

Инженерное оборудование зданий и сооружений

УДК 697.34

DOI: 10.14529/build170307

НЕЙРОСЕТЕВЫЕ АЛГОРИТМЫ ДЛЯ РЕШЕНИЯ ЗАДАЧИ КРАТКОСРОЧНОГО ЛОКАЛЬНОГО ПРОГНОЗИРОВАНИЯ ТЕМПЕРАТУРЫ НАРУЖНОГО ВОЗДУХА

А.А. Февралев¹, Ю.С. Приходько², Д.М. Бабайлова²

¹ ЗАО «РИДАН», г. Челябинск

² Южно-Уральский государственный университет, г. Челябинск

В процессе решения задачи повышения эффективности автоматизации управления системой отопления разработана и оптимизирована адаптивная модель для краткосрочного локального прогнозирования температуры наружного воздуха. При работе данной модели и длительном прогнозировании высок риск возникновения и накопления ошибки. Для минимизации данных рисков разработан дополнительный адаптационный механизм с помощью нейросети, построенной по схеме персептрона Розенблата. В качестве способа обучения использован алгоритм обратного распространения ошибки как наилучший метод для постоянного улучшения и обучаемости сети с течением времени. На основании построенной модели проведены численные эксперименты по прогнозированию температуры в течение года. Проведен анализ и сравнение результатов, определено влияние различных характеристик нейросети на качество получаемого прогноза.

Ключевые слова: численное моделирование, прогнозирование локальной температуры, эффективность системы отопления, искусственная нейросеть.

Введение

Данная статья продолжает разработку алгоритма прогнозирования температуры наружного воздуха. В предыдущей статье [1] авторами рассматривалась возможность создания краткосрочного прогноза локальной температуры наружного воздуха, также были разработаны и опробованы основные методики прогнозирования. Эти методы были апробированы с помощью минимальных вычислений, которые производились с помощью программы Microsoft Excel. При проведении расчетов на больших объемах данных, потребовались дополнительные адаптационные механизмы. Авторами предложено использовать искусственную нейросеть – многоуровневый персептрон Розенблата, в качестве алгоритма обучения использовался метод обратного распространения ошибки.

С помощью построенной модели проведены численные исследования по погодным данным за несколько лет. Изучено влияние характеристик нейросети на получаемые результаты.

Методология прогнозирования, входные данные нейросети для осуществления прогноза

Алгоритм разрабатывался для локального прогнозирования температуры наружного воздуха [2]. Адаптивная модель изменения температуры

наружного воздуха построена на основании четырех исходных составляющих:

- статистика изменения температуры в данной местности за прошедшие несколько лет;
- прогноз погоды, учитывающий ежедневные процессы смены дня и ночи, влияние угла падения солнечных лучей и качество воспринимающей поверхности;
- тренд текущих изменений, определяемый по методике экспоненциального выравнивания;
- изменение локального атмосферного давления.

Для сравнения произведено моделирование при различных шагах прогнозирования (1 и 3 часа) и использованы различные характеристики нейросети (количество слоёв, количество нейронов на каждом слое, коэффициент обучаемости).

Описание нейросети, расчетный алгоритм, метод обратного распространения ошибки

Математическая модель для прогнозирования погодных условий разработана на основе нейронной сети. Искусственная нейронная сеть (ИНС) – математическая модель, а также её программное или аппаратное воплощение, построенная по принципу организации и функционирования биологических нейронных сетей, т. е. сетей нервных клеток живого организма.

Нейронные сети не программируются в привычном смысле этого слова, они обучаются. Возможность обучения – одно из главных преимуществ нейронных сетей перед традиционными алгоритмами. Технически обучение заключается в нахождении коэффициентов связей между нейронами. В процессе обучения нейронная сеть способна выявлять сложные зависимости между входными и выходными данными, а также выполнять обобщение [3].

Каждый нейрон состоит из двух типов элементов: тела нейрона и дендритов. Тело нейрона реализует нелинейную функцию (функцию активации нейрона). Дендриты принимают входные сигналы и модифицируют их посредством весовых коэффициентов, схема взаимодействия на рис. 1.

