodriguez H. Evolutive design of ARMA and ANN models for time series forecasting // Renewable Energy. 2012. Vol. 44. Pp. 225-230. DOI: 10.1016/j.renene.2012.01.084
8. Valipour M., Banihabib M.E., Behbahani M.R. Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir // Journal of Hydrology. 2013. Vol. 476. Pp. 433–441. DOI: 10.1016/j.jhydrol.2012.11.017
9. Орлов А.И. Компьютерно-статистические методы: состояние и перспективы // Научный журнал КубГАУ. 2014. № 103. С. 163-195.
10. Пьяных А.А. Анализ применения комбинированных моделей при краткосрочном прогнозировании временных рядов // Журнал СФУ. Техника и технологии. 2014. Т. 7, № 3. С. 359-363.
11. Panapakidis I.P. Clustering based day-ahead and hour-ahead bus load forecasting models // International Journal of Electrical Power & Energy Systems. 2016. Vol. 80. Pp. 171–178. DOI: 10.1016/j.ijepes.2016.01.035
12. Jiménez-Pérez P.F., Mora-López L. Modeling and forecasting hourly global solar radiation using clustering and classification techniques // Solar Energy. 2016. Vol. 135. P. 682-691. DOI: 10.1016/j.solener.2016.06.039
13. Azimi R., Ghayekhloo M., Ghofrani M. A hybrid method based on a new clustering technique and multilayer perceptron neural networks for hourly solar radiation forecasting // Energy Conversion and Management. 2016. Vol. 118. Pp. 331-344. DOI: 10.1016/j.enconman.2016.04.009
14. Сизов А.А. Идентификация методов прогнозирования временных рядов с переменной структурой // Системы компьютерной математики и их приложения. 2015. № 16. С. 101-103.
15. Краковский Ю.М., Лузгин А.Н. Адаптивная вероятностно-статистическая кластерная модель интервального прогнозирования нестационарных динамических показателей // Современные технологии. Системный анализ. Моделирование. 2015. № 1(45). С. 80-84.
16. Краковский Ю.М., Лузгин А.Н. Интервальное прогнозирование нестационарных динамических показателей на основе модели вероятностной нейронной сети // Научная мысль. 2016. № 1. С. 116-122.
17. Spearman's rank correlation coefficient. Wikipedia: свободная энциклопедия. Режим доступа: https://en.wikipedia.org/wiki/Spearman's_rank_correlation_coefficient (дата обращения 25.06.2016).

18. The R project of statistical computing: веб-сайт. Режим доступа: http://www.r-project.org (дата обращения 20.04.2016).
19. Лощинин М.А. Отдельные аспекты анализа временных рядов и прогнозирования на языке R // Техника и технология: новые перспективы развития. 2015. № 17. С. 12-16.
20. Краковский Ю.М., Лузгин А.Н. Программное обеспечения интервального прогнозирования нестационарных динамических показателей // Вестник ИрГТУ. 2015. № 4. С.12-16.

Science & Education of the Bauman MSTU
Electronic journal
ISSN 1994-0408

Science and Education of the Bauman MSTU, 2016, no. 09, pp. 60–73.

DOI: **10.7463/0916.0845015**

Received: 04.08.2016
Revised: 18.08.2016

© Bauman Moscow State Technical Unversity

Dynamic Indicator Predictability Assessment Based on Rank Correlation Coefficient

Yu.M. Krakovsky[1], **A.N. Luzgin**[2,*] *alexln@mail.ru

[1]Irkutsk State University of Railway Transport, Irkutsk, Russia
[2]Administration of Irkutsk city, Irkutsk, Russia

Keywords: interval prediction, estimate of predictability, dynamic indicator, rank correlation, accuracy of prediction

Most modern institutions and enterprises carry out their activities under uncertainty when managerial decision-making effectiveness depends directly on the prediction accuracy of basic dynamic indicators, which, as a rule, are formalized in the form of time-series. It is known that the most promising methods for prediction of these indicators are clustered and neural ones. In previous articles the authors proposed to use an approach of the interval prediction of dynamic indicators along with such methods. The gist of this approach is to assess the predictive values of a dynamic indicator based on the probability of their membership in the pre-entered interval. Since such a prediction determines an interval in which there will be the future dynamic indicator value rather than the future dynamic indicator value itself, this prediction was called the interval prediction and the respective probabilities are referred to as the interval ones.

The interval prediction uses all the available value prehistory of the time-series, which directly affects the quality of a constructed predictive model and, as a result, the accuracy of the interval prediction at the future point of time. The question arises: is it possible, based on the prehistory of the time-series, to estimate numerically a possibility of the interval prediction, without realizing prediction itself? To solve this problem the article offers an algorithm for calculating of the interval predictability coefficient based on the modified Spearman's rank correlation coefficient. It was experimentally shown, that the value of the coefficient of interval predictability allows quantitative assessment to define, whether it is expedient to use cluster or neural methods for the interval prediction of the dynamic indicator at the current time. It is recommended to conduct the interval prediction of dynamic indicator at the current time only in case a value of the interval predictability coefficient, calculated on the basis of sampling time-series, is at least 0.6.

