

自己増殖型ニューラルネット(SOINN)とパターンベース人工知能

長谷川修

東京工業大学 像情報工学研究施設

〒226-8503 横浜市緑区長津田町 4259 R2-52

E-mail: hasegawa@isl.titech.ac.jp, oh@ieee.org

あらまし 我々人間を含む生体が実世界で発揮する知能（知的機能）を人工的に実現したいという欲求は古くからあるが、今日に至っても、せいぜい昆虫レベルの知能しか実現されていない。

言うまでもなく、生体の知能は多数のニューロンから成る脳によって生み出されるが、その脳が入出力している信号は全てパターン情報であり、全ての脳は、巨大なパターン情報処理マシンであると言ってよい。このことは、視覚や聴覚を持ちながら、言語を持たない（シンボル情報を必要としない）生物が多数存在することなどからも確認できる。すなわち、一般に脳は、視覚、聴覚、触覚といった異なるモダリティのパターン信号をオンラインかつ並列に受け入れつつ、それらの個々の情報の記憶や認識、さらには複数のパターン間の連想・推論といった高度な処理まで行い、その結果として知的行動（運動パターンの出力など）を発現しているのである。

これまでのところ、そうしたことが可能な人工のパターン情報処理マシンは存在しない。筆者は、こうした知見は、これからパターン情報学が目指すべき重要な指針を与えてくれると考える。つまり今後我々は、

- (1) ノイジーで膨大、不安定なパターン情報から有意義な情報をオンラインで取り出せる
- (2) 取り出した情報の意味や価値を、環境（社会的環境と物理的環境の双方）と相互作用しながら獲得すると共に、獲得した知識を能動的に運用して汎用の問題を解決できる

といったパターン情報処理マシンを実現することが必要なのである。そうしたマシンは、「パターンベース人工知能」と呼ぶべきものであり、今後その実現に向けて様々な手法が提案されると予想される。本稿ではその一例として、筆者らが独自に研究を進めている自己増殖型ニューラルネットワーク(Self-Organizing Incremental Neural Networks : SOINN)を紹介する。

キーワード パターンベース人工知能, オンライン追加学習, 人工脳, SOINN,

Self-Organizing Incremental Neural Network and its Application for Pattern Based Artificial Intelligence

Osamu Hasegawa

Imaging Science and Engineering Lab., Tokyo Institute of Technology
4259, R2-52, Nagatsuda, Midori-ku, Yokohama, Kanagawa, 226-8503, Japan

Abstract To create an intelligent system which works well in the real-world, we need to realize a pattern based intelligence called “Pattern Based AI (PB-AI)”. PB-AI is supported by a self-organizing incremental neural network (SOINN) which is capable of on-line unsupervised classification and topology learning. In this paper, we introduce SOINN and its applications for many pattern-based problems.

Keyword Pattern based AI, Artificial Brain, Online Incremental Learning, SOINN

序

- Google で「パターンベース人工知能」で検索すると、5件ヒット。そのうち4件は長谷川研関係
- 「pattern based artificial intelligence」でもヒットは8件。
- 「パターンベース人工知能」って、何？

1

パターンベース人工知能

- 実世界は「パターン」であふれている。
- 人間を含む生体の脳が扱う信号は、全てパターン信号
 - 従来のAIはシンボルベースの人工知能
 - 生体の脳のような、パターンベースの人工知能の必要性。
- しかしこれまで、それをどのようにしたら実現できるのか、手がかりがほとんど無かった。
- 長谷川研では、独自技術の開発を通じ、その実現を図っている。

2

独自技術: SOINN

GNG vs SOINN


- demoGNG で検索
- SOINN デモ
- GNG: Growing Neural Gas
- SOINN: Self-Organizing Incremental Neural Network

3

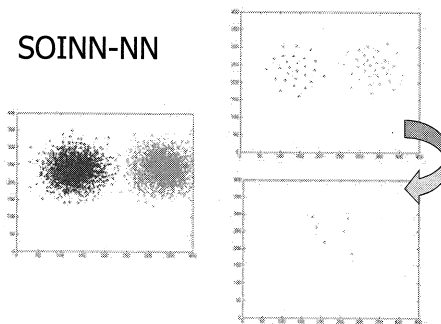
SOINN (Self-Organizing Incremental Neural Network)