Функция активации может иметь различный вид. Чаще всего используется логистическая функция или функция S-образного вида (сигмоид). В данном случае:

$$y = \frac{1 - e^{-x}}{1 + e^{-x}}. \quad (1)$$

Состояние нейрона определяется суммой состояний его синапсов: значение на входе каждого синапса умножается на его вес, после чего суммируется с остальными произведениями. Значение на выходе нейрона – это функция от его состояния.

$$y_{K(j)} = \sum_{i=1 \dots n} W_{K(i)(j)} \cdot X_{(i)}, \quad (2)$$

где $j = 1 \dots m$, m – количество входных импульсов; $i = 1 \dots n$, n – количество нейронов на каждом слое; $K = 1 \dots p$, p – количество слоев.

Для обучения нейронной сети необходимо располагать обучающими данными. Обучение – это последовательность итераций, в ходе которой подбираются весовые коэффициенты нейронов на основе сопоставления динамики входных данных и существующих алгоритмических цепей нейросети с последующей корректировкой последних. Так как температурные данные поступают с каждым следующим шагом, наилучшей эффективностью в качестве способа обучения нейросети будет обла-

дать метод обратного распространения ошибки.

При обучении происходит изменение весовых коэффициентов. На следующем шаге алгоритма действительный выходной сигнал сети сравнивается с желаемым выходным сигналом, а именно – реальной температурой наружного воздуха. Разница между этими двумя сигналами называется ошибкой δ выходного слоя сети. Далее данная ошибка распространяется через сеть в обратном порядке. Весовые коэффициенты W_{ij} , используемые для обратного распространения ошибки, равны тем же коэффициентам, что использовались во время вычисления выходного сигнала, изменяется только направление потока данных (сигналы передаются от выхода ко входу). Этот процесс повторяется для всех слоёв сети. Если ошибка пришла от нескольких нейронов – она суммируется. Ошибка сети:

$$\delta_{(K-1)(j)} = \sum_{i=1 \dots n} W_{(K-1)K(j)(i)} \cdot \delta_{K(i)}, \quad (3)$$

где $j = 1 \dots m$, m – количество входных импульсов; $i = 1 \dots n$, n – количество нейронов на каждом слое; $K = 1 \dots p$, p – количество слоев.

Корректировка весовых коэффициентов производится следующим образом:

$$W'_{(K-1)K(i)(j)} = W_{(K-1)K(i)(j)} + \eta \delta_{K(j)} \frac{df(e)}{d(e)} y_{(K-1)(i)}. \quad (4)$$

В формуле (4) $df(e)/d(e)$ является производной от функции активации нейрона, чьи весовые коэффициенты корректируются. Для применения метода обратного распространения ошибки передаточная функция нейронов должна быть дифференцируема. По своей сути метод является модификацией классического метода градиентного спуска.

Полученные результаты, анализ (различные варианты в зависимости от параметров нейросети)

Построение нейросети – сложный многоуровневый процесс. При хаотически изменяющихся входных данных, динамика обучения не поддается математическому анализу. В ходе исследования

