

Impact Factor:

ISRA (India) = 6.317
ISI (Dubai, UAE) = 1.582
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
ПИИЦ (Russia) = 3.939
ESJI (KZ) = 8.771
SJIF (Morocco) = 7.184

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

SOI: [1.1/TAS](#) DOI: [10.15863/TAS](#)

International Scientific Journal Theoretical & Applied Science

p-ISSN: 2308-4944 (print) e-ISSN: 2409-0085 (online)

Year: 2023 Issue: 11 Volume: 127

Published: 27.11.2023 <http://T-Science.org>

Issue

Article



Igor Alexandrovich Lapin

Peter the Great St. Petersburg Polytechnic University
Master's Student
Institute of Computer Science and Technology

Oleg Yurievich Sabinin

Peter the Great St. Petersburg Polytechnic University
Candidate of Engineering Sciences, Docent
Institute of Computer Science and Technology

RESEARCH AND PLANNING THE DEVELOPMENT OF AN AUTOMATED SYSTEM FOR BUILDING RELATIONAL DATABASE MODELS BASED ON PROVIDED TASK TEXT IN NATURAL LANGUAGE

Abstract: In this paper authors research the possibility of developing an automated system for building relational database models based on provided task text in natural language. Authors describe the root cause of the problem they're solving, proof the actuality of such development, and explain the most essential problems. Also, different approaches in natural language processing and classification are researched as well. Authors propose an initial algorithm and architecture for developing such system.

Key words: Natural language processing, relational databases, model building, text analysis, SQL, text classification.

Language: Russian

Citation: Lapin, I. A., & Sabinin, O. Yu. (2023). Research and planning the development of an automated system for building relational database models based on provided task text in natural language. *ISJ Theoretical & Applied Science*, 11 (127), 311-320.

Soi: <http://s-o-i.org/1.1/TAS-11-127-39> **Doi:**  <https://dx.doi.org/10.15863/TAS.2023.11.127.39>

Scopus ASCC: 1700.

ИССЛЕДОВАНИЕ И ПЛАНИРОВАНИЕ РАЗРАБОТКИ АВТОМАТИЧЕСКОЙ СИСТЕМЫ ДЛЯ ФОРМИРОВАНИЯ МОДЕЛЕЙ РЕЛЯЦИОННЫХ БАЗ ДАННЫХ НА ОСНОВЕ ТЕКСТА ЗАДАНИЯ НА ЕСТЕСТВЕННОМ ЯЗЫКЕ

Аннотация: В данной статье рассматривается возможность создания автоматической системы для построения моделей реляционных баз данных на основе текста задания на естественном языке. Описывается суть проблематики, обосновывается актуальность подобной разработки, а также объясняются основополагающие проблемные моменты. Также рассматриваются различные подходы к анализу текстов на естественном языке, их классификации. Предлагается первичный алгоритм для реализации такой системы, а также ее первичная архитектура.

Ключевые слова: Обработка естественного языка, реляционные базы данных, построение моделей, анализ текста, SQL, классификация текста.

Введение

Ни одна информационная система на сегодняшний день не обходится без хранилища

данных и способов оперирования ими, которые предоставляются механизмами таких инструментов как базы данных. При разработке

Impact Factor:

ISRA (India) = 6.317
ISI (Dubai, UAE) = 1.582
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
ПИИЦ (Russia) = 3.939
ESJI (KZ) = 8.771
SJIF (Morocco) = 7.184

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

современных информационных систем этап проектирования является одним из наиболее важных, если не самым важным, и проектирование баз данных в нем играет одну из ключевых ролей.

Множество информационных систем для интеграции в повседневную жизнь общества, или же бизнес-процессы, разрабатываются крупными компаниями, как, к примеру, Сбер, Яндекс, ВТБ, VK и т. п. Подобные представители IT-индустрии могут позволить себе найти профессиональных специалистов в разработке и администрировании баз данных.

Но стоит учесть, что регулярно появляется огромное количество стартапов, академических проектов, или же просто небольших проектов. Объединяет эти категории наличие зачастую достаточно скромного бюджета. Есть также учебные проекты, которые и вовсе лишены любого финансирования (речь идет не о проектах на гранты и т. п., а именно о проектах в рамках учебной деятельности). При этом средняя зарплата специалистов в области разработки баз данных на 2023 год составляет 150.000 рублей [1]. Это может оказаться значительной позицией для небольшого бюджета. В то же время высокая стоимость оплаты труда профессионального специалиста может стать не основной проблемой в формировании команды, в отличие от того факта, что многим специалистам просто не выгодно подобная временная проектная деятельность, если к тому же они не смогут заработать больше, чем на постоянной позиции.

