

ПРИМЕНЕНИЕ ЦИФРОВОЙ ОБРАБОТКИ СИГНАЛОВ И НЕЙРОННОЙ СЕТИ ПРИ ФОРМИРОВАНИИ ПРОГНОЗА ВРЕМЕННЫХ РЯДОВ ДАННЫХ ДЛЯ ЦЕЛЕЙ ОБНАРУЖЕНИЯ АНОМАЛИЙ ПРИ АВТОМАТИЗИРОВАННОМ УПРАВЛЕНИИ ТЕХНОЛОГИЧЕСКИМИ ПРОЦЕССАМИ

С целью обнаружения аномалий и повышения качества прогнозирования динамических потоков данных, наблюдаемых с сенсоров в автоматизированных системах управления технологическими процессами (АСУ ТП), предлагается применять прогнозирующий модуль, состоящий из последовательно соединенных блока цифровой обработки сигналов (ЦОС) и прогнозирующего блока с использованием нейронной сети (НС) (прогнозирующего автоэнкодера (автокодировщика), predictive Autoencoder (PAE)). В проведенном исследовании показано, что блок предварительной ЦОС входного прогнозируемого сигнала, состоящий из параллельного набора (гребенки) цифровых фильтров нижних частот с конечными импульсными характеристиками (КИХ-ФНЧ), приводит к неравновесному учету корреляционных связей временных отсчетов входного сигнала и повышению точности конечного результата прогнозирования. Предложенный и рассмотренный в работе прогнозирующий автоэнкодер (PAE), кроме восстановления на выходе PAE входного сигнала, или части входного сигнала, также формирует на выходе прогнозируемые отсчеты входного сигнала на заданное количество временных шагов «вперед», что повышает точность результата прогнозирования. Уменьшение ошибки прогноза происходит за счет наложения ограничений при формировании прогноза, то есть дополнительного требования восстановления на выходе НС входных выборок отсчетов – «стабилизаторов». Введение «стабилизаторов» повышает точность результата прогнозирования. При возникновении анома-

лий в работе АСУ ТП будут происходить структурные изменения в сигнале ошибки формируемого прогноза, в результате анализа этих структурных изменений ошибки прогноза, собственно происходит детектирование (обнаружение) аномалий в наблюдаемых процессах АСУ ТП. В данном случае рассматривается режим обучения «частично с учителем». Исходные данные при таком подходе представляют только класс «нормальных данных», при этом, при обучении «частично с учителем» не требуется информация об аномальном классе целевых данных

Ключевые слова: цифровая фильтрация, нейронная сеть, прогнозирование, прогнозирующий автоэнкодер, автокодировщик, вертикальный сигнал, автоматизированная система управления технологическими процессами, поток данных.

Ragozin A. N.

THE USE OF DIGITAL SIGNAL PROCESSING AND A NEURAL NETWORK WHEN GENERATING A FORECAST OF TIME SERIES OF DATA FOR THE PURPOSE OF DETECTING ANOMALIES IN THE IN THE AUTOMATED CONTROL OF TECHNOLOGICAL PROCESSES

In order to detect anomalies and improve the quality of forecasting dynamic data flows observed from sensors in Industrial Control System (ACS), it is proposed to use a predictive module consisting of a series-connected digital signal processing unit (DSP) and a predictive unit using a neural network (predictive autoencoder (Auto Encoder), predictive Autoencoder (PAE)). The study showed that the preliminary DSP block of the predicted input signal, consisting of a parallel set (comb) of digital low-pass filters with finite impulse responses (FIR-LPF), leads to a non-equilibrium account of the correlation relationships of the time samples of the input signal and to increase the accuracy of the final prediction result. The predicted autoencoder (PAE) proposed and considered in the work, in addition to restoring the input signal or part of the input signal at the PAE output, also generates the predicted samples of the input signal for the specified number of «forward» time steps at the output, which increases the accuracy of the prediction result. The reduction of the forecast error occurs due to the imposition of restrictions in the formation of the forecast, that is, an additional requirement to restore the input samples of the samples – «stabilizers» at the NS output. The introduction of «stabilizers» increases the accuracy of the prediction result. When anomalies occur in the ACS operation, structural changes will oc-

cur in the error signal of the generated forecast, as a result of the analysis of these structural changes in the forecast error, the anomalies are actually detected in the observed ACS processes. In this case, the mode of study is «partly with the teacher». The initial data in this approach represent only the class of «normal data», while learning «partly with the teacher» doesn't require information about the anomalous class of target data.

Keywords: digital filtering, neural network, forecasting, predictive autoencoder (Auto Encoder), vertical signal, Industrial Control System, data stream.

