



ИПМ им.М.В.Келдыша РАН

Абрау-2023 • Труды конференции



Труды XXV Всероссийской научной конференции

Научный сервис в сети Интернет

З.В. Апанович

Приложения графов знаний для цифровизации предприятий

Рекомендуемая форма библиографической ссылки

Апанович З.В. Приложения графов знаний для цифровизации предприятий // Научный сервис в сети Интернет: труды XXV Всероссийской научной конференции (18-21 сентября 2023 г., онлайн). — М.: ИПМ им. М.В.Келдыша, 2023. — С. 25-37.

<https://doi.org/10.20948/abrau-2023-11>

<https://keldysh.ru/abrau/2023/theses/11.pdf>

Видеозапись выступления

Презентация к докладу

Приложения графов знаний для цифровизации предприятий

З.В. Апанович¹

¹ *Институт систем информатики им. А.П. Ершова
Сибирского отделения Российской академии наук*

Аннотация. Графы знаний проделали большой путь эволюции от простого множества RDF-триплет до систем получения новых знаний. Если в прежние годы основным приложением графов знаний считался семантический поиск, то на современном этапе графы знаний проникают во все области промышленного производства. Данная работа является обзором новых вариантов графов знаний, предназначенных для использования в современном производстве.

Ключевые слова: граф знаний, Интернет Вещей, цифровой двойник, исполняемый граф знаний

Applications of Knowledge Graphs in modern Industry

Z.V. Apanovich^{1,2}

¹ *Novosibirsk state university*

² *Institute of Informatics Systems SBIRAS*

Abstract. Knowledge graphs have come a long way in evolution from a simple set of RDF triples to systems for obtaining new knowledge. While in previous years semantic search was considered the main application of knowledge graphs, nowadays knowledge graphs penetrate into all areas of industrial production. This work is an survey of new applications of knowledge graphs intended for use in modern production.

Keywords: knowledge graph, Internet of Things, digital twin, executable knowledge graph

1. Введение

Графы знаний (ГЗ) с момента их громкого появления под лозунгом «вещи, а не строки» (“things not strings”) прошли большой путь эволюции. После их первоначального определения, где граф знаний понимался просто как RDF-граф, то есть множество триплет в виде (*субъект*,

предикат, объект), были сформулированы такие критерии качества графов знаний как *покрытие, корректность и свежесть*. Затем определение графа знаний было дополнено требованием *достоверности знаний*, а позже графы знаний превратились в *системы получения новых знаний* [1]. Если в начальные годы основным приложением графов знаний считался семантический поиск, то сейчас в список приложений входят вопросно-ответные системы, рекомендательные системы, системы принятия решений и многие другие.

Наступление четвертой промышленной революции, наряду с увеличением связей между людьми, механизмами и датчиками смещает принятие решений на основе данных с уровня отдельных персон на системный уровень и способствует повышению эффективности производства. Применение машинного обучения в промышленности, в частности, разнообразных моделей нейронных сетей для обработки системных данных и данных от разнообразных датчиков обуславливает переход к умному производству. С ростом промышленного Интернета Вещей предприятия будут использовать все более мощные, взаимосвязанные и интеллектуальные устройства. Необходимость обеспечивать взаимодействие между огромным количеством людей, механизмов, датчиков и моделей машинного обучения открывает огромные перспективы применения семантических моделей, таких как графы знаний.

Семантические модели внедряются в различных отраслях Промышленного Интернета вещей для моделирования и управления знаниями предметной области. Их приложения варьируются от управления следующим поколением производства до объяснимого транспорта и энергосбережения в зданиях для устойчивого будущего и от использования семантической интеграции различных датчиков IoT до автоматизации аналитики созданных данных. В настоящий момент количество разновидностей графов знаний значительно расширяется за счет новых приложений. Появляются такие вариации графов знаний как Динамические графы знаний, Исполняемые графы знаний, Виртуальные графы знаний и др. В данной работе будет сделан обзор современных графов знаний и их приложений, обусловленных потребностями четвертой промышленной революции.

