パラメータ直交化法を用いたノイズのある量子振幅推定法

田中 智樹^{1,2,3,a)} 宇野 隼平^{1,4} 小野寺 民也^{1,5} 山本 直樹^{1,3} 鈴木 洋一¹

概要:現在,次世代のコンピュータとして,量子コンピュータに注目が集まっている. それは従来のコン ピュータと比べ,計算量の優位性が示されているアルゴリズムを実行できるためであり,その一つに量子振 幅推定法という,従来のコンピュータを用いた場合に比べ,振幅という値を2乗の計算量の優位性を持って 推定できることが知られている. 他方,現在の量子コンピュータは,NISQ と呼ばれるように,限られたリ ソースしかなく,現在の量子コンピュータを使う上では,特にノイズの影響を考慮に入れたアルゴリズムの 構築が必要である. 本稿では,ノイズのある量子コンピュータでの,量子振幅推定法を実行する問題につい て議論する.量子コンピュータ自体で起こっているノイズを完璧に特定することは困難であるため,何かし らのモデルを置き,実験結果から推定を行うことをする. モデルの表現力をあげることで,より真のモデル 分布に近づけることができるが,一方で推定自体が難しくなるトレードオフがある. そこで,本稿では,脱 分極ノイズモデルを拡張した形で,ノイズモデルを導入する. しかしながら,拡張したモデルでは,ノイズ に起因するパラメータが多すぎ,推定ができないため,同じようなノイズを受けると推定される補助回路を 導入する. さらに,補助回路を導入したモデルでは多次元のパラメータ推定問題,つまりは多次元の最適化 問題を扱う必要が生じるが,これをパラメータ直交化法を用いる条件式である微分方程式が解析的に解けることも 述べる.最後に,シミュレーターおよび IBM の量子コンピュータでの検証を行う.

1. はじめに

現在,次世代のコンピュータとして,量子コンピュータ に注目が集まっている.それは従来のコンピュータと比べ, 計算量の優位性が示されているアルゴリズム [1], [2], [3] が 知られており,その一つに量子振幅推定法 [4](以下振幅推 定法)がある.これは,従来のコンピュータを用いた場合 に比べ,振幅という値を2乗の計算量の優位性を持って推 定できることが知られているアルゴリズムである.そして, このアルゴリズムは,モンテカルロ計算 [5], [6] や機械学 習 [7], [8] 等,様々な応用が提案されている重要なアルゴリ ズムの一つである.この Brassard ら [4] によって提案され た振幅推定法は,主に量子振幅増幅と,量子位相推定(逆 量子フーリエ変換)という二つの部分から構成されてお

1	慶應義塾大学 量子コンピューティングセンター	
	223-8522, 神奈川県横浜市港北区日吉 3-14-1	
~		

- ² 株式会社三菱 UFJ フィナンシャル・グループ,株式会社三菱 UFJ 銀行
- 100-8388 東京都千代田区丸の内 2-7-1³ 慶應義塾大学大学院 理工学研究科
- 223-8522, 神奈川県横浜市港北区日吉 3-14-1 4 ひずほりせい チャテクノロジャブ性ゴクせ
- ⁴ みずほリサーチ&テクノロジーズ株式会社 101-8443 東京都千代田区神田錦町 2-3
- ⁵ 日本アイ・ビー・エム株式会社
- 103-8510 東京都中央区日本橋箱崎町 19-21
- ^{a)} ttomoki@user.keio.ac.jp

り、十分なハードウェアがあるという前提に立ったアルゴ リズムである.一方で、現在の量子コンピュータは、Noisy Intermediate-Scale Quantum (NISQ) [9] と呼ばれるよう に、量子ビットの数や計算可能な時間が限られており、更 に、ノイズの影響を考慮に入れたアルゴリズムの構築が必 要である.

そこで、直近、量子位相推定を用いない量子振幅推定 法がいくつも提案されている [10], [11], [12], [13]. これら は、量子位相推定が不要となったことで、量子ビットの数 を削減することができ、更に量子回路の深さを減らすこと ができることから、限られた計算時間でも計算できる可能 性がある、より現在向けのアルゴリズムとなっている. 続 く [14] では,特に鈴木ら [10] の最尤推定を用いる振幅推定 法を用いて,脱分極ノイズの影響を考慮に入れたアルゴリ ズムを構築している.ただし、このノイズの取り扱いにつ いては非常に注意深く扱う必要がある.なぜならば,量子 コンピュータ自体で起こっているノイズを完璧に特定する ことは困難であるためである.実際には、何かしらのモデ ルを置き、実験結果から推定を行うことをする.より、モ デルの表現力をあげることで,より真のモデル分布に近づ けることができるが、一方で推定自体が難しくなるトレー ドオフがある.

そこで、本稿では、著者らによって [15] でも扱っている ように、脱分極ノイズモデルを拡張した形で、ノイズモデ ルを導入し、振幅推定の問題を扱う.まず、2章では、本 稿で用いる主な手法の説明を,具体的には 2.1 節で最尤推 定を用いた振幅指定法を、2.2節では、パラメータ直交化 法の説明を行う. そして, 脱分極ノイズモデルを拡張した モデルを, 3.1節で行う. しかしながら, 拡張したモデルで は、ノイズに起因するパラメータが多すぎるため、推定がで きないため、同じようなノイズを受けると推定される補助 回路を導入する.この補助回路を導入したモデルによって, 最尤推定を行うことで振幅を推定することができるが、こ の最尤推定は多次元となるため、つまりは多次元の最適化 問題を扱う必要が生じる.多次元の最適化問題は一般に解 くことが簡単ではないが、ここでは 2.2 節で紹介したパラ メータ直交化法という手法を用いることで,1次元の最適 化問題に帰着できることを 3.2 節で示す. 特に、パラメータ 直交化法を用いる条件式である微分方程式が解析的に解け ることも述べる. そして,4章では、シミュレーターおよび IBM の超電導量子コンピュータ実機 [16] での検証を行い, 5章でまとめを行う.

