

УДК 693.543.5

ВОЗМОЖНОСТИ ПРИМЕНЕНИЯ НЕЙРОННЫХ СЕТЕЙ В СТРОИТЕЛЬНОМ МАТЕРИАЛОВЕДЕНИИ

Д.В. Бородин, С.С. Рябова

*Военно-космическая академия имени А.Ф. Можайского, Санкт-Петербург,
г. Санкт-Петербург (Российская Федерация)*

Аннотация. В работе показана возможность применения нейронных сетей в строительстве. Приведены примеры такого использования. Рассмотрены преимущества развития методов нейросетевого моделирования применительно к решению строительных задач. Приведены особенности нейросетевых методов обработки данных. Показаны возможности применения Neural Network Start (NNStart) пакета расширения программного комплекса MATLAB для решения различных задач. Описан процесс решения задачи регрессии с применением нейросети в данной программе. Показаны группы входных данных для полносвязной нейросети прямого распространения (Feed Forward NN). Рассмотрены основные алгоритмы обучения такой сети. Приведен нейросетевой прогноз (с одним слоем скрытых нейронов) величины прочности жаростойкого пенобетона в зависимости от изменения количества его компонентов. Проведен сравнительный анализ качества работы нейронной сети, смоделированной в программном комплексе MATLAB в зависимости от заданного количества нейронов в скрытом слое и выбранном способе обучения сети.

Ключевые слова: нейронные сети, машинное обучение, обучение сети, задача регрессии, жаростойкий пенобетон, нейросеть прямого распространения, MATLAB, NNStart, FNN.

Ссылка для цитирования: Бородин Д.В., Рябова С.С. Возможности применения нейронных сетей в строительном материаловедении // Инженерные исследования. 2022. №5 (10). С. 3-11. EDN: BMLSFT

THE POSSIBILITIES OF USING NEURAL NETWORKS IN BUILDING MATERIALS SCIENCE

D.V. Borodin, S.S. Ryabova

Military Space Academy named after A.F. Mozhaysky, St.Petersburg (Russian Federation)

Abstract. The paper shows the possibility of using neural networks in construction. Examples of such use are given. The advantages of the development of neural network modeling methods in relation to solving construction problems are considered. The features of neural network methods of data processing are given. The possibilities of using Neural Network Start (NNStart) of the MATLAB software package extension for solving various tasks are shown. The process of solving the regression problem using a neural network in this program is described. Groups of input data for a fully connected neural network of direct propagation (Feed Forward NN) are shown. The basic algorithms of training such a network are considered. A neural network forecast (with one layer of hidden neurons) of the strength of heat-resistant foam concrete, depending on the change in the number of its components, is given. A comparative analysis of the quality of the neural network modeled in the MATLAB software package, depending on the specified number of neurons in the hidden layer and the selected method of network training, is carried out.

Keywords: neural networks, machine learning, network learning, regression problem, heat-resistant foam concrete, direct propagation neural network, MATLAB, NNStart, FNN.

For citation: Borodin D.V., Ryabova S.S. The possibilities of using neural networks in building materials science // Inzhenernyye issledovaniya [Engineering Research]. 2022. No.5 (10). Pp. 3-11. EDN: BMLSFT

ВВЕДЕНИЕ

В настоящее время все более широкое применение в различных сферах и областях приобретают различные методы машинного обучения, а в частности нейронные сети. Однако в строительстве применение данных подходов остается недостаточно развито и распространено, несмотря на то что их применение может качественно улучшить и упростить целый ряд строительных процессов.

В строительстве возможно использование методов машинного обучения для прогнозирования категории технического состояния несущих конструкций зданий и сооружений по наличию в них дефектов, оценивания риска наступления аварийного состояния конструкции, оперативного составления планов и определения потребности в ресурсах для устранения неисправностей, определения физико-механических свойств материалов в зависимости от условий их производства и эксплуатации, оценка компетентности подрядчиков, проведение непредвзятого конъюнктурного анализа сметных расценок и множества других задач.

В статье [1] рассмотрены нейросетевые методы оценки затрат на научно-исследовательские и проектно-изыскательские работы при строительстве автомобильных дорог, позволяющие на основе данных по запроектированным ранее объектам произвести ранжирование ценообразующих факторов по степени их влияния на цену научно-исследовательских и проектно-изыскательских работ, выполняемых для проектов государственно-частного партнерства.

