

Д.А. Беспалов, А.С. Болдырев

СПОСОБ МОНИТОРИНГА С ПРОГНОЗИРОВАНИЕМ СОСТОЯНИЯ ДАТЧИКОВЫХ СЕТЕЙ НА ОСНОВЕ СТАТИСТИКИ*

В современном мире становится все больше источников данных, которые используются в распределенных системах для решения задач анализа, управления и оповещения. Они имеют различную физическую природу и степень сложности. Примером таких источников для интеллектуальных систем являются датчики и датчиковые сети. Данная статья посвящена разработке способа мониторинга датчиковых сетей на основе статистик для решения задачи обнаружения аномалий и прогнозирования. В основе предложенного способа лежит метод экспоненциального сглаживания с применением разномасштабных статистик. Теоретические предпосылки работы опираются на интерпретацию поведения объекта как системы с нормальными и аномальными участками работы, оцениваемыми по показаниям сети датчиков. При этом, как входные, так и выходные временные ряды параметров могут быть интерпретированы как аппроксимации с определенной точностью, а также с нулевой изменчивостью или наличием артефактов поведения. Эффективность применения такого подхода для систем охраны периметра, предупреждения проникновения на охраняемую территорию или повышения уровня опасности в некоторой области определяется возможностью предварительной оценки угрозы на месте и выдаче соответствующего оповещения на центральный узел распределенной системы. В связи с этим, в данной статье также приводится структура разрабатываемой и внедряемой распределенной информационной системы мониторинга с предсказанием, выполненной с соблюдением современной концепции микросервисов, применением современных программных технологий и специализированных баз данных. Подобная система является масштабируемой как по горизонтали, так и по вертикали, что делает ее эффективной для практического применения. Новизна данного подхода заключается в применении нестандартного алгоритма предсказания для анализа сигналов датчиковых систем и в комбинации его с методом предварительной обработки данных средствами вейвлет-анализа.

Датчиковые сети; статистика; аномалия; предсказание; тренд; сглаживание; ряд.

D.A. Bepalov, A.S. Boldyrev

METHOD OF MONITORING WITH FORECASTING THE STATUS OF SENSOR NETWORKS BASED ON STATISTICS

In the modern world, there are more and more data sources that are used in distributed systems to solve problems of analysis, management and notification. They have a different physical nature and degree of complexity. Examples of such sources for intelligent systems are sensors and sensor networks. The method for monitoring sensor networks based on statistics to solve the problem of detection of anomalies and forecasting is developed. The proposed method is based on the exponential smoothing using different-scale statistics. Theoretical prerequisites of the work are based on the interpretation of the behavior of the object as a system with normal and anomalous areas of work, estimated by the sensor network. In this case, both input and output time series of parameters can be interpreted as approximations with a certain accuracy, as well as with zero variability or the presence of artifacts of behavior. The effectiveness of such an approach for perimeter security systems, prevention of penetration into the protected area or increase of the level of danger in a certain area is determined by the possibility of preliminary threat assessment on the spot and issuing an appropriate alert to the central node of the distributed system. In this regard, this article also describes the structure of the distributed and distributed information monitoring system with prediction, implemented in compliance with the modern concept of microservices, the use of modern software technologies and specialized databases. Such a system is scalable both

* Работа выполнена в Южном федеральном университете при финансовой поддержке Минобрнауки РФ в рамках реализации проектной части госзадания № 2.3928.2017/4.6.

horizontally and vertically, which makes it effective for practical use. The novelty of this approach is the use of a non-standard prediction algorithm for the analysis of signals of sensor systems and in combination with the method of preliminary data processing by means of wavelet analysis.

Density networks; statistics; anomaly; prediction; trend; smoothing; series.

Введение. Для начала следует отметить, почему так важно внедрять способы мониторинга с прогнозированием. Как следует из названия, работа связана как со слежением за параметрами некоторой системы, так и с предсказанием направления и темпов развития ее. Этот вопрос чрезвычайно важен при любом масштабе системы. Возьмем, например, систему, выполняющую некоторые охранные функции в отдельной организации или систему, которая следит за глобальными параметрами погоды целого региона [1]. Разница в этих двух случаях скрывается в основном в числе источников данных, в масштабе территориального охвата и в инертности реакции на изменение собственного состояния. В любом случае, даже такие разномасштабные системы могут быть описаны схожими математическими моделями и сведены к наборам параметров.