2. 準備

本章では、本稿で用いる最尤指定を用いた振幅推定法と、 パラメータ直交化法について説明する.

2.1 最尤推定を用いた振幅推定法

本節では,最尤推定を用いた振幅推定法 [10] を説明する. まず,推定したいパラメータ $\theta \in [0, \pi/2]$ を振幅に埋め込 む演算子 A を次の形で与える.

$$\mathcal{A} \left| 0 \right\rangle_{n+1} = \sin \theta \left| \Psi_1 \right\rangle_n \left| 1 \right\rangle + \cos \theta \left| \Psi_0 \right\rangle_n \left| 0 \right\rangle \tag{1}$$

ここで、 $|0\rangle_{n+1} = |0\rangle^{\otimes n}$ であり、 $|\tilde{\Psi}_1\rangle_n$ および $|\tilde{\Psi}_0\rangle_n$ は直 交するn量子ビットの状態である.そして、式1の状態を $|\Psi\rangle_{n+1}$ と置く、つまり、 $|\Psi\rangle_{n+1} := \mathcal{A}|0\rangle_{n+1}$ である.そし て、振幅増幅演算子(Grover演算子)*G*を次で与える.

 $\mathcal{G} = -\mathcal{A}\mathcal{U}_0 \mathcal{A}^{\dagger} \mathcal{U}_f \tag{2}$

ただし、 $U_0 \ge U_f$ は、次で定義される演算子である.

$$\mathcal{U}_{0} = I_{n+1} - 2 \left| 0 \right\rangle_{n+1} \left\langle 0 \right|_{n+1},$$

$$\mathcal{U}_{f} = I_{n+1} - 2I_{n} \otimes \left| 1 \right\rangle \left\langle 1 \right| = I_{n} \otimes \sigma_{z}.$$
(3)

なお, I_n は恒等演算子である.さて,ここで任意の正の整 数 m_k に対して, $|\Psi\rangle_{n+1}$ に振幅増幅演算子Gを m_k 回,作 用させると,

$$\mathcal{G}^{m_k} |\Psi\rangle_{n+1} = \sin((2m_k+1)\theta) |\Psi_1\rangle_n |1\rangle + \cos((2m_k+1)\theta) |\tilde{\Psi}_0\rangle_n |0\rangle.$$
(4)

となる. この状態において,最後の量子ビットが {|0⟩,|1⟩} である測定基底で測定すると, "1" が得られる確率は,次 で与えられる.

$$p_{\theta}^{(k)} = \mathbb{P}(\{h_k = 1\}) = \sin^2((2m_k + 1)\theta)$$
(5)

なお、 $h_k \in \{0,1\}$ は2変数の確率変数であり、そして、 $\mathbf{h} = (h_1, \dots, h_M) \in \{0,1\}^M$ とし、 \mathbf{h} に対する確率密度関数 $P(\mathbf{h}; \theta)$ を次で置く、

$$P(\mathbf{h};\theta) = \prod_{k=1}^{M} (p_{\theta}^{(k)})^{h_k} (1-p_{\theta}^{(k)})^{1-h_k}.$$
 (6)

更に,異なる m_k に対して, N_{shot} 回測定をした結果を $\mathbf{H} = \{\mathbf{h}^1, \cdots, \mathbf{h}^{N_{\text{shot}}}\}$ とし,尤度関数 $L_G(\theta; \mathbf{H})$ を以下で 定義をする.

$$L(\theta; \mathbf{H}) = \prod_{j=1}^{N_{\text{shot}}} P(\mathbf{h}^{j}; \theta)$$
(7)

そして,最尤推定を用いてθを推定することができる.

$$\hat{\theta}_{\mathrm{ML}} = \arg \max_{\theta} L(\theta; \mathbf{H}) = \arg \max_{\theta} \ln L(\theta; \mathbf{H})$$
 (8)

そして, Cramér–Rao の不等式を用いることで, θ の標準 偏差 ϵ の下限を得ることができる. つまり,

$$\epsilon^{2} = \mathbb{E}\left[(\theta - \hat{\theta})^{2}\right] \ge \frac{1}{N_{\text{shot}}} J(\theta)^{-1}$$
(9)

が成り立つ.ここで, $J(\theta)$ は次で与えられる Fisher 情報 量である.

$$J(\theta) = \mathbb{E}\left[\left(\frac{\partial}{\partial\theta}\ln P(\mathbf{h};\theta)\right)^2\right].$$
 (10)

なお,この下限は,漸近的に達成可能であることが知られている.

改めて, [10] によると, $m_k = k$ とした場合, $\epsilon = O(\epsilon^{-4/3})$ となり, 古典的な場合である $O(\epsilon^{-2})$ より優位性がある. 更 に, $m_k = a^k(a \, \mathrm{i} 1 \, \mathrm{k})$ 大きな実数) とした場合, $\epsilon = O(\epsilon^{-1})$ となり, これは Heisenberg 限界を達成する.

