



РЕГУЛИРОВАНИЕ ВЛАЖНОСТИ БЕТОННОЙ СМЕСИ С ПРИМЕНЕНИЕМ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Е.А. Муравьева (ФГБОУ ВО «Уфимский государственный нефтяной технический университет»)
Э.Р. Еникеева (ГБОУ ВО «Альметьевский государственный нефтяной институт»)

Рассмотрен подход к автоматизированному регулированию влажности бетонной смеси на базе искусственных нейронных сетей. Предложен алгоритм оценки влажности смеси. Показано, что в условиях данного процесса наилучшей является нейронная сеть, созданная на основе алгоритма Левенберга-Марквардта.

Ключевые слова: бетонная смесь, искусственная нейронная сеть, моделирование, нейрон, влажность.

Введение

Промышленное производство является одним из наиболее перспективных направлений для использования искусственных нейронных сетей (ИНС). Тенденция перехода к высокоавтоматизированным производственным модулям требует увеличения числа «интеллектуальных» объектов, способных к саморегуляции и самонастройке. Однако производственным процессам присуще огромное множество взаимосвязанных параметров, что крайне усложняет создание аналитических моделей, аппроксимирующих процесс с необходимой точностью. Сложность производства неуклонно растет. Это приводит к стагнации во внедрении новых технологических решений. Помимо этого, в некоторых случаях аналитические модели, которые успешно моделируют технологический процесс, невозможно использовать из-за недостатка вычислительных мощностей. Поэтому существует необходимость в нахождении альтернативных подходов в моделировании производственных процессов. Одним из них является использование ИНС, предоставляющих возможность создавать модели, которые работают в реальном времени и обладают малыми погрешностями. Учитывая эти свойства нейронных сетей, их можно использовать для решения таких задач, как: прогнозирование, проектирование автоматизированных систем управления, управление качеством, управление манипуляторами роботов, машинное зрение, визуализация диспетчерской информации и т.д.

В промышленном производстве ИНС могут найти применение при создании модели управления рисками, планировании производственного цикла предприятия, обеспечении информационной безопасности сетей связи. Аналитические модели построены на теоретических представлениях о принципах работы объекта и точно прогнозируют лишь относительно простые системы.

В свою очередь ИНС обучается на основе данных экспериментов и могут моделировать работу объекта с большим числом изменяющихся параметров.

Рассмотрим возможности применения ИНС для регулирования влажности бетонной смеси.

Описание объекта автоматизации

Бетон, железобетон и строительные растворы являются основным строительным материалом, который повсеместно применяется при строительстве любых объектов. Для получения бетонной смеси необходимы такие материалы, как цемент определенной марки, гравий, щебень, песок и вода. Свойства получаемого бетона зависят не только от выбранной марки цемента, но и от количества добавляемой воды в раствор и температуры окружающей среды.

Следовательно влажность — один из главных параметров, которыми следует управлять. От водоцементного соотношения зависит скорость схватывания, устойчивость и прочность конструкции. Поэтому необходимо поддерживать баланс. При избытке влаги цемент не сможет связать компоненты смеси в единое целое и бетон получится некачественным. При недостатке воды бетон затвердеет слишком быстро и будет иметь низкую прочность.

Для бетона марки М400 влажность должна находиться в диапазоне 16...18%. Если влажность меньше 16% необходимо добавить воды, если больше 18% - остальные компоненты смеси (цемент, заполнитель, гравий, пластификатор).

С учетом данных обстоятельств необходим постоянный мониторинг основных параметров процесса. Влажность предлагается контролировать при помощи микропроцессорной системы мониторинга влажности, которая функционирует на основе интеллектуальных датчиков¹.

¹ Пат. 2444725 РФ. Способ оценки влажности пастообразного материала в процессе его сушки в вальцеленточной сушильной установке/Артемова С.В., Грибков А.Н., Брянкин К.В., Назаров А.С.; заявитель и патентообладатель ТГТУ; опубл. 10.03.2012 г.

