

УДК 004.738.5:339.187.2

Шифр специальности ВАК 2.3.4

Р.С. Кульшин, А.А. Сидоров

Двухконтурная концепция выбора и оптимизации рекомендательных алгоритмов для бизнеса в цифровой среде

Актуальность. Развитие цифровых платформ усиливает значение рекомендательных алгоритмов как инструмента управления пользовательским выбором, персонализацией предложений и поддержкой бизнес-процессов компании. **Цель исследования.** Целью работы является разработка двухконтурной концепции выбора и оптимизации рекомендательных алгоритмов для бизнеса в цифровой среде, обеспечивающей согласование технической оценки алгоритмов с последующей проверкой их прикладной результативности. **Методы.** В исследовании использованы методы сравнительного анализа, многокритериальной оценки, моделирования процедуры выбора алгоритма, агрегирования частных показателей в интегральный критерий, а также концептуального описания бизнес-валидации рекомендательных решений. **Научная новизна.** Предложена двухконтурная концепция выбора и оптимизации рекомендательных алгоритмов, отличающаяся разделением процедуры оценки на внутренний контур многокритериального офлайн-анализа и внешний контур проверки выбранного решения по онлайн-показателям пользовательского и экономического отклика. **Результаты.** Показано, что выбор рекомендательного алгоритма не должен основываться на одной локальной метрике, поскольку качество рекомендаций определяется совокупностью разнонаправленных характеристик. Обоснована роль интегрального критерия как основы предварительного сравнения, ранжирования и настройки алгоритмов до их внедрения в реальную цифровую среду. **Практическая значимость.** Предложенный подход может применяться цифровыми платформами, интернет-магазинами, медиасервисами и иными компаниями для обоснованного выбора рекомендательных алгоритмов, настройки их гиперпараметров и последующей проверки влияния рекомендаций на пользовательское поведение и бизнес-результаты.

Ключевые слова: рекомендательные системы, бизнес в цифровой среде, управленческие решения, многокритериальная оценка, интегральный показатель.

DOI: 10.21293/1818-0442-2026-29-1-152-159

Введение

Электронная коммерция, медиасервисы, образовательные платформы и другие цифровые экосистемы оперируют чрезвычайно большим количеством объектов, которые потенциально могут быть предложены пользователю. В этих условиях для бизнеса критическое значение приобретает задача управляемого представления ассортимента: компаниям необходимо не просто хранить и обслуживать большое число товаров, услуг или единиц контента, а обеспечивать их эффективное доведение до конкретного пользователя [1]. Именно здесь рекомендательные системы становятся важнейшим инструментом бизнеса в цифровой среде, поскольку влияют на вовлечённость пользователей [2, 3], вероятность повторного взаимодействия с платформой, потребление контента, продвижение ассортимента и, в конечном счёте, на экономическую результативность сервиса [4].

Практическая проблема бизнеса заключается в выборе рекомендательного алгоритмического решения, которое будет наилучшим образом соответствовать целям компании и ограничениям её цифровой инфраструктуры. При этом алгоритмические решения потенциально могут характеризоваться не одним, а совокупностью разнородных аспектов их качества: точность, качество ранжирования, разнообразие рекомендаций, вычислительная эффективность и другие параметры [5–7].

Для организации недостаточно, чтобы алгоритм демонстрировал высокое значение по какой-либо, пусть и даже самой релевантной относительно целей

его применения метрике. В реальной среде необходимо одновременно учитывать качество персонализации, способность правильно ранжировать объекты, разнообразие рекомендательной выдачи, вычислительные затраты на обработку данных и возможность масштабирования при росте числа пользователей и объектов. Следовательно, выбор рекомендательного алгоритма представляет собой задачу управленческого характера, в которой требуется согласовать разнонаправленные критерии и соотнести технические свойства модели с бизнес-целями компании.

На этом фоне становится очевидной ограниченность практики, при которой выбор рекомендательного алгоритма осуществляется по одной локальной метрике, чаще всего по показателю точности [8, 9]. Такой подход приемлем в узко вычислительной постановке, но он недостаточен для задач бизнеса, где требуется учитывать множественность эффектов и ограничений. Для компании принципиально важно не максимизировать изолированный показатель, а выбрать такое решение, которое будет приемлемым с точки зрения совокупного результата для цифровой системы. Отсюда вытекает необходимость разработки подхода, способного связать аналитическую оценку алгоритмов с логикой управленческого выбора.

Рекомендательная система как объект управления в бизнесе

Если рассматривать рекомендательную систему в организационном контексте, то её следует трактовать не как автономный модуль генерации персона-

лизированных списков, а как элемент механизма управления цифровым взаимодействием между компанией, обладающей ассортиментом, и пользователем. Через рекомендации бизнес-структура фактически управляет структурой пользовательского выбора, распределением внимания между объектами каталога и балансом между качеством сервиса и стоимостью его эксплуатации.

