



УДК 004.89
DOI: 10.37661/1816-0301-2025-22-4-55-64

Оригинальная статья
Original Article

Технология трансляции естественно-языковых правил мерчандайзинга в цифровые планыграммы

К. С. Курочка, Ю. Д. Ёвженко✉

Гомельский государственный технический
университет им. П. О. Сухого,
пр. Октября, 48, Гомель, 246029, Беларусь
✉E-mail: yuevzhenko@gmail.com

Аннотация

Цели. Целями исследования являются разработка и апробация подхода для автоматического преобразования правил выкладки товаров, сформулированных на естественном языке, в формализованные машиночитаемые инструкции для преодоления разрыва между бизнес-требованиями и их технической реализацией.

Методы. Предложен гибридный подход, в котором большая языковая модель выполняет функцию семантического транслятора, преобразуя пользовательский запрос в команду на специализированном предметно-ориентированном языке. Полученная команда затем обрабатывается детерминированным парсером на основе регулярных выражений для валидации и извлечения параметров. Для оценки качества трансляции использовалась метрика *BLEU* на специально созданном датасете из 200 пар «запрос – эталон». Эффективность подхода сравнивалась с базовым методом, основанным на правилах.

Результаты. Эксперимент показал высокую точность формализации запросов в сравнении с базовым подходом. Качественный анализ подтвердил способность системы корректно интерпретировать синонимы и сленг, извлекать неявно заданные параметры и отфильтровывать нерелевантные команды, что доказывает робастность предложенного подхода.

Заключение. Сделан вывод о жизнеспособности и практической значимости предложенного подхода для снижения трудоемкости и повышения эффективности процессов мерчандайзинга. Разработанная система представляет собой фундамент для создания нового поколения интеллектуальных инструментов управления торговым пространством.

Ключевые слова: большие языковые модели, парсер, метаязык, планыграмма, семантический транслятор, естественный язык

Для цитирования. Курочка, К. С. Технология трансляции естественно-языковых правил мерчандайзинга в цифровые планыграммы / К. С. Курочка, Ю. Д. Ёвженко // Информатика. – 2025. – Т. 22, № 4. – С. 55–64. – DOI: 10.37661/1816-0301-2025-22-4-55-64.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Поступила в редакцию | Received 26.09.2025
Подписана в печать | Accepted 17.10.2025
Опубликована | Published 30.12.2025

The technology of translating natural language merchandising rules into digital planograms

Konstantin S. Kurochka, Yury D. Youzhanka✉

Gomel State Technical University named after P. O. Sukhoi,
av. Oktyabrya, 48, Gomel, 246029, Belarus

✉E-mail: yuevzhenko@gmail.com

Abstract

Objectives. The aim of the research is to develop and test an approach for the automatic transformation of product layout rules, formulated in natural language, into formalized machine-readable instructions to bridge the gap between business requirements and their technical implementation.

Methods. A hybrid approach is proposed in which a large language model performs the function of a semantic translator, converting a user query into a command in a specialized domain-specific language. The resulting command is then processed by a deterministic parser based on regular expressions for validation and parameter extraction. The BLEU metric was used to evaluate the quality of the translation on a specially created dataset of 200 «query-reference» pairs. The effectiveness of the approach was compared with a baseline rule-based method.

Results. The experiment showed high accuracy in the formalization of queries compared to the baseline approach. A qualitative analysis confirmed the system's ability to interpret correctly synonyms and slang, extract implicitly specified parameters, and filter out irrelevant commands, which proves the robustness of the proposed approach.

Conclusion. The conclusion is made about the viability and practical significance of the proposed approach for reducing labor intensity and increasing the efficiency of merchandising processes. The developed system represents a foundation for creating a new generation of intelligent tools for managing retail space.

Keywords: large language models, parser, meta-language, planogram, semantic translator, natural language

For citation. Kurochka K. S., Youzhanka Y. D. *The technology of translating natural language merchandising rules into digital planograms*. Informatika [Informatics], 2025, vol. 22, no. 4, pp. 55–64 (In Russ.). DOI: 10.37661/1816-0301-2025-22-4-55-64.

Conflict of interest. The authors declare of no conflict of interest.

