

量子ネイティブな未来へ:ゲート式量子コンピュータによる実規模輸送ルート最適化

齊藤 岳穂
Takaho Saito

森山 英二
Eiji Moriyama

概要

ゲート式量子計算を中核に、実規模の輸送ルート最適化を量子回路化し、量子機械学習による実問題適用の成立性を示した。選定した量子回路を量子シミュレータ上で運用し、輸送率100%を維持したまま、古典計算と比較して性能が改善することを確認した。

1. はじめに

:量子技術への期待とアイシンの挑戦

1.1 量子技術の時代背景

量子技術は、基礎研究の成果が産業応用へ移行する転換点にある。国連総会は2025年を「国際量子科学技術年 (IQY)」と宣言し、量子科学の社会実装を国際的に推進している。2022年のノーベル物理学賞では量子もつれの実証が顕彰され、量子力学の正当性が決定づけられた。さらに2025年の同賞では、電気回路における巨視的量子トンネル効果とエネルギー量子化を手のひらサイズの系で示した成果が顕彰され、量子現象をハードウェアとして制御し活用する潮流が一層明確になっている。

1.2 なぜ今、量子コンピュータか

実社会の最適化問題は、選択肢が指数関数的に増大する「組合せ爆発」の壁に直面している。特に、時間や積載量といった厳格な制約条件を伴う輸送計画等は、規模が拡大すると従来コンピュータである古典コンピュータでは最適な答えを導き出すことが困難となる。これに対し量子コンピュータは、従来とは全く異なる量子力学に基づく新しいコンピュータであり、現在の計算能力の限界を突破する可能性を有している。現段階のハードウェアは発展途上ではあるが、実用化に向けては、現実の制約下でどの規模まで解けるかを実証することが重要である。

1.3 アイシンの狙い

我々は、量子コンピュータを将来の計算基盤の一つとして捉え、実問題での適用可能性を段階的に検証してい

る。本稿では、「トラック輸送ルート最適化」を例題として取り上げる。データには実規模の19拠点データを用いて、量子計算を用いた解探索の成立性と効果を検討する。

2. 量子コンピュータの概要と検証アプローチ

2.1 計算原理の違い:ビットから量子ビットへ

1章で述べた「組合せ爆発」の課題に対し、量子コンピュータがブレイクスルーとなり得る背景には、情報の持ち方が根本的に異なる点がある。古典コンピュータが「0」または「1」のいずれかの状態をとるビットで情報を処理するのに対し、量子コンピュータは「0」と「1」を同時に合わせ持つ量子ビットを用いる。この重ね合わせ等の性質により、探索空間が極めて大きい問題に対して、解探索や学習の一部を効率化できる可能性がある。本稿で扱うゲート式量子コンピュータでは、量子ゲートの並びを量子回路として設計し、実行・測定して結果を得る。以降、「量子回路化」とは、対象問題の解探索手順の全部あるいは一部を量子回路として表現可能な形へ変換することを指す。計算原理が異なるため、古典アルゴリズムをそのまま量子計算で実行することはできず、量子コンピュータの性能を活かすには、量子計算に適合したアルゴリズム設計が不可欠である。

2.2 ハードウェアの現在地

量子コンピュータの産業応用には、ハードウェアの成熟度を理解する必要がある。現在の量子コンピュータはNISQ (Noisy Intermediate-Scale Quantum)と呼ばれる段階にあり、数十~百数十量子ビット規模で利用可能である一方、計算過程でノイズが発生しやすい。この

ため、回路が深くなるほど結果が劣化しやすく、大規模問題をそのまま実機で扱うことは容易ではない。一方、将来像として、量子誤り訂正により誤り耐性を備えたFTQC (Fault-Tolerant Quantum Computer)が研究開発されている。FTQCの実現には大規模な量子ビット資源が必要とされ、到達には時間を要する。したがって現時点では、NISQの制約を前提に、「アルゴリズムのどの部分を量子回路化し、どの規模まで成立させるか」を設計することが要点となる。