Таблица 1. Данные для обучения нейронной сети

Изначальная влажность смеси	Температура ОС	Влажность ОС	Итоговая влажность
17,78	22,48	71,10	15,34
15,11	24,82	69,79	20,15
15,94	24,05	70,76	18,69
17,48	22,87	69,43	15,79
16,95	23,24	71,80	17,01
16,64	23,13	71,69	17,23
18,90	23,51	66,62	14,82
...
16,15	22,89	66,94	16,88
17,22	23,20	68,25	16,28

База технического обеспечения системы мониторинга влажности включает микроконтроллер MSP430 фирмы Texas Instruments и датчики влажности и температуры SH15. В состав ПО системы мониторинга влажности входят: модуль опроса датчиков, модуль расчета влажности материала, базы знаний и данных. Математическим обеспечением служит нейросетевая модель косвенного измерения влажности бетонной смеси.

Определение влажности материала

Определение влажности материала производится следующим образом. Измерения факторов, влияющих на процесс производства бетонной смеси, проводят группами датчиков – общими и датчиками, установленными в бетоносмесителе. Общие датчики нужны для снятия показаний влажности и температуры окружающей среды; датчики, установленные в бетоносмесителе, предназначены для определения влажности смеси.

Используется способ бесконтактного контроля влажности в реальном режиме времени с использованием инфракрасного влагомера ММ710. Преимущества метода: работа в реальном режиме времени и точное бесконтактное измерение влажности.

После получения информации от датчиков, необходимо установить, удовлетворяет ли влажность бетонной смеси требованиям технологического процесса. Для этого предлагается использовать искусственную нейронную сеть.

Выбранная архитектура нейросетевых моделей обуславливает необходимость нормализации выборок данных. Имея разный физический смысл, они могут существенно различаться по абсолютным значениям. Например, выборка содержит температуру, измеряемую

в десятках градусов Цельсия, и электрическую емкость, измеряемую в миллиардных долях Фарада. Нормализация дает возможность привести все используемые числовые значения переменных к одинаковой области их изменения, благодаря чему появляется возможность свести их вместе в одной нейросетевой модели.

Для проведения операции нормализации данных, необходимо точно знать границы изменения значений соответствующих переменных. Им будут соответствовать пределы интервала нормализации. Когда точно установить пределы изменения переменных невозможно, они задаются с учетом минимальных и максимальных значений в имеющейся выборке данных.

С сигналами, поступающими с датчиков, проводят операцию нормализации, затем подают на входы заранее обученной нейросети. На выходе получают оценку текущей влажности материала в бетоносмесителе.

Входами сети являются нормализованные значения x_1 – изначальная влажность смеси; x_2 – температура окружающей среды; x_3 – влажность окружающей среды. Выходом является значение итоговой влажности. Обучение нейронной сети организуют по образцовым мерам технологических параметров в адаптивном диапазоне бетоносмесителя с фиксированной точностью. Образцовые меры оценивались согласно ГОСТ 12730.2-78. «Бетоны. Метод определения влажности». Нормализация данных производится по формуле

$$x_q^n = x_q K_{амт}^n + K_{оф}^n, q = \overline{1, Q},$$

- где q – номер входа нейронной сети;
- x_q^n, x_q нормированное и ненормированное значение q -го входа нейронной сети соответственно;
- $K_{амт}^n, K_{оф}^n$ амплитудный и офсетный коэффициенты нормализации;
- Q – число входов нейронной сети для расчета влажности смеси φ_i^k в бетоносмесителе.

Алгоритм оценки влажности смеси состоит из следующих шагов.

- Шаг 1. Опрос датчиков бетоносмесительной установки и вычисление значений входов нейронной сети.
 - Шаг 2. Проверка условия вхождения измеренных значений в адаптивные диапазоны значений, использовавшихся при обучении нейронной сети. В случае невыполнения условия данные записываются в память, и отправляется сообщение пользователю.
 - Шаг 3. Нормализация полученных значений.
 - Шаг 4. Расчет влажности материала по аналитической модели.
 - Шаг 5. Денормализация значения влажности материала.
 - Шаг 6. Сохранение рассчитанного значения в память.
- Рассмотрим три метода обучения нейронных сетей и выберем оптимальный:
- 1) алгоритм Левенберга-Марквардта;
 - 2) Байесовская регуляризация;
 - 3) метод сопряженных градиентов.




