ISSN 2413–9858

Научная статья
УДК 681.2.089

УЛЬТРАЗВУКОВОЙ НЕЙРОСЕТЕВОЙ КОМПЛЕКС ЭКСПРЕСС-КОНТРОЛЯ КАЧЕСТВА КИРПИЧА

В.Ф. Тележкин[1], П.А. Угаров[1,*], М.А. Девятов[1]

[1] Южно-Уральский государственный университет, Челябинск, Россия
* E-mail: ugarovpa@susu.ru

Аннотация. Рассмотрен комплекс неразрушающего ультразвукового контроля, предназначенный для определения прочности кирпича, с градуировочной характеристикой на основе нейросети. Проведен анализ публикаций о применимости ультразвукового метода и сделан вывод о его перспективности. Кратко описан состав комплекса, его технические особенности и порядок проведения испытаний. Градуировочная характеристика реализована на базе нейронной сети со скрытыми слоями, что позволило повысить точность по сравнению с более простыми градуировочными зависимостями, исследовавшимися ранее. Для обучения нейронной сети использовали массив размеченных данных, полученных в ходе разрушающих испытаний, L2-регуляризацию и блочную кросс-валидацию. При этом в качестве признаков выступали скорость распространения ультразвука и параметры технологического процесса. Сделан вывод о том, что ультразвуковой метод в сочетании с нейросетевой моделью применим для предварительного экспресс-контроля.

Ключевые слова: *ультразвуковой контроль; нейронная сеть; неразрушающий контроль; машинное обучение; кросс-валидация; прочность.*

Для цитирования: Тележкин В.Ф., Угаров П.А., Девятов М.А. Ультразвуковой нейросетевой комплекс экспресс-контроля качества кирпича // *Вестник науки и образования Северо-Запада России*. 2025. Т. 11. № 1. С. 77–85.

Original article

ULTRASONIC NEURAL NETWORK COMPLEX FOR BRICKS EXPRESS QUALITY CONTROL

V.F. Telezhkin[1], P.A. Ugarov[1,*], M.A. Devyatov[1]

[1] South Ural State University, Chelyabinsk, Russia
* E-mail: ugarovpa@susu.ru

Abstract. The article considers a non-destructive ultrasonic testing system designed to determine the strength of bricks with a calibration characteristic based on a neural network. An analysis of publications on the applicability of the ultrasonic method is carried out, and a conclusion is made about its prospects. The composition of the system, its technical characteristics and the test procedure are briefly described. The calibration characteristic is implemented on the basis of a neural network with hidden layers, which made it possible to increase the accuracy compared to simpler calibration dependencies studied earlier. To train the neural network an array of labeled data obtained during destructive tests, L2-regularization and block cross-validation were used. The ultrasound propagation speed and process parameters served as features. It is concluded that the ultrasonic method in combination with the neural network model is applicable for preliminary express control.

Key words: *ultrasonic control; neural network; nondestructive testing; machine learning;*

cross-validation; strength.

For citation: Telezhkin V.F., Ugarov P.A., Devyatov M.A. Ultrasonic neural network complex for bricks express quality control. *Journal of Science and Education of North-West Russia*. 2025. V. 11. No 1. pp. 77–85.

Введение

При производстве кирпича, как и других строительных материалов, большую роль играет контроль качества. Для определения интересующих характеристик, к числу которых относятся водопоглощение, морозостойкость, а также прочность на изгиб и на сжатие, традиционно применяются разрушающие испытания, обеспечивающие наилучшую точность [1]. С другой стороны, неразрушающие методы, такие как ультразвуковой, позволяют значительно сократить время и затраты на контроль качества. Поэтому представляет интерес исследование применимости неразрушающих методов, а также разработка испытательных комплексов с градуировочными характеристиками, которые позволяют определять требуемые показатели.