Такой подход особенно важен для компаний, функционирующих в формате цифровых платформ. Следовательно, задача выбора и настройки рекомендательного алгоритма приобретает свойства задачи управления в организационной системе, поскольку от неё зависит не только качество вычислительного результата, но и эффективность функционирования целого сегмента бизнеса.

Несмотря на то, что бизнес заинтересован в росте показателей фактического отклика и экономического результата, таких как CTR (click-through rate, отношение числа кликов на товар к числу их показов), CVR (conversion rate, отношение CVR к количеству покупок) и GMV (gross merchandise value, общая стоимость всех проданных товаров или услуг через торговую площадку за определенный период) и т.д. [10], на этапе предварительного выбора алгоритма эти показатели, как правило, ещё недоступны. До внедрения решения в эксплуатацию и проведения онлайн-экспериментов компания располагает главным образом офлайн-метриками, полученными на исторических данных. В результате возникает разрыв между тем, что нужно бизнесу как конечный эффект, и тем, что реально может быть измерено на стадии аналитического отбора альтернатив.

Этот разрыв имеет принципиальное значение [11]. Если офлайн-метрики напрямую отождествляются с бизнес-результатом, возникает риск методологически некорректных выводов о полезности алгоритма. Если же, напротив, отказаться от формализованной офлайн-оценки из-за отсутствия прямых бизнес-показателей, процесс выбора алгоритма становится слабо обоснованным и превращается в эмпирический или интуитивный. Следовательно, требуется концептуальная схема, которая позволяла бы использовать офлайн-метрики как основание предварительного управленческого выбора, но при этом не подменяла бы ими окончательную бизнес-оценку.

Двухконтурная концепция

Основная идея предлагаемой двухконтурной концепции заключается в том, что задача выбора и оптимизации рекомендательных алгоритмов в бизнесе не должна решаться на основе единого набора показателей, а требует разграничения аналитического и прикладного уровней оценки. Такая постановка обусловлена тем, что на этапе предварительного выбора алгоритма организация располагает, главным образом, офлайн-метриками, тогда как фактическая полезность рекомендательной системы для бизнеса проявляется уже в процессе эксплуатации и выражается через поведенческие и экономические показатели. Следовательно, методологически кор-

ректная модель должна, с одной стороны, обеспечивать формализованный предварительный выбор алгоритма на основе измеряемых характеристик, а с другой – сохранять возможность последующей проверки того, насколько этот выбор действительно оправдан с точки зрения бизнес-целей компании.

В этой связи предлагается рассматривать процедуру выбора и оптимизации рекомендательных алгоритмов как двухконтурную систему. Первый контур является внутренним и выполняет функцию офлайн-аналитического ядра. В нём осуществляется сбор частных метрик с последующей сверткой в интегральный показатель, используемый для сравнения альтернативных алгоритмов и настройки их параметров. Методические основы построения данного интегрального показателя, а также подход к объединению частных критериев разработаны авторами и представлены в работе [12]. Второй контур является внешним и выполняет функцию бизнес-валидации: на этом уровне предварительно выбранное решение проверяется в реальной цифровой среде по показателям фактического пользовательского и экономического отклика. Такая архитектура позволяет избежать смешения различных по природе критериев, сохраняя при этом их логическую преемственность в рамках единой концепции.

Принципиально важно, что в рамках данного подхода офлайн-метрики не трактуются как прямые бизнес-показатели. Такой взгляд особенно значим в условиях, когда организация должна сопоставить несколько альтернативных моделей, но ещё не располагает результатами А/В-тестирования [13], фактическими значениями онлайн-метрик или другими показателями практического использования. Следовательно, офлайн-контур не заменяет бизнес-оценку, а выполняет функцию предварительного многокритериального отбора и оптимизации решений в условиях ограниченной наблюдаемости конечного эффекта.

Вместе с тем бизнес-метрики не включаются непосредственно во внутренний контур текущей постановки. Они образуют внешний уровень подтверждения практической полезности выбранного решения. Если внутренний контур отвечает на вопрос о том, какой алгоритм является предпочтительным по совокупности измеряемых офлайн-характеристик, то внешний контур отвечает на вопрос о том, подтверждается ли эта предварительная оценка в реальных условиях функционирования цифровой платформы. В перспективе возможно построение обобщённой меры, объединяющей онлайн- и офлайн-компоненты, однако в рамках текущего позиционирования эти уровни сознательно разведены для сохранения методологической строгости и интерпретационной ясности.

Двухконтурная концепция выбора рекомендательного алгоритма представлена на рис. 1. В таком представлении офлайн-метрики получают статус прокси-характеристик бизнес-значимых свойств рекомендательной системы, а бизнес-метрики сохраняют статус внешнего критерия её практической результативности.

