

ОСОБЕННОСТИ РАЗВИТИЯ МЕТОДОВ КЛАСТЕРИЗАЦИИ ДАННЫХ И ИХ ПРАКТИЧЕСКОЕ ПРИМЕНЕНИЕ В ИНДУСТРИИ 4.0

FEATURES OF THE DEVELOPMENT OF DATA CLUSTERING METHODS AND THEIR PRACTICAL APPLICATION IN INDUSTRY 4.0

**M. Roza
S. Dementiev**

Summary. The article discusses the features of the development of data clustering methods and their practical application in the context of Industry 4.0. Modern clustering algorithms such as K-means, DBSCAN, as well as their adaptation to the conditions of a dynamic environment of production processes are analyzed. Special attention is paid to the advantages and disadvantages of each method, as well as the criteria for choosing the appropriate algorithm, depending on the specifics of the data being processed. The practical part of the article includes examples of successful clustering applications in various industries: from predictive maintenance in manufacturing to improving the accuracy of marketing in retail. The trends and future directions of research in the field of data clustering are considered, including the use of machine learning and deep learning algorithms, as well as the need to create adaptive methods capable of working with changing data in real time.

Keywords: data analysis, competitiveness, real data, clustering, Internet of things, artificial intelligence, optimization, adaptive data.

Роза Мария Петровна

Аспирант, Сибирский государственный
университет науки и технологий
имени академика М.Ф. Решетнева, г. Красноярск
mashenka-roza@mail.ru

Дементьев Сергей Юрьевич

Аспирант, Сибирский государственный
университет науки и технологий
имени академика М.Ф. Решетнева, г. Красноярск
super.wark@mail.ru

Аннотация. В статье рассматриваются особенности развития методов кластеризации данных и их практическое применение в контексте Индустрии 4.0. Анализируются современные алгоритмы кластеризации, такие как K-means, DBSCAN, а также их адаптация под условия динамичной среды производственных процессов. Особое внимание уделяется достоинствам и недостаткам каждого метода, а также критериям выбора подходящего алгоритма в зависимости от специфики обрабатываемых данных. Практическая часть статьи включает примеры успешного применения кластеризации в различных отраслях: от предиктивного обслуживания в производстве до повышения точности маркетинга в розничной торговле. Рассматриваются тенденции и будущие направления исследований в области кластеризации данных, включая использование алгоритмов машинного обучения и глубокого обучения, а также необходимость создания адаптивных методов, способных работать с меняющимися данными в реальном времени.

Ключевые слова: анализ данных, конкурентоспособность, реальные данные, кластеризация, интернет вещей, искусственный интеллект, оптимизация, адаптивные данные.

Методы автоматической группировки данных, или кластеризации, представляют собой ключевые инструменты в области машинного обучения и анализа данных. Их суть заключается в разделении множества объектов на группы (кластеры) таким образом, чтобы объекты внутри одной группы были максимально схожи друг с другом, а объекты из разных групп — максимально различны. Это позволяет выявлять скрытые структуры в данных и делать выводы, которые могут быть полезны в различных прикладных задачах.

Основные направления развития методов автоматической группировки:

- Методы на основе центроидов (например, K-средних, K-медоида): Эти алгоритмы работают на основе определения центров кластеров и минимизации расстояний между объектами и цен-

трами. Метод K-средних, созданный в 1957 году, остаётся одним из самых популярных и простых в применении [1ds.hj].

- Методы на основе плотности (например, DBSCAN, OPTICS): Эти алгоритмы выявляют кластеры, основываясь на плотности точек в пространстве. Они полезны для нахождения кластеров произвольной формы и для работы с шумом в данных.
- Иерархические методы: Эти методы строят иерархическую структуру кластеров, что позволяет пользователю выбрать уровень детализации в зависимости от задачи.