Анализ публикаций, в которых затрагивается применение ультразвуковых методов в целях контроля качества керамического кирпича, показывает, что некоторые авторы считают такие методы достаточно эффективными в определенных условиях [2-5], тогда как в других работах [1, 6, 7] отмечается недостаточно выраженная корреляция между скоростью распространения ультразвукового импульса и характеристиками прочности. Тем не менее, в [1] сообщается, что «…при правильном использовании, учете большого количества факторов, в узких рамках методы [ультразвукового контроля] могут успешно применяться». Также авторы [1] отмечают, что использование таких методов наиболее перспективно именно на производственном предприятии, где можно построить градуировочные характеристики, учитывающие местные особенности.

Авторы [2] замеряли скорость распространения ультразвукового импульса в кирпичах разного вида и обнаружили, что корреляционная связь между прочностью на сжатие и скоростью распространения ультразвука достаточно выражена, хотя разброс данных велик. Тем не менее, для конкретного места происхождения кирпича удается построить градуировочные зависимости, вполне применимые на практике. Это подтверждает, что ультразвуковой метод может оказаться весьма полезным в рамках внутрипроизводственного контроля на конкретном предприятии, где можно построить индивидуальные градуировочные характеристики.

Также контроль непосредственно на заводе позволяет использовать в качестве первичных признаков не только скорость распространения ультразвука, но и дополнительные доступные параметры, несущие информацию о виде сырья, температуре, длительности технологических операций и т. д. Как минимум, результаты экспресс-анализа ультразвуковым методом можно использовать для первоначального контроля с минимальными затратами, после которого при необходимости проводится исследование традиционными разрушающими методами.

Возможность применения и точность метода ультразвукового контроля определяются градуировочными зависимостями, которые связывают время или скорость распространения ультразвукового импульса в образце, а также дополнительные известные параметры технологического процесса с его качественными характеристиками, такими как прочность на сжатие. Для получения этих зависимостей требуется определенный объем размеченных данных, позволяющих провести регрессионный анализ. После этого можно определять характеристики образцов, замеряя скорость распространения ультразвука с помощью специального оборудования. В данной работе исследуется возможность применения градуировочной характеристики в виде нейронной сети.

Состав комплекса и порядок проведения испытаний

Скорость ультразвукового импульса замеряется с помощью приборов УК–14П, УК–10ПМ, УК–15П и других. Для автоматизации процесса построения градуировочных характеристик и дальнейшего практического применения построен комплекс, обеспечивающий автоматическую загрузку результатов испытаний в персональный компьютер со специализированным программным обеспечением.

Для преобразования электрических сигналов в ультразвук применяются пьезоэлектрические акустические преобразователи. Прибор производит около одного измерения в секунду, а для сопряжения с компьютером применяется интерфейс RS-232. Вспомогательный контроллер, обеспечивающий связь и оцифровку данных, реализован на базе микроконтроллера фирмы Atmel. Более подробно реализация аппаратной части описана в работе [4].

Программное обеспечение работает под управлением ОС Windows и решает следующие задачи:

- сбор данных для последующего построения градуировочных зависимостей с ручным заполнением формы (типоразмер, дополнительные технологические параметры, партия, дата, число измерений для образца);
- информирование пользователя о возможных проблемах, таких как нарушение работы ультразвукового передатчика или ненадежный контакт электроакустических преобразователей с образцом;
- передача указаний пользователю по этапам технологического процесса (фиксация образца и т. д.);
- автоматическое выполнение серии измерений на одном образце с целью последующего усреднения и исключения выбросов;
- регрессионный анализ для построения простых градуировочных характеристик;
- обучение нейросетевой градуировочной модели по данным, размеченным («labeled») на основании результатов разрушающих испытаний.
- сервисные функции для работы с базой данных и выбора тех или иных градуировочных характеристик;
- ввод текстовых комментариев пользователя для каждого образца;
- определение характеристик новых образцов по найденным градуировочным зависимостям и известным параметрам режима технологического процесса.

Как правило, методы разрушающего контроля позволяют определять для каждого конкретного образца лишь одну характеристику (к примеру, прочность на сжатие), потому что при исследовании образец разрушается. Поэтому при построении градуировочных зависимостей каждый образец может использоваться только один раз.

