

Персонализация на микроуровне: гибридная модель подбора заданий в образовательных системах

А.В. ЖИВЕТЬЕВ

Государственный университет «Дубна», г. Дубна, Россия

Аннотация. Статья посвящена разработке гибридной модели подбора заданий на микроуровне в адаптивных образовательных системах. В отличие от традиционных подходов, основанных на фиксированных тестах, предложенный метод учитывает индивидуальные особенности обучающегося при выборе каждого следующего задания. Теория отклика на задание (Item Response Theory, IRT) обеспечивает математическую строгость и возможность вычисления информативности элементов. Нечеткая логика служит инструментом работы с неопределенностью и корректировки выбора в условиях близких значений информативности. Модель многорукого бандита задает стратегию балансирования между исследованием и эксплуатацией. Интеграция этих трех подходов формирует итеративный цикл, включающий инициализацию на основе экспертной оценки, обновление параметров способности обучающегося, расчет информативности, выбор оптимального элемента и его корректировку с помощью нечетких правил. Практическая значимость исследования заключается в применимости модели в системах компьютерного адаптивного тестирования, интеллектуальных тьюторских системах и онлайн-курсах.

Ключевые слова: адаптивное тестирование, персонализация на микроуровне, Item Response Theory (IRT), нечеткая логика, многорукий бандит, информативность задания, гибридные модели, образовательная аналитика, интеллектуальные тьюторские системы, диагностика знаний.

DOI: 10.14357/20790279250402 **EDN:** ANHUZP

Введение

В условиях цифровой трансформации образования ключевой задачей становится разработка методов персонализации обучения, позволяющих учитывать индивидуальные особенности каждого учащегося. Особый интерес представляет персонализация на микроуровне — выбор конкретного задания в каждый момент взаимодействия с системой. Такой подход принципиально отличается от построения образовательных траекторий, так как фокусируется не на общей последовательности модулей или курсов, а на точечном подборе заданий, обеспечивающих максимальную информативность процесса.

Классическая модель тестирования предполагает формирование для каждого обучающегося фиксированного набора заданий случайного уровня сложности. В результате слабый студент может получить непропорционально трудный тест, а сильный — чрезмерно легкий, что искажает оценку их знаний.

Разработка тестовых заданий и обработка результатов тестирования очень важны, однако не меньшее значение имеет порядок предъявления за-

даний обучаемому и метод определения его уровня знаний по результатам тестирования, т.е. модель тестирования. При измерении уровня знаний согласно классической модели тестирования, для каждого обучающегося формируется тест определенной длины из выбранных случайным образом заданий тестового пространства. При этом тесты отличаются по сложности, и итоговая оценка формируется по числу правильных ответов с учетом весовых коэффициентов заданий. Недостатком такого тестирования может быть появление ситуаций, когда слабому студенту попадает сложный тест и как следствие этого — практическое отсутствие ответов. С другой стороны сильный студент может получить легкий тест и не реализовать свои способности. Для обеспечения максимальной информативности результатов контроля необходимо, чтобы средняя сложность предъявляемого обучаемому теста соответствовала его гипотетическому уровню обученности. Практически это можно осуществить с помощью адаптивного тестирования [1].

В статье предлагается гибридный метод подбора заданий на микроуровне, объединяющий IRT

(Item Response Theory), нечеткую логику и модель многорукого бандита. Такой подход обеспечивает одновременно точность диагностики и гибкость адаптации, сокращая количество заданий и снижая нагрузку на обучающегося.

1. Теоретико-методологическая база

Традиционные методы контроля знаний, основанные на фиксированных тестах, не учитывают динамику процесса и индивидуальные различия испытуемых. В то же время современные статистические и алгоритмические модели позволяют подбирать задания адаптивно. IRT представляет собой математическую модель анализа тестовых данных, которая выходит за рамки простого подсчета числа правильных ответов и позволяет одновременно оценивать уровень латентной способности испытуемого (например, знаний по математике или навыков чтения), а также параметры тестовых заданий, включая их сложность и способность различать участников с разным уровнем подготовки. К настоящему времени, за рубежом появились десятки тысяч научных исследований по IRT, возникла эффективная практика применения теории, на ее основе создаются адаптивные обучающие и контролирующие системы многих университетов и стран [2]. В IRT основной предмет исследования — формальные свойства каждого тестового задания. Эти свойства определяются по одной из математических моделей, применяемых к эмпирическим данным результатов испытуемых на данное задание [3].