Введение. Планограмма, по сути, представляет собой визуальную схему или диаграмму, детально регламентирующую размещение конкретных товаров на торговом оборудовании – стеллажах, полках, витринах или холодильниках в розничной точке продаж [1]. Основная цель создания планограмм заключается в оптимизации использования торгового пространства, максимизации продаж и прибыли, улучшении покупательского опыта и обеспечении соответствия выкладки общим стратегиям категории и бренда [2]. Процесс формирования этих схем, известный как планограммирование, исторически развивался и на сегодняшний день включает в себя различные подходы, отличающиеся степенью автоматизации, используемыми инструментами и объемом анализируемых данных.

На заре развития розничной торговли и мерчандайзинга составление планограмм зачастую носило интуитивный и ручной характер. Специалисты по выкладке или категорийные менеджеры могли использовать простые эскизы от руки, масштабные чертежи на бумаге или базовые таблицы в электронных редакторах, таких как *Excel*, для схематичного отображения расположения товаров. При этом сотрудники должны были опираться на свой опыт и интуицию, а также выступать в роли контролеров, обеспечивающих соответствие выкладки многочисленным требованиям. Требования делились на две большие группы: во-первых, обязательные к исполнению государственные нормативно-правовые акты, регулирующие правила соседства и условия продажи отдельных товарных групп^{1,2}, и, во-вторых, внутренние корпоративные регламенты, брендбуки

¹О мерах реализации товаров, произведенных в Республике Беларусь : постановление Совета Министров Респ. Беларусь от 4 февр. 2015 г. № 72. – URL: <https://etalonline.by/document/?regnum=C21500072> (дата обращения: 17.07.2025).

²О государственном регулировании производства, оборота и потребления табачного сырья и табачных изделий : Декрет Президента Респ. Беларусь от 17 дек. 2002 г. № 28. – URL: <https://etalonline.by/document/?regnum=Pd0200028> (дата обращения: 17.07.2025).

и коммерческие условия договоров с поставщиками. Вся ответственность за интерпретацию, запоминание и ручное применение этого массива неструктурированной информации полностью ложилась на сотрудника. В результате такой подход страдал от ряда системных недостатков: высокой вероятности ошибок и несоответствия нормативным требованиям, колоссальной трудоемкости, сложности внесения оперативных изменений, низкой точности визуализации, трудностей в тиражировании на сеть магазинов и, главное, отсутствия системного анализа объективных данных о продажах и прибыльности каждого товара в привязке к занимаемому им месту.

С развитием информационных технологий появились специализированные программные решения для планogramмирования. Эти программные комплексы предлагают значительно более совершенные инструменты для создания, редактирования и анализа планогамм. Они позволяют создавать точные двумерные и даже трехмерные визуализации торгового оборудования с размещенными на нем товарами, используя базы данных с изображениями упаковок и их габаритами. Важным преимуществом такого программного обеспечения является возможность интеграции с учетными системами ритейлера, что позволяет привязывать к каждой товарной позиции (*SKU*) на планогамме актуальные данные о продажах, прибыли, оборачиваемости, остатках и других ключевых показателях эффективности (*KPI*). Это дает возможность категорийным менеджерам принимать более обоснованные решения о размещении товаров, основываясь не только на визуальной привлекательности, но и на конкретных цифрах. Программное обеспечение также облегчает процесс тиражирования утвержденных планогамм по сети магазинов и контроль за их исполнением.

Несмотря на значительный прогресс, связанный с использованием специализированного программного обеспечения, процесс составления планогамм во многом остается зависимым от человеческого фактора и требует значительных временных затрат. Специалисту необходимо не только владеть инструментарием программы, но и уметь интерпретировать большие объемы данных, учитывать множество факторов и ограничений. К таким факторам относятся как количественные показатели продаж, так и качественные аспекты: стратегические цели категории, договорные обязательства с поставщиками (например, требования к доле полки или определенному месту размещения), правила соседства товаров (например, не размещать бытовую химию рядом с продуктами питания), принципы визуального мерчандайзинга (цветовые блоки, размещение товаров-лидеров на уровне глаз, учет потоков покупателей), а также физические ограничения самого торгового оборудования и конкретного магазина.

Особую сложность представляют интеграция и учет требований, изложенных в неструктурированных или полуструктурированных источниках, таких как маркетинговые гайдлайны, брендбуки, условия промоакций или контрактные обязательства с поставщиками. Эти требования часто формулируются в текстовом виде и содержат специфические правила выкладки, которые сложно напрямую транслировать в параметры программного обеспечения для планogramмирования. Специалисту приходится вручную анализировать эти документы и следить за соблюдением всех изложенных в них условий при формировании схемы выкладки. Это не только увеличивает трудоемкость и время создания планогаммы, но и повышает риск ошибок или неполного учета всех релевантных требований, что может привести к неоптимальной выкладке, нарушению договоренностей или снижению эффективности маркетинговых инициатив.

