

DOI: 10.17323/2587-814X.2025.2.25.40

Разработка рекомендательных систем для повышения эффективности регулируемых закупок в электроэнергетике

А.И. Денисова^a 

E-mail: a.i.denisova@inbox.ru

Д.А. Созаева^{a,b} 

E-mail: dasozaeva@gmail.com

К.В. Гончар^{a,c} 

E-mail: goncharkv@gmail.com

^a Государственный университет управления, Москва, Россия

^b Университет «Синергия», Москва, Россия

^c МГТУ им. Н.Э. Баумана, Москва, Россия

Аннотация

В статье рассмотрены пути повышения эффективности функционирования рынка регулируемых закупок за счет внедрения рекомендательных систем в существующую ИТ-инфраструктуру закупок. На примере государственных, муниципальных и коммерческих закупок электроэнергетических товаров рассмотрены перспективные для внедрения классы рекомендательных систем, предложена методология разработки подобных сервисов, раскрыты алгоритмы обработки, конфигурации и интерпретации данных, необходимых для их функционирования. Обосновано отличие авторского подхода к созданию сервисов от ранее опубликованных работ, проведена апробация и А/В тестирование, представлена оценка эффективности. Получены результаты, имеющие научную новизну (обоснована методология использования нейронных сетей применительно к отрасли закупок) и практическую значимость (достигнута экономия времени заказчика на поиск поставщиков до 40%, расширен пул потенциальных поставщиков, диверсифицированы риски поставщиков за счет подбора релевантных для них процедур из новых сфер и от новых заказчиков, обеспечена возмож-

ность поставщикам находить до 2–3 новых заказчиков за 1 рекомендательную рассылку с периодичностью 1–2 раза в неделю). Предложено внедрение разработок в практику оператора электронных торгов по госзакупкам. Дальнейшее развитие рекомендательных сервисов и решений для сферы закупок авторы видят в улучшении анализа семантического (текстового, логического, визуального) содержания документов закупки, а также поведенческих стратегий поставщиков. Риски и ограничения же связывают с дороговизной содержания штата разработчиков-практиков по нейронным сетям, возможными галлюцинациями нейронных сетей и их высокой чувствительностью к ошибке и качеству исходных данных-сетей.

Ключевые слова: рекомендательные системы, эффективность регулируемых закупок, вероятность победы в госзакупках, персонализированные рекомендации, «незакрытие» торгов, конкуренция в закупках

Цитирование: Денисова А.И., Созаева Д.А., Гончар К.В. Разработка рекомендательных систем для повышения эффективности регулируемых закупок в электроэнергетике // Бизнес-информатика. 2025. Т. 19. № 2. С. 25–40. DOI: 10.17323/2587-814X.2025.2.25.40

Введение

Совершенствование ИТ-решений и развитие цифровой экосистемы для проведения государственных и муниципальных закупок, закупок компаний с государственным участием (далее – госзакупки, регулируемые закупки) являются приоритетными задачами государственной программы РФ «Управление государственными финансами и регулирование финансовых рынков» на период до 2030 года [1]. На первых этапах реализации программы за счет цифровизации закупок решались задачи организации электронного взаимодействия заказчиков и поставщиков, обеспечивалось ускорение закупочных процедур, снижались барьеры для выхода предпринимателей на рынок госзаказа, повышались конкуренция и степень публичности торгов, снижалась коррупционная составляющая. В последние несколько лет развитие информационных технологий в сфере управления регулируемыми закупками сталкивается с новыми вызовами, что отражается в приоритетах развития отрасли в период с 2025 по 2030 годы. По мнению авторов данного исследования, это связано с тенденциями, которые намечаются в целом в электронной коммерции. Так, в настоящее время показатели быстродействия и отказоустойчивости, возможность размещать и обрабаты-

вать значительные объемы данных, соблюдение их конфиденциальности уже не являются конкурентными преимуществами информационных систем: это обязательный набор, гарантирующий выживание на рынке. Сильными сторонами современных ИТ-решений становятся встроенные алгоритмы и сервисы, которые позволяют прогнозировать последствия принимаемых управленческих решений, при этом не требуют от пользователя специальных навыков программирования. Внедрение подобных разработок позволяет снизить риски и негативные последствия принимаемых решений для финансово-хозяйственной деятельности организации, минимизировать транзакционные издержки по операционным задачам, обеспечить устойчивое функционирование предприятия и достижение поставленных перед ним задач. Если говорить о сфере регулируемых закупок, то актуальными вызовами для нее последние три года являются проблемы эффективного «закрытия» торгов (успешного проведения процедуры с определением победителя и заключением с ним контракта), высокие риски расторжения контрактов, а также поддержание оптимального уровня конкуренции в закупках. «Незакрытие» процедур закупок, неявка поставщиков на торги часто связаны с невыгодными ценовыми и качественными

условиями контрактов, установленными заказчиками [2]. Риски расторжения, казалось бы, успешно заключенных контрактов, обусловлены не только форс-мажором на стороне поставщика при исполнении обязательств, как часто принято считать, но и переоценкой предпринимателями своих производственных возможностей и ресурсных ограничений при первоначальном планировании участия в конкретной закупке. Рассмотрим эту проблему на примере государственных и муниципальных закупок, где статистика наиболее точная. Согласно данным мониторинга Минфина России, в 2023 году было расторгнуто 323131 контрактов на общую сумму 708,5 млрд руб., что составляет 9,2% от общего количества и 5,9% от общей стоимости заключенных контрактов в 2023 году; в 2022 году количество расторгнутых контрактов составило 295072 шт., в процентах от количества и стоимости заключенных в 2022 году контрактов это также составило 9,2% и 5,9% соответственно [3]. По данным отчетов за 1 и 2 кварталы 2024 года, статистика расторжений незначительно улучшилась по количеству контрактов (стало меньше) и ухудшилась по стоимостным показателям (общая стоимость расторгнутых контрактов выросла [4]). Таким образом, значимых изменений по статистике расторжений выявлено не было. Что касается «конкуренции на торгах», то данный показатель в регулируемых закупках формально отвечает на вопросы о присутствии достаточного числа участников на товарных и отраслевых рынках, а также о наличии перекосов в сторону закупок у единственного поставщика (подрядчика, исполнителя), картельных сговоров и других антиконкурентных соглашений. Для более точной иллюстрации снова обратимся к статистике государственного и муниципального заказа. С 2022 года данный показатель также колеблется в пределах 2–3 заявки на одну процедуру против 4,2 – за период до пандемии, вызванной коронавирусом COVID-19 [5]. Минфин отмечает рост числа закупок у единственного поставщика и бьет тревогу из-за негативных тенденций в части конкуренции.

