

Научная статья | Original paper

УДК 004.8:159.9.072:37.018.43

Искусственный интеллект в психодиагностике: когнитивные состояния в цифровой образовательной среде

Н.Е. Юрьева

Московский государственный психолого-педагогический университет

Москва, Российская Федерация

✉ yurieva.ne@gmail.com

Резюме

В статье рассматривается задача построения мультимодальных ИИ-моделей для диагностики когнитивного состояния обучающихся (концентрация, усталость, стресс) в цифровых образовательных средах. Обоснована необходимость перехода от традиционных методов психодиагностики к автоматизированным системам на основе обработки естественного языка, компьютерного зрения и поведенческого анализа. Предложена математическая модель на основе гибридной архитектуры CNN-LSTM с адаптацией параметров под индивидуальные когнитивные профили. Описана структура модели, приведены рекомендации по её построению и интеграции в цифровую образовательную инфраструктуру. Обсуждаются проблемы интерпретируемости, приватности и устойчивости таких моделей, а также перспективы их применения.

Ключевые слова: когнитивное состояние, мультимодальный анализ, искусственный интеллект, нейросети, персонализированное обучение, цифровая среда

Для цитирования: Юрьева, Н.Е. Искусственный интеллект в психодиагностике: когнитивные состояния в цифровой образовательной среде. *Моделирование и анализ данных*, 15(3), 47—55. <https://doi.org/10.17759/mda.2025150303>



Artificial intelligence in psychodiagnostics: cognitive states in a digital educational environment

N.E. Yuryeva

Moscow State University of Psychology and Education, Moscow, Russian Federation

✉ yuryeva.ne@gmail.com

Abstract

The article discusses the task of building multimodal AI models for diagnosing the cognitive state of students (concentration, fatigue, stress) in digital educational environments. The necessity of transition from traditional methods of psychodiagnostics to automated systems based on natural language processing, computer vision and behavioral analysis is substantiated. A mathematical model based on the CNN-LSTM hybrid architecture with the adaptation of parameters to individual cognitive profiles is proposed. The structure of the model is described, recommendations for its construction and integration into the digital educational infrastructure are given. The problems of interpretability, privacy, and sustainability of such models, as well as the prospects for their application, are discussed.

Keywords: cognitive state, multimodal analysis, artificial intelligence, neural networks, personalized learning, digital environment

For citation: Yuryeva, N.E. (2025). Artificial intelligence in psychodiagnostics: cognitive states in a digital educational environment. *Modelling and Data Analysis*, 15(3), 47—55. (In Russ.). <https://doi.org/10.17759/mda.2025150303>

Введение

Цифровизация образования стала неотъемлемой частью современного образовательного процесса, трансформируя не только методы преподавания и формы представления учебного материала, но и способы взаимодействия между участниками образовательной среды (Солдатова, 2018). Одним из наиболее перспективных направлений является интеграция технологий искусственного интеллекта (ИИ) для мониторинга и сопровождения обучающихся. Особенно важной задачей становится оценка когнитивного состояния студентов, включающего такие параметры, как концентрация внимания, усталость и уровень стресса — ключевые индикаторы успешного усвоения материала.

Традиционные подходы к психодиагностике, включая анкетирование, интервью и наблюдение, характеризуются высокой степенью субъективности и ограниченной чувствительностью к кратковременным колебаниям состояния (Reis et al., 2018). В условиях онлайн-обучения, когда преподаватель зачастую не имеет визуального и аудиального контакта с обучающимся, данные методы становятся еще менее



применимыми (Reis et al., 2018). В ответ на эти вызовы развивается новое направление — когнитивно-ориентированная ИИ-психодиагностика, основанная на автоматическом анализе мультимодальных данных.

Использование ИИ позволяет обрабатывать неструктурированные данные — такие как текст, аудио, видео и поведенческие метрики — в реальном времени. Это создает предпосылки для построения персонализированных адаптивных траекторий обучения, ориентированных на текущее психоэмоциональное состояние обучающегося. Особенно перспективным является мультимодальный подход, сочетающий различные каналы восприятия, что повышает достоверность предсказания когнитивных состояний (D'Mello & Kory, 2015).

