

# 仮説推論のコストに基づく協調による時系列の理解

Understanding Sequential Events by Cost-Based Cooperation of Multiple Abducers

大澤 幸生\* 谷内田 正彦\*  
Yukio Ohsawa Masahiko Yachida

\* 大阪大学大学院基礎工学研究科  
Graduate School of Engineering Science, Osaka University, Toyonaka 560, Japan.

1996年7月23日 受理

**Keywords:** cost-based abduction, sequential events, distributed reasoning.

## Summary

Understanding sequential events is important, for recognizing a sound sequence, diagnosing a system's varying fault-states, etc. For this purpose, the underlying coherence among observed events should be grasped. However, in many cases the variation speed of events is totally unknown and unpredictable. Therefore, previously presented and prevalent inference approaches using transition probabilities cannot be employed, and also there has been no former logical inference frameworks which overcome this crucial problem. This paper presents a Cost-based Cooperation of Multiple Abducers (CCMA), for explaining sequential events reflecting underlying common causes. Here, multiple abducers, i.e., inference systems of cost-based abduction each of which is assigned to one event observed at a time, work distributedly sending messages about their obtained hypotheses-sets to adjacent abducers. This CCMA obtains underlying common causes of sequential events, even if it is unknown and unpredictable how fast the underlying situation is varying, due to the mixture of numerical messages and logical inference of abduction without parameters on continuity of events like a conditional probabilities. We estimate the performance of this CCMA, for example problems of diagnosing varying faults of electronic circuits.

## 1. はじめに

時系列として観測される事象の背後にある原因を理解することは、変化する故障状態の診断、音の理解、自然言語理解などで共通の重要な課題である。確率モデルは、そのための一つのアプローチと言えよう。例えばマルコフモデルを用いた画像 [Geman 84] や筆記文字の認識 [Chen 94]、ベイジアンネットワークによる音源分離 [Kashino 95] などでは、連続する事象間の依存の度合を遷移確率で表し、時系列としての確からしさを最大化することによって時系列全体で一貫した（コヒーレントな）原因を取り出していることになる。

しかし、これらで用いられる遷移確率は、実際には

データとして得るのが難しいことが多い。その理由を簡単に述べる。時刻  $t$  で事象  $E$  が生じたときの、直後の観測時刻  $t + dt$  で同じ事象  $E$  が生起する遷移確率  $p_c$  は、次の様に状態の変化の速さに支配される。

ケース 1) 状態変化が観測時間幅  $dt$  に対し十分速い場合 時刻  $t$  と時刻  $t + dt$  の事象は独立に近づくので、 $p_c$  は事象  $E$  の単独の生起確率  $p$  に等しい。

ケース 2) 状態変化が観測時間幅  $dt$  に対し十分遅い場合 事象  $E$  の継続時間の期待値を  $L$  とする。時刻  $t$  で事象  $E$  が生じた時に時刻  $t + dt$  で  $E$  が生起しない確率を  $dt/L$  (即ち、時刻  $t$  が継続時間  $L$  の最後の  $dt$  に含まれる確率) と見積もれば、 $p_c$  は  $1 - dt/L$  となる。

しかし、多くの場合、実際の事象の変化の速さはばらつきが大きく、事実上未知である。例えば、回路の部品への水分付着や接触不良などの故障状態は、蒸発や外力という多様な現象によって変化するから変化の速さには大きなばらつきが伴う。このような場合、観測されているのが上記のケース1と2（又はその中間）のどちらに属するかさえ不明となる。仮にケース2に属すると分かっても、 $L$ の値が不明であれば遷移確率  $p_c$  も不明となる。

遷移確率の様な一貫性の度をあらかじめ設けない手法としては、仮説推論において時系列中の観測事象をなるべく似た解仮説で説明するというもの [Ng 90] がある。しかし、後述する様にこの手法は時系列全体での原因の一貫性（以下、コヒーレンスと呼ぶ）を強く仮定しており、この仮定は状態の変化が遅い場合しか成り立たない。