Анализируя все вышеперечисленное, довольно затруднительно определить, какая же проблема имеет более высокий приоритет. Низкая конкуренция из-за пассивности поставщиков, незнания ими условий и возможностей рынка, опасений не справиться, которая приводит к заключению контрактов с совсем слабыми игроками, единственным поставщиком, или высокие требования заказчиков, приводящие к отказу поставщиков в принципе вы-

ходить на рынок регулируемых закупок, и последующее «незакрытие» торгов? В такой ситуации кажется, что есть дисбаланс между целями, которые преследуют заказчики и поставщики на рынке госзаказа и информацией, которой они располагают. Это подтверждается масштабным исследованием коллектива НИУ ВШЭ, который отмечает «несоответствие между критериями эффективности закупок, которыми в своей текущей деятельности руководствуются заказчики и поставщики, и теми целями, на которых в настоящее время сфокусирована система регулирования закупок» [6]. Заказчики стремятся продемонстрировать любой ценой высокую конкуренцию на их закупках, достигнутую экономию, минимальное количество расторжений контрактов, тогда как поставщики ориентированы на минимальную конкуренцию и экономию, но солидарны с заказчиками в вопросах расторжения контрактов: хотят выполнить их без негативных для себя последствий. Значимость сферы регулируемых закупок для экономики страны обуславливает потребность в поддержании баланса интересов участников этого рынка, согласованности их действий, главным образом, по мнению авторов, за счет повышения их информированности. Решение задачи информированности сторон закупочного процесса о характере, состоянии рынка, перспективах и целесообразности проведения процедур закупок или участия в них в конкретное время, в конкретном регионе и при иных определенных условиях должно быть релевантным современному уровню развития технологий. Одним из возможных решений данной проблемы в условиях активной цифровизации может быть внедрение *рекомендательных предиктивных систем*, которые будут стимулировать поставщиков к участию в тендерах, позволят подбирать соответствующие их масштабам, опыту, ресурсообеспеченности закупочные процедуры для успешного участия. Для заказчиков развитие на рынке подобных предиктивных сервисов имеет множество плюсов: на их процедуры будут заявляться те контрагенты, которые имеют потенциал для исполнения контрактов, будет обеспечен не номинальный, а реальный уровень конкуренции среди достойных игроков рынка, а, значит, риски недобросовестного исполнения или расторжения существенно снизятся.

Таким образом, цель данного исследования – обосновать применение конкретного класса рекомендательных (предиктивных) систем для повышения эффективности участия предпринимателей

в регулируемых закупках и продемонстрировать работу сервиса на примере отдельной отрасли/сферы. Чтобы обосновать новизну такого подхода, обратимся к некоторым теоретическим аспектам вопроса.

1. Методология разработки и внедрения рекомендательных сервисов для сферы регулируемых закупок

Рекомендательная система (recommender system (RecSys)) – это алгоритм, подбирающий и предлагающий пользователю релевантный контент на основе имеющейся информации о контенте, о пользователе, его поведении, а также о поведении других пользователей и о действиях пользователей по отношению к контенту [7].

Рекомендательные системы играют всё более важную роль в современном мире информации и коммерции. С постоянным увеличением объема данных и контента, доступного для пользователей, становится всё сложнее сориентироваться и найти персонализированную информацию. Рекомендательные системы способны решить вышеперечисленные проблемы: благодаря анализу предпочтений пользователей и контекста, они способны предоставить персонализированные рекомендации, соответствующие интересам и потребностям пользователей.

Возникает вопрос, а чем же тогда отличаются системы поддержки принятия решений, уже известные науке и практике, от рекомендательных систем? Основы систем поддержки принятия решений (моделирование предпочтений, принятие решений в условиях неопределенности) [8–10], нашли частичное применение в современных алгоритмах рекомендательных систем, но при этом некоторые важные аспекты (например, психологические и когнитивные), как правило, остаются за рамками. Дело в том (и это важно подчеркнуть), что системы поддержки принятия решений и рекомендательные системы создаются с разными целями. Рекомендательная система ориентирована на предсказание того, какой контент может быть интересен пользователю, основываясь на его прошлом поведении, предпочтениях и действиях других пользователей, добиваясь персонализации предложений за счет использования различных алгоритмов обработки данных и выявления скрытых закономерностей, зачастую с отсутстви-

ем обоснования конкретного выбора. Классическая система поддержки принятия решений же, в свою очередь, создана для того, чтобы помочь пользователю принять осознанное и обоснованное решение в условиях неопределенности. При этом дается обоснование того, почему та или иная альтернатива лучше прочих.

В последние годы наблюдается взрывной рост интереса разработчиков и пользователей именно к рекомендательным системам в различных областях, включая электронную коммерцию, социальные сети, музыку, фильмы, новости и многое другое. Отчасти это можно связать и с тем, как изменилась теория выбора: долгие годы экономисты говорили о «рациональном выборе», когда поведение потребителя было измеримым. Мерами эффективности принимаемых решений выступали, нередко, бюджетные ограничения. Развитие «иррациональной теории выбора» и работы Р. Талера [11], да и в целом интерес к поведенческой экономике привело к популяризации эмоциональной, социальной, личностной составляющих при принятии решений, совершении покупок, продаж и т.д. Стало очевидно: именно благодаря рекомендациям пользователи получают персонализированный контент, который соответствует их индивидуальным интересам, что существенно повышает удобство использования большинства ИТ-сервисов.

Что касается такой специфичной области, как регулируемые закупки, то в идеале система формирования рекомендаций должна работать следующим образом: поставщику с определенной регулярностью предлагается перечень наиболее релевантных для них процедур, в которых, как ожидается, он примет участие. При этом рекомендация может поступать через разные каналы коммуникации: уведомления в личном кабинете пользователя, email-рассылку, уведомления через мессенджеры и т.д.

В информационном поле известны несколько попыток разработки и внедрения рекомендательных систем в сфере закупок как на российском, так и на зарубежном рынке [12–14], однако они имеют ряд ограничений.

Предлагаемые в работах по развитию рекомендательных сервисов основные подходы можно разделить на пять групп [15–17], и рассмотреть через призму закупок.

1. Контентная фильтрация (content-based filtering) – алгоритм анализирует характеристики элементов, с которыми уже «работал» пользователь, и предлагает ему похожие. В контексте системы закупок это может означать, например, то, что поставщику будут предлагаться те процедуры, заказчик которых находится в одном из тех регионов, где поставщик уже работал.

2. Коллаборативная фильтрация (collaborative filtering) – алгоритм анализирует историю действий пользователей и ищет среди них группы со схожими предпочтениями, чтобы предлагать новым пользователям именно то, что понравилось другим: эта система основывается на истории взаимодействия пользователей с элементами. В контексте системы закупок это может означать, что будут сформированы пулы похожих поставщиков, например, по принципу работы в одном регионе и в рамках одной сферы. Тогда, если поставщик *A* принял участие в какой-то процедуре, то поставщику *B* из этого же пула можно рекомендовать поучаствовать в этой же процедуре.

3. Рекомендации на основе популярности (popularity-based) – алгоритм рекомендует элементы, которые пользуются наибольшей популярностью среди пользователей. Этот подход можно усложнить – поделить пользователей на кластеры и определять наиболее популярные элементы по ним. Наиболее целесообразно использовать эту технологию в ситуации, когда нет достаточного количества данных о конкретном пользователе. В контексте системы закупок, мы можем рекомендовать, например, такие процедуры, которые относятся к наиболее популярным сферам по классификатору ОКПД¹.

4. Рекомендации на основе знаний о предметной области (knowledge-based) – алгоритм предлагает пользователю элементы, по тому или иному принципу связанные с теми, которыми он уже интересовался. Поскольку в данном исследовании авторы отталкиваются, прежде всего, от потребностей поставщика, данный подход является слабо применимым. Тем не менее, для заказчика его реализация могла бы выглядеть следующим образом: заказчик *A* провел закупку лазерных принтеров, и после этого система предлагает ему провести еще закупку бумаги А4 и подбирает список подходящих для этого поставщиков.

5. Гибридные системы (hybrid systems) предлагают комбинацию нескольких перечисленных подходов между собой (в основном это контентная и коллаборативная фильтрации) для предоставления наиболее персонализированных рекомендаций.

