

実世界パターン情報の非停止型学習・認識手法の提案

A proposal of non-stop learning and recognition scheme for real-world pattern information

神谷 祐樹*¹ 申 富饒*¹ 長谷川 修*^{2,3}
Yuki Kamiya Shen Furao Osamu Hasegawa

*¹東京工業大学大学院 総合理工学研究科 知能システム科学専攻

Department of Computational Intelligence and Systems Science, Tokyo Institute of Technology

*²東京工業大学大学院理工学研究科像情報工学研究施設 / *³科学技術振興機構 さきがけ研究 21
Imaging Science and Engineering Lab., Tokyo Institute of Technology / PRESTO, JST

To learn and recognize pattern information by traditional methods of pattern recognition under fluctuating environments is generally impossible. The scheme of continuous learning under fluctuating environments leads to a countermeasure against the “symbol grounding problem”. We suggest a scheme of learning and recognition that works incrementally and continuously for understanding real-world pattern information influenced a great deal by noise. This scheme is characterized by integration of learning phase and recognition phase, and is consist of several layers of structural analysis and one layer of conceptual shaping. It is effective in order to learn and recognize under the fluctuating environment that the number of classes is indefinable. We use expanded-GNG as a layer of structural analysis, and conducted an experiment of clustering about two features of color and form by it, under the assumption that humans and four birds appear one after another.

1. はじめに

実世界で人間と共存する人工の知能を考える上で、記号接地問題の解決は不可避である。記号接地問題は、開放系としての実世界と、推論・行動計画の基盤としての記号系との間に有効なインタフェースが存在しないために生じ、この点をいかに扱うかが課題となっている。

実世界(日常生活環境)は常に変動を伴う環境であり、実世界から得られる視覚パターン情報の学習・認識の問題は、信号レベルではパターン信号の混合・減衰やノイズの影響などに対応しなければならない。

また一般に、より高次のレベルでは予め設定された学習サンプルに基づいて学習器が構成されるが、環境の変動により学習サンプルと大幅に異なるパターンが入力された場合、出力結果の妥当性は保障されない。さらには、実世界では学習すべきクラス数が増えることも想定されるが、従来のパターン認識手法の多くがこの問題に対処できない。

そこで本研究では、実世界の変動に常に追従(学習)しつつ、同時に認識を行うことの可能なメカニズムの実現を目標とする。すなわち提案手法には学習フェーズ、認識フェーズといった区別がなく、学習は恒常的(非停止)である。本稿ではこのうち、概念解析層(後述)に関する初期の実験結果について述べる。

2. 提案手法

実世界パターン情報を追加的・連続的に学習・認識する手法の概要を図1に示す。提案手法は構造解析層と概念形成層で構成される。構造解析層は、実世界から得た入力パターンの分布構造を学習・分類する。

構造解析層は複数の層の階層構造から成り、下位層から上位層へ解析した構造を徐々に抽象化して伝播する。また、複数の

特徴を複合的に解析するよう構造解析層が並列に配置される。概念形成層は、構造解析層から出力される解析結果から入力パターン情報の概念(記号)を形成する。さらに、能動的あるいは受動的に人間など外部からの教師信号を得ることで、形成した概念と関連する構造解析層間の構造(結合重み)を更新する。




図1: 提案手法の概要:斜線部分が常に機能し非停止型学習を行う

以上のシステムは自律的なボトムアップの学習と、教示を得てのトップダウンの学習を絶えず行う。学習結果はそのまま認識に適用するため、学習過程と認識過程の区別はない。以上により、常に変動を伴う環境において、システムに入力される膨大なパターン情報を追加的・連続的に学習しつつ、同時に認識も可能となる。

本提案手法を実現するため、構造解析層の最下層にGNG [Fritzke 94] を拡張した独自の手法(以下、拡張GNG)[Shen 04]を導入する。拡張GNGは入力分布をノード(ニューロン)が自己増殖しながら追加的・連続的に近似し分類する性質を持つ。これはすなわち、常にクラス数が増加する環境下で教師なしクラスタリングを行っていることに相当する。また、拡張GNGはノイズに対する耐性を有していることも付記する。

上位の構造解析層および概念形成層を構成するためには、拡張GNGが実世界パターン情報を学習・分類した結果につい

連絡先: 神谷 祐樹, 〒 226-8503 横浜市緑区長津田町 4259
東京工業大学像情報工学研究施設 R2-52 長谷川研究室,
Tel:045-924-5180, Fax:045-924-5175,
E-mail:youki@isl.titech.ac.jp

て検討する必要がある。以下では、基礎実験として拡張 GNG に実世界パターン情報を学習・分類させた結果について考察する。

3. 基礎実験

3.1 実験方法

実験では、屋外数箇所に設置した定点カメラからの映像を例題とし、映像中に出現する 5 種の対象を拡張 GNG で分類させた。映像のフレームレートは 15fps である。出現する対象は人間および 4 種の野鳥 (スズメ, ムクドリ, ハクセキレイ, カラス) である。ただし人間については服装の異なる複数人を入力とした。入力画像例を図 2 に示す。

