

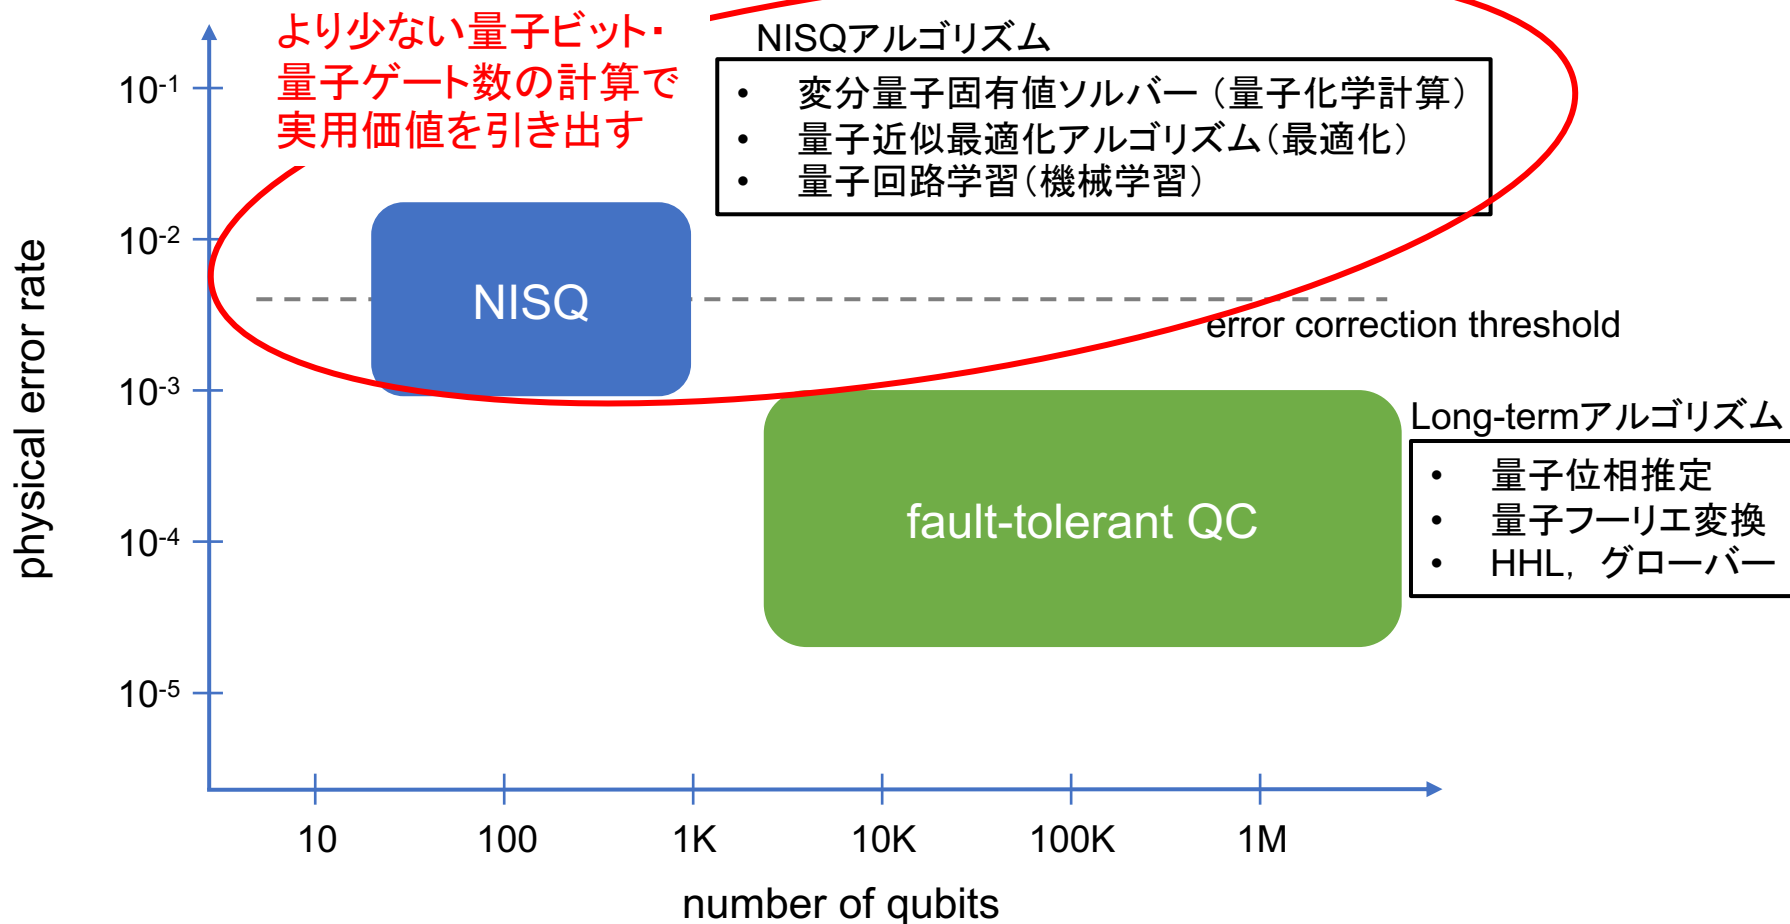
機械学習を用いた NISQアルゴリズム向けの 誤り補償手法の開発

矢野碩志 鈴木雄大

徳永PM 鈴木TA

背景: NISQアルゴリズム

NISQ(Noisy Intermediate Scale Quantum)デバイス *Quantum*, 2, 79 (2018) Preskill
数年から数十年以内に開発される小・中規模の量子コンピュータ



背景: ノイズへの取り組み

□量子誤り訂正


冗長性を加えることでノイズから情報を守る

→エラー率が低い大量の量子ビットが必要

□量子誤り補償

統計的な処理を行いノイズを低減する

→追加の量子ビットを必要とせず、NISQデバイスでも実装が可能



Shor-code (1 qubit → 9 qubits)

$$|0\rangle \rightarrow |0_L\rangle \equiv |+++ \rangle$$


