

# NISQ デバイスを用いた量子ニューラルネットワークにおける 量子回路の構成と学習性能の評価

丸茂 直樹<sup>†</sup> 和田 康孝<sup>††</sup> 上田 和紀<sup>†</sup> 木村 啓二<sup>†</sup>

<sup>†</sup> 早稲田大学

<sup>††</sup> 明星大学

E-mail: <sup>†</sup>naoki\_marumo@fuji.waseda.jp, ueda@ueda.info.waseda.ac.jp, keiji@waseda.jp

<sup>††</sup>yasutaka.wada@meisei-u.ac.jp

**あらまし** 変分量子アルゴリズム (Variational Quantum Algorithm: VQA) による量子機械学習では、学習モデルを構成する部分 (Ansatz) の反復回数を多くするほど、そして多くの量子ビットがもつれ (エンタングルメント) を起こすほど学習能力が上がる。一方、現在実現されている量子ゲート方式コンピュータの NISQ (Noisy Intermediate-Scale Quantum computer) デバイスでは、ノイズを許容し誤り訂正を行わない。そのため回路が深くなるほどノイズによって理論通りの状態を出力できなくなる。すなわち、NISQ デバイスで VQA による量子機械学習を行うと、学習性能とデバイスのノイズ特性がトレードオフの関係になる。以上を踏まえ、本稿では、ノイズのある環境における回路構成の違いによる学習性能の差を精度の観点から評価した。評価の結果、VQA による量子機械学習においてエンタングルメントが必要不可欠であること、及びゲート数が最小限に抑えられる線形なエンタングルメントの場合には Ansatz の反復回数が増え、回路の深さが深くなっても精度の低下は小さく、ノイズのないシミュレーションと同等の性能が得られることを確認した。

**キーワード** NISQ, 量子機械学習, 変分量子アルゴリズム

## Evaluating composition of quantum circuit and learnability in quantum neural network with NISQ devices

Naoki MARUMO<sup>†</sup>, Yasutaka WADA<sup>††</sup>, Kazunori UEDA<sup>†</sup>, and Keiji KIMURA<sup>†</sup>

<sup>†</sup> Waseda University

<sup>††</sup> Meisei University

E-mail: <sup>†</sup>naoki\_marumo@fuji.waseda.jp, ueda@ueda.info.waseda.ac.jp, keiji@waseda.jp

<sup>††</sup>yasutaka.wada@meisei-u.ac.jp

### 1. はじめに

量子ゲート方式の量子コンピュータは適切なアルゴリズムを作ることで、組み合わせ最適化以外にも機械学習や化学計算などの様々な用途に利用可能であり、古典コンピュータでは解決が難しい問題への応用が期待されている。特に VQA による量子機械学習 [1]~[3] では、パラメータ化された量子回路 (Parameterized Quantum Circuit: PQC) のパラメータを学習モデルの重みとして学習する。そのため理論的には量子ゲートが多いほど学習能力は向上する。さらに VQA においてはエンタングルメントがあるほうが学習能力は向上する。

現在の量子ゲート方式のコンピュータは NISQ デバイスと呼ばれる小規模の量子ビットを備えたものである。その特徴は量子ゲートの操作によってノイズが生じる一方で誤り訂正をしないことであり、理想的な結果を得たい場合には量子ゲート数削減によるノイズの最小化が求められる。また、エンタングルメントは単一の量子ビットに対するゲートよりもエラーが発生しやすいので、エンタングルメントも最小化が求められる [4]。

NISQ デバイスで VQA による量子機械学習を実現する際は、この両方の観点を踏まえて回路を設計しなくてはならない。しかしながら、筆者等の知る限り VQA による量子機械学習における最適な量子回路の実現方法は見つかっておらず、ノイズの

ある環境における最適な回路の実現方法の体系化はさらに難しい。

本稿では、VQAによる量子機械学習の学習性能とノイズ特性がトレードオフであることに着目し、ノイズ環境下における最適な回路実現のために考慮すべき要素を検証した。

本稿の構成は以下の通りである。2.節でVQAによる量子機械学習とNISQデバイスの概要について説明し、3.節で関連研究を紹介する。4.節で様々な量子回路でのVQAによる量子機械学習を精度の観点で評価する。

