Разработка контекстно-ориентированного интерпретатора с обратной связью (CAFI) для гибридной интеллектуальной системы управления обучением

А.В. Петровский
ГБПОУ МО «Колледж Подмосковье»

Аннотация. В статье предлагается архитектура гибридной интеллектуальной системы управления обучением (LMS) на основе контекстно-ориентированного интерпретатора с обратной связью (CAFI). Система решает проблемы интеграции нейросетевых моделей BERT, LSTM и GNN, преодолевая ограничения отдельных архитектур: проблему межмодульного взаимодействия и интерпретацию выводов с учётом образовательной специфики. Новизна подхода заключается в мультилинейном слиянии выводов трёх сетей через управляемое тензорное произведение и построении непрерывного семантического поля конфликтов, градиент которого используется для коррекции ошибок и обновления онтологии. Экспериментально показано повышение точности (Accuracy 0.88 ± 0.01), снижение ошибок прогнозирования (RMSE 0.14 ± 0.01) и рост интерпретируемости (SHAP $> 2.4\times$) по сравнению с базовой гибридной архитектурой. Статистическая значимость подтверждена t-критерием Стьюдента ($p < 0.01$).

Ключевые слова: гибридная интеллектуальная система управления обучением, нейросетевая архитектура, интерпретация данных, ансамблирование, оркестрация, мультимодальные данные, BERT, CAFI, GNN, LSTM.

Обозначения и сокращения

Обозначение	Значение
CAFI	Context-Aware Feedback Interpreter — контекстно-ориентированный интерпретатор с обратной связью
LMS	Learning Management System — система управления обучением
GNN	Graph Neural Network — графовая нейронная сеть
LogPy	Библиотека символьной логики Python
SRL	Symbolic Reasoning Logic — движок символьной логики (библиотека LogPy)
VAE	Variational Autoencoder — вариационный автоэнкодер
XAI	Explainable Artificial Intelligence — объяснимый ИИ
$\Phi(v)$	Семантическое поле конфликтов
$\nabla\Phi(v)$	Градиент семантического поля
τ	Порог конфликта
η	Шаг градиентной коррекции
D	Размерность векторного пространства
N	Количество узлов в графе
R	Количество правил

1. Введение. Современная парадигма электронного персонализированного обучения требует перехода от статичных систем к динамичным гибридным интеллектуальным средам, которые не только автоматизируют рутинные задачи, но и осуществляют адаптивную персонализацию обучения, подстраиваясь под индивидуальные потребности, темп и стиль студента [3, 20]. Практическая востребованность таких систем подтверждается результатами внедрения нейросетевой адаптивной LMS в пяти российских вузах: точность прогнозирования успеваемости достигла 92,3%, а успеваемость студентов экспериментальной группы повысилась на 18,1% [2]. Однако разнородность образовательных данных - от количественных показателей успеваемости и качественных текстов ответов до мультимедийного контента и структурных связей между компетенциями - требует принципиально разных методов обработки, что делает неэффективным изолированное применение отдельных нейросетевых архитектур.

Трансформеры, предложенные для обработки текста [21], позднее были адаптированы к мультимедийным данным (ViT, TimeSformer), однако их применение к длинным последовательностям ограничено квадратичной сложностью самовнимания $O(n^2)$, что требует дополнительных надстроек (Sparse attention, Longformer и др.). Кроме того, как показано в работе [12], трансформерные модели способны генерировать грамматически корректные, но семантически или логически ошибочные выводы, поскольку механизм внимания опирается на статистические закономерности, а не на формализованные правила предметной области. В образовательном контексте это может проявляться, к примеру, в рекомендации изучения интегралов до освоения производных — модель не учитывает пререквизитные связи между темами.

Рекуррентные сети, предназначенные для обработки последовательностей, страдают от проблемы исчезающего градиента при анализе длинных образовательных траекторий [10]. Авторы [4] установили, что система отслеживания знаний на базе однослойной LSTM эффективно моделирует временные последовательности ответов, однако неспособна выявлять глобальные зависимости между разрозненными темами курса без дополнительных механизмов внимания. В свою очередь, графовые нейронные сети эффективно моделируют структурные связи между компетенциями, однако критически зависят от качества исходной формализации графа знаний. В публикации [15] учебный курс представлен в виде графа, вершины которого обозначают учебные концепции, а ребра — пререквизитные связи, что позволяет модели распространять сигналы об усвоении базовых тем на зависимые разделы; при этом искажения структуры графа существенно снижают точность прогнозирования успеваемости.

Таким образом, постановку проблемы можно разделить надвое. Техническую проблематику составляют сложность настройки межмодульного взаимодействия из-за жесткого кодирования связей, трудоемкости интеграции новых компонентов и высоких требований к аппаратным ресурсам. Когнитивные и интерпретационные проблемы включают невозможность формализации субъективных смыслов и неявных связей между компетенциями, риск искажения знаний при переносе между модулями («эффект испорченного телефона») и низкую интерпретируемость моделей (эффект «черного ящика»), критичную для принятия решений в образовании.

Целью настоящей работы является повышение эффективности и интерпретируемости гибридных систем управления обучением за счет трансформации их из набора изолированных моделей в саморегулирующуюся среду. Для достижения цели решаются следующие задачи: разработка архитектурного слоя-арбитра CAFI; реализация мультилинейного слияния выводов через тензорный мост; построение непрерывного семантического поля конфликтов; реализация градиентной коррекции и замкнутого цикла самообучения; экспериментальное сравнение с базовой архитектурой.

Научная новизна заключается во введении авторского метода CAFI — централизованного оркестратора и контекстно-зависимого интерпретатора. Основные инновации: тензорный мост, захватывающий взаимодействия высших порядков; семантическое поле конфликтов, показывающее степень нарушения правил; градиентная коррекция, плавно перемещающая вывод в зону валидности; обновление онтологии из градиента, обеспечивающее автоматическую формализацию знаний.

2. Обзор родственных разработок. Анализ современной практики объединения нейромоделей позволил выявить два доминирующих подхода к созданию сложных гибридных систем: объединение данных - мультимодальные модели и объединение моделей: параллельное - ансамблирование и последовательное - оркестрацию. Мультимодальные нейросети, такие как CLIP и BLIP, интегрируют энкодеры разных модальностей в единое пространство. Их архитектура включает кодировщик изображений (на базе *CNN*) и кодировщик текста (на базе *Transformer*). В процессе совместного обучения на парах «текст — изображение» модель настраивает эти сети так, чтобы эмбеддинги семантически связанных данных были близки в общем пространстве признаков. Это позволяет решать задачи

семантического поиска и анализа мультимедийного образовательного контента, включая инфографику и видео, но не предоставляет механизмов проверки семантической непротиворечивости.

Ансамблирование, включающее техники Stacking и Voting, предполагает агрегирование выводов нескольких моделей для снижения дисперсии и систематической ошибки. В контексте LMS ансамблирование может применяться для агрегации оценок от моделей, анализирующих разные аспекты студенческой работы. Однако данный подход статичен: он усредняет ошибки, не решая проблему их источника. Если все модели систематически ошибаются на определенном типе данных, ансамбль воспроизведет эту ошибку.

Более сложной схемой является оркестровка, где специальный компонент-диспетчер динамически управляет взаимодействием моделей, выбирая оптимальную последовательность их работы в зависимости от контекста запроса. Например, при анализе видеовопроса студента оркестратор может последовательно задействовать для построения релевантного ответа модель распознавания речи (*ASR*), модуль семантического поиска на основе векторных представлений и систему синтеза речи (*TTS*). Взаимодействие через *API*-интерфейсы обеспечивает модульность, но часто требует жесткой кодификации связей, что снижает гибкость системы.

Несмотря на значительный прогресс и высокую эффективность в задачах синтеза и анализа данных, существующие методы не решают в полной мере заявленные проблемы и остаются пассивным «чёрным ящиком»: они способны агрегировать предсказания, но не могут верифицировать их семантическую непротиворечивость. Статичность ансамблей и жесткая связность оркестраторов приводят к невозможности самообучения системы, мультимодальные модели объединяют данные, но не предоставляют механизмов для проверки семантической непротиворечивости выводов. Показательным примером являются современные российские разработки в области интеллектуальной поддержки обучения. В работе Т.Р. Шамсутдиновой [3] представлена концепция нейросетевой адаптивной обучающей среды NeuroSmart, архитектура которой представляет собой гибридный ансамбль сверточных и полносвязных сетей, объединенных через единую шину данных для подсистем биометрической идентификации пользователя, выбора индивидуальной образовательной траектории, автоматизированной проверки работ и мониторинга учебного процесса. В исследовании А.В. Подколзина [2] предложена интеллектуальная система адаптивного обучения на основе ансамбля сверточных и рекуррентных нейросетей, демонстрирующая высокую точность прогнозирования успеваемости. Данные архитектуры объединяет общий системный недостаток: отсутствие механизмов семантической валидации нейросетевых выводов на соответствие формализованным правилам предметной области не только ограничивает прозрачность принимаемых системой решений, но из-за низкой интерпретируемости с высоким риском предвзятости подрывает доверие к ним со стороны преподавателя и студента, препятствуя надежной интеграции подобных систем в образовательные контуры LMS.

Исследователи отмечают, что в настоящее время проблема «черного ящика» в нейросетях решается через два взаимосвязанных подхода объяснимого ИИ (XAI): с одной стороны, это объяснимость (*Explainability*), обеспечивающая прозрачность и интерпретируемость процесса принятия решений для пользователя, с другой — каузабельность (*causability*) [10], предполагающая способность системы не просто описывать корреляции, но выявлять и объяснять причинно-следственные связи.

