

DOI: 10.34031/2071-7318-2024-9-11-42-55

<sup>1,2</sup>Римшин В.И., <sup>3,\*</sup>Амелин П.А., <sup>3</sup>Сулейманова Л.А.<sup>1</sup>Национальный исследовательский Московский государственный строительный университет<sup>2</sup>Научно-исследовательский институт строительной физики  
Российской академии архитектуры и строительных наук<sup>3</sup>Белгородский государственный технологический университет им. В.Г. Шухова

\*E-mail: p.amelin@inbox.ru

## НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ НЕСУЩЕЙ СПОСОБНОСТИ ЖЕЛЕЗОБЕТОННЫХ ЭЛЕМЕНТОВ

**Аннотация.** Статья посвящена исследованию силового сопротивления железобетонных изгибаемых элементов на различных стадиях их жизненного цикла с учетом коррозионного повреждения арматуры и последующего композитного усиления. В работе рассмотрены изменения характеристик железобетонных конструкций под воздействием эксплуатационных и агрессивных факторов окружающей среды, что приводит к снижению их несущей способности. Основное внимание уделено коррозии арматурной стали, которая вызывает растрескивание бетонного покрытия и уменьшение сечения арматуры, снижая долговечность конструкции. Для прогнозирования остаточной прочности и несущей способности железобетонных элементов предложен подход, основанный на применении искусственных нейронных сетей. Прогнозирование осуществлялось с использованием искусственных нейронных сетей в программном комплексе Statistica. Разработаны и протестированы модели многослойного перцептрона с использованием данных об испытаниях железобетонных балок с различными повреждениями и усилениями. Модели искусственных нейронных сетей были валидированы с использованием кросс-валидации и показали высокую устойчивость к изменению входных данных, что подтверждает их пригодность для практического применения в гражданском строительстве для оценки остаточной несущей способности. Применение искусственных нейронных сетей позволяет учитывать нелинейные зависимости между параметрами и улучшает прогнозируемые результаты, что делает их более надежным инструментом по сравнению с традиционными методами.

**Ключевые слова:** железобетонные конструкции, коррозия арматуры, искусственные нейронные сети, прогнозирование прочности, многослойный перцептрон, композитное усиление, моделирование жизненного цикла

**Введение.** Силовое сопротивление железобетонных элементов изменяется на протяжении всего жизненного цикла объекта капитального строительства в зависимости от возраста материалов, уровней и режимов нагружения, а также сопутствующих характеристик окружающей среды [1–3].

На этапе проектирования конструкций в качестве исходных данных расчета закладываются идеализированные характеристики материалов, в результате чего фактическое силовое сопротивление изготовленной на заводе конструкции несколько отличается от проектного. В российских строительных правилах расчет конструкций производится по методу предельных состояний, несоответствие силового сопротивления в железобетоне решается посредством учета коэффициентов надежности и условий работы, увеличивающих закладываемые значения нагрузок и уменьшающие механические характеристики материалов.

С первого дня эксплуатации объекта капитального строительства его конструкции подвергаются воздействию как силовых, так и

агрессивных несилевых нагрузок, что приводит к развитию коррозионных процессов в бетоне и арматуре, уменьшая силовое сопротивление и вызывая преждевременное наступление предельных состояний в конструкции [4].

Коррозия арматурных стальных стержней (арматуры) в железобетонных конструкциях является основной причиной снижения долговечности конструкции. Когда карбонизация или концентрация хлорид-ионов на поверхности стали достигают критического значения, оксидная пленка может депассивироваться и начать коррозию [5–8]. Хорошо известно, что продукты коррозии, образующиеся на границе раздела бетон-сталь, могут привести к объемному расширению и, в конечном итоге, к растрескиванию бетонного покрытия. Коррозия также может вызывать уменьшение площади поперечного сечения арматуры и существенно влиять на ее механические свойства, в том числе на предел текучести, предел прочности и пластичность, что значительно уменьшает остаточный срок службы железобетонных изгибаемых элементов [9, 10].

Коррозия арматуры в большей степени изменяет геометрические характеристики

арматуры, нежели физико-механические характеристики стали. Расчетная площадь поперечного сечения поврежденной стальной арматуры представляется как [11]:

$$A_s^* = A_s - A_s^{cor}, \quad (1)$$

где  $A_s$  – площадь поперечного сечения стальной арматуры до коррозии;  $A_s^{cor}$  – расчетная площадь коррозионных повреждений поперечного сечения стальной арматуры.

С целью увеличения срока эксплуатации и силового сопротивления поврежденных железобетонных элементов современным решением является использование композитных материалов на основе стекло- и углепластиков при проведении ремонтно-восстановительных работ. Данные композитные материалы имеют высокие показатели прочности на растяжение, малый вес и высокую степень коррозионной стойкости. При включении элементов усиления в работу их волокна воспринимают силовое воздействие, а матрица перераспределяет нагрузку между волокнами и предохраняет от агрессивного воздействия окружающей среды [12–15].

Существует большое количество научных исследований, основанных на эмпирическом методе прогнозирования несущей способности усиленных железобетонных элементов, которые однако не имеют универсальной применимости, что противоречит получению более обобщенного решения. Тем не менее, проводятся исследования по прогнозированию параметров остаточной прочности с использованием методов мягких вычислений (искусственных нейронных сетей (ИНС), генетических алгоритмов, нечеткой логики, метода опорных векторов и т. д.), которые показали существенное улучшение прогнозируемого результата и оказались более надежным подходом.

Предполагается, что с учетом огромного количества данных, полученных в результате различных экспериментов на протяжении многих лет, надежные методы интеллектуального анализа данных, основанные на парадигмах вычислительного интеллекта и машинного обучения, способны преодолеть ограничения традиционных методов [16]. ИНС – это хорошо зарекомендовавшие себя технологии, которые применяются в самых разных приложениях, от распознавания образов до оптимизации. Одной из привлекательных особенностей ИНС является их способность выполнять нелинейные многомерные интерполяции. Эта особенность ИНС позволяет улавливать существующие нелинейные зависимости между входными и выходными параметрами. ИНС является

наиболее часто используемым методом в различных областях инженерных наук [17].

В настоящее время существуют исследования, в которых используются ИНС в качестве эффективного метода, обеспечивающего ее применимость в гражданском строительстве. В работе [18] представлена модель нейронной сети, которая прогнозирует работоспособность бетона с материалами, заменяющими цемент. Результаты их модели нейронной сети показали высокую сходимость с экспериментальными результатами и продемонстрировали высокую эффективность данного метода. В работах Римшина В.И. [19, 20] изучено применение искусственного интеллекта при обследовании зданий и сооружений для обнаружения существующих дефектов конструкций и дальнейшего их композитного усиления. В работе [21] исследовано применение ИНС для прогнозирования предельного несущего момента железобетонных плит при пожаре. Модель ИНС была построена, обучена и протестирована с использованием 294 наборов данных для плит, подвергшихся воздействию огня. Показано, что модель ИНС с высокой степенью точности предсказывает предельную нагрузку момента железобетонных плит при пожаре в рассматриваемом диапазоне входных параметров.

ИНС достаточно широко применяются при моделировании многих проблем гражданского строительства, однако нет исследований относительно прогнозирования несущей способности железобетонных элементов на различных стадиях жизненного цикла, включающих коррозионное повреждение стальной арматуры изгибаемых элементов с их последующим композитным усилением, что является предметом данного исследования.

**Методы.** Искусственные нейронные сети обычно представляются как системы тесно взаимосвязанных «нейронов», которые могут вычислять значения на основе входных данных [22]. Для создания нейронной сети использован программный продукт STATISTICA Neural Networks (SNN), разработанный компанией StatSoft.

Для разработки моделей ИНС была реализована последовательность следующих этапов:

1. Сбор данных о несущей способности железобетонных элементов: на данном этапе был собран и систематизирован массив данных, отражающих значения независимых переменных железобетонных изгибаемых элементов. Эти данные являются важными переменными, влияющими на изгибающий момент и

разрушающую нагрузку и должны учитываться при разработке модели нейронной сети.

2. Создание и подготовка базы данных: Следующим шагом была запись и подготовка обширной базы данных, включающей все собранные экспериментальные и расчетные данные. База данных была структурирована таким образом, чтобы обеспечить удобный доступ к информации и ее эффективное использование в процессе обучения нейронной сети. Подготовка данных включала их нормализацию и предварительную обработку для устранения возможных аномалий и ошибок измерений.