## 2. 問題背景

### 2.1 量子機械学習

量子コンピュータでは古典的な機械学習では生成困難な統計パターンを生成し、古典的には認識が難しい統計パターンを認識できる可能性がある [5]。これまでに、VQA や、連続変数ニューラルネットワーク [6] などの様々な量子機械学習アルゴリズムが提案されている [7]。しかしながら、これらの評価は量子ビット数の制限やノイズの存在を前提としない理想的な環境を想定したものが多く、その一方で、現在利用可能なNISQデバイスには、上記で想定していなかった制限事項が存在することから、現時点で実装可能なアルゴリズムは多くない。本稿では、現時点で実装可能なVQAによる量子機械学習を実装し、その最適化を行う。

VQAによる量子機械学習は量子コンピュータと古典コンピュータのハイブリッド構成により実現されている (図1)。まず量子コンピュータでは古典的なデータの特徴を量子状態に符号化する (Feature Map)。この Feature Map に対してパラメータを持つ量子ゲートとエンタングルメントから構成される回路 (Ansatz) を作用させ、その後最終的な量子状態を測定する。量子状態測定後、古典コンピュータで測定した量子状態を古典的なデータに復号する。そして復号したデータと正解のラベルとの対応から誤差を算出し Ansatz のパラメータにフィードバックする。上記処理を複数回繰り返す、正解ラベルとの誤差が最小になるように Ansatz のパラメータを最適化する。

VQAによる量子機械学習は古典的なフィードフォワードニューラルネットワークに対し、表現可能性や学習可能性が高い [8]。その学習性能は Feature Map や Ansatz の量子回路の構成や最適化関数、制約に依存する。特に量子ニューラルネットワークの根幹に当たるPQCである Feature Map や Ansatz の構成の影響は大きい。本稿では特に Ansatz に着目し、その構成の違いによる性能の差を精度の観点で評価する。

Ansatz はパラメータを持つ回転ゲートの集合であるローテーションブロックと、もつれを生じさせる CNOT ゲートなどの集合であるエンタングルメントブロックを1つの大きなブロックとし、それが反復することで構成される。ローテーションブロックは Ansatz に1つ以上必要になる。Qiskitにより実装する際のエンタングルメントブロックの構成方法を以下に示す [9]。

- linear : 全体の量子ビット数が  $N$  の時、量子ビット  $q_k$  は量子ビット  $q_{k+1}, q_{k+2}, \dots, q_N$  ともつれる。
- full : 各量子ビットがほかのすべての量子ビットに対して

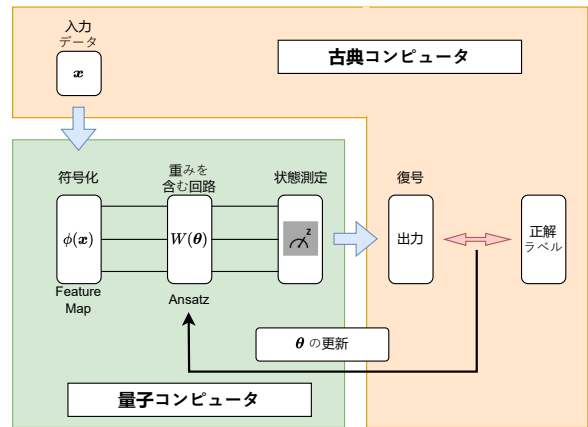


図1 VQAによる量子機械学習の構成

それぞれもつれる。

- reverse linear : linear とは逆方向にもつれる。全体の量子ビット数が  $N$  の時、量子ビット  $q_k$  は量子ビット  $q_{k-1}, q_{k-2}, \dots, q_0$  ともつれる。
- circular : 基本は linear と同じだが、その前に最後の量子ビットから最初の量子ビットに対するもつれがある。
- sca (shifted circular alternating) : 基本は circular と同じだが、circular で linear に対して追加した最後の量子ビットから最初の量子ビットに対するもつれを回路の反復に応じてシフトする。

ローテーションブロックに対するエンタングルメントブロックの割合、そしてその構成方法、Ansatz 中でのブロックの反復回数の組み合わせにより多様な種類の Ansatz を構成できる。Ansatz は古典ニューラルネットワークにおける中間層に当たり、その中のゲート数が多く、量子回路が深く、複雑になるほどモデルの表現能力が上がり、結果的に学習性能が上がる。