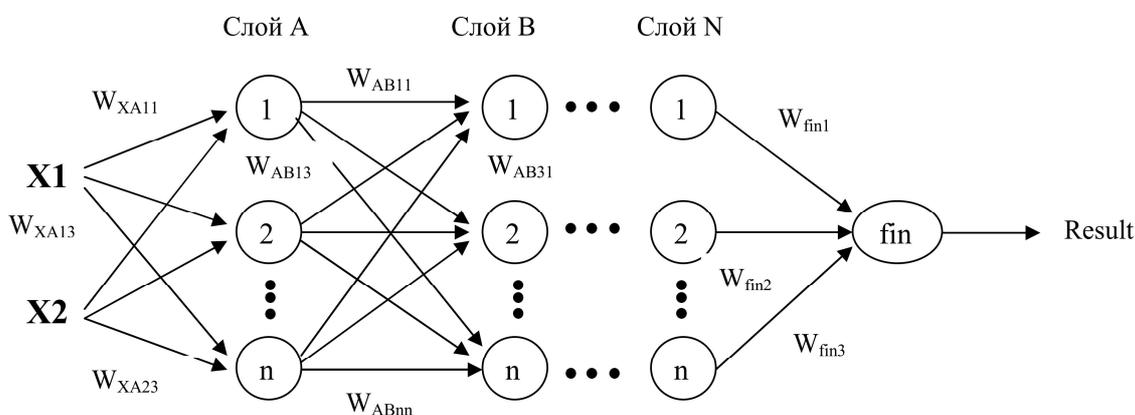


Рис. 1. Принципиальная схема используемой нейросети

Инженерное оборудование зданий и сооружений

было проведено множество экспериментов с различными расчётными характеристиками:

- шаг прогнозирования (Δt);
- количество слоёв сети (X_n);
- количества нейронов в каждом слое (NN);
- коэффициент, влияющий на скорость обучения сети (η).

Все численные эксперименты проводились на основании статистических погодных данных в г. Челябинске [5]. Оптимальные прогнозы даются в интервале X_n NN = 150–300. С увеличением количества слоёв точность прогноза нейросети повышается лучше, чем с увеличением количества нейронов.

Анализ данных не позволяет выявить устойчивой зависимости обучаемости сети от сочетания NN и N_u за исключением того факта, что существуют некоторые области, вблизи которых прогнозы более точны. Такие области находятся экспериментально, путём сравнения рядов модулей отклонений и частоты проявления минимальных отклонений, выбранных для нескольких нейросетей на одном временном промежутке с одинаковым шагом прогнозирования [6, 7].

В ходе анализа было выявлено, что точность нейросетей с шагом прогнозирования 1 час, имеющих в своей структуре семь слоёв, близка к точности нейросетей, имеющих в своей структуре шесть слоёв, вплоть до сотых долей. Дальнейшее увеличение количества слоёв нецелесообразно, так как ведёт к усложнению кода программы, увеличению объёма используемой операционной памяти и увеличению времени исполнения программы.

На рис. 2 изображены температурные кривые, характеризующие реальную температуру и температурные графики прогноза, данного нейросетью ХАВСDEF NN = 36, $\eta = 0,2$ (шестислойная, содержит

36 нейронов на каждом слое, коэффициент обучаемости $\eta = 0,2$) при шаге прогнозирования 1 и 3 часа.

В жилищном секторе допустимы колебания температуры ± 2 °С. Чем реже результат прогнозирования отклоняется от реального значения температуры, тем надёжнее прогнозирование и стабильнее работа нейросети.

Для оценки способностей сети к обучению оценено среднее количество отклонений для различных функций на ± 2 °С из каждого последующего периода прогнозов одинаковой длительности. Таким образом, рис. 3 показывает, какая доля прогнозов из каждой сотни разошлась с действительной температурой более чем на 2 градуса.

Из рис. 3 видно, что в начале обучения нейросеть с шагом прогнозирования 1 час отклоняется от реальной температуры сильнее, чем на ± 2 °С, в 5–10 % случаев, а нейросеть с шагом прогнозирования 3 часа отклоняется от реальной температуры сильнее, чем на ± 2 °С, в 40–50 % случаев.

Если посмотреть долю отклонений для нейросети с шагом прогнозирования 1 час после 7000 итераций, то можно заметить, что общая доля отклонений прогноза от реальной температуры сильнее, чем на ± 2 °С, снизилась с 5–10 % случаев до 1–7 % случаев. Аналогично, доля отклонений прогноза от реальной температуры сильнее, чем на ± 2 °С, для нейросети с шагом прогнозирования 3 часа после 7000 итераций снизилась с 40–55 % случаев до 25–40 % случаев. Подробнее на рис. 4.

Способности нейросети к обучению видны также при рассмотрении модуля отклонения на первых 100 итерациях и последних 100 итерациях, что видно на рис. 5.

Для сравнения рассмотрим для одного временного участка результаты прогнозов различных нейросетей с шагом прогнозирования 1 час (рис. 6).

