

自己組織化と外部知性との結合

—架空のコンピュータHALの生誕によせて—

Self-Organization Symbiotic with External Intelligence: In Relation with Supposed Birth of HAL by Yasuo MATSUYAMA
(Department of Electrical, Electronics & Computer Engineering, Waseda University).

松山 泰男¹

¹ 早稲田大学理工学部電気電子情報工学科

1. はじめに

「1997年」は、架空の意味ではあるが、強力なコンピュータが生まれた年になっており、そして今年はその「任務始め」の年となっている。さて、そのマシンとは、1968年に出版されたA. C. ClarkeのSF小説「2001年宇宙の旅」¹⁾に登場するHAL 9000のことである。HALは、「Heuristic ALgorithmic」という2つの対立した概念にちなんだ名称ということになっている^{*}。この物語の中で、HALは感性をもって人と対等に意志の疎通を行い、さらに木星への有人宇宙飛行²⁾において乗組員の生命維持装置を司るという何とも恐ろしい役割を担っている。ところが、身に存在したわずかなバグのために暴走を起こし、人間に生命危機をもたらすという大悪役を演じてしまうのである。

HALは現在においてももちろん実体をなしていないコンピュータである。しかしながら、同じ1997年に、Deep Blueが人間のチェス・チャンピオンを破ったことから分かるように、その部分的機能はすでに実現されている。そして、この「1997年以降」を意識して、現在の最先端コンピュータとHALとの比較が、学術書や学会講演などにおいて実際にまじめになされている。たとえば、D. G. Stork²⁾は、A. C. ClarkeやM. Minskyへのインタビュー、そして自身を含む多くの識者からの稿に基づいて、スーパーコンピューティング、人工知能、コネクショニズム、信頼性、そして感性情報処理の最前線を調べ、HALの能力との比較を行っている。また、コネクションマシンの開発に携わったD. Waltzは、ICNN'97の招待講演³⁾の中で、HALへの道はまだ遠いものであると認識した上で、「論理処理だけに基づくシステムは、“hopelessly

brittle^{*3}”である」と述べている。そして、「AIとコネクショニズム、あるいは関連する諸分野がそれぞれの特長を提供し合い、構造が不明確な状況でも作動できる情報処理が実現されるべきだ」と説いている。

さて、不明確な状況での情報処理とは、どのような場面で登場するのであろうか。個別技術については、たとえば感性情報処理やゲームに見受けられるようになり成熟している^{2), 3)}。ところが、何か一つ足りない。それは高度な個別技術をきわめて多数寄せ集めたときに、その設定数の多さのために、外部からの指定だけでは統合動作にもっていけないことである。HALの多様な能力は、そのすべてが外部から司令されたものではないはずである。すなわちHALは自身の機能の自己組織化を行い、磨きをかけたはずである。そこで、本稿では、HALへの道をたどろうとすると、なしでは済まされない大事な項目である自己組織化と情報処理に主眼を置くことにする。用意している内容は次の通りである。まず第2章においては、学習と自己組織化についての導入を行い、いくつかの手法を与えることにする。そして、ここでの手法を第3章における外部知性との結合へと発展させ、感性情報処理における実例を示してみることにする。次の第4章は、やや高みに立ったものとなっている。これは、学習や自己組織化といった分野が、理論の意味でも深さを追求できる分野であることを説明するために用意したものである。そして、最後の第5章においては、コネクショニズム的学習に直接対応しうるコンピュータの問題点について、いくつかの指摘を行うこととする。

2. 学習と自己組織化

ここでいう「学習」とは、計算機構(コンピュータ)が、入力に基づいてある目的にかなった情報処理形態を実現していくことを意味している。そして「自己組織化」とは、その学習の過程において、計算機構の内部状態が何らかの自律性をもって形成されていく

