

# 科学

Science Journal *KAGAKU*

VOL.71 2001 別刷

---

---

岩波書店

---

■ヒト知性の計算神経科学<第5回その1>

## モザイクの拡張とコミュニケーション

川人光男 銅谷賢治 春野雅彦

まず、前回ヒトの感覚運動統合のモデルとして導入したモザイクの仕組みを振り返ろう。つぎに、モザイクを強化学習と階層モザイクに拡張する。これに基づいて、シンボルの生成、他者の内部状態の推定、および他者の意図の推定によるみまね学習がなぜ実現するのか説明できる。それによって、感覚運動統合のモデルとして提案された多重順逆対モデルが、コミュニケーションの計算モデルのためのアルゴリズムの機構を表現とハードウェア双方のレベルで提供する道筋を示すことが可能になる。

連載第4回では、ヒト知性の計算理論の出発点となる多重順逆対モデルを説明した。多種多様な道具や環境に柔軟に対処できる、ヒトのすばらしい感覚運動統合の能力は、脳内に学習によって並列に獲得された多数の逆モデルが、さまざまな行動の側面に合わせて的確に切り替えられ、組み合わせられ実現していると考えられる。

感覚と運動の入出力を統合し、複雑なヒトの動作を実現するこのしくみが、みまねやコミュニケーション、言語に共通の基盤を与えていることを示すのが、第5回の目的であり、またこの連載の核心の一つでもある。そのために、第5回はその1、その2の2回に分け、筆者たちの新しいアイデアを詳しく紹介することになった。前回の第4回(11月号(2000))で、制御工学的に紹介した、多重順逆対モデルとその拡張であるモザイクの特徴を、違った切り口でわかりやすく再度説明するところから始めよう(前回と合わせて読むとより理解しやすいだろう)。

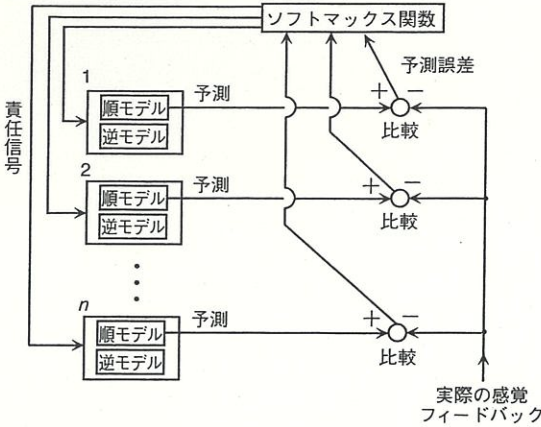
### モザイクとは何であったか

計算理論や行動実験のデータ、そして脳活動の非侵襲計測実験データに基づくと、多数の逆モデルを並列に学習し、また切り替えるために脳が用いていると考えられる有効な戦略は、一つ一つの逆モデルにそれと対となる順モデルを組み合わせること(順逆モデル対)である。多数の順モデルは、脳から身体各部の骨格筋などに送られた運動指令のコピーをそれぞれが同時に受け取って、並列に未来の感覚フィードバックを予測する。これらの多数の予測結果は、実際に得られた感覚フィードバックと比較されそれぞれの順モデルごとに誤差が計算される。この誤差からソフトマックス関数を経て、それぞれの順逆モデル対(モジュール)ごとに責任信号が計算されるのであった(図1a)。


各対の責任信号は0から1の間の値をとり、すべての対で足し合わされると1となる。ある行動の局面で、特定の対だけがよい予測をすると、その対の責任信号が1に近くなる。つまり、その対がその局面に対して単独で大きな責任をもつ。脳が送り出す運動指令は、ほとんどその対の逆モデルが計算する運動指令になる。ここでのポイント