Создана программа, предназначенная для использования в автоматизированной системе предупреждения осложнений при строительстве нефтяных и газовых скважин. Которая способна по показаниям с разных датчиков и общей оценке обстановки заранее прогнозировать осложнения в процессе бурения и принимать превентивные меры по их предотвращению [2].

В монографии [3] излагается метод определения причин появления трещин в конструкциях зданий, который основывается на нечетких правилах. В ней развиваются идеи профессора А. П. Ротштейна по медицинской диагностике на нечеткой логике [4] и по теории генетико-нечеткой идентификации [5] с учетом специфики объекта диагностирования – трещин строительных конструкций.

В диссертации [6] реализован, адаптированный к задаче определения категории технического состояния железобетонной изгибаемой конструкции, базирующийся на нечеткой логике, алгоритм. Эта технология позволяет дать строгое математическое описание расплывчатых утверждений и реализует попытку преодолеть лингвистический барьер между человеком и компьютером. Сформулированы предпосылки эффективности использования нейросетевых подходов к проблемам строительства. [7] Показаны примеры решения задач теории упругости и пластичности, строительной механики и строительных конструкций с помощью нейронных сетей [8, 9].

МАШИННОЕ ОБУЧЕНИЕ

Единого определения для термина машинное обучение пока нет. Но большинство исследователей формулируют его примерно так. Машинное обучение - это наука о том, как заставить искусственный интеллект (ИИ) учиться и действовать как человек, а также сделать так, чтобы он сам постоянно улучшал свое обучение и способности на основе предоставленных нами данных о реальном мире. Искусственная нейронная сеть (далее - нейросеть или ИНС) - математическая модель, а также её программное или аппаратное воплощение, построенная по принципу организации и функционирования биологических нейронных сетей – сетей нервных клеток живого организма. Нейросеть является одним из видов машинного обучения [10].

Изначально компьютеры использовались для задач, алгоритм решения которых был известен человеку. И только в последние годы пришло понимание, что они могут находить способ решать задачи, для которых алгоритма решения нет или он не известен. Так появился искусственный интеллект в широком смысле и технологии машинного обучения, в частности. С помощью машинного обучения ИИ может анализировать данные, запоминать информацию, строить прогнозы, воспроизводить готовые модели и выбирать наиболее подходящий вариант из предложенных. Особенно полезны такие системы там, где необходимо выполнять огромные объемы вычислений: например, банковский скоринг (расчет кредитного рейтинга), аналитика в области маркетинговых и статистических исследований, бизнес-планирование, демографические исследования, инвестиции, поиск фейковых новостей и мошеннических сайтов. В сфере инвестиций алгоритмы на базе машинного обучения анализируют рынок, отслеживают новости и подбирают активы, которые выгоднее всего покупать именно сейчас. При этом с помощью предикативной аналитики система может предсказать, как будет меняться стоимость тех или иных акций за конкретный период и корректирует свои данные после каждого важного события в отрасли. Процесс машинного обучения, вообще то, выглядит следующим образом. Есть большое число однотипных задач, в которых

известны условие и правильный ответ или один из возможных ответов. Модель машинного обучения, например, глубинная нейронная сеть, работает по принципу «черного ящика», который принимает на вход условие задачи, а на выходе выдает произвольный ответ. У «черного ящика» есть дополнительные параметры, которые влияют на то, как будет обрабатываться входной сигнал. Процесс обучения нейросети заключается в поиске таких значений параметров, при которых она будет выдавать ответ, максимально близкий к правильному. Когда мы настроим параметры нужным образом, нейросеть сможет правильно (или максимально близко к этому) решать и другие задачи того же типа - даже если никогда не знала ответов к ним.

Нейросетевые методы обработки данных имеют ряд качественных особенностей, основными из которых, применительно к строительной сфере, можно назвать:

– Решение задач при неизвестных закономерностях. Используя способность обучения на множестве примеров, нейронная сеть способна решать задачи, в которых неизвестны закономерности развития ситуации и зависимости между входными и выходными данными. Здесь стоит отметить теорему универсальности, которая звучит следующим образом: теоретически нейросеть всего с одним скрытым слоем способна аппроксимировать любую функцию с любой точностью при достаточном количестве нейронов скрытого слоя [11]. Стоит отметить, что решение получается непрерывным, то есть отобразить разрыв функции невозможно. Увеличение количества слоев в свою очередь увеличит точность аппроксимации. Примером применения такого метода в строительном материаловедении может быть определение характеристики жаростойкого материала (например, прочность пенобетона) по данным состава и технологических факторов, совместное влияние которых на прочность неизвестно.