$$|1\rangle \rightarrow |1_L\rangle \equiv |--- \rangle$$

with

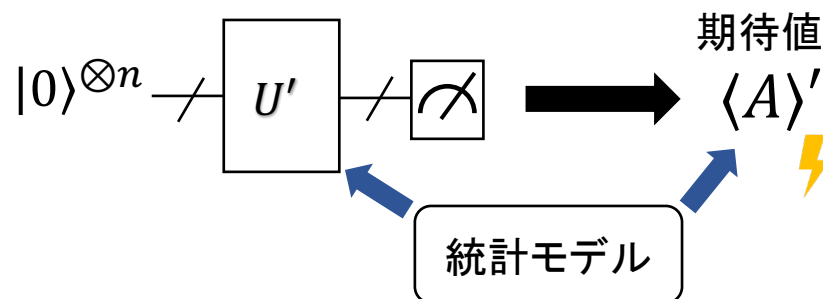
$$|+\rangle = \frac{1}{\sqrt{2}} (| \overset{0}{\uparrow} \overset{0}{\uparrow} \overset{0}{\uparrow} \rangle + | \overset{1}{\downarrow} \overset{1}{\downarrow} \overset{1}{\downarrow} \rangle)$$

$$|-\rangle = \frac{1}{\sqrt{2}} (| \overset{0}{\uparrow} \overset{0}{\uparrow} \overset{0}{\uparrow} \rangle - | \overset{1}{\downarrow} \overset{1}{\downarrow} \overset{1}{\downarrow} \rangle)$$