Поэтому, в работах авторов предлагается использовать универсальный подход, который легко можно масштабировать как по вертикали (например, усложняя систему), так и по горизонтали (например, вводя новые источники и типы данных).

Постановка задачи. В качестве основного постулата работы следует отметить тот факт, что сейчас уже недостаточно обнаружить момент аномалии в работе системы или объекта, то есть момент превышения параметром или группой параметров каких-либо критических значений – важно предвосхитить этот момент. То есть, фактически, предсказать аномалию или предупредить о «возможном» приближении к критическому значению.

В такой ситуации, имея некоторый прогноз для системы с мониторингом, можно задействовать механизмы «второго контура», которые, например, содержат элементы искусственного интеллекта или реализуют другой бионический подход. Второй контур реализует принцип принятия решения и выполнит предписанные алгоритмом инструкции.

В самых сложных случаях, принятие решения можно направить на человека-оператора, который получит график текущего состояния системы, метрики развития, точки возникновения вероятных аномалий и приблизительный прогноз [7–9]. Далее эксперт принимает решение, но уже не по десяткам показателей, сведенным к табличной или графической формам, а по нескольким из них, в которых ожидается аномалия или приближение критических значений.

Использование предсказательной аналитики дает эксперту или элементам искусственного интеллекта, время для принятия решений.

Теоретическая часть. В данной работе авторами был применен тезис, что большинство показателей, основанных на реальных физических величинах и выдаваемых датчиковыми сетями, имеют три следующие характеристики:

- ◆ ряд временных параметров;
- ◆ трендовую составляющую;
- ◆ сезонность (повторяемость).

В основе этого представления лежит модель Хольта-Винтерса [4, 5], расширяемая оригинальный метод Хольтерса до трехпараметрического за счет применения рядов временных параметров, на которые можно наложить методы экспоненциального сглаживания, т.е.:

$$L_t = k * \frac{Y_t}{S_{t-s}} + (1 - k)(L_{t-1} + T_{t-1}),$$

$$T_t = b \cdot (L_t - L_{t-1}) + (1 - b)T_{t-1},$$

$$S_t = q * \frac{Y_t}{L_t} + (1 - q) * S_{t-s},$$

где L_t – это результат экспоненциально-сглаженного ряда временного параметра в датчиковой сети на текущий период, а L_{t-1} , соответственно, за предыдущий, T_t – трендовое значение ряда за текущий период, а T_{t-1} , – за предыдущий, S_t – коэффициент сезонности временного ряда для текущего такта, и S_{t-s} – для предыдущего, k – коэффициент сглаживания, такой, что $k \in [0,1]$, $b \in [0,1]$ – коэффициент сглаживания тренда, а $q \in [0,1]$ – коэффициент сглаживания сезонности.

Естественно, что начальные значения параметров сезонности и тренда, то есть T_0 и S_0 равны нулю.

Тогда, прогнозное значение будет определяться состоянием:

$$Y_{t+p} = (L_t + pT_t)S_{t-s+p},$$

где p – порядковый номер периода, на который делается прогноз временного ряда.

Такой способ прогнозирования относится к классу адаптивных моделей Брауна, способных изменять свою структуру и параметры, приспособляясь к изменению условий и описывая процессы с линейной и параболической тенденцией или трендом.

Параболические тренды хорошо вписываются в модель анализируемых данных напряженности, так как в них четко прослеживается два стабильных момента: момент спокойствия с малой волатильностью ряда и момент нарастания ряда с последующим падением в момент присутствия аномалии в виде скачка напряженности.

Собственно говоря, это хорошо демонстрирует наложенный график реального и предсказанного сигнала, представленный на рис. 1.

Оценка ошибки прогнозирования проводится как среднеквадратическое отклонение реального ряда параметров система от прогнозируемого [6]. А для каждого отдельного значения графика y применяется относительная ошибка аппроксимации, вычисляемая по формуле $|\varepsilon|/y$.