– Адаптивное к изменениям окружающей среды. Нейронные сети обладают способностью адаптироваться к изменениям окружающей среды. В частности, нейронные сети, обученные действовать в определенной среде, могут быть легко переучены для работы в условиях незначительных колебаний параметров среды. Более того, для работы в нестационарной среде (где статистика изменяется с течением времени) могут быть созданы нейронные сети, переучивающиеся в реальном времени. Чем выше адаптивные способности системы, тем более устойчивой будет ее работа в нестационарной среде. При этом следует заметить, что адаптивность не всегда ведет к устойчивости; иногда она приводит к совершенно противоположному результату. Например, адаптивная система с параметрами, быстро изменяющимися во времени, может также быстро реагировать и на посторонние возбуждения, что вызовет потерю производительности. Для того чтобы использовать все достоинства адаптивности, основные параметры системы должны быть достаточно стабильными, чтобы можно было не учитывать внешние помехи, и достаточно гибкими, чтобы обеспечить реакцию на существенные изменения среды. Например, если в ходе исследования взаимосвязи прочности жаростойкого пенобетона с предполагаемыми факторами выясняется, что появляются дополнительные не учтенные ранее причины (например, влияет теплофизика), то есть возможность доучить нейросеть

– Потенциальное быстрое действие. Процесс обучения нейросети на большом массиве данных происходит достаточно долго. Однако обученная нейросеть обладает потенциальным сверхвысоким быстрым действием за счет использования массового параллелизма обработки информации и способна с высокой скоростью решать поставленные задачи, например, оперативного определения категории технического состояния конструкций

– Учет «совокупности» факторов. Нейросеть способна учесть зависимость влияния каждого входного параметра на выходной результат от совокупности влияния остальных параметров, когда при обычной оценке эти влияния могут казаться независимыми. Иными словами, она может учесть влияние входных параметров друг на друга и учесть это влияние в своей работе.

В данной работе для решения задачи определения прочности жаростойкого пенобетона в зависимости от состава смеси использован программный комплекс MATLAB, в частности встроенный в него пакет Neural Network Start.

MATLAB - пакет прикладных программ для решения задач технических вычислений. Neural Network Start (NNStart) – упрощенная версия пакета расширения MATLAB, содержащая средства для моделирования, проектирования, разработки и визуализации искусственных нейронных сетей (ИНС).

Запуск пакета NNStart производится командой nnstart. После чего программа открывает диалоговое окно с выбором варианта задачи, которую мы будем решать с помощью ИНС.

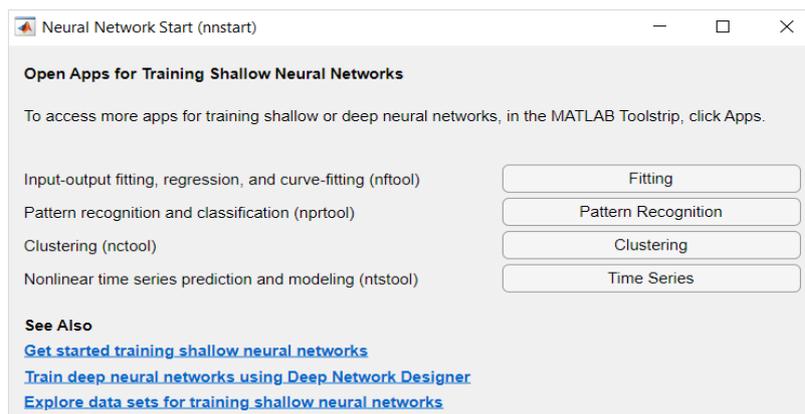


Рис. 1. Выбор задачи
Fig. 1. Task selection

Программа позволяет решать задачи: Fitting - регрессии, аппроксимации кривой; Pattern Recognition - распознавания образов (для работы с изображениями); Clustering – кластеризация, или обработка размеченных данных для поиска закономерностей и объединения объектов в группы по каким-то признакам; Time Series – аппроксимация временных рядов (для прогнозирования во времени).

ПРИМЕР РЕШЕНИЯ ЗАДАЧИ

Будем решать задачу регрессии, поэтому выбираем первый тип задачи Fitting. После выбора задачи программа создаст схему структуры сети, и позволит выбрать основные параметры.

