

ПРИМЕНЕНИЕ ДИНАМИЧЕСКОЙ РЕГУЛЯРИЗАЦИИ ПРИ ДООБУЧЕНИИ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ НА ДАННЫХ МЕДИЦИНСКОГО ДОМЕНА

Свириденко Дмитрий Константинович

Студент

НИЯУ МИФИ, Москва, Россия

E-mail: dmitrii.sviridenko@yandex.ru

Научный руководитель — Зайцев Константин Сергеевич

Большие языковые модели зарекомендовали себя как инструмент, способный решать широкий круг задач — от написания программного кода до создания сложных логических цепочек, что обеспечило им широкое применение в современной обработке естественного языка. Тем не менее, для успешной интеграции в узкоспециализированные области базовые модели нуждаются в дополнительном обучении с учителем на специализированных наборах данных [1]. Такое обучение связано с риском эффекта катастрофического забывания [2]. Это феномен, при котором модель, обученная на одной задаче, при дообучении на новой задаче теряет способность эффективно решать предыдущую.

Для обеспечения компромисса между адаптацией модели к новому предметному домену и сохранением ранее сформированных компетенций в литературе предлагается ряд методологических подходов [3]. К ним относятся: (1) методы регуляризации параметров (например, Elastic Weight Consolidation), ограничивающие изменение весов, значимых для предыдущих задач; (2) архитектурные методы, предусматривающие динамическое расширение структуры нейронной сети для интеграции новых знаний (в частности, использование LoRA-адаптеров); (3) методы воспроизведения, основанные на сохранении подмножества ранее наблюдавшихся данных и их повторном включении в процесс дообучения; (4) методы дистилляции знаний, реализуемые в рамках парадигмы «учитель–ученик».

На практике наибольшая эффективность достигается при комбинировании указанных подходов, например совместном применении LoRA для повышения вычислительной эффективности обучения и различных схем регуляризации. Так, метод Elastic Weight Consolidation ограничивает вариации параметров, критически важных для ранее освоенных задач, тогда как дистилляция знаний от фиксированной модели-учителя минимизирует расхождение между вероятностными распределениями выходов обучаемой и базовой мо-

делей. Однако статичность регуляризатора ограничивает пластичность модели: фиксированные ограничения препятствуют эффективному усвоению новой терминологии, конфликтующей с исходными представлениями.

Развитием идей регуляризации стали динамические подходы, при которых модель-учитель изменяется в процессе обучения. Такие методы основаны на концепции «учитель-ученик»: обучаемая модель (модель-ученик) обучается на текущей задаче, а модель-учитель обновляется с определенной задержкой.

В результате работы был реализован метод, который использует дистилляцию через KL-дивергенцию между логитами обучаемой модели и динамически изменяемой модели-учителя, веса которой обновляются по закону экспоненциального скользящего среднего.

Разработанный метод был экспериментально проверен на модели Qwen2-1.5B при дообучении на медицинском корпусе, состоящем из описания результатов тонкоигольной аспирационной биопсии (ТАБ) узлов щитовидной железы. Модель, обученная предложенным методом, продемонстрировала лучший баланс между адаптацией к новому домену и сохранением предобученных знаний по сравнению с альтернативными подходами: дообучением с использованием статической модели-учителя и обучением без регуляризации.

Литература

1. Raffel C., Shazeer N., Roberts A., Lee K., Narang S., Matena M., Zhou Y., Li W., Liu P. J. Exploring the limits of transfer learning with a unified text-to-text transformer // Journal of Machine Learning Research. 2020. Vol. 21. P. 1–67.
2. Luo Y., Yang Z., Meng F., Li Y., Zhou J., Zhang Y. An empirical study of catastrophic forgetting in large language models during continual fine-tuning: <https://arxiv.org/abs/2308.08747>.
3. Wang L., Zhang X., Su H., Zhu J. A comprehensive survey of continual learning: Theory, method and application: <https://arxiv.org/abs/2302.00487>.