

УДК 519.7

**Л.А. Мыльников<sup>1</sup>, Н.А. Гергель<sup>1</sup>, А.В. Кычкин<sup>1</sup>, Б. Краузе<sup>2</sup>**<sup>1</sup>Пермский национальный исследовательский политехнический университет,  
Пермь, Россия<sup>2</sup>Университет прикладных наук Анхальта, Кётен, Германия

## **ИСПОЛЬЗОВАНИЕ ДИНАМИЧЕСКИХ ПРЕДИКТИВНЫХ МОДЕЛЕЙ ДЛЯ УПРАВЛЕНИЯ ТЕХНИЧЕСКИМИ СИСТЕМАМИ С ИНЕРТНОСТЬЮ**

Актуальность представленного исследования связана с необходимостью учета особенностей рассматриваемых систем для дальнейшего повышения эффективности их функционирования. Цель работы связана с необходимостью демонстрации возможности построения эмпирических регрессионных моделей на основе статистических данных и на их основе построения систем управления, показывающих большую по сравнению с системами автоматического регулирования эффективность. Работа осуществлена на основе использования статистических данных и методов машинного обучения, которые использовались для построения регрессионных моделей. Модели управления были основаны на ретроспективных данных, которые использовались для моделирования изменений температуры помещения в зависимости от температуры на улице и величины отбираемого из теплосистемы тепла, а также для моделирования изменения температуры теплоносителя в зависимости от изменения температуры помещения и уличной температуры. Наибольшая точность была получена с помощью метода lasso. Модели, полученные с помощью этого метода, и были положены в основу получения системы управления и оценки реакции системы. Полученные модели относятся к классу динамических предиктивных моделей, предложена структура их применения в системах управления теплоснабжением многоэтажных офисных зданий с учетом ее инертности. Удалось показать большую эффективность предложенных решений по сравнению с использованием ПИД-регулятора на ретроспективных данных, а также зависимость решения от выбора данных. Значимость исследования: проведенное исследование позволяет строить модели управления, которые могут работать как в автоматическом режиме, так и в роли систем поддержки принятия решений при обосновании вопросов внедрения систем управления и оценки потенциальной экономии от их использования.

**Ключевые слова:** информационная система, управление, модель, информационная инфраструктура, поддержка принятия решений, машинное обучение.

**L.A. Mylnikov<sup>1</sup>, N.A. Gergel<sup>1</sup>, A.V. Kychkin<sup>1</sup>, B. Krause<sup>2</sup>**

<sup>1</sup>Perm National Research Polytechnic University, Perm,  
Russian Federation

<sup>2</sup>University of Applied Sciences Anhalt, Koethen, Germany

## **DINAMIC PREDICTION MODEL IN CONTROL SYSTEMS OF TECHNIC PROCESSES WITH INERTIA**

The paper investigates the performance of control systems taking into consideration the characteristics of these systems. In order for the efficient performance to be achieved, statistical data are used to build empirical regression models which are further expanded to control systems; as a result, control systems exhibit higher performance parameters than those with regulatory control. In the study, we use statistical data and machine learning methods which were applied for building regression models. Control models are built on the retrospective data being used for both simulating changes in room temperature depending on the temperature outside and the amount of heat obtained from heat supply, and for simulating changes in the temperature of heat carrier depending on the changes in room temperature and the temperature outside. Method lasso produced most accurate values. The models which were obtained with help of this method were used for building a control system and estimating system reaction. These models refer to the class of dynamic predictive models. The paper suggests how these models can be applied to control heat supply in high rise office buildings by taking into account the inertness of heat supply. The calculations evidenced higher efficiency of suggested solutions compared to the application of PID control systems on retrospective data and showed that the solution depends on the selection of data. The suggested approach allows to build control models which can operate in automatic mode and can be used as decision support systems by giving reasons for the integration of control systems and the assessment of potential savings.

**Keywords:** information system, control, model, simulation, information infrastructure, decision support, machine learning.

