クリギング法を用いたゼロ次最適化アルゴリズムによる 量子状態作成

数理情報学専攻 48-206201 **穴澤 徳明**

指導教員 山西 健司 教授

1 背景

量子コンピュータを構成するデバイスは外部からの ノイズによる量子誤りの頻度が非常に大きく,量子誤り を訂正し十分な計算が行える状態(エラーフリー)が求 められる. Gottesman-Kitaev-Preskill 状態(GKP 状 態)[1] という量子状態は,ウィグナー関数と呼ばれる位 相空間上の擬確率分布において規則的に多くのシャー プな構造を持つ特殊な性質を持つ. これにより GKP 状 態は,離散的な確率密度分布を持ちながら光波の連続的 な性質を保つため,連続変数型(Continuous Variable: CV)量子計算において量子もつれを生むことが可能で あり,また量子誤り訂正能力も備えている. そのため大 規模な量子もつれを生成でき,将来的に複雑な量子計算 を行える有望な量子状態として期待される.

GKP 状態を準備することでエラーフリーを備えた ユニバーサルな量子計算を行う方法が提唱され,この GKP 状態の実現に向けて盛んに研究が行われている. 数値実験では任意の状態生成問題に対し多層パーセプ トロンを用いたパラメータ最適化への帰着が行われ,誤 差逆伝播による求解で GKP 状態との内積が 0.99 以上 の量子状態が得られている [2].

本研究ではこのパラメータ最適化問題において,勾配 を必要としないゼロ次最適化手法を導入する.これに より状態ベクトルの観測困難性を回避でき,量子デバイ スでの実現可能性が高まる.また1次勾配を必要しな いため,量子状態の差を表す距離の中で微分困難なもの も損失関数として扱うことが可能である.

2 問題設定

量子状態はヒルベルト空間内の L2 ノルム 1 を保つベ クトルで表現可能であり、 |ψ⟩ と表される. これを状態 ベクトルと呼ぶ.

$$|\psi\rangle$$
:状態ベクトル, $c_n \in \mathbb{C}, n = 0, 1, 2, \dots$ (1)

$$|\psi\rangle = (c_0, c_1, \dots, c_n, \dots)^{\mathrm{T}}.$$
 (2)

量子回路は、入力 $|\psi_0\rangle$ から出力 $|\psi\rangle$ への行列変換で 記述可能である. $\theta \in \mathbb{R}^f$ を量子回路のパラメータ列、 $U(\theta) \in \mathbb{C}^{N \times N}$ を量子回路に対応する行列変換であると する.このとき出力は以下を満たす.

$$|\psi\rangle = U(\theta)|\psi_0\rangle. \tag{3}$$

ここで所望のターゲット |ψ_t) を出力するための最適な θ を決定するパラメータ最適化問題を考えることができ る.出力とターゲットの量子状態の近さをベクトルの 内積で表現する Fidelity を用いる.

$$F(\psi_t, \psi) = |\langle \psi_t | \psi \rangle|^2.$$
(4)

最適化問題は以下.

$$\max_{\boldsymbol{\rho}} \quad F(\psi_t, \psi). \tag{5}$$

以下のような損失関数(Fidelity 損失)を構成すること が多い.

$$Z(\theta) = 1 - F(\psi_t, \psi). \tag{6}$$

式変形により損失関数を定数差で以下のように取り替え ることができ,最小化問題は等価であることが言える.

$$Z(\theta) = \left| \left\langle \psi_t | \psi \right\rangle - 1 \right|. \tag{7}$$

3 既存手法

シミュレーションでは,損失関数 Z(θ) のθによる勾 配を自動微分により計算し,最急降下法であれば学習 率 η を決めて以下のような更新式に従い最適化を行う ことが可能である.先行研究では実際に深層学習で主 に用いられている勾配法の Adam を用い [3],学習率を 調整することで高速化を狙った.いずれのシミュレー ションも数百程度のゲートを持つネットワークを用い て 0.99 を超える Fidelity を達成した.

$$\theta \mapsto \theta - \eta \nabla_{\theta} Z. \tag{8}$$

仮想回路での最適化によって得られたパラメータ設定 を実際の回路に利用すると誤差が発生するため,実際の 回路で最適化を行う必要がある.しかし既存手法は勾 配計算のために観測が困難な |ψ⟩ を用いる必要がある. これは ∇_θZ を必要とするアルゴリズムを用いることで 必ず発生する課題である.

4 提案手法

本研究ではパラメータ最適化問題にゼロ次最適化を 導入する. ゼロ次最適化とはパラメータ $\tilde{\theta}_i$ と関数値 $y_i = Z(\tilde{\theta}_i)$ のサンプルのみを用い,勾配情報を使わな い最適化アルゴリズムである.

$$D = \{ (\tilde{\theta}_1, y_1), (\tilde{\theta}_2, y_2), \dots, (\tilde{\theta}_M, y_M) \}.$$
(9)

以下に各アルゴリズムの概略を示す.