### 2.2 NISQ デバイス

ゲート方式の量子コンピュータは NISQ デバイスと汎用大型量子コンピュータに分類できる。汎用大型量子コンピュータは最低でも数万から数十万量子ビットをもち、誤り訂正も行うようなデバイスを表す。一方で、NISQ デバイスは数百から数千量子ビットを持つ小規模のものを表す。そしてノイズを許容し、誤り訂正をしないという特徴を持つ。現在、実現可能な量子ゲート方式のハードウェアは NISQ デバイスにあたる。

NISQ デバイスにおいて量子ビットが状態を維持することができる時間 (コヒーレンス時間) は限られており、経過時間により確率的に状態に誤りが生じ、これがノイズの原因となる。また、量子ビット間のクロストークもノイズの原因である。以上から回路中の量子ゲート数が増えるほどノイズが生じやすくなり、結果として状態に誤りが混入しやすくなる。しかし、NISQ デバイスでは誤り訂正をせず、これらを許容するため、量子回路の深さや幅が増加すると、量子回路から得られる状態の忠実度が低下し、信頼性も下がる [10]。すなわち、NISQ デバイスでは量子ゲートが少ないほどノイズの影響が小さくなる。ノイズの影響を小さくするためには、量子回路の深さを浅くし、量子

回路に含まれる量子ゲート数を少なくすることが求められる。また複数量子ビットに対するゲートは単一量子ビットに対するゲートよりもエラーの確率が高い [4]。そのためエンタングルメントも最小限にする必要がある。

### 2.3 NISQ デバイスを用いた VQA による量子機械学習

2.1 節では、Ansatz を複雑で深さの深い量子回路にすると VQA による量子機械学習の学習性能を上げることができると述べた。一方で、2.2 節では量子回路を浅くすると含まれる量子ゲートを最小化でき、NISQ デバイスにおけるノイズも最小化できることから、ノイズによる学習性能の低下を防ぐことができると述べた。すなわち Ansatz の構成について、VQA による量子機械学習の学習性能の特性と NISQ デバイスのノイズの特性がトレードオフの関係にある。本稿ではトレードオフの関係を踏まえて、ノイズのある環境における Ansatz の構成の違いによる学習性能の差を精度の観点で評価する。

量子回路の構成は論理量子ゲートレベルで考える。しかし、実機のデバイスに実装されている物理量子ゲートは限られている。そのため論理量子ゲートと物理量子ゲートは必ずしも 1 対 1 で対応するわけではなく、複数の物理量子ゲートの組み合わせによって 1 つの論理量子ゲートを構成する必要があることがある。さらに論理的な量子回路ではすべての量子ビットがそれぞれと接続しているが、実際にはすべての量子ビットと接続しているわけではなく、SWAP が挟まれる。つまり論理量子ゲートレベルでゲート数が少なくなるように構成しても、NISQ デバイスではその回路をさらに物理量子ゲートレベルにマッピングする必要があるため、組み合わせによってはこの時に量子ゲートが大幅に増加し、ノイズの原因になる [11]。

## 3. 関連研究

### 3.1 VQA におけるエンタングルメント

VQA は量子機械学習以外にも関数の最適化に効果的なアルゴリズムである。文献 [12] では VQA を物性物理等の固有値求解問題に利用している。Ansatz にエンタングルメントがない場合は、ある場合に比べて解が収束しきった時に最小化したい目的関数の値が大きくなるという実験結果を示し、VQA におけるエンタングルメントの必要性に言及している。

### 3.2 VQA による量子機械学習とノイズ

文献 [13] では本稿の評価対象の 1 つでもある Iris データセットについて、主に最適化関数や回路構成を変えた時にノイズのない場合のシミュレーションと実機で目的関数や精度を評価している。その結果、ノイズのない場合のシミュレーションの精度の最高は 97.7% であるのに対して、実機での最高の精度は 73.3% となった。この原因として、使用したデバイスの接続トポロジー制約によりゲート数が増加し、結果としてノイズの影響が大きくなったと述べている。

## 4. 評価

### 4.1 評価方法

本稿の評価では数値分類と Iris, Lupus, Aids [14], Teaching Assistant evaluation (TAE) の全 5 種類のデータセットを対象と

