

РАЗРАБОТКА АДАПТИВНЫХ АЛГОРИТМОВ АВТОМАТИЗИРОВАННОГО ФОРМИРОВАНИЯ УПРАВЛЯЮЩИХ РЕШЕНИЙ В ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМАХ УПРАВЛЕНИЯ ОСТАТОЧНЫМИ ЗНАНИЯМИ ПЕРСОНАЛА

Тарасов Вячеслав Сергеевич

Аспирант,

Российский Технологический Университет МИРЭА

slavatarasov207@gmail.com

**DEVELOPMENT OF ADAPTIVE
ALGORITHMS FOR AUTOMATED
FORMATION OF CONTROL DECISIONS
IN INTELLIGENT SYSTEMS
FOR MANAGING RESIDUAL KNOWLEDGE
OF STAFF**

V. Tarasov

Summary. In the context of dynamic technological development and the imperative of continuous professional education (Life-Long Learning), increasing the effectiveness of in-house training (IFT) by optimizing the residual knowledge (RK) of employees is becoming critical. This research article is devoted to the development of scientific and methodological support for the automated formation of management decisions in organizational systems based on monitoring information on personnel performance. The intelligent core of the system is neuro-fuzzy networks of the Adaptive Resonance Theory (ART) family, in particular Fuzzy ARTMAP, the clustering results of which serve as the basis for generating targeted pedagogical and organizational interventions. A formalization of the problem of selecting the optimal control action is presented, and multi-level algorithms are developed that ensure the transition from cluster-oriented (group) recommendations to highly personalized interventions that take into account the detailed knowledge profile and contextual information of each employee. The developed approach enables the implementation of a closed-loop management of residual knowledge, significantly increasing the adaptability of educational trajectories and the overall competence of personnel.

Keywords: residual knowledge, continuous learning, Fuzzy ARTMAP, data clustering, intelligent decision support, control actions, personalization, organizational system.

Аннотация. В условиях динамичного технологического развития и императива непрерывного профессионального образования (Life-Long Learning), критически важным становится повышение эффективности внутрифирменного обучения (ВФО) за счет оптимизации остаточных знаний (ОЗ) сотрудников. Данная научная статья посвящена разработке научно-методического обеспечения для автоматизированного формирования управляющих решений в организационных системах, базирующихся на мониторинговой информации об успеваемости персонала. В качестве интеллектуального ядра системы используются нейро-нечеткие сети семейства Adaptive Resonance Theory (ART), в частности, Fuzzy ARTMAP, результаты кластеризации которых служат основой для генерации адресных педагогических и организационных воздействий. Представлена формализация задачи выбора оптимального управляющего воздействия, а также разработаны многоуровневые алгоритмы, обеспечивающие переход от кластерно-ориентированных (групповых) рекомендаций к высоко персонализированным интервенциям, учитывающим детальный профиль знаний и контекстную информацию каждого сотрудника. Разработанный подход позволяет реализовать замкнутый контур управления остаточными знаниями, существенно повышая адаптивность образовательных траекторий и общую компетентность персонала.

Ключевые слова: остаточные знания, непрерывное обучение, Fuzzy ARTMAP, кластеризация данных, интеллектуальная поддержка принятия решений, управляющие воздействия, персонализация, организационная система.

Введение

Актуальность проблемы управления качеством подготовки кадров в постиндустриальной экономике детерминирована быстрым устареванием профессиональных компетенций и необходимостью их непрерывного обновления. Традиционные образовательные парадигмы демонстрируют ограниченную эффективность в условиях, когда ключевым ресурсом выступает «интеллектуальный капитал» организации.

В этом контексте особую значимость приобретает задача объективной оценки и целенаправленного повышения уровня «остаточных знаний» — совокупности компетенций, сохраняющихся у специалиста после завершения формального или внутрифирменного образовательного цикла.

В анализе существующего ВФО и программ профессиональной переподготовки (ПП) были выявлены методологические ограничения существующих систем

контроля ОЗ и предложен «нейросетевой базис», представляющий модифицированные алгоритмы Fuzzy ART и Fuzzy ARTMAP для интеллектуального анализа мониторинговых данных об успеваемости сотрудников. Эти алгоритмы позволяют эффективно структурировать данные, классифицируя профили знаний персонала на гомогенные кластеры, что является фундаментом для «data-driven» управления.

Настоящая статья фокусируется на финальном и наиболее критичном этапе цикла управления: разработке «алгоритмов автоматизированного формирования управляющих решений». Эффективность системы определяется не только точностью диагностики классификации профилей ОЗ, но и адекватностью предписанных воздействий, направленных на минимизацию пробелов в когнитивных областях и закрепление усвоенного материала. Задача состоит в том, чтобы трансформировать диагностические данные принадлежности сотрудника к кластеру C_j в конкретные, применимые и оптимальные управляющие воздействия A^* , которые максимизируют целевые показатели повышения квалификации при рациональном использовании организационных ресурсов [12].

