

## Классификация состояний объектов городской инфраструктуры с использованием нейронных сетей

*И.Н. Глухих, Ю.Е. Карякин, А.К. Березовский, А.А. Дудина*

*Тюменский государственный университет*

**Аннотация:** В данной работе рассматривается возможность применения нейронных сетей с целью классификации состояний сложных объектов. Для этого производится программная реализация нейросетевого классификатора и сравниваются результаты с алгоритмом выбора на основе К-ближайших соседей.

**Ключевые слова:** классификация, нейронные сети, принятие решений, прецедент.

### Введение

В настоящее время все возрастающая сложность организационно-технических систем городской инфраструктуры становится объективной реальностью. Это обусловлено возрастанием количества структурных элементов архитектуры систем, многообразием связей между ними, а также возрастающим объемом потоков информации, циркулирующих в процессах управления и принятия решений. Последнее связано, в частности, с внедряемыми технологиями цифровизации объектов городского хозяйства и созданием компонентов умных городов.

Все это, в свою очередь, влияет на сложность выработки оперативных управленческих решений в ситуациях, требующих своевременного вмешательства обслуживающего персонала, оперативно-диспетчерских служб, ремонтных и иных обеспечивающих компаний. Такие ситуации могут быть связаны как с возникновением аварий на объектах городской инфраструктуры (в системах тепло-, газо-, водо-, энергоснабжения), так и с иными нештатными ситуациями, которые могут влиять на эффективность объектов городской инфраструктуры.

Один из перспективных подходов к автоматизации и интеллектуализации процессов принятия решений в подобных ситуациях на

сложных технологических объектах основан на методе вывода решений по прецедентам – case based reasoning, CBR [1, 2].

Метод CBR предполагает, что имеется набор пар <Ситуация, Решение>, каждая из которых является известным из практики кейсом, когда в той или иной ситуации принималось решение, и этот выбор впоследствии был положительно оценен экспертами.

С наличием таких кейсов, при возникновении некоторой проблемной ситуации ее нужно сравнить с известными кейсами, после чего выбрать наиболее близкий из них, чтобы использовать уже готовое решение. Такой подход обладает важным преимуществом – в условиях дефицита времени на принятие решений он позволяет от трудоемкой задачи синтеза неизвестного решения перейти к задаче выбора из готовых вариантов «по аналогии».

Сложный технологический объект городской инфраструктуры представляется множеством разнообразных по своей природе элементов и отношений между ними. Этими элементами могут быть «трансформаторные подстанции», «ремонтные бригады», «диспетчерские пункты» и т.п. Каждый из элементов сложного объекта может находиться в каком-то состоянии. В самом простом случае может быть всего два состояния «Исправен», «Неисправен», однако, на практике таких состояний будет больше. У каждого элемента есть некоторый набор атрибутов (параметров), их значения будут определять то или иное состояние.

Когда начинаем рассматривать объект (систему) в целом, все становится несколько сложнее. Возникает понятие «ситуация». Ситуация (ситуация на сложном объекте) – это набор конкретных состояний элементов объекта и отношений между ними в данный момент времени. Наблюдаемые отношения между элементами и состояния этих элементов образуют текущую ситуацию.

---

В базе прецедентов будут храниться кейсы (прецеденты), каждый из которых содержит ситуацию и ее решение. Под решением будем понимать некоторый набор (совокупность) действий, который приводит сложный объект из одной ситуации (нежелательной, аварийной, опасной) к другой ситуации (целевой). На уровне состояний решение – это некоторая траектория, связанная с переходом от одного состояния элементов сложного объекта к другому.

Чтобы разрешить какую-либо критическую ситуацию, необходимо найти в базе прецедентов такую же или «похожую» ситуацию и взять решение, которое с ней связано. Задача вывода решений в прецедентной системе в простом случае сводится к поиску самой «похожей» ситуации.

При реализации подхода CBR возникает проблема сравнения текущей ситуации с имеющимися в базе прецедентами и выбора наиболее подходящего управленческого решения [3]. Одним из распространенных методов сравнения ситуаций является метод К-ближайших соседей [4]. Этот метод обладает рядом недостатков, такими, как зависимость от выбора метрики, необходимость шкалирования и нормирования при наличии разнотипных параметров. Подобные недостатки могут привести к сложности, а иногда невозможности использования данного метода.

Рассматривая ситуацию управления через совокупность состояний элементов сложного объекта и связей между ними, задачу поиска «похожей» ситуации можно представить как задачу распознавания и сравнения состояний элементов сложного объекта, в которых они находятся в текущей ситуации и в ситуациях, которые зафиксированы в базе прецедентов [5].

Данная задача может быть решена с использованием нейронных сетей, которые обладают рядом достоинств [6-8], одно из которых возможность «уйти» от проблем метода К-ближайших соседей, связанных с разнотипными параметрами.