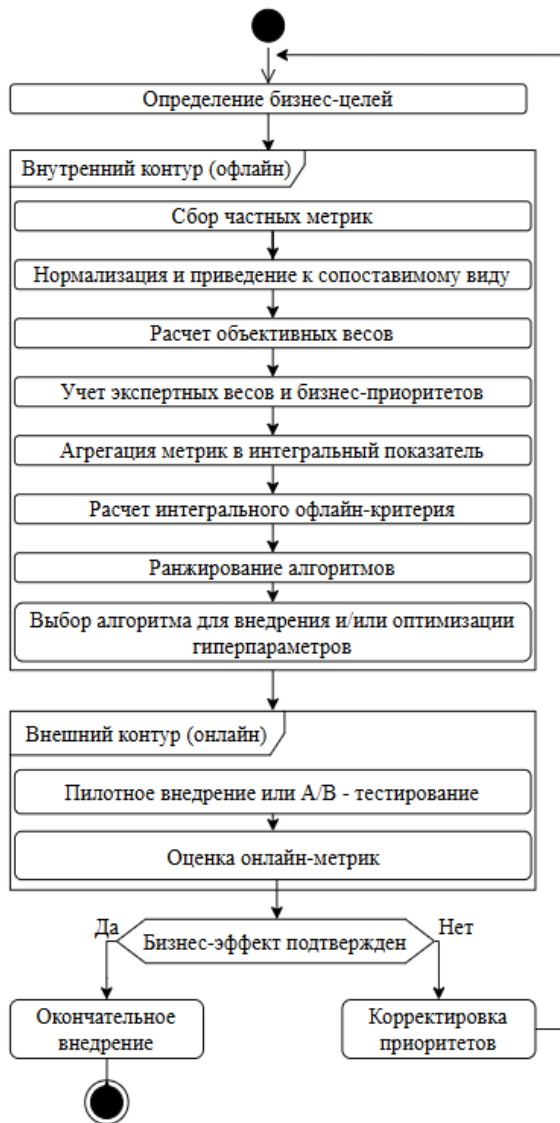


Рис. 1. Двухконтурная концепция выбора рекомендательного алгоритма

Именно такое разделение функций позволяет рассматривать предложенную концепцию как инструмент поддержки управленческих решений в бизнесе, а не только как способ вычисления итогового балла качества алгоритма.

Внутренний контур

Внутренний контур объединённой концепции представляет собой офлайн-аналитическое ядро, предназначенное для предварительного сравнения, выбора и настройки рекомендательных алгоритмов. Его задача состоит в преобразовании множества разрозненных характеристик в единую систему офлайн-оценки, обеспечивающую сопоставимость альтернатив и возможность их последующего ранжирования. Тем самым внутренний контур формирует методологическую основу предварительного отбора решений до их практической проверки во внешнем контуре.

Постановка задачи определения алгоритма и его гиперпараметров представлена в виде следующего кортежа (1):

$$K_{\text{внутр}} = \langle \mathbf{A}, \mathbf{O}, \mathbf{M}, \mathbf{P} \mid A^*, O^* \rangle, \quad (1)$$

где $\mathbf{A}$ – множество альтернативных рекомендательных алгоритмов; $\mathbf{O}$ – множество допустимых конфигураций их гиперпараметров для каждого алгоритма; $\mathbf{M}$ – множество частных офлайн-метрик; $\mathbf{P}$ – множество бизнес-приоритетов; A^* – выбранный алгоритм; O^* – выбранная конфигурация его гиперпараметров.

На первом этапе внутреннего контура осуществляется сбор частных офлайн-метрик, характеризующих различные стороны работы рекомендательного алгоритма. Речь идёт не об одном локальном показателе, а о совокупности характеристик, отражающих как качество формируемых рекомендаций, так и ресурсные особенности функционирования модели. Далее метрики нормализуются и приводятся к сопоставимому виду, поскольку исходные показатели имеют различную размерность, измеряются в разных единицах и могут различаться по направленности предпочтения.

После нормализации частные метрики объединяются в укрупнённые субиндексы, отражающие основные аспекты качества рекомендательного алгоритма. В рассматриваемой постановке 13 частных показателей агрегируются в четыре субиндекса второго уровня: «Ресурсы», «Точность», «Ранжирование» и «Разнообразие». Веса частных показателей и субиндексов используются для отражения их различной значимости в интегральной оценке рекомендательного алгоритма. В рамках предлагаемого подхода итоговые веса формируются на основе сочетания объективной и экспертной составляющих.

Объективные веса рассчитываются по данным и отражают информативность показателей при сравнении алгоритмов. Экспертные веса задаются с учетом бизнес-приоритетов цифровой платформы, например, необходимости повысить точность рекомендаций, снизить вычислительные затраты, улучшить ранжирование или увеличить разнообразие выдачи.