Типовой вариант архитектуры для решения задач данного вида – Feed Forward NN (FNN). Полносвязная нейросеть прямого распространения, в которой каждый нейрон последующего слоя связан со всеми нейронами предыдущего. Она хорошо подходит для решения задач такого типа, хотя и имеет определенные недостатки, которые необходимо учитывать при решении более масштабных задач.

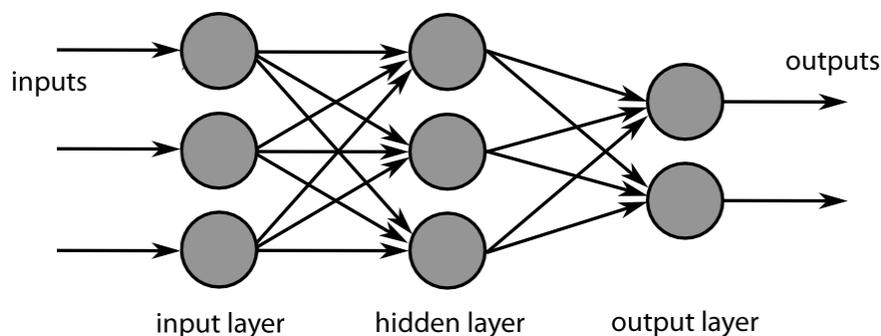


Рис. 2. Схема FNN сети
Fig. 2. FNN network diagram

В нашем случае имеем нейронную сеть с одним входным, одним скрытым и одним выходным слоем. Функция активации скрытого слоя – сигмовидная $y(a) = \frac{1}{1+e^{-a}}$, выходного – линейная $y(a) = a$.

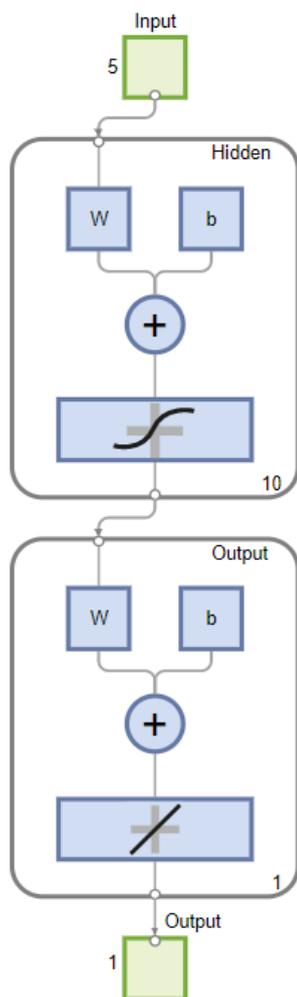


Рис. 3. Схема структуры ИНС
Fig. 3. Diagram of the structure of ANN

Для обучения и проверки сети в работе используются экспериментально полученные данные, которые отражают значение прочности жаростойкого пенобетона в зависимости от количества (в граммах) добавленных в смесь компонентов. Во всех случаях общий состав смеси оставался неизменным за исключением 5 компонентов, которые мы в тех или иных количествах добавляли в смесь (табл.1).

Таблица 1. Перечень добавок
 Table 1. List of additives

Название компонента	Минимальное количество, грамм	Максимальное количество, грамм
Шлак тонкомолотый	10	78
Шамот	26	51
Водоцементное отношение 0,45	218	268
Суперпластификатор	0,5	1,5
Нанодобавка	0,5	2,9

Для работы с ИНС было экспериментально получено 45 значений входных и связанных с ними выходных данных. Входные – столбец, содержащий в себе 5 численных значений, каждому из которых соответствует количество (грамм) вещества добавленного в смесь. Выходные – одно значение, соответствующее реальному значению прочности ($\frac{\text{кгс}}{\text{см}^2}$) жаростойкого пенобетона после твердения. Все данные были занесены в таблицу Excel, нормализованы, то есть приведены к значениям от 0 до 1 и размещены в удобном для дальнейшего использования программой порядке.

На следующем этапе работы мы импортируем наши данные из Excel в рабочее пространство MATLAB создавая 2 нумерованные матрицы, input (inp) 5x45, и output (out) 1x45 содержащие в себе соответственно данные из входной и выходной таблиц. Из пространства MATLAB повторно импортируем данные в пакет NNStart, указывая какие данные будут входом, а какие выходом.