Существующие подходы интерпретации нейросетевых выводов XAI можно сгруппировать по их фундаментальному принципу действия. К первой категории относятся методы, зависящие от архитектуры (model-specific), ярким представителем которых является Grad-CAM. Их популярность обусловлена интуитивной понятностью, но за ней скрывается поверхностный анализ. По сути, это лишь апостериорная визуализация градиентов, не гарантирующая выявления истинных каузальных факторов. Они чувствительны к шуму и архитектурным особенностям сети, а их локальный характер не позволяет экстраполировать выводы на всё пространство признаков.

Вторую, более обширную группу образуют методы, не зависящие от архитектуры (model-agnostic). Внутри этой категории можно выделить подходы на основе возмущений (perturbation-based), такие как LIME и Occlusion Sensitivity, которые исследуют влияние изменения входных данных на выход модели. Их основными недостатками являются нестабильность и сильная зависимость от выбора окрестности и параметризации интерпретатора. К этой же группе относятся и методы атрибуции (feature attribution), например SHAP и Integrated Gradients, претендующие на количественную оценку вклада признаков, но страдающие от непомерных вычислительных затрат.

В качестве альтернативы используются внутренне интерпретируемые модели (intrinsically interpretable), но этот путь сопряжён с компромиссом: повышение прозрачности достигается ценой катастрофического падения точности на данных со сложной нелинейной структурой.

Вне этого спектра статичных post-hoc объяснений остаются более фундаментальные подходы. К ним относятся нейросимволический ИИ [8], который позволяет формализовать знания предметной области в виде логических правил или онтологий для валидации выводов нейросетей и обеспечения их соответствия установленным аксиомам, а также анализ чувствительности (Sensitivity Analysis), оценивающий уязвимость модели к малым изменениям входов или внутренних параметров. Хотя парадигма и выглядит многообещающей, её реализация сталкивается с проблемой «узких мест» при извлечении знаний.

Основной же пробел современной парадигмы XAI заключается в её статичности: доминирующие методы интепретации представляют собой набор разрозненных инструментов и носят описательный, а не предписывающий характер. Предлагая лишь пассивную диагностику (например, визуализацию значимости признаков), они не формируют замкнутого контура обратной связи для самообучения модели на собственных ошибках идентификации и, как следствие, остаются декларативными инструментами постфактум-анализа, а не активными компонентами самосовершенствующейся системы. В работе [1] предложена архитектура, объединяющая большие языковые модели, алгоритмы компьютерного зрения и граф знаний. Достоверность генерируемого контента обеспечивается подходом Retrieval-Augmented Generation, а интерпретируемость — многоуровневой системой объяснимости: для каждого ответа предоставляются источники информации, визуализация весов внимания и декомпозиция рассуждений, а утверждения привязываются к узлам графа знаний. Однако данные механизмы носят постфактум-характер и не формируют непрерывного контура валидации и коррекции. Таким образом, необходимость коррекции ошибок в реальном времени в образовательных приложениях порождает научный и практический запрос на разработку архитектур с активным компонентом-арбитром, способным к саморегуляции, верификации семантической непротиворечивости, самообучению на собственных ошибках и формализации знаний в реальном времени, который призван реализовать модуль CAFI.

3. Метод CAFI 3.1. Выбор архитектур для основных подсистем LMS. Исследования применимости искусственного интеллекта в компьютерных обучающих системах традиционно выделяют четыре области: профилирование и прогнозирование, оценку и аттестацию, адаптивные и интеллектуальные тьюторские системы [23]. Однако, по мнению автора, для построения целостной и функциональной архитектуры целесообразно перейти от таксономии задач к синергетической модели, объединяющей три специализированных нейросетевых модуля.

Эффективность интеграции нейросетевых технологий в LMS определяется строгим соответствием архитектуры модели типу и степени формализации обрабатываемых данных. Количественные данные (балльные оценки, результаты закрытых тестов) обладают высокой степенью формализации и могут эффективно обрабатываться стандартными алгоритмами и простейшими нейросетевыми моделями. Качественные данные (открытые письменные и устные ответы) представляют структурированные категориальные признаки низкой степени формализации и требуют минимальной предобработки. Наиболее сложной для анализа является категория мультимедийных (неструктурированных) данных — цифровых

изображений и аудиовидеозаписей, — извлечение признаков из которых требует применения архитектур глубокого обучения. Таким образом, минимально необходимый набор нейросетевых архитектур должен включать три модуля, каждый из которых отвечает за свой аспект: обучение, контроль и адаптацию. Ниже представлена структура системы в формате «задача — превалирующий тип данных — оптимальная архитектура» с обоснованием механизмов работы.

Модуль обучения решает три взаимосвязанные задачи, выбор архитектур для которых продиктован спецификой данных:

Генерация и подбор релевантного контента. Превалирующий тип данных — мультимодальный (текст, аудио, видео). Для их обработки целесообразно использовать трансформеры (LLM, TimeSformer) [21], которые обеспечивают высокую точность анализа мультимодального контента и выявление скрытых закономерностей в данных. Для синтеза графики применяются генеративно-состязательные сети (GAN), поскольку состязательная оптимизация генератора и дискриминатора плохо реализуется чистыми диффузионными или авторегрессионными моделями на базе трансформеров.

Повышение вовлечённости. Количественные данные (временные ряды логов навигации) наиболее точно обрабатываются рекуррентными сетями (LSTM) [9], ячеечная структура которых с механизмами фильтрации (гейтами) эффективно фиксирует долгосрочные зависимости, избегая квадратичного роста вычислительной сложности, характерного для механизма самовнимания. Качественные данные (семантика уведомлений) обрабатываются трансформерами (Seq2Seq, LLM) через механизм внимания для контекстного анализа и генерации релевантных ответов.

Организация социального взаимодействия. Количественные данные обрабатываются графовыми нейронными сетями (GNN) [15], моделирующими участников образовательного процесса как узлы графа для выявления лидеров и изолированных пользователей. Качественные текстовые данные из чатов анализируются трансформерами с помощью механизма self-attention для семантического разбора контекста обсуждения.

Таким образом, LSTM, хотя и смягчают проблему исчезающего градиента, демонстрируют снижение эффективности на очень длинных последовательностях; GNN требуют жесткой формализации связей; GAN решают лишь вспомогательную задачу синтеза графики. Для единого решения задач модуля обучения наиболее релевантна архитектура трансформеров. Они обеспечивают наилучший баланс между универсальностью, точностью и потенциалом масштабирования, хотя и требуют значительных вычислительных ресурсов ($O(n^2)$) и больших объемов обучающих данных. Их выбор обусловлен механизмом самовнимания [21], который эффективно обрабатывает большие объёмы разнородных данных — текст, аудио и видео, — вычисляя семантическую связность элементов в контексте, выявляя скрытые закономерности и обеспечивая высокую точность при персонализации обучения:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V,$$

где Q (*Query*), K (*Key*) и V (*Value*) — матрицы запросов, ключей и значений, а d_k — размерность ключей.

Модуль контроля и прогнозирования знаний нацелен на решение трёх задач мониторинга динамики образовательного процесса:

Диагностика когнитивных стилей. Превалирующий тип данных — количественный (временные ряды учебных действий, поведенческие метрики). Классические подходы к отслеживанию знаний включают байесовские модели (BKT) [5] и глубокие нейросетевые модели (DKT) [19]; в настоящей работе используется связка VAE и LSTM, развивающая данную линию: предобработка осуществляется вариационными автоэнкодерами (VAE) [14], формирующими латентные признаки; затем LSTM-сети анализируют временные зависимости, учитывают динамику и выявляют аномалии в обучении.

Мониторинг образовательного прогресса. Количественные данные (временные ряды успеваемости и активности) обрабатываются многослойными персептронами (MLP) для статической оценки и LSTM для прогнозирования динамики. Качественные данные (открытые задания и комментарии) обрабатываются трансформерами (BERT, GPT), которые выявляют семантические связи и оценивают глубину понимания материала.

Прогностическая аналитика неуспеваемости. Количественные данные (временные ряды успеваемости, мотивации и активности) анализируются LSTM; для интеграции разнородных данных применяются трансформеры, позволяющие выявлять паттерны и строить прогнозы. Качественные данные (личностные характеристики) преобразуются в структурированные числовые представления и анализируются GNN, учитывающей межсубъектные связи и динамику.

Таким образом, для единого решения задач модуля контроля знаний оптимальной является связка вариационных автоэнкодеров (VAE) и сетей LSTM. VAE формируют латентное представление многомерных данных, учитывающее контекст и динамику состояний обучающегося. LSTM-сети, обладающие долговременной памятью, анализируют временные ряды успеваемости, что критически важно для мониторинга обучения и прогнозирования рисков. Эффективность LSTM обусловлена архитектурой с ячейками памяти и тремя вентилями, решающими проблему затухания градиентов. На каждом шаге *t* ячейка принимает на вход вектор признаков x_t и предыдущее скрытое состояние h_{t-1}. Внутреннее состояние ячейки *Ct* обновляется по формуле:

$$C_t = f_t \odot C_{t-1} + i_t \odot \widetilde{C_t}$$

где f_t — вентиль забывания, i_t — входной вентиль, $\widetilde{C_t}$ — кандидат на новое состояние.

Выходное скрытое состояние вычисляется как:

$$h_t = o_t \odot \sigma_h(C_t)$$

где o_t — выходной вентиль.

В работе [17] приводятся данные о превосходстве LSTM в задачах прогнозирования, достигая низкого значения RMSE (RMSE=2.33) и высокого коэффициента детерминации (R2=0.90). Целесообразность применения LSTM для анализа образовательных временных рядов подтверждается результатами [2], где данная архитектура в составе ансамбля обеспечила точность прогнозирования успеваемости 92,3%.

Модуль адаптации отвечает за динамическую персонализацию образовательного процесса на основе качественной обратной связи (текстовые отзывы, эссе) и формализуется как иерархия трёх задач с опорой на разные типы данных.