Введение

Обнаружение аномалий в процессах (в динамических потоках данных) во многом определяет эффективность управления информационной безопасностью в автоматизированных системах управления технологическими процессами (АСУ ТП). Методы обнаружения аномалий применяются для решения задач обнаружения атак как на информационном уровне, так и на кибернетическом уровне в АСУ ТП.

Атаки вызывают аномалии (то есть, неожиданное изменение) в поведении наблюдаемых процессов (в динамике наблюдаемых временных рядов данных) при работе АСУ ТП. Методы обнаружения аномалий в процессах АСУ ТП относят к поведенческим методам [1,2]. Поведенческие методы основаны на моделях «нормального» функционирования АСУ ТП. При этом задача обнаружения аномалий состоит в обнаружении расхождений между текущим (наблюдаемым) процессом работы АСУ ТП и процессом работы, который является эталонным для АСУ ТП (то есть, для АСУ ТП, работающей в штатном режиме). Любое несоответствие наблюдаемого процесса и эталонного процесса АСУ ТП рассматривается как аномалия (или вторжение).

Для обнаружения аномалий (или, вторжений) в АСУ ТП применяются нейронные сети, и с их использованием процедура прогнозирования наблюдаемых динамических потоков данных [3–7]. При построении прогноза нейронная сеть обучается при нормальной, штатной (без влияния дестабилизирующих воздействий) работе АСУ ТП. Детектирование (обнаружение) аномалий происходит в результате сравнения наблюдаемого временного ряда (динамического потока данных) АСУ ТП, с прогнозом этого временного ряда (прогнозом динамического потока данных), формируемого нейронной сетью, ранее обученной при нормальной работе АСУ ТП (работе АСУ ТП в штатном режиме, без влияния дестабилизирующих воздействий). Результат срав-

нения (разности) наблюдаемого и прогнозируемого временного ряда (наблюдаемого процесса) АСУ ТП определяется как сигнал (временной ряд) ошибки прогноза.

При возникновении аномалий в работе АСУ ТП будут происходить структурные изменения в сигнале ошибки формируемого прогноза, в результате анализа этих структурных изменений ошибки прогноза, собственно происходит детектирование (обнаружение) аномалий в наблюдаемых процессах АСУ ТП.

В данном случае рассматривается режим обучения «частично с учителем». Исходные данные при таком подходе представляют только класс «нормальных данных», при этом, при обучении «частично с учителем» не требуется информация об аномальном классе целевых данных

Очевидно, что точность настройки формируемого прогноза наблюдаемого процесса АСУ ТП, работающей в штатном режиме играет важную роль, так как в данном случае формируемый прогноз наблюдаемого процесса АСУ ТП является эталонной моделью процесса АСУ ТП, работающей в штатном режиме [8].

1. Актуальность и прикладная значимость формирования прогноза при обнаружении аномалий в процессах АСУ ТП.

Процессы, протекающие в АСУ ТП, являются сложными многокомпонентными процессами. Прогноз сложных многокомпонентных временных рядов данных необходимо проводить в различных временных масштабах (краткосрочный, среднесрочный, долгосрочный), то есть необходимо формировать многокомпонентный прогноз временных рядов. Этапы построения многокомпонентного прогноза временных рядов данных рассмотрены в работах [9, 10]. При этом наблюдаемый сложный многокомпонентный процесс АСУ ТП раскладывается с использованием технологии цифровой обработки сигналов (ЦОС) на отдельные базовые компоненты, далее каждая базовая компонента прогнозируется на свой интервал прогнозирования с ис-

пользованием технологии нейронных сетей, в итоге по совокупности полученных прогнозов с различными интервалами прогнозирования формируется завершенный многокомпонентный прогноз наблюдаемого процесса работающей АСУ ТП. Методы прогнозирования, также рассмотрены в работах [11-15].

Формирование многокомпонентного прогноза позволяет детектировать (обнаруживать) аномалии в наблюдаемом множестве всех временных рядов, отражающих работу АСУ ТП в результате покомпонентного сравнения каждой отдельной компоненты многокомпонентного временного ряда с каждым прогнозом соответствующей отдельной компоненты этого временного ряда, что позволит обнаруживать во множестве наблюдаемых временных рядов АСУ ТП аномалии отдельно по их различным динамическим характеристикам. Подобный подход существенно повышает эффективность управле-

нейронной сети (прогнозирующего автоэнкодера (автокодировщика), predictive Autoencoder (PAE)).

Исследуется влияние параметров блока ЦОС на качество прогнозирования входного сигнала, также исследуется влияние на качество формируемого прогноза, особенности архитектуры прогнозирующего автоэнкодера (PAE), налагающей дополнительные ограничения на результат формируемого прогноза в виде требований дополнительного восстановления на выходе PAE входного сигнала, или части входного сигнала.

