

УДК 502/504 : 628.171

С. Н. КАРАМБИРОВ, М. А. МОРДЯСОВ, Ю. Г. БУРКОВА

Федеральное государственное бюджетное образовательное учреждение высшего профессионального образования «Российский государственный аграрный университет – МСХА имени К. А. Тимирязева»
Институт природообустройства имени А. Н. Костякова

ПРИМЕНЕНИЕ КЛАСТЕРНОГО АНАЛИЗА И НЕЙРОННЫХ СЕТЕЙ ДЛЯ АНАЛИЗА КАЧЕСТВА ФУНКЦИОНИРОВАНИЯ ИНЖЕНЕРНЫХ СЕТЕЙ В ШТАТНЫХ И ПОСЛЕАВАРИЙНЫХ УСЛОВИЯХ

Приведены общие сведения о нейронных сетях, используемых для решения задач кластеризации. Применение этого аппарата для системы водоснабжения реального объекта позволило выявить закономерности работы системы по напорам и отборам воды для штатных и аварийных режимов.

Водоснабжение, гидравлическая увязка, система подачи и распределения воды, кластерный анализ, нейронные сети.

There are given general data on the neural networks used for solving clustering tasks. Usage of this apparatus for the water supply system of the real object made it possible to reveal regularities of the work of the system on heads and selections of water for normal and emergency states.

Water supply, hydraulic linkage, water supply and distribution system, cluster analysis, neural networks.

В последнее время для решения практических задач все чаще используют искусственные нейронные сети. Они имеют ряд преимуществ по сравнению с другими вычислительными моделями: адаптивность, обучаемость, обобщающую способность и т.д.

Публикации об использовании нейронных сетей в гидравлике и гидрологии начали появляться в девяностые годы прошлого столетия. В последнее время количество таких публикаций увеличивается. Хотя нейронные сети сравнительно новое направление, нейросетевые алгоритмы конструктивно применяют для решения самых разных задач.

В данной статье рассмотрены вопросы применения нейронных сетей для решения задач кластеризации. Нейронные сети позволяют объединять объекты напорных трубопроводных систем, гидравлические характеристики которых имеют сходные признаки.

Под нейронными сетями подразумеваются вычислительные структуры, которые моделируют простые биологические процессы, обычно ассоциируемые с процессами человеческого мозга [1]. Элементарным преобразователем в нейронных сетях (НС) является искусственный нейрон, названный так по аналогии с биологическим

прототипом. К настоящему времени предложено много моделей нейронных сетей.

Структура искусственного нейрона показана на рисунке 1. В состав нейрона входят множители (синапсы), сумматор и нелинейный преобразователь. Синапсы умножают входной сигнал x на число, характеризующее силу связи – вес синапса w . Сумматор выполняет сложение сигналов, поступающих по синаптическим связям, и внешних входных сигналов. Нелинейный преобразователь представляет собой функцию одного аргумента – выход сумматора. Эта функция называется функцией активации, или передаточной функцией нейрона.




Рис. 1. Структура искусственного нейрона

В целом нейрон реализует скалярную функцию y векторного аргумента:

$$S = \sum_{i=1}^n w_i x_i + b; \quad (1)$$

$$y = f(S),$$

где w_i – вес синапса; b – значение смещения; S – результат суммирования; y – выходной сигнал нейрона; f – нелинейная функция активации.

Синаптические связи с положительными весами называют возбуждающими, с отрицательными – тормозящими. Одной из наиболее распространенных является нелинейная функция активации с насыщением – логистическая функция, или сигмоид:

$$f(S) = \frac{1}{1 + e^{-S}}. \quad (2)$$

Перед применением сеть должна быть обучена подбором соответствующих синапсов w . Если выходной сигнал известен, этот процесс называется обучением с учителем. Если выходной сигнал заранее не известен, получаем обучение без учителя. Как и в случае обучения с учителем, он заключается в подстройке весов синапсов. Оказывается, сеть способна обобщать схожие образы, относя их к одному классу.

Простейшие нейронные сети получили название персептронов. Они состоят из одного слоя искусственных нейронов, соединенных с помощью весовых коэффициентов с множеством входов.

Рассмотрим одну из разновидностей нейронных сетей – сеть Кохонена. Она предназначена для разделения входных векторов на подгруппы. Компоненты входных векторов подаются на входы всех нейронов сети. В процессе обучения без учителя настраиваются синаптические веса нейронов. После предъявления достаточного количества входных векторов синаптические веса определяют кластеры. Сеть может быть использована для кластерного анализа, если заранее известно число кластеров.

