

АНАЛИТИЧЕСКИЕ И ЧИСЛЕННЫЕ МЕТОДЫ РАСЧЕТА КОНСТРУКЦИЙ ANALYTICAL AND NUMERICAL METHODS OF STRUCTURAL ANALYSIS

DOI: 10.22363/1815-5235-2026-22-2-93-104

EDN: JZQSKW

Научная статья / Research article

Прогнозирование температурных напряжений в твердеющих массивных монолитных конструкциях по данным мониторинга температур

В.С. Тюрина^{ORCID}, А.С. Чепурненко^{ORCID}, Б.М. Языев^{ORCID}

Донской государственный технический университет, Ростов-на-Дону, Российская Федерация

✉ anton_chepurnenk@mail.ru

Поступила в редакцию: 30 января 2026 г.

Доработана: 13 марта 2026 г.

Принята к публикации: 20 марта 2026 г.

Аннотация. Температурные напряжения в процессе твердения массивных монолитных конструкций, являются значимым фактором риска раннего трещинообразования, что напрямую влияет на долговечность и несущую способность зданий и сооружений. Упрощенные методы расчёта, основанные на гипотезах о характере распределения температур и напряжений, часто демонстрируют невысокую точность, что актуализирует поиск более совершенных подходов к прогнозированию напряжённого состояния. В настоящей работе предложен метод прогнозирования температурных напряжений в массивных монолитных фундаментных плитах на основе искусственных нейронных сетей (ИНС) с использованием данных мониторинга температур в режиме реального времени. Для этого были исследованы три архитектуры ИНС — рекуррентная, прямого распространения и каскадная. Для обучения сформирован обширный датасет, включающий 499 800 записей, полученных на основе параметрических конечно-элементных расчётов. Модели продемонстрировали высокую точность предсказания, при этом наилучший результат показала нейросеть прямого распространения со среднеквадратической ошибкой 0,025 МПа². Верификация на экспериментальных данных подтвердила практическую применимость подхода, включая способность прогнозировать момент образования трещин. Разработанный метод позволяет эффективно и с меньшими вычислительными затратами, по сравнению с традиционным моделированием, анализировать данные мониторинга температур в реальном времени, что способствует повышению надёжности строительных конструкций.

Ключевые слова: массивные монолитные конструкции, фундаментная плита, температурные напряжения, машинное обучение, мониторинг, раннее трещинообразование

Вклад авторов: Тюрина В.С. — проведение исследования, обработка данных, графическое оформление, написание текста;

Чепурненко А.С. — программное обеспечение, подготовка текста статьи, рецензирование и редактирование; Языев Б.М. — общее научное руководство, формулировка концепции исследования. Авторы ознакомлены с окончательной версией статьи и одобрили ее.

Заявление о конфликте интересов. Авторы заявляют об отсутствии конфликта интересов.

Тюрина Василина Сергеевна, кандидат технических наук, доцент кафедры строительной механики и теории сооружений, Донской государственный технический университет, Российская Федерация, 344003, г. Ростов-на-Дону, пл. Гагарина, д. 1; eLIBRARY SPIN-код: 8808-2687, ORCID: 0009-0001-6399-401X; e-mail: vasilina.93@mail.ru

Чепурненко Антон Сергеевич, доктор технических наук, профессор кафедры строительной механики и теории сооружений, Донской государственный технический университет, Российская Федерация, 344003, г. Ростов-на-Дону, пл. Гагарина, д. 1; eLIBRARY SPIN-код: 7149-7981, ORCID: 0000-0002-9133-8546; e-mail: anton_chepurnenk@mail.ru

Языев Батыр Меретович, доктор технических наук, профессор кафедры строительной механики и теории сооружений, Донской государственный технический университет, Российская Федерация, 344003, Ростов-на-Дону, пл. Гагарина, д. 1; eLIBRARY SPIN-код: 5970-5350, ORCID: 0000-0002-5205-1446; e-mail: ps62@yandex.ru

© Тюрина В.С., Чепурненко А.С., Языев Б.М., 2026

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License
<https://creativecommons.org/licenses/by-nc/4.0/legalcode>

Заявление о доступности данных. Обучающий датасет доступен для скачивания по ссылке: <https://doi.org/10.13140/RG.2.2.33439.62880/>

Финансирование. Исследование выполнено за счет гранта Российского научного фонда № 25-19-00164, <https://rscf.ru/project/25-19-00164/>

Для цитирования: Тюрин В.С., Чепурненко А.С., Языев Б.М. Прогнозирование температурных напряжений в твердеющих массивных конструкциях по данным мониторинга температур // Строительная механика инженерных конструкций и сооружений. 2026. Т. 22. № 2. С. 93–104. <http://doi.org/10.22363/1815-5235-2026-22-2-93-104> EDN: JZQSKW

Prediction of Thermal Stress in Hardening Mass Concrete Structures Using Temperature Monitoring Data

Vasilina S. Tyurina^{ID}, Anton S. Chepurnenko^{✉ ID}, Batyr M. Yazyev^{ID}

Don State Technical University, Rostov-on-Don, Russian Federation

✉ anton_chepurnenk@mail.ru

Received: January 30, 2026

Revised: March 13, 2026

Accepted: March 20, 2026

Abstract. Thermal stress during the hardening of mass concrete structures is a significant risk factor for early cracking, which directly impacts the durability and load-bearing capacity of buildings and structures. Simplified calculation methods based on hypotheses about the pattern of temperature and stress distributions often demonstrate low accuracy, necessitating the search for more advanced approaches to stress state prediction. This paper proposes a method for predicting the thermal stress in mass concrete foundation slabs based on artificial neural networks (ANNs) using real-time temperature monitoring data. Three ANN architectures were investigated: recurrent, feedforward, and cascade. A comprehensive dataset, including 499,800 records obtained from parametric finite element calculations, was compiled for training. The models demonstrated high prediction accuracy, with the feedforward neural network achieving the best result, with a mean-square error of 0.025 MPa². Verification using experimental data confirmed the practical applicability of the approach, including the ability to predict the timing of crack formation. The developed method enables efficient and less computationally expensive analysis of temperature monitoring data in real time compared to traditional modeling, thereby improving the reliability of building structures.