表 1 回路内のエンタングルメントの重要性の評価時の回路の組み合わせ

ローテーションブロック数 [個]	3	5
エンタングルメントブロック数 [個]	0, 1, 3	0, 1, 2, 5

表 2 Ansatz のエンタングルメントの種類とブロックの反復の評価時の回路の組み合わせ

エンタングルメント	linear, full, reverse linear, circular, sca, なし
反復回数 [回]	1, 2, 3, 4, 5, 6, 7, 8

し、各データセットの 80% を学習用に、20% を推論用に使用した。また、Ansatz の構成に関係しない実装上の構成は統一した。Feature Map はエンタングルメントの種類が linear で反復回数が 2 回の ZZ Feature Map を使用した。誤差関数は交差エントロピーを用いた。最適化手法には SPSA などの勾配を使う手法もあるが、今回は勾配を必要としない制約付きの線形近似による最適化を行う COBYLA を用いた。

まず、エンタングルメントの必要性を調査するため、回路の中のエンタングルメントブロックの数を変化させた。次に、最適なエンタングルメントの種類や回路ブロックの増加による性能向上とノイズの影響のトレードオフの関係を調査するため、エンタングルメントの種類や大きな回路ブロックの反復回数を変化させた。この 2 つのいずれの実験においても各構成で、最大のエポック数を 25, 50, 100, 200, 500 回と変え、それぞれ 4 回ずつ精度の測定を行い、その平均を調べた。また量子回路の構成によっては、エポック数が最大まで達する前に目的関数が収束しきり、最大まで達しないこともあったので、その場合は収束したときの平均のエポック数も求めた。これらのすべての組み合わせは Qiskit の AerSimulator によるノイズのないシミュレーションと、それに IBM 社の実機である IBM Brisbane のキャリブレーションデータを基にしたノイズのモデルを付加したノイズがあるシミュレーションで行った。

回路内のエンタングルメントの重要性を評価する時の回路の組み合わせを表 1 に示す。また、Ansatz のエンタングルメントの種類とブロックの反復の評価時の回路の組み合わせを表 2 に示す。

さらに実機である NISQ デバイスを用いて回路ブロックの反復と精度の評価を、シミュレーションで評価した組み合わせの中の一部について行った。具体的には Iris データセットについて、エンタングルメントの種類を linear、最大のエポック数を 25 回と固定し、回路ブロックの反復回数を 2 回と 4 回で変化させた。また実機の NISQ デバイスとして 127 量子ビットを持つ IBM Brisbane を使用した。IBM Brisbane の基本的なデータを表 3 に示す。

### 4.2 全データの結果

各データセットにおけるノイズの有無と精度の最高、最低、平均、中央値、分散を表 4 に示す。表より、ノイズのある場合の精度の分散に着目すると、Iris では 0.0133 であるのに対して、Iris 以外のデータセットではいずれも 0.004 未満で、分散が小さ

表3 IBM Brisbane の基本データ (2024年1月20日現在)

Qubit 数	127
Error per layered gate for a 100-qubit chain	1.9 %
Circuit layer operations per second	5K
Processor type	Eagle r3
Basis gates	ECR, ID, RZ, SX, X
Median ECR error	8.132e-3
Median SX error	2.308e-4
Median readout error	1.270e-2
Median T1	222.53 us
Median T2	140.7 us

表4 エンタングルメントの種類, 反復回数と精度についての各データセットの結果の概要

ノイズ	データセット	最高	最低	平均	中央値	分散
なし	数値分類	0.59	0.38	0.50	0.51	0.00131
	Iris	0.98	0.23	0.82	0.85	0.0149
	Lupus	0.79	0.56	0.71	0.72	0.00249
	Aids	0.53	0.27	0.40	0.40	0.00371
	TAE	0.52	0.23	0.37	0.37	0.00219
あり	数値分類	0.61	0.39	0.49	0.50	0.00118
	Iris	0.99	0.28	0.79	0.81	0.0133
	Lupus	0.78	0.58	0.71	0.71	0.00210
	Aids	0.50	0.28	0.40	0.40	0.00345
	TAE	0.51	0.23	0.37	0.37	0.00214

い. すなわち数値分類, Lupus, Aids, TAE の4種類のデータセットでは, Ansatz の構成の違いによる精度の差が小さく, 回路構成の比較が難しい. そのためこれ以降では Iris データセットの評価結果に着目し議論を進める.