3. Разработка, обучение и тестирование моделей нейронных сетей: после подготовки данных была осуществлена разработка нескольких архитектур моделей нейронных сетей. Каждая из моделей была обучена на подготовленном наборе данных. Обучение включало многократную настройку параметров модели и корректировку весов связей между нейронами для минимизации ошибки прогнозирования. Кроме того, были проведены тестовые испытания моделей для оценки их точности и производительности на независимых наборах данных.

4. Анализ результатов и выбор оптимальной модели: на этапе анализа результатов оценивалась эффективность каждой из разработанных моделей. Основными критериями выбора оптимальной модели были минимальная ошибка прогнозирования, высокая точность и способность модели к обобщению. Анализ результатов позволил выбрать наиболее эффективную структуру нейронной сети, которая лучше всего справляется с задачей прогнозирования тепловых потерь.

5. Определение изгибающего момента и разрушающей нагрузки: на заключительном этапе с использованием выбранной модели нейронной сети были выполнены расчеты изгибающего момента и разрушающей нагрузки рассматриваемых изгибаемых элементов. Модель позволила определить величину изгибающего момента и разрушающей нагрузки с учетом всех собранных расчетных и экспериментальных данных.

База данных, используемая для обучения, была разделена на три группы (рис. 1, а):

Обучающая группа: 70 % всех данных было выделено для обучения модели. Этот набор данных использовался для корректировки параметров и весов модели, чтобы она могла точно прогнозировать на основе входных данных. Данные в этой группе были случайным образом выбраны из общей базы.

Тестовая группа: 15 % данных от общего объема использовались для тестирования модели. Этот набор данных был применен для оценки качества обучения и выявления возможных проблем в моделировании. Тестовая группа данных позволяла проверить, как модель ведет себя на данных, которые не были использованы в процессе обучения.

Группа валидации: последние 15 % данных были выделены для этапа валидации. Эта группа использовалась для оценки способности модели к обобщению и ее производительности на данных, которые ранее не использовались ни для обучения, ни для тестирования. Этап валидации был необходим для определения того, насколько хорошо модель будет справляться с реальными данными, отличающимися от обучающих.

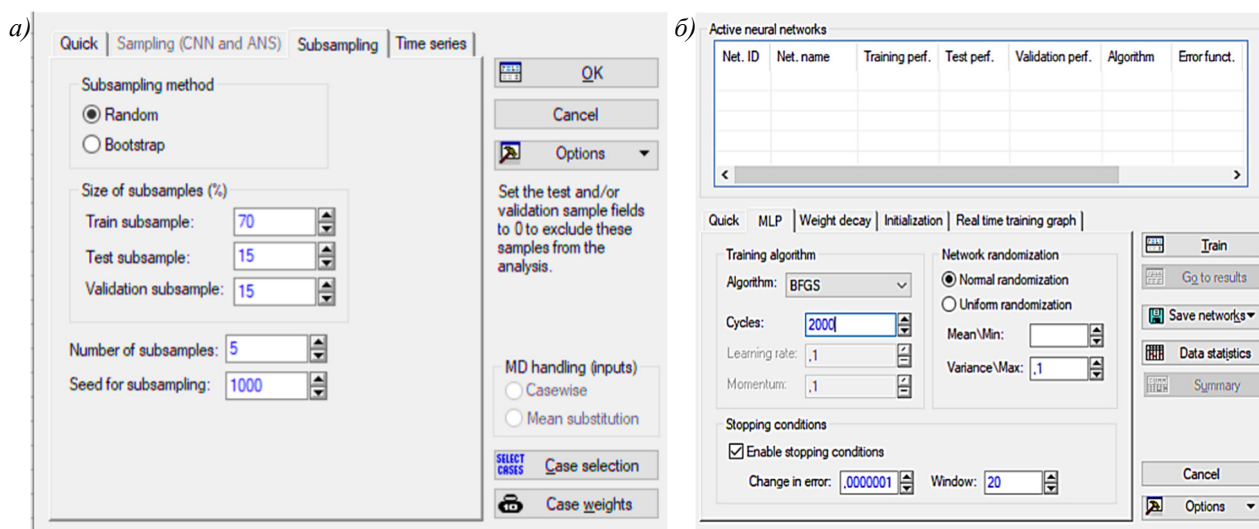


Рис. 1. Настройка параметров обучения модели ИНС: а – настройка количества нейронных сетей при обучении; б – настройка количества циклов обучения

Общий процесс обучения нейронной сети включал 2000 циклов (эпох) построения, как указано на рис. 1, б. Это означало, что модель проходила процесс обучения 2000 раз, каждый раз обновляя свои параметры и веса для улучшения качества прогнозирования.

Выходные данные после каждого этапа подвыборки представляли собой уменьшенные массивы данных, которые обрабатывались для повышения качества модели. На каждом шаге обучения данные проходили через слой подвыборки, где они фильтровались и уменьшались в размере перед передачей в следующий этап, что позволяло повысить точность и производительность модели.

Многослойный перцептрон (MLP) был выбран в качестве основной архитектуры ИНС из-за его способности эффективно решать задачи нелинейного многомерного прогнозирования. MLP обладает рядом преимуществ:

Способность к нелинейной интерполяции: MLP может моделировать сложные нелинейные зависимости между входными данными (например, прочность бетона, параметры арматуры, степень коррозии) и выходными данными (изгибающий момент, разрушающая нагрузка).

Гибкость в настройке параметров: В процессе обучения нейронной сети можно настроить количество слоев, количество нейронов в каждом слое и типы функций активации, что позволяет адаптировать модель к конкретной задаче.

Высокая точность прогнозирования: При правильной настройке MLP демонстрирует высокую точность прогнозов, что подтверждается низкими значениями средней абсолютной ошибки (MAE) и высоким соответствием прогнозируемых значений экспериментальным данным.

Способность к обучению на больших данных: MLP может эффективно обучаться на больших массивах данных, что особенно важно при наличии значительного объема экспериментальных данных для различных стадий жизненного цикла железобетонных элементов.

Процесс обучения был многократно повторен для получения оптимальной модели, наиболее точно отражающей зависимость между входными переменными и ожидаемыми результатами. В ходе каждой итерации обучения параметры модели корректировались для минимизации ошибки прогноза. Этот процесс продолжался до тех пор, пока не была достигнута заданная точность или не была найдена модель с наилучшей производительностью.

Для оценки качества полученных моделей был проведен статистический анализ выходных данных. Основным показателем для оценки точности прогнозирования выступала средняя абсолютная ошибка (MAE), которая измеряет среднее абсолютное отклонение прогнозируемых значений от фактических данных. Сравнение значений MAE для различных моделей позволило определить наиболее точную и надежную модель для дальнейшего использования в прогнозировании.

При построении сети испробован набор функций активации нейронов (линейная, логарифмическо-сигмоидная и т.д.). Функция ошибок SOS (Sum Of Squares) минимизирует среднеквадратическую ошибку полученной нейронной сети и вычисляется по формуле:

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

где  $y_i$  – выходное значение  $i$ -го нейрона выходного слоя;  $\hat{y}_i$  – требуемое значение  $i$ -го нейрона выходного слоя.

Из полученного набора ИНС пакет SNN предлагает пользователю самостоятельно выбрать сеть с наилучшими параметрами. Критерием отбора является показатель наименьшей ошибки обучения контрольной партии при одновременном учете соответствующих ошибок обучения тестовой и обучающей партий. Затем анализ полученных и прогнозных значений разрушающей нагрузки проводится графически и при помощи вычисления величины относительной погрешности. Получение удовлетворительных результатов является завершающим этапом создания нейросетевой моде.

Анализ данных по общей чувствительности инструментами программы выявляет независимые переменные, имеющие наибольшее влияние на расчетное значение разрушающей нагрузки  $F_{ult}$  и разрушающего момента  $M_{ult}$ . Отсутствие линейной зависимости между независимыми переменными подтверждают с помощью матрицы с парными коэффициентами корреляции. Визуальный анализ поверхности, построенной в STATISTICA для этих переменных, определяет набор регрессий, на основе которых будет выполнен подбор формулы для инженерных расчетов.