Авторы статьи видят цели рекомендательной системы в сфере закупок прежде всего в расширении аудитории участников закупок, повышении их активности на торгах и в обеспечении за счет этого роста конкуренции и снижения количества несостоявшихся закупок. Проблеме несостоявшихся процедур на торгах авторы уже посвятили ряд своих работ [18, 19] и считают её одной из ключевых в контексте эффективности закупочной деятельности. В связи с этим использовать подход (3) – рекомендации на основе популярности – нецелесообразно, поскольку таким образом поставщикам будут рекомендованы процедуры с уже высоким уровнем конкуренции. Кроме того, процесс закупок очень четко связан со временем – возможность подавать заявки и участвовать в торгах длится в среднем 1–2 недели. Рекомендации также должны формироваться с соответствующей периодичностью. Соответственно, если для генерации рекомендаций отталкиваться от уже свершившегося факта участия других поставщиков, то велика вероятность, что новый поставщик на эту процедуру просто не успеет, так как процедура уже станет неактуальной. В связи с этим можно заключить, что в данном случае наиболее подходящим методом для формирования рекомендательной системы в сфере закупок является *контентная фильтрация*. Опираясь на этот тезис, необходимо обосновать новизну подхода: до настоящего времени масштабно рекомендательные системы в сфере государственных закупок не использовались, оставаясь исключительно прерогативой электронной коммерции и B2B сервисов.

2. Принципы подбора исходных данных для формирования рекомендаций

Взрывной рост интереса к рекомендательным сервисам обусловлен тем, что практически все процедуры по госзакупкам сегодня проводятся в электронной форме. Обеспечивают проведение

¹ Общероссийский классификатор продукции по видам экономической деятельности

электронных торгов электронные торговые площадки (ЭТП). Для развития своего тезиса авторами среди всех площадок были отобраны «федеральные операторы торгов», которые имеют право проводить закупки госзаказчиков по 44-ФЗ: Сбербанк АСТ, РТС-Тендер, Национальная электронная площадка (Фабрикант), ЭТП ГПБ (Газпромбанк), АГЗ РТ, АО «ЕЭТП» (Росэлторг), Российский аукционный дом (ЭТП РАД), ТЭК-Торг [20]. К этой группе можно отнести еще одну площадку – ЭТП АСТ ГОЗ, на ней проводятся торги государственного оборонного заказа.

Информационную базу исследования составляют данные об активности поставщиков на площадке АО ЕЭТП (Росэлторг) с 2020 года (историческая выборка) с учетом открытых данных, размещенных в ЕИС². Обучение модели строилось на данных об участиях с 2020 года, разделенных на двухнедельные интервалы (в соответствии со средней продолжительностью сбора заявок на торги). Тестирование модели проводилось за период октябрь–декабрь 2023 года. Были рассмотрены только электронные закупки, то есть те, извещения о проведении которых были опубликованы. При этом для тестирования и отработки была выбрана конкретная отрасль: энергетическая сфера. Таким образом, хотя бы один товар, который закупал заказчик в тестируемой процедуре, входил в группу ОКПД2 27 «Оборудование электрическое». Выбор товаров для электроэнергетики был обусловлен их высокой значимостью для жизнеобеспечения заказчиков. Также были составлены «профили» поставщиков на основе их предпочтений по историческим данным. Интерес для авторов представляли следующие аспекты: характеристики поставщика, в том числе, в каких сферах деятельности он занят (согласно классификатору ОКПД2), где (в каких регионах и на каких площадках), по какой нормативной базе (в соответствии с какими федеральными законами проводятся закупки) и с кем поставщик взаимодействует.

В качестве заказчиков рассматривались несколько типов организаций:

- ♦ органы власти, учреждения бюджетной сети, расходующие бюджетные средства в соответствии с федеральным законом № 44-ФЗ от 05.04.2013 «О

контрактной системе в сфере закупок товаров, работ, услуг для обеспечения государственных и муниципальных нужд»;

- ♦ компании с государственным и муниципальным участием (такие как ПАО «Газпром», ПАО «Сбербанк», ПАО «ВТБ» и т.д.), а также государственные и муниципальные унитарные предприятия, действующие на основе федерального закона № 223-ФЗ от 18.07.2011 «О закупках отдельных видов юридических лиц»;
- ♦ коммерческие заказчики, проведение закупок которых определяется только Гражданским кодексом РФ и правилами, установленными заказчиками.

Если необходимость сбора и обработки формальных характеристик для профиля поставщика (регион, основная сфера деятельности и прочие) была очевидна в контексте формирования рекомендаций, то вопрос с оценкой взаимодействия в парах «конкретный заказчик – конкретный поставщик» недостаточно изучен. Это связано с тем, что информация об участии компаний в тендерах с 2022 года не предназначена для публикации в открытых источниках, что существенно усложняет выявление предпочтений и моделей поведения в парах заказчик-поставщик. Между тем, опираясь на свой экспертный опыт в отрасли закупок, авторы исследования предположили, что неэкономические отношения между заказчиками и поставщиками (дружеские, родственные, национальные, религиозные, политические и другие) также могут влиять на предпочтения поставщиков.

Для проверки такого аспекта, авторы попробовали удостовериться в том, что связь между заказчиками и поставщиками действительно имеет место: в *таблице 1* представлена оценка частоты взаимодействия конкретных заказчиков с конкретными поставщиками в 2022 и 2023 годах. Даже без учета более узкоспециализированных сфер деятельности (детальных кодов ОКПД2), доля устойчивых взаимодействий значительная, особенно на фоне сокращения количества заказчиков (согласно данным из открытых источников (ЕИС в сфере закупок) на примере площадки Росэлторг), в 2023 году по сравнению с 2020 их количество сократилось на 35%).

² Единая информационная система в сфере закупок, <https://zakupki.gov.ru/epz/main/public/home.html>

Таблица 1.

Оценка взаимодействия поставщиков и заказчиков в рамках группы ОКПД2 27

Показатель	2022	2023
Доля постоянных пар «заказчик-поставщик», которые уже выявлялись ранее (начиная с 2020 года) на площадке Росэлторг, среди всех сформированных пар за год, %	19,9	21,1
Отношение количества постоянных пар «заказчик-поставщик», которые уже выявлялись ранее (начиная с 2020 года) на примере площадки Росэлторг, к количеству уникальных заказчиков, проявивших активность в течение соответствующего года, %	0,89	0,96
Средний уровень конкуренции на торгах (среднее количество заявок на одну процедуру (лот)), %	2,05	2,01

С учетом вышеперечисленного, алгоритм формирования рекомендаций был составлен из следующих шагов:

1. Формирование базового профиля каждого поставщика³ – статистическая оценка его предпочтений.
2. Сбор информации о всех релевантных опубликованных процедурах за последние две недели.
3. Предварительная фильтрация процедур по ценовым категориям. Сегодня в работе крупных федеральных операторов торгов по госзакупкам устоялась практика сегментации торгов в зависимости от начальной (максимальной) цены контракта [3]. В зависимости от ценового сегмента, в котором проводится закупка, и в котором работает поставщик, закупочная процедура рекомендуется или не рекомендуется предпринимателю-потенциальному участнику торгов. Обычно выделяют 12 сегментов: «до 100 тыс. рублей», «от 100 до 500 тыс. рублей» и т.д. до сегмента «от 100 млн рублей», а также отдельный случай, когда цена не определена. Эмпирически было установлено, что поставщику нецелесообразно рекомендовать процедуры, цена которых не попадает в его ценовую категорию или ближайшие соседние. Соблюдение данного правила важно, так как у участника закупки попросту может не быть нужных ресурсов для участия в тендере, а, при выигрыше – для исполнения контракта.
4. Расчет значений признаков, на основе которых формируются рекомендации, по формуле (1):

$$x_i = \frac{\bar{x}_i \cdot n}{N}, \quad (1)$$

где \bar{x}_i – средняя доля данного признака в истории поставщика;

n – количество уникальных совпадений признака с историей поставщика;

N – общее количество уникальных значений признака в процедуре.

5. Расчет взвешенной суммы всех признаков процедуры. Вес определяет важность каждого признака в итоговой оценке, их определение – отдельная задача, непосредственно влияющая на качество предсказания.