Современные алгоритмы оптимизируются для работы на больших данных путем распределения вычислительных нагрузок. Поэтому благодаря параллельным и распределенным вычислениям происходит улучшение производительности и устойчивости методов. А новые

подходы при построении устойчивых к шуму алгоритмов разрабатываются для того, чтобы минимизировать влияние выбросов на результаты кластеризации [2].

Использование нейронных сетей с методами глубокого обучения для извлечения признаков в свою очередь позволяет улучшать качество кластеризации, особенно при работе с неструктурированными данными, такими как текст или изображения. Еще осуществляется интеграция методов кластеризации с подходами активного обучения и самообучения для улучшения точности и адаптивности.

Разработка алгоритмов, способных работать с огромными объемами данных, с использованием таких технологий, как Apache Spark и Hadoop, что значительно увеличивает возможности применения кластеризации в реальном времени.

Что касается интерпретации результатов: очень важно не только группировать данные, но и давать подробные пояснения к полученным результатам. Для этого ведется работа по созданию более понятных и прозрачных методов анализа кластеров.

В настоящее время кластеризация активно применяется в различных областях и её возможности становятся всё более актуальными благодаря развитию технологий и увеличению объёмов данных. Был рассмотрен ряд областей, в которых кластеризация играет ключевую роль:

1. Маркетинговые исследования.

Компании используют кластеризацию для сегментации клиентов на основе их поведения, предпочтений и демографических факторов. Это позволяет осуществлять целевую рекламу и персонализированные предложения, что увеличивает уровень отклика и лояльности клиентов.

2. Анализ социальных сетей.

Кластеризация помогает выявлять сообщества пользователей, основываясь на их взаимодействии, таких как лайки, комментарии и обмен сообщениями. Это может помочь в выявлении влиятельных пользователей или в анализе тем, обсуждаемых внутри этих сообществ.

3. Биомедицина.

В области здравоохранения кластеризация используется для группировки геномных данных, выявления подтипов болезней и нахождения закономерностей, которые могут помочь в разработке новых методов лечения.

4. Обработка изображений.

Кластеризация применяется для сегментации изображений, выделяя важные объекты и структуры. Это может быть использовано в таких сферах, как медицинская диагностика, автономные автомобили и системы видеонаблюдения.

5. Анализ временных рядов.

В задачах, связанных с прогнозированием, кластеризация может быть использована для группировки временных рядов, что позволяет идентифицировать схожести между различными наборами данных, а также выявлять аномалии.

Проблема и вызовы кластеризации заключается в том, что несмотря на обширное применение методов кластеризации, существуют и сложности, с которыми сталкиваются практики и исследователи.

Определение числа кластеров. Во многих алгоритмах, таких как K-средние, предварительно необходимо задать количество кластеров, что может быть нелегко в зависимости от характера данных.

Чувствительность к выбросам. Многие алгоритмы кластеризации подвержены влиянию шумов и выбросов, а это вполне может привести к искажению конечных результатов.

Сложность кластеров может состоять в том, что кластеры могут иметь сложные формы и различные плотности, что будет затруднять их связь с классическими алгоритмами, например, такими как K-средние.

Выбор соответствующих характеристик. Точность кластеризации также напрямую зависит от выбора признаков или характеристик для анализа. Неподходящие признаки могут снизить качество группировки и привести к неправильным выводам.

Но, несмотря на связанные с ней проблемы, существует множество алгоритмов кластеризации, каждый из которых имеет свои особенности и области применения. Рассмотрим более подробно примеры алгоритмов кластеризации.

1. K-средние (K-means):

Является одним из самых популярных алгоритмов, который разбивает данные на K кластеров путем минимизации суммы квадратов расстояний от каждой точки до центра своего кластера. Он хорошо работает с большими наборами данных, но требует предустановленного числа классов. Чтобы более точно понять, как устроен

алгоритм, рассмотрим практическое применение алгоритма K-средних на основе набора данных о клиентах. Задача сегментации клиентов для маркетинговых целей. Пример задачи — сегментация клиентов.

