

# ПРИМЕНЕНИЕ ТЕХНОЛОГИИ ЦИФРОВОЙ ОБРАБОТКИ СИГНАЛОВ ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ ПРОГНОЗИРОВАНИЯ ВРЕМЕННЫХ РЯДОВ ДАННЫХ В СИСТЕМАХ ОБНАРУЖЕНИЯ АНОМАЛИЙ В НАБЛЮДАЕМЫХ ПРОЦЕССАХ АВТОМАТИЗИРОВАННЫХ СИСТЕМ УПРАВЛЕНИЯ ТЕХНОЛОГИЧЕСКИМИ ПРОЦЕССАМИ<sup>1</sup>

Прогнозирование динамических временных рядов данных играет важную роль при построении систем обнаружения аномалий при защите информации в различных системах управления технологическими процессами (АСУ ТП). Для повышения точности прогнозирования динамических временных рядов данных применяется предварительная цифровая обработка (цифровая фильтрация) сигналов для разложения наблюдаемого временного ряда, поступающего с сенсоров АСУ ТП на отдельные компоненты. При таком подходе производится компонентное разложение и фильтрация исходного сигнала с использованием гребенки цифровых фильтров, что существенно повышает качество формируемого прогноза. Проведен анализ сигнала ошибки результата прогнозирования с использованием цифрового спектрального и биспектрального анализа. Показано, что для случая «идеального прогноза» сигнал ошибки предсказания является непредсказуемым остатком, то есть стремится к состоянию белого шума. В работе показано, что анализ ошибки прогноза с использованием методов цифрового спектрального и биспектрального анализа позволяет формировать оценку качества результата прогнозирования. Проведенное сравнение показывает существенное повышение эффективности использования предварительной цифровой фильтрации с це-

<sup>1</sup> Исследование поддержано грантом Российского научного фонда (проект № 22-71-10095).

лю повышения точности прогнозирования наблюдаемых динамических временных рядов данных АСУ ТП. Работа с нейронными сетями проводилась в пакете расширения MATLAB «Deep Learning Toolbox». Для спектрального и биспектрального анализа сигналов использовался пакет «Higher Order Spectral Analysis Toolbox».

**Ключевые слова:** цифровая фильтрация, нейронная сеть, прогнозирование, спектральный анализ, биспектральный анализ, вертикальный сигнал, горизонтальный сигнал.

Ragozin A.N., Pletenkova A.D.

# THE APPLICATION OF DIGITAL SIGNAL PROCESSING TECHNOLOGY TO IMPROVE THE ACCURACY OF FORECASTING TIME SERIES DATA IN ANOMALY DETECTION SYSTEMS IN THE OBSERVED PROCESSES OF AUTOMATED PROCESS CONTROL SYSTEMS

Forecasting dynamic time series of data plays an important role in the construction of anomaly detection systems for information protection in various automated process control systems (APCS). To improve the accuracy of forecasting dynamic time series of data, preliminary digital processing (digital filtering) of signals is used to decompose the observed time series coming from the APCS sensors into separate components. With this approach, component decomposition and filtering of the original signal are performed using a digital filter comb, which significantly improves the quality of the generated forecast. The error signal of the prediction result was analyzed using digital spectral and bispectral analysis. It is shown that for the case of «perfect prediction» the prediction error signal is an unpredictable residual, that is, it tends to the state of white noise. The paper shows that the analysis of the forecast error using the methods of digital spectral and bispectral analysis makes it possible to form an assessment of the quality of the forecast result. The comparison shows a significant increase in the efficiency of using preliminary digital filtering to improve the accuracy of forecasting the observed dynamic time series of APCS data. Work with neural networks was carried out in the MATLAB «Deep Learning Toolbox» extension package. For spectral and bispectral analysis of signals, the «Higher Order Spectral Analysis Toolbox» package was used.

**Keywords:** digital filtering, neural network, forecasting, spectral analysis, bispectral analysis, vertical signal, horizontal signal.

## **Введение**

Кибератаки, направленные на работу автоматизированных систем управления технологическими процессами (АСУ ТП), могут приводить к катастрофическим последствиям [1-3], поэтому актуальной является задача повышения точности обнаружения кибератак на АСУ ТП. Для обнаружения вторжений в АСУ ТП применяются нейронные сети и с их использованием процедура прогнозирования наблюдаемых сигналов [4-8]. Кибератаки вызывают аномалии (то есть, неожиданное изменение) в поведении наблюдаемых процессов (в динамике временных рядов данных) при работе АСУ ТП. При построении прогноза нейросеть обучается при нормальной (без влияния дестабилизирующих воздействий) работе АСУ ТП. Детектирование (обнаружение) аномалий происходит в результате сравнения каждого отдельного временного ряда из наблюдаемого множества всех временных рядов, с каждым соответствующим прогнозом этого отдельного временного ряда из наблюдаемого множества всех временных рядов. При формировании аномалий в работе АСУ ТП будут происходить структурные изменения в сигнале ошибки формируемого прогноза, по обнаружению этих структурных изменений, собственно, происходит обнаружение аномалий в наблюдаемых процессах АСУ ТП. Очевидно, что качество (то есть, точная настройка) формирования прогноза наблюдаемого сигнала играет важную роль.

Метод предварительной цифровой фильтрации при формировании прогноза сигнала с использованием нейросетей ранее рассматривался в работах [9-11]. Применение метода предварительной цифровой фильтрации сигнала в задачах обнаружения аномалий рассматривалось в работах [12-13]. Другие методы обнаружения аномалий с использованием нейронных сетей рассмотрены в работах [14-18].

В работе исследуется влияние параметров блока предварительной цифровой фильтрации на качество получаемого прогноза.

