

# ИСПОЛЬЗОВАНИЕ АЛГОРИТМОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ АНАЛИЗА НЕСТРУКТУРИРОВАННЫХ СТАТИСТИЧЕСКИХ ДАННЫХ

**В. В. Малахова, О. В. Малахов**

*Луганский государственный университет им. В. И. Даля, Россия*  
E-mail: malakhova\_viktoriya84@mail.ru, oleg\_home1@mail.ru

В работе рассматривается процедура проведения анализа неструктурированных статистических данных с использованием алгоритмов искусственного интеллекта. Последовательность действий подробно описана с разбиением на следующие этапы: сбор информации, формирование исходных данных, выбор модели машинного обучения и метода кластеризации данных, обучение модели кластеризации данных, выполнение анализа данных с использованием алгоритмов искусственного интеллекта.

## USING ARTIFICIAL INTELLIGENCE ALGORITHMS TO ANALYZE UNSTRUCTURED STATISTICAL DATA

**V. V. Malakhova, O. V. Malakhov**

The paper considers the procedure for analyzing unstructured statistical data using artificial intelligence algorithms. The sequence of actions is described in detail, divided into the following stages: collecting information, generating source data, choosing a machine learning model and a data clustering method, training a data clustering model, performing data analysis using artificial intelligence algorithms.

**Введение.** В современном мире искусственный интеллект занял прочное положение в поисковых системах, активно применяется при обработке больших объемов неструктурированной информации, для управления технологическими процессами и подвижными объектами без участия человека [1].

Владение технологиями искусственного интеллекта, либо не владение ими, в настоящее время стало тем критерием, по которому целые страны и народы либо перейдут в новую эпоху развития Человечества, либо так и останутся на задворках цивилизации [2].

**Постановка задачи.** Разработать и описать процедуру проведения анализа неструктурированных статистических данных с использованием алгоритмов искусственного интеллекта.

**Этап 1 – Сбор исходных данных.** В качестве типичного примера источника первичной информации используем справочник «Россия в цифрах» [3] – официальное издание Росстата. Статистические данные представлены таблицей, заголовок и начальная часть которой показаны в таблице. Поля таблицы содержат текстовую информацию и цифровые данные в формате вещественных чисел.

## Исходная форма представления статистических данных

	Площадь территории, тыс. км <sup>2</sup>	Численность населения, тыс. человек	Среднегодовая численность занятых, тыс. человек	Среднедушевые денежные доходы в мес-спл, руб.	Среднедушевые денежные расходы в мес-спл, руб.	Среднемесячная номинальная начисленная заработная плата работников организаций, руб.	Выловый региональный продукт (в текущих основных ценах), млрд. руб.	Основные фонды в экономике (по полной учетной стоимости), млрд. руб.	Объем отгруженных товаров собственного производства, выполненных работ и услуг собственными силами, млн. руб.			Продукция сельского хозяйства, млн. руб.	Ввод в действие общей площади жилых помещений, тыс. м <sup>2</sup>	Оборот розничной торговли, млрд. руб.	Сальдированный финансовый результат (прибыль минус убыток) в экономике, млн. руб.	Индекс потребительских цен, процентгов	Инвестиции в основной капитал, млрд.руб.
									Добыча полезных ископаемых	Обрабатывающие производства	Производство и распределение электроэнергии, газа и воды						
<u>Белгородская область</u>	27,1	<u>1552,9</u>	698,1	<u>30024</u>	26998	26873	<u>686,4</u>	1290	88757	568628	27415	226544	1350,1	298,7	213778	104,4	143,8
<u>Брянская область</u>	34,9	<u>1220,5</u>	522,2	<u>25606</u>	25030	22819	<u>269,9</u>	627	280	171421	16421	78312	665,1	219,9	16516	106,1	68,3

**Этап 2 – Формирование исходных данных.** Производим сканирование страниц издания и распознавание присутствующей в составе полученных изображений текстовой информации. Первые строки полученного текста, содержащего информацию о социально-экономических показателях с разбивкой по областям, приведены в листинге 1.

```
Белгородская область | 27,1 | 1552,9 | 698,1 | 30024 | 26998 | 26873 | 686,4 |
Брянская область      | 34,9 | 1220,5 | 522,2 | 25606 | 25030 | 22819 | 269,9 |
```

