7C-03

Deep neural network を用いた時系列の予測学習における継続学習手法の検討

中條　亨一†　　尾形　哲也‡

早稲田大学基幹理工学研究科表現工学専攻†　　早稲田大学理工学術院‡

1. はじめに

Deep neural network (DNN)は事前に収集したデータを直接入力することで，ネットワーク自体が特徴量を獲得するよう学習するため，認識や翻訳，自動運転といった分野で高い性能を示している．ただし，一般に DNN は単一のデータセットの分布を学習することを仮定しており，複数のデータセットを継続的に学習する場合，過去に獲得した学習重みが新しいデータの情報に偏ってしまう破滅的忘却を避けられない．逐次学習すべきデータが与えられると想定される実環境において，それらのデータを DNN が継続的に学習できる能力が必要である．

DNN における継続学習手法として，Kirkpatrick らが提案した elastic weight consolidation (EWC) [1]が注目を集めている．EWC は学習済みの重みが過去のタスクに対する重要度としてフィッシャー情報量を利用し，新しい学習データを訓練する際に正則化項として重みの更新を制限するアルゴリズムである．

また，学習済みネットワークを転移する手法[2]や蒸留学習[3, 4]，リハーサルによる疑似データの生成[5, 6]によって過去のタスクに関わる情報を保存する手法が提案されている．これらの手法では，ネットワークが事前に獲得した特徴を継続学習に再利用することから，過去の学習データを再学習する場合と比較してより効率よく学習できることが示されている．

上記の継続学習手法では認識問題や強化学習による行動選択課題で成果を示すことが報告されている．一方，時系列の予測学習課題への適用例には乏しくいまだ議論が不十分であると考えられる．

そこで本研究は，EWC とリハーサル法を時系列の予測学習に適用し，学習結果を比較することを目的とする．ここでは，sketch-rnn の描画学習[7]に対して EWC およびリハーサルを適用し，学習後のネットワークの潜在空間を比較した．

2. Sketch-rnn による描画生成

Sketch-rnn [7]は人間が描画したスケッチを学習データとして，DNN による描画生成を実現している．学習器は encoder と decoder，2 つの recurrent neural network (RNN)からなる sequence-to-sequence モデルである．それぞれの RNN は各ステップにおける線の移動量，ペンの状態を時系列で与えられる．Sketch-rnn は入力されたスケッチの時系列を variational autoencoder として学習し，encoder からサンプリングされた潜在変数 $z \sim N(\mu, \sigma)$ に対する kullback-leibler divergence および decoder による再構成コストを最小化するよう重みを更新する．

3. 比較する継続学習手法

本研究では継続学習手法として EWC およびリハーサルを用いる．以下に各手法の概要を記す．

3.1 Elastic Weight Consolidation

EWC [1]では過去のタスクに関連する情報を基に学習重み θ を正則化する項を加えることで，過去の学習データを使用せず継続学習を行う．タスク A の学習により重み θ_A を得たのち，続けてタスク B を学習する場合の損失 $L(\theta)$ は，

$$L(\theta) = L_B(\theta) + \sum_i \frac{\lambda}{2} F_i(\theta_i - \theta_A)^2 \qquad (1)$$

Consolidation on predictive learning of time sequences by a deep neural network

† Ryoichi NAKAJO,
Department of Intermedia Art and Science, Waseda University
‡ Testuya OGATA,
Faculty of Science and Engineering, Waseda University

Copyright ©2020 Information Processing Society of Japan.
All Rights Reserved.

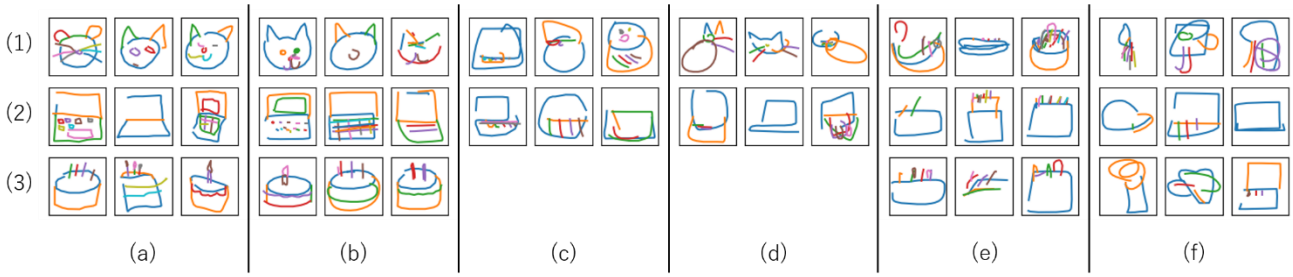

図 1: (1) cat, (2), laptop, (3) cake の描画．(a) 学習データ，(b) 3 種すべてを同時に学習後の描画，(c) EWC で(1, 2)を継続学習，(d) リハーサルで(1, 2)を継続学習，(e) EWC で(1-3)を継続学習，(f) リハーサルで(1-3)を継続学習．