Многорукий бандит — это алгоритм принятия решений, суть которого заключается в обеспечении баланса между исследованием и использованием (эксплуатацией) какого-то из рассматриваемых вариантов решения с целью максимизации целевой метрики и минимизации убытков [4].

В качестве компонента модели используется подход, ранее апробированный в [5]. В нем сложность заданий определяется экспертами и выражается в единицах сложности (ЕСЗ), а затем обрабатывается с использованием аппарата нечеткой логики. Такой механизм позволяет формализовать экспертные оценки через систему лингвистических переменных и правил («низкая», «средняя», «высокая» сложность), обеспечивая более гибкий выбор заданий в условиях неопределенности. В предлагаемой гибридной модели данный компонент служит основой для корректировки процесса подбора заданий на микроуровне: он позволяет сглаживать колебания, возникающие при чисто статистическом выборе на базе IRT, и тем самым

повышает устойчивость системы при работе с реальными учащимися.

2. Модель подбора заданий

При проектировании систем персонализации на микроуровне ключевой задачей является выбор следующего задания, которое будет предъявлено учащемуся. Этот выбор должен учитывать как статистические характеристики заданий, так и индивидуальные особенности обучающегося, доступные в его цифровом профиле [6], тем самым обеспечивая баланс между точностью диагностики и поддержанием мотивации. Для решения данной задачи целесообразно опираться на интеграцию методов IRT и нечеткой логики.

IRT предоставляет формальный статистический аппарат для описания связи между ответами учащихся и их скрытой способностью (θ). В рамках IRT каждое задание характеризуется параметрами сложности (b), дискриминации (a) и угадывания (c), которые могут быть оценены на основе накопленных эмпирических данных. Таким образом, IRT позволяет вычислить информативность задания и использовать ее в качестве критерия при подборе вопросов. На ранних этапах функционирования системы параметры заданий могут задаваться экспертами через единицы сложности (ЕСЗ), что обеспечивает содержательную валидность и возможность запуска модели до накопления статистически значимых данных. Несовпадения между экспертной и статистической оценкой сложности несут дополнительную диагностическую ценность и позволяют корректировать качество заданий.

В то же время применение одних только статистических моделей не всегда обеспечивает устойчивость системы в реальном времени. На практике необходимо учитывать неопределенность и «мягкие» факторы, которые трудно формализовать в вероятностных терминах. Для этого целесообразно использовать методы нечеткой логики, позволяющие работать с лингвистическими переменными, такими как «слишком легкое», «оптимальное» или «слишком сложное» задание, а также «много» или «мало» времени до завершения теста. Нечеткий вывод на основе базы правил позволяет динамически корректировать сложность предъявляемых заданий, сглаживая резкие колебания и снижая риск перегрузки учащегося. Подобный подход ранее был апробирован в модели управления сложностью учебного курса [5].

Несмотря на преимущества комбинации IRT и нечеткой логики, остается вопрос стратегиче-

ской организации выбора заданий. IRT позволяет оценить информативность каждого элемента, а нечеткая логика — сгладить неопределенность и избежать перегрузки учащегося. Однако в реальном процессе тестирования система должна не только анализировать текущее состояние, но и выстраивать последовательность заданий так, чтобы балансировать между уточнением уже имеющихся оценок и исследованием новых областей знаний. Для решения этой задачи целесообразно обратиться к постановке задачи многорукого бандита, которая в явном виде формализует баланс между исследованием и эксплуатацией.

Классическая задача многорукого бандита формулируется как необходимость выбора на каждом шаге одного из множества «автоматов» (рукавов), каждый из которых дает вознаграждение по случайному закону с неизвестным распределением. Впервые она была сформулирована в [7].

Если перенести эту постановку в область адаптивного обучения, можно рассматривать учебные задания как аналоги таких автоматов. Каждое задание обладает неизвестной для системы характеристикой — вероятностью того, что конкретный студент решит его правильно. Эта вероятность зависит от параметров задания и от текущего уровня знаний обучающегося.