誤り補償なし



誤り補償あり



➤ 統計モデルを用いて理想的な値に近い $\langle A \rangle'$ を出力

背景: 誤り補償

□ 確率的誤りキャンセル *Phys Rev Lett* **119**, 180509 (2017) Temme *et al.*

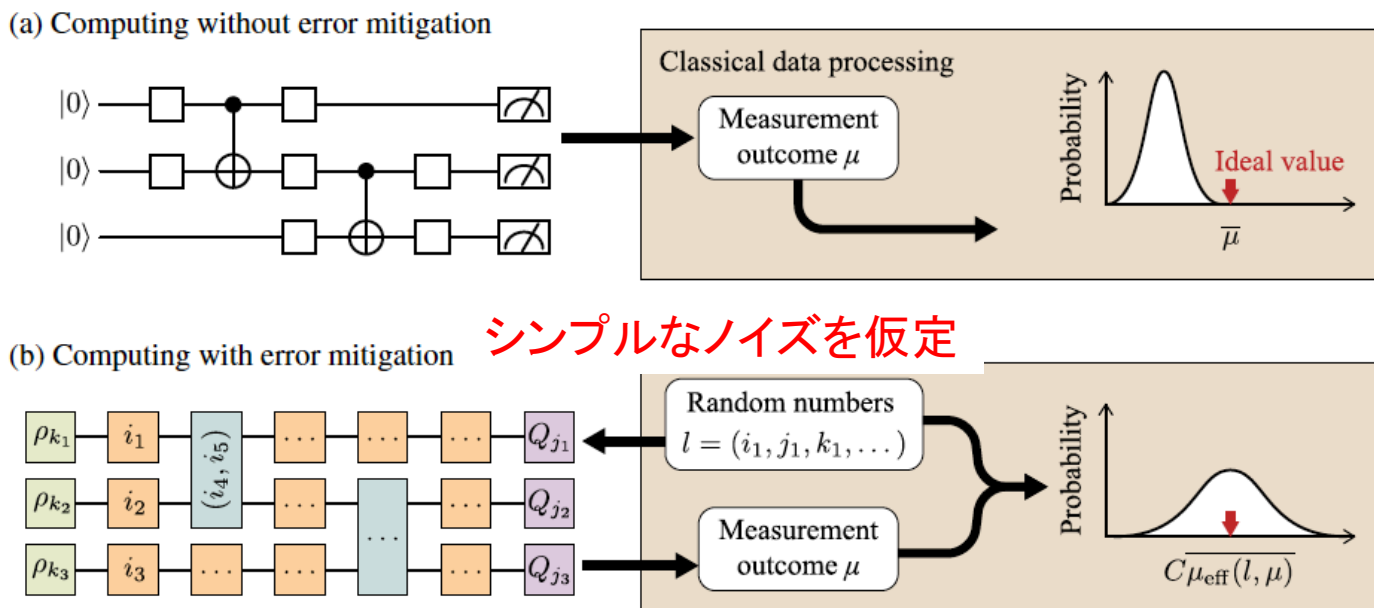


Figure from *Phys Rev X* **8**, 031027 (2018) Endo *et al.*

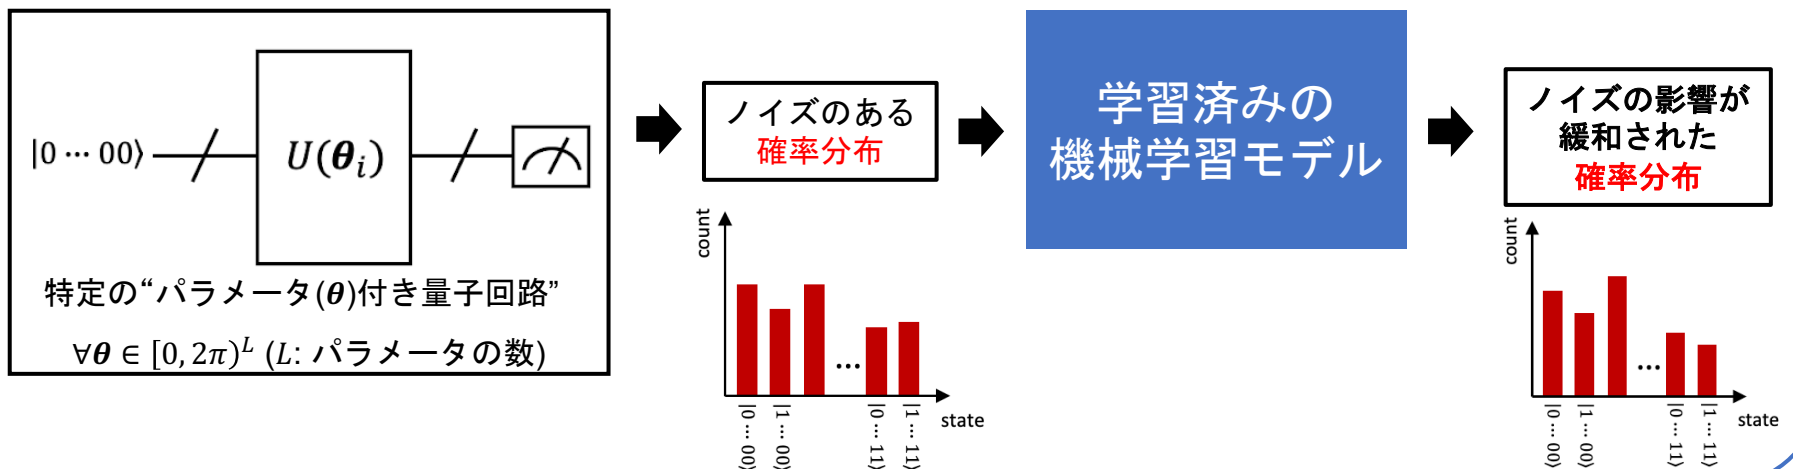
シンプルなノイズモデルを仮定するだけでは不十分

➤ **機械学習**により計算に影響を与える様々なノイズを低減する

本プロジェクトの目的

量子コンピュータ上でNISQアルゴリズムを実行したときに生じるノイズの低減を行う手法の開発

本プロジェクト成果物の使用例



期待される効果

- より正確に観測値を推定できるようになり、NISQアルゴリズムの**計算精度の向上に貢献**
- 量子機械学習における生成モデル(量子敵対生成ネットワーク, 量子回路ボルンマシン)や量子近似最適化アルゴリズムに適用が可能

プロジェクト成果概要

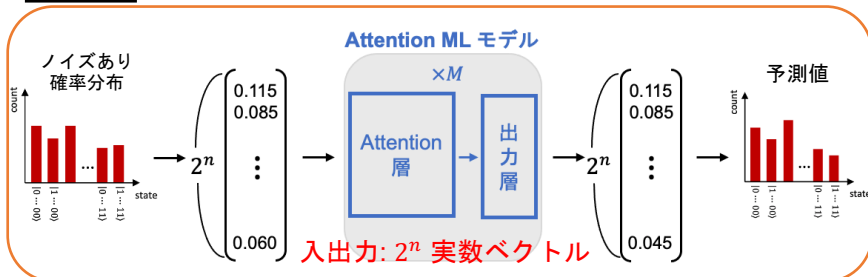
プロジェクト開始～第2回中間報告会

2020.06

2020.11