* ただし、「H」、「A」、「L」をアルファベット順に1文字ずらすと「T」、「B」、「M」となることから、今もって著者の当初意図への推測が行われている。

*2 したがって、1997年に実際に火星に着陸した無人探査機「マーズ・パスファインダー」よりもずっと高いレベルの科学技術が要求される。

*3 “brittle”には、「碎けやすい」あるいは「もろい」といった意味がある。

ことを指すものとする。したがって、一般的な自己組織化は目に見える表現になっているとは限らないのであるが、本稿では2次元や3次元に可視化できる場合に紙数を割くことにする。そして、このような自己組織化と可視化が一体となった手法の代表がこの後で登場する自己組織化特徴マップ(self-organizing feature map)である。可視化とは一体になつてない場合の例については、第5章で触れることにする。

2.1 学習と自己組織化

コネクションズムに基づく学習においては、多数個の小さな素子からなる結合系が内部状態(結合重み⁴⁾)を更新していく。したがって、自己組織化とは、その結合重みが変化していく、特有な相互関係が生じることを意味するものとなる。図-1はこのことを説明する基本的なモデルである。この図において、 x_n は素子 n への入力、そして y_m は素子 m からの出力である。 w_{mn} は素子 n から素子 m への結合重みであり、素子 m への結合重みをまとめて重みベクトル w_m と表すこととする。同様に、 \mathbf{x} や \mathbf{y} は入出力をベクトル表現したものとする。一方、破線の矢印は自分自身と他の素子とを比較するための通信を意味するものである。

上のような自己組織化は、次々に与えられる入力データ \mathbf{x} を、学習素子全体が保持するデータ群、 w_m 、($m=1, \dots, M$)、で近似することに相当している。そして、ここで大事なことは、その保持しているデータ群にいろいろな構造を持ち込むことが可能であることであり、自己組織化とは、まさしくこのことを指しているのである。このように、学習による自己組織化は「データの近似」を基本構造として有している。したがって、この部分は近似誤差を評価関数(コスト関数)とみなした最適化問題として定式化できることになる。

2.2 特徴マップと競合学習: 可視的な自己組織化

自己組織化の過程を、数式に基づき、かつ視覚的に表現しようという試みは、D. G. WillshawとC. von der Malsburg⁵⁾による網膜のマップに関する研究に始まり、T. Kohonen⁶⁾による自己組織化特徴マップ^{*4}へと引き継がれて、ロボットの経路設定、組合せ最適化、データベース分類などに広く応用されている。この特徴マップは、前述のような、それ自身が可視化されている自己組織化の代表例である。このとき、競合学習はこのような特徴マップを生成させる最も有効な手法となり、その高度化は特徴マップの応用範囲を広げるための重要な項目となっている。そこで、競合学習と特徴マップとの関連について調べてみよう。

*4 特徴マップと同等の構造は、それより以前に、スタンフォード大学の情報圧縮グループが、ベクトル量子化に関連して発表していた。Kohonenは、自己組織化という意味で貢献をしたと解釈される。

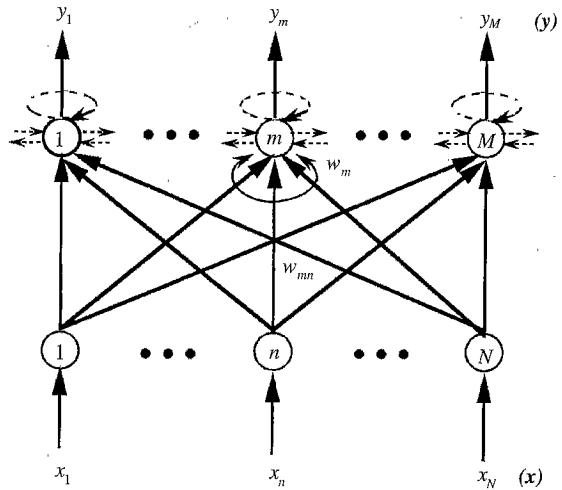


図-1 素子間の結合と重みベクトル

競合学習は、図-1にあるすべての学習素子($m=1, \dots, M$)の内で、入力 \mathbf{x} に対して近似誤差(コスト)最小の意味で最もよく整合する素子だけが出力を出し、かつその重みベクトルが更新されるものである。これは、勝者独占型とよばれている。ただし、勝者独占だけでは情報処理に役立つ自己組織化は生じない。したがって自己組織化特徴マップは、勝者が自分のパートナとする他の素子にも学習を行わせることによって生成される⁶⁾。このように、特徴マップの生成は、最適化すべきコスト関数と勝者のパートナ設定とに依存する。このコスト関数は、広いクラスの問題を扱えるように、数式として的一般性が必要である。一方、パートナ設定は、どのようなトポロジーの特徴マップを取り扱うかといったことに対応し、多くの場合、問題に応じてあらかじめ決められている^{*5}。そこで、次節において、広範な問題を扱えるコストに基づく競合学習について調べてみることにする。