### 4.3 エンタングルメントと精度

ローテーションブロックが3個及び5個のそれぞれの場合に対してエンタングルメントブロックの数を変化させ, これらの各組み合わせに対する精度を評価した結果を図2及び図3にそれぞれ示す. 図2より, ローテーションブロックが3個の場合はノイズの有無によらず, エンタングルメントブロックの数が0個の時と比較して, 1個及び3個の場合は14%以上精度が向上している. 同様に図3より, ローテーションブロックが5個の場合はノイズの有無によらず, エンタングルメントブロックの数が0個の時と比較して, 1個以上の場合は10%以上精度が向上している. これらの結果からノイズの有無に関わらず, エンタングルメントがない場合と比べて, 1個でもエンタングルメントブロックがあることで精度が向上することが分かる. ローテーションブロックが3個の場合はエンタングルメントブロックの数が1個の時が最も精度が最もよく, 3個になると精度が落ちている. 学習データを用いて同じ組み合わせで精度を推論すると精度が落ちないことから, エンタングルメントが多くなることで, 過学習を起していることが原因である. 一方でローテーションブロックが5個の場合はエンタングルメントブロックの数が5個の時が最も精度が最もよく, 過学習の傾向は見られない.




図2 ローテーションブロックが3個の場合のエンタングルメントブロックの数に対する精度




図3 ローテーションブロックが5個の場合のエンタングルメントブロックの数に対する精度

### 4.4 回路の反復と精度

物理量子ゲートレベルでのゲートの総数を表5に示す. 基本的に論理ゲート単位では回路ブロックの反復回数に比例してゲート数も増える. しかし, 表5より物理量子ゲートレベルではゲート数の増加は反復回数に比例しない. そして一部の場合は反復回数が増加しても物理量子ゲートレベルではゲート数が減少することもある. また, 論理量子ゲートレベルでは異なるエンタングルメントの種類を反復回数を変えて比較しても大小関係は変わらなかったが, 物理量子ゲートレベルではその大小関係も変わっている部分がある. そして物理量子ゲートレベルで見ると, エンタングルメントがない場合を除いて, エンタングルメントの種類が linear や reverse linear の場合が少なく, full や circular などはその約2倍から4倍の物理ゲートを使用する.

エンタングルメントの種類が linear, full, 及びエンタングルメントがない各場合の Ansatz 内のブロックの反復回数と精度の関係性を評価した結果を図4, 図5, 及び図6にそれぞれ示す. エンタングルメントの種類が linear の場合は反復回数が4回の

表 5 各回路構成における物理量子ゲートの総数

反復回数	エンタングルメントの種類					
	linear	full	reverse linear	circular	sca	none
1	46	101	44	87	83	24
2	76	150	72	190	130	32
3	106	233	100	293	233	40
4	136	325	128	383	313	48
5	166	572	156	464	417	56
6	196	452	184	602	495	64
7	226	826	212	684	620	72
8	256	633	240	544	506	80

時まで、full の場合には反復回数が 2 回の時まで、基本的に反復回数の増加に応じて精度も向上している。一度高い精度がでると精度は頭打ちになり、大きな変化は起きにくくなる。理想的には反復回数が一定まで増えた時には精度の変化がなくなる。しかし今回得られた結果からは linear で最大 10% 程度、full で最大 15% 程度の振動がみられた。この結果を調査するため学習用データで同様に推論すると、精度はほとんど振動せず高い精度を維持した。すなわち、反復回数が増えることで過学習が発生していることがわかる。

同様にノイズの影響も踏まえて議論を進める。表 5 より、full の物理量子ゲートの総数は linear に比べて最低でも約 2 倍以上である。図 4 と図 5 の結果を比較すると、エンタングルメントの種類が linear の時は、ノイズの有無による精度の差はいずれの組み合わせでも 8% 以下である一方で、その種類が full の時はノイズの有無による精度の差が最大で 15% となる。特に回路ブロックの反復回数が 6 回以上と多い場合に注目すると、linear に比べて full のほうがノイズの有無による差が大きい傾向にある。すなわち、論理量子ゲートレベルで CNOT ゲートが多いエンタングルメントで回路ブロックの反復回数が多い時には、物理量子ゲートレベルではその総数の増加が著しいためノイズの影響が顕著に表れることが分かる。また linear の場合は、回路ブロックの反復回数を増やしてもノイズによる精度の低下が小さい。