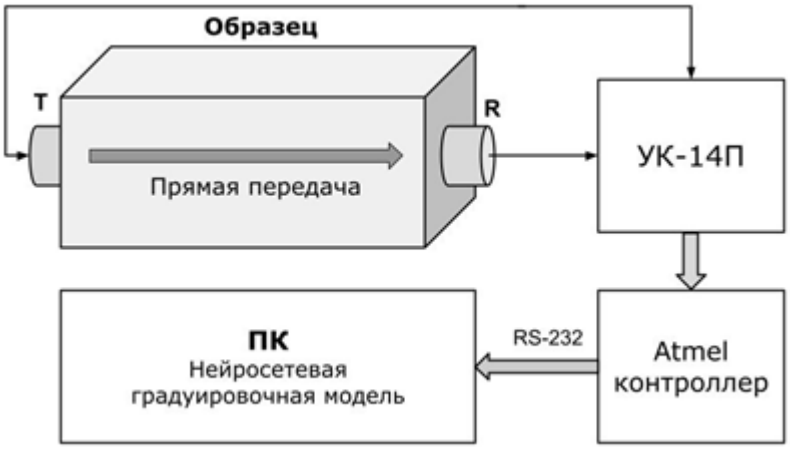


Рисунок 1 – Схема испытаний методом прямой передачи

Испытания проводились с установкой ультразвуковых пьезоэлектрических преобразователей на образце в прямом направлении (так называемый метод прямой передачи — «Direct Transmission» — см. рис. 1) [2].

В случае необходимости граница раздела между поверхностью образца и излучателем/приемником выравнивалась, поскольку ее неоднородность существенно влияет на время прохождения ультразвукового импульса. Для обеспечения надежного акустического контакта поверхности ультразвуковых преобразователей обрабатывались специальной смазкой. Скорость ультразвукового импульса рассчитывалась исходя из времени прохождения ультразвукового импульса и известной длины пути. Для каждого образца записывали и усредняли 10 показаний с исключением выбросов.

Нейросетевая градуировочная модель

Для построения градуировочной характеристики выполнили ультразвуковые исследования серии из l образцов, которые затем подвергли разрушающим испытаниям, по результатам которых получили размеченное множество образов данных $X^l = \{(x_i, y_i)_{i=1}^l\}$.

Вектор признаков x_i в каждом образе данных включает основной параметр — среднюю скорость распространения ультразвука — и дополнительные агрегированные параметры технологического режима, несущие информацию о виде сырья, температуре, длительности технологических операций и пр. По результатам разрушающих испытаний серии образцов были получены фактические значения прочности каждого образца $\{y_i\}$, которые затем сопоставили с признаками $\{x_i\}$. Таким образом, построили так называемое размеченное («labeled») исходное множество данных, пригодное для машинного обучения нейронной сети.

Задача построения градуировочной характеристики (модели) сводится к поиску решающей функции («decision function»), приближающей ответы $a_i = a(x_i)$ к требуемым значениям $\{y_i\}$ на всем множестве образов данных X. При построении любой аппроксимирующей модели, будь то простая нелинейная регрессия или нейронная сеть, важно, чтобы она хорошо показывала себя не только на обучающем массиве данных, но и на новых образцах, которые будут исследоваться в будущем. Поэтому в общем случае из массива обучающих данных в той или иной форме выделяется тестовая выборка, которая не используется в обучении непосредственно, но позволяет верифицировать итоговую обученную модель. Если модель будет давать на тестовой выборке значительно худшие результаты, чем на обучающей, это является признаком переобучения. Одним из лучших методов оценки модели является кросс-валидация (перекрестная проверка) [8].