**Основная часть.** В данном исследовании для разработки ИНС были использованы данные, полученные в ходе ряда научных работ, направленных на изучение различных аспектов изменения несущей способности железобетонных конструкций. В частности, анализировались долговременные характеристики и прочность железобетонных

балок, поврежденных коррозией, а также влияние коррозии арматуры на гибкость и несущую способность конструкций [23–27]. Для повышения точности моделей ИНС учитывались результаты испытаний, которые включали в себя данные о поведении балок с различной степенью коррозионных повреждений и их восстановлении с использованием различных композитных материалов [28–32].

Кроме того, исследование охватило методы прогнозирования остаточной прочности железобетонных элементов, поврежденных коррозией. В этом контексте особое внимание уделялось изучению влияния хлорид-индуцированной коррозии на прочностные характеристики арматуры и остаточную несущую способность конструкций [33–36].

Анализ экспериментальных данных позволил разработать и проверить модели ИНС, способные точно прогнозировать изменения несущей способности с учетом различных условий эксплуатации и типов коррозионных повреждений.

Дополнительно, в исследовании рассматривались методы усиления железобетонных элементов с использованием композитных материалов, таких как углеволокно и полимерные композиты [37–40], что обеспечивало повышение их долговечности и устойчивости к нагрузкам [41–43]. Это позволило создать более точные нейросетевые модели, способные учитывать сложные нелинейные зависимости между множеством параметров.

Таблица 1

Результаты обучения нейронных сетей

№ п/п	Для прогнозирования $M_{ult}$				Для прогнозирования $F_{ult}$			
	Имя	Эффективность			Имя	Эффективность		
		тренировки	теста	валидации		тренировки	теста	валидации
1	MLP 284-30-10	0,999922	0,995913	0,988006	MLP 284-30-10	0,999838	0,996627	0,991081
2	MLP 284-30-10	0,999594	0,992118	0,989673	MLP 284-30-10	0,999954	0,995162	0,973873
3	MLP 284-30-10	0,999795	0,992909	0,992310	MLP 284-30-10	0,999092	0,988775	0,989723
4	MLP 284-30-10	0,999873	0,971586	0,974042	MLP 284-30-10	0,999848	0,979741	0,977229
5	MLP 284-30-10	0,999880	0,993680	0,996994	MLP 284-30-10	0,999882	0,993392	0,995320
6	MLP 284-25-10	0,999722	0,995287	0,990161	MLP 284-25-10	0,999782	0,995322	0,987784
7	MLP 284-25-10	0,999784	0,993678	0,989060	MLP 284-25-10	0,999716	0,993658	0,983077
8	MLP 284-25-10	0,999766	0,994148	0,993420	MLP 284-25-10	0,999650	0,991696	0,992685
9	MLP 284-25-10	0,999479	0,979182	0,984282	MLP 284-25-10	0,999279	0,970103	0,976101
10	MLP 284-25-10	0,999906	0,991932	0,995543	MLP 284-25-10	0,998589	0,989274	0,992692
11	MLP 284-20-10	0,999798	0,995500	0,988056	MLP 284-20-10	0,999536	0,993931	0,976836
12	MLP 284-20-10	0,999561	0,990958	0,982348	MLP 284-20-10	0,999723	0,994022	0,978554
13	MLP 284-20-10	0,999716	0,991941	0,992881	MLP 284-20-10	0,999315	0,994574	0,991685
14	MLP 284-20-10	0,999752	0,980177	0,986914	MLP 284-20-10	0,999301	0,981245	0,989627
15	MLP 284-20-10	0,999264	0,991829	0,995232	MLP 284-20-10	0,999644	0,992466	0,993724
16	MLP 284-15-10	0,998628	0,991551	0,980449	MLP 284-15-10	0,994385	0,985153	0,977751
17	MLP 284-15-10	0,999508	0,993384	0,980368	MLP 284-15-10	0,997166	0,987935	0,973077
18	MLP 284-15-10	0,999388	0,992349	0,993328	MLP 284-15-10	0,997357	0,990536	0,988127
19	MLP 284-15-10	0,995630	0,958286	0,954502	MLP 284-15-10	0,990113	0,965424	0,972163
20	MLP 284-15-10	0,999170	0,992453	0,994698	MLP 284-15-10	0,996987	0,987856	0,992558
21	MLP 284-10-10	0,986399	0,978637	0,965899	MLP 284-10-10	0,983183	0,977061	0,953678
22	MLP 284-10-10	0,997963	0,978623	0,966952	MLP 284-10-10	0,968846	0,952406	0,939923
23	MLP 284-10-10	0,977392	0,953614	0,966238	MLP 284-10-10	0,991981	0,978865	0,977706
24	MLP 284-10-10	0,963163	0,933696	0,947541	MLP 284-10-10	0,973996	0,940773	0,955331
25	MLP 284-10-10	0,998501	0,985240	0,989080	MLP 284-10-10	0,961710	0,951492	0,954032
26	MLP 284-5-10	0,873070	0,858881	0,863841	MLP 284-5-10	0,878781	0,862156	0,858238
27	MLP 284-5-10	0,865545	0,855580	0,820574	MLP 284-5-10	0,849257	0,818935	0,809539
28	MLP 284-5-10	0,815058	0,825742	0,792471	MLP 284-5-10	0,857492	0,844351	0,830335
29	MLP 284-5-10	0,840748	0,790865	0,837632	MLP 284-5-10	0,835337	0,815911	0,835298
30	MLP 284-5-10	0,853030	0,857495	0,857817	MLP 284-5-10	0,866444	0,855859	0,870861



Для прогнозирования несущей способности железобетонных изгибаемых элементов применено математическое моделирование искусственными нейронными сетями (ИНС). Входной слой созданной ИНС состоит из независимых переменных – призмной прочности бетона  $R_b$  (МПа), ширины поперечного сечения  $b$  (мм), высоты поперечного сечения  $h$  (мм), предела текучести стальной арматуры растянутой зоны  $R_s$  (МПа), коэффициента стального армирования  $\mu_s$  (%), снижения площади поперечного сечения арматуры вследствие коррозии  $\Delta A_s$ , прочности полимеркомпозитного холста  $R_f$  (МПа), коэффициента полимеркомпозитного

армирования  $\mu_f$  (%), расстояния от опоры до места приложения сосредоточенной силы  $l$  (мм). Выходной слой включает зависимые переменные – значения изгибающего момента  $M_{ult}$  (кН·м) и разрушающей нагрузки  $F_{ult}$ , кН. Количество испытаний должно превышать число независимых переменных более чем в 4–5 раз для обеспечения их статистической значимости

Для обучения нейронной сети применялся метод многократных подвыборок (cross-validation), архитектуру нейронной сети в виде многослойного персептрона (MLP), использующего от 5 до 30 нейронов на внутреннем слое сети (см. табл. 1), как представлено на рис. 2.

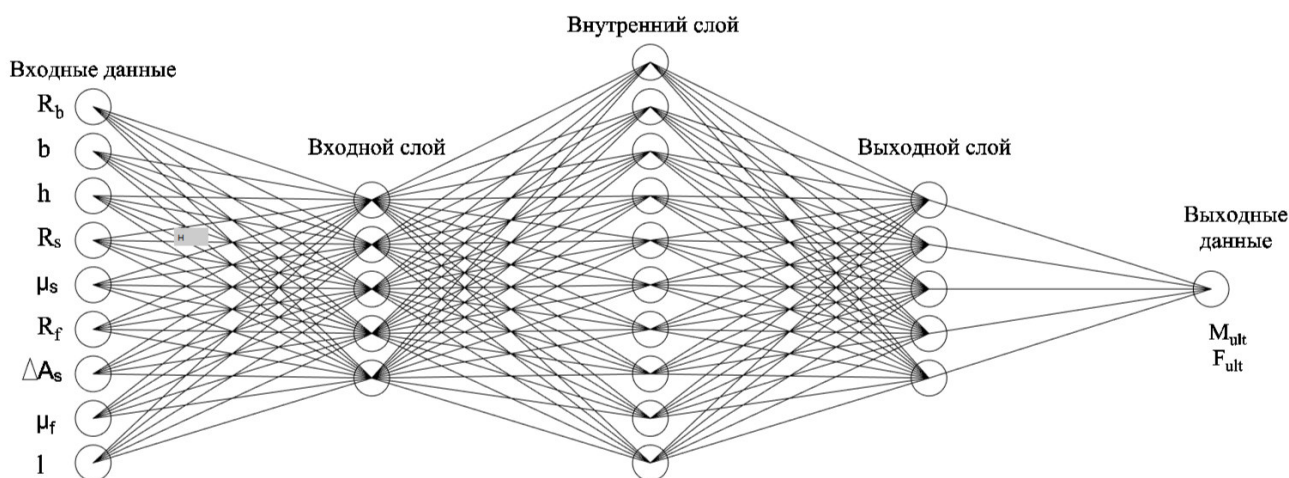


Рис. 2. Архитектура одной из созданных нейронных сетей (с 10 нейронами на внутреннем слое сети)