Рис. 1. Настройка параметров нейронной сети

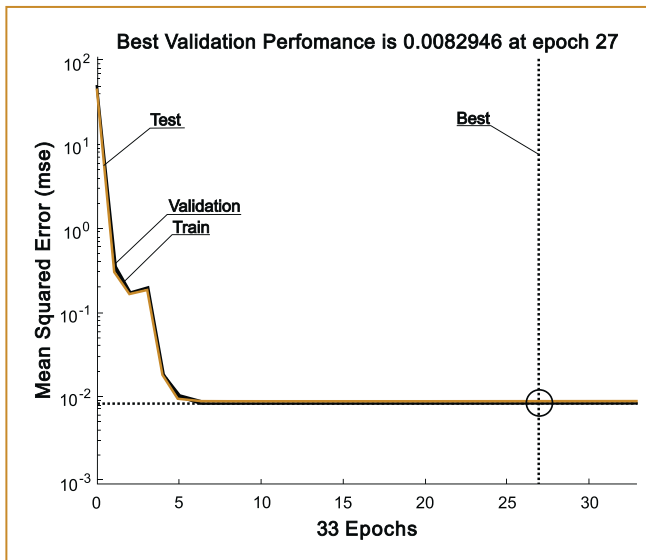


Рис. 2. Функция *plotperform* для алгоритма Левенберга-Марквардта

Нейросети для всех трех методов создавались в программном пакете Matlab. База данных для обучения сети каждым из трех алгоритмов состоит из 1008 образцов. Фрагмент данных для обучения сети представлен в табл. 1.

Данные разбиваются на три группы:

1) тренировочные – предоставляются сети во время обучения, и сеть корректируется в соответствии с ее ошибкой (706 образцов);

2) проверочные – используются для измерения обобщения сети и остановки обучения, когда обобщение перестает улучшаться (151 образец);

3) тестировочные – не влияют на обучение и поэтому обеспечивают независимую оценку производительности сети во время и после обучения (151 образец).

Для решения поставленной задачи создадим двухслойную сеть обратного распространения ошибки, включающую 10 нейронов во входном слое с передаточной функцией *logsig* (вычисляет выход слоя по его входу.), один нейрон во втором слое с передаточной функцией *logsig* и один нейрон в выходном слое с передаточной функцией *purelin* (реализует однонаправленную сеть, обучаемую с применением алгоритма обратного распространения). Структура сети представлена на рис. 1.

Следующий шаг – обучение нейронной сети. Выберем наиболее подходящий для этого алгоритм.

Выбор метода обучения нейросети

Алгоритм Левенберга-Марквардта (метод оптимизации, направленный на решение задач о наименьших квадратах)

предназначен для оптимизации параметров нелинейных регрессионных моделей. Предполагается, что в качестве критерия оптимизации используется среднеквадратичная ошибка модели на обучающей выборке. Алгоритм заключается в последовательном приближении заданных начальных значений параметров к искомому локальному оптимуму.

После обучения нейронной сети воспользуемся функциями *plotperform* (рис. 2) и *plotregression* (рис. 3) для оценки качества работы сети. Лучшая производительность (0,0082946) достигается на 27-й эпохе.

Функция обучения использует в качестве средства борьбы с переобучением обучение с ранним остановом. Из графика видно, что обучение остановлено, когда ошибка на проверочном множестве перестала уменьшаться.

Перед использованием нейронной сети необходимо проанализировать валидность результатов вычислений нейросети на тестовом множестве входных векторов. В качестве тестировочных данных требуется использовать массив, элементы которого отличаются от элементов массива, использованного для обучения нейронной сети.

Для оценки надежности итогов работы сети воспользуемся результатами регрессионного анализа, полученными при сравнении эталонных значений со значениями на выходе сети, когда на вход поданы входные векторы тестового массива данных. Для этого можно применить функцию *postreg*.