Таким образом, возникает очевидный разрыв между высокоуровневыми бизнес-требованиями, часто выраженными на естественном языке, и низкоуровневой технической реализацией в специализированном программном обеспечении. Этот разрыв является ключевым барьером на пути к полной автоматизации и повышению эффективности процесса планogramмирования. Для его преодоления необходимы новые подходы, способные «понимать» и формализовать неструктурированные текстовые инструкции [3]. В связи с этим целями настоящей работы являются создание и исследование подхода и архитектуры системы для автоматизации формирования планогамм на основе семантического анализа правил выкладки, заданных на естественном языке.

Методы. В основе предлагаемого решения лежит концепция разделения задач между стохастической, семантически мощной системой, в качестве которой выступает большая языковая мо-

дель (large language model, *LLM*), и детерминированной, логически строгой системой (обработчик инструкций на основе регулярных выражений). Авторы рассматривают большую языковую модель не как конечный генератор планограммы, а как семантический транслятор. Ее ключевая задача – преобразовать запрос пользователя, сформулированный на гибком и потенциально неоднозначном естественном языке, в инструкцию на строго формализованном, однозначном и машиночитаемом метаязыке.

Такой подход позволяет использовать сильные стороны *LLM* – понимание контекста, извлечение сущностей и их взаимосвязей [4, 5] – и одновременно нивелировать ее слабые стороны, такие как недетерминированность, возможность «галлюцинаций» и генерации синтаксически некорректных или логически противоречивых данных.

Для реализации предложенной концепции был разработан специализированный метаязык команд – предметно-ориентированный язык, созданный специально для описания операций с планограммами. Ключевой особенностью такого языка является его строгий и однозначный характер. Каждая команда имеет императивную форму (например, РАЗМЕСТИ, УСТАНОВИ, СОПТИРОВКА), четко указывающую на выполняемое действие. Эта директивность подкрепляется строгим синтаксисом, который регламентирует точный порядок ключевых слов и их параметров. В свою очередь, каждый параметр типизированный: он должен соответствовать определенному типу данных, такому как целое число или строка, и может иметь дополнительные ограничения, например обязательность или принадлежность к допустимому диапазону значений.

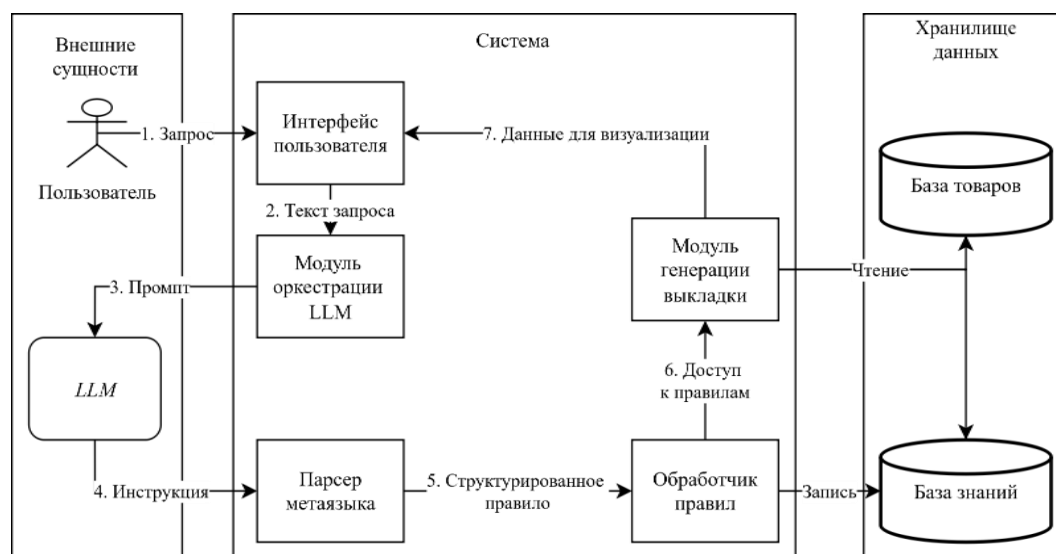
Примером команды метаязыка является РАЗМЕСТИ КАТЕГОРИЮ. Согласно спецификации (представлена ниже) она требует обязательного указания названия категории и номера полки, а также позволяет опционально задать долю занимаемого места и ограничения по весу:

```
{
  "command": "РАЗМЕСТИ КАТЕГОРИЮ",
  "syntax": "РАЗМЕСТИ КАТЕГОРИЮ '<название>' НА ПОЛКЕ <номер> [ЗАНЯВ <%> МЕСТА] [ВЕС [ОТ <мин> КГ] [ДО <макс> КГ]]",
  "parameters": [
    { "name": "название_категории", "type": "string", "required": true },
    { "name": "номер_полки", "type": "integer", "required": true },
    { "name": "доля_процентов", "type": "float", "required": true },
    { "name": "минимальный_вес", "type": "float", "required": false, "min": 0 },
    { "name": "максимальный_вес", "type": "float", "required": false, "min": 0 }
  ]
}
```