Гибридный вес показателя определяется по формуле (2):

$$w_j = K_{\text{эксперт}} w_j^{\text{эксперт}} + (1 - K_{\text{эксперт}}) w_j^{\text{объект}}, \quad (2)$$

где w_j – итоговый вес j -го показателя; $w_j^{\text{эксперт}}$ – экспертный вес показателя; $w_j^{\text{объект}}$ – объективный вес показателя; $K_{\text{эксперт}}$ – коэффициент доверия к экспертной оценке.

Аналогично определяется вес субиндекса (3):

$$W_g = K_{\text{эксперт}} W_g^{\text{эксперт}} + (1 - K_{\text{эксперт}}) W_g^{\text{объект}}, \quad (3)$$

где W_g – итоговый вес g -го субиндекса; $W_g^{\text{эксперт}}$ – экспертный вес субиндекса; $W_g^{\text{объект}}$ – объективный вес субиндекса; $K_{\text{эксперт}}$ – коэффициент доверия к экспертной оценке.

Обобщенная формула расчета интегрального показателя (4):

$$I = \sum_{g=1}^G W_g \left(\sum_{j \in \mathbf{M}_g} w_{jg} r_{ij} \right), \quad (4)$$

где I – интегральный показатель качества рекомендательного алгоритма; G – множество групп показателей, т.е. количество субиндексов; M_g – множество частных метрик, входящих в g -й субиндекс; r_{ij} – нормализованное значение j -й частной метрики для i -го алгоритма; w_{jg} – вес j -й метрики внутри g -го субиндекса; W_g – вес g -го субиндекса в общей интегральной оценке.

Полученный интегральный критерий (рис. 2) используется для сравнения и ранжирования альтернативных алгоритмов, снижая неоднозначность выбора в условиях конфликта метрик и создавая более устойчивое основание для предварительного управленческого решения. Кроме того, он может применяться как целевая функция при оптимизации гиперпараметров [14], что позволяет настраивать модель с учётом нескольких аспектов качества одновременно, а не ориентироваться на одну частную метрику. Тем самым внутренний контур выполняет функцию многокритериального аналитического отбора и настройки решений, пригодных для последующей бизнес-валидации.

Практическая применимость объединённой концепции определяется возможностью интерпретировать результаты офлайн-оценки не только в вычислительной, но и в управленческой логике. Если интегральный критерий и его субиндексы рассматривать лишь как технические показатели, их использование будет ограничено внутренним анализом алгоритмов.

Субиндекс «Ресурсы» отражает эксплуатационную стоимость алгоритма, его масштабируемость и пригодность к использованию в рамках имеющейся цифровой инфраструктуры. Субиндекс «Точность» характеризует степень соответствия рекомендаций интересам пользователя и, следовательно, способность системы обеспечивать персонализацию клиентского предложения. Субиндекс «Ранжирование» описывает качество распределения объектов в выдаче, определяя, насколько эффективно система направляет пользовательское внимание к наиболее значимым предложениям. Субиндекс «Разнообразие» связан с широтой представления ассортимента, снижением однотипности выдачи и поддержанием долгосрочного интереса пользователя к платформе.

Тем самым совместное рассмотрение четырёх субиндексов позволяет анализировать рекомендательную систему не только как вычислительный механизм, но и как управляемый элемент бизнеса. Это делает интегральную оценку интерпретируемой для субъекта управления и позволяет использовать её как инструмент предварительного выбора и настройки алгоритмов в соответствии с организационными целями и ограничениями компании.

Учет приоритетов бизнеса в выборе и оптимизации алгоритмов рекомендаций

Важной особенностью объединённой двухконтурной концепции является возможность адаптации процедуры выбора и настройки рекомендательных алгоритмов к целям и ограничениям конкретной организации. В реальной практике бизнеса в цифровой среде универсального критерия качества, одинаково применимого для всех компаний и всех сценариев использования, не существует. Требования к рекомендательной системе зависят от особенностей платформы, структуры ассортимента, поведения пользователей, доступной вычислительной инфраструктуры и текущих управленческих задач. Вследствие этого одна и та же модель может по-разному оцениваться в зависимости от организационного контекста её применения.

В предлагаемой концепции учёт таких различий обеспечивается через систему весов, используемую при формировании интегрального критерия. Именно веса позволяют отразить относительную значимость отдельных аспектов оценки и тем самым согласовать процедуру сравнения алгоритмов с приоритетами бизнеса.

В результате интегральная оценка выступает не как фиксированный вычислительный показатель, а как настраиваемый критерий выбора, чувствительный к целям организации. Это переводит задачу отбора алгоритма из плоскости формального сравнения моделей в плоскость поддержки управленческого решения.

Практическое значение такого подхода состоит в том, что компания получает возможность изменять направление выбора и оптимизации алгоритмов в зависимости от своей текущей стратегии.




Рис. 2. Функциональная сеть вычисления интегрального показателя [12]

При изменении организационных приоритетов меняется и конфигурация интегрального критерия, а значит, и итоговое ранжирование алгоритмов. Благодаря этому одна и та же методика может использоваться в различных бизнес-сценариях без изменения общей логики оценки, но с корректировкой параметров под конкретную задачу.