Keywords: mass concrete structures, foundation slab, thermal stresses, machine learning, monitoring, early crack formation

Authors' contribution: Tyurina V.S. — investigation, data processing, graphic design, text writing; Chepurnenko A.S. — software, text draft, review and editing; Yazyev B.M. — supervision, conceptualization. The authors read and approved the final version of the article.

Conflicts of interest. The authors declare that there is no conflict of interest.

A statement about data availability. The training dataset is available for download at: <https://doi.org/10.13140/RG.2.2.33439.62880/>

Funding. The study was supported by the grant of the Russian Science Foundation No. 25-19-00164, <https://rscf.ru/project/25-19-00164/>

For citation: Tyurina VS, Chepurnenko AS, Yazyev BM. Prediction of thermal stress in hardening mass concrete structures using temperature monitoring data. *Structural Mechanics of Engineering Constructions and Buildings*. 2026;22(2):93–104. <http://doi.org/10.22363/1815-5235-2026-22-2-93-104> EDN: JZQSKW

1. Введение

Широко распространенной проблемой для массивных бетонных и железобетонных конструкций является образование температурных трещин в раннем возрасте. При гидратации цемента выделяется большое количество тепла, вызывая неравномерный нагрев: ядро конструкции нагревается значительно сильнее поверхности. При последующем охлаждении возникают растягивающие напряжения, превышающие прочность молодого бетона, что и приводит к растрескиванию [1; 2]. Это снижает прочность, долговечность, эстетику сооружений и повышает риски коррозии [3].

Наиболее распространенным инструментом для оценки риска раннего трещинообразования является конечно-элементное моделирование. Оно позволяет анализировать эволюцию температурных полей и напряжений с учетом изменения ключевых свойств бетона во времени. Особенно критичным является учет зависимости прочностных и деформативных характеристик бетона от времени и условий твердения, так как игнорирование этого фактора приводит к некорректной оценке НДС [4–6].

Недостатком конечно-элементного моделирования является невозможность учета неопределенности входных данных, включая температуру окружающей среды и основания, скорость ветра, варьирова-

ние тепловыделения бетона при использовании цементов различных поставщиков и т.д. Вариабельность входных данных может привести к существенному отклонению фактических температур и напряжений в конструкции от ожидаемых. В существующих системах мониторинга состояния массивных конструкций (Maturix¹, Giatec SmartRock²), как правило, выполняются замеры только температур, но не напряжений [7]. Напряжения могут быть определены косвенно по деформациям, однако датчики для определения деформаций весьма сложны и дороги, так как они должны быть способны корректировать показания с учетом температуры [8]. Поэтому актуальной является задача оперативной оценки фактических напряжений в конструкции по данным мониторинга температур в режиме реального времени. Такая оценка позволяет своевременно принять меры по недопущению раннего трещинообразования, включая дополнительную теплоизоляцию поверхностей для снижения температурных градиентов в случае, когда напряжения приближаются к опасным уровням [9].

В [10] была предложена упрощенная методика оценки температурных напряжений в массивных монолитных фундаментных плитах. Вместо традиционного подхода, основанного на разности температур между центром и поверхностью [11–14], предложенный метод использует данные по температурам в трех характерных точках по толщине плиты (нижняя, средняя и верхняя). Формулы были проверены с помощью численного моделирования и показали высокую точность для плит толщиной до 2 м. Значительные погрешности при толщине плиты 2 м и более связаны с используемой гипотезой о параболическом распределении температур и напряжений по толщине. Исследование направлено на преодоление данного ограничения с помощью методов машинного обучения. Отметим, что ранее методы машинного обучения использовались только для прогнозирования тепловыделения бетона [15], его коэффициента теплопроводности [16] и прочностных характеристик [17–18], оценки температурного перепада между центром и поверхностью конструкции [19], определения максимального уровня напряжений при фиксированных входных данных [20], проектирования рационального состава бетонной смеси [21–24].

Целью исследования — разработка и апробация метода прогнозирования температурных напряжений в массивных монолитных фундаментных плитах на основе ограниченных данных мониторинга температур в характерных точках по толщине с использованием искусственных нейронных сетей. В рамках поставленной цели решены следующие задачи:

- 1) создание представительного обучающего датасета на основе параметрических конечно-элементных расчетов, охватывающего вариации геометрических, прочностных и теплофизических параметров;
- 2) разработка и обучение трех архитектур искусственных нейронных сетей (рекуррентной, прямого распространения и каскадной) для прогнозирования напряжений по данным мониторинга температур;
- 3) оценка точности и сравнительной эффективности предложенных моделей на основе метрик качества обучения и анализа графиков регрессии;
- 4) выполнение верификации разработанных моделей на экспериментальных данных для реальной фундаментной плиты.

2. Методы

Средой для реализации моделей машинного обучения выступает MATLAB R2021a (пакет Neural Network Toolbox). В качестве входных параметров моделей машинного обучения выбраны 7 величин: температуры в трех точках плиты по толщине (T_{bot} у нижней поверхности, T_{mid} в середине толщи и T_{up} у верхней поверхности), время t в сутках, класс бетона B по прочности на сжатие согласно Межгосударственному стандарту, действующему на территории РФ ГОСТ 18105-2018³, толщина плиты h и темп твердения ($rate$). Выходными параметрами моделей выступают три значения: напряжения σ_{bot} у нижней поверхности, σ_{mid} в середине толщи, и σ_{up} у верхней поверхности (МПа). Рассмотрены три варианта архитектуры искусственных нейронных сетей (ИНС):

- 1) рекуррентная нейронная сеть (Layer recurrent neural network, рис. 1);
- 2) искусственная нейронная сеть прямого распространения (Feedforward neural network, рис. 2);
- 3) каскадная нейронная сеть (Cascade forward neural network, рис. 3).

