

# СТРОИТЕЛЬНЫЕ КОНСТРУКЦИИ, ЗДАНИЯ И СООРУЖЕНИЯ

## BUILDING CONSTRUCTIONS, BUILDINGS AND ENGINEERING STRUCTURES



УДК 69.07

Оригинальное эмпирическое исследование

<https://doi.org/10.23947/2949-1835-2025-4-4-53-60>


### Нейросетевое моделирование прочности нормальных сечений сборных железобетонных ребристых плит

В.И. Римшин<sup>1,2</sup> , С.В. Усанов<sup>3</sup> , А.Н. Выдрин<sup>2</sup>, А.Е. Керн<sup>4</sup>, Е.С. Макарова<sup>4</sup>

<sup>1</sup> Национальный исследовательский Московский государственный строительный университет, г. Москва, Российская Федерация

<sup>2</sup> Научно-исследовательский институт строительной физики Российской академии архитектуры и строительных наук, г. Москва, Российская Федерация

<sup>3</sup> Кубанский государственный технологический университет, г. Краснодар, Российская Федерация

<sup>4</sup> Новосибирский государственный архитектурно-строительный университет (Сибстрин), г. Новосибирск, Российская Федерация  
 [v.rimhin@niisf.ru](mailto:v.rimhin@niisf.ru)



EDN: RZMZDC

#### Аннотация

**Введение.** Сборные железобетонные ребристые плиты получили широкое применение в качестве перекрытий и покрытий зданий промышленного, жилого и общественного назначения. Их использование в данном качестве обусловлено высокой технологичностью изготовления, эффективным использованием бетона и возможностью автоматизации производства на заводах. Одной из важных задач при проектировании таких конструкций является расчет несущей способности нормальных сечений. Традиционные методы расчёта являются надежными, но морально устарели. Сейчас в инженерной практике всё чаще применяются методы машинного обучения, где исследователи делают выбор в пользу искусственных нейронных сетей (ИНС). Использование традиционных методов при обработке структурированных данных, таких как таблицы и базы данных, имеет свои ограничения. Нейросети способны анализировать неструктурированные данные, такие как текст, изображения и видео, что открывает новые возможности для анализа и понимания информации. В статье предложен подход к нейросетевому моделированию несущей способности нормальных сечений сборных железобетонных ребристых плит.

**Материалы и методы.** Структурированный и обработанный массив данных (датасет) включает 20 образцов, для которых разработана и верифицирована расчётная модель на основе многослойного персептрона. Входными параметрами служат геометрические и физико-механические характеристики плит и величины приложенных нагрузок, выходной параметр — предельный изгибающий момент, вычисленный по методу предельных состояний.

**Результаты исследования.** Обучение на ограниченной выборке не привело к переобучению модели благодаря корректному разделению данных на тестовую, обучающую и контрольную партии и использованию квазиньютоновского метода оптимизации. Модель продемонстрировала высокую точность и надёжность. Искусственные нейронные сети успешно выявляют нелинейные зависимости между параметрами без априорных допущений.

**Обсуждение и заключение.** Предложенная модель не заменяет существующие расчёты, но служит эффективным цифровым инструментом для быстрой проверки проектных решений, оптимизации армирования и повышения надёжности конструкций. Её внедрение в системы BIM и цифровые платформы строительства соответствует требованиям Индустрии 4.0 и создает новые возможности для проектирования сборных железобетонных конструкций.

**Ключевые слова:** ребристая железобетонная плита перекрытия, изгибаемые элементы, искусственные нейронные сети, машинное обучение

**Для цитирования.** Римшин В.И., Усанов С.В., Выдрин А.Н., Керн А.Е., Макарова Е.С. Нейросетевое моделирование прочности нормальных сечений сборных железобетонных ребристых плит. *Современные тенденции в строительстве, градостроительстве и планировке территорий*. 2025;4(4):53–60. <https://doi.org/10.23947/2949-1835-2025-4-4-53-60>

## Neural Network Modeling of the Strength of Normal Sections of Prefabricated Reinforced Concrete Ribbed Slabs

Vladimir I. Rimshin<sup>1,2</sup> , Sergey V. Usanov<sup>3</sup> , Aleksey N. Vydrin<sup>2</sup>, Anna E. Kern<sup>4</sup>, Elizaveta S. Makarova<sup>4</sup>

<sup>1</sup> National Research Moscow State University of Civil Engineering, Moscow, Russian Federation

<sup>2</sup> Scientific Research Institute of Building Physics of the Russian Academy of Architecture and Building Sciences, Moscow, Russian Federation