Графики на рис. 3 показывают линейную регрессию результатов обучения сети на трех рассмотренных под-

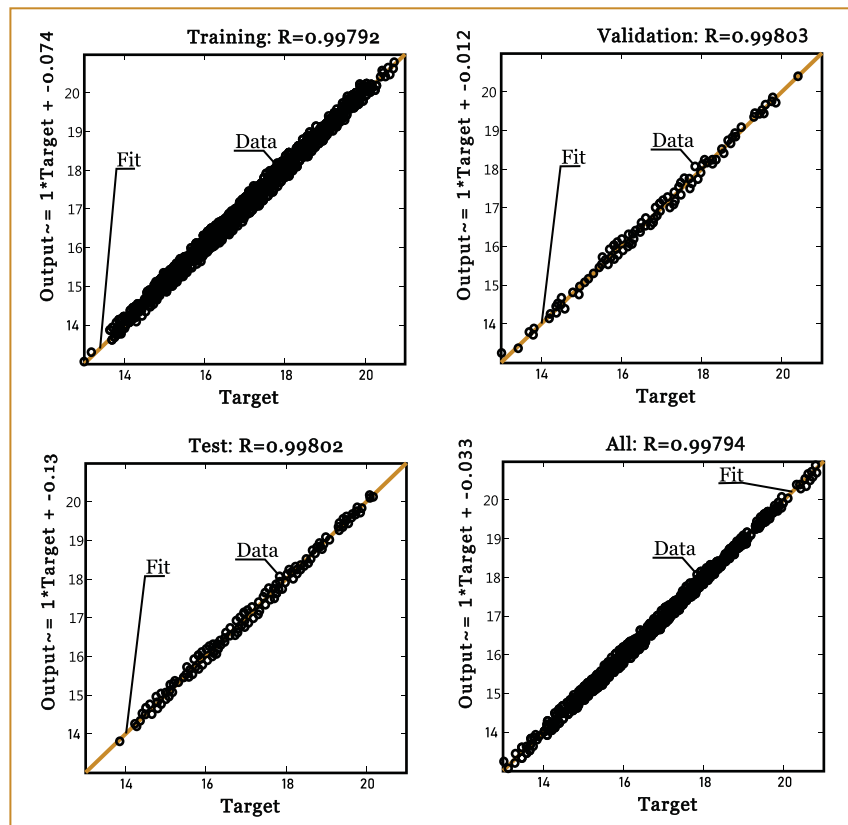


Рис. 3. Функция *plotregression* для алгоритма Левенберга-Марквардта

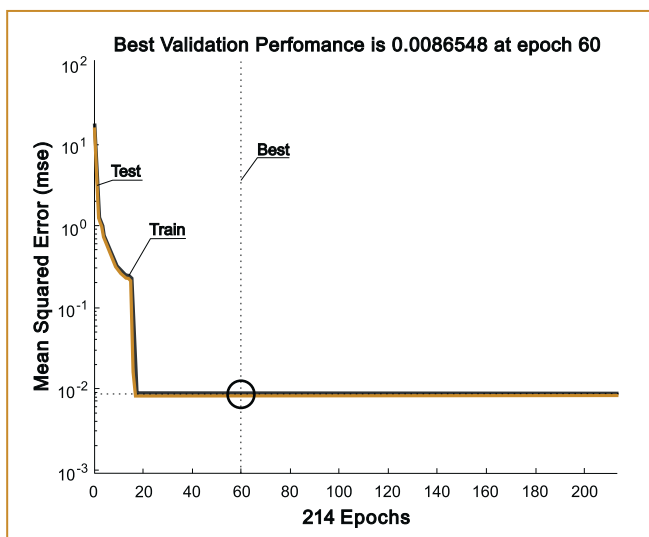


Рис. 4. Функция *plotperform* для байесовской регуляризации

множествах (training, validation и test) и на всех множествах. Для каждого результата рассчитывается коэффициент корреляции R , строится график и выводится уравнение регрессии в виде $Output = a \times Target + b$. При полном совпадении выходов сети с целевыми значениями $R=1$, $a=0$, $b=0$.

Коэффициенты корреляции для алгоритма Левенберга-Марквардта:

$$R_{Tr} = 0,99792; R_V = 0,99803; R_{Te} = 0,99802; R_A = 0,99792.$$

В байесовском подходе выбор того или иного решения h ведется в рамках некоторой модели H , задающей ограничения на его вид. Решение выбирается как наиболее вероятное. Преимуществом данного метода является то, что нейросети, созданные при его помощи, практически невозможно переобучить, так как параметры являются облаком вероятности. Переобучение нейросети происходит, когда модель нейросети слишком сильно подстраивают под имеющиеся данные. При поступлении данных, которые отсутствуют в БД, нейросеть начнет работать некорректно.