Mitsuo KAWATO ATR 人間情報通信研究所, 科学技術振興事業団・創造科学推進事業・川人学習動態脳プロジェクト, ATR 先端情報科学研究部(国際電気通信基礎技術研究所), Kenji DOYA ATR 先端情報科学研究部(国際電気通信基礎技術研究所), 科学技術振興事業団・戦略基礎研究・脳を創る, Masahiko HARUNO ATR 先端情報科学研究部(国際電気通信基礎技術研究所)

(a) もっとも単純な多重順逆対モデル



(b) 各モジュールに責任信号予測器を追加



(c) 各モジュールの順モデルを予測器に、逆モデルを制御器に拡張




図1 モザイクへの拡張。(a)  $n$  個の順逆モデル対(モジュール)からなるもっとも単純な多重順逆対モデル。順モデルは受け取った運動指令のコピーから自らの学習の状態に応じて感覚フィードバックを予測し、逆モデルは同様に自らの学習の状態に応じて運動指令を計算する。(b) (a) のモデルに責任信号予測器を追加した多重順逆対モデル。(c) 順モデルを予測器に、逆モデルを制御器に拡張したモザイク。このような拡張によって基本的な感覚運動統合しか扱えなかったモデルが、コミュニケーションや言語などのヒトの知性まで説明できるようになるのである。

は、順モデルと逆モデルの学習は、公平かつ一様に進むのではないことだ。責任信号の大きな対の順モデルと逆モデルだけが学習し、他の対ではほとんど学習しない(モデルを構成する係数が変化しない)。これによって、特定の行動の局面に、特定の対が割り当てられ、関係ない局面で無駄な学習が生じて、それまでの学習によって獲得されてきた“記憶”が失われないようになっている。

責任信号に応じて、制御の切り替えをおこない、学習に適した対を選択することは、つぎのように自動的におこなわれる。まず、多数の逆モデルが計算する運動指令はそれぞれの責任信号で重みづけられて線形に加算され、その結果が最終的な脳の運動指令となる。上で述べた通り、特定の順モデルだけ特別予測がよければ、その対だけ責任信号は1に近く、他の対の責任信号は皆0にごく近くなる。この場合は、予測のよい順モデルと対になっている逆モデルが計算した運動指令が最終的な運動指令になる。

では、各モジュールでの学習はどう進むのだろうか。順モデルの学習に使われる誤差信号は、実際の感覚フィードバックから、おのおのの順モデルの予測を差し引いて得られるが、さらに、それに対応する対の責任信号が掛け合わされ、これに基づいて学習が進む。同様に、逆モデルの学習に使われる誤差信号は、正しい運動指令から、おの

おの逆モデルが計算した運動指令を引いた答え(フィードバック誤差学習を使う場合にはフィードバック運動指令)であるが、さらに、誤差信号に対応する責任信号が掛け合わされる。

すると順モデルの予測がよくない対の責任信号は0に近いから、掛け合わされた後の誤差信号は順モデルに関しても、逆モデルに関してもほとんど0になる。誤差信号が0では、学習がまったく進行しないので、ある行動の局面に無関係な対は、そのときまったく学習せず、他の局面では有効な記憶を保持できる。それに対して責任信号が1に近い対では、すべての責任を引き受けて、学習が進行し、それに対応した正確な運動制御が可能になる。

これが“切り替え”による学習と制御のしくみである。しかし切り替えだけでは、モジュールの数に対応した運動制御しか実現せず、ヒトのもつ多種多様な行動のレパートリーは実現しない。

### 切り替えから組合せへ

責任信号をソフトマックス関数で計算しているために、0と1だけの離散的な切り替えだけではなく、複数の対をアナログ的に組み合わせることも可能になる。たとえば二つの対の順モデルの予測が同じくらいよく、他の順モデルの予測は悪い

とする。すると、二つの対の責任信号は両者とも2分の1に近くなる。したがって、運動指令は、この二つの対の逆モデルの出力の平均になる。順モデルと逆モデルの学習はこの二つの対に関しては、一つだけで全責任をもつ場合と比べて半分の手軽さで進むことになる。他の対では学習はほとんどおこなない。