Для формирования прогноза наблюдаемого временного ряда (или, отдельной компоненты наблюдаемого многокомпонентного временного ряда) предлагается к рассмотрению прогнозирующий модуль, состоящий из последовательно соединенных блока ЦОС и прогнозирующего блока с использованием нейронной сети (рис. 1).

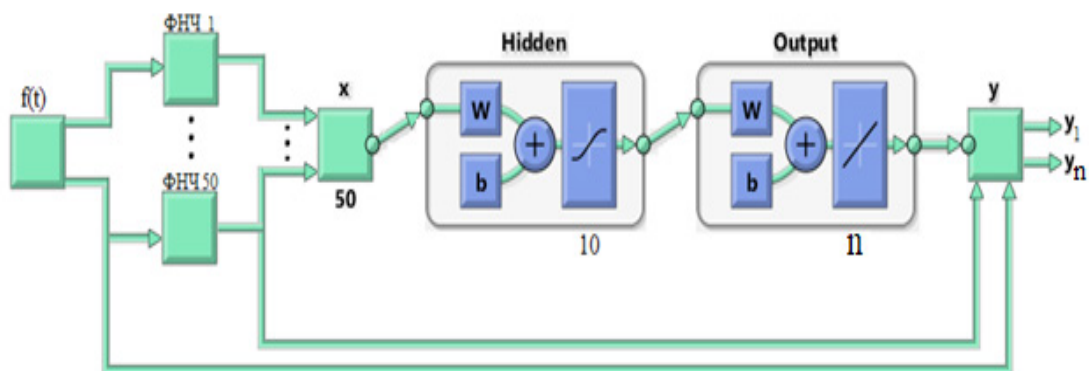


Рис. 1. Структурная схема прогнозирующего модуля: блок ЦОС и прогнозирующий блок с использованием нейронной сети

ния информационной безопасностью в АСУ ТП.

Необходимо отметить, что для целей обнаружения аномалий в работе АСУ ТП к формируемому прогнозу, наблюдаемых временных рядов АСУ ТП предъявляются высокие требования по качеству формируемого прогноза.

В работе исследуется структура прогнозирующего модуля и влияние ее параметров на качество прогноза наблюдаемых сигналов АСУ ТП.

2. Формирование структуры прогнозирующего модуля.

В работе рассматривается и исследуется прогнозирующий модуль, состоящий из последовательно соединенных блока ЦОС и прогнозирующего блока с использованием

В прогнозирующем модуле (рис. 1) блок ЦОС состоит из гребенки цифровых фильтров нижних частот (ФНЧ). При этом на выходе гребенки ФНЧ формируется набор отфильтрованных компонентов входного сигнала. Набор полученных отфильтрованных компонентов входного сигнала с выхода гребенки ФНЧ назовем «вертикальным сигналом». То есть, «вертикальный сигнал», это многоканальный сигнал с выхода гребенки ФНЧ, в данном примере (рис. 1), состоящей из 50 КИХ-ФНЧ (ФНЧ с конечной импульсной характеристикой) с последовательно уменьшающимися частотами среза их частотных характеристик.

При таком подходе происходит последовательная фильтрация шумов входного сигнала с использованием параллельного наборо-

ра (гребенки) цифровых КИХ-ФНЧ. В данном случае, более далекие (с большим запаздыванием по времени) от текущего момента времени отсчеты входного сигнала подвергаются более глубокому сглаживанию, чем отсчеты входного сигнала, более близкие к текущему моменту времени, что в свою очередь

прогнозирующего блока с использованием нейронной сети подается последовательный набор («вертикальный сигнал» с количеством отсчетов равным 50), состоящий из последних временных отсчетов каждой из 50 полученной компоненты с выхода гребенка из 50 КИХ-ФНЧ.

