

追加学習可能な対向伝搬自己増殖型 ニューラルネットワーク (CP-SOINN) の提案

日大生産工 (学部) ○片山 翔太 日大生産工 山内 ゆかり

1 まえがき

自己組織化マップ (Self-Organizing Map: SOM)[1]では、入力データに対する教師なし学習により学習を行い入力データの自動分類を行うことができるという特徴がある。

この学習では主に入力されたデータの分類という特徴からパラメータの種類に依存して入力データのパラメータごとに近似するものを分類することでデータの特性の近いものを解析する画像認識や文字認識に利用されている。また、この学習を時間依存にせずに入力データのみに依存することで追加学習に適応させることに成功した自己増殖ニューラルネットワーク (Self-Organizing Incremental Neural Network: SOINN) [2]の登場により、画像認識や近似データの分類技術に飛躍的な向上が見られた。

これらの手法を実現するためには、入力データに対して一定の領域に対して重みを期待される入力データに割り振られる分だけ用意し領域内を入力データによって能動的に更新し続けることにより学習を実現させている。

間所らは、適応的カテゴリ写像ネットワーク (Adaptive Mapping Network: AMN) [3]を提唱し上記のSOMを利用し、そこに適応共鳴理論 (Adaptive Resonance Theory: ART) [4]、対向伝搬ネットワーク (Counter Propagation Network: CPN) [4]を組み合わせて3つのモジュールに分割することでオンライン学習可能なネットワークを作成した。

このネットワークでは、SOINNと近似する部分があり、データのみに依存することができるかつ教師信号を自動生成することで入力データの長期保存を必要としない高速学習をおよび認識を実現した。

しかし、従来研究ではCPNの性質から一度作成したマップから大きく外れるデータである未確認データが入力されるとそれまでに記憶していたデータ分類が崩壊してしまうことが既存研究の問題点として挙げられている[3]。

そこで、CPNのマップ領域を自己増殖可能な形式とすることで、学習終了後も追加学習可能になる手法を提案する。

2 従来研究

2.1 間所らはSOMを入力データのベクトル量子化という点に利用し、量子化した大きさをその後の計算に利用している。この処理をコードブックモジュールとして実行している。

$$y_j^{cm}(t) = \sqrt{\sum_{i=1}^I (x_i^{cm}(t) \cdot w_{i,j}^{cm}(t))^2} \quad (1)$$

次にコードブックモジュールにおけるアルゴリズムを示す。

1. ランダム初期化した重みと入力データの差分から最小を求める。
2. 近傍距離を学習における時間遷移を基に計算する。
3. 学習係数の更新。
4. 式(1)からART、CPNへ出力するデータを作成する。

2.2 ラベリングモジュールによる教師信号の自動生成

本モジュールによってラベルの自動生成を行うことで教師信号を作成する。

教師信号の中身は、最大発火点以外を0に設定することで最大発火した部分のみ影響を与え、それ以外の影響を除去したノイズ処理の役目も担っているため、教師信号の中身は直感的にラベルの大きさと同等な単位行列となる。

実際に学習を行う部分では、入力データの大きさが一定の閾値未満、すなわち発火が行われなくなるまで学習を続け、その重みを基にカテゴリを分類し入力データのカテゴリへの帰属を判定する。

Additional Learning Counter Propagation of Self-Organizing
Incremental Neural Network
Yoshihisa SUGIURA and Yukari YAMAUCHI

学習の結果、カテゴリ分類のために使用される重みは発火の判定に使用するため教師信号と内部関数の一つで双方向に重みが設定されておりその重みが限りなく一致することにより学習が進むにつれてのデータの自動分類に必要な計算量が低減される。

・ラベリングモジュールの相互作用関数

以下にラベリングモジュールであるARTの実行する関数を示し、どのように相互作用するかを示す。

$$w_j^{lm}(t) = y_j(t) + au_j(t-1) \quad (2)$$

$$h_j^{lm}(t) = \frac{w_j^{lm}(t)}{e + \|w\|} \quad (3)$$

$$f(x) = \begin{cases} 0 & \text{if } 0 \leq x < \theta \\ x & \text{if } x \geq \theta \end{cases} \quad (4)$$

$$v_j^{lm}(t) = f(h_j^{lm}(t)) + bf(q_j^{lm}(t-1)) \quad (5)$$

$$u_j^{lm}(t) = \frac{v_j^{lm}}{e + \|v\|} \quad (6)$$

$$p_j^{lm}(t) = \begin{cases} u_j^{lm} & (\text{inactive}) \\ u_j^{lm} + dz_{kj}^{lm}(t) & (\text{active}) \end{cases} \quad (7)$$

$$q_j^{lm}(t) = \frac{p_j^{lm}}{e + \|p\|} \quad (8)$$

e は0除算にならないための固定値である。

・カテゴリ帰属判定のための値 $\|r\|$

以下にカテゴリへの帰属を判定する式を示す。

$$r_j^{lm}(t) = \frac{u_j^{lm}(t) + s \cdot p_j^{lm}(t)}{e + \|u\| + \|s \cdot p\|} \quad (9)$$

$$\rho < e + \|r\| \quad (10)$$

式(10)を満たしたとき、ARTの内部関数である式(2)~(8)を用いて入力データの計算結果 w が1時刻前の入力データの計算結果と差分をとった時0.01未満になる時までARTを繰り返し、一度の入力データごとに最適な結果が出るまでの試行することでより最適なカテゴリ分類が可能である。