---

В данной работе исследуется возможность применения нейронных сетей для распознавания состояний элементов сложного объекта и сравниваются результаты их применения с методом К-ближайших соседей. Для этого в работе решаются следующие задачи: реализация генератора состояний и создание дата сета для проведения экспериментов; программная реализация нейросетевого классификатора и алгоритма выбора на основе К-ближайших соседей; проведение экспериментов и сравнение результатов.

### **Постановка задачи**

Рассмотрим задачу классификации состояний элементов сложного объекта (системы) с помощью создаваемой нейронной сети. Для этого в качестве моделируемой системы была выбрана сеть технологических объектов городской инфраструктуры, в частности городская водопроводная система. Объекты водопроводной инфраструктуры характеризуются рядом параметров. В качестве атрибутов, достаточных для классификации состояний на этих объектах, с учетом внутренних условий, условий внешней среды и их окружения, можно выбрать следующие:

- Latitude (широта), float;
- Longitude (долгота), float;
- Steel (марка стали трубопровода), string;
- Inner Pressure (внутреннее давление), float;
- Pressure (атмосферное давление), float;
- Temperature (температура), float;
- Wind Speed (скорость ветра), float;
- Commissioning (год запуска), integer;
- Last Repair (год последнего обслуживания), integer;
- Humidity (влажность), float;
- Fallout (мм осадков), integer;

– Class (класс состояния), integer.

Правила возникновения критических состояний не всегда можно описать с помощью формальных зависимостей. В данной работе принимается, что критические состояния возникают при достижении определенных значений одним атрибутом или их совокупностью.

Для проверки качества классификации состояний с помощью нейронной сети использовались методы имитационного моделирования. Генерируется 2 набора данных с 4 классами состояний. Класс 1 всегда представляет собой штатный режим работы - когда ни одно из правил возникновения аварии не выполняется, остальные классы – это варианты возникновения аварийных ситуаций. В первом сценарии все критические состояния возникают однозначно по соответствующему атрибуту. Во втором сценарии рассмотрены классы 3 и 4 аварий, которые имеют пересечение в условиях возникновения. Так, класс аварии 3 возникает при превышении определенного значения по температуре, а класс 4 - при достижении определенной температуры, и при условии длительного времени без обслуживания. В качестве сети будет использоваться многослойный перцептрон, а данными послужит набор данных о состояниях объектов водопроводной сети.

### **Программная реализация и проведение экспериментов**

Для анализа возможности использования нейронной сети для классификации состояний объектов была реализована нейросеть с помощью библиотеки Keras на языке Python. Было сгенерировано 728 наборов данных с 4 классами состояний, по 182 для каждого класса, фрагмент кода нейронной сети показан на рис. 1.

Также для сравнения был рассмотрен классический способ классификации методом ближайших соседей. Фрагмент кода его реализации представлен на рис. 2.

```
import tensorflow as tf
from matplotlib import pyplot as plt
inputs = tf.keras.Input(shape=(11,))
x = tf.keras.layers.Dense(22, activation='relu', kernel_initializer='he_uniform')(inputs)
dropout = tf.keras.layers.Dropout(.1)(x)
x = tf.keras.layers.Dense(8, activation='relu', kernel_initializer='he_uniform')(dropout)
outputs = tf.keras.layers.Dense(4, activation='softmax')(x)
model = tf.keras.Model(inputs=inputs, outputs=outputs)
model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
history = model.fit(X1, Y1, epochs=100, validation_data = (X2, Y2), batch_size=8, verbose=2)
```

Рис. 1. – Фрагмент кода реализации нейронной сети

```
from sklearn.neighbors import KNeighborsClassifier
import pandas as pd
neigh = KNeighborsClassifier(n_neighbors=3)
neigh.fit(X1, Y1)
neigh.score(X2, Y2)
```

Рис. 2. – Фрагмент кода реализации метода KNN

На рис. 3 представлена архитектура нейронной сети, с помощью которой производится классификация состояний объекта водопроводной инфраструктуры.