6. Ранжирование процедур по взвешенным суммам значений признаков. Чем выше значение – тем больше эта процедура подходит для конкретного поставщика. Поставщику рекомендуются 10 процедур с максимальным значением взвешенной суммы всех признаков процедуры.

Далее алгоритм был реализован на языке Python преимущественно с использованием библиотек numpy, и, отчасти, sklearn, catboost, pytorch.

3. Разработка и тестирование прототипа рекомендательной системы

Приведем итоговый список факторов, на основе которых оказалось целесообразным ранжирование рекомендации для конкретного поставщика:

³ В контексте поставленной задачи здесь анализируются только те поставщики, кто хотя бы раз участвовал в процедурах на закупку товаров по ОКПД2 27.

- ◆ наличие условия о том, что закупка предназначена для субъектов малого и среднего предпринимательства;
- ◆ заказчик;
- ◆ факт хотя бы одной победы поставщика у данного заказчика;
- ◆ регион заказчика;
- ◆ факт хотя бы одной победы поставщика в регионе заказчика;
- ◆ нормативная база (44-ФЗ, 223-ФЗ, коммерческая закупка);
- ◆ факт хотя бы одной победы поставщика в рамках соответствующей нормативной базы;
- ◆ сфера деятельности (по полному коду ОКПД);
- ◆ факт хотя бы одной победы в рамках соответствующей сферы деятельности (по полному коду ОКПД);
- ◆ склейка сферы деятельности и региона заказчика (интерпретируется как участия поставщика в соответствующем регионе в тендере в конкретной сфере и, аналогично, факт хотя бы одной победы);
- ◆ склейка сферы деятельности и заказчика (интерпретируется как участия поставщика в тендере от соответствующего заказчика в конкретной сфере и, аналогично, факт хотя бы одной победы);
- ◆ склейка сферы деятельности и региона заказчика (интерпретируется как участия поставщика в соответствующем регионе в тендере в конкретной сфере и, аналогично, факт хотя бы одной победы);
- ◆ склейка сферы деятельности и площадки, на которой опубликовано извещение (интерпретируется как участия поставщика в тендере на соответствующей площадке в конкретной сфере и, аналогично, факт хотя бы одной победы).

Важно было также и оценить качество модели. Основная метрика качества модели контентной фильтрации в данном случае – *recall at K* ($r@K$), то есть чувствительность (полнота) на K элементах [9]. Авторы посчитали «позитивным прогнозом» такой исход, когда поставщик принял участие в конкретной процедуре из 10 рекомендованных ($r@10$). Ис-

пользуя в качестве целевой метрики именно чувствительность, коллектив стремился к увеличению количества реальных рекомендаций разным поставщикам. При этом эти 10 процедур были определены путем ранжирования по наибольшей вероятности участия для конкретного поставщика. С точки зрения бизнес-логики, наиболее важной в рекомендованном списке процедур оказывалась самая первая процедура – именно её пользователь вероятнее всего мог просмотреть в большинстве случаев.

Определение весов признаков имеет ключевую роль при расчете рейтинга. В данных для обучения есть сведения о факте участия поставщиков в потенциально интересных (предварительно отфильтрованных) процедурах: «1» – принял участие, «0» – обратный случай. Задача алгоритма ранжирования – упорядочить процедуры для конкретного поставщика таким образом, чтобы среди первых 10 вероятность участия была максимальной. Иными словами, оценивается, в каких процедурах из 10 первых рекомендованных поставщик действительно принял участие, и затем рассчитывается $r@10$. Для расчета рейтинга было использовано два подхода:

- ◆ моделирование вероятности участия конкретного поставщика в конкретной процедуре и ранжирование по полученным оценкам вероятности;
- ◆ ранжирование по взвешенной сумме значений x_i , причем методы определения весов могут быть разные.

В базовом варианте, при построении модели дерева решений с помощью *sklearn*, значение $r@10$ составляет $0,21^4$.

С использованием базовой модели были проведены следующие эксперименты:

- 1) расчет взвешенной суммы, метод получения весов – последовательное исключение каждого признака для выявления наиболее значимых и выставление весов в соответствии с последующим изменением ключевой метрики ($r@10 = 0,23$);
- 2) аналогично первому пункту, но исходные значения признаков были предварительно нормированы ($r@10 = 0,25$);

⁴ Здесь и далее подобные оценки были получены на обучающей выборке с перекрестной проверкой $k = 5$.

3) расчет взвешенной суммы, метод получения весов – байесовская оптимизация, целевая метрика – вероятность участия в первых десяти процедурах ($r@10 = 0,22$).

Значительного изменения метрики не наблюдалось, а наилучший исход давал вариант (2). Далее были проведены эксперименты с различными моделями классификации для улучшения метрики:

- 1) случайный лес (sklearn [21]), $r@10 = 0,306$;
- 2) градиентный бустинг на деревьях решений (catboost [22]), $r@10 = 0,331$;
- 3) полносвязная нейросеть с одним скрытым слоем, построенная на PyTorch [23], $r@10 = 0,355$.

Алгоритм случайного леса (Random Forest) – это ансамблевый метод на основе множества деревьев решений. Каждое дерево строится на случайной подвыборке обучающих данных (с повторениями), и используется случайный набор признаков на каждом узле для разделения. Градиентный бустинг на деревьях решений (Gradient Boosting Decision Trees, GBDT) – это модификация алгоритма, в которой деревья строятся одно за другим, каждое новое дерево корректирует ошибки предыдущего [24].

На *рисунке 1* представлена иллюстрация нейросети, построенной в рамках пункта (3). Для наглядности число входов было принято равным трем. Скрытый слой предназначен для выделения наиболее значимых признаков. В качестве функции активации использована ReLU (Rectified Linear Unit). Количество нейронов в скрытом слое

может быть произвольным, здесь их количество по итогам экспериментов было принято равным 10. Функция активации выходного слоя – сигмоида (логистическая функция), возвращает число в диапазоне от 0 до 1.

Нейросеть обучалась с использованием функции потерь Focal Loss. Это модификация функции перекрестной энтропии, обычно используется в задачах с сильно несбалансированными классами, снижая вес для легко классифицируемых [25]. Для каждого батча (партии данных) эта функция была рассчитана по формуле (2).

$$\text{FocalLoss} = -\frac{1}{N} \sum_{i=1}^N \alpha_i (1 - p_i)^\gamma \log(p_i), \quad (2)$$

где N – число примеров в батче;

α_i – весовой коэффициент для правильного класса;

p_i – предсказанная вероятность правильного класса;

γ – параметр фокусировки.

Относительно невысокие значения метрики объясняются специфической сферой деятельности: поскольку в деятельности электронной торговой площадки интересны, прежде всего осуществленные участия, то по среднему уровню конкуренции можно оценить, что типичный поставщик взаимодействует с «контентом» примерно 2 раза в год. Приведем сравнение с сервисом Netflix в США: известно, что в 2019 году в его каталоге было 47000 эпизодов сериалов и 4000 фильмов [26], а количество подписчиков во втором квартале было равно 60,1 млн человек

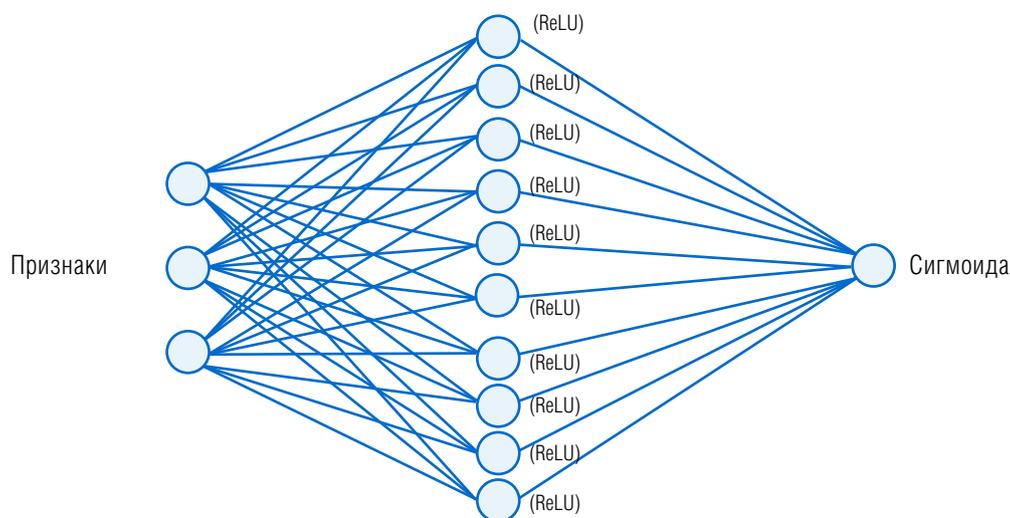


Рис. 1. Архитектура полносвязной нейронной сети для прогнозирования участия поставщиков.