<sup>3</sup> Kuban State Technological University, Krasnodar, Russian Federation

<sup>4</sup> Novosibirsk State University of Architecture and Civil Engineering (Sibstrin), Novosibirsk, Russian Federation

✉ [v.rimhin@niisf.ru](mailto:v.rimhin@niisf.ru)

### Abstract

**Introduction.** Precast reinforced concrete ribbed slabs are broadly used as floors and coverings for industrial, residential and public buildings. Their use in this capacity is due to the high technological efficiency of manufacturing, efficient use of concrete and the possibility of automating factory production. One of the critical tasks in designing such structures is to calculate the bearing capacity of normal cross sections. Traditional calculation methods are reliable, but they are outdated. Machine learning methods are increasingly being employed in engineering, where researchers are opting for artificial neural networks (ANNs). The use of traditional methods in processing structured data such as tables and databases has its limitations. Neural networks are capable of analyzing unstructured data such as text, images, and videos, which opens up new prospects for analyzing and comprehending information. The article sets forth an approach to neural network modeling of the bearing capacity of normal sections of prefabricated reinforced concrete ribbed slabs.

**Materials and Methods.** A structured and processed data array (dataset) includes 20 samples for which a computational model based on a multilayer perceptron has been developed and verified. The input parameters are the geometric as well as physical and mechanical characteristics of the slabs and the applied load, the output parameter is the limiting bending moment calculated using the limit state method.

**Research Results.** Training on a limited sample did not lead to retraining of the model due to the correct division of data into test, training and control batches and the use of the quasi-Newton optimization method. The model has displayed a high level accuracy and reliability. Artificial neural networks are capable of identifying nonlinear dependencies between the parameters with no a priori assumptions.

**Discussion and Conclusion.** The suggested model is not a substitute for the existing calculations, but it serves as an efficient digital tool for quick verification of design solutions, optimization of reinforcement and improvement of structural reliability. Its implementation into BIM systems and digital construction platforms is in compliance with the requirements of Industry 4.0 and creates new opportunities for designing prefabricated reinforced concrete structures.

**Keywords:** ribbed reinforced concrete floor slab, bendable elements, artificial neural networks, machine learning

**For citation.** Rimshin VI, Usanov SV, Vydrin AN, Kern AE, Makarova ES. Neural Network Modeling of the Strength of Normal Sections of Prefabricated Reinforced Concrete Ribbed Slabs. *Modern Trends in Construction, Urban and Territorial Planning*. 2025;4(4):53–60. <https://doi.org/10.23947/2949-1835-2025-4-4-53-60>

**Введение.** В современном промышленном и гражданском строительстве сборные железобетонные ребристые плиты остаются одним из востребованных решений для устройства перекрытий и покрытий зданий благодаря сочетанию экономичности, надёжности и технологичности. Их применение оправдано высокой степенью заводской готовности, налаженностью массового серийного производства, оптимальной формой поперечного сечения, минимизирующей расход бетона при обеспечении необходимой несущей способности и деформативности.

Расчёт прочности нормальных сечений ребристых плит является неотъемлемой частью расчетов по I группе предельных состояний. Традиционные методы расчёта, приведенные в СП 63.13330.2018 «Бетонные и железобетонные конструкции. Основные положения», являются надежными и хорошо зарекомендовали себя, но в последние два десятилетия в инженерной практике всё чаще применяются методы машинного обучения. Чаще всего исследователи делают выбор в пользу искусственных нейронных сетей (ИНС). Преимущество ИНС заключается в способности выявлять скрытые нелинейные зависимости между множеством входных параметров и целевой переменной. В отличие от аналитических моделей, ИНС не требуют априорного задания функциональных зависимостей, что делает их особенно ценными, в частности, для определения несущей способности строительных конструкций. Вопросы информационного моделирования в расчете строительных конструкций и применения искусственного интеллекта в данной области были рассмотрены в российской [1–8] и зарубежной [9–16] технической литературе.

Целью настоящей статьи является разработка и верификация нейросетевой модели для прогнозирования несущей способности нормальных сечений сборных железобетонных ребристых плит.

**Материалы и методы.** Объектами исследования служили 20 ребристых плит шириной приведенного сечения от 1460 до 1150 мм, рабочей высотой от 370 до 240 мм и пролетом от 4550 до 8100 мм. Более подробные сведения о датасете приведены в таблице 1.