- 長谷川研究室で独自開発
- 競合学習型のニューラルネットの一種
- ノイズに強く追加学習とクラスタリングが可能
 - アルゴリズムが簡単→計算軽い
 - 「発達の学習」に適する
- 様々な問題に展開可能
 - 教師なし学習、教師あり学習、準教師あり学習、時系列パターン認識、連想記憶、パターンベース推論

4



SOINN-NN





Dataset	ADC (acc)	NSC (acc)	EMC (acc)	NND (acc)	ENC (acc)	EMC (acc)	WTS (acc)	LVC (acc)	MCS (acc)	TAB (acc)	NNC (acc)	HTF (acc)
Ins	97.4 ± 0.6	96.7 ± 0.4	96.5 ± 0.7	96.7 ± 0.6	96.7 ± 0.7	96.7 ± 0.7	96.7 ± 0.7	96.7 ± 0.7	96.7 ± 0.7	96.7 ± 0.7	96.7 ± 0.7	96.7 ± 0.7
Breast cancer	97.4 ± 0.3	97.2 ± 0.3	96.9 ± 0.3	97.2 ± 0.3	97.2 ± 0.3	97.2 ± 0.3	97.2 ± 0.3	97.2 ± 0.3	97.2 ± 0.3	97.2 ± 0.3	97.2 ± 0.3	97.2 ± 0.3
Ionosphere	90.4 ± 0.4	91.9 ± 0.2	87.4 ± 0.6	86.1 ± 0.7	83.9 ± 0.7	86.8 ± 0.7	85.9 ± 0.7	86.4 ± 0.6	86.8 ± 0.6	88.1 ± 0.6	86.4 ± 0.6	86.4 ± 0.6
Glass	73.3 ± 1.6	70.2 ± 1.3	80.0 ± 1.3	73.3 ± 1.3	73.3 ± 1.3	73.3 ± 1.3	73.3 ± 1.3	73.3 ± 1.3	73.3 ± 1.3	73.3 ± 1.3	73.3 ± 1.3	73.3 ± 1.3
Liver disorders	87.5 ± 0.7	83.9 ± 1.3	59.5 ± 1.7	87.5 ± 1.0	87.5 ± 1.0	87.5 ± 1.0	87.5 ± 1.0	87.5 ± 1.0	87.5 ± 1.0	87.5 ± 1.0	87.5 ± 1.0	87.5 ± 1.0
Plant Indiana	73.8 ± 0.8	63.4 ± 1.6	60.7 ± 0.9	74.7 ± 0.7	74.7 ± 0.7	74.7 ± 0.7	74.7 ± 0.7	74.7 ± 0.7	74.7 ± 0.7	74.7 ± 0.7	74.7 ± 0.7	74.7 ± 0.7
Wine	83.4 ± 1.5	73.7 ± 1.9	71.9 ± 1.9	73.9 ± 1.3	73.9 ± 1.3	73.9 ± 1.3	73.9 ± 1.3	73.9 ± 1.3	73.9 ± 1.3	73.9 ± 1.3	73.9 ± 1.3	73.9 ± 1.3
Average	82.3 ± 0.9	80.4 ± 1.2	75.3 ± 0.9	81.3 ± 0.9	81.3 ± 0.9	81.3 ± 0.9	81.3 ± 0.9	81.3 ± 0.9	81.3 ± 0.9	81.3 ± 0.9	81.3 ± 0.9	81.3 ± 0.9

(a) Recognition ratio in percentages, displayed with average of 10 times 10-fold cross-validation and standard deviation. Bold face recognition ratio means the best or near best classifier.

Dataset	ADC (acc)	NSC (acc)	EMC (acc)	NND (acc)	ENC (acc)	MDC (acc)	WTS (acc)	LVC (acc)	MCS (acc)	TAB (acc)	NNC (acc)	HTF (acc)
Ins	5.7 (6.6)	7.2 (8.3)	2.0 (4)	100 (148)	96 (9)	9.2 (5)	10 (13)	15 (22)	9.3	3	100	7.3
Breast cancer	1.4 (8.8)	1.8 (25.6)	0.29 (7)	100 (1)	97 (5)	1.8 (5)	1.6 (11)	5.9 (60)	6.4	7	100	1.3
Ionosphere	3.4 (13.1)	31 (1.35)	4.0 (7)	100 (2)	90 (2)	100 (1)	11 (28)	6.8 (24)	13	24	100	3.7
Glass	13.7 (13.1)	97 (0.80)	17 (6)	100 (1)	73 (1)	100 (1)	58 (119)	48 (97)	38	13	100	13
Liver disorders	4.6 (5.6)	4.9 (60)	11 (19)	100 (14)	69 (8)	100 (1)	4.1 (14)	8.4 (2)	51	10	100	10
Plant Indiana	0.8 (6.6)	1.7 (260)	1.0 (4)	100 (17)	74 (16)	8.1 (6)	0.3 (2)	3.4 (26)	48	15	100	11
Wine	2.2 (6.6)	96 (4.8)	29 (37)	100 (1)	70 (1)	100 (1)	4.5 (8)	32 (57)	35	7	100	12
Average	4.6	34.2	10.0	100	81.3	59.9	12.5	16.8	23.5	12.4	100	9.8