[27]. В 2024 году было доступно около 7000 фильмов и телешоу [28] (точное количество серий сериала не разглашалось, но в 2024 году было добавлено более 10000 новых серий [29]) для 90 миллионов подписчиков (США и Канада) [30]. При этом неизвестно, сколько «запросов» в среднем за год делает пользователь, но можно предположить, что по крайней мере одно (в реальности это число, вероятно все-го, значительно больше). Даже при такой приближенной оценке среднее количество взаимодействий с контентом составляет 118 раз в год. Здесь необходимо подчеркнуть, что поведение пользователей на рынке закупок имеет свою особенность, которая довольно сильно отличается от стандартных сфер применения рекомендательных систем. Распределение активности среди поставщиков – неравномерное – в рамках некоторых категорий ОКПД2 количество участий в год может превышать 1000, а в иных – единицы. Вместе с тем, как факт «активности» в закупках можно рассматривать любые действия поставщика на странице процедуры (просмотры, скачивания документации к процедуре и т.п.).

Как было подтверждено в ходе экспериментов, чем больше пул закупок, потенциально подходящих поставщику, тем сложнее релевантным процедурам попасть в топ-10. В среднем поставщику действительно может подходить довольно много процедур, поэтому сложность ранжирования возрастает. И вот здесь решающим фактором оказывается как раз регулярность взаимодействия между поставщиками и заказчиками (те самые поведенческие аспекты, упомянутые в начале работе).

Тем не менее, было получено обоснование пользы от внедрения рекомендательной системы в работу площадки в рамках А/В тестирования. Для этого были выделены две группы (А и В) поставщиков, работающих на площадке по ОКПД2 27, примерно одинакового объема. Тестирование проводилось на 10 недельных интервалах в конце 2023 года, в рамках теста поставщикам рассылались письма на электронные адреса. Необходимо было, чтобы состав этих групп был однородный, поэтому они были подобраны так, чтобы в каждой была примерно одинаковая доля активных и неактивных клиентов и примерно одинаковая доля по предпочитаемым ценовым категориям закупок. Также необходимо было, чтобы средняя частота открытия писем с рассылаемыми до эксперимента «наивными» рекомендациями была бы значимо не различима (фактически разница составила не более 2%), а сами группы

были практически одинаковыми по количеству. По каждому письму считалось количество просмотров этого письма и количество переходов из письма на электронную площадку для просмотра информации о закупке. На интервалах 6–9 (рис. 2) поставщикам из группы А осуществлялась рассылка рекомендаций по описанной методологии: каждые две недели по электронной почте высылался список из 10 процедур, рекомендованных каждому для участия. В остальное время рассылка также осуществлялась, но рекомендации формировались «наивным» образом: поставщику предлагались случайные 10 закупок, которые были объявлены в его регионе, с профилями деятельности, в которых он уже работал, и в ценовых категориях, которые ему подходили.

Результаты представлены на рисунках 2 и 3.

Таким образом, можно заключить, что рекомендательные рассылки воспринимались клиентами позитивно и с интересом, стимулировали их к дополнительным действиям, способствовали их информированию. За счет этого были получены положительные эффекты для конкурентной среды на торгах.

4. Результаты и обсуждения

Предложенные разработки уже частично внедрены в работу оператора торгов АО «ЕЭТП» (Росэлторг), что обеспечило увеличение количество успешно завершенных процедур на 3,7% [31], а в целом заказчики на 40% улучшили результативность поиска поставщиков. Конечно же, это работает и в обратную сторону: если заказчики чаще находят

Разница, А - В, ед.

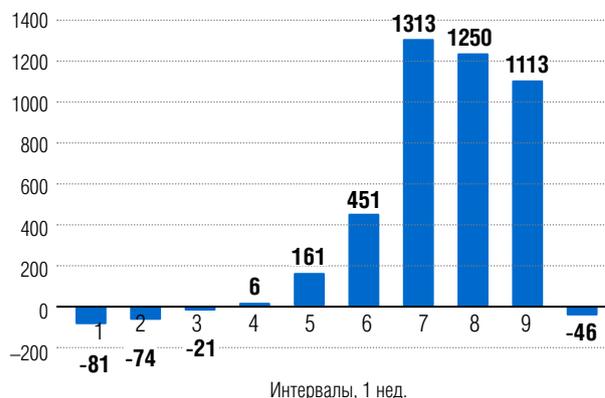


Рис. 2. Разница между количеством просмотров письма с рекомендациями по группе А с аналогичным показателем по группе В.

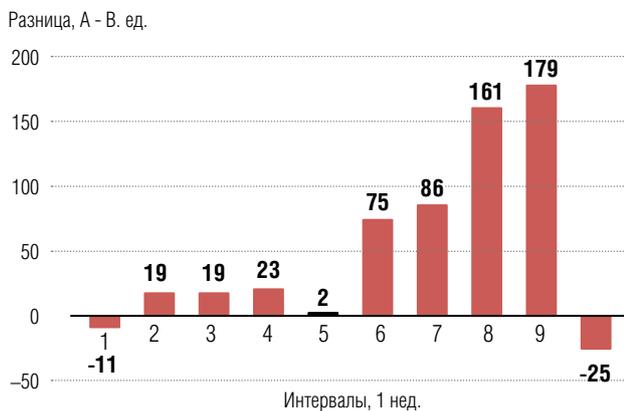


Рис. 3. Разница между количеством переходов на площадку из письма с рекомендациями по группе А с аналогичным показателем по группе В.

себе исполнителей по контрактам и договорам, то и предприниматели с большей вероятностью открывают релевантные для себя новые рынки сбыта, реже сталкиваются с проблемами расторжения контрактов. Однако, несмотря на положительный опыт и оптимистичные перспективы, авторы отмечают и риски внедрения рекомендательных сервисов. Так, при росте количества параметров, на основе которых строятся рекомендации, есть риск увеличить «зашумленность модели». То есть, не выявив приоритетную группу параметров, благодаря которым и формируется наиболее точная рекомендация, разработчики могут тратить существенные усилия времени и вычислительные мощности на сбор, обработку, хранение второстепенных характеристик. Избежать таких рисков поможет привлечение отраслевых экспертов, которые смогут скорректировать содержательную часть разработки. Вторая группа рисков связана с переобучением системы, что может происходить из-за дисбаланса в исходных данных (например, из-за популярности ряда категорий классификатора ОКПД2), чрезмерной сложности модели (тогда алгоритм будет «запоминать» отдельные предпочтения наиболее активных клиентов вместо того, чтобы выделить общие признаки).