2.3 実用化に向けた架け橋:量子シミュレータ

本研究で扱う19拠点規模の実データを、現状のNISQ実機で直接解くことは、精度・規模の観点から制約が大きい。そこで、アルゴリズム自体のポテンシャルを先行して検証する基盤として量子シミュレータを用いる。量子シミュレータは、古典コンピュータ上で量子回路の振る舞いを数値的に模擬する技術であり、ハードウェアに依存せずに量子回路の設計検討や動作確認を行える。厳密な模擬は量子ビット数に対して計算量・メモリ量が指数的に増大し、大規模回路では計算負荷が高いという制約もあるが、ノイズを含まない理想的な挙動を確認できるため、量子回路化の妥当性評価に適する。

3. 提案アプローチ

3.1 目標と全体像

本研究では、輸送ルート最適化を制約付きTSP(Travelling Salesperson Problem)として捉え、探索空間が大きく制約が複合する問題に機械学習を適用する。探索の枠組みは強化学習を基本とし、探索効率を高めるための手法を組み合わせる。また、グラフ構造データの特徴抽出にGNN(Graph Neural Networks)¹⁾や、複数の情報を同時に考慮しながら最適な意思決定を行うMHA(Multi-Head Attention)²⁾を用いた。

3.2 量子×古典ハイブリッド方針

現在のNISQデバイスではエラー率や規模の制約が大きく、NN(ニューラルネットワーク)全体を量子回路化することは容易ではない。そこで本研究では、古典コンピュータが周辺処理と学習制御を担い、量子化の効果が期待できる計算要素に量子回路を適用するハイブリッド構成とした。

4. アルゴリズム実装

本章では、強化学習とActive Search³⁾による解探索ループ、およびGNN・MHAによる意思決定構造を説明し、量子回路化する計算要素を明確化する。

4.1 解探索ループ

本手法は、エピソード(1日の輸送計画を最後まで作る1回の試行)を多数回反復し、良い解が出やすい方向へ探索を寄せる。図1に示すように、(1)同一NNで候補解を複数生成(バッチ)、(2)輸送率に基づくスコアで評価、(3)ベスト結果を保存し、(4)スコアを用いてNNを更新する、という処理を繰り返す。

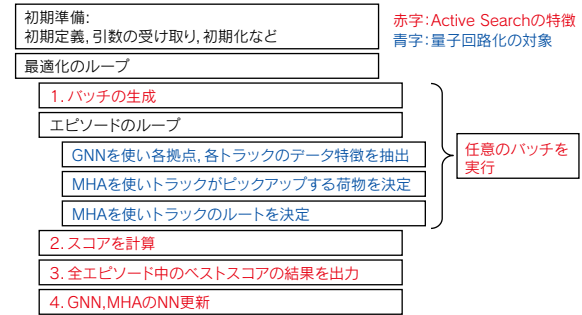


図1 処理フロー

4.2 強化学習

強化学習では、エージェント(輸送計画モデル)が環境(トラック・輸送拠点・荷物情報)を観測し、行動として「積荷の決定」と「移動先」を選択する。報酬は、全荷物に対して実際に輸送した荷物の割合である輸送率を最大化するように設計した。

4.3 Active Search

Active Searchは、個々の入力である当日の輸送条件に対して、解探索ループのバッチ生成→評価→保存→更新を反復し、その入力に適した探索へ逐次調整する手法である。これにより、総当たりではなく、良い解が出やすい方向へ探索を誘導しながら改善を重ねることができ、局所的最適解に陥るリスクを低減できる可能性がある。

4.4 NN構造:GNNエンコーダとMHAデコーダ




図2 輸送計画の状態を表すグラフの例

赤ノード L_i は拠点 i 、緑ノード T_j はトラック j を表す。拠点間エッジは移動関係(距離・時間等)、トラック-拠点エッジはトラックの位置や到達可能性など、意思決定に必要な関係性を表現する。

輸送計画の状態は、図2のように拠点とトラックからなるグラフとして表す。GNNはエンコーダとしてグラフ上

の情報を集約し、意思決定に用いる埋め込み表現へ変換する。得られた埋め込みを入力とし、MHAがデコーダとして(1)積み荷選択、(2)次の移動先選択を逐次的に行う。

4.5 量子回路化の対象

3章で述べた通り、規模やノイズのNISQ制約を踏まえ、本研究では古典処理と量子回路を用いるハイブリッド構成とした。具体的には、図3に示すGNNエンコーダと、2つのMHAデコーダの主要部を量子回路として実装する。入力特徴量を量子状態へエンコードし、量子回路でGNNによる特徴変換とMHAによる注意計算を行った後、測定により古典データとして読み出して後段処理に接続する。

