

量子敵対的生成ネットワークによる画像生成および量子画像処理アプリケーションの開発

—量子機械学習による効率的な画像エンコーディング—

1. 背景

エッジ検出とは、画像の色の鋭敏な変化を検出することによって画像内の物体を検出する技術である。画像内の物体の形を鮮明にすることができるため、医療現場など既にさまざまなことに応用がされている。量子画像処理の分野においても量子エッジ検出のアルゴリズムは提案されている。このアルゴリズムは他の量子アルゴリズムと同様に古典のアルゴリズムと比べて量子加速がみられる。しかし、そのアルゴリズム自体には量子加速がみられるが、画像を量子状態として用意しなければならない。量子画像エッジ検出アルゴリズムに則したエンコード方法を使用すると、任意の画像を表現する量子状態を用意するためには任意の量子状態を用意しなければならない。任意の量子状態を用意するには指数個のゲート数が必要[ニールセンチャン]になるため、ここが量子エッジ検出のボトルネックとなってしまう。

2. 目的

量子敵対的生成ネットワークを利用することによって多項式個のゲート数で画像を表現する量子状態を生成し、量子エッジ検出アルゴリズムをはじめとした量子画像処理のボトルネックを解消することで、量子優位性を保持した一連の量子画像処理アプリケーションの開発。

3. ソフトウェア開発内容

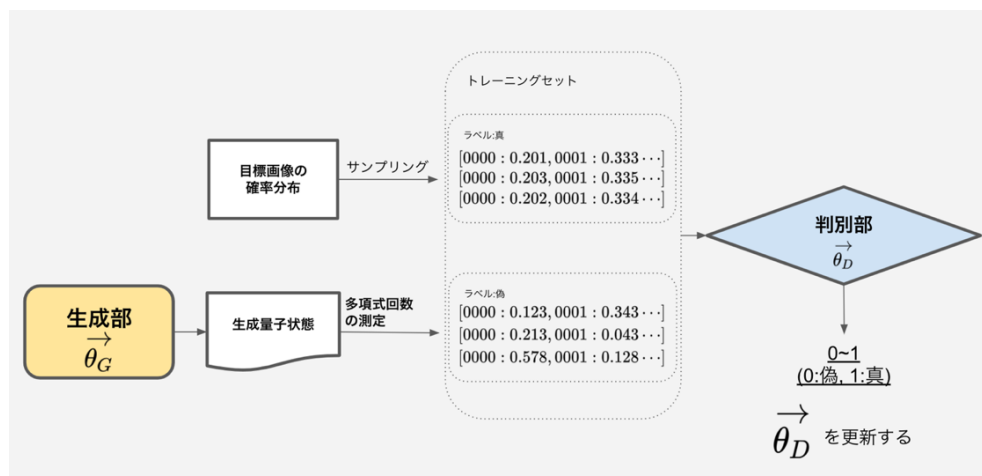


図 1 判別部の学習フロー

はじめに、開発した量子敵対的生成ネットワークについて説明していく。まず、判別部の学習について説明する。真のトレーニングセットとして目標画像の確率分

$$L_D(\vec{\theta}_D, \vec{\theta}_G) = \log D_{\vec{\theta}_D}(r) + \log(1 - D_{\vec{\theta}_D}(g))$$

布をサンプリングしたもの、これはつまり、目標画像を完全に表現した量子状態を測定したときに出力される結果のことである。これは実装では、目標である量子状態を量子コンピュータのシミュレーター上に状態ベクトルとして直接入力し、それを測定するシミュレーションを行うことによって真のトレーニングセットを生成している。これらに真のラベルを与える。偽のトレーニングセットとしては、 $\vec{\theta}_G$ より生成部から生成される量子状態を多項式回数測定し、その各計算基底の測定回数を全体の測定回数で割って正規化したものとしている。 $\vec{\theta}_G$ は初期値は乱数より生成される。トレーニングセットは真も偽もどちらも画像のピクセル数と同じ大きさのベクトルである。これらが判別部の入力となる。判別部はピクセル数と同じ大きさのベクトルを入力とし、0~1の値を出力する。出力値が0に近ければ偽を意味し、1に近ければ真を意味する。そして、真のラベルのベクトルが入力されたときは真、偽のラベルのベクトルが入力されたときは偽と判別されるように $\vec{\theta}_D$ を更新していく。 $\vec{\theta}_D$ を更新しているときは、 $\vec{\theta}_G$ の値は固定する。