2.3 調和競合学習と多目的最適化

ここでは、調和競合学習⁷⁾とよばれる一般的な競合学習を導入し、それを用いて特徴マップを生成する方法について説明する。従来の手法は、この場合の特例となっている。

調和競合学習においては、最適化のためのコスト関数は次のような一般的な項を含んでいる。

$$(f + \sum_{k=1}^K \lambda_k g_k)(\prod_{\ell=1}^L h_\ell) Q \quad (1)$$

ここに、関数 $f(\mathbf{x}, \mathbf{w}_m)$ は、入力ベクトル \mathbf{x} を重みベクトル \mathbf{w}_m ($m=1, \dots, M$)、で近似したときの誤差である。また、関数 g_k ($k=1, \dots, K$)、は解こうとする問題を反映した制約を指定するものであり、 λ_k は係数

*5 たとえば、網目、円環、あるいは木構造がある。

である。そして $Q(x, w_m)$ は重みベクトル w_m が勝者となるときに 1 となり、そうでないときは 0 となる関数であり、これが出力 y_m である。このとき、調和競合学習においては、与えられた入力データ x に対して(1)式を最小化する重みベクトル w_m を見つけ、

$$w_m^{\text{new}} = w_m^{\text{old}} + \Delta w_m \quad (2)$$

によりコスト関数を減少させる。

上の問題は、互いに矛盾する可能性がある目的関数 f と g_k を、競合学習により折り合いを付けて、すなわち調和的に減少させるという多目的最適化問題となっている。このとき、 h_ℓ はデータのラベルを表すものであり、(1)式は単なる近似度ではなくてデータへのラベルや教師信号を受け付けられることを表している。このような多目的最適化は、いろいろな問題を解くのに有効な定式化である。とりわけ、 f と g_k とが協調する場合には、劣悪な局所最適性を避ける問題に適用できる⁷⁾。

2.4 調和競合学習による特徴マップの生成

2.2 節で述べておいたように、勝者のパートナにも次のような学習を行わせると、特徴マップが生成される。

$$w_{N(m)}^{\text{new}} = w_{N(m)}^{\text{old}} + \Delta w_{N(m)} \quad (3)$$

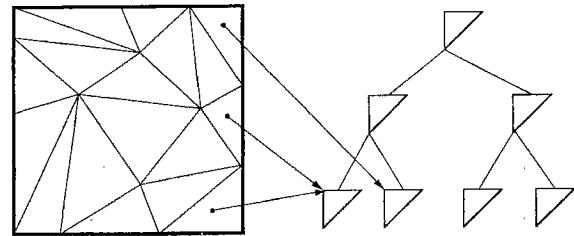
ここに $N(m)$ は、勝者 w_m が指定するパートナの番号である⁸⁾。このような特徴マップは、重みベクトル同士のトポロジーを指定し、その上で学習により実際の空間配置を得たものである。したがって、正確には「重みベクトル特徴マップ」と呼ぶべきものである。多目的最適化に基づく調和競合学習とその重みベクトル特徴マップは、いっそう広範な応用問題に適用できる⁷⁾。しかしながら、この種の特徴マップは、データ空間のもつ性質の一部分を抽出しただけになっている。そのため、この特徴マップのみを用いて原データの近似的再生やパターン認識を行おうとすると、失敗に終わることが多い。そこで、次節においては、原データに固有なパターンを別な形式で抽出する特徴マップの自己組織化を考えてみることにする。