1. Формализация задачи генерации управляющих решений

Управляющее решение в контексте данной интеллектуальной системы определяется как дискретное воздействие или их комплекс, направленный на корректировку индивидуальной образовательной траектории сотрудника или стратегии обучения группы. Эти решения формируются на «микроуровне управления» и являются прямым ответом на выявленное состояние остаточных знаний [2].

1.1. Определение входных и выходных параметров

Формализация задачи основана на определении ключевых информационных векторов и целевой функции:

1. «Профиль знаний обучающегося S_i »: вектор признаков $x_i \in R^n$ (мониторинговые данные), характеризующий текущее состояние ОЗ сотрудника i в момент времени t . Включает баллы по темам, время реакции, активность в LMS (learning management system) и т.д.
2. Кластерное состояние C_j »: результат классификации i -го обучающегося, полученный с помощью Fuzzy ARTMAP.
3. Характеристики кластера P_j »: набор интегральных метрик, описывающих группу C_j :

- * μ_j : вектор средних баллов по темам.
- * σ_j : средняя дисперсия (показатель однородности кластера).
- * F_j : частота встречаемости критических пробелов, представляющих собой тем с баллом ниже порогового по каждой теме.
- * Λ_j : интегральный показатель сложности кластера, связанный с количеством и глубиной пробелов.

4. «Контекстная информация K_i »: данные, не включенные в профиль S_i , но влияющие на выбор воздействия в виде предпочтения формата обучения, доступное время, роль в проекте, история реакции на предыдущие рекомендации.
5. «Множество управляющих воздействий A »: дискретный набор возможных альтернатив $A = \{A_1, A_2, \dots, A_m\}$.

1.2. Оптимизационная модель выбора воздействия

Задача формирования управляющего решения для обучающегося i сводится к поиску оптимальной альтернативы $A^* \in A$, которая максимизирует «целевую функцию эффективности» E :

$$A^* = \operatorname{argmax}_{A \in A} E(A, S_i, K_i, P_j)$$

где функция E отражает прогнозируемый интегральный эффект от воздействия A .

2. Интегрированная Модель Генерации и Оптимизации Управляющих Воздействий (ИМГОУВ)

Для эффективной генерации решений ИМГОУВ использует иерархическую структуру, состоящую из двух ключевых уровней, что позволяет сбалансировать экономию ресурсов на групповом управлении с точностью, требуемой для индивидуальной персонализации:

1. «Генерация базовых кластерных рекомендаций»: ответ на общую проблему, свойственную кластеру C_j .
2. «Персонализация и приоритизация»: адаптация базовых рекомендаций с учетом S_i и K_i .

2.1. Алгоритм формирования базовых рекомендаций

Целью данного этапа является определение подмножества рекомендаций $R_{\text{баз},j} \subset A$, наиболее релевантных для большинства сотрудников, отнесенных к кластеру C_j .

Вход: Характеристики кластера $P_j = \{\mu_j, \sigma_j, F_j, \Lambda_j\}$,
 Тип кластера.

Выход: Набор базовых рекомендаций $R_{\text{баз},j}$.

Таблица 1.

Кластеры остаточных знаний и соответствующие им базовые управляющие решения

Тип Кластера (Пример)	Диагностические Критерии	Базовые Рекомендации (баз)	Rationale (Педагогическая цель)
Высокий уровень ОЗ	$\mu_j > T_{\text{high}}, \Lambda_j$ низкая	A_6 (Углубленные материалы), A_5 (Участие в проекте)	Стимулирование дальнейшего развития, предотвращение демотивации
Пробелы в базовых знаниях	$F_{jk} > T_{\text{частота}}$ для $k \in \text{База}$	A_1^k (Доп. материалы по k), A_2^k (Практика по k), A_4 (Консультация)	Целенаправленное устранение фундаментных когнитивных дефицитов
Неравномерное усвоение	σ_j высокая, Λ_j умеренная	A_7 (Смена стратегии само работы), A_3 (Повторное тестирование)	Оптимизация мета когнитивных навыков и саморегуляции обучения

Алгоритм иницирует $R_{\text{баз},j}$ как пустое множество и наполняет его в соответствии с predetermined системой правил, основанной на пороговых значениях T . Например, если Λ_j превышает порог $T_{\text{сложность}}$, система автоматически включает в $R_{\text{баз},j}$ рекомендацию A_4 , поскольку сложная структура пробелов требует непосредственного вмешательства наставника. Этот механизм обеспечивает быструю реакцию системы на коллективные проблемы, снижая потребность в индивидуальном диагностировании для каждой типовой ситуации.