References

1. Chuchueva I.A., Pavlov Y.N. Extrapolation of pseudorandom number sequence on maximum likeness. *Nauka i obrazovanie MGTU im. N.E. Baumana = Science and Education of*

the Bauman MSTU, 2009, no. 7. Available at: http://technomag.neicon.ru/doc/129712.html, accessed 12.05.2016. (in Russian).

2. Vasil'yev D.A., Ivashchenko V.A. Forecasting of industrial enterprises active loads based on data clustering. *Vestnik SGTU = Vestnik Saratov State Technical University*, 2009, no. 4. pp. 96-98. (in Russian).
3. Chernetsov S.A., Chuchueva I.A. Neuro-fuzzy prediction of the glucose level of patients with insulin-dependent diabetes. *Nauka i obrazovanie MGTU im. N.E. Baumana = Science and Education of the Bauman MSTU*, 2010, no. 11, pp. 1-9. Available at: http://technomag.neicon.ru/doc/162847.html (accessed 18.05.2016). (in Russian).
4. Mitrea C.A., Lee K.M., Wu Z. Comparison between Neural Networks and Traditional Forecasting Methods: A Case Study. *International Journal of Engineering Business Management*, 2009, vol.1, no. 2, pp. 19-24. DOI: 10.5772/6777
5. Gosasang V., Chandraprakaikul W., Kiattisin S. A Comparison of Traditional and Neural Networks Forecasting Techniques for Container Throughput at Bangkok Port. *The Asian Journal of Shipping and Logistics*, 2011, vol. 27, no. 3, pp. 463-482. DOI: 10.1016/s2092-5212(11)80022-2
6. Surajit C., Deepak J., Goutami C. Trend estimation and univariate forecast of the sunspot numbers: development and comparison of ARMA, ARIMA and autoregressive neural network models. *Comptes Rendus Geoscience*, 2011, vol. 343, pp. 433-442. DOI: 10.1016/j.crte.2011.07.008
7. Flores J., Graff M., Rodriguez H. Evolutive design of ARMA and ANN models for time series forecasting. *Renewable Energy*, 2012, vol. 44, pp. 225-230. DOI: 10.1016/j.renene.2012.01.084
8. Valipour M., Banihabib M.E., Behbahani M.R. Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir. *Journal of Hydrology*, 2013, vol. 476, pp. 433–441. DOI: 10.1016/j.jhydrol.2012.11.017
9. Orlov A.I. Computer-statistical methods: state and prospects. *Nauchnyy zhurnal KubGAU = Scientific Journal of KubSAU*, 2014, no. 103, pp. 163-195. (in Russian).
10. P'yanykh A.A. Analysis of Application of the Combined Models at Short-Term Forecasting of Time Series. *Zhurnal SFU = Journal of SibFU. Engineering & Technologies*, 2014, vol. 7, no. 3, pp. 359-363. (in Russian).
11. Panapakidis I.P. Clustering based day-ahead and hour-ahead bus load forecasting models. *International Journal of Electrical Power & Energy Systems*, 2016, vol. 80, pp. 171–178. DOI: 10.1016/j.ijepes.2016.01.035
12. Jiménez-Pérez P.F., Mora-López L. Modeling and forecasting hourly global solar radiation using clustering and classification techniques. *Solar Energy,* 2016, vol. 135, pp. 682-691. DOI: 10.1016/j.solener.2016.06.039

13. Azimi R., Ghayekhloo M., Ghofrani M. A hybrid method based on a new clustering technique and multilayer perceptron neural networks for hourly solar radiation forecasting. *Energy Conversion and Management*, 2016, vol. 118, pp. 331-344.
DOI: 10.1016/j.enconman.2016.04.009
14. Sizov A.A. Identification of forecasting methods for time series with variable structure. *Sistemy komp'yuternoy matematiki i ikh prilozheniya*, 2015, no. 16, pp. 101-103. (in Russian).
15. Krakovskiy Yu.M., Luzgin A.N. Adaptive probabilistic statistical cluster model for interval prediction of non-stationary dynamic indicators. *Sovremennye tekhnologii. Sistemnyy analiz. Modelirovanie = Modern technologies. System analysis. Modeling*, 2015, no. 1(45), pp. 80-84. (in Russian).
16. Krakovskiy Yu.M., Luzgin A.N. Interval prediction of unsteady dynamic parameters based on probabilistic neural network model. *Nauchnaya mysl' = Scientific Thought*, 2016, no. 1, pp. 116-122. (in Russian).
17. *Spearman's rank correlation coefficient*. Wikipedia: free encyclopedia. Available at: https://en.wikipedia.org/wiki/Spearman's_rank_correlation_coefficient (accessed 25.06.2016).
18. *The R project of statistical computing*: website. Available at: http://www.r-project.org (accessed 20.04.2016).
19. Loshchinin M.A. Some aspects of time series analysis and forecasting in terms of R. *Tekhnika i tekhnologiya: novye perspektivy razvitiya*, 2015, no. 17, pp. 12-16. (in Russian).
20. Krakovskiy Yu.M., Luzgin A.N. Software for interval prediction of non-stationary dynamic indicators. *Vestnik IrGTU = Bulletin of Irkutsk State Technical University*, 2015, no. 4, pp. 12-16. (in Russian).