

ТЕХНИЧЕСКИЕ НАУКИ TECHNICAL SCIENCES

УДК 004.032.26
ББК 32.97
Г 27

Гушанский Сергей Михайлович

Кандидат технических наук, доцент кафедры вычислительной техники Института компьютерных технологий и информационной безопасности Южного федерального университета, Таганрог, тел. (8634) 371656, e-mail: smgushanskiy@sfnedu.ru

Горбунов Александр Валерьевич

Кандидат технических наук, доцент кафедры информационной безопасности телекоммуникационных систем Института компьютерных технологий и информационной безопасности Южного федерального университета, Таганрог, тел. (8634) 371902, e-mail: avgorbunov@sfnedu.ru

Переверзев Владимир Андреевич

Старший преподаватель кафедры вычислительной техники Института компьютерных технологий и информационной безопасности Южного федерального университета, Таганрог, тел. (8634) 371656, e-mail: pereverzevva@mail.ru

Применимость квантовых нейронных сетей для задач распознавания и обнаружения образов^{*} (Рецензирована)

Аннотация. Статья посвящена исследованиям, направленным на поиск методов применения квантовых нейронных сетей (КНС) для задач распознавания и обнаружения образов, обеспечивающих существенное сокращение времени вычислений при сохранении заданной точности. Рассматриваются особенности современного подхода к решению задач распознавания и обнаружения образов на основе нейронных сетей и глубокого обучения, анализируются принципы обработки данных в искусственных нейронных сетях, приводятся используемые в них алгоритмы. На примере распознавания и обнаружения образов выделяются недостатки, которые можно решить с привлечением квантовых нейросетей, и приводятся возможные преимущества, получаемые от переноса алгоритмов и принципов обработки современных глубоких нейросетей на платформу квантовых вычислений. Проанализированы возможности и дана оценка применимости использования КНС для задач распознавания и обнаружения образов и, как следствие, практической, физической реализации КНС на симуляторах и в дальнейшем на реальных квантовых вычислителях. Представлен метод обучения КНС для компьютерного моделирования квантовых принципов обработки данных, что позволит изучать и анализировать функционирование созданной КНС, а также оптимизировать ее с учетом особенностей симуляции квантовых вычислений.

Ключевые слова: нейронные сети, кубит, квантовая схема, квантовая нейронная сеть, распознавание, обнаружение образов.

Gushansky Sergey Mikhaylovich

Candidate of Technical Sciences, Associate Professor of Department of Computer Engineering, Institute of Computer Technologies and Information Security, Southern Federal University, Taganrog, ph. (8634) 371656, e-mail: smgushanskiy@sfnedu.ru

Gorbunov Aleksandr Valeryevich

Candidate of Technical Sciences, Associate Professor of Department of Information Security of Telecommunication Systems, Institute of Computer Technologies and Information Security, Southern Federal University, Taganrog, ph. (8634) 371902, e-mail: avgorbunov@sfnedu.ru

Pereverzev Vladimir Andreevich

Senior Lecturer of Department of Computer Engineering, Institute of Computer Technologies and Information Security, Southern Federal University, Taganrog, ph. (8634) 371656, e-mail: pereverzevva@mail.ru

Applicability of quantum neural networks for solving pattern recognition and detection problems

Abstract. The paper presents studies aimed at finding methods for applying quantum neural networks (QNN) for pattern recognition and pattern detection, providing a significant reduction in computation time while maintaining a

^{*} Работа выполнена при финансовой поддержке РФФИ, грант № НК 19-07-01082.

given accuracy. The features of the modern approach to solving pattern recognition and detection problems based on neural networks and deep learning are considered. The principles of data processing in artificial neural networks are analyzed, and the algorithms used in them are presented. An example of pattern recognition and detection is used to highlight the disadvantages that can be solved with the involvement of quantum neural networks, and to report the possible benefits derived from the transfer of algorithms and processing principles of modern deep neural networks to the quantum computing platform. The feasibilities are analyzed and an assessment is made of the applicability of the use of QNN for problems of pattern recognition and detection and, as a result, of practical, physical implementation of QNN on simulators and later on real quantum devices. A method of teaching QNN for computer simulation of quantum principles of data processing is presented, which will allow studying and analyzing the functioning of the QNN created, as well as optimizing it taking into account the features of quantum computing simulation.

Keywords: neural networks, qubit, quantum scheme, quantum neural network, recognition, pattern detection.

Введение. Квантовые вычислители способны решать задачи, которые не под силу классическим машинам, и на данном этапе являются перспективным методом резкого повышения производительности вычислений. Хотя обширное внедрение квантовых вычислителей в массы при текущем уровне развития технологий невозможно, тем не менее, квантовые вычисления уже долгое время считаются одним из наиболее перспективных направлений. Можно отыскать сферы деятельности, в которых дела обстоят довольно оптимистично. Среди таких областей можно выделить криптографию, квантовую химию, некоторые материальные науки и с недавнего времени к этому списку можно отнести машинное обучение.

