

H-026

メタ学習による追加学習の高速化 Meta-Learning for Fast Incremental Learning

大平 岳将[†]
Takayuki Ohira

山内 康一郎[†]
Koichi Yamauchi

大森 隆司[†]
Takashi Omori

1. まえがき

ニューラルネットワークに対し、最急降下法のような従来の学習法を用いて新規の学習サンプルを学習した場合、過去に学習したサンプルを忘却してしまうという現象が起こる。この現象を少ない計算量で防ぐために、学習モジュールに過去に学習したサンプルをいくつか保持するバッファを追加する手法が提案されている [1]。この手法では、新規入力はまだバッファに格納され、学習機械はバッファ内の全データを off-line 学習する。バッファ容量を超えるサンプルが提示されたときは、バッファ内のサンプルのうち最も誤差の小さいサンプルを削除する。しかし、この手法ではバッファ内のサンプルを再学習するための計算時間が必要となる。

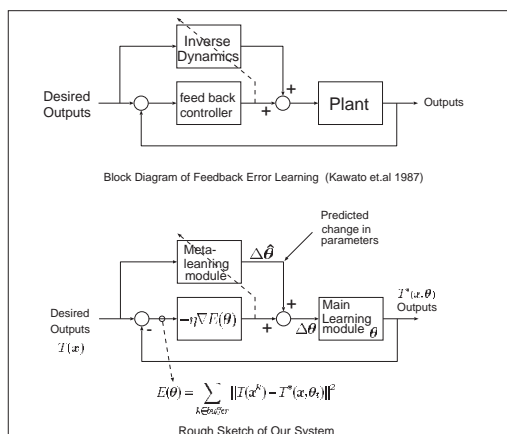


図 1: 提案システムと逆モデルとの比較

これに対し、本研究では、川人ら [2](図 1 上) が提案した、随意運動の学習と制御のモデルを元に、学習機械の計算時間を削減するための学習システムを提案する。川人らのモデルでは、本来ならばフィードバック制御で多数回の反復計算によって最適な制御を行うところを、フィードバック制御機の最終的な解を近似する逆モデルを用いることで、反復計算回数の削減を実現している。

我々が提案するシステムは、main-learning モジュールと meta-learning モジュールの 2 つのモジュールから構成される。main-learning モジュールは出力関数の近似を行い、meta-learning モジュールは main-learning モジュールが持つパラメータの適切な変化量の予測を行う。main-、meta-learning モジュールは、それぞれ川人らのモデルの制御対象と逆モデルに対応し (図 1 下)、main-learning モジュールが誤差逆伝播法によるフィードバック型の学習を行う一方、meta-learning モジュールはメタ情報から main-learning モジュールの最適パラメータ

変化量を予測するフィードフォワード型の学習を行う。2 章では提案システムの構造について説明し、3 章では提案システムの計算機実験の結果について述べる。

2. システム構造




図 2: 提案システムの構造 (詳細は本文参照)

本システムは、過去の入力サンプルを格納するバッファ、main-learning モジュール、meta-learning モジュールで構成される (図 2)。2 つの学習モジュールには、中間細胞を適応的に追加する Resource Allocating Network(RAN)[3] を用いている。RAN は radial basis function(RBF) の一種であり、その出力は式 1 で表される。

$$T^*(x) = \sum_{\alpha} h_{\alpha} \exp\left(-\frac{1}{\sigma_{\alpha}^2} \|x - u_{\alpha}\|^2\right) \quad (1)$$

ここに h_{α} , u_{α} , σ_{α} はそれぞれ、中間細胞と出力との間の結合強度、中心位置、標準偏差を表す。また、meta-learning モジュールの出力層には、自身が行う予測の信頼度を $[0, 1]$ で出力するユニットを追加している。

main-learning モジュールは、学習サンプルから出力関数の近似を行う。通常 main-learning モジュールは、前章で述べた従来の追加学習システムと同様に、バッファ内に格納したサンプルに対して最急降下法によって学習を進めていく。一方、meta-learning モジュールは過去の学習経験を元に、main-learning モジュールの持つパラメータの適切な変化量の予測を行う。ここで予測するパラメータ変化量は、main-learning モジュールが過去に学習した内容の忘却を防ぎながら新規のサンプルに対する誤差を小さくするものである必要がある。そして、meta-learning モジュールの予測の信頼度が高いと判断されると、main-learning モジュールは最急降下法の代わりにその予測によるパラメータの修正を行う。

meta-learning モジュールの予測が適切に行われれば、main-learning モジュールの学習は予測による変更の 1 度のみで終わることになる。また、予測による変更後に誤差が残っている場合でも、少数回の最急降下法によるパラメータの更新で学習を終了させることができると期待される。