В качестве критерия, определяющего качество найденной градуировочной зависимости, используем средний эмпирический риск [9], представляющий собой среднеквадратичную ошибку (MSE) (1).

$$Q(a, X^l) = \sqrt{\frac{1}{l}\sum_{i=1}^{l} L(a, x_i)} \to min \quad (1)$$

Здесь $L(a, x_i) = (a(x_i) - y(x))^2$ — квадратичная ошибка для отдельного образа данных. В случае параметрических моделей $a(x) = g(x, w)$, где w — вектор параметров модели, в случае нейронной сети — общий вектор весов. Таким образом, поиск модели сводится к задаче параметрической оптимизации.

В качестве $g(x, w)$ можно использовать различные линейные и нелинейные зависимости. Например, в предыдущей работе [4] исследовались характеристики трех видов — линейная, экспоненциальная и в виде функции Кобба — Дугласа, — при этом в качестве первичного признака использовалась не скорость, а время прохождения ультразвукового

ISSN 2413–9858

импульса. Наилучшие результаты показала функция Кобба-Дугласа, средний эмпирический риск для которой составил 29,45 [4].

В некоторых случаях более эффективными могут оказаться и другие решающие функции. Например, в работе [2] авторы аппроксимировали зависимость прочности на сжатие от скорости ультразвука квадратичной кривой, которая показала хорошие результаты для кирпича из определенного места происхождения; эта кривая представлена на рис. 2 и в целом хорошо согласуется с зависимостями, установленными в [4].

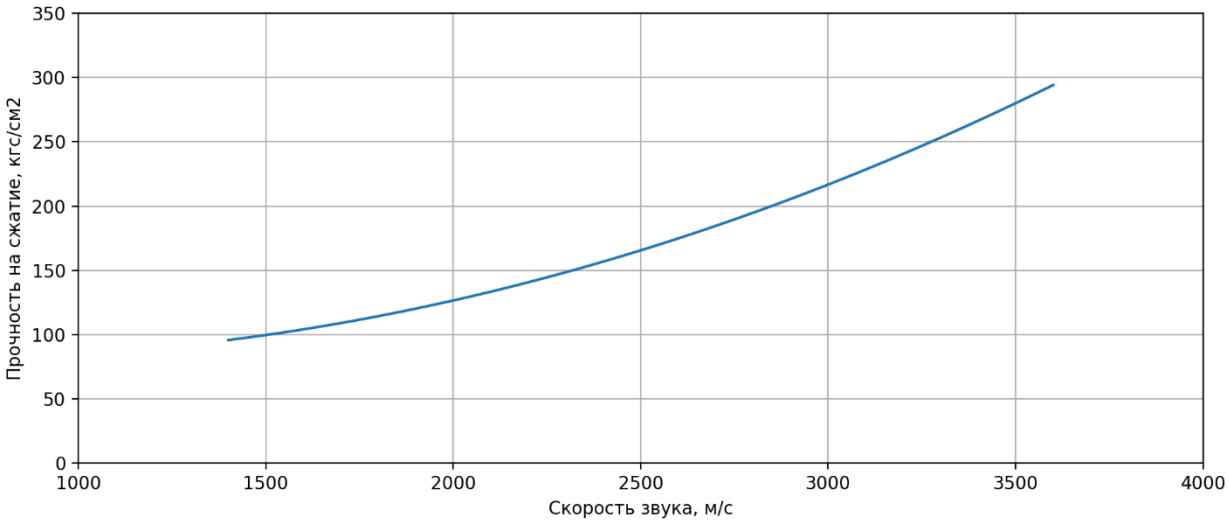


Рисунок 2 – Квадратичная аппроксимирующая кривая зависимости прочности на сжатие от скорости ультразвука

В настоящей работе исследовали возможность использования нейронной сети с весами в виде вектора w в качестве решающей функции $g(x,w)$. Известно, что выбор слишком большого количества нейронов в скрытых слоях увеличивает время, затрачиваемое на обучение сети, а также в некоторой степени способствует ее переобучению [10]. Учитывая, что в упомянутых выше исследованиях были получены удовлетворительные результаты с использованием достаточно простых аппроксимирующих функций, было принято решение исследовать нейронные сети с небольшим количеством скрытых последовательных слоев, каждый из которых выполняет вычисления по данным с предыдущего слоя.