**Введение.** В настоящее время разработано большое количество методов управления техническими системами. Для повышения их эффективности обсуждается возможность использования упреждающего управления [1–3]. Такое управление показывает себя с лучшей стороны, если существует некоторое время – время реакции системы на возмущающее и управляющее воздействия (инертность объекта управления). На практике реакция по разным параметрам может иметь различное запаздывание, зависеть от внешних факторов. Такая реакция может отличаться и для двух одинаковых объектов в связи с тем, что они функционируют в разных условиях, имеют разную степень износа, могли проходить техническое обслуживание и регламентные работы, в результате которых отдельные детали были заменены или обновлены, уже при изготовлении не может быть сделано абсолютно идентичных изделий. Таким образом, для управления необходимо построение

модели, которая будет учитывать особенности системы и будет предсказывать ее поведение или поведение ее отдельных параметров, необходимых для выработки управляющего воздействия.

Построение таких моделей в настоящее время осуществляется на основе эмпирических методов – методов машинного обучения и использования статистических данных об объекте управления [4]. Ключевыми вопросами в этом случае становятся задача выбора метода, недостаточный объем или недостоверность данных, факторы неопределенности, многофакторность, вопросы обучения моделей.

**Объект исследования.** В качестве примера рассмотрим задачу управления индивидуальным тепловым пунктом многоэтажного здания для поддержания стабильной температуры в помещении. Индивидуальный тепловой пункт (ИТП) рассматриваемого офисного здания – комплекс технических средств, расположенных в обособленном помещении и осуществляющих инженерные подключения системы отопления и горячего водоснабжения к централизованной тепловой сети. Структурная схема ИТП, включающая средства автоматизации и управления, приведена на рис. 1 (см. подробнее в [5] и [6]).

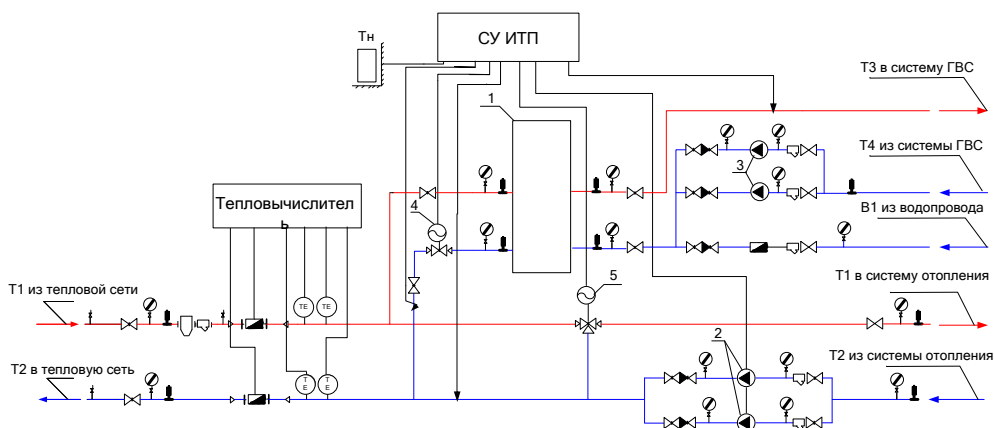


Рис. 1. Структурная схема индивидуального теплового пункта многоэтажного здания: 1 – пластинчатый теплообменник, 2 – циркуляционные насосы ГВС с частотно-регулируемым электроприводом (ЧРП), 3 – смесительно-повысительные насосы отопления с ЧРП, 4 – двухходовой регулирующий клапан с электрическим приводом, 5 – трехходовой регулирующий клапан с электрическим приводом, MS12 (СУ ИТП) – контроллер системы управления, блок управления циркуляционными насосами, датчики температуры,  $T_n$  – наружная температура

ИТП выполнен по зависимой схеме отопления с одноступенчатой системой горячего водоснабжения (ГВС). Из тепловой сети через подающий трубопровод осуществляется подача теплоносителя с температурой 95–70 °С в здание. С помощью обратного трубопровода в сеть попадает теплоноситель, который отдает часть тепловой энергии, необходимой для обогрева помещений и нужд ГВС. Движение теплоносителя в отопительном контуре поддерживается циркуляционными насосами (см. элемент 2 на рис. 1), которые включаются периодически.