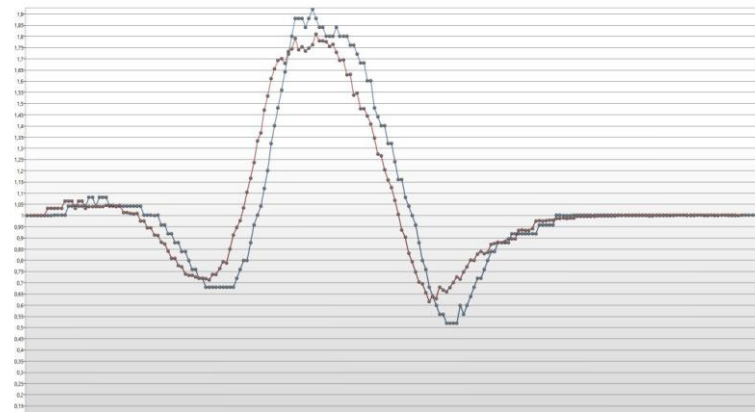


Рис. 1. Графики реального и предсказанного сигналов

В таком случае, необходим дополнительный анализ временных рядов для настройки параметрической модели, то есть для определения значений коэффициентов k , b и q таких, чтобы точность прогноза на участках с высокой гладкостью была аппроксимационно близка хотя бы к 90% (следуя из условий применения и большого количества накладываемых и неконтролируемых факторов).

В этой связи, следует отметить, что места, в которых постоянно отслеживаемая ошибка предсказания будет резко стремиться вниз от ожидаемой величины. Например от 95 %, однозначно являются местами появления артефактов поведения системы или артефактов в показаниях элементов датчиковой сети.

Этот факт объясняется тем, что большинство наблюдаемых сигналов в нормальном состоянии подчиняются закону авторегрессии, то есть их текущее значение зависит от предыдущего с учетом некоторых малых коэффициентов, которые определяют параметры самой модели авторегрессии, т.е.:

$$A_t = c + \varepsilon_t + \sum_j^{J-1} A_{t-j} a_j,$$

где c – это некоторый постоянный коэффициент, всегда прибавляется к прогнозируемому ряду, a_j – это набор коэффициентов периодов, ε_t – случайная составляющая ряда или шум, а A_t – это само значение ряда в конкретный период.

Наиболее вероятно, что в этом месте локализована аномалия поведения системы [2] или аномальное значение параметров, что чаще всего приводит к выходу системы за пределы нормальных условий и к возникновению стрессовой ситуации, например катастрофы, что чрезвычайно актуально как для простых систем, так и даже для отдельных областей и регионов стран [10].

Следует также отметить, что в исходном виде, сигналы от датчиков напряженности плохо поддаются анализу, как видно из следующих рисунков, в нем присутствует большая волатильность между соседними отсчетами как по всему сигналу (рис. 2), так и большой разброс относительно средних значений даже на относительно спокойных участках (рис. 3).




Рис. 2. Исходный сигнал с датчика напряженности




Рис. 3. «Спокойный» участок сигнала без аномалий

В этом случае, гистограмма распределения значений исходного сигнала неравномерна (рис. 4).




Рис. 4. Гистограмма распределения значений исходного сигнала

В этом случае предлагается проводить предварительную обработку исходных данных при помощи методов вейвлет-анализа, способного не только сгладить исходные данные, но и их эффективно анализировать как во временном пространстве, так и в частотном, сегментировать, локализовать аномальное поведение, а также сжимать для более компактного хранения и передачи.

В этом случае, модель анализируемых данных $X(t)$ представляется в виде функции $f(t)$, искаженной аддитивными шумами $\eta(t)$, разложенной в композицию рядов с помощью квадратурно-зеркальных фильтров [21], построенному по дискретному ортогональному базису вейвлет-функций $\{\psi_n\}$ то есть:

$$WX[n] = \langle X, \psi_n \rangle,$$

$$Wf[n] = \langle f, \psi_n \rangle,$$

$$W\eta[n] = \langle \eta, \psi_n \rangle.$$

Преобразование строится как дискретная свертка и дает наложение:

$$WX[n] = Wf[n] + W\eta[n].$$

То есть мы можем разделить сигнал от датчика на более или менее «чистый» f и зашумленный η , используя только очищенный вид для предсказания.

Сигнал от датчика напряженности, обработанный методами вейвлет-анализа (вейвлетом Добеши 4-го порядка) показан на рис. 5.




Рис. 5. Сглаженный сигнал после обработки методами вейвлет-анализа

Данный сигнал имеет более высокую плотность гистограмму распределения значений (рис. 6).




