

В.М. Синеглазов, д.т.н.  
(Національний авіаційний університет, Україна)  
П.А. Чинник  
(НТУУ «КПІ ім. Ігоря Сікорського», Україна)

### Нові квантові оператори у задачі розпізнаванні зображень

*У даній роботі запропоновано нові параметризовані квантові оператори для машинного навчання. Розглянуто їх використання у машинному навчанні. Зроблено порівняння квантових моделей: квантова модель на основі запропонованих квантових операторів, квантова модель на основі класичних параметризованих квантових операторів.*

Нові квантові оператори в задачах розпізнавання зображень відкривають нові горизонти для розвитку комп'ютерного зору та машинного навчання. Квантові алгоритми, використовуючи феномени квантової суперпозиції та заплутаності, мають потенціал значно покращити ефективність та точність аналізу великих обсягів даних зображень. У даній доповіді демонструються можливості застосування нових квантових операторів для розпізнавання зображень, а також оцінюється їх вплив на продуктивність і якість алгоритмів у порівнянні з класичними операторами.

У квантових моделях машинного навчання основному використовують параметризовані оператори  $R_x(\theta)$  і  $R_y(\theta)$

$$R_x(\theta) = \begin{bmatrix} \cos \frac{\theta}{2} & -i \sin \frac{\theta}{2} \\ -i \sin \frac{\theta}{2} & \cos \frac{\theta}{2} \end{bmatrix}$$

$$R_y(\theta) = \begin{bmatrix} \cos \frac{\theta}{2} & -\sin \frac{\theta}{2} \\ \sin \frac{\theta}{2} & \cos \frac{\theta}{2} \end{bmatrix}$$

Як ми бачимо у квантовому операторі фігурують тригонометричні функції, звідси слідує, що квантовий стан системи буде залежати від цих періодичних функцій і наше математичне сподівання спостереження буде залежати від тригонометричної функції. Із-за того, що це є періодична функція нам важко робити навчання квантової моделі, тому що ми обмежені в певному інтервалі. Якщо ми будемо виходити з цього інтервалу, то ми отримуватимемо

знову ті самі значення тригонометричної функції, що означає, що ми отримуватимемо одні й ті самі квантові стани.

Тому ми пропонуємо замість тригонометричних функцій, використовувати гіперболічні функції, у яких немає періодів.

Нижче продемонстровано гіперболічний оператор  $Hx(x)$  і  $Hу(x)$

$$Hx(x) = \frac{1}{\sqrt{ch^2(x) + sh^2(x)}} \begin{bmatrix} ch(x) & -ish(x) \\ ish(x) & ch(x) \end{bmatrix}$$

$$Hy(x) = \frac{1}{\sqrt{ch^2(x) + sh^2(x)}} \begin{bmatrix} ch(x) & -sh(x) \\ sh(x) & ch(x) \end{bmatrix}$$

Тепер продемонструємо результати навчання на датасеті MNIST. Розмір датасету 100 зображень: 50 – п'ятірок і 50 – одиниць. 70 об'єктів були в тренувальній вибірці, а 30 об'єктів у тестовій вибірці. Навчання відбувалося за допомогою алгоритму Adam з 300 ітерацій. Функція помилки MSE. Топологія мережі [2] наведена на рис. 1




Рис. 1. Топологія квантової моделі машинного навчання

На рисунку 2 наведено графік зменшення помилки моделі на основі оператора  $Ry$ .




Рис. 2. Графік помилки моделі на базі оператора  $R_y$

Результати навчання і прогнозування даної моделі наведенні в табл. 1

Таблиця 1

Результати прогнозування моделі на операторі  $R_y$

|  |  |  |  |  |  |  |
|--|--|--|--|--|--|--|
|  |  |  |  |  |  |  |
|  |  |  |  |  |  |  |
|  |  |  |  |  |  |  |
|  |  |  |  |  |  |  |

Результати прогнозування не втішні.

Тепер розглянемо на гіперболічних операторах. Як можемо бачити за рисунком 3, швидкість і якість навчання краща, ніж при використанні класичних квантових операторів.

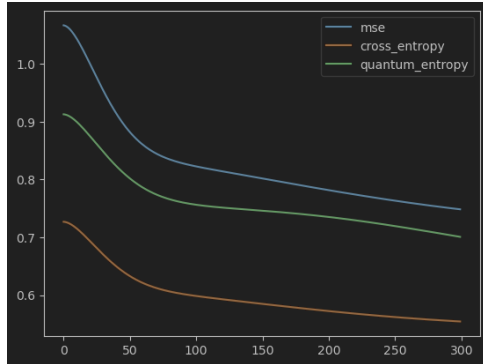


Рис. 3. Графік помилки моделі на базі оператора  $H_U$

Як можемо бачити, швидкість навчання моделі швидше, порівнянно з квантової моделі на базі  $H_U$ .

У таблиці 2 можемо бачити результати навчання і прогнозування моделі на базі  $H_U$ .

Таблиця 2

Результати прогнозування моделі на операторі  $H_U$

|  |  |  |  |  |  |  |
|--|--|--|--|--|--|--|
|  |  |  |  |  |  |  |
|  |  |  |  |  |  |  |
|  |  |  |  |  |  |  |
|  |  |  |  |  |  |  |

### Висновок

Результати експериментів продемонстрували, що квантові моделі, які базуються на гіперболічних операторах демонструють чудові характеристики навчання, порівняно з класичними квантовими операторами, які базують на тригонометричних функціях. На гіперболічних операторах модель навчається швидше і при цьому ми отримуємо результати навчання не гірші, ніж при використанні класичних операторів. На датасеті MNIST ми отримали помилку меншу, ніж при використанні класичних операторів, що демонструють метрики. Такого результату вдалося досягти, тому що гіперболічні функції не є періодичними і коли ми прямуємо до плюс чи до мінус нескінченності, тим самим математичне сподівання спостереження прямує до 1 чи до -1.

### Список літератури

1. M. Cerezo, Andrew Arrasmith, Ryan Babbush, Simon C. Benjamin, Suguru Endo, Keisuke Fujii, Jarrod R. McClean, Kosuke Mitarai, Xiao Yuan, Lukasz Cincio, and Patrick J. Coles (2019). Variational Quantum Algorithms [Online]. Available: <https://arxiv.org/pdf/2012.09265.pdf>
2. Diego Guala, Shaoming Zhang, Esther Cruz, Carlos A. Riofrío, Johannes Klepsch, Juan Miguel Arrazola (2023). Practical overview of image classification with tensor-network quantum circuits [Online]. Available: <https://www.nature.com/articles/s41598-023-30258-y>
3. L. Wright, F. Barratt, J. Dborin, V. Wimalaweera, B. Coyle, and A. G. Green (2022). Deterministic Tensor Network Classifiers [Online]. Available: <https://arxiv.org/pdf/2205.09768.pdf>
4. Diederik P. Kingma, Jimmy Lei Ba (2014). Adam: A Method For Stochastic Optimization [Online]. Available: <https://arxiv.org/pdf/1412.6980>