$D(x)$ を x を判別部に入力したときの出力、 r を学習データ、 g を生成データとしたとき、判別部のコスト関数 L_D は
で表される。これを最大化するように $\vec{\theta}_D$ を更新していく。

パラメータの更新則は、 $\vec{\theta}_D^k$ 、 $\vec{\theta}_G^k$ をkステップ目の $\vec{\theta}_D$ 、 $\vec{\theta}_G$ 、 χ を学習率とすると、

$$\vec{\theta}_D^{k+1} = \vec{\theta}_D^k + \chi_D \nabla_{\vec{\theta}_D} L_D(\vec{\theta}_D^k, \vec{\theta}_G^k)$$

で表される。

最適化アルゴリズムとしては、勾配を使って最適化を行う、ADAM法を使用した。

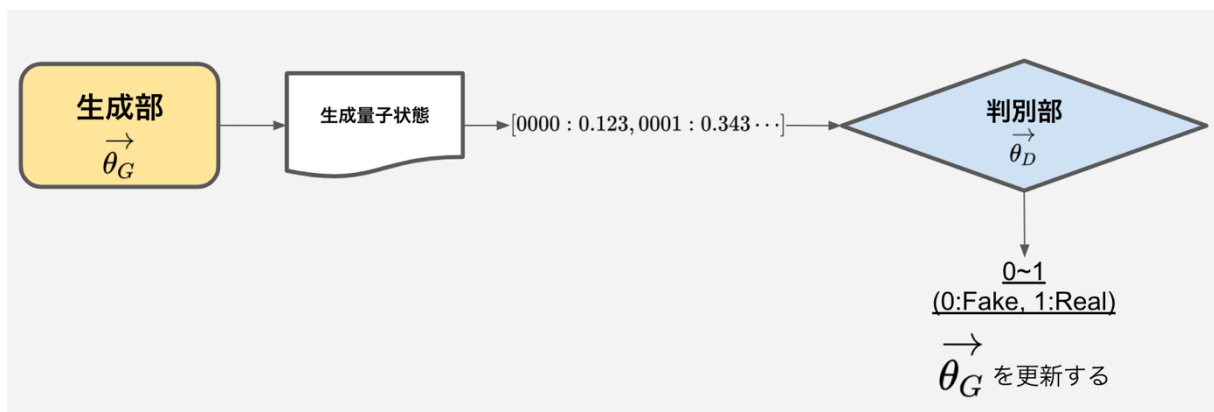


図 2 生成部の学習フロー

次に生成部の学習について。判別部の学習と同じように $\vec{\theta}_G$ から生成された生成量子状態を測定して正規化したベクトルを判別部の入力として、判別部が0~1を出力する。この出力から、生成部が生成したものが真と判定されるように、 $\vec{\theta}_G$ を更新し

ていく。 $\vec{\theta}_G$ を更新しているときは、 $\vec{\theta}_D$ は固定する。

生成部のコスト関数 L_G は、

$$L_G(\vec{\theta}_D, \vec{\theta}_G) = \log(D_{\vec{\theta}_D}(g))$$

で表される。これを最大化するように $\vec{\theta}_G$ を更新していく。パラメータの更新則は、

$$\vec{\theta}_G^{k+1} = \vec{\theta}_G^k + \chi_G \nabla_{\vec{\theta}_G} L_G(\vec{\theta}_D^k, \vec{\theta}_G^k)$$