¹ Maturix — Concrete temperature, strength and maturity monitoring. URL: <https://maturix.com/> (дата обращения: 27.01.2026)

² Giatec Scientific Inc — Smart Construction Testing Technologies. URL: <https://www.giatecscientific.com/> (дата обращения: 27.01.2026)

³ ГОСТ 18105-2018. Бетоны. Правила контроля и оценки прочности. НИИЖБ им. А.А. Гвоздева. Москва : Стандартинформ, 2019. 19 с. URL: <https://www.mos.ru/upload/documents/files/2071/GOST18105-2018.pdf> (дата обращения: 27.01.2026)

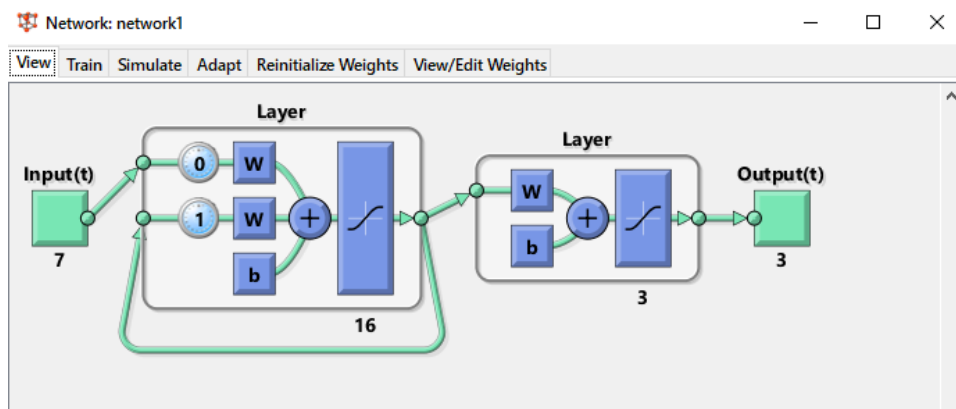


Рис. 1. Рекуррентная нейронная сеть (скриншот из MATLAB)

И с т о ч н и к: выполнено В.С. Тюриной.

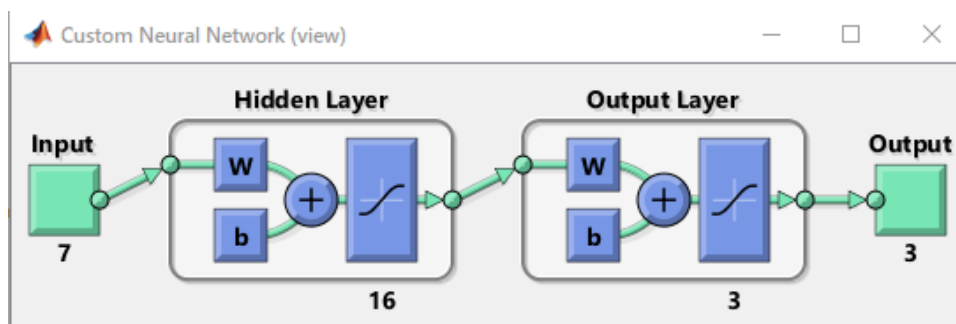


Рис. 2. Нейронная сеть прямого распространения (скриншот из MATLAB)

И с т о ч н и к: выполнено В.С. Тюриной.

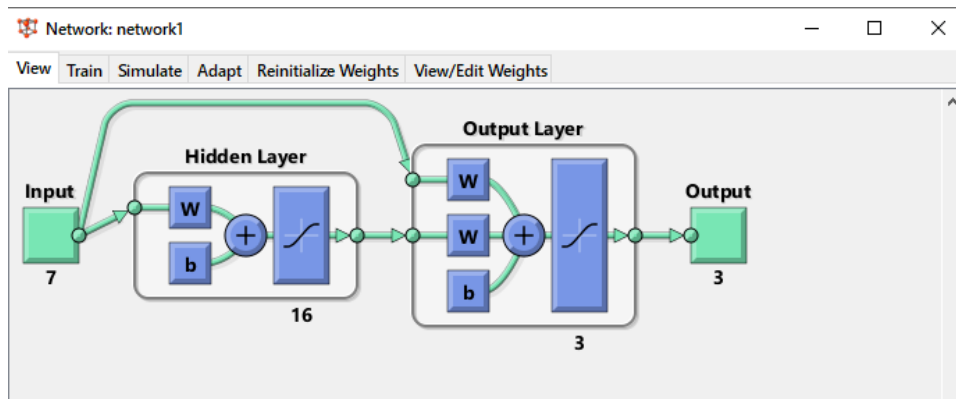


Рис. 3. Каскадная нейронная сеть (скриншот из MATLAB)

И с т о ч н и к: выполнено В.С. Тюриной.

Для всех вариантов ИНС принято по одному скрытому слою с шестнадцатью нейронами. При формировании обучающего датасета толщина плиты варьировалась от 1 до 3 м с шагом 0,5 м, коэффициент теплоотдачи на верхней поверхности менялся от 2 до 30 Вт/(м²·°С) с шагом 4 Вт/(м²·°С), класс бетона принимал значения от В25 до В45 с шагом 5 МПа. Температура окружающей среды варьировалась от 5 до 35 °С с шагом 5 °С. Для темпа твердения было введено три целочисленных значения: 1, 2, 3, соответствующие быстро твердеющему, нормально твердеющему и медленно твердеющему бетону. Принятые диапазоны изменения входных признаков охватывают наиболее распространенные параметры бетонирования и геометрии массивных монолитных фундаментных плит.

Функция тепловыделения задавалась уравнением [25]

$$Q(t) = Q_{28} \exp \left(k \left(1 - \left(\frac{28}{t-b} \right)^x \right) \right), \quad (1)$$

где Q_{28} — суммарное тепловыделение 1 м³ бетона к возрасту 28 сут, k и x — коэффициенты, определяющие кинетику тепловыделения, b — индукционный период.

Параметры функции тепловыделения приведены в табл. 1. Для каждого набора значений $[B \ h \ h_{up} \ T_{\infty} \ rate]$ выполнялся расчет температурного поля и напряженно-деформированного состояния с определением температур и напряжений в трех характерных точках (низ, середина, верх) для 119 моментов времени от 0,5 до 30 сут с шагом 0,25 сут. Расчет температурного поля выполнялся методом конечных элементов (МКЭ) в упрощенной одномерной постановке по методике, приведенной в [26]. Расчет напряженно-деформированного состояния производился по методике, представленной в [27].

