Технология и организация строительства

УДК 658.5:624.05

DOI 10.23968/1999-5571-2020-17-3-127-133

© С. А. Болотин, д-р техн. наук, профессор

© Хошнав Юсиф Бабакар Хуссейн, аспирант

© Бохан Хайтам, аспирант

(Санкт-Петербургский государственный
архитектурно-строительный университет,
Санкт-Петербург, Россия)

E-mail: sbolotin@mail.ru, yousif.babakr@gmail.com,
haitham_kh9@yahoo.com

© S. A. Bolotin, Dr. Sci. Tech., Professor

© Khoshnaw Yousif Babakr Hussein, post-graduate student

© Bohan Haitham, post-graduate student

(Saint Petersburg State University
of Architecture and Civil Engineering,
St. Petersburg, Russia)

E-mail: sbolotin@mail.ru, yousif.babakr@gmail.com,
haitham_kh9@yahoo.com

РЕГРЕССИОННАЯ ОЦЕНКА НОРМ ЗАТРАТ ТРУДА НА ОСНОВЕ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ

REGRESSION ASSESSMENT OF LABOR COST STANDARDS BASED ON NEURAL NETWORK SIMULATION

Календарное планирование строительства базируется на данных по продолжительностям выполнения работ, которые непосредственным образом связаны со значениями трудовых затрат. Это обеспечивает получение наиболее точных результатов календарного планирования, реализуемого как на этапе строительного проектирования, так и в процессе его оперативного управления. В РФ и в других ведущих зарубежных странах для строительства разработаны базы данных по нормируемым затратам труда. Однако многие развивающиеся страны, например, Республика Ирак, не обеспечены собственными нормативами по трудовым затратам, а поэтому они вынуждены либо использовать нормативы других стран, либо определять продолжительности работ с помощью экспертных оценок, что приводит к существенной погрешности календарного планирования строительства. Для создания баз данных по нормативам трудовых затрат используются различные методы, которые основаны либо на хронометражных измерениях, либо на физиологических способах измерения антропологических параметров, связанных с энергетическими затратами рабочих. Поскольку использование этих подходов требует существенных затрат и времени, то в качестве приемлемой альтернативы предлагается методика, основанная на сборе статистических данных, входящих в исполнительную документацию по строительству, экспертных данных, определяющих выполнимость нормативных условий выполнения работ, и регрессионной обработке итоговых результатов, основанной на использовании возможностей моделирования искусственных нейронных сетей.

Ключевые слова: календарное планирование строительства, оперативное управление строительством, исполнительная документация в строительстве, трудовые затраты, моделирование нейронных сетей.

Construction scheduling is based on data on the duration of works, which are directly related to the values of labor costs. This ensures obtaining of the most accurate results of scheduling implemented both at the stage of construction design and in the process of its operational management. In the Russian Federation and in other leading foreign countries, there have been developed databases for standardized labor costs in the field of construction. However, many developing countries, for example, the Republic of Iraq, are not provided with their own standards for labor costs, and therefore, they are forced to use either the standards of other countries or determine the duration of work with the help of expert estimates, which leads to a significant error in the construction planning schedule. To create databases on labor standards, various methods are used that are either based on timing measurements, or on physiological methods for measuring anthropological parameters associated with the energy costs of workers. Since the use of these approaches requires significant costs and time, a technique is proposed as an acceptable alternative. This technique is based on the collection of statistical data included in the executive documentation for construction, expert data that determine the feasibility of regulatory conditions for the performance of work, and regression processing of the final results based on the use of modeling capabilities of artificial neural networks.

Keywords: construction scheduling, operational management of construction, executive documentation in construction, labor costs, neural network simulation.

Для эффективного управления строительным производством на основе календарного планирования используются нормативы трудовых затрат. Одним из подходов в создании соответствующих нормативных баз является хронометражный способ измерения трудовых затрат, который может быть реализован как на общих, так и на моментных наблюдениях. Продуктивным методом является и физиологический подход, обеспечивающий своеобразную объективность результатов измерений, которая обычно не свойственна остальным методам. Он заключается в том, что все устанавливаемые нормы труда формируются на основании личных физиологических затрат работника (количество потребляемого кислорода, средняя температура тела, сердечные показатели и т. п.). Именно по этой причине физиологический метод считается самым точным при формировании норм физического труда работников.