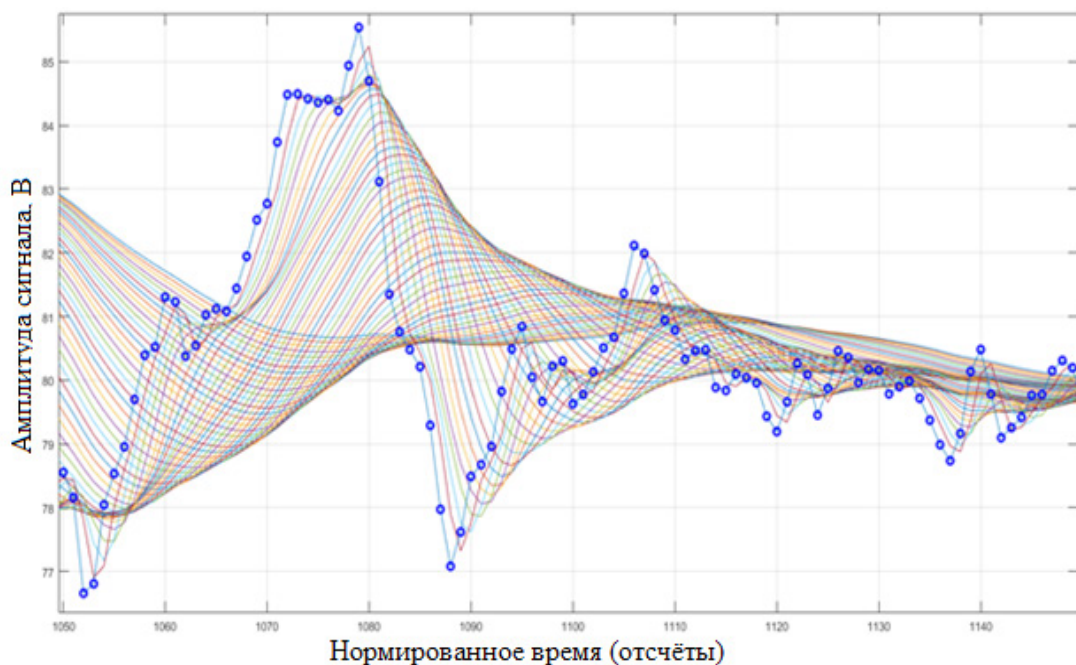


Рис. 2. Входной сигнал (синие точки) и отфильтрованные компоненты с выхода блока ЦОС

приводит к неравновесному учету корреляционных связей временных отсчетов входного сигнала и текущего отсчета результата прогноза на выходе прогнозирующего модуля (рис. 1). Неравновесный учет корреляционных связей временных отсчетов входного сигнала в формируемом прогнозе приводит к повышению точности результата прогнозирования.

В более ранних исследованиях в ходе проведенных экспериментов установлено, что использование полученных дополнительных признаков из сформированного описанным способом «вертикального сигнала» повышает точность обнаружения кибератак на АСУ ТП [16].

На рис. 2, в качестве примера изображен входной сигнал (синие точки) и «вертикальный сигнал» – набор полученных отфильтрованных 50 компонентов входного сигнала с выхода гребенки 50 КИХ-ФНЧ с последовательно уменьшающимися частотами среза их частотных характеристик. Необходимо отметить, что с выхода блока ЦОС далее, на вход

В прогнозирующем модуле (рис. 1) прогнозирующий блок с использованием нейронной сети, следующий за блоком ЦОС состоит из двухслойной нейронной сети (в данном примере, скрытый слой – 10 нейронов, тангенциальная функция активации, выходной слой – линейная функция активации).

Необходимо отметить, что в прогнозируемом блоке может использоваться другая архитектура НС.

На вход прогнозирующего блока подаются отсчеты «вертикального сигнала» с выхода блока ЦОС, при этом, целевыми отсчетами (подаваемыми на выход НС) при обучении прогнозирующего модуля являются целевые (прогнозируемые) отсчеты входного сигнала (впоследствии, итоговые результаты прогноза), также, подаются дополнительно целевые отсчеты, выполняющие роль «стабилизаторов» – выборка заданной длины из отсчетов «вертикального сигнала» со входа НС (то есть, с выхода блока ЦОС), плюс выборка заданной длины из отсчетов исходного входного сигнала (то есть, со входа блока ЦОС).

Введение «стабилизаторов» наделяет прогнозирующий блок (рис. 1) свойствами автоэнкодера (автокодировщика) (Autoencoder (AE)) [17–20], что сужает пространство выбора при формировании прогноза НС за счет наложения ограничений при формировании прогноза. Ограничения требуют, кроме восстановления на выходе НС прогнозируемых отсчетов выборок сигнала (то есть, результата прогноза), также, дополнительно восстановление входных выборок отсчетов – «стабилизаторов». Введение «стабилизаторов» повышает точность результата прогнозирования.

В данном случае (при наличии дополнительных целевых отсчетов – «стабилизаторов») для прогнозирующего блока с использованием НС можно предложить название «прогнозирующего автоэнкодера» (predictive Autoencoder (PAE)).

Предложенная в работе структура PAE обобщает понятие классического автоэнкодера (Autoencoder (AE)), наделенного только свойством восстановления входного сигнала.

3. Исследование структуры и параметров блока ЦОС прогнозирующего модуля на точность формируемого прогноза.

Рассмотрим влияние блока ЦОС на точность формируемого прогноза.

На рис. 3 изображена структурная схема прогнозирующего модуля с упрощенной структурой: отсутствует блок ЦОС, на вход НС подаются непосредственно отсчеты входного сигнала (прогнозируемого сигнала), также отсутствует использование выборок стабилизаторов. То есть, в данном случае прогноз осуществляется непосредственно двухслойной НС, на вход которой подаются 50 последовательных отсчета входного (прогнозируемого) сигнала.