なお、量子回路には複数の種類があり、計算コストや学習挙動への影響は重要であるため、量子回路3種類の比較を予備検証として6章にまとめて示す。

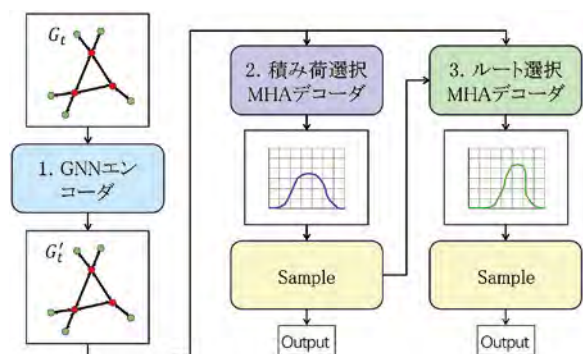


図3 提案モデルの処理フロー

時刻 t の状態グラフ G_t をGNNエンコーダで埋め込み表現 G'_t に変換し、MHAデコーダにより(1)積み荷選択、(2)移動先選択を順に行う。本稿では、これらエンコーダおよびデコーダの主要部を量子回路として実装する。

5. 古典機械学習を用いた評価結果

本章では、量子回路化を伴わない古典機械学習アルゴリズムを用い、実規模(19拠点・1日分)の実データに対して輸送ルート最適化を行い評価した。

5.1 評価環境

評価環境はAWSのc7a.4xlargeを使用した。データは、各品番の箱総数・輸送先・箱サイズ・総重量、および各拠点の受入シフト(昼勤・夜勤)と拠点間移動時間を含む。制約条件として、受入シフト遵守、出発拠点への復帰、1シフト8時間(1日2シフト)、各回40分の荷役作業時間を適用した。

5.2 最適化結果

古典機械学習を適用した結果、輸送率100%を満たす計画を、トラック5台・ドライバ9名で導出できた。これは、トラック6台・ドライバ10名の人手の計画に対し、輸送リソースを約16%削減しつつ輸送率100%を達成した

ことを意味する。

この結果から、実データ規模においても古典機械学習により(i)制約を満たした計画生成、(ii)輸送率100%の確保、(iii)輸送リソースの削減、が同時に成立することを確認できた。本結果は、7章で扱う量子機械学習の効果を評価する際の、比較基準として用いる。

表1 評価結果

		人	古典機械学習 (量子回路化なし)	量子機械学習 (量子回路化あり)
アルゴリズム	手法	手作業	・強化学習 with Active Search ・GNN ・MHA NN	・強化学習 with Active Search ・量子GNN ・量子MHA NN
	目的関数	-	運んだ荷物割合の最大化	
入力制約	拠点数	19		
	1シフトのトラック稼働時間	8時間		
	1日のシフト数	2シフト		
	トラック輸送終了地点	開始地点と同じ		
	荷役時間	40分/回		
結果	輸送率	100%		
	トラック台数とドライバ人数	6台 10名	5台 9名	5台 9名
	トラック総稼働時間	80時間	69時間55分	63時間53分
	計算時間	-	6時間30分	4時間40分

6. 量子回路の予備検証:回路構造と採用回路の決定

本章では、7章で示す量子機械学習の本評価に先立ち、量子回路構造の違いが学習の到達度と目標到達までの計算コストに与える影響を整理し、量子機械学習で用いる回路を選定する。評価対象は、量子直交層(Quantum Orthogonal Layer)⁴⁾を構成する代表的な3種類の回路Pyramid、Iks、Butterflyである。いずれもRBS(Reconfigurable Beam Splitter)ゲートにより直交変換(SO(n))を実装する量子回路として位置づけられる。

6.1 評価設計

回路差の影響を明確にするため、評価は「解探索として成立しているか」と「計算資源として現実的か」の2点に集約した。ただし、回路構造の比較で混乱が生じやすい点として、固定の学習回数で測る計算時間(単位計算時間)と、所定の性能に到達するまでに要する計算時間(総計算時間)を区別して扱う。