В любой стране, создавшей собственную базу данных по нормативам трудовых затрат, имеются соответствующие организации, выпускающие сборники этих материалов [1–3]. Так, в Великобритании это компании BCIS (сборник *Comprehensive Building Price Book* и др.) и Davis Langdon, an AECOM Company (сборники *Spon's Price Books*); в США — Compass International (сборник *Global Construction Costs Yearbook* и др.) и RSMeans (*Building Construction Cost Data Book* и др.); во Франции — Groupe Moniteur (сборник *Le coût des travaux de bâtiment* и др.) и т. д. В СССР нормы трудовых затрат создавались на основе данных, получаемых нормативно-исследовательскими станциями, в дальнейшем эти нормы директивно вводились государством в строительную отрасль. В РФ, являющейся правопреемницей СССР, нормы также вводятся государством, но в большинстве случаев они носят рекомендательный характер. В большинстве стран разработка стоимостных показателей и показателей трудозатрат — это отдельный вид коммерческой деятельности, а выпускаемые ими сборники цен применяются на добровольной основе [1].

Особый интерес представляют нормы RATU, созданные финской ассоциацией «Строительная индустрия», так как они выполнены в виде технологических карт на строительные рабо-

ты с детальным описанием проводимых операций и представляют собой картотеку системы стандартизации строительного производства [3]. Данные нормы содержат укрупненную и пооперационную информацию о затратах труда, рекомендуемом составе звена, необходимых документах и планах, требуемых материалах, машинах и оборудовании, технике безопасности, мероприятиях по обеспечению качества, а также особые инструкции и указания. Карты RATU носят производственно-технологический характер, а по мере развития техники и технологий картотека совершенствуется и устаревшие нормы заменяются новыми. Для сбора и пополнения исходных данных постоянно задействовано несколько десятков строительных компаний и стройплощадок. Участвующие в исследовании компании и стройплощадки находятся в различных районах Финляндии, и каждая норма вычисляется на основе данных, полученных не менее чем с 10 объектов, при этом погрешность нормы не превышает 10 %. В РФ нормы затрат труда также являются производственными и носят название «Единые нормы и расценки» (ЕНиР). Все нормы, вошедшие в ЕНиР и RATU, определяются нормальными условиями производства работ.

Представленный анализ показывает, что для создания базы данных по трудовым затратам требуется достаточно большое время и ресурсные затраты. Поэтому альтернативой имеющим место подходам может стать регрессионная оценка норм затрат труда. Регрессионная процедура, направленная на создание базы данных трудовых затрат, может быть осуществлена на основе использования статистики по реализованным строительным проектам, информация по которым отражена в соответствующей исполнительной документации и дополнена экспертными оценками условий, при которых получены фактические трудовые затраты. При реализации регрессионного подхода необходимо обосновать форму применяемой регрессионной процедуры. Для этого рассмотрим использование традиционного регрессионного анализа и более современного способа, основанного на моделировании нейронных сетей [4].

Первоначально метод множественного регрессионного анализа был ориентирован на описание линейных моделей. В дальнейшем же для

решения нелинейных задач либо применялась линеаризация параметров моделей, либо разрабатывался специфический алгоритм нелинейной регрессии [5]. В любом случае, для решения нелинейных задач посредством классического регрессионного анализа требовалась априорная информация о форме нелинейной связи между искомой функцией и входящими в нее аргументами.

Для использования метода нейросетевого моделирования не требуется информация, определяющая степень нелинейности поставленной задачи [6]. При сравнении этих альтернатив считается, что при статистическом подходе основное время решения задачи расходуется на анализ парных корреляций, а при нейросетевом моделировании основное время расходуется на обучение сетей [7]. В работе [8] Джеймс Маккаффри использует термин «регрессия нейронной сети» (neural network regression, NNR) и считает, что этот тип регрессии является самой мощной формой, обеспечивающей корректную реализацию регрессионной задачи. Но для его реализации требуется построение адекватной архитектуры нейронной сети.