また、式(3)を満たすことができない場合はラベルへの分類が成功したとして次の入力データの分類を開始する。

2.3 マッピングモジュールでの学習遷移

モジュール内の学習遷移は入力 y と重み u との差分の最小を求め、該当するラベルから教師信号を利用してマップに適応する。

以下に更新式を示す。

$$\Delta u = \alpha(t)(y_j^{cm}(t) - u_{j,(l,m)}^{mm}(t)) \quad (11)$$

$$u_{j,(l,m)}^{mm}(t+1) = u_{j,(l,m)}^{mm}(t) + \Delta u \quad (12)$$

$$\Delta v = \beta(t)(T_k(t) - v_{(l,m),k}^{mm}(t)) \quad (13)$$

$$v_{(l,m),k}^{mm}(t+1) = v_{(l,m),k}^{mm}(t) + \Delta v \quad (14)$$

式(11)、(12)では教師なし学習の結果を受けての教師なし学習による更新を行い、量子化された入力データをマップに適応する。

式(13)、(14)では作成された教師信号によって発生する教師あり学習を適応することで、ノイズの除去かつ特徴量の増幅を行う。この重みは発火を表し、どのカテゴリに属しているかの指針となる。

3 提案手法

本研究では、従来研究のCPNモジュールに、追加学習を可能にする自己増殖型ニューラルネットワーク (Self-Organizing Incremental Neural Network: SOINN) を採用したCP-SOINNを提案する。

CP-SOINNでは、CPNにおいて大きな弱点であった拡張性のなさ、既学習知識の崩壊を解決するため、学習時に必要なノード (カテゴリ) をマップ上に構成する。カテゴリの増加に伴い学習に必要なノードを付加することで、データでも追加学習する適応的学習が行えると考えられる。

下記に提案手法のアルゴリズムを示す。

1. コードブックモジュールにおける入力データ量子化は通常の自己組織化マップ (SOM) のアルゴリズムにより、既存手法と同様に学習する。
2. ラベリングモジュールにおけるラベル生成は、教師なし学習の場合のみ適用され、既存手法と同様のアルゴリズムを用いる。
3. マッピングモジュールにおけるカテゴリ学習は、SOINNのノード生成アルゴリズム

ムにより、初期データ2つから追加的にカテゴリを構成する。

以上の手順を繰り返すことで、時間遷移でラベルの増加にも対応できるかつ学習マッピングエリアの拡大による未知の入力に対する学習が実現できる。

4 実験環境

本実験では、入力データは手書き文字データのオープンソースであるOptdigits[6]を利用しており、マップとして表示させる重みはランダムに初期化している。以下の2次元平面環境のカテゴリマップを用いて実験を行う。画面に映し出されている数字はマップのひとつずつに割り振られたカテゴリで、初期では-1として初期化されている。