Нейронная сеть была реализована на языке Python с использованием функционала библиотеки TensorFlow и API Keras. Последний представляет собой высокоуровневый API для построения и обучения нейросетевых моделей. В Keras реализован последовательный стек слоев Sequential, в котором каждый слой имеет единственный входной тензор и единственный выходной тензор. В этом стеке использовали так называемые «плотные» (Dense) слои. Такой слой получает информацию от каждого элемента предыдущего слоя, производя матричное перемножение этих элементов с определенными весами. Размерность выходного пространства была равна 8. Использовали функцию активации ReLU. Она преобразует сигнал на входе в величину от 0 до бесконечности. Если входной сигнал не превышает 0, то ReLU выдает ноль, иначе — входной сигнал без изменений. Также использовали схему регуляризации типа L2. Данная регуляризация обеспечивает уменьшение весов слоев сети, но никогда не доводит их до 0. Она помогает предотвратить переобучение, делая сеть менее чувствительной к небольшим изменениям входных данных, то есть она становится более робастной. Это важно в контексте рассматриваемого обучающего массива данных, в котором значения скорости распространения ультразвука имеют достаточно большой разброс. Шаг регуляризации составлял 0,01, и регуляризация

ISSN 2413–9858

применялась к матрице ядра. Архитектура построенной нейросетевой градуировочной модели с двумя скрытыми слоями представлена на рис. 3.

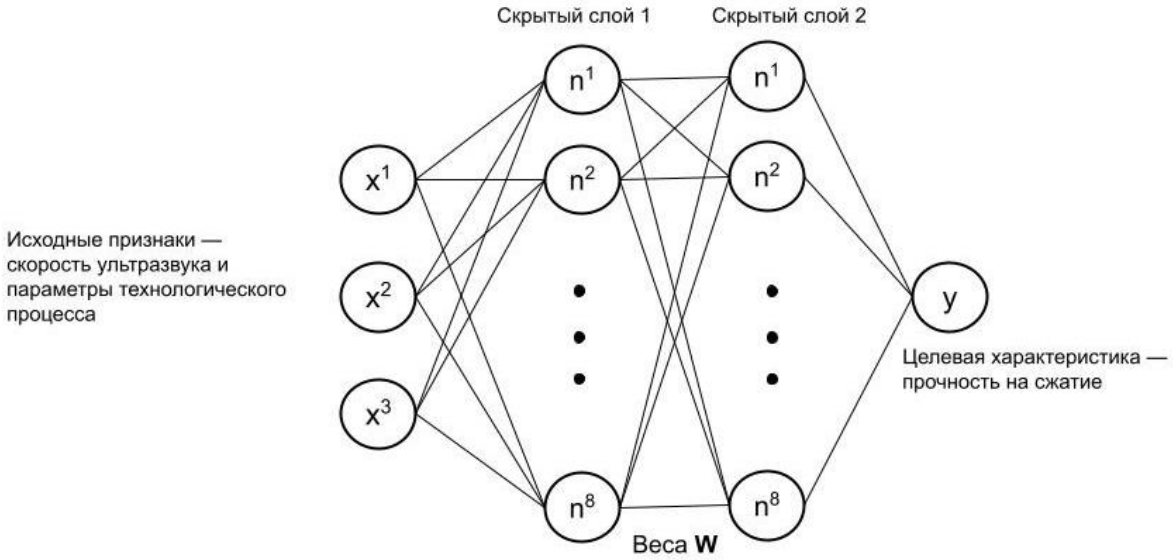


Рисунок 3 – Архитектура градуировочной нейронной сети

На рис. 4 показана часть размеченного множества образов данных, использовавшихся для обучения сети. В общей сложности разрушающим испытаниям подвергли 276 образцов. Показан срез множества по одному из признаков, а именно по усредненной скорости распространения ультразвукового импульса.