В своей основе нейронные сети базируются на образе биологического нейрона с группой синапсов. Через каждый из синапсов данный нейрон соединяется с другими нейронами (x_i) через входные связи. Вес нейрона — величина, характеризующая каждый синапс, обозначается как w_i . Для каждого нейрона состояние определяется путем расчета взвешенной суммы его входов и рассчитывается по формуле

$$NET = \sum w_i x_i. \quad (1)$$

Нейрон имеет аксон, определяющий выходной сигнал, связывающий взвешенную сумму входных сигналов функцией активации, и этот сигнал поступает на синапсы следующих нейронов. В искусственных нейронных сетях используются различные функции активации [9, 10], среди которых логистическая функция активации является наиболее популярной [11]:

$$Y = \frac{1}{1 + \exp(-NET)}. \quad (2)$$

Представленная логистическая функция может быть использована для решения поставленной регрессионной задачи. В общем случае для построения адекватной нейронной сети необ-

ходимо использовать большое количество нейронов, которые образуют ее многослойность. Каждый слой искусственной нейронной сети представляет собой многообразие нейронов, непрерывно взаимодействующих между собой послойно и принимающих сигналы от других нейронов. Поскольку выбор архитектуры искусственной нейронной сети определяется конкретной задачей, то для данной задачи используется многослойная сеть прямого распространения, которая имеет название многослойный перцептрон. Так как на заданный вектор входных значений данная сеть вырабатывает единственную совокупность выходных значений, которые не зависят от ее предыдущего состояния, то ее принято считать статической. В монографии [11] дается рекомендация относительно равенства числа нейронов во входном слое числу входных параметров и дается рекомендация о достаточности использования трех скрытых слоев.

На рисунке представлен двухслойный перцептрон, у которого на вход подаются сигналы, имитирующие независимые переменные, а с выходного нейрона снимается сигнал, обеспечивающий аппроксимацию функциональной связи типа $Y(X_1, X_2, X_3, X_4)$.

На входы сети подаются сигналы, имитирующие условия обеспеченности выполнения работы X_i по трудовым ресурсам, машинам и механизмам, материалам, а также отклонение от нормы погодных условий, увеличивающее трудовые затраты. При этом значения перечисленных выше условий определяются на основе экспертных оценок, а значения трудовых затрат Y определяются на основе исполнительной документации, например по форме КС-2. Поскольку нейронные сети работают с числовыми данными, лежащими в разных диапазонах, то для всех переменных осуществляется их нормировка, приводящая все данные к единому диапазону от 0 до 1. Если обозначить нормируемый параметр входного значения обобщенной литерой L , то нормируемое значение будет рассчитываться по формуле

$$L_i = (X_i - \min X_i) / (\max X_i - \min X_i). \quad (3)$$

Нормировка входных и выходных данных осуществляется по всему обучающему массиву, пример которого представлен в табл. 1.

Двухслойный перцептрон-аппроксиматор $Y(X_1, X_2, X_3, X_4)$

В первых четырех строках табл. 1 показаны результаты ввода 10 вариантов данных, отражающих условия обеспеченности полученных трудовых затрат (фактических, ФТЗ). В последующих четырех строках показаны результаты расчета нормированных значений обеспечен-

ности нормативных условий. Чаще всего сложно ответить на вопрос, какое количество наблюдений необходимо для обучения сети. В общем обзоре по нейронным сетям¹ дается следующее

¹ URL: http://ru.wikipedia.org/wiki/Нейронная_сеть (дата обращения: 18.01.2020).

Таблица 1

Пример обучающего массива, состоящего из 10 вариантов данных

№ параметра	Величина	Номер варианта									
		1	2	3	4	5	6	7	8	9	10
1	Рабочие X_1 , %	60	70	50	60	65	70	75	70	75	90
2	Машины X_2 , %	65	50	75	90	65	70	75	70	85	80
3	Материалы X_3 , %	60	90	65	50	65	90	65	75	70	85
4	Погода X_4 , %	65	50	70	70	75	75	80	90	80	80
5	Нормирование X_1	0,25	0,50	0,00	0,25	0,38	0,50	0,63	0,50	0,63	1,00
6	Нормирование X_2	0,38	0,00	0,63	1,00	0,38	0,50	0,63	0,50	0,88	0,75
7	Нормирование X_3	0,25	1,00	0,38	0,00	0,38	1,00	0,38	0,63	0,50	0,88
8	Нормирование X_4	0,38	0,00	0,50	0,50	0,63	0,63	0,75	1,00	0,75	0,75
9	Y , чел. · см/м ³	0,35	0,32	0,45	0,39	0,38	0,26	0,34	0,33	0,3	0,26
10	Нормирование Y	0,47	0,32	1,00	0,68	0,63	0,00	0,42	0,37	0,21	0,00
11	Расчет выхода Y_1	0,57	0,22	0,88	0,74	0,49	0,17	0,28	0,45	0,25	0,09
12	Расчет выхода Y_2	0,48	0,30	0,95	0,71	0,45	0,08	0,32	0,46	0,29	0,08
13	Расчет выхода Y_3	0,42	0,27	0,92	0,68	0,46	0,09	0,37	0,46	0,21	0,09

эвристическое правило: количество наблюдений должно превышать связи в сети в 10 раз. Для наших целей, ввиду информационной сложности первичной задачи, решаемой на основе сбора большого числа статистических данных, обучающий массив определен десятью вариантами. Заметим, что это число вариантов удовлетворяет нижней границе репрезентативности данных, получаемых в процессе создания финских норм трудовых затрат RATU.

