

分割自己組織化マップと自己増殖型 NN による対抗伝搬学習

日大生産工(学部)○佐藤 武尊 日大生産工 山内 ゆかり

1 まえがき

ウェブサーバーにおけるログデータやウェブ上の配信等のマルチメディアデータなどのビッグデータを扱うために機械学習が注目されている。

適応的カテゴリ写像ネットワーク(Adaptive Mapping Networks: AMN)とは、適応的かつ追加的に系列データを学習し、カテゴリマップとして可視化する手法である。

間所らは、カテゴリマップとして可視化するAMNを提案した。1)しかし、この研究では自己組織化マップ(Self Organizing Map: SOM)が使われていたため、追加学習に対応することができなかった。

本研究では、分割自己組織化マップと自己増殖型ニューラルネットワーク (Self-Organizing Incremental Neural Network: SOINN) を用いることを提案し追加学習の実装を検討する。

2 研究背景および従来手法

間所らは,SOINNと同じように,教師なし学習に基づくオンライン学習により,追加的にカテゴリの時間的な特性に加えて,空間的な関係性をカテゴリマップとして可視化する新しい枠組みを提案した。

適応的かつ追加的に系列データを学習し、カテゴリマップとして可視化する手法として、適応カテゴリ写像ネットワークが提案されている。

以下の図 1 に AMN のネットワークの構造を示す.




図1. AMNネットワークの構造

AMNは、入力データをベクトル量子化するコードブックモジュール、カテゴリを適応的かつ追加的に生成するラベリングモジュールそして、カテゴリの空間的な関係性をカテゴリマップとして可視化するマッピングモジュールの3つもモジュールから構成されている。

コードブックモジュールはSOMを用いて構成されている,近傍と競合の概念により,教師なし学習による自己写像特性を通じて,SOMは特徴が類似するデータの集合体を形成する.SOMのネットワークは,入力層とマッピング層の2層から構成される.入力層には,入力データの特徴次元数と同じ数のユニットが割り当てられる.入力データを自己写像するマッピング層は,低次元空間に配置されたユニット群から構成される.

ラベリングモジュールは、カテゴリの候補となるラベルを生成する。従来手法では、時系列データに対して安定性と可塑性を保ちながら適応的かつ追加的にラベルを形成する教師なしニューラルネットワークの適応共鳴理論(Adaptive Resonance Theory: ART)を用いて本モジュールを構成している。ARTは多数の派生形が提案されているが連続値が入力できるART-2が用いられている。ART-2のネットワークは、特徴表現層のF1と、カテゴリ表現層のF2から構成されている。F1は、6層のサブレイヤから構成されており、入力データが各サブレイヤを遷移することによって、短期記憶(Short Term Memory: STM)を実現する。STMはノイズ除去と特徴強調を行う。F2には位相の強弱により長期記憶(Long Term Memory: LTM)としてカテゴリが形成される。LTMはユニット単位で生成され、独立したラベルが割り振られる。

マッピングモジュールでは,学習結果としてカテゴリマップを生成する.本モジュールは,競合と近傍の概念により,パターンを特定のカテゴリに分類する教師あり対抗伝搬ネットワーク(Counter Propagation Networks: CPN)を用いて構成する.CPNネットワークは,入力層,マッピング層,及びGross berg層で構成される.入力層とマッピング層は,コードブックモジュ

Split Self Organizing Map and Self-Organizing Incremental Neural Network
by Counter Propagation Learning
Takeru SATO and Yukari YAMAUCHI

ールで使用するSOMと同じであるが,Gross berg層には教師信号が入力される.従来手法では,Gross berg層に教師信号を直接提示するのではなく,ラベリングモジュールを構成するART-2のF2に割り振られるラベルを教師信号として用いている.このように,CPNとART-2を組み合わせることでラベリング処理の自動化を実現している.

3 提案手法

従来研究では,SOMが使われているためカテゴリマップに追加学習が対応できていない.

本研究では,ANM ネットワーク内のコードブックモジュール内で使われている SOM の出力を SOINN での入力として使えるようにするために分割し,マッピングモジュール内の SOM を追加学習が行える SOINN へと変更する.これによりカテゴリマップを追加学習に対応させることが期待できる.

4 実験結果および検討

SOINNの実装が間に合わなかったため実装した従来研究の結果を示す.この実験で検討すべきものは文字の認識精度である.今回の研究では学習にカテゴリマップの代わりとして,Optdigits 2)を利用して行う.Optdigitsは0~9までを表現するデータが入っている.またこれには学習時に用いるoptdigits_traと認識時に使用するoptdigits_testが存在する.

表1. 実装した従来研究10回の認識精度[%]

実験回数	認識度
1	74.23
2	71.34
3	71.73
4	75.96
5	72.73
6	73.85
7	75.74
8	71.17
9	76.41
10	74.40
平均	73.76

表1は実験を10回行った認識精度の結果である.最大で9回目の76.41%で平均73.756%という結果になったが,本来の従来研究では認識精度は97.17%となっており,本研究ではそれよりも低い結果となった.現在考えられる原因としては,従来研究よりもカテゴリマップのユニ

ットが30×30なのに対し今回実装したマップのユニットが10×10となっていることが考えられるが,それでも従来研究と結果が離れすぎているため,ほかにも原因があると考えられる.

5 まとめ

今回SOINNの実装が間に合わなかったため,提案手法を実装することができなかった.また,従来研究の結果が本来よりも低い結果となってしまった.そのため,まずは従来研究の問題の解決,その後のSOINNの実装,SOMの分割化を行い提案手法の実装を目指す.

【参考文献】

- 1)間所 洋和,佐藤 和人,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ィ学会誌)Vol.26,No6,pp.903-912(2014) pp903-912
- 2)Optical recognition of handwritten
<https://archive.ics.uni.edu/ml/datasets/optical+recognition+of+handwritten+digits>
最終アクセス日時 2018/10/16 12時30分