Необходимо отметить, что построение обнаружителей аномалий наблюдаемых процессов можно рассматривать с позиции формирования компактного кластера наблюдаемых процессов «нормально» работающей АСУ ТП. Аномальным считается наблюдаемый процесс, выходящий за границы компактного

кластера, сформированного при обучении нейронной сети построению прогноза в режиме нормально работающей АСУ ТП (без дестабилизирующих воздействий).

### **1. Этап предварительной цифровой обработки (фильтрации) наблюдаемых сигналов**

Предлагаемый в исследовании подход заключается в предварительной подготовке данных наблюдаемого временного ряда с использованием технологии цифровой фильтрации. Предварительно подготовленные данные более помехозащищены, что существенно улучшает качество прогноза наблюдаемого временного ряда.

В работе исследуется влияние изменения значений параметров и структуры блока предварительной цифровой фильтрации на качество прогноза. Предлагаемый метод предварительной цифровой обработки прогнозируемого временного ряда заключается в прохождении сигнала через гребенку цифровых фильтров нижних частот (цифровые ФНЧ с конечными импульсными характеристиками (КИХ))) и в получении на выходе набора отфильтрованных компонентов исходного сигнала. Набор полученных компонентов сигнала с выхода гребенки ФНЧ назовем «вертикальным сигналом». То есть, «вертикальный сигнал», это многоканальный сигнал с выхода гребенки ФНЧ с последовательно уменьшающимися частотами среза их частотных характеристик. При таком подходе производится компонентное разложение исходного сигнала и последовательная фильтрация шумов с использованием параллельного набора цифровых ФНЧ. При этом исходный сигнал (до применения предварительной цифровой фильтрации), назовем горизонтальным входным сигналом.

Проведенное исследование является развитием направления, отраженного в более ранних работах [9-12] и заключающееся, именно в анализе влияния структуры и параметров блока предварительной цифровой фильтрации на качество прогноза исходного временного сигнала, а также в применении технологии цифрового спектрального и биспектрального анализа в оценке качества и точности получаемого прогноза.

Метод биспектрального анализа рассмотрен в обзорных работах [19,20].

### **2. Формирование прогноза наблюдаемого временного ряда**

Рассмотрим входной анализируемый сиг-

нал. На рисунке 1 в качестве примера представлен сложный сигнал (временной ряд данных), отражающий протекающий процесс в технической системе. Временная ось представлена в отсчетах.

На рисунке 2 отражен участок временного ряда (рис. 1), который не будет задейство-

ван в обучении нейронной сети для формирования прогноза.

После выбора участка (рис.2) временного ряда данных для анализа формирования прогноза, оставшийся временной ряд (из рис.1) будет использован для обучения нейронной сети.

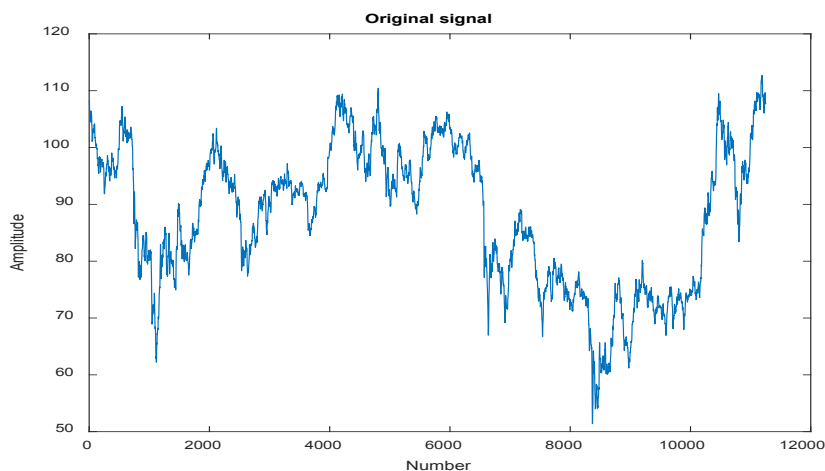


Рис. 1 Входной временной ряд

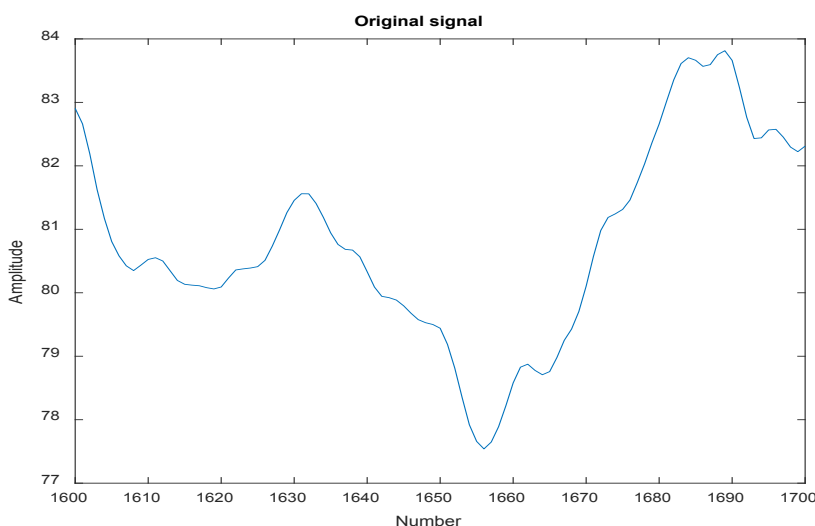


Рис. 2 Временной ряд данных для формирования прогноза

Результат предварительной цифровой фильтрации наблюдаемого временного ряда (рисунок 1) показан на рисунке 3 для участка исходного сигнала, отраженного на рисунке 2.