Как показано в [1], процесс создания квантовых алгоритмов, в том числе в области обработки изображений, весьма трудоемкий, и их общее количество несопоставимо мало, по сравнению с количеством классических.

В настоящее время наблюдается стремительный рост интереса к квантовым алгоритмам распознавания образов, поскольку уже появились первые квантовые компьютеры и программные интерфейсы к ним. Появились фирмы и стартапы, ориентированные на разработку и исследование исключительно данного направления компьютерной науки. Это объясняется тем, что применение квантовых алгоритмов после появления квантовых компьютеров позволяет экспоненциально увеличить скорость решения вычислительных задач. Такое важное преимущество квантовых алгоритмов при решении ряда сложных вычислительных задач и недостаточная изученность их возможностей позволяет сделать вывод о важности исследований в этой области.

Современные принципы распознавания и обнаружения образов. Если раньше для распознавания и обнаружения образов использовались методы компьютерного или технического зрения (Computer Vision), то есть теории и технологии создания машин, которые могут производить обнаружение, отслеживание и классификацию объектов, то в последнее время данные задачи активно используют технологии машинного обучения, искусственного интеллекта, включая такие направления, как глубокое обучение (Deep Learning) и нейронные сети (Neural Network).

Уже сложилась четкая динамика частичной замены методов из библиотек алгоритмов компьютерного зрения (например, OpenCV) глубокими искусственными нейросетями (YOLO, R-CNN, SegNet и т.п.), довольно хорошо справляющимися с задачами классификации, идентификации предметов, явлений, процессов и ситуаций.

Искусственные нейронные сети (ИНС) доказали свою полезность, и поэтому нельзя назвать удивительным факт привлечения в эту область квантовых нейронных сетей (КНС). Эти сети способны производить вычисления быстрее, чем классические ИНС, благодаря квантово-механическим эффектам.

Как упоминалось в [1], для моделирования задач распознавания и обнаружения образов на квантовых вычислителях необходимо исследовать 2 направления:

- разработать методики создания квантовых алгоритмов, обрабатывающих изображения путем преобразования классических алгоритмов обработки изображений в квантовые (аналог классических алгоритмов компьютерного зрения);
- провести исследование применимости квантовых нейронных сетей в задачах обнаружения и распознавания (аналог искусственных нейронных сетей).

Искусственный интеллект, машинное обучение, глубокое обучение. Связь между этими понятиями показана на рисунке 1 [2]. Под областью искусственного интеллекта обычно понимают автоматизацию интеллектуальных задач, выполняемых людьми. Искусственный интеллект (ИИ) – это громадная область, охватывающая машинное обучение и глубокое обучение, а также включающая в себя многие подходы, не связанные с обучением.

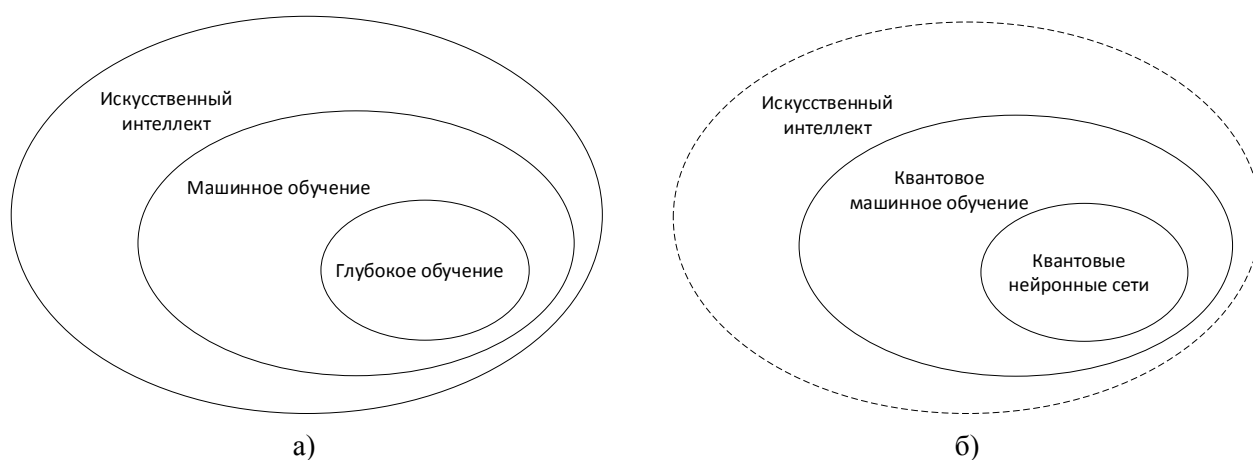


Рис. 1. Взаимосвязь искусственного интеллекта, машинного и глубокого обучения в классическом подходе (а) и квантовом подходе (б)