Особенно важен данный механизм на этапе оптимизации гиперпараметров. Настройка алгоритмов может выполняться как по общей интегральной оценке, так и по одному доминирующему субиндексу. В первом случае достигается более сбалансированное улучшение характеристик модели. Во втором случае оптимизация подчиняется приоритетному направлению, однако остальные аспекты качества сохраняются в структуре оценки за счёт ненулевых весов. Это позволяет реализовать не только режим общего повышения качества, но и режим целенаправленной адаптации рекомендательной системы к конкретной управленческой задаче.

Учёт приоритетов бизнеса в рамках объединённой концепции означает, что интегральный критерий используется как инструмент управляемого выбора и настройки рекомендательных алгоритмов. Его функция состоит не только в агрегировании множества метрик, но и в формализации организационных целей, в соответствии с которыми осуществляется предварительный отбор и оптимизация решений для цифровой платформы.

Интегральная оценка в рамках объединённой двухконтурной концепции рассматривается не как самостоятельный итог вычислений, а как основание для предварительного управленческого решения о выборе и настройке рекомендательного алгоритма. Она используется для сравнения альтернативных моделей и их ранжирования по степени соответствия совокупности критериев, значимых для конкретной организационной ситуации, что придаёт процедуре выбора более формализованный характер.

Кроме того, интегральная оценка может служить основанием для более сложных решений, в том числе для выбора ансамблевых или комбинированных конфигураций, если отдельные алгоритмы демонстрируют преимущества по разным направлениям оценки. Поскольку критерий представляет собой настраиваемую многокритериальную конструкцию, он допускает корректировку по мере изменения задач бизнеса, организационных условий и стратегии платформы. Благодаря этому интегральная оценка может использоваться не только как инструмент разового выбора, но и как средство последовательного сопровождения управленческих решений в процессе развития цифрового сервиса.

Внешний контур: бизнес-валидация

Внешний контур концепции предназначен для проверки того, подтверждается ли предварительный аналитический выбор рекомендательного алгоритма в реальных условиях функционирования цифровой платформы. Необходимость данного этапа обусловлена тем, что внутренняя офлайн-оценка остаётся

ограниченной рамками исторических данных и не позволяет в полной мере судить о фактическом влиянии алгоритма на поведение пользователей и результаты бизнеса. Поэтому внешний контур выполняет функцию практической валидации предварительно выбранного решения после его внедрения или тестового запуска в реальной среде. Если внутренний контур отвечает на вопрос о том, какой алгоритм является предпочтительным по совокупности измеряемых офлайн-характеристик, то внешний контур отвечает на вопрос о том, приводит ли этот выбор к желаемому прикладному эффекту в реальном бизнесе. Тем самым он завершает цикл оценки и переводит результат аналитического отбора в плоскость проверки его фактической управленческой состоятельности.

В качестве показателей внешнего контура рассматриваются онлайн-метрики, отражающие фактический пользовательский и экономический отклик на работу рекомендательной системы. Основными метриками могут выступать CTR, CVR и GMV, которые позволяют оценивать влияние рекомендательных алгоритмов уже не только на качество выдачи как таковой, а на реальные бизнес-показатели цифровой платформы. В отличие от офлайн-метрик, данные показатели фиксируют результат функционирования алгоритма в среде реального взаимодействия пользователей с сервисом и потому обладают прямой прикладной значимостью для компании.

Практически внешний контур реализован через тестовую эксплуатацию алгоритма, сравнение нескольких альтернатив в рабочей среде и процедуры А/В-тестирования [15, 16]. На этом этапе организация получает возможность сопоставить не только внутренние оценки качества моделей, но и их реальный вклад в достижение целевых показателей платформы.

Постановка задачи определения результата бизнес-валидации и итогового управленческого решения представлена в виде следующего кортежа (5):

$$K_{\text{внеш}} = \langle A^*, O^*, T, Z | V, D \rangle, \quad (5)$$

где T – множество процедур тестовой эксплуатации или А/В-тестирования; Z – множество онлайн-метрик пользовательского и экономического отклика; V – результат бизнес-валидации; D – итоговое управленческое решение.

В качестве основного набора онлайн-показателей внешнего контура в данной постановке рассматриваются (6)

$$Z = \{CTR, CVR, GMV\}, \quad (6)$$

где CTR характеризует кликабельность рекомендательной выдачи, CVR – способность рекомендаций приводить к целевому действию, а GMV – экономический результат взаимодействия пользователей с платформой. При необходимости данный набор может быть дополнен другими показателями, например, средним чеком, глубиной просмотра или долей повторных взаимодействий.