これまでのところでは、ノイズがない場合について議論 を行った.しかしながら、現在の量子コンピュータはノイ ズがある.そこで、[14] では、ノイズがある場合の最尤推 定を用いた振幅推定について、特に脱分極ノイズモデルを 仮定して議論を行なっている.特に脱分極ノイズの大き さ κ (これは直接推定したいパラメータではなく、局外パラ メータと呼ばれる)を用いて、モデルを構築すると、"1"が 得られる確率 $p_{\theta,\kappa}^{(k)}$ は、次で示すことができる.

$$p_{\theta,\kappa}^{(k)} = \frac{1}{2} - \frac{1}{2} e^{-\kappa m_k} \cos(2(2m_k + 1)\theta)$$
(11)

本確率を用いてノイズがない場合と同様に $P(\mathbf{h}; \theta, \kappa)$ およ び尤度関数 $L(\theta, \kappa; \mathbf{H})$ を構成することができ、2 次元の最 尤推定を行うことで、推定したいパラメータ θ を得ること

情報処理学会研究報告

IPSJ SIG Technical Report

ができる.ただし,ノイズ自体を完全に特定することは困 難であるため,よりモデルを拡張することで,モデルの表現 力をあげることを行いたい.そこで,複数の局外パラメー タ $\beta = (\beta_1, \dots, \beta_M)$ を持つモデルを考える.脱分極ノイ ズの場合と同様の議論を考えると,尤度関数 $L(\theta, \beta; \mathbf{H})$ の 最適化問題は,M + 1次元のパラメータが存在することと なり,一般に簡単ではない.そこで,次の 2.2 節では,多 次元の最適化問題を回避する一つの手法として,パラメー タ直交化法を要約を行う.

2.2 パラメータ直交化法

本節では [17], [18] に基づき,パラメータ直交化法について要点を述べる.パラメータ直交化法とは,後に示す条件式となる微分方程式を満たすような変数変換を行うことで,推定したいパラメータ (parameter of interest) と局外パラメータ (nuisance parameter) を分離する方法である. この条件を満たすことができる場合,尤度方程式は1次元となり,1次元の最適化問題を解くことで最尤推定が可能となる.

ここでは、確率 $p(x; \theta, \beta)$ について、特に、推定したい パラメータが θ の一つ、局外パラメータ $\beta = (\beta_1, \dots, \beta_M)$ は、M 個ある場合を考える、そして、次を満たす変数変換 を考える、

$$\theta = \theta(\xi_1) = \xi_1, \ \beta_k = \beta_k(\xi_1, \xi_2, \cdots, \xi_{M+1})$$
(12)

ここで, $\boldsymbol{\xi} = (\xi_1, \xi_2, \dots, \xi_{M+1})$ は変数変換後のパラメータ であり, $\boldsymbol{\xi}$ を用いたフィッシャー情報行列 $J_{\boldsymbol{\xi}}$ は,任意の $k = 2, 3, \dots, M+1$ に対して次を満たす.

$$(J_{\boldsymbol{\xi}})_{1,k} = 0 \tag{13}$$

つまり,この式は変数変換後の Fisher 情報行列 (1,k) 成分 がゼロとなることである.そして,この条件式は次の微分 方程式を満たすことである.

$$J_{1,i} + \sum_{k=2}^{M+1} J_{i,k} \frac{\partial \beta_{k-1}}{\partial \xi_1} = 0$$
 (14)

注意すべきことに,この方程式の解はユニークに決まるものではない.改めて,パラメータ直交化法の狙いについて述べる.変数変換を行う上で満たす条件式 $(J_{\xi})_{1,k} = 0$ は,次のように書き換えることができる.

$$0 = (J_{\boldsymbol{\xi}})_{1,k} = \mathbb{E}\left[\frac{\partial \ln p(x;\boldsymbol{\xi})}{\partial \xi_1} \frac{\partial \ln p(x;\boldsymbol{\xi})}{\partial \xi_k}\right]$$
$$= -\mathbb{E}\left[\frac{\partial^2}{\partial \xi_1 \partial \xi_k} \ln p(x;\boldsymbol{\xi})\right]$$
$$\approx -\frac{1}{N_x} \sum_g \frac{\partial^2}{\partial \xi_1 \partial \xi_k} \ln p(x_g;\boldsymbol{\xi})$$
$$= -\frac{1}{N_x} \frac{\partial^2}{\partial \xi_1 \partial \xi_k} \ln L(\boldsymbol{\xi};\boldsymbol{x})$$
(15)



つまり,この式は, $(\partial/\partial\xi_1) \ln L(\boldsymbol{\xi}; \boldsymbol{x}) = 0$ を示している.す なわち,サンプル回数が大きい漸近的な極限では, θ の臨界点 (微分がゼロとなる点)が, ξ_k に依存しないことを示している. よって, $\theta = \xi$ の最尤推定に関しては, $\bar{\xi}_k \forall k \ge 2$ をラフに選 び,1次元の最適化問題 $\max_{\xi_1} \ln L(\xi_1, \bar{\xi}_2, \dots, \bar{\xi}_{M+1}; \boldsymbol{x})$ を解 けば良いことがわかる.最後に, θ に関する Cramér-Rao の 下限である $(J^{-1})_{1,1}$ は, ξ に関する下限 $(J_{\xi}^{-1})_{1,1} = (J_{\xi})_{1,1}^{-1}$ と同じになる.つまり,変数変換によって,達成可能な下 限が変わっていないことを示している.

3. パラメータ直交化法を用いた振幅推定法

本章では、振幅推定法に、パラメータ直交化法の適用を 行う. 3.1 節ではモデルの拡張を行うとともに、補助回路 の導入をし、3.2 節では実際にパラメータ直交化法を適用 する.