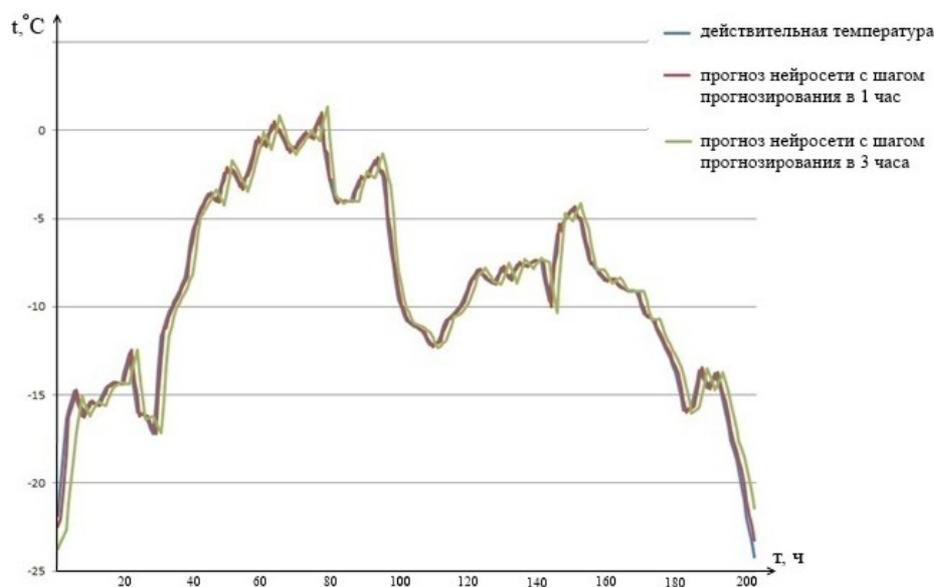


Рис. 2. Отклонения сетей с разным шагом прогнозирования

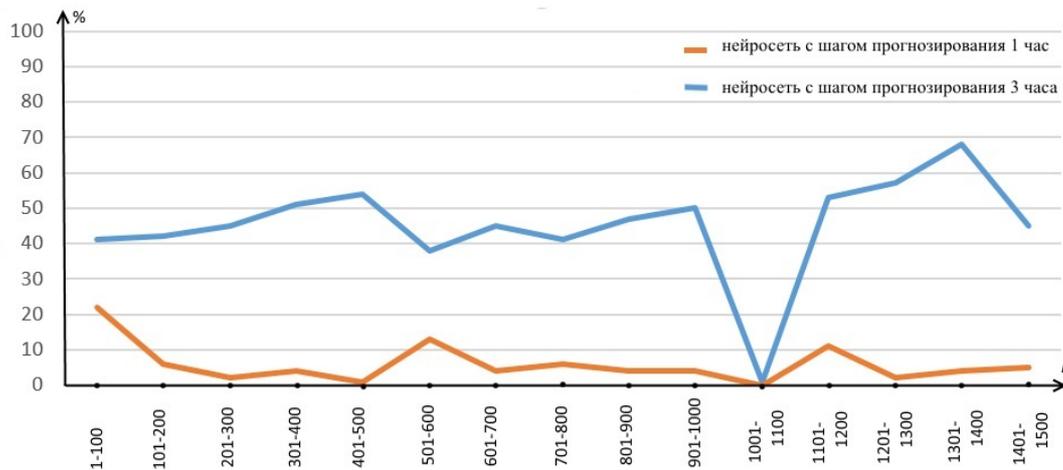


Рис. 3. Частота превышения допустимого отклонения

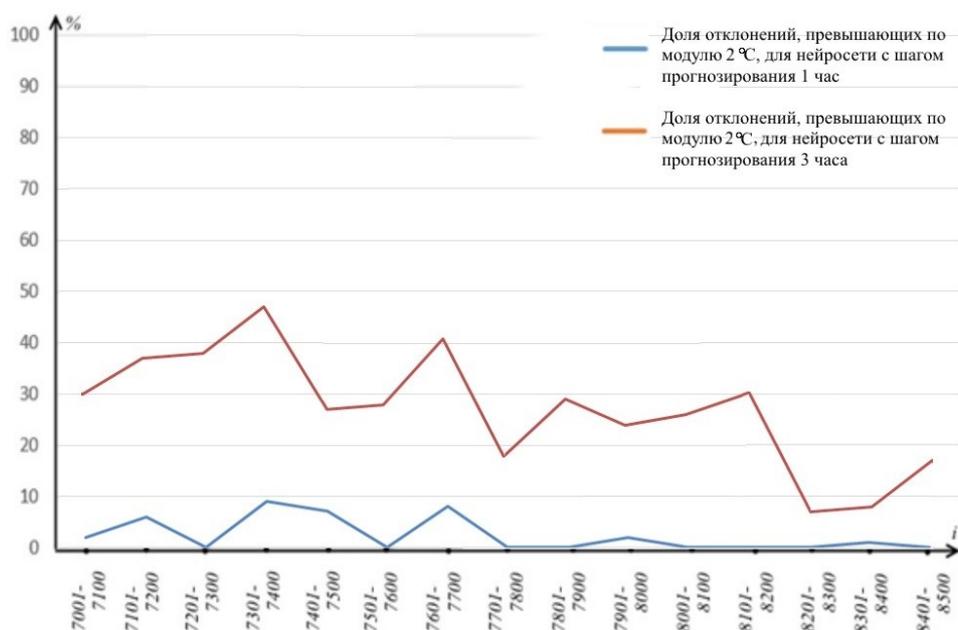


Рис. 4. Частота превышения допустимого отклонения сети с шагом прогнозирования 1 час и 3 часа после 7000 итераций обучения