Рис. 6. Гистограмма распределения значений обработанного сигнала

В этом случае, эффективность такой предварительной обработки может быть оценена при помощи пороговой функции $d_n(x)$ как:

$$\tilde{F} = \sum_{n=0}^{N-1} d_n(WX[n])\psi_n.$$

В свою очередь, пороговая функция оценки подбирается исходя из критерия минимизации потери полезной информации либо экспериментальным путем, либо на основе статистики в ходе эксперимента.

Так как вейвлет-декомпозиция итерационно раскладывает сигнал на уровни по две компоненты: аппроксимация и детализация, то для пороговой оценки и шумоподавления мы будем использовать детализацию, а для отображения для пользователя и предсказания – аппроксимацию.

Кроме того, если применять глубокие уровни разложения (выше третьего) для анализа и предсказания именно аппроксимационной компоненты, можно повысить эффективность предложенного способа мониторинга с предсказанием, увеличив вероятность прогноза до 95 %.

Вид аномалии на сигнале с датчика напряженности в данном случае показан на рисунке (рис. 7).




Рис. 7. Локализация и вид аномалии на обработанных данных

Если предложенный способ используется в составе системы мониторинга, то в этом месте логично формировать уведомления о высокой вероятности возникновения аномалии тренда или других параметров временного ряда и отправлять их на монитор эксперта [3].

Экспериментальная часть. Для апробации предложенного способа была разработана система, представленная на следующем рис. 8. Система разрабатывается на языке высокого уровня Python, отлично подходящем как для научных расчетов, так и для проектирования, тестирования и внедрения [15–20].