3.1 補助回路

まず, IBM の量子コンピュータ [16] ibm.kawasaki で実際に振幅推定法を実行することを考える. ノイズがない理想的な量子コンピュータの場合,最後の量子ビットが1である確率は,式(5)で示す通り, $p_{\theta}^{(k)} = \sin^2((2m_k + 1)\theta)$ となる.一方で,現状の量子コンピュータはノイズがあり,実際に IBM の実機を用いた結果が図図 1 の青い実線で示すものである.前節で述べた脱分極ノイズがある場合には,式(11)の通り,

$$p_{\theta,\kappa}^{(k)} = \frac{1}{2} - \frac{1}{2} e^{-\kappa m_k} \cos(2(2m_k + 1)\theta)$$
(16)

となる.しかしながら,実際の量子コンピュータでは,様々 なノイズがあるため,より一般的なモデルである次の形に 拡張する.

$$p_{\theta,\beta_k}^{(k)} = \frac{1}{2} - \frac{1}{2}\beta_k \cos(2(2m_k + 1)\theta)$$
(17)

これは脱分極ノイズを含む形であり,更に振幅増幅の回数 *m_k* に拠らないものである.そして,確率分布密度関数および尤度関数が次で与えられる.

$$P(\mathbf{h}; \theta, \boldsymbol{\beta}) = \prod_{k=1}^{M} [p_{\theta, \beta_k}^{(k)}]^{h_k} [1 - p_{\theta, \beta_k}^{(k)}]^{1 - h_k}$$

$$L(\theta, \boldsymbol{\beta}; \mathbf{H}) = \prod_{j=1}^{N_{\text{shot}}} P(\mathbf{h}^j; \theta, \boldsymbol{\beta})$$
(18)

なお, $\boldsymbol{\beta} = (\beta_1, \dots, \beta_M)$ であり, h_k , **h**, **H** は前述と同じよ うものである. しかしながら, この場合, Fisher 情報行列 が正則でなくなってしまうため, このままでは扱うことが できない.

そこで, Fisher 情報行列の正則性の回復を行うために, 別の補助回路の導入を行う. この回路は, 元のものとは違 う回路ながら,同じノイズを受けると想定されるものであ る.まず, "振幅増幅しない" 演算子 R を次の形で置く.

$$\mathcal{R} := -\mathcal{A}U_0 \mathcal{A}^{\dagger} I_{n+1}. \tag{19}$$

これは、振幅増幅演算子 $\mathcal{G} = -\mathcal{A}\mathcal{U}_0 \mathcal{A}^{\dagger}\mathcal{U}_f$ の $\mathcal{U}_f = I_n \otimes \sigma_z$ を恒等演算子に置き換えたものである.なお、量子コピュー タの実機において、IBM の超電導量子コンピュータのよう に、Z 基底で測定している時、Z ゲートは、フレームチェ ンジによって実現されており、パルスの当たらない操作 となっており [19]、これは NMR[20] やイオントラップ方 式 [21] でも同様に実装されている.ここでは、演算子 G と R は同様のノイズを受けていると仮定して議論を進める.

そして, 演算子 $R \in R$ がのして, 補助回路 $\mathcal{R}\mathcal{G}^{m_k-1} |\Psi\rangle_{n+1}$ を導入する. これは \mathcal{G}^{m_k} の最後の演算子 $\mathcal{G} \in \mathcal{R}$ に置き換えたものであり, ノイズがない場合には, 次のようになる.

$$\mathcal{R}\mathcal{G}^{m_{k}-1} |\Psi\rangle_{n+1} = (-\mathcal{A}U_{0}\mathcal{A}^{\dagger})(-\mathcal{A}U_{0}\mathcal{A}^{\dagger}\mathcal{U}_{f})\mathcal{G}^{m_{k}-2} |\Psi\rangle_{n+1}$$
$$= \mathcal{U}_{f}\mathcal{G}^{m_{k}-2} |\Psi\rangle_{n+1}.$$
(20)

実際にはノイズがあり,(17)と同じノイズがあると仮定し た場合の最後の量子ビットが "1"である確率 $q_{\theta, \theta_k}^{(k)}$ は,

$$q_{\theta,\beta_k}^{(k)} = \frac{1}{2} - \frac{1}{2}\beta_k \cos(2(2(m_k - 2) + 1)\theta) = \frac{1}{2} - \frac{1}{2}\beta_k \cos(2(2m_k - 3)\theta)$$
(21)

となる. つまり, これは振幅増幅の回数が2つ分遅れるモ デルとなり, 実際に実機を用いて結果が図1の橙色の破線 であり, これは同様のノイズを受けるという仮定を支援す る結果である.

そして,これらの確率を用いて,確率密度関数および尤 度関数を以下で構成する.

$$Q(\boldsymbol{\ell};\boldsymbol{\theta},\boldsymbol{\beta}) = \prod_{k=1}^{M} [q_{\boldsymbol{\theta},\boldsymbol{\beta}_{k}}^{(k)}]^{\ell_{k}} [1 - q_{\boldsymbol{\theta},\boldsymbol{\beta}_{k}}^{(k)}]^{1-\ell_{k}}$$

$$L(\boldsymbol{\theta},\boldsymbol{\beta};\mathbf{H},\mathbf{L}) = \prod_{i=1}^{N_{\text{shot}}} P(\mathbf{h}^{i};\boldsymbol{\theta},\boldsymbol{\beta}) \prod_{j=1}^{N_{\text{shot}}'} Q(\boldsymbol{\ell}^{j};\boldsymbol{\theta},\boldsymbol{\beta})$$
(22)

なお、 N'_{shots} は補助回路の測定回数である.また、 $\mathbf{L} = \{\boldsymbol{\ell}^1, \cdots, \boldsymbol{\ell}^{N'_{shots}}\}$ であり、更に、 $\boldsymbol{\ell} = (\ell_1, \cdots, \ell_M)$ であり、 ℓ_k は $\mathcal{R}\mathcal{G}^{m_k-1}$ を一度だけ測定した結果である.これにより、対応する Fisher 情報行列は、逆行列を持つようになり、最尤推定を行えば、つまり、arg max $L(\theta, \boldsymbol{\beta}; \mathbf{H}, \mathbf{L})$ の 最適化問題を解くことを行えば良い.しかしながら、これはM + 1次元の最適化問題となるため、Mが大きい時には一般的には簡単には解くことができない.そこで、次節でパラメータ直交化法を用いることで、1次元の最適化問題に帰着できることを説明する.