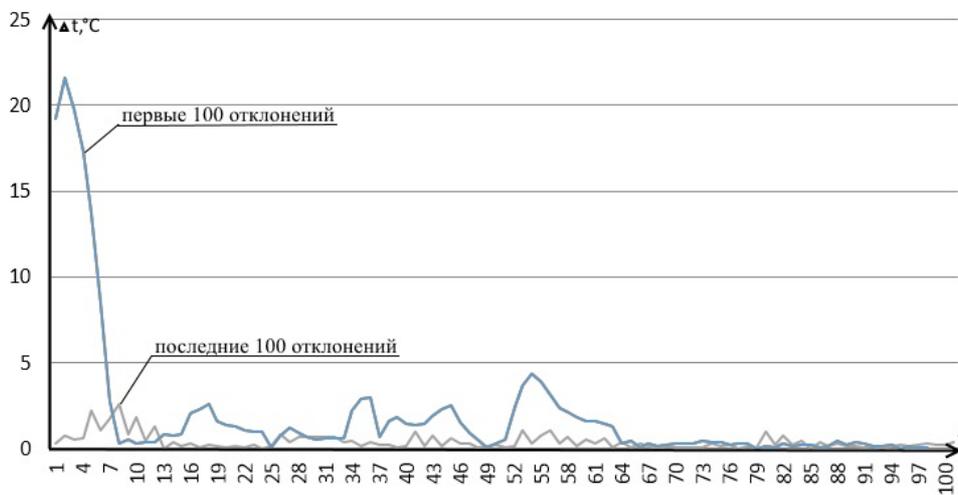


Рис. 5. Модуль отклонения нейросети в начале и конце обучения

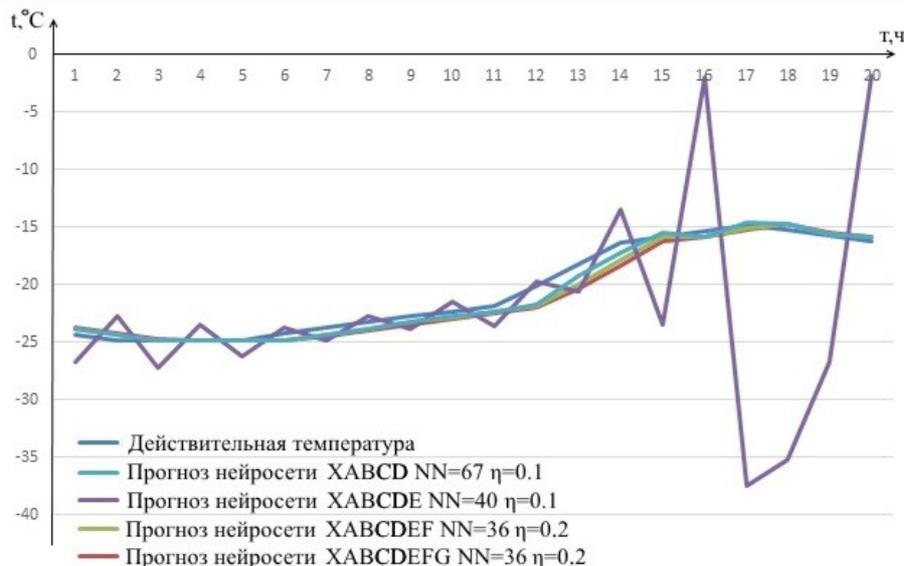


Рис. 6. Отклонения различных нейросетей

Как видно из графика, наиболее близки к действительной температуре нейросети с шестью рядами нейронов и с четырьмя, они обеспечивают модуль отклонения от действительной температуры меньше 2 градусов. При этом сеть с шестью рядами более стабильна.

Заключение

Разработанная модель может быть использована для превентивного управления системами отопления, т. е. регулирование с учетом будущих изменений температуры, что позволит снизить или даже полностью исключить эффект перетопа при резком потеплении, а также минимизирует колебания температуры внутреннего воздуха. В конечном итоге это приведет к дополнительной экономии и повысит эффективность потребления теплоты потребителем.

Модель также может быть использована для прогнозирования погоды в местах с жарким климатом и использоваться при регулировании системами холодоснабжения по аналогичному принципу.

Использование искусственных нейросетей позволило добиться самообучаемости модели, что привело к получению стабильных результатов при выполнении большого количества прогнозов, например, при прогнозе с шагом 1 час в течение всего года, средняя величина ошибки менее 0,5 градусов. Данные алгоритмы можно использо-

вать для построения принципиально новых методик регулирования отпуском теплоты системами жизнеобеспечения здания.

Литература