Таким образом:

- Автоматы (рукава) = задания из банка тестов.
- Вознаграждение = результат ответа обучающегося. Например, «1» за правильный ответ, «0» за ошибку. Шкалу можно регулировать – в разных моделях IRT доступны соответствующие параметры.
- Стратегия выбора = алгоритм адаптивного подбора заданий, который балансирует между исследованием (подача новых заданий для уточнения оценки уровня знаний) и использованием (подача заданий, наиболее соответствующих текущей модели знаний студента).

В задаче многорукого бандита существует широкий спектр алгоритмов, различающихся по способу балансировки между исследованием и использованием. Наиболее простые стратегии, такие как ϵ -greedy, обеспечивают базовый уровень адаптивности, но в образовательном контексте их применение ограничено: случайный выбор заданий может приводить к предъявлению слишком легких или чрезмерно трудных вопросов, что снижает эффективность диагностики знаний. Более изощренные методы, например UCB, позволяют управлять этим балансом за счет выбора заданий с учетом неопределенности в оценке их параметров. Такой подход более органично вписывается в зада-

чи адаптивного тестирования, где важно не только фиксировать успехи, но и уточнять модель уровня знаний учащегося.

Особое внимание заслуживает Thompson Sampling, который опирается на вероятностные (байесовские) оценки распределений успешности и тем самым естественным образом интегрируется с моделями типа IRT. Данный метод обеспечивает гибкое сочетание диагностической функции (исследование) и обучающей (подбор заданий в зоне ближайшего развития). Наконец, развитие идей бандита привело к постановке контекстных моделей, где выбор задания осуществляется с учетом индивидуальных характеристик обучающегося и его образовательной траектории. Такой подход представляется наиболее перспективным для систем персонализированного обучения, поскольку позволяет учитывать не только средние вероятности успеха, но и богатый контекст — от текущего уровня знаний до особенностей когнитивного профиля, например, определяемого с потока видеокamеры [8]. Подробно алгоритмы описаны в [9].

Алгоритм подбора заданий в системе персонализации на микроуровне строится как итеративный цикл, в котором объединяются три подхода: статистическое моделирование (IRT), механизмы работы с неопределенностью (нечеткая логика) и алгоритмы оптимизации выбора (многорукий бандит).

1. Инициализация. При старте тестирования выбор первых заданий осуществляется на основе экспертной оценки сложности [5]. Это позволяет запускать алгоритм без предварительной калибровки параметров и гарантирует содержательную валидность.
2. Оценка способности (IRT). После каждого ответа пересчитывается скрытая способность обучающегося (θ) с использованием IRT-модели. Параметры заданий (a , b , c) фиксированы (получены ранее либо заданы экспертно на старте).
3. Расчет информативности (IRT). Для каждого доступного задания вычисляется информативность $I(\theta)$, отражающая ценность данного элемента для уточнения уровня θ . Формируется подмножество кандидатов с наибольшим значением $I(\theta)$.
4. Баланс исследования и эксплуатации (многорукий бандит). Среди кандидатов применяется стратегия многорукого бандита. Каждое задание рассматривается как «рука автомата», а вознаграждением выступает прирост информации о θ . Алгоритмы (например, ϵ -greedy, UCB или Thompson Sampling) позволяют балансировать между эксплуатацией (выбором задания, уже показавшего высокую информативность для текущего уровня θ) и исследованием (выбором

задания с неопределенной, но потенциально ценной информативностью).

5. Нечеткий селектор. Результаты выбора дополняются процедурой нечеткой логики, которая выступает как корректирующий слой. Она не изменяет параметры заданий, а выполняет роль устойчивого фильтра: если несколько заданий эквивалентны по информативности и стратегии бандита, то предпочтение отдается элементу с более «сбалансированным» рассогласованием $|\theta - b|$, либо с учетом регламентных факторов (например, оставшегося времени).
6. Предъявление и обновление. Выбранное задание предъявляется обучающемуся. После ответа обновляется только θ , а данные накапливаются для последующей офлайн-калибровки параметров заданий. Экспертные оценки и IRT-параметры остаются неизменными в онлайн-режиме.