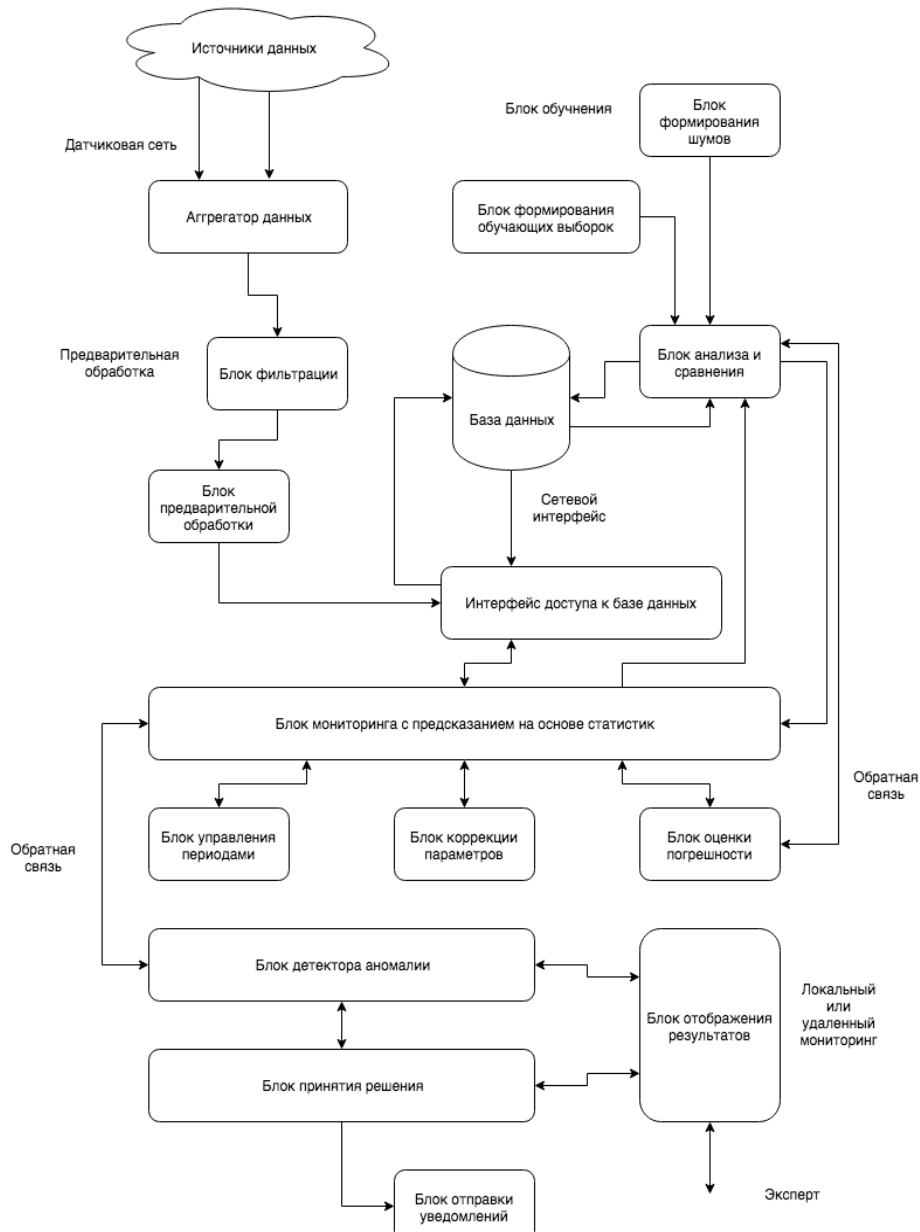


Рис. 8. Структура системы мониторинга с предсказанием

Данная система принимает показания на сеть датчиков локально или по сети Интернет при помощи **агрегатора данных**. В этом блоке производится разделение потоков информации, кэширование [14] и, при необходимости, добавление именованных метрик источников с временными метками. В **блоке фильтрации** выполняется очистка данных от шумов, если эта операция не проводилась на источнике, удаление неполных, испорченных или потерянных пакетов серии. Далее данные передаются в **блок предварительной обработки**, где выполняется их нормализация, унификация формата пакета и т.п. действия. После этого, валидные пакеты данных направляются посредством **интерфейса доступа к базе данных** в саму базу. В качестве базы данных используется так называемая **time-series database** типа **InfluxDB** [11–13], которая ориентирована на хранение временных рядов параметров в определенном формате. В качестве входного звена для базы данных используется **интерфейс Telegraf**. Через этот же интерфейс доступа к базе данных информацию принимает **блок мониторинга с предсказанием на основе статистик**. В нем выполняются приведенные выше расчеты, выполняется **прогноз и коррекция параметров**. **Блок оценки погрешности** предсказания играет роль точки обратной связи с **Блоком обучения**, который контролируется со стороны эксперта. Результат мониторинга с предсказанием подается на **блок детектора аномалий** и, в последствии, на **блок принятия решения**.

Эти блоки определяют факт возрастания вероятности происхождения аномалии в анализируемых временных рядах параметров и формируют уведомления при помощи **блока отправки уведомлений**.

Сведенный воедино в графическом и текстовом виде результат работы выдается на **блок отображения результатов**, который наблюдается на мониторе эксперта, расположенном локально в физическом секторе системы или удаленно по сети Интернет.

Интерфейс для нормального отображения результатов строится на технологии **Grafana**, модуль которого входит в инфраструктуру **InfluxDB Cloud (TICK)**.

Также необходимо отметить, что **TICK** позволяет использовать дополнительный источник уведомлений (алертов, alerts) на основе **Chronograf**. Таким образом мы имеем два источника алертов: внутренний источник системы и внешний – со стороны **Chronograf**. Последний поддерживает связь с модулем предварительной обработки **Karacitor**, который будет введен в систему на следующей стадии разработки, и позволяет использовать пуш-уведомления и корпоративные мессенджеры типа Slack.

Блок обучения необходим для моделирования ситуации, когда идет настройка системы мониторинга с предсказанием. В этом случае моделируется ситуация поступления геренируемых сигналов с зашумлением или реальных исторических данных с опозданием как минимум на 1 период, для того чтобы эксперт мог настроить коэффициенты системы наилучшим образом, а частности, адаптируя к физическим особенностям сигналов, темпу времени, частоте следования отсчетов и т.п.

Вывод. Таким образом, разрабатываемая система мониторинга с прогнозированием по предложенному способу вводится в эксплуатацию и активно тестируется, а сам способ является актуальным, так как показывает хорошие результаты с низким процентом ошибок на реальных сигналах.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Boldyreff A.S., Bepalov D.A., Adzhiev A.K.* Automated information-analytical system for thunderstorm monitoring and early warning alarms using modern physical sensors and information technologies with elements of artificial intelligence // Proceedings of SPIE. "Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping II". – 2017. – P. 102180P.