Таблица 1

Характеристики ребристых железобетонных плит

№ п/п	$b_f'$ , мм	$h_0$ , мм	$b$ , мм	$l_0$ , мм	$q$ , кН/м	$R_b$ , МПа	$R_s$ , МПа	$A_{sp}$ , см <sup>2</sup>	$M_{ult}$ , кНм
1	1460	370	150	6250	16,95	17	695	4,40	124,15
2	1160	370	185	7080	19,60	17	870	6,08	147,39
3	1160	344	185	7900	11,93	22	1215	2,49	111,70
4	1150	270	150	5675	18,15	17	520	5,88	87,70
5	1360	344	185	8100	18,66	22	1300	4,51	214,25
6	1360	344	185	8100	17,40	17	1300	2,27	94,54
7	1450	240	150	5400	16,90	17	1250	2,88	92,40
8	1450	270	150	7050	16,89	17	1390	3,23	157,42
9	1450	270	150	4700	11,31	17	1390	1,15	46,84
10	1360	260	185	4690	17,54	22	1130	2,12	67,52
11	1460	370	150	6200	17,05	17	690	4,50	128,20
12	1160	370	185	7050	19,30	17	880	5,98	145,10
13	1160	344	185	7850	11,53	22	1190	2,53	115,10
14	1150	270	150	5700	18,25	17	530	6,05	90,30
15	1360	344	185	8000	18,82	22	1300	4,61	220,10
16	1360	350	185	8050	17,00	17	1250	2,05	93,38
17	1450	240	150	5350	16,50	17	1250	2,72	90,50
18	1450	270	150	7000	16,68	17	1390	3,18	156,10
19	1450	270	150	4750	11,33	17	1390	1,19	49,92
20	1360	260	185	4550	17,24	22	1130	1,95	65,23

Для каждой плиты приведены следующие параметры: приведенная ширина полки  $b_f'$  ( $x_1$ ), рабочая высота  $h_0$  ( $x_2$ ), приведенная ширина ребра  $b$  ( $x_3$ ), расчетный пролет  $l_0$  ( $x_4$ ), величина приложенной равномерно распределенной нагрузки  $q$  ( $x_5$ ), призменная прочность бетона  $R_b$  ( $x_6$ ), предел текучести стальной арматуры  $R_s$  ( $x_7$ ), площадь сечения преднапряжённой арматуры  $A_{sp}$  ( $x_8$ ) и значение предельного изгибающего момента  $M_{ult}$  ( $y$ ). Последняя величина в дальнейшем будет являться результатом прогноза нейросетевой модели. Предельные изгибающие моменты вычислены по методу предельных состояний.

Для построения нейросетевой модели использовался программный комплекс STATISTICA 14.0 с модулем Neural Networks, обеспечивающим реализацию архитектуры в виде многослойного персептрона с обратным распространением ошибки. Создание нейронной сети в виде многослойного персептрона обусловлено спецификой поставленной задачи. Искусственная нейронная сеть включает в себя три слоя. Входной слой состоял из 8 приведенных выше независимых переменных. Число нейронов в скрытом слое изменялось от 1 до 20. После прохождения скрытого слоя сигнал, преобразовываясь на каждом этапе с помощью соответствующих функций активации, поступал в выходной слой, содержащий единственную зависимую переменную —  $M_{ult}$  ( $y$ ). Каждый из нейронов скрытого и выходного слоя соединен со всеми нейронами предыдущего слоя.

Размер датасета позволил получить оптимальное соотношение обучающей, тестовой и контрольной выборки в процентном выражении 70, 15 и 15 соответственно. Количество эпох (циклов обучения) равно 1000 (рис. 1). Для обработки поступающих сигналов на каждом этапе были испробованы все функции активации (рис. 2).