Нельзя не отметить также риски «человеческого фактора» — ошибки при проведении А/В тестов, что усугубляется высокой чувствительностью такой системы к ошибке; дороговизну и сложность технического сопровождения и кадрового обеспечения подобного рода разработок.

Заключение

Таким образом, в результате проведенного исследования авторский коллектив выполнил следующие задачи:

- ♦ сформировал гипотезу о целесообразности использования рекомендательных систем для повышения эффективности государственных, муниципальных и корпоративных закупок (регулируемых закупок);
- ♦ исследовал типологии систем и обосновал выбор конкретного класса систем, наиболее релевантного для выработки рекомендаций для участников рынка регулируемых закупок;
- ♦ разработал прототип рекомендательной системы, для чего обосновал методологию его построения и структуру данных для его наполнения;
- ♦ провел тестирование прототипа на закупках для электроэнергетической отрасли путем рассылки рекомендаций принять участие в конкретных торгах предпринимателям, которые потенциально могли бы, в силу своего рыночного положения и победить в процедуре, и эффективно выполнить контракт.

Проведенное исследование позволило, во-первых, расширить проблематику оценки и повышения эффективности регулируемых закупок. В настоящее время эффективность в этой области определяется уровнем конкуренции (количество заявок на 1 процедуру) и полученной экономией (насколько дешевле от первоначальной заявленной цены удалось закупиться). Однако качественные показатели, такие как личные предпочтения участников закупок, факторы выбора тех или иных процедур или заказчиков оставались малоизученными. Персонализированные рекомендации позволяют лучше исследовать настроения и возможности участников рынка, повышать результативность торгов.

Во-вторых, по итогам исследования получены значимые для науки и практики результаты. В частности, разработана методология построения рекомендательных сервисов для государственных нужд, а не для решения чисто коммерческих задач. В дальнейшем такая методология может быть тиражирована и на другие области, где государство является контрагентом. Что касается практики, то планируется превращение прототипа в полноценную систему и последующее полное внедрение в работу оператора торгов.

Дальнейшие направления исследований, по мнению авторов, могут носить более прикладной характер, ориентированный на настройку рекомендательных сервисов под особенности конкретных отраслей, а также изучение возможностей других классов рекомендательных систем. ■

Благодарности

Исследование выполнено при финансовой поддержке Российского научного фонда (проект 23-28-01644).

Литература

1. Постановление Правительства РФ от 15 апреля 2014 г. №320 «Об утверждении государственной программы Российской Федерации «Управление государственными финансами и регулирование финансовых рынков» (с изменениями и дополнениями) // Система «Гарант». [Электронный ресурс]: <https://base.garant.ru/70644234> (дата обращения 07.10.2024).
2. Денисова А.И., Созаева Д.А., Гончар К.В., Александров Г.А. Анализ факторов незакрытия торгов по госзакупкам лекарственных препаратов // Проблемы прогнозирования. 2024. № 2. С. 178–191. <https://doi.org/10.47711/0868-6351-203-178-191>
3. Сводный аналитический отчет о результатах мониторинга закупок товаров, работ, услуг для обеспечения государственных и муниципальных нужд, а также закупок товаров, работ, услуг отдельными видами юридических лиц за 2023 г. // Минфин России, 2024. [Электронный ресурс]: https://minfin.gov.ru/common/upload/library/2024/05/main/Svodnyu_2023.pdf (дата обращения 07.10.2024).
4. Ежеквартальный отчет по результатам мониторинга закупок товаров, работ, услуг для обеспечения государственных и муниципальных нужд, а также закупок товаров, работ, услуг отдельными видами юридических лиц за II квартал 2024 г. // Минфин России, 2024. [Электронный ресурс]: https://minfin.gov.ru/common/upload/library/2024/07/main/II_kvartal_2024_g.pdf (дата обращения 07.10.2024).
5. Кузнецов М. Что ожидает рынок госзакупок в 2024 году // Российская газета – Экономика Центрального округа. 2024. № 4(9246). [Электронный ресурс]: <https://rg.ru/2024/01/11/reg-cfo/delo-za-malym.html> (дата обращения 07.10.2024).
6. Яковлев А.А., Балаева О.Н., Родионова Ю.Д., Ткаченко А.В. Проблемы и эффективность госзакупок глазами их участников // Всероссийский экономический журнал ЭКО. 2020. № 11. С. 83–103. <https://doi.org/10.30680/ЕСО0131-7652-2020-11-83-103>
7. Фальк К. Рекомендательные системы на практике. М.: ДМК Пресс, 2020.
8. Баранов В.В. Процессы принятия управляющих решений, мотивированных интересами. М.: Физматлит, 2005.
9. Кравченко Т.К., Исаев Д.В. Системы поддержки принятия решений: учебник и практикум для вузов. 2-е изд., перераб. и доп. изд. М.: Юрайт, 2024.
10. Кини Р., Райфа Х. Принятие решений при многих критериях: предпочтения и замещения. Пер. с англ. / Под ред. И.Ф. Шахнова. М.: Радио и связь, 1981.
11. Талер Р. Новая поведенческая экономика. Почему люди нарушают правила традиционной экономики. М.: Эксмо, 2022.
12. García Rodríguez M.J., Montequín V., Ortega-Fernández F., Balsera J. Bidders recommender for public procurement auctions using machine learning: data analysis, algorithm, and case study with tenders from Spain // Complexity. 2020. Article 8858258. <https://doi.org/10.1155/2020/8858258>
13. Hickok M. Public procurement of artificial intelligence systems: new risks and future proofing // AI & Society. 2024. Vol. 39. P. 1213–1227. <https://doi.org/10.1007/s00146-022-01572-2>
14. Разработка и исследование моделей многоклассовых классификаторов для рекомендательной системы подготовки заявок на портале единой информационной системы в сфере закупок / Я.А. Селиверстов и [др.] // Информатика, телекоммуникации и управление. 2022. Т. 15. №. 2. С. 43–62. <https://doi.org/10.18721/JCSTCS.15204>
15. Bias and debias in recommender system: A survey and future directions / Chen J. [et al.] // ACM Transactions on Information Systems. 2023. Vol. 41. No. 3. Article 67. <https://doi.org/10.1145/3564284>
16. Ko H., Lee S., Park Y., Choi A. A survey of recommendation systems: Recommendation models, techniques, and application fields // Electronics. 2022. Vol. 11. No. 1. Article 141. <https://doi.org/10.3390/electronics11010141>
17. Андриянов Н.А., Атаходжаева М.Р., Бородин Е.И. Математическое моделирование рекомендательной системы и обработка данных телекоммуникационной компании с помощью моделей машинного обучения // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». 2022. Т. 22. № 2. С. 17–28. <https://doi.org/10.14529/ctcr220202>
18. Денисова А.И., Созаева Д.А., Гончар К.В., Александров Г.А. Совершенствование методологии оценки экономической эффективности государственных закупок лекарственных средств // Финансовый журнал. 2023. Т. 15. № 4. С. 63–81. <https://doi.org/10.31107/2075-1990-2023-4-63-81>
19. Денисова А.И., Созаева Д.А., Гончар К.В., Александров Г.А. Анализ факторов незакрытия торгов по госзакупкам лекарственных препаратов // Проблемы прогнозирования. 2024. № 2. С. 178–191. <https://doi.org/10.47711/0868-6351-203-178-191>