Значения ФТЗ, определяемые литерой Y, выполняют роль «учителя», с помощью которого подбираются весовые множители для всех нейронов принятой сети. Способность к обучению является фундаментальным свойством нейронной сети, а сам процесс обучения рассматривается как итерационный расчет весов сети, необходимых для решения заданной регрессионной задачи. На рисунке все рассчитанные весовые множители представлены тремя индексами: первый индекс определяет номер слоя сети, второй — номер нейрона в слое, третий — порядковый номер входа конкретного нейрона. В выходном слое, состоящем из единственного нейрона, соответствующие веса определены одним индексом.

По выходу сети, представленному множеством нормированных значений, осуществляется корректировка всех весовых множителей. Самый известный вариант алгоритма обучения нейронной сети называется алгоритмом обратного распространения ошибки (back propagation). В нем рассчитывают вектор градиента поверхности ошибок, определяющий направление кратчайшего спуска по поверхности из определенной точки. При модификации весов используется принцип коррекции по ошибке, а в качестве функции ошибок использована сумма квадратов ошибок.

Определенную трудность представляет вопрос, связанный с определением длины шага расчета, определяющей время расчета. В монографии [11] показана важность этого параметра, а для нахождения правильной скорости в сложных сетях применяются адаптивные алгоритмы динамического управления скоростью [12, 13]. Для задач, решаемых на основе статистики трудовых затрат, поверхности отклика могут иметь достаточно сложный характер, но без наличия разного рода сингулярностей. Анализ научных

данных показал, что длина шага должна определяться эмпирически, исходя из приемлемого времени обучения. Обучение сети заканчивается либо при достижении ошибкой некоторого уровня малости, либо при прекращении ее уменьшения, либо по прохождении определенного количества шагов. Иными словами, специалист может самостоятельно выбирать необходимое требование остановки.

Перейдем к показу конкретных результатов использования многослойного перцептрона, схема и параметры которого основаны на учтенных выше научно-практических рекомендациях. Представленные в табл. 1 исходные данные вводились в три вида нейронных сетей: однослойную, двухслойную и трехслойную сеть, которые в табл. 2 помечены соответствующими индексами.

Результаты расчета норм трудовых затрат для разных сетей оказались достаточно близкими, и их относительная погрешность оказалась менее 3 %. Вместе с этим расчет показал, что в качестве нормы трудовых затрат может быть принято значение 0,25 чел.-смен/м³, так как коэффициент парной корреляции для трехслойной сети составил наибольшее значение $\rho = 0,97$. Таким образом, на основе представленных в табл. 2 и других аналогичных экспериментальных данных, к использованию может быть рекомендован трехслойный перцептрон.

Общими характеристиками для моделирующих сетей являются: объем обучающей выборки, состоящий из 10 вариантов, шаг итерации, определяющий время расчета и принятый равным 0,2, и общее число итераций, равное 10 000. При этом время расчета, осуществленного в программе-макросе и реализованного в среде табличного процессора Excel на ноутбуке эконом-класса, составило менее 1 с.

Данные по тестированию сетей, связанные с оценкой погрешности воспроизводимости ре-

Таблица 2

Результаты расчета норм трудовых затрат

Число слоев	Значения ФТЗ Y	Коэффициент парной корреляции ρ
1	0,262	0,93
2	0,242	0,96
3	0,254	0,97

зультатов расчета, показали, что вариация значений составила менее 2 %, и этого вполне достаточно для определения норматива трудовых затрат. Как указано выше, требования к погрешности, установленные разработчиками финских норм трудовых затрат RATU, ограничены значением 10 %.

Намного большую погрешность в результат регрессионного определения норм трудовых затрат вносит погрешность определения процентов соответствия нормативным условиям осуществления трудового процесса. Например, если уменьшить все исходные данные оценки процентов соответствия нормативным условиям на 10 %, то примерно на эту же величину уменьшится рассчитанный норматив трудовых затрат. Из этого следует, что для получения более актуальных результатов при использовании предложенного метода необходимо его сочетание с такими методами экспертных оценок, применение которых обеспечивает расчет погрешностей [14].