Таким образом все сводится к тому, что, скорее всего, вместо найма профессионального специалиста в разработке/администрировании БД необходимо будет искать альтернативы. Чаще всего заниматься планированием и разработкой БД в проекте придется либо другим разработчикам, с отличным основным профилем, либо же, как нередко бывает, и вовсе человеку, не имеющему даже смежной специализации. В этом случае не только страдает качество итоговой информационной системы, в силу некачественной реализации работы с данными, но и существенно возрастают временные затраты и когнитивная нагрузка, так как ответственному работнику приходится усваивать большое количество новой информации, включая непростую теоретическую составляющую, а затем учиться применять эти знания на практике.

Однако, даже если оценивать процесс проектирования БД специалистом, он все равно потребует значительных временных затрат и приведет к высокой когнитивной нагрузке, так как во многих случаях необходимо придумать, каким образом правильно и оптимально формализовать спецификацию требуемой базы в виде описания технического задания. В результате встает вопрос

– есть ли способ упростить и ускорить хотя бы часть процесса проектирования баз данных? И на этот вопрос можно найти ответ.

В рамках данной статьи рассматривается возможность создания системы, которая позволила бы автоматически генерировать модель базы данных (к примеру, в формате DDL скрипта) на основе некоторого текстового описания на естественном языке. Использование такой системы в будущем могло бы позволить снизить требования к специалистам для некоторых проектов, а также снизить когнитивную нагрузку на этом этапе проектирования и уменьшить затрачиваемое на него время.

Recent works on automated NLP systems

Для лучшего представления о поставленной задаче и возможных методах ее решения рациональным окажется рассмотреть некоторые последние работы схожей тематики. Варианты различных задуманных архитектур систем, а также подходов к их реализации для достижения схожих, однако отличающихся друг от друга в силу специфики каждого конкретного случая, результатов позволят заложить основу для реализации задуманной системы.

В работе [2] освещается подход к реализации когнитивной системы автоматизированной службы поддержки, которая могла бы «понимать» содержимое запросов от пользователей, верно их классифицировать, распределяя по категориям, анализировать и предлагать подходящее решение.

Приводится следующую модель жизненного цикла обработки запроса с проблемой системой (рис. 1) [2]. На первом этапе (Problem Diagnostics) извлекается логическая структура текста проблемы, происходит идентификация разделения на основе контекста, а также классификация проблемы. При этом используется анализ на основе паттернов (см. раздел 5) с предварительным разделением возможных компонент текста на большое количество групп, как контекстно-зависимых, так и инвариантных к контексту. После этого выполняется анализ первопричин (Root Cause Analysis – RCA), для чего используются собранные данные по прошлым запросам и их решениям, а также производится предобработка естественного языка для вычленения конкретных смысловых фраз (здесь и токенизация, и определение частей речи и прочее). На последнем этапе выполняется анализ семантического совпадения извлеченной информации с накопленной, в том числе с применением одного из достаточно простых, но вполне эффективных методов машинного анализа – Support Vector Machine (SVM) (см. раздел 5), по которой имеются рекомендации, которые и формируются в итоге и отправляются пользователю в качестве разрешения проблемы

Impact Factor:

ISRA (India) = 6.317	SIS (USA) = 0.912	ICV (Poland) = 6.630
ISI (Dubai, UAE) = 1.582	ПИИЦ (Russia) = 3.939	PIF (India) = 1.940
GIF (Australia) = 0.564	ESJI (KZ) = 8.771	IBI (India) = 4.260
JIF = 1.500	SJIF (Morocco) = 7.184	OAJI (USA) = 0.350

(это могут быть советы по необходимым действиям, скрипты и т. п.)

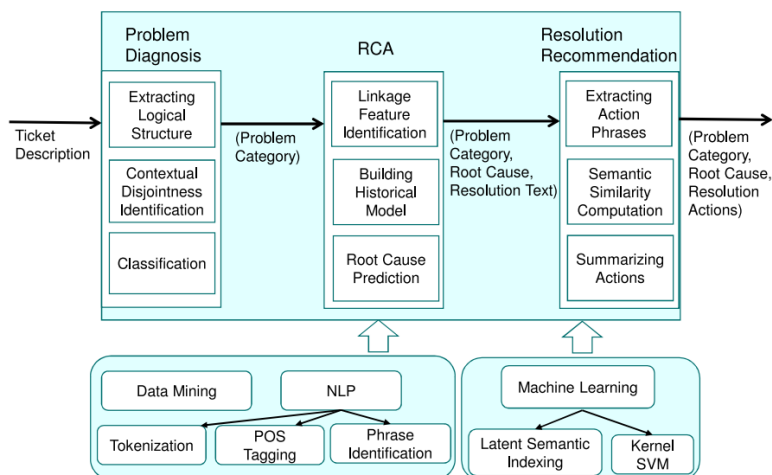


Рисунок 1 – Модель жизненного цикла обработки запроса в работе [2]

В работе [3] освещается подход к обработке запросов к реляционной базе данных, составленных на естественном языке, и перевод их в SQL запросы для непосредственного извлечения информации.

