

睡眠期間を導入したモデル選択付き追加学習

Incremental learning and model selection for radial basis function through sleep

佐藤正義*¹ 山内康一郎*¹
Masayoshi SATO Koichiro YAMAUCHI

*¹北海道大学 大学院情報科学研究科

Graduate School of Information Science and Technology, Hokkaido University

This paper presents a learning method that achieves incremental learning and model selection simultaneously. Particularly, this method works well even if the distribution of learning samples is not independently distributed samples, which is a common condition to make usual online learning methods work normally. The method repeats two learning phases alternately: Awake- and Sleep-phases. During awake-phase, the learner records new instances in rote, whereas the learner rehearsals the recorded samples and achieves model-selection during sleep-phase. We compared the proposed method with the other similar methods by using benchmark datasets. Moreover, we also applied our method to a virtual robot navigation.

1. はじめに

マシンラーニングにおける online 学習法は、学習サンプルを予めためておく必要が無いという点で扱いやすい手法であるが、一方で注意すべき条件がある。それは、学習データの分布が同一かつ独立 (i.i.d) でなければならないということである。しかし、この条件を現実の環境に求めることは難しく、たいいてい場合には、データが非独立に現れたり、はたまた途中で望ましい出力が変化したりもする。

本研究では、学習データが非独立に現れる状況を想定し、オンライン学習とモデル選択とを同時実行できる手法を提案する。非独立に現れるデータを、従来のオンライン学習法にそのまま適用すると、過去に学習した結果を忘却するという (catastrophic forgetting) が発生する。これを防ぐため、定期的リハーサル期間を設けた手法 (Incremental Learning through sleep: ILS) を提案する。この手法をベンチマークテストによって多種法と比較すると共に、ヴァーチャルロボットのナビゲーション課題 (時系列データの学習) にも適用を試みた。

2. 提案システム ILS

ILS は、それまでに得られた知識で認識を行いつつ新たに得られたデータを丸暗記学習を行う Awake Phase と、それまでの知識と新たに得られた知識を織り交ぜて不要ユニットを削除しながら再学習を行う Sleep Phase、そして Sleep Phase の後に、丸暗記した内容を消去する等の処理を行う Post Sleep Phase をこの順序で繰り返すことによって時系列パターンを追加的に学習する (図 1 参照)。以下に、それぞれの学習 Phase を詳述する。

2.1 Awake Phase

Awake Phase では、その前の Sleep Phase までの知識を保持している Main Net (M-Net) と、新たに得られるデータを丸暗記学習する Fast Net (F-Net) によって行われる。M-Net はパラメータ固定の RBF で構成し、F-Net は Generalized Regression Neural Network (MGRNN) [3] で構成する。入力

は M-Net と F-Net の両方に同時に与えられ、ネットワーク全体の最終出力は二つのネットワークの出力の重み付き和によって計算される。この最終出力と教師信号の誤差がある一定の閾値を超えると、与えられた入力データは未知であるとみなし、F-Net に入力データに対応する新しい中間細胞を割り付けることによって丸暗記学習を行う。Awake Phase では、一定個数の入力を学習すると終了し、次の Sleep Phase へと進む。

2.2 Sleep Phase

Sleep Phase では、それまで保持していた M-Net の過去の記憶と、Awake-Phase で得られた F-Net の新しい記憶から、新しい知識を再構築することを目的とする。再構築された知識は最終的には M-Net の結合強度として保存される。これを実現するために、別途 Slow learning Net (S-Net) を用意し、M-Net と F-Net の両方から擬似学習サンプルを想起、生成して学習させる。ただし、S-Net はその学習に先立って M-Net のパラメータ (結合荷重、中間細胞等) をコピーして初期化するものとする。S-Net は、M-Net が保持していた記憶と F-Net が保持していたデータを織り交ぜた擬似サンプルを学習することとなる。S-Net の学習では新たな中間細胞の追加と不要な中間細胞の削除を同時に行う MRAN [4] の学習アルゴリズムを使用するため、冗長な中間細胞を減らしつつ学習することができる。S-Net は M-Net と F-Net の中間細胞数に比例した数の擬似サンプルを学習する。Post Sleep Phase では、S-Net を M-Net と置き換え、次の Awake Phase へ進む。