Машинное обучение (ML, Machine Learning) – это подмножество искусственного интеллекта, которое использует алгоритмы, чтобы научить компьютеры принимать решения, как это делают люди. Изначально основным направлением машинного обучения стало стремление имитировать человеческий мозг с помощью так называемых искусственных нейронных сетей. Эти нейронные сети моделируют работу нашего мозга, получая информацию, обрабатывая ее через последовательность искусственных нейронов и создавая выходные данные. Нейронные сети используют большое количество самых современных технологий искусственного интеллекта.

Хотя изначально, на заре появления нейронных сетей, витала идея бионического подхода, то есть имитации вычислений как в мозгу, однако на данный момент глубокое обучение – чистая математика, не имеющая к процессам в мозгу никакого отношения, а основными причинами успеха глубокого обучения стали:

- совершенствующиеся алгоритмы (обратного распространения ошибки, методов оптимизации Adam, RMSprop и т.п.) и архитектуры (CNN, RNN, GAN и т.п.);
- доступные объемы данных (dataset, наборы данных);
- ускорение обучения и вывода с помощью GPU (CUDA, OpenCL).

Искусственная глубокая нейронная сеть. Современные архитектуры глубоких нейронных сетей отличаются от предыдущих поколений наличием довольно большого (иногда более 100) количества скрытых слоев. Классическая структура таких нейросетей и устройство одного нейрона в ней показаны на рисунке 2.

С точки зрения математики нейронная сеть – это универсальный аппроксиматор, позволяющий аппроксимировать любую функцию и позволяющий реализовать любую сложную зависимость между входом и выходом. Чем больше будет слоев в многослойной нейронной сети, тем более сложное будет промежуточное представление и тем более сложную зависимость можно будет реализовать на ней.

Основой всех библиотек и пакетов глубокого обучения (TensorFlow, Keras, PyTorch и т.п.) является алгоритм для подсчета производных для любых дифференцируемых графов вычислений. Эффективный способ вычисления всех производных называется backpropagation (обратное распространение ошибки). Смысл его состоит в организации двух проходов вычислений, прямого (forward) и обратного (backward). И если на прямом осуществляется вычисление результирующей функции, то цель обратного – вычислить производные

и скорректировать веса, уменьшив ошибку. Также производные, которые считает обратный граф, нужно считать в определенной точке, именно для этого нужен прямой проход – он рассчитывает аргументы всех этих производных [3].

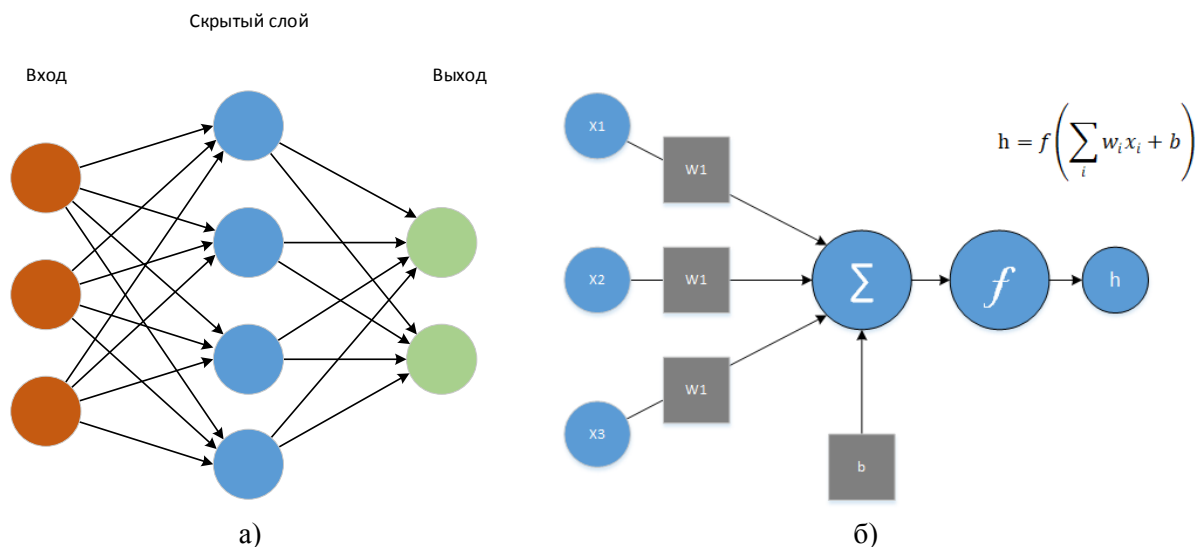


Рис. 2. Структура нейросетей (а) и классическая схема одного нейрона (б)

Следует отметить, что для распознавания и обнаружения образов на изображениях широкое применение нашли сверточные нейронные сети. Такие сети строятся чередованием сверточных и пулинговых слоев с полносвязными слоями на завершающих этапах нейронной сети. Впервые такая архитектура была представлена в [4]. Успешный перенос ее на новую вычислительную платформу снимет любые вопросы о применимости квантовых нейронных сетей в задачах распознавания и обнаружения образов.

