

# OPTIMIZATION OF DATA PROCESSING ON THE BASIS OF MODIFIED TRAINING OF NEURAL NETWORK AND SEGMENTATION OF CASUAL TIME PROCESSES

S. M. Kholmönov

Samarkand State University,  
140104, Samarkand, Uzbekistan

---

---

In traditional monitoring systems of industrial-technological complexes with non-stationary objects of control the quality of casual time series (CTS) identification and data accuracy increase up to the required level is ensured by involving difficult analytical relationships defined in the form of differential, difference, recurrence equations, which are realized by high iterative algorithms. Optimization of identification and data processing is ensured by adjustment parameters of CTS identification model using difficult recurrence relationships when conditions provide availability of extensive prior knowledge.

The perspective approach to elimination of high-iterative method of calculation under a priori insufficient of data and uncertainty during developing mechanisms of regulatory and adjustment of non-stationary objects parameters is to develop methods and models that combine opportunity, properties and features of neural networks (NN) with mechanisms for extraction and use of useful knowledge, hidden properties, specific characteristics of CTS. In this case the mathematical apparatus of soft computing successfully completes composition of known methods and algorithms, constructed on the basis of statistical and dynamic approaches, and also expands the capacity of existing toolkits. The important task of NN using is training of the network, and known algorithms of forward and back-propagation of errors are based on methods of least squares, gradient optimization and their modifications that lead to labor intensive computing of precise values of the optimization functional, especially when it is necessary to solve tasks with high dimensionality.

In this work the mathematical model of data processing optimization is formalized in view of application the mechanism of adjustment, where the task of optimization of data processing is to regulate the value of output result of identification  $u(\cdot)$  on the basis of selecting the suboptimal set of NN training parameters.

Concept of probability, evolutionary computation, adaptation of parameters of computational schemes of NN structural components are used for improvement and development methods to optimization data processing and solution of tasks of search during NN training. Solution of designing of adapted modified computational schemes of NN structural components is to form a sub-optimal set of parameters such as weights of neurons, synaptic connections coefficients, type of activation function, rational architecture, functional relationships „inputs and outputs“.

Use of NN radial-basis activation functions gives to network the feature of self-tuning and self-adaptation, and allows to carry out dynamic adjustment of parameters of computational schemes of NN structural components. The mechanism for use the methods of parameters adjustment on the basis of selection fractal characteristics, segmentation, filtering and analysis is proposed to empower and improve the adequacy of models to describe objects with non-stationary components of CTS.

The developed program complex includes module of identification and synthesis of dynamic models described non-stationary objects, modules of modified NN training on the basis of radial-basis functions,

segmentation, CTS filtering, adjustments of parameters, results of which testing are received at 538 training sets generated from set of CTS measurements.

The study showed that during implementation of developed methods and algorithms for the identification, the number of areas accounted for the change of quasi-stationary segments increased on 10–12%, and the number of accounted classes of non-stationary events increases on 20–30% due to determination and formation of sub-optimal sets, application of segmentation mechanisms, nonlinear filtering and NN training, and this undoubtedly proves obvious of optimization of data processing based on synthesis of statistical, dynamical and neuro networking models.

**Key words:** non-stationary object, data processing, identification, optimization, training of neural network, adjustment of parameters, segmentation, nonlinear filtration.