В своей простейшей одномерной форме сеть представляет собой так называемый «слой Кохонена», который функционирует по правилу «победитель получает все».

Выход каждого нейрона Кохонена является просто суммой взвешенных элементов входов:

$$S_j = w_{1j}x_1 + w_{2j}x_2 + \dots + w_{nj}x_n = \sum x_i w_{ij}, \quad (3)$$

где S_j – выход j -го нейрона; $W_j = w_{1j}, w_{2j}, \dots, w_{nj}$ – вектор весов j -го нейрона Кохонена; $X = x_1, x_2, \dots, x_n$ – вектор входного сигнала.

Нейрон Кохонена с максимальным значением S_j является «победителем». Его выход равен единице, у остальных он равен нулю.

Слой Кохонена классифицирует входные векторы в группы сходных векторов. Это достигается с помощью такой подстройки весов, когда близкие входные векторы активизируют один и тот же нейрон слоя. Слой Кохонена обучается без учителя, в результате чего слой приобретает способность разделять несхожие входные векторы.

При обучении слоя Кохонена на вход подается вектор и вычисляется его скалярное произведение с векторами весов всех нейронов. Скалярное произведение является мерой сходства между входным вектором и вектором весов. Нейрон с максимальным значением скалярного произведения объявляется победителем, и его веса подстраиваются таким образом, чтобы весовой вектор приближался к входному:

$$W_n = W_c + \mu(X - W_c), \quad (4)$$

где W_n – новое значение веса; W_c – предыдущее значение этого веса; μ – параметр скорости обучения.

Каждый вес, связанный с выигравшим нейроном, изменяется пропорционально разности между его величиной и величиной входа, к которому он присоединен. Направление поправки минимизирует разность между весом и соответствующим элементом входного сигнала [1].

Для оценки эффективности работы напорных гидравлических систем используют стоимостные и физические категории: себестоимость 1 м³ воды; ее качество; затраты на строительство, реконструкцию и эксплуатацию системы, на обеспечение бесперебойности подачи воды потребителям и т. д. Вместе с тем, остаются в стороне такие характеристики системы, как разделение потребителей (узлов сети) по отборам и располагаемым напорам в штатных и аварийных ситуациях и т. д.

Такие объединения характеризуют правильность проектирования и эксплуатации системы, как правило, не имеют признаков функциональных зависимостей и обычно относятся к конкретному гидравлическому объекту. Применение к нему традиционных подходов регрессивного анализа не всегда является эффективным. Конструктивным в данном случае оказалось использование методов классификации и кластеризации. Оба подхода имеют много общего, но классификация образов предполагает наличие предварительно определенных классов, задание которых для напорных гидравлически систем возможно лишь в редких случаях.

По этой причине основное внимание

уделялось задачам кластеризации, которые помещают близкие образы в один кластер. В качестве инструмента кластеризации использовались нейронные сети, в частности слой Кохонена, схема которого представлена на рис. 2.




Рис. 2. Схема нейронной сети Кохонена

В качестве объекта изучения выбрана водопроводная сеть города Ленинградской области с населением 60 тыс. чел. План сети приведен на рис. 3, аппроксимация значений свободных напоров и земли – на рис. 4.




Рис. 3. План сети




Рис. 4. Аппроксимация значений свободных напоров и земли

На первом этапе проведена кластеризация узлов в штатных условиях работы. В качестве признаков выбраны свободные напоры и отборы в узлах гидравлической сети (рис. 5). Очевидно, функциональная зависимость в этом случае отсутствует. Данные группируются вокруг трех центров кластеров.

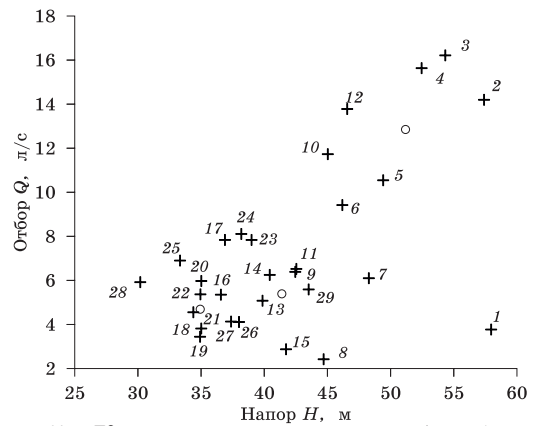


Рис. 5. Кластеризация узлов (свободных напоров и отборов) гидравлической сети, штатные условия (Кингсепп, цифрами у крестиков обозначены номера узлов, а кружками – центры кластеров)

Первый кластер в левом нижнем углу рисунка характеризуется небольшими значениями напоров (около 35 м, при среднем требуемом значении 30 м) и расходов (около 5 л/с). Это узлы на периферии сети с преобладанием жилого фонда.