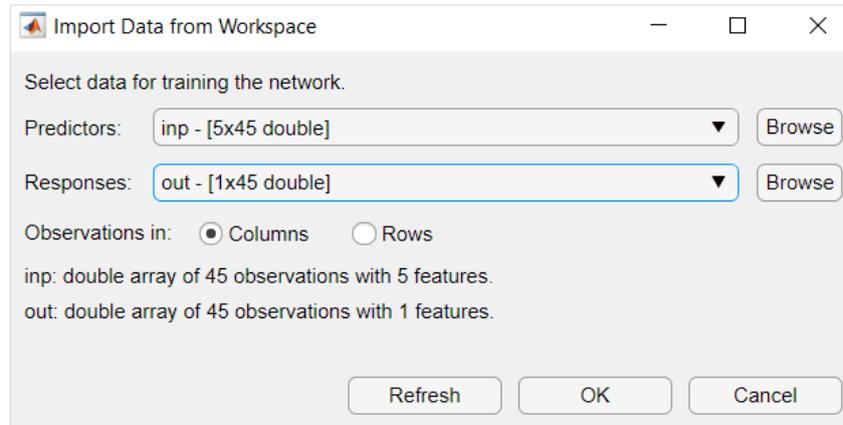


Рис.4. Импорт данных в ИНС
Fig.4. Importing data into ANN

После импорта данных задаем количество нейронов в скрытом слое и выбираем способ обучения сети, данные параметры выбираются методом проб и ошибок, путем анализа качества работы сети в разных вариантах. Предлагаемые способы обучения это:

1. Алгоритм Байесовской регуляции. Рационально применять, при необходимости обобщения сложных или шумных наборов данных. Обучение прекращается в соответствии с адаптивной минимизацией веса. Особенности этого способа является долгое обучение и усложненный процесс доучивания.

2. Алгоритм Левенберга-Марквардта заключается в последовательном приближении заданных начальных значений параметров к искомому локальному оптимуму. Алгоритм отличается от метода сопряженных градиентов тем, что использует матрицу Якоби модели, а не градиент вектора параметров. При использовании этого метода обучение автоматически прекращается, как только обобщение перестает улучшаться.

3. Масштабируемый алгоритм сопряженных градиентов - итерационный метод для безусловной оптимизации в многомерном пространстве. Этот метод так же, как алгоритм Левенберга-Марквардта автоматически останавливает обучение при прекращении улучшения, однако он требует меньше памяти, но больше времени.

Для выбора оптимального варианта способа обучения и количества нейронов построим и обучим поочередно всеми тремя способами сеть, содержащую в скрытом слое сначала 10, затем 50 нейронов (табл.2).

Точность аппроксимации оцениваем с помощью коэффициента корреляции (regression R-value) и среднеквадратического отклонения (Mean Squared Error) между получаемыми сетью значениями с целевыми значениями прочности жаростойкого пенобетона.

Коэффициент корреляции r (1) – это статистическая мера, которая вычисляет силу связи между относительными движениями двух переменных ($X_i; Y_i$). Значения коэффициента корреляции находятся в диапазоне от -1,0 до 1,0. Если вычисленное число больше 1,0 или меньше -1,0, то это свидетельствует о наличии погрешности в измерении корреляции. Это объясняется тем, что корреляция -1,0 показывает идеальную отрицательную корреляцию, в то время как корреляция 1,0 показывает идеальную положительную корреляцию. Корреляция 0,0 означает, что нет никакой связи между движением двух переменных. Чем ближе коэффициент корреляции к 1,0, тем лучше качество работы сети и ближе предсказанные нейросетью значения к экспериментальным данным.

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X}) \cdot (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \cdot \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (1)$$

где \bar{X} (2), \bar{Y} (3) – средние значения выборок

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n} (X_1 + \dots + X_n) \quad (2)$$

$$\bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i = \frac{1}{n} (Y_1 + \dots + Y_n) \quad (3)$$

Среднеквадратическое отклонение (СКО) S (4) - статистическая характеристика распределения случайной величины (X_i), показывающая среднюю степень разброса значений величины относительно математического ожидания. Среднеквадратическое отклонение измеряется в единицах самой случайной величины и используется при расчёте стандартной ошибки среднего арифметического, при построении доверительных интервалов, при статистической проверке гипотез, при измерении линейной взаимосвязи между случайными величинами.

$$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2} \quad (4)$$

где \bar{X} – среднее значение выборки (2).