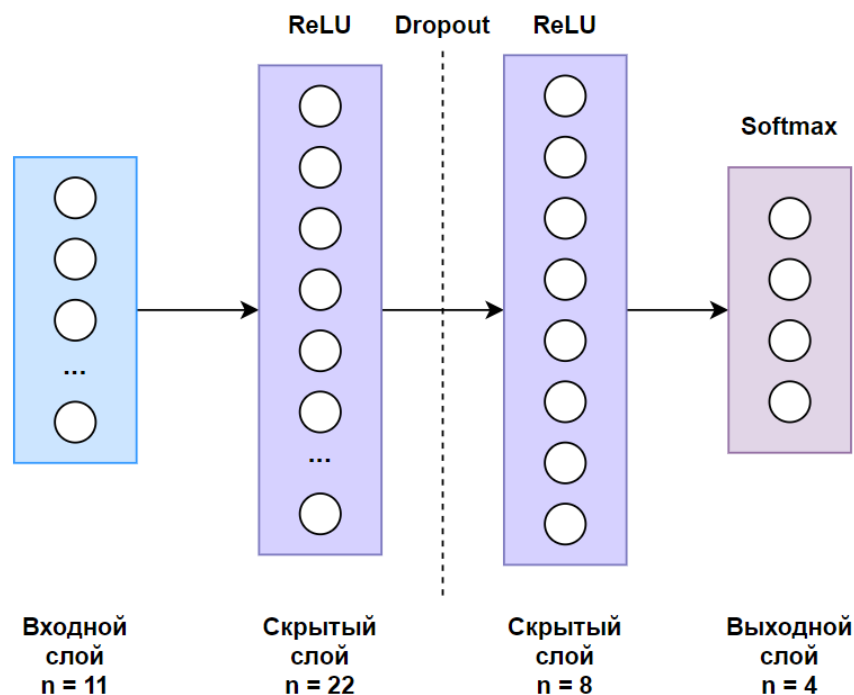


Рис. 3. - Архитектура нейронной сети – классификатора состояний

## Анализ результатов эксперимента

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

Для оценки результатов, полученных с помощью нейронной сети, было произведено сравнение с результатами классификации метода К-ближайших соседей. В качестве обучающей выборки выбирается 80% от общего числа наборов данных.

Нейросеть реализована с помощью библиотеки Keras на языке Python. Наилучшие результаты показала нейросеть с размером пакета 8 и 11, входными нейронами, содержащая 2 скрытых слоя с 22 нейронами в первом, и 8 нейронами во втором с функциями активации *relu*, и выходным слоем с функцией активации *softmax*.

На рис. 4 слева представлен результат обучения и проверки нейросети для сценария, когда критические состояния не имеют пересекающихся условий. К 100 эпохе точность на обучающей выборке стала равной 93,3%, а точность на контролирующей выборке - 93,7 %. Точность классификации методом К-ближайших соседей составила 68% при  $K=3$ .




Рис. 4. - Результаты нейросети для классов без пересекающихся условий (слева) и для классов с пересекающимися условиями (справа)

На рис. 4 справа представлен результат обучения и проверки нейросети для сценария, когда критические ситуации имеют пересекающиеся условия. В данном случае, точность на обучающей выборке составила 93,4%, а точность на контролирующей – 86,5%. По результатам проверки, наибольшая точность с методом К-ближайших соседей составила 58% при  $K=3$ .

### Заключение

Было произведено сравнение эффективности использования нейросети и метода К-ближайших соседей для решения задачи классификации состояний на объектах водопровода. Рассмотрены два случая, с разными условиями возникновения критических состояний. Во всех рассмотренных примерах нейросеть показывает более высокий процент точности по сравнению с методом К-ближайших соседей. К недостаткам использования нейросети можно отнести чувствительность к размеру выборки и необходимость настройки гипер-параметров, а к преимуществам - точность и возможность использования различных типов данных в качестве входа. Таким образом, в задачах распознавания состояний, где можно выделить заданное количество классов, нейросети могут показать более высокую точность по сравнению с методом К-ближайших соседей.

Полученные результаты позволяют реализовать двухэтапный отбор «похожих» ситуаций в базе прецедентов при возникновении текущей критической ситуации. На первом этапе происходит распознавание состояний элементов сложного объекта. На следующем этапе формализуется описание текущей ситуации через векторы этих состояний и выполняется сравнение с аналогичным представлением ситуаций в базе кейсов.

Благодаря такому подходу мы имеем возможность создать нейросетевые классификаторы состояний, обученные для заданного и ограниченного набора состояний каждого из элементов сложного объекта. При этом большое число элементов и их состояний, комбинации которых

---



образуют разные ситуации, на практике обеспечивают почти неограниченные возможности представления всех возможных ситуаций на сложном объекте. Таким образом, даже возникновение в процессе эксплуатации новой ситуации не потребует переобучения нейросетей, т.к. они работают при неизменном множестве состояний. Для решения задачи отбора ситуаций на втором этапе при этом могут использоваться различные методы сравнения ситуаций, в том числе нейросетевые методы оценки схожести [9, 10].

