

DQNNベースのFidelity予測による蒸留最適化

1. 研究の背景

- 量子ネットワークの現状
 - 電子もつれ状態のFidelity管理が重要課題
 - Distillation(蒸留)**による量子状態品質改善が必要不可欠
- 以前研究の問題点
 - MAB (Multi-Armed Bandit) 研究での課題発見
 - Distillationの品質改善は成功
 - 時間変動の不確実性**が深刻な問題
- 解決への着目点
 - Fidelity事前予測の重要性**
- 研究の着目点
 - 効率的なFidelity予測手法の開発により、量子ネットワークの実用化を促進

2. 関連研究、Fidelity評価手法

- Fidelity測定・評価手法
 - QST (Quantum State Tomography)
 - 基底別測定の反復による完全**再構成**による品質評価
 - 特徴: **測定の反復**により、Fidelityが実際に判明
 - DNN-QST応用: 測定効率性の向上研究
 - 測定回数・測定基底数の最適化
 - QNB (Quantum State Tomography)
 - ネットワーク性能のFidelity予測手法
 - 回路シーケンス群**をリンク間に配置し実行、複数回の**バウンス**を通じてfidelity推測
 - NN応用: 予測値を用いた経路探索研究
 - MAB契合: 動的経路選択への応用 (LINKSELFIE)
- 既存研究の課題
 - QSTとQNBの問題
 - 量子リソース**消費**が不可避
 - 測定後の状態破壊、予測精度の限界
 - Fidelity予測のためのリソースと量子通信に必要なリソースの**競合可能性**


3. 提案手法

- アプローチ
 - QNNベースの数式活用**により、量子リソース消費を削減しながらFidelity予測可能な構造を提案
 - 意思決定**メカニズム: Distillation実行可否の自動判断
- 入力層: 量子ネットワークパラメータ
 - ネットワークトポロジー情報
 - 距離情報、環境パラメータ (温度、振動等)
 - チャネル透過率、ノイズレベル、エンタングルメント品質

- 隠れ層: 量子状態処理 + Lindblad動力学モデリング
 - 量子状態の特徴抽出・パターン認識
 - Lindblad マスター方程式による物理的動力学反映
 - $\frac{d\rho}{dt} = -\frac{i}{\hbar}[H, \rho] + \sum_i \gamma_i (L_i \rho L_i^\dagger - \frac{1}{2}\{L_i^\dagger L_i, \rho\})$
 - Decoherence、ノイズ効果の現実的モデリング
- 出力層: Fidelity予測値→Distillation意思決定
 - 予測Fidelityの算出
 - 設定閾値との比較判定
 - Distillation実行・非実行の自動決定

4. 詳細 (DQNNおよびDistillation)

- DQNN (Dissipative Quantum Neural Network)
 - 目的: 量子状態間の関係を学習し、量子情報処理タスクを実行
 - 原理: **量子版ニューラルネットワーク**
 - 各層間でユニタリ変換を通じて情報を伝播
 - 訓練過程でFidelityを損失関数として使用し最適化



- 量子状態蒸留 (Quantum State Distillation)
 - 目的: ノイズのある複数の量子状態から高品質な量子状態を生成
 - 原理: EPRペア2組を使用した確率的プロセス
 - 2組間の測定を繰り返し、測定結果を比較
 - Fidelityを段階的に改善**

5. 今後の予定

- シミュレーターの試し
 - Netsquid環境での様々なネットワーク構成における性能評価およびノイズモデルの影響分析
- GCNを利用した量子ネットワーク適応性研究
 - 動的ネットワーク構成への対応
 - グラフ畳み込みネットワークによる複雑なトポロジー最適化