На рисунке 3 показан набор полученных компонентов временного ряда с выхода гребенки фильтров нижних частот (ФНЧ). После прохождения временного ряда через гребенку ФНЧ с конечными импульсными характеристиками (КИХ) получаем базовые компоненты данного временного ряда. В данном сравнении гребенка ФНЧ состоит из 31 КИХ-

ФНЧ с последовательно уменьшающимися частотами среза их частотных характеристик.

В этом примере горизонтальным сигналом называется исходный сигнал (рис. 2), а вертикальным сигналом (длина вертикального сигнала равна 31 отсчету) является последовательный набор последнего временного отсчета каждой из 31 полученной компоненты с выхода гребенка ФНЧ из 31 КИХ-ФНЧ с последовательно уменьшающимися частотами среза их частотных характеристик.

При сравнении качества полученного

прогноза для варианта горизонтального или вертикального типов сигналов используется (показано на рисунке 4) двухслойная нейронная сеть с гиперболическими функциями активации в первом слое и линейной функцией активации во втором слое. Для машинного об-

учения использовалось 7000 точек анализируемого временного ряда в пропорции 60% - тренировка, 30% - проверка и 10% - тестирование. Размерность горизонтального и вертикального сигналов, подаваемых на вход нейронной сети одинаковая и равна 31 отсчету.

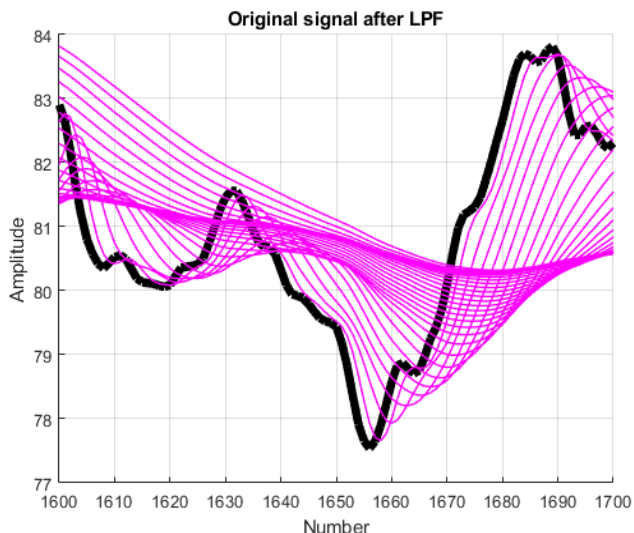


Рис. 3 Результат компонентного преобразования временного ряда данных для формирования прогноза




Рис. 4 Структура нейросетевого экстраполятора

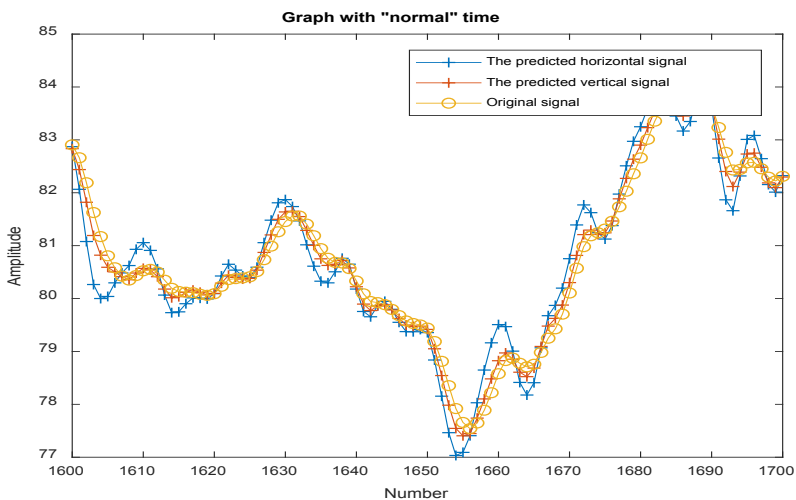


Рис. 5 Результат построения прогноза

### 3. Анализ результатов прогнозирования наблюдаемого временного ряда

Результат построения прогноза для вертикального сигнала и горизонтального сигнала

ла отображен на рисунке 5, увеличенный участок результата отображен на рисунке 6. «Желтым» на рисунках 5 и 6 отображен исходный сигнал, то есть сигнал, который опережа-

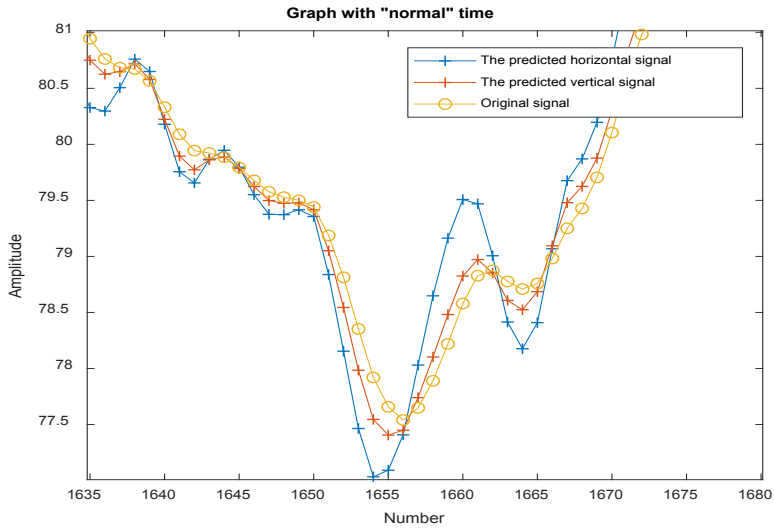


Рис. 6 Увеличенный участок результата построения прогноза (рис.5)