Таблица 1. Параметры в уравнении тепловыделения

Параметр	k	x	Q_{28} , МДж/м ³	b , сут
Быстро твердеющий (1)	0,14	0,4	130 + 3·(B – 25)	0,167
Нормально твердеющий (2)	0,19	0,51		
Медленно твердеющий (3)	0,24	0,62		

Источники: выполнено В.С. Тюриной.

Теплофизические характеристики грунта принимались постоянными и равными: коэффициент теплопроводности $\lambda_g = 0,9$ Вт/(м·°С), удельная теплоемкость $c_g = 750$ Дж/(кг·°С), плотность $\rho_g = 1800$ кг/м³. Для бетона принимались следующие значения теплофизических характеристик: $\lambda = 2,67$ Вт/(м·°С), $c = 1000$ Дж/(кг·°С), $\rho = 2400$ кг/м³. Функция изменения прочности бетона при сжатии задавалась уравнением [28]

$$R = R_{28} \exp \left(s \left(1 - \sqrt{\frac{28}{t_{eq} - b}} \right) \right), \quad (2)$$

где $R_{28} = B + 12$ — прочность бетона при сжатии в возрасте 28 сут, s — коэффициент, зависящий от кинетики твердения бетона, $t_{eq} = DM / 20$ — эквивалентный возраст бетона, выражаемый через его степень зрелости DM :

$$DM = \int_0^t T(\tau) d\tau, \quad (3)$$

где $T(\tau)$ — температура в точке в возрасте τ .

Коэффициент s принимался равным 0,2 для быстро твердеющего, 0,35 для нормально твердеющего и 0,5 для медленно твердеющего бетона. Модуль упругости бетона определялся как функция от прочности при сжатии по формуле [28]

$$E(R) = 22265 \left(\frac{R}{10} \right)^{0,28} \text{ МПа}. \quad (4)$$

Значение R в формулу (4) следует подставлять в МПа. Коэффициент Пуассона бетона считался не зависящим от времени и температуры твердения ($\nu = 0,2$). До эквивалентного возраста 12 ч модуль упругости бетона принимался равным нулю (считалось, что бетон еще не является твердым телом и напряжения в нем отсутствуют). Послойность укладки бетонной смеси при расчете не учитывалась. Начальная температура грунта принималась равной температуре окружающей среды.

Полученные в результате расчета значения температур T_{bot} , T_{mid} , T_{up} помещались в массив входных параметров вместе с величинами $[B, h, rate]$ и временем t . Напряжения σ_{bot} , σ_{mid} , σ_{up} помещались в массив целевых значений выходных переменных. Общий объем обучающего датасета составил 4200 численных экспериментов ($4200 \times 119 = 499800$ строк). Фрагмент сформированного обучающего набора данных представлен в табл. 2.

Таблица 2. Фрагмент обучающего набора данных

№	Входные параметры							Выходные параметры		
	T_{bot} , °C	T_{mid} , °C	T_{up} , °C	t , сут	B , МПа	h , м	rate	σ_{bot} , МПа	σ_{mid} , МПа	σ_{up} , МПа
1	23,97	31,98	29,18	0,5	25	1	1	0,000	0,000	0,000
2	27,31	35,90	32,27	0,75	25	1	1	-0,002	-0,088	0,094
3	29,31	37,68	33,69	1	25	1	1	-0,095	-0,116	0,178
4	30,67	38,54	34,33	1,25	25	1	1	-0,248	-0,108	0,256
5	31,63	38,91	34,53	1,5	25	1	1	-0,424	-0,087	0,335
6	32,33	39,01	34,46	1,75	25	1	1	-0,606	-0,062	0,415
7	32,84	38,93	34,24	2	25	1	1	-0,784	-0,036	0,492
8	33,20	38,73	33,91	2,25	25	1	1	-0,954	-0,010	0,565
9	33,44	38,46	33,52	2,5	25	1	1	-1,114	0,014	0,631
10	33,58	38,14	33,10	2,75	25	1	1	-1,262	0,037	0,691
11	33,66	37,77	32,65	3	25	1	1	-1,399	0,059	0,743
12	33,67	37,39	32,20	3,25	25	1	1	-1,525	0,080	0,789
13	33,62	36,98	31,74	3,5	25	1	1	-1,640	0,100	0,828
14	33,54	36,56	31,28	3,75	25	1	1	-1,745	0,118	0,861
15	33,42	36,14	30,83	4	25	1	1	-1,842	0,136	0,889
...
499786	76,22	70,58	37,56	26,5	45	3	3	-5,600	-1,337	8,696
499787	76,08	70,38	37,54	26,75	45	3	3	-5,609	-1,317	8,631
499788	75,94	70,18	37,52	27	45	3	3	-5,617	-1,297	8,566
499789	75,80	69,99	37,50	27,25	45	3	3	-5,624	-1,278	8,501
499790	75,66	69,79	37,49	27,5	45	3	3	-5,630	-1,258	8,436
499791	75,51	69,60	37,47	27,75	45	3	3	-5,636	-1,239	8,372
499792	75,37	69,41	37,45	28	45	3	3	-5,642	-1,220	8,307
499793	75,23	69,22	37,44	28,25	45	3	3	-5,647	-1,202	8,243
499794	75,09	69,03	37,42	28,5	45	3	3	-5,651	-1,184	8,179
499795	74,94	68,84	37,40	28,75	45	3	3	-5,654	-1,166	8,116
499796	74,80	68,65	37,39	29	45	3	3	-5,657	-1,148	8,053
499797	74,65	68,46	37,37	29,25	45	3	3	-5,660	-1,130	7,990
499798	74,51	68,28	37,36	29,5	45	3	3	-5,662	-1,113	7,927
499799	74,37	68,10	37,34	29,75	45	3	3	-5,663	-1,095	7,864
499800	74,22	67,91	37,32	30	45	3	3	-5,664	-1,078	7,802

Источник: выполнено В.С. Тюриной.

Обучение моделей искусственных нейронных сетей выполнялось при помощи алгоритма Левенберга — Марквардта. Обучающий датасет случайным образом разделялся на три части: Training, Validation и Test, использовавшиеся для обучения, валидации и тестирования. Пропорция разбиения составляла 75:15:15 %. В качестве метрики качества обучения принималась величина среднеквадратической ошибки (MSE):

$$MSE = \frac{1}{n} \sum_{j=1}^n (T_i - Y_i)^2, \quad (5)$$

где n — объем обучающей выборки, Y_i — прогнозируемые нейросетью значения напряжений, T_i — целевые значения напряжений.

