

Введение. Квантовые алгоритмы стали многообещающим средством решения сложных вычислительных задач, недоступных классическим компьютерам. Использование принципов квантовой механики позволяет находить решения с экспоненциально большей скоростью для некоторого спектра задач. Как пример квантовых алгоритмов хорошо себя зарекомендовали вариационные квантовые анзацы, которые нашли применение в областях химии, финансов и логистики. Одним из перспективных направлений выступает квантовое машинное обучение, где добавление всего одного кубита позволяет увеличить размерность модели вдвое. Однако на данный момент одной из основных трудностей применения квантового машинного обучения является алгоритм поиска градиента функции потерь. Для квантовых симуляторов данная задача решается, как и в классическом случае, однако такие техники не применимы в квантовых вычислениях. Существующие квантовые методы оказываются медленными [1] или труднореализуемыми [2]. В данной работе представлен комбинированный подход получения градиента, в основе которого лежат идеи из квантового алгоритма обратного распространения [2] и параметрического сдвига [3]. Новая реализация позволяет считать градиент параллельно для нескольких параметров и может быть использована для текущих реализаций квантовых вычислителей.

Основная часть. Суть алгоритма параметрического сдвига [3] заключается в получении градиента в виде разности двух прогонов одной и той же схемы, но с различными сдвигами на $\pi/2$ по интересующему параметру и в данном подходе получение градиента является постобработкой результатов вычисления квантового компьютера. Предлагаемый нами метод благодаря принципу квантовой суперпозиции позволяет получать градиент по интересующему параметру сразу из результатов вычислений без постобработки. Также наличие параллелизма позволяет получить кратное ускорение, несмотря на усложнение итоговой квантовой схемы и некоторое снижение точности.

Для применения данного метода при обучении квантовых нейронных сетей необходимо также задать функцию потерь прямо внутри квантовой цепи. В случае бинарной классификации можно применить соответствующий гейт поворота, что правда даёт периодическую функцию потерь, но подходящую при малых значениях скорости обучения.

Выводы. В рамках данной работы был реализован представленный метод поиска градиента функции потерь для квантового машинного обучения на квантовом симуляторе. При оптимизации модели по одному параметру наблюдается ускорение на 20–30% в сравнение с широко используемым параметрическим сдвигом при равном количестве запусков квантовой схемы. Также был реализован метод для оптимизации модели по нескольким параметрам (3), что дало кратное ускорение вычисления градиента.

Список использованных источников:

1. K. Mitarai, M. Negoro, M. Kitagawa, K. Fujii Quantum Circuit Learning // Physical Review Letters – 2018 – A 98, 032309 – pp. 1–2.
2. A. Abbas, R. King, H.-Y. Huang, W.J. Huggins, R. Movassagh, D. Gilboa, Jarrod R. McClean On quantum backpropagation, information reuse, and cheating measurement collapse // <https://arxiv.org/abs/2305.13362> – 2023 – pp. 21–22.
3. M. Schuld, V. Bergholm, C. Gogolin, J. Izaac, N. Killoran Evaluating analytic gradients on quantum hardware // Physical Review Letters – 2019 – A 99, 032331 – 2–3.