

| | |
|--------------|---|
| Title | 階層型混成ニューラルネットワークモデルによる追記学習に関する研究 |
| Author(s) | 小川, 知之 |
| Citation | |
| Issue Date | 1999-03 |
| Type | Thesis or Dissertation |
| Text version | author |
| URL | http://hdl.handle.net/10119/1287 |
| Rights | |
| Description | Supervisor:日比野 靖, 情報科学研究科, 修士 |

階層型混成ニューラルネットワークモデルによる 追記学習に関する研究

小川 知之

北陸先端科学技術大学院大学 情報科学

1999年2月15日

キーワード： 混成ニューラルネットワークモデル、追記学習、適応共鳴理論 (ART)、パーセプトロン、競合学習.

本論文では、追記学習可能な、かつカテゴリの統合を行なうことのできる階層型混成ニューラルネットワークモデル、適応型カテゴリ統合回路網 *Adaptive Category Unifying Network* (ACU_N) を提案する。このモデルでは追記学習が可能であり、加えて認識したカテゴリを統合することができる。

本論文で“subset 問題”と呼ばれる、適応共鳴理論 (ART) において、分類することができないパターン群、つまり、ある入力パターンとその subset であるパターンについても検証した。

まず最初に、分類されたグループを表現するための語を定義した。多くの文献においては、このような語として“カテゴリ”、“クラスタ”、“クラス”を使用しているが、区別されていないのが現状である。本論文では、これらの3語を以下のように定義し区別する。

1. カテゴリ： 基本的、或は最小の分類単位。
2. クラスタ： いくつかの似ているカテゴリの集合。
3. クラス： いくつかの任意のカテゴリの集合。

提案したアーキテクチャは、任意の2値の入力パターンに応じて自己組織化、自己安定化し、教師信号によって得られたカテゴリをクラスへと統合する。

一般に、訓練されたニューラルネットワークでは、新規パターンのみを追記的に学習することが困難である。というのは、このような学習を行なうと、以前学習したパターンを想起するためのネットワークの状態を変更してしまうからである。それゆえ、もしネット

ワークに新規パターンを学習させようとするのであれば、以前学習に用いたパターンを含めたすべてのパターンを使用して、最初から学習をやり直さなければならない。

ニューラルネットワークは、大きく分けて、教師有り学習モデルと、教師無し学習モデルの2つのタイプに分類することができる。

教師有り学習モデルである単純パーセプトロンは、良く知られているように、線形分離不可能なパターンを分類することはできない。一方、教師無し学習を行なう競合学習モデルは、任意の入力パターンを分類することができるが、分類されたカテゴリをクラスへと統合することはできない。これは、線形分離不可能な入力パターンの分類が、ハミング距離のような類似度による分類と全く相容れないということに起因する。つまり、線形分離不可能なパターン群を分類した結果できたグループは、似ていないということである。

そこで、これらの2つの学習モデルの特徴を組み合わせることにより、任意の2値入力パターン群を分類し、クラスへ統合することができる新しい特徴を得ようとするのは自然な考え方である。つまり、競合学習モデルによりカテゴリの分類を行ない、教師あり学習モデルを用いることで分類されたカテゴリの統合を行なうのである。

本アーキテクチャは、入力パターンの分類を行なう ART の層と、カテゴリを統合するための単純ヘッブ則を用いた単純パーセプトロンの層からなる。これらの層をそれぞれ、A 層、P 層と呼ぶ。特に、ART の出力層を“カテゴリ表現層”、P 層の出力層を“クラス表現層”と呼び、カテゴリ表現層の出力はその入力パターンの属すカテゴリを表し、クラス表現層の出力は、そのカテゴリが属すクラスを意味する。

このアーキテクチャの動作は、カテゴリ分類フェーズとカテゴリ統合フェーズの2つのフェーズに分けられる。ART によるカテゴリ分類フェーズでは、できる限り細かくカテゴリ分けを行なう。この時の分類精度は vigilance parameter ρ によって調整され、この値は通常、少なくとも 0.8 以上に設定される。次に、得られたカテゴリが P 層で統合される(カテゴリ統合フェーズ)。

新規パターンと学習済みのパターンとで取り得るカテゴリとクラスの関係は、以下の4つのケースに分類される。

1. カテゴリが同じで、かつクラスも同じ。
2. カテゴリが同じで、かつクラスが異なる。
3. カテゴリが異なり、かつクラスは同じ。
4. カテゴリが異なり、かつクラスも異なる。

1、3、4 番目のケースでは、競合学習の出力を入力とするパーセプトロンの学習によっては、結合荷重は変更されないということが保証されている。言い替えれば、学習によって変更される結合経路は、それぞれ独立であるということである。

しかしながら、2 番目のケースにおいては、パーセプトロンにおける一般の位置にない点に関する問題と ART での subset 問題を含んでいる。このような入力パターンが本モ

デルに提示されると、P 層において学習が収束しないが、これは ACTUN の欠点ではなく A 層での分類失敗に起因するものである。

このような現象は、 ρ が小さい時に生じる問題である。したがって、本モデルでは ρ の値は大きめに設定される必要が有る。subset 問題に関しては、問題の起こったパターンを再度提示することで解決することができる。

本アーキテクチャでは、 ρ を十分に大きく設定していさえすれば、学習が収束することが保証されている。