Таким образом, *LLM* получает задачу не сгенерировать планограмму, а перевести фразу «Положи молочные продукты на первую полку, пусть они займут 70 % места» в команду «РАЗМЕСТИ КАТЕГОРИЮ 'Молочные продукты' НА ПОЛКЕ 1 ЗАНЯВ 70 % МЕСТА». Это делает результат работы *LLM* предсказуемым и верифицируемым.

Предлагается следующая архитектура системы, построенная по модульному принципу, который обеспечивает сквозную обработку запроса пользователя от ввода на естественном языке до финальной визуализации. Весь процесс можно разделить на несколько логических этапов, каждый из которых реализуется отдельными компонентами (рисунок).

Начальный этап взаимодействия с системой начинается в пользовательском интерфейсе, который предоставляет специалисту (мерчендайзеру, категорийному менеджеру) текстовый чат для ввода команд. Введенный запрос передается в модуль оркестрации *LLM*, выполняющий роль связующего звена с нейросетью. Данный компонент формирует расширенный промпт, который включает системную инструкцию и полную спецификацию метаязыка для «обучения» модели в рамках одного запроса (*few-shot learning*) [6], и непосредственно текст пользователя. Затем этот промпт обрабатывается внешней большой языковой моделью, которая возвращает строку, формализованную согласно синтаксису метаязыка.

Архитектурная схема системы
System Architecture Diagram

Далее сгенерированная строка поступает в критически важный компонент – парсер метаязыка, первоочередная задача которого – валидация. С помощью набора скомпилированных регулярных выражений парсер проверяет соответствие строки одному из известных шаблонов команд, что гарантирует детерминированность и высокую производительность этого этапа. В случае успеха парсер извлекает из строки все параметры, преобразует их в требуемые типы данных (*int*, *float*) и проверяет на соответствие заданным ограничениям. В результате на выходе формируется гарантированно корректный структурированный объект, готовый к дальнейшей обработке. На заключительном этапе этот верифицированный объект передается в обработчик правил – хранилище, которое аккумулирует все правила выкладки. После обновления базы знаний активируется модуль генерации выкладки. Этот алгоритм, основываясь на всем наборе правил и данных о товарах, рассчитывает конкретное положение каждого объекта на полках. Финальный результат его работы отображается пользовательским интерфейсом в виде интерактивной трехмерной модели планограммы, замыкая таким образом цикл обработки запроса.

Рассмотрим сквозной процесс выполнения запроса на конкретном примере:

Шаг 1. Пользователь вводит в чат команду на естественном языке: «Выкладка брендов внутри товарных категорий происходит по возрастанию рейтинга брендов от меньшего к большему по ходу движения покупательского потока».

Шаг 2. Модуль оркестрации формирует промпт, включающий спецификацию метаязыка и запрос пользователя, и отправляет его в LLM.

Шаг 3. LLM, проанализировав запрос и предоставленную ей спецификацию команд, генерирует ответ в виде строки на метаязыке: «СОРТИРОВКА БРЕНДОВ 'Рейтинг бренда (по возрастанию)'».

Шаг 4. Строка поступает на вход парсера. Парсер находит совпадение со своим регулярным выражением для команды «СОРТИРОВКА БРЕНДОВ». С помощью именованных групп извлекаются значения параметров, которые приводятся к нужным типам. На выходе формируется структурированный объект:

```
{
  "command": "СОРТИРОВКА БРЕНДОВ",
  "parameters": {
    "тип_сортировки": "Рейтинг бренда (по возрастанию)"
  }
}
```

Шаг 5. Структурированный объект передается в обработчик правил, который обновляет глобальное правило сортировки. Теперь при любой последующей генерации планаграммы модуль генерации выкладки будет применять этот принцип: внутри каждой категории товары будут сгруппированы по брендам, а сами бренды будут расположены в порядке возрастания их рейтинга. Отображенный результат позволит пользователю увидеть, что бренды с низким рейтингом находятся в начале блока, а с высоким – в конце.