2.5 グループ化特徴マップの生成

ここでは具体的な例に基づいて、「グループ化特徴マップ」とよばれるもう1つ別の特徴マップを提示する。

図-2(a)は、 $N \times N$ ピクセルからなるデジタル画像であるとする。1つのピクセルは、色調の意味で、8

⁸⁾ パートナー指定の例としては、図-1で素子 M を素子 1 につないで閉曲線を作るものがある。この指定は、ユークリッド空間における巡回セールスマン問題や、いろいろな制約条件を課した運搬車経路問題に対応している⁷⁾。



(a) グループ化特徴マップ (b) 重みベクトル特徴マップ

図-2 2種類の特徴マップ

個の隣接するピクセルのうち、かなりのものと関連を有している。これは、画像を受容する網膜を考えれば分かることである。そうすると、色調を反映したより大きなメッシュ構造を用いて、ピクセル群をグループ化するという問題が生じる。図-2(a)においては、グループ化は三角形領域としてなされており、全体として画面1枚を分割したメッシュパターンとなっている。これがグループ化特徴マップである。これとよく似たパターンは、前述の重みベクトル特徴マップを用いても生成できる⁶⁾。ところが、実は両者はまったく性質の異なるものなのである。すなわち、グループ化特徴マップは、さらに重みベクトル特徴マップを生成させるために利用できるのである。これは、図-2(b)においては、一例として、探索において効率のよい木構造として表示している。ここにおいて、1つの重みベクトルは、この図の三角形領域の中にあるピクセル全体を表したものとなっている。

以上のようにして、「原データ → グループ化特徴マップ → 重みベクトル特徴マップ」という階層が生じるのであるが、グループ化特徴マップも重みベクトル特徴マップも、最適化に基づいた学習により構造が決められる。いま、グループ化特徴マップと個々の重みベクトルを用いて画像を再生する問題を考えてみよう。この場合、最適化のためのコスト関数(評価関数)は、再生された画像がどの程度良好かということを表す量となる。この学習の過程で図-2(a)のメッシュパターンが決まり、同時に図-2(b)の重みベクトルも獲得される。すなわち、メッシュとそこに埋め込むテクスチャとが得られるのである。

3. 外部からの指定を受容できる自己組織化

前章で見たように、自己組織化は教師なし学習の結果として多様なパターンを生成する。しかしながら、最適化として定式化されているという意味で、この自己組織化にも「大いなる教師」、すなわちコスト関数が介在しているのである。そこで、「教師」としての外部情報についてもう少し踏み込んで考えてみること

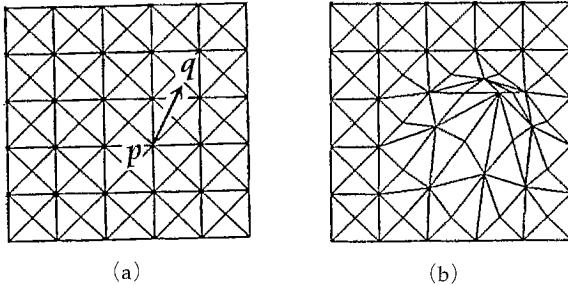


図-3 グループ化特徴マップの変形

にする。

3.1 ラベルによる自己組織化の誘導

ここでは、入力データにあらかじめカテゴリを表すラベルが与えられている場合を考える。この場合、もしそのラベルと自己組織化の様子とが合わなければ、通常の勝者ではない別の重みベクトルが競合学習の勝者として選ばれる。これは、(1)式における h_p が大きな値をとるか、あるいは(2)式において $-\Delta w_{m(n)}$ を用いることを意味する。学習ベクトル量子化⁶⁾は、このような形の調和競合学習の特別な形となっている。

教師信号をラベルにより与える方法は、外部知性が自己組織化の様子を制御する方法としては最も単純なものである。しかしながら、このように部分的に教師信号を与えただけでも、単純な自己組織化に比べて驚くほどの性能向上をもたらす。