Управление насосом осуществляется в автоматическом режиме с помощью контроллера. Автоматическое поддержание необходимого температурного графика в отопительном контуре осуществляется с помощью алгоритма ПИД-регулирования [1]. Контролер воздействует на регулирующий клапан, расположенный на подающем трубопроводе на стороне внешней тепловой сети. Между подающим и обратным трубопроводами установлена смесительная переключательная с обратным клапаном, за счет которой осуществляется подмес в подающий трубопровод из обратной линии теплоносителя, с более низкими температурными показателями. Для исследования возможностей управления на основе предиктивных моделей была рассмотрена схема управления, приведенная на рис. 2.

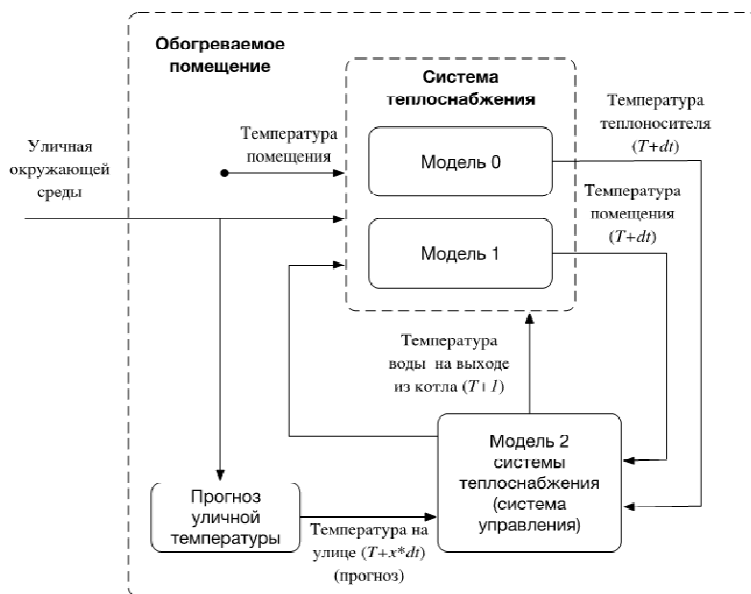


Рис. 2. Структура модели системы теплоснабжения на основании данных

Для реализации данной схемы необходимо установление зависимости между входом и выходом для моделей 0, 1 и 2 на рис. 2 (построение моделей прогнозирования температуры помещения, нагревания воды, температуры воды после прохождения по контуру обогрева).

Такие модели могут быть получены эмпирическим путем с использованием регрессионных моделей и методов машинного обучения. Машинное обучение в настоящее время широко применяется во всех областях, где стоит задача сбора и анализа данных [7].

Задачей машинного обучения является нахождение неизвестной зависимости между известными множествами объектов. При этом такие методы требуют наличия статистических данных (рис. 3), а выбор конкретного метода осуществляется на основе оценки точности описания, полученной на основе обучающей выборки данных модели на тестовых данных [8].

На рис. 3 представлены данные, которые использовались для обучения модели в форме временных рядов [9]. Это данные за два месяца отопительного сезона. Экспериментальным путем было выяснено, что смешение данных отопительного сезона и сезона, когда отопление не подается, так же, как и использование данных не соответствующего периоду отопления сезона, приводит к получению моделей, не проходящих проверку на адекватность или имеющих значительные отклонения при визуальном сопоставлении выборок (при отображении их как в виде временных рядов, так и диаграмм размахов) [10].




Рис. 3. Используемые выборки данных для построения и анализа системы управления ИТП: *а* – обучающая, *б* – тестовая

**Прогнозирование параметров модели.** Нам необходимо решить вопрос прогнозирования значений параметров, характеризующих объект исследования. Для этого мы будем определять зависимость исследуемых параметров от нескольких признаков. Такую задачу называют задачей регрессионного анализа. Для работы с данными и решения задачи регрессии рассматривались такие методы машинного обучения [11], как: *Neural Network*, *Support Vector Machine (SVM)*, *k-NN*, *PLS Regression*, *Lasso*, *Bayesian linear regression (Bayesian statistics)*.

Основным недостатком метода *SVM* является его чувствительность к шумам [12]. Идентификация и удаление компонентов шума из векторов пространственных объектов на большом наборе данных – непростая задача. Кроме этого на метод оказывает негативное влияние высокая размерность (зависимость целевого значения от большого количества параметров и факторов) [12].