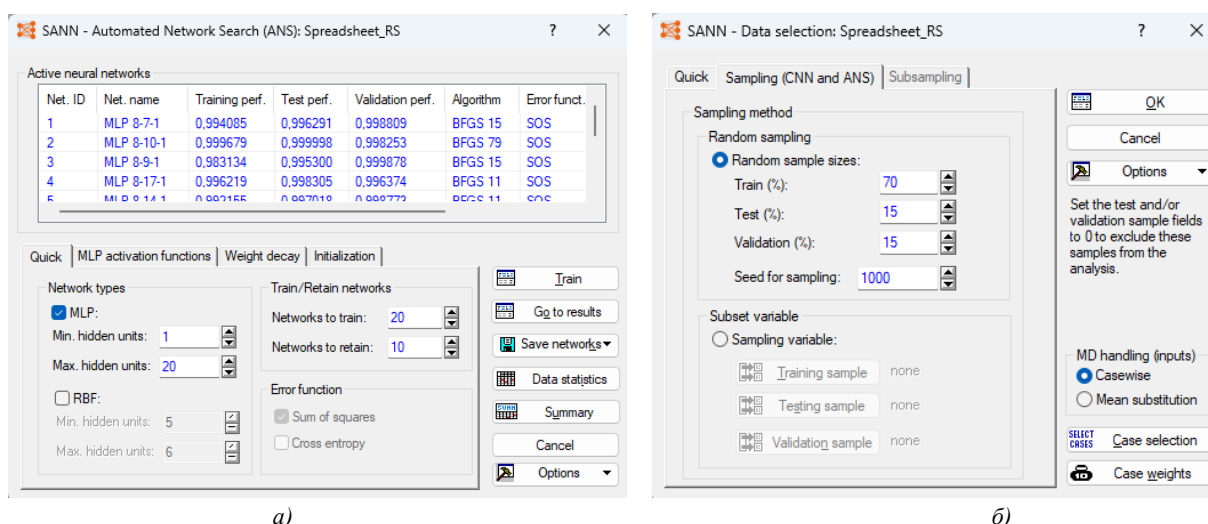


Рис. 1. Характеристики нейросетевой модели: а — для случайной выборки; б — для скрытого слоя и обучения ИНС

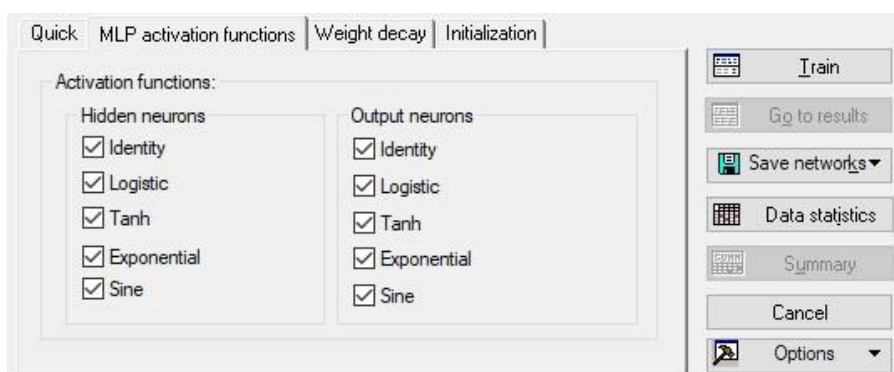


Рис. 2. Выбранные функции активации скрытого и выходного слоя нейронов

Алгоритм Бroyдена-Флетчера-Гольдфарба-Шанно (BFGS) представляет собой один из наиболее эффективных методов квазиньютоновской оптимизации, применяемый для обучения искусственных нейронных сетей. Функция потерь с весовыми коэффициентами минимизируется итеративно. В рамках настоящего исследования данный алгоритм использовался для адаптивного обновления параметров сети на основе аппроксимации обратной матрицы Гессе, что позволяет учитывать вторые производные функции ошибки без явного их вычисления. В качестве целевой функции была принята сумма квадратов отклонений (Sum of Squares, SOS), определяемая по формуле (1):

$$E(w_{ij}) = \sum_{i=1}^m (y_i - y_i')^2, \quad (1)$$

где  $y_i$  — выходное значение  $i$ -го нейрона выходного слоя;  $y_i'$  — требуемое значение  $i$ -го нейрона выходного слоя.

Обучение проводилось итеративно, то есть на каждом этапе (эпохе) на вход последовательно подавались все наблюдения, а результирующие значения сопоставлялись с целевыми и рассчитывалась соответствующая величина ошибки. В программе STATISTICA итоги расчета представляются в табличной форме. Точность результатов нейросетевого прогнозирования оценивалась сопоставлением результатов созданной модели с опытными величинами и вычислялась по формуле (2):

$$\delta = \frac{y_{\text{инс}} - y_i}{y_i} \cdot 100\%, \quad (2)$$

где  $y_{\text{инс}}$  — значение разрушающего изгибающего момента, полученное при прогнозировании с помощью ИНС в  $i$ -ом испытании;  $y_i$  — фактическое значение разрушающего изгибающего момента в  $i$ -ом испытании.

Были протестированы 10 архитектур MLP с количеством скрытых слоёв от 2 до 19 (рис. 3 и 4). Наилучшие результаты продемонстрировала нейронная сеть с архитектурой MLP 8-9-1, выделенная зеленой рамкой.