責任信号が0と1の間の中間的な値をとれることが、多重順逆対モデルで、有限個のモジュールから、無数(モジュールの数の指数関数的に多い)の行動パターンを作り出せる理由になっているのだ。

たとえば、連載第4回の図2で説明した簡単な物体操作についても一つのシミュレーションの例で説明しよう。物体は、質量、粘性、弾性の三つの物理的特性で完全に記述できるので、物体の性質とそれを表現する順モデル、逆モデルは、数学的には、それぞれ質量、粘性、弾性の3軸をもつ3次元空間の1点で表わせる。

さて、3次元空間内の四面体は四つの頂点をもつ。春野ら<sup>(1)</sup>は、四つの頂点に対応する四つの物体を操作する運動の予測と制御を、四つの順逆モデル対にまずそれぞれ学習をさせた。その後で、四面体の中に含まれる任意の物体を、この順逆対モデルに与えると、計算された責任信号の値は、物体の物理的特性を近似するために四つのモデルを線形加算する最適の係数値にごく近くなった。つまり、初めて操作を経験する物体の物理特性を四つのモジュールの出力を責任信号に基づいて重みづけて、うまく運動を予測し、物体を制御することができた。多重順逆モデル対は、単にモジュールの0,1の切り替えをおこなうだけでなく、モジュールをうまく組み合わせる能力をもっているのである。

### 責任信号予測器による 行動パターンの自律生成

ヒトは実際に運動を実行する前から、行動の側面に応じた運動プログラムを準備できる。それはなぜだろうか。これを説明するために、責任信号

予測器が、一つのモジュールに1個ずつ追加された。上で述べた簡単な多重順逆対モデルを拡張する第一歩である(図1b)。

責任信号予測器は、文脈情報に基づいて、運動が始まる前に、責任信号の推定値を計算して、どの対が選択されるべきか決定する。文脈情報とは、運動が始まる前にモジュールの選択に用いることのできる任意の情報のことであった。一般的には、さまざまな行動の側面で、視覚、聴覚、体性感覚、過去の運動指令の履歴、情動信号などあらゆる情報がモジュール選択に使われることが考えられる。ある行動の文脈でどのモジュールが適当かを指し示すので、文脈情報という用語を用いる。

たとえば春野ら<sup>(1)</sup>の物体操作では、二つの場合が研究された。第4回で説明した、順モデルの予測のよさによって、運動の後で初めてモジュールの選択が可能な基本的な学習が第1の例である。第2の例は、一つ一つの物体が異なる形状をしていて、形状のちがいを視覚的に認識して、正しい対を選べる場合である。これには、責任信号予測器の学習が必要になる。しかし、ここでは、形状と物体の物理特性の対応を陽に教えてくれる教師はいない。責任信号予測器は、ソフトマックス関数から計算された責任信号を教師信号として、自動的に形状から物理特性への対応づけを学習した。上でも説明したように文脈情報は視覚に限らない。たとえば、ヒトの脳では、つぎにどんな動作をなさよという言葉による教示も、責任信号予測器が使うことのできる文脈情報の1種になっている。

多数の責任信号予測器がその出力と入力を介して結びついたネットワークを作ると、他の責任信号予測器の出力も文脈情報の一つとなる。こうすると、多重順逆対モデルは、単に外界の変化に追従してモジュールを切り替えるだけでなく、自立的に複雑な行動パターンを生成し始める。なぜなら、責任信号予測器のネットワークは、巡回結合型の神経回路であり、一般的にいう“力学系”を構成しているからだ。このような回路に、安定な周期軌道(リミットサイクル解など)を生み出す力学系を学習によって埋め込めることが知られている。

したがって責任信号予測器を含む多重順逆対モデルは、最初にトリガー信号を与えるだけで、一連の複雑な行動パターンを自立的に作り出せる。つまり自立的に時間的、空間的にモジュールを組み合わせることができる。たとえば、ある時間帯では第1と第2のモジュールを2分の1の重みで組み合わせ、つぎの時間帯では第1と第9、第10のモジュールをそれぞれ4分の1、4分の1、2分の1の重みづけで組み合わせることが、外部のプログラムではなく、責任信号予測器ネットワークのダイナミクスとして実現できる。次回(第5回その2)に説明する、運動の時系列の学習のシミュレーション<sup>(2)</sup>もこのような性質に基づいている。