3. Результаты и обсуждение

Статистические характеристики сформированного массива данных представлены в табл. 3. Надежная работа модели обеспечивается только в диапазонах между \min и \max для входных параметров, поскольку использование искусственных нейронных сетей для экстраполяции может привести к непредсказуемым результатам.

Таблица 3. Статистические характеристики обучающего набора данных

Характеристика	Входные переменные							Выходные переменные		
	T_{bot}	T_{mid}	T_{up}	t	B	h	rate	σ_{bot}	σ_{mid}	σ_{up}
среднее	46,35	46,16	27,78	15,25	35	2	2	-2,98	-0,52	2,42
станд. отклон.	15,08	16,77	12,71	8,59	7,07	0,71	0,82	2,10	0,97	3,36
min	6,21	6,32	5,23	0,50	25	1	1	-9,21	-4,53	-9,95
25 %	35,96	34,20	17,64	7,75	30	1,5	1	-4,41	-1,12	0,27
50 %	46,57	45,92	27,39	15,25	35	2	2	-2,94	-0,39	2,45
75 %	57,40	58,05	36,59	22,75	40	2,5	3	-1,51	0,18	4,71
max	85,57	99,69	79,89	30,00	45	3	3	3,11	2,27	12,55

Источники: выполнено В.С. Тюриной.

Матрица коэффициентов корреляции приведена в табл. 4. Из данных табл. 4 видно, что очень сильная положительная связь (коэффициент корреляции R_{XY} более 0,9) наблюдается между параметрами T_{bot} и T_{mid} . Сильная положительная связь ($0,7 \leq R_{XY} < 0,9$) также наблюдается между параметрами T_{up} и T_{bot} , σ_{up} и T_{bot} , σ_{mid} и T_{bot} , σ_{mid} и T_{mid} . Наличие корреляционной связи между температурами у нижней поверхности, в середине толщи и у верхней поверхности объясняется тем, что разогрев конструкции вследствие тепла гидратации сопровождается подъемом температуры во всех точках. Наличие сильной связи между температурами и напряжениями также полностью соответствует физике процесса.

Сильная отрицательная связь наблюдается между параметрами σ_{up} и σ_{mid} . Это согласуется с результатами работы [29], где было показано, что при использовании гипотезы о параболическом распределении температуры по толщине и симметричных условий теплообмена между приращениями напряжений σ_{up} и σ_{mid} существует следующая связь:

$$2\Delta\sigma_{\text{mid}} = -\Delta\sigma_{\text{up}}. \quad (6)$$

При несимметричных условиях теплообмена (теплообмен с грунтом и атмосферой) данное соотношение нарушается, но сильная отрицательная корреляционная связь между σ_{up} и σ_{mid} сохраняется.

Средняя положительная связь ($0,5 \leq R_{XY} < 0,7$) наблюдается между параметрами h и T_{bot} , h и T_{mid} , h и σ_{up} . Очевидно, что с ростом толщины плиты наблюдается рост максимальной температуры в середине толщи конструкции. Поскольку большая часть тепла отводится через верхнюю поверхность плиты, с ростом толщины также возрастает и температура у нижней поверхности.

Умеренная положительная связь ($0,3 \leq R_{XY} < 0,49$) наблюдается между параметрами T_{up} и σ_{up} , t и σ_{mid} , темпом твердения и величиной σ_{bot} . Полностью независимыми в обучающем наборе данных являются параметры h и t , B и t .

Ход процесса обучения для рекуррентной нейронной сети, нейросети прямого распространения и каскадной нейронной сети показан соответственно на рис. 4–6. Процесс обучения ограничивался 1000 итераций. Лучшее значение среднеквадратической ошибки в 1000-й итерации было достигнуто для нейронной сети прямого распространения и составило $0,025 \text{ МПа}^2$.

Таблица 4. Матрица коэффициентов корреляции

Параметры	T_{bot}	T_{mid}	T_{up}	t	B	h	$rate$	σ_{bot}	σ_{mid}	σ_{up}
T_{bot}	1,00	0,96	0,73	-0,18	0,23	0,53	-0,06	-0,21	-0,72	0,79
T_{mid}	0,96	1,00	0,76	-0,36	0,21	0,55	-0,04	0,02	-0,83	0,84
T_{up}	0,73	0,76	1,00	-0,20	0,08	0,10	-0,01	0,26	-0,36	0,44
t	-0,18	-0,36	-0,20	1,00	0,00	0,00	0,00	-0,46	0,48	-0,34
B	0,23	0,21	0,08	0,00	1,00	0,00	0,00	-0,25	-0,11	0,15
h	0,53	0,55	0,10	0,00	0,00	1,00	0,00	-0,24	-0,68	0,63
$rate$	-0,06	-0,04	-0,01	0,00	0,00	0,00	1,00	0,47	-0,09	0,26
σ_{bot}	-0,21	0,02	0,26	-0,46	-0,25	-0,24	0,47	1,00	-0,10	0,02
σ_{mid}	-0,72	-0,83	-0,36	0,48	-0,11	-0,68	-0,09	-0,10	1,00	-0,91
σ_{up}	0,79	0,84	0,44	-0,34	0,15	0,63	0,26	0,02	-0,91	1,00

Источник: выполнено В.С. Тюриной / Source: made by V.S. Tyurina.

Наилучший результат проверки составил 0,033262 на эпохе 1000




Рис. 4. Ход процесса обучения для рекуррентной нейросети
Источник: выполнено В.С. Тюриной.

Наилучший результат проверки составил 0,025136 на эпохе 1000.




Рис. 5. Ход процесса обучения для нейросети прямого распространения
Источник: выполнено В.С. Тюриной.

Наилучший результат проверки составил 0,028529 на эпохе 1000




Рис. 6. Ход процесса обучения для каскадной нейронной сети
Источник: выполнено В.С. Тюриной.

