

Автоматическая нормализация гетерогенных данных IoT-датчиков на основе языковых моделей с использованием внешних источников

Подморин Д.О. (ИТМО)

Научный руководитель – аспирант, инженер Ковальчук М.А. (ИТМО)

Введение.

Современный Интернет вещей — это быстро развивающаяся сетевая структура, направленная на интеграцию физических устройств в цифровое пространство, используя интернет как среду для передачи данных [1]. Стремительное развитие Интернета вещей (IoT) и других систем, требующих внедрения большого количества устройств, привело к возникновению проблем в области совместимости данных из-за разнообразия форматов и протоколов связи между различными устройствами и системами.

Согласно аналитике от промышленных партнеров, ручная интеграция одного датчика занимает от 2 до 4 часов. Это время уходит на поиск и чтение документации, написание драйверов и проверку работы интегрированного устройства.

Анализируя полученные данные с реальной IoT системы, были обнаружены 1200 уникальных параметров, каждое устройство имеет примерно 3-4 целевых параметра. Таким образом, в систему было интегрировано примерно 350 датчиков. Исходя из этой информации, мы можем посчитать, что компания потратила 1050 человеко-часов на интеграцию или 131 рабочий день.

Таким образом, ручная интеграция новых устройств требует больших трудозатрат на одно устройство, а ввиду большого числа устройств требует автоматизации.

Основная часть. В рамках решения проблемы унификации параметров с датчиков были разработаны 4 алгоритма:

- 1) Алгоритм, основанный на онтологиях и экспертных знаниях. Данный подход позволяет автоматизировать интеграцию для известных данных путем создания четких правил преобразования. Основным недостатком подхода является необходимость экспертных знаний для создания новых правил.
- 2) Алгоритм, основанный на больших языковых моделях (БЯМ). Формат входных данных может быть не определен, что требует создания гибкого алгоритма преобразования данных. Языковые модели являются гибким инструментом и даже могут работать с неизвестными форматами, что позволяет применять их для интеграции IoT-устройств в общую систему [2].
- 3) Гибридный алгоритм, объединяющих онтологии и БЯМ. Основная идея заключается в оптимизации запросов к языковой модели. Использование онтологий позволяет снизить количество токенов, что позволяет избежать переполнения контекста БЯМ.
- 4) Алгоритм, основанный на гибридном подходе с использованием поиска документации в сети Интернет для повышения качества унификации. Данный подход требует грамотного промптирования поскольку документация также будет тратить контекстное модели [3].

Выводы. Были разработаны 4 алгоритма и проведены эксперименты. Наиболее эффективный алгоритм показал прирост производительности примерно в 18 раз над ручной интеграцией при высоком качестве.

Список использованных источников:

1. Elijah, O., Rahman, T. A., Orikumhi, I., Leow, C. Y., Hindia, M. N. (2018). An overview of Internet of Things (IoT) and data analytics in agriculture: Benefits and challenges. IEEE Internet of Things Journal, 5, 3758–3773
2. Mior, Michael J. "Large Language Models for JSON Schema Discovery." arXiv preprint arXiv:2407.03286 (2024).
3. Clavié, Benjamin Ciceu, Alexandru Naylor, Frederick Soulié, Guillaume Brightwell, Thomas.

(2023). Large Language Models in the Workplace: A Case Study on Prompt Engineering for Job Type Classification.