3. 計算機実験

ILS の有効性を示すため、ILS と、従来型のモデル選択付きオンライン学習法である、EFuNN, RFWR, GRNN+editing, AOSVR との比較を行なった。図 2(a)(b) に各々の手法の提示サンプル数に対する平均二乗誤差とユニット数を示す。この結果より、ILS はユニット数では RFWR に劣るものの誤差は最も小さくなっていることが分かる。ただし、ユニット数ではなくパラメータ数で比較するならば ILS は最も少なくなる。

次に、ILS を virtual robot のナビゲーション課題に適用した [5]。このため時系列パターンを扱えるようにリカレント結合を設け、delay-line も付加した Recurrent ILS (ReILS) に拡張した (図 3)。比較のため ReILS と従来手法の 1 つである MRAN

連絡先: 佐藤正義, 北海道大学大学院情報科学研究科, 〒060-0814 札幌市北区北 14 条西 9 丁目, 001-706-6815, justice@complex.eng.hokudai.ac.jp




図 1: ILS の構造と学習




図 2: servo データセットを使ったベンチマークテスト
左: 平均二乗誤差 (a), 右: 平均ユニット数 (b)

とをそれぞれ実装したロボットを用いて、計算機シミュレーションにより、パフォーマンスを比較した。ロボットに求められる課題は、青、黄色、赤、紫の4種類の色の異なる障害物があるフィールド上を、障害物や壁に衝突することなくスタートからゴールまでたどり着くというものである。ロボットは各障害物の色を構成する「Red」「Green」「Blue」のそれぞれを感知する17個、合計51個の視覚センサーを持つ。ReILSおよびMRANは、これらセンサーからの51次元の入力から、1次元の方向舵制御信号を出力とする。ReILSとMRANには直前6ステップにおいて自ら出力した方向をdelay-lineに保持させ、入力にフィードバックさせた。ReILSを実装したロボットの図を図3に示す。学習タスクは、フィールドの右上から左下へ向かう経路Aを学習させた後、さらにもう一つ、フィールドの右下から左上へ向かう経路Bを追加学習させ、その後、両方の経路を再現できるかどうかを観察した(図4参照)。ReILSでは、経路Aと経路Bを提示する合間に睡眠期間を挿入した。二つの経路は途中で得られる視覚情報が同一となる部分があり、現時点での視覚情報だけではなく過去に辿った経路情報を用いなければ区別できないという時系列パターンとなっている。

実験の結果、ReILSを実装したロボットはどちらの経路も再現することができたが、MRANを実装したロボットは時系列パターンを正しく追加学習できず、途中で壁に衝突し、学習させた経路を正しく再現することができなかった(図5)。

4. まとめ

本研究では、睡眠期間を導入した追加学習法であるILSと、それを時系列パターン学習用に拡張したReILSとを提案した。




図 3: ReILSを実装したロボット




図 4: 学習させる経路




図 5: 学習後のロボットの挙動 左: ReILS, 右: MRAN (点線はロボットの軌跡)

計算機シミュレーションの結果、ILSはより少ないメモリソースで学習サンプルを追加的に正しく学習できることが確認できた。

参考文献

- [1] S. Kremer, "ISpatio-temporal Connectionist Network: A Taxonomy and Review" *Neural Computation*, vol. 13, 249-306, (2001)
- [2] K. Yamauchi and J. Hayami, "Incremental Learning and Model Selection for Radial Basis Function Network through Sleep" *IEICE TRANSACTIONS on Information and Systems*, Vol. E90-D, No.4, 722-735, (2007)
- [3] D. Tomandl and A. Schober, "A Modified Generalized Regression Neural Network (MGRNN) with a new efficient training algorithm as a robust 'black-box-tool' for data analysis" *Neural Networks* Vol. 14, 1023-1034, (2001)
- [4] "L. Yingwei et al: A Sequential Learning Scheme for Function approximation Using Minimal Radial Basis Function Neural Networks, *Neural Computation*, Vol 9, 461-478, (1997)
- [5] Koichiro Yamauchi and Masayoshi Sato, "Incremental Learning of Spatio-temporal Patterns with Model Selection" *ICANN2007 International Conference on Artificial Neural Networks*, LNCS4668, 149-158, (2007)