2. Виртуальные графы знаний и интеграция множественных источников данных

Тенденция цифровизации в обрабатывающей промышленности приводит к огромному росту объема и сложности данных, генерируемых машинами, участвующими в производственных процессах. Эти данные становятся важным активом для улучшения эффективности производства. Однако раскрытие потенциала этих данных - серьезная проблема для

многих организаций. Часто данные находятся в разрозненных хранилищах, которые не связаны между собой, но содержат семантически связанные данные, возможно с избыточной и противоречивой информацией. Поэтому эффективное использование данных требует интеграции данных, которая включает очистку, дедупликацию и семантическую гомогенизацию. По оценке компании Bosch, усилия по интеграции данных составляют примерно 70-80% по сравнению с 20-30%, необходимыми для анализа данных. В последние годы для решения этой проблемы используются методы семантической интеграции данных на основе виртуальных графов знаний.

В этом подходе онтология моделирует предметную область и определяет общий словарь виртуального графа знаний, который скрывает от пользователя физическую структуру источников данных, а также обогащает данные из источников некоторыми общими знаниями. Онтологий связана с конкретными источниками данных через декларативные спецификации данных в терминах отображений (mappings), которые связывают классы и свойства онтологии с конкретными представлениями данных в разрозненных источниках. Онтология вместе с отображениями представляет собой виртуальный граф знаний, к которому можно писать запросы SPARQL. Запросы формулируются в терминах онтологии, описывающей предметную область, и пользователю не требуется понимание конкретных источников данных, знание о взаимосвязях между этими источниками или способе кодирования данных в отдельных источниках. Ключевой технологией является технология переписывания запросов (query rewriting), которая позволяет избежать физической материализации источников в графе знаний. Запрос SPARQL транслируется в серию SQL запросов к различным источникам данных, а затем результаты запросов собираются в единый ответ на исходный SPARQL запрос. Схема этого подхода показана на рис. 1.

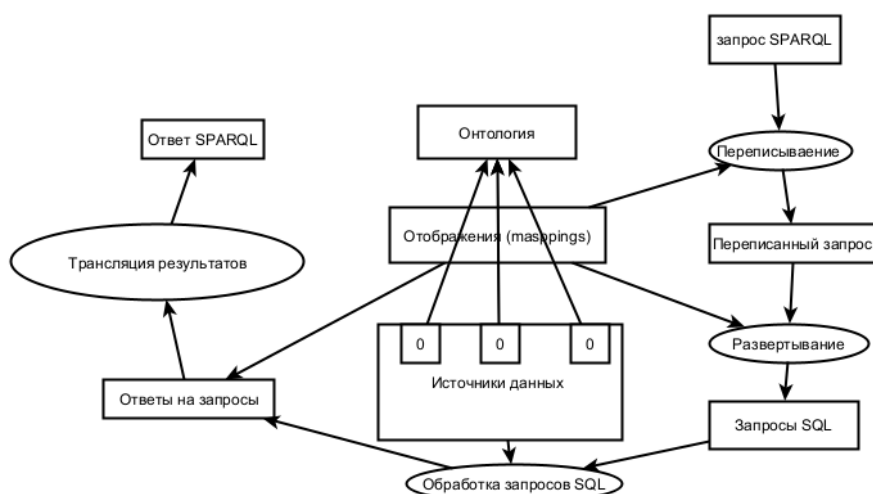


Рис.1. Схема семантической интеграции множественных источников данных.

В работе [2] описано приложение этого подхода в норвежской многонациональной нефтегазовой компании Equinor (ранее Statoil ASA). Одна из обычных задач геологов Equinor - найти новые пригодные для эксплуатации скопления нефти или газа в заданных областях, своевременно анализируя данные об этих областях. Однако сбор необходимых данных не является тривиальной задачей, так как данные хранятся в нескольких сложных и больших источниках данных, включая EPDS, Recall, CoreDB, GeoChemDB, OpenWorks, Compass и NPD FactPages. Построение правильных запросов ко всем этим источникам невозможно для геологов Equinor, поэтому они должны сообщить свои потребности в информации ИТ-специалистам, которые затем превращают их в запросы SQL. Это резко влияет на эффективность поиска правильных данных для поддержки принятия решений. Эта проблема была решена путем создания виртуального графа знаний, позволившего создать каталог запросов в терминах предметной области.