*Neural Network* и метод *k-NN* применяются к моделям любой сложности, но при работе с большими данными расчет производится медленнее и ухудшается точность. За счет усреднения значения получается хороший результат, но в сравнении с другими методами машинного обучения результат себя не оправдывает. *k-Nearest Neighbor* обычно используется в приложениях интеллектуального анализа данных. Значение *k*, которое дает наибольшую точность, зависит от имеющегося набора данных и должно быть настроено заранее [13]. Минусом нейронных сетей являются сложность интерпретации принципов получения решений, так как модель, по сути, является «черным ящиком», а также высокая зависимость результата от используемых данных и неудовлетворительные результаты в случае, если данные имеют периодические процессы (данные часто усредняются).

При использовании байесовского подхода и метода *PLS* регрессии [14] в задачах регрессии могут возникать сложности, связанные с получением оценок при использовании больших объемов данных ввиду потерь точности [15]. Расчеты на имеющихся статистических данных также показали наилучшие результаты при использовании метода *Lasso*. Кроме этого данный метод является быстрым, что особенно важно в задачах управления.

*Lasso (Least Absolute Shrinkage and Selection Operator)* – это метод понижения размерности. В статистике и машинном обучении *Lasso* является методом регрессионного анализа, который выполняет выбор переменных (коэффициентов) и регуляризацию с целью повышения точности прогнозирования, исключая недостатки метода наименьших

квадратов [16]. Метод может работать с любыми подмножествами, зависящими от формы ограничения, что приводит к обращению в 0 некоторых коэффициентов модели. Он решает основную проблему – неустойчивость к оценкам коэффициентов (признаков) в задаче линейной регрессии, когда независимые переменные коррелируют друг с другом. Данная проблема решается путем наложения ограничения на норму вектора коэффициентов модели.

Учитываем целевую функцию

$$\frac{1}{N} \sum_{i=1}^N f(x_i, y_i, \alpha, \beta),$$

где регрессионный коэффициент  $\beta = (\beta_1, \beta_2, \dots, \beta_m)'$  определяет вектор  $\mu$

$$\mu = \sum_{j=1}^m x_j \beta_j = X\beta,$$

где  $X$  – матрица значений свободных переменных (матрица признаков),  $X = (x_1, x_2, \dots, x_m)$ . В случае большого числа матрицы признаков метод приводит к повышению устойчивости.

Регуляризованная версия *Lasso* с оценкой будет выглядеть следующим образом:

$$\min_{\alpha, \beta} \frac{1}{N} \sum_{i=1}^N f(x_i, y_i, \alpha, \beta),$$

где  $\alpha$  – комплексный параметр, контролирующий величину штрафа, т.е. показывает, насколько коэффициенты уклоняются от оценок наименьших квадратов и нуля.

Если сравнивать данный метод с *Ridge* регрессией [17], оценочные коэффициенты *Lasso* имеют более низкую дисперсию и менее склонны к превышению, чем метод наименьших квадратов. Поэтому плюс данного метода состоит в том, что мы можем осуществить не только регуляризацию параметров, но и приравнять некоторые из коэффициентов к нулю.

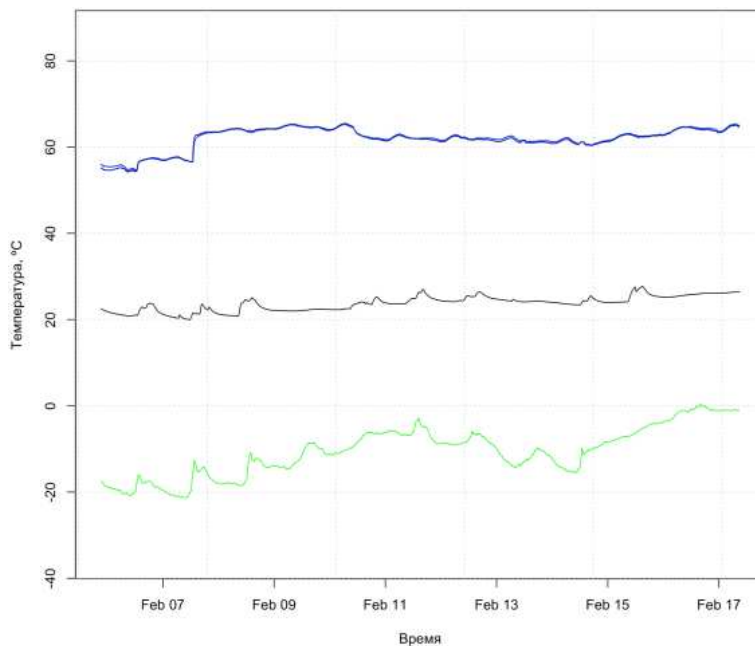
Введем для каждой переменной  $\beta$  две неотрицательные переменные следующего вида:

$$\beta = \beta^+ - \beta^-, \text{ где } \beta^+ \geq 0, \beta^- \geq 0, \|\beta\|_1 \leq \tau.$$


Тогда при уменьшении  $\tau$  получим  $\beta^+ = \beta^- = 0$ . Это означает исключение коэффициента.

В итоге метод *Lasso* осуществляет отбор признаков, исключая шумовые и признаки, связанные с ощутимыми затратами, и хорошо решает проблему мультиколлинеарности.

На основе его использования были получены результаты, приведенные на рис. 4.




*a*



*б*

Рис. 4. Данные, получаемые в результате прогнозирования параметров модели методом Lasso: *a* – температура теплоносителя, *б* – температура обогреваемого помещения, *в* – температура теплообменника





6

Рис. 4. Окончание

Полученные при прогнозировании результаты, прошли проверку на адекватность по критериям Пирсона и Фишера на всем тестовом интервале. Такое качество предсказания результатов в зависимости от других параметров модели позволяет использовать данные для построения модели системы теплоснабжения и системы управления и проверить возможности предиктивного управления в таких задачах.

**Предиктивное управление системой теплоснабжения.** В результате проведенных модельных экспериментов выяснилось, что получаемые данные смещены относительно шкалы времени. Это смещение оказалось равно двум часам. Выяснение значения этой величины необходимо при рассмотрении каждого параметра системы по отдельности и может быть определено экспериментально. В случае если имеется некоторый интегральный показатель, то необходимо определять величину инертности как функцию от времени (которая зависит от группы параметров, влияющих на значение оцениваемого критерия):

$$J(\Delta t) = \arg \max_{\tau \leq \Delta t \leq T} \int_t^{t+\Delta t} (J(t + \Delta t) - (t + \Delta t)) d\Delta t,$$

где  $\tau$  – минимальное время инертности,  $T$  – горизонт времени рассматриваемого процесса,  $t$  – текущее время,  $J(t)$  – интегральный показатель.

Использование приведенных выкладок и моделей для отдельных параметров, а также схемы, приведенной на рис. 2, позволило получить данные, приведенные на рис. 5.




Рис. 5. Расчеты температуры теплообменника и обогреваемого помещения, полученные на модели, в сравнении с исходными данными

Из графика видно, что в большинстве случаев, если учитывать инертность протекающего процесса, то для поддержания заданного уровня температуры в помещении достаточно меньшей температуры нагрева. В среднем на рассматриваемом участке интегральный нагрев теплоносителя мог быть осуществлен на  $23\ 213,13\text{ }^{\circ}\text{C}$  меньше, что при среднем объемном расходе в  $5\ \text{м}^3/\text{ч} = 0,08\ \text{м}^3/\text{мин}$  системы теплоснабжения дает  $23\ 213,13 \cdot 0,08 \cdot 0,0001 = 0,1857$  Гкал экономии за 12 суток. При цене  $1319,13$  руб./Гкал (минимальная цена за Гкал для населения) [18] экономия составит 245 рублей. В течение 7 месяцев отопительного сезона это обеспечивает 3500 рублей экономии без учета повышения тарифов, а также, что более важно, стабильную температуру в помещении.

При рассмотрении диапазона в 10 лет при сохранении текущей динамики повышения тарифов это уже может составить до 115 тыс. рублей для одного объекта. Если рассмотреть экономию в масштабах небольшого города (количество зданий до 1000 штук), то это уже составит

115 млн. рублей. При этом первый участок графика (см. рис. 5), дающий худшие результаты, является участком адаптации системы и при непрерывном управлении не будет повторяться, а значит, и оказывать отрицательное влияние на систему управления, что повысит экономический эффект использования предиктивных методов управления, и это при том, что приведенные цифры получены при управлении уже автоматизированными ИТП [19].