本システムの学習手順を要約すると以下ようになる。

[†]北海道大学大学院工学研究科

1. main-learning モジュールのパラメータ θ^{old} を退避する
2. 新規学習サンプルに対する誤差 $E(\theta^{old})$ を計算する
3. $E(\theta^{old})$ からメタ情報 m を計算し, meta-learning モジュールの入力とする
4. meta-learning モジュールが main-learning モジュールのパラメータ予測値 g^* を出力する
5. meta-learning モジュールの予測の信頼度が高ければ, main-learning モジュールのパラメータを予測値を用いて修正する
6. 新規学習サンプルをバッファに格納する
7. main-learning モジュールはバッファ内のデータを最急降下法により誤差が閾値以下になるまで学習する. 必要ならば新しい中間細胞を割り付ける
8. 実際の main-learning モジュールのパラメータ変化量 $\theta^{new} - \theta^{old}$ を元に meta-learning モジュールの学習を行う

なお, main-learning モジュールの中間細胞の割り付けは, 新規入力に対しての誤差と, 最近傍の中間細胞との距離が閾値以上の時に行う. meta-learning モジュールへの入力となるメタ情報 m には, 新規入力に対する main-learning モジュールの出力の二乗誤差の正規化勾配ベクトル $D/\|D\|$ と, 入力と最近傍のテンプレートとの距離 d との両方 $m = (D/\|D\|, d)$ を用いる. D と d はそれぞれ以下の式で表される.

$$D = \nabla_{\theta_m} E(\theta^{old}) |_{\theta_m = \theta_m^{old}}, d = \|x - u_{i_1}\|^2 \quad (2)$$

ここで, $E(\theta^{old})$ は main-learning モジュールの新規サンプルに対する誤差を示す. 距離情報 d を使用するのには, メタ学習ネットワークに対して, 細胞を追加するとき, しないときそれぞれのパラメータ変化量を正確に予測させるためである, しかし, 正規化勾配ベクトルの全ての次元を meta-learning モジュールの入力として用いると, 入力空間が大きくなりすぎて適切な探索が行えない可能性がある. そこで, 実際に入力として用いるのは新規入力の近傍 n 個の main-learning モジュールの中間細胞に関する正規化勾配ベクトルを用いる. また, meta-learning モジュールの学習時に用いる教師信号は, main-learning モジュールの実際のパラメータ変化量を $\|D\|$ で割ったものを用いる. 信頼度出力ユニットの教師信号 T_C は以下の式によって定義した.

$$T_C \equiv \exp\left(\frac{-\|\frac{\Delta\theta_m}{\|D\|} - g^*(m, \xi)\|^2}{\sigma_C^2}\right) \quad (3)$$

なお, meta-learning モジュールの学習は main-learning 学習終了毎に 1 度だけ行われる.

3. 実験

今回は, 提案システムとオリジナルの RAN の性能比較を行った. 実験には, CMU Learning Benchmark Archive にある Mackey-Glass カオス時系列の予測問題を用いた. 学習サンプルは 4 次元の入力と 1 次元の教師信号で構成されている. 実験は $t = 200$ から $t = 3200$ まで 3000 個の学習サンプルを $t = 200$ から順に学習システムに提示して行った.

図 3 は関数近似ネットワークの累積学習回数を表したものである. なお, 提案システムの信頼度の閾値は 0.7,

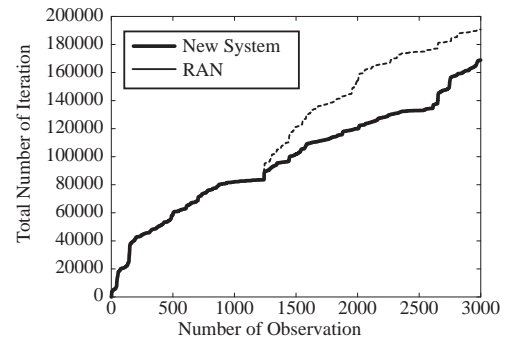


図 3: 累積学習回数の比較

meta-learning モジュールの予測を適用するのは main-learning モジュールの入力近傍 5 個の中間細胞とした. 提案システムでは提示データ数が増えるに従い予測の信頼度が増加し, 提示データ数が約 1200 程度に達した時点で予測の適用が始まっている. そして, 予測の適用によって RAN のみでの学習に比べ, 少ない学習回数で学習を行っている. これは, メタ学習の利用により過去に学習した学習戦略を使うことで高速化されたと考えられる. この結果から, 提案システムはカオス時系列という周期性が不明瞭なデータに対しても, 学習回数を減少させることができていることがわかる.

4. 考察とまとめ

実験を通じ, RAN を用いた追加学習においてメタ学習による過去の学習経験に基づくパラメータの変化量の予測を利用することで, 計算量を減少させることが可能であることを示した. 今後は, 人手で行っている信頼度の閾値の設定部分を, 問題の難しさに応じてシステム側が自動的に設定するように改良を加え, より複雑な問題に対しても適応できるようにしていく予定である.

参考文献

- [1] H.Yamakawa, D.Masumoto, T.Kimoto, and S.Nagata. Active data selection and subsequent revision for sequential learning with neural networks. *World congress of neural networks(WCNN'94)*,3:661-666, 1994.
- [2] M.Kawato, K.Furukawa, and R.Suzuki. A Hierarchical Neural-Network Model for Control and Learning of Voluntary Movement. *Biological Cybernetics*.57,169-185, 1987.
- [3] John Platt:A Resource-Allocating Network for Function Interpolation. *Neural Computation*,3,213-225,1991