Квантовые симуляторы. В настоящее время в мире, в том числе и в России, ведутся активные работы по исследованию и физической реализации квантового компьютера. Прототипы вычислительных устройств уже были построены в различных точках мира в различное время, но пока не создано полноценного и общедоступного квантового компьютера имеет смысл выполнять моделирование квантовых вычислений на ЭВМ с классической архитектурой.

Цели, преследуемые при построении программных моделей, совершенно разные – от моделирования квантового канала передачи данных в криптографии, до моделирования квантовых алгоритмов на группе кубит, поэтому модели строятся совершенно разными способами и подходами. Программные математические модели, являясь достаточно доступными, имеют ограниченную производительность и могут использоваться исключительно для разработки и отладки квантовых вычислительных алгоритмов.

На текущий момент существует большое количество различных сред моделирования (как консольных, так и графических), библиотек API, а также моделей отдельных алгоритмов. В настоящее время их общее количество, согласно [5], перевалило за сотню.

Графические среды моделирования предоставляют большие возможности для построения и управления процессом моделирования. Среди всех графических сред некоторые ориентированы на построение и моделирование алгоритмов с помощью квантовых схем, но они предоставляют совершенно разные возможности. Другие позволяют проводить моделирование воздействия операторов на кубит, одновременно визуализируя их действие на трехмерной модели кубита – сфере Блоха. Некоторые модели строятся на базе существующих математических сред моделирования, например, модель алгоритма Гровера, разработанная в Санкт-Петербургском государственном университете.

Однако вычислительная сложность таких имитаторов как частного случая моделирования квантовых явлений на классической вычислительной технике в общем случае требует экспоненциального объема данных и вычислений, что было показано еще в 1982 г. в

работе американского физика Ричарда Фейнмана «Моделирование физики на компьютерах». Поэтому разрабатываются математические и аппаратные методики, позволяющие в зависимости от моделируемого алгоритма квантового вычисления в несколько раз повысить вычислительную эффективность таких моделей и расширить возможности разработчиков квантовых алгоритмов по их отладке. Часть из них имеет математическое ядро, построенное на графовом подходе, который в отличие от обычного матричного подхода позволяет значительно экономить память при моделировании.

Отдельного упоминания заслуживают библиотеки API для построения программ моделирования квантовых вычислений, которые предоставляют готовый функционал для построения собственной модели. В качестве инструментов для увеличения производительности разрабатываемых средств моделирования могут использоваться уже готовые решения, такие как реализация симуляторов квантового вычислителя при помощи многопроцессорных вычислительных систем или ускорение моделирования при помощи видеокарт.

Что касается непосредственно аппаратной реализации, специализированной только под моделирование квантовых вычислений, то эти подходы имеют ряд недостатков. В частности – это зависимость аппаратных средств от программных, причем в плане оптимизации вычислений, так что эффективность такого подхода будет существенно зависеть от проблемно-ориентированного персонального компьютера.

В других работах осуществляется попытка переложить программную модель квантового компьютера на аппаратуру с использованием ПЛИС. В этом случае, предлагаемая модель не будет являться эффективной при достаточно сложных моделируемых алгоритмах, использующих для вычислений квантовую запутанность. Однако самой главной проблемой для эффективной работы аппаратного ускорителя является пересылка данных между ПК и ускорителем, так как объемы информации при моделировании квантового регистра более чем из 30 кубитов требуют для реализации свыше 1 Гб оперативной памяти; и далее, при увеличении числа кубитов, необходимые ресурсы растут экспоненциально.

Квантовое машинное обучение. Основным препятствием для нейронных сетей является время, необходимое для обучения их принятию решений. Нередко проводят недели, даже месяцы, обучая нейронную сеть из-за недостатка вычислительной мощности. Что, если бы был способ использовать возможности квантовых вычислений для ускорения процесса обучения, делая эти сложные сети осуществимыми?

Квантовое машинное обучение (Quantum Machine Learning) – пересечение машинного обучения и квантовых вычислений. Оно стремится использовать возможности квантовых компьютеров для обработки информации со скоростью, значительно превышающей скорость традиционных компьютеров. Однако это не так просто, как перенести существующий код из процессора в квантовый процессор. Код должен уметь сначала говорить на квантовом языке кубитов. Большая часть сегодняшней работы по квантовому машинному обучению и пытается решить именно эту проблему.