- ① 確率分布を入出力とする機械学習モデルを用いたパラメータ付き量子状態の誤り補償

概略図



モデル概要

量子状態が取りうる 2^n の長さの状態に関する確率分布を機械学習モデルに入力し、ノイズを抑制した確率分布を得る

(n : 量子ビット数)

成果

代表的な2つのノイズモデルについて誤り補償可能であることを確認

この手法では量子ビット数に対して、モデルのサイズが指数的に大きくなる問題を回避することは困難

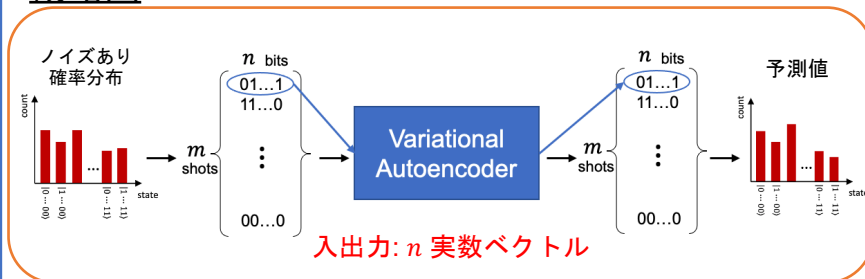
第2回中間報告会～現在

2020.11

2021.02

- ② ビット列を入出力とする機械学習モデルを用いたパラメータ付き量子状態の誤り補償

概略図



モデル概要

量子状態を観測したときに得られる m 個の n ビット列を機械学習モデルに入力し、ノイズを抑制した m 個の n ビット列を得る

(n : 量子ビット数, m : 測定回数)

成果

1量子状態について誤り補償可能であることを確認

パラメータ付き量子状態について本手法が使える開発途中

方法: 概要 (①②共通)

i のとり方 = サンプル手法

ランダムサーチ
パラメータ空間 θ 上に一様分布を仮定してサンプリング


$\theta_i \in \mathbb{R}^L$ ($i = 1, \dots, N$)

古典データ

変分回路のパラメータ

(N : 訓練データの数)

