

論文 / 著書情報
Article / Book Information

題目(和文)	
Title(English)	Balancing Old and New Classes for Class-Incremental Learning Methods
著者(和文)	JODELETQUENTIN MAGIC
Author(English)	Quentin Magic Jodelet
出典(和文)	学位:博士(学術), 学位授与機関:東京科学大学, 報告番号:甲第32号, 授与年月日:2024年12月31日, 学位の種別:課程博士, 審査員:村田 剛志,岡崎 直観,篠田 浩一,横田 理央,金崎 朝子
Citation(English)	Degree:Doctor (Academic), Conferring organization: Institute of Science Tokyo, Report number:甲第32号, Conferred date:2024/12/31, Degree Type:Course doctor, Examiner:,,,,,
学位種別(和文)	博士論文
Category(English)	Doctoral Thesis
種別(和文)	審査の要旨
Type(English)	Exam Summary

(博士課程)

論文審査の要旨及び審査員

報告番号	甲第		号	学位申請者氏名		Jodelet Quentin Magic	
論文審査 審査員		氏 名		職 名		氏 名	職 名
	主査	村田 剛志		教授		金崎 朝子	准教授
	審査員	岡崎 直観		教授	審査員		
		篠田 浩一		教授			
		横田 理央		教授			

論文審査の要旨（2000 字程度）

本論文は“Balancing Old and New Classes for Class-Incremental Learning Methods”と題し、英文7章とAppendixからなっている。 第1章「Introduction」では、深層学習において、新しいデータやタスクが追加されることによって、以前に学習したものが忘れ去られて性能が極端に悪化する破滅的忘却と呼ばれる現象があることを指摘している。継続学習はそれを軽減しかつ新たなものも学習するための手法である。本論文は画像分類のタスクを対象とした深層学習におけるクラス継続学習を扱うと述べ、さらに本論文の貢献や構成、出版論文リストについて述べている。 第2章「Incremental Learning and State-of-the-Art Methods」では、継続学習の説明や関連研究、最新の手法について述べている。単一の段階で全訓練データにアクセス可能な状態で学習するのは異なり、継続学習においては複数の段階で異なる訓練データを用いて学習する。学習器の安定性と可塑性のバランスについての議論や、クラス継続学習に類似したタスク継続学習やドメイン継続学習との差異を述べた上で、クラス継続学習の定義や訓練の設定、評価指標、計算コスト等について述べている。さらにクラス継続学習の主要なアプローチとして、過去のクラスの訓練データの一部を保持するリハーサルメモリ、蒸留、重み正規化、動的ネットワーク、バイアス修正などを紹介している。さらにリハーサルメモリを用いない exemplar-free クラス継続学習とその手法であるファインチューンベースの手法や固定表現ベースの手法について述べている。 第3章「Balanced Softmax for Class-Incremental Learning With and Without Memory」では、Balanced Softmax を用いるクラス継続学習の手法について述べている。クラス継続学習においては、訓練データが段階的に与えられるが、過去のクラスの訓練データの一部を保持して以後の訓練に用いるやり方ではデータ量が新しいクラスのものに偏り、性能が悪化する。この対策として、段階的な訓練の後にバランスの取れた小さいデータ集合によるファインチューンを行う balanced finetuning がよく用いられる。その訓練における損失関数として、通常の Softmax 関数ではなく、過去のクラスの重要度をコントロールする重みを導入した Balanced Cross-Entropy loss 関数を新たな手法として述べている。この手法は、最新のクラス継続学習の手法である LUCIR や PODNet 等と組み合わせることによってさらに性能を向上させることができ、訓練時における計算量を減らすことができることを実験によって示している。この手法を拡張した、メモリなしのクラス継続学習のための Relaxed Balanced Softmax Cross-Entropy についても、性能が向上して安定性と可塑性のバランスが取れていることを示している。 第4章「Memory Augmented using Diffusion Model for Class-Incremental Learning」では、訓練データの一部をメモリに保持する代わりに、訓練済みの拡散モデルを用いたクラス継続学習について述べている。破滅的忘却を軽減する手法としてリハーサルメモリがあるが、メモリのサイズが制約となる。この制約を回避する方法として、ImageNet などの外部の訓練データを用いる手法が近年提案されている。本章では Stable Diffusion 等の訓練済み拡散モデルが生成する人工画像を訓練データとして用いる手法 MADM を提案している。最新のクラス継続学習の手法である LUCIR や FOSTER 等と組み合わせることによって大幅に精度が向上することを示している。 第5章「Future-Proofing Class-Incremental Learning」では、未来予測クラス継続学習について述べている。クラス継続学習においてはリハーサルメモリがよく用いられるが、訓練データのプライバシー等の理由で適用できない場合がある。リハーサルメモリを用いない exemplar-free クラス継続学習では、特徴抽出器を訓練する初期段階でアクセス可能なクラス数が非常に限られている場合は性能が悪化してしまう。その解決策として、対象とするデータではないがそれに類似した外部データを用いる手法が提案されている。変化する実世界の全ての可能な訓練データを集めるのは
--

不可能であり、起こりそうな特定の対象を予測して事前学習し、その上でクラス継続学習を行うのが現実的であると考えられるためである。本章では拡散モデルによって対象とするデータに類似した画像を生成し、それを用いて特徴抽出器を事前学習する手法 FPCIL について述べている。従来手法は以前の学習で現れた過去のクラスのデータを拡散モデルで生成しているのに対し、FPCIL はこれから学習する未来のクラスのデータを生成して事前学習を行い、高い性能を示している。

第 6 章「Discussion」では、第 3 章から第 5 章までで述べた手法の関係について述べ、さらに各手法の限界について述べている。

第 7 章「Conclusion」では、本論文の主要な貢献についてまとめた上で、今後の研究の方向性について述べている。

Appendix では、4 章で提案した MADM に関する追加実験について述べている。

以上で述べたように、本論文では、深層学習における問題点である破滅的忘却を軽減するためのクラス継続学習について、損失関数の改良、訓練済み拡散モデルの生成データの利用、未来のクラス予測による特徴抽出器の事前学習という 3 つのアプローチを提案し、実験によってその有効性を示している。本論文でのクラス継続学習の成果は、画像分類だけでなく、自然言語処理やグラフ学習などの幅広い分野に対しても応用が期待できるものであり、機械学習において学術上寄与するところが大きい。よって本論文は博士（学術）の学位論文として十分価値があるものと認める。

注意：「論文審査の要旨及び審査員」は、東工大リサーチリポジトリ(T2R2)にてインターネット公表されますので、公表可能な範囲の内容で作成してください。