1. Февралев, А.А. Краткосрочное локальное прогнозирование погоды при решении задачи повышения эффективности системы отопления / А.А. Февралев, Ю.С. Приходько // Вестник ЮУрГУ. Серия «Строительство и архитектура». – 2016. – Т. 16, № 2. – С. 48–52.
2. Русин, И.Н. Сверхкраткосрочные прогнозы погоды / И.Н. Русин, Г.Г. Тараканов. – СПб.: Изд-во РГГМИ, 1996. – 308 с.
3. Principles of training multi-layer neural network using back propagation [Принципы обучения многослойной нейросети с помощью обратного распространения ошибки]. – http://galaxy.agh.edu.pl/~vlsi/AI/backp_t_en/backprop.html
4. Хайкин, С. Нейронные сети: полный курс: пер. с англ. / С. Хайкин. – 2-е изд. – М.: Издат. дом «Вильямс», 2006. – 1104 с.
5. Архив погоды в г. Челябинске. – <http://rp5.ru>
6. Лукашин, Ю.П. Адаптивные методы краткосрочного прогнозирования временных рядов: учебное пособие / Ю.П. Лукашин. – М.: Финансы и статистика, 2003. – 416 с.
7. Бокс, Дж. Анализ временных рядов, прогноз и управление / Дж. Бокс, Г.М. Дженкинс. – М.: Мир, 1974. – 406 с.

Февралев Алексей Андреевич, руководитель специальных проектов, ЗАО «РИДАН» (Челябинск), группа компаний Данфосс, fevral25@mail.ru

Приходько Юрий Сергеевич, студент кафедры «Градостроительство, инженерные сети и системы», Южно-Уральский государственный университет (Челябинск), prihogiko@yandex.ru

Бабайлова Дарья Михайловна, студент кафедры «Градостроительство, инженерные сети и системы», Южно-Уральский государственный университет (Челябинск), bdm74@bk.ru

Поступила в редакцию 20 апреля 2017 г.