Net. name	Training perf.	Test perf.	Validation perf.	Training error	Test error	Validation error	Training algorithm	Error function	Hidden activation	Output activation
MLP 8-7-1	0.994085	0.996291	0.998809	10.62153	16.48046	9.93623	BFGS 15	SOS	Logistic	Identity
MLP 8-10-1	0.999679	0.999998	0.998253	0.63092	0.07326	15.30478	BFGS 19	SOS	Tanh	Tanh
MLP 8-9-1	0.983134	0.995300	0.999878	31.72447	12.67781	58.40971	BFGS 15	SOS	Identity	Tanh
MLP 8-17-1	0.996219	0.998305	0.996374	6.83131	18.37588	20.66575	BFGS 11	SOS	Tanh	Identity
MLP 8-14-1	0.992155	0.997018	0.998773	13.76911	21.46851	20.28928	BFGS 11	SOS	Identity	Identity
MLP 8-13-1	0.984357	0.998660	0.999682	28.98711	6.83088	53.70908	BFGS 21	SOS	Tanh	Tanh
MLP 8-11-1	0.992339	0.997115	0.999887	13.50086	16.44569	11.82677	BFGS 11	SOS	Tanh	Identity
MLP 8-19-1	0.995462	0.996490	0.998304	8.10334	15.24956	9.80945	BFGS 11	SOS	Logistic	Identity
MLP 8-8-1	0.998522	0.997551	0.998666	2.71952	7.02600	9.66670	BFGS 34	SOS	Tanh	Exponentia
MLP 8-2-1	0.999066	0.998745	0.998871	1.76863	4.50505	4.40192	BFGS 58	SOS	Logistic	Exponentia

Рис. 3. Характеристики полученных ИНС

Net. name	Training perf.	Test perf.	Validation perf.	Training error	Test error	Validation error	Training algorithm	Error function	Hidden activation	Output activation
MLP 8-9-1	0.983134	0.995300	0.999878	31.72447	12.67781	58.40971	BFGS 15	SOS	Identity	Tanh

Рис. 4. Характеристики наилучшей ИНС


Значения предельного изгибающего момента по данным расчета и прогноза выбранной ИНС иллюстрирует таблица 2. Также в таблице можно видеть принадлежность каждого случая к обучающей либо тестовой партиям.

Таблица 2

Результаты прогнозирования для выбранной ИНС

Case name	$M_{ult}$ Target	Mult - Output 3. MLP 8-9-1
1	124,1500	127,8000
2	147,3900	149,7304
3	111,7000	118,3796
4	87,7000	81,9504
6	94,5400	100,3477
7	92,4000	101,5405
9	46,8400	41,1607
10	67,5200	71,4283
12	145,1000	147,2489
13	115,1000	114,5124
14	90,3000	90,6634
15	220,1000	196,9605
16	93,3800	84,6343
20	65,2300	62,0702

Величина рассчитанной по формуле (2) усредненной относительной погрешности MLP 8-10-1 равна 5,6 %. По графику (рис. 6) видно, что точность работы полученной модели высокая, модель успешно справляется с поставленной задачей. Легко заметить, что только один случай несколько удален от диагонали, представляющей собой идеальное место расположения точек прогноза. Остальные значения, предсказанные моделью, лишь незначительно отклоняются от диагонали.

Рис. 6. Зависимость между фактическим и прогнозными значениями  $M_{ult}$ 

Выбранная ИНС «научилась» учитывать имеющиеся неявные зависимости между всеми параметрами. Она не просто «запоминает» данные, а обнаруживает физически обоснованные закономерности. Нейросетевая модель



не использует никаких предположений и допущений (о форме эпюры напряжений и пр.), только обучается на реальных данных. При этом с увеличением размеров датасета следует ожидать существенного повышения точности работы предлагаемой модели.

Отдельно отметим, что не только точность модели является ее преимуществом, но и время расчета всеми известными методами, включая численное моделирование, уступает нейронным сетям. Это дает дополнительные аргументы в пользу дальнейшего внедрения ИНС в состав проектных работ.

**Результаты исследования.** Полученные результаты подтверждают, что искусственные нейронные сети являются новым обоснованным подходом к определению несущей способности изгибаемых элементов, являются эффективным методом решения задачи. Усредненные значения отношений фактических и расчетных разрушающих изгибающих моментов и коэффициентов их вариации получилось равным 0,993 и 0,069 соответственно. Несмотря на высокую точность, на сегодняшний день ИНС не заменяет другие методы расчета конструкций, но может быть рекомендована как дополнительный цифровой инструмент для проверки проектных решений, оптимизации армирования железобетонных элементов и повышения надёжности конструкций.