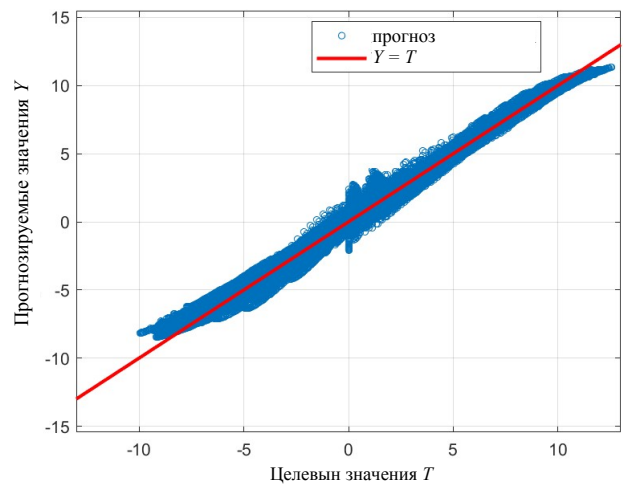


Рис. 7. График регрессии для рекуррентной нейронной сети
Источник: выполнено В.С. Тюриной.

На рис. 7–9 приведены графики регрессии для трех моделей машинного обучения. По оси абсцисс отложены целевые значения напряжений T , а по оси ординат — прогнозируемые нейронными сетями Y . Характер графиков для рассмотренных моделей совпадает, все точки находятся на небольшом удалении от прямой $Y = T$. Коэффициенты корреляции между целевыми и прогнозируемыми значениями близки к единице.

Обученные модели также апробировались на экспериментальных данных для массивной монолитной фундаментной плиты толщиной 2 м, приведенных в работе [30]. Прогнозирование напряжений выполнялось по экспериментальным значениям температур. Далее результаты прогноза сравнивались с результатами натурных измерений. Поскольку на верхней поверхности температура испытывала сильные суточные колебания, применялось предварительное сглаживание экспериментальных данных (рис. 10). Для нижней поверхности и середины толщи экспериментальные значения температур приведены в табл. 5.




Рис. 8. График регрессии для нейросети прямого распространения

Источник: выполнено В.С. Тюриной.




Рис. 9. График регрессии для каскадной нейросети

Источник: выполнено В.С. Тюриной.

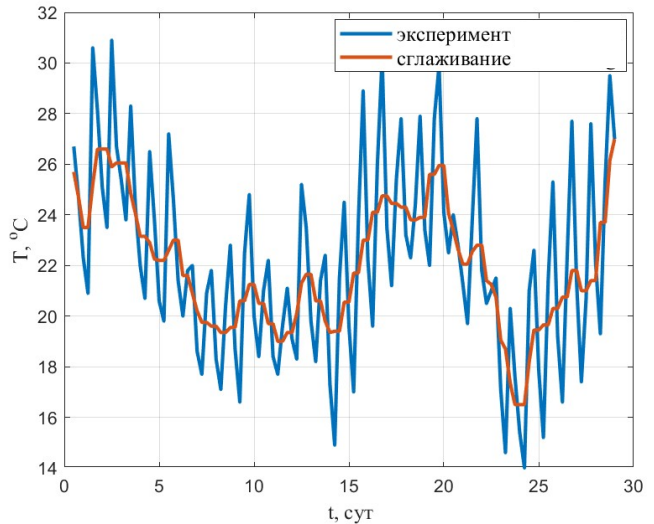


Рис. 10. График изменения температуры на верхней поверхности плиты до и после сглаживания

Источник: выполнено В.С. Тюриной.

Таблица 5. Экспериментальные значения температур в середине толщи и у нижней поверхности

t , сут	0,5	1	2	3	4	5	6	7	8	9	10	11	12	13	14
T_{mid} , °C	23,1	28,8	41,8	44,3	42,6	40	37,3	35,3	33,3	31,5	30,2	29,2	28,3	27,4	26,9
T_{bot} , °C	23	25,7	32	35	36,3	36,4	35,9	35,1	34,2	33,3	32,4	31,5	30,7	29,9	29,2
t , сут	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29
T_{mid} , °C	26,1	25,8	25,7	25,8	25,9	25,8	25,7	25,5	25,3	24,4	23,5	23,1	23	23	23,1
T_{bot} , °C	28,6	28,1	27,6	27,2	26,8	26,6	26,3	26,1	26	25,7	25,4	25,1	24,7	24,4	24,2

Источник: выполнено В.С. Тюриной.

Бетон, из которого была выполнена плита, по используемой в настоящей работе классификации относится к быстротвердеющим и имеет класс примерно В22,5. На рис. 11 представлено сравнение предсказаний искусственных нейронных сетей с экспериментальными данными для центра фундаментной плиты. Для сравнения также приведены результаты конечно-элементного моделирования с использованием зависимостей (2)–(4). Функция тепловыделения при конечно-элементном расчете была подобрана таким образом, чтобы обеспечить максимальное совпадение расчетных температур с экспериментальными.

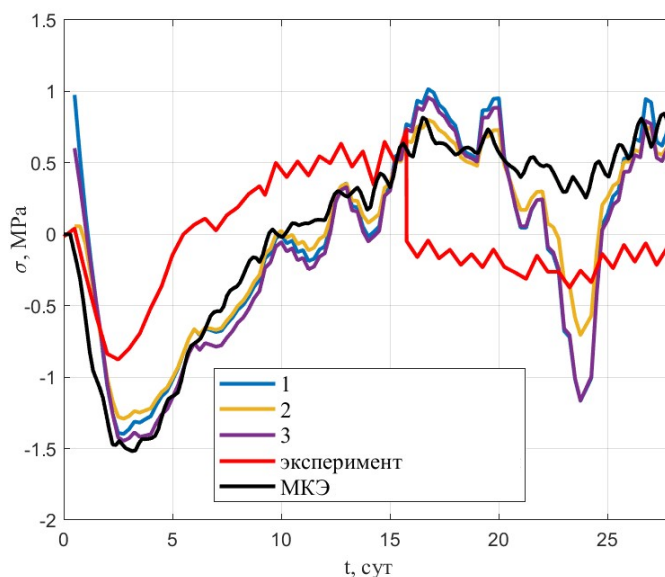


Рис. 11. Сравнение предсказаний нейросетей с экспериментальными данными и результатами конечно-элементного анализа:

1 — рекуррентная нейронная сеть; 2 — нейросеть прямого распространения; 3 — каскадная нейронная сеть

И с т о ч н и к: выполнено В.С. Тюриной.