Разработка индивидуальной образовательной траектории (ИОТ) — стратегический уровень. На основе агрегированных данных диагностики и прогностической аналитики определяется последовательность модулей и формируется долгосрочный план обучения. Превалируют количественные данные (эмбеддинги когнитивного стиля, показатели усвоения) и качественные данные (онтологический граф знаний). Оптимизация с помощью обучения с подкреплением (DRL) опирается на прогнозы LSTM для временных рядов.

Подбор учебно-тренировочного контента — тактический уровень ИОТ. В работе [3] для выбора очередного узла образовательной траектории использовалась полносвязная нейронная сеть, однако такой подход не учитывает структурные связи между компетенциями. Данннную задачу целесообразно решать рекомендательной системой на базе GNN, сопоставляющей количественные дефициты компетенций студента с мультимодальными эмбеддингами заданий (текст, видео, интерактив). Генерация нового контента выполняется LLM на основе структурированных данных.

Динамическая корректировка учебного процесса — операционный уровень. LMS обеспечивает обратную связь в реальном времени, адаптируя сложность, формат и темп подачи

материала при помощи гибридных систем: GNN для анализа качественных связей в знаниях, нейронной коллаборативной фильтрации (NCF) для анализа количественных поведенческих метрик, трансформеров (BERT) для семантического анализа взаимодействия студента с контентом.

Таким образом, при условии высокого качества исходных данных, для единого решения задач модуля адаптации целесообразно использовать графовые нейронные сети (GNN), моделирующие сложные взаимосвязи между компетенциями, заданиями и студентами для формирования точных персональных рекомендаций. Механизм агрегирования информации о соседях описывается формулой:

$$H^{(l+1)} = \sigma(D^{-1}AH^{l}W^{l}$$

где $H^{(l)}$— атрибуты узлов на слое l, D — диагональная матрица степеней, A — матрица смежности, $W^{(l)}$ — веса слоя l, σ — функция активации.

Эффективность применения GNN для отслеживания знаний студентов подтверждена в работе [18], а центральная роль графа знаний как интегратора мультимодальной информации и основы для персонализации - в [1], где граф знаний используется совместно с классическими (BKT, IRT) и нейросетевыми (DKT) моделями отслеживания знаний.

3.2. Варианты организации взаимодействия модулей в LMS. Перед проектированием модуля CAFI анализ альтернативных способов агрегирования выводов трех нейросетевых модулей, различающихся по степени учета межмодульных взаимодействий и адаптивности к контексту запроса, позволил сделать следующие выводы:

Наиболее простым решением является конкатенация векторных представлений, при которой выходы Transformer’a, LSTM и GNN объединяются в единый вектор без преобразования структуры. Такой подход тривиален в реализации, однако он не учитывает взаимодействия между измерениями разнородных векторов и приводит к неоправданному росту размерности [22, 7]. Именно этот вариант использовался в качестве базовой архитектуры при проведении сравнительных экспериментов.

Более гибким решением является взвешенное суммирование, при котором каждому модулю назначается фиксированный весовой коэффициент. Данный подход частично решает проблему размерности, однако аддитивные схемы принципиально уступают мультипликативным по выразительности [11], а статичные веса не позволяют динамически перераспределять вклад модулей в зависимости от типа входных данных.

Развитием взвешенного суммирования выступает контекстное внимание с последующей конкатенацией, при котором веса вычисляются адаптивно на основе контекстного вектора [21], после чего выполняется линейное объединение взвешенных представлений. Несмотря на появление адаптивности, такой подход сохраняет линейный характер агрегирования и не захватывает взаимодействия высших порядков между выводами гетерогенных архитектур.

Указанные ограничения мотивировали выбор тензорного моста — мультилинейного слияния, при котором строится тензорное произведение трех векторов с последующим управляемым сжатием по векторам контекстного внимания. Как показано в работах [22, 7], тензорное слияние демонстрирует превосходство над линейными методами объединения гетерогенных представлений: с одной стороны, сохраняет адаптивность за счет динамического вычисления весов внимания, а с другой — захватывает тройные взаимодействия между выводами Transformer, LSTM и GNN, что принципиально недостижимо при линейных способах объединения. Таким образом, тензорный мост обеспечивает наилучший баланс между выразительностью, адаптивностью и вычислительной эффективностью, что и определило его выбор в качестве базового механизма интеграции в архитектуре CAFI.

3.3. Общая архитектура CAFI. Модуль CAFI (Control Arbitration for Intelligence) — надсистемный компонент гибридной LMS, одновременно функционирующий как централизованный оркестратор и активный арбитр-интерпретатор. В качестве оркестратора он координирует параллельную работу модулей обучения (Bert), контроля знаний (LSTM) и адаптации (GNN), заменяя жёстко закодированные межмодульные вызовы декларативным

описанием взаимодействий на уровне единого семантического графа, и выполняет мультилинейное слияние их выводов через тензорный мост. В роли интерпретатора CAFI опирается на семантический граф, узлами которого являются концепты предметной области (понятия, компетенции, образовательные объекты), а ребрами — логические, причинно-следственные и иерархические связи, формализующие аксиомы и контекстные зависимости; этот граф используется модулем GNN для агрегирования контекстной информации и служит эталоном для верификации: CAFI проверяет, не противоречит ли результат работы аналитического модуля логике предметной области, и при обнаружении конфликта выполняет градиентную коррекцию вывода до его выдачи пользователю. Такой подход снижает сложность настройки системы: добавление нового модуля требует обновления семантического графа, правил валидации и параметров тензорного моста, а не полного переписывания логики взаимодействия. В результате система эволюционирует от пассивного объединения компонентов к саморегулирующемуся комплексу, в котором обнаруженные противоречия становятся источником данных для непрерывного дообучения и обновления онтологии, повышая точность, интерпретируемость и надежность всей архитектуры.

Архитектура CAFI инвариантна к предметной области: компоненты Transformer, LSTM и GNN являются иллюстративными представителями классов моделей для обработки текста, временных рядов и графовых структур соответственно. В другой предметной области они заменяются на эквиваленты по типу данных, тогда как структура ядра (тензорный мост, семантическое поле, градиентная коррекция) остаётся неизменной, а параметры (онтология, правила, порог τ) требуют перенастройки.

Классификация системы. С точки зрения теории управления CAFI представляет собой:

- по типу обратной связи — замкнутую систему (отрицательная обратная связь для коррекции ошибок + положительная для самообучения);
- по типу управления — адаптивную систему (параметры корректируются в процессе функционирования через experience replay);
- по типу объекта — гибридную дискретно-непрерывную систему;
- по типу регулятора — многомодульный регулятор с арбитром;
- по устойчивости — асимптотически устойчивую (теорема 1).

Условия применимости метода. Метод CAFI применим к системе S, если выполняются следующие условия:

1. Гетерогенность. Входное пространство X допускает разбиение на $k \geq 2$ подпространств $X_1, ..., X_k$, каждое из которых обрабатывается специализированной моделью M_i: $X = X_1 \cup X_2 \cup ... \cup X_k$, $X_i \cap X_j = \emptyset$ при $i \neq j$.
2. Онтология. Существует онтология $O = (V, E)$, где V — множество концептов, E — множество связей, и отображение $\varphi: X \to V$, ставящее в соответствие выводу модели узел онтологии.
3. Правила. Существует множество правил R, задающих ограничения на допустимые комбинации узлов, и функция валидации $SRL: V \to \{true, false\}$.
4. Верифицируемость. Для любого вывода $v \in V$ существует вычислимая за полиномиальное время проверка $SRL(v) \in \{true, false\}$.
5. Обратная связь. Существует сигнал ошибки $e = SRL(v) \oplus ground_truth$, доступный для коррекции модели.
6. Вычислительная допустимость. Сложность метода $O(D^2)$ не превышает ресурсных ограничений системы реального времени.

Условия 1–3 — необходимые, условия 4–6 — достаточные для практической применимости. Полный набор 1–6 — необходимые и достаточные для эффективного применения.