**Обсуждение и заключение.** Разработанная модель может быть интегрирована в системы BIM, что соответствует стратегии Индустрии 4.0. Успешное применение ИНС в строительной отрасли — это естественный этап эволюции инженерной науки. Дальнейшим шагом может быть разработка открытого API для доступа к модели в рамках цифровой платформы.

### Список литературы/References

1. Римшин В.И., Анпилов С.М., Усанов С.В. Применение когнитивных технологий для прогнозирования прочности тонких стенок двутавровых балок. *Эксперт: теория и практика*. 2024;1(24):42–52. [https://doi.org/10.51608/26867818\\_2024\\_1\\_42](https://doi.org/10.51608/26867818_2024_1_42)

Rimshin VI, Anpilov SM, Usanov SV Application of Cognitive Technologies to Predict the Strength of Thin Walls of I-Beams. *Expert: Theory and Practice*. 2024;1(24):42–52. (In Russ.) [https://doi.org/10.51608/26867818\\_2024\\_1\\_42](https://doi.org/10.51608/26867818_2024_1_42)

2. Римшин В.И., Соловьев А.К., Сулейманова Л.А., Амелин П.А. Нейросетевое прогнозирование физико-механических характеристик композитных материалов используемых для усиления строительных конструкций. *Эксперт: теория и практика*. 2023;4(23):101–107. [https://doi.org/10.51608/26867818\\_2023\\_4\\_101](https://doi.org/10.51608/26867818_2023_4_101)

Rimshin VI, Solovyov AK, Suleymanova LA, Amelin PA Neural Network Forecasting of Physical and Mechanical Characteristics of Composite Materials Used to Strengthen Building Structures. *Expert: Theory and Practice*. 2023;4(23):101–107. (In Russ.) [https://doi.org/10.51608/26867818\\_2023\\_4\\_101](https://doi.org/10.51608/26867818_2023_4_101)

3. Тарасов И.В. Индустрия 4.0: понятие, концепции, тенденции развития. *Стратегии бизнеса*. 2018;6(50):43–49. <https://doi.org/10.17747/2311-7184-2018-5-43-49>

Tarasov IV. INDUSTRY 4.0: Concept & Development. *Business Strategies*. 2018;6(50):43–49. (In Russ.) <https://doi.org/10.17747/2311-7184-2018-5-43-49>

4. Римшин В.И., Усанов С.В. Нейросетевое моделирование прочности нормальных сечений балок с жесткой композитной арматурой. *Известия высших учебных заведений. Строительство*. 2025;7(799):5–15. <https://doi.org/10.32683/0536-1052-2025-799-7-5-15>

Rimshin VI, Usanov SV Neural Network Modeling of the Strength of Normal Cross-Sections of Beams with Rigid Composite Reinforcement. *News of Higher Educational Institutions. Construction*. 2025;7(799):5–15. (In Russ.) <https://doi.org/10.32683/0536-1052-2025-799-7-5-15>

5. Римшин В.И., Усанов С.В., Воробьев А.Е., Савельев Е.С. Восстановление несущей способности железобетонных плит перекрытия на примере многоэтажного гражданского здания. *БСТ: Бюллетень строительной техники*. 2025;6(1090):46–48. URL: <https://elibrary.ru/item.asp?id=82379614> (дата обращения: 21.10.2025).

Rimshin VI, Usanov SV, Vorobyov AE, Savelyev ES Restoration of the Bearing Capacity of Reinforced Concrete Floor Slabs on the Example of a Multi-Storey Civil Building. *BST: Bulletin of the Construction Equipment*. 2025;6(1090):46–48. (In Russ.) <https://elibrary.ru/item.asp?id=82379614> (accessed: 21.10.2025)

6. Римшин В.И., Усанов С.В., Воробьев А.Е., Савельев Е.С. Численное моделирование напряженно-деформированного состояния балок с жесткой композитной арматурой. *Вестник Поволжского государственного технологического университета. Серия: Материалы. Конструкции. Технологии*. 2025;1(33):63–73. <https://doi.org/10.25686/2542-114X.2024.4.63>

Rimshin VI, Usanov SV, Vorobev AE, Savelev ES Numerical Simulation of the Stress-Strain State of Beams with Rigid Composite Reinforcement. *Vestnik of Volga Tech. Series: Materials. Constructions. Technologies*. 2025;1(33):63–73. (In Russ.) <https://doi.org/10.25686/2542-114X.2024.4.63>