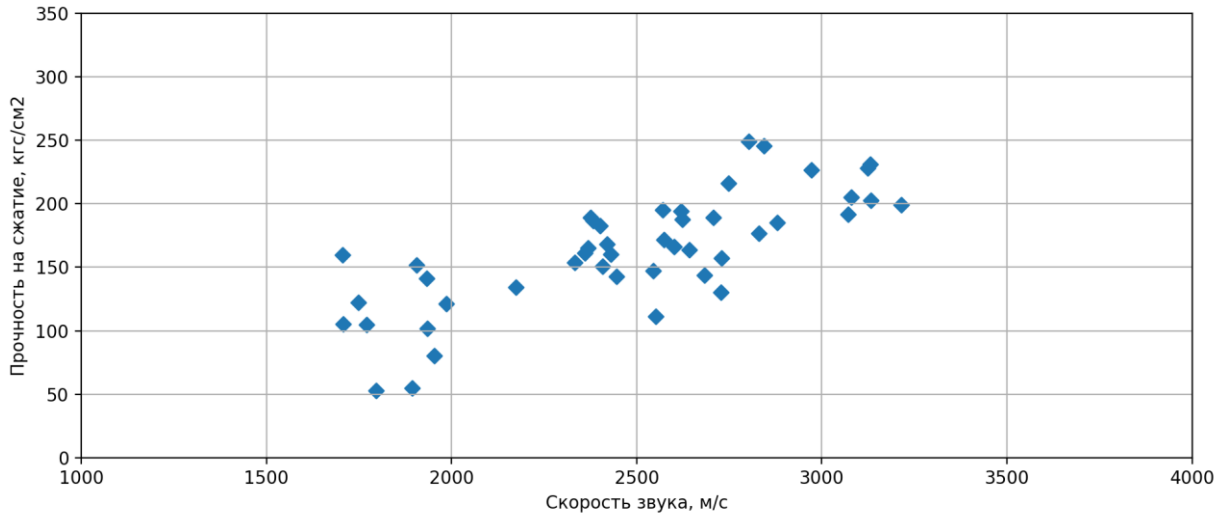


Рисунок 4 – Часть размеченного массива обучающих данных (срез по признаку прочности на сжатие)

Рассмотрим обучение нейронной сети. Существуют различные методы оптимизации весов, многие из которых реализованы в Keras. Например, на данный момент одним из лучших считается алгоритм Adam (Adaptive Moment Estimation), который показывает лучшую скорость обучения по сравнению с другими адаптивными алгоритмами благодаря более быстрой сходимости и устойчивости. Однако в нашей задаче, где выборка обучающих

данных относительно невелика, и скорость работы не имеет большого значения, лучшие результаты показал традиционный стохастический градиентный спуск (SGD).

При обучении нейронной сети важно тестировать результат на данных, которые не использовались при обучении. Так как обучающий массив невелик, применили -блочную кросс-валидацию (метод $k-fold$) с параметром $k=5$ [8]. В этом случае размеченное множество образов данных делится на 5 частей и проводится k итераций обучения, в каждой из которых одно из k подмножеств используется в качестве тестового и модель обучается на оставшихся $k-1$ подмножествах.

Описанная модель была обучена с использованием функционала библиотеки TensorFlow (всего было проведено 15 000 эпох обучения) и показала средний эмпирический риск для k моделей, проверенных на k тестовых выборках, $Q(a,X^l)=27{,}71$. Это лучше, чем удалось получить при использовании более простых градуировочных зависимостей в работе [4]. Еще одним преимуществом нейросетевого подхода является валидация модели в процессе обучения, что позволяет рассчитывать на лучшие результаты для новых образцов, не входивших в обучающий массив данных.

Тем не менее, важно отметить, что применение ультразвукового метода для определения прочностных характеристик кирпича имеет ряд недостатков. В первую очередь это относительно большой разброс значений скорости распространения ультразвука при определенной прочности, что не позволяет считать получаемые градуировочные зависимости универсальными. Однако они вполне применимы для предварительного экспресс-контроля на конкретном предприятии, когда известна не только скорость распространения ультразвука, но и другие дополнительные признаки, которые можно использовать при обучении, такие как вид сырья, температура, длительность технологических операций и прочее.