2. Беспалов Д.А. Предварительная обработка временных рядов параметров в задаче обнаружения аномалий в работе информационных систем, использующих пластиковые карты // Известия ЮФУ. Технические науки. – 2017. – № 5-6 (190-191). – С. 48-65.
3. Беспалов Д.А., Ананьев А.А. Способ обнаружения аномалий в работе информационных систем, использующих пластиковые карты // Известия ЮФУ. Технические науки. – 2017. – № 5-6 (190-191). – С. 38-48.
4. Helge Brügger. Holt-Winters Traffic Prediction on Aggregated Flow Data. Network Architectures and Services, September 2017. Seminars FI / IITM SS 17. – P. 25-32.
5. Bermúdez J.D., Segura J.V. & Vercheri E. Bayesian forecasting with the Holt–Winters model // Journal of the Operational Research Society. – 2010. – Vol. 61. – P. 164-171.
6. Gelper S., Fried R. & Croux C. Robust forecasting with exponential and Holt-Winters smoothing // Journal of Forecasting. – 2010. – Vol. 29. – P. 285-300.
7. Adzhiev Anatoly Kh., Boldyrev Anton S., Bolgov Yuriy V., Manfred Wendisch, Bondareva Olga. V. Advanced remote sensing of thunderstorm events and atmospheric electric field // Proceedings of SPIE "Remote Sensing of Clouds and the Atmosphere XXII" 2017. – P. 104240M.
8. Boldyrev A.S., Boldyreva K.A. Modeling of the Electric Field near the Surface Layer under Strong Turbulent Mixing. Geophysical Research Abstracts. Vol. 17, EGU General Assembly, 2015.
9. Adzhiev A.Kh., Boldyreff A.S., Kazakova S. Method of Thunderstorm Activity Monitoring Using Lightning Sensors and Electric Field Mills. Geophysical Research Abstracts. Vol. 17, EGU General Assembly, 2015.
10. Adzhiev Anatoly, Boldyreff Anton, Kuliev Dalhat, Kondratyeva Natalia and Chochayev Khizir. Characteristics of Thunderstorm Activity and Parameters of Lightning in the South of Russia // European Conference on Severe Storms 2015 14;18 September 2015, Wiener Neustadt, Austria ECSS2015-91.
11. John Shahid. InfluxDB Documentation. Release 4.1.1. Sep. 13, 2017. – 21 p.
12. Syeda Noor Zehra Naqvi. Sofia Yfantidou. Time Series Databases and InfluxDB. Universite libre de Bruxelles. Advanced Databases Winter Semester 2017-2018. December 17, 2017. – 41 p.
13. Andrew Lahiff. Monitoring with InfluxDB and Grafana. STFC RAL. HEPiX 2015 Fall Workshop, BNL. UK Computing for Particle Physics. 2015. – 30 p.
14. Josiah L. Carkson. Redis in Action. Manning Publications. Shelter Island. 2013. – 322 p.
15. Wes McKinney. Python for Data Analysis. – OReilly Media, Inc, 2013. – 470 p.
16. Jake VanderPlas. Python Data Science Handbook. – OReilly Media, Inc, 2017. – 548 p.
17. Arnaud Beck. Data analysis with python. Laboratoire Leprince-Ringuet, École Polytechnique, CNRS/IN2P3.
18. Joel Grus. Data science from scratch. – OReilly Media, Inc, 2015. – 464 p.
19. Edouard Duchesnay, Tommy Lofstedt. Statistics and Machine Learning in Python. Release 2. Jun 22, 2018. – 201 p.
20. Allen B. Downey. Think Stats. Green Tea Press, Needham, Massachusetts. 2014. – 264 p.
21. Малла С. Вэйвлеты в обработке сигналов. – М.: Изд-во Мир, 2005. – 672 с.

REFERENCES

1. Boldyreff A.S., Bespalov D.A., Adzhiev A.K. Automated information-analytical system for thunderstorm monitoring and early warning alarms using modern physical sensors and information technologies with elements of artificial intelligence, *Proceedings of SPIE. "Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping II"*, 2017, pp. 102180P.
2. Bespalov D.A. Predvaritel'naya obrabotka vremennykh ryadov parametrov v zadache obnaruzheniya anomalii v rabote informatsionnykh sistem, ispol'zuyushchikh plastikovye karty [Pre-processing of time series of parameters in the problem of detection of anomalies in the information systems using plastic cards], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2017, No. 5-6 (190-191), pp. 48-65.
3. Bespalov D.A., Anan'ev A.A. Sposob obnaruzheniya anomalii v rabote informatsionnykh sistem, ispol'zuyushchikh plastikovye karty [Method of detection of anomalies in the information systems using plastic cards], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2017, No. 5-6 (190-191), pp. 38-48.
4. Helge Brügger. Holt-Winters Traffic Prediction on Aggregated Flow Data. Network Architectures and Services, September 2017. Seminars FI / IITM SS 17, pp. 25-32.