При анализе ошибок и производительности сетей на различных выборках (табл. 1) можно сделать вывод, что для набора обучающих данных, собранных на основании расчетных и экспериментальных исследований, наиболее подходящей является: для данных о изгибающем моменте – нейронная сеть 5, имеющая 30 нейронов на внутреннем слое, с высокими показателями эффективности как на этапе обучения (0,999880), так и на этапе тестирования (0,993680) и валидации (0,996994); для данных о разрушающей нагрузке – нейронная сеть 5, также имеющая 30 нейронов на внутреннем слое, с показателями эффективности как на этапе обучения (0,999882), так и на этапе тестирования (0,993392) и валидации (0,995320), что свидетельствует об их высокой точности и надежности.

Выбор данной сети обоснован тем, что ее прогнозы демонстрируют высокую степень соответствия фактическим значениям. Это подтверждается графиком прогнозов временных рядов для сети (рис. 3), на котором представлены

данные для тренировочной, тестовой и валидационной выборок.

Кроме того, гистограмма остатков (рис. 4) указывает на соответствие распределения ошибок нормальному закону распределения Гаусса-Лапласа. Это подтверждается наличием пика в центре гистограммы и относительно симметричными боковыми сторонами, что свидетельствует о сбалансированности предсказаний и отсутствии значимых систематических ошибок.

Дополнительно, точность модели подтверждается плотным распределением точек вдоль прямой линии на графике сравнения фактических и прогнозируемых значений (рис. 5).

Высокая концентрация точек около прямой линии указывает на то, что фактические значения практически совпадают с прогнозируемыми, что свидетельствует о минимальных отклонениях.

Полученные регрессионные модели допускают среднюю абсолютную ошибку (MAE) для набора данных изгибающего момента – 0,74 %; для разрушающей нагрузки – 0,84 %.

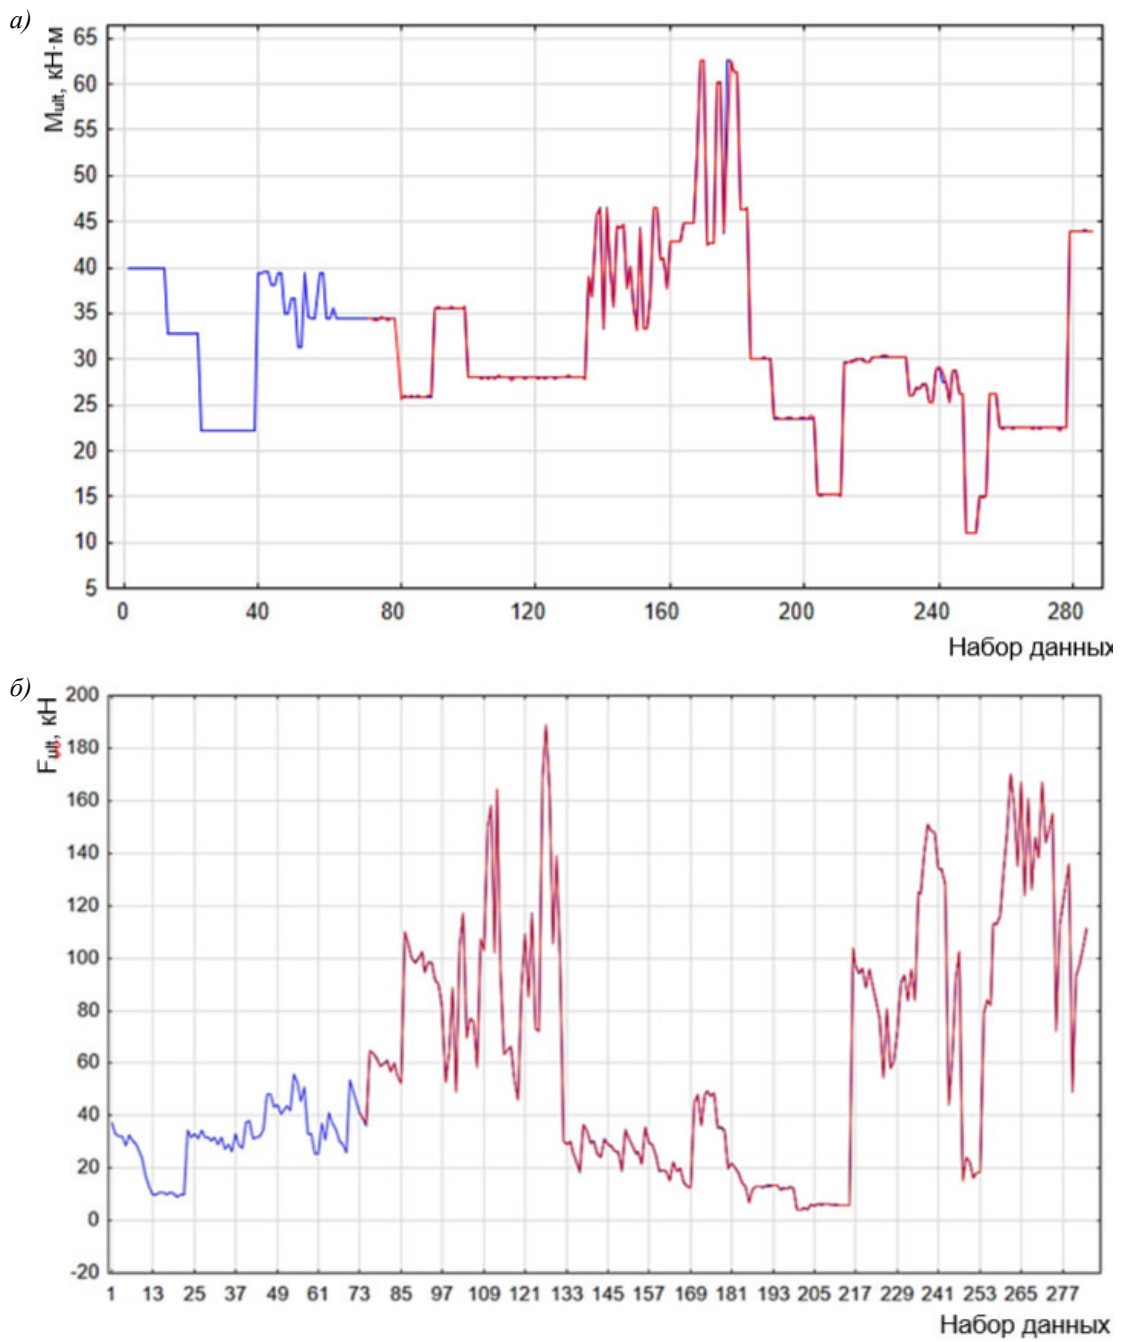


Рис. 3. График прогнозов временных рядов для сети с использованием тренировочной, тестовой и валидационной выборок:  
*a* – для набора данных изгибающего момента; *б* – для набора данных разрушающей нагрузки




Рис. 4. Гистограмма остатков: *a* – для набора данных изгибающего момента;  
*б* – для набора данных разрушающей нагрузки

