

Штепа В. Н., Заец Н. А., Прокопеня О. Н., Луцкая Н. Н.

ВЕРОЯТНОСТНЫЕ НЕЙРОННЫЕ СЕТИ В ЗАДАЧАХ УПРАВЛЕНИЯ КОМБИНИРОВАННЫМИ СИСТЕМАМИ ВОДООЧИСТКИ

Введение. Указ Президента Республики Беларусь № 166 от 22 апреля 2015 года “О приоритетных направлениях научнотехнической деятельности в Республике Беларусь на 2016-2020 годы” призван обеспечить концентрацию ресурсов на создании принципиально новых оборудования и технологий V и VI технологических укладов, а также создании высокотехнологичных производств, которые обеспечивают рациональное природопользование.

Очевидно, что повторное использование сточных вод в технологических процессах повышает эффективность использования ресурсов предприятиями и соответствует приоритетным научным направлениям. Однако техническая реализация такой задачи характеризуется сложностью, поскольку необходимого результата можно достигнуть, только используя комбинированные системы водоочистки, включающие несколько из базовых методов [1]: механический, химический, физико-химический и биологический, т. е. загрязнители имеют разную природу (биологическую, химическую, физическую).

Негативно действуют на эффективность систем управления следующие факторы [1]: многофакторность и многостадийность биофизико-химических процессов, недостаточная номенклатура измерительных приборов способных работать в режиме реального времени в агрессивной среде, постоянное действие возмущений.

С учётом весомости вероятностной составляющей, для определения стратегий поведения комбинированных систем водоочистки применяется математический аппарат теории игр [1]. Для разработки подсистем принятия решений используется игровой подход. Если рассмотреть систему управления с ее стремлением получить максимальную ресурсоэффективность в процессе функционирования, включая и обеспечение экологической безопасности, с одной стороны, а качество сточной воды, которое точно определить невозможно, с другой стороны, то взаимодействие этих сторон можно описать как игру, причем – как статистическую игру. Статистическая игра – это бескоалиционная парная матричная игра в чистых стратегиях. В процессе принятия управляющего решения система обладает информацией, что окружающая среда может принять одно из нескольких состояний – стратегий (реализаций изменения параметров качества воды во времени) и сталкивается с неопределенностью относительно того конкретного состояния, в которое вступит природа в ближайшее время. Такая игра описывается платежной матрицей, классификацию образов можно проводить на основе теории статистических решений.

Однако было установлено [2–3], что такие алгоритмы имеют недостаток – существенную нечувствительность к началу смены одного образа на другой, что, в случае систем водоочистки, может привести к катастрофическим последствиям. Хотя при определенной стационарности показателей качества воды теория статистических решений демонстрирует необходимое предикативное качество.

Исходя из необходимости адекватной оценки начала смены одного образа на другой, с учётом функциональных особенностей и анализа исследований других авторов [4], для решения такой задачи было предложено применение математического аппарата вероятностных нейронных сетей.

Постановка задачи. С целью компенсации недостатков теории

статистических решений при управлении комбинированными системами водоочистки, создать на основе вероятностных нейронных сетей адекватный и чувствительный к началу смены образов классификатор.

Материалы и методика исследований. Формула Байеса позволяет определить вероятность определенного события (гипотезы) при наличии только косвенных подтверждений (данных) [5], которые могут содержать неточности, что особенно важно для решения нашей задачи.

Запись формулы Байеса

$$P(A|B) = \frac{P(A|B)P(A)}{P(B)}, \quad (1)$$

где $P(A)$ – априорная вероятность гипотезы A ;

$P(A|B)$ – вероятность гипотезы A при наступлении события B (апостериорная вероятность);

$P(B|A)$ – вероятность наступления события B при истинности гипотезы A ;

$P(B)$ – вероятность наступления события B .

Важное следствие формулы Байеса – формула полной вероятности события, зависит от нескольких несовместимых гипотез (и только от них)

$$P(B) = \sum_{i=1}^N P(A_i)P(B|A_i), \quad (2)$$

где N – количество гипотез.

С учетом (2) приходим к выводу, что вероятность наступления события B зависит от ряда гипотез A_i , если известны степени достоверности этих гипотез (например, экспериментальные данные по качеству воды).