Если раньше это представление квантовой информации кубитом было единственным и все алгоритмы разрабатывались с учетом операций над кубитами или квантовыми регистрами (аналог цифрового сигнала), то в последнее время начал развиваться подход, использующий непрерывное представление при моделировании (аналог аналогового сигнала) квантовых гейтов.

Получается, что на данный момент существуют 2 варианта: discrete-variable (DV) гейты, используемые в кубитовой модели, и continuous-variable (CV) гейты, используемые в qumode модели квантовых вычислений.

Кубит (qubit) и кумод (qumode) – различные формы квантовых вычислений. Но большинство существующих квантовых компьютеров и чипов могут иметь дискретные переменные. Это связано также с тем, что для квантово-оптического частотного эксперимента, связанного с квантовыми вычислениями, шум среды непрерывной переменной намного выше, чем дискретной, что отражается на результате вычислений и измерений. Пока техника не достигла возможности при проведении квантовых вычислений исключить влияние внешней

среды и физических эффектов в ней на результаты работы квантовых вычислителей, данный подход, видимо, будет преобладающим.

Ясно, что размеры изображений задают чуть ли не самые существенные требования не только к квантовым вычислителям, но даже к симуляторам. Просто кодируя изображение по аналогии с битами изображения, уже для небольших изображений можно столкнуться с невозможностью реализации вычислений с использованием той или иной библиотеки. Большинство симуляторов, где в качестве аппаратных ускорителей используются видеокарты, могут моделировать до 24 кубит (связано с ограничениями ускорителя по работе с текстурами).

Однако в настоящее время проект Xanadu [6] разрабатывает модель обработки непрерывных переменных CV. У них есть некоторые наработки по алгоритмам CV и квантовому машинному обучению (QML). В качестве базовых частиц используются фотоны.

В традиционных квантовых компьютерах информация хранится в кубитах, которые могут принимать значения 0 или 1 и их суперпозиций. Их фотонный подход использует «структуры», где информация кодируется в непрерывной переменной. И таким образом, объем информации в каждой qumode может быть значительно больше, чем в кубите.

PennyLane – это кросс-платформенная библиотека Python для квантового машинного обучения, автоматического дифференцирования и оптимизации гибридных квантово-классических вычислений. В PennyLane устройство может быть аппаратным устройством (например, IBM QX4, через плагин PennyLane-PQ) или программным симулятором (например, Strawberry Fields, через плагин PennyLane-SF).

Библиотека поддерживает устройства, использующие как кубитную модель квантовых вычислений, так и устройства, использующие CV-модель квантовых вычислений. Фактически реализует гибридную модель вычислений, содержащую как кубит, так и квантовые узлы CV. На рисунке 3 показана структура графа гибридных вычислений. Используя такой универсальный математический базис квантовой теории информации, доступный в PennyLane, существует возможность независимо от архитектуры самого квантового компьютера провести анализ квантовых алгоритмов распознавания и обнаружения.




Рис. 3. Пример графа гибридных вычислений

Квантовые нейронные сети (КНС). Работающие нейронные сети стали огромным шагом вперед для искусственного интеллекта (ИИ). Тем не менее, существующие нейронные сети еще не в состоянии использовать мощь квантовых компьютеров. Первым шагом к созданию работающей КНС является моделирование отдельного квантового нейрона [7, 8].

Рассмотрим, как представлены квантовые нейроны и как КНС сравниваются с традиционными нейронными сетями.

Поскольку существуют разные интерпретации квантовой механики, существуют разные способы представления квантового нейрона. Одна из таких интерпретаций – многомировая интерпретация или интерпретация Эверетта. Эта теория утверждает, что суще-

ствуется множество параллельных вселенных, каждая из которых разыгрывает каждую возможную историю и будущее одновременно. Она дает представление о том, как следует вести себя КНС. Подобно тому, как традиционная нейронная сеть как бы «имитирует человеческий мозг», КНС может имитировать квантовую физику. Согласно [9] исследователи из Университета штата Пенсильвания используют эту интерпретацию для разработки методологии построения QNN.

Традиционные нейронные сети используют одну сеть для хранения множества шаблонов. Что если в КНС используется много сетей для хранения множества шаблонов, как, например, может быть много вселенных, содержащих много реальностей? Квантовая суперпозиция может сделать это возможным за счет суперпозиции, позволяя кубиту находиться в нескольких состояниях одновременно. Распространяя эту аналогию на нейронные сети, теоретически КНС сможет хранить все возможные шаблоны в суперпозиции одновременно (!). Таким образом, каждый шаблон в сети представляет свою собственную параллельную вселенную.

