

Арсланов Марсель Сунильевич

студент 2 курса магистратуры по направлению «Программная инженерия»,
Уфимского университета науки и технологий,

РФ, г. Уфа

E-mail: osnovamarsel@yandex.ru

Валиев Салават Марсович

студент 2 курса магистратуры по направлению «Программная инженерия»,
Уфимского университета науки и технологий,

РФ, г. Уфа

E-mail: salawat.valieff@yandex.ru

ПЕРЕНОС ОБУЧЕНИЯ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ

Аннотация: в статье рассматриваются современные проблемы переноса обучения в больших языковых моделях (LLM). Проанализированы основные теоретические подходы к transfer learning, выявлены технологические барьеры, препятствующие эффективному переносу знаний. На основе изучения практических примеров сформулированы предложения по повышению эффективности адаптации LLM к специализированным задачам. Приведены данные о влиянии структуры датасетов и параметров моделей на качество переноса. Делается вывод о необходимости внедрения гибридных методов обучения и развитии meta-learning для дальнейшего повышения гибкости и точности LLM.

Ключевые слова: перенос обучения, большие языковые модели, адаптация моделей, transfer learning, fine-tuning, нейронные сети, генерация текста

TRANSFER LEARNING SYSTEM FOR LARGE LANGUAGE MODELS

Abstract: the article addresses current challenges of transfer learning in large language models (LLM). Theoretical approaches to transfer learning are analyzed, and technological barriers to effective knowledge transfer are identified. Based on the study of practical cases, proposals are formulated to improve the adaptation of LLMs to specialized tasks. The impact of dataset structure and model parameters on transfer quality is discussed. The article concludes on the necessity of implementing hybrid learning methods and developing meta-learning techniques to enhance the flexibility and accuracy of LLMs.

Keywords: transfer learning, large language models, model adaptation, fine-tuning, neural networks, text generation

Развитие больших языковых моделей (LLM) в последние годы впечатляет масштабами, но за завесой успехов скрывается парадокс: чем больше модель, тем труднее эффективно использовать её знания в новых задачах. Ожидание, что предобученные гиганты вроде GPT-NeoX будут "от природы" решать любые проблемы, не оправдалось. В исследовании Arutyunov и Avdoshin было показано, что без тщательной настройки большие трансформеры проваливают даже базовые конкурсные задания по программированию: после дообучения на специализированных датасетах модели типа GPT-NeoX смогли правильно решить лишь около 3% задач [1].

Ситуацию усложняет и высокая стоимость переноса. Дообучение модели с 20 миллиардами параметров требует использования восьми GPU NVIDIA A100 на протяжении многих дней [1]. Даже при наличии ресурсов часто нет необходимых качественных данных: по данным Dyomochkina и коллег, успешность машинного перевода напрямую зависит от структуры корпуса данных, уровня его разметки и энтропии текстов [2]. Высокоэнтропийные домены, такие как художественная литература, значительно ухудшают качество переноса знаний.

Проблема усугубляется цикличностью развития технологий. Как напоминает история машинного перевода (провал ALPAC в 1966 году [2]),

завышенные ожидания приводят к разочарованию и спаду интереса. Сейчас LLM рискуют повторить эту траекторию, если не будет найдено решений для эффективного переноса обучения.

Идея переноса обучения возникла далеко не вчера. Первые упоминания о возможности использовать знания, полученные на одной задаче для другой, датируются 1990-ми годами, когда начались первые эксперименты в области машинного зрения. Сегодня transfer learning прочно встроился в архитектуру работы с LLM.

Нажимова Н. А. и Лебедев А. А. выделяют три ключевых типа переноса: индуктивный, трансдуктивный и неконтролируемый [5]. Индуктивный перенос используется тогда, когда исходная и целевая задачи различаются, но имеются размеченные данные. Примером служит дообучение модели на датасетах медицинских текстов. Трансдуктивный перенос работает, когда исходная задача и данные совпадают, но разные распределения (например, перевод юридических документов с английского на китайский). Неконтролируемый перенос вообще не предполагает наличия разметки и применяется, например, в генерации кода на новых языках программирования.

Развитие методов переноса сопровождалось совершенствованием моделей. В эпоху традиционного rule-based машинного перевода (1960–1990 гг.) перенос знаний был ограничен жёсткими правилами. Переход к статистическому машинному переводу (SMT) в 1990-е годы и далее к нейронным методам (NMT) в 2010-е показал: успех переноса зависит от объема и качества данных [2].

Современные технологии переноса в больших языковых моделях часто используют стратегии fine-tuning и prompt-tuning. Fine-tuning предполагает полную адаптацию параметров модели к новой задаче, тогда как prompt-tuning позволяет обучать небольшие "подсказки", оставляя параметры модели нетронутыми. Копнин А. А. отмечает, что будущее лежит в интеграции методов: например, объединении fine-tuning с техникой хранения важнейших знаний через EWC (Elastic Weight Consolidation) [4].