**Выводы.** Использование данных прогнозов в задачах управления открывает новые возможности исследования инертных процессов, протекающих в технических системах, позволяет учитывать различные значения запаздывания реакции для различных параметров и тем самым повышать согласованность функционирования элементов системы и качество управления (в рассмотренном случае энергоэффективность [20]).

*Работа выполнена при финансовой поддержке правительства Пермского края, проект № С-26/058.*

### **Библиографический список**

1. Kiam Heong Ang, Chong G., Yun Li. PID control system analysis, design, and technology // IEEE Transactions on Control Systems Technology. – 2005. – Vol. 13. – № 4. – С. 559–576.
2. Shi Z. Knowledge-based decision support system // Journal of Computer Science and Technology. – 1987. – Vol. 2. – № 1. – С. 22–29.
3. Model Predictive Control applied for building thermal control / G. Neculoiu, V. Dache, G. Stamatescu, V. Sgarciu // Proceedings of Int Aegean Conference on Electrical Machines and Power Electronics (ACEMP); Int Conference on Optimization of Electrical and Electronic Equipment (OPTIM); Int Symposium on Advanced Electromechanical Motion Systems (ELECTROMOTION). – 2015. – P. 363–368.
4. Paprotny A., Thess M. Realtime data mining: self-learning techniques for recommendation engines. – 2013.
5. Кычкин А.В. Программно-аппаратное обеспечение сетевого энергоучетного комплекса // Датчики и системы. – 2016. – № 7. – С. 24–30.
6. Петрова И.Ю., Зарипова В.М., Лежнина Ю.А. Проектирование информационно-измерительных и управляющих систем для интеллектуальных зданий. Направления дальнейшего развития // Вестник МГСУ. – 2015. – № 12. – С. 147–157.

7. Интеллектуальный анализ данных в управлении производственными системами (подходы и методы) / Л.А. Мыльников, Б. Краузе, М. Кютц, К. Баде, И.А. Шмидт. – М.: БИБЛИО-ГЛОБУС, 2017. – 334 с.

8. Мыльников Л.А., Селедкова А.Б. Способ выбора метода прогнозирования и горизонта планирования параметров с использованием оценки риска // Информационные технологии. – 2018. – Т. 24. – № 2. – С. 97–103.

9. Садовникова Н.А., Шмойлова Р.А. Анализ временных рядов и прогнозирование. – М.: Издательский дом университета «Синергия», 2016. – 152 с.

10. Wickham H.R, Grolemund G. For data science: import, tidy, transform, visualize, and model data. – Sebastopol, CA: O'Reilly, 2016. – 492 p.

11. Witten I.H., Frank E. Data mining: practical machine learning tools and techniques. – Amsterdam ; Boston, MA: Morgan Kaufman, 2005. – 525 p.

12. A new electricity price prediction strategy using mutual information-based SVM-RFE classification / Z. Shao, S. Yang, F. Gao, K. Zhou, P. Lin // Renewable and Sustainable Energy Reviews. – 2017. – Vol. 70. – P. 330–341.

13. Ougiaroglou S., Diamantaras K.I., Evangelidis G. Exploring the effect of data reduction on Neural Network and Support Vector Machine classification // Neurocomputing. – 2018. – Vol. 280. – P. 101–110.

14. A primer on partial least squares structural equation modeling (PLS-SEM) / red. J.F. Hair. – Los Angeles: Sage, 2017.

15. Woody N.A., Brown S.D. Partial least-squares modeling of continuous nodes in Bayesian networks // Analytica Chimica Acta. – 2003. – Vol. 490. – № 1–2. – P. 355–363.

16. Strong rules for discarding predictors in lasso-type problems: Strong Rules for Discarding Predictors / R. Tibshirani, J. Bien, J. Friedman, T. Hastie, N. Simon, J. Taylor, R.J. Tibshirani // Journal of the Royal Statistical Society: Series B (Statistical Methodology). – 2012. – Vol. 74. – № 2. – P. 245–266.

