

Разговорный искусственный интеллект для инклюзивного образования

*Виктория Игоревна Фирсанова, Санкт-Петербургский государственный университет,
аспирант 2 года обучения, st085687@student.spbu.ru, +79043372620*

Разговорный искусственный интеллект — это область исследований, связанная с разработкой диалоговых систем, например, чат-ботов и виртуальных помощников. Диалоговые модели обеспечивают взаимодействие человека и машины, моделируя человеческую реакцию на текстовые стимулы. Такие агенты, как ChatGPT или Google Bard, доказали свою эффективность в решении задач образовательного (Kasneci et al., 2023), медицинского (Moons, Van Bulck, 2023), информационного (Sobania et al., 2023) и других секторов. Однако применение разговорного искусственного интеллекта в социальной сфере связано с рисками. Робастные генеративные модели требуют особого обращения (промт-инжиниринга), склонны к «галлюцинациям» (порождению фальшивой, но весьма убедительной информации) и дискриминации, вызванной предвзятостью (bias) (Kasneci et al., 2023). Исследование изучает перспективы внедрения моделей разговорного искусственного интеллекта в сферу инклюзивного образования и предлагает несколько вариантов решений перечисленных проблем на примере разработки диалогового агента для людей с расстройствами аутистического спектра.

В работе используется авторский вопросно-ответный датасет на тему инклюзивного образования и расстройств аутистического спектра, с которым можно ознакомиться по ссылке <https://doi.org/10.6084/m9.figshare.13295831>. Собранный мной набор данных использовался для разработки разговорной модели машинного обучения и экспериментов из следующих областей искусственного интеллекта, как науки: Data-Centric AI (Zha et al., 2023), Transfer Learning (Ruder et al., 2019), Graph Learning (Xia et al., 2021).

Набор данных, использованный в настоящем исследовании, наследует структуру датасета SQuAD 2.0 (Rajpurkar et al., 2018). Свой материал я собирала с помощью краудсорсинг-платформы Toloka. Краудворкерам предлагалось прочитать отрывки текста, извлеченные из русскоязычного веб-ресурса Autistic City (<https://aspergers.ru>), а затем сформулировать один или несколько вопросов к отрывкам и перечислить возможные ответы. Для оценки влияния структуры данных на производительность модели я преобразовывала дизайн датасета несколько раз в рамках экспериментирования. Более подробную информацию можно найти в моей статье "Two

Approaches to Building Dialogue Systems for People on the Spectrum". Статья была представлена на воркшопе Data Centric AI NeurIPS 2021 и доступна по адресу https://datacentricai.org/neurips21/papers/123_CameraReady_NeurIPS_2021.pdf.

Датасет использовался для тонкой настройки нескольких моделей с архитектурой Transformer (Vaswani et al., 2017) с открытым исходным кодом. Производились попытки создания извлекающих и генеративных вопросно-ответных систем с помощью добавления слоев для извлечения текста к моделям BERT (Devlin et al., 2019), DistilBERT (Sanh et al., 2019) и XLM-RoBERTa (Conneau et al., 2020), а также использования вопросов из датасета в качестве префикса для генеративной модели GPT-2 (Radford et al., 2019), которая должна была научиться отвечать на вопросы на основе информации из датасета с помощью мета-обучения. Демонстрация работы представлена в репозитории и пример использования модели доступны в репозитории <https://github.com/vifirsanova/empr>. Графовое обучение в данном исследовании является экспериментальной идеей улучшения моделей вопросно-ответных систем путем комбинирования возможностей больших языковых моделей, таких как ChatGPT или InstructGPT (Ouyang et al., 2022), с графовым машинным обучением.

Список источников:

1. Conneau, A., Khandelwal, K., Goyal, N., Chaudhary, V., Wenzek, G., Guzmán, F., ... & Stoyanov, V. (2019). Unsupervised cross-lingual representation learning at scale. arXiv preprint arXiv:1911.02116.
2. Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:1810.04805.
3. Kasneci, E., Seßler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., ... & Kasneci, G. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274.
4. Moons, P., & Van Bulck, L. (2023). ChatGPT: can artificial intelligence language models be of value for cardiovascular nurses and allied health professionals. *European Journal of Cardiovascular Nursing*.
5. Ouyang, L., Wu, J., Jiang, X., Almeida, D., Wainwright, C., Mishkin, P., ... & Lowe, R. (2022). Training language models to follow instructions with human feedback. *Advances in Neural Information Processing Systems*, 35, 27730-27744.

6. Radford, A., Wu, J., Child, R., Luan, D., Amodei, D., & Sutskever, I. (2019). Language models are unsupervised multitask learners. *OpenAI blog*, 1(8), 9.
7. Rajpurkar, P., Jia, R., & Liang, P. (2018). Know what you don't know: Unanswerable questions for SQuAD. *arXiv preprint arXiv:1806.03822*.
8. Sanh, V., Debut, L., Chaumond, J., & Wolf, T. (2019). DistilBERT, a distilled version of BERT: smaller, faster, cheaper and lighter. *arXiv preprint arXiv:1910.01108*.
9. Sobania, D., Briesch, M., Hanna, C., & Petke, J. (2023). An analysis of the automatic bug fixing performance of ChatGPT. *arXiv preprint arXiv:2301.08653*.
10. Xia, F., Sun, K., Yu, S., Aziz, A., Wan, L., Pan, S., & Liu, H. (2021). Graph learning: A survey. *IEEE Transactions on Artificial Intelligence*, 2(2), 109-127.
11. Zha, D., Bhat, Z. P., Lai, K. H., Yang, F., Jiang, Z., Zhong, S., & Hu, X. (2023). Data-centric artificial intelligence: A survey. *arXiv preprint arXiv:2303.10158*.