## References

1. Myatt G. Making Sense of Data Analysis and Data Mining. Hobken: John Wiley & Sons, 2007.
2. Neyrosetevaya model analiza texnologicheskix vremennix ryadov v ramkax metodologii Data Mining [Neuronetworking model for analysis of technological time series in methodology Data Mining] / A. M. Vulfin, A. I. Frid // Informacionno-upravlyayushiye sistemi. 2011. N 5. P. 31–38.
3. Scott, A. C. Neuroscience: a mathematical primer / Alan S. Scott. — New York: Springer–Verlag, 2002.
4. Jumanov I. I., Kholmonov S. M. Optimizatsiya obucheniya neyrosetevoy sistemi obrabotki dannix na osnove statisticheskix svoystv informatsii [Optimization of training of neuronetworking system of data processing on the basis of information statistical properties] // Problemi informatiki I energetiki. 2011. N 3. P. 50–56.
5. Sezer, E. Employment and comparison of different artificial neural networks for epilepsy diagnosis from EEG signals / E. Sezer, H. Isik, E. Saracoglu // J. Med. Syst. 2012. N 36. P. 347.
6. Chipiga A. F., Voronkin R. A. Obucheniye iskusstvennix neyronnix setey putyom sovmestnogo ispolzovaniya metodov lokalnoy optimizatsii I geneticheskix algoritmov [Training of artificial neural networks by sharing methods of local optimization and genetic algorithms] // Izvestiya TRTU. T. 33. N 4. P. 172–174.
7. Lawhern, V. Detection and classification of subject-generated artifacts in EEG signals using autoregressive models / V. Lawhern, W.D. Hairston, K. McDowell, M. Westerfield, K. Robbins // Journal of Neuroscience Methods. 2012. N 208. P. 181.
8. Jumanov I. I., Abdullayev A. N. Kontrol tochnosti peredachi informatsii v sistemax avtomatizatsii izmereniya I obrabotki dannix nestacionarnoy prirodi [Control of information accuracy during transfer in systems of automation measurement and processing of data with non-stationary nature] // WCIS — 2006, TGTU, Tashkent. P. 15–21.
9. Djumanov O. I. Adaptive designing for neuronetworking system of processing the data with non-stationary nature // Peer-reviewed & Open access journal „ATI — Applied Technologies & Innovations“, Issue 1, April 2011. Prague, 2011. V. 4. P. 48–57.
10. Ningsheng Gong, Wei Shao, Hongwei Xu. The Conjugate Gradient Method with Neural Network. Control, 2010, IEEE, Nanjing, Jiangsu, China.
11. Yarushkina N. G. Osnovi nechetkix I gibridnix system [Bases of fuzzy and hybrid systems]: Uchebnoye posobiye. M.: Finansi I statistika. 2004. P. 70–120.
12. Kholmonov S. M. Optimizatsiya obrabotki dannix na osnove metodov otbora informativnix priznakov dlya prognozirovaniya nestacionarnix obyektov [Optimization of data processing on the basis of methods to selecting informative attributes for forecasting non-stationary objects] // X nauchno-prakticheskaya konferentsiya „Sovremenniye instrumentalniye sistemi, informatsionniye tekhnologii I innovatsii“, 19–23 marta 2013 g. Moskva, 2013. P. 264–269.

---

13. Primeneniye metodov segmentasii k obrabotke geofizicheskix dannix [Application of methods of segmentation to processing the geophysical data] / V. V. Geppner, A. B. Tristanov, P. P. Firstov // Kompleksniye seismologicheskiye i geofizicheskiye issledovaniya Kamchatki, KSiGIK — 2006. Materiali Vserossiyskoy nauchno-tehnicheskoy konferensii, 2006. P. 183–187.

14. Sinha, R. K. Artificial neural networks and wavelet based automated detection of sleep spindles, REM sleep and wake states / R. K. Sinha // J. Med. Syst. 2008. N 32. P. 291.

# ОПТИМИЗАЦИЯ ОБРАБОТКИ ДАННЫХ НА ОСНОВЕ МОДИФИЦИРОВАННОГО ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ И СЕГМЕНТАЦИИ СЛУЧАЙНЫХ ВРЕМЕННЫХ ПРОЦЕССОВ

С. М. Холмонов

Самаркандский государственный университет,  
140104, Самарканд, Узбекистан

---

---

УДК 658.512.011

Сформулирована задача и разработаны методы нейросетевой идентификации нестационарных объектов с механизмами настройки параметров моделей описания случайных временных рядов (СВР) и вычислительных схем нейронной сети (НС). Разработан модифицированный алгоритм обучения НС на основе субоптимальных наборов параметров и радиально-базисной активационной функции. Предложены процедуры предварительной обработки СВР, включающие методы сегментации и фильтрации нестационарных составляющих. Методы обучения НС с упрощенными процедурами поиска глобального и локальных экстремумов функционала оптимизации, определения рациональных параметров моделей описания СВР, нелинейной фильтрации с задержкой по времени, адаптивной сегментации с выделением фрактальных характеристик, формирования групп классов, настройки вычислительных схем структурных компонентов радиально-базисной сети реализованы в системах мониторинга технологических процессов.