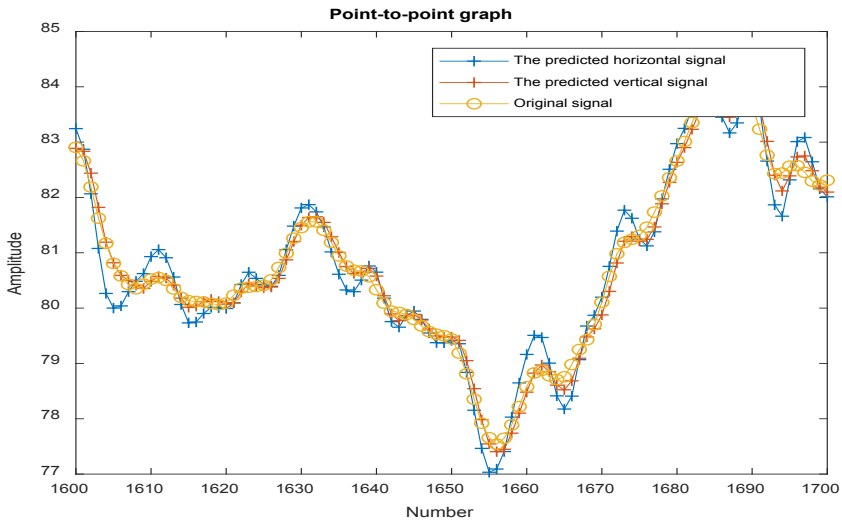


Рис. 7 Наложение прогноза на исходный временной ряд

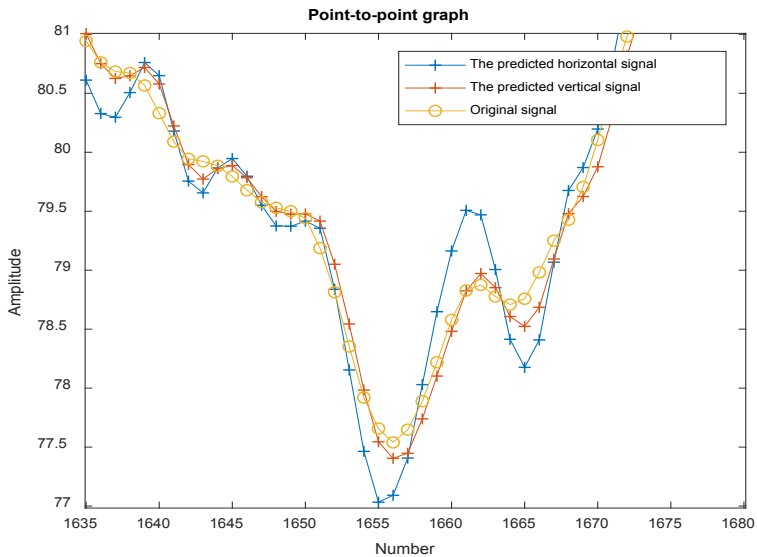


Рис. 8 Увеличение наложения прогноза на исходный временной ряд

ет сигналы прогнозов на один дискретный отсчет времени «вперед».

Результат построения прогноза для вертикального сигнала и горизонтального сигнала также, отображен на рисунке 7, увеличенный участок результата отображен на рисунке 8. В данном случае «жёлтым» на рисунках 7 и 8 отображен исходный «целевой» сигнал, то есть сигнал, к которому сигналы прогнозов должны стремиться, то есть в идеальном случае совпадать с ним.

Из графика на рисунке 6 и 8, а также, 5 и 7 видно, что метод прогнозирования при использовании вертикального сигнала (то есть, с использованием технологии предварительной цифровой фильтрации) имеет более высокое качество и точность прогнозирования.

#### 4. Анализ результатов ошибки прогнозирования наблюдаемого временного ряда

В таблице 1 приведена сводка результатов прогнозирования для случая горизонтального сигнала (то есть, без применения предварительной фильтрации) и вертикального сигнала (то есть, с применением предварительной фильтрации). Ошибка прогнозирования оценивалась в виде зависимости значения СКО от длины (количества дискрет) горизонтального или вертикального сигналов, подаваемых на вход нейронной сети. По этому количеству дискрет реализуется прогноз на последующую одну точку (дискрет) этого сигнала. Результаты таблицы 1 отображены на рисунке 9.

Таблица 1

#### Численное сравнение СКО и процента ошибки спрогнозированного временного ряда

Значения СКО и процент ошибки на временном ряде данных для формирования прогноза			
Тип входного сигнала	Количество точек	СКО	Процент ошибки по сигналу
Вертикальный	121	0.1817	0.6793
Вертикальный	61	0.1834	0.7671
Вертикальный	31	0.182	0.7752
Вертикальный	16	0.1811	0.8936
Вертикальный	11	0.1807	0.7293
Вертикальный	8	0.1813	0.6798
Вертикальный	4	0.1815	0.8345
Вертикальный	2	0.1985	0.7584
Горизонтальный	121	0.2446	1.6737
Горизонтальный	61	0.2901	2.036
Горизонтальный	31	0.2776	1.9836
Горизонтальный	16	0.2732	2.1163
Горизонтальный	11	1.1362	9.4731
Горизонтальный	8	1.0859	9.3066
Горизонтальный	4	1.0578	9.3307
Горизонтальный	2	0.6074	5.1555