(b) Compression ratio in percentages, the optimal parameter value tuned

SVMIに應用: SV数を削減 実行時の速度を高速化

表4. CVM, BVMとの比較結果

Table 4. Comparison between proposed method and CVM, BVM.

Dataset	Number of SV	認識手法		
		CVM	BVM	LtSVM
KDD Cup 1999	Number of SV	13	53	219
	認識率 (%)	92.60	92.34	91.93
	Train-Time(sec)	142.9 + 6.501	1.27	2.09
WEB	Number of SV	2975	9859	5540
	認識率 (%)	99.19	99.07	99.04
	Train-Time(sec)	116 + 1.7	220.17	23.17
IJCNN	Number of SV	2952	9516	5721
	認識率 (%)	98.72	98.37	98.38
	Train-Time(sec)	170.4 + 16	269.4	67.38
USPS	Number of SV	454	4094	1428
	認識率 (%)	99.35	99.50	99.53
	Train-Time(sec)	406 + 1.6	735.5	67.09

SOINN-AM: Associative Memory for Online Incremental Learning in Noisy Environment


A.Sudo, A.Sato, O.Hasegawa

Experiment:

- Training patterns


- The methods compared with SOINN-AM
 - BAM with PRLAB [1]
 - KFMAM [2]
 - KFMAM-FW [3]

Algorithm: Learning Associative Pair



13


The result:



14

Experiment: one-to-many association

- Below training pairs were presented sequentially:



- SOINN-AM → **100% Perfect Recall**

15

Experiment: real-valued data

- Below training pairs were presented sequentially:



16


知識を追加的に獲得可能な パターンベースの推論システム

東京工業大学 知能システム科学専攻
須藤 明人 佐藤 彰洋 長谷川 修

17

提案手法のニューラルネットワークモデルとしての解釈 「ならば」の知識の蓄積


- SOINN-AMの連想記憶を自然に拡張できる



18


提案手法のニューラルネットワークモデルとしての解釈
「または」を含むif-thenルールの蓄積

- SOINN-AMの多対多の連想機能を利用することで実現できる




提案手法のニューラルネットワークモデルとしての解釈
「かつ」を含むif-thenルールの蓄積

- 「かつ」を表すために「片方だけが発火することを防止するエッジ」を新たに設ける




提案手法のニューラルネットワークモデルとしての解釈
「～でない」を含むif-thenルールの蓄積

- ノードが保持しているパターン情報のペアのそれぞれについて、否定かどうかを表すフラグを設ける




知識からの推論方法

- If-thenルールをためこんだSOINN-AMにあるパターンを入力すると、推論結果となるパターンが出力される




実験 利用した画像

- パターン情報として以下のような画像を利用した



推論結果




パターンベース人工知能

さらなる展開
人工脳の実現に向けて

GAM
General Associative Memory


GPBR
General Pattern Based Reasoning

GAMの構成例



3層構造⇒ 連想層(関連), 記憶層(SOINNs), 入力層(インターフェース)

脳の外側面とブロードマン分類



QAFのモデル

意識的行動から無意識(常識)の獲得へ

- Q(question)
 - 問題が与えられる
- A(answer)
 - 問題を解いてみる
- F(feedback)
 - うまく解けた?