Целью работы является разработка методологических и математических основ построения ИИ-модели для диагностики когнитивного состояния студентов в цифровой образовательной среде. В статье обоснована необходимость формализации задач классификации когнитивного состояния, приведены принципы построения гибридных нейросетевых архитектур и рассмотрены вызовы, связанные с внедрением подобных технологий в образовательную практику.

Постановка задачи

Задача предсказания когнитивного состояния студента формализуется как задача многоклассовой классификации по множеству признаков, извлечённых из мультимодальных источников.

Обозначим обучающую выборку как:

$$D = \{(X_i, y_i)\}_{i=1}^N$$

где $X_i \in \mathbb{R}^d$, $y_i \in 0, 1, 2$.

Здесь X_i — вектор признаков для i -го объекта, собранный из четырёх модальностей:

- $X_i^{(text)} \in \mathbb{R}^{d^1}$ — текстовые признаки (эмбединги, синтаксические и семантические характеристики);
- $X_i^{(audio)} \in \mathbb{R}^{d^2}$ — аудиофичи (энергетика речи, длительность пауз, спектры);
- $X_i^{(video)} \in \mathbb{R}^{d^3}$ — визуальные признаки (движения глаз, выражения лица, мимика);
- $X_i^{(behavior)} \in \mathbb{R}^{d^4}$ — поведенческие характеристики (скорость набора текста, активность пользователя).

Итоговый вектор X_i получается конкатенацией всех подмножеств признаков:

$$X_i = [x_i^{(text)}; x_i^{(audio)}; x_i^{(video)}; x_i^{(behavior)}] \in \mathbb{R}^d,$$

где $d = d^1 + d^2 + d^3 + d^4$

Модель должна аппроксимировать отображение:

$$f: \mathbb{R}^d \rightarrow \{0, 1, 2\}$$



то есть, каждому объекту из пространства признаков сопоставляется класс из конечного множества меток.

Функция потерь определяется как усреднённая кросс-энтропия:

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K 1_{[y_i=k]} \cdot \log(\widehat{y_{i,k}})$$

где:

L — значение функции потерь;

N — число объектов в обучающей выборке;

K — число классов;

y_i — истинная метка i -го объекта;

$y_{i,k}$ — вероятность, что i -й объект принадлежит классу k ;

$1_{[y_i=k]}$ — индикатор (равен 1, если метка совпадает, и 0 — иначе).

Дополнительно модель должна удовлетворять следующим критериям:

- устойчивость к частичному отсутствию модальностей,
- способность к обучению на ограниченных выборках,
- интерпретируемость (с помощью attention, SHAP или LIME),
- персонализация — возможность адаптации под конкретного студента.

Обзор существующих подходов

Современные методы диагностики когнитивного состояния можно условно разделить на несколько классов (Baker, 2019):

1. **Физиологические методы:** анализ сердечного ритма, вариабельности пульса, электроэнцефалографии и других биомаркеров. Они обладают высокой точностью, но требуют специализированного оборудования и нарушают естественность образовательного процесса.
2. **Анализ текста (NLP):** применяется для оценки когнитивной сложности, уровня стресса и усталости по письменным или устным сообщениям обучающегося. Используются эмбединги (Word2Vec, BERT), модели тональности, лексическая насыщенность.
3. **Анализ аудиопотока:** позволяет оценить эмоциональное состояние по интонации, тембру, скорости речи. Это направление активно развивается с использованием сверточных и рекуррентных сетей, таких как LSTM.
4. **Компьютерное зрение:** технологии распознавания лиц и жестов позволяют оценивать вовлеченность, усталость, признаки скуки или стресса. (Grafsgaard et al., 2014) Особенно перспективны архитектуры CNN, интегрированные с attention-механизмами (D'Mello & Kory, 2015).
5. **Анализ поведения:** сбор логов взаимодействия с учебной платформой (переключение между вкладками, скорость выполнения заданий, клики) позволяет выявить паттерны, связанные с изменениями когнитивного состояния (Baker, 2019).