На рис. 4 изображена структурная схема прогнозирующего модуля с добавленным блоком ЦОС при этом, отсутствует использование выборок стабилизаторов. В данном случае прогноз входного сигнала осуществляется двухслойной НС, на вход которой подаются 50 последовательных отсчетов «вертикального сигнала» с выхода блока ЦОС из 50 КИХ – ФНЧ.




Рис. 3. Структурная схема прогнозирующего модуля: отсутствует блок ЦОС и отсутствуют отсчеты – «стабилизаторы» в прогнозирующем блоке с использованием нейронной сети




Рис. 4. Структурная схема прогнозирующего модуля: добавлен блок ЦОС, но отсутствуют отсчеты – «стабилизаторы» в прогнозирующем блоке с использованием нейронной сети

Структура PAE, кроме восстановления входного сигнала реализует, также дополнительно его прогнозирование за пределы восстанавливаемого входного сигнала. Наделение архитектуры AE классического автоэнкодера также, свойствами «предиктора» (то есть, перевод архитектуры AE в архитектуру PAE), дает возможность существенно расширить область решаемых им задач, то есть задач, решаемых с использованием архитектуры PAE.

На рис. 5 приведены результаты формирования прогноза, исследуемого технического входного сигнала на один шаг и два временных шага вперед с использованием прогнозирующего модуля, представленного на рис. 3. На рис. 5, синяя линия – целевая линия, то есть линия сигнала, с которой значения прогноза должны совпадать (учтено смещение по времени для прогнозируемых и целевых отсчетов сигнала). Пурпурная линия –




Рис. 5. Сформированный прогноз на один и два шага по времени вперед, отсутствует блок ЦОС

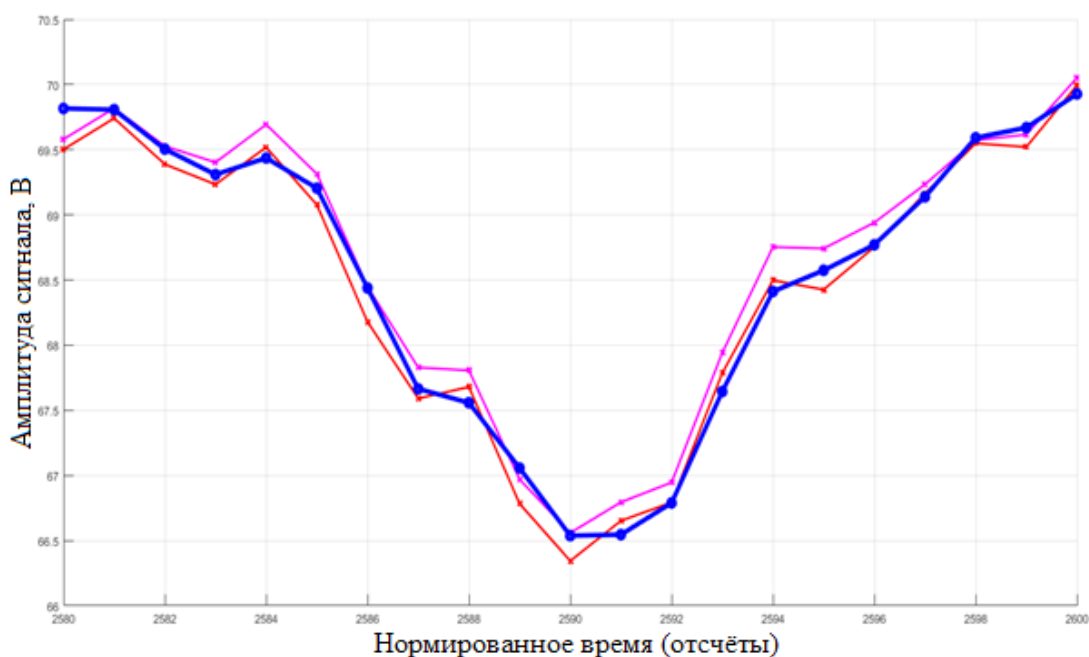


Рис. 6. Сформированный прогноз на один и два шага по времени вперед при наличии блока ЦОС

прогноз на один шаг по времени вперед, красная линия – прогноз на два шага по времени вперед.

На рис. 6 приведены результаты формирования прогноза входного сигнала на один шаг и два временных шага вперед с использованием прогнозирующего модуля, представленного на рис. 4, то есть при наличии блока ЦОС.