Листинг 1. Исходные данные, приведенные к текстовому формату

Выполняем преобразование полученного текста в формат CSV – текстовую форму представления электронных таблиц [4]. В документе формата CSV каждая строка таблицы представлена строкой текстового файла с разделителями. В процессе преобразования запятая, символ десятичного разделителя целой и дробной части вещественных чисел, подлежит замене на символ «точка». В качестве разделителя используем символ «точка с запятой» (листинг 2).

```
Белгородская область;27.1;1552.9;698.1;30024;26998;26873;686.4;
Брянская область;34.9;1220.5;522.2;25606;25030;22819;269.9;
```

Листинг 2. Представление исходных данных в формате CSV – кода

Для обработки информации средствами языка программирования *Python* используем библиотеку математических функций с открытым исходным кодом *numpy* [5]. Загружаем исходный CSV файл с образованием многомерного массива X (листинг 3).

```
import numpy as np
X = np.loadtxt('data_1.csv', delimiter=';')
```

Листинг 3. Загрузка исходного CSV файла  
в массив средствами библиотеки *numpy*

В качестве двумерного тестового набора данных для проведения анализа

выберем:

- среднедушевые денежные доходы в месяц (руб./чел.) А;
- отношение валового регионального продукта (млн. руб.) к численности населения региона (тыс. человек) В.

Визуализация тестового набора данных, выполненная средствами *Python* с использованием графической библиотеки *matplotlib.pyplot*, приведена на рис. 1.




Рис. 1. Визуализация исходных данных

**Этап 3 – Выбор модели машинного обучения и метода кластеризации данных.** В общем случае обучение алгоритмов классификации производится по тренировочным данным, с которыми ассоциированы определенные метки (маркеры). После прохождения этапа обучения алгоритм искусственного интеллекта может классифицировать немаркированные, но однотипные с тестовыми данные, относя их к той или иной группе (кластеру).

При известном заранее количестве кластеров  $N$  можно воспользоваться методом  $k$ -средних ( $k$ -means) [6]. Основная идея метода заключается в циклическом обновлении центров тяжести кластеров (центроидов). Итеративный процесс продолжается до тех пор, пока при выполнении очередной итерации все центроиды не сдвинутся более, чем на некоторую заданную величину погрешности, т.е. с определенной точностью займут свои оптимальные положения. Выбор положения центроида каждого кластера направлен на минимизацию инерции или суммы квадратов внутри кластера:

$$\sum_{i=0}^N \min_{\mu_j \in C} (\|x_i - \mu_j\|^2),$$

где  $\mu_j$  – положение центроида в кластере  $C$ ;

$x_i$  – образцы в кластере  $K_j$ .

Рассмотрим более сложный механизм формирования модели машинного обучения, относящейся к категории искусственного интеллекта «обучение без учителя». Построим модель машинного обучения без привлечения маркирован-

ных тренировочных данных. Предоставим возможность искусственному интеллекту самому распределить представленные данные по категориям, которые пока нам неизвестны. Полагаем, что набор исходных данных генерируется под влиянием неявных факторов, управляющих их распределением.

В рамках проводимого исследования выполняем кластеризацию данных принимая условие, что количество кластеров заранее не известно. Воспользуемся непараметрическим алгоритмом обучения, основанном на методе сдвига среднего (*Mean Shift*) [7]. Данный алгоритм рассматривает все пространство признаков как функцию распределения вероятности. При этом в базовом распределении существуют  $K$  пиков, соответствующих центрам тяжести такого же количества кластеров. Результатом выполнения алгоритма, реализующего метод сдвига среднего является определение максимального количества кластеров и идентификация их центров.

$$m(x_i) = \frac{\sum_{x_j \in N(x_i)} K(x_j - x_i) x_j}{\sum_{x_j \in N(x_i)} K(x_j - x_i)},$$

где  $N(x_i)$  – соседство образцов на заданном расстоянии вокруг  $x_i$ ;

$m(x_i)$  – вектор среднего сдвига, указывающий на максимальную плотность точек.

**Этап 4 – Обучение модели кластеризации данных.** Одним из основных параметров чувствительности базового процесса при оценке плотности распределения данных в алгоритме сдвига среднего является ширина окна (*bandwidth*). Малая ширина окна способствует появлению большого количества кластеров, излишне широкое окно приводит к слиянию отдельных кластеров в более крупные. Следует учесть, что отклонение ширины окна как в одну, так и в другую сторону от оптимального значения приводит к снижению информативности результатов кластеризации данных. Подключаем модуль *sklearn.cluster* [8] библиотеки *sklearn*. Ширина окна задается величиной параметра *quantile* (листинг 4).

```
from sklearn.cluster import MeanShift, estimate_bandwidth
bandwidth_X = estimate_bandwidth(X, quantile=0.1, n_samples=len(X))
```

