

属性知識学習における未知クラス推定の認識率の向上

日大生産工 (学部) ○間野内 彰斗 日大生産工 山内 ゆかり

1 まえがき

近年、少子高齢化に伴う労働力不足や介護士不足等を補うため、人と同様に稼働できる自律知能ロボットの開発が急務である。しかし人の生活環境で知識を獲得する知的発達機構に関する研究が発展途上であった。知的発達機構の実現のため、多種多様な物体を認識する機構の構築が必要であることが挙げられる。実環境でロボットの稼働を想定した時、予め学習物体を全て与えることは困難なため、環境に応じてその場で追加学習できるオンライン追加学習がロボットの知的発達機構に対して必須である。

そこで Kawewong らはオンライン追加学習が可能な属性ベースの学習手法を提案した[1]。属性ベースの学習手法とは物体が持つ属性(大まかなカテゴリ)を組み合わせることで推定する学習である[2]。しかしこの手法は1つの属性に対して1つの学習器を使うため処理時間が増大する問題がある。学習器に教師情報を管理するアルゴリズムが存在せず1つの学習器で1つの概念しか学習できないためである。

この問題に対して、木村らは自己増殖ニューラルネットワーク (Self-Organizing Incremental Neural Network: SOINN) に対して、教師情報に対する統計情報の算出アルゴリズムを追加し、教師情報の統計的な推定器を取り入れた[3]。これにより教師あり学習に対応でき1つの学習機で複数の教師情報に対する学習を可能とした。その結果学習器の数が少なくなるため、計算回数が少なくなり処理時間を大幅に削減することが出来た。しかし認識率は従来と多少劣り、認識精度にばらつきが存在していると書かれている。

本研究では、ノードの生成及び削除の調整を行い、認識率の向上と認識精度の安定性の向上を試みる。

2 従来研究

2.1 Adjusted-SOINN(以下SOINN)

自己増殖ニューラルネットワーク (Self-Organizing Incremental Neural Network:

SOINN) とは SOM[4]などに着想を得て構築された学習手法である、入力に合わせてノードが増殖や消滅を行い、仮想的なノードの繋がりを用いて構造化されるネットワークモデルである[5]。SOINNには複数のアルゴリズムが存在し、事前に定義するパラメータ数が少なく計算時間が短い特徴がある。定義するパラメータは λ と Agemax が存在する。従来手法・提案手法はこの SOINN を使用して改良を行う。

2.2.木村らSOINN (以下KSOINN)

KSOINNはSOINNから大きく2つの改良をしている。1つはノードにクラスの教師信号のラベル情報を付加させ、1つのネットワークにすべてのクラスの情報の学習を可能にした。ラベル情報とはクラスの関連度合いを保持している。図1に例を示す。




図1. ラベル情報の付加

もう1つはノードに年齢を導入した。木村らはノイズの削除処理で早い段階と遅い段階で入力されたノードのステップ数が異なることが原因であると考え、事前定義した年齢の倍数に達したノードのみを削除を行うようにした。

3 提案手法

本研究では KSOINN の改良を提案し認識率の向上と安定性の向上を試みる。KSOINN は、SOINN と比べノード数は多いがエッジが全然引かれないためクラスタリングが余り行われない欠点があった。

そこで本研究では、ノードが挿入される際、第1勝者ノードの閾値範囲内に入力ノードがある場合エッジを結ぶ条件を加えた。本来入力

ノードが第 1 第 2 勝者のいずれかの閾値範囲を超える場合、分布の近似が不十分であると判定されてノードが入力される。そのためいずれかの閾値の範囲内に入力ノードがあるならばその勝者ノードと近似した分布である可能性が高いと言えるためエッジを引いて学習を行う。

4 実験環境

本実験では、64次元のデータを用いてデータの認識を行う。3823個の入力データをSOINN空間内に挿入・削除を行い、学習を行う。ノードを挿入する際にラベルを付加させる。この流れを学習フェーズとする。この過程を行い量子化誤差の削減を目標とする。次にテストデータの入力データと学習フェーズのSOINN空間内のテストデータと近いノードのラベルを用いて推定を行う。この流れを認識フェーズとする。この過程を行い、100回認識フェーズをした際の認識率の向上を目標とする。

また、SOINN、KSOINNの環境で実験し、提案手法の比較を行った。ノイズ除去を行う際、SOINNは時刻 t が事前定義する λ の倍数の時に行うため、KSOINN、従来手法と比べ削除頻度が多い。同条件にするため、SOINNに対しての λ の値は2倍の数値とする。

表 1. 各手法における量子化誤差

回数	1 回 目	2 回 目	3 回 目
SOINN	1.176	1.178	1.160
KSOINN	1.260	1.245	1.253
提案手法	1.076	1.072	1.053

表 1 の結果について説明すると、KSOINN は λ の数を半分にしたためか SOINN より量子化誤差が増えている。提案手法では、 λ の数が半分だが SOINN よりノードの生存率が高く量子化誤差を削減できていることがわかる。




図 2. 各手法における認識率

10 回認識を行った結果認識率にばらつきはあるが SOINN、KSOINN と比べ認識率を上回る結果を出すことができた。

5 まとめ

本研究では、認識率の精度と認識精度の安定性の向上を目的とした提案をした。学習結果から認識率の最適な解を得ることができた。

しかし本研究では、木村らが用意した入力データと認識を行う際に用いる関連度表を準備することができなかつたため各手法の認識率は今回の結果と異なる可能性があると思われる。今後の課題は入力データと関連度表を用いて再度認識率、認識精度を比較することと、高次元データを低次元データにし、SOINN 空間内の動作を目視できるようにすることである。

「参考文献」

- [1] A. Kawewong, and O. Hasegawa: “Fast and incremental attribute transferring and classifying system for detecting unseen object classes”, International Conference on Artificial Neural Networks, Vol.6354, pp.563-568, 2010.
- [2] C. H. Lampert, H. Nickisch, and S. Harmeling: “Learning to detect unseen object classes by between-class attribute transfer”, IEEE Conference on Computer Vision and Pattern Recognition, pp.951-958, Jun. 2009.
- [3] 木村 大毅, PICHAI Kankuekul, 長谷川 修, 属性知識の高速オンライン学習と転移による未知クラス推定, 知能と情報 26(5), pp.830-843, 2014
- [4] T. Kohonen: “Self-organized formation of topologically correct feature maps”, Biological Cybernetics, Vol.43, No.1, pp.59-69, Jan. 1982.
- [5] F. Shen, and O. Hasegawa: “A fast nearest neighbor classifier based on self-organizing incremental neural network”, Neural Networks, Vol.21, No.10, pp.1537-1547, Dec. 2008.