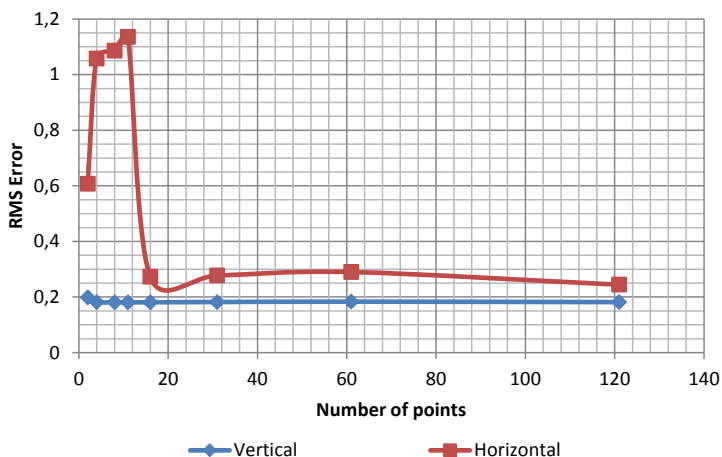


Рис. 9 График зависимости СКО от количества точек, использованных для предсказания

По результатам данных представленных на рисунках 8 и 9 видно, что качество прогноза существенно выше при использовании предложенного метода предварительной цифровой фильтрации, то есть при переходе от горизонтального сигнала к вертикальному сигналу фактически при любой размерности (длине) прогнозируемых сигналов.

Проведем спектральный анализ сигнала ошибки результатов прогнозирования, что дает возможность получить данные о том, ка-

кие ошибки предсказания преобладают при той или иной структуре подаваемого на нейросеть сигнала.

На рисунках 10 и 11 приведены результаты спектрального анализа для случая горизонтального и вертикального сигналов соответственно. Размерность (длина) сигналов, подаваемых на вход нейронной сети равна 31. Ось частот на графиках рисунков 10 и 11 отображена в нормированных частотах [Рад.].

Сравнивая спектры сигналов ошибки




Рис. 10 Спектр ошибки прогнозирования временного ряда горизонтального сигнала

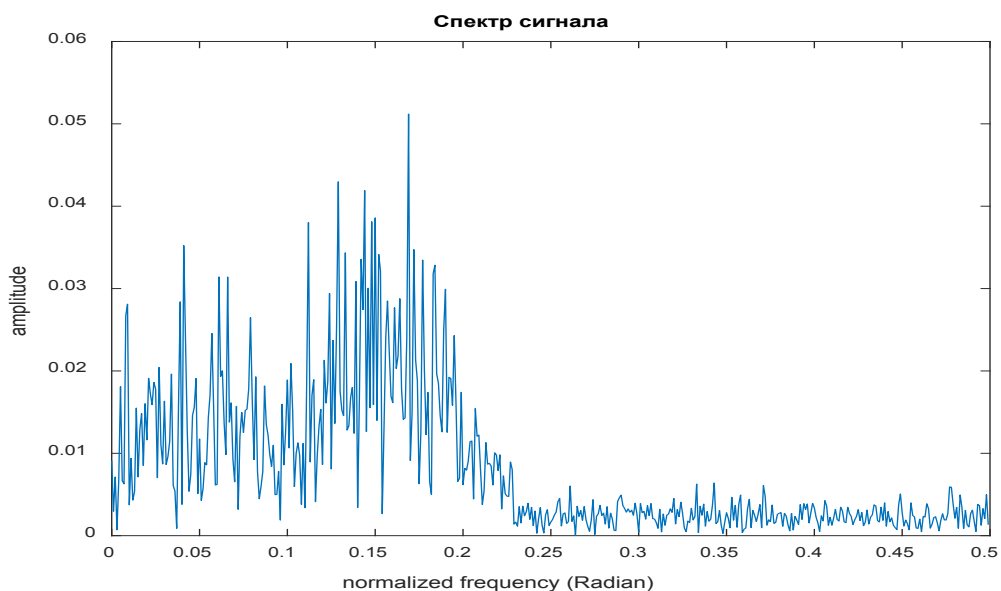


Рис. 11 Спектр ошибки прогнозирования временного ряда вертикального сигнала



прогноза на рисунках 10 и 11, можно отметить, что в случае с сигналом ошибки вертикального сигнала амплитуда спектра гораздо меньше. В спектре ошибки горизонтального сигнала (рис.10) помимо гармоник, появляющихся в спектре ошибки вертикального сигнала, выражены более низкочастотные составляющие, что свидетельствует об ухудшении динамических характеристик предиктора, формирующего прогноз без использова-

ния технологии предварительной цифровой фильтрации.

На рисунках 12–15 представлены результаты биспектрального анализа сигнала ошибки прогноза. Биспектральный анализ позволяет определить отклонение сигнала ошибок от распределения по «нормальному закону». Также, биспектральный анализ отображает нелинейные взаимодействия гармоник, присутствующих в спектре сигнала ошибки прогноза.




Рис. 12 Трехмерное представление биспектра сигнала ошибки прогнозирования горизонтального временного ряда

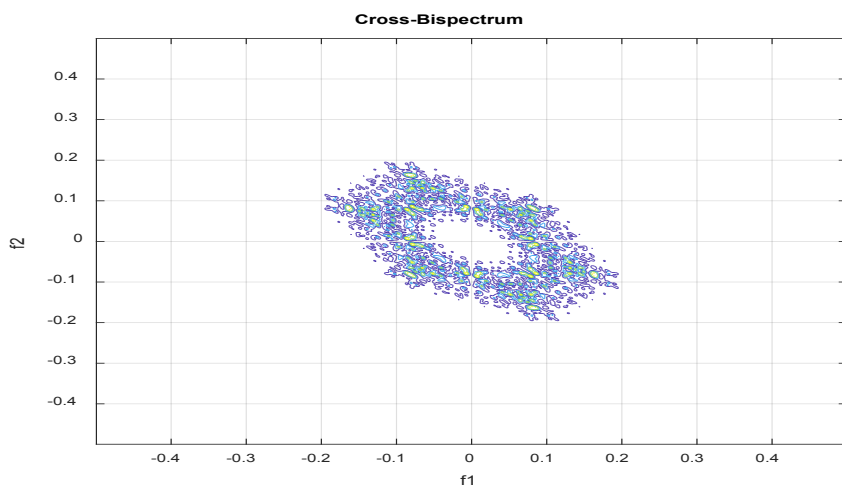


Рис. 13 Вид биспектра сигнала ошибки прогнозирования горизонтального временного ряда в горизонтальном разрезе