3.2 パラメータ直交化法を用いた振幅推定法

前節で導入した式 (17) に対して, 2.2 節で説明したパラ メータ直交化法を用いる. つまり,式 (14) にある条件と なる微分方程式を考える. なお,ここでは $N_{\text{shots}} = N'_{\text{shots}}$ とする. さて,条件式は任意の $k = 1, \dots, M$ に対して, $A_k^p(\xi_1) = \cos^2(2(2m_k+1)\xi_1), A_k^q(\xi_1) = \cos^2(2(2m_k-3)\xi_1)$ とすると,以下のようになる.

$$\frac{\partial \beta_{k}(\boldsymbol{\xi})}{\partial \xi_{1}} \left(\frac{A_{k}^{p}(\xi_{1})}{1 - A_{k}^{p}(\xi_{1})\beta_{k}^{2}(\boldsymbol{\xi})} + \frac{A_{k}^{q}(\xi_{1})}{1 - A_{k}^{q}(\xi_{1})\beta_{k}^{2}(\boldsymbol{\xi})} \right) \\ = -\frac{\beta_{k}(\boldsymbol{\xi})}{2} \left(\frac{1}{1 - A_{k}^{p}(\xi_{1})\beta_{k}^{2}(\boldsymbol{\xi})} \frac{\partial A_{k}^{p}}{\partial \xi_{1}} + \frac{1}{1 - A_{k}^{q}(\xi_{1})\beta_{k}^{2}(\boldsymbol{\xi})} \frac{\partial A_{k}^{q}}{\partial \xi_{1}} \right)$$
(23)

すると、 $\beta_k(\boldsymbol{\xi})$ は次を満たす.

$$\{1 - A_k^p(\xi_1)\beta_k^2(\boldsymbol{\xi})\}\{1 - A_k^q(\xi_1)\beta_k^2(\boldsymbol{\xi})\} = c_k(\boldsymbol{\xi}') \quad (24)$$

なお、 c_k は局外パラメータ $\xi' = (\xi_2, \cdots, \xi_{M+1})$ から生じる任意の関数である、そして、式 (24) は次のように解くことができる.

$$\beta_k^2(\boldsymbol{\xi}) = \frac{A_k^p + A_k^q \pm \sqrt{(A_k^p + A_k^q)^2 - 4A_k^p A_k^q (1 - c_k(\boldsymbol{\xi}'))}}{2A_k^p A_k^q}$$
(25)

更に β_k(**ξ**) ≥ であること等から,次の解を得ることがで きる.

$$\beta_k(\boldsymbol{\xi}) = \sqrt{\frac{A_k^p + A_k^q - \sqrt{(A_k^p + A_k^q)^2 - 4A_k^p A_k^q (1 - c_k(\boldsymbol{\xi}'))}{2A_k^p A_k^q}}}{(26)}}$$

2.2 節でも説明している通り、パラメータ直交化法を用い ることで、測定回数の漸近的な極限において、 $\theta = \xi_1$ の推 定に関して、 $c_k(\xi')$ は影響を与えないことがわかる.それ ゆえに、 $c_k(\xi')$ はラフに選び、式 (22)で与えられている尤

度関数を,1次元の関数に置き換えて,最尤推定すること が可能となる.そして,この変数変換は解析的に解がもと まっていることから追加の計算量はほとんど必要ないこと がわかる.つまり,条件式である微分方程式が解析的に解 けていることが本質的に重要なことである.

4. デモンストレーション

4.1 節では数値シミュレーションを行い, 4.2 節では実際 に IBM の超電導量子コンピュータを用いて実験を行う.

4.1 数値シミュレーション

本節では数値シミュレーションを行う.具体的には,測 定回数が有限の範囲でパラメータ直交化法が有効かを検証 する.つまり,次の尤度方程式を考える.

$$\frac{\partial}{\partial \theta} \ln L(\theta, \beta; \mathbf{H}, \mathbf{L}) = 0, \qquad (27)$$

ここで, β_k(**ξ**) は,式 (26) で得られるものである.実際に 量子コンピュータを用いて計算を行う場合においても,測 定回数は出来るだけ小さい方がよく,この解析は重要で ある.

数値シミュレーションのパラメータは次のようにする. 求める値である $\theta_* = 0.35$ とし、測定回数は振幅増幅の回路 $\mathcal{G}^{m_k} |\Psi\rangle_{n+1}$ および、補助回路 $\mathcal{R}\mathcal{G}^{m_k-1} |\Psi\rangle_{n+1}$ ともに、 $N_{\text{shot}} = N'_{\text{shot}} = 50$ とする.そして、振幅増幅の回数 m_k は 2^{k-1} ($k = 1, 2, \ldots, 8$) とし、真の確率分布は、式 (11) に おける $\kappa = 0.01$ としたものである.なお、式 (24) にある { c_1, \ldots, c_8 } は次の場合の 2 通りを考える.