Из представленных графиков видно, что три модели машинного обучения и МКЭ дают примерно одинаковые результаты за исключением начального момента времени. Более адекватное предсказание в начальный момент времени предлагает нейросеть прямого распространения, которая показала из всех рассмотренных моделей меньшую среднеквадратическую ошибку. В момент времени 16 сут при проведении эксперимента было зафиксировано образование трещины в плите, что соответствует скачку на экспериментальном графике. В данный момент времени нейросети достаточно точно предсказывают величину растягивающего напряжения. Отклонения результатов эксперимента от результатов конечно-элементного расчета и предсказаний нейросетей наблюдаются в промежутке времени от 3 до 11 сут. Их можно объяснить отклонением фактической зависимости модуля упругости бетона от времени от той, что была заложена в модели.

4. Заключение

В рамках проведенного исследования разработан и апробирован подход к прогнозированию температурных напряжений в массивных монолитных фундаментных плитах на основе данных мониторинга температур с использованием методов машинного обучения. В качестве моделей были рассмотрены три архитектуры искусственных нейронных сетей: рекуррентная нейронная сеть, нейросеть прямого распространения и каскадная нейронная сеть. Обучение проводилось на датасете объемом 499 800 строк, сформированном на основе 4200 численных экспериментов и охватывающем широкий диапазон варьирования геометрических, прочностных и теплофизических параметров.

1. Наилучшие результаты показала модель нейронной сети прямого распространения, достигшая среднеквадратической ошибки в прогнозировании напряжений, равной 0,025 МПа². Все три модели про-

демонстрировали высокую точность прогнозирования, что подтверждается графиками регрессии с коэффициентами корреляции между целевыми и прогнозируемыми значениями, близкими к единице. Верификация разработанных моделей ИНС на экспериментальных данных для плиты толщиной 2 м показала их адекватность и практическую применимость. Особенно точно модели предсказали момент возникновения растягивающих напряжений, соответствующий зафиксированному в эксперименте трещинообразованию на 16-е сутки.

2. Предложенный подход позволяет преодолеть ограничения существующих методик, основанных на гипотезе параболического распределения температур и напряжений, и обеспечивает точное прогнозирование для конструкций толщиной более 2 м. Использование ИНС позволяет существенно сократить вычислительные затраты по сравнению с прямым конечно-элементным моделированием, что делает метод эффективным инструментом для оперативного анализа данных мониторинга в реальном времени.

Таким образом, применение методов машинного обучения для прогнозирования температурных напряжений в твердеющих массивных конструкциях является перспективным направлением, способствующим повышению точности оценки напряженно-деформированного состояния и предотвращению раннего трещинообразования.

Список литературы

1. Safiuddin M., Kaish A.B.M., Woon C.-O., Raman S.N. Early-age cracking in concrete: causes, consequences, remedial measures, and recommendations // *Applied Sciences*. 2018. Vol. 8. No. 10. Article no. 1730. <https://doi.org/10.3390/app8101730>
2. Klemczak B., Batog M., Pilch M., Žmij A. Analysis of cracking risk in early age mass concrete with different aggregate types // *Procedia engineering*. 2017. Vol. 193. P. 234–241. <https://doi.org/10.1016/j.proeng.2017.06.209>
3. Mazzoli A., Monosi S., Plescia E.S. Evaluation of the early-age-shrinkage of fiber reinforced concrete (FRC) using image analysis methods // *Construction and Building Materials*. 2015. Vol. 101. P. 596–601. <https://doi.org/10.1016/j.conbuildmat.2015.10.090>
4. Waller V., d'Aloia L., Cussigh F., Lecrux S. Using the maturity method in concrete cracking control at early ages // *Cement and Concrete Composites*. 2004. Vol. 26. No. 5. P. 589–599. [https://doi.org/10.1016/S0958-9465\(03\)00080-5](https://doi.org/10.1016/S0958-9465(03)00080-5)
5. Alos Shepherd D., Dehn F. Experimental study into the mechanical properties of plastic concrete: Compressive strength development over time, tensile strength and elastic modulus // *Case Studies in Construction Materials*. 2023. Vol. 19. Article no. e02521. <https://doi.org/10.1016/j.cscm.2023.e02521> EDN: DAARVN
6. Xu J., Shen Z., Yang S., Xie X., Yang Z. Finite element simulation of prevention thermal cracking in mass concrete // *International Journal of Computing Science and Mathematics*. 2019. Vol. 10. No. 4. P. 327–339. <https://doi.org/10.1504/IJCSM.2019.102691>
7. Julia R., Agrela F., Rosales M., López-Alonso M., Cuenca-Moyano G. Execution of large-scale sustainable pavement with recycled materials and eco-hybrid additions to cement. Assessment of Mechanical Behaviour and Life Cycle // *Construction and Building Materials*. 2025. Vol. 453. Article no. 139558. <https://doi.org/10.1016/j.conbuildmat.2025.139967> EDN: GOCOWJ
8. Namatēvs I., Gaigals G., Ozols K. ConMonity: An IoT-Enabled LoRa/LTE-M platform for multimodal, real-time monitoring of concrete curing in construction environments // *Sensors*. 2026. Vol. 26. Article no. 14. <https://doi.org/10.3390/s26010014> EDN: CNKAJT
9. Aniskin N.A., Chuc N.T., Khanh P.K. The use of surface thermal insulation to regulate the temperature regime of a mass concrete during construction // *Power Technology and Engineering*. 2021. Vol. 55. No. 1. P. 1–7. <https://doi.org/10.1007/s10749-021-01310-6> EDN: TSLLPN
10. Tyurina V., Chepurnenko A., Tkachev D. A simplified method for assessing thermal stresses during the construction of massive monolithic foundation slabs based on temperatures at three points // *Buildings*. 2026. Vol. 16. No. 1. Article no. 188. <https://doi.org/10.3390/buildings16010188>
11. Liu L., Zhao S., Xin J., Wang Z. Simplified analysis of thermal cracks in low — heat Portland cement concrete // *Advances in Civil Engineering*. 2022. Vol. 2022. Article no. 7630568. <https://doi.org/10.1155/2022/7630568> EDN: IQXPLS
12. Aniskin N.A., Nguyen T.C. Predictive model of temperature regimes of a concrete gravity dam during construction: Reducing cracking risks // *Buildings*. 2023. Vol. 13. No. 8. Article no. 1954. <https://doi.org/10.3390/buildings13081954> EDN: LFTQTEG
13. Nguyen C.T., Luu X.B. Reducing temperature difference in mass concrete by surface insulation // *Magazine of Civil Engineering*. 2019. Vol. 4. No. 88. P. 70–79. <https://doi.org/10.18720/MCE.88.7> EDN: HHFAQQ
14. Van Lam T., Nguen C.C., Bulgakov B.I., Anh P.N. Composition calculation and cracking estimation of concrete at early ages // *Magazine of Civil Engineering*. 2018. Vol. 82. Article no. 13. <https://doi.org/10.18720/MCE.82.13> EDN: YZNUZV

