

**Культурная предвзятость в российских системах искусственного интеллекта:
анализ идеологических репрезентаций в нейросети Шедевр**

Научный руководитель – Телин Кирилл Олегович

Саджая Лука Васильевич

Студент (магистр)

Московский государственный университет имени М.В.Ломоносова, Факультет
политологии, Кафедра государственной политики, Москва, Россия

E-mail: luka.sadjaya@yandex.ru

Проблема культурной предвзятости в алгоритмах становится ключевой в контексте разработки национальных систем Искусственного Интеллекта (ИИ). Исследование фокусируется на нейросети Шедевр (Яндекс) как примере, демонстрирующем противоречие между стремлением к технологическому суверенитету и доминированием западно-центричных культурных репрезентаций в российской разработке. Объект исследования — визуальные образы политических идеологий, генерируемые нейросетью, предмет — культурная предвзятость в их формировании. Методология включала систематический анализ изображений девяти идеологий (коммунизм, социализм, анархизм, национализм, фашизм, нацизм, либертарианство, либерализм, консерватизм) по четырём категориям: понятие, будущее, общество, типичный представитель.

Основные результаты исследования:

1. Нейросеть Шедевр демонстрирует значительную западноцентричность в визуализации идеологий. Например, левые идеологии (коммунизм и социализм) представлены через стереотипные образы разрушения и упадка, с преобладанием красного цвета и военной символики. При этом коммунизм ассоциируется преимущественно с азиатскими и русскими персонажами, что отражает географическую привязку идеологии.
2. Анархизм визуализируется как постапокалиптический сценарий с разрухой и мародерами, что свидетельствует о смешении понятий "анархизм" и "анархия". Нацизм и фашизм представлены через депрессивные образы с элементами антиутопии, что также соответствует западным культурным стереотипам.
3. Либерализм и либертарианство ассоциируются с позитивными образами, связанными с американской государственной символикой, что подчеркивает доминирование западной перспективы в алгоритмах нейросети.
4. Консерватизм визуализируется через образы, напоминающие членов английского парламента или американских политиков, включая Дональда Трампа, что указывает на культурную предвзятость в репрезентации данной идеологии.

Проблема культурной предвзятости в нейросети Шедевр отражает более широкий феномен "западного взгляда" в разработках искусственного интеллекта [4]. Этот феномен связан с концепцией "датаколониализма" [3]. Преобладание западных данных в обучающих выборках создает форму информационной колонизации, навязывая чуждые культурные модели. Аналогичные выводы представлены в исследованиях, изучающих навязывание стереотипов алгоритмами, в том числе в поисковых системах и в других генеративных нейросетях [1, 2, 5, 6, 7, 8, 9]. Эти исследования подтверждают, что алгоритмы искусственного интеллекта часто становятся инструментами культурной гегемонии, что проявляется и в работе нейросети Шедевр.

Выводы:

1. Шедевр воспроизводит западноцентричные идеологические стереотипы, что противоречит целям технологического суверенитета.

2. Для создания культурно-релевантных систем ИИ необходимы датасеты, отражающие российские интерпретации социально-политических концепций.

3. Разработка таких систем должна избегать идеологической ангажированности, стремясь к отражению многообразия общественных дискурсов.

Исследование подчёркивает актуальность коррекции культурной предвзятости в отечественных нейросетях как условия достижения подлинного технологического суверенитета.

Источники и литература

- 1) Basu, A., Babu, R. V., & Pruthi, D (2023). Inspecting the Geographical Representativeness of Images from Text-to-Image Models. Indian Institute of Science, Bangalore.
- 2) Buolamwini, J., Gebru, T. (2018). Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification. Proceedings of the 1st Conference on Fairness, Accountability and Transparency, PMLR 81, 1–15.
- 3) Couldry, N., Mejias, U. A. (2019). The Costs of Connection: How Data Is Colonizing Human Life and Appropriating It for Capitalism. Stanford University Press.
- 4) Gautam, S., Venkit, P. N., Ghosh, S. (2024). From Melting Pots to Misrepresentations: Exploring Harms in Generative AI.
- 5) Hagerty, A., Rubinov, I. (2019). Global AI Ethics: A Review of the Social Impacts and Ethical Implications of Artificial Intelligence.
- 6) Kidd, C., Birhane, A. (2023). How AI Can Distort Human Beliefs. Science, 380(6651), 1222–1223
- 7) Noble, S. U. (2018). Algorithms of Oppression: How Search Engines Reinforce Racism. New York: NYU Press, 2018.
- 8) Biases in large image-text AI model favor wealthier, Western perspectives // University of Michigan News. 2023. URL: <https://news.engin.umich.edu/2023/12/biases-in-large-image-text-ai-model-favor-wealthier-western-perspectives/> (дата обращения: 05.03.2025).
- 9) Rest of World. 2023. URL: <https://restofworld.org/2023/ai-image-stereotypes/> (дата обращения: 05.03.2025).