従来手法のこれらの問題点を解決する為、本研究では、コストに基づく仮説推論（Cost-Based Abduction, 以下 CBA と略す）の推論システムを協調させることによってコヒーレンスを捉える。詳細は後述するが、CBA では [Ng 90] とは逆にコヒーレンスを考慮していない反面、その分速い変化の中での一つの時点での観測事象に対しても可能性の高い解仮説を選ぶことができる。本論文では、CBA における候補仮説の重み（後述）がその仮説が真となる確率の負の対数を意味することを利用した協調推論によって時系列のコヒーレンスを考慮する手法 CCMA（Cost-based Cooperation of Multiple Abducers, 以下 CCMA と略す）を提案する。具体的には、複数のアブデューサ（CBA の推論システム）がそれぞれ、時系列のうち一時点の事象の説明を行う。あるアブデューサが得た解仮説（担当した事象の説明）に含まれる要素仮説の重みをすぐ隣のアブデューサで減少させ、再び一斉に独立に仮説推論を行うという繰り返しを行った末、収束した結果を正しい理解と見なす。時系列中の事象間での遷移確率は与えないので、CCMA は状態の変化の速さが未知でも有効となる。

以下、2章で筆者らの手法の元となる仮説推論の枠組みについて述べ、3章で CCMA のアルゴリズムとその意味を示す。4章で実験結果から CCMA の有効性を解の評価から示し、5章で推論時間の評価を行う。最後に6章で結論を述べる。

## 2. 仮説推論とその解仮説の評価関数

[Poole 87, Poole 93] の仮説推論は、理論的な基盤性

と診断や設計に応用できる実用性の両面で、知識処理の重要な枠組みである [石塚 91]。はじめに、この仮説推論の基本動作を要約する。まず知識を、常に成立し他と矛盾の可能性のない背景知識  $\Sigma$  と、真偽は不明で他と矛盾の可能性を有する仮説知識  $H$  に分ける（ $H$  の要素を以下、要素仮説と呼ぶ）。このような知識ベースからある事象（ゴール） $G$  を説明、あるいは証明したいが、 $\Sigma$  からだけではゴール  $G$  を証明できないとき、 $\Sigma$  と併せて  $G$  の証明を可能とする（式 (2)）ような  $H$  の無矛盾な部分集合（解仮説） $h$  を見出す（式 (1),(2),(3)）。式 (3) の  $\phi$  は空節即ち矛盾を表す）のが仮説推論の基本動作である。

$$h \in 2^H, \quad (1)$$

$$h \cup \Sigma \vdash G, \quad (2)$$

$$h \cup \Sigma \not\vdash \phi. \quad (3)$$

一般に、ある事象  $G$  を説明する解仮説は多く存在するので、どの解を選ぶかを定めるために解の評価関数が必要となる。ここでは次の二つの評価関数に着目する。

- 1) コストに基づく仮説推論 各要素仮説に数値的の重みが付されており、含まれる要素仮説の重み（要素仮説  $\eta$  の重みを  $w(\eta)$  とする）の和（コスト）が最小となる解仮説を求める。即ち、式 (4) の  $cost$  を最小化する。

$$cost = \sum_{\eta \in h} w(\eta). \quad (4)$$

全ての要素仮説の重みを1とすれば、要素仮説を最小個数含む解仮説を選択することになり、一種の極小解仮説（他の解仮説を含まない解仮説）となる。[Charniak 90] では、重みを各仮説の真となる確率の負の対数とすれば、CBA により事後確率最大の解仮説が得られることが示された。この点は本論文で重要な役割を果たすので、次にその理由を要約する。

1. 要素仮説  $\eta$  の真となる確率  $p(\eta)$  に対し、 $\eta$  の重みを式 (5) の様に与える。

$$w(\eta) = -\log(p(\eta)) \quad (5)$$

2. 式 (5) より、解仮説  $h$  のコスト、即ち  $h$  にふくまれる要素仮説  $\eta_i (i = 1, 2, \dots, |h|)$  の重みの和は  $-\log(\prod_{i=1, |h|} p(\eta_i))$  となる。これは、要素仮説  $\eta_1, \eta_2, \dots, \eta_{|h|}$  が独立であった時にそれらが同時に真となる確率（ $h$  の事後確率に比例する）の負の対数に等しい。
3. 故に、式 (5) の様に重みを与えれば、CBA に