Авторами предлагается следующая модель системы (рис. 2) [3]. На вход подается запрос на естественном английском языке. В модуле обработки естественного языка сперва производится токенизация для формирования из входного запроса списка слов. Далее

производится лемматизация этого списка. После этого слова разделяются на группы по частям речи (POS-tagging). Затем происходит анализ предложений при помощи регулярных выражений для выделения различных свойств для SQL запросов. После того, как все ключевые слова выделены происходит их соотнесение с языко-специфичными терминами SQL для формирования конечного запроса.

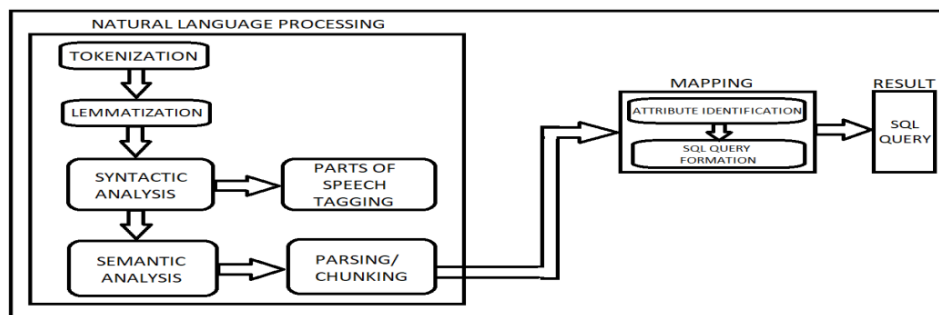


Рисунок 2 - Модель предлагаемой системы в работе [3]

В данной работе автор не использует методы машинного обучения, а применяет лишь подход, основанный на паттернах, выделяя атрибуты из преобработанного текста с использованием регулярных выражений (по сути паттерны).

В еще одной работе [4] также рассматривается алгоритм для автоматического транслирования запросов на естественном языке в SQL запросы. При описании этого алгоритма автор больше внимания уделил вопросу о разделении SQL запросов на группы по функциональности, а также моменту соотнесения выделенных атрибутов из запроса реальным атрибутам и таблицам схемы. Для этого требуется

составлять «карту» схемы базы данных, чтобы получить представления обо всех таблицах, их атрибутах и соединениях. Для решения этой задачи автор предлагает использовать машинные методы, чтобы не составлять «карту» схемы каждый раз вручную, тем самым сэкономив время и автоматизировав процесс.

System Architecture

Основываясь на приведенный в прошлом разделе краткий обзор некоторых работ о современных системах и алгоритмах, схожих с задуманной системой, упомянутой во введении к данной статье, можно обозначить первичную

Impact Factor:

ISRA (India) = 6.317	SIS (USA) = 0.912	ICV (Poland) = 6.630
ISI (Dubai, UAE) = 1.582	РИИЦ (Russia) = 3.939	PIF (India) = 1.940
GIF (Australia) = 0.564	ESJI (KZ) = 8.771	IBI (India) = 4.260
JIF = 1.500	SJIF (Morocco) = 7.184	OAJI (USA) = 0.350

архитектуру такой системы, а также выделить некоторые этапы ее реализации и возможные инструменты.




Рисунок 3 – Первичная архитектура задуманной системы

На рисунке 3 изображена первичная схема возможной архитектуры задуманной системы. Пользователь будет взаимодействовать с некоторым интерфейсом, например, с веб-API – это повысит доступность за счет мультиплатформенности. Через этот интерфейс будет происходить сообщение с основными компонентами и сервисами приложения (включая доступ к БД приложения через сервисный слой). Также отдельно выделен модуль для непосредственной работы с NLP, так как, скорее всего, приложение и скрипты будут реализовываться на разных языках программирования (наиболее популярным и часто используемым языком для NLP является Python).

При этом, учитывая специфику решаемой проблемы, потребуется, чтобы сформированная системой модель БД была максимально полезна пользователю, а это значит, что простого описания или визуального представления такой модели будет недостаточно, - потребуется практический результат, который можно будет сразу использовать. Наиболее актуальным в таком случае оказывается представление модели в виде

набора DDL скриптов для создания всех компонентов модели и связывания их между собой возможными ограничениями. Такой скрипт возможно будет сразу загрузить в IDE для СУБД и получить практический результат – готовую к использованию БД.

Таким образом, можно представить более подробно процессы, происходящие в модуле «NLP Scripts» на рисунке 3. На рисунке 4 приведен первичный алгоритм обработки исходного текста на естественном языке для получения результирующей модели БД. Исходный текст будет предобработан (приведение к инфинитиву, удаление предлогов и т. д.), затем при помощи алгоритмов машинного обучения будут выделены основные компоненты и связи, после чего будет выполнено соотнесение найденных компонент с требуемыми для построения модели БД элементами. После этого будет сформирована модель сперва в сущностях выбранного языка программирования, а затем будет построен DDL скрипт.