### モザイクの強化学習への拡張

モザイク(MOdule Selection And Identification Control)とは、このような多重順逆対モデルをさらに拡張したアーキテクチャである。多数のモジュール(Module)が並列に用意されて同時に働き、モジュール内の予測器の予測のよさに応じて、制御(Control)と学習(Identification)が重みづけられる(Selection)という本質はまったく変わらない。ただし、多重順逆対モデルがもっている特殊性をとりのぞいて、大事な性質だけに絞った、より広いクラスのモデルとして拡張している。またもちろんモデルの見た目が、美術工芸のモザイクと似ているというアナロジーに基づいた命名でもある。

多重順逆対モデルの特殊性とは何だろうか。それは順モデルと逆モデルにある。

順モデルはふつうは、手や目といった制御対象や外界にある道具のダイナミクスを、あるいは視覚空間の中での変換のキネマティクスをモデル化するのに用いる。しかし多重順逆対モデルでは、運動指令から感覚フィードバックが作られるまでのすべての過程の予測をおこなう。ここにはたとえば、末梢神経系、筋肉、腕、道具、センサーなどのダイナミクスとキネマティクスすべての特性が含まれているから、これらをひっくるめたものの順モデルであるともいえる。しかし、順モデル

というには、あまりにたくさんの絡み合った複合過程のモデルになってしまうので、運動指令から感覚フィードバックを計算する“予測器”であるといったほうが自然に理解いただけるであろう。

逆モデルを一般化したい方は“制御器”であるが、逆モデルに制限することで、三つの不自然ともいえる仮定をしてしまうことになる。第1に制御対象の入出力特性が逆転できるという仮定である。これは冗長自由度や複数の筋肉がある、(まさにここで問題にしている)システムでは一般に成り立たない。第2に、逆モデルに目標軌道が入力として与えられることを仮定している。これは、数種類の眼球運動に関しては正しいが、たとえば腕の到達運動に関しては、脳内に目標軌道が表現されているかどうかは、いまだに決着がつかない。第3に逆モデルの学習による獲得では、何らかの教師あり学習(フィードバック誤差学習も含めて)が生じることが仮定されているが、それでは連載第3回でも説明した他のクラスの学習を排除してしまっている。

ヒトの神経回路をよりよくモデル化するために、これらの特殊性をのぞいて、逆モデルを制御器に拡張し、順モデルを予測器に拡張したものが、モザイクなのである(図1c)。

モザイクの制御器を強化学習で獲得すると、図2に示すようになる<sup>(3)(4)(5)</sup>。強化学習とは、連載第3回で解説したとおり、報酬信号に基づいて生じる学習のことであった\*。

モザイクと連続版強化学習<sup>(6)</sup>の組合せがうまくいくことは、単振り子の振り上げを例題として示された<sup>(3)(5)</sup>。単振り子の振り上げとは、支点からつり下げられた1自由度の振り子の回転軸に大きさの制限が付けられたトルク(図3a)をうまく与えて、まっすぐ倒立した状態を実現する制御問題

\* 強化学習のアルゴリズムにはさまざまな種類があるが、どんな方法でもモザイクで使える。しかし、モザイクには予測モデルがすでに準備されているので、強化学習の中でも、Actor-Critic法や、Q学習など、制御対象の予測モデルを陽に使わないものと比べ、連続版強化学習<sup>(6)</sup>や、この後本文で説明するMLQC(Multiple Linear Quadratic Controllers)など予測モデルを用いる方法と組み合わせると、学習によって獲得した予測モデルがモジュールの選択だけでなく制御器の学習にも使えるという特徴がある。