よって事後確率が最大の解仮説が得られる。

2) **Explanatory Coherence** [Ng 90] 式 (6) の解仮説の良さ  $C$  が最大となる解を求める。ここで、 $K$  個の連続する事象のうち、 $x$  番目を説明する解仮説と  $y$  番目を説明する解仮説の共通の要素仮説の個数を  $N_{xy}$ 、知識の規模を  $N$  で表す。

$$C = \frac{\sum_{1 \leq x \leq y \leq K} N_{xy}}{N \binom{K}{2}} \quad (6)$$

即ち、観測事象の時系列のうち、複数の観測事象を支持する要素仮説の個数を最大化するもので、簡単にいえば時系列中の事象をなるべく似た（一貫性のある）原因で説明することに当たる。

式 (5), (6) の評価関数を、時系列の説明という視点から比較してみる。まず、式 (5) ではコヒーレンスが考慮できない。時系列中の観測事象の論理積を説明する解仮説を求めることは可能であるが、それでは事象の順序という情報が抜けてしまう。又、ある時間と別の時間の一貫性が問題なので、時間変数を用いて異なる時刻を区別しただけでは解決にならない。一方、Explanatory Coherence は、事象間の一貫性を表わす遷移確率の様なパラメータを用いないので、状況の変化速度が未知でも原因を推論できるように見える。しかし、実際には強いコヒーレンスが前提となっており、これが式 (6) の  $C$  の最大化という形をとっているに過ぎない。実際、Explanatory Coherence ではコヒーレンスの弱い（変化が観測時点の間隔に比べて速い）時系列を理解する場合には、 $N_{xy}$  が 0 に近づくから解を選別できない。このように考えると、時間的な変化の速さを仮定せずに実際の事象を理解するためには、コヒーレンスの強さにかかわらず解を選別できる推論、具体的には次の性質を備えた推論が必要であることが分かる。

**性質 1)** コヒーレンスの強い部分時系列では、隣合う事象の解仮説は要素仮説を共有しようとする。

**性質 2)** コヒーレンスの弱い部分時系列では、隣合う事象の解仮説でも要素仮説を共有しない。

そこで本論文では、これらの性質を満足する時系列理解のための新しい推論手法 CCMA を提案する。

### 3. 仮説推論のコストに基づく協調

この章では、仮説推論のコストに基づく協調 (CCMA) について述べる。先にその動作を要約しておく、複数のアブデューサ (CBA の推論システム)

のそれぞれが時系列のうち一時点の観測事象の原因を推論する。この結果得られた解仮説に含まれる要素仮説  $\eta$  の重みを、すぐ隣の時点のアブデューサで 0 とし（この意味は 3.3 節参照）、又一斉に仮説推論を行うという繰り返しによる協調推論である。以下、この CCMA の原理と動作について具体的に述べる。

#### 3.1 満たすべき制約

時系列中の  $K$  個の観測事象を  $G_j (j = 1, 2, \dots, K)$  で表わす。 $G_j (j = 1, 2, \dots, K)$  について、候補仮説集合  $H$  から式 (7) から式 (9) の制約を満たす部分集合  $h_j (j = 1, 2, \dots, K)$  を求める。

$$h_j \in 2^H, \quad (7)$$

$$h_j \cup \Sigma \vdash G_j, \quad (8)$$

$$h_j \cup \Sigma \not\vdash \phi. \quad (9)$$

$\Sigma$  は式 (10) の様なホーン節を集めた背景知識とする。ここで、 $x_1, x_2, x_3, \dots, x_n$  は条件、 $y$  は結論を意味するアトムで、本論文ではそれぞれ原因と結果を表わす。 $H$  の要素仮説もこの様なアトムとして表現する。

$$y : -x_1, x_2, x_3, \dots, x_n. \quad (10)$$

式 (10) で、 $y$  が空節  $\phi$  であれば、前件部が矛盾することを意味し、この矛盾は式 (9) で禁止されている。即ち、同一の時刻での事象間の矛盾の発生を禁止する制約である。実際には、異なる時刻の事象間でも矛盾の可能性があるが、ここでは状態の変化の速さの未知な時系列を扱う点に注意されたい。即ち、時刻  $t$  で北に向かって走っている車が瞬時に U ターンをして直後の時刻  $t + dt$  で南に移動しているという場合さえ許さなければならず、この両時刻の事象は矛盾として禁止できない。従って、同時生起する事象の間の矛盾に限り禁止する。