**Ключевые слова:** нестационарный объект, обработка данных, идентификация, оптимизация, обучение нейронной сети, настройка параметров, сегментация, нелинейная фильтрация.

**Актуальность темы.** Эффективность систем мониторинга деятельности производственно-технологических комплексов с нестационарными объектами управления в различных сферах народного хозяйства, таких как экономика, здравоохранение, метрология, экология, зависит от применяемых подходов к повышению качества идентификации, аппроксимации, анализа, интерпретации результатов обработки данных, представляемых в виде многокомпонентных случайных временных рядов (СВР).

В традиционных системах мониторинга качество идентификации СВР до требуемого уровня обеспечивается путем привлечения сложных аналитических зависимостей, задаваемых в виде дифференциальных, разностных, рекуррентных уравнений, которым характерна высокая итеративность вычислительных процедур [1]. Оптимизация обработки данных при этом обеспечивается за счет настройки параметров моделей идентификации СВР с помощью сложных математических соотношений при условии наличия обширных априорных сведений.

Перспективным подходом к устранению высокой итеративности расчетов, априорной недостаточности данных и неопределенности при выработке механизмов регулирования

и настройки параметров нестационарных объектов является разработка методов и моделей, совмещающих возможности, свойства и особенности нейронных сетей (НС) с механизмами извлечения и использования полезных знаний, скрытых свойств, специфических характеристик СВР [2, 3]. При этом математический аппарат мягких вычислений, одним из компонентов которого является НС, удачно дополняет состав известных методов и алгоритмов, построенных на основе статистических и динамических подходов, расширяя возможности существующего инструментария [2, 4].

Важной задачей при использовании НС является обучение сети, причем известные алгоритмы прямонаправленного и обратного распространения ошибок основаны на методах наименьших квадратов, градиентной оптимизации и их модификации, которые приводят к трудоемким вычислениям точных значений функционала оптимизации, сложность которых возрастает с увеличением размерности решаемых задач [4–6].

В связи с этим, ниже излагаются результаты разработки методов обучения НС на основе проектирования субоптимальных наборов параметров, модификации вычислительных схем структурных компонентов НС и алгоритмов поиска глобального и локальных экстремумов с упрощенными процедурами, позволяющими достичь большой точности обработки данных вне зависимости от размерности задач и при уменьшении вычислительных, а, следовательно, временных и материальных затрат.

**Постановка задачи оптимизации обработки данных нестационарных объектов на основе нейронных сетей.** Реализация методов оптимизации обработки данных по существующим подходам требует обширных сведений о специфических статистических и динамических характеристиках данных по каждому объекту идентификации и набору параметров [4]. Однако, при математической формализации функций оптимизации необходимо учитывать условия, когда априорная информация задается в частичном виде или вообще может отсутствовать и параметры моделей описания СВР характеризуются большой неопределенностью, причем получение адекватной модели идентификации в этих условиях также не всегда представляется возможным. Проблема оптимизации обработки данных при этом становится связанной с решением задач настройки параметров моделей описания СВР, способных учитывать свойства нестационарности данных, влияние случайных всплесков и вспышек в динамике СВР и других факторов внешних воздействий.

Функция оптимизации обработки данных, базирующаяся на применении механизма настройки параметров модели описания СВР, формализуется в виде

$$J = F(u(t - \Delta t), \mathbf{a}, \varpi),$$

где  $u(t - \Delta t)$  — результат идентификации СВР;  $\mathbf{a}$  — вектор заданных априорных сведений о динамике СВР;  $\varpi$  — вектор нестационарных случайных возмущений и помех.