Средний кластер с центром 42 м и 5,5 л/с группирует узлы в центре гидравлической сети. Основными потребителями здесь являются жители, коммунальные и промышленные предприятия.

Третий кластер с координатами центра 52 м и 13 л/с объединяет узлы, близкие к водопитателям с крупными промышленными предприятиями и многоэтажными домами, питаемыми от станций подкачки.

Аналогичный расчет выполнен для той же сети, но при отказе участка (3–4) и с учетом зависимости узловых расходов от располагаемых напоров (рис. 6) [2, 3].

Здесь данные также группируются вокруг центров трех кластеров, однако интерпретация результатов в данном случае иная. Первый кластер (слева направо) характеризуется высокой плотностью входящих в него элементов. Сюда попали узлы с напорами значительно меньше требуемого (30 м), что говорит об их отказах и частичной потере работоспособности системы. Число таких узлов превышает 2/3 от всех узлов системы, а отключение участка ведет к перебоям подачи воды в них (как правило, только на верхних этажах). Для второго и третьего кластеров разброс элементов значительно выше. Это узлы в начале и частично в середине гидравлической сети. Авария участка или вовсе не отражается на подаче воды (для третьего кластера) или приводит к незначительному снижению напора, что, скорее всего, не скажется на водопотреблении.




Рис. 6. Кластеризация узлов (свободных напоров и отборов), отказ участка (3–4), Кингисепп

Выводы

Использование методов кластеризации и нейронных сетей является эффективным средством анализа работы систем водоснабжения.

Анализ результатов позволяет сделать выводы о характере работы системы в штатных и аварийных ситуациях.

1. Дьяконов В. П., Круглов В. В. MATLAB 6.5 SP1/7/7 SP1/7 SP2 + Simulink 5/6. Инструменты искусственного интеллекта и биоинформатики. Серия «Библиотека профессионала». – М.:

Солон-Пресс, 2006. – 456 с.

2. Карамбиров С. Н. Новые подходы в моделировании и оптимизации трубопроводных систем. Основы, концепции, методы. – LAP LAMBERT Academic Publishing, 2012. – 355 с.

3. Карамбиров С. Н. Математическое моделирование систем подачи и распределения воды в условиях многорежимности и неопределенности: монография. – М.: ФГОУ ВПО МГУП, 2004. – 196 с.

Материал поступил в редакцию 11.04.14.

Карамбиров Сергей Николаевич, доктор технических наук, профессор кафедры «Информационные технологии в строительстве»

Тел. 8 (499) 153-97-66

E-mail: karamba.msuee@mail.ru

Мордясов Михаил Александрович, кандидат технических наук, зав. лабораторией трубопроводных систем и сооружений, член корреспондент академии ЖКН России, эксперт ГУ РИНКЦЭ

Тел. 8 (495) 491-94-46

Моб. 8-903-961-03-52

Буркова Юлия Геннадьевна, кандидат технических наук, доцент кафедры «Информационные технологии в строительстве»

Тел. 8 (499) 153-97-66

E-mail: burkova.msuee@mail.ru

УДК 502/504:556.04

Н. Л. ФРОЛОВА, Н. И. АЛЕКСЕЕВСКИЙ, В. А. ЖУК

Московский государственный университет имени М. В. Ломоносова

МОНИТОРИНГ ГИДРОЛОГИЧЕСКИХ ПРОЦЕССОВ И ОБЕСПЕЧЕНИЕ БЕЗОПАСНОСТИ ВОДОПОЛЬЗОВАНИЯ*

Предложены рекомендации по совершенствованию мониторинга гидрологических процессов. Рассмотрены примеры решения данной задачи для различных опасных гидрологических явлений.

Опасные гидрологические процессы, мониторинг.

Recommendations about improvement of monitoring of hydrological processes are offered. Examples of the solution of this task for the various dangerous hydrological phenomena are reviewed.

Dangerous hydrological processes, monitoring.

* Работа выполнена при частичной финансовой поддержке РФФИ (проект № 13-05-00113), гранта Правительства РФ для государственной поддержки научных исследований, проводимых под руководством ведущих ученых в российских вузах (проект № 11.G. 34.31.0007), ФЦП «Развитие водохозяйственного комплекса Российской Федерации в 2012–2020 годах»