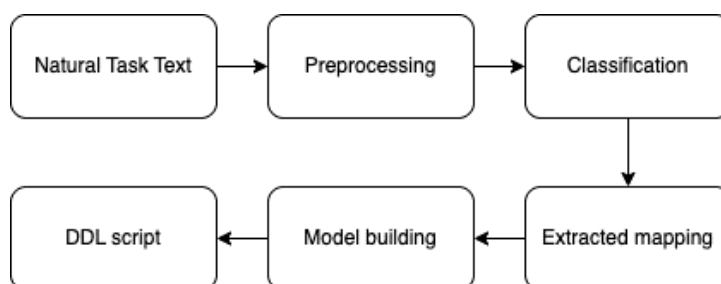


Рисунок 4 – Первичный алгоритм обработки исходного текста и формирования модели

Для классификации и сопоставления извлеченной информации возможно будет воспользоваться как анализом на основе паттернов (см. раздел 5), так и методами машинного обучения (см. раздел 5). Сама задача классификации ставится здесь для того, чтобы выделить основные сущности, для последующего сопоставления со спецификацией реляционных

БД (т. е. таблицы, их атрибуты, ограничения, типы данных и т. д.).

Построение модели в рамках сущностей выбранного языка программирования и формирование DDL скрипта на основе этих сущностей является не самой тривиальной, но уже решенной задачей в рамках бакалаврской работы автора данной статьи [5].

Impact Factor:

ISRA (India) = 6.317
ISI (Dubai, UAE) = 1.582
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
РИИЦ (Russia) = 3.939
ESJI (KZ) = 8.771
SJIF (Morocco) = 7.184

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

Предполагается разрабатывать систему для работы сперва только с текстами на английском языке, так как это позволит воспользоваться более обширным набором инструментов (библиотеки, словари и т. д.), а также избавит от необходимости соотнесения русскоязычных и англоязычных терминов, что упростит работу. Однако в будущем, при успешной реализации системы для работы с английским языком, возможно будет расширение функциональности для работы и с русским.

Problem of semantics

Основная проблема, которая появляется при попытке транслировать любые выражения,

концепции или понятия с естественного языка в понятную компьютеру форму – это неоднозначность [6]. Причем неоднозначность как в отсылках к определенным объектам, что проиллюстрировано на рисунке 5, так и в концепциях. К примеру, «Джон лежит на диване» и «на Джоне лежит большая ответственность». В этом случае необходимо, чтобы было хотя бы минимальное понимание области (домена), в которой используется концепция в конкретном случае.

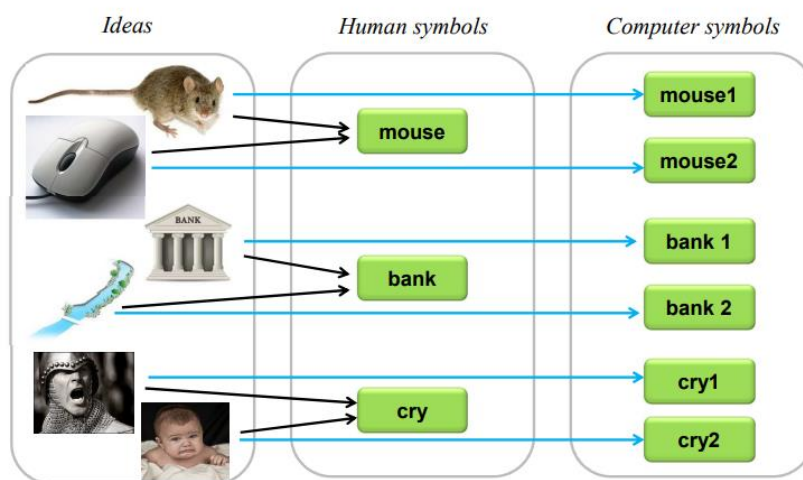


Рисунок 5 - Пример неоднозначности обозначений

Пример на рисунке 5 показывает, что в нашем естественном языке много понятий, для обозначения которых используется один и тот же термин, одно и то же слово. Однако есть и обратная ситуация – у многих понятий очень часто встречается несколько различных обозначений (рис. 6). При этом некоторые обозначения могут пересекаться для разных понятий, как в первом

примере, замыкая этот круг. Человек способен понять различия основываясь на собственном жизненном опыте и множестве накопленных в сознании контекстных ассоциаций. Компьютер же не обладает подобными возможностями изначально, и необходимо каким-то образом позволить ему четко дифференцировать понятия и концепции.




Рисунок 6 - Пример множественности обозначений

Обычно, когда речь идет о проблемах семантики, затрагивают также вопрос о принципе открытости реального мира [6]. Суть заключается в том, что окружающий нас мир не является

бинарным. В математике и классической логике мы привыкли использовать закон исключенного третьего, смысл которого сводится к тому, что любое высказывание однозначно является либо

Impact Factor:

ISRA (India) = 6.317
ISI (Dubai, UAE) = 1.582
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
РИИЦ (Russia) = 3.939
ESJI (KZ) = 8.771
SJIF (Morocco) = 7.184

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

истинным, либо ложным. В основе компьютеров лежит именно классическая логика, позволяющая обосновывать все операции в машинном коде, состоящим из единиц (истина) и нулей (ложь). Так как с любого верхнего уровня всегда все сводится к исполнению инструкций машинного кода на

платах, физически реализованных на принципах классической логики, это четко дает понять, что компьютеры не могут оперировать информацией в условиях открытого мира напрямую, когда классическая логика не применима.

