

## КЛАССИФИКАЦИЯ СОСТОЯНИЯ ОБЪЕКТА МОНИТОРИНГА С ПОМОЩЬЮ НЕЙРОСЕТИ

***Аннотация.** В работе рассмотрена задача классификации состояния объекта мониторинга с помощью искусственной нейронной сети. Проведен эксперимент по определению наиболее эффективной модели для решения задач классификации на основе табличных данных. Эффективность оценивалась с помощью метрики Ассигасу, описывающей долю верно определенных классов. Наиболее эффективной моделью определена полносвязная нейронная сеть с нормированными входными данными.*

***Ключевые слова:** нейронная сеть, классификатор, объект мониторинга, классификация состояния.*

**Введение.** Самостоятельное рассмотрение задачи классификации состояния связано с тем, что объекты мониторинга могут быть различной природы, описываются разными наборами и типами параметров, а для идентификации их состояний могут использоваться разные методы [1, 2]. В простом случае объект может находиться в одном из двух состояний «Исправен-Неисправен» или «Доступен-Недоступен», однако, источником для определения конкретного состояния могут служить различные входные данные: табличные качественные, табличные количественные или, например, данные в виде изображения с камеры наблюдения.

**Проблема исследования.** Следовательно, для анализа входных данных, поступающих от объекта, и дальнейшего их преобразования в единообразный вид необходим классификатор, подобранный с учетом типа входных данных.

Классификация состояния может основываться на получаемых в реальном времени данных (количественных и качественных) с датчиков системы мониторинга и телеметрии. Такая передача данных характерна для технологического оборудования или интерфейсов и линий связи.

Также может основываться на данных, которые являются результатом анализа косвенных признаков или иной качественной информации, что характерно для систем операционного окружения, непосредственные данные с которых не собираются (состояние сервисных служб и персонала, наличие ресурсов, объекты инфраструктуры и т. п.).

«Классическим» способом классификации объектов (ситуаций), характеризуемых набором нормализованных параметров, является метод K-ближайших соседей [1], в котором расстояние между ситуациями вычисляется как евклидово расстояние.

В случае, когда есть возможность собирать данные и формировать наборы обучающих примеров для распознавания состояний, целесообразно использовать методы машинного или глубокого обучения [3, 4]. Нейронные сети обладают рядом достоинств [5-7], в частности, возможность избавления от проблем, связанных с разнотипными параметрами и коллизиями, возникающими вследствие взаимозаменяющихся атрибутов.

#### *Качественные и количественные данные*

Для классификации на основе табличных качественных и количественных данных целесообразно применить известные подходы:

1. Регрессионные модели. Объединяют широкий класс универсальных функций, которые описывают некоторую закономерность. В качестве входных данных целесообразно использовать измеряемые количественные табличные данные. Недостатки: нелинейная зависимость параметров элемента СО, необходимо уточнение или интерпретация выходного значения.

2. Деревья решений. В качестве входных данных наиболее целесообразно использовать символьные качественные табличные данные. Недостатки: тенденция к переобучению, малое количество входных параметров (до 5), после превышения которого качество классификации резко уменьшается.

3. Искусственные нейронные сети. На вход наиболее целесообразно подавать нормированные либо классифицированные количе-

ственные табличные данные. Недостатки: требуется большое количество обучающих примеров с отображением всех возможных закономерностей.

Для задачи распознавания состояний объектов в системе водоснабжения по табличным данным в работе [8] были проведены эксперименты, которые показали применимость нейросетевой технологии и ее преимущество по сравнению с классическим методом К-ближайших соседей (KNN).

**Материалы и методы.** Для проведения эксперимента в качестве элемента, у которого будет классифицироваться состояние, был выбран «Газовый котел RB-207», являющийся частью СТО (тепловой пункт здания). Котел имеет 4 класса состояния («работает», «неисправность», «авария», «отключен»).

Состояние котла описывается следующими семью атрибутами:

- Рабочее давление газа, атм
- Давление в контуре отопления, МПа
- Давление в контуре ГВС, МПа
- Температура теплоносителя, °С
- Расход газа, м<sup>3</sup>/час
- Напряжение, В
- IT система котла, ON/OFF (качественный параметр)

Было составлено два набора данных: для обучения (1Т) и для проверки (1V), 500 и 25 ситуаций соответственно. Под ситуацией в данном случае будем понимать комбинацию значений атрибутов.

Обучающий набор 1Т содержит по 125 ситуаций каждого класса. Класс 1 всегда представляет собой штатный режим работы, когда ни одно из правил возникновения нештатной ситуации не выполняется. Классы 2 и 3 описывают нештатные ситуации, они могут иметь пересечения по атрибутам между собой и 1 классом. Состояние принимает класс 2 или 3 при условии, что хотя бы один атрибут принял значение из диапазона, принадлежащей классу 2 или 3.

Например, все атрибуты имеют значения, принадлежащие диапазону класса 1, а температура теплоносителя имеет значение 95°С, принадлежащее диапазону класса 2, следовательно, класс состояния элемента — 2 «неисправность». Или, все атрибуты имеют значения,

принадлежащие диапазону класса 1 и 2, а температура теплоносителя имеет значение 102°C, принадлежащее диапазону класса 3, следовательно, класс состояния элемента — 3 «авария».