Еще одно приложение подхода виртуальных графов знаний, реализованное в фирме Siemens, описано в работе [3]. Подразделение Siemens Energy управляет несколькими сервисными центрами, которые удаленно контролируют и выполняют диагностику нескольких тысяч устройств, таких как газовые и паровые турбины, генераторы и компрессоры, установленные на электростанциях. Для выполнения диагностики доступ к данным и интеграция как статических данных (например, конфигурация и структура турбин), так и динамических данных (например, данные от датчиков) особенно важны, но очень сложны. Опять же использование виртуальных графов знаний позволяет справиться с этой проблемой.

3. Графы знаний для цифровых двойников

Одной из областей применения семантических моделей являются *цифровые двойники*. Цифровой двойник — это цифровое представление системы IoT, способное непрерывно обучаться в течение всего жизненного цикла системы и прогнозировать поведение системы IoT. Цифровые двойники предназначены для постоянного использования на протяжении всего жизненного цикла системы - от предоставления рекомендаций при создании системы, до автоматизации ее производства и оптимизации ее работы путем диагностики аномалий или улучшения контроля и прогнозирования. Ядро Цифрового Двойника формируют два тесно взаимодействующие понятия:

1. Модель искусственного интеллекта (ИИ), такая как машинное обучение (МО) или имитационная модель, способная к непрерывному обучению на основе данных, а также объяснению и прогнозированию поведения системы.

2. Цифровой поток, который связывает базовые источники данных на протяжении жизненного цикла системы.

Оба понятия тесно взаимодействуют друг с другом, поскольку цифровой поток должен использоваться для автоматизации настройки моделей ИИ, чтобы позволить масштабировать их приложение, в то время как результаты модели ИИ должны быть передаваться обратно в Цифровой Поток для анализа и объяснения новых знаний.

Технологии семантических графов знаний очень хорошо подходят для реализации цифрового потока [4]. Есть несколько примеров применения семантических моделей для представления цифровых двойников [4, 5] в разных отраслях промышленности. В работе [6] показано, как управлять отраслевыми данными с помощью семантических моделей, в [7] представлена архитектура цифрового двойника для Индустрии 4.0, а в [4] рассматривается несколько подходов к геопространственному графу знаний для цифрового двойника Великобритании.

В фирме IBM была развернута эталонная архитектура для семантического цифрового двойника [8]. Она используется для различных клиентов в течение нескольких лет. Эталонная архитектура была реализована в продукте KITT (Keep IoT Trivial), который используется в таких продуктах как IBM Maximo и IBM TRIRIGA, для интеграции данных из нескольких различных решений в цифровых потоках. Основной идеей архитектуры является отделение уровня данных от уровня графа. Уровень данных связывается с данными из различных федеративных бэкендов системы. Они объединены уровнем абстракции доступа к семантическим данным. Этот уровень представляет собой микросервисную среду, которая отображает каждый тип представления данных в интерфейс ключ/значение, позволяющий строить запросы к соответствующим данным нормализованным способом. Различается три типа представлений данных: данные временных рядов, данные двоичных файлов, текстовые данные/данные JSON.

Граф знаний представляет собой in-memo граф семантических свойств. Он сочетает в себе возможность использования ризонеров, характерную для RDF хранилищ и компактность представления, характерную для графов свойств. На уровне графа реализован RDFS+ ризонер, поддерживающий транзитивные запросы, а также вывод на основе событий. Уровень приложения содержит различные решения, используемые Цифровым двойником. Они состоят из инструментов ИИ для машинного обучения и оптимизации, которые автоматически настраиваются из графа знаний и интерфейса пользователя.

Для тестирования архитектуры был разработан бенчмарк DTBM (Digital Twin Benchmark), являющийся примером предприятия с несколькими производственными линиями. Базовая модель определяет

триединство таких классов как *Locations*, *Asset*, *Data*, которые являются общими с другими онтологиями IoT, такими как BRICK [7]. Каждая производственная линия имеет несколько роботов разных типов, роботы связаны с помощью ремней (*Belt*) и состоят из шарниров и манипуляторов (*Arm* и *Join*).

KITT поддерживает семантическое извлечение информации из потоков данных, которое в одном вызове встроенного ризонера выдает данные и их семантический контекст из графа знаний. Например, пользователь может запросить все данные типа *Power*, связанные с сущностью типа *Robot*, с историей его заданий *Workorder* и последним изображением (*Image*) с камеры наблюдения за роботом. Такой запрос извлечет все данные об энергопотреблении с платформы IoT (Watson IoT), историю обслуживания из системы управления активами (Maximo) и изображения из хранилища объектов (COS).