Рис. 14 Трехмерное представление биспектра сигнала ошибки прогнозирования вертикального сигнала

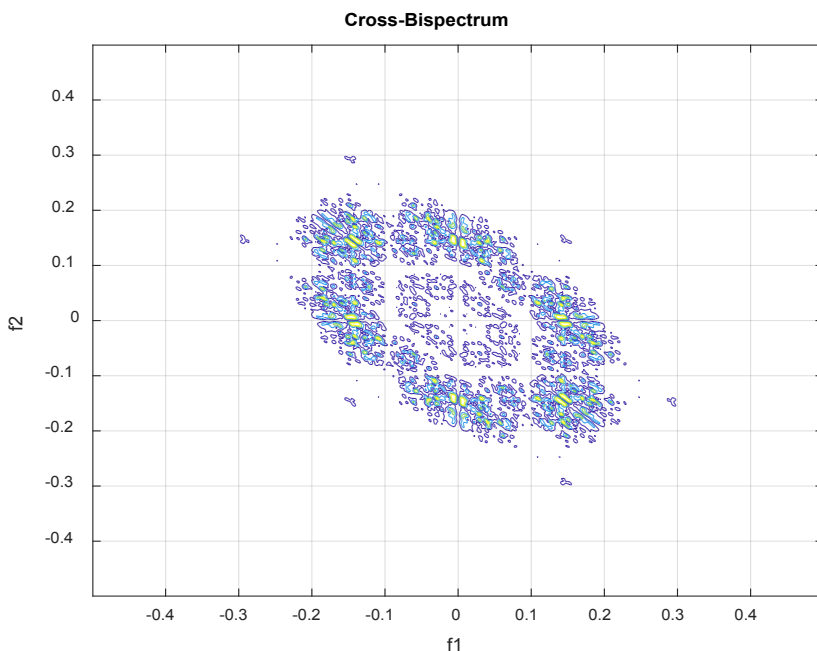


Рис. 15 Вид биспектра сигнала ошибки прогнозирования вертикального временного ряда в горизонтальном разрезе

При сравнении рисунков 12 и 14 видно, что во временном ряде сигнала ошибки для случая горизонтального сигнала нелинейная связь между гармоническими составляющими выражена в большей степени (более высокий уровень амплитуды биспектра). Это связано с тем, что при прогнозировании для случая горизонтального сигнала, в точках перегиба прогнозируемого временного ряда возникают выраженные локальные переходные процессы в работе предиктора, что существенно снижает его динамические характеристики. Предиктор, работающий в режиме «вертикального сигнала», не имеет такого выраженного недостатка.

При сравнении рисунков 12 и 14, а также рисунков 13 и 15 (вид «сверху», горизонтальный срез) видно, что биспектр сигнала ошибки предиктора, работающего в режиме «вертикального сигнала» имеет более низкий уровень, а также занимает более широкую полосу частот, что свидетельствует, также что сигнал ошибки прогнозирования в режиме «вертикального сигнала» более близок по своей структуре к «гауссовскому шуму», что также свидетельствует о более высоком качестве прогноза.

#### **Заключение**

При формировании аномалий в работе АСУ ТП будут происходить структурные изменения в сигнале ошибки формируемого прогноза, по обнаружению этих структурных из-

менений, собственно, происходит обнаружение аномалий в наблюдаемых процессах АСУ ТП. Очевидно, что качество (то есть, точная настройка) формирования прогноза наблюдаемого сигнала играет важную роль.

В спектре сигнала ошибки предиктора в режиме горизонтального сигнала помимо гармоник, появляющихся в спектре сигнала ошибки предиктора в режиме вертикального сигнала, выражены, также более низкочастотные составляющие, что свидетельствует об ухудшении динамических характеристик предиктора, формирующего прогноз без использования технологии предварительной цифровой фильтрации.

При прогнозировании для случая горизонтального сигнала (то есть, без предварительной цифровой фильтрации), в точках перегиба прогнозируемого временного ряда возникают выраженные локальные переходные процессы в работе предиктора, что существенно снижает его динамические характеристики и точность настройки прогноза. Предиктор, работающий в режиме вертикального сигнала, не имеет такого выраженного недостатка.

Качество формируемого прогноза существенно выше при использовании предложенного метода предварительной цифровой фильтрации, то есть при переходе от горизонтального сигнала к вертикальному сигналу фактически при любой размерности (длине) прогнозируемых сигналов.