本章では、以下を記録し、回路の成立性と効率性を総合評価した。

- (1) 学習終了時点のベスト輸送率
- (2) 全バッチの平均輸送率
- (3) 学習回数(学習の進み方の比較に使用)
- (4) 計算時間(固定学習回数での単位計算時間、および必要学習回数を加味した総計算時間の推定に使用)

ベスト輸送率から輸送率100%であることを確認した上で、輸送率100%が得られる実行を複数回確保し、全バッチの平均輸送率と学習回数の傾向を比較した。計算時間については、単位計算時間の推移と、輸送率の到達挙動から推定される必要学習回数を合わせ、目標到達までの総計算時間として解釈した。

なお、目的関数には時間項を含まないため、トラック総稼働時間は回路性能比較の主指標からは外し、本章では回路構造が学習と計算コストに与える影響に焦点を当てる。

6.2 比較した3種類の量子回路

図4に、比較対象とした3種類の回路模式図を示す。Pyramid回路はSO(n)の次元に一致する $n(n-1)/2$ 個のパラメータを持ち、表現力が高い一方で深さが量子ビット数に対して線形となる。Butterfly回路はパラメータ数が $(n \log n)/2$ で、深さが対数オーダーとなり効率的であるが、表現力と接続性の面で制約が生じ得る。lks回路は、上記二者の中間的な設計思想として比較に含めた。




図4 量子直交層を構成する3種類の量子回路の模式図

いずれもRBSゲート列により直交変換を実装し、深さや接続性のゲート配置とパラメータ数が異なる。

6.3 量子回路の役割

本研究の量子回路は、古典ベクトルを量子状態へ写像し、直交変換を与えた後、測定により古典特徴量として読み出す「量子直交層」として機能する。入力は、 n 次元ベクトル x をユニタリ空間上で扱うため、単項基底上の振幅として符号化する。具体的には、以下のUnary basis encoding形式でエンコードする。

$$|x\rangle = \frac{1}{\|x\|} \sum_{i=1}^n x_i |i\rangle$$

直交変換はRBSゲートにより実装される。RBS(θ)は $\{|01\rangle, |10\rangle\}$ 部分空間で回転を与え、量子直交層の基本部品となる。また、量子状態から古典ベクトルを復元するには測定が必要であり、符号も含めた復元のためにトモグラフィ手順が導入される。これは追加の計算コストを伴い、要求精度が高いほどショット数が増える点に留意が必要である。

6.4 予備検証結果とPyramid回路採用理由

予備検証の結果、回路構造の差は主に(1)単位計算

時間、(2)学習の進み方(到達挙動)、(3)規模拡大への感度に現れ、(4)最適化の安定性に大きな差は現れなかった。以下に要点を示す。

6.4.1 単位計算時間(固定学習回数での計算時間推移)

固定学習回数(100,300,500,1000)に対する計算時間推移を図5に示す。単位計算時間は、概ね量子回路の深さ(量子ゲート数)に依存し、Pyramidは他方式に比べて長くなる傾向が確認された。これは、Pyramidが高い表現力を得る代償として回路が深くなる設計であることと整合している。

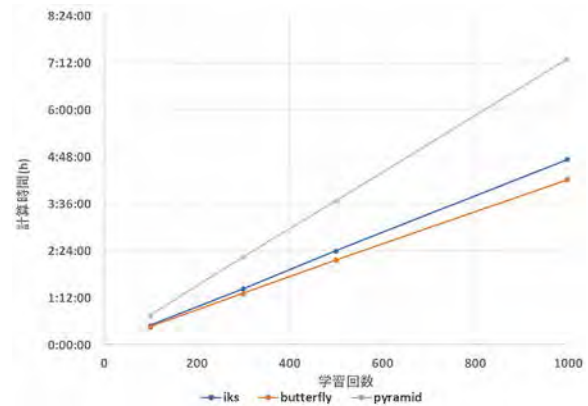


図5 学習回数と計算時間の推移(単位計算時間の比較)