Построенная на таких теоретических основах байесовская сеть является вероятностной моделью, которая представляет собой множество переменных и их вероятностных зависимостей. Формально, байесовская сеть – направленный ациклический граф, вершинами которого являются переменные, а ребра кодируют условные зависимости между переменными. Вершины могут представлять переменные любых типов, быть взвешенными параметрами, скрытыми переменными или гипотезами. Если ребро выходит из вершины A в вершину B , то A называют отцом B , а B называют потомком A . Множество вершин-предков вершины X_i обозначим как $parents(X_i)$. Тогда совместное распределение значений в вершинах можно расписать как результат локальных распределений

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | parents(X_i)), \quad (3)$$

где n – количество локальных распределений.

К частному случаю байесовских сетей относятся вероятностные нейронные сети (probabilistic neural networks – PNN). Это – вид нейронных сетей, которые эффективно применяются для решения задач классификации, где плотность вероятности принадлежности классам оценивается с помощью ядерной аппроксимации.

При решении задач классификации выходы сети можно интерпретировать как оценки вероятности, что элемент принадлежит некоторому классу. Сеть фактически учится оценивать функцию

Штепа Владимир Николаевич, к. т. н., доцент, доцент кафедры высшей математики и информационных технологий Полесского государственного университета, e-mail: shns1981@gmail.com.

Заец Наталья Анатольевна, к. т. н., доцент, доцент кафедры автоматизации и робототехнических систем им. акад. И.И. Мартыненко Национального университета биоресурсов и природопользования Украины, e-mail: z-n@ukr.net.

Луцкая Наталья Николаевна, к. т. н., доцент, доцент кафедры автоматизации и интеллектуальных систем Национального университета пищевых технологий Украины, e-mail: lutskanm2017@gmail.com.
Украина, 01601, г. Киев, ул. Владимирская, 68.

Прокопеня Олег Николаевич, к. т. н., доцент, зав. кафедрой автоматизации технологических процессов и производств Брестского государственного технического университета, e-mail: olegprokopeny@mail.ru.

Беларусь, БрГТУ, 224017, г. Брест, ул. Московская, 267.

плотности распределения вероятности.

Аналогичная полезная интерпретация может иметь место и в задачах регрессии – выход сети рассматривается как ожидаемое значение модели в данной точке пространства входов. Это ожидаемое значение связано с плотностью вероятности общего распределения входных и выходных данных.

В более общем случае байесовская статистика дает возможность оценивать плотность вероятности распределения параметров модели по имеющимся данным. Для того чтобы минимизировать ошибку, выбирается модель с такими параметрами, при которых плотность вероятности будет наибольшей. При решении задачи классификации можно оценить плотность вероятности для каждого класса, сравнить между собой вероятности принадлежности различных классов и выбрать наиболее вероятный.

На самом деле именно это происходит, когда мы обучаем нейронную сеть решать задачу классификации – сеть пытается определить (аппроксимировать) плотность вероятности каждого класса.

В основу классификации в сети PNN положена идея, что для каждого образца можно принять решение на основе выбора наиболее вероятного класса из тех, которым мог бы принадлежать этот образец. Такое решение требует оценки функции плотности вероятности для каждого класса. Эта оценка устанавливается в результате рассмотрения учебных данных. Правилком является то, что класс с плотным распределением в области неизвестного образца будет более многочисленным по сравнению с другими классами. Точно так же будет иметь преимущество и класс с высокой априорной вероятностью или высокой ценой ошибки классификации.

Для двух классов A и B , согласно этому правилу, выбирается класс A , если

$$h_A c_A f_A(x) \geq h_B c_B f_B(x), \quad (4)$$

где h – априорная вероятность; c – цена ошибки классификации; $f(x)$ – функция плотности вероятностей.

Верная оценка ошибки классификации требует основательного знания предметной области, но во многих случаях она и априорные вероятности выбираются одинаковыми для всех классов.

Оценить функции плотности распределения вероятностей можно с помощью метода Парцена, в котором используется весовая функция, имеющая центр в точке, которая представляет учебный образец. Такая весовая функция называется функцией потенциала или ядром. Чаще всего в качестве ядра используется функция Гаусса. Чтобы построить функцию распределения класса, для каждого вектора рассматривается функция Гаусса с центром в точке, соответствующей этому вектору. Затем функции Гаусса суммируются, в результате чего получается искомая функция распределения.

Традиционно используется более простая форма функции Гаусса, содержащая квадраты евклидовых расстояний от неизвестного образца к элементам слоя образцовых образов

$$g(x) = \sum_{i=1}^n \exp\left(-\frac{\|x - x_i\|^2}{\sigma^2}\right), \quad (5)$$

где σ – параметр, который задает ширину функций Гаусса;

x – неизвестный входной образец.