Фактическая реализация КНС, которая представляет несколько параллельных вселенных, еще не осуществима. Тем не менее, можно моделировать один квантовый нейрон. Согласно исследованию MIT Technology Review [10], исследовательская группа из Университета Павии в Италии внедрила первую в мире однослойную нейронную сеть на квантовом компьютере [11] в 2018 году.

В результате этой работы была предложена схема реализации искусственного нейрона на квантовом процессоре, показанная на рисунке 4.




Рис. 4. Обобщенная схема квантовой реализации искусственного нейрона на квантовом процессоре

Реализация унитарных преобразований на квантовом процессоре является сложной, что можно видеть на примере искусственного квантового нейрона на основе 4 кубитов (см. рис. 5). На высоком уровне вход проходит через серию гейтов, которые являются частью квантовой схемы. На рисунке они, обозначенные Z , $H^{\otimes N}$ и $X^{\otimes N}$, имитируют векторы весов в традиционных нейронных сетях.




Рис. 5. Квантовая схема для искусственного нейрона с 4 кубитами

Эта модель способна точно имитировать поведение одного нейрона. Тем не менее, он еще не масштабируется до глубокой нейронной сети, которая состоит из множества слоев таких нейронов. Представленная однослойная модель способна идентифицировать только простые шаблоны. Однако это, можно сказать, первый шаг в эффективном обучении КНС на квантовом оборудовании и шаг к реализации концепции многих миров нейронных сетей.

Преимущества квантовых нейронных сетей. КНС кажутся чрезвычайно сложными и непостижимыми. Но есть веская причина, почему они изучаются. Согласно [7, 9] КНС предлагают много преимуществ по сравнению с традиционными нейронными сетями, включая:

- экспоненциальная емкость памяти;
- более высокая производительность для меньшего количества скрытых нейронов;
- ускоренное обучение;
- скорость обработки (10^{10} бит/с);
- малый масштаб (10^{11} нейронов/мм³);
- более высокая стабильность и надежность.

Эти преимущества решают большинство, если не все, ограничения традиционных нейронных сетей, используемых в задачах распознавания и обнаружения образов. Это также означает, что существует чрезвычайно высокий стимул быть первопроходцем в квантовом пространстве машинного обучения, чтобы использовать эти преимущества. В настоящее время предпринимается много усилий для реализации полнофункциональной КНС.

Метод моделирования квантовых принципов обработки. В результате анализа квантовых симуляторов и библиотек мы остановились на упомянутой выше библиотеке PennyLane [6], так как в нее вошли все лучшие идеи классического машинного обучения, которые удалось перенести на квантовые компьютеры. Как уже отмечалось, главной составляющей в глубоком обучении является автоматическая дифференциация. Производная функции говорит нам, как эта функция изменяется, и, имея доступ к этой производной, мы можем постепенно модифицировать и оптимизировать модель машинного обучения в соответствии с нашими потребностями. Как правило, автоматическое дифференцирование реализуется с использованием алгоритма обратного прохода (backwardpass), который строит градиент, используя цепное правило.

Существует два пути применения методов автоматического дифференцирования к квантовым вычислениям. Первый заключается в моделировании квантовых вычислений с использованием классической библиотеки машинного обучения. Однако эта стратегия никогда не даст квантового преимущества, поскольку она по своей сути ограничена неэффективностью моделирования квантовой физики с помощью классических компьютеров. Вторая стратегия заключается в создании версии автоматической дифференциации, которая естественным образом совместима с квантовым оборудованием и которая будет продолжать работать и становиться все более полезной по мере того, как квантовые компьютеры будут прогрессировать.

Возникает вопрос: как мы можем вычислить градиенты квантовых вычислительных схем, когда даже моделирование их выхода классически неразрешимо? Разумным выходом из этой ситуации является использование одного и того же квантового оборудования как для оценки квантовой схемы, так и для вычисления ее градиентов. Архитектура такой гибридной КНС, позволяющей реализовывать обучение, представлена на рисунке 6.

На ней выделены части, выполняемые на квантовом (QPU) и классическом (CPU) процессоре. Условно алгоритм обучения можно разбить на 2 части. Алгоритм 1: квантовые состояния, которые были ранее подготовлены, подаются на квантовые модули, реализующие квантовую нейронную сеть для задач распознавания и обнаружения образов, которые вычисляют $\langle H_i \rangle$. Результат попадает в CPU в виде суммы всех состояний. Алгоритм 2: используя классический алгоритм оптимизации (Adam, RMSprop), работающий на CPU, принимает на вход совокупное состояние $\langle H \rangle$, определяет новые параметры состояния, которые затем

обратно подаются на QPU, реализуя таким образом классическую идею обратного распространения ошибки – коррекцию параметров по результатам вычислений.