После обучения нейронной сети воспользуемся функциями *plotperform* (рис. 4) и *plotregression* (рис. 5) для оценки качества работы сети.

Лучшая производительность (0,0086548) достигается на 60-й эпохе.

Коэффициенты корреляции для алгоритма байесовской регуляризации: $R_{Tr} = 0,99796$; $R_{Te} = 0,99794$; $R_A = 0,99795$;

Метод сопряженных градиентов — итерационный метод для безусловной оптимизации в многомерном простран-

*Хотя в мире нет предмета,
который был бы слабее
и нежнее воды, но она может
разрушить самый
твердый предмет.*

Лао-цзы

стве. Метод сопряженных градиентов часто реализуется как итерационный алгоритм, применимый к разреженным системам, которые слишком велики, чтобы их можно было обрабатывать прямой реализацией или другими прямыми методами. Большие разреженные системы часто возникают при численном решении уравнений в частных производных или задач оптимизации. Метод сопряженных градиентов также может использоваться для решения задач неограниченной оптимизации, таких как минимизация энергии. Метод двусопряженных градиентов обеспечивает обобщение на несимметричные матрицы. Различные нелинейные методы сопряженных градиентов ищут минимум нелинейных уравнений и целевых функций черного ящика.

После обучения нейронной сети воспользуемся функциями *plotperform* (рис. 6) и *plotregression* (рис. 7) для оценки качества работы сети.

Максимальная производительность (0,01017) достигается на 156-й эпохе. Эта производительность является худшей из трех методов.