4. Исполняемые графы знаний для контроля качества сварки в BOSH

Точечная сварка сопротивлением – это пример полностью автоматизированного и эффективного производственного процесса, широко применяемого в автомобилестроительной промышленности, на долю которой ежегодно приходится производство миллионов автомобилей по всему миру. Для осуществления сварки два колпачка электродов сварочной горелки сжимают два или три металлических листа между электродами с усилием и пропускают ток высокого напряжения. За счет сопротивления выделяется огромное количество тепла. Материал на небольшой площади между электродами плавится и образует точечный сварочный шов, соединяющий рабочие листы, известный как точка сварки. Качество операции сварки обычно количественно оцениваются показателями качества, такими как диаметр пятна, как предписано в международных стандартах. Для точного определения диаметра пятна обычной практикой является разрезание сварного кузова автомобиля и измерение размера пятна, что разрушает сваренные автомобили и является чрезвычайно дорогой операцией. В настоящее время Bosch разрабатывает методы оценки качества сварки, основанные на машинном обучении, чтобы уменьшить потребность в разрушенных кузовах автомобилей. Более того, у Bosch много источников данных для схожих производственных процессов, поэтому возможность повторного использования решений машинного обучения очень желательна, поэтому что их можно перенести на аналогичные данные или вопросы машинного обучения.

Для оценки качества сварки применяется три важные направления машинного обучения такие как визуальная аналитика, статистическая аналитика и аналитика машинного обучения, основанная, например, на нейронных сетях. В работе [7] предлагается закодировать решения

машинного обучения при помощи графа знаний таким образом, чтобы графы знаний помогали в описании знаний о машинном обучении и решениях стандартизированным и прозрачным способом с помощью системы на основе графического интерфейса и визуализации графа знаний. Данный подход называется *исполняемые графы знаний*, потому что такие графы знаний могут быть преобразованы в скрипты машинного обучения, которые можно модифицировать и повторно использовать для решения похожих проблем.

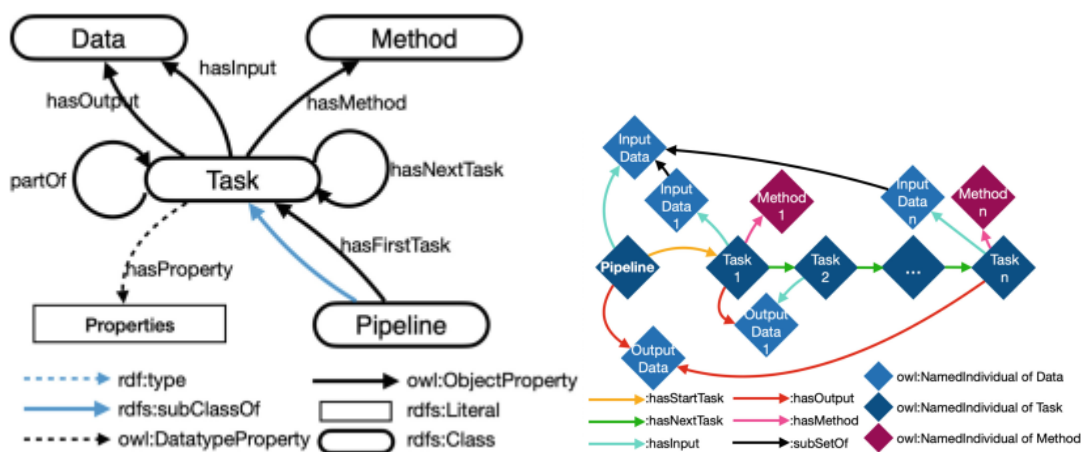


Рис. 2. (а) Связи между основными классами исполняемого графа знаний. (б) Пример исполняемого графа знаний.

На рисунке 2(а) показаны связи между основными классами *Data*, *Method*, *Task*, *Pipeline*, а на рисунке 2(б) показан пример исполняемого графа знаний.

Фреймворк поддерживает трансляцию исполняемого графа знаний в исполняемые скрипты. Он состоит из пяти слоев: слой данных (не граф знаний), уровень приложений, уровень базы данных графа знаний, уровень семантических модулей и уровень семантических артефактов.