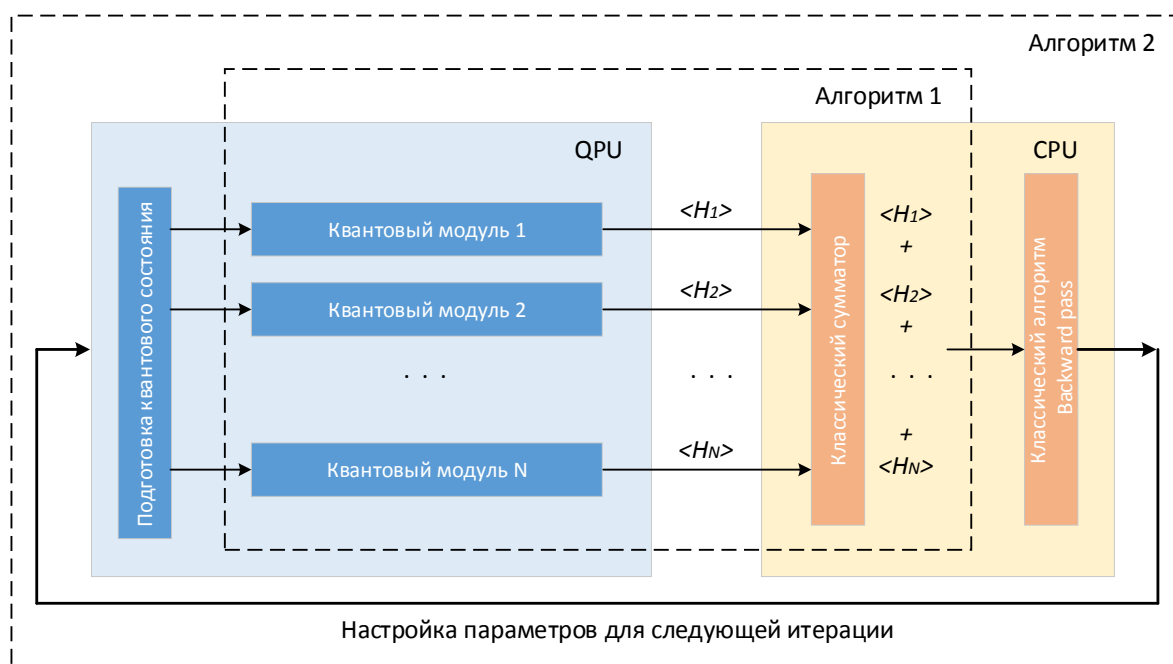


Рис. 6. Архитектура гибридной КНС

Заключение. На данный момент КНС находятся в стадии зарождения. Исследования, проводимые различными научными лабораториями [11–15], уже заложили основу для будущих работ в квантовом пространстве алгоритмов машинного обучения, что привело к появлению новых алгоритмов и квантовых нейронных сетей (quantum neural network, QNN).

Таким образом, предложен метод обучения КНС, позволяющий изучать и анализировать функционирование созданной КНС, а также оптимизировать ее с учетом особенностей симуляции квантовых вычислений в задачах распознавания и обнаружения образов.

Примечания:

1. The Computational Structure of the Quantum Computer Simulator and Its Performance Evaluation / V. Potapov, S. Gushansky, V. Guzik, M. Polenov // Software Engineering and Algorithms in Intelligent Systems: proceedings of 7th computer science on-line conference, 2018. Springer International Publishing Switzerland, 2018. Vol. 1. P. 198–207. URL: https://link.springer.com/chapter/10.1007/978-3-319-91186-1_21
2. Шолле Франсуа. Глубокое обучение на Python. СПб.: Питер, 2018. 400 с.
3. SkillFactory. Курс по нейронным сетям и deep learning. URL: <https://skillfactory.ru> (дата обращения: 20.04.2019).
4. The Computational Structure of the Quantum Computer Simulator and Its Performance Evaluation / V. Guzik, S. Gushanskiy, M. Polenov, V. Potapov // Advances in Intelligent Systems and Computing. Software Engineering Perspectives and Application in Intelligent Systems. Czech Republic, 2018.
5. List of QC simulators. URL: <https://quantiki.org/wiki/list-qc-simulators> (дата обращения: 16.03.2019).
6. Официальный сайт Xanadu. URL: <https://xanadu.ai> (дата обращения: 16.03.2019).