7. Римшин В.И., Анпилов С.М., Рощина С.И., Усанов С.В. Практические подходы к устранению коллизий в информационных моделях зданий. *Эксперт: теория и практика*. 2024;3(26):87–94. [https://doi.org/10.51608/26867818\\_2024\\_3\\_87](https://doi.org/10.51608/26867818_2024_3_87)

Rimshin VI, Anpilov SM, Usanov SV Practical Approaches to Eliminating Collisions in Information Models of Buildings. *Expert: Theory and Practice*. 2024;1(24):42–52. (In Russ.) [https://doi.org/10.51608/26867818\\_2024\\_3\\_87](https://doi.org/10.51608/26867818_2024_3_87)

8. Курбатов В.Л., Римшин В.И., Шубин И.Л., Волкова С.В. *Информационное моделирование и искусственный интеллект в современном строительстве и жилищно-коммунальном хозяйстве*, 2-е издание, переработанное. Москва: Издательский дом АСВ; 2025. <https://elibrary.ru/item.asp?id=82433619> (дата обращения: 21.10.2025).

Kurbatov VL, Rimshin VI, Shubin IL, Volkova SV *Information Modeling and Artificial Intelligence in Modern Construction and Housing and Communal Services* (2nd edition, revised) Moscow: Publishing House ASV; 2025. (In Russ.) <https://elibrary.ru/item.asp?id=82433619>. (accessed: 21.08.2025)

9. Perera R., Barchin M., Arteaga A., Diego A. Prediction of the ultimate strength of reinforced concrete beams FRP-strengthened in shear using neural networks. *Composites. Part B: Engineering*. 2010;41:287–298. <http://dx.doi.org/10.1016/j.compositesb.2010.03.003>

10. Peng F., Wenyuan X., Weichen X. Database Evaluation of Shear Strength of Slender Fiber-Reinforced Polymer-Reinforced Concrete Members. *ACI Structural Journal*. 2020;117(3):273–282. <http://dx.doi.org/10.14359/51723504>

11. Estep D.D. *Bending and Shear Behavior of Pultruded Glass Fiber Reinforced Polymer Composite Beams with Closed and Open Sections*. West Virginia University; 2014. 545 p. <https://doi.org/10.33915/etd.545>

12. Lagaros N.D. Artificial Neural Networks Applied in Civil Engineering. *Applied Sciences*. 2023;13(2):1131. <https://doi.org/10.3390/app13021131>

13. Afrifa R.O., Adom-Asamoah M., Owusu-Ansah E. Artificial neural network model for low strength RC beam shear capacity. *Journal of Science and Technology*. 2012;32(2):119–132. <http://dx.doi.org/10.4314/jst.v32i2.13>

14. Ahmad A., Cotsovos D.M., Lagaros N.D. Framework for the development of artificial neural networks for predicting the load carrying capacity of RC members. *SN Applied Sciences*. 2020;2:545. <https://doi.org/10.1007/s42452-020-2353-8>

15. Mansour M.Y., Dicleli M., Lee J.Y., Zhang J. Predicting the shear strength of reinforced concrete beams using artificial neural networks. *Engineering Structures*. 2004;426:781–799. <http://dx.doi.org/10.1016/j.engstruct.2004.01.011>

16. Imam A., Anifowose F., Azad A.K. Residual Strength of Corroded Reinforced Concrete Beams Using an Adaptive Model Based on ANN. *International Journal of Concrete Structures and Materials*. 2015;9(2):159–172. <http://dx.doi.org/10.1007/s40069-015-0097-4>

#### Об авторах:

**Римшин Владимир Иванович**, доктор технических наук, профессор, профессор кафедры жилищно-коммунального комплекса Национального исследовательского Московского государственного строительного университета (129337, Российская Федерация, г. Москва, Ярославское шоссе, 26), заведующий лабораторией мониторинга жилищно-коммунального хозяйства и радиационной безопасности в строительстве Научно-исследовательского института строительной физики Российской академии архитектуры и строительных наук (127238, Российская Федерация, г. Москва, Локомотивный проезд, 21), [ResearchID](#), [ScopusID](#), [ORCID](#), [v.rimshin@niisf.ru](mailto:v.rimshin@niisf.ru)

**Усанов Сергей Владимирович**, кандидат технических наук, доцент кафедры строительных конструкций Кубанского государственного технологического университета (350042, Российская Федерация, г. Краснодар, ул. Московская, 2), [ResearchID](#), [ScopusID](#), [ORCID](#), [svusanov@gmail.com](mailto:svusanov@gmail.com)