パラメータ付き量子回路




ノイズモデルを仮定したシミュレータ


シミュレータ

入力

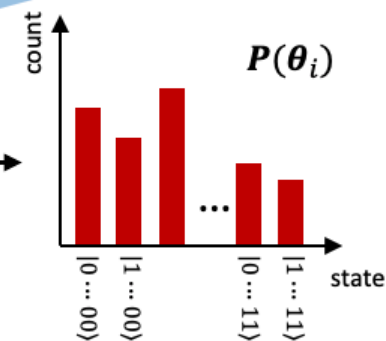
教師値



ノイズあり
確率分布

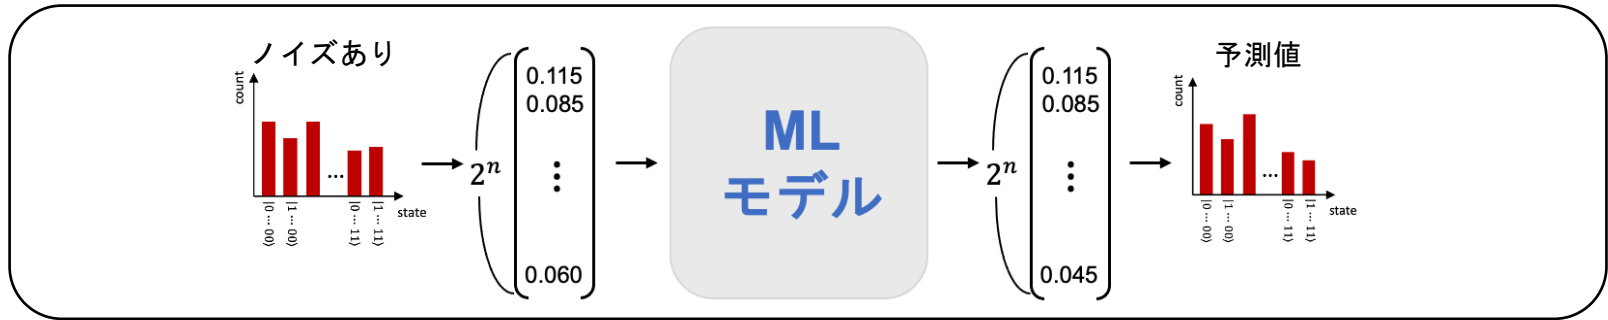


教師あり機械学習



ノイズなし
確率分布

① 確率ベクトルを入出力とする機械学習モデル



線形機械学習モデル



- 入力: 2^n 実数ベクトル、出力: 2^n 実数ベクトル
- 2層ニューラルネットワーク
- 活性化関数: 線形関数 (Linear)
- コスト関数: 平均二乗誤差 (MSE) + 制約項

$$cost = \sum (\mathbf{y}^{true} - \mathbf{y}^{pred})^2 + \left(1 - \sum y_i^{pred}\right)^2$$

Attention ML モデル (非線形機械学習モデル)



- 入力: 2^n 実数ベクトル、出力: 2^n 実数ベクトル
- Attention ML モデル (m 層の Attention層 + 出力層)
- 活性化関数: ReLU (中間層)・Softmax(出力層)
- コスト関数: 平均二乗誤差 (MSE)
- その他: skip connection・Layer Normalization

① 確率ベクトルを入出力とする機械学習モデル

Depolarizing channelにおける誤り補償実験

□ 実験設定

量子回路: 3量子ビット, 20パラメータ

サンプリング手法: ランダムサーチ

評価指標:

ノイズなし確率分布との平均二乗誤差(MSE)