17. Hoerl A.E., Kennard R.W. Ridge Regression: Biased Estimation for Nonorthogonal Problems // Technometric. – 1970. – Vol. 12. – № 1. – P. 55.

18. Постановление Региональной службы по тарифам Пермского края от 20.12.2017 № 300-т. Доступ из справ.-правовой системы КонсультантПлюс.

19. Wicaksono D., Firmansyah E., Nugroho H.A. A Microclimate Closed House Control Design for Broiler Strain // Proceedings of 7th International Annual Engineering Seminar (InAES). – 2017. – P. 11–16.

20. Кычкин А.В., Мусихина К.Г., Разепина М.Г. Исследование эффективности создания и внедрения системы энергоменеджмента на промышленном предприятии // Вестник Пермского национального исследовательского политехнического университета. Электротехника, информационные технологии, системы управления. – 2014. – № 1(9). – С. 66–79.

### References

1. Kiam Heong Ang, Chong G., Yun Li. PID control system analysis, design, and technology. *IEEE Transactions on Control Systems Technology*, 2005, vol. 13, no. 4, pp. 559-576.

2. Shi Z. Knowledge-based decision support system. *Journal of Computer Science and Technology*, 1987, vol. 2, no. 1, pp. 22-29.

3. Neculoiu G., Dache V., Stamatescu G., Sgarciu V. Model Predictive Control applied for building thermal control. *Proceedings of Int Aegean Conference on Electrical Machines and Power Electronics (ACEMP); Int Conference on Optimization of Electrical and Electronic Equipment (OPTIM); Int Symposium on Advanced Electromechanical Motion Systems (ELECTRO-MOTION)*, 2015, pp. 363-368.

4. Paprotny A., Thess M. Realtime data mining: self-learning techniques for recommendation engines, 2013.

5. Kychkin A.V. Programmno-apparatnoe obespechenie setevogo energouchetnogo kompleksa [Software and hardware of the network energy-accounting complex]. *Datchiki i sistemy*, 2016, no. 7, pp. 24-30.

6. Petrova I.Iu., Zaripova V.M., Lezhnina Iu.A. Proektirovanie informatsionnoizmeritel'nykh i upravliaiushchikh sistem dlia intellektual'nykh zdanii. Napravleniia dal'neishego razvitiia [Design of information-measuring and control systems for smart houses. Directions for further development] *Vestnik Moskovskogo gosudarstvennogo stroitel'nogo universiteta*, 2015, no 12, pp. 147-157.

7. Myl'nikov L.A., Krauze B., Kiutts M., Bade K., Shmidt I.A. Intellektual'nyi analiz dannykh v upravlenii proizvodstvennymi sistemami (podkhody i metody) [Intelligent data analysis in the management of production systems (approaches and methods)]. Moscow: Biblio-Globus, 2017. 334 p.

8. Myl'nikov L.A., Seledkova A.B. sposob vybora metoda prognozirovaniia i gorizonta planirovaniia parametrov s ispol'zovaniem otsenki riska [Method for choosing the prediction method and the planning horizon using a risk assessment]. *Informatsionnye tekhnologii*, 2018, vol. 24, no. 2, pp. 97-103.