---

## Литература

1. Falliere, N., Murchu, L. O., &Chien, E. (2011). W32. Stuxnet Dossier Version 1.4. Symantec Security Response.
2. Lee, R., Assante, M., &Conway, T. (2014). ICS CP/PE (Cyber-to-Physical or Process Effects) case study paper–German steel mill cyber attack. Sans ICS.
3. Lee, R. M., Assante, M. J., & Conway, T. (2016). Analysis of the Cyber Attack on the Ukrainian Power Grid. SANS Industrial Control Systems, 23.
4. Xiao, Y. J., Xu, W. Y., Jia, Z. H., Ma, Z. R., & Qi, D. L. (2017). NIPAD: a Non-Invasive Power-Based Anomaly Detection Scheme for Programmable Logic Controllers. *Frontiers of Information Technology & Electronic Engineering*, 18(4), 519-534.
5. Wang, W., Xie, Y., Ren, L., Zhu, X., Chang, R., & Yin, Q. (2018, May). Detection of Data Injection Attack in Industrial Control System Using Long Short Term Memory Recurrent Neural Network. In 2018 13th IEEE Conference on Industrial Electronics and Applications (ICIEA) (pp. 2710-2715). IEEE.
6. Kravchik, M., & Shabtai, A. (2018, October). Detecting Cyber Attacks in Industrial Control Systems Using Convolutional Neural Networks. In *Proceedings of the 2018 Workshop on Cyber-Physical Systems Security and PrivaCy* (pp. 72-83). ACM.
7. Filonov, P., Kitashov, F., &Lavrentyev, A. (2017). RNN-Based Early Cyber-Attack Detection for the Tennessee Eastman Process. arXiv preprint arXiv:1709.02232.
8. Filonov, P., Lavrentyev, A., &Vorontsov, A. (2016). Multivariate Industrial Time Series with Cyber-Attack Simulation: Fault Detection Using an Lstm-Based Predictive Data Model. arXiv preprint arXiv:1612.06676.
9. A. Ragozin, V.Telezhkin, P.Podkorytov. Prediction of Aggregate Multicomponent Time Series in Industrial Automated Systems Using Neural Network, *Lecture Notes in Engineering and Computer Science: Proceedings of The International MultiConference of Engineers and Computer Scientists 2019, 13-15 March, 2019, Hong Kong*, pp 17-19.
10. A.N. Ragozin, A.A. Razumov. *Neural Networks Forecasting with Preliminary Digital Filtering of Complex Radio Signals: The Physics and Technology of Wave Processes 2018, September 10 – 14, 2018, Miass*, pp. 37-38.
11. A. N. Ragozin, V. F. Telezhkin, P. S. Podkorytov. State Prediction in Control Systems via Compound Time Series: Neural Network Approach. *EEE SoutheastCon 2019 Von Braun Center Huntsville, Alabama April 11th-14th, 2019*. Pages 1–6.
12. A.N. Ragozin, V.F. Telezhkin, P. S. Podkorytov. Forecasting Complex Multi-Component Time Series within Systems Designed to Detect Anomalies in Dataflows of Industrial Automated Systems. *SIN '19: Proceedings of the 12th International Conference on Security of Information and Networks September 2019 Article No.: 2 Pages 1–5*.
13. Alexander N. Sokolov, Andrey N. Ragozin, Ilya A. Pyatnitsky, Sergei K. Alabugin, *Applying of Digital Signal Processing Techniques to Improve the Performance of Machine Learning-Based Cyber Attack Detection in Industrial Control System. SIN'19: Proceedings of the 12th International Conference on Security of Information and Networks September 2019 Article No.: 23 Pages 1–4*.
14. Muna, A. H., Moustafa, N., &Sitnikova, E. (2018). Identification of Malicious Activities in Industrial Internet of Things Based on Deep Learning Models. *Journal of Information Security and Applications*, 41, 1-11.
15. Potluri, S., Diedrich, C., &Sangala, G. K. R. (2017, September). Identifying False Data Injection Attacks in Industrial Control Systems Using Artificial Neural Networks. In 2017 22nd IEEE International Conference on Emerging Technologies and Factory Automation (ETFA) (pp. 1-8). IEEE.
16. Yang, H., Chen, T., Guo, X., Wang, X., & Li, F. (2017, December). Research on Intrusion Detection of Industrial Control System Based on OPSO-BPNN Algorithm. In 2017 IEEE 2nd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC) (pp. 957-961). IEEE.
17. Demertzis, K., Iliadis, L., &Spartalis, S. (2017, August). A Spiking One-Class Anomaly Detection Framework for Cyber-Security on Industrial Control Systems. In *International Conference on Engineering Applications of Neural Networks* (pp. 122-134). Springer, Cham.
18. Wu, Z., Albalawi, F., Zhang, J., Zhang, Z., Durand, H., &Christofides, P. (2018). Detecting and Handling Cyber-attacks in Model Predictive Control of Chemical Processes. *Mathematics*, 6(10), 173.
19. Ch.L. Nikias, A.P. Petropulu *Higher-Order Spectral Analysis*, PTR Prentice Hall, Englewood Cliffs NJ, 1993.
20. Nikias C.L., Raghuvveer M.R. *Bispektral Estimation: a Digital Signal Processing Framework // Proceedings of the IEEE. 1987. V. 75. p. 869-891.*