References:

1. The Computational Structure of the Quantum Computer Simulator and Its Performance Evaluation / V. Potapov, S. Gushansky, V. Guzik, M. Polenov // Software Engineering and Algorithms in Intelligent Systems: proceedings of 7th computer science on-line conference, 2018. Springer International Publishing Switzerland, 2018. Vol. 1. P. 198–207. URL: https://link.springer.com/chapter/10.1007/978-3-319-91186-1_21
2. Chollet F. Deep Learning with Python. SPb.: Piter, 2018. 400 pp.
3. SkillFactory. Course on neural networks and deep learning. URL: <https://skillfactory.ru> (access date: 20.04.2019).
4. The Computational Structure of the Quantum Computer Simulator and Its Performance Evaluation / V. Guzik, S. Gushanskiy, M. Polenov, V. Potapov // Advances in Intelligent Systems and Computing. Software Engineering Perspectives and Application in Intelligent Systems. Czech Republic, 2018.
5. List of QC simulators. URL: <https://quantiki.org/wiki/list-qc-simulators> (access date: 6.03.2019).
6. Official site of Xanadu. URL: <https://xanadu.ai> (access date: 16.03.2019).

7. Ежов А.А. Квантовые нейронные сети. URL: <http://www.triniti.ru/CTF&VM/Articles/Ezhov1.pdf> (дата обращения: 17.03.2019).
8. An Artificial Neuron Implemented on an Actual Quantum Processor / Francesco Tacchino, Chiara Macchiavello, Dario Gerace, Daniele Bajoni. URL: <https://arxiv.org/pdf/1811.02266.pdf> (дата обращения: 27.03.2019).
9. Alexandr A. Ezhov, Dan Ventura. Quantum neural networks. URL: <http://axon.cs.byu.edu/papers/ezhov.fdisis00.pdf>
10. MIT Technology Review. URL: <https://www.technologyreview.com/s/612435/machine-learning-meet-quantum-computing/> (дата обращения: 15.04.2019).
11. An Artificial Neuron Implemented on an Actual Quantum Processor / Francesco Tacchino, Chiara Macchiavello, Dario Gerace, Daniele Bajoni. URL: <https://arxiv.org/pdf/1811.02266.pdf> (дата обращения: 27.03.2019).
12. Quantum machine learning / J. Biamonte, P. Wittek, N. Pancotti, P. Rebentrost, N. Wiebe, S. Lloyd // Nature. 2017. N 549. P. 195–202.
13. Kapoor A., Wiebe N., Svore K. Quantum Perceptron Models, Advances In Neural Information Processing Systems (NIPS 2016). 2016. No. 29. P. 3999–4007.
14. Unsupervised Machine Learning on a Hybrid Quantum Computer / J.S. Otterbach, R. Manenti, N. Aldoudst, A. Bestwick, M. Block [et al.]. 2017. arXiv: 1712.05771.
15. Architecture and Software Implementation of a Quantum Computer Model / V. Guzik, S. Gushanskiy, M. Polenov, V. Potapov // 5th Computer Science On-line Conference (CSOS), 2016. Czech Republic, 2016. P. 59–68. URL: https://link.springer.com/chapter/10.1007/978-3-319-33622-0_6
7. Ezhov A.A. Quantum neural networks. URL: <http://www.triniti.ru/CTF&VM/Articles/Ezhov1.pdf> (access date: 17.03.2019).
8. An Artificial Neuron Implemented on an Actual Quantum Processor / Francesco Tacchino, Chiara Macchiavello, Dario Gerace, Daniele Bajoni. URL: <https://arxiv.org/pdf/1811.02266.pdf> (access date: 27.03.2019).
9. Alexandr A. Ezhov, Dan Ventura. Quantum neural networks. URL: <http://axon.cs.byu.edu/papers/ezhov.fdisis00.pdf>
10. MIT Technology Review. URL: <https://www.technologyreview.com/s/612435/machine-learning-meet-quantum-computing/> (access date: 15.04.2019).
11. An Artificial Neuron Implemented on an Actual Quantum Processor / Francesco Tacchino, Chiara Macchiavello, Dario Gerace, Daniele Bajoni. URL: <https://arxiv.org/pdf/1811.02266.pdf> (access date: 27.03.2019).
12. Quantum machine learning / J. Biamonte, P. Wittek, N. Pancotti, P. Rebentrost, N. Wiebe, S. Lloyd // Nature. 2017. N 549. P. 195–202.
13. Kapoor A., Wiebe N., Svore K. Quantum Perceptron Models, Advances In Neural Information Processing Systems (NIPS 2016). 2016. No. 29. P. 3999–4007.
14. Unsupervised Machine Learning on a Hybrid Quantum Computer / J.S. Otterbach, R. Manenti, N. Aldoudst, A. Bestwick, M. Block [et al.]. 2017. arXiv: 1712.05771.
15. Architecture and Software Implementation of a Quantum Computer Model / V. Guzik, S. Gushanskiy, M. Polenov, V. Potapov // 5th Computer Science On-line Conference (CSOS), 2016. Czech Republic, 2016. P. 59–68. URL: https://link.springer.com/chapter/10.1007/978-3-319-33622-0_6