NEURAL NETWORK USAGE FOR SOLVING THE PROBLEM OF SHORT-TERM LOCAL FORECAST OF OUTDOOR TEMPERATURE

A.A. Fevraleev¹, fevral25@mail.ru

Yu.S. Prikhodko², npuxogiko@yandex.ru

D.M. Babaylova², bdm74@bk.ru

¹ RIDAN CJSC, Chelyabinsk, Russian Federation

² South Ural State University, Chelyabinsk, Russian Federation

To increase the efficiency of control automation of the heating system an adaptive model of short-term local forecast of outdoor temperature is designed and optimized. At the operation of the given model and long-term forecasting there is a high risk of occurrence and accumulation of an error. To avoid this negative effect a special adaptive mechanism of the model made by neural network is constructed in accordance with Rosenblatt perceptron scheme. As a learning method the back propagation algorithm is used as the best method for continual improvement and network learning capacity in length of time. Based on the constructed model many numerical experiments are carried out to predict the temperature during the year. The analysis and comparison of the results are performed, the influence of various characteristics of neural network on the quality of the received forecast is determined.

Keywords: numerical modeling, local temperature forecast, efficiency of the heating system, artificial neural network.

References

1. Fevraleev A.A., Prikhod'ko Yu.S. [Short-Term Local Weather Forecast in Case of Solving a Problem of Increasing the Efficiency of Heating System]. *Bulletin of South Ural State University. Ser. Construction Engineering and Architecture*, 2016, vol. 16, no. 2, pp. 48–52 (in Russ.).
2. Rusin I.N., Tarakanov G.G., *Sverkhkratkosrochnye prognozy pogody* [Ultra-Short-Term Weather Forecasts]. St. Petersburg, RGGMI Publ., 1996. 308 p.
3. Printsipy obucheniya mnogosloynoy neyroseti s pomoshch'yu obratnogo rasprostraneniya oshibki [Principles of Training Multi-Layer Neural Network Using Backpropagation]. Available at: http://galaxy.agh.edu.pl/~vlsi/AI/backp_t_en/backprop.html
4. Khaykin Saymon. *Neyronnye seti: polnyy kurs* [Neural Networks: a full course]. Moscow, Izdatel'skiy dom «Vil'yams» Publ., 2006. 1104 p.
5. Arkhiv pogody v g. Chelyabinske [Weather Data Archive in Chelyabinsk]. Available at: <http://rp5.ru>
6. Lukashin Yu. P. *Adaptivnye metody kratkosrochnogo prognozirovaniya vremennykh ryadov: Uchebnoe posobie* [Adaptive Methods for Short Time Series Forecasting: Study Guide]. Moscow, Finansy i statistika Publ., 2003. 416 p.
7. Boks Dzh., Dzenkins G.M. *Analiz vremennykh ryadov, prognoz i upravlenie* [Time series analysis, forecast and management]. Moscow, Mir Publ., 1974. 406 s.

Received 20 April 2017

ОБРАЗЕЦ ЦИТИРОВАНИЯ

Февралев, А.А. Нейросетевые алгоритмы для решения задачи краткосрочного локального прогнозирования температуры наружного воздуха / А.А. Февралев, Ю.С. Приходько, Д.М. Бабайлова // Вестник ЮУрГУ. Серия «Строительство и архитектура». – 2017. – Т. 17, № 3. – С. 48–53. DOI: 10.14529/build170307

FOR CITATION

Fevraleev A.A., Prikhodko Yu.S., Babaylova D.M. Neural Network Usage for Solving the Problem of Short-Term Local Forecast of Outdoor Temperature. *Bulletin of the South Ural State University. Ser. Construction Engineering and Architecture*. 2017, vol. 17, no. 3, pp. 48–53. (in Russ.). DOI: 10.14529/build170307