Для каждой онлайн-метрики рассчитывается относительное изменение по сравнению с базовым алгоритмом (7)

$$\Delta z_k = \frac{z_k^{\text{новый}} - z_k^{\text{базовый}}}{z_k^{\text{базовый}}}, \quad (7)$$

где Δz_k – относительное изменение показателя; $z_k^{\text{новый}}$ – значение k -й онлайн-метрики при использовании выбранного алгоритма; $z_k^{\text{базовый}}$ – значение той же метрики для базового решения.

Для получения обобщенной оценки бизнес-эффекта использована агрегированная величина (8)

$$B = \sum_{k=1}^K q_k \Delta z'_k, \quad (8)$$

где B – интегральная оценка бизнес-эффекта во внешнем контуре; K – множество онлайн-метрик; q_k – вес k -й бизнес-метрики, отражающий ее значимость для цифровой платформы; $\Delta z'_k \in [-1; 1]$ – нормированное относительное изменение показателя.

Результаты внешнего контура используются для принятия итогового управленческого решения о целесообразности внедрения выбранного рекомендательного алгоритма. Для этого агрегированная оценка бизнес-эффекта B сопоставляется с пороговым значением y , которое заранее задается организацией с учетом целей эксперимента, допустимого уровня риска и минимально приемлемого прироста онлайн-показателей.

Правило принятия решения представлено в таблице.

В результате именно внешний контур позволяет либо подтвердить корректность предварительного управленческого выбора, либо выявить необходимость его пересмотра.

Правила принятия решений

Условие	Интерпретация результата бизнес-валидации	Управленческое решение
$B \geq y$	Выбранный алгоритм обеспечивает достаточное улучшение совокупности онлайн-показателей относительно базового решения	Алгоритм принимается к внедрению или масштабированию на цифровой платформе
$0 \leq B < y$	Эффект является положительным, но недостаточным для уверенного принятия решения. Улучшение онлайн-показателей есть, однако оно не достигает порога значимости	Требуется дополнительное тестирование, увеличение объема выборки, продление эксперимента или уточнение параметров алгоритма
$B < 0$	Бизнес-эффект не подтвержден. Совокупное изменение показателей является отрицательным – ухудшение результата по сравнению с базовым решением	Необходимо скорректировать бизнес-приоритеты, веса показателей или гиперпараметры и вернуться во внутренний контур оценки

Заключение

В статье предложена объединённая двухконтурная концепция выбора и оптимизации рекомендательных алгоритмов, ориентированная на использование в задачах поддержки управленческих решений

в бизнесе. Показано, что выбор алгоритма не может быть обоснован на основе одной локальной метрики, поскольку качество рекомендательной системы носит многокритериальный характер и связано с необходимостью одновременного учёта точности, ранжирования, разнообразия и ресурсных ограничений.

Обосновано, что внутренний контур концепции должен обеспечивать предварительный аналитический выбор и настройку алгоритмов на основе интегрального офлайн-критерия, тогда как внешний контур должен выполнять функцию последующей бизнес-валидации по онлайн-показателям фактического пользовательского и экономического отклика. Такая постановка позволяет использовать офлайн-метрики как измеряемое ядро предварительного выбора, не подменяя ими прямые бизнес-метрики.

Практическая значимость предложенного подхода состоит в том, что интегральная оценка может применяться как для сравнения альтернативных алгоритмов, так и для оптимизации их гиперпараметров, обеспечивая более согласованный и обоснованный выбор решений в зависимости от целей и ограничений цифровой платформы. Тем самым рекомендательная система рассматривается не как изолированный вычислительный модуль, а как управляемый элемент организационного механизма компании.

Работа выполнена в рамках государственного задания Минобрнауки России; проект FEWM-2026-0011.

Литература

1. Cheng H. Wide & deep learning for recommender systems / H. Cheng, L. Koc, J. Harmsen [et al.] // Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. – Boston, MA, USA: ACM, 2016. – P. 7–10.
2. Ghanem N. Balancing consumer and business value of recommender systems: a simulation-based analysis / N. Ghanem, S. Leitner, D. Jannach // Electronic Commerce Research and Applications. – 2022. – Vol. 55. – P. 101195. DOI: 10.1016/j.elerap.2022.101195.
3. De Biasio A. Economic recommender systems – a systematic review / A. De Biasio, N. Navarin, D. Jannach // Electronic Commerce Research and Applications. – 2024. – Vol. 63. – P. 101352. DOI: 10.1016/j.elerap.2023.101352.
4. Adomavicius G. Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions / G. Adomavicius, A. Tuzhilin // IEEE Transactions on Knowledge and Data Engineering. – 2005. – Vol. 17, No. 6. – P. 734–749. DOI: 10.1109/TKDE.2005.99.
5. Gomez-Urbe C.A. The Netflix recommender system: algorithms, business value, and innovation / C.A. Gomez-Urbe, N. Hunt // ACM Transactions on Management Information Systems. – 2015. – Vol. 6, No. 4. – P. 1–19.
6. Zangerle E. Evaluating recommender systems: survey and framework / E. Zangerle, C. Bauer // ACM Computing Surveys. – 2022. – Vol. 55, No. 8. – P. 1–38. DOI: 10.1145/3556536.
7. Gunawardana A. Evaluating recommender systems / A. Gunawardana, G. Shani, S. Yogev // Recommender Systems Handbook. – 3rd ed. – New York: Springer US, 2022. – P. 547–601. DOI: 10.1007/978-1-0716-2197-4_15.
8. Zheng Y. A survey of recommender systems with multi-objective optimization / Y. Zheng, D. Wang // Neurocomputing. – 2022. – Vol. 474. – P. 141–153. DOI: 10.1016/j.neucom.2021.11.041.