Заключение

Рассмотренный комплекс позволяет проводить неразрушающий ультразвуковой контроль кирпича и других строительных материалов с целью определения прочности на сжатие и других характеристик. Построена градуировочная модель с архитектурой в виде полносвязной нейронной сети с двумя скрытыми слоями, которая была обучена на размеченном массиве исходных данных, сформированном по результатам разрушающих испытаний серии образцов.

Результаты обучения модели показали, что комплекс пригоден для экспресс-анализа прочностных характеристик на конкретном предприятии. Однако градуировочная характеристика не является универсальной и имеет ограниченную точность, поэтому данный метод не может полностью заменить традиционные разрушающие методы.

Представляет интерес дальнейшее исследование нейросетевых градуировочных моделей, при этом лучших результатов можно достичь, если учитывать не только скорость ультразвука, но и как можно больше параметров технологического процесса, таких как вид сырья, температура и т. д. Как правило, такие данные доступны только на производственном предприятии, что еще раз подтверждает применимость метода именно для внутрипроизводственного экспресс-контроля.

СПИСОК ИСТОЧНИКОВ

1. Улыбин А.В., Зубков С.В. О методах контроля прочности керамического кирпича при обследовании зданий и сооружений // Инженерно-строительный журнал. 2012. № 3 (29). С. 29–34.

2. Brozovsky J., Zach J., Brozovsky J., Jr. Determining The Strength of Solid Burnt Bricks in Historical Structures // 9th International Conference on NDT of Art, Jerusalem, 2008. Available at: https://www.ndt.net/article/art2008/papers/011Brozovsky.pdf.

3. Brozovsky J., Zach J., Brozovsky J., Jr. Non-destructive testing of solid brick compression strength in structures // The e-Journal of Nondestructive Testing, 2007. Vol. 12, No 11. Available at: https://www.ndt.net/article/panndt2007/papers/1.pdf.

4. Тележкин В.Ф., Угаров П.А. Ультразвуковая система для экспресс-анализа технических характеристик кирпича // Известия Челябинского научного центра УрО РАН, 2000. № 1. С. 171–180.

5. Перунов А.С. К вопросу применения ультразвукового метода при контроле однородности реставрационного кирпича // Инженерный вестник Дона, 2021. № 3 (75). С 370–378.

6. Dizhur D., Lumantarna R., Biggs D.T. et al. In-situ assessment of the physical and mechanical properties of vintage solid clay bricks // Mater Struct, 2017. № 50. P. 1–23.

7. Зубков С.В., Улыбин А.В., Федотов С.Д. Исследование механических свойств кирпичной кладки методом плоских домкратов // Инженерно-строительный журнал, 2015. № 8. С. 20–29.

8. Berrar, D. Cross-Validation // Reference Module in Life Sciences Encyclopedia of Bioinformatics and Computational Biology, 2019. Vol. 1. P. 542–545.

9. Qi J., Du J., Siniscalchi S.M. et al. On Mean Absolute Error for Deep Neural Network Based Vector-to-Vector Regression // IEEE Signal Processing Letters, 2020. Vol. 27. P. 1485–1489.

10. Arifin F., Robbani H., Annisa T. Variations in the Number of Layers and the Number of Neurons in Artificial Neural Networks: Case Study of Pattern Recognition // Journal of Physics: Conference Series, 2019. № 1413(1):01201. doi: 10.1088/1742-6596/1413/1/012016.

REFERENCES

1. Ulybin A.V., Zubkov S.V. *O metodakh kontrolya prochnosti keramicheskogo kirpicha pri obsledovanii zdaniy i sooruzheniy* [On methods of testing the strength of ceramic bricks during inspection of buildings and structures]. *Inzhenerno-stroitel'nyy zhurnal*, 2012. No 3 (29), pp. 29–34.

2. Brozovsky J., Zach J., Brozovsky J., Jr. Determining The Strength of Solid Burnt Bricks in Historical Structures. 9th International Conference on NDT of Art, Jerusalem, 2008. Available at: https://www.ndt.net/article/art2008/papers/011Brozovsky.pdf.