Для получения достоверных результатов данные автоматически случайным образом разделяем на 3 группы:

- Учебный набор данных (Training): Образец данных, используемых для соответствия модели – 70%.
- Набор данных проверки (Validation): Выборка данных, используемая для объективной оценки соответствия модели учебному набору данных при настройке гиперпараметров модели. Оценка становится более предвзятой, поскольку навывк в наборе данных проверки включается в конфигурацию модели – 15%.
- Тестовый набор данных (Test): Выборка данных, используемых для объективной оценки окончательной модели, подходящей для набора данных обучения – 15%.

После чего проводим обучение сети поочередно всеми тремя методами, результаты обучения показаны на рис.5 – рис.7. Из графиков видно, что Алгоритмы Левенберга-Марквардта и сопряженных градиентов заканчивают свое обучение, на 10 и 39 эпохе обучения, когда перестает уменьшаться СКО (MSE). Алгоритм Байесовской регуляции в свою очередь проводит 278 эпох и затрачивает на обучение значительно больше времени и ресурсов, хотя очевидно, что обучение после 38 эпохи не улучшает качество работы сети.

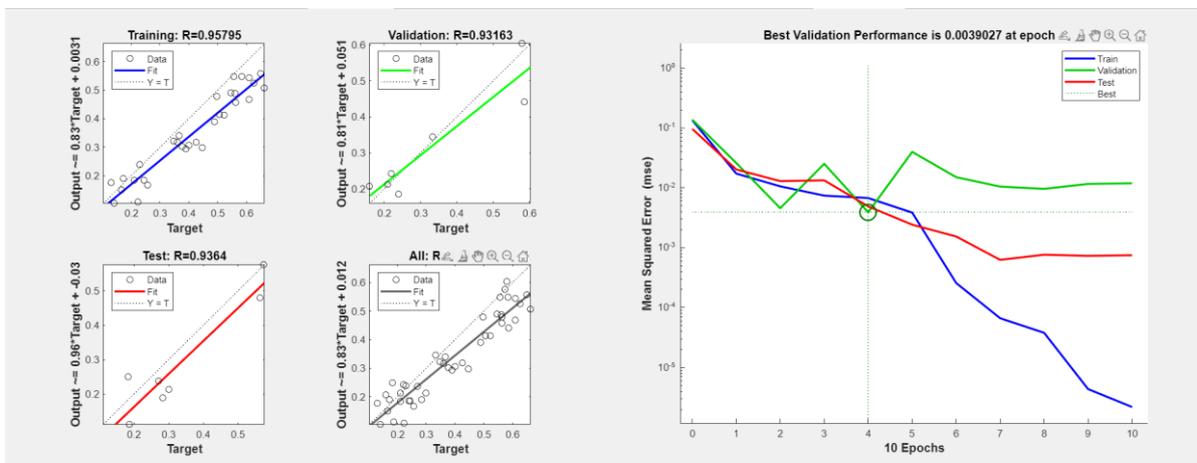


Рис.5. Алгоритм Левенберга-Марквардта (10 нейронов в скрытом слое)

Fig.5. Levenberg-Marquardt algorithm (10 neurons in a hidden layer)