Для оценки преимуществ предложенного гибридного подхода было проведено сравнение с базовым методом, представляющим собой детерминированный парсер на основе набора регулярных выражений, разработанных для извлечения параметров непосредственно из текста запроса, минуя *LLM*. В отличие от *LLM*-подхода данный метод не способен обрабатывать синонимы или неявные указания, если они не были заранее жестко запрограммированы.

Результаты эксперимента. Для оценки эффективности предложенной системы и, в частности, ключевого ее компонента – способности *LLM* к качественной формализации естественно-языковых запросов – был проведен вычислительный эксперимент. Целью эксперимента являлась количественная и качественная оценка точности преобразования неструктурированных пользовательских команд в строго типизированные инструкции на метаязыке. Для этого был сформирован валидационный набор данных, состоящий из 200 уникальных пар «запрос – эталон», отражающих широкий спектр возможных пользовательских сценариев. Набор данных, использованный в настоящем исследовании, доступен по запросу у авторов. Следует отметить, что данный датасет, созданный для доказательства концепции (*Proof-of-Concept*), является относительно небольшим, что обусловлено высокой трудоемкостью ручной разметки. Набор был спроектирован таким образом, чтобы можно было проверить систему на устойчивость к различным лингвистическим конструкциям: от прямых и однозначных команд («Установи промежуток между товарами в 1 см») до более разговорных форм с использованием сленга и синонимов («На полке 1: омывайка (40 %/до 4 кг), антифриз (60 %/от 1 кг)»), а также запросов, требующих логического вывода («На полке 11 разместить три категории поровну...»). Кроме того, в датасет были включены заведомо нерелевантные и бессмысленные фразы («Какая сегодня погода?», «абракадабра»), чтобы оценить способность системы отфильтровывать нецелевой ввод.

В качестве оцениваемых *LLM* были выбраны три ведущие модели: *GPT-4* от *OpenAI*, *Gemini 2.5 Pro* от *Google* и *Qwen3* от *Alibaba*. Для количественной оценки качества трансляции была выбрана метрика *BLEU* (*Bilingual Evaluation Understudy*), традиционно применяемая для оценки качества машинного перевода. Использование *BLEU* в данном контексте оправдано, поскольку задача, по сути, является переводом с гибкого естественного языка на формальный язык команд. Метрика *BLEU* оценивает степень совпадения *n*-граммов (последовательностей слов) между сгенерированной моделью строкой и эталонной строкой, что позволяет получить объективную численную меру их близости. При этом авторы осознают, что *BLEU* не всегда отражает семантическую корректность. Результаты эксперимента по расчету среднего значения *BLEU* для каждой модели на всем тестовом наборе данных представлены в таблице. Для сравнения также приведена точность (*Accuracy*) – доля полностью корректно распознанных парсером команд.

Результаты оценки качества формализации запросов

Results of the evaluation of the quality requests formalization

Модель <i>Model</i>	Значение BLEU <i>BLEU Value</i>	Точность, % <i>Accuracy, %</i>	Время выполнения запроса, с <i>Time to complete the request, s</i>
<i>GPT-4</i>	0,8227	98,5	~ 2
<i>Gemini 2.5 Pro</i>	0,7315	100,0	
<i>Qwen3</i>	0,7051	100,0	
Базовый метод (запросы пользователя)	N/A	0,5	< 0,1
Базовый метод (эталон)	N/A	100,0	

Полученные значения *BLEU*, превышающие 0,7 для всех моделей, свидетельствуют о высоком общем качестве формализации. Это означает, что в большинстве случаев сгенерированные командами строки были очень близки или полностью идентичны эталонным. Модель *GPT-4* показала несколько лучший результат, что может быть связано с особенностями ее архитектуры и наборами данных для обучения. Однако близость результатов говорит о том, что предложенный подход является робастным и зависит не от конкретной реализации *LLM*, а, скорее всего, от самой концепции семантического транслятора.

Высокие показатели точности распознавания транслированных команд подтверждают, что модели не просто генерируют синтаксически похожий текст, но и корректно извлекают семантику запроса. Для более объективной оценки в таблицу также добавлены результаты для базового метода, точность которого для необработанных пользовательских запросов составила всего 0,5 %. Это подчеркивает неспособность жестких правил справляться с лингвистической вариативностью, синонимами и сленгом в отличие от предлагаемого *LLM*-подхода.