Первоначально собираются необработанные данные сварки с производственных линий. Эти данные преобразуются модулем интеграции данных (с помощью онтологий предметной области) в графы знаний машинного обучения для сварочных аппаратов, которые представляет собой тип графа знаний о данных сварки с некоторой аннотацией машинного обучения. Эти графы знаний используются четырьмя типами аналитических приложений на уровне приложений.

В основе фреймворка лежат несколько онтологий. Онтологии предметной области включают в себя различные онтологии сварки, например, онтологию сварки пятна сопротивлением. Эти онтологии создаются на основе онтологии производства верхнего уровня [2]. Онтология производства семантически связана с онтологией верхнего

уровня для указанных выше аналитических задач (data science ontology, O^{ds}). Эта онтология содержит три основных класса: класс всех данных *Data*, класс всех алгоритмов *Method*, класс всех скриптов *Task*, класс *Task* содержит важный подкласс, который называется *Pipeline* (конвейер), состоящий из множества упорядоченных задач. Множество онтологий задач машинного обучения включает онтологию визуализации (O^{visu}), онтологию статистического анализа (O^{stats}) и онтологию машинного обучения (O^{ml}), которые создаются на основе онтологии O^{ds} . Эти онтологии задач служат схемами для модуля построения исполняемых графов знаний, который переводит исполняемые конвейеры данных в исполняемые графы знаний, включая граф знаний визуализации, граф статистических знаний и граф знаний конвейера машинного обучения. Эти исполняемые графы могут быть переведены модулем Executable Knowledge Graph Translator в исполняемые скрипты для трех аналитических приложений: визуальная аналитика, статистическая аналитика и аналитика машинного обучения, которые генерируют соответствующие результаты.

5. Графы знаний для развертывания приложений машинного обучения на промышленных устройствах Интернета Вещей

Одним из примеров задач, требующих конвергенции информационных и операционных технологий, является задача развертывания моделей машинного обучения (МО) на промышленных устройствах. Применение машинного обучения, в частности нейронных сетей (НС), в промышленности, использующей данные от датчиков и системные данные может предоставить надежную информацию о промышленном предприятии и ускорить интеллектуальное производство. Стандартные приложения машинного обучения передают массивные полевые данные в облако и централизованно обрабатывают данные. Имеются опасения, что такая передача данных вызывает многочисленные проблемы, такие как высокое потребление энергии и задержки, утечка конфиденциальной информации, перегрузка полосы пропускания.

Ожидается, что с развитием Интернета вещей (IoT) заводы будут оснащаться все более мощными, связанными и интеллектуальными устройствами. Выгрузка аналитики машинного обучения из облака на устройства промышленного интернета вещей (Industrial IoT, IIoT) позволит выполнять задачи машинного обучения рядом с источниками данных и снизит зависимость от передачи данных, что устраняет задержку и заботы о безопасности.

Устройства IIoT бывают всех форм и размеров, различаются встроенными датчиками, доступной памятью и объемом памяти, а также имеют разные платформы времени выполнения. В контексте машинного обучения на устройстве они используют модели нейронных сетей для

интерпретации данных датчиков, прогнозирования их окружения и выполнения интеллектуальных действий локально.

Модели НС также весьма разнообразны. Они разрабатываются с различными структурами, например, различными комбинациями слоев и индивидуализированных блоков пре- и постобработки. Кроме того, большинство обученных моделей НС распространяются как двоичные файлы без четкого и стандартизированного описания их использования.

В исследовательских подразделениях фирмы Siemens разрабатывается фреймворк под названием Semantic Low-Code Engineering for ML [11] (семантическая разработка низкоуровневого кода для машинного обучения) с целью изучения возможностей использования формализованных семантических моделей для описания гетерогенных устройств ПоТ и моделей нейронных сетей соответственно. Благодаря онтологиям, знания об устройствах ПоТ и моделях машинного обучения, таких как нейронные сети, могут быть промоделированы и централизованно храниться в графах знаний, что делает знания доступными для поиска. В результате становится возможным независимое от поставщика обнаружение знаний и подбор моделей нейронных сетей, соответствующих характеристикам и возможностям каждого устройства. Важным моментом является и то, что используются семантические шаблоны приложений, так называемые рецепты, чтобы помочь разработчикам интегрировать приложения ML в более крупные конвейеры и быстро создавать приложения для конечных пользователей.