20. Постановление Правительства РФ от 08.06.2018 N 656 (ред. от 23.12.2024) «О требованиях к операторам электронных площадок, операторам специализированных электронных площадок, электронным площадкам, специализированным электронным площадкам и функционированию электронных площадок, специализированных электронных площадок, подтверждении соответствия таким требованиям, об утрате юридическим лицом статуса оператора электронной площадки, оператора специализированной электронной площадки» // КонсультантПлюс. [Электронный ресурс]: https://www.consultant.ru/document/cons_doc_LAW_300361/ (дата обращения 07.10.2024).
21. RandomForestClassifier // scikit-learn: Machine Learning in Python. [Электронный ресурс]: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html> (дата обращения 11.02.2025).
22. CatBoostClassifier // CatBoost library. [Электронный ресурс]: https://catboost.ai/docs/en/concepts/python-reference_catboostclassifier (дата обращения 11.02.2025).
23. torch.nn // PyTorch [Электронный ресурс]: <https://pytorch.org/docs/stable/nn.html> (дата обращения 11.02.2025)
24. Ансамблевые методы: Градиентный бустинг, случайные леса, бэггинг, метод голосования, стекинг // scikit-learn: Машинное обучение в Python. [Электронный ресурс]: <https://scikit-learn.ru/stable/modules/ensemble.html> (дата обращения 11.02.2025).
25. Lin T.-Y., Goyal P., Girshick R., He K., Dollár P. Focal loss for dense object detection // 2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy. 2017. P. 2999–3007. <https://doi.org/10.1109/ICCV.2017.324>
26. Content available on Disney's new streaming service's (Disney+) compared to Netflix in the United States as of April 2019 // Statista. [Электронный ресурс]: <https://www.statista.com/statistics/1041104/disney-catalog-netflix-comparison-us/> (дата обращения 10.10.2024).
27. Сафронов А. Количество подписчиков Netflix в США упало впервые за 8 лет // РБК Инвестиции. 2019. [Электронный ресурс]: <https://quote.ru/news/article/5d3013649a794752c4a31fee> (дата обращения 10.10.2024).
28. Morley M. Netflix library by the numbers 2024: 589 new originals released and library swells to over 7,000 titles // What's on Netflix. 2025. [Электронный ресурс]: <https://www.whats-on-netflix.com/news/netflix-library-by-the-numbers-2024/> (дата обращения 10.05.2025).
29. Moore K. Netflix added over 10,000 episodes of TV in 2024 // What's on Netflix. 2025. [Электронный ресурс]: <https://www.whats-on-netflix.com/news/netflix-added-over-10000-episodes-of-tv-in-2024/> (дата обращения 10.05.2025).
30. Number of Netflix paying streaming subscribers worldwide as of 4th quarter 2024, by region // Statista. 2025. [Электронный ресурс]: <https://www.statista.com/statistics/483112/netflix-subscribers/> (дата обращения 10.05.2025).
31. Рекомендательная система в сфере электронных закупок // Альянс в сфере искусственного интеллекта. 2020. [Электронный ресурс]: <https://ai-russia.ru/library/roseltorg-system> (дата обращения 10.10.2024).

Об авторах

Денисова Анна Игоревна

кандидат экономических наук;

старший преподаватель, кафедра математических методов в экономике и управлении, Институт информационных систем, Государственный университет управления, Россия, 109542, г. Москва, Рязанский пр-т, 99;

E-mail: a.i.denisova@inbox.ru

ORCID: 0000-0002-2296-237X

Созаева Джамиля Алимовна

доктор экономических наук, доцент;

руководитель лаборатории, проектно-учебная лаборатория исследований и разработок в сфере цифровизации управления, Государственный университет управления, Россия, 109542, г. Москва, Рязанский пр-т, 99;

доцент, кафедра оценочной деятельности и корпоративных финансов, Университет «Синергия», Россия, 125190, г. Москва, Ленинградский пр-т, 80, корп. Г;

E-mail: dasozaeva@gmail.com

ORCID: 0000-0003-3955-891X

Гончар Константин Валерьевич

младший научный сотрудник, проектно-учебная лаборатория исследований и разработок в сфере цифровизации управления; Государственный университет управления, Россия, 109542, г. Москва, Рязанский пр-т, 99;

старший преподаватель, кафедра ИУ-3, МГТУ им. Н.Э. Баумана, Россия, 105005, г. Москва, 2-я Бауманская ул., д. 5;

E-mail: goncharkv@gmail.com

ORCID: 0000-0001-7345-3340

Development of recommendation systems to improve the efficiency of regulated procurement in the electric power industry

Anna I. Denisova^a

E-mail: a.i.denisova@inbox.ru

Dzhamilya A. Sozaeva^{a,b}

E-mail: dasozaeva@gmail.com

Konstantin V. Gonchar^{a,c}

E-mail: goncharkv@gmail.com

^a State University of Management, Moscow, Russia

^b Synergy University, Moscow, Russia

^c Bauman Moscow State Technical University, Moscow, Russia

Abstract

This article considers ways to improve the efficiency of the regulated procurement market by implementing recommender systems into the existing procurement IT infrastructure. Using state, municipal and commercial procurement of electric power products as an example, the article considers promising classes of recommender systems for implementation, proposes a methodology for developing such services, and discloses algorithms for processing, configuring and interpreting data necessary for their operation. The difference between the author's approach to creating services and previously published works is substantiated, testing and A/B testing are carried out, and an assessment of the effectiveness is presented. The results obtained have scientific novelty (the methodology of using neural networks in relation to the procurement industry has been substantiated) and practical significance (the customer's time saved on searching for suppliers by up to 40%; the pool of potential suppliers has been expanded; supplier risks have been diversified by selecting relevant procedures from new areas and from new customers; suppliers have been provided with the opportunity to find up to 2–3 new customers for 1 recommendation mailing with a frequency of 1–2 times a week). We proposed to implement the developments in the practice of the operator of public procurement tenders. The authors see further development of recommendation services and solutions for the procurement industry in improving the analysis of semantic (text, logical) content of procurement documents, as well as the behavioral strategies of suppliers. The risks and limitations are associated with the high cost of maintaining a staff of developers-practitioners in neural networks, possible hallucinations of neural networks and their high sensitivity to errors and original data sets.

Keywords: recommender systems, efficiency of regulated procurement, probability of winning in public procurement, personalized recommendations, “non-closing” of tenders, competition in procurement

Citation: Denisova A.I., Sozaeva D.A., Gonchar K.V. (2025) Development of recommendation systems to improve the efficiency of regulated procurement in the electric power industry. *Business Informatics*, vol. 19, no. 2, pp. 25–40. DOI: 10.17323/2587-814X.2025.2.25.40