9. Jannach D. A survey on multi-objective recommender systems / D. Jannach, H. Abdollahpouri // *Frontiers in Big Data*. – 2023. – Vol. 6. – P. 1157899. DOI: 10.3389/fdata.2023.1157899.

10. Jannach D. Measuring the business value of recommender systems / D. Jannach, M. Jugovac // *ACM Transactions on Management Information Systems*. – 2019. – Vol. 10, No. 4. – Art. 16. – P. 1–23. DOI: 10.1145/3370082.

11. Castells P. Offline recommender system evaluation: challenges and new directions / P. Castells, A. Moffat // *AI Magazine*. – 2022. – Vol. 43, No. 2. – P. 225–238. DOI: 10.1002/aaai.12051.

12. Кульшин Р.С. Обобщенная метрика оценки эффективности алгоритмов рекомендательных систем на основе энтропийного метода / Р.С. Кульшин, А.А. Сидоров // *Проблемы управления*. – 2024. – № 4. – С. 44–60. DOI: 10.25728/pu.2024.4.4.

13. Gilotte A. Offline A/B testing for recommender systems / A. Gilotte, C. Calauzènes, T. Nedelec et al. // *Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining*. – Marina Del Rey, USA: ACM, 2018. – P. 198–206.

14. Кульшин Р.С. Оптимизация гиперпараметров рекомендательных алгоритмов посредством обобщенной метрики оценивания / Р.С. Кульшин, А.А. Сидоров // *Программная инженерия*. – 2026. – Т. 17, № 2. – С. 67–82. DOI: 10.17587/prin.17.67-82.

15. Quin F. A/B testing: a systematic literature review / F. Quin, D. Weyns, M. Galster, C.C. Silva // *Journal of Systems and Software*. – 2024. – Vol. 211. – Art. 112011. DOI: 10.1016/j.jss.2024.112011.

16. Jeunen O. Powerful A/B-testing metrics and where to find them / O. Jeunen, S. Baweja, N. Pokharna, A. Ustimenko // *Proceedings of the 18th ACM Conference on Recommender Systems*. – New York: ACM, 2024. – P. 816–818. DOI: 10.1145/3640457.3688036.

Кульшин Роман Сергеевич

Аспирант, ст. преподаватель каф. автоматизации обработки информации (АОИ) Томского государственного ун-та систем управления и радиоэлектроники (ТУСУР) Ленина пр-т, 40, г. Томск, Россия, 634050
ORCID: 0000-0002-6891-1869
Тел.: +7-923-721-35-98
Эл. почта: roman.s.kulshin@tusur.ru

Сидоров Анатолий Анатольевич

Канд. эконом. наук, зав. каф. АОИ ТУСУР Ленина пр-т, 40, г. Томск, Россия, 634050
ORCID: 0000-0002-9236-3639
Тел.: +7 (382-2) 41-41-31
Эл. почта: anatolii.a.sidorov@tusur.ru

Поступила в редакцию: 14.04.2026.

Принята к публикации: 22.05.2026.

Kulshin R.S., Sidorov A.A.

A Dual-Loop Framework for Selecting and Optimizing Recommendation Algorithms for Business in a Digital Environment

Relevance. The development of digital platforms reinforces the importance of recommendation algorithms as a tool for managing user choice, personalizing offers, and supporting company

business processes. **Purpose of the study** is to develop a dual-loop framework for selecting and optimizing recommendation algorithms for business in a digital environment, ensuring the alignment of the technical evaluation of algorithms with subsequent verification of their practical effectiveness. **Methods.** The study employs comparative analysis methods, multi-criteria evaluation, modeling of the algorithm selection procedure, the adjustment of particular indicators into an integral criterion, as well as a conceptual description of the business validation of recommendation solutions. **Novelty.** The dual-loop framework of selecting and optimizing recommendation algorithms is proposed, which is characterized by dividing the evaluation procedure into an internal loop of a multi-criteria offline analysis and an external loop of verifying the selected solution based on online indicators of user and economic response. **Results.** It is shown that the choice of a recommendation algorithm should not be based on a single local metric, since the quality of recommendations is determined by a set of multidirectional characteristics. The role of the integral criterion as the basis for preliminary comparison, ranking and tuning of algorithms before their implementation in the real digital environment is substantiated. **Practical significance.** The proposed approach can be applied by digital platforms, online stores, media services and other companies to make an informed choice of recommendation algorithms, adjust their hyperparameters and then check the impact of recommendations on user behavior and business results.