Класс 4 может иметь пересечения по атрибутам, принадлежащим классам 1 и 2. Но решающее значение принадлежности к классу имеет качественный параметр атрибута «IT система котла», принимающий значение OFF. В случае значения ON состояния относится к классу 1 или 2. Если же при значении OFF хотя бы один атрибут принимает значение, принадлежащее классу 3, то и состояния всего элемента будет иметь принадлежность к классу 3 «авария» независимо от значения атрибута «IT система котла».

Проверочный набор 1V содержит 25 ситуаций с неравномерным частотным распределением классов.

Для классификации состояния элемента «Газовый котел RB-207» на языке python с использованием библиотек sklearn, keras и пакета tensorflow были построены:

- регрессионная модель (функция активации выходного слоя Relu, количество нейронов на выходе нейросети = 1, функция ошибки — MAE, метрика MAE);
- полносвязная нейронная сеть для многоклассовой классификации (функция активации выходного слоя Softmax, функция ошибки sparse\_categorical\_crossentropy, метрика accuracy, optimizer — adam, количество нейронов на выходе нейросети = 4);
- модель KNN (к-ближайших соседей);
- модель дерева решений.

На вход регрессионной модели подавались значения атрибутов через запятую. На выходе округленное до целого значение, обозначающее класс состояния (0, 1, 2 или 3).

На вход полносвязной нейронной сети подавались значения атрибутов в исходном виде и нормированные значения атрибутов — количественные параметры преобразовывались в 0, 1, 2 в зависимости от принадлежности диапазону (нормальные значения, ненормальные значения, авария), значение атрибута «IT система котла» преобразовывалось в 0/1 в случае состояния OFF/ON соответственно. Нормализация параметров осуществлялась с помощью нормативной документации производителя котла RB-207 с указанными

допустимыми диапазонами значений параметров. На выходе нейронной сети: вектор в формате  $S^{N\beta}$ . Например, вектор [0, 1, 0, 0] означает 2 класс состояния элемента — «неисправность».

На вход модели KNN подавались нормированные значения параметров в диапазоне [0; 1].

На вход модели дерева решений подавались значения атрибутов в исходном виде и в виде нормированных значений, как на вход полносвязной нейронной сети.

Результаты работы при классификации ситуаций из проверочного набора представлены в табл. 1.

Таблица 1

### Результаты обработки проверочного набора

<i>Модель</i>	<i>Ситуаций с верно определенным классом (из 25 ситуаций)</i>	<i>Accuracy</i>
Нейронная сеть (нормированные значения)	25	100%
Регрессионная	23	92%
Нейронная сеть (значения в исходном виде)	21	84%
KNN	19	76%
Дерево решений (нормированные значения)	19	76%
Дерево решений (значения в исходном виде)	15	60%

Из табл. 1 можно увидеть, что полносвязная нейронная сеть без ошибок выполнила классификацию состояний элемента «Газовый котел RB-207».

**Заключение.** Для задачи классификации состояния с исходными данными в виде качественных и количественных параметров полносвязная нейронная сеть является наиболее подходящим инструментом для классификации ввиду безошибочной классификации данных проверочного набора.

Однако стоит заметить, что для использования нейронной сети потребовалась подготовка входных данных (нормирование значений). Нормирование значение в случае отсутствия экспертных

данных, устанавливающих правила нормирования, может стать неоднозначной задачей.

В случае отсутствия возможности нормализации количественных параметров подаваемых на вход модели целесообразно применить регрессионную модель в качестве классификатора.

## СПИСОК ЛИТЕРАТУРЫ

1. Айвазян С. А. Прикладная статистика: классификация и снижение размерности / С. А. Айвазян, В. М. Бухштабер, И. С. Енюков, Л. Д. Мешалкин. — Москва : Финансы и статистика, 1989. — Текст : непосредственный.
2. Вапник В. Н. Восстановление зависимостей по эмпирическим данным / В. Н. Вапник — Москва : Наука, 1979. — Текст : непосредственный.
3. Michel T. Machine Learning / Т. Michel. — New York : McGraw Hill., 1997. — Текст : непосредственный.
4. Bishop С. М. Pattern Recognition and Machine Learning / С. М. Bishop. — Springer, 2006. — Текст : непосредственный.
5. Староверов Б. А. Схемы взаимодействия поставщиков и получателей прогнозов электропотребления на основе использования нейросетевой информационной системы / Б. А. Староверов, И. В. Семёнов. — Текст: электронный // Инженерный вестник Дона. — 2018. — № 1. — URL: [ivdon.ru/ru/magazine/archive/n1y2018/4784](http://ivdon.ru/ru/magazine/archive/n1y2018/4784) (дата обращения: 25.05.2022).
6. Chen J. Research on agricultural monitoring system based on convolutional neural network / J. Chen, H. Zhou, H. Hu [et al.]. — Text : electronic // Future Generation Computer Systems. — 2018. — Vol. 88. — P. 271-278. — DOI: 10.1016/j.future.2018.05.045.
7. Mathise, M. B. Learning similarity measures from data / M. B. Mathise, A. Aamodt, K. Bach, H. Langseth. — Text : electronic // Progress in Artificial Intelligence. — 2020. — Vol. 9. — P. 129-143. — DOI: 10.1007/s13748-019-00201-2.
8. Глухих И. Н. Классификация состояний объектов городской инфраструктуры с использованием нейронных сетей / И. Н. Глухих, Ю. Е. Карякин, А. К. Березовский, А. А. Дудина. — Текст : непосредственный // Инженерный вестник Дона. — 2021. — № 8.