9. Sadovnikova N.A., Shmoilova R.A. Analiz vremennykh riadov i prognozirovanie. Moscow: Izdatel'skii dom universiteta "Sinergii", 2016. 152 p.
10. Wickham H.R, Grolemund G. For data science: import, tidy, transform, visualize, and model data. Sebastopol, CA: O'Reilly, 2016. 492 p.
11. Witten I.H., Frank E. Data mining: practical machine learning tools and techniques. Amsterdam ; Boston, MA: Morgan Kaufman, 2005. 525 p.
12. Shao Z., Yang S., Gao F., Zhou K., Lin P. A new electricity price prediction strategy using mutual information-based SVM-RFE classification. *Renewable and Sustainable Energy Reviews*, 2017, vol. 70, pp. 330-341.
13. Ougiaroglou S., Diamantaras K.I., Evangelidis G. Exploring the effect of data reduction on Neural Network and Support Vector Machine classification. *Neurocomputing*, 2018, vol. 280, pp. 101-110.
14. A primer on partial least squares structural equation modeling (PLS-SEM). Ed. J.F. Hair. Los Angeles: Sage, 2017.
15. Woody N.A., Brown S.D. Partial least-squares modeling of continuous nodes in Bayesian networks. *Analytica Chimica Acta*, 2003, vol. 490, no. 1-2, pp. 355-363.
16. Tibshirani R., Bien J., Friedman J., Hastie T., Simon N., Taylor J., Tibshirani R.J. Strong rules for discarding predictors in lasso-type problems: Strong Rules for Discarding Predictors. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 2012, vol. 74, no. 2, pp. 245-266.
17. Hoerl A.E., Kennard R.W. Ridge Regression: Biased Estimation for Nonorthogonal Problems. *Technometric*, 1970, vol. 12, no 1, P. 55.
18. Postanovlenie Regional'noi sluzhby po tarifam Permskogo kraia ot 20.12.2017 No. 300-t. [Decree of the Regional Tariff Service of the Perm Krai of December 20, 2017 No. 300-t]. Dostup iz spravochno-pravovoi sistemy Konsul'tantPlius.
19. Wicaksono D., Firmansyah E., Nugroho H.A. A Microclimate Closed House Control Design for Broiler Strain. *Proceedings of 7th International Annual Engineering Seminar (InAES)*, 2017, pp. 11-16.
20. Kychkin A.V., Musikhina K.G., Razepina M.G. Issledovanie effektivnosti sozdaniia i vnedreniia sistemy energomenedzhmenta na promyshlennom predpriatii [Analyzis of the effectivity of the creation and implementation of the energy management system in an industrial enterprise]. *Vestnik Permskogo natsional'nogo issledovatel'skogo politekhnicheskogo universiteta. Elektrotekhnika, informatsionnye tekhnologii, sistemy upravleniia*, 2014, no. 1(9), pp. 66-79.

### Сведения об авторах

**Мыльников Леонид Александрович** (Пермь, Россия) – кандидат технических наук, доцент кафедры «Микропроцессорные средства автоматизации» Пермского национального исследовательского политехнического университета (614990, Пермь, Комсомольский пр., 29, e-mail: leonid.mylnikov@pstu.ru).

**Гергель Наталья Александровна** (Пермь, Россия) – магистрант кафедры «Микропроцессорные средства автоматизации» Пермского национального исследовательского политехнического университета (614990, Пермь, Комсомольский пр., 29, e-mail: natalia\_gergel@mail.ru).

**Кычкин Алексей Владимирович** (Пермь, Россия) – кандидат технических наук, доцент кафедры «Микропроцессорные средства автоматизации» Пермского национального исследовательского политехнического университета (614990, Пермь, Комсомольский пр., 29, e-mail: aleksey.kychkin@gmail.com).

**Краузе Бернд** (Кётен, Германия) – доктор, профессор факультета информатики и языков Университета прикладных наук г. Анхальта (06366, Кётен, ул. Ломанштрассе 23, e-mail: bernd.krause@hs-anhalt.de).

### About the authors

**Mylnikov Leonid Aleksandrovich** (Perm, Russian Federation) is a Ph.D. in Technical Science, Associated Professor of Microprocessor Automation Means Department Perm National Research Polytechnic University (614990, Perm, 29, Komsomolsky pr., e-mail: leonid.mylnikov@pstu.ru).

**Gergel Natalia Aleksandrovna** (Perm, Russian Federation) is a Master Student at Microprocessor Automation Means Department Perm National Research Polytechnic University (614990, Perm, 29, Komsomolsky pr., e-mail: natalia\_gergel@mail.ru).

**Kychkin Aleksey Vladimirovich** (Perm, Russian Federation) is a Ph.D. in Technical Science, Associated Professor of Microprocessor Automation Means Department Perm National Research Polytechnic University (614990, Perm, 29, Komsomolsky pr., e-mail: aleksey.kychkin@gmail.com).

**Krause Bernd** (Koethen, Germany) – doctor of mathematic, faculty of Computer Science and Languages at Anhalt University of Applied Sciences (06366, Koethen, Lohmannstrasse 23, e-mail: bernd.krause@hs-anhalt.de).

Получено 25.04.2018