本実験では、フレーム間差分および背景差分等によって入力映像から動作物体を抽出した画像から、2 種類の特徴ベクトルを作成し、入力ベクトルとした。作成したベクトルは色特徴と形状特徴であり、ベクトルの次元数はそれぞれ 512,48 次元である。また各クラスのサンプル数は 450 である。作成した色特徴ベクトルに主成分分析を行い、2 次元に写したベクトルの分布を図 3 左に示す。各クラスを表す点はそれぞれスズメ (○), ムクドリ (□), ハクセキレイ (×), カラス (◇), 人間 (+) である。



図 2: 入力画像例 (左上から順にスズメ, ムクドリ, ハクセキレイ, カラス, 人間)

各対象が映像中に存在する時間が短く、作成したサンプル数が少数であったため、作成したサンプルベクトルから無作為にベクトルを順次 5000 回抽出し、各対象 (クラス) につき約 5 分 30 秒分の入力ベクトルデータを作成した。この 5000 回の入力を 1 セットとし、5 クラス分を連続的に入力することで、5 種の対象が連続的に出現する状況を想定した。入力の詳細を表 1 に示す。表は入力ベクトルの番号と属するクラスを表している。1~5000 シグナルはスズメのサンプルベクトル、5001~10000 シグナルはムクドリのサンプルベクトルであり、以下表の順に各クラスのサンプルベクトルが入力される。このような状況下で拡張 GNG に対象を分類させる実験を 100 回施行し、5 クラス分のデータの入力が終了した時点で、分類結果について検証を行った。

表 1: 入力シーケンス

		入力単位:千シグナル				
入力	~5	~10	~15	~20	~25	
クラス	スズメ	ムクドリ	ハクセキレイ	カラス	人間	

3.2 実験結果および考察

拡張 GNG に連続的に 5 クラス分のサンプルパターンを与えた場合の結果について考察する。拡張 GNG が出力するノードと入力ベクトルとの間で最近傍法による識別を行い、各クラスの入力ベクトルの識別された分類クラス数と、他クラスと分類が混同したベクトル数について分析し、分類結果を評価した。

色特徴ベクトルを用いた実験について、実験結果の例を図 3 右に示す。図は 5 クラスの学習が終了した時点での拡張 GNG のノードの分布とクラスを表している。

色特徴ベクトルと形状特徴ベクトルの実験結果を分析した結果、拡張 GNG は追加的・連続的に入力されるベクトルの分布を、ノイズの影響を除去しながら良好に近似できることがわかった。

しかし一方で、入力されるクラス間のベクトルが類似、もしくは複数のクラスの分布に重なりがある場合、クラス数の推定には課題が残ることもわかった。具体的には、色特徴ベクトルの場合、スズメとハクセキレイには体に複数の色の模様があり、見えの向きの変化によって色の比率が変動しサンプルベクトルの分散が大きくなる。そのため多くのベクトルが他のクラスと混同されたと考える。

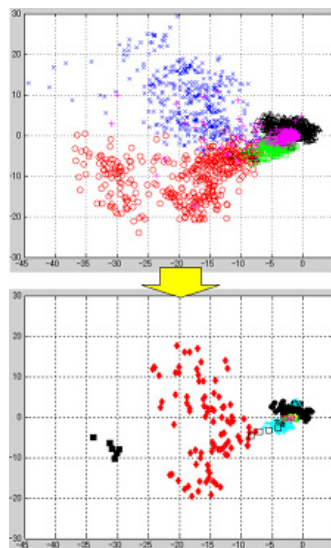


図 3: 分布 (上) の入力ベクトルを拡張 GNG が学習し出力したノードの分布 (下)(分布は 2 次元写像)

形状特徴ベクトルを用いて行った実験においても、類似の傾向が見られた。これは、対象物体の見えの変化が特徴ベクトルに影響し、各クラスのベクトルの分散が大きくなったためと考えられる。こうしたエラーは、本研究の枠組みにおいては、図 1 に示すように教師信号を用いたトップダウン処理により修正を加えることとなる。

4. むすび

本稿では、図 1 に示す提案手法の構造解析層として拡張 GNG を用いた実世界パターン情報の学習・分類の基礎実験を行い、初期の結果を得た。今後は、図 1 に示すメカニズムのより上位の部分の実装・実験を進める必要がある。

参考文献

- [Fritzke 94] B.Fritzke: “A growing neural gas network learns topologies”, Advances in Neural Information Processing Systems 7, MIT Press, pp.625-632 (1995)
- [Shen 04] F.Shen and O.Hasegawa: “A growing neural network for online unsupervised learning”, Journal of Advanced Computational Intelligence and Intelligent Informatics, Vol.8, No.2, pp.121-129, (2004)