Такой алгоритм сочетает преимущества трех подходов: IRT обеспечивает математическую строгость оценки способности, многорукий бандит задает стратегию оптимального выбора в условиях неопределенности, а нечеткая логика выступает механизмом адаптивной коррекции, повышающим устойчивость и гибкость работы системы.

Заключение

Предложенная гибридная модель подбора заданий может быть использована в системах компьютерного адаптивного тестирования, электронных образовательных платформах и интеллектуальных тьюторских системах. На микроуровне она позволяет повысить точность диагностики способностей учащегося за счет использования IRT и обеспечить гибкость адаптации благодаря методам нечеткой логики. Включение алгоритмов многорукого бандита открывает возможность стратегического управления процессом выбора, что особенно актуально при больших банках заданий.

Практическая значимость модели заключается в оптимизации длины тестирования и исключении избыточных заданий, что делает процесс более комфортным для обучающихся и эффективным для преподавателей. В перспективе модель может быть расширена за счет интеграции дополнительных источников данных, таких как время ответа, паттерны ошибок или метаданные о заданиях, а также за счет адаптации алгоритмов многорукого бандита к образовательным задачам.

Литература

1. Использование теории тестовых заданий (Item Response Theory) в адаптивном тестировании [Электронный ресурс]. – URL: [https://science.fandom.com/ru/wiki/Использование_Теории_тестовых_заданий_\(Item_Response_Theory\)_в_адаптивном_тестировании](https://science.fandom.com/ru/wiki/Использование_Теории_тестовых_заданий_(Item_Response_Theory)_в_адаптивном_тестировании) (дата обращения: 29.09.2025)
2. Родионов А.В., Братищенко В.В. Применение IRT-моделей для анализа результатов обучения в рамках компетентного подхода // Современные проблемы науки и образования. 2014. № 4.
3. Аванесов В. История педагогической теории измерений // Педагогические измерения. 2012. №3. URL: <https://cyberleninka.ru/article/n/istoriya-pedagogicheskoy-teorii-izmereniy> (дата обращения: 29.09.2025).
4. Бутко А.М. А/В тестирование и многорукие бандиты как способы сегментного тестирования продукта / А.М. Бутко // Молодежная школа-семинар по проблемам управления в технических системах имени А.А. Вавилова. 2023. Т. 1. С. 47-50.
5. Применение методов нечеткой логики для формирования адаптивной индивидуальной траектории обучения на основе динамического управления сложностью курса / М. А. Белов, С. И. Гришко, А. В. Живетьев [и др.] // Моделирование, оптимизация и информационные технологии. 2022. Т. 10. № 4(39). С. 7-8. DOI 10.26102/2310-6018/2022.39.4.018.
6. Живетьев А.В., Белов М.А. Проблемы управления индивидуальной образовательной траекторией студента на основе цифрового профиля и цифрового следа // Системный анализ в науке и образовании. 2024. № 4. С. 37–44.
7. Robbins H. Some aspects of the sequential design of experiments // Herbert Robbins selected papers. New York: Springer. 1985. P. 169–177.
8. Живетьев А.В. Адаптивная выдача учебно-методических материалов на основе моделей нейролингвистического программирования по результатам оценки позы учащегося за компьютером или в аудитории средствами машинного обучения / А. В. Живетьев, М. А. Белов // Computational Nanotechnology. 2024. Т. 11. № 3. С. 81-88. DOI 10.33693/2313-223X-2024-11-3-81-88.
9. Смирнов Д.С. Модель принятия решений при наличии экспертов как модифицированная задача о многоруком бандите / Д. С. Смирнов, Е. В. Громова // Математическая теория игр и ее приложения. 2017. Т. 9. № 4. С. 69-87.