В качестве демонстрации возможностей такого подхода приводится решение на программируемом логическом контроллере (ПЛК) Siemens SIMATIC S7-1500, использующем низкокодую платформу Siemens Mendix. Показывается как найти и сопоставить модель нейронной сети с SIMATIC S7-1500 Technology Module Neural Processing Unit (TM NPU), подсоединенном к камере Intel RealSense для классификации объектов различных типов на конвейерной ленте.

Структура приложения SeLoC-ML показана на рисунке 3. Для описания устройств использовалась стандартная онтология TD (Things Description) [12]. Онтология для описания моделей машинного обучения в контексте IoT, была создана путем повторного использования существующих онтологий, таких как S3N и SOSA[13].

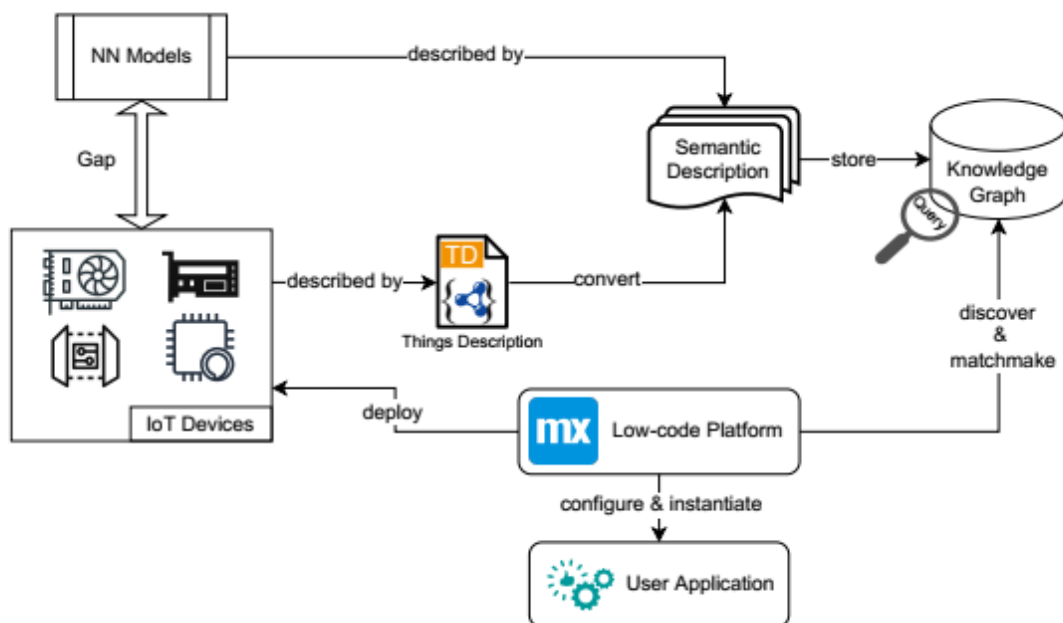


Рис. 3. Архитектура фреймворка SeLoC-ML.

Для исследовательских и демонстрационных целей онтология была разработана так, чтобы гарантировать ее интероперабельность и совместимость с онтологией TD, которая применяется для описания устройств IoT.

Онтология нейронных сетей может отображать три различные формы информации о нейронных сетях:

- 1) метаданные, такие как дата создания, категория и текстовое описание;
- 2) структура, такая как входной и выходной слой;
- 3) требования к оборудованию, такие как память и датчики.

Для демонстрации был создан упрощенный граф знаний, состоящий из девяти устройств IoT и 22 моделей нейронных сетей. Пары модель нейронной сети – устройство Интернета Вещей выдаются из графа при помощи запроса SPARQL. Примером запроса, который можно направить графу знаний является:

Запрос. Имеется обученная модель нейронной сети для классификации движения, использующая данные гироскопа и акселерометра. Учитывая, что минимальные требования к оперативной памяти и флэш-памяти для запуска этой модели равны 121 и 610 Кб соответственно, необходимо выяснить, какие доступные устройства могут работать с этой моделью.

Заключение

Одной из самых больших проблем в области цифровизации промышленности является преодоление разрыва между операционными технологиями (OT) и информационными технологиями (ИТ).