エンタングルメントがない場合の結果はほかの場合と大きく異なり、回路ブロックの反復回数が 1 回の時が最も精度が高く、反復回数が増えるごとに精度が低下している。これはエンタングルメントがない場合は反復回数が増えても Ansatz の表現能力が向上しない一方で、反復回数を増やす以前と等価な演算を行うためのパラメータが増えてしまい、最適化が難しくなることが原因である。エンタングルメントがある組み合わせに比べると精度が最高でも 90% までしか上がらず、反復回数の増加により精度が低下していることから理想的な結果が得られない。

これらの結果からエンタングルメントがない場合は学習性能が不十分であり、エンタングルメントを含む組み合わせより精度が悪い。そしてエンタングルメントがある場合には、理想的には反復回数の増加により精度が上がり、その上限に達しても精度を維持するが、実際には反復回数が多くなりすぎると過学習が起きるため、精度の上限を維持することが難しい。加えて




図 4 linear の場合の Ansatz 内の回路ブロックの反復回数と精度




図 5 full の場合の Ansatz 内の回路ブロックの反復回数と精度




図 6 エンタングルメントがない場合の Ansatz 内の回路ブロックの反復回数と精度

linear のような物理量子ゲートレベルでも量子ゲートが少ないエンタングルメントではノイズによる学習能力の低下が小さい。

#### 4.5 実機による評価の結果

実機を使用した時の回路ブロックの反復回数と精度の関係を



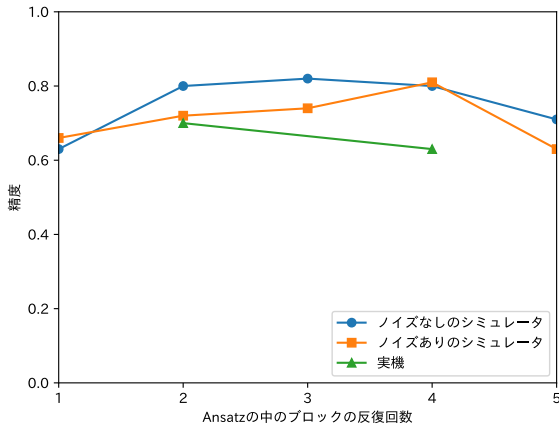


図7 実機使用時の Ansatz 内の回路ブロックの反復回数と精度

図7に示す。図7には最大のエポック数やエンタングルメントの種類が同じ場合のシミュレーションの結果も併記した。図7より、シミュレータでは回路ブロックの反復回数が2回から4回に増えた時に精度は低下しないが、実機では精度が7%低下している。これは、利用可能時間の制限により最大のエポック数が25回と少なく学習が十分にできていないことで、パラメータが初期値に依存していることが原因である。回路構成による精度の差の評価にはエポック数の増加が必要である。

シミュレータと実機の結果を比較すると最大で20%の精度の差が出ているところがある。しかしながら、先行研究[13]では最大のエポック数を200回としたときの最高の精度が73.3%であり、エポック数が多いにもかかわらずシミュレーションとの精度の差は今回の結果と同様に20%程度あった。その結果と比べると少ないエポック数でも同程度の精度が出ていることから、実機のノイズ耐性が年々高くなっており、それに伴いノイズによる精度の悪化が小さくなっていることが考えられる[4]<sup>1</sup>。すなわち、エンタングルメントの種類がlinearのようにCNOTゲートを多く必要としない場合は、実機でもシミュレータとほぼ同程度の精度が出せるようになっている。

## 5. まとめ

本稿ではノイズのある環境でのVQAによる量子機械学習における学習性能の特性とNISQデバイスのノイズの特性がトレードオフの関係であることに着目し、精度の観点で複数の構成の Ansatz を評価した。その結果、エンタングルメントは学習性能を向上するために必要不可欠であることが確認できた。1つでもエンタングルメントブロックがあれば、それ以上増やした時も精度は大きくは変化しない。また、ノイズの有無によらずエポック数が十分であるときにはエンタングルメントがある回路では精度が一定まで上がり、その後精度が小さく振動することが確認できた。そしてノイズがある時に、反復回数が一定以上に増えた時もlinearのようにゲートの数が少ない場合