Задача оптимизации обработки данных заключается в настройке значения выходного результата идентификации  $u(\cdot)$  на основе регулирования значений параметров моделей описания СВР, входящих в структуру оптимального набора обучения. Для этого пригодны различные подходы к устранению нестационарных случайных возмущений и помех, основанные на статистических и динамических моделях, а перспективным направлением считается перетрансляция свойств динамических СВР на НС, позволяющая использовать уникальные особенности и возможности сети. Предлагаемый подход к оптимизации обработки данных включает этапы предварительной обработки данных, сегментирования СВР, выявления скачкообразных изменений и нестационарных составляющих, иденти-

фикации и сглаживания на основе механизмов регулирования параметров структурных компонентов НС с радиально-базисными активационными функциями [7–9].

Ключевым моментом нейросетевой идентификации СВР является оптимизация обучения НС, что в традиционных методах с прямым и обратным распространением ошибок достигается использованием трудоемких методов перебора всевозможных вариантов, отжига, запрета, стохастического моделирования при поиске глобального и локального экстремумов градиентных функций [2, 6, 10].

В работах [3, 11, 12] для совершенствования и развития методов оптимизации обработки данных и решения проблемы поиска при обучении НС использованы концепции вероятностного, эволюционного вычислений, адаптации параметров вычислительных схем структурных компонентов НС. Определено, что задача проектирования адаптированных модифицированных вычислительных схем структурных компонентов НС заключается в формировании субоптимального набора параметров — весов нейронов, коэффициентов синаптических связей, вида активационной функции, рациональной архитектуры, функциональных зависимостей „входы–выходы“. В результате синтеза решений этих задач алгоритмы обучения НС приобретают большие возможности при поиске глобального и локальных экстремумов функционала оптимизации, а, следовательно, достижения высокой точности обработки данных при упрощенных вычислительных процедурах. Кроме того, устраняется чувствительность алгоритмов обучения к размерности задач и повышается их устойчивость [4, 6, 12].

Важным принципом оптимизации обработки данных является также сохранение необходимых сведений о результатах предыдущего поиска (успешных и неуспешных), сокращение времени при новых итерациях работы системы, использование базы данных (БД) и базы знаний (БЗ). В связи с этим, на архитектурном уровне проектируемой системы предполагается включение БЗ, в которой хранится информация о свойствах и особенностях НС; она протоколирует все запуски, связанные с поиском субоптимального набора параметров для настройки модели нестационарных объектов и вычислительных схем структурных компонентов НС вместе с такими конечными результатами, как извлечение статистических, специфических характеристик, динамических и других полезных свойств объектов и закономерностей из временных рядов [13].

**Формирование субоптимального набора параметров на основе радиально-базисных функций активации нейронов.** Особенностью подхода, предлагаемого в настоящей работе для обеспечения качественной идентификации и точной обработки данных, является применение радиально-базисных функций активации НС, которые наделяют сети свойствами самонастройки и самоадаптации, что позволяет осуществлять динамическую настройку параметров вычислительных схем структурных компонентов НС [4].

Спроектированная радиально-базисная сеть (РБС) имеет единственный скрытый слой с нелинейной активационной функцией. Для построения модифицированных вычислительных схем структурных компонентов РБС вводятся следующие обозначения параметров:  $\mathbf{c} = c_1, c_2, \dots, c_n$  — вектор центра активационной функции нейронов скрытого слоя;  $\sigma_j$  — ширина окна активационной функции  $j$ -го нейрона скрытого слоя;  $f(X, c) = e^{-\sum_{j=1}^n (x_j - c_j)^2 / \sigma_j^2}$  — радиально-симметричная активационная функция нейрона скрытого слоя;  $\omega_{ij}$  — вес связи между  $i$ -м нейроном исходного слоя и  $j$ -м нейроном скрытого слоя;  $H$  — размер скрытого слоя сети, равный количеству тренировочных шаблонов  $Q$ .