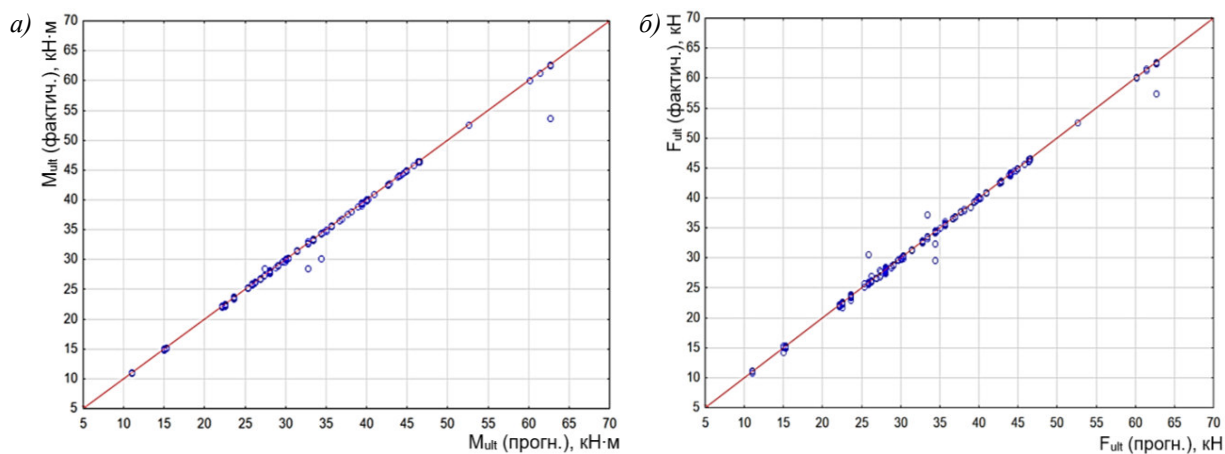


Рис. 5. Сравнение фактических и прогнозируемых значений: *а* – для набора данных изгибающего момента; *б* – для набора данных разрушающей нагрузки

**Выводы.** В процессе исследований было установлено, что одним из ключевых аспектов настройки моделей ИНС является определение оптимального количества нейронов на внутреннем слое сети. Результаты экспериментов показали, что оптимальное количество нейронов для эффективного прогнозирования составляет 30. Результаты показывают, что увеличение числа нейронов на внутреннем слое позволяет лучше моделировать сложные зависимости между входными и выходными переменными, но чрезмерное количество нейронов может привести к переобучению модели, что ухудшает ее способность к обобщению на новых данных.

Применение MLP при прогнозировании физико-механических характеристик железобетонных конструкций предлагает большую гибкость в настройке параметров, таких как количество слоев, число нейронов в каждом слое и тип функции активации, что позволяет адаптировать модель под конкретные задачи и условия эксплуатации. Этот подход обеспечивает высокую универсальность модели, позволяя ей эффективно обучаться на больших объемах данных, что особенно важно в контексте анализа железобетонных конструкций на различных стадиях их жизненного цикла.

Применение ИНС для прогнозирования несущей способности строительных конструкций, в частности железобетонных элементов, имеет несколько важных преимуществ. Во-первых, ИНС могут учитывать множество факторов, таких как коррозионные процессы и степень повреждения арматуры, что позволяет более точно предсказывать остаточную прочность материалов. Во-вторых, в отличие от традиционных методов, ИНС не требуют жестких предположений о функциональной форме зависимости между параметрами, что позволяет использовать их для более широкого спектра задач и условий

эксплуатации. В-третьих, разработанные модели позволяют повысить надежность конструкций за счет точного предсказания их предельных состояний и своевременного принятия мер по предотвращению разрушения.

Таким образом, использование ИНС, и в частности многослойных перцептронов, для прогнозирования несущей способности железобетонных элементов является перспективным направлением, которое обеспечивает высокую точность прогнозов, улучшает управление жизненным циклом конструкций и повышает их надежность и долговечность. Разработанные модели продемонстрировали свою эффективность, допуская MAE не более 0,85 %, что свидетельствует о возможности их применения для решения практических задач в строительной отрасли.

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Бондаренко В.М. Элементы диссипативной теории силового сопротивления железобетона // Строительная механика инженерных конструкций и сооружений. 2014. № 2. С. 47–57.
2. Кецко Е.С., Римшин В.И., Лесовик Р.В., Смоляго Г.А. Жизненный цикл здания образовательной организации с проверкой состояния несущих конструкций. Систем. требования: AdobeAcrobatReader. URL: <https://esj.today/PDF/58SAVN623.pdf> (дата обращения: 27.08.2024).
3. Римшин В.И., Соловьев А.К., Амелин П.А., Никитин А.А. Теория деградации в жизненном цикле зданий и сооружений []. Систем. требования: AdobeAcrobatReader. URL: <https://esj.today/PDF/45SAVN523.pdf> (дата обращения: 27.08.2024).
4. Смоляго Г.А., Фролов Н.В., Дронов А.В. Анализ коррозионных повреждений эксплуати-



руемых изгибаемых железобетонных конструкций зданий и сооружений // Вестник БГТУ им. В.Г. Шухова. 2019. № 1. С. 52–57. DOI: 10.12737/article\_5c506209065dd6.02007715.

5. Feng G., Jin Z., Jiang Y., Wang X., Zhu D. Localized corrosion propagation of steel in cracked mortar and long-term corrosion of steel reinforcement in cracked concrete in seawater environment // Corrosion Science. 2024. Vol. 228. 111793. DOI: 10.1016/j.corsci.2023.111793.

6. Римшин В.И., Сулейманова Л.А., Амелин П.А., Крючков А.А. Экспериментальные исследования изгибаемых железобетонных элементов, имеющих повреждения арматуры вследствие контакта с хлоридной агрессивной средой // Эксперт: теория и практика. 2023. № 3(22). С. 138–146. DOI: 10.51608/26867818\_2023\_3\_138.

7. Gómez-Luna G.F., López-Calvo H.Z., Bremner T.W., Fajardo-San Miguel G.J., Castro-Borges P., Montes-García P. Assessment of corrosion prevention methods for steel reinforcement embedded in concrete exposed to a natural marine environment // Construction and Building Materials. 2023. Vol. 385. 131514. DOI: 10.1016/j.conbuildmat.2023.131514.

8. Овчинников И.И. Современное состояние проблемы расчета армированных конструкций, подвергающихся воздействию агрессивных сред // Строительство уникальных зданий и сооружений. 2012. № 2(2). С. 46–60.

9. Zhang G., Tian Y., Zhao R., Liu Y., Shao Y., Feng H., Jin N., Jin X., Wu H., Yan D., Zhou Z., Wang Sh., Zhang Zh., Li B., Wang J. Dynamic self-balanced electrochemical model for non-uniform corrosion of steel reinforcement in concrete under combined effects of heat-moisture-chlorine-oxygen // Journal of Building Engineering. 2023. Vol. 80. 108117. DOI: 10.1016/j.jobe.2023.108117.

10. Selyaev V.P., Selyaev P.V., Sorokin E.V., Kechutkina E.L. Modeling of the reinforced concrete structure performance at joint influence of mechanical and chemical loads // IOP Conference Series: Materials Science and Engineering. 2018. Pp. 012–060. DOI 10.1088/1757-899X/456/1/012060.

11. Frolov N.V., Smolyago G.A. Reinforced concrete beams strength under power and environmental influences // Magazine of Civil Engineering. 2021. No. 3(103). 10303. DOI 10.34910/MCE.103.3.

12. Римшин В.И., Сулейманова Л.А., Амелин П.А., Фролов Н.В. Композитное усиление железобетонных изгибаемых элементов, поврежденных под воздействием хлоридной агрессивной среды // Эксперт: теория и практика. 2023. № 1(20). С. 29–34. DOI: 10.51608/26867818\_2023\_1\_29.

13. Меркулов С.И., Есипов С.М., Есипова Д.В. Экспериментальные исследования трещинообразования железобетонных балок, усиленных композитными материалами // Вестник Донбасской национальной академии строительства и архитектуры. 2019. № 3. С. 102–107.

14. Elghazy M., El Refai A., Ebead U., Nanni A. Effect of corrosion damage on the flexural performance of RC beams strengthened with FRCM composites // Compos. Struct. 2017. Vol. 180. Pp. 994–1006. DOI: 10.1016/j.compstruct.2017.08.069.

15. Al-Saidy A.H., Saadatmanesh H., El-Gamal S., Al-Jabri K.S., Waris B.M. Structural behavior of corroded RC beams with/without stirrups repaired with CFRP sheets // Materials and Structures / Matériaux et Constructions. 2016. Vol. 49. Pp. 3733–3747. DOI: 10.1617/s11527-015-0751-y.

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. Vol. 9. No 2. Pp. 159–172. DOI: 10.1007/s40069-015-0097-4/

17. Abdalla J.A., Elsanosi A., Abdelwahab A. Modelling and simulation of shear resistance of R/C beams using artificial neural network // J Franklin I. 2007. Vol. 344. Pp. 741–756. DOI: 10.1016/j.jfranklin.2005.12.005.