6. **Мультимодальные подходы:** объединяют все вышеуказанные источники, позволяя повысить достоверность диагностики. В качестве моделей используются CNN+LSTM, трансформеры (например, Multimodal Transformer), графовые нейронные сети. (Grafsgaard et al., 2014).
7. **Личностно-адаптивные модели:** комбинируют информацию о когнитивных стилях, привычках и прошлом опыте для персонализации диагностики.

Вывод: мультимодальные подходы обеспечивают наибольшую устойчивость к шуму, адаптивность и обоснованность предсказаний. Однако они предъявляют высокие требования к вычислительным ресурсам и инфраструктуре (D'Mello & Kory, 2015).

Методология

Модель построена по принципу параллельной обработки мультимодальных данных, с выделением и интеграцией признаков из каждой модальности в отдельных подсетях:

- Сверточная нейронная сеть (CNN) обрабатывает видеопоток, извлекая пространственные характеристики (мимика, движение глаз, выражение лица).
- Рекуррентная сеть LSTM используется для анализа аудио- и текстовых последовательностей, что позволяет учитывать их временную динамику.
- Полносвязная сеть (MLP) отвечает за анализ поведенческих признаков, таких как скорость набора, движение мыши, частота взаимодействий.

Итоговое представление z формируется путём конкатенации выходных векторов всех подмоделей:

$$z = \left[z^{(\text{video})}; z^{(\text{text})}; z^{(\text{audio})}; z^{(\text{behavior})} \right]$$

где каждая компонента соответствует вектору признаков, полученному из соответствующей модальности.

z — объединённое латентное представление;

$z^{(\text{video})}$ — вектор признаков с CNN;

$z^{(\text{text})}$ — из LSTM по тексту;

$z^{(\text{audio})}$ — из LSTM по аудио;

$z^{(\text{behavior})}$ — выход MLP по поведенческим данным.

Классификация осуществляется с помощью слоя Softmax:

$$\hat{y} = \text{Softmax}(Wz + b)$$

где $W \in \mathbb{R}^{K \times d'}$, z — объединённое латентное представление признаков, d' — его размерность, K — число классов;

- W — матрица весов выходного слоя,
- b — вектор смещений,
- \hat{y} — вектор предсказанных вероятностей принадлежности к каждому из классов.



Для повышения качества и устойчивости обучения в модели могут использоваться:

- Dropout — регуляризация за счёт случайного обнуления нейронов во время обучения;
- Batch Normalization — нормализация скрытых состояний для стабилизации и ускорения сходимости;
- Residual-соединения — прямые связи между слоями, улучшающие распространение градиентов в глубокой архитектуре.

Этапы обучения и параметры оптимизации

Процесс обучения предлагаемой модели включает два ключевых этапа, направленных на достижение высокой обобщающей способности и адаптацию к особенностям конкретной образовательной среды.

Этап 1. Базовое предварительное обучение

На первом этапе производится обучение на обобщённом наборе мультимодальных данных, включающем разнообразные записи речи, текста, видео и поведенческих признаков, полученных от множества пользователей. Этот набор данных создаётся путём агрегации открытых датасетов и собственных коллекций, соответствующих целевому контексту, но не привязанных к конкретной платформе.

Цель: сформировать устойчивые представления признаков, выявить кросс-модальные зависимости, повысить устойчивость модели к шуму и частичному отсутствию модальностей.

Этап 2. Тонкая настройка (до настройки модели)

На втором этапе производится до настройка модели на узкоспециализированной выборке, полученной с конкретной платформы дистанционного образования. Эта выборка отражает:

- специфическую динамику взаимодействий студентов с интерфейсом;
- доменные особенности языка, используемого в письменных и устных коммуникациях;
- характерные визуальные и аудиопрофили (например, веб-камеры, микрофоны, фон).