Таблица 1. Различия открытого и закрытого миров

	Открытый мир	Закрытый мир
Входные данные	Tuscany and Calabria are regions of Italy. Champagne is not a region of Italy.	
Вопрос 1	Is Tuscany an Italy region?	
Ответ 1	Yes	Yes
Вопрос 2	Is Champagne an Italy region?	
Ответ 2	No	No
Вопрос 3	Is Catalonia an Italy region?	
Ответ 3	Unknown	No

В 1908 году Л. Э. Я. Брауэр выступил с критикой классической логики, отметив, что закон исключенного третьего применим лишь к конечным областям [7]. Наш окружающий мир справедливо можно считать областью не конечной. Таким образом, при рассмотрении проблем семантики в общем виде можно говорить о том, что принцип открытости мира, по сути, не удастся реализовать в машинном виде, так как третье, неизвестное состояние утверждения, помимо «истина» и «ложь» (табл. 1) нереализуемо в классической логике.

Однако стоит отметить, что при решении обозначенной во введении проблемы для реализации системы автоматической генерации модели БД на основе текста на естественном языке нет необходимости строить модель мира, в случае чего проблема открытости мира играла бы роль, так как у системы нет цели отвечать на вопросы, а ее основной задачей, по сути, должна являться классификация и определение некоторых отношений между компонентами текста, причем тексты эти реализуют некоторую абстракцию конечной области приложения реляционной алгебры.

На сегодняшний день проблему понимания семантики компьютерами решают двумя основными способами: построение семантических сетей и онтологий, в которых описываются классы сущностей, отношения между ними, и которые реализуют пояснение семантических связей между объектами классов для машин [8]. Однако такой подход является не гибким, а также достаточно сложным в реализации, так как требует, по сути, ручной формализации большого количества понятий и концепций. Вторым вариантом, который сейчас в различных формах активно применяется в индустрии информационных технологий, а также и за ее

пределами, являются методы анализа естественного языка [9, 10].

Natural language analysis methods

1 Pattern-matching

Анализ на основе паттернов (правил), или же rule-based анализ, производится с использованием заранее подготовленных лингвистических правил, по которым будет классифицироваться текст. Причем правила эти составляются вручную. Такие правила могут, к примеру, состоять лишь из слов-маркеров, наличие которых отнесет фрагмент текста или же весь текст к определенному классу [10, 11].

Такой подход использовался еще до появления традиционных статистических методов классификации, и во многом считается несколько устаревшим, а также проигрывающим в точности и стабильности статистическим методам на сегодняшний день [12]. Однако в определенных ситуациях этот подход все еще может быть актуален. К примеру, если рассматриваемая предметная область является достаточно узкой и специфической, для нее возможно построить четкие правила, при этом их количество будет вполне адекватно.

Тем не менее в любом случае такой метод потребует достаточно глубокого понимания предметной области и большого объема предварительной работы по подготовке наборов правил [13]. Таким образом данный метод отличается высокой трудозатратностью.

2 Statistical methods

Наивный Байесовский Классификатор (NB) реализует теорему Байеса и широко применяется для решения проблем классификации текста ввиду своей простоты [12]. Байесовский классификатор является статистически оптимальным классификатором, учитывая не только

Impact Factor:

ISRA (India) = 6.317
ISI (Dubai, UAE) = 1.582
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
ПИИЦ (Russia) = 3.939
ESJI (KZ) = 8.771
SJIF (Morocco) = 7.184

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

вероятность того, что образ будет относиться к некоторому классу, но также и вероятность появления образа из этого класса [14]. Существуют также различные модификации стандартного NB, которые могут показывать лучшие результаты в зависимости от конкретного набора данных.

Метод k-ближайших соседей (K-Nearest Neighbors, KNN) относит неопознанный фрагмент к какому-либо классу основываясь на известных фрагментах-соседах. Для использования этого алгоритма не требуется составлять модель. Можно взять k тренировочных текстов и оценивать требуемый на основе близости соседей. Существует положительная корреляция между объемом данных и временем работы, так что при обработке больших наборов данных алгоритм будет работать ощутимо долго [12].

Support Vector Machine (SVM) – популярный метод классификации, в котором любой текст представляется вектором [12]. В данном случае решается проблема бинарного разделения образов на две категории. Строится плоскость, которая должна находиться между двумя категориями и на максимальном расстоянии от каждой. Таким образом каждый вектор либо однозначно находится с одной стороны от плоскости, либо его большая часть.