Для реализации вычислительных схем РБС при введенных параметрах требуется выполнение следующих процедур инициализации: синаптические веса нейронов в скрытом слое принимаются равными; центры активационных функций нейронов скрытого слоя размещаются в точках, входящих в набор тренировочных шаблонов:  $c_j = \bar{X}_j$ ,  $j = 1, H$ ; ширина окон активационных функций нейронов скрытого слоя  $\sigma_j$ ,  $j = 1, H$ , выбирается в расширенном интервале  $\sqrt{H}/2 < \sigma < 3\sqrt{H}/2$ ; для определения весов нейронов  $w_{ij}$ ,  $i, j = 1, H$  исходного слоя предъявляется весь набор тренировочных шаблонов.

Выход  $i$ -го нейрона, предъявляемый шаблону для  $p$ -го выхода при обучении НС, определяется как

$$\begin{aligned} Y_i &= w_{i1}f(\bar{X}_p, c_1) + w_{i2}f(\bar{X}_p, c_2) + \dots + w_{iH}f(\bar{X}_p, c_H) = \\ &= w_{i1}f(\bar{X}_p, X_1)w_{i2}f(\bar{X}_p, X_2) + \dots + w_{iH}f(\bar{X}_p, X_H) = D. \end{aligned}$$

Выходы сети для всех шаблонов задаются уравнениями, заданными в матричной форме

$$\Phi w^T = D,$$

где  $\Phi = \|f_{ij}\|_{i,j=1,H}$  — интерполирующая поверхность матрицы  $f_{ij} = f(\bar{X}_i, \bar{X}_j)$ ;  $w^T = \|w_{ij}\|_{i,j=1,H}$  — матрица синаптических весов исходного слоя НС;  $D = \|d_{ij}\|_{i,j=1,H}$  — матрица исходных шаблонов.

Матрица синаптических весов находится из уравнения

$$w^T = \Phi^{-1}D,$$

и результаты решения уравнений обеспечивают прохождение интерполяционной поверхности в пространстве входных тренировочных шаблонов.

Отметим, что изложенный математический аппарат обучения НС ориентируется лишь только на идентификацию нестационарного объекта, в которой составляющие СВР предполагаются стационарными. Наряду с этим, при динамической нейросетевой идентификации неотъемлемой частью решаемой задачи является обработка нестационарных составляющих СВР. Однако, использование для оптимизации обучения НС при нестационарных составляющих СВР численных методов связано с определенными трудностями, к которым относятся следующие: расхождение результатов решения задач приводит к тому, что искомые параметры НС не оптимизируются; в случае оптимизации поиска на основе овражных функций или функций с несколькими минимумами, к классу которых относятся радиально-базисные функции, алгоритмы обучения НС сходятся медленно.

В связи с этим, с целью повышения устойчивости обучения НС с учетом нестационарных составляющих СВР в соответствии с предложенным подходом, следующей задачей исследования является разработка методов синтеза процедур предварительной обработки данных, заключающихся в выделении фрактальных характеристик, сегментации, фильтрации и анализа СВР с механизмами настройки вычислительных схем структурных компонентов РБС [13, 14].

**Оптимизация обработки данных на основе сегментации и фильтрации фрактальных характеристик СВР.** Предполагается, что СВР представляет последовательность неупорядоченных в случайные неравноотстоящие моменты времени измерений показателей, наблюдений, ситуаций. Сегментация представляется функциями, которые используются для извлечения поведения и свойств СВР путем разбиения временного ряда

на участки, соответствующие определенным структурным единицам, принятым постоянными [13, 14].

Каждый однородный сегмент описывается моделью

$$M(A, \sigma, D_n),$$

где  $A$  — весовые коэффициенты;  $\sigma$  — ошибки сегментации;  $D_n$  — дисперсия ошибки сегментации.

Обнаружение наличия скачка в нестационарном СВР в момент  $t$  производится путем проверки условия превышения заданной пороговой величины  $D_0$ .

По алгоритму сегментации СВР выполняются следующие процедуры:

- когда количество предъявленных шаблонов в каком-либо однородном сегменте меньше, чем в многокомпонентной СВР, то осуществляется его слияние с левым сегментом „соседом“;
- процесс продолжается до тех пор, пока динамика сегментированного СВР не перестанет изменяться;
- формируются группы классов для последующего анализа сегментированных СВР;
- объединяются и укрупняются разбитые по классам совокупности выделенных сегментов на предыдущих этапах;
- расширяется количество выделяемых классов для обнаружения переходных состояний нестационарного процесса.