図2 強化学習モザイク—強化学習制御器と予測器が一つのモジュールの構成要素となる。予測器の予測のよさからソフトマックス関数で責任信号を計算すること、すべての制御器からの出力を責任信号で加重して線形和をとって全体の制御出力とすること、予測器と強化学習制御器の獲得において、学習方程式の右辺に責任信号がかけられて、各モジュールの学習への寄与が決められる点などはすべて多重順逆対モデルと同じである。したがって違いは、多重順逆対モデルでは、逆モデルへの入力として目標軌道が与えられていて、運動指令の教師信号(もしくは誤差信号として用いられるフィードバック運動指令)に基づいて教師あり学習がおこなわれるのに対して、目標軌道も教師信号(誤差信号)もない条件の下で、強化学習にしたがって制御器が学習で獲得される点である。

である(図3a)。単振り子のダイナミクスは簡単ではあるが非線形であるため、制御入力の大きさに制限がある場合には、単一の線形制御器では、振り子が垂れ下がった状態から倒立させることはできない。しかし連続版強化学習モザイクは、振り子が垂れ下がった状態と倒立した状態のそれぞれのまわりに対応した二つの予測器を学習で獲得し、また、それに対応した価値関数(連載第3回参照)と制御器を学習することで振り上げに成功した(図3b)。

予測モデルをさらに直接的に利用して制御器を設計した強化学習モザイクが、MLQC法というモデルを用いたものである<sup>(3)(4)\*</sup>。

4個のモジュールを用いたMLQC法で、入れ替わりに与えられる2種類の単振り子を操作しながら、振り上げができるようになる状況をシミュ

レーションし、4個のモジュールでうまく学習が進み、分化が進んでいくかを調べた(これは非線形性と非定常性の両者がある制御問題になっている)<sup>(3)(4)</sup>。

最初1種類の振り子しか与えられないと、複数のモジュールが縮退して、同じ性質をもつようになる。しかし、第2の性質の異なる振り子を制御すると、縮退していたモジュールが分化して、二つの制御対象の非線形特性を複数の近似点でうまく分割する。じつは、これは年をとると新しいスポーツを学ぶのがむずかしくなる理由であると解釈できる。

つまり、赤ん坊のうちは行動のレパートリーは非常に限られているから、脳内のモジュールの数のほうがずっと多くて、大部分のモジュールが縮退をおこしている。ここで新しい行動(第2の振り子に相当)を学習するときは、縮退していたモジュールが分化して素早く対応できる。ところが年をとってほとんどのモジュールがそれぞれ違う目的に割り振られているときに、新しいスポーツを学ぼうとすると、すでに存在しているモジュー

\* MLQC(Multiple Linear Quadratic Controllers)法。各予測モデルは線形に限る。それぞれのモジュールの中で、報酬関数を2次関数で局所的に近似する。すると線形予測モデルと、2次報酬関数の下で、制御器は最適線形フィードバック則として(リッカチ方程式を解いて)得られる。




図3 単振り子の振り上げ。学習のシミュレーション実験では、モザイクは感覚フィードバック入力として支点のまわりの回転角速度を受け取り、制御のための信号として支点まわりのトルクを出力する。強化学習のための報酬信号は、重りをどれだけ持ち上げられたかで決まる。

ルをいったん壊して、しかもこれまでの行動のレパートリーも保たなければいけないから、モジュールの役割分担の大幅な再編成が生じなければいけないので、困難なのである。

強化学習へ拡張したモザイクは、このように行動の目的が与えられたときに、脳内でモジュール構造が自己組織される学習過程を説明できるのである。

### モザイクの階層化

ここまで拡張してきたモザイクをさらに階層化、つまり役割の異なるモザイクを並列ではなく、いくつかのレベルで重ねていくことで何が実現するのだろうか？

基本的なモザイクでは、筋肉と骨格などの制御対象と道具や環境といった外界のダイナミクスが、予測と制御の対象だった。階層モザイクでも、一番低いレベルでは、制御対象と外界のダイナミクスが、予測と制御の対象である。しかし、階層モザイクのあるレベルでは、それより一つ下のレベルを予測と制御の対象とする。このとき上のレベルが下のレベルで表現されているすべての変数を予測し、制御しようとするれば、階層構造ではなくなるので、主に下の階層の責任信号のダイナミクスが予測と制御の対象になる(図4)。