18. Bai J., Wild S., Ware J.A. Using neural networks to predict workability of concrete incorporating metakaolin and fly ash // Advances in Engineering Software. 2003. Vol. 34. Pp. 663–669. DOI: 10.1016/S0965-9978(03)00102-9.

19. 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). С. 101–107. DOI 10.51608/26867818\_2023\_4\_101.

20. Римшин В.И., Кучеренко В.А. Применение искусственного интеллекта при обследовании арматуры зданий и сооружений // Известия высших учебных заведений. Строительство. 2024. № 1(781). С. 39–46. DOI 10.32683/0536-1052-2024-781-1-39-46.

21. Erdem H. Prediction of the moment capacity of reinforced concrete slabs in fire using artificial neural networks // Advances in Engineering Software. 2010. Vol. 41. Pp. 270–276. DOI: 10.1016/j.advengsoft.2009.07.006.

22. Kumar E.P., Sharma E.P. Artificial Neural Networks – A Study // International Research Journal of Engineering and Technology. 2014. Vol. 2. Pp. 143–148.

23. Maaddawy T.E., Soudki K., Topper T. Long-term performance of corrosion-damaged reinforced concrete beams // *ACI Structural Journal*. 2005. Vol. 102. No. 5. Pp. 649–656.
24. Mangat P.S., Elgarf M.S. Flexural strength of concrete beams with corroding reinforcement // *ACI Structural Journal*. 1999. Vol. 96. No. 1. Pp. 149–159.
25. Попеско А.И. Коррозия железобетонных конструкций и их несущая способность // *Инженерные проблемы современного железобетона*. 1995. С. 299–304.
26. Jin W.L., Zhao Y.X. Test study on bending strength of corroded reinforced concrete beams // *Industrial Construction*. 2001. Vol. 31(5). Pp. 9–11.
27. Hui Y.L., Li R., Lin Z.S., Quan M.Y. Experimental studies on the property before and after corrosion of rebars in basic concrete members // *Industrial Construction*. 1997. Vol. 27(4). Pp. 14–18.
28. Cao F.B., Wang C.X., Liu L.G., Xin Y.D., Li J.H., Tian Z.G. Experimental study and rigidity analysis on corroded reinforced recycled concrete beams // *Building Structure*. 2015. Vol. 45(10). Pp. 49–55. DOI: 10.1007/s11709-020-0637-0.
29. Xia J., Jin W.L., Li L.Y. Effect of chloride-induced reinforcing steel corrosion on the flexural strength of reinforced concrete beams // *Magazine of Concrete Research*. 2012. Vol. 64(6). Pp. 471–485. DOI: 10.1680/mac.10.00169.
30. Azad A.K., Ahmad S., Al-Gohi B.H.A. Flexural strength of corroded reinforced concrete beams // *Magazine of Concrete Research*. 2010. Vol. 62(6). Pp. 405–414. DOI: 10.1680/mac.2010.62.6.405.
31. Azad A.K., Ahmad S., Azher S.A. Residual strength of corrosion-damaged reinforced concrete beams // *ACI Materials Journal*. 2007. Vol. 104(1). Pp. 40–47.
32. Shang D.F. Study on flexural behavior of corroded reinforced concrete beams. Dissertation for the Doctoral Degree. Shanghai: Tongji University, 2005. 115 p.
33. Rodriguez J., Ortega L.M., Casal J. Load carrying capacity of concrete structures with corroded reinforcement // *Construction & Building Materials*. 1997. Vol. 11(4). 239248.
34. Chen J. Study on degradation regularity of bearing capacity of RC beams under corrosive conditions // *Journal of Disaster Prevention and Mitigation Engineering*. 2013. Vol. 33. Pp. 83–87.
35. Zhang Z. Experimental study of bending behavior of corroded reinforced concrete beams. Dissertation for the Doctoral Degree. Shanghai: Shanghai Jiao Tong University, 2010. 156 p.
36. Смоляго Г.А., Крючков А.А., Дрокин С.В., Дронов А.В. Исследование аспектов хлоридной коррозии железобетонных конструкций // *Вестник БГТУ им. В.Г. Шухова*. 2014. № 2. С. 22–24.
37. Фролов Н.В. Экспериментальные исследования кинетики развития коррозионных повреждений бетона в изгибаемых железобетонных элементах при силовых и средовых воздействиях // *Вестник БГТУ им. В.Г. Шухова*. 2020. № 2. С. 34–43. DOI: 10.34031/2071-7318-2020-5-2-34-43.
38. Wang Y., Wu J. Flexural Behavior of Corroded Concrete Beams Strengthened with Carbon Fiber-Reinforced Polymer // *Materials*. 2023. Vol. 16. 4355. DOI: 10.3390/ma16124355.
39. Михуб А., Польской П.П., Маилян Д.Р., Блягоз А.М. Сопоставление опытной и теоретической прочности железобетонных балок, усиленных композитными материалами, с использованием разных методов расчета // *Новые технологии*. 2012. Вып. 4. С. 101–110.
40. Григорьева Я.Е. Экспериментальное исследование влияния внешнего армирования изгибаемых железобетонных балок углеволокном на прочность и жесткость конструкций // *Вестник МГСУ*. 2011. №8. С. 181–185.
41. Быков А.А., Третьякова А.Н., Калугин А.В., Балакирев А.А. Определение несущей способности изгибаемых элементов, усиленных композиционными материалами // *Промышленное и гражданское строительство*. 2011. № 7. С. 18–21.
42. Бокарев С.А., Костенко А.Н., Смердов Д.Н., Неровных А.А. Экспериментальные исследования при пониженных и повышенных температурах железобетонных образцов, усиленных полимерными композиционными материалами // *Наукоедение. Систем. требования: Adobe Acrobat Reader*. URL: <https://naukovedenie.ru/PDF/94tvn313.pdf> (дата обращения: 27.08.2024).
43. Vieira M.M., Santos A.R.S. Mont'alverne A.M., Bezerra L.M., Montenegro L.C.S., Cabral A.E.B. Experimental analysis of reinforced concrete beams strengthened in bending with carbon fiber reinforced polymer // *Revista IBRACON De Estruturas E Materiais*. 2016. Vol. 9(1). Pp. 123–152. DOI: 10.1590/S1983-41952016000100008

#### Информация об авторах

**Римшин Владимир Иванович**, доктор технических наук, профессор, член-корреспондент отделения строительных наук. E-mail: v.rimshin@niist.ru. Национальный исследовательский Московский государственный строительный университет. Россия, 129337, Москва, Ярославское шоссе, д. 26. Научно-исследовательский институт строительной физики Российской академии архитектуры и строительных наук. Россия, 127238, г. Москва, проезд Локомотивный, д. 21.

**Амелин Павел Андреевич**, ассистент кафедры строительства и городского хозяйства. E-mail: p.amelin@inbox.ru. Белгородский государственный технологический университет им. В.Г. Шухова. Россия, 308012, Белгород, ул. Костюкова, д. 46.

**Сулейманова Людмила Александровна**, доктор технических наук, профессор, заведующий кафедрой строительства и городского хозяйства. E-mail: ludmilasuleymanova@yandex.ru. Белгородский государственный технологический университет им. В.Г. Шухова. Россия, 308012, Белгород, ул. Костюкова, д. 46.

Поступила 07.08.2024 г.