で表される。

最適化アルゴリズムとしては、こちらはさまざまなものを試したので一つには絞ることはできないが、後述する成功例に使用した最適化アルゴリズムは、Powell 法である。実験において試した最適化アルゴリズムはこの他に、勾配を使用する BFGS, Adam, CG。勾配を使用しない Powell、Cobyla、Nelder-Mead, NFT を使って実験を行なった。

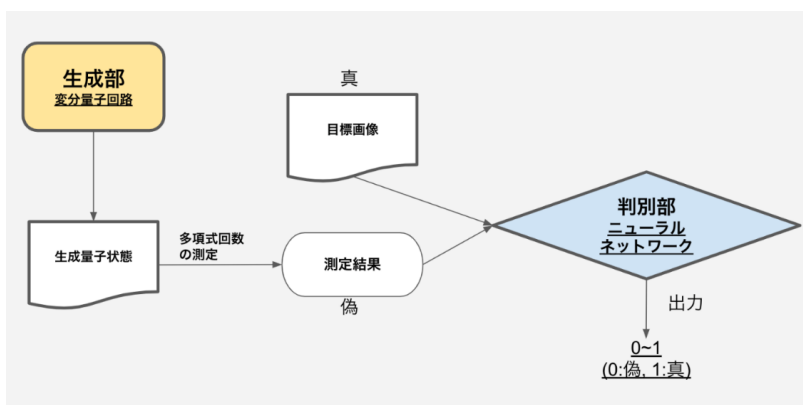


図 3 量子敵対的生成ネットワークの全体像

これが今回構築した量子敵対的生成ネットワークの全体像である。学習としては、 $\vec{\theta}_D$ と $\vec{\theta}_G$ の更新を細かく交互に行う。そして学習を終えると最終的な $\vec{\theta}_G$ が得られ、そこから目標画像を表現する量子状態を生成できる。

4. 新規性・優位性

エッジ検出アルゴリズムの性能比較
(nピクセルの画像のとき)

アルゴリズム	ビット数	計算量
Sobel(古典)	$8 * n \text{ bits}$	$O(n)$
Canny(古典)	$8 * n \text{ bits}$	$O(n)$
量子[Yao et al. 2018]	$\log_2 2n + 1 \text{ qubits}$	$O(1)$

図 4 エッジ検出アルゴリズムの古典と量子の性能比較

量子画像処理は古典のアルゴリズムに対して優位性を持っているものがある。代表的なものが量子エッジ検出アルゴリズムである。上図より、量子エッジ検出アルゴリズムは、ビット数および計算量どちらにおいても古典に優位性を持っている。計算量に至っては量子アルゴリズムは定数であるので、どんなに画像が大きくなっても計算量は変わらないので、大きな可能性を持っていることがわかる。

本開発物である量子敵対的生成ネットワークは、量子画像処理において必ずボトルネックになる画像を量子状態にエンコードするプロセスを解決するものである。従来の方法では指数個のゲート数が必要なのに対し、この方法を使えば多項式個のゲート数に大幅に削減することができる。この方法によって、量子画像処理の量子優位性を担保することができる。

さらには本プロジェクトの量子敵対的生成ネットワークは量子画像処理の枠組みに留まらぬ可能性を秘めている。量子コンピュータ上で何らかのデータを処理したい場合必ず量子状態に変換することになるが、確率振幅上にエンコードすれば量子ビットがデータ量に対して対数個で済むが、ゲート数は指数個になってしまう。が、本プロジェクト成果物を応用すれば別のデータもエンコードすることができるので、どんなデータでも多項式個のゲート数で量子状態にエンコードすることができる。

5. 期待されるユーザー価値と社会へのインパクト

量子エッジ検出をはじめたとした量子画像処理が実際に古典よりも優位性を保ったまま実現すれば、量子エッジ検出においてはピクセル数がどんなに増加しても計算量が変わらないので、莫大にサイズが大きな画像の処理でも高速で行うことができる可能性がある。また、量子機械学習とのコンビネーションによって古典では扱うことのできなかつた特徴見出すことができるなど、大きな可能性を秘めている。

6. 氏名（所属）

種谷 望(慶應義塾大学環境情報学部)