2.2. Алгоритм персонализации и формирования финальных рекомендаций

Переход от $R_{\text{баз},j}$ к индивидуально оптимизированному воздействию A_i^* требует учета текущего микросостояния сотрудника S_j и его контекстных особенностей K_j .

Вход: $R_{\text{баз},j}$, Профиль знаний S_j , Контекстная информация K_j .

Выход: Финальный набор рекомендаций A_i^* .

Процесс персонализации реализуется через три основные функции: «Подавление, Уточнение и Добавление».

2.2.1. Подавление (Elimination)

Функция «Подавления» предотвращает назначение избыточных интервенций, что является критичным для сохранения мотивации и эффективного использования ресурсов.

Если базовая рекомендация $A \in R_{\text{баз},j}$ направлена на тему k , но детальный профиль S_j показывает, что текущий уровень знаний x_{jk} по этой теме превышает $T_{\text{достаточно}}$ (например, сотрудник уже самостоятельно устранил пробел), то A исключается из набора $R_{\text{перс},j}$.

Это соответствует принципу «пластичности» ART-сети, где индивидуальные изменения даже при сохранении общей кластерной принадлежности моментально отражаются в управляющем контуре [2].

2.2.2. Уточнение (Refinement)

Функция «Уточнения» адаптирует формат и интенсивность воздействия A к предпочтениям и ограничениям K_j сотрудника.

Правило 1: если $A = A_1$ дополнительный материал и K_j содержит предпочтение 'Видео-лекции', то A_1 трансформируется в «Рекомендация видео-лекций по теме k ».

Правило 2: если $A = A_2$ практические задачи и K_j сигнализирует о высокой текущей занятости 'Дефицит времени', то A_2 адаптируется до «Набор из 5 коротких, сфокусированных задач», что минимизирует временные затраты при сохранении обучающего эффекта.

2.2.3. Добавление (Augmentation)

Функция «Добавления» использует «контекстную информацию K_j », включая связи между когнитивными областями, для создания связанных, кросс-доменных рекомендаций.

Правило: если $R_{\text{перс},j}$ содержит рекомендацию по теме k , и K_j указывает на высокий интерес к смежной теме k' например, k — «Основы SQL», k' — «Анализ данных», то добавляется воздействие $A_6^{k \rightarrow k'}$: «Углубленный материал по применению k в контексте k' ».

Этот механизм способствует «глубокому обучению» и переходу от разрозненных остаточных знаний к интегрированным профессиональным компетенциям.

2.3. Приоритизация и финальная генерация

После этапов подавления, уточнения и добавления, набор $R_{\text{перс},j}$ приоритизируется. Приоритизация основывается на:

1. Критичности пробела: те темы, где x_{jk} имеет минимальное значение, получают наивысший приоритет.
2. Организационной важности: Учет экспертно заданных весов важности для каждой темы, определяемых управляющей организацией ВФО.

Результатом является финальный, упорядоченный набор управляющих воздействий A_i^* , готовый к автоматической передаче в модуль исполнения ИТ-системы.

3. Модель оценки эффективности управляющих решений

Автоматизированный выбор оптимального воздействия A^* требует количественной оценки его потенциальной эффективности E . Поскольку функция E является многокритериальной, ее структура должна отражать баланс между образовательным результатом и операционными затратами [4].

$$E(A, S_i, K_i, P_j) = \sum_{k=1}^L w_k \cdot E_k(A, S_i, K_i)$$

Где E_k — оценка по k -му критерию, а w_k — весовой коэффициент критерия.

3.1. Ключевые критерии оценки

Таблица 1.

Критерии оценки эффективности управляющих решений

Критерий ()	Описание	Формализация
E_{gain} (Прогнозируемый прирост знаний)	Ожидаемое количественное изменение x_{jk} после применения A .	Предиктивная модель (например, на основе регрессии, обученной на исторической динамике).
E_{cost} (Затраты ресурсов)	Время наставника, стоимость материалов, время сотрудника.	Нормализованная функция затрат $C(A)$ (чем ниже затраты, тем выше E_{cost}).
E_{fit} (Соответствие)	Насколько A соответствует индивидуальным предпочтениям K_i (формат, время).	Бинарная или нечеткая мера соответствия $f(A, K_i)$.
E_{risk} (Снижение риска)	Вероятность, что неназначение A приведет к критической ошибке в профессиональной деятельности.	Функция, обратно пропорциональная F_j и Δ_j по критическим темам.

3.2. Адаптация весовых коэффициентов

Для обеспечения адаптивности системы весовые коэффициенты w_k не должны быть статичными. Они должны динамически корректироваться на основе анализа фактических результатов.