Шаг 1. Подготовка данных.

Предположим, у нас есть следующий набор данных о клиентах, включающий два признака: Возраст клиента (от 18 до 70 лет) и Годовой доход (в тысячах единиц). Данные могут выглядеть так (см таблицу 1):

Таблица 1.

Практический пример набора данных для метода K-средних

Клиент	Возраст	Годовой доход
1	23	30
2	45	70
3	34	50
4	50	100
5	25	40
6	60	85

Источник: составлено автором на основании данных для практической задачи

Шаг 2. Выбор числа кластеров (k).

Перед применением алгоритма необходимо определить количество кластеров k. Это можно сделать с помощью метода локтя. Мы будем постепенно увеличивать k и вычислять сумму квадратов расстояний (SSE) для каждого значения.

Шаг 3. Применение алгоритма K-средних.

Теперь применим алгоритм K-средних. Алгоритм условно можно разделить на следующие шаги:

1. Инициализация: случайным образом выбрать k точек из данных как центры кластеров (центроиды).
2. Присвоение кластера: для каждого клиента вычислить расстояние до каждого центроида и присвоить клиента кластеру, соответствующему ближайшему центроиду.
3. Обновление центроидов: после присвоения всех клиентов кластерам обновить центроиды, вычислив средние значения для каждого кластера.
4. Повторение: повторять шаги 2 и 3 до тех пор, пока центроиды не перестанут изменяться или изменения станут минимальными.

Шаг 4. Визуализация результатов.

После завершения работы алгоритма можно визуализировать результаты, построив график с клиентами. На графике разные кластеры будет удобно обозначить разными цветами.

Ниже представлен пример кода на языке Python с использованием библиотеки scikit-learn:

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.cluster import KMeans
# Создание DataFrame
data = {'Возраст': [23, 45, 34, 50, 25, 60, 35, 43, 20, 55],
        'Годовой доход': [30, 70, 50, 100, 40, 85, 60, 90, 35, 75]}
df = pd.DataFrame(data)
# Определение числа кластеров
k_values = range(1, 10)
sse = []
for k in k_values:
    kmeans = KMeans(n_clusters=k, random_state=0)
    kmeans.fit(df)
    sse.append(kmeans.inertia_) # Сумма квадратов
# Метод локтя
plt.figure(figsize=(10, 6))
plt.plot(k_values, sse, marker='o')
plt.title('Метод локтя для выбора k')
plt.xlabel('Число кластеров (k)')
plt.ylabel('Сумма квадратов')
plt.grid()
plt.show()
# Применение K-средних с выбранным k
optimal_k = 3
kmeans = KMeans(n_clusters=optimal_k, random_state=0)
df['Кластер'] = kmeans.fit_predict(df)
# Визуализация кластеров
plt.figure(figsize=(10, 6))
plt.scatter(df['Возраст'], df['Годовой доход'],
            c=df['Кластер'], cmap='viridis')
plt.scatter(kmeans.cluster_centers_[:,0], kmeans.cluster_centers_[:, 1], s=300, c='red', label='Центроиды')
plt.title('Сегментация клиентов на основе K-средних')
plt.xlabel('Возраст')
plt.ylabel('Годовой доход')
plt.legend()
plt.grid()
plt.show()
```

Шаг 5. Интерпретация результатов

После выполнения кода можно увидеть, как клиенты разбиты на три кластера в зависимости от их возраста и годового дохода. Центроиды кластеров обозначены красным, что позволяет понять, какие группы клиентов образовались и где находятся их центры.

Алгоритм K-средних является мощным инструментом для кластеризации и может быть использован во множестве практических приложений, от сегментации клиентов до анализа данных. Важно помнить о правильной интерпретации результатов и выборе числа кластеров для получения оптимальных результатов.

2. Иерархическая кластеризация:

Иерархическая кластеризация — это метод, который позволяет создавать древовидную структуру (дендрограмму) для визуализации отношений между объектами в наборе данных. Этот метод полезен, когда необходимо понять структуру данных или иерархию между разными группами. Рассмотрим практический пример, иллюстрирующий процесс иерархической кластеризации данных.

Пример задачи — Классификация растений.

Предположим, что у нас есть набор данных о растениях, состоящий из нескольких признаков, таких как:

- Длина листа (в см)
- Ширина листа (в см)
- Высота растения (в см)

И имеется небольшой пример набора данных (см. таблицу 2):

Таблица 2.

Набор данных для примера задачи по классификации растений

Растение	Длина листа	Ширина листа	Высота растения
1	5	2	30
2	6	2,5	35
3	7	3	40
4	5	2,2	32
5	10	5	60
6	9	4,8	55

Источник: составлено автором на основании данных для практической задачи

Шаг 1. Выбор метрики расстояния.

Для иерархической кластеризации необходимо выбрать метрику расстояния, которая будет использоваться для вычисления расстояний между объектами. Популярные варианты включают евклидово расстояние, манхэттенское расстояние и многие другие. На данном примере было выбрано евклидово расстояние.

Шаг 2. Выбор метода кластеризации.

Существует два основных подхода к иерархической кластеризации: аггломеративный (bottom-up) и сопря-

жённый (top-down). В примере используем аггломеративный метод, который начинается с каждого объекта как отдельного кластера и постепенно объединяет их.

Шаг 3. Построение дендрограммы.

1. Инициализация: каждое растение начинается как отдельный кластер.
2. Расчет расстояний: сначала вычисляются расстояния между всеми парами кластеров. На первой итерации имеется множество кластеров, состоящих из одного растения.
3. Объединение кластеров: на каждой итерации два ближайших кластера объединяются в один. Расстояние между новообразованным кластером и остальными кластерами пересчитывается с помощью метода связи (например, метод ближайшего соседа, метод дальнего соседа или метод среднemasштабного соседа).
4. Повторение: Эта процедура продолжается до тех пор, пока все объекты не будут объединены в один кластер.
5. Дендрограмма: В итоге строится дендрограмма, на которой по оси X располагаются объекты, а высота объединения показывает степень сходства между кластерами. Построение дендрограммы на языке Python будет выглядеть следующим образом:

```
import numpy as np
import pandas as pd
from scipy.cluster.hierarchy import dendrogram, linkage
import matplotlib.pyplot as plt
# Создание датафрейма
data = {
    'Длина листа': [5, 6, 7, 5, 10, 9],
    'Ширина листа': [2, 2.5, 3, 2.2, 5, 4.8],
    'Высота растения': [30, 35, 40, 32, 60, 55]}
df = pd.DataFrame(data)
# Применение иерархической кластеризации
Z = linkage(df, method='average') # Метод среднего
расстояния
# Визуализация дендрограммы
plt.figure(figsize=(10, 7))
dendrogram(Z, labels=df.index + 1)
plt.title(«Дендрограмма растений»)
plt.xlabel(«Растения»)
plt.ylabel(«Расстояние»)
plt.show()
```

Шаг 4. Интерпретация результатов.

Теперь, когда получена дендрограмма, можно определить, сколько кластеров необходимо. Например, если видно, что некоторые растения имеют очень близкие размеры (что видно по высоте объединения), мы мо-

жем создать два кластера: один для маленьких растений и один для больших.

Иерархическая кластеризация обеспечивает интуитивно понятный способ визуализации структуры данных и может быть особенно полезна, когда заранее неизвестно число кластеров. Этот метод также помогает исследовать данные и выявлять дополнительные закономерности, что может быть полезно при дальнейшей обработке данных или принятии решений.

3. DBSCAN:

DBSCAN (Density-Based Spatial Clustering of Application with Noise). Алгоритм, основанный на плотности, который может находить кластеры произвольной формы и игнорировать выбросы. Он группирует точки на основе заданной плотности и имеет два основных параметра: радиус окрестности и минимальное количество точек.

Преимуществом данного алгоритма перед алгоритмом K-средних является то, что он способен выделять кластеры произвольной формы, и к тому же определять число кластеров. И, несмотря на то, что данный метод был впервые предложен в 1996, он применяется на практике и по сей день. Это алгоритмический подход, и он базируется на достаточно разумных эвристиках, которые были предложены самим автором этого алгоритма.

В алгоритме на основе эpsilon-окрестности объекты подразделяются на три типа:

- **корневой:** содержащий не менее m объектов в эpsilon-окрестности;
- **граничный:** не корневой, но находящийся в окрестности корневого;
- **шумовой (выброс):** не граничный, не корневой.

Под типами объектов — понимается одна из эвристика. Так все-таки, каким образом они используются в алгоритме и для чего они вообще нужны.

Допустим, что имеется некоторый набор данных в двумерном признаковом пространстве. Для начала необходимо случайным образом выбрать объект x , из этого набора данных. Если же в эpsilon-окрестности этого объекта менее m других объектов, то он помечается как возможный шумовой. Далее, случайным образом снова выбираем объект, уже исключая ранее рассмотренные, и опять проверяем полноту его эpsilon-окрестности. Если в ней находится не менее m других объектов, то вектор будет помечен как корневой. Следовательно, для всех точек, входящих в эту окрестность, процедура рекуррентно повторяется. Причем, если же объект не содержит достаточного количества соседей в своей окрестности, то он помечается граничным, в противном случае — корневым. Таким образом перебираются все

объекты, которые захватываются заданной эpsilon-окрестностью. И поэтому формируется кластер.

Затем, процесс повторяется с самого начала, исключая уже ранее обработанные точки. Случайным образом отбирается объект и формируется еще один кластер, или же шумовые образы. В итоге, после прохождения по всем объектам выборки, на выходе получено разбиение данных на кластеры и шумовые образы, которые не вошли ни в один из кластеров. Стоит отметить, что число кластеров было определено автоматически, исходя из заданных параметров ϵ и m .

Реализация алгоритма DBSCAN по заданным параметрам (см. рисунок 1):

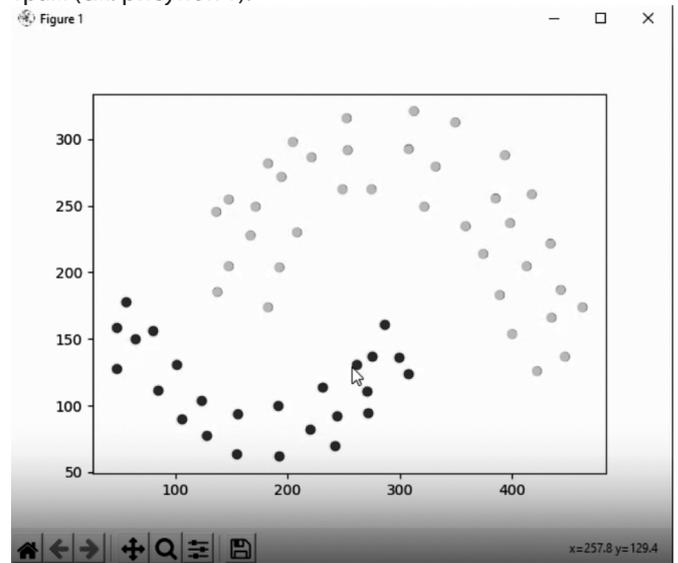


Рис. 1. Результат работы алгоритма DBSCAN

Источник: составлено автором на основании реализации алгоритма

DBSCAN — это мощный алгоритм для кластеризации, особенно в ситуациях с неравномерными плотностями кластеров и признаками шума. Он является предпочтительным выбором, когда не известно количество кластеров, и хорошо подходит для работы с высоко размерными данными.

