

УДК 004

ПРОБЛЕМЫ БОЛЬШИХ ВЫБОРОК ДАННЫХ

Рогов Д.Е., студент гр. ИИМ-221, 2 курс
 Кузбасский государственный технический университет имени Т.Ф.
 Горбачева, г. Кемерово

Выборки больших данных представляют собой важный аспект современного анализа данных, но они также сталкиваются с несколькими проблемами. Одной из основных сложностей является обработка и хранение огромных объемов информации [1-4]. Это требует высокой вычислительной мощности и эффективных методов обработки данных [5].

Еще одной проблемой является качество данных. В больших объемах информации могут присутствовать ошибки [6], выбросы [7] или неполные записи (рисунок 1) [8], что может исказить результаты анализа. Гарантировать чистоту данных становится сложной задачей.

| | | | |
|-------------|-------------|-------------|---|
| 0,246 | 0 | 0 | 0 |
| 0,010822511 | 0,002662338 | 0,377358491 | |
| 0 | 0 | 0 | |
| 0,002164502 | 0,000532468 | 0,075471698 | |
| 0 | 0 | 0 | |
| 0 | 0 | 0 | |
| 0 | 0 | 0 | |
| 0,001623377 | 0,000399351 | 0,056603774 | |
| 0 | 0 | 0 | |
| 0,001082251 | 0,000266234 | 0,037735849 | |
| 0,000541126 | 0,000133117 | 0,018867925 | |
| 0 | 0 | 0 | |
| 0 | 0 | 0 | |
| 0,002164502 | 0,000532468 | 0,075471698 | |
| 0,002705628 | 0,000665584 | 0,094339623 | |
| 0 | 0 | 0 | |
| 0,002705628 | 0,000665584 | 0,094339623 | |
| 0,001082251 | 0,000266234 | 0,037735849 | |
| 0,002705628 | 0,000665584 | 0,094339623 | |
| 0 | 0 | 0 | |
| 0,001082251 | 0,000266234 | 0,037735849 | |

Рисунок 1 – Пример неполных данных

Сложности возникают также при необходимости выбора подходящих алгоритмов для анализа больших данных. Некоторые методы, эффективные на небольших выборках, могут оказаться неэффективными или даже неприменимыми при работе с огромными объемами данных [9].

Вопросы конфиденциальности и безопасности также становятся более актуальными при работе с большими данными. Необходимо разработать эффективные механизмы для защиты личных данных и предотвращения возможных утечек информации [10].

Наконец, важно учитывать вычислительные затраты при анализе больших данных. Это может потребовать значительных инвестиций в вычислительное оборудование и технологии, чтобы обеспечить эффективную обработку и хранение данных [11].

Все эти проблемы подчеркивают важность разработки инновационных подходов к работе с большими данными, чтобы извлекать максимальную пользу из их потенциала, минимизируя при этом возможные негативные.

Список литературы:

1. Свидетельство о государственной регистрации программы для ЭВМ № 2023680124 Российская Федерация. BrainPower : № 2023669010 : заявл. 16.09.2023 : опубл. 26.09.2023 / Р. В. Майтак. – EDN QXVJIM.
2. Математические и программные методы построения моделей глубокого обучения : Учебное пособие / А. В. Протодяконов и др. – Вологда : Общество с ограниченной ответственностью "Издательство "Инфра-Инженерия", 2023. – 176 с. – ISBN 978-5-9729-1484-5. – EDN PZLUAN.
3. Свидетельство о государственной регистрации программы для ЭВМ № 2023680335 Российская Федерация. Maitak Intelligence Natural Language Processing Module : № 2023669704 : заявл. 27.09.2023 : опубл. 28.09.2023 / Р. В. Майтак.
4. Методы восстановления непараметрической регрессии в условиях несбалансированных данных / А. Д. Салычева и др. – Вологда : Общество с ограниченной ответственностью "Издательство "Инфра-Инженерия", 2024. – 192 с. – ISBN 978-5-9729-1856-0. – EDN AAJATW.
5. Свидетельство о государственной регистрации программы для ЭВМ № 2023684619 Российская Федерация. Efficient Network: № 2023684038: заявл. 14.11.2023: опубл. 16.11.2023 / П. А. Пылов.
6. Свидетельство о государственной регистрации программы для ЭВМ № 2023680070 Российская Федерация. Модернизированная модель DBSCAN для определения скрытых взаимосвязей : № 2023668841 : заявл. 13.09.2023 : опубл. 26.09.2023 / Р. В. Майтак. – EDN KQUUKF.
7. Асимптотический анализ поведения прикладных моделей машинного обучения : Учебное пособие / А. В. Протодяконов и др. – Вологда : Общество с ограниченной ответственностью "Издательство "Инфра-Инженерия", 2023. – 144 с. – ISBN 978-5-9729-1455-5. – EDN ARHQME.

8. Свидетельство о государственной регистрации программы для ЭВМ № 2023684621 Российская Федерация. Destructed Deep Random Forest: № 2023684050: заявл. 14.11.2023: опубл. 16.11.2023 / П. А. Пылов.
9. Свидетельство о государственной регистрации программы для ЭВМ № 2023684622 Российская Федерация. Mask Made AI: № 2023684042: заявл. 14.11.2023: опубл. 16.11.2023 / П. А. Пылов.
10. Свидетельство о государственной регистрации программы для ЭВМ № 2023680103 Российская Федерация. Cognitive Solution : № 2023669189 : заявл. 19.09.2023 : опубл. 26.09.2023 / Р. В. Майтак. – EDN QEMFJA.
11. Свидетельство о государственной регистрации программы для ЭВМ № 2023684624 Российская Федерация. Программа автоматического распознавания лиц в видеопотоке: № 2023684236: заявл. 15.11.2023: опубл. 16.11.2023 / П. А. Пылов.