訓練量子回路数: 10,000

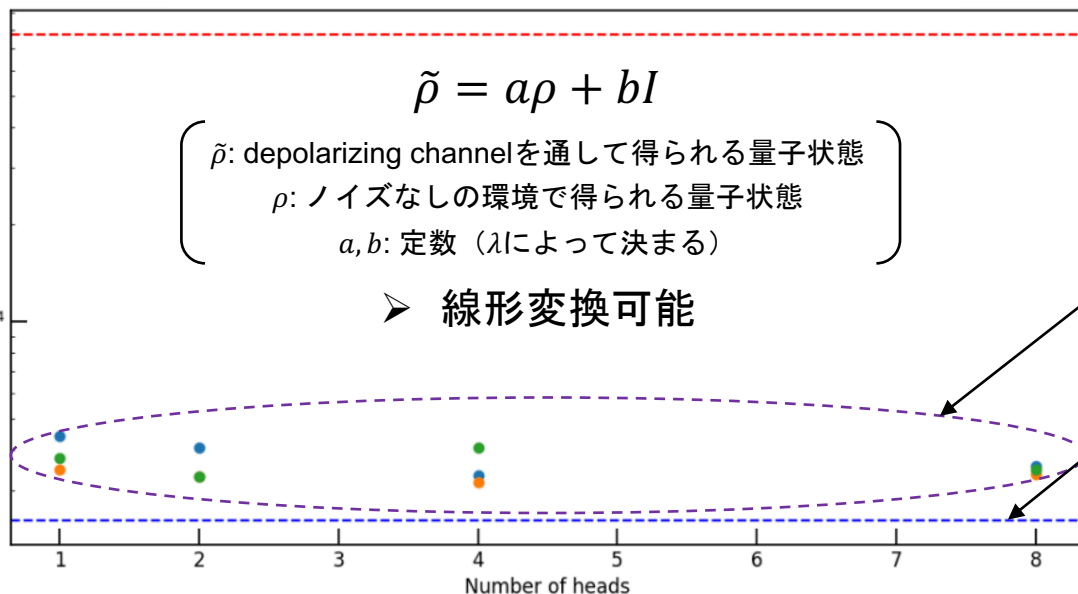
検証量子回路数: 10,000

ノイズ: Depolarizing channel $\lambda_1 = \lambda_2 = 0.01$

λ_1, λ_2 : single- and two-qubit depolarizing noise rate

$$E(\rho) = (1 - \lambda)\rho + \lambda \text{Tr}[\rho] \frac{I}{2^n}$$

ρ : 量子状態 (密度演算子)
 I : 恒等演算子
 λ : Depolarizing error parameter



ノイズ除去前

Attention MLモデルによるノイズ除去後

線形機械学習モデルによるノイズ除去後

線形モデルとほぼ同等の精度で
ノイズ除去に成功

① 確率ベクトルを入出力とする機械学習モデル

Amplitude-damping channelにおける誤り補償実験

□ 実験設定

量子回路: 3量子ビット, 20パラメータ

サンプリング手法: ランダムサーチ

評価指標:

ノイズなし確率分布との平均二乗誤差(MSE)

訓練量子回路数: 10,000


検証量子回路数: 10,000

ノイズ: Amplitude-damping channel $\gamma = 0.004$
(線形モデルで誤り補償可能かどうか非自明)

$$E(\rho) = K_0\rho K_0^\dagger + K_1\rho K_1^\dagger$$

$$K_0 = \begin{pmatrix} 1 & 0 \\ 0 & \sqrt{1-\gamma} \end{pmatrix}, K_1 = \begin{pmatrix} 0 & \sqrt{\gamma} \\ 0 & 0 \end{pmatrix}$$

ρ : 量子状態(密度演算子)
 γ : Amplitude damping parameter



① 確率ベクトルを入出力とする機械学習モデル

Amplitude-damping channelにおける誤り補償実験

□ 実験設定

量子回路: 3量子ビット, 20パラメータ

サンプリング手法: ランダムサーチ

評価指標:

ノイズなし確率分布との平均二乗誤差(MSE)

訓練量子回路数: ~~40,000~~ → 1,000


検証量子回路数: 10,000

ノイズ: Amplitude-damping channel $\gamma = 0.004$
(線形モデルで誤り補償可能かどうか非自明)