はノイズがない時との精度の差が出ない。一方でfullのようにCNOTゲートの数が多いと、反復回数が多い時にノイズの有無により精度の差が大きくなり、ノイズがある環境では精度が低下する。また実機の性能が向上することで、少なくともlinearのようなCNOTゲートを多く必要としない回路については、シミュレータでの結果と同程度の高い精度が得られることを確認した。以上より、ノイズのある環境でもエンタングルメントの種類がlinearのようにCNOTゲートが少ない回路構成にできれば、回路ブロックの反復回数を増やしてもノイズの影響を最小限にとどめることができるため、高精度の結果が得られる可能性がある。以上の結果は現在のNISQデバイスのノイズ環境では、ノイズの影響よりも学習性能の効果の方が重要な要素となり、全体的な学習性能の向上に寄与することを示唆している。

**謝辞** 本研究は【日本学術振興会二国間交流事業】JPJSBP120226002の支援を受けたものです。

## 文献

- [1] K. Mitarai, M. Negoro, M. Kitagawa, and K. Fujii. "Quantum circuit learning," *Physical Review A*, vol.98, no.3, Sept. 2018, 032309.
- [2] V. Havlíček, A.D. Córcoles, K. Temme, A.W. Harrow, A. Kandala, J.M. Chow, and J.M. Gambetta, "Supervised learning with quantum-enhanced feature spaces," *Nature*, vol.567, no.7747, pp.209–212, March 2019.
- [3] J.R. McClean, J. Romero, R. Babbush, and A. Aspuru-Guzik. "The theory of variational hybrid quantum-classical algorithms," *New Journal of Physics*, vol.18, no.2, Feb. 2016, 023023.
- [4] T. Patel, A. Potharaju, B. Li, R.B. Roy, and D. Tiwari, "Experimental evaluation of nisq quantum computers: error measurement, characterization, and implications," *SC20: International Conference for High Performance Computing, Networking, Storage and Analysis*, pp.1–15, Atlanta, USA, Nov. 2020.
- [5] J. Biamonte, P. Wittek, N. Pancotti, P. Rebentrost, N. Wiebe, and S. Lloyd, "Quantum machine learning," *Nature*, vol.549, no.7671, pp.195–202, Sept. 2017.
- [6] N. Killoran, T.R. Bromley, J.M. Arrazola, M. Schuld, N. Quesada, and S. Lloyd. "Continuous-variable quantum neural networks," *Phys. Rev. Res.*, vol.1, no.3, Oct. 2019, 033063.
- [7] R. Zhao and S. Wang, "A review of quantum neural networks: methods, models, dilemma," *arXiv*, Sept. 2021.
- [8] A. Abbas, D. Sutter, C. Zoufal, A. Lucchi, A. Figalli, and S. Woerner, "The power of quantum neural networks," *Nature Computational Science*, vol.1, no.6, pp.403–409, June 2021.
- [9] IBM, "IBM Quantum Documentation: TwoLocal," <https://docs.quantum.ibm.com/api/qiskit/qiskit.circuit.library.TwoLocal>. (Accessed 2024/2/15).
- [10] H. Yetis and M. Karakoes, "Investigation of noise effects for different quantum computing architectures in ibm-q at nisq level," *2021 25th International Conference on Information Technology (IT)*, pp.1–4, Zabljak, Montenegro, Feb. 2021.
- [11] N. Elsayed Amer, W. Gomaa, K. Kimura, K. Ueda, and A. El-Mahdy. "On the learnability of quantum state fidelity," *EPJ Quantum Technology*, vol.9, no.1, Nov. 2022, Article 31.
- [12] A. Kandala, A. Mezzacapo, K. Temme, M. Takita, M. Brink, J.M. Chow, and J.M. Gambetta, "Hardware-efficient variational quantum eigensolver for small molecules and quantum magnets," *Nature*, vol.549, no.7671, pp.242–246, Sept. 2017.
- [13] M. Piatrienka, I. and Rusek, "Quantum variational multi-class classifier for the iris data set," *Computational Science – ICCS 2022*, no.13353, pp.247–260, London, UK, June 2022.
- [14] J.S. Simonoff, *Analyzing Categorical Data*, Springer Texts in Statistics, Springer New York, NY, 2003.

(注1)：実験に利用した環境では以前の実機上のノイズに関する情報が残っており、世代間のノイズ特性の比較ができない。