Цель: адаптировать модель к контексту реального применения, улучшить интерпретируемость и повысить точность классификации в конкретных условиях.

Обучение может проводиться с использованием градиентного спуска с адаптивной корректировкой шагов, например с помощью оптимизатора Adam (Kingma, Ba, 2015), который обеспечивает быструю сходимость и устойчивость при обучении на гетерогенных признаках.

Используемые параметры:

- Оптимизатор: Adam (Wang, Yu, 2025).
- Learning rate: 0.001 — выбран как сбалансированный стартовый шаг, обеспечивающий прогресс без переобучения.
- Batch size: 32 — разумный компромисс между стабильностью градиента и скоростью обучения.



- Количество эпох: 100 — установлено с учётом эмпирического сходимости на валидационных выборках.
Дополнительно могут использоваться:
- Early stopping по значению функции потерь на валидации.
- Model checkpointing — сохранение лучшей модели по метрике F1 или accuracy.

Этические и технические вызовы

Основные вызовы внедрения ИИ в психодиагностику связаны с:

1. **Приватностью:** аудио- и видеоданные являются чувствительными. Необходимы методы анонимизации, локальной обработки (on-device AI) и согласий на сбор данных (Kartasheva, 2022).
2. **Этическими рисками:** автоматическая диагностика может быть использована для санкций (например, понижения оценки), что требует включения человека в контур принятия решений (Савгильдина, 2024).
3. **Интерпретируемостью:** решения модели должны быть объяснимы для преподавателя и обучающегося. Это возможно через визуализацию attention-карт, генерацию текстовых объяснений. Для внедрения ИИ-моделей в образовательную практику важно обеспечить интерпретируемость выводов, особенно при использовании в поддержке принятия решений преподавателями (Grafsgaard et al., 2014).
4. **Инфраструктурой:** обработка мультимодальных потоков требует высокой вычислительной мощности. Решение — сжатие моделей (TinyML), внедрение онтологий для редукции признаков.
5. **Правовой неопределённостью:** пока нет нормативной базы, регулирующей ИИ-диагностику в образовании.

Заключение

ИИ-психодиагностика представляет собой перспективное направление цифровой педагогики, позволяющее в реальном времени отслеживать и учитывать когнитивное состояние обучающихся. Мультимодальные модели позволяют повысить точность, устойчивость и адаптивность диагностических систем, обеспечивая тем самым переход от статичной модели обучения к динамически адаптируемой.

Разработка таких систем требует междисциплинарного подхода — сочетания машинного обучения, когнитивной психологии и педагогики. В будущем необходимо:

- расширение корпусных баз для обучения моделей;
- создание стандартов этической ИИ-диагностики;
- разработка человеко-ориентированных интерфейсов;
- реализация открытых фреймворков для образовательных учреждений.

Представленный подход может рассматриваться как один из возможных шагов в сторону персонализированного цифрового образования (Коровникова, 2021), однако его практическая реализация потребует дальнейших исследований, апробации и нормативного закрепления.