15. *Van Tran M., La H., Nguyen T.* Hybrid machine learning for predicting hydration heat in pipe-cooled mass concrete structures // *Construction and Building Materials*. 2025. Vol. 481. Article no. 141558. <https://doi.org/10.1016/j.conbuildmat.2025.141558> EDN: OTLQKB
16. *Sargam Y., Wang K., Cho I.H.* Machine learning based prediction model for thermal conductivity of concrete // *Journal of Building Engineering*. 2021. Vol. 34. Article no. 101956. <https://doi.org/10.1016/j.job.2020.101956> EDN: RIIOZE
17. *Tuvayanond W., Kamchoom V., Prasittisopin L.* Efficient machine learning for strength prediction of ready-mix concrete production (prolonged mixing) // *Construction innovation*. 2026. Vol. 26. No. 2. P. 369–394. <https://doi.org/10.1108/CI-09-2023-0240> EDN: TEFJHH
18. *Chou J.S., Tsai C.F., Pham A.D., Lu Y.H.* Machine learning in concrete strength simulations: Multi-nation data analytics // *Construction and Building materials*. 2014. Vol. 73. P. 771–780. <https://doi.org/10.1016/j.conbuildmat.2014.09.054>
19. *Klemczak B., Bqba D., Siddique R.* Machine learning-based prediction of heat transfer and hydration-induced temperature rise in mass concrete // *Energies*. 2025. Vol. 18. No. 17. Article no. 4673. <https://doi.org/10.3390/en18174673> EDN: ZVWFTY
20. *Do T.A., Le B.A.* Machine learning approach for predicting early-age thermal cracking potential in concrete bridge piers // *Forces in Mechanics*. 2024. Vol. 17. Article no. 100297. <https://doi.org/10.1016/j.finmec.2024.100297> EDN: STXYTP
21. *Shahrokhishahraki M., Malekpour M., Mirvalad S., Faraone G.* Machine learning predictions for optimal cement content in sustainable concrete constructions // *Journal of Building Engineering*. 2024. Vol. 82. Article no. 108160. <https://doi.org/10.1016/j.job.2023.108160> EDN: THDUVM
22. *Sun G., Du M., Shan B., Shi J., Qu Y.* Ultra-high performance concrete design method based on machine learning model and steel slag powder // *Case Studies in Construction Materials*. 2022. Vol. 17. Article no. e01682. <https://doi.org/10.1016/j.cscm.2022.e01682> EDN: PNYATB
23. *Forsdyke J.C., Zviashynski B., Lees J.M., Conduit G.J.* Probabilistic selection and design of concrete using machine learning // *Data-Centric Engineering*. 2023. Vol. 4. Article no. e9. <https://doi.org/10.1017/dce.2023.5> EDN: VLTCTA
24. *Li Z., Yoon J., Zhang R., Rajabipour F., Srubar III W.V., Dabo I., Radlińska A.* Machine learning in concrete science: applications, challenges, and best practices // *npj Computational Materials*. 2022. Vol. 8. No. 1. Article no.127. <https://doi.org/10.1038/s41524-022-00810-x> EDN: BSEOLV
25. *Несветаев Г.В., Корянова Ю.И.* Прогноз кинетики прочности бетона при твердении в условиях, отличных от нормальных // *Современные тенденции в строительстве, градостроительстве и планировке территорий*. 2023. Т. 2. № 4. С. 59–68. <https://doi.org/10.23947/2949-1835-2023-2-4-59-68> EDN: UAIZPO
26. *Chepurmenko A., Nesvetaev G., Koryanova Y.* Modeling non-stationary temperature fields when constructing mass cast-in-situ reinforced-concrete foundation slabs // *Architecture and Engineering*. 2022. Vol. 7. No. 2. P. 66–78. <https://doi.org/10.23968/2500-0055-2022-7-2-66-78> EDN: AKGXYN
27. *Chepurmenko A.S., Nesvetaev G.V., Koryanova Y.I., Yazyev B.M.* Simplified model for determining the stress-strain state in massive monolithic foundation slabs during construction // *International Journal for Computational Civil and Structural Engineering*. 2022. Vol. 18. No. 3. P. 126–136. <https://doi.org/10.22337/2587-9618-2022-18-3-126-136> EDN: RQQYSK
28. *Chepurmenko A.S., Nesvetaev G.V., Koryanova Yu.I., Shut V.V., Tyurina V.S.* Experience of concreting a massive monolithic foundation slab // *Construction Materials and Products*. 2025. Vol. 8. No. 5. P. 2. <https://doi.org/10.58224/2618-7183-2025-8-5-2> EDN: ECAUPO
29. *Chepurmenko A., Tyurina V.* Simplified method for determining thermal stresses during the construction of massive monolithic foundation slabs // *CivilEng*. 2023. Vol. 4. No. 3. P. 740–752. <https://doi.org/10.3390/civileng4030042> EDN: PBHJUB
30. *Smolana A., Klemczak B., Azenha M., Schlicke D.* Thermo-mechanical analysis of mass concrete foundation slabs at early age — essential aspects and experiences from the FE modeling // *Materials*. 2022. Vol. 15. No. 5. Article no.1815. <https://doi.org/10.3390/ma15051815> EDN: SNFMFC