 $1: \{0.844, 0.134, 0.956, 0.238, 0.236, 0.623, 0.793, 0.324\}$

 $2: \{0.571, 0.452, 0.475, 0.259, 0.107, 0.965, 0.362, 0.522\}$

図 2(a) および (b) は、それぞれケース 1, 2 の対数尤度 関数である式 (27) の形状を青色および橙色の実線で示し、 求める値である $\theta_* = 0.35$ を赤の破線で示している. これ らの図から、式 (22) の解である対数尤度の最大値は、推定 したい値の近い値であることがわかる. つまり、 $\{c_k\}$ の値 に依存せず、1 次元の最適化問題を解くことで良いことを 示している. 更に、この尤度関数の形状は非常に複雑な形 であることもわかり、これは最尤推定がうまくいかない可 能性があることを示している. だからこそ、パラメータ直 交化法を用いることで、この多次元の最適化問題を扱わな くてよくなる.

そして,最大値以外の $L(\boldsymbol{\xi}; \mathbf{H}, \mathbf{L})$ の局値,つまり,式 (27)の解は,ほぼ $\{c_k\}$ に依存しないことが,図3からわ かる.図3は, $\theta = 0.35$ 付近のケース 1,2の場合,つまり, 図2の拡大図を重ねたものである.この図3から,対数尤 度関数の形は, $\{c_k\}$ の値によって変わることを示している. 更に,注目すべきことは,局値の位置がケース 1とケース 2 で,近いことである.測定回数 N_{shot} が小さいため,若干





図 2 青色および橙色の実線は,式 (22) にある対数尤度関数を,赤色の破線は推定したい値 θ_{*} = 0.35 を示している.



図 3 図 2(a),(b) の真の値 0.35 周辺の拡大図である.

の差はあるものの, 理論から予測されるように, N_{shot} を大 きくすると, 差は小さくなることが確認している.

次に、パラメータ直交化法を用いた場合の、振幅推定法の推定精度について議論を行う.パラメータについては、 $\{c_k\}$ の値以外、直前の場合と同じものを用いる.図4では、横軸に演算子 A の呼び出し回数 $N_q = \sum_{k=1}^M N_{\text{shot}}(2m_k+1)$ を取り、縦軸に推定精度を示したものである.赤色の細い実線、橙色の太い実線はそれぞれ、ノイズがない場合の古典的なランダムサンプリング(つまり $m_k = 0$ の時)と、量子振幅推定法を用いた場合の、Cramér-Raoの下限である.



図 4 θの推定精度と、演算子 A の総呼び出し回数 N_q の関係を示す.赤色の細い実線と、橙色の太い実線は、ノイズのない Cramér-Raoの下限であり、それぞれ古典的な場合と、量子的な場合を示している.緑色の破線と、青色の点線は、それぞれ、二次元の最尤推定を用いる手法と、パラメータ直交化法を用いた場合の Cramér-Raoの下限である.なお、脱分極ノイズモデルを仮定している.そして紫色のバツ点は、真の値 θ_{*} = 0.35と本章での手法を用いて数値シミュレーション計算された値 θ との標準誤差を示している.

この二つを比べると、後者の方が二乗での早く誤差が減少 することが確認でき、量子振幅推定法の優位性がわかる. そ して, 三角点のある緑色の破線と四角点のある青色の点線 は,それぞれ脱分極ノイズを仮定した際の,二次元の最尤指 定を用いた場合と、本章で議論したパラメータ直交化法を 用いた場合の Cramér-Rao の下限である.また, 橙色の太 い実線と、緑色の破線、青色の点線の三つの場合は、振幅増 幅の回数は $m_k = 2^{k-1}$ としており,前者の二つの場合では 測定回数を N_{shot} = 100 とし, 後者の場合では振幅増幅の 回路および補助回路の両方の測定回数 $N_{\rm shot} = N'_{\rm shot} = 50$ とすることで, 各 mk について, 100 回の測定を行なうよう にしている. なお, 青色の破線の場合, Fisher 情報行列の逆 行列の (1,1) 成分を計算しているが, これはパラメータ直 交化法を用いた前後で変化しないことに注意する.そして, 紫色のバツ点は, パラメータ直交化法を用いた振幅推定法 を用いてシミュレーションを行なったものであり, 真の値 $\theta_* = 0.35$ と推定した値 θ の分散を表している. なお, すべ てのkに対して $c_k = 0.3$ としている.

まず,脱分極ノイズモデルを仮定した2次元の最尤推定 を用いた緑色の破線と,パラメータ直交化法を用いた場合 の青色の点線は,非常に近いことがわかる.この結果は,真 の分布が脱分極ノイズだけからなることから,本稿で議論 した,パラメータを増やしたモデルが真のモデルを正しく 捉えることをできていることを示している.次に,緑色の 破線と青色の点線は,赤色の細い実線,つまり古典的な場 合より良い精度出せる領域がある.つまり,ノイズがあっ たとしても量子振幅推定法の優位性が得られることを示し ている.そして,紫色のバツ点,すなわちシミュレーショ ンの結果が Cramér-Rao の下限,つまり理論的な下限であ る青色の点線にほぼ一致していることである. これは,パ ラメータ直交化法を用いた手法がうまく機能していること を示しており,多次元の,特に本シミュレーションでは9 次元の最適化問題を,1次元の最適化問題に帰着でき,うま く推定ができていることを示している. なお,図2で示し た複雑な尤度関数の形は,9次元の関数を最大化し,最尤推 定を行うことが難しいことを示しており,9次元の最適化 を行なった場合には,シミュレーションの紫色のバツ点と, Cramér-Raoの下限である青色の点線の乖離が大きくなる ものと推測される.