В качестве вывода по представленной разработке приведем пошаговую методику регрессионного формирования нормы трудовых затрат.

1. Определяется множество строительных объектов, на которых имеется исполнительная документация по выбранному виду работы.

2. По исполнительной документации для выбранного вида работы определяются затраты труда, связанные с единичным объемом выполненных работ, что соответствует значениям фактических трудовых затрат.

3. По принятой шкале, которая должна быть единой для всего множества объектов, оценивается обеспеченность фактических условий выполнения работ.

4. С учетом нормировки формируется единый обучающий массив данных.

5. Далее обучающий массив обрабатывается в нейронной сети, сформированной на основе трехслойного перцептрона, и в результате получают данные по аппроксимации зависимости трудовых затрат от условий их получения.

6. Заключительная часть регрессионного воспроизведения нормы трудовых затрат связана с процедурой экстраполяции, которая учитывает полную (100 %-ную) обеспеченность выполнения условий организации трудового процесса.

Библиографический список

1. Болотин С. А., Котовская М. А. Анализ европейской и российской нормативных баз трудовых затрат применительно к календарному планированию строительства // Вестник гражданских инженеров. 2013. № 2 (37). С. 98–103.
2. Солин А. А. Анализ зарубежного опыта разработки и применения сборников цен на строительные работы // Строительство. Экономика и управление. 2011. № 1. С. 46–52.
3. Порошнева Л. Г. Финский опыт: кадры решают все! // Бюллетень национального объединения строителей. 2011. № 8 (15). С. 57–133. URL: http://сроамур.рф/doc/nostroy_bull/15.pdf (дата обращения: 30.10.2019).
4. Каллан Р. Основные концепции нейронных сетей / пер. с англ. А. Г. Сивака. М.: Вильямс, 2001. 287 с.
5. Draper N. R., Smith H. Applied Regression Analysis. 2nd ed. New York: John Wiley & Sons, 1981. 709 p.
6. Boussabaine A. H. The use of artificial neural networks in construction management // Construction Management and Economics. 1996. Vol. 14 (5). Pp. 427–436.
7. Ежов А. А., Шумский С. А. В чем различие нейронных сетей и статистики? // Нейрокомпьютинг и его применение в экономике и бизнесе. М.: МИФИ, 1998. 224 с. URL: <https://helpiks.org/3-10999.html> (дата обращения: 20.01.2020).
8. Маккаффри Дж. Тесты — Регрессия нейронной сети // MSDN. 2010. Т. 31, № 3. Март. URL: <https://docs.microsoft.com/ru-ru/archive/msdn-magazine/2016/march/test-run-neural-network-regression> (дата обращения: 15.01.2020).
9. Karpathy A., Fei-Fei Li. CS231n: Convolutional Neural Networks for Visual Recognition (Course Notes). 2019. URL: <http://cs231n.stanford.edu>, <http://cs231n.github.io> (дата обращения: 17.12.2019).
10. Милютин И. Функции активации нейросети: сигмоида, линейная, ступенчатая, ReLu, tahn. 29.11.2018. URL: <https://neurohive.io/ru/osnovy-data-science/activation-functions/> (дата обращения: 20.12.2019).
11. Patterson J., Gibson A. Deep Learning. A Practitioner's Approach. Sebastopol, CA: O'Reilly, 2017. 994 p.
12. Bengio Y. Practical Recommendation for Gradient-Based Training of Deep Architectures // In: Montavon G., Orr G. B., Müller K. R. (eds.). Neural Networks: Tricks of the Trade. Lecture Notes in Computer Science, vol. 7700. Springer, Berlin, Heidelberg. URL: <https://arxiv.org/abs/1206.5533> (дата обращения: 10.01.2020).
13. Duchi J., Hazan E., Singer Y. Adaptive Subgradient Methods for Online Learning and Stochastic

Optimization // Journal of Machine Learning Research. 2011. Vol. 12 (61). Pp. 2121–2159. URL: <http://jmlr.org/papers/v12/duchi11a.html> (дата обращения: 20.01.2020).

14. Болотин С. А., Дадар А. Х. Определение погрешности квалиметрической оценки весов аддитивных показателей качества календарных планов строительства // Изв. вузов. Строительство. 2010. № 2 (614). С. 29–33.