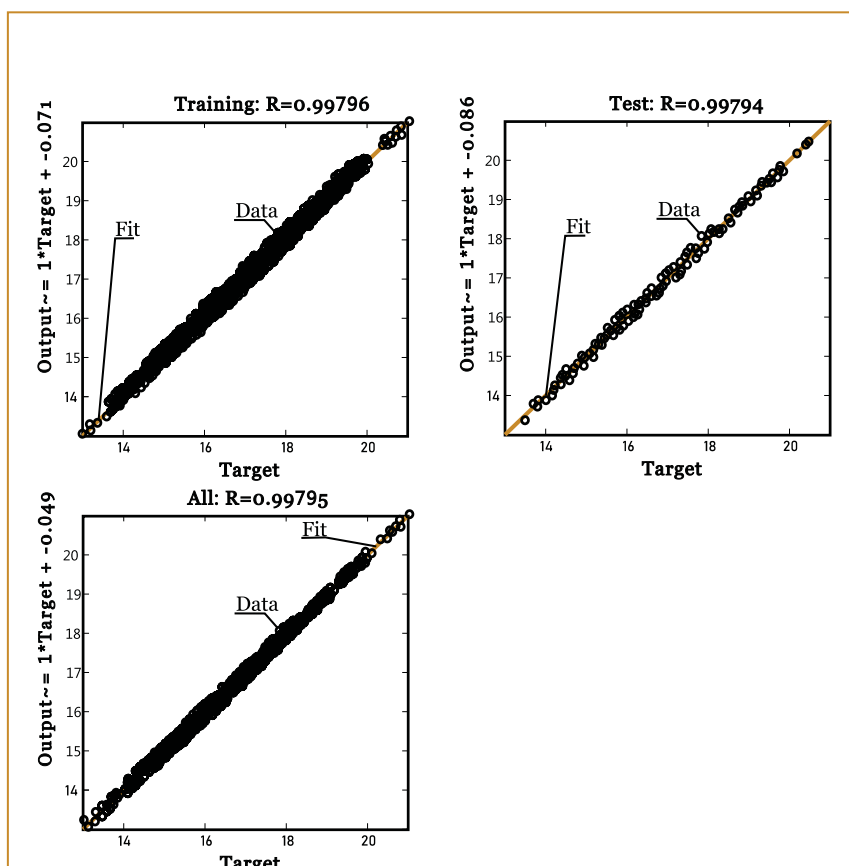


Рис. 5. Функция *plotregression* для байесовской регуляризации

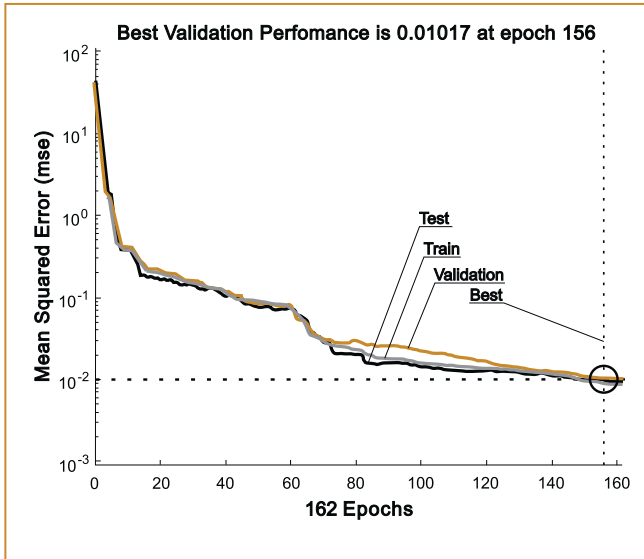


Рис. 6. Функция plotperform для метода сопряженных градиентов

Таблица 2. Пример оценки влажности смеси нейросетью

x1	x2	x3	Образцовая мера Φ_i	Оценка влажности по модели Φ_i	Абсолютная погрешность	Относительная погрешность
17,98	24,05	73,01	17,06	17,14	0,08	0,48
17,62	23,79	66,82	16,23	16,30	0,07	0,41
16,91	23,41	71,31	17,16	17,31	0,15	0,87
18,04	24,05	67,42	16,28	16,24	0,04	0,23
17,18	24,54	70,32	17,87	18,03	0,16	0,91
17,38	23,60	69,93	16,76	16,82	0,06	0,38
16,73	22,78	68,66	16,52	16,46	0,07	0,41
16,09	24,69	70,79	19,33	19,35	0,02	0,10
17,51	22,85	69,57	16,04	15,88	0,16	1,00
18,18	22,95	69,13	15,15	15,24	0,09	0,60

Коэффициенты корреляции для алгоритма сопряженных градиентов: $R_{Tr} = 0,99786$; $R_V = 0,9974$; $R_{Te} = 0,99734$; $R_A = 0,99773$;

- Анализ данных, приведенных на рис. 2-7, показал, что:
- 1) лучшая производительность (0,0082946) достигнута в методе Левенберга-Марквардта;
 - 2) лучший коэффициент корреляции тренировочных данных ($R_{Tr} = 0,99796$) достигнут в алгоритме байесовской регуляризации;

3) лучший коэффициент корреляции проверочных данных ($R_V = 0,99803$) достигнут в алгоритме Левенберга-Марквардта;

4) лучший коэффициент корреляции тестировочных данных ($R_{Te} = 0,99802$) достигнут в алгоритме Левенберга-Марквардта;

5) лучший коэффициент корреляции ($R_A = 0,99795$) достигнут в алгоритме байесовской регуляризации.

Таким образом, в условиях данного процесса наилучшей является нейронная сеть, созданная на основе алгоритма Левенберга-Марквардта.