29

意識と無意識

表 1-1 意識過程と無意識過程における情報処理の比較。

意識	無意識
直列的	並列的
低い計算効率(エラーが多い、低速処理、相互干渉あり、処理の脆感性)	高い計算効率(エラーが少ない、高速処理、相互干渉なし、処理の柔軟性)
非モジュール的	モジュール的
コンテキスト依存的	コンテキストから独立
意図的	自動的
漸時的	同時的
整合的	非整合的
容量限界をもつ	容量限界をもたない
意識的注意が必要	意識的注意なしに生じる
随意的	不随意的

「無意識」の工学的実現に向けた手がかり

Subsumption Architecture (包摂アーキテクチャ)

Rodney A. Brooks, "A Robust Layered Control System for a Mobile Robot", IEEE Journal of Robotics and Automation, 2:14-23, 1986.

SAの実装の実際




図4. 制御の層構造。高次のレベルの層は低レベルの制御を包摂して制御を実現する。このシステムはどのレベルでも制御可能であり、下位層のみでも完全な制御システムを構成する。

32

iRobot

Prof. Rodney A. Brooks
Co-founder, Chairman and Chief Technology Officer
<http://www.irobot.com/>



昆虫レベルの知能は
実現されている



33


パターンベース推論システムを用いた 移動ロボットの認知地図の獲得と利用

東京工業大学 知能システム科学専攻
長谷川研究室 坪山 学

研究背景 認知地図 (cognitive map)


→ 行動と反応とも密接に結びついた知識群 (≠ 地図)

- 空間行動によって、局所的な環境の目印が認識され、それが統合されて全体の空間配置が学習される
- 学習後には目印を手がかりに、見通しが開かない場所にも到達できる



提案モデル全体図


● 三層構造 → 次元数の異なる入力データの取り扱い
効率のよい知識獲得



この下位構造としてSA

実験1の設定


- 実験の目的
動作の確認。
(認知地図、行動計画)



- 実験の手順
e-puckからの入力データを学習させ内部の様子や動作を確認する。

実験結果1-(1)


認知地図の獲得 (100ステップ入力)



実験結果1-(3)


• 画像データから想起

学習に使用したデータから想起
→ 全ての画像で想起できた



入力 想起結果

学習に使用したデータ以外から想起
→ 未知と判断されたものもあった




入力 想起結果

実験2の設定

- 実験の目的
シンボルによる指示と内部のパターンデータを組み合わせた推論で、指示された場所までの経路計画を行わせる。

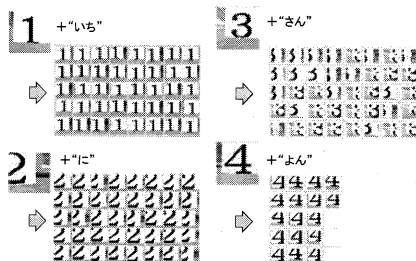
• 実験の手順

1. 18000ステップの探索を行う
2. 数字の見える場所の名前を教える
(右図の場所には「に」と教えた)
3. 「いち」から「よん」に行け」などシンボルによる指示を与える



実験結果2-(1)


• 名前付け(シンボルグラウンディング)



実験結果2-(2)①

- 場所の名前で指示し、経路計画を出力させる

「いち」から「に」までの行動計画



ヒューmanoイドの知能

- 超少子高齢化時代の到来
- 人間の生活環境に溶け込み、不特定のタスクを実行可能なヒューmanoイドへのニーズは大きい
- 汎用の問題解決器をヒューmanoイドに実装したい

43

現在取り組んでいる研究

実世界で汎用的な問題解決が可能な知能の開発

- 経験から学習し、自立的・追加的に知識を獲得
- 未経験の目標でも、試行錯誤的に達成可能




これができるロボットの実現

因果関係の獲得と利用

- QAFの実装
 - 初期段階では人間が手助けしてもよい
 - 幼児も養育者の支援を必要とする
- 実世界版一般問題解決器の実現
 - オペレータ(知識)を増やし、教示を受けていない不特定の問題への対処も可能にする
- 意識的行動から無意識的(反射的)行動へ
 - 獲得知識の「常識」化
 - 経験をつみ、知識が増えると処理が速くなる。

45

SONYの研究例(2005年)




ベルをたたく動作を教えているところ。デモではベルの場所を少しずつ変えながら、何回か動作を教えていた。音を確認すると「おお」という歓声を上げる(左)、同じくボールを転がす動作を教えているところ(右)

<http://ascii24.com:80/news/tech/article/2005/04/08/655282-000.html>

46

東工大長谷川研の研究例(2009年)