Листинг 4. Подключение модуля *sklearn.cluster*,  
оценка ширины окна для массива  $X$

Производим обучение модели кластеризации с учетом заданной оценки ширины окна (листинг 5).

```
meanshift_model = MeanShift(bandwidth=bandwidth_X, bin_seeding=True)
meanshift_model.fit(X)
```

Листинг 5. Обучение модели кластеризации на основе метода сдвига среднего

**Этап 5 – Выполнение анализа данных с использованием алгоритмов искусственного интеллекта.** Определяем количество кластеров *num\_clusters*

для заданной ширины окна и массив координат их центров *cluster\_centers* (листинг 6).

```
labels = meanshift_model.labels_  
num_clusters = len(np.unique(labels))  
cluster_centers = meanshift_model.cluster_centers_
```

Листинг 6. Определение количества кластеров и расположение их центров

Результат работы программы в текстовом виде представлен на листинге 7.

```
Количество кластеров = 9  
Центры кластеров:  
[[ 283.60666667 24341.33333333]  
 [ 356.675      26623.41666667]  
 [ 395.86       28550.9        ]  
 [ 546.675     39541.75        ]  
 [ 505.73333333 32197.66666667]  
 [ 1701.5       51124.         ]  
 [ 1283.1       56974.         ]  
 [ 1093.        59097.         ]  
 [ 855.8        46135.         ]]
```

Листинг 7. Результат определения количества кластеров и расположения их центров

Графическое представление результата с использованием библиотеки *matplotlib.pyplot* приведено на рис. 2.




Рис. 2. Графическое представление результата кластеризации данных

**Заключение.** В работе рассматривается процедура проведения анализа не-

структурированных статистических данных с использованием алгоритмов искусственного интеллекта. Последовательность действий подробно описана с разбиением на следующие этапы: сбор информации, формирование исходных данных, выбор модели машинного обучения и метода кластеризации данных, обучение модели кластеризации данных, выполнение анализа данных с использованием алгоритмов искусственного интеллекта.

Использование алгоритмов искусственного интеллекта при обработке больших массивов неструктурированных данных позволяет производить кластеризацию представленных данных как опираясь на известные ранее критерии, так и способом поиска различных изначально неявных метрик сходства.

## СПИСОК ЛИТЕРАТУРЫ

1. *Киселев Б. Н.* Результат интеллектуальной деятельности, созданный искусственным интеллектом, и результат интеллектуальной деятельности, созданный при помощи искусственного интеллекта // Актуальные проблемы науки и практики: Гатчинские чтения-2019 : Сборник науч. трудов по материалам VI Междун. науч.-практич. конф. 2019. Т. 2. С. 123-126.

2. *Гутаревич В. О., Рябко К. А., Рябко Е. В.* Проблемы и направления совершенствования экологических характеристик горно-транспортных машин с дизельной установкой // Вестник Донецкого национального технического университета. 2018. № 1 (11). С. 12-17.

3. Россия в цифрах. 2017 : Краткий статистический сборник / Федеральная служба государственной статистики (Росстат). М., 2017. 511 с. [Электронный ресурс]. URL: <http://komitet4.km.duma.gov.ru/upload/site28/rus17.pdf?ysclid=lq9j5gnsus110188126> (дата обращения 10.10.2023).

4. Учебник Python 3. CSV. [Электронный ресурс]. URL: [https://learn4kid-python.firebaseio.com/python\\_data\\_structure/python\\_csv\\_all/#пример-файла-csv](https://learn4kid-python.firebaseio.com/python_data_structure/python_csv_all/#пример-файла-csv) (дата обращения 24.09.2023).

5. Библиотека математических функций Python numpy. [Электронный ресурс]. URL: <https://numpy.org> (дата обращения 24.09.2023).

6. Кластеризация K-means. [Электронный ресурс]. URL: <https://scikit-learn.org/stable/modules/clustering.html#k-means> (дата обращения 24.09.2023).

7. *Московкин В. М., Сизъунго М., Голиков Н. А.* Кластерный анализ инновационной активности регионов РФ на основе метода Mean Shift // Оригинальные исследования. 2019. Т. 9. № 6. С. 117-149.

8. Кластеризация Mean Shift. [Электронный ресурс]. URL: <https://pythonprogramming.net/mean-shift-from-scratch-python-machine-learning-tutorial/> (дата обращения 24.09.2023).