Более глубокий анализ результатов выходит за рамки единой метрики. Качественный анализ работы моделей на тестовом датасете позволил выявить несколько ключевых закономерностей. Во-первых, все модели продемонстрировали превосходную способность к синонимии и распознаванию сленга. Например, запросы, содержащие слова «охлаждайка» или «антифриз», были корректно преобразованы в инструкцию с использованием каноничного термина «охлаждающие жидкости». Это является критически важным преимуществом использования *LLM* по сравнению с системами, основанными на жестких правилах и ключевых словах.

Во-вторых, система успешно справлялась с извлечением неявно выраженных параметров. Так, запрос «На полке 1 разместить охлаждайку и омывайку поровну» был верно интерпретирован как «ПОЛКА 1: охлаждающие жидкости (50 %), стеклоомыватели (50 %)\», а инструкция «разместить три категории поровну» привела к корректному распределению долей 33, 33 и 34 % для соблюдения суммарного ограничения в 100 %. Это демонстрирует не простое извлечение сущностей, а способность модели к базовым логическим операциям в контексте поставленной задачи [6].

В-третьих, важным результатом является способность системы к самофильтрации. Все нерелевантные запросы, такие как «Как дела?» или «Закажи мне пиццу», были правильно классифицированы и привели к генерации специальной команды НЕОПОЗНАННАЯ КОМАНДА, что предотвращает попадание «мусорных» данных в правила. Это подтверждает надежность системы в реальных условиях эксплуатации, где пользовательский ввод не всегда является идеальным.

Таким образом, проведенный анализ результатов подтверждает эффективность и адекватность предложенного метода. Связка из *LLM*, выступающей в роли семантического транслятора, и строгого парсера метаязыка позволяет достичь высокой точности формализации правил выкладки, сохраняя при этом гибкость и удобство естественно-языкового интерфейса для пользователя. Это доказывает жизнеспособность архитектуры и открывает путь к созданию интуитивно понятных и мощных инструментов для автоматизации мерчандайзинга.

Анализ ошибок и ограничения. Несмотря на высокие общие показатели, качественный анализ выявил ряд систематических недостатков, определяющих текущие границы применимости предложенного подхода. Наиболее часто ошибки проявлялись при обработке сложных инструкций, содержащих несколько логически связанных или взаимоисключающих условий. В таких случаях модель успешно идентифицировала основное намерение, но не справлялась с декомпозицией и обработкой всех второстепенных ограничений. Так, например, запрос «На полке 2 остаток заполни 'тормозными жидкостями', а сортировку брендов установи по рейтингу.» либо транслировался частично: система генерировала команду на размещение категории «Тормозные жидкости», но полностью игнорировала инструкцию по сортировке, либо генерировалась команда «НЕОПОЗНАННАЯ КОМАНДА». Это демонстрирует ограничение в способности *LLM* к композиционному анализу – разложению сложной задачи на последовательность более простых.

Другая существенная трудность возникала, когда запрос содержал субъективные или неоднозначные понятия, не имеющие прямого эквивалента в формализованном метаязыке. Пытаясь интерпретировать такие команды, модель могла делать недопустимые предположения, приводящие

к семантическим ошибкам или «галлюцинациям». Например, на просьбу «На полке 1 разместить охлаждающие жидкости рядом со стеклоомывателями.» система могла сгенерировать команду на размещение категорий последовательно, делая произвольный выбор их порядкового расположения. Такое поведение недопустимо в системах, требующих высокой точности и детерминизма.

Основной причиной указанных недостатков является опора исключительно на метод «обучения на нескольких примерах» (*few-shot learning*), который не всегда позволяет модели уловить все тонкости предметной области. Для устранения этих ошибок планируется работа в двух направлениях. В краткосрочной перспективе предполагается использование более сложных техник промпт-инжиниринга, например *chain-of-thought*, которые заставляют модель «рассуждать» перед выдачей ответа, что повышает точность при работе со сложной логикой. В долгосрочной перспективе ключевым решением является дообучение (*fine-tuning*) *open-source*-модели на расширенном датасете, включающем большое количество примеров сложных и неоднозначных запросов. Такой подход позволит адаптировать ее к специфике задачи и значительно снизить вероятность подобных ошибок.