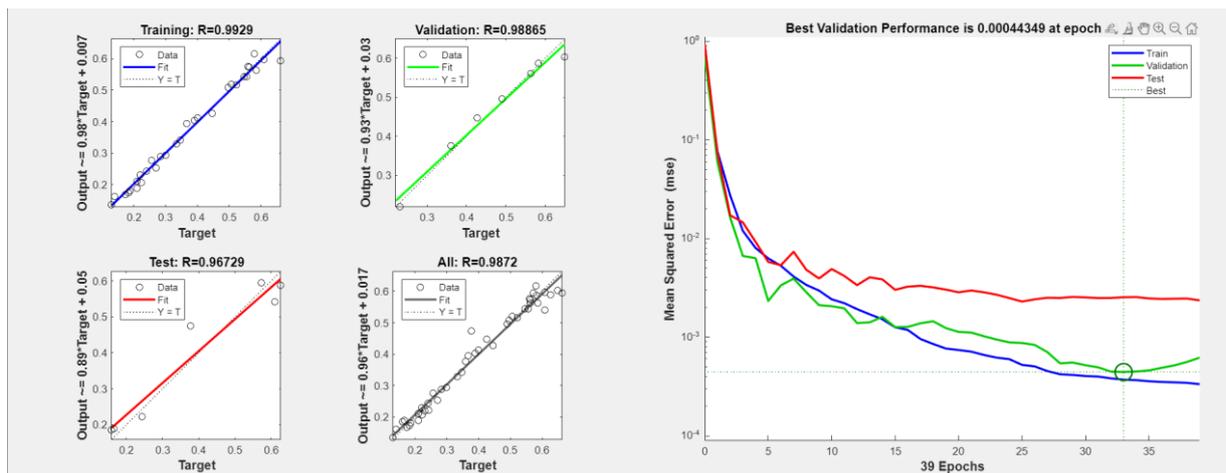


Рис.6. Масштабируемый алгоритм сопряженных градиентов (10 нейронов в скрытом слое)
Fig.6. Scalable algorithm of conjugate gradients (10 neurons in a hidden layer)

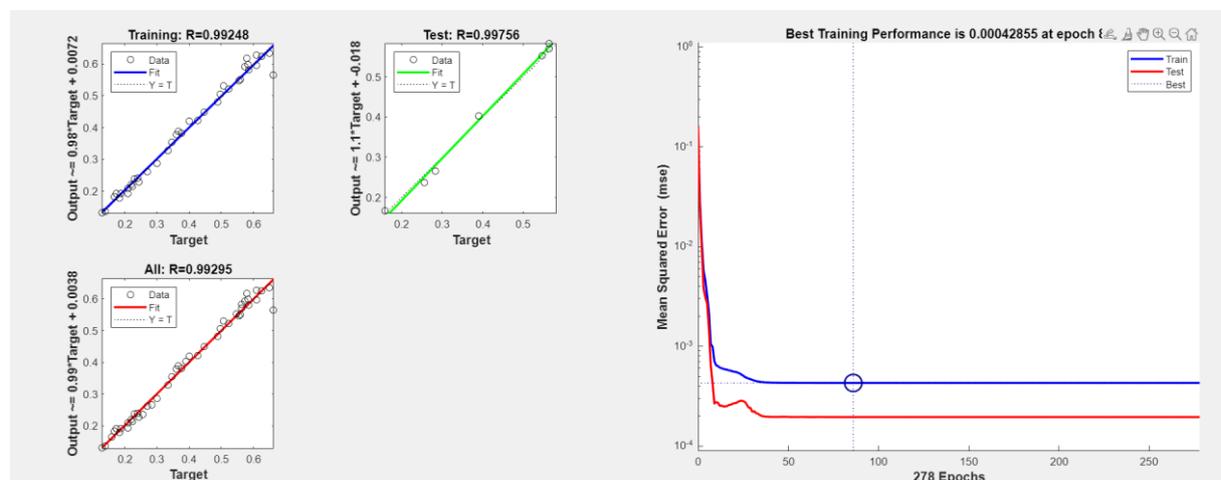


Рис.7. Алгоритм Байесовской регуляции (10 нейронов в скрытом слое)
Fig.7. Bayesian regulation algorithm (10 neurons in a hidden layer)

Аналогично были построены сети, содержащие в скрытом слое 50 нейронов, а результаты вычисления коэффициентов корреляции сведены в табл.2.

Таблица 2. Результаты вычисления коэффициентов вариации
 Table 2. Results of calculation of coefficients of variation

	Training		Validation		Test		All	
	10	50	10	50	10	50	10	50
Алгоритм Левенберга-Марквардта	0,95795	0,99976	0,93163	0,84674	0,9364	0,81636	0,9423	0,91453
Масштабируемый алгоритм сопряженных градиентов	0,9929	0,9969	0,98865	0,6049	0,9672	0,53549	0,9870	0,80543
Алгоритм Байесовской регуляции	0,99248	0,9992	-	-	0,99756	0,96169	0,99295	0,9919

ЗАКЛЮЧЕНИЕ

Проведя анализ качества аппроксимации зависимости прочности жаростойкого пенобетона от состава смеси нейронной сетью с одним слоем скрытых нейронов в зависимости от выбранного метода обучения и количества нейронов скрытого слоя, можем сделать вывод, что алгоритм Байесовской регуляции лучше подходит для решения данной задачи с новыми составами, которые отсутствовали в обучающей выборке

и как следствие позволяет с большей точностью масштабировать решение на более широкий диапазон значений, тем самым предсказывать величину прочности жаростойкого пенобетона новых, ранее не испытанных составов. Коэффициент вариации тестовой выборки для сети с 10 нейронами в скрытом слое, обученной по этому алгоритму, после 38 эпохи обучения равен 0,99756, против 0,9364 у алгоритма Левенберга-Марквардта и 0,9672 у алгоритма сопряженных градиентов. Причем точность работы сети незначительно меняется при увеличении числа нейронов скрытого слоя, и мы можем остановиться на сети, содержащей 10 скрытых нейронов.