Сравнительный анализ результатов, представленных на рис. 5 и 6, свидетельствует о более высокой точности результата прогнозирования с использованием блока ЦОС в прогнозирующем модуле. Для данного примера сред-

неквадратичное отклонение (СКО) результата прогноза на два шага вперед, представленного на рис. 5 имеет величину 0,2101, а для результата прогноза, представленного на рис. 6 имеет величину $СКО=0,1917$, соответственно. На рис. 5, 6 приведены результаты подгонки прогнозирующего модуля (отображено в диапазоне от 2580 до 2600 нормированных временных отсчётов). Обучение НС методом Левенберга-Маркварда производилось на выборке сигнала длиной 5000 отсчетов, при этом распределение входных данных: подгонка – 70%, контроль – 15%, тестирование – 15%.

4. Исследование влияния структуры прогнозирующего блока с использованием нейронной сети на точность формируемого прогноза.

Рассмотрим влияние использования целевых отсчетов «стабилизаторов» на точность формируемого прогноза. В этом, случае фор-

опережением по времени прогнозируемого сигнала, соответственно шагу прогноза по времени вперед.

Необходимо отметить, что в данном случае прогнозирующий блок (рис. 1) имеет архитектуру, предложенного в данной работе «прогнозирующего автоэнкодера PAE».

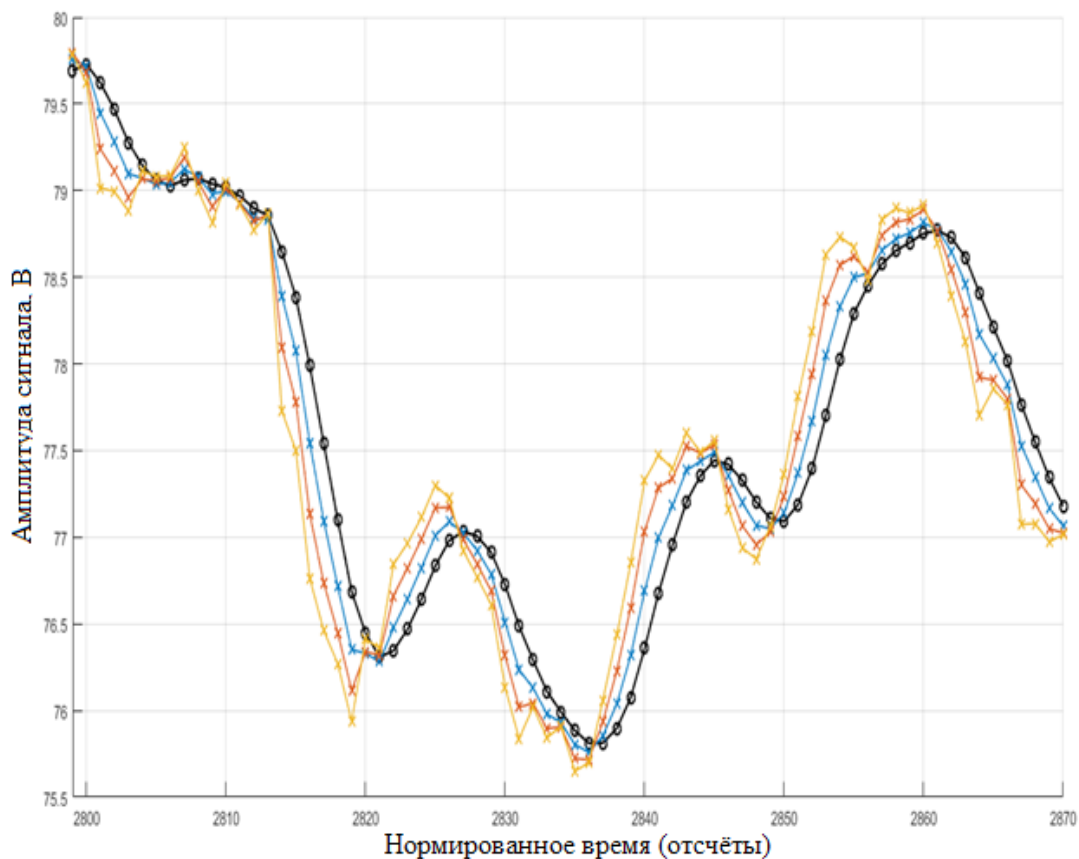


Рис. 7. Сформированный прогноз на один, два и три шага по времени вперед при наличии блока ЦОС и использовании дополнительных целевых отсчетов «стабилизаторов» (архитектура PAE)

мирование прогноза входного сигнала производится при использовании «полной» архитектуры прогнозирующего модуля (рис. 1).

На рис. 7 приведены результаты формирования прогноза входного сигнала (результаты тестирования, отображено в диапазоне от 2800 до 2870 нормированных временных отсчётов за пределами интервала подгонки) на один, два и три временных шага вперед с использованием прогнозирующего модуля, представленного на рис. 1, то есть при наличии блока ЦОС и использовании отсчетов «стабилизаторов». Для данного примера используется шесть отсчетов «стабилизаторов»: три последовательных отсчета с выхода блока ЦОС, то есть со входа НС и три последовательных отсчета входного сигнала, то есть со входа блока ЦОС.