Технологии развиваются и объёмы данных увеличиваются, поэтому можно с точностью утверждать, что методы автоматической группировки будут продолжать эволюционировать. Но ни в коем случае не стоит забывать, что методы автоматической группировки данных обладают огромным потенциалом и широким спектром применения, и также требуют внимательного подхода к выбору методов и интерпретации получаемых результатов.

Индустрия 4.0 — представляет собой некую концепцию, которая объединяет в себе передовые техно-

логии, такие как Интернет вещей (IoT), искусственный интеллект (AI), машинное обучение, большие данные и автоматизацию, для создания более умных и гибких производственных систем. Методы кластеризации (автоматической группировки) играют особую роль в этой новой эре благодаря своему вкладу в анализ данных, оптимизацию процессов, а также принятие решений.

Развитие методов автоматической группировки является динамичной областью, в которой продолжают появляться новые алгоритмы и подходы. Они позволяют более эффективно обрабатывать и анализировать данные, играя важную роль в научных исследованиях и практических приложениях. Понимание и применение этих методов является необходимым навыком для современных специалистов в области анализа данных и машинного обучения. Методы кластеризации находят свое применение во множестве сфер. Ниже приведены несколько примеров применения методов кластеризации в контексте Индустрии 4.0 [3].

1. Оптимизация производственных процессов.

Методы кластеризации могут использоваться для анализа больших объемов данных, собираемых с датчиков в производственных системах. Классифицируя данные о работе различных машин и процессов. Предприятия могут выявлять паттерны производительности и определять группы машин с похожими характеристиками, что позволяет проводить более точные прогнозы о возможных поломках и необходимости обслуживания. А также могут оптимизировать загрузку оборудования, перераспределяя задачи между машинами на основе их производительности и состояния.

2. Предиктивное обслуживание.

Кластеризация может использоваться для создания моделей предиктивного обслуживания. Анализируя данные из сенсоров, можно кластеризовать оборудование по состоянию, выявляя группы машин с высокой вероятностью выхода из строя. Это позволяет снижать время простоя за счет планирования обслуживания и предупреждения о неисправностях заранее. А также сокращать затраты за счет повышения эффективности работы оборудования и уменьшения количества внеплановых ремонтов.

3. Анализ потребительского поведения.

В рамках розничной торговли и электронной коммерции методы кластеризации помогают анализировать данные о клиентах и их покупательских привычках. Сегментировать клиентов на основе их покупок, что позволяет создавать целевые предложения и персонализированные рекомендательные системы. Определять

группы товаров, которые часто покупаются вместе, что может помочь в организации маркетинговых кампаний и управлении запасами.

4. Оптимизация цепочек поставок

Кластеризация играет важную роль в анализе данных, связанных с поставками и логистикой [4]. Она помогает определять группы поставщиков на основе надежности, стоимости и времени доставки, что способствует оптимизации выбора партнеров для компании. Также с помощью кластеризации осуществляется анализ путей поставок для оптимизации логистики и уменьшения затрат, выявляя наиболее эффективные маршруты и методы доставки.

5. Умные города и транспорт.

В контексте умных городов процессы кластеризации помогают анализировать данные о движении транспорта и поведении пассажиров, что способствует улучшению транспортной инфраструктуры и предложению более эффективных маршрутов. Процессы кластеризации упрощают управление ресурсами, такими как электроэнергия и вода, путем группировки данных по районам и выявления паттернов потребления.

6. Обучение и адаптация AI-систем.