### **Благодарность за финансовую поддержку работы**

*Исследование поддержано РФФИ и Тюменской областью, номер проекта 20-47-720004.*

### **Литература**

1. Глухих И.Н., Глухих Д.И. Метод Case Based Reasoning при управлении сложными технологическими объектами городской инфраструктуры // Инженерный вестник Дона, 2021, № 7. URL: [ivdon.ru/ru/magazine/archive/n7y2021/7074](http://ivdon.ru/ru/magazine/archive/n7y2021/7074).
2. Chan W. An expert decision support system for monitoring and diagnosis of petroleum production and separation processes. Expert Systems with Applications, 2005, 1(29), pp. 131-143. DOI: 10.1016/j.eswa.2005.01.009
3. Watson I.D., Marir F.: Case-based reasoning: A review. The Knowledge Engineering Review, 1994, V. 9. N 4, 355-381.
4. Еремеев А. П., Варшавский П. Р. Моделирование рассуждений на основе прецедентов в интеллектуальных системах поддержки принятия решений // Искусственный интеллект и принятие решений. – 2009. №. 2. С. 45-57.
5. Glukhikh I, Glukhikh D. Case Based Reasoning for managing urban infrastructure complex technological objects // CEUR Workshop Proceedings. 2021. Vol. 2843, no. 038. URL: [ceur-ws.org/Vol-2843/paper038.pdf](http://ceur-ws.org/Vol-2843/paper038.pdf).

6. Пампуха И. В., Березовская Ю. В. Обоснование использования нейронных сетей в системах поддержки принятия решения при функционировании сложных систем // Збірник наукових праць Військового інституту Київського національного університету імені Тараса Шевченка. – 2013. №. 42. С. 85-90.
7. Староверов Б. А., Семенов И. В. Схемы взаимодействия поставщиков и получателей прогнозов электропотребления на основе использования нейросетевой информационной системы // Инженерный вестник Дона, 2018, №1. URL: [ivdon.ru/ru/magazine/archive/n1y2018/4784](http://ivdon.ru/ru/magazine/archive/n1y2018/4784)
8. Chen, J., Zhou, H., Hu, H., Song, Y., Huang, Y.: Research on agricultural monitoring system based on convolutional neural network. Future Generation Computer Systems, 2018, 88, pp. 271-278. DOI: 10.1016/j.future.2018.05.045.
9. Карякин Ю.Е., Дудина А.А, Интеграция CBR-методов и технологии нейронных сетей // Вестник научных конференций. 2021. № 4-1 (68). С.48-50.
10. Mathise M.B., Aamodt A., Bach K., Langseth H. Learning similarity measures from data // Progress in Artificial Intelligence. 2020. Vol. 9. Pp. 129–143. DOI: 10.1007/s13748-019-00201-2. URL: [arxiv.org/abs/2001.05312](https://arxiv.org/abs/2001.05312).

### References

1. Gluhih I.N., Gluhih D.I. Inzhenernyj vestnik Dona, 2021, № 7. URL: [ivdon.ru/ru/magazine/archive/n7y2021/7074](http://ivdon.ru/ru/magazine/archive/n7y2021/7074).
  2. Chan W. An expert decision support system for monitoring and diagnosis of petroleum production and separation processes. Expert Systems with Applications, 2005, 1(29), pp. 131-143. DOI: 10.1016/j.eswa.2005.01.009
  3. Watson I.D., Marir F.: Case-based reasoning: A review. The Knowledge Engineering Review, 1994, V. 9. № 4, 355-381.
  4. Yeremeyev A. P., Varshavskiy P. R. Iskusstvennyy intellekt i prinyatiye resheniy. 2009. № 2. pp. 45-57.
-



5. Glukhikh I, Glukhikh D. CEUR Workshop Proceedings. 2021. Vol. 2843, no. 038. URL: [ceur-ws.org/Vol-2843/paper038.pdf](http://ceur-ws.org/Vol-2843/paper038.pdf).
6. Pampukha I.V., Berezovskaya Y.V. Sbornik nauchnykh trudov Voennoy instituta Kiyevskogo natsional'nogo universiteta imeni Tarasa Shevchenko. 2013. № 42. pp. 85-90.
7. Staroverov B. A., Semenov I. V. Inzhenernyj vestnik Dona, 2018, №1. URL: [ivdon.ru/ru/magazine/archive/n1y2018/4784](http://ivdon.ru/ru/magazine/archive/n1y2018/4784)
8. Chen, J., Zhou, H., Hu, H., Song, Y., Huang, Y.: Research on agricultural monitoring system based on convolutional neural network. Future Generation Computer Systems, 2018, 88, pp. 271-278. DOI: 10.1016/j.future.2018.05.045.
9. Karyakin Y.E., Dudina A.A. Vestnik nauchnykh konferentsiy. 2021. № 4-1 (68). Pp.48-50.
10. Mathise M.B., Aamodt A., Bach K., Langseth H. Progress in Artificial Intelligence. 2020. Vol. 9. pp. 129–143. DOI: 10.1007/s13748-019-00201-2. URL: [arxiv.org/abs/2001.05312](https://arxiv.org/abs/2001.05312).