На рис. 7, линии прогноза изображены с

В качестве примера на рис. 8 приведены зависимости ошибки прогноза на три шага вперед по времени для трех вариантов архитектур прогнозирующих модулей (рис. 1, 3, 4) (результаты тестирования, отображено в диапазоне от 2800 до 2870 нормированных временных отсчётов, то есть совпадает с рис. 7). Линия синего цвета – для архитектуры на рис. 1, линии красного и черного цвета для архитектур на рис. 3 и 4, соответственно.

Из рис. 8 видно, что линия (синяя линия) ошибки прогноза, соответствующая «полной» архитектуре прогнозирующего модуля (рис. 1) носит более сглаженный характер, что соответствует более высокому качеству результата прогнозирования.

В табл. 1 приведены рассчитанные значения СКО ошибки результата прогнозирова-

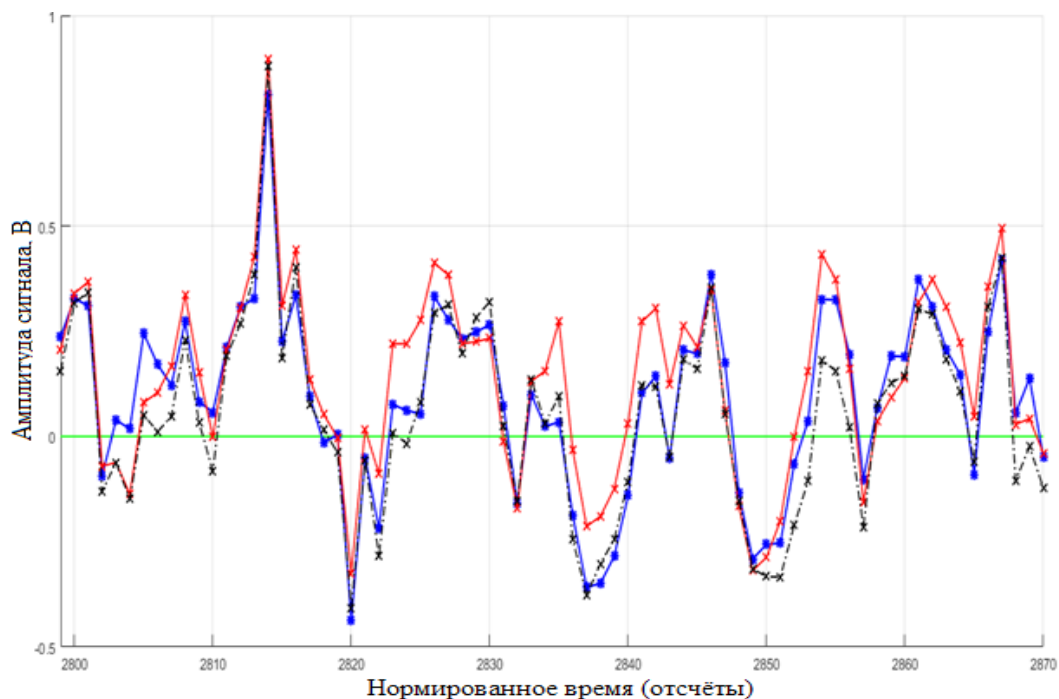


Рис. 8. Зависимости ошибки прогноза на три шага вперед по времени для трех вариантов архитектур прогнозирующих модулей (цвета линий: синий, красный и черный соответствуют рис. 1, 3, 4, соответственно)

ния на один, два и три шага по времени вперед для трех вариантов архитектур прогнозирующих модулей (рис. 1, 3, 4).

нений, собственно происходит обнаружение аномалий в наблюдаемых процессах АСУ ТП. При этом существенно возрастают требова-

Таблица 1

Среднеквадратические отклонение результатов прогноза для трех типов прогнозирующих модулей

Прогнозирующий модуль	СКО прогноза на 1 шаг вперед	СКО прогноза на 2 шага вперед	СКО прогноза на 3 шага вперед
Рисунок 3	0,0626	0,1463	0,2615
Рисунок 4	0,0401	0,1045	0,2026
Рисунок 1	0,0399	0,1044	0,1944

Из результатов, приведенным в табл. 1, следует, что архитектура прогнозирующего модуля (рис. 1), с использованием рассмотренного в работе прогнозирующего автоэнкодера (РАЕ) позволяет осуществлять прогнозирование временных рядов данных с более высокой точностью, что важно при использовании предложенного в работе прогнозирующего модуля в составе обнаружителя (детектора) аномалий процессов АСУ ТП.