В области искусственного интеллекта и машинного обучения кластеризация используется для оптимизации моделей обучения. Данные разделяются на группы для повышения качества обучения, когда модели обучаются на более однородных данных. Методы кластеризации применяются для улучшения систем рекомендаций, где пользователи и элементы в свою очередь группируются для предоставления более точных рекомендаций.

7. Интеллектуальные производственные системы.

В рамках концепции «умной фабрики» методы кластеризации способствуют созданию более интеллектуальных производственных систем [5]. Осуществляется классификация различных процессов на основе их эффективности и потребления ресурсов, что позволяет реализовать более устойчивые и экономичные производственные методы. Происходит объединение данных от различных производственных линий для идентификации общих проблем и их устранения.

8. Мониторинг и анализ качества.

Кластеризация может активно использоваться в процессе контроля качества. Группировка данных о дефектах на основе производственных партий для выявления корневых причин проблем. Анализ производственных

данных для выявления закономерностей, указывающих на возможные проблемы в качестве продукции.

9. Разработка новых продуктов.

Используя методы кластеризации, компании могут более эффективно разрабатывать новые продукты, анализируя отзывы и предпочтения клиентов. Определять группы клиентов с похожими интересами, что позволяет сфокусироваться на разработке новых характеристик продукта, которые будут наиболее привлекательны для целевых групп. Исследовать паттерны покупок и предпочтений для создания более целенаправленных маркетинговых стратегий.

Эти примеры показывают, как применение кластеризации может обработку данных сделать более проактивной и ориентированной на результаты, что важно для достижения успеха в эпоху цифровой трансформации.

Кластеризация в Индустрии 4.0 предоставляет мощные инструменты для анализа данных и оптимизации процессов. Благодаря своей способности выявлять скрытые паттерны и группировать данные, методы ав-

томатической группировки помогают компаниям повышать эффективность, снижать затраты и улучшать взаимодействие с клиентами [6]. Важно отметить, что успех применения этих методов зависит от правильной настройки алгоритмов, качественной предобработки данных и интерпретации полученных результатов.

Кластеризация является мощным инструментом для анализа и интерпретации данных. Хотя она сталкивается с определенными вызовами и проблемами, её разнообразие методов и применений делает её неотъемлемой частью современного анализа данных. Разработка новых алгоритмов и улучшение существующих методик продолжается, что позволяет расширять горизонты её применения в новых и захватывающих областях. По мимо всего кластеризация представляет собой мощный инструмент в арсенале аналитиков данных и исследователей для распознавания закономерностей в больших объемах данных. Несмотря на свои ограничения и вызовы, правильное использование методов кластеризации может значительно обогатить понимание данных, привести к более информированным решениям и улучшить множество бизнес-процессов.

ЛИТЕРАТУРА

1. Jain A.K. Data clustering: 50 years beyond K-means / A.K. Jain // *Pattern Recognition Letters*, — 2010. — 31(8), p.651–666.
2. Hodge V.J., Survey of Outlier Detection Methodologies / V.J. Hodge, J.A. Austin // *Artificial Intelligence Review*, — 2004. — 22(2), p.85–126.
3. Zhao R. Application of Clustering Algorithms in Industry 4.0: A Review / R. Zhao, Y. Liu // *Journal of Manufacturing Systems*, — 2019. — 51, p.67–77.
4. Benitez J.A Framework for the Implementation of Industry 4.0 in Automotive Supply Chains / J. Benitez // *Journal of Business Research*, — 2020. — 118, p. 332–339.
5. Jabbour A.B. L. de S. The Influence of Industry 4.0 Technologies on Supply Chain Resilience: A Classification System. / A.B.L. de S. Jabbour // *International Journal of Production Economics*, — 2020. — 221, 107482.
6. Bessant J. Managing Product Development: The Role of Industry 4.0 in Product Design. / J. Bessant, D. Francis // *International Journal of Production Economics*, — 2019. — 207, p.162–172.

© Роза Мария Петровна (mashenka-roza@mail.ru); Дементьев Сергей Юрьевич (super.wark@mail.ru)
Журнал «Современная наука: актуальные проблемы теории и практики»