

1. はじめに

継続学習は、過去に学習した知識を維持しつつ、増加する新しいタスクの知識を学習する必要がある。従来手法として、生成モデルを用いた生成リプレイによる継続学習がある [1]。この手法では、生成モデルで過去のデータを生成し、生成データと実データを用いて分類器を学習する。これにより、過去の知識の忘却を抑制している。この生成リプレイによる継続学習では、過去のデータを再生するだけでなく、多様なデータを生成する必要がある。そこで本研究では、テキスト指示による画像スタイル変換を導入した生成リプレイによる自己教師あり継続学習法を提案し、その有効性を評価する。

2. 継続学習

継続学習は、時間の流れと共に増加するデータやタスクを学習する際に、過去の知識に対する破滅的忘却を抑制する必要がある。破滅的忘却とは、新しいデータ分布への適応によって古いデータ分布を捉える能力が低下する問題である。

2.1. Deep Diffusion-based Generative Replay

Deep Diffusion-based Generative Replay (DDGR) は、Diffusion model を用いて過去のデータを生成し、生成データと実データを用いて分類器を学習する生成リプレイによる継続学習である。DDGR では、分類器の出力と生成モデルの出力に基づく相互のフィードバックを通じ、生成データの品質低下を軽減する。しかし、生成モデルが生成するデータは、学習する過去のデータに依存する。

2.2. Lifelong Unsupervised Mixup

Lifelong Unsupervised Mixup (LUMP) [2] は、新しいデータとリプレイバッファに保存した過去のデータを mixup で合成して学習に用いる経験リプレイによる自己教師あり継続学習である。LUMP は、自己教師あり学習法を導入しているため、ラベルなしデータで学習でき、教師あり学習よりも優れた汎化性能を持つ。しかし、限られた容量のリプレイバッファ内のデータを再生するため、学習できる知識が限定的である。

3. 提案手法

本研究では、テキスト指示による画像スタイル変換を導入した生成リプレイによる自己教師あり継続学習法を提案する。提案手法は、生成リプレイによる継続学習法と経験リプレイによる自己教師あり継続学習法を組み合わせ、従来手法の問題点を解決する。提案手法のアーキテクチャを図 1 に示す。提案手法では、過去のタスクで学習したデータの潜在変数を、一定数だけリプレイバッファに保存する。保存した潜在変数を生成モデルに入力することで、過去のデータを生成し、学習に使用する。また、生成モデルに油絵風やピクセルアート風等のスタイルを指定するテキストを入力することで、同一の潜在変数から多様な画像を生成する。

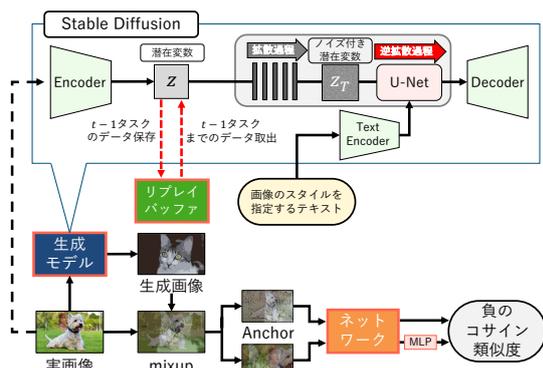


図 1：提案手法のアーキテクチャ

4. 評価実験

LUMP との比較により、提案手法の有効性を評価する。実験条件として、ネットワークは ResNet18、自己教師あり学習法は SimSiam、生成モデルは事前学習済み Stable Diffusion を用いる。データセットは、CIFAR-10 (5 タスク、各タスク 2 クラス)、CIFAR-100 (20 タスク、各タスク 5 クラス) を用いる。エポック数は 200、バッチサイズは 256、生成するデータ数は 1 クラスにつき 20 に設定する。評価方法は、k 近傍法を用いる。評価指標は、平均精度と平均忘却率を用いる。平均精度は全タスクにおけるモデルの平均的な分類精度、平均忘却率は過去のタスクの精度低下を表す。

4.1. 定量的評価

提案手法の評価結果を表 1 に示す。表 1 より、提案手法は LUMP と同等の精度であるが、忘却率が高くなっている。これは、再生する過去のデータ数が少量であり、現在のタスクを優先する学習になっているためだと考える。解決策として、生成するデータ数を増やすことが考えられる。しかし、少量の潜在変数からデータを生成するため、生成データは似たパターンが多数生成されてしまう。そのため、生成データは、実データの分布を逸脱しない範囲で変化を与え、過去の知識を大量に再生する必要があると考える。

表 1：CIFAR-10, CIFAR-100 における評価結果

提案手法	CIFAR-10		CIFAR-100	
	精度 [%](↑)	忘却率 [pt](↓)	精度 [%](↑)	忘却率 [pt](↓)
LUMP	88.64	2.28	77.98	3.92
提案手法	90.17	4.78	77.46	9.45

4.2. 定性的評価

提案手法による生成画像を図 2 に示す。図 2 より、りんごや椅子のクラスの場合、特徴を捉えた画像が生成されている一方で、蜂や牛のクラスの場合、特徴を捉えきれない画像も生成されている。これは、生成モデルが背景と対象の区別をしないためだと考える。また、トカゲや缶のクラスの場合、テキストによる影響を大きく受けた画像が生成されている。テキストは、生成モデルに多様な画像を生成させる点において有効であるが、場合によっては元の画像の特徴を失う原因にもなる。そのため、生成画像が元の画像の特徴を保ちつつ、テキストによる影響を適切に導入する方法を模索する必要があると考える。



図 2：提案手法による生成画像

5. おわりに

本研究では、テキスト指示による画像スタイル変換を導入した生成リプレイによる自己教師あり継続学習法を提案した。評価実験では、従来手法と提案手法は同等の精度であることを確認した。今後は、実データの分布内で変化を与えたデータを生成し、過去のデータを大量に再生することで、忘却率の改善を図る予定である。

参考文献

[1] G. Rui, L. Weiwei, “DDGR: Continual Learning with Deep Diffusion-based Generative Replay”, ICML, 2023.
 [2] D. Madaan, *et al.*, “Representational Continuity for Unsupervised Continual Learning”, ICLR, 2022.