References

1. Bolotin S. A., Kotovskaya M. A. *Analiz evropeyskoy i rossiyskoy normativnykh baz trudovykh zatrat primenitel'no k kalendarnomu planirovaniyu stroitel'stva* [Analysis of European and Russian normative bases of labour costs in regard to construction scheduling]. *Vestnik grazhdanskikh inzhenerov – Bulletin of Civil Engineers*, 2013, no. 2 (37), pp. 98–103.

2. Solin A. A. *Analiz zarubezhnogo opyta razrabotki i primeneniya sbornikov tsen na stroitel'nye raboty* [Analysis of foreign experience in the development and application of collections of prices for construction work]. *Stroitel'stvo. Ekonomika i upravlenie – Construction. Economics and management*, 2011, no. 1, pp. 46–52.

3. Porshneva L. G. *Finskiy opyt: kadry reshayut vse!* [Finnish experience: personnel are the decisive factor!]. *Byulleten' natsional'nogo ob'edineniya stroiteley – Bulletin of the National Association of Builders*, 2011, no. 8 (15), pp. 57–133. Available at: http://sroamur.rf/doc/nostroy_bull/15.pdf (accessed: 30.10.2019).

4. Kallan R. *Osnovnye kontseptsii neyronnykh setey* [Basic concepts of neural networks]. Transl. from English by Sivak A. G. Moscow, ViLyams Publ., 2001, 287 p.

5. Draper N. R., Smith H. *Applied Regression Analysis*. 2nded. New York, John Wiley & Sons Publ., 1981, 709 p.

6. Boussabaine A. H. The use of artificial neural networks in construction management. *Construction Management and Economics*, 1996, vol. 14 (5), pp. 427–436.

7. Ezhov A. A., Shumskiy S. A. *V chem razlichie neyronnykh setey i statistiki?* [What is the difference between neural networks and statistics?]. In: *Neyrokompyuting i*

ego primenenie v ekonomike i biznese [Neuro-computing and its application in economics and business]. Moscow, MIFI Publ., 1998, 224 p. Available at: <https://helpiks.org/3-10999.html> (accessed: 20.01.2020).

8. Makkafr Dzh. *Testy — Regressiya neyronnoy seti* [Tests: neural network regression]. *MSDN – Bulletin of MSDN*, 2010, vol. 31, no. 3. Available at: <https://docs.microsoft.com/ru-ru/archive/msdn-magazine/2016/march/test-run-neural-network-regression> (accessed: 15.01.2020).

9. Karpathy A., Fei-Fei Li. CS231n: *Convolutional Neural Networks for Visual Recognition (Course Notes)*. 2019. Available at: <http://cs231n.stanford.edu>, <http://cs231n.github.io> (accessed: 17.12.2019).

10. Milyutin I. *Funktsii aktivatsii neyroseti: sigmoida, lineynaya, stupenchataya, ReLu, than* [Neural network activation functions: sigmoid, linear, step, ReLu, than]. 29.11.2018. Available at: <https://neurohive.io/ru/osnovy-data-science/activation-functions/> (accessed: 20.12.2019).

11. Patterson J., Gibson A. *Deep Learning. A Practitioner's Approach*. Sebastopol, CA, O'Reilly Publ., 2017, 994 p.

12. Bengio Y. *Practical Recommendation for gradient-based training of deep architectures*. In: Montavon G., Orr G. B., Müller K. R. (eds.). *Neural networks. Tricks of the trade. Lecture notes in computer science*, vol. 7700. Springer, Berlin, Heidelberg. Available at: <https://arxiv.org/abs/1206.5533> (accessed: 10.01.2020).

13. Duchi J., Hazan E., Singer Y. Adaptive subgradient methods for online learning and stochastic optimization. *Journal of Machine Learning Research*, 2011, vol. 12 (61), pp. 2121–2159. Available at: <http://jmlr.org/papers/v12/duchi11a.html> (accessed: 20.01.2020).

14. Bolotin S. A., Dadar A. Kh. *Opredelenie pogreshnosti kvalimetricheskoy otsenki vesov additivnykh pokazateley kachestva kalendarnykh planov stroitel'stva* [Determining the error of the qualimetric estimation of weights of additive quality indicators of construction calendar plans]. *Izv. vuzov. Stroitel'stvo – News of Higher Schools. Construction*, 2010, no. 2 (614), pp. 29–33.