Использование вероятностной нейронной сети для оценки образов параметров качества сточных вод. В пакете прикладных математических программ "Statistica" синтезировали и адекватно настроили (среднеквадратичная погрешность – 2,05%) нейронную сеть Кохонена (рис. 3).

При этом применялся алгоритм самоорганизации, предполагающий:

- 1) инициализацию синаптических весов в сети (с использованием датчика случайных чисел);
- 2) конкуренцию (competition) – для любого входного образа и для всех нейронов сети вычисляется значение дискриминантной функции, которая является основой конкуренции, и нейрон с максимальным значением дискриминантной функции становится победителем;
- 3) кооперацию – нейрон-победитель определяет пространственное расположение соседних возбужденных нейронов;

4) настройку весовых коэффициентов (адаптация) – значение дискриминантной функции возбужденных нейронов увеличивается для данного образа путем настройки весовых коэффициентов. При адаптации отзыв нейрона-победителя на близкий входной образ увеличивается.

На вход подавались результаты экспериментальных данных [1], где параметрами качества воды были приняты: БПК, pH, концентрация взвесей, концентрация нитратов. Обучающая выборка содержала 680 наборов. Осуществлялась проверка на "переобучение". С использованием нейронной сети Кохонена получено 4 образа входных переменных (табл. 1).

Таблица 1 – Образы параметров качества воды

Номер образа	БПК, г/м ³	pH	Концентрация взвесей, г/м ³	Концентрация нитратов, мг/л
Образ 1	345-349	6,5-6,7	550-561	46-55
Образ 2	398-403	6,7-7,1	558-701	73-78
Образ 3	430-447	6,9-7,8	865-904	59-64
Образ 4	453-481	7-8,3	873-910	52-73

При синтезе PNN-классификатора образов как входные использовали те же величины, что и при проведении экспериментов (табл. 2).

Таблица 2 – Диапазоны изменения входных данных

БПК, г/м ³	pH	Концентрация взвесей, г/м ³	Концентрация нитратов, мг/л
350–500	5–9,5	500–3000	45–80

Выход нейронной сети – номер класса (образа), к которому относится полученный набор входных величин.

Нейросетевой слой добавления имеет по одному элементу для каждого класса из обучающего множества данных. Ко всем элементам этого слоя идут связи только от элементов слоя образцов, принадлежащих к соответствующему образу.

Активность элемента слоя образов равна

$$O_i = \exp\left(-\frac{\sum (w_{ij} - x_j)^2}{\sigma^2}\right), \quad (6)$$

где w_{ij} – значения весовых коэффициентов.

Весовые значения связей, идущих от элементов слоя образов к элементам слоя добавления, фиксируются равными 1.

Элемент слоя добавления просто заключает исходные значения элементов слоя образов. Эта сумма дает оценку значения функции плотности распределения вероятности для совокупности экземпляров этого класса. Выходные элементы представляют собой дискриминаторы пороговой величины, указывающие элемент слоя добавления с максимальным значением активации (то есть указывают на один из 4 образов качества воды).

Для такой сети не требуется обучение в том смысле, которое требуется для сетей типа перцептрона, радиально-базисной функции и т.д., так как все параметры PNN-сети (число элементов и значения весов) определяются непосредственно учебными данными.

Процедура её использования является относительно простой [5] – после того как сеть построена, неизвестный экземпляр можно подать на вход сети, и в результате прямого прохода через сеть выходной слой укажет класс, к которому, скорее всего, принадлежит образец.

В контексте нашей задачи, интерес представляет не столько дискретная классификация образов, сколько значение выхода слоя добавления, который высчитывает плотности распределения вероятности для совокупности экземпляров соответствующего образа. То есть по выходу этого слоя можно отслеживать динамику изменения (потенциальной смены) образов качества воды.

Используя экспериментальные данные, в пакете прикладных математических программ Statistica реализовали PNN-сеть (рис. 1).

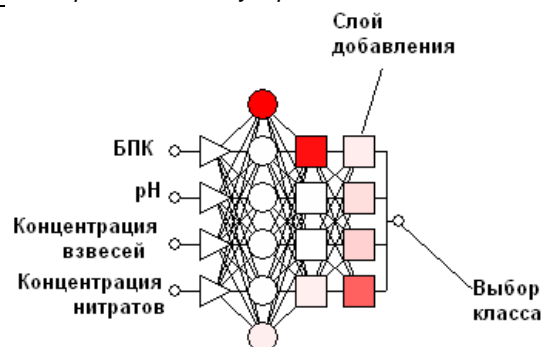


Рисунок 1 – Архитектура вероятностной нейронной сети классификации образцов качества воды

Для исследования качества классификации (функциональной эффективности) создали 25 возможных наборов входных параметров, принадлежащим к разным классам (табл. 1).