**Выдрин Алексей Николаевич**, аспирант лаборатории мониторинга жилищно-коммунального хозяйства и радиационной безопасности в строительстве Научно-исследовательского института строительной физики Российской академии архитектуры и строительных наук (127238, Российская Федерация, г. Москва, Локомотивный проезд, 21), [AuthorID](#), [aleksey-vydrin@yandex.ru](mailto:aleksey-vydrin@yandex.ru)

**Керн Анна Евгеньевна**, студент Новосибирского государственного архитектурно-строительного университета (Сибстрин) (630008, Российская Федерация, г. Новосибирск, ул. Ленинградская, 113), [AuthorID](#), [a.kern@sibstrin.ru](mailto:a.kern@sibstrin.ru)

**Макарова Елизавета Сергеевна**, студент Новосибирского государственного архитектурно-строительного университета (Сибстрин) (630008, Российская Федерация, г. Новосибирск, ул. Ленинградская, 113), [makarova\\_elizaveta\\_s@mail.ru](mailto:makarova_elizaveta_s@mail.ru)

**Заявленный вклад соавторов:**

**В.И. Римшин:** научное руководство, концепция исследования, развитие методологии, итоговые выводы.

**С.В. Усанов:** написание исходного текста, построение и анализ моделей, редактирование статьи.

**А.Н. Выдрин:** подготовка текста, сбор и обработка данных.

**А.Е. Керн:** сбор и обработка данных.

**Е.С. Макарова:** сбор и обработка данных.

**Конфликт интересов:** авторы заявляют об отсутствии конфликта интересов.

**Все авторы прочитали и одобрили окончательный вариант рукописи.**

**About the Authors:**

**Vladimir I. Rimshin**, Dr.Sci. (Eng.), Professor, Professor of the Department of Housing and Utilities Sector at the National Research Moscow State University of Civil Engineering (26 Yaroslavskoye Highway, Moscow, 129337, Russian Federation), Head of the Laboratory for Monitoring Housing and Utilities Sector and Radiation Safety in Construction at the Scientific Research Institute of Building Physics of the Russian Academy of Architecture and Construction Sciences (21 Lokomotivniy Driveway, Moscow, 127238, Russian Federation), [ResearchID](#), [ScopusID](#), [ORCID](#), [v.rimshin@niisf.ru](mailto:v.rimshin@niisf.ru)

**Sergey V. Usanov**, Cand.Sci. (Eng.), Associate Professor at the Department of Building Structures, Kuban State Technological University (2 Moskovskaya Str., Krasnodar, 350042, Russian Federation), [ResearchID](#), [ScopusID](#), [ORCID](mailto:svusanov@gmail.com), [svusanov@gmail.com](mailto:svusanov@gmail.com)

**Aleksey N. Vydrin**, PhD student at the Laboratory for Monitoring Housing and Utilities Sector and Radiation Safety in Construction at the Scientific Research Institute of Building Physics of the Russian Academy of Architecture and Construction Sciences (21 Lokomotivniy Driveway, Moscow, 127238, Russian Federation), [AuthorID](#), [aleksey-vydrin@yandex.ru](mailto:aleksey-vydrin@yandex.ru)

**Anna E. Kern**, student of Novosibirsk State University of Architecture and Civil Engineering (Sibstrin) (113 Leningradskaya Str., Novosibirsk, 630008, Russian Federation), [AuthorID](#), [a.kern@sibstrin.ru](mailto:a.kern@sibstrin.ru)

**Elizaveta S. Makarova**, student of Novosibirsk State University of Architecture and Civil Engineering (Sibstrin) (113 Leningradskaya Str., Novosibirsk, 630008, Russian Federation), [makarova\\_elizaveta\\_s@mail.ru](mailto:makarova_elizaveta_s@mail.ru)

**Claimed Contributorship:**

**VI Rimshin:** scientific supervision, research concept, development of the methodology, final conclusions.

**SV Usanov:** writing the original manuscript, designing and analyzing the models, editing the manuscript.

**AN Vydrin:** preparation of the manuscript, collection and processing of the data.

**AE Kern:** collection and processing of the data.

**ES Makarova:** collection and processing of the data.

**Conflict of interest statement:** the authors do not have any conflict of interest.

**All authors have read and approved the final version of manuscript.**

Поступила в редакцию / Received 07.09.2025

Поступила после рецензирования / Reviewed 19.09.2025

Принята к публикации / Accepted 08.10.2025