CCMA では、異なる時刻の事象間の一貫性を、先に要点を述べた様に協調推論によって実現する。これは、制約ではなく推論という情報の流れによって実現するものなので、改めて次の 3.2 節で具体的に述べる。

#### 3.2 CCMA のアルゴリズム

CCMA では、次の様に推論する。まず、各時点のゴール (観測事象) にそれを説明するアブデューサ (CBA の推論システム) を割り当てる。同時に起きた複数の事象については、それらの論理積を一つのゴールとする。 $j$  番目のアブデューサで式 (7)~(9) の制約を満たす解仮説  $h_j$  を得、アブデューサ間で解仮説の情報を互いの要素仮説の重みへの影響としてやり取りすること

表1 あるサイクルでの  $\eta_{ij}$  と  $t_{i(j-1)} + t_{i(j+1)}$  に対する、次のサイクルでの  $w_{ij}$

$t_{i(j+1)} + t_{i(j-1)}$ State of $\eta_{ij}$	0	1	2
reactive period	$w_{ij}$	0	0
relative refractory period	$w_{ij}$	$w_{ij}$	0
absolute refractory period	$w_{0ij}$	$w_{ij}$	$w_{ij}$

によって、協調的にコヒーレンスの理解に達する。正確には下のアルゴリズムに従う。ここで、 $t_{ij}$  と  $w_{ij}$  はそれぞれ、 $j$  番目のアブデューサ（観測事象  $G_j$  を説明する）の  $i$  番目の要素仮説  $\eta_{ij}$  の、真理値（真:1, 偽:0）と重みである。真理値が1の要素仮説の集合が解仮説となる。

#### CCMA のアルゴリズム

1.  $k = 0$ .
2.  $k = k + 1$ .  $j$  番目のアブデューサでゴール  $G_j$  に対する最適（コスト最小）解  $h_j$  を得る。 $t_{ij}$  が1となれば、現（第  $k$ ）サイクルを  $\eta_{ij}$  の絶対不応期（absolute refractory period）とする。 $t_{ij}$  が0で、直前（第  $k-1$ ）サイクルが  $\eta_{ij}$  の絶対不応期であったなら、第  $k$  サイクルを  $\eta_{ij}$  の相対不応期（relative refractory period）とする。それ以外では、第  $k$  サイクルを  $\eta_{ij}$  の反応期（reactive period）とする。
3.  $w_{ij}$  を表1の通り変更し、2へ。変更すべき  $w_{ij}$  がなければ終了。

表1は、第  $k$  サイクルでの  $t_{i(j-1)} + t_{i(j+1)}$ ,  $\eta_{ij}$  の状態の組み合わせに対する、直後の第  $k+1$  サイクルでの  $w_{ij}$  を表わしている（例えば、“ $w_{ij}$ ”は  $w_{ij}$  が第  $k$  サイクルでの値に留まることを意味する）。表1に示すように、第  $j$  アブデューサの推論結果で  $t_{ij}$  が1（ $\eta_{ij}$  が真）になると、 $\eta_{ij}$  が1サイクルの絶対不応期に入り、この期間は  $t_{i(j-1)}$  と  $t_{i(j+1)}$  が共に1になったとしても（即ち、両隣が  $\eta_{ij}$  を真であると主張しても） $w_{ij}$  は減少しない。しかも、 $t_{i(j-1)}$  と  $t_{i(j+1)}$  が共に0となれば、現在の  $\eta_{ij}$  への信念は隣のアブデューサが支持しないものと諦めて、第1サイクルの開始時の重み  $w_{0ij} (\geq w_{ij})$  に戻る。絶対不応期の直後の1サイクルは、 $\eta_{ij}$  は相対不応期に入る。相対不応期には  $w_{ij}$  は、 $t_{i(j-1)}$  と  $t_{i(j+1)}$  の両方が1のときだけ0と

なる。1サイクルの相対不応期が終わる  $\eta_{ij}$  は、 $t_{i(j-1)}$  と  $t_{i(j+1)}$  のどちらか片方が1であれば  $w_{ij}$  が0になる反応期に戻る。この様に不応期という期間を設ける理由については、3・4節に述べることにする。

#### 3・3 CCMA の動作の意味

式(5)により、CBAにおいて仮説の重みを0とすることは、その仮説の真となる確率を1とすることに当たり、これは近隣のアブデューサの推論結果を信じることを意味する。即ち、CCMAの操作の意味を2章末尾の性質1), 2)と対応付けて言えば、各アブデューサは