実世界版一般問題解決器
Real World - General Problem Solver (RW-GPS)
まずは2~3歳児程度の知能を目指す



47

東工大長谷川研の研究例(2009年)

RW-GPS

- パターン情報のシンボルグラウンディングに基づく概念形成
- 人との相互作用や経験を通じたオペレータ(因果関係に関する知識)の獲得と順位づけ
- 獲得した複数のオペレータを能動的に運用し、実世界の不特定の問題を解決
- 問題解決の方法論を低位の「入力・反射メカニズム」に組み込むことによる常識の獲得と利用

48

まとめ

残念なことに、「強いAI」を志向した研究は、世界的に見てもほんの数例しかない。

「パターンベース人工知能」は、その突破口になる可能性がある。

今後、効果的な実利用例が示せれば、爆発的に研究・開発が進むと考える。

49

謝辞

本研究を熱意をもって推進してくれた、長谷川研の在校・卒業・修了生に深く感謝いたします。

本研究の推進にあたり、NEDO「産業技術研究助成事業」より支援を受けました。記して感謝いたします。

50

関連文献(1)

Furao Shen and Osamu Hasegawa, "An Incremental Network for On-line Unsupervised Classification and Topology Learning", Neural Networks, Vol.19, No.1, pp.90-106, (2005)

Furao Shen, Tomotaka Ogura and Osamu Hasegawa, "An enhanced self-organizing incremental neural network for online unsupervised learning", Neural Networks, Vol.20, No.8, pp.893-903, (2007)

Furao Shen and Osamu Hasegawa, "A Fast Nearest Neighbor Classifier Based on Self-organizing Incremental Neural Network", Neural Networks, Vol.21, No.10, pp.1537-1547, (2008)

Sudo Akihito; Sato Akihiro; Hasegawa Osamu, "Associative Memory for Online Learning in Noisy Environments Using Self-organizing Incremental Neural Network", IEEE Transactions on Neural Networks, (2009) in press

51

関連文献(2)

Furao Shen, Akihito Sudo, Osamu Hasegawa, "An Online Incremental Learning Pattern-based Reasoning System", Neural Networks, (conditionally accepted)

Xiaoyuan He, Ryo Kojima and Osamu Hasegawa : "Developmental Word Grounding through A Growing Neural Network with A Humanoid Robot", IEEE Trans. SMC-Part B, Vol.37, No.2, pp.451-462, (2007)

Xiaoyuan He, Tomotaka Ogura, Akihiro Satou and Osamu Hasegawa, "Developmental Word Acquisition And Grammar Learning by Humanoid Robots through A Self-Organizing Incremental Neural Network", IEEE Trans. SMC-Part B, Vol.37, No.5, pp.1357-1372, (2007)

小倉和貴, 申富鏡, 長谷川修: "オンライン教師なし分類のための追加学習手法", 電子情報通信学会論文誌. D Vol. J90-D, No.6, pp.1610-1622 (2007)

52

関連文献(3)

神谷祐樹, 申富鏡, 長谷川修, "自己増殖型ニューラルネットワークを用いたプロトタイプ生成による高速最近傍識別", 電子情報通信学会論文誌, Vol. J90-D No. 11 pp. 3000-3013, (2007)

桜井啓介, 神谷祐樹, 長谷川修, "競合型ニューラルネットワークを用いたオンライン準教師付能動学習手法" 電子情報通信学会論文誌, Vol. J90-D No. 11 pp. 3000-3013, (2007)

須藤明人・佐藤彰洋・長谷川 修, "自己増殖型ニューラルネットワークを用いたノイズのある環境下での追加学習が可能な連想記憶モデル", 日本神経回路学会誌, Vol.15, No.2, pp.98-109, (2008)

53

関連文献(4)

岡田将吾, 長谷川修, "自己増殖型ニューラルネットワークを用いた時系列データの学習・認識", 電子情報通信学会論文誌, Vol. J91-D No. 4 pp. 1042-1057, (2008)

須藤明人・坪山 学・張 シンリ・佐藤彰洋・長谷川 修, "自己増殖型ニューラルネットワークを用いたパターン情報ベースの推論機", 電子情報通信学会論文誌, Vol. J91-D No. 6 pp. 1634-1647, (2008)

笠井、戸部、申、長谷川: "オンラインプロトタイプ生成による大規模データに対する高速SVM構築法", 電子情報通信学会論文誌 D, 採録決定 (2009)

54