4.1 ベイズ最適化 (BO)[4]

最小値を取る確率最大の点を逐次的に探索して最適 化を行う.入力はカーネル K,近似関数 $\hat{Z}(\theta)$,探索空 間 Θ ,訓練データ D,損失関数 $Z(\theta)$.出力は $Z(\theta)$ を最 小化する $\theta_{opt} \in \Theta$.まずカーネルを用いて各点の平均, 分散を計算する.(よくガウスカーネルを用いる.)

$$\mu(\cdot \mid D), \sigma(\cdot \mid D) \leftarrow K \mid D. \tag{10}$$

次に,獲得関数最大化により次の探索点を決定する.

$$\hat{\theta} = \arg\min_{\Theta} \hat{Z}(\mu(\theta \mid D), \sigma(\theta \mid D)).$$
(11)

以上を収束するまで繰り返す.

4.2 Direct Optimization by Kriging method (DO by Kriging)

入力は探索空間 Θ , 訓練データ D, 損失関数 $Z(\theta)$, ハ イパーパラメータ a_s, a_r . 出力は BO と同様. BO の獲 得関数の代わりに, クリギング法 [5] による内挿で近似 関数 $\hat{Z}(\theta)$ を計算する.

$$h_{i,j} = \left\| \tilde{\theta}_i - \tilde{\theta}_j \right\| \tag{12}$$

$$g_{i,j} = \frac{1}{2} \left(y_i - y_j \right)^2 \tag{13}$$

$$\Sigma_{i,j} = a_s \exp\left\{-\left(\frac{g_{i,j}}{a_r}\right)^2\right\}$$
(14)

$$b_i(\theta) \leftarrow a_s \exp\left\{-\left(\frac{\left\|\theta - \tilde{\theta}_i\right\|}{a_r}\right)^2\right\}$$
 (15)

$$\hat{Z}(\theta) \leftarrow \bar{y} + b(\theta)^{\mathrm{T}} \Sigma^{-1} (\mathbf{y} - \bar{y} \mathbf{1})$$
 (16)

次に,近似関数の最小値を探索する.

$$\hat{\theta} = \underset{\Theta}{\arg\min} \hat{Z}(\theta) \tag{17}$$

以上を収束するまで繰り返す.

4.3 Gradient Descent by Kriging method (GD by Kriging)

DO by Kriging で近似関数最小化の代わりに,近似 勾配 $\nabla_{\theta} \hat{Z}$ を用いて勾配降下法を行う.

$$\hat{\theta} = \theta - \eta \nabla_{\theta} \hat{Z}(\theta) \tag{18}$$

4.2, 4.3 のクリギング内挿はサンプルサイズ |D| の 増加に従って計算量が増加してしまう.以下のような 規則に従って $D' \subset D$ を選ぶことにする.サンプル $(\tilde{\theta}_i, y_i)$ のスコア J_i は初期値として1が与えられる.

$$J_i = 1, \quad (^\forall i). \tag{19}$$

次に, D'は D の中から重み J_i に従って一定数選ばれる. そして,各ステップ T でスコアを以下のように更新する. Tにおける損失関数を Z_T とする.

$$J_i \mapsto \max(1, J_i + |D|(Z_T - Z_{T-1})),$$

(if $(\tilde{\theta}_i, y_i) \in D'$). (20)

これにより, *Z_T* が減少した場合はその時に選ばれたサ ンプルのスコアは上昇し, *Z_T* が増加した場合はスコア が減少する.

5 数值実験

 $|\psi\rangle$ の観測困難性を克服できるゼロ次最適化の中では GD by Kriging が最大 Fidelity を達成した.

表1. 既存手法と提案手法の比較

手法	最大 Fidelity	$\ket{\psi}$ の必要性
誤差逆伝播	0.6	0
BO[4]	0.45	X
DO by Kriging	0.47	×
GD by Kriging	0.52	×

参考文献

- A. Kitaev D. Gottesman and J. Preskill. Encoding a qubit in an oscillator. 2001.
- [2] Juan Miguel Arrazola, Thomas R. Bromley, Josh Izaac, Casey R. Myers, Kamil Brádler, and Nathan Killoran. Machine learning method for state preparation and gate synthesis on photonic quantum computers. 2018.
- [3] Diederik P. Kingma and Jimmy Ba. Adam: A method for stochastic optimization, 2014.
- [4] Peter I. Frazier. A tutorial on bayesian optimization, 2018.
- [5] Georges Matheron. The intrinsic random functions and their applications. Advances in applied probability, Vol. 5, No. 3, pp. 439–468, 1973.