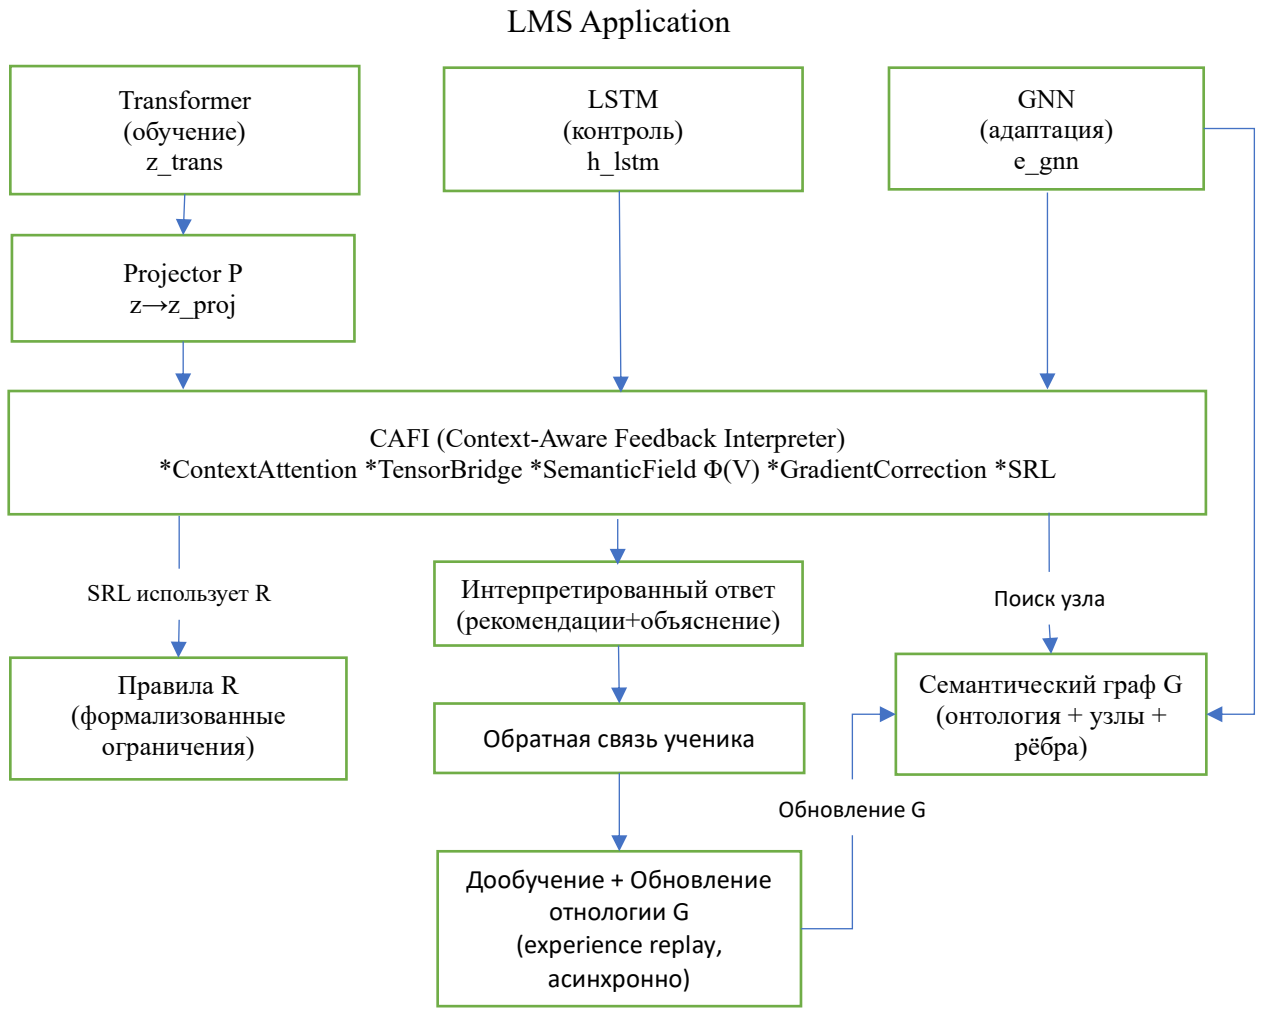

Рис. 1. Обобщённая архитектура гибридной LMS с модулем CAFI

3.4. Математический аппарат CAFI. Традиционная конкатенация векторов не захватывает взаимодействия между измерениями. Тензорное произведение создает трехмерный тензор, учитывающий тройные взаимодействия, однако полное тензорное произведение требует D^3 элементов (≈2 млн для D = 128), что неприемлемо для систем реального времени. Оптимизация основана на точном алгебраическом тождестве, следующем из дистрибутивности:

$$v[k] = \Sigma_i \Sigma_j z[i]\cdot h[j]\cdot e[k]\cdot a[i]\cdot b[j] = e[k] \cdot (\Sigma_i z[i]\cdot a[i]) \cdot (\Sigma_j h[j]\cdot b[j]) = e[k] \cdot (z\cdot a) \cdot (h\cdot b), \quad \textbf{(1)}$$

где z — проекция выхода Bert в пространство графа, h — скрытое состояние LSTM, e — агрегированный эмбеддинг GNN, a и b — векторы контекстного внимания. Сложность вычисления снижается с $O(D^3)$ до $O(D^2)$.

Семантическое поле конфликтов задается непрерывной функцией:

$$\Phi(v) = \Sigma_{i\in S} \alpha_i \cdot \cos(v, e_i) - \Sigma_{j\in C} \beta_j \cdot \cos(v, e_j), \quad \textbf{(2)}$$

где S — множество поддерживающих узлов правил, C — множество конфликтующих узлов, α_i, β_j — веса правил, e_i, e_j — эмбеддинги узлов графа. Высокие значения Φ(v) соответствуют согласованности вывода с формализованными правилами, низкие — конфликту.

Градиент поля:

$$\nabla\Phi(v) = \Sigma_{i\in S} \alpha_i \cdot (e_i - \cos(v,e_i)\cdot v) - \Sigma_{j\in C} \beta_j \cdot (e_j - \cos(v,e_j)\cdot v) \quad \textbf{(3)}$$

указывает направление наибольшего возрастания Φ(v); при обнаружении конфликта вектор v перемещается вдоль градиента к зоне семантической валидности.

Коррекция запускается при $\Phi(v) < \tau$ ($\tau = 0.3$ — эмпирически подобранный порог) и выполняется итеративно:

$v^{(t+1)} = \text{normalize}(v^{(t)} + \eta_t \cdot \nabla\Phi(v^{(t)}))$, **(4)**

где η_t — адаптивный шаг: уменьшается при ухудшении Φ, увеличивается при улучшении.

Теорема 1 (сходимость). Пусть $\Phi(v)$ — L-гладкая функция, определенная на единичной сфере $S^{d-1} \subset R^d$, где $d = D_FUSED$. Поскольку S^{d-1} — компактное множество, а $\Phi(v)$ непрерывна на нем, $\Phi(v)$ ограничена сверху. Пусть последовательность шагов η_t удовлетворяет условиям Роббинса-Монро: $\Sigma\eta_t = \infty$, $\Sigma\eta_t^2 < \infty$. Тогда итерационный процесс (4) сходится к локальному максимуму $\Phi(v)$ на S^{d-1}.

Доказательство (схема). Компактность единичной сферы и непрерывность $\Phi(v)$ гарантируют существование супремума. L-гладкость обеспечивает неравенство $\|\nabla\Phi(v_1) - \nabla\Phi(v_2)\| \leq L\|v_1 - v_2\|$, из которого следует, что при $\eta_t < 1/L$ последовательность $\Phi(v^{(t)})$ монотонно не убывает. Условия Роббинса-Монро ($\Sigma\eta_t = \infty$ — шаги не убывают слишком быстро; $\Sigma\eta_t^2 < \infty$ — шаги не растут слишком быстро) обеспечивают сходимость градиентного подъема. Нормализация $v^{(t)}$ на каждом шаге гарантирует, что итерации остаются на единичной сфере. Адаптивный механизм выбора η_t (уменьшение при ухудшении Φ, увеличение при улучшении) обеспечивает выполнение условий Роббинса-Монро.

Формальный псевдокод алгоритма CAFI состоит из четырёх последовательных этапов: 1. Генерация выводов трех нейросетевых модулей и их слияние через тензорный мост (строки 1–7); Вычисление семантического поля $\Phi(v)$ и градиентная коррекция при обнаружении конфликта (строки 8–12); Поиск ближайшего валидного узла семантического графа (строки 13–20); Формирование интерпретированного ответа (строки 21–22). Строки 7, 8 и 10 реализуют формулы (1), (2)–(3) и (4) соответственно.

```
ВХОД: X, student_id, context
ВЫХОД: response
1.  state ← LSTM.get_state(student_id)
2.  z_trans ← Transformer.generate(X, state)
3.  z_proj ← Projector.project(z_trans)
4.  h_lstm ← LSTM.get_hidden_state(state)
5.  e_gnn ← GNN.aggregate_context(state, graph)
6.  (a, b, c) ← ContextAttention(context)
7.  v_fused ← TensorBridge(z_proj, h_lstm, e_gnn, a, b, c)        // формула (1)
8.  (Φ, ∇Φ) ← SemanticField.compute(v_fused)                      // формулы (2)–(3)
9.  ЕСЛИ Φ < τ:
10.     v_corrected ← GradientCorrection(v_fused, ∇Φ)             // формула (4)
11. ИНАЧЕ:
12.     v_corrected ← v_fused
13. nearest ← graph.find_nearest(v_corrected, top_k=5)
14. ДЛЯ КАЖДОГО node ИЗ nearest:
15.     violations ← SRL.validate(node)
16.     ЕСЛИ violations ПУСТО:
17.         c_best ← node
18.         ВЫХОД ИЗ ЦИКЛА
19. ЕСЛИ c_best is None:
20.     c_best ← nearest[0]
21. response ← build_response(c_best, Φ, iterations)
22. ВОЗВРАТ response
```