6.4.2 学習挙動

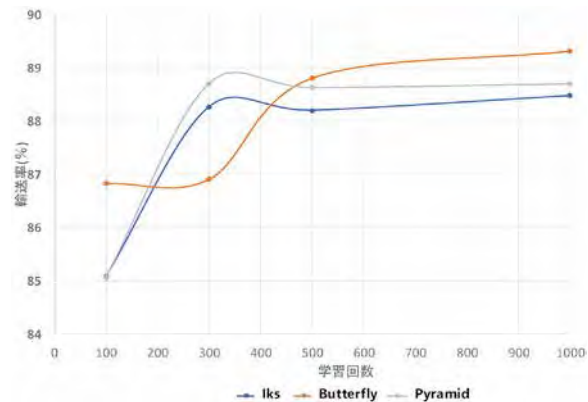


図6 学習回数と輸送率の推移

学習回数100~300の区間で、Butterflyのみ学習が進みにくい傾向が確認された。一方で、輸送率の最終水準である到達点は3種類で概ね同水準であり、頭打ちの挙動自体は共通して観測された。

ここで重要なのは、単位計算時間が短い回路が必ずしも総計算時間で有利とは限らない点である。すなわち、単位計算時間が長いPyramidであっても、輸送率がより少ない学習回数で目標水準に到達するならば、目標到達までの総計算時間は抑えられる可能性がある。本章ではこの観点を採用理由に反映する。

6.4.3 規模拡大への感度

エンコーダ入力次元に対しては, Butterflyは頭打ち傾向が示唆される一方, lksとPyramidは検証範囲では規模が大きいほど性能が向上する傾向が確認された. デコーダ入力次元については, 3種類で差はほぼ見られなかった. 本研究では実データ規模への拡張を重視するため, 規模拡大に対して性能が劣化しにくい傾向は, 回路選定の重要な判断材料となる.

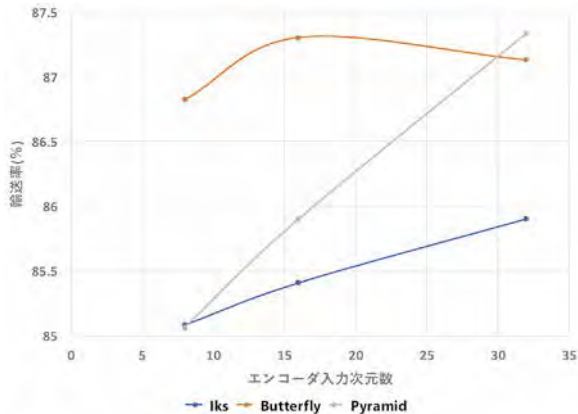


図7 エンコーダ入力次元と輸送率の推移

6.4.4 最適化の安定性

エンコーダとデコーダの組合せを変えた総当たり評価により, 輸送率100%に達した回数が5回に到達するまでに「輸送率100%にならなかった回数」を失敗回数としてカウントし, 最適化の安定性を比較した. どの量子回路も連続して5回輸送率100%に到達し, 安定性に差のないことが確認された.

6.4.5 混合量子回路による補強評価

上述のとおり, 固定学習回数での単位計算時間では量子ゲートが多いほど不利になり得るため, 回路の総合的な効率を追加で確認する目的で, エンコーダとデコーダに異なる回路種を割り当てる混合量子回路の比較を学習回数固定で実施した. 結果として, デコーダ側でPyramidを用いる組合せが高い輸送率を示す傾向が確認され, 量子直交層の中でも特にデコーダでPyramidが有効に機能することが示唆された.

表2 混合量子回路の比較結果

		デコーダ		
		lks	Butterfly	Pyramid
エン コー ダ	lks	86.722	86.75	88.586
	Butterfly	88.96	87.324	89.072
	Pyramid	87.08	87.464	89.826

以上を踏まえ, 本研究の量子機械学習で用いる量子回路はPyramidとした. Pyramidは単位計算時間の観点では不利になり得る一方, (i)学習の到達挙動が良好

で必要学習回数を抑えられる可能性が高いこと, (ii)規模拡大に対して性能が向上する傾向が確認されたこと, (iii)混合量子回路の比較においてPyramid (特にデコーダ側)の有効性が示唆されたことを総合し, 目標到達までの総計算時間を抑えつつ, 量子回路化を推進できる回路として採用した. これにより, 量子回路化による解の成立と, 実装上の計算資源に対する現実性の両立を優先した.