Decision Trees (DT) – принцип работы алгоритма похож на принцип работы нейронных сетей, но вместо системы весов используется концепция соответствия определенным логическим правилам [15]. Дерево строится на стадии роста, распределяя тренировочный набор данных на части, а затем на фазе сокращения изначальные данные обобщаются до построенных категорий. Однако такой метод показывает плохие результаты по скорости при увеличении объема данных [15], а также лучшие результаты могут достигаться лишь при переобучении модели под каждый новый набор данных [12].

Стоит отметить, что на сегодняшний день стандартный DT алгоритм почти не используется, вместо него обычно применяется Random Forest (RF), смысл которого в использовании множества DT-деревьев, которые обучаются на случайных фрагментах набора данных, а итоговое решение принимается на основе нескольких результатов по DT. Таким образом RF оказывается точнее, а также избавляет от проблем переполнения деревьев. К тому же он оказывается еще более устойчивым к шумам и неточностям в данных, чем стандартный DT алгоритм [16].

3 Deep learning

Методы глубокого обучения завязаны на использование нейронных сетей, симулирующих работу человеческого мозга при принятии решений. Такой подход позволяет извлекать даже

свойства высокого уровня из наборов данных и показывают лучшие результаты, нежели традиционные статистические методы в решении задач распознавания речи, обработки изображений или понимания текста [12].

Convolutional Neural Network (CNN) – сверточные нейронные сети, обычно используются для классификации изображений, так как их работа основана на отклике фильтров (свертке с фильтрами) с различными ядрами (kernel) [17]. Однако, возможно использовать CNN и для решения задач NLP (Natural Language Processing). Если представить элементы текст в векторном виде, и объединить векторы в матрицу, чтобы общее представление текста соответствовало формату представления изображения, то будет возможно применение фильтров и получение их отклика аналогичным образом с тем, как этот процесс происходит для изображений.

Recurrent Neural Network (RNN) – рекуррентные нейронные сети. Такие сети способны хорошо справляться с задачами прогнозирования. В RNN используется три типа слоев: входной, скрытый и выходной. За каждый временной период на вход подаются векторы токенов фиксированного размера, которые затем последовательно передаются в рекуррентную единицу [17]. Таким образом организуется некоторая «память» сети, которая как раз и представлена этим скрытым слоем, и каждый следующий временной этап использует в том числе эту накопленную информацию для лучшего принятия решений.

Существуют также некоторые другие вариации алгоритмов нейронных сетей, вроде ReNN (Recursive Neural Network) методов, Attention-based методов и др. Также существуют методы, основанные на предобучении, примерами которых являются OpenAI ChatGPT и Google BERT. Такие нейронные сети сейчас часто называют «языковыми моделями». Суть их в том, что они способны подготавливать «обучающий материал» для понимания машиной семантики естественного языка [12]. Реализуется это за счет анализа большого количества необработанной информации на естественном языке, за счет чего накапливается и постоянно передается между слоями множество контекстуальных знаний, что, в соответствии с особенностями семантики, описанными в предыдущем разделе, позволяет приблизиться к новому качественному уровню в понимании текстов на естественном языке.

4 Hybrid analysis

Гибридный подход предполагает совместное использование метода анализа, основанного на паттернах (правилах), и методов машинного обучения [10]. В некоторых случаях это может

Impact Factor:

ISRA (India) = 6.317
ISI (Dubai, UAE) = 1.582
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
РИИЦ (Russia) = 3.939
ESJI (KZ) = 8.771
SJIF (Morocco) = 7.184

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

оказаться хорошей практикой. К примеру, если алгоритмы машинного обучения, используемые в системе анализа естественного языка, были обучены на конкретных классах текста, разделенных, допустим, по смыслу. В этом случае можно сперва разделять входной набор данных на эти классы основываясь на заданных правилах соответствия.

Subject area knowledge systematization

Большинство современных подходы к обработке естественного языка предполагают наличие определенного набора знаний о предметной области, в соответствии с которыми будут создаваться лингвистические правила (паттерны), задаваться классы образов,

составляться модель для обучения машинных алгоритмов. Исходя из этого и для решения обозначенной во введении проблемы потребуется некоторое формальное систематизированное описание рассматриваемой предметной области, а именно – домена знаний о моделировании реляционных баз данных.

Обычно, когда речь идет о реляционных базах данных, основной рассматриваемый элемент, – отношение, представляется следующим образом (рис. 7). Отношение состоит из множества атрибутов и ассоциированных с ними множеств значений, которые в результате выражаются конкретными наборами значений, так называемыми строками, или tuple'ами [18].