Живетьев Александр Викторович. Федеральное государственное бюджетное образовательное учреждение высшего образования «Университет «Дубна», г. Дубна, Россия. Аспирант. Область научных интересов: цифровые профили, рекомендательные системы, автоматизация управления образовательным процессом, ИИ в образовании. E-mail: zhivetyev@gmail.com

Personalization at the Micro Level: A Hybrid Model for Task Assignment in Educational Systems

A. V. Zhivetyev

Dubna State University, Dubna, Moscow region, Russia

Abstract. This paper presents a hybrid model for item-level selection in adaptive educational systems. Unlike traditional approaches based on fixed tests, the proposed method enables real-time personalization by selecting each subsequent task according to the learner's individual profile. Item Response Theory (IRT) provides mathematical rigor and allows estimation of item informativeness; fuzzy logic serves as a mechanism for handling uncertainty and refining the choice when items have similar informativeness, thereby increasing system stability; and the multi-armed bandit model introduces a strategy for balancing exploration and exploitation, which is particularly important when working with large item banks. The integration of these three approaches forms an iterative cycle that includes initialization based on expert difficulty ratings, updating of learner ability parameters, calculation of informativeness, selection of the optimal item, and its adjustment using fuzzy rules. This hybrid approach improves diagnostic accuracy, reduces the number of items administered, and lowers cognitive load. The practical significance of the research lies in its applicability to computer adaptive testing systems, intelligent tutoring systems, and online courses, offering promising prospects for the development of more flexible and intelligent tools for personalized learning.

Keywords: *adaptive testing; micro-level personalization; Item Response Theory (IRT); fuzzy logic; multi-armed bandit; item informativeness; hybrid models; learning analytics; intelligent tutoring systems; knowledge diagnostics.*

DOI: 10.14357/20790279250402 **EDN:** ANHUZP

References

1. Use of Item Response Theory in Adaptive Testing [Internet]. Available from: [https://science.fandom.com/ru/wiki/Использование_Теории_тестовых_заданий_\(Item_Response_Theory\)_в_адаптивном_тестировании](https://science.fandom.com/ru/wiki/Использование_Теории_тестовых_заданий_(Item_Response_Theory)_в_адаптивном_тестировании) [Accessed 2025 Sep 29].
2. Rodionov A.V., Bratishchenko V.V. Application of IRT models for analyzing learning outcomes within the competence-based approach. *Sovremennye problemy nauki i obrazovaniya*. 2014;(4). (In Russ).
3. Avanesov V. History of the pedagogical theory of measurements. *Pedagogicheskie izmereniya*. 2012;(3). Available from: <https://cyberleninka.ru/article/n/istoriya-pedagogicheskoy-teorii-izmereniy> [Accessed 2025 Sep 29]. (In Russ).
4. Butko A.M. A/B testing and multi-armed bandits as methods of product segment testing. In: *Molodezhnaya shkola-seminar po problemam upravleniya v tekhnicheskikh sistemakh im. A.A. Vavilova*. 2023;1:47–50. (In Russ).
5. Belov M.A., Grishko S.I., Zhivetyev A.V., et al. Application of fuzzy logic methods for forming an adaptive individual learning trajectory based on dynamic course complexity control. *Modelirovanie, optimizatsiya i informatsionnye tekhnologii*. 2022;10(4(39)):7–8. doi:10.26102/2310-6018/2022.39.4.018. (In Russ).
6. Zhivetyev A.V., Belov M.A. Problems of managing an individual educational trajectory of a student based on digital profile and digital footprint. *Sistemnyi analiz v nauke i obrazovanii*. 2024;(4):37–44. (In Russ).
7. Robbins H. Some aspects of the sequential design of experiments. In: *Herbert Robbins Selected Papers*. New York: Springer. 1985. P. 169–177.
8. Zhivetyev A.V., Belov M.A. Adaptive delivery of teaching materials based on neuro-linguistic programming models using machine learning to assess student posture at a computer or in a classroom. *Komp'yuternye nanotekhnologii*. 2024;11(3):81–88. doi:10.33693/2313-223X-2024-11-3-81-88. (In Russ).
9. Smirnov D.S., Gromova E.V. A decision-making model with experts as a modified multi-armed bandit problem. *Matematicheskaya teoriya igr i ee prilozheniya*. 2017;9(4):69–87. (In Russ).

Alexander V. Zhivetyev. Graduate Student, Dubna State University, Dubna, Moscow region, Russia. E-mail: zhivetyev@gmail.com