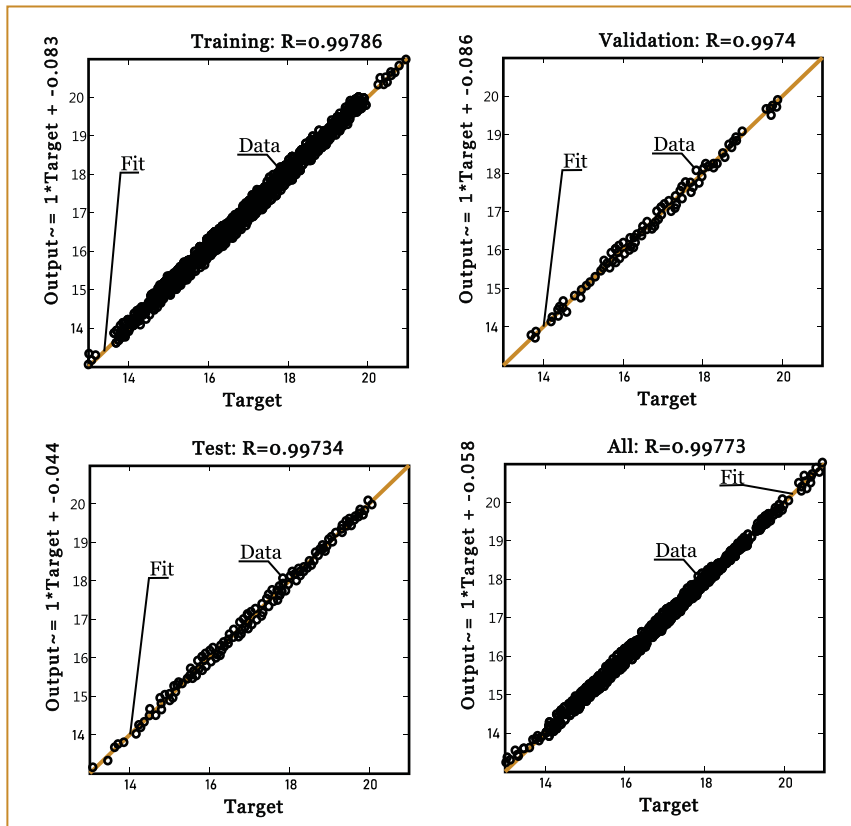


Рис. 7. Функция plotregression для метода сопряженных градиентов

Для использования обученной сети для обработки данных необходимо воспользоваться функцией sim.

Например, пусть имеются следующие входные данные (x_1 — изначальная влажность смеси; x_2 — температура окружающей среды; x_3 — влажность окружающей среды): $x_1 = 17,98$; $x_2 = 24,05$; $x_3 = 73,01$.

Функция sim примет следующий вид: `sim(net, [17.98;24.05;73.01])`. Результатом выполнения функции будет итоговая влажность, равная 17,14%. Измеренная в лаборатории влажность для этих входных параметров — 17,06%. В табл. 2 приведен пример оценки влажности смеси нейросетью.

На вход нейросети поступают значения с трех входов (x_1 ; x_2 ; x_3), значения каждого из входов умножаются на весовые коэффициенты, полученные в ходе обучения сети. Рассчитанные значения суммируются и образуют входную информацию. Теперь можно получить выходные данные, подставив входную

информацию в функцию активации (функция активации — это способ нормализации входных данных). Полученное значение является оценкой влажности φ_i бетонной смеси нейросетью. При выходе значения φ_i за рамки технологического процесса нейросеть через OPC-сервер посылает команду в SCADA-систему для подачи воды, если влажность ниже необходимой, или компонентов цемента, если выше.

Для приведенных в таблице данных максимальная абсолютная погрешность не превышает 0,16, а относительная — 1%.

Вывод

В результате проведенных исследований удалось создать искусственную нейронную сеть, которая позволяет поддерживать заданный уровень влажности бетонной смеси.

Были рассмотрены три алгоритма: алгоритм Левенберга-Марквардта; байесовская регуляризация; метод сопряженных градиентов. Проведенные исследования показали, что максимальные результаты достигаются при использовании метода Левенберга-Марквардта. В результате проведенных тестов сделан вывод об адекватности модели, так как полученные значения согласуются с экспериментальными данными. Абсолютная погрешность при данном алгоритме составила 0,16, а относительная 1%.