Keywords: recommendation systems, digital business environment, management decisions, multi-criteria assessment; integral indicator.

Funding. The work was carried out within the framework of the state assignment of the Ministry of Education and Science of the Russian Federation; project FEWM-2026-0011.

DOI: 10.21293/1818-0442-2026-29-1-152-159

References

1. Cheng H., Koc L., Harmsen J. Wide & deep learning for recommender systems. *Proceedings of the 1st Workshop on Deep Learning for Recommender Systems*, Boston, MA, USA, ACM, 2016, pp. 7–10.
2. Ghanem N., Leitner S., Jannach D. Balancing consumer and business value of recommender systems: a simulation-based analysis. *Electronic Commerce Research and Applications*, 2022, vol. 55, pp. 101195. DOI: 10.1016/j.elerap.2022.101195.
3. De Biasio A., Navarin N., Jannach D. Economic recommender systems – a systematic review. *Electronic Commerce Research and Applications*, 2024, vol. 63, pp. 101352. DOI: 10.1016/j.elerap.2023.101352.
4. Adomavicius G., Tuzhilin A. Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 2005, vol. 17, no. 6, pp. 734–749. DOI: 10.1109/TKDE.2005.99.
5. Gomez-Urbe C.A., Hunt N. The Netflix recommender system: algorithms, business value, and innovation. *ACM Transactions on Management Information Systems*, 2015, vol. 6, no. 4, pp. 1–19.
6. Zangerle E., Bauer C. Evaluating recommender systems: survey and framework. *ACM Computing Surveys*, 2022, vol. 55, no. 8, pp. 1–38. DOI: 10.1145/3556536.
7. Gunawardana A., Shani G., Yorgev S. Evaluating recommender systems. *Recommender Systems Handbook*, 2022, pp. 547–601. DOI: 10.1007/978-1-0716-2197-4_15.
8. Zheng Y., Wang D. A survey of recommender systems with multi-objective optimization. *Neurocomputing*, 2022, vol. 474, pp. 141–153. DOI: 10.1016/j.neucom.2021.11.041.

9. Jannach D., Abdollahpouri H. A survey on multi-objective recommender systems. *Frontiers in Big Data*, 2023, vol. 6, pp. 1157899. DOI: 10.3389/fdata.2023.1157899.

10. Jannach D., Jugovac M. Measuring the business value of recommender systems. *ACM Transactions on Management Information Systems*, 2019, vol. 10, no. 4, p. 1–23. DOI: 10.1145/3370082.

11. Castells P., Moffat A. Offline recommender system evaluation: challenges and new directions. *AI Magazine*, 2022, vol. 43, no. 2, pp. 225–238. DOI: 10.1002/aaai.12051.

12. Kulshin R.S., Sidorov A.A. An Entropy-Based Composite Indicator for Evaluating the Effectiveness of Recommender System Algorithms. *Control Sciences*, 2024, vol. 4, pp. 37–51. DOI: 10.25728/cs.2024.4.4.

13. Gilotte A., Calauzènes C., Nedelec T. Offline A/B testing for recommender systems. Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining, Marina Del Rey, USA, ACM, 2018, pp. 198–206.

14. Kulshin R.S., Sidorov A.A. [Optimization of hyperparameters of recommendation algorithms through a single evaluation metric]. *Software Engineering*, 2026, vol. 17, no. 2, pp. 67–82, DOI: 10.17587/prin.17.67-82 (in Russ.).

15. Quin F., Weyns D., Galster M., Silva C. A/B testing: a systematic literature review. *Journal of Systems and Software*, 2024, vol. 211, pp. 112011, DOI: 10.1016/j.jss.2024.112011.

16. Jeunen O., Baweja S., Pokharna N., Ustimenko A. Powerful A/B-testing metrics and where to find them. Proceedings of the 18th ACM Conference on Recommender Systems,

New York, ACM, 2024, pp. 816–818, DOI: 10.1145/3640457.3688036.

Roman S. Kulshin

Postgraduate student, Senior Lecturer,
Department of Data Processing Automation,
Tomsk State University of Control Systems
and Radioelectronics (TUSUR)
40, Lenin Ave., Tomsk, Russia, 634050
ORCID: 0000-0002-6891-1869
Phone: +7-923-721-35-98
Email: roman.s.kulshin@tusur.ru

Anatoly A. Sidorov

Candidate of economic sciences, Head,
Department of Data Processing Automation, TUSUR
40, Lenin Ave., Tomsk, Russia, 634050
ORCID: 0000-0002-9236-3639
Phone: +7 (382-2) 41-41-31
Email: anatii.a.sidorov@tusur.ru

Received: 14.04.2026.

Accepted: 22.05.2026.