Вероятностная нейронная сеть верно классифицировала все наборы с четким преимуществом на выходе слоя добавления плотности распределения вероятностей соответствующих образов-победителей (рис. 2).



Рисунок 2 – Плотности распределение вероятностей при проверке эффективности PNN-сети

Учитывая приемлемые результаты оценки динамики изменения образов вероятностными нейронными сетями, предлагается

применять их перед блоками принятия решений в системах управления комбинированными установками водоочистки (рис. 3).



Рисунок 3 – Структурная схема использования вероятностной нейронной сети при управлении комбинированными системами водоочистки

При этом данные на PNN-сеть поступают с блоков фильтрации информации (с датчиков качества воды) и формирования образов, например, с использованием самоорганизующихся сетей Кохонена.

Заключение. Вероятностные нейронные сети можно использовать для оценки динамики изменения качества воды в комбинированных системах водоочистки, поскольку качество оценки подтверждено результатами моделирования – верно классифицированы все 25 учебных образов.

В системах управления PNN-сети рекомендуется устанавливать перед подсистемой выбора стратегий после блоков фильтрации и адаптивного формирования образов. Для этого необходимо осуществить декомпозицию их архитектуры с последующей программной реализацией.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Донченко, М.И. Очистка растворов от дисперсных примесей методом электрокоагуляции. 2. Осаждение глинистых примесей при переменных гидродинамических режимах, факторный эксперимент / М.И. Донченко, О.Г. Срибная, Ф.И. Гончаров, В.Н. Штета // Вісник Національного технічного університету "ХПІ". – Харків: НТУ "ХПІ". – 2009. – № 22. – С. 57–65.
2. Kohonen, T. Self-Organizing Maps (Third Extended Edition): ISBN 3-540-67921-9 – New York, 2001. – 501 p.
3. Lakhmi, S. Martin Fusion of Neural Networks, Fuzzy Systems and Genetic Algorithms: Industrial Applications / S. Lakhmi, N.M. Jain — CRC Press, CRC Press LLC, 1998.
4. Каллан, Р. Основные концепции нейронных сетей / Р. Каллан. – М.: Издательский дом «Вильямс», 2001. – 516 с.
5. Гареев, А.Ф. Применение вероятностной нейронной сети для задачи классификации текстов / А.Ф. Гареев // Наука и образование. – М.: НиО. – 2004. – № 11. – С. 105–117.

Материал поступил в редакцию 16.05.2018

SHTERA V.M., ZAIETS N.A., PROKOPENYA O.N., LUTSKAIA N.N. The probabilistic neural network in the control problems of the combined water treatment systems

The shortcomings of the modern systems of the selecting management strategies in times of unforeseen factors and the shortcomings of the current approaches in the management of water treatment plants combined are analyzed. The theoretical foundations of probability theory of the neural networks and Bayesian networks are considered. On the basis of self-organization formed Kohonen network the quality of water, where the control parameters used BOD, pH, concentration of suspended solids and the concentration of nitrate the probabilistic neural network evaluation of dynamics of images is synthesized. It has tested its functional efficiency and confirmed the prospect use. The block diagram of the corresponding control system with integration into it PNN-network described. The direction of the future research is formulated.

УДК 628.162

Романовский В. И., Клебеко П. А., Романовская Е. В.

ОЧИСТКА ПРОМЫВНЫХ ВОД СТАНЦИЙ ОБЕЗЖЕЛЕЗИВАНИЯ С ИСПОЛЬЗОВАНИЕМ ОТХОДОВ ВОДОПОДГОТОВКИ

Для хозяйственно-питьевого водоснабжения населения Республики Беларусь в основном используется вода подземных источников. В подземной воде республики наблюдается повышенное содержание железа (рис. 1), а иногда и других соединений, которые

Романовский В.И., к. т. н., старший преподаватель Белорусского государственного технологического университета.

Романовская Е.В., ассистент Белорусского государственного технологического университета.

Беларусь, 220050, г. Минск, ул. Свердлова, 13а.

Клебеко П.А., аспирант РУП «Центральный научно-исследовательский институт комплексного использования водных ресурсов».

Беларусь, 220086, г. Минск, ул. Славинского, 1, корпус 2.