© Римшин В.И., Амелин П.А., Сулейманова Л.А., 2024

<sup>1,2</sup>*Rimshin V.I.*, <sup>3,\*</sup>*Amelin P.A.*, <sup>3</sup>*Suleymanova L.A.*  
<sup>1</sup>*National Research Moscow State University of Civil Engineering*  
<sup>2</sup>*Research Institute of Building Physics*  
*of the Russian Academy of Architecture and Construction Sciences*  
<sup>3</sup>*Belgorod State Technological University named after V.G. Shukhov*  
*\*E-mail: p.amelin@inbox.ru*

## NEURAL NETWORK FORECASTING OF THE LOAD-BEARING CAPACITY OF REINFORCED CONCRETE ELEMENTS

**Abstract.** *The article is devoted to the study of the force resistance of reinforced concrete bending elements at various stages of their life cycle, taking into account corrosion damage to the reinforcement and subsequent composite reinforcement. The paper considers changes in the characteristics of reinforced concrete structures under the influence of operational and aggressive environmental factors, which leads to a decrease in their bearing capacity. The main attention is paid to the corrosion of reinforcing steel, which causes cracking of the concrete coating and a decrease in the cross-section of the reinforcement, reducing the durability of the structure. To predict the residual strength and bearing capacity of reinforced concrete elements, an approach based on the use of artificial neural networks is proposed. Forecasting was carried out using artificial neural networks in the Statistica software package. Multilayer perceptron models were developed and tested using test data for reinforced concrete beams with various damages and reinforcements. Artificial neural network models were validated using cross-validation and showed high stability to changes in input data, which confirms their suitability for practical application in civil engineering for assessing the residual bearing capacity. The use of artificial neural networks allows taking into account nonlinear dependencies between parameters and improves predicted results, which makes them a more reliable tool compared to traditional methods.*

**Keywords:** *reinforced concrete structures, reinforcement corrosion, artificial neural networks, strength prediction, multilayer perceptron, composite reinforcement, life cycle modeling*

### REFERENCES

1. Bondarenko V.M. Elements of the dissipative theory of force resistance of reinforced concrete [Elementy dissipativnoj teorii silovogo soprotivleniya zhelezobetona]. Structural mechanics of engineering structures and constructions. 2014. No. 2. Pp. 47–57. (rus)
2. Ketsko E.S., Rimshin V.I., Lesovik R.V., Smolyago G.A. Life cycle of the building of an educational organization with checking the condition of load-bearing structures [ZHiznennyj cikl zdaniya obrazovatel'noj organizacii s proverkoj sostoyaniya nesushchih konstrukcij]. Bulletin of Eurasian Science. System requirements: AdobeAcrobatReader. URL: <https://esj.today/PDF/58SAVN623.pdf> (Accessed 27 august 2024) (rus)
3. Rimshin V.I., Soloviev A.K., Amelin P.A., Nikitin A.A. Theory of degradation in the life cycle of buildings and structures [Teoriya degradacii v zhiznennom cikle zdaniy i sooruzhenij]. Bulletin of

Eurasian Science. System requirements: AdobeAcrobatReader. URL: <https://esj.today/PDF/45SAVN523.pdf> (Accessed 27 august 2024) (rus)

4. Smolyago G.A., Frolov N.V., Dronov A.V. Analysis of corrosion damage to operated bending reinforced concrete structures of buildings and structures [Analiz korrozionnyh povrezhdenij ekspluatiruemyh izgibaemyh zhelezobetonnih konstrukcij zdaniy i sooruzhenij]. Bulletin of BSTU named after V.G. Shukhov. 2019. No. 1. Pp. 52–57. DOI: 10.12737/article\_5c506209065dd6.02007715. (rus)

5. Feng G., Jin Z., Jiang Y., Wang X., Zhu D. Localized corrosion propagation of steel in cracked mortar and long-term corrosion of steel reinforcement in cracked concrete in seawater environment. Corrosion Science. 2024. Vol. 228. 111793. DOI: 10.1016/j.corsci.2023.111793.

6. Rimshin V.I., Suleimanova L.A., Amelin P.A., Kryuchkov A.A. Experimental studies of bending reinforced concrete elements with damaged reinforcement due to contact with a chloride aggressive environment [Eksperimental'nye issledovaniya izgibaemyh zhelezobetonnyh elementov, imeyushchih povrezhdeniya armatury vsledstvie kontakta s hlорidnoy agressivnoy sredoy]. *Expert: Theory and Practice*. 2023. No. 3(22). Pp. 138–146. DOI: 10.51608/26867818\_2023\_3\_138. (rus)
7. Gómez-Luna G.F., López-Calvo H.Z., Bremner T.W., Fajardo-San Miguel G.J., Castro-Borges P., Montes-García P. Assessment of corrosion prevention methods for steel reinforcement embedded in concrete exposed to a natural marine environment. *Construction and Building Materials*. 2023. Vol. 385. 131514. DOI: 10.1016/j.conbuildmat.2023.131514.
8. Ovchinnikov I.I. Current state of the problem of calculating reinforced structures exposed to aggressive environments [Sovremennoe sostoyanie problemy rascheta armirovannyh konstrukcij, podvergayushchihsvya vozdeystviyu agressivnyh sred]. *Construction of unique buildings and structures*. 2012. No. 2(2). Pp. 46–60. (rus)
9. Zhang G., Tian Y., Zhao R., Liu Y., Shao Y., Feng H., Jin N., Jin X., Wu H., Yan D., Zhou Z., Wang Sh., Zhang Zh., Li B., Wang J. Dynamic self-balanced electrochemical model for non-uniform corrosion of steel reinforcement in concrete under combined effects of heat-moisture-chlorine-oxygen. *Journal of Building Engineering*. 2023. Vol. 80. 108117. DOI: 10.1016/j.job.2023.108117.
10. Selyaev V.P., Selyaev P.V., Sorokin E.V., Kechutkina E.L. Modeling of the reinforced concrete structure performance at joint influence of mechanical and chemical loads. *IOP Conference Series: Materials Science and Engineering*. 2018. Pp. 012–060. DOI: 10.1088/1757-899X/456/1/012060.
11. Frolov N.V., Smolyago G.A. Reinforced concrete beams strength under power and environmental influences. *Magazine of Civil Engineering*. 2021. No. 3(103). 10303. DOI: 10.34910/MCE.103.3.
12. Rimshin V.I., Suleimanova L.A., Amelin P.A., Frolov N.V. Composite reinforcement of reinforced concrete bending elements damaged under the influence of a chloride aggressive environment [Kompozitnoe usilenie zhelezobetonnyh izgibaemyh elementov, povrezhdennyh pod vozdeystviem hlорidnoy agressivnoy sredy]. *Expert: theory and practice*. 2023. No. 1 (20). Pp. 29–34. DOI: 10.51608/26867818\_2023\_1\_29. (rus)
13. Merkulov S.I., Esipov S.M., Esipova D.V. Experimental studies of cracking in reinforced concrete beams reinforced with composite materials [Eksperimental'nye issledovaniya treshchinoobrazovaniya zhelezobetonnyh balok, usilennyh kompozitnymi materialami]. *Bulletin of the Donbass National Academy of Civil Engineering and Architecture*. 2019. No. 3. Pp. 102–107. (rus)
14. Elghazy M., El Refai A., Ebead U., Nanni A. Effect of corrosion damage on the flexural performance of RC beams strengthened with FRCM composites. *Compos. Struct*. 2017. Vol. 180. Pp. 994–1006. DOI: 10.1016/j.compstruct.2017.08.069.
15. Al-Saidy A.H., Saadatmanesh H., El-Gamal S., Al-Jabri K.S., Waris B.M. Structural behavior of corroded RC beams with/without stirrups repaired with CFRP sheets. *Materials and Structures / Materiaux et Constructions*. 2016. Vol. 49. Pp. 3733–3747. DOI: 10.1617/s11527-015-0751-y.
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. Vol. 9. No 2. Pp. 159–172. DOI: 10.1007/s40069-015-0097-4/
17. Abdalla J.A., Elsanosi A., Abdelwahab A. Modelling and simulation of shear resistance of R/C beams using artificial neural network. *J Franklin I*. 2007. Vol. 344. Pp. 741–756. DOI: 10.1016/j.jfranklin.2005.12.005.
18. Bai J., Wild S., Ware J.A. Using neural networks to predict workability of concrete incorporating metakaolin and fly ash. *Advances in Engineering Software*. 2003. Vol. 34. Pp. 663–669. DOI: 10.1016/S0965-9978(03)00102-9.
19. Rimshin V.I., Soloviev A.K., Suleimanova L.A., Amelin P.A. Neural network forecasting of physical and mechanical characteristics of composite materials used to strengthen building structures [Nejrosetevoe prognozirovanie fiziko-mekhanicheskikh harakteristik kompozitnyh materialov ispol'zuemyh dlya usileniya stroitel'nyh konstrukcij]. *Expert: Theory and Practice*. 2023. No. 4 (23). Pp. 101–107. DOI: 10.51608/26867818\_2023\_4\_101. (rus)
20. Rimshin V.I., Kucherenko V.A. Application of artificial intelligence in the inspection of reinforcement of buildings and structures [Primenenie iskusstvennogo intellekta pri obsledovanii armatury zdaniy i sooruzhenij]. *Izvestiya vysshih uchebnyh zavedenij. Stroitel'stvo*. 2024. No. 1 (781). Pp. 39–46. DOI: 10.32683/0536-1052-2024-781-1-39-46. (rus)
21. Erdem H. Prediction of the moment capacity of reinforced concrete slabs in fire using artificial neural networks // *Advances in Engineering Software*. 2010. Vol. 41. Pp. 270–276. DOI: 10.1016/j.advengsoft.2009.07.006.