7. 量子機械学習を用いた評価結果

本章では, 古典機械学習と同一条件の計算環境を用い, 量子機械学習の性能を評価した.

7.1 評価環境

評価環境はAWSのc7a.4xlargeとし, 19拠点の1日分の実データを対象とした. 制約条件も同一とした.

量子計算は, 同AWSインスタンス上で量子シミュレータを実行し, 6章で選定したPyramid回路を用いて最適化を行った.

7.2 最適化結果

5章で述べた古典機械学習に対し量子機械学習でも, 輸送率100%を維持したまま, トラック台数およびドライバー人数の必要リソースは古典機械学習と同等の5台・9名となった (表1). 加えて, トラック総稼働時間が69時間55分から63時間53分へ約8.6%短縮し, 運用面の効率が向上した. さらに, 同一AWS環境上での計算時間も6時間30分から4時間40分へ約28%短縮し, 解探索の実行効率の観点でも改善が確認できた. 6章で述べた通りPyramid回路は学習の収束が早く, 少ないエピソード数で解に到達したため, 計算負荷の高い量子シミュレータを用いても計算時間が短縮されている.

8. おわりに

8.1 成果の総括

本稿では, 輸送ルート最適化を例題として, 量子計算を組み込んだ機械学習による解探索の成立性と効果を検証した. 量子回路化した特徴抽出および意思決定を含む量子古典ハイブリッド構成により, 19拠点の実データ規模の制約付き問題に対しても解探索が成立し, 100%の輸送率を維持したまま, トラック総稼働時間および計算時間の短縮を量子シミュレータ上で実行することで示した. これにより, 量子技術を実務課題へ適用するためのアルゴリズム設計と検証基盤が整いつつあることを示した.

さらに, 量子ハードウェア制約を考慮した3拠点という限定的な規模ではあるが, 同一の制約条件の下で, 127

量子ビットのIBM量子コンピュータ「IBM-Osaka」を用いた実機計算も実施した。誌面の都合上、本稿では詳細を割愛するものの、IBMが提供するエラー抑制⁵⁾やエラー緩和⁶⁾機能等を併用することで、実機環境においても量子回路が動作し得ることを確認している。

8.2 今後の展望

今後は、量子コンピュータ実機の成熟度を見極めながら、実機での検証を適切なタイミングで段階的に進める。実機検証ではFTQCの到来も視野に入れ、古典計算のみでは探索が困難となるさらなる大規模問題（例えば100拠点規模）への挑戦を検討する。加えて、本稿で得た量子機械学習の知見を、物流に留まらず材料開発やCAE等、製造業における製品設計の課題へ横展開し、課題解決への寄与を目指す。

8.3 謝辞

本研究はアメリカに本社を置くQC Ware社との共同研究として実施しました。同社からの技術的支援および有益な助言に対し、深く感謝の意を表します。

参考文献

- 1) T.N.Kipf,M.Welling:Semi-Supervised Classification with Graph Convolutional Networks,International Conference on Learning Representations (ICLR)(2017),<https://openreview.net/forum?id=SJU4ayYgl>
- 2) F.Sanches,et al.:Short Quantum Circuits in Reinforcement Learning Policies for the Vehicle Routing Problem, Physical Review A,Vol.105,p.062403(2022),<https://doi.org/10.1103/PhysRevA.105.062403>
- 3) N.Heess,et al.(Google DeepMind):Producing flexible behaviours in simulated environments,
<https://deepmind.google/discover/blog/producing-flexible-behaviours-in-simulated-environments/>(参照2025.02.10)
- 4) I.Kerenidis,et al.:Classical and Quantum Algorithms for Orthogonal Neural Networks,arXiv:2106.07198(2021),<https://doi.org/10.48550/arXiv.2106.07198>
- 5) IBM:Error Mitigation and Suppression Techniques,IBM Quantum Documentation,
<https://docs.quantum.ibm.com/guides/error-mitigation-and-suppression-techniques>

筆者



齊藤 岳穂

第1先行開発部
インフラ基盤技術開発室
量子技術開発に従事



森山 英二

第1先行開発部
インフラ基盤技術開発室
量子技術開発に従事