と表される．ここで，λ は正則化項の強さ，F_i は過去のタスク A に関するフィッシャー情報量の対角成分を示す．

3.2 リハーサル

リハーサルは学習済みのネットワークが出力したデータを継続学習時の追加データと併せて学習する手法である [5]．過去のタスクに関する情報はネットワークの出力したデータに依存し，継続学習時の学習データの増加を抑えている．また，学習済みのネットワークは過去のタスクの特徴を捉えているため，実際の学習データを与える場合と比べ効率よく学習可能であることが示唆されている[5].

4. 実験

本研究では Quick, Draw! [8]から 3 種のスケッチデータ {cat, laptop, cake}を順番に継続学習する実験を行った．学習するスケッチデータ数はそれぞれ 70,000 とした．Sketch-rnn の encoder RNN のユニット数を 256，decoder RNN のユニット数を 512 とし，潜在変数 z を 128 次元に設定し，描画生成学習を実施した．また，継続学習時，EWC 正則化の強さは$\lambda = 1.0 \times 10^3$とし，リハーサルで出力するデータ数は 210,000 とした．

継続学習後，学習済みネットワークで描画生成を実施したところ，図 1 のようなスケッチを得た．リハーサル法による生成データは EWC と比較してスケッチの見た目を捉えているように推察される．一方で 3 種のスケッチを学習後，最初に学習した cat の生成コストは，EWC で 1.34±0.04，リハーサルで 2.38±0.05 と EWC のほうが低いことが確認された．さらに，潜在変数 $z \sim N(\mu, \sigma)$ についてパラメータμを線形判別分析により可視化する図を図 2 に示す．EWC・リハーサルともに類似した特徴空間となり，EWC がスケッチ間の特徴がやや近づくことが確認できた．

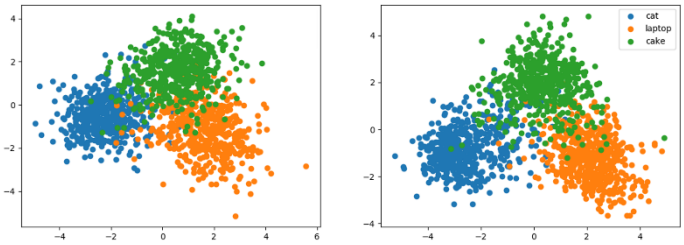

図 2: 潜在変数のパラメータμに対する線形判別分析．(左) EWC による学習結果，(右) リハーサルによる学習結果．

5. まとめ

本研究では，EWC およびリハーサルによる継続学習を時系列の予測学習課題に適用しその結果を比較した．時系列の予測学習として sketch-rnn の描画生成を挙げ，1 種ずつ継続学習を実施したところ，EWC は学習損失でリハーサルに勝る一方，両者とも類似した特徴を得ることが確認された．

参考文献

[1] J. Kirkpatric, et al., “Overcoming catastrophic forgetting in neural networks,“ in Proceedings of the National Academy of Science, 114, 3521-3526, 2017.
[2] A. A., Rusu, et al., “Progressive Neural Networks,” arXiv preprint arXiv:1610.04286, 2016.
[3] S. Hou, et al., “Lifelong Learning via Progressive Distillation and Retrospection,” in Proceedings of European Conference on Computer Vision, 1, 437-452, 2018.
[4] J. Schwarz, et al., “Progress & Compress: A scalable framework for continual learning,” in Proceedings of Machine Learning Research, 80, 4528-4537, 2018.
[5] A. Robins, “Catastrophic forgetting, rehearsal and pseudorehearsal,” Connection Science, 7, 123-146, 1995.
[6] C. Atkinson, et al., “Pseudo-Rehearsal: Achieving Deep Reinforcement Learning without Catastrophic Forgetting,” arXiv prepring arXiv:1812.02464, 2019.
[7] D. Ha and D. Eck, “A Neural Representation of Sketch Drawings,” 6th International Conference of Learning Representation, 2018.
[8] J. Jongejan, et al., “Quick, Draw! – A.I. Experiment,” https://quickdraw.withgoogle.com/, 2016.

Copyright ©2020 Information Processing Society of Japan.
All Rights Reserved.