References

1. Garant System (2014) *Resolution of the Government of the Russian Federation of April 15, 2014 No. 320 "On approval of the state program of the Russian Federation "Public Finance Management and Regulation of Financial Markets" (with amendments and additions)*. Available at: <https://base.garant.ru/70644234> (accessed 10 October 2024) (in Russian).
2. Denisova A.I., Sozaeva D.A., Gonchar K.V., Aleksandrov G.A. (2024) Analysis of factors for failure to close tenders for public procurement of drugs. *Problems of Forecasting*, no. 2, pp. 178–191 (in Russian). <https://doi.org/10.47711/0868-6351-203-178-191>
3. Ministry of Finance of Russia (2024) *Consolidated analytical report on the results of monitoring the procurement of goods, works, services to meet state and municipal needs, as well as the procurement of goods, works, services by certain types of legal entities for 2023*. Available at: https://minfin.gov.ru/common/upload/library/2024/05/main/Svodnyy_2023.pdf (accessed 10 October 2024) (in Russian).
4. Ministry of Finance of Russia (2024) *Quarterly report on the results of monitoring the procurement of goods, works, services to meet state and municipal needs, as well as the procurement of goods, works, services by certain types of legal entities for the second quarter of 2024*. Available at: https://minfin.gov.ru/common/upload/library/2024/07/main/II_kvartal_2024_g.pdf (accessed 10 October 2024) (in Russian).
5. Kuznetsov M. (2024) What awaits the public procurement market in 2024. *Rossiyskaya Gazeta – Economy of the Central District*, no. 4(9246). Available at: <https://rg.ru/2024/01/11/reg-cfo/delo-za-malym.html> (accessed 10 October 2024) (in Russian).
6. Yakovlev A.A., Balaeva O.N., Rodionova Yu.D., Tkachenko A.V. (2020) Problems and efficiency of public procurement through the eyes of their participants. *All-Russian economic journal ECO*, no. 11, pp. 83–103 (in Russian). <https://doi.org/10.30680/ECO0131-7652-2020-11-83-103>
7. Falk K. (2020) *Recommender systems in practice*. Moscow: DMK Press (in Russian).
8. Baranov V.V. (2005) *Processes of making management decisions motivated by interests*. Moscow: Fizmatlit (in Russian).
9. Kravchenko T.K., Isaev D.V. (2024) *Decision support systems: textbook and practical training for universities. 2nd edition, revised and additional edition*. Moscow: Yurait (in Russian).
10. Keeney R.L., Raiffa H. (1976) *Decisions with multiple objectives: Preferences and value tradeoffs*. John Wiley & Sons.
11. Thaler R. (2022) *New behavioral economics. Why people break the rules of traditional economics*. Moscow: Eksmo (in Russian).
12. García Rodríguez M.J., Montequín V., Ortega-Fernández F., Balsera J. (2020) Bidders recommender for public procurement auctions using machine learning: data analysis, algorithm, and case study with tenders from Spain. *Complexity*, article 8858258. <https://doi.org/10.1155/2020/8858258>
13. Hickok M. (2024) Public procurement of artificial intelligence systems: new risks and future proofing. *AI & Society*, vol. 39, pp. 1213–1227. <https://doi.org/10.1007/s00146-022-01572-2>
14. Seliverstov Y.A., Komissarov A.A., Lesovodskaya A.A., et al. (2022) Development and research of models of multi-class classifiers for a recommender system for preparing applications on the e-procurement. *Computing, Telecommunications and Control*, vol. 15, no. 2, pp. 43–62 (in Russian). <https://doi.org/10.18721/JCSTCS.15204>
15. Chen J., Dong H., Wang X., et al. (2023) Bias and debias in recommender system: A survey and future directions. *ACM Transactions on Information Systems*, vol. 41, no. 3, article 67. <https://doi.org/10.1145/3564284>
16. Ko H., Lee S., Park Y., Choi A. (2022) A survey of recommendation systems: Recommendation models, techniques, and application fields. *Electronics*, vol. 11, no. 1, article 141. <https://doi.org/10.3390/electronics11010141>
17. Andrianov N.A., Atakhodjaeva M.R., Borodin E.I. (2022) Mathematical modeling of a recommender system and data processing of a telecommunications company using machine learning models. *Bulletin of the South Ural State University. Series: Computer technologies, management, radio electronics*, vol. 22, no. 2, pp. 17–28 (in Russian). <https://doi.org/10.14529/ctcr220202>
18. Denisova A.I., Sozaeva D.A., Gonchar K.V., Aleksandrov G.A. (2023) Improving the methodology for assessing the economic efficiency of public e-procurement of medicines. *Financial Journal*, vol. 15, no. 4, pp. 63–81 (in Russian). <https://doi.org/10.31107/2075-1990-2023-4-63-81>
19. Denisova A.I., Sozaeva D.A., Gonchar K.V., Aleksandrov G.A. (2024) Analysis of factors for non-closure of tenders for public procurement of medicines. *Problems of Forecasting*, no. 2, pp. 178–191 (in Russian). <https://doi.org/10.47711/0868-6351-203-178-191>
20. ConsultantPlus (2024) *Resolution of the Government of the Russian Federation of 08.06.2018 N 656 (as amended on 23.12.2024) "On the requirements for operators of electronic platforms, operators of specialized electronic platforms, electronic platforms, specialized electronic platforms and the functioning of electronic platforms, specialized electronic platforms, confirmation of compliance with such requirements, on the loss of the status of an operator of an electronic platform, operator of a specialized electronic platform by a legal entity"*. Available at: https://www.consultant.ru/document/cons_doc_LAW_300361/ (accessed 10 October 2024) (in Russian).

21. scikit-learn: Machine Learning in Python (2025) *RandomForestClassifier*. Available at: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html> (accessed 11 February 2025).
22. CatBoost library (2025) *CatBoostClassifier*. Available at: https://catboost.ai/docs/en/concepts/python-reference_catboostclassifier (accessed 11 February 2025).
23. PyTorch (2025) *torch.nn*. Available at: <https://pytorch.org/docs/stable/nn.html> (accessed 11 February 2025).
24. scikit-learn: Machine Learning in Python (2025) *Ensembles: Gradient boosting, random forests, bagging, voting, stacking*. Available at: <https://scikit-learn.org/stable/modules/ensemble.html> (accessed 11 February 2025).
25. Lin T.-Y., Goyal P., Girshick R., He K., Dollár P. (2017) Focal loss for dense object detection. *2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy*, pp. 2999–3007. <https://doi.org/10.1109/ICCV.2017.324>
26. Statista (2025) *Content available on Disney's new streaming service's (Disney+) compared to Netflix in the United States as of April 2019*. Available at: <https://www.statista.com/statistics/1041104/disney-catalog-netflix-comparison-us/> (accessed 10 October 2024).
27. Safronov A. (2019) Netflix US subscribers fall for first time in 8 years. *RBC Investments*. Available at: <https://quote.ru/news/article/5d3013649a794752c4a31fee> (accessed 10 October 2024).
28. Morley M. (2025) Netflix library by the numbers 2024: 589 new originals released and library swells to over 7,000 titles. *What's on Netflix*. Available at: <https://www.whats-on-netflix.com/news/netflix-library-by-the-numbers-2024/> (accessed 10 May 2025).
29. Moore K. (2025) Netflix added over 10,000 episodes of TV in 2024. *What's on Netflix*. Available at: <https://www.whats-on-netflix.com/news/netflix-added-over-10000-episodes-of-tv-in-2024/> (accessed 10 May 2025).
30. Statista (2025) *Number of Netflix paying streaming subscribers worldwide as of 4th quarter 2024, by region*. Available at: <https://www.statista.com/statistics/483112/netflix-subscribers/> (accessed 10 May 2025).
31. Alliance in the field of artificial intelligence (2020) *Recommender system in the field of electronic procurement*. Available at: <https://ai-russia.ru/library/roseltorg-system> (accessed 10 October 2024).

About the authors

Anna I. Denisova

Candidate of Sciences (Economics);

Senior Lecturer, Institute of Information Systems, Department of Mathematical Methods in Economics and Management, State University of Management, 99, Ryazansky Ave., Moscow 109542, Russia;

E-mail: aidenisova@inbox.ru

ORCID: 0000-0002-2296-237X

Dzhamilya A. Sozaeva

Doctor of Sciences (Economics), Associate Professor;

Head of Laboratory, Project-training Laboratory for Research and Development in the Field of Digitalization of Management, State University of Management, 99, Ryazansky Ave., Moscow 109542, Russia;

Associate Professor, Department of Valuation Activities and Corporate Finance, Synergy University, 80, Bldg. G, Leningradsky Ave., Moscow 125190, Russia;

E-mail: dasozaeva@gmail.com

ORCID: 0000-0003-3955-891X

Konstantin V. Gonchar

Junior Researcher, Project-training Laboratory for Research and Development in the Field of Digitalization of Management, State University of Management, 99, Ryazansky Ave., Moscow 109542, Russia;

Senior Lecturer, Department of IU-3, Bauman Moscow State Technical University, 5, 2-nd Baumanskaya St., Moscow 105005, Russia;

E-mail: goncharkv@gmail.com

ORCID: 0000-0001-7345-3340