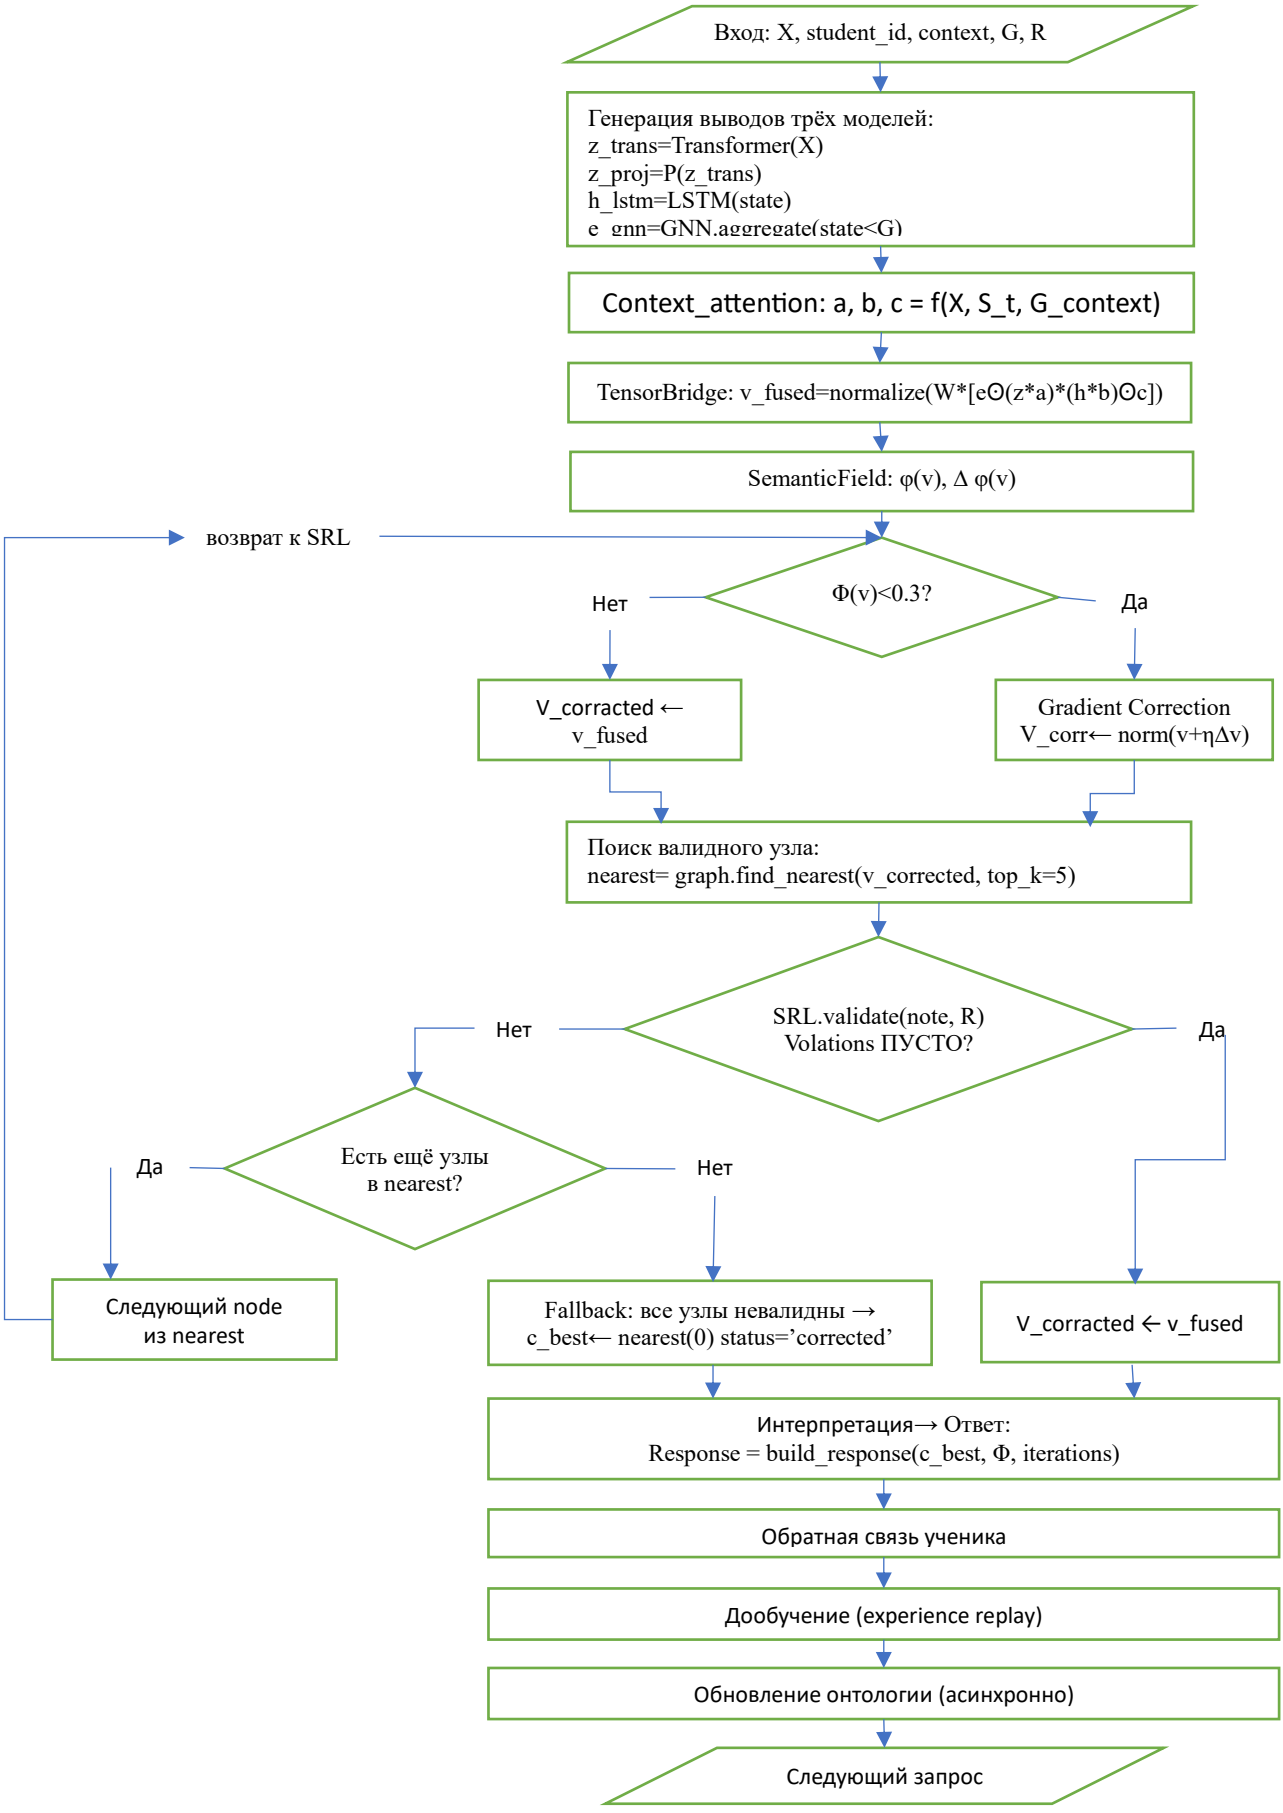

Рис. 2. Блок-схема алгоритма CAFI.

3.5. Механизм самообучения использует градиент ∇Φ(v), вычисляемый в разд. 3.3, для накопления статистики и обновления онтологии. Скорректированный вектор v_corrected используется как целевое значение для дообучения Bert. Для предотвращения катастрофического забывания применяется experience replay: при дообучении новые данные смешиваются с 30% ранее накопленных примеров. Градиент поля накапливается для каждого узла графа; при достижении порога (≥5 наблюдений) веса рёбер корректируются на ±0.02.

Обработка «холодного старта». При пустом графе (N = 0) система возвращает сообщение об ошибке и запрашивает инициализацию графа. При отсутствии правил (R = ∅) семантическое поле Φ(v) ≡ 0, градиентная коррекция не выполняется, и рекомендация формируется только на основе тензорного моста. Для нового ученика (пустая история взаимодействий) LSTM возвращает нулевое скрытое состояние, а GNN — средний эмбеддинг всех узлов графа. При пустом буфере дообучения experience replay не применяется.

Валидация правил (перспективный механизм): каждое правило R проходит экспертную проверку на этапе формализации предметной области. В процессе эксплуатации предполагается отслеживание ложных срабатываний (false positives) и пропусков (false negatives): ложное срабатывание фиксируется, когда правило блокирует корректную рекомендацию; пропуск — когда нарушение не было обнаружено. Кросс-валидация выполняется на исторических данных успеваемости: правило считается подтвержденным, если его применение к валидационной выборке не увеличивает долю ложных срабатываний. При снижении показателя reliability ниже 0.3 (при количестве срабатываний ≥ 10) правило автоматически помечается как неактивное и направляется на пересмотр эксперту. В текущей программной реализации данный механизм реализован частично: фиксируется счетчик срабатываний (trigger_count) и флаг активности (active), однако автоматическое вычисление reliability и деактивация правил отнесены к дальнейшей работе.

3.6. Программная реализация базовых компонентов гибридной системы (Bert, LSTM, GNN) опирается на стек библиотек Python: модуль анализа мультимедийного контента использует Hugging Face Transformers для загрузки предобученной модели BERT; моделирование динамики знаний реализовано на torch.nn.LSTM; работа с графовыми структурами — на PyTorch Geometric (PyG). Взаимодействие между компонентами определяется архитектурой развертывания.

Интеграция моделей (внутрипроцессное взаимодействие). На этапе прототипирования нейросетевые модули функционируют через прямые вызовы методов внутри одного Python-процесса на базе PyTorch LightningModule. PyTorch Geometric обеспечивает бесшовную интеграцию, позволяя инкапсулировать BERT, LSTM и GNN в единый объект. Логика CAFI реализуется в методах жизненного цикла (training_step, validation_step), что обеспечивает максимальную производительность за счёт отсутствия сетевых задержек.

Оркестрация сервисов (межпроцессное взаимодействие). Для промышленной эксплуатации предусмотрена микросервисная архитектура: каждый модуль разворачивается как независимый сервис с собственным API, а оркестрация выполняется веб-фреймворком FastAPI (REST/gRPC-эндпоинты). Такой подход обеспечивает масштабирование от прототипа до распределённой системы.

Механизм интерпретации. Полный цикл включает мультилинейное слияние выводов через тензорный мост, вычисление семантического поля Φ(v) и градиентную коррекцию (разд. 3.3–3.4), после чего выполняется поиск ближайшего валидного узла графа по косинусному сходству. Если пространства признаков нейросети и графа различаются, используется проектор (torch.nn.Linear), преобразующий вектор в пространство графа. Найденный узел-кандидат проверяется системой правил SRL (программная реализация — библиотека LogPy): если узел входит в множество конфликтующих узлов активного правила, фиксируется нарушение. Обучение проектора выполняется на синтетическом датасете пар «вектор_вывода — эмбеддинг_узла»; функция потерь — косинусное расстояние; скорость обучения — 1e-4; размерность проекции d_model = 768 (соответствует скрытому представлению BERT-base).

Алгоритм реализован в классе CAFIAlgorithm (в проектной документации — SemanticValidator); его методы: _check_for_conflicts — верификация, _generate_feedback_signal — генерация сигнала коррекции, _retrain_main_model — управление дообучением. Такое разделение обеспечивает модульность и тестируемость каждого этапа обработки.