Список источников / References

1. Baker, R.S. (2019). Challenges for the future of educational data mining: The Baker Learning Analytics Prizes. *Journal of Educational Data Mining*, 11(1), 1—17. <https://doi.org/10.5281/zenodo.3554745>
2. D'Mello, S., & Kory, J. (2015). A review and meta-analysis of multimodal affect detection systems. *ACM Computing Surveys*, 47(3), Article 43. <https://doi.org/10.1145/2682899>. Открытый PDF (author version): <https://people.ict.usc.edu/~gratch/CSCI534/Readings/dmello-MMML-Survey.pdf>
3. Grafsgaard, J.F., Wiggins, J.B., Boyer, K.E., Wiebe, E.N., & Lester, J.C. (2014). Predicting learning and affect from multimodal data streams in task-oriented tutorial dialogue. In J. Stamper, Z. Pardoc, M. Mavrikis, & B.M. McLaren (Eds.), *Proceedings of the 7th International Conference on Educational Data Mining (EDM 2014)* (pp. 122—129). International Educational Data Mining Society. <https://learndialogue.org/pdf/LearnDialogue-Grafsgaard-EDM-2014.pdf>
4. Reis, R.C.D., Isotani, S., Rodriguez, C.L., Jaques, P.A., & Bittencourt, I.I. (2018). Affective states in computer-supported collaborative learning: Studying the past to drive the future. *Computers & Education*, 120, 29—50. <https://doi.org/10.1016/j.compedu.2018.01.015>. Открытый PDF: <https://isiarticles.com/bundles/Article/pre/pdf/126884.pdf>
5. Kingma, D.P., Ba, J. (2015). Adam: A method for stochastic optimization. *arXiv*. <https://doi.org/10.48550/arXiv.1412.6980>
6. Kartasheva, M.I. (2022). The role of the self-system in the structure of mental states regulation during the educational activities. *Yaroslavl Pedagogical Bulletin*, (1), 162—174. <https://doi.org/10.20323/1813-145X-2022-1-124-162-174>
7. Wang, J., Yu, Y. (2025). *Machine learning approach to student performance prediction of online learning*. *PLOS ONE*, 20(1), e0299018. <https://doi.org/10.1371/journal.pone.0299018>
8. Солдатова, Г.У. (2018). Цифровая социализация в культурно-исторической парадигме: изменяющийся ребенок в изменяющемся мире. *Социальная психология и общество*, 9(3), 71—80. <https://doi.org/10.17759/sps.2018090308>
Soldatova, G.U. (2018). Digital socialization in the cultural-historical paradigm: A changing child in a changing world. *Social Psychology and Society*, 9(3), 71—80. (In Russ.). <https://doi.org/10.17759/sps.2018090308>
9. Савгильдина, И.С. Использование искусственного интеллекта в образовании: перспективы и этические дилеммы // Актуальные исследования. 2024. № 46 (228). Ч. II. С. 66—68. URL: <https://apni.ru/article/10526-ispolzovanie-iskusstvennogo-intellekta-v-obrazovanii-perspektivy-i-eticheskie-dilemmy>
Savgildina, I.S. (2024). The use of artificial intelligence in education: Prospects and ethical dilemmas. *Actual Research*, 46(228), Pt. II, 66—68. (In Russ.). URL: <https://apni.ru/article/10526-ispolzovanie-iskusstvennogo-intellekta-v-obrazovanii-perspektivy-i-eticheskie-dilemmy>
10. Коровникова, Н.А. Искусственный интеллект в образовательном пространстве: проблемы и перспективы // Социальные новации и социальные науки. — Москва: ИНИОН РАН, 2021. — № 2. — С. 98—113
Korovnikova, N.A. (2021). Artificial intelligence in the educational space: Problems and prospects. *Social Innovations and Social Sciences*, 2, 98—113. (In Russ.). Moscow: INION RAS.



Информация об авторах

Юрьева Наталья Евгеньевна, кандидат технических наук, научный сотрудник, Московский государственный психолого-педагогический университет (ФГБОУ ВО МГППУ), г. Москва, Российская Федерация, ORCID: <https://orcid.org/0000-0003-1419-876X>, e-mail: yuryeva.ne@gmail.com

Information about the authors

Nataliya E. Yuryeva, PhD (Engineering), Research Fellow, Moscow State University of Psychology and Education (MSUPE), Moscow, Russia, ORCID: <https://orcid.org/0000-0003-1419-876X>, e-mail: yuryeva.ne@gmail.com

Поступила в редакцию 22.08.2025

Поступила после рецензирования 01.09.2025

Принята к публикации 02.09.2025

Опубликована 30.09.2025

Received 2025.08.22

Revised 2025.09.01

Accepted 2025.09.02

Published 2025.09.30