Заключение. В ходе данного исследования была успешно разработана и апробирована система для автоматизации формирования плановграмм на основе семантического анализа текстовых данных. Ключевым результатом работы стало подтверждение эффективности предложенной гибридной архитектуры, в которой большая языковая модель выступает в роли семантического транслятора с естественного языка на формализованный метаязык. Такой подход позволил использовать сильные стороны *LLM* в понимании контекста и семантики, одновременно нивелировав риски недетерминированности за счет последующей обработки строго детерминированным парсером. Разработанный предметно-ориентированный язык выступил в качестве надежного контракта между компонентами системы, гарантируя, что в правила поступают только валидные и однозначные инструкции. Эффективность данного подхода была количественно подтверждена в ходе вычислительного эксперимента: значения метрики *BLEU* свидетельствуют о высокой точности трансляции широкого спектра пользовательских запросов, включая разговорные формы и команды с неявными параметрами.

Практическая значимость полученных результатов заключается в создании инструмента, способного изменить подходы к управлению торговым пространством. Внедрение подобной системы позволяет значительно снизить трудоемкость и временные затраты на создание и обновление плановграмм, повысить скорость реакции ритейлера на маркетинговые изменения и минимизировать количество ошибок, обусловленных человеческим фактором. Это, в свою очередь, позволит сделать процесс плановграммирования доступным для более широкого круга сотрудников.

Следует отметить и ограничения данного исследования. Во-первых, валидация проводилась на статичном датасете и не включала тестирование на реальных производственных нагрузках с участием конечных пользователей. Во-вторых, как показал анализ ошибок, текущая реализация может испытывать трудности с интерпретацией неоднозначных или логически сложных правил.

Настоящая работа открывает широкие перспективы для дальнейшего развития. Следующим логическим шагом является переход от реактивного инструмента, выполняющего команды, к проактивной интеллектуальной системе, способной самостоятельно предлагать оптимальные решения. Этого можно достичь путем глубокой интеграции с аналитическими данными о продажах, что позволит системе генерировать плановграммы на основе *ABC*-анализа и других метрик эффективности. Дальнейшее развитие может включать создание полноценного диалогового ассистента, способного не только выполнять задачи, но и объяснять свои решения; расширение до мультимодальной системы, анализирующей визуальную информацию с фотографий реальных полок [7], и проведение полноценного тестирования с участием категорийных менеджеров для оценки эффективности и удобства системы в реальных практических условиях. Переход на дообученные (*fine-tuned*) *open-source*-модели позволит повысить точность, снизить операционные издержки и обеспечить полную конфиденциальность данных.

При внедрении подобных систем важно учитывать и этические аспекты. Существует риск, что *LLM*, обученные на огромных массивах интернет-данных, могут обладать скрытыми

предубеждениями, например, отдавая предпочтения более известным брендам при неоднозначных формулировках. Это требует дополнительного контроля и, возможно, дообучения моделей на специфических корпоративных данных для минимизации подобных рисков и обеспечения беспристрастной выкладки.

Таким образом, представленная работа закладывает фундамент для создания нового поколения интеллектуальных систем управления торговым пространством, делая процесс мерчандайзинга более гибким, быстрым и основанным на данных.

Вклад авторов. К. С. Курочка сформулировал цель и идею исследования, Ю. Д. Ёвженко разработал программное обеспечение и провел его тестирование, оформил текст рукописи. Оба автора участвовали в написании и редактировании текста рукописи.

Список использованных источников

1. Швецова, А. М. Разработка планогаммы как эффективный инструмент маркетинга / А. М. Швецова, С. Н. Хрипунов // Молодые ученые – развитию Национальной технологической инициативы (ПОИСК-2018) : материалы межвузовской (с международным участием) молодежной науч.-техн. конф., 24–27 апр. 2018 г. – Иваново : ИВГПУ, 2018. – С. 129–130.
2. Shelf space reallocation for out of stock reduction / E. Frontoni, F. Marinelli, R. Rosetti, P. Zingaretti // Computers & Industrial Engineering. – 2017. – Vol. 106. – P. 32–40. – DOI: 10.1016/j.cie.2017.01.006.
3. Курочка, К. С. Применение генеративно-ассоциативных нейросетевых моделей для создания планогамм / К. С. Курочка, Ю. С. Башаримов // Актуальные вопросы экономической науки в XXI веке : материалы Междунар. науч.-практ. конф. – Х чтения, посвященные памяти известного белорусского и российского ученого-экономиста Михаила Вениаминовича Научителя, Гомель, 24 окт. 2024 г. / М-во образования Республики Беларусь, Гомельский гос. ун-т им. Ф. Скорины ; редкол.: А. К. Костенко [и др.]. – Гомель, 2024. – С. 139–141.
4. Jurafsky, D. Speech and Language Processing / D. Jurafsky, J. H. Martin. – 3rd ed. draft. – Stanford University, 2023. – 613 p.
5. Artificial intelligence in supply chain management: A systematic literature review / R. Toorajipour, V. Sohrabpour, A. Nazarpour [et al.] // Journal of Business Research. – 2021. – Vol. 122. – P. 502–517. – DOI: 10.1016/j.jbusres.2020.09.016.
6. Language models are few-shot learners / T. B. Brown, B. Mann, N. Ryder [et al.] // Advances in Neural Information Processing Systems (NeurIPS). – 2020. – Vol. 33. – P. 1877–1901.
7. Масалитина, Н. Н. Математическая модель принятия решений при лечении остеохондроза поясничного отдела позвоночника / Н. Н. Масалитина, К. С. Курочка, Е. Л. Цитко // Информатика. – 2019. – Т. 16, № 1. – С. 24–35.