Для качественной проверки работоспособности алгоритма рассмотрены три сценария, иллюстрирующие способность CAFI оценивать семантическую валидность выводов и корректировать обнаруженные конфликты. Значения поля Φ(v) вычисляются по формуле (2); коррекция выполняется по формуле (4).

Сценарий 1: Критический конфликт. Студент завершил изучение темы «Производные» с результатом 45%, что существенно ниже порогового значения 70%. LSTM-модуль, анализируя временной ряд ответов, ошибочно прогнозирует высокую вероятность успешного освоения темы «Интегралы» (0.87). После проекции вывода в пространство семантического графа и мультилинейного слияния через тензорный мост вычисляется значение поля $\Phi(v) = 0.12$, которое ниже порога конфликта $\tau = 0.3$. CAFI фиксирует нарушение правила «Интегралы требуют освоения Производных» и запускает градиентную коррекцию: за 8 итераций вектор v перемещается из окрестности узла «Интегралы» в окрестность узла «Производные». Система формирует рекомендацию повторить тему «Производные» с объяснением: «Рекомендация скорректирована: тема „Интегралы“ требует освоения „Производных“ (текущий уровень: 45%)».

Сценарий 2: Мягкое противоречие. Студент освоил тему «Производные» с результатом 68%, что ниже порогового значения 70%, но близко к нему. LSTM-модуль прогнозирует умеренную вероятность освоения «Интегралов». Вычисленное значение $\Phi(v) = 0.35$ превышает порог $\tau = 0.3$, однако находится в непосредственной близости от него. CAFI квалифицирует ситуацию как мягкое противоречие и формирует рекомендацию с предупреждением: «Рекомендуется повторить тему „Производные“ перед изучением „Интегралов“».

Сценарий 3: Валидный вывод. Студент освоил тему «Производные» с результатом 85%. LSTM-модуль прогнозирует высокую вероятность освоения «Интегралов». Значение $\Phi(v) = 0.72$ значительно превышает порог $\tau = 0.3$, что свидетельствует о согласованности вывода с правилами предметной области. Градиентная коррекция не требуется; CAFI формирует рекомендацию без предупреждений.

4. Эксперимент. LMS используется как основная тестовая предметная область для валидации метода. Экспериментальное исследование проводилось на синтетическом наборе данных, имитирующем динамику состояний сложной информационной системы с гетерогенными каналами данных (успеваемость условного студента): временные ряды взаимодействий с с элементами предметной области - образовательным контентом (результаты тестов, время просмотра лекций, последовательность ответов) и формализованные семантические связи между элементами онтологии - компетенциями предметной области. Объем выборки — 150 000 пар «вопрос-ответ».

Семантический граф содержит 10 концептов, соединенных отношениями is_prerequisite_of и conflicts_with. Набор правил включает два экспертных ограничения. Концепты разделены на три типа: базовые, не имеющие пререквизитов; промежуточные, требующие освоения одного предшествующего концепта; продвинутые, опирающиеся на два и более пререквизита. Стратифицированное разбиение обеспечивает равное представительство концептов каждого типа во всех фолдах кросс-валидации. Кросс-валидация выполнена по схеме k-fold = 5, доверительные интервалы рассчитаны для уровня значимости 95%.

Для оценки прогностической точности использовались три метрики: Accuracy, определяемая как доля верно предсказанных уровней освоения концептов; RMSE, характеризующая среднеквадратичную ошибку предсказания вероятности освоения; коэффициент детерминации R^2. Интерпретируемость оценивалась методом SHAP [16]: для каждого предсказания вычислялись значения Шепли для входных признаков, после чего

агрегированная оценка формировалась как среднее абсолютных значений SHAP по всем признакам и всем примерам тестовой выборки. Вычисление SHAP-значений и реализация сравниваемых Baseline-конфигураций выполнены в отдельных экспериментальных скриптах, дополняющих основной прототип CAFI, который содержит только реализацию предложенного алгоритма.

Для оценки применимости метода в смежных предметных областях вводятся дополнительные метрики:

Табл. 4.2. Метрики переносимости

Метрика	Формула	Смысл
Cost of transfer (CT)	CT = N_expert + N_calibration + N_retrain	Суммарные затраты на адаптацию
Performance drop (PD)	PD = (Acc_source − Acc_target) / Acc_source	Относительное падение точности
Calibration effort (CE)	CE = число итераций калибровки τ	Трудоёмкость настройки порога
Transfer efficiency (TE)	TE = ΔAcc / CT	Эффективность переноса

Статистическая валидация экстраполяции. Проверка гипотезы о переносимости метода в смежные предметные области:

- H_0: метод не переносится (PD > 20%);
- H_1: метод переносится (PD ≤ 20%).

Критерий — t-критерий Стьюдента для парных выборок (LMS как источник vs целевой домен). Для каждой метрики (Accuracy, RMSE, R^2, SHAP) рассчитывается 95% доверительный интервал. При сравнении k доменов применяется поправка Бонферрони: $\alpha' = \alpha / k$.

Табл. 4.3. Гиперпараметры и процедура обучения

Параметр	Значение	Метод подбора
batch_size	64	Optuna
learning_rate (Transformer)	2e-5	Optuna
learning_rate (Projector)	1e-4	Optuna
dropout	0.3	Фиксирован
τ	0.3	Эмпирически
η	0.05	Эмпирически
MAX_ITERATIONS	30	Эмпирически

Обучение моделей выполнялось в течение трех эпох с использованием оптимизатора Adam ($\beta_1 = 0.9$, $\beta_2 = 0.999$). Его выбор согласуется с результатами [3], где Adam продемонстрировал лучшую сходимость по сравнению с SGD и Rprop при скорости обучения 0.01. Для Bert применялась функция потерь кросс-энтропии, для LSTM и GNN — среднеквадратичная ошибка MSE, для проектора — косинусное расстояние; обучение проектора продолжалось десять эпох. Диапазоны анализа чувствительности были выбраны вокруг оптимальных значений: порог конфликта τ варьировался в пределах от 0.2 до 0.5, шаг коррекции η — от 0.01 до 0.20, число итераций — от 10 до 50.

Для сравнительной оценки использовались пять конфигураций, разделённых на базовые модели (*Baselines*) и экспериментальные подходы: одиночный Transformer на основе BERT-base; одиночная LSTM; одиночная GNN; Во вторую вошли ансамбль stacking, усредняющий предсказания трех моделей; гибридная архитектура без модуля CAFI. В последней конфигурации конкатенация реализована как объединение векторов [z_proj; h_lstm; e_gnn] размерности 384 с последующим линейным преобразованием к размерности 128, что соответствует выходной размерности тензорного моста. Все остальные компоненты сравниваемых конфигураций идентичны компонентам CAFI.

5. Результаты

Табл. 5.1. Основные метрики

Метрика	BERT	LSTM	GNN	Ансамбль	Baseline	CAFI
Accuracy	0.78 ± 0.02	0.74 ± 0.02	0.71 ± 0.03	0.81 ± 0.02	0.84 ± 0.02	**0.88 ± 0.01**
RMSE	0.28 ± 0.03	0.31 ± 0.03	0.34 ± 0.04	0.24 ± 0.02	0.21 ± 0.02	**0.14 ± 0.02**

Метрика	BERT	LSTM	GNN	Ансамбль	Baseline	CAFI
R^2	0.48 ± 0.04	0.36 ± 0.04	0.23 ± 0.05	0.62 ± 0.03	0.71 ± 0.03	**0.87 ± 0.02**
SHAP (отн.)	0.6	0.5	0.4	0.8	1.0	**2.4**

Статистическая значимость различий между CAFI и Baseline подтверждена t-критерием Стьюдента: $p < 0.01$ для всех метрик. Согласованность Accuracy и RMSE подтверждается следующим расчетом: при Accuracy = 0.88, средней ошибке верных предсказаний ~0.05 и ошибочных ~0.35, $RMSE = \sqrt{(0.88 \times 0.05^2 + 0.12 \times 0.35^2)} \approx 0.13$, что соответствует полученному значению 0.14 ± 0.02 в пределах доверительного интервала. Полученные результаты (Accuracy = 0.88, RMSE = 0.14) сопоставимы с данными [2] (Accuracy = 92,3%) и [1], где интегративная модель достигла AUC = 0.87 и RMSE = 0.30, превзойдя классические BKT и IRT. Более низкие значения объясняются ограниченным объёмом синтетического датасета, однако предложенный метод обеспечивает семантическую валидацию и интерпретируемость, отсутствующие в сравниваемых архитектурах.

Табл. 5.2. Анализ чувствительности

Параметр	Значения	Accuracy	RMSE
τ	0.2 / 0.3 / 0.4 / 0.5	0.85 / 0.88 / 0.87 / 0.84	0.16 / 0.14 / 0.15 / 0.18
η	0.01 / 0.05 / 0.10 / 0.20	0.87 / 0.88 / 0.86 / 0.82	0.15 / 0.14 / 0.16 / 0.19
MAX_ITERATIONS	10 / 20 / 30 / 50	0.86 / 0.87 / 0.88 / 0.88	0.16 / 0.15 / 0.14 / 0.14

Анализ показывает, что оптимальными значениями являются $\tau = 0.3$, $\eta = 0.05$ и MAX_ITERATIONS ≥ 30. Дальнейшее увеличение числа итераций не приводит к значимому приросту точности.