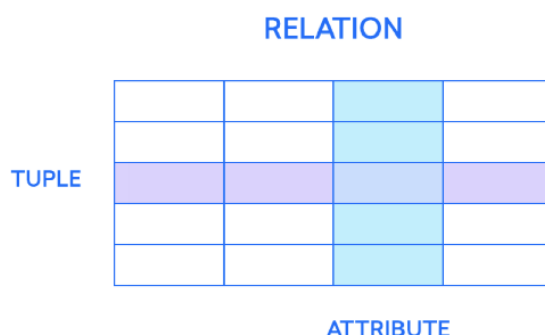


Рисунок 7 – Как представляется отношение в теории реляционных баз данных

Это представление соотносится с тем, что известно из теории реляционной алгебры. А именно – что примитивная реляционная схема представляет триплет вида:

$$PRS = (\Omega, \Delta, dom), \quad (1)$$

где Ω – конечный набор атрибутов, Δ – конечный набор множеств возможных значений, $dom - \Delta \rightarrow \Omega$ функция, которая ассоциирует с каждым атрибутом некоторое множество значений, соответствующее ему [19]. Также известно, что полная реляционная схема также представляет из собой триплет, состоящий из примитивной реляционной схемы PRS , неформального описания реляционной схемы на естественном языке M и набора условий (ограничений) SC на отношения схемы, представляющих собой булевы функции соответствия условию (2).

$$RS = (PRS, M, SC), \quad (2)$$

Опираясь на формулы 1 и 2 можно выделить следующие основные компоненты:

- 1) Сущности – то есть непосредственно классы объектов реального мира, которые необходимо формализовать в рамках теории реляционных баз данных, организуя таблицу;
- 2) Атрибуты сущностей – некоторые свойства и признаки классов объектов реального мира, которые могут принимать различные значения из свойственных им множеств;
- 3) Отношения между классами объектов реального мира и/или между атрибутами одного класса объектов; некоторые правила, ограничения, связи между сущностями/атрибутами.

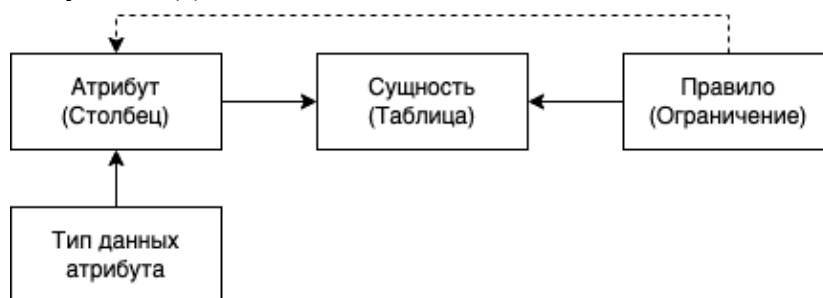


Рисунок 8 – Схема отношений выделенных компонент

Impact Factor:

ISRA (India)	= 6.317	SIS (USA)	= 0.912	ICV (Poland)	= 6.630
ISI (Dubai, UAE)	= 1.582	ПИИЦ (Russia)	= 3.939	PIF (India)	= 1.940
GIF (Australia)	= 0.564	ESJI (KZ)	= 8.771	IBI (India)	= 4.260
JIF	= 1.500	SJIF (Morocco)	= 7.184	OAJI (USA)	= 0.350

На рисунке 8 изображено схематическое представление отношений между выделенными основными компонентами предметной области. Так как теория реляционной алгебры описывает отношения, то главной компонентой можно справедливо считать сущность (в последствии таблицу). Для сущности определяются атрибуты (в последствии столбцы таблицы), ее свойства, для каждого из которых также важно определить тип данных, отражающий домен присущих атрибуту значений. Также на схеме отражены правила (условия/ограничения) для реляционной схемы, которые могут определять отношений между сущностями, о чем свидетельствует непрерывная стрелка от компоненты Правило, но также правила возможно применять и к атрибутам, о чем свидетельствует вторая стрелка.

Однако, если мы обратимся к спецификациям реализаций реляционной теории на практике, а именно – к различным реляционным системам управления базами данных (СУБД) (к примеру, СУБД Oracle [20]), мы увидим, что правила, или ограничения, применяются все также к таблице (сущности), только описывают не внешние отношения, а внутренние. Таким образом, нет необходимости напрямую связывать правила с атрибутами, ведь это может быть сделано через правила для сущности, о чем и свидетельствует пунктирная стрелка от компоненты Rule. Формально связь есть, но на практике она реализуется через сущность, которой атрибуты принадлежат.

Conclusion and future plans

Можно однозначно сказать, что с использованием современных подходов к

обработке естественного языка задуманную систему, описанную во введении, реализовать возможно. При обработке текста на естественном языке лучше будет использовать более современные подходы, основанные на методах машинного обучения, так как они более автоматизированы и дают лучшие результаты по сравнению с онтологическим моделированием и анализом на основе правил. Однако допустимо использование гибридного подхода с целью улучшения или упрощения классификации, если это будет актуально. Выбор конкретного метода машинного обучения будет зависеть от эффективности одного в конкретном случае, что возможно будет определить в будущем на тестовой выборке, оценив результаты, полученные разными методами.

В последующих работах планируется составить модель для использования алгоритмов машинного обучения, подобрать инструменты для предобработки текста, а также подготовить некоторый набор данных для обучения и тестирования эффективности алгоритмов машинного обучения. Когда этот этап будет пройден, планируется начать разработку конечного приложения, которое будет реализовывать обмен данными с пользователем, обработку текстов заданий на генерацию модели на естественном языке, а также непосредственно генерацию модели реляционной базы данных на основе выделенной из текста информации.