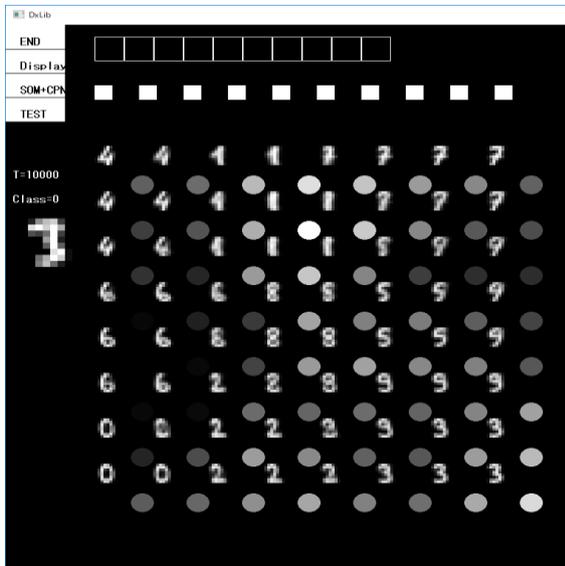


図1.コードブックモジュール実行例

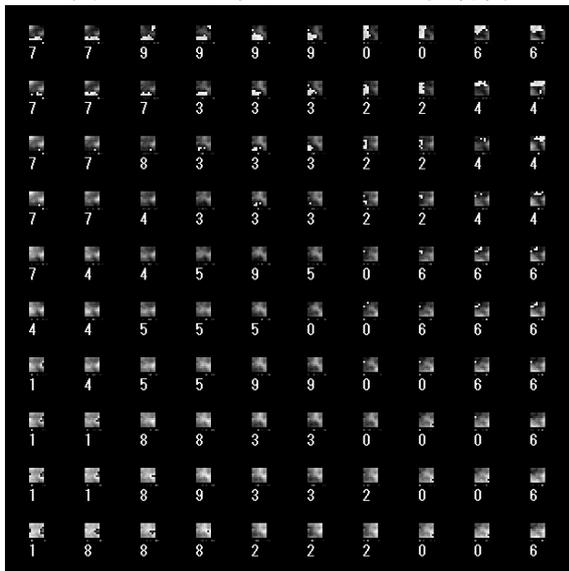


図2 マッピングモジュール実行例

図1に示されているのは実験環境における初期画面であり、ここから左に表示されているOptdigits入力データを利用し、中央に示すマップで量子化であるSOMを実行、マッピングした結果を図2に示すエリアに適応させることでカテゴリマップの可視化を図っている。

処理が開始すると、最初に入力データの量子化を実行、その後ラベル付け、マップとしての可視化を実行する。システムとしては時間遷移を二つに分離しており量子化部分を前半、マッピングによるカテゴリ分類を後半としている。メイン挙動は後半部分に集約されているため、ここでは後半部分に絞っての説明となり、1ステップごとの実行結果は後半部分のみを表示することになっている。

入力データの数はトレーニング時とテスト実行時によって異なり、ステップ数も同様であるため後述する。実験環境として利用されるマップの最大の大きさは30×30に設定されており、学習の初期段階ではマップの大きさを10×10に制限している。

トレーニングデータでの実験を行う際には先にトレーニング用のデータを入力量10,000として実行し、カテゴリの数が5個になるまではマップの拡張を行わないものとした。

テストデータでの実験を行う際には、学習済みカテゴリの中に新たに入力されたデータがカテゴリに一致しないときは常にカテゴリを追加してよいこととして追加学習の可用性を求めた。

左図に示すのは、実験開始から初期学習までの結果であり、10試行分のデータを取得して計測した認識率の解析結果が次に示す表1である。

表1 実行結果、データセットの認識率

Digits	Training	Test
0	96.61%	94.94%
1	79.24%	67.03%
2	77.22%	77.97%
3	83.78%	74.32%
4	85.47%	89.50%
5	70.93%	69.23%
6	92.27%	87.29%
7	96.22%	84.92%
8	41.57%	35.63%
9	61.90%	68.33%
Ave	78.80%	75.01%

表 1 の結果は、現時点までの学習結果および認識率である。現状は表を鑑みるに 0 の入力最大の認識率を示しており、8 の入力データが最小の認識率を示している。カテゴリマップの適応はおおよそ期待通りであるが、マップの拡張性の不足から、現状では適応させるマップの大きさの変動を視野に入れて実験を継続している。

5 まとめ

本研究では、追加学習に対する CPN の不寛容性を改良するために CPN の実行時前にカテゴリの増加を判断し、その都度マップの拡大をすることによって既存のマッピングエリアの大きさを変えことなく追加学習する学習手法を提案した。正常な動作が行われた場合、より高い精度での入力データの認識およびカテゴリ分類が期待される。

提案手法の今後の課題としては、現状ではマップエリアの開放でしか追加過学習の手法を提案できていないが、今後の課題としてマップの可塑性を前提とした類似データの統合によるマップエリアの縮小手法の確立が求められる。現状のままでは、一定以上のカテゴリを超えてカテゴリが作成されてしまった場合、マップエリアの拡大が追い付かず、長期間による追加学習を続けた場合学習が進むにつれて不正確な結果を出すことにつながると考えられるため、改良方向としてはカテゴリの独立性を生かしたままでのカテゴリの統合が必要となる。

「参考文献」

- 1) T. Kohonen, Self-Organizing Maps, Springer Series in Information Sciences, 1995
- 2) F. Shen and O. Hasegawa, "An Incremental Network for On-Line Unsupervised Classification and Topology Learning. "Neural Networks, vol.19, no.11, pp.90-106,2006
- 3) データの位相構造をカテゴリマップとして可視化する適応的写像ネットワーク, 知能と情報(日本知能情報ファジイ学会誌)Vol26. No6. 903-912(2014)
- 4) Gail A. Carpenter and Stephen Grossberg ART2 : self-organization of stable category recognition codes for analog input patterns (a reprint from Applied Optics Volume 26, number 23, December, 1987)
- 5) R.H. Nielsen, "Counterpropagation networks," Appl. Opt. vol.26, pp4979-4983, 1987
- 6) Optical recognition of handwritten digits: (<https://archive.ics.uci.edu/ml/datasets/Optical+Recognition+of+Handwritten+Digits>)