## References

1. Falliere, N., Murchu, L. O., &Chien, E. (2011). W32. Stuxnet Dossier Version 1.4. Symantec Security Response.
2. Lee, R., Assante, M., &Conway, T. (2014). ICS CP/PE (Cyber-to-Physical or Process Effects) case study paper–German steel mill cyber attack. Sans ICS.
3. Lee, R. M., Assante, M. J., & Conway, T. (2016). Analysis of the Cyber Attack on the Ukrainian Power Grid. SANS Industrial Control Systems, 23.
4. Xiao, Y. J., Xu, W. Y., Jia, Z. H., Ma, Z. R., & Qi, D. L. (2017). NIPAD: a Non-Invasive Power-Based Anomaly Detection Scheme for Programmable Logic Controllers. *Frontiers of Information Technology & Electronic Engineering*, 18(4), 519-534.
5. Wang, W., Xie, Y., Ren, L., Zhu, X., Chang, R., & Yin, Q. (2018, May). Detection of Data Injection Attack in Industrial Control System Using Long Short Term Memory Recurrent Neural Network. In 2018 13th IEEE Conference on Industrial Electronics and Applications (ICIEA) (pp. 2710-2715). IEEE.
6. Kravchik, M., & Shabtai, A. (2018, October). Detecting Cyber Attacks in Industrial Control Systems Using Convolutional Neural Networks. In Proceedings of the 2018 Workshop on Cyber-Physical Systems Security and PrivaCy (pp. 72-83). ACM.
7. Filonov, P., Kitashov, F., &Lavrentyev, A. (2017). RNN-Based Early Cyber-Attack Detection for the Tennessee Eastman Process. arXiv preprint arXiv:1709.02232.
8. Filonov, P., Lavrentyev, A., &Vorontsov, A. (2016). Multivariate Industrial Time Series with Cyber-Attack Simulation: Fault Detection Using an Lstm-Based Predictive Data Model. arXiv preprint arXiv:1612.06676.
9. A. Ragozin, V.Telezhkin, P.Podkorytov. Prediction of Aggregate Multicomponent Time Series in Industrial Automated Systems Using Neural Network, Lecture Notes in Engineering and Computer Science: Proceedings of The International MultiConference of Engineers and Computer Scientists 2019, 13-15 March, 2019, Hong Kong, pp 17-19.
10. A.N. Ragozin, A.A. Razumov. Neural Networks Forecasting with Preliminary Digital Filtering of Complex Radio Signals: The Physics and Technology of Wave Processes 2018, September 10 – 14, 2018, Miass, pp. 37-38.
11. A. N. Ragozin, V. F. Telezhkin, P. S. Podkorytov. State Prediction in Control Systems via Compound Time Series: Neural Network Approach. EEE SoutheastCon 2019 Von Braun Center Huntsville, Alabama April 11th-14th, 2019. Pages 1–6.
12. A.N. Ragozin, V.F. Telezhkin, P. S. Podkorytov. Forecasting Complex Multi-Component Time Series within Systems Designed to Detect Anomalies in Dataflows of Industrial Automated Systems. SIN '19: Proceedings of the 12th International Conference on Security of Information and Networks September 2019 Article No.: 2 Pages 1–5.
13. Alexander N. Sokolov, Andrey N. Ragozin, Ilya A. Pyatnitsky, Sergei K. Alabugin, Applying of Digital Signal Processing Techniques to Improve the Performance of Machine Learning-Based Cyber Attack Detection in Industrial Control System. SIN'19: Proceedings of the 12th International Conference on Security of Information and Networks September 2019 Article No.: 23 Pages 1–4.
14. Muna, A. H., Moustafa, N., &Sitnikova, E. (2018). Identification of Malicious Activities in Industrial Internet of Things Based on Deep Learning Models. *Journal of Information Security and Applications*, 41, 1-11.
15. Potluri, S., Diedrich, C., &Sangala, G. K. R. (2017, September). Identifying False Data Injection Attacks in Industrial Control Systems Using Artificial Neural Networks. In 2017 22nd IEEE International Conference on Emerging Technologies and Factory Automation (ETFA) (pp. 1-8). IEEE.
16. Yang, H., Chen, T., Guo, X., Wang, X., & Li, F. (2017, December). Research on Intrusion Detection of Industrial Control System Based on OPSO-BPNN Algorithm. In 2017 IEEE 2nd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC) (pp. 957-961). IEEE.
17. Demertzis, K., Iliadis, L., &Spartalis, S. (2017, August). A Spiking One-Class Anomaly Detection Framework for Cyber-Security on Industrial Control Systems. In International Conference on Engineering Applications of Neural Networks (pp. 122-134). Springer, Cham.
18. Wu, Z., Albalawi, F., Zhang, J., Zhang, Z., Durand, H., &Christofides, P. (2018). Detecting and Handling Cyber-attacks in Model Predictive Control of Chemical Processes. *Mathematics*, 6(10), 173.
19. Ch.L. Nikias, A.P. Petropulu Higher-Order Spectral Analysis, PTR Prentice Hall, Englewood Cliffs NJ, 1993.
20. Nikias C.L., Raghuvver M.R. Bispektral Estimation: a Digital Signal Processing Framework // Proceedings of the IEEE. 1987. V. 75. p. 869-891.

---

**РАГОЗИН Андрей Николаевич**, кандидат технических наук, доцент кафедры защиты информации, доцент кафедры инфокоммуникационных технологий высшей школы электроники и компьютерных наук ФГАОУ ВО «Южно-Уральский государственный университет» (национальный исследовательский университет). Россия, 454080, г. Челябинск, пр. Ленина, 76. E-mail: ragozinan@susu.ru

**ПЛЕТЕНКОВА Анастасия Дмитриевна**, аспирант кафедры защита информации, ФГАОУ ВО «Южно-Уральский государственный университет (национальный исследовательский университет)». Россия, 454080, г. Челябинск, пр. Ленина, E-mail: pletenkovaad@susu.ru

**RAGOZIN Andrey Nikolaevich**, Candidate of Sciences in Technology, Department of Information Security, Department of Information Technology, Federal State Autonomous Educational Institution of Higher Education «South Ural State University» (national research university). Russia, 454080, Chelyabinsk, Lenin Ave., 76. E-mail: ragozinan@susu.ru

**PLETENKOVA Anastasia Dmitrievna**, post-graduate student of the Information Security Department, Federal State Autonomous Educational Institution of Higher Education «South Ural State University» (national research university). Russia, 454080, Chelyabinsk, Lenin Ave., 76. E-mail: pletenkovaad@susu.ru