これによって、下のレベルで複数の運動プリミティブの時間的切り替えを規定する責任信号の一

つの時間系列をよく予測し制御できる行動プリミティブが、一つ上のレベルの一つのモジュールとなる。つまり、階層モザイクでは、感覚運動統合の学習を通して、さまざまなレベルで、運動と行動を階層的にモジュール化できる。

階層モザイクは、トップダウンの信号の流れ(制御)とボトムアップの信号の流れ(予測)のどちらか一方が全体のダイナミクスを支配するのではなく、両者が微妙にバランスしているところに特徴がある。

階層モザイクは基本的なモザイクとその計算原理が共通しているという意味で、神経科学の生理データや解剖データに裏付けられている(連載の各回参照)。その一方で、階層構造の上位には、複雑な行動の単位、みまねのための抽象的な表現、言語のシンボルなどヒトの知性に固有と思われる高次機能の表現が学習によって——ヒト以外の動物でよく研究されている感覚運動統合を基礎にした学習を通して——自己組織的に獲得できる。この意味で、連載第1回で主張した、神経回路や神経計算原理としては、チンパンジーやサルなどと連続していて、しかもヒトの知性を説明できる枠組みを初めて与えたことになるのである。

図4に示した下の階層は最下層であり、その入出力を通して、筋肉骨格系、外界などと直接相互作用している。しかし、それ以外の点では、ここで示す定式化は、任意の深い階層構造の中の隣合う上下の2階層に適用できる。下の階層の構造




図4 階層モザイクの基本回路図。上の階層を上付き添字Hで、下の階層をLで表わす。下の階層には三つのモジュールを、上の階層には二つのモジュールを示したが、もちろんこの数は任意である。予は予測器、制は制御器、責予は責任信号予測器を表わす。

は、基本的なモザイクと同じであるので、階層構造に由来する違いだけを説明しよう。

ここで重要な役割をはたすのが、責任信号予測器の結びついたネットワークである。各モジュールの責任信号予測器は、基本的な文脈情報  $CI^L$  以外に2種類の文脈情報を受け取る。第1は、同じ階層の他の責任信号予測器、および自分自身が出力する信号である。第2は、上の階層の、制御器が計算するより高い階層で生成される運動指令  $mc^H$  であり、これが上の階層から下の階層に降りてきて文脈情報  $CI_d^L$  として渡される。

上の階層が下の階層をより直接的に制御する極端な場合には、 $CI_d^L$  は下の階層の責任信号予測値  $\lambda^L$  を直接規定する。しかし一般的には、責任信号予測器は、3種類の文脈情報を受け取って、責任信号の予測値、いい換えれば、責任信号の事前確率を計算する。このように責任信号(二つの文脈情報を含む)によって結びついた責任信号予測器のネットワークは何を実現するのであろうか。

先に簡単に説明したように、責任信号予測器の

ネットワークは、たとえ外界と切り離されていても、相互結合によってあるダイナミクスをもつ。このようなダイナミクスが、筋肉骨格系、外界、予測器、制御器のダイナミクスと結びつくと、新たな力学系のダイナミクスがうまれる。その結果、たとえ外界の状態が定常であっても、責任信号予測器のダイナミクスによって、時間的に変化する文脈情報がつくり出され、結果として、責任信号予測器の状態も運動指令も変化する可能性がある。つまり最下層のモザイクと外界が結合したシステムは、また力学系となっているのである。