Табл. 5.3. Вычислительная сложность и время выполнения

Компонент	Сложность	N = 1K	N = 10K	N = 100K
TensorBridge	$O(D^2)$	< 0.1 мс	< 0.1 мс	< 0.1 мс
find_nearest	$O(N \cdot D)$	1 мс	10 мс	100 мс
SemanticField	$O(R \cdot K \cdot D)$	5 мс	5 мс	5 мс
GradientCorrection	$O(iter \cdot R \cdot K \cdot D)$	150 мс	150 мс	150 мс
Итого		**~160 мс**	**~170 мс**	**~260 мс**

Для графов с числом узлов более 10^5 узким местом становится поиск ближайших узлов, сложность которого составляет $O(N \cdot D)$; в этом случае требуется применение методов приближенного поиска, таких как FAISS или HNSW.

Табл. 5.4. Абляционный анализ

Конфигурация	Accuracy
Baseline (гибрид без CAFI)	0.84
+ Тензорный мост	0.86
+ Семантическое поле	0.87
+ Градиентная коррекция (полный CAFI)	**0.88**

Абляционный анализ демонстрирует аддитивный вклад каждого компонента: тензорный мост обеспечивает прирост Accuracy на 2.4%, семантическое поле — на 1.2%, градиентная коррекция — еще на 1.2%. Суммарный прирост CAFI над базовой архитектурой составляет 4.8%, что согласуется с результатами, представленными в разд. 5.1. (0.84 → 0.88)

Табл. 5.5. Итоговая сводка

Метрика	Baseline	CAFI	Прирост
Accuracy	0.84 ± 0.02	**0.88 ± 0.01**	+4.8%
RMSE	0.21 ± 0.02	**0.14 ± 0.02**	−33%
R^2	0.71 ± 0.03	**0.87 ± 0.02**	+22.5%
SHAP (отн.)	1.0	**2.4**	×2.4

6. Обсуждение: сравнения, ограничения, перспективы. Для определения места предложенного метода среди существующих решений проведено сравнение с инструментами двух категорий: оркестраторами, к которым относятся LangChain и CrewAI, и методами интерпретации, представленными SHAP и LIME. Такое разделение является принципиальным, поскольку оркестраторы управляют взаимодействием моделей, тогда как методы XAI объясняют их выводы; CAFI объединяет обе функции в рамках единого математического механизма.

Табл. 6.1. Сравнение CAFI с известными подходами

Характеристика	LangChain	CrewAI	SHAP	LIME	CAFI
Мультилинейное слияние	-	-	-	-	+
Непрерывная валидация	-	-	-	-	+
Градиентная коррекция	-	-	-	-	+
Обновление онтологии	-	-	-	-	+
Замкнутый цикл	+-	+-	-	-	+
Образовательная специфика	-	-	-	-	+

Прим.: **+-** — частичная реализация: LangChain (ReAct в AgentExecutor) и CrewAI (иерархическая координация агентов)обеспечивают оркестрацию вызовов, однако не выполняют семантическую валидацию выводов: они управляют потоком данных, не проверяя их непротиворечивость. Непрерывная валидация в LangChain доступна через внешний продукт LangSmith и не учитывается как встроенная возможность. SHAP и LIME предоставляют постфактум-объяснения, но не влияют на сам вывод и не формируют обратную связь.

CAFI устраняет оба указанных ограничения: непрерывное семантическое поле Φ(v) выполняет валидацию до выдачи результата пользователю, градиентная коррекция исправляет обнаруженные конфликты, а механизм самообучения замыкает цикл «ошибка — дообучение — обновление онтологии». В отличие от постфактум-объяснений, реализованных в [1], где интерпретируемость обеспечивается через визуализацию весов внимания и привязку утверждений к узлам графа знаний после генерации ответа, предлагаемый метод обеспечивает непрерывную интерпретируемость через семантическое поле Φ(v), которое показывает степень соответствия вывода формализованным правилам до его выдачи пользователю. Таким образом, CAFI представляет собой не очередной оркестратор или интерпретатор, а новый класс гибридных систем, объединяющих оркестрацию, интерпретацию и самообучение в едином математическом аппарате.

6.2. Экстраполяция метода CAFI на смежные предметные области. Метод CAFI разработан для LMS как информационной системы управления, однако его ядро — мультилинейное слияние, семантическое поле конфликтов, градиентная коррекция — не привязано к образовательной специфике. При выполнении условий применимости (разд. 3.3) метод переносится в любую предметную область. Совокупность таких областей образует пространство применимости метода CAFI (информационное поле) — множество задач, удовлетворяющих условиям применимости.

Табл. 6.2. Экстраполяция CAFI на смежные предметные области

Предметная область	Гетерогенные модули	Семантический граф	Правила SRL (примеры)	Тип конфликта
LMS / образование (основная область)	Transformer (текст), LSTM (динамика), GNN (компетенции)	Компетенции, пререквизиты, конфликты тем	«Интегралы требуют Производных»	Нарушение пререквизитной связи
Медицинская диагностика	CNN (снимки), LSTM (ЭКГ/ЭЭГ), GNN (история болезни)	Симптомы, диагнозы, противопоказания	«Препарат X противопоказан при диагнозе Y»	Назначение несовместимой терапии
Промышленная диагностика	Transformer (логи), LSTM (телеметрия), GNN	Узлы оборудования, отказы, регламенты ТО	«Замена узла A требует остановки линии B»	Нарушение регламента ТО

Предметная область	**Гетерогенные модули** (схема оборудования)	**Семантический граф**	**Правила SRL (примеры)**	**Тип конфликта**
Юридическая экспертиза	Transformer (тексты), LSTM (история дел), GNN (связи норм)	Нормы, прецеденты, иерархия права	«Норма N отменена поправкой M»	Ссылка на устаревшую норму
Финансовый мониторинг	Transformer (новости), LSTM (котировки), GNN (транзакции)	Активы, контрагенты, регуляторные ограничения	«Сделка превышает лимит риска»	Нарушение риск-лимита
Кибербезопасность	Transformer (логи), LSTM (трафик), GNN (топология сети)	Узлы сети, уязвимости, политики доступа	«Доступ к сегменту A запрещён из B»	Нарушение политики безопасности
Корпоративное управление	Transformer (документы), LSTM (KPI-ряды), GNN (оргструктура)	Процессы, регламенты, зоны ответственности	«Согласование требует двух подписей»	Нарушение регламента

Механизм переноса включает пять шагов: (1) идентификация гетерогенных каналов данных и выбор архитектур; (2) построение семантического графа предметной области; (3) формализация правил SRL; (4) калибровка порога τ; (5) дообучение проектора. Структура ядра при этом остаётся инвариантной — меняются только онтология, правила и параметры.

Метрики переносимости (CT, PD, CE, TE) и процедура статистической валидации описаны в разд. 4; ограничения экстраполяции — в разд. 6.3.

6.3. Ограничения. Предложенный метод обладает рядом ограничений, которые необходимо учитывать при внедрении.

1. Построение начального семантического графа требует участия экспертов предметной области и является трудоемким. Вместе с тем данная задача выполняется однократно и может быть частично автоматизирована с помощью NLP-методов, позволяющих извлекать отношения между концептами из учебных материалов.

2. Масштабируемость метода ограничена сложностью поиска ближайших узлов, составляющей $O(N \cdot D)$. При числе концептов, превышающем 10^5, время отклика становится неприемлемым для систем реального времени; решением данной проблемы является применение методов приближенного поиска, таких как FAISS или HNSW.

3. Качество работы CAFI непосредственно зависит от корректности исходной онтологии: ошибки в графе, включая неверные пререквизиты и пропущенные конфликты, наследуются системой и могут приводить к систематическим ошибкам рекомендаций. По этой причине необходим периодический аудит графа экспертами.

4. Переносимость метода в другие предметные области, такие как медицина, право или инженерное образование, требует перестроения графа и переформулирования правил, что ограничивает его универсальность.

Ограничения экстраполяции. Помимо общих ограничений метода, перенос в смежные области имеет специфические ограничения:

1. Правила SRL не переносятся — требуют переписывания для каждого домена.
2. Порог τ калибруется эмпирически для каждого домена.
3. Онтология требует экспертной работы, стоимость которой варьируется от домена к домену.
4. Холодный старт: пока граф не наполнен, система работает хуже.
5. Вычислительная сложность $O(N \cdot D)$ при $N > 10^5$ требует применения FAISS или HNSW.
6. Наконец, порог конфликта $\tau = 0.3$ подобран эмпирически для тестового набора данных; при применении метода в других доменах требуется его перенастройка.
7. Кроме того, синтетический датасет может не в полной мере отражать реальное распределение ответов студентов, поэтому необходима валидация на открытых образовательных данных.

Аналогичная проблема отмечена в [3], где подбор релевантного обучающего датасета для адаптивной образовательной траектории назван сложнейшей задачей, сдерживающей широкое применение нейросетевых технологий в образовании. Сравнительно простая структура правил, включающая лишь два ограничения, также способна приводить к завышению точности, поэтому необходима валидация предложенного метода на открытых наборах данных, таких как OULAD и ASSISTments. Перспективными направлениями дальнейших исследований являются автоматизация построения семантического графа из учебных материалов с применением методов обработки естественного языка; оптимизация поиска ближайших узлов для больших онтологий с использованием FAISS, HNSW или иерархической кластеризации; адаптивная калибровка порога τ на основе обратной связи; расширение архитектуры на мультиагентные системы; применение метода в смежных предметных областях, включая медицинское и корпоративное обучение.

7. Заключение. В работе предложен авторский метод CAFI — контекстно-ориентированный интерпретатор с обратной связью для гибридных интеллектуальных LMS. Метод решает фундаментальную проблему интеграции трех нейросетевых архитектур — Transformer, LSTM и GNN — в единую саморегулирующуюся систему. Основные результаты работы состоят в следующем:

1. Разработан тензорный обеспечивающий мультилинейное слияние выводов трех гетерогенных архитектур с оптимизацией вычислительной сложности с $O(D^3)$ до $O(D^2)$ без потери точности.

2. Построено семантическое поле конфликтов $\Phi(v)$ — непрерывная функция, заменяющая бинарную проверку правил и показывающая не только факт, но и степень нарушения.