Теперь обучение НС с настройкой параметров структурных компонентов и моделей описания нестационарных объектов модифицируется в соответствии со следующими важными моментами обработки данных:

- область возможных значений вектора настроечных параметров рассматривается как  $[0, C_1] \times [0, C_2] \times \dots \times [0, C_i] \times \dots$ , где  $C_i$  — размерность настроечной матрицы для выделенного сегмента;
- при оптимизации показателя качества обучения НС уменьшается область возможных значений параметров за счет объединения и укрупнения классов выделенных сегментов.

**Результаты реализации методов и алгоритмов оптимизации обработки данных.** Разработан программный комплекс, реализующий алгоритмы оптимизации анализа и обработки данных на основе синтеза динамических моделей, алгоритмов обучения НС, сегментации, фильтрации СВР, настройки параметров.

Реализован алгоритм выбора альтернативного решения, который основан на оценке и ранжировании каждого выхода НС. При этом выбор НС с наиболее сильным откликом позволяет выделить еще несколько близких к данному значению альтернативных решений.

В таблице приведены результаты тестирования, полученные при 538 обучающих наборах, сформированных из множества измерений СВР.

Анализ результатов исследований показал, что при реализации систем обработки данных на основе гибридной идентификации количество учитываемых участков смены квазистационарных сегментов увеличивается на 10–12 %, а количество классов учитываемых нестационарных событий увеличивается на 20–30 % за счет определения и формирования субоптимальных наборов, применения механизмов сегментации, нелинейной фильтрации и обучения НС, что, безусловно, доказывает очевидность оптимизации обработки информации на основе синтеза статистических, динамических и нейросетевых моделей.



Таблица

Результаты тестирования методов и алгоритмов обработки данных

Задачи моделирования	Модели идентификации	Точность обработки данных в %
Сегментация СВР	Авторегрессионные модели	61,9
Модификация сегментирования путем фильтрации СВР	Ортогональные полиномы, фильтры Калмана	78,7
Идентификация объекта	Динамические модели на базе нелинейных фильтров	82,0
Идентификация объекта с настройкой параметров	Модели НС	69,0
Гибридная идентификация с настройкой параметров	Модели выделения фрактальных характеристик, фильтра Калмана, обучение НС с радиально-базисной функцией	87,0

**Заключение.** Разработанные методы оптимизации, идентификации и обработки данных на основе РБС, модификации вычислительных схем структурных компонентов НС, регулирования и настройки параметров сети и определения субоптимальных наборов на основе сегментации и фильтрации нестационарных составляющих СВР рекомендованы для решения различных задач моделирования, анализа и синтеза системы управления нестационарными объектами, функционирующими в условиях недостаточности априорных сведений и неопределенности.

Разработанная гибридная модель идентификации СВР путем синтеза авторегрессионных моделей, нелинейных фильтров с задержкой по времени, адаптивной модели сегментации с формированием групп классов и предложенный алгоритм обучения НС на основе радиально-базисной функции активации позволяют эффективно сглаживать нестационарные составляющие СВР и адаптировать параметры в реальном режиме времени.

Практическая ценность результатов исследований оценивается показателями увеличения количества участков смены квазистационарных сегментов и классов нестационарных событий, что позволяет более полно учитывать статистические, специфические характеристики, динамические свойства и скрытые закономерности в данных для оптимизации обработки нестационарных объектов.

## Список литературы

1. Myatt G. Making Sense of Data Analysis and Data Mining. Hobken: John Wiley & Sons, 2007.
2. Нейросетевая модель анализа технологических временных рядов в рамках методологии Data Mining / А. М. Вульфин, А. И. Фрид // Информационно-управляющие системы. 2011. № 5. С. 31–38.
3. Scott, A. C. Neuroscience: a mathematical primer / Alan S. Scott. New York: Springer-Verlag, 2002.
4. Жуманов И. И., Холмонов С. М. Оптимизация обучения нейросетевой системы обработки данных на основе статистических свойств информации // Проблемы информатики и энергетики. 2011. № 3. С. 50–56.
5. Sezer, E. Employment and comparison of different artificial neural networks for epilepsy diagnosis from EEG signals / E. Sezer, H. Isik, E. Saracoglu // J. Med. Syst. 2012. N 36. P. 347.