References:

1. (2023). *Zarplati: razrabotchik baz danih, Rossiya, fevral 2023 goda. zarplan.com - obzori zarplat*: Retrieved 01.05.2023 from https://zarplan.com/zarplata/RAZRABOTCHIK_BAZDANNYH/ROSSIJA
2. Agarwal, S., et al. (2017). Automatic problem extraction and analysis from unstructured text in IT tickets. *IBM Journal of Research and Development*, 2017, Vol. 61, №. 1, pp. 4: 41-4: 52.
3. Uma, M., et al. (2019). *Formation of SQL from natural language query using NLP*. 2019 International Conference on Computational Intelligence in Data Science (ICCIDS), IEEE, 2019, pp. 1-5.
4. Sabinin, O. Y., & Gorbатов, N. V. (2019). Development of an algorithm for translating natural language sentences into SQL queries. *ISJ Theoretical & Applied Science*, 05 (73), 414-418.
5. Lapin, I. A. (2022). *Research and development of program means of an automatic relational database DDL-scripts generation: bachelor graduation work*. Saint Petersburg: SPbSTU.
6. Khriyenko, O. (2018). *Semantic Web in a nutshell: lecture*. (p.34). JYVÄSKYLÄ: UNIVERSITY OF JYVÄSKYLÄ.
7. Karpenko, A. S. (2015). Neklassicheskie logiki versus klassicheskoy. *Logiko-filosofskie shtudii*, 2015, №. 3, pp. 13-47.

Impact Factor:

ISRA (India) = 6.317
ISI (Dubai, UAE) = 1.582
GIF (Australia) = 0.564
JIF = 1.500

SIS (USA) = 0.912
ПИИИ (Russia) = 3.939
ESJI (KZ) = 8.771
SJIF (Morocco) = 7.184

ICV (Poland) = 6.630
PIF (India) = 1.940
IBI (India) = 4.260
OAJI (USA) = 0.350

8. Khriyenko, O. (2018). *Ontologies: lecture.* (p.63). JYVÄSKYLÄ: UNIVERSITY OF JYVÄSKYLÄ.
9. Chowdhary, K. R., & Chowdhary, K. R. (2020). *Natural language processing. Fundamentals of artificial intelligence*, 2020, pp. 603-649.
10. (2023). *Text classification in NLP. Educative.* Retrieved 19.06.2023 from <https://www.educative.io/answers/text-classification-in-nlp>
11. Sabinin, O. Y., Shabalina, J. V., & Tarasova, I. V. (2019). Extracting method of automatic text summarization on the basis of neural networks. *ISJ Theoretical & Applied Science*, 06 (74), 601-607.
12. Li, Q., et al. (2022). A survey on text classification: From traditional to deep learning. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2022, Vol. 13, №. 2, pp. 1-41.
13. Denisov, M. E., et al. (2022). Izvlechenie kluchevih ponyatiy i svyazey mezhdu nimi iz tematiceskikh tekstov na russskom yazike. *Inzhenerniy vestnik Dona*, 2022, №. 12 (96), pp. 338-345.
14. Belyh, I. N. (2023). *Metodi obrabotki eksperimentalnih dannih: lecture.* Saint Petersburg: SPbSTU.
15. Thangaraj, M., & Sivakami, M. (2018). Text classification techniques: A literature review. *Interdisciplinary journal of information, knowledge, and management*, 2018, Vol. 13, p. 117.
16. Prashanthi, G., et al. (2023). Natural Language to SQL: Automated Query Formation Using NLP Techniques. *E3S Web of Conferences, EDP Sciences*, 2023, Vol. 391, pp.01115.
17. Sokolvyak, E. S. (2022). Glubokoe obuchenie dlya zadach obrabotki estestvennogo yazika. *Vestnik studencheskogo nauchnogo obschestva GOU VPO "Donetskiy nacionalniy universitet"*, 2022, Vol. 1, № 14, pp. 196-202, EDN ULSIOO.
18. (2023). *What is the Relational Model. Digital Ocean.* Retrieved 22.06.2023 from <https://www.digitalocean.com/community/tutorials/what-is-the-relational-model>
19. Paredaens, J., De Bra, P., Gyssens, M., & Van Gucht, D. (1989). *EATCS Monograph on Theoretical Computer Science - The Structure of the Relational Database Model / Paredaens Jan, De Bra Paul, Gyssens Mark, Van Gucht Dirk.* (p.231). Berlin: Springer-Verlag / ed. by Brauer W., Rozenberg G., Salomaa A.
20. (2023). *SQL Language Reference - Constraint. Oracle Help Center.* Retrieved 22.06.2023 from <https://docs.oracle.com/en/database/oracle/oracle-database/21/sqlrf/constraint.html#GUID-1055EA97-BA6F-4764-A15F-1024FD5B6DFE>