Если после применения воздействия A произошло значительное улучшение профиля S_i то есть фактический прирост ΔS_i превысил прогнозируемый E_{gain} , веса критериев, способствовавших выбору A , должны быть усилены. И наоборот, если воздействие A оказалось неэффективным несмотря на высокий прогнозируемый E_{gain} , веса, ассоциированные с этим выбором, должны быть понижены.

Данный механизм реализуется через «замкнутый контур управления» (feedback loop), где исторические данные об эффективности воздействий используются для «обучения предиктивной модели» например, алгоритма регрессии или Reinforcement Learning, которая постоянно уточняет веса w_k . Это позволяет системе эволюционировать, адаптируясь к меняющимся паттернам усвоения знаний в организационной среде.

4. Интеграция алгоритмов в Информационную Технологию

Разработанные алгоритмы генерации управляющих решений являются ключевым компонентом «Модуля формирования управляющих решений» в общей архитектуре ИТ управления остаточными знаниями.

Модуль функционирует следующим образом:

1. Прием диагностических данных: получение кластерного идентификатора C_j , параметров P_j , а также профиля S_i и контекста K_i от «Модуля интеллектуального анализа» Fuzzy ARTMAP.
2. Генерация базовых рекомендаций: применение алгоритмов группового уровня для формирования $R_{баз,j}$.
3. Персонализация: Применение функций «Подавления», «Уточнения» и «Добавления», а также расчет оценки эффективности E для каждой альтернативы.
4. Выбор A_i^* : выбор оптимального воздействия A_i^* путем максимизации E .
5. Исполнение: передача A_i^* через «Модуль интеграции» в LMS для автоматического назначения материалов или в интерфейс наставника для организационных задач типа A_4 или A_5 [8].

Использование четкой иерархии правил и верифицируемой функции E делает процесс принятия решений «интерпретируемым», позволяя управляющему персо-

налу понимать логику, на основе которой были назначены те или иные рекомендации.

Заключение

В настоящей статье представлена концепция и детальная алгоритмическая реализация интеллектуальной поддержки принятия управленческих решений, направленной на оптимизацию остаточных знаний сотрудников в рамках непрерывного образовательного процесса.

Разработанные методы и алгоритмы обеспечивают полную автоматизацию контура управления остаточными знаниями, снижая операционную нагрузку на управляющий персонал и гарантируя, что каждый сотрудник получает своевременные, адресные и оптимальные рекомендации, способствующие устойчивому повышению его профессиональной компетентности и, как следствие, общей производительности организационной системы.

ЛИТЕРАТУРА

1. Grossberg S. Adaptive Resonance Theory / S. Grossberg // Encyclopedia of Machine Learning. — 2011. — DOI: 10.1007/978-0-387-30164-8_11.
2. Artificial Intelligence: Adaptive Resonance Theory (ART) // GeeksforGeeks. — URL: <https://www.geeksforgeeks.org/artificial-intelligence/adaptive-resonance-theory-art/>
3. R.J. Sethi, Essential Computational Thinking: Computer Science from Scratch. Cognella Academic Publishing, 2020
4. C. Mahoney, P. Gronvall, N. Huber-Fliflet, and J. Zhang, "Explainable Text Classification Techniques in Legal Document Review: Locating Rationales without Using Human Annotated Training Text Snippets," in 2022 IEEE International Conference on Big Data (Big Data). Osaka, Japan: IEEE, Dec. 2022, pp. 2044–2051.
5. "On minimizing cost in legal document review workflows," arXiv:2106.09866 [cs], Jun. 2021
6. S. Grossberg, "Toward Autonomous Adaptive Intelligence: Building Upon Neural Models of How Brains Make Minds," IEEE Transactions on Systems, Man, and Cybernetics: Systems, vol. 51, no. 1, pp. 51–75, Jan. 2021.
7. E. Yang, S. MacAvaney, D.D. Lewis, and O. Frieder, "Goldilocks: Justright tuning of BERT for technology-assisted review," arXiv:2105.01044, [cs], May 2021
8. R. Keeling, R. Chhatwal, P. Gronvall, and N. Huber-Fliflet, "Humans Against the Machines: Reaffirming the Superiority of Human Attorneys in Legal Document Review and Examining the Limitations of Algorithmic Approaches to Discovery," Richmond Journal of Law & Technology, vol. 26, no. 3, p. 65, 2020.
9. L. McInnes, J. Healy, and J. Melville, "UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction," Sep. 2020.
10. Xu R., & Wunsch II, D.C. (2005). "Survey of clustering algorithms." IEEE transactions on neural networks, 16(3), 593–611
11. Turban E. Decision Support and Business Intelligence Systems / E. Turban, J.E. Aronson, T.-P. Liang, R. Sharda. — 8th ed. — Pearson Prentice Hall, 2007. — 772 p.
12. Holsapple C.W. (2003). Handbook on Knowledge Management: Foundations, Processes, and Services. Springer