Список литературы

1. *Спицын В.Г., Цой Ю.Р.* Применение искусственных нейронных сетей для обработки информации: методические указания к лабораторным работам. — Томск: Изд-во ТПУ, 2007. — 31 с.
2. *Бурков М.В.* Нейронные сети и нейроконтроллеры: Уч. пособие. СПб.: ГУАП, 2013. 284 с.
3. *Ахметов Б.С., Горбаченко В.И.* Нейронные сети. Лабораторный практикум. Алматы, 2015.
4. *Muravyova E.* Intellectual control of oil and gas transportation system by multidimensional fuzzy controllers with precise terms / Muravyova E., Sagdatullin A., Emekeev A. // Applied Mechanics and Materials. 2015. Т. 756. С. 633.
5. *Muravyova E.* The analysis of opportunities of construction and use of avionic systems based on cots-modules / Muravyova E., Bondarev A., Kadyrov R., Rahman P. // ARPN Journal of Engineering and Applied Sciences / 01.2016. Vol. 11.
6. *Muravyova E.A.* Simulation of Multidimensional Non-Linear Processes Based on the Second Order Fuzzy Controller / Muravyova E.A., Solovov K.A., Soloveva O.I., Sultanov R.G., Charikov P.N. // Key Engineering Materials, Vol. 685, pp. 816-822, Mar. 2016.
7. *Rahman P. A., Muraveva E. A., Sharipov M. I.* Reliability Model of Fault-Tolerant Dual-Disk Redundant Array // Key Engineering Materials. 2016. Vol. 685, pp 805-810.
8. *Muravyova E.A.* The Questions of Circuitry Design when Forming the Switching Functions of the Control System of the Matrix Frequency Converter / Muravyova E.A., Bondarev A.V., Kadyrov R.R., Shulaeva E.A. // Indian Journal of Science and Technology. V. 8(S10), 2015. PP. 1-8.
9. *Muravyova E.A.* Two fuzzy controller synthesis methods with the double base of rules: Reference points and training using // Industrial Engineering, Applications and Manufacturing (ICIEAM) : International Conference on Industrial Engineering, Applications and Manufacturing, 16-19 May 2017 / IEEE. - СПб., 2017.
10. *Muravyova E.A.* Simulation of salt production process // IOP Conference Series: Earth and Environmental Science : IPDME 2017 / IOP Publishing. - 2017. - Vol. 87. - 052018.
11. *Muravyova E.A.* Chlorine condenser-evaporatorsimulation // IOP Conference Series: Earth and Environmental Science : IPDME 2017 / IOP Publishing. - 2017. - Vol. 87. - 082032.
12. *Muravyova E.A., Sharipov M. I.* Method of fuzzy controller adaptation // Proceedings of the International Conference "Actual Issues of Mechanical Engineering" 2017 (AIME 2017). November 2017.
13. *Muravyova E.A., Shulaeva E.A., Charikov P.N. and et.* Optimization of the structure of the control system using the fuzzy controller // 9th International Conference on Theory and Application of Soft Computing, Computing with Words and Perception, (ICSCCW 2017), Budapest. Procedia Computer Science. Vol. 120. 2017. PP. 487-494.

Муравьева Елена Александровна — д-р техн. наук, проф., заведующая кафедрой АТИС, Филиал ФГБОУ ВО «Уфимский государственный нефтяной технический университет» в г. Стерлитамаке,
Еникеева Эльза Рашитовна — канд. техн. наук, доцент кафедры «Электро- и теплоэнергетика», ГБОУ ВО «Альметьевский государственный нефтяной институт».
 E-mail: muraveva_ea@mail.ru, elza.enikeeva@mail.ru

Schneider Electric запускает работу Центра Цифровых Услуг для внешних заказчиков

Компания Schneider Electric объявила о начале работы Центра Цифровых Услуг (Digital Hub, ЦЦУ) для внешних заказчиков в России и странах СНГ. Основная задача Digital Hub — реализация комплексных проектов с цифровой составляющей. Центр Цифровых Услуг действует по двум основным направлениям.

- Реализация цифровых проектов «под ключ». Schneider Electric предлагает широкое разнообразие программных продуктов: от облачных систем аналитики и мониторинга до мощных локальных программных комплексов. Основная функция ЦЦУ — помочь разобраться в многообразии продуктов, предложить и реализовать

цифровые решения под актуальные и нестандартные задачи для экономики и оптимизации рабочего процесса организации.

- Техническое и документальное сопровождение облачных решений серии Advisor (Советчик). Возможности этих аналитических систем позволяют следить за работой оборудования в режиме реального времени и анализировать ее путем выявления закономерностей в большом массиве получаемых данных, а также предлагают опцию консультации в случае возникновения нештатной ситуации, которую проводит группа локальных и международных экспертов Schneider Electric.

<https://www.se.com/ru/ru/>