References

1. Shvetsova A. M., Khripunov S. N. *Development of a planogram as an effective marketing tool*. Molodye uchenye – razvitiyu Natsional'noi tekhnologicheskoi initsiativy (POISK-2018): materialy mezhvuzovskoj (s mezhdunarodnym uchastiem) molodezhnoj nauchno-tehnicheskoy konferencii, 24–27 aprel'ja 2018 g. [Young Scientists for the Development of the National Technology Initiative (POISK-2018): Proceedings of the Inter-university (with International Participation) Youth Scientific and Technical Conference, 24–27 April 2018]. Ivanovo, Ivanovskij gosudarstvennyj politehnicheskij universitet, 2018, pp. 129–130 (In Russ.).
2. Frontoni E., Marinelli F., Rosetti R., Zingaretti P. Shelf space reallocation for out of stock reduction. *Computers & Industrial Engineering*, 2017, vol. 106, pp. 32–40. DOI: 10.1016/j.cie.2017.02.004.
3. Kurochka K. S., Basharimov Yu. S. *Application of generative-associative neural network models for creating planograms*. Aktual'nye voprosy ekonomicheskoi nauki v XXI veke : materialy Mezhdunarodnoj nauchno-prakticheskoy konferencii – X chteniia, posviashchennye pamiati izvestnogo belorusskogo i rossiiskogo uchenogo-ekonomista Mikhaila Veniaminovicha Nauchitelja, Gomel', 24 oktjabrja 2024 g. [Topical Issues of Economic Science in the XXI Century: Proceedings of the International Scientific and Practical Conference – X Readings Dedicated to the Memory of the Famous Belarusian and Russian Economist Mikhail Veniaminovich Nauchitel, Gomel, 24 October 2024]. Gomel, 2024, pp. 139–141 (In Russ.).
4. Jurafsky D., Martin J. H. *Speech and Language Processing*, 3rd ed. draft. Stanford University, 2023, 613 p.

5. Toorajipour R., Sohrabpour V., Nazarpour A., Oghazi P., Fischl M. Artificial intelligence in supply chain management: A systematic literature review. *Journal of Business Research*, 2021, vol. 122, pp. 502–517. DOI: 10.1016/j.jbusres.2020.09.009.

6. Brown T. B., Mann B., Ryder N., Subbiah M., Kaplan J. D., Amodei D. Language models are few-shot learners. *Advances in Neural Information Processing Systems (NeurIPS)*, 2020, vol. 33, pp. 1877–1901.

7. Masalitina N. N., Kurocha K. S., Tsitko E. L. *Mathematical model of decision making in the treatment of osteochondrosis of the lumbar spine*. *Informatika [Informatics]*, 2019, vol. 16, no. 1, pp. 24–35 (In Russ.).

Информация об авторах

Курочка Константин Сергеевич, кандидат технических наук, доцент, Гомельский государственный технический университет им. П. О. Сухого.

Ёвженко Юрий Дмитриевич, магистрант, Гомельский государственный технический университет им. П. О. Сухого.

E-mail: yuevzhenko@gmail.com

Information about the authors

Konstantin S. Kurochka, Ph. D. (Eng.), Assoc. Prof., Gomel State Technical University named after P. O. Sukhoi.

Yury D. Youzhanka, Master's Student, Gomel State Technical University named after P. O. Sukhoi.

E-mail: yuevzhenko@gmail.com