3.2 外部知性による自己組織化の操作

ここでは、外部知性が学習系における自己組織化を利用する場合を、感性情報処理を例にあげて調べてみる。

図-3は画像のグループ化特徴マップを例にとった場合である。いま、図-3(a)は図-2(a)と同様に学習の結果として得られたグループ化特徴マップであるとする。そして、外部知性はこのグループ化特徴マップに対して、頂点 p を別の位置 q に移動するように指定しているとする。この指令は、グループ化特徴マップの正則性(三角形の保存)を守ると、図-3(b)のような結果をもたらす。このような教師情報は、自己組織化のどの段階においても与えることができるのであるが、ここでは、生成されたグループ化特徴マップを、外部知性からの指定に基づいて変形することを考えてみよう。これは実は、上のようなメッシュパターンを仲介にして仮想的な静止画像を作り、さらには仮想的な動画像を生成することに相当しているのである。

図-4において、 $t=0.0$ は自己組織化の結果生成されたグループ化特徴マップにテクスチャ(たとえば図-2(b)の重みベクトル)を埋め込んだ再生画像である。

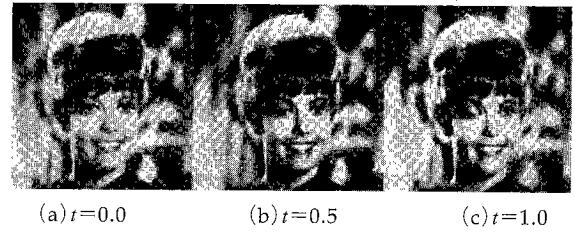


図-4 パーチャル動画像の生成

一方、同図で $t=1.0$ は、図-3(b)のように、外部知性からの指定に従って変形がなされたグループ化特徴マップを用いた生成画像であり、女性は片目を閉じている。また、 $t=0.5$ は時間的に補間を施してできたグループ化特徴マップを用いた生成画像であり、片目を閉じる途中である。このように、任意の時刻におけるグループ化特徴マップに重みベクトル(色のテクスチャ)を割り当てることができ、任意のフレーム数の圧縮画像を生成できる。したがって、以上のようにして生成された一連のフレームをモニタ上に時間表示してみれば仮想的な動画像が得られることになる。いま、このような手順を情報圧縮として考えてみると、静止画像の意味で $t=0.0$ の画像は、0.481 bit/pixelで34.2 dBとなっている。しかしながら、これを動画像圧縮の意味で考えてみると、頂点の移動情報は一枚の画像全体に比べてきわめて小さいので、さらにフレームレートで割ることになり、レートは $0.481/30=0.016$ bit/pixelとなる。これは、外部情報が「意味あるいは意図」の部分のみを指定していることに起因している。なお、実際に動画像として表示する場合には、さらにMPEGxの圧縮率が利得されることを付け加えておく。!

4. 確率的学習：さらなる理論の発展

コネクショニズムにおける学習や自己組織化は、実は裏に潜んでいる確率構造を反映したものとなっていて、理論的な深さが存在する。ここではそのことについて調べてみることにする。

4.1 トレーニングデータと確率

コネクショニズムにおける学習や自己組織化においては、通常、大量のトレーニングデータが与えられる。たとえば、図-1においても、入力は1つ1つのサンプルベクトル x として供給される。また、教師あり学習の代表となっている誤差逆伝播法についても同じことがいえる。すなわち、トレーニングデータは、密度が不均一な空間からたまたま現れたサンプルなのである。ところが、第2章の各部分で提示した学習と自己組織化の手法においては確率構造は特に意識されておらず、いずれも「統計モデルを仮定しないアルゴリ

ズム」となっていた。したがって、確率構造を仮定したアルゴリズムを構成した後、データに離散的確率量を与える、2.3節にあるようなサンプルごとの学習アルゴリズムが得られるのである。

多くの確率的学習アルゴリズムは、そのでき上がり姿が華麗であり、理論的に多くの魅力を有している。そこで次節において、学習や自己組織化といった分野の研究が、逆に新たな情報量や確率的アルゴリズムを助長している例を調べてみることにしよう。