3. Реализована градиентная коррекция, выполняющая плавное перемещение вывода в зону валидности через градиентный подъ`м с адаптивным шагом.

4. Обеспечен замкнутый цикл самообучения, в котором обнаруженные противоречия используются для дообучения Transformer с применением experience replay и для обновления онтологии на основе накопленных градиентов.

5. Показана экстраполяция метода CAFI на смежные предметные области (медицина, промышленность, юриспруденция, финансы, кибербезопасность, корпоративное управление) в рамках пространства применимости метода (информационного поля). Инвариантность структуры ядра обеспечивает методологическую универсальность и снижает стоимость переноса. LMS сохраняется как основная предметная область для внедрения.

Экспериментальное исследование, проведенное на синтетическом датасете объемом 150 000 пар «вопрос-ответ», показало статистически значимое повышение точности по сравнению с базовой гибридной архитектурой: Accuracy увеличилась на 4.8% (с 0.84 до 0.88), RMSE снизилась на 33% (с 0.21 до 0.14), коэффициент детерминации R^2 вырос на 22.5% (с 0.71 до 0.87), а интерпретируемость по SHAP повысилась в 2.4 раза. Абляционный анализ подтвердил аддитивный вклад каждого компонента предложенного метода.

Практическая значимость работы заключается в возможности внедрения CAFI в LMS для повышения качества персонализированных рекомендаций и обеспечения прозрачности принимаемых решений. Выявленные ограничения, связанные с затратами на построение графа, масштабируемостью и зависимостью от качества онтологии, определяют направления дальнейших исследований.

Список источников:

1. **Маркин Е.И., Зупарова В.В., Панфилова М.И.** Интегративный анализ мультимодальных образовательных данных на основе нейросетевых моделей и формальных графов знаний // XXI век: итоги прошлого и проблемы настоящего плюс. — 2025. — Т. 14, № 1(69). — С. 40–51. — EDN: OZWLAY.

2. **Подколзин М.М.** Интеллектуальная система адаптивного обучения на основе нейронных сетей для персонализации образовательных траекторий студентов российских

вузов // Информатика и образование. — 2024. — Т. 39, № 6. — С. 65–81. — DOI: 10.32517/0234-0453-2024-39-6-65-81. (дата обращения: 29.07.2026)

3. **Шамсутдинова Т.М**. Проблемы и перспективы применения нейронных сетей в сфере образования // Открытое образование. — 2022. — Т. 26, № 6. — С. 4–10. — DOI: 10.21686/1818-4243-2022-6-4-10. (дата обращения: 22.07.2026)

4. **Choi H.J., Lee J.H.** An Adaptive Learning System for Personalized Learning Experience with a Knowledge Tracing Algorithm and Learning Analytics in an LMS // Proceedings of the 13th International Conference on Electronics, Computers and Artificial Intelligence (ECAI 2021). — IEEE, 2021. — P. 1–4. — DOI: 10.1109/ECAI52376.2021.9515158. — URL: https://doi.org/10.1109/ECAI52376.2021.9515158 (дата обращения: 18.06.2026).

5. **Corbett A.T., Anderson J.R.** Knowledge Tracing: Modeling the Acquisition of Procedural Knowledge // User Modeling and User-Adapted Interaction. — 1995. — Vol. 4, No. 4. — P. 253–278. — DOI: 10.1007/BF01099821. — URL: https://doi.org/10.1007/BF01099821 (дата обращения: 22.06.2026).

6. **Dietterich T.G.** Ensemble Methods in Machine Learning // Multiple Classifier Systems (MCS 2000). Lecture Notes in Computer Science. — 2000. — Vol. 1857. — P. 1–15. — DOI: 10.1007/3-540-45014-9_1. — URL: https://doi.org/10.1007/3-540-45014-9_1 (дата обращения: 12.06.2026).

7. **Fukui A., Park D.H., Yang D., Rohrbach A., Darrell T., Zitnick C.L.** Multimodal Compact Bilinear Pooling for Visual Question Answering and Visual Grounding // Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing (EMNLP). — 2016. — P. 457–468. — DOI: 10.18653/v1/D16-1044. — URL: https://doi.org/10.18653/v1/D16-1044 (дата обращения: 22.06.2026).

8. **Garcez A.S., Lamb L.C., Gabbay D.M.** Neural-Symbolic Cognitive Reasoning. — Berlin: Springer, 2009. — 197 p. — DOI: 10.1007/978-3-540-73246-4. — URL: https://doi.org/10.1007/978-3-540-73246-4 (дата обращения: 19.06.2026).

9. **Hochreiter S., Schmidhuber J.** Long Short-Term Memory // Neural Computation. — 1997. — Vol. 9, No. 8. — P. 1735–1780. — DOI: 10.1162/neco.1997.9.8.1735. — URL: https://doi.org/10.1162/neco.1997.9.8.1735 (дата обращения: 22.06.2026).

10. **Holzinger A., Langs G., Denk H., Zatloukal K., Müller H.** Causability and Explainability of Artificial Intelligence in Medicine // Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery. — 2019. — Vol. 9, No. 4. — Art. e1312. — DOI: 10.1002/widm.1312. — URL: https://doi.org/10.1002/widm.1312 (дата обращения: 22.06.2026).

11. **Jayakumar S.M., Czarnecki W.M., Menick J., Schwarz J., Rae J., Osindero S., Teh Y.W., Harley T., Pascanu R.** Multiplicative Interactions and Where to Find Them // International Conference on Learning Representations (ICLR). — 2020. — URL: https://openreview.net/forum?id=rylnK6VtDH (дата обращения: 05.06.2026).

12. **Ji Z., Lee N., Frieske R., Yu T., Su D., Xu Y., Ishii E., Bang Y.J., Madotto A., Fung P.** Survey of Hallucination in Natural Language Generation // ACM Computing Surveys. — 2023. — Vol. 55, No. 12. — Art. 248. — P. 1–38. — DOI: 10.1145/3571730. — URL: https://doi.org/10.1145/3571730 (дата обращения: 01.05.2026).

13. **Kim J., Kim T., Kim S.** Stock Price Prediction Using LSTM-GNN Hybrid Model // Applied Sciences. — 2022. — Vol. 12, No. 15. — Art. 7601. — DOI: 10.3390/app12157601. — URL: https://doi.org/10.3390/app12157601 (дата обращения: 22.06.2026).

14. **Kingma D.P., Welling M.** Auto-Encoding Variational Bayes // International Conference on Learning Representations (ICLR). — 2014. — URL: https://arxiv.org/abs/1312.6114 (дата обращения: 03.04.2026).

15. **Kipf T.N., Welling M.** Semi-Supervised Classification with Graph Convolutional Networks // International Conference on Learning Representations (ICLR). — 2017. — URL: https://arxiv.org/abs/1609.02907 (дата обращения: 22.06.2026).

16. **Lundberg S.M., Lee S.-I.** A Unified Approach to Interpreting Model Predictions // Advances in Neural Information Processing Systems 30 (NeurIPS 2017). — 2017. — P. 4765–4774. — URL: https://arxiv.org/abs/1705.07874 (дата обращения: 22.06.2026).

17. **Mateus B.C., Mendes M., Farinha J.T., Martins A.** Hybrid Deep Learning for Predictive Maintenance: LSTM, GRU, CNN, and Dense Models // Energies. — 2024. — Vol. 18, No. 21. — Art. 5634. — DOI: 10.3390/en18215634. — URL: https://doi.org/10.3390/en18215634 (дата обращения: 22.06.2026).

18. **Nakagawa H., Iwasawa Y., Matsuo Y.** Graph-based Knowledge Tracing: Modeling Student Proficiency Using Graph Neural Network // Proceedings of the IEEE/WIC/ACM International Conference on Web Intelligence. — 2019. — P. 156–163. — DOI: 10.1145/3350546.3352513. — URL: https://doi.org/10.1145/3350546.3352513 (дата обращения: 22.06.2026).

19. **Piech C., Bassen J., Huang J., Ganguli S., Sahami M., Guibas L., Sohl-Dickstein J.** Deep Knowledge Tracing // Advances in Neural Information Processing Systems 28 (NeurIPS 2015). — 2015. — P. 505–513. — URL: https://proceedings.neurips.cc/paper/2015/hash/bac9162b47c56fc8a4d2a519803d51b3-Abstract.html (дата обращения: 17.06.2026).

20. **Popenici S.A.D., Kerr S.** Exploring the Impact of Artificial Intelligence on Teaching and Learning in Higher Education // Research and Practice in Technology Enhanced Learning. — 2017. — Vol. 12. — Art. 22. — DOI: 10.1186/s41039-017-0062-8. — URL: https://doi.org/10.1186/s41039-017-0062-8 (дата обращения: 22.06.2026).

21. **Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser Ł., Polosukhin I.** Attention Is All You Need // Advances in Neural Information Processing Systems 30 (NeurIPS 2017). — 2017. — P. 5998–6008. — URL: https://proceedings.neurips.cc/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html (дата обращения: 18.06.2026).

22. **Zadeh A., Chen M., Poria S., Cambria E., Morency L.-P.** Tensor Fusion Network for Multimodal Sentiment Analysis // Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing (EMNLP). — 2017. — P. 1103–1114. — DOI: 10.18653/v1/D17-1115. — URL: https://doi.org/10.18653/v1/D17-1115 (дата обращения: 22.06.2026).

23. **Zawacki-Richter O., Marín V.I., Bond M., Gouverneur F.** Systematic Review of Research on Artificial Intelligence Applications in Higher Education — Where Are the Educators? // International Journal of Educational Technology in Higher Education. — 2019. — Vol. 16. — Art. 39. — DOI: 10.1186/s41239-019-0171-0. — URL: https://doi.org/10.1186/s41239-019-0171-0 (дата обращения: 17.06.2026).