この力学系は、一つ上の階層のモザイクにとって、予測と制御の対象である。したがって、感覚フィードバックと、運動指令さえ規定すれば、上の階層の仕組みも基本的なモザイクとまったく同じことになる。つまり、上の階層で生成される運動指令  $mc^H$  は、下の階層に渡される文脈情報  $CI_d^L$  であり、上の階層に渡される感覚フィードバック  $sf^H$  は、下の階層の責任信号  $\lambda^L$  である。次回(第5回その2)で紹介する運動系列の学習の



例では、2種類の系列のどちらを選択して実行すべきかを直接、あるいは間接に示唆する言語指示、視聴覚情報などは、上のレベルの責任信号予測器への文脈情報  $CI^H$  になっている。そのために運動の実行をする前に運動系列を選択することができるのである。

### 上の階層は下の階層をどう制御するのか

上の階層は下の階層で生じていることをすべて観測するのではなく、どのモジュールが活性化されているかを表わす責任信号を受けとり、またその将来の値を予測することによって、下の階層と外界がどのような状態にあるのかについて大まかに認知し予測する。また、運動指令を直接計算するのではなく、下の階層のどのモジュールがより責任を取るべきかという文脈情報を制御して、下の階層の制御器に優先順位をつけて、最終的な運動指令に間接的に影響を与える。

しかし予測に関しても制御に関しても完全な情報を提供したりされたりしているわけではないから、完全な予測と制御はおこなえず、下の階層で生じることの多くがいわば予想外のノイズでそれにボトムアップ的に影響されることになる。

すでに述べたように、責任信号予測器のネットワークは、外界との相互作用なしに、モジュールの切り替えを自律的におこなうことができる。次回以降の予告の意味も込めて、発声発話を例にとろう。高い階層は、下の階層がおこなう調音器官への運動指令を直接規定するのではなく、例えば音韻に対応する運動制御のモジュールを選択する。

より高い階層は、例えば、単語などを指定できる。

モザイクは改良を加えられ、ヒトの知性に迫る機能を発揮しようとしている。上の階層が下の階層の責任信号の時間変化を予測するというアイデアは、谷ら<sup>(7)(8)</sup>が最初に提案した。われわれの定式化では、ボトムアップの予測の流れだけではなく制御器によるトップダウンの流れも導入した。それによって、責任信号予測器のネットワークのダイナミクスに事前確率としての責任信号推定値を加えた、トップダウンとボトムアップの相互作用による階層化が実現する。

次回(第5回その2)では、階層モザイクによる学習の実例、シンボル生成、みまねのシミュレーションを通して、感覚運動統合から言語にまで共通する計算原理を解説しよう。

### 文 献

- (1) M. HARUNO et al.: in 'Advances in Neural Information Processing Systems' Vol. 11, MIT Press(1999)pp. 31~37
- (2) M. HARUNO et al.: Soc Neurosci Abst., 25, 1910 (1999)
- (3) K. DOYA et al.: ERATO Kawato Dynamic Brain Project Technical Report(2000)
- (4) 鮫島和行ほか: 電子情報通信学会論文誌, 印刷中
- (5) 片桐憲一: 奈良先端科学技術大学院大学修士論文(1999)
- (6) K. DOYA: Neural Computation, 12, 219(2000)
- (7) J. TANI & S. NOLFI: in 'Proc of the Fifth Int Conf on Simulation of Adaptive Behavior', R. PFEIFER, B. BLUMBERG, J. A. MEYER & S. W. WILSON eds. MIT Press(1998)pp. 270~279
- (8) J. TANI & S. NOLFI: Neural Netw., 12, 1131 (1999)

## 50年前には

### 酵素化学研究の方向

…しかし一方既にあまりにも数多い酵素が我々の前に未整理のまま並んでいるではないか、もうこれ以上新しい酵素は沢山だ、すでに知られているもので充分だから、それを何とか整理する一方、その中の重要な

ものについて物理化学的に正体をつきつめて行く方が物理化学的な解析的精神に添うものではないか、というイデオロギーの酵素化学者があっても不思議ではない。(以下略) 小倉安之

[科学]第21巻第2号(1951)〈話題〉抜粋