

2021 年度森泰吉郎記念研究振興基金研究者育成費 成果報告書

選択的忘却を伴う統合管理型継続学習システムの構築

政策・メディア研究科修士課程 2 年 CI プログラム

川島 寛乃

はじめに

本成果報告書では本研究費を活用した 慶應義塾大学大学院政策・メディア研究科 2021 年度修士論文「クラス難易度を考慮した容量制御を伴うニューラルネットワークを用いた画像分類の継続学習」の内容を一部抜粋・編集し、報告致します。

※ソフトウェア学会論文誌への投稿および一部提案手法の特許申請のため、詳細図表・結果につきまして記述を控えさせていただきます。

研究概要

近年計算機技術が発達し、さらに大量のデータの蓄積が可能となったことでさまざまなタスクにニューラルネットワークが用いられており、特に画像分類においては数々のデータセットにおいて人間の認識精度を上回る結果を達成している。実用化も盛んに行われているが、その重要な課題として、実世界においてデータやタスクが変化した場合にモデルを柔軟に更新、適応させるための技術が確立されていないことが挙げられる。通常のニューラルネットワークは収集した一定のデータにおいて入出力関係の学習するため、データやタスク構造の変化に対応することを想定していない。しかし現実の運用では、画像分類において分類したいクラス数が増加する可能性がある [1][2]。

そこで、複数のステップに渡り与えられる異なるクラスの訓練データを用いて、過去のステップの学習で得た知識を統合しながら 1 つのモデルを段階的に学習する、継続学習の研究が注目されている [3]。最も基本的な継続学習の手法として、過去に得られた訓練データの一部をコアデータとしてストレージに保持し、それを新しく得られた訓練データと合わせて訓練に用いるリプレイ手法がある。過去のリプレイ手法では、訓練データの一部を選ぶ際に特徴量や勾配を用いた手法が用いられており、クラスごとに保持するデータの数は一定であった [4][5][6]。しかし、実際にはクラスごとにデータの分布や判別するための特徴の粒度は大きく異なるため、各クラス同じ数のデータを用いてモデルを学習した場合でも、クラスごとの精度には大きな差が生じる [7]。

そこで、本研究ではクラスごとにその難易度を算出し、難易度に応じて保持するコアデータのクラスごとの容量を定める継続学習手法 M-fluct を提案する。人間が難しい勉強の際により多くの例を参考にしたり問題を解いたりすると同様に、リプレイにおいても難易度の高いクラスのデータを優先的に多く保持することで、限られたメモリリソースを効率的に活用しモデルの精度の維持に貢献できる。クラス難易度は、クラスごとに得られる訓練データの特徴量の分散およびそのクラスごと差異をもとに算出し、データ数の設定時には温度パラメータに応じてその影響度を調整する。また M-fluct ではステップごとの学習で更新されるため値が安定しないモデルの出力を直接用いて画

像を分類するのではなく、途中に得られる特徴量をクラスタリングして分類をすることで、ステップごとの訓練データの変化により頑健な分類を実現する。

提案手法の性能を評価するため、実験では複数のベンチマークにおいて提案手法および比較手法において、各ステップやクラスの精度および訓練時間に基づいて性能を評価した。その結果、コアデータ量をクラスごとに制御し、かつコアデータとして保持する訓練データをランダムに選択した提案手法が最も高く精度を維持できることが明らかになった。

研究業績

Hirono Kawashima, Jin Nakazawa, Tadashi Ohkoshi, "Replay-based Continual Learning System with Data Capacity Control for Each Class", The 3rd Workshop on Intelligent IoT for Empowering The People's Lifestyle and Well-being, AI-driven Data Intelligence Session, 2021.

謝辞

本研究は、2021年度の森泰吉郎記念研究振興基金研究者育成費に採択いただきましたことにより、実装および実験に必要な機材を購入でき遂行することができました。この場を借りて深く御礼申し上げます。

参考文献

- [1] Lomonaco, Vincenzo, and Davide Maltoni. "Core50: a new dataset and benchmark for continuous object recognition." Conference on Robot Learning. PMLR, 2017.
- [2] He, Jiangpeng, and Fengqing Zhu. "Online continual learning for visual food classification." Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021.
- [3] Sebastian Thrun. Is learning the n-th thing any easier than learning the first? pages 640–646, 1996.
- [4] Sylvestre-Alvise Rebuffi, Alexander Kolesnikov, Georg Sperl, and Christoph H Lampert. icarl: Incremental classifier and representation learning. In Proceedings of the IEEE conference on Computer Vision and Pattern Recognition, pages 2001–2010, 2017.
- [5] David Lopez-Paz and Marc'Aurelio Ranzato. Gradient episodic memory for continual learning. Advances in neural information processing systems, 30:6467–6476, 2017.
- [6] meya Prabhu, Philip HS Torr, and Puneet K Dokania. Gdumb: A simple approach that questions our progress in continual learning. In European conference on computer vision, pages 524–540. Springer, 2020.
- [7] Sinha Saptarshi, Hiroki Ohashi, and Katsuyuki Nakamura. "Class-Wise Difficulty-Balanced Loss for Solving Class-Imbalance." Proceedings of the Asian Conference on Computer Vision. 2020.