5. *Bermúdez J.D., Segura J.V. & Vercheri E.* Bayesian forecasting with the Holt–Winters model, *Journal of the Operational Research Society*, 2010, Vol. 61, pp. 164-171.
6. *Gelper S., Fried R. & Croux C.* Robust forecasting with exponential and Holt-Winters smoothing, *Journal of Forecasting*, 2010, Vol. 29, pp. 285-300.
7. *Adzhiev Anatoly Kh., Boldyrev Anton S., Bolgov Yuriy V., Manfred Wendisch, Bondareva Olga. V.* Advanced remote sensing of thunderstorm events and atmospheric electric field, *Proceedings of SPIE "Remote Sensing of Clouds and the Atmosphere XXII" 2017*, pp. 104240M.
8. *Boldyrev A.S., Boldyreva K.A.* Modeling of the Electric Field near the Surface Layer under Strong Turbulent Mixing. Geophysical Research Abstracts. Vol. 17, EGU General Assembly, 2015.
9. *Adzhiev A.Kh., Boldyreff A.S., Kazakova S.* Method of Thunderstorm Activity Monitoring Using Lightning Sensors and Electric Field Mills. Geophysical Research Abstracts. Vol. 17, EGU General Assembly, 2015.
10. *Adzhiev Anatoly, Boldyreff Anton, Kuliev Dalhat, Kondratyeva Natalia and Chochayev Khizir.* Characteristics of Thunderstorm Activity and Parameters of Lightning in the South of Russia // European Conference on Severe Storms 2015 14;18 September 2015, Wiener Neustadt, Austria ECSS2015-91.
11. *John Shahid.* InfluxDB Documentation. Release 4.1.1. Sep. 13, 2017, 21 p.
12. *Syeda Noor Zehra Naqvi. Sofia Yfantidou.* Time Series Databases and InfluxDB. Universite libre de Bruxelles. Advanced Databases Winter Semester 2017-2018. December 17, 2017, 41 p.
13. *Andrew Lahiff.* Monitoring with InfluxDB and Grafana. STFC RAL. HEPiX 2015 Fall Workshop, BNL. UK Computing for Particle Physics. 2015, 30 p.
14. *Josiah L. Carkson.* Redis in Action. Manning Publications. Shelter Island. 2013, 322 p.
15. *Wes McKinney.* Python for Data Analysis. O'Reilly Media, Inc, 2013, 470 p.
16. *Jake VanderPlas.* Python Data Science Handbook. O'Reilly Media, Inc, 2017, 548 p.
17. *Arnaud Beck.* Data analysis with python. Laboratoire Leprince-Ringuet, École Polytechnique, CNRS/IN2P3.
18. *Joel Grus.* Data science from scratch. O'Reilly Media, Inc, 2015, 464 p.
19. *Edouard Duchesnay, Tommy Lofstedt.* Statistics and Machine Learning in Python. Release 2. Jun 22, 2018, 201 p.
20. *Allen B. Downey.* Think Stats. Green Tea Press, Needham, Massachusetts. 2014, 264 p.
21. *Malla S.* Veyvlety v obrabotke signalov [Wavelets in signal processing]. Moscow: Izd-vo Mir, 2005, 672 p.

Статью рекомендовал к опубликованию д.т.н., профессор А.М. Белевцев.

Болдырев Антон Сергеевич – Южный федеральный университет; e-mail: boldyrev@sfedu.ru; 347928, г. Таганрог, пер. Некрасовский, 44; тел.: +78634371883; к.ф.-м.н.; доцент; Ио директора ИРТСУ.

Беспалов Дмитрий Анатольевич – e-mail: dabespalov@sfedu.ru; тел.: +78634371656; кафедра ВТ ИКТИБ; к.т.н.; доцент.

Boldyrev Anton Sergeevich – Southern Federal University; e-mail: boldyrev@sfedu.ru; 44, Nekrasovskiy, Taganrog, 347928, Russia; phone: +78634371883; cand. of phis.-math. sc.; associate professor.

Bespalov Dmitriy Anatol'evich – e-mail: dabespalov@sfedu.ru; phone: +78634371656; cand. of eng. sc.; associate professor.