3. Brozovsky J., Zach J., Brozovsky J., Jr. Non-destructive testing of solid brick compression strength in structures. The e-Journal of Nondestructive Testing, 2007. Vol. 12, No. 11, pp. 1–9.

4. Telezhkin V.F., Ugarov P.A. *Ul'trazvukovaya sistema dlya ekspress-analiza tekhnicheskikh kharakteristik kirpicha* [Ultrasonic system for express analysis of technical characteristics of bricks]. *Izvestiya Chelyabinskogo nauchnogo tsentra UrO RAN*. 2000. No. 1, pp. 171–180.

5. Perunov A.S. *K voprosu primeneniya ul'trazvukovogo metoda pri kontrole odnorodnosti restavratsionnogo kirpicha* [On the issue of using the ultrasonic method in monitoring the homogeneity of restoration bricks]. *Inzhenernyy vestnik Dona*, 2021. No. 3 (75), pp. 370–378.

6. Dizhur D., Lumantarna R., Biggs D.T. et al. In-situ assessment of the physical and mechanical properties of vintage solid clay bricks. Mater Struct. 2017. № 50, pp. 1–23.

7. Zubkov S.V., Ulybin A.V., Fedotov S.D. Issledovanie mekhanicheskikh svoystv kirpichnoy kladki metodom ploskikh domkratov [Study of mechanical properties of brickwork using flat jack method]. Inzhenerno-stroitel'nyy zhurnal. 2015. No. 8, pp. 20–29.

8. Berrar, D. Cross-Validation. Reference Module in Life Sciences Encyclopedia of Bioinformatics and Computational Biology. 2019. Vol. 1, pp. 542–545.

9. Qi J., Du J., Siniscalchi S.M. et al. On Mean Absolute Error for Deep Neural Network Based Vector-to-Vector Regression. IEEE Signal Processing Letters. 2020. Vol. 27, pp. 1485–1489.

10. Arifin F., Robbani H., Annisa T. Variations in the Number of Layers and the Number of Neurons in Artificial Neural Networks: Case Study of Pattern Recognition. Journal of Physics: Conference Series, 2019. № 1413(1):01201. doi: 10.1088/1742-6596/1413/1/012016.

ИНФОРМАЦИЯ ОБ АВТОРАХ	INFORMATION ABOUT THE AUTHORS
Тележкин Владимир Федорович – доктор технических наук, профессор, Южно-Уральский государственный университет (454080, Россия, г. Челябинск, пр-т Ленина 76, e-mail: telezhkinvf@susu.ru)	*Telezhkin Vladimir Fedorovich* – Dr. Sci. (Eng.), Professor, South Ural State University (454080, Russia, Chelyabinsk, Lenin prospect 76, e-mail: telezhkinvf@susu.ru)
Угаров Павел Александрович – кандидат технических наук, доцент, Южно-Уральский государственный университет (454080, Россия, г. Челябинск, пр-т Ленина 76, e-mail: ugarovpa@susu.ru)	*Ugarov Pavel Aleksandrovich* – Ph.D. (Eng), Assoc. Prof., South Ural State University (454080, Russia, Chelyabinsk, Lenin prospect 76, e-mail: ugarovpa@susu.ru)
Девятов Максим Александрович – кандидат технических наук, доцент, Южно-Уральский государственный университет (454080, Россия, г. Челябинск, пр-т Ленина 76, e-mail: ugarovpa@susu.ru)	*Devyatov Maksim Aleksandrovich* – Ph.D. (Eng), Assoc. Prof., South Ural State University (454080, Russia, Chelyabinsk, Lenin prospect 76, e-mail: deviatovma@susu.ru)

Статья поступила в редакцию 10.01.2025; одобрена после рецензирования 26.01.2025, принята к публикации 01.02.2025
The article was submitted 10.01.2025; approved after reviewing 26.01.2024; accepted for publication 01.02.2025