4.2 EMアルゴリズムとその拡張

EMアルゴリズム(Expectation-Maximization algorithm)⁸⁾は、その名称が示すように、確率構造のよさあるいは確からしさを表す量の平均値をとり、それを最大化するという繰返し推定法となっており、その応用範囲はきわめて広い。そして多くの学習法はこの場合の特例となっている。ところが、コネクショニズムの学習法は逆にEMアルゴリズムそのものの拡張に影響を与えている。たとえば、WEM(α -Weighted EM algorithm)⁹⁾と呼ばれるものがそれであり、次のようなアルゴリズムとなっている。

[WEM: E-step] 次のような期待値 $Q_{X|Y}^{(\alpha)}(\psi|\varphi)$ を計算する。

$$Q_{X|Y}^{(\alpha)}(\psi|\varphi) = \frac{2}{1+\alpha} \left[\int_x p(x|y, \varphi) \left\{ \frac{p(x, y|\psi)}{p(x|y|\varphi)} \right\}^{\frac{1+\alpha}{2}} dx - 1 \right]$$

[WEM: M-step] 次のような最大化を行う。

$$\psi^* = \arg \max_{\psi} Q_{X|Y}^{(\alpha)}(\psi|\varphi)$$

[WEM: U-step] 収束判定を行う。未収束ならば、 φ を ψ^* によりアップデートしてE-stepに戻る。

このアルゴリズムにおいて、 X は完全データ、そして Y は実際に観測できるデータ、すなわち不完全データである。そして、 ψ や φ は確率量の関数形を表すパラメータである。 α は、Rényiによる α -ダイバージェンス、またはそのlogを取り去った形の α -ダイバージェンス^{☆7, 10)}のパラメータである。通常のEMアルゴリズムは、 $\alpha = -1$ の場合に対応している。この α の値は学習の速度や局所最適性に影響を与え、関連した議論から、確率重みが付いたフィッシャー情報量^{☆8}の一般形などが得られる⁹⁾。

WEMはもう1つ大事な性質を有している。すなわち、WEMを用いると、順方向と逆方向とが対になっ

^{☆7} パラメータ α を有し、 $\alpha = -1$ のときにKullback-Leibler数となるような情報量。そのさらに特別な場合がShannonのエントロピーである。

^{☆8} 負の対数尤度を確率のパラメータベクトルで2階変微分し、さらにその期待値をとってできる行列。

たブロックが得られるので、これをシストリックアレイ^{☆9}のようにつなぐことができる。これは、分割統治(divide-and-conquer)に基づくモデリングと密接に関連している。

5. 「Wah教授からの宿題」とその対極

本稿では、架空のコンピュータHALから話を起こし、HALへの道の必要条件の1つと目されている学習と自己組織化、そして外部知性との結合に話を進めた。また、アルゴリズムの一般化および高度化の観点から、確率構造に根ざした学習理論についても論述した。そこで、もう一度HALを引き合いに出して、学習、自己組織化、コンピュータについて次の2つのことを考えてみよう。

まず第一の項目は、アーキテクチャに関連したものである。本稿で与えた学習や自己組織化はコネクショニズムに基づくもので、それを情報処理として利用する場合には、粒度の小さな、そしてきわめて多数のプロセッサ群からなるMIMD構造が対応するアーキテクチャになる。ところが、ユーザ側(プログラマ)は、複雑度に起因する制約のため、各プロセッサにいちいち個別の指示を出すことはできない。このような場合、バックグラウンドに何らかの自己組織化情報処理を設定し、ユーザは、ほんの少しだけ陽に指定を与えることにする。これは実現性がありそうである。さて、問題は次の段階である。イリノイ大学^{☆10}のB. Wah教授は、以前に、Thinking Machines社が会社更生法を申請したことに関連して、私に次のような問い合わせをしてきた。すなわち、「たとえば100万から1000万台の数のプロセッサをもつ超並列コンピュータを考えてみよう。これは、原理的にはもはや可能になっている。そしてこのようなマシンが欲しい。そうすると、このようなコンピュータを商業ベースで必要とする分野を皆で考えてみなければならない」^{☆11}。その通りである。よい適用分野の発見は、何にも増して進歩を助長させるのである。