Заключение

При формировании аномалий в потоках данных АСУ ТП будут происходить структурные изменения в сигнале ошибки формируемого прогноза наблюдаемого процесса АСУ ТП, по обнаружению этих структурных изме-

ния к точности настройки прогнозирующего модуля, формирующего эталонную модель процесса АСУ ТП, работающей в штатном режиме.

Показано, что предварительная ЦОС входного прогнозируемого сигнала в виде предложенного в работе блока из параллельного набора (гребенки) цифровых КИХ-ФНЧ, приводит к неравновесному учету корреляционных связей временных отсчетов входного сигнала и повышению точности результата прогнозирования.

Предложенный в работе прогнозирующий модуль, состоящий из последовательно соединенных блока ЦОС и прогнозирующего блока с использованием нейронной сети

(прогнозирующего автоэнкодера, predictive Autoencoder (PAE)), позволяет осуществлять прогнозирование временных рядов данных с более высокой точностью, что повышает качество обнаружения аномалий в процессах АСУ ТП.

Литература / References

1. Debar H., Dacier M., Wespi A. Towards a taxonomy of intrusion-detection systems // *Computer Networks*. 1999. vol. 31. Issue 8. pp. 805–822.
2. А. А. Браницкий, И. В. Котенко, Анализ и классификация методов обнаружения сетевых атак, Тр. СПИИРАН, 2016, выпуск 45, 207–244 DOI: <https://doi.org/10.15622/sp.45.13> [A. A. Branitskiy, I. V. Kotenko, Analiz i klassifikatsiya metodov obnaruzheniya setevykh atak, Tr. SPIIRAN, 2016, vypusk 45, 207–244 DOI: <https://doi.org/10.15622/sp.45.13>].
3. Y. J. Xiao, W. Y. Xu, Z. H. Jia, Z. R. Ma & D. L. Qi (2017), «NIPAD: a Non-Invasive Power-based Anomaly Detection Scheme for Programmable Logic Controllers. *Frontiers of Information Technology & Electronic Engineering*», 18(4), 519-534.
4. W. Wang, Y. Xie, L. Ren, X. Zhu, R. Chang & Q. Yin (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.
5. M. Kravchik & A. Shabtai (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.
6. P. Filonov, F. Kitashov & A. Lavrentyev (2017), «RNN-based Early Cyber-attack Detection for the Tennessee Eastman Process», arXiv preprint arXiv:1709.02232.
7. P. Filonov, A. Lavrentyev & A. Vorontsov (2016), «Multivariate Industrial Time Series with Cyber-attack Simulation: Fault Detection Using an Lstm-based Predictive Data Model», arXiv preprint arXiv:1612.06676.
8. 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, pp. 1–5.
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, 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.
11. S. Tomonobu and T. Hitoshi, «One-hour-ahead load forecasting using neural network», IEEE Transactions on Power Systems, no. 1, pp. 21–24, 2002.
12. R. Huang, T. Huang, and Gadh, «Solar generation prediction using the ARMA model in a laboratory-level micro-grid», in IEEE Third International Conference on Smart Grid Communications, Sydney, 2012, pp. 528–533.
13. A. M. Abdurakhmanov, M. V. Volodin, E. Yu. Zybin, and V. N. Ryabchenko, «Methods for predicting power consumption in distribution networks (review)», Russian Internet Journal of Electrical Engineering, pp. 3–23, 2016.
14. A. N. Ragozin, A. A. Razumov, «Neural network forecasting with preliminary digital filtering of complex radio signals», in XVI International scientific and technical conference Physics and technical applications of wave processes, Miass, 2018, pp. 285–290.
15. M. Granroth-Wilding and S. Clark, «What Happens Next? Event Prediction Using a Compositional Neural Network Model», AAAI, pp. 2727–2733, 2016.
16. A. N. Sokolov, A. N. Ragozin, I. A. Pyatnitsky, S. 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, pp. 1–4.
17. 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
18. Hinton GE, Krizhevsky A, Wang SD. Transforming auto-encoders. In *International Conference on Artificial Neural Networks 2011 Jun 14* (pp. 44-51). Springer, Berlin, Heidelberg.

19. Hinton, G. E., & Zemel, R. S. (1994). Autoencoders, minimum description length and Helmholtz free energy. In *Advances in neural information processing systems* 6 (pp. 3-10).

20. Sakurada, M., & Yairi, T. (2014, December). Anomaly detection using autoencoders with nonlinear dimensionality reduction. In *Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis* (p. 4). ACM

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, проспект Ленина, д. 76. E-mail: ragozinan@susu.ru

RAGOZIN Andrey, 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, prsp. Lenina, 76. E-mail: ragozinan@susu.ru