Операционные технологии находятся в центре физического мира, состоящего из производственного оборудования, генерирующего огромное количество данных, в то время как информационные технологии используют центры обработки данных, серверы и интеллектуальные приложения для потребления данных. Эти две области традиционно функционировали изолированно. Развитие четвертой промышленной революции, наряду с увеличением связи между людьми, машинами и датчиками, способствует сближению ИТ и ОТ, перенося принятие решений на основе данных с человека на уровень системы и повышая тем самым эффективность производства. Семантические технологии и, в частности, графы знаний прекрасно подходят в качестве инструмента для решения указанных задач и привлекают внимание крупнейших компаний таких как IBM, Siemens и др. к их активному использованию. Поэтому в данной работе рассмотрены несколько современных приложений графов знаний для решения актуальных задач цифровизации производства.

Литература

1. Апанович З.В. Эволюция понятия и жизненного цикла графов знаний // Системная информатика. — 2020. — № 16. — С. 57-74
2. Kharlamov E., Hovland D., Skjæveland M.G., Bilidas D., Jiménez-Ruiz E., Xiao G., Soylu A., Lanti D., Rezk M., Zheleznyakov D., Giese M., Lie H., Ioannidis Y.E., Kotidis Y., Koubarakis M., Waaler A. Ontology based data access in Statoil. *Journal of Web Semantics*. — 44:2017. — pp. 3–36.
3. Kharlamov E., Mailis T., Mehdi G., Neuenstadt C., Özçep Ö. L., Roshchin M., Solomakhina N., Soylu A., Svingos C., Brandt S., Giese M., Ioannidis Y.E., Lamparter S., Möller R., Kotidis Y., Waaler A. Semantic access to streaming and static data at Siemens // *Journal of Web Semantics*. — 44. — 2017. — pp. 54–74.
4. Akroyd, J., Mosbach, S., Bhave, A., Kraft, M. Universal digital twin-a dynamic knowledge graph // *Data-Centric Engineering*. — 2021. — vol. 2
5. Kharlamov, E., Martin-Recuerda, F., Perry, B., Cameron, D., Fjellheim, R., Waaler, A.: Towards semantically enhanced digital twins. // *IEEE International Conference on Big Data*. — 2018. — pp. 4189–4193
6. Kalaycı, E.G., Grangel Gonz'alez, I., L'osch, F., Xiao, G., Kharlamov, E., Calvanese, D., et al.: Semantic integration of Bosch manufacturing data using virtual knowledge graphs. // *International Semantic Web Conference (ISWC)*. — 2020. — pp. 464–481
7. Lietaert, P., Meyers, B., Van Noten, J., Sips, J., Gadeyne, K. Knowledge graphs in digital twins for AI in production. // *Advances in Production Management Systems (APMS)*. — 2021. — pp. 249–257

8. Ploennigs, J., Semertzidis, K., Lorenzi, F., Mihindikulasooriya, N. (2022). Scaling Knowledge Graphs for Automating AI of Digital Twins// The Semantic Web – ISWC 2022. ISWC 2022. Lecture Notes in Computer Science. — vol 13489. — Springer, Cham. https://doi.org/10.1007/978-3-031-19433-7_46
9. Zheng, Z. et al. (2022). Executable Knowledge Graphs for Machine Learning: A Bosch Case of Welding Monitoring // The Semantic Web – ISWC 2022. ISWC 2022. — Lecture Notes in Computer Science. — vol 13489. Springer, Cham. https://doi.org/10.1007/978-3-031-19433-7_45
10. Svetashova, Y., et al.: Ontology-enhanced machine learning: a bosch use case of welding quality monitoring // ISWC. — 2020
11. Ren, H., Dorofeev, K., Anicic, D., Hammad, Y., Eckl, R., Runkler, T.A. (2022). SeLoC-ML: Semantic Low-Code Engineering for Machine Learning Applications in Industrial IoT. // The Semantic Web – ISWC 2022. Lecture Notes in Computer Science. — vol 13489. Springer, Cham. https://doi.org/10.1007/978-3-031-19433-7_48
12. Charpenay, V., Kabisch, S., Kosch, H.: Introducing Thing Descriptions and Interactions: An Ontology for the Web of Things// 2016 International Semantic Web Conference. — Springer, Kobe, Japan 2016. — pp. 55-66
13. Compton, M., Barnaghi, P., Bermudez, L., Garcia-Castro, R., Corcho, O., Cox, S., Graybeal, J., Hauswirth, M., Henson, C., Herzog, A., et al., The SSN Ontology of the W3C Semantic Sensor Network Incubator Group // Journal of Web Semantics. — 17. — 2012. — pp. 25-32. <https://doi.org/10.2139/ssrn.3198991>