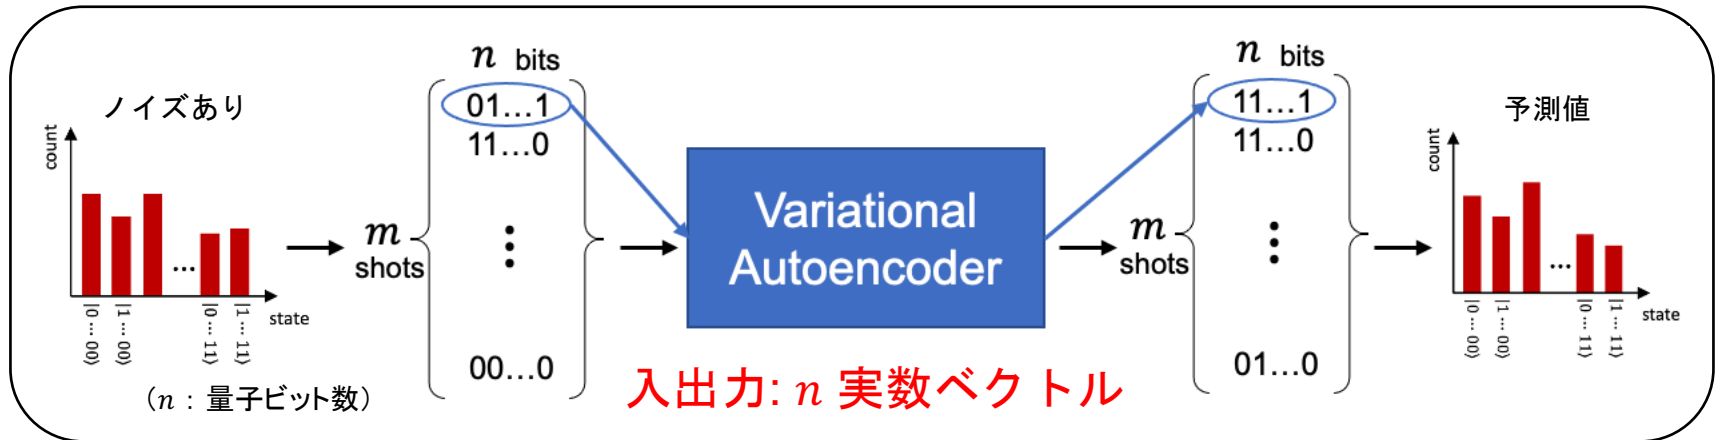
$$E(\rho) = K_0 \rho K_0^\dagger + K_1 \rho K_1^\dagger$$

$$K_0 = \begin{pmatrix} 1 & 0 \\ 0 & \sqrt{1-\gamma} \end{pmatrix}, K_1 = \begin{pmatrix} 0 & \sqrt{\gamma} \\ 0 & 0 \end{pmatrix}$$

ρ : 量子状態(密度演算子)
 γ : Amplitude damping parameter




② ビット列を入出力とする機械学習モデル



Variational AutoEncoder (VAE) 概略図

エンコーダ 潜在空間 デコーダ



- 入力: n ビット列, 出力: n ビット列
- 入力, 教師データはそれぞれノイズあり, ノイズなしの確率分布から取得
- VAEはエンコーダ, 潜在空間, デコーダから構成
- エンコーダ, デコーダは2層のニューラルネット
- 運用時もエンコーダに未知データを入力して使用

② ビット列を入出力とする機械学習モデル


1量子状態に対する depolarizing channel の補償

□ 実験設定


量子回路: 4量子ビット, 14パラメータ

ノイズ: depolarizing channel ($\lambda = 0.01$)


用いた量子回路




ノイズあり確率分布(入力)



誤り補償後の確率分布



ノイズなし確率分布(教師)



定量的な評価: 平均二乗誤差 (MSE)

$$MSE(\mathbf{y}, \hat{\mathbf{y}}) = \frac{1}{N} \sum_i (y_i - \hat{y}_i)^2$$

\mathbf{y} : 教師値, $\hat{\mathbf{y}}$: 予測値, N : $\mathbf{y}(\hat{\mathbf{y}})$ の次元

MSE(ノイズ補償前) : 3.7×10^4

MSE(ノイズ補償後) : 2.6×10^4

➤ 1量子状態に対する depolarizing channel の補償が可能であることを確認

本プロジェクトの成果と今後の展望

< 成果 >

- 特定のパラメータ付き量子回路を対象とし、機械学習を用いて誤り補償を行う手法①と②を開発
- 提案手法①により、少規模のパラメータ付き量子回路に対して、depolarizing channel・amplitude dampingのノイズを緩和可能であることを確認
 - 特に提案手法① Attention ML モデルは少ないデータで誤り補償可能
- 提案手法②において、対象とする量子回路の量子ビット数が増加しても実行可能なモデルへと拡張
 - 1量子状態について誤り補償可能であることを確認

< 今後の展望 >

- 提案手法②を拡張し、パラメータ付き量子回路に対する誤り補償手法を確立
 - 実用性に向けて、教師値を古典コンピュータで効率的に計算できるものに限定