次に、上のような巨大なコンピュータではなくて、逆にその対極として、最も身近なものについて考えてみよう。それはVLSIのさらなる進展¹¹⁾に根ざした装着型コンピュータ(wearable computer)である。学

^{☆9} systolic array：互いに交差する入出力対をもつブロックからなる情報処理機構。

^{☆10} 物語上、HALはイリノイ大学のあるアーバナで生まれたことになっている¹²。そこは実際に製造された並列マシン、ILLIAC 4の生誕地である。文献2)には、日本のメーカーも含めて、現時点でどこがHALの生誕地になりうるのかの詰踏みもなされている。

^{☆11} ただし、「各プロセッサに1つの素粒子を割り当てるといった種類の例題は、前もって答えからは除外しておきたい」ということである。

習や自己組織化は常に入力を監視することによって成り立つ。人間の感性情報処理はちょうどこの形になっている。ここにも適用分野を見つけられるはずである。

謝辞 本稿の準備段階で貴重なコメントをいただいた担当委員と閲読者の方々に深く感謝いたします。そして、調査費等を活用させていただいた各財団や諸企業に深甚の謝意を表します。また、参考文献については総数の適正值に従ったため、多くの優れた文献を割愛せざるを得ませんでした。ここにその旨を記してお詫びし、大方のご寛容を乞う次第です。

参考文献

- 1) Clarke, A.C.: 2001: A Space Odyssey, Hutchinson/Star, London (1968).
(伊藤典夫訳：2001年宇宙の旅，早川書房，東京(1993)；2010年宇宙の旅(1994)；3001年終局の旅(1997))。
- 2) Stork, D.G. (Ed.): HAL's Legacy, MIT Press, Cambridge, Mass. (1997).
(日暮雅通訳：HAL伝説，早川書房，東京(1997))。
- 3) Waltz, D.: Neural Nets and AI: Time for Synthesis, Invited Speech at ICNN'97 (unpublished lecture), IEEE (1997).
- 4) 松本 元, 重松征史, 市川道教: 脳研究から情報処理へ—脳型コンピュータの開発にむけて, 情報処理, Vol. 38, No. 5, pp. 369-375 (May 1997).
- 5) Willshaw, D.G. and von der Malsburg, C.: How Patterned Neural Connections can be Set Up by Self-organization, Proc. R. Soc. Lond. B, Vol. 194, pp. 431-445 (1976).
- 6) Kohonen, T.: Self-Organization and Associative Memory, Springer Verlag, Heidelberg (1984).
- 7) Matsuyama, Y.: Harmonic Competition: A Self-organizing Multiple Criteria Optimization, IEEE Trans. NN, Vol. 7, No. 3, pp. 652-668 (1996).
- 8) Dempster, A.P., Laird, N.M., and Rubin, D.B.: Maximum Likelihood from Incomplete Data via the EM Algorithm, J. R. Stat. Soc. Sr. B., Vol. 39, pp. 1-38 (1978).
- 9) Matsuyama, Y.: The α -EM Algorithm: A Block Connectable Generalized Learning Tool for Neural Networks, in J. Mira et al. (Eds.), Biological and Artificial Computation: From Neuroscience to Technology, pp. 483-492, Springer Verlag, Berlin (1997).
- 10) 甘利後一, 長岡浩司: 情報幾何の方法, 岩波書店, 東京 (1993).
- 11) 片山泰尚: 最先端ダイナミックメモリ, 情報処理, Vol. 38, No. 3, pp. 169-174 (Mar. 1997).

(平成9年7月23日受付)



松山 泰男(正会員)

1947年生。1974年早稲田大学理工学研究科博士課程修了。工学博士。同年日本学术振興会による日米交換訪問員(1978年スタンフォード大学工学研究科博士課程了; Ph.D.)。茨城大学工学部教授を経て、早稲田大学理工学部教授。計算機構一般、学習アルゴリズム、マルチメディア情報処理に興味をもっている。1992年電子情報通信学会論文賞、1998年IEEE Fellow受賞。著書「VLSI設計入門」(共立、1983)、「C言語とUNIX」(日刊工業、1986)、「コンピュータ理工学辞典」(共立、1997)他。