СПИСОК ЛИТЕРАТУРЫ

1. Карпович М.А. Нейросетевые методы оценки затрат на научно-исследовательские и проектно-испытательские работы // Вестник Воронежского государственного университета инженерных технологий. 2014. № 1(59). С. 235-240. EDN: SDHBLJ.
2. Свидетельство о государственной регистрации программы для ЭВМ № 2020660892 Российская Федерация. Программный компонент "Нейросетевые расчеты - построение моделей прогноза осложнений и аварийных ситуаций при бурении и строительстве скважин" (ПКНР): № 2020660182: заявл. 08.09.2020; опубл. 15.09.2020 // Н. А. Еремин, А. Н. Дмитриевский, О. К. Чащина-Семенова [и др.]; заявитель Федеральное государственное бюджетное учреждение науки Институт проблем нефти и газа Российской академии наук.
3. Панкевич О. Д., Штовба С. Д. Діагностування тріщин будівельних конструкцій за допомогою нечітких баз знань. Монографія. Вінниця: УНІВЕРСУМ Вінниця, 2005. С. 108.
4. Ротштейн А.П. Медицинская диагностика на нечеткой логике. Вінниця: Континент - ПРИМ, 1996. С. 132.
5. Ротштейн А.П. Интеллектуальные технологии идентификации: нечеткая логика, генетические алгоритмы, нейронные сети. - Вінниця: УНІВЕРСУМ - Вінниця, 1999. С. 320.
6. Тонков Ю.Л. Математические модели для идентификации категории технического состояния строительных конструкций на основе нечеткой логики // Диссертация на соискание ученой степени кандидата технических наук. Пермский национальный исследовательский политехнический университет. 2018. С. 208.
7. Максимова О.М. Разработка и применение нейросетевой технологии прогнозирования к задачам строительной механики и конструкций // Междунар. Конгресс «Наука и инновации в строительстве» SIB. 2008: сб. науч. тр. Воронеж. 2008. С. 146–151.
8. Максимова О.М. Создание и применение нейросетевой технологии для прогнозирования в строительных конструкциях и строительной механике // Фундаментальные и прикладные проблемы науки: сб. науч. тр. I Международного симпозиума. 2010. Т. 2. С. 3–24.
9. Максимова О.М. Развитие и применение нейросетевых технологий для задач механики и строительных конструкций // Вестник Иркутского государственного технического университета. 2013. № 8(79). С. 81-89. EDN RASWYX.
10. Looney C. Pattern Recognition Using Neural Networks: Theory and Algorithms for Engineers and Scientists. Oxford University Press. 1997. P. 458.
11. Cybenko G. V. Approximation by Superpositions of a Sigmoidal function // Mathematics of Control Signals and Systems. 1989. Т. 2, № 4. С. 303-314.

ОБ АВТОРАХ

Дмитрий Владимирович Бородин – курсант кафедры «Специальные сооружения ракетно-космических комплексов». Военно-космическая академия имени А.Ф. Можайского. 197198, Россия, г. Санкт-Петербург, Ждановская ул., д. 13. E-mail: dmitriy_working@mail.ru

Светлана Сергеевна Рябова – научный сотрудник кафедры «Специальные сооружения ракетно-космических комплексов». Военно-космическая академия имени А.Ф. Можайского. 197198, Россия, г. Санкт-Петербург, Ждановская ул., д. 13. E-mail: sergeeva_ss@mail.ru

ABOUT THE AUTHORS

Dmitrij V. Borodin – Cadet of the Department of «Special Structures of Rocket and Spase Complexes». Military Space Academy named after A.F. Mozhaysky. 197198, Russia, St. Petersburg, Zhdanovskaya str., 13. E-mail: dmitriy_working@mail.ru

Svetlana S. Ryabova – researcher of the department «Special structures of rocket and space complexes». Military Space Academy named after A.F. Mozhaysky. 197198, Russia, St. Petersburg, Zhdanovskaya str., 13. E-mail: sergeeva_ss@mail.ru