

## **ПРОТОКОЛ РАСПРОСТРАНЕНИЯ КРИВИЗНЫ ДЛЯ АУГМЕНТАЦИИ ПРОИЗВОЛЬНОЙ ТОПОЛОГИИ НЕЙРОННЫХ СЕТЕЙ ЧЕРЕЗ ПРИЗМУ ЛОКАЛЬНОЙ ГЕОМЕТРИИ**

**Введение.** Современные методы обучения глубоких нейронных сетей в основном опираются на градиенты первого порядка. На практике это приводит к типичной ситуации: модель продолжает обучаться, но качество и устойчивость оптимизации начинают деградировать, а причины трудно локализовать по одному лишь градиенту. Во многих архитектурах данная проблема смягчается за счет заранее заданных остаточных связей[3], нормализаций или ручного увеличения ширины слоев. Однако выбор расположения skip-connections и других структурных модификаций обычно определяется шаблонами (например, регулярной разметкой блоков) или перебором вариантов, что плохо переносится на модели со сложной топологией вычислительного графа. Научная проблема состоит в отсутствии практичного и достаточно строгого аппарата, который позволял бы измерять “проходимость” архитектуры для сигналов кривизны и на этой основе принимать решения о структурном вмешательстве во время обучения. Иными словами, требуется перейти от диагностики к управлению: не только фиксировать геометрические ограничения оптимизации, но и целенаправленно изменять топологию сети так, чтобы устранить архитектурные узкие места.

**Основная часть.** В работе предлагается протокол распространения кривизны для нейронных сетей произвольной топологии, представимых ориентированным ациклическим графом. В отличие от распространенных подходов, ограничивающихся приближенными внутрислойными оценками кривизны или анализом спектра Гессиана постфактум[4], рассматривается межзловое (межблочное) взаимодействие: насколько согласованно разные части графа “видят” геометрию ландшафта потерь[5] в ходе оптимизации. Протокол строится как вычисляемое расширение стандартного обратного распространения, где вместо хранения полной матрицы Гессиана используются направленные произведения Гессиана на вектор[1] и их стохастические агрегаты. Такая постановка делает возможной регулярную оценку межблочных эффектов для больших моделей без квадратичных затрат памяти.

На основе результатов протокола вводится интерпретируемая диагностическая карта, описывающая качество межблочного взаимодействия в графе. На практике это проявляется как выявление “геометрических теней”: ситуаций, когда между функционально связанными блоками формально существует путь вычислений, но вклад кривизны при распространении по этому пути существенно ослабевает. Подобные зоны приводят к тому, что параметры разных частей сети обновляются слабо согласованно, возрастает чувствительность к гиперпараметрам и повышается риск остановки оптимизации. Ключевой особенностью подхода является то, что диагностический сигнал интерпретируется как управляющий: карта взаимодействия становится критерием структурного вмешательства.

В рамках данной работа основная задача разрабатываемого протокола - аналитический синтез skip-connections. Вместо заранее заданной схемы добавления остаточных связей предлагается процедура выбора мест для соединения узлов, которая опирается на измеряемую в процессе обучения картину межблочной кривизны. В простейшем варианте протокол выделяет пары блоков, между которыми наблюдается устойчивое ослабление

взаимодействия, и формирует ограниченный набор кандидатов для добавления остаточного пути. Далее выполняется проверка кандидатов в щадящем режиме: связь вводится через параметризованный “мягкий” канал, что позволяет оценить ее влияние на согласованность кривизны без разрушения текущей динамики обучения. Выбор производится по принципу максимального восстановления глобальной когерентности графа при минимальном числе добавленных ребер, то есть с учетом вычислительного бюджета и ограничений по сложности. В результате skip-connections интерпретируются не как архитектурный шаблон, а как средство восстановления проводимости кривизны между блоками.

Важно, что тот же формализм естественно обобщается на другие типы аугментации. Если протокол фиксирует локальный “коллапс взаимодействия” внутри блока или в окрестности узла, то вместо добавления skip-пути может быть целесообразно расширение параметрической емкости: увеличение ширины, добавление параллельной ветви, установка адаптеров или введение дополнительных линейных преобразований. В предлагаемой концепции такие вмешательства трактуются единообразно - как способы повысить способность архитектуры передавать и согласовывать сигналы кривизны[2]. Таким образом, формализм не привязан к конкретному семейству сетей: он применим к сверточным, рекуррентным и архитектурам Transformer, а также к комбинированным вычислительным графам, где ручной дизайн соединений затруднен.

**Выводы.** Предложенный протокол распространения кривизны переводит анализ второго порядка из режима “дорогой post-диагностики” в режим практического инструмента управления структурой модели. Основной практический результат - методика целевого синтеза skip-connections по измеряемому межблочному взаимодействию, позволяющая повышать устойчивость оптимизации и снижать зависимость от эвристик разметки остаточных путей. Дополнительный результат - единый критерий для запуска более общей аугментации топологии и параметров (расширения, добавления ветвей и адаптеров) в тех зонах, где геометрическая согласованность деградирует. Предлагаемый подход может быть внедрен в существующие фреймворки глубокого обучения как модуль мониторинга и структурного контроля, работающий на основе произведений Гессиана на вектор и не требующий хранения полной матрицы.

#### **Список использованных источников**

1. Pearlmutter B. A. Fast exact multiplication by the Hessian //Neural computation. – 1994. – Т. 6. – №. 1. – С. 147-160.
2. Martens J., Grosse R. Optimizing neural networks with kronecker-factored approximate curvature //International conference on machine learning. – PMLR, 2015. – С. 2408-2417.
3. He K. et al. Deep residual learning for image recognition //Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – С. 770-778.
4. Ghorbani B., Krishnan S., Xiao Y. An investigation into neural net optimization via hessian eigenvalue density //International Conference on Machine Learning. – PMLR, 2019. – С. 2232-2241.
5. Amari S. Information geometry and its applications. – Springer, 2016. – Т. 194.