4.2 実機による実験

本節では, IBM の超電導量子コンピュータ "ibm_kawasaki"を用いて、パラメータ直交化法を用いた 振幅推定法の実験を行う.そのために, [10], [14], [15], [22] にあるように、 $S = \sum_{j=0}^{2^n-1} f(j)r(j)$ を振幅推定法を用い て計算する.そして、次に示す演算子 $\mathcal{A} = \mathcal{T}(\mathcal{P} \otimes I_1)$ で 振幅にSを埋め込むことを考える.

$$\mathcal{A} |0\rangle_{n} |0\rangle = \mathcal{T} \sum_{j} \sqrt{r(j)} |j\rangle_{n} |0\rangle$$
$$= \sum_{j} \sqrt{r(j)} |j\rangle_{n} \left(\sqrt{f(j)} |1\rangle + \sqrt{1 - f(j)} |0\rangle\right)$$
$$= \sqrt{S} |\tilde{\Psi}_{1}\rangle |1\rangle + \sqrt{1 - S} |\tilde{\Psi}_{0}\rangle |0\rangle$$
(28)

なお, $|\tilde{\Psi}_1\rangle = \sum_j \sqrt{r(j)f(j)/S} |j\rangle_n$ および, $|\tilde{\Psi}_0\rangle = \sum_j \sqrt{r(j)(1-f(j))/(1-S)} |j\rangle_n$ と置く. そして, 式 (1) から, 振幅推定により $S = \sin^2 \theta$ で推定できる. 本検証で は, 任意の j に対して, $f(j) = \sin^2(\pi j/10)$, $r(j) = 1/2^n$ とし, 特に n = 1 のシンプルな場合を扱う. なお, $\mathcal{P} \in \mathcal{T}$ は, Hadamard ゲートと, 制御された y 回転ゲートで実装 することができる. 推定したい値 $\theta = 0.175$ とし, つまり, $S = 3.03 \times 10^{-2}$ の計算を行う.

そして、振幅増幅の回数 $m_k = 2^{k-1}$ 、(k = 1, 2, ..., 7) と し、局外パラメータ $\beta = (\beta_1, ..., \beta_7)$ を用いて、パラメー タ直交化法を適用する. 図5は、 θ の推定精度と、演算子 A の総呼び出し回数 $N_q = \sum_{k=1}^M N_{shot}(2m_k+1)$ の関係を示し ている.赤色の細い実線は、古典的なランダムサンプリン グ、つまり、 $m_k = 0$ の時、橙色の太い実線は、ノイズがな い場合の量子振幅推定法を用いた場合の、Cramér-Rao の 下限であり、図4と同じものである.そして、青色のバツ点 は、実機を用いた場合の、推定したい値である $\theta_* = 0.175$ と誤差を示している.なお、 $c_k = 0.3$ とし、測定回数は、振 幅増幅回路の場合と補助回路の場合の両方で、 $N_{shot} = 50$ としている.更に、 $N_{rep} = 2,119$ 回同じ実験を繰り返して 実行し、標準誤差の3倍をエラーバーとして示しており、 これらのパラメータを表1にまとめて示す.

この図 5 から $N_q=3 imes 10^3$ の範囲では,定数倍のオー



図 5 θの推定精度と, 演算子 A の総呼び出し回数 N_q の関係を 示す.赤色の細い実線と, 橙色の太い実線は, ノイズのない Cramér-Raoの下限であり, それぞれ古典的な場合と, 量子的 な場合を示している.青色のバツ点は, 実機の結果であり, こ の手法を用いた際の推定精度の誤差を示している.

表 1 2 量子ビット (実機)	を用いた際のパラメー	ター覧
項目	文字	値
測定回数	$N_{\rm shot} = N_{\rm shot}'$	50
振幅増幅の回数	m_k	2^k
推定する値	heta	0.175

誤差を評価するための繰返回数

 $N_{\rm rep}$

2,119

バーヘッドはあるものの, N_q^{-1} に近い傾きを示しているこ とがわかる.これは、前節の数値シミュレーションの場合 で採用した κ = 0.01 よりも実機のノイズが大きく,実機の 不確かさによるものと考えられる.それにもかかわらず, $N_q = 3 \times 10^3$ の付近の青色のバツ点では、古典的な場合の 赤い細い実線より良い推定精度を得ている。ただし、振幅 増幅の回数を増やしても、ノイズの影響により推定精度を より良くできないことがわかる. 実際に、"ibm_kawasaki" から得られた本結果は、[14] で用いた "ibmq_valenica" と 同程度のノイズの大きさであり、矛盾しない結果である. これらの結果は、多次元の最適化問題を解かずに、1次元 の最大化問題を解くことで、振幅推定法を実行でき、特定 できないノイズ環境下でも機能することを示している.更 に、脱分極ノイズモデルをより一般的なモデルに拡張する ことができることを示しており、更に、パラメータ直交化 法を用いることで, θの推定値は, 局外パラメータβによ らず、そして、局外パラメータを推定せずに、ほぼ正確に計 算できる可能性があることを示唆している.

5. まとめ

本稿では、パラメータ直交化法を用いた振幅推定法を説 明した.より一般的なノイズモデルを導入することで、よ り未知のノイズを扱えるようにモデルの拡張を行うが、そ れにより推定が困難になることを、補助回路の導入によっ て解消し、更に多次元の最適化問題も、パラメータ直交化 法を用いることで、1次元の問題に帰着することをした. 本直交化法を用いる際の一つの難しさは,条件となる微分 方程式を解くことだが,これが解析的に解けていることも, 本稿の貢献の一つである.