References

1. Apanovich Z.V. E`volyuciya ponyatiya i zhiznennogo cikla grafov znaniy // Sistemnaya informatika. — 2020. — № 16. — S. 57-74
2. Kharlamov E., Hovland D., Skjæveland M.G., Bilidas D., Jiménez-Ruiz E., Xiao G., Soylyu A., Lanti D., Rezk M., Zheleznyakov D., Giese M., Lie H., Ioannidis Y.E., Kotidis Y., Koubarakis M., Waaler A.. Ontology based data access in Statoil. Journal of Web Semantics. — 442017. — pp. 3–36.
3. Kharlamov E., Mailis T., Mehdi G., Neuenstadt C., Özçep Ö. L., Roshchin M., Solomakhina N., Soylyu A., Svingos C., Brandt S., Giese M., Ioannidis Y.E., Lamparter S., Möller R., Kotidis Y., Waaler A. Semantic access to streaming and static data at Siemens // Journal of Web Semantics. — 44. — 2017. — pp. 54–74.
4. Akroyd, J., Mosbach, S., Bhave, A., Kraft, M. Universal digital twin-a dynamic knowledge graph //Data-Centric Engineering. — 2021. — vol. 2

5. Kharlamov, E., Martin-Recuerda, F., Perry, B., Cameron, D., Fjellheim, R., Waaler, A. Towards semantically enhanced digital twins. // IEEE International Conference on Big Data. — 2018. — pp. 4189–4193.
6. Kalaycı, E.G., Grangel González, I., L'osch, F., Xiao, G., Kharlamov, E., Calvanese, D., et al.: Semantic integration of Bosch manufacturing data using virtual knowledge graphs. // International Semantic Web Conference (ISWC). — 2020. — pp. 464–481
7. Lietaert, P., Meyers, B., Van Noten, J., Sips, J., Gadeyne, K. Knowledge graphs in digital twins for AI in production. // Advances in Production Management Systems (APMS). — 2021. — pp. 249–257
8. Ploennigs, J., Semertzidis, K., Lorenzi, F., Mihindikulasooriya, N. Scaling Knowledge Graphs for Automating AI of Digital Twins // The Semantic Web – ISWC 2022. ISWC 2022. Lecture Notes in Computer Science. — vol 13489. — Springer, Cham. https://doi.org/10.1007/978-3-031-19433-7_46
9. Zheng, Z. et al. (2022). Executable Knowledge Graphs for Machine Learning: A Bosch Case of Welding Monitoring // The Semantic Web – ISWC 2022. ISWC 2022. — Lecture Notes in Computer Science. — vol 13489. Springer, Cham. https://doi.org/10.1007/978-3-031-19433-7_45
10. Svetashova, Y., et al.: Ontology-enhanced machine learning: a bosch use case of welding quality monitoring // ISWC. — 2020
11. Ren, H., Dorofeev, K., Anicic, D., Hammad, Y., Eckl, R., Runkler, T.A. SeLoC-ML: Semantic Low-Code Engineering for Machine Learning Applications in Industrial IoT. // The Semantic Web – ISWC 2022. Lecture Notes in Computer Science. — vol 13489. Springer, Cham. https://doi.org/10.1007/978-3-031-19433-7_48
12. Charpenay, V., Kabisch, S., Kosch, H.: Introducing Thing Descriptions and Interactions: An Ontology for the Web of Things// 2016 International Semantic Web Conference. — Springer, Kobe, Japan 2016. — pp. 55-66
13. Compton, M., Barnaghi, P., Bermudez, L., Garcia-Castro, R., Corcho, O., Cox, S., Graybeal, J., Hauswirth, M., Henson, C., Herzog, A., et al. The SSN Ontology of the W3C Semantic Sensor Network Incubator Group // Journal of Web Semantics. — 17. — 2012. — pp. 25-32. <https://doi.org/10.2139/ssrn.3198991>