22. Kumar E.P., Sharma E.P. Artificial Neural Networks – A Study // International Research Journal of Engineering and Technology. 2014. Vol. 2. Pp. 143–148.
23. Maaddawy T.E., Soudki K., Topper T. Long-term performance of corrosion-damaged reinforced concrete beams. *ACI Structural Journal*. 2005. Vol. 102. No. 5. Pp. 649–656.
24. Mangat P.S., Elgarf M.S. Flexural strength of concrete beams with corroding reinforcement. *ACI Structural Journal*. 1999. Vol. 96. No. 1. Pp. 149–159.
25. Popesko A.I. Corrosion of reinforced concrete structures and their load-bearing capacity [Korrozija zhelezobetonnyh konstrukcij i ih nesushchaya sposobnost']. Engineering problems of modern reinforced concrete. 1995. Pp. 299–304. (rus)
26. Jin W.L., Zhao Y.X. Test study on bending strength of corroded reinforced concrete beams. *Industrial Construction*. 2001. Vol. 31(5). Pp. 9–11.
27. Hui Y.L., Li R., Lin Z.S., Quan M.Y. Experimental studies on the property before and after corrosion of rebars in basic concrete members. *Industrial Construction*. 1997. Vol. 27(4). Pp. 14–18.
28. Cao F.B., Wang C.X., Liu L.G., Xin Y.D., Li J.H., Tian Z.G. Experimental study and rigidity analysis on corroded reinforced recycled concrete beams. *Building Structure*. 2015. Vol. 45(10). Pp. 49–55. DOI: 10.1007/s11709-020-0637-0.
29. Xia J., Jin W.L., Li L.Y. Effect of chloride-induced reinforcing steel corrosion on the flexural strength of reinforced concrete beams. *Magazine of Concrete Research*. 2012. Vol. 64(6). Pp. 471–485. DOI: 10.1680/mac.10.00169.
30. Azad A.K., Ahmad S., Al-Gohi B.H.A. Flexural strength of corroded reinforced concrete beams. *Magazine of Concrete Research*. 2010. Vol. 62(6). Pp. 405–414. DOI: 10.1680/mac.2010.62.6.405.
31. Azad A.K., Ahmad S., Azher S.A. Residual strength of corrosion-damaged reinforced concrete beams. *ACI Materials Journal*. 2007. Vol. 104(1). Pp. 40–47.
32. Shang D.F. Study on flexural behavior of corroded reinforced concrete beams. Dissertation for the Doctoral Degree. Shanghai: Tongji University, 2005. 115 p.
33. Rodriguez J., Ortega L.M., Casal J. Load carrying capacity of concrete structures with corroded reinforcement. *Construction & Building Materials*. 1997. Vol. 11(4). 239248.
34. Chen J. Study on degradation regularity of bearing capacity of RC beams under corrosive conditions. *Journal of Disaster Prevention and Mitigation Engineering*. 2013. Vol. 33. Pp. 83–87.
35. Zhang Z. Experimental study of bending behavior of corroded reinforced concrete beams. Dissertation for the Doctoral Degree. Shanghai: Shanghai Jiao Tong University, 2010. 156 p.
36. Smolyago G.A., Kryuchkov A.A., Drokin S.V., Dronov A.V. Study of aspects of chloride corrosion of reinforced concrete structures [Issledovanie aspektov hloridnoj korrozii zhelezobetonnyh konstrukcij]. *Bulletin of the Belgorod State Technological University named after V.G. Shukhov*. 2014. No. 2. Pp. 22–24. (rus)
37. Frolov N.V. Experimental studies of the kinetics of development of corrosion damage to concrete in bending reinforced concrete elements under force and environmental influences [Eksperimental'nye issledovaniya kinetiki razvitiya korroziionnyh povrezhdenij betona v izgibaemyh zhelezobetonnyh elementah pri silovyh i sredovyh vozdeystviyah]. *Bulletin of BSTU named after V.G. Shukhov*. 2020. No. 2. Pp. 34–43. DOI: 10.34031/2071-7318-2020-5-2-34-43. (rus)
38. Wang Y., Wu J. Flexural Behavior of Corroded Concrete Beams Strengthened with Carbon Fiber-Reinforced Polymer. *Materials*. 2023. Vol. 16. 4355. DOI: 10.3390/ma16124355.
39. Mihub A., Polskoy P.P., Mailyan D.R., Blagoz A.M. Comparison of experimental and theoretical strength of reinforced concrete beams reinforced with composite materials using different calculation methods [Sopostavlenie opytnoj i teoreticheskoj prochnosti zhelezobetonnyh balok, usilennyh kompozitnymi materialami, s ispol'zovaniem raznyh metodov rascheta]. *Novye tekhnologii*. 2012. Issue 4. Pp. 101–110. (rus)
40. Grigorieva Ya.E. Experimental study of the effect of external reinforcement of bending reinforced concrete beams with carbon fiber on the strength and rigidity of structures [Eksperimental'noe issledovanie vliyaniya vneshnego armirovaniya izgibaemyh zhelezobetonnyh balok uglevoloknom na prochnost' i zhestkost' konstrukcij]. *Bulletin of MGSU*. 2011. No. 8. Pp. 181–185. (rus)
41. Bykov A.A., Tretyakova A.N., Kalugin A.V., Balakirev A.A. Determination of the bearing capacity of bending elements reinforced with composite materials [Opredelenie nesushchej sposobnosti izgibaemyh elementov, usilennyh kompozitsionnymi materialami]. *Industrial and Civil Engineering*. 2011. No. 7. Pp. 18–21. (rus)
42. Bokarev S.A., Kostenko A.N., Smerdov D.N., Nerovnykh A.A. Experimental studies at low and high temperatures of reinforced concrete samples reinforced with polymer composite materials [Eksperimental'nye issledovaniya pri ponizhennyh i povyshennyh temperaturah zhelezobetonnyh obrazcov, usilennyh polimernymi kompozitsionnymi materialami]. *Naukovedenie*. System requirements:



AdobeAcrobatReader. URL: <https://naukovedenie.ru/PDF/94tvn313.pdf> (Accessed 27 august 2024) (rus)

*Information about the authors*

**Rimshin, Vladimir I.** Doctor of Technical Sciences, Professor, Corresponding Member of the Department of Construction Sciences. E-mail: [v.rimshin@niist.ru.ru](mailto:v.rimshin@niist.ru.ru). National Research Moscow State University of Civil Engineering. Russia, 129337, Moscow, Yaroslavskoe shosse, 26/ Research Institute of Building Physics of the Russian Academy of Architecture and Construction Sciences. Russia, 127238, Moscow, Lokomotivny proezd, 21.

**Amelin, Pavel A.** Assistant of the Department of Construction and Urban Economy. E-mail: [p.amelin@inbox.ru](mailto:p.amelin@inbox.ru). Belgorod State Technological University named after V.G. Shukhov. Russia, 308012, Belgorod st. Kostyukova, 46.

**Suleymanova, Lyudmila A.** DSc, Professor, Head of the Department of Construction and Urban Economy. E-mail: [ludmilasuleimanova@yandex.ru](mailto:ludmilasuleimanova@yandex.ru). Belgorod State Technological University. V.G. Shukhov. Russia, 308012, Belgorod, st. Kostyukova, 46.

---

*Received 07.08.2024*

**Для цитирования:**

Римшин В.И., Амелин П.А., Сулейманова Л.А. Нейросетевое прогнозирование несущей способности железобетонных элементов // Вестник БГТУ им. В.Г. Шухова. 2024. № 11. С. 42–55. DOI: 10.34031/2071-7318-2024-9-11-42-55

**For citation:**

Rimshin V.I., Amelin P.A., Suleymanova L.A. Neural network forecasting of the load-bearing capacity of reinforced concrete elements. Bulletin of BSTU named after V.G. Shukhov. 2024. No. 11. Pp. 42–55. DOI: 10.34031/2071-7318-2024-9-11-42-55