Практика показывает, что даже мощные модели не всегда справляются с переносом. Arutyunov и Avdoshin провели серию экспериментов с моделями GPT-J (6 миллиардов параметров) и GPT-NeoX (20 миллиардов параметров), обучая их на датасете APPS, предназначенном для генерации программного кода. Результаты оказались плачевными: при строгой метрике успешного решения задачи модели достигли 0–3% точности [1].

Причина провала — неподходящий датасет и отсутствие предварительного обучения на коде. Попытка дообучить модели на корпусах вопросов и ответов со StackOverflow (StaQC, CoNaLa) привела к небольшому улучшению, но даже тогда уровень успешных тестов вырос всего до 3% [1]. Пример показателен: перенос без учета структуры данных и специфики задачи приводит к коллапсу.

В противоположность этому стоит опыт проекта МЕТЕО в Канаде. С 1976 по 2001 годы система автоматически переводила до 80 000 слов прогноза погоды ежедневно между английским и французским языками [2]. Успех объяснялся низкой энтропией текстов: структура сводок была крайне предсказуемой. Прямой перенос знаний работал почти идеально без сложного дообучения.

Dyomochkina V. V. также приводит примеры, где системы машинного перевода, несмотря на масштабные корпуса, терпели неудачи при работе с поэзией и художественными текстами [2]. Причина — высокая семантическая неоднозначность и слабая предсказуемость структуры текста.

Эти факты подчеркивают: перенос знаний невозможен без тщательной адаптации под конкретные условия применения. Принцип "обучил на всём — применяй где угодно" здесь не работает.

Чтобы изменить ситуацию, необходимо пересмотреть саму стратегию переноса обучения в больших моделях. Прежде всего, требуется качественная подготовка датасетов. Нажимова Н. А. указывает, что важен не столько объем данных, сколько их структура и релевантность [5]. Формирование специальных, низкоэнтропийных корпусов для дообучения позволяет повысить переносимость моделей без увеличения затрат на вычисления.

Бадалходжаев Т. И. делает акцент на использовании гибридных стратегий: например, сочетание дообучения на небольшом специализированном датасете с последующим prompt-tuning для решения частных задач [3]. Такой подход позволяет добиться высокого качества с минимальными ресурсами.

В техническом плане необходимо развитие методов адаптивного fine-tuning. Использование алгоритмов, фиксирующих важные параметры базовой модели (например, через Elastic Weight Consolidation), позволяет минимизировать "забывание" уже освоенных знаний при переносе [4].

Организационно важно понимать: большие языковые модели не универсальны. Они требуют создания специализированных версий для разных доменов. Примером может служить тренд на создание узкопрофильных LLM: CodeGen для программирования, BioGPT для биомедицины.

Наконец, концептуально необходимо внедрять идеи meta-learning и few-shot learning. Вместо длительного дообучения на больших датасетах модели должны уметь быстро адаптироваться к новым задачам на основе минимального количества примеров [4]. Эта стратегия уже доказала свою эффективность в системах zero-shot перевода между редкими языками [2].

Если же игнорировать эти рекомендации, рынок столкнется с очередной "зимой ИИ", аналогичной той, что последовала за докладом ALPAC 1966 года, обрушившим надежды на машинный перевод [2].

Список литературы

1. Arutyunov G. A., Avdoshin S. M. Big Transformers for Code Generation // Proceedings of the Institute for System Programming of the RAS. – 2022. – Vol. 34, No. 4. – P. 79–88. – DOI 10.15514/ISPRAS-2022-34(4)-6. – EDN SKLCPR.

2. Dyomochkina V. V., Gruzdev D. Yu., Lukyanova E. V. Machine translation in hindsight // Research Result. Theoretical and Applied Linguistics. – 2024. – Vol. 10, No. 2. – P. 21–45. – DOI 10.18413/2313-8912-2024-10-2-0-2. – EDN DXLYBG.

3. Бадалходжаев Т. И., Аргунова Н. В. Преимущества использования трансферного обучения // Информационно-коммуникационные технологии в педагогическом образовании. – 2023. – № 6(87). – С. 1–4. – EDN IWODYP.

4. Копнин А. А. Способы и методы машинного обучения: интеграция, взаимодействие и дополнение методов // Наука и бизнес: пути развития. – 2023. – № 12(150). – С. 21–24. – EDN ZERPMS.

5. Нажимова Н. А., Лебедев А. А. Transfer Learning в нейронных сетях // Тенденции развития науки и образования. – 2024. – № 108-12. – С. 93–95. – DOI 10.18411/trnio-04-2024-661. – EDN BCZPKU.