また,量子コンピュータを物理実験の装置としてみなす と,実験装置から必要な値を精密に得る必要があるが,一 方で量子コンピュータはノイズ,特に未知のノイズがある 状況下である.つまり,実験結果からそれらのノイズの効 果をうまく処理する必要があり,そこには統計的な手法を 用いることが有用である.これは,振幅推定の問題に限る 話ではなく,例えばエラー訂正を考えた場合にも物理的な 系ではノイズは存在するため,考えなければならない問題 であり,重要な問題である.

謝辞 本稿は、文部科学省 Quantum Leap Flagship Program (JPMXS0118067285 および JPMXS0120319794)の 支援を受け行われた.

参考文献

- David Deutsch and Richard Jozsa. Rapid solution of problems by quantum computation. Proceedings of the Royal Society of London. Series A: Mathematical and Physical Sciences, Vol. 439, No. 1907, pp. 553–558, 1992.
- [2] Peter W Shor. Polynomial-time algorithms for prime factorization and discrete logarithms on a quantum computer. SIAM review, Vol. 41, No. 2, pp. 303–332, 1999.
- [3] Lov K Grover. A fast quantum mechanical algorithm for database search. In *Proceedings of the twenty-eighth annual ACM symposium on Theory of computing*, pp. 212–219, 1996.
- [4] Gilles Brassard, Peter Hoyer, Michele Mosca, and Alain Tapp. Quantum amplitude amplification and estimation. *Contemporary Mathematics*, Vol. 305, pp. 53–74, 2002.
- [5] Ashley Montanaro. Quantum speedup of Monte Carlo methods. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, Vol. 471, No. 2181, p. 20150301, 2015.
- [6] Patrick Rebentrost, Brajesh Gupt, and Thomas R Bromley. Quantum computational finance: Monte Carlo pricing of financial derivatives. *Physical Review A*, Vol. 98, No. 2, p. 022321, 2018.
- [7] Anupam Prakash. Quantum algorithms for linear algebra and machine learning. PhD thesis, UC Berkeley, 2014.
- [8] Nathan Wiebe, Ashish Kapoor, and Krysta M. Svore. Quantum algorithms for nearest-neighbor methods for supervised and unsupervised learning. *Quantum Inf. Comput.*, Vol. 15, pp. 316–356, 2015.
- John Preskill. Quantum computing in the nisq era and beyond. *Quantum*, Vol. 2, p. 79, 2018.
- [10] Yohichi Suzuki, Shumpei Uno, Rudy Raymond, Tomoki Tanaka, Tamiya Onodera, and Naoki Yamamoto. Amplitude estimation without phase estimation. *Quantum Information Processing*, Vol. 19, No. 2, p. 75, 2020.
- [11] Scott Aaronson and Patrick Rall. Quantum approximate counting, simplified, in Symposium on Simplicity in Algorithms. pp. 24–32. SIAM, 2020.
- [12] Dmitry Grinko, Julien Gacon, Christa Zoufal, and Stefan Woerner. Iterative quantum amplitude estimation. *npj Quantum Information*, Vol. 7, No. 1, pp. 1–6, 2021.
- $\left[13\right]$ Kouhei Nakaji. Faster amplitude estimation. Quantum

Inf. Comput., Vol. 20, pp. 1109-1122, 2020.

- [14] Tomoki Tanaka, Yohichi Suzuki, Shumpei Uno, Rudy Raymond, Tamiya Onodera, and Naoki Yamamoto. Amplitude estimation via maximum likelihood on noisy quantum computer. *Quantum Information Processing*, Vol. 20, No. 9, pp. 1–29, 2021.
- [15] Tomoki Tanaka, Shumpei Uno, Tamiya Onodera, Naoki Yamamoto, and Yohichi Suzuki. Noisy quantum amplitude estimation without noise estimation. *Phys. Rev. A*, Vol. 105, p. 012411, 2022.
- [16] IBM Quantum Experience. https://quantumcomputing.ibm.com.
- [17] David Roxbee Cox and Nancy Reid. Parameter orthogonality and approximate conditional inference. Journal of the Royal Statistical Society: Series B (Methodological), Vol. 49, No. 1, pp. 1–18, 1987.
- [18] Jun Suzuki. Nuisance parameter problem in quantum estimation theory: tradeoff relation and qubit examples. *Journal of Physics A: Mathematical and Theoretical*, Vol. 53, No. 26, p. 264001, 2020.
- [19] David C McKay, Christopher J Wood, Sarah Sheldon, Jerry M Chow, and Jay M Gambetta. Efficient z gates for quantum computing. *Physical Review A*, Vol. 96, No. 2, p. 022330, 2017.
- [20] Emanuel Knill, R Laflamme, R Martinez, and C-H Tseng. An algorithmic benchmark for quantum information processing. *Nature*, Vol. 404, No. 6776, pp. 368–370, 2000.
- [21] Emanuel Knill, Dietrich Leibfried, Rolf Reichle, Joe Britton, R Brad Blakestad, John D Jost, Chris Langer, Roee Ozeri, Signe Seidelin, and David J Wineland. Randomized benchmarking of quantum gates. *Physical Review* A, Vol. 77, No. 1, p. 012307, 2008.
- [22] Tomoki Tanaka, Shumpei Uno, Yohichi Suzuki, and Rudy Raymond. https://github.com/Qiskit/ qiskit-community-tutorials/blob/master/algorithms/ SimpleIntegral_AEwoPE.ipynb, 2019. Accessed: 2021-10-01.