

1. はじめに

機械学習モデルの大規模化に伴い、計算資源や学習時間が増大し、計算コストの増加が問題となっている。解決策として、量子コンピュータを利用した量子機械学習が注目されている。量子機械学習の代表的な手法である HQNN-Quanv[1] は、量子畳み込み層を構成する量子回路のパラメータを学習で最適化し、タスクに適した特徴抽出が可能である。しかし、単一の量子畳み込み層では、使用可能な量子ビット数や量子回路の深さに制約があり、局所的・大域的な特徴を同時に抽出することが困難である。そこで本研究では、局所的・大域的な特徴を同時に抽出するために、量子・古典双方の特徴を活用した MS-HQNN を提案する。

2. HQNN-Quanv

HQNN-Quanv は、量子回路にパラメータ化量子回路 (Parameterized Quantum Circuits; PQC) を導入した手法である。HQNN-Quanv の構造を図 1 に示す。本手法は、量子ゲートのパラメータを学習により最適化することで、タスクに適した特徴の抽出が可能である。まず、入力データを量子状態にエンコードし、量子畳み込み層で特徴抽出を行う。その後、量子ビットの状態を測定し、全結合層で分類を行う。HQNN-Quanv は、使用可能な量子ビット数や量子回路の深さに制約があるため、局所的・大域的な特徴を同時に抽出することが困難である。




図 1: HQNN-Quanv の構造

3. 提案手法

本研究では、HQNN-Quanv における課題を解決する Multi Scale-HQNN (MS-HQNN) を提案する。MS-HQNN は、タスクに適した特徴抽出を行うため、PQC を導入した量子畳み込み層と古典畳み込み層を並列に組み合わせた手法である。MS-HQNN の構造を図 2 に示す。量子畳み込み層の高次元な特徴と古典畳み込み層の線形な特徴を結合することにより、表現力を向上させる。さらに、マルチストライド構造を導入することで、異なるスケールで抽出した特徴を結合する。これにより、局所的な特徴と大域的な特徴を同時に抽出できる。学習においては、損失関数から得られる勾配を古典畳み込み層と量子畳み込み層へ逆伝播させ、両層のパラメータを最適化する。




図 2: MS-HQNN の構造

4. 評価実験

提案手法の有効性を検証するため、複数のデータセットでの既存手法との分類精度比較および推論時に各層・カーネルの出力を全て 0 に置換するマスク実験により、各層・カーネルの寄与度分析を行う。

4.1. 実験概要

本実験では、提案手法、CNN、HQNN-Quanv、提案手法の畳み込み層を量子層または古典層に置換し、マルチストライド構造を維持した場合 (Quantum Only, Classical Only) の分類精度を比較する。ここで、分類精度の比較のみでは、量子層および古典層が相補的な役割を果たし

ているかを十分に確認できない。そこで、各構成要素の貢献度を明らかにするため、推論時に各層および各カーネルの出力を 0 に置換するマスク実験を行う。エポック数は 50、バッチサイズは 100、最適化手法は Adam、損失関数は Cross Entropy Loss を用いる。データセットについては、分類精度の比較実験では MNIST, Fashion-MNIST および CIFAR-10、マスク実験では CIFAR-10 を用いる。

4.2. 実験結果

実験結果を表 1 に示す。MNIST では、Classical Only および提案手法が 99.02% の最高精度を達成した。CNN の精度は 98.85% であり、CNN より 0.17 ポイント向上している。Fashion-MNIST では、Classical Only が 91.22% の最高精度を達成し、提案手法は 90.53% であった。MNIST より複雑な分類タスクである CIFAR-10 で、提案手法は 67.77% の分類精度を達成し、他手法を上回る精度となった。以上より、提案手法の有効性を確認した。

表 1: 各手法における分類精度

Model	Test acc [%]		
	MNIST	Fashion MNIST	CIFAR-10
CNN	98.85	88.72	65.10
HQNN-Quanv	86.49	81.07	32.53
Quantum Only	98.93	88.92	65.67
Classical Only	99.02	91.22	66.23
MS-HQNN	99.02	90.53	67.77

次に、層単位のマスク実験結果を図 3 に示す。q1, c1 はストライド 1, q2, c2 はストライド 2 における量子および古典層を表す。量子層をマスクした場合、古典層よりも精度低下が大きく、量子層の寄与が大きいことが確認された。また、ストライド 1 の層をそれぞれマスクした際に精度低下が顕著であり、詳細な特徴抽出の重要性が示唆された。

最後に、カーネル単位のマスク実験結果を図 4 に示す。括弧内の数字 0~3 はカーネル番号を表す。ストライド 1 では、単一カーネルのマスクによる精度低下の幅が大きく、代替困難な特徴を抽出していると考えられる。一方、ストライド 2 では精度低下が小さく、特徴が複数カーネルに分散して寄与していると考えられる。




図 3: 畳み込み層単位のマスク実験結果




図 4: カーネル単位のマスク実験結果

5. おわりに

本稿では、量子・古典特徴の階層的融合によるマルチスケール画像分類として、MS-HQNN を提案した。比較実験の結果、提案手法は、複雑な特徴を持つ CIFAR-10 において全ての比較手法を上回る精度を達成した。今後は、量子層と古典層の配置・組み合わせの変更による分類精度向上や特徴抽出差異の分析を行う。

参考文献

- [1] Senokosov, et al. Quantum machine learning for image classification. *Machine Learning: Science and Technology*, 5(1):015040, March 2024.