6. Чипига А. Ф., Воронкин Р. А. Обучение искусственных нейронных сетей путем совместного использования методов локальной оптимизации и генетических алгоритмов // Известия ТРТУ. Т. 33. № 4. С. 172–174.
7. Lawhern, V. Detection and classification of subject-generated artifacts in EEG signals using autoregressive models / V. Lawhern, W. D. Hairston, K. McDowell, M. Westerfield, K. Robbins // Journal of Neuroscience Methods. 2012. N 208. P. 181.
8. Жуманов И. И., Абдуллаев А. Н. Контроль точности передачи информации в системах автоматизации измерения и обработки данных нестационарной природы // Мат. четвертой всемирной конференции „Интеллектуальные системы для индустриальной автоматизации“ WCIS — 2006, ТГТУ, Ташкент. С. 15–21.
9. Djumanov O. I. Adaptive designing for neuronetworking system of processing the data with non-stationary nature // Peer-reviewed & Open access journal „ATI — Applied Technologies & Innovations“, Issue 1, April 2011. Prague, 2011. V. 4. P. 48–57.
10. Ningsheng Gong, Wei Shao, Hongwei Xu. The Conjugate Gradient Method with Neural Network. — Control, 2010, IEEE, Nanjing, Jiangsu, China.
11. Ярушкина Н. Г. Основы нечетких и гибридных систем: Учебное пособие. М.: Финансы и статистика. 2004. С. 70–120.
12. Холмонов С. М. Оптимизация обработки данных на основе методов отбора информативных признаков для прогнозирования нестационарных объектов // X-я Межд. научно-практ. конференция „Современные инструментальные системы, информационные технологии и инновации“, 19–23 марта 2013 г. Москва, 2013. С. 264–269.
13. Применение методов сегментации к обработке геофизических данных / В. В. Геппенер, А. Б. Тристанов, П. П. Фирстов // Комплексные сейсмологические и геофизические исследования Камчатки КСиГИК-2006. Материалы Всероссийской научно-технической конференции, 2006. С. 183–187.
14. Sinha, R. K. Artificial neural networks and wavelet based automated detection of sleep spindles, REM sleep and wake states / R. K. Sinha // J. Med. Syst. 2008. N 32. P. 291.



**Холмонов Сунатилло Махмудович** — ассистент кафедры информационных технологий Самаркандского государственного университета; тел.: +998933330367; e-mail: s-kolmonov@mail.ru.

**Холмонов Сунатилло Махмудович** окончил физико-математический факультет Самаркандского государственного университета по специальности „Прикладная математика и информатика“ в 2009 году. С 2012 года работает ассистентом на кафедре „Информационные технологии“ механико-математического факультета СамГУ. С. М. Холмоновым опубликовано 67 научных работ в материалах конференций и научных журналах и получено 5 свидетельств о регистрации программных продуктов в Агентстве интеллектуальной собственности Республики Узбекистан. Его текущие исследовательские

интересы включают информационные технологии, автоматизированные системы управления, обеспечение достоверности информации в телекоммуникационных системах, нечеткие множества, нейросетевые технологии.

**Sunatillo Maxmudovich Kholmonov** received his M.Sc. degree in applied mathematics from the Samarkand State University, Uzbekistan in 2002. Currently, he is the assistant in the Department of Information Technologies at Samarkand State University, Uzbekistan. He has published 67 research papers in proceedings of international conferences/workshops and archival journals, and also 5 certificates about official registration of software in Agency of Intellectual Property of the Republic of Uzbekistan. His research interests include information technologies, automation managing systems, information reliability in telecommunication systems, fuzzy sets, and neural networks.