1) 隣接する（直前か直後の）事象のそれぞれのアブデューサによる説明を、とりあえずそのまま信頼する。

2) 隣接アブデューサによる説明を信じるよりも自分の推論結果の方が自分の観測した事象にふさわしい場合は、自分の解仮説を優先する。

ということになる。例えば、観測時刻  $t_1, t_2, t_3 (t_1 \leq t_2 \leq t_3)$  のそれぞれに、 $G_1$ （小さなモーター音）、 $G_2$ （中ぐらいのモーター音）、 $G_3$ （大きなモーター音）という三つの音を聞いたとする。これを、次の簡単な背景知識  $\Sigma$  と仮説知識  $H$  を用いて理解することを考える。

$\Sigma$   $G_1 : -bike_{running}, road_{is\ far}.$

$G_1 : -compressor.$

$G_2 : -bike\ is\ running, road\ is\ not\ far.$

$G_2 : -shaver.$

$G_3 : -bike\ is\ running, road\ is\ near.$

$H$   $bike\ is\ running, shaver, compressor,$

$road\ is\ near, road\ is\ not\ far, road\ is\ far$

この知識を、図1の様なグラフ表現で表わすことにする。例えば、図1の節Aは  $\Sigma$  の最後のルールを意味する。この3つの音を理解するCCMAの動作の様子を図2に示す。図2で、サイクル1では、解は  $h_1$ : compressor,  $h_2$ : shaver,  $h_3$ : bike is running, road is near となるので、メッセージが点線矢印の向きに伝達する。ここで、アブデューサ3から左に向けて bike is running の重みが0とされて行き、サイクル3の解を得る。サイクル3からはCCMAのアルゴリズムのステップ3で重みを変更されないので推論は終了する。サイクル3の解は、バイクが走っている（bike is running）という一貫した仮説を用いて3つの観測事象全てを理解している。

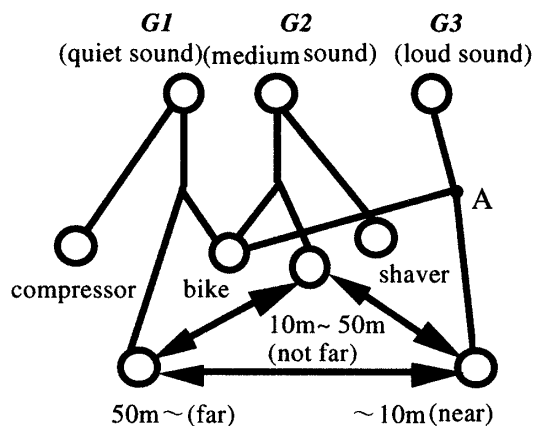
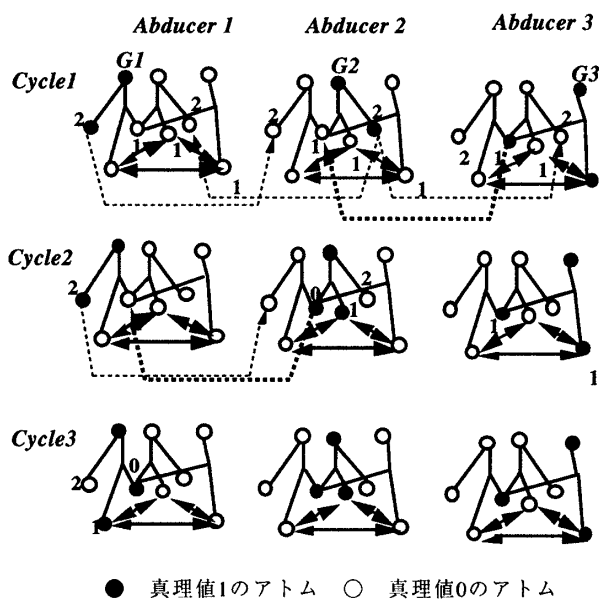


図1 3つのモーター音の例についての知識のグラフ表現



● 真理値1のアトム ○ 真理値0のアトム

図2 図1の例についてのCCMAによる推論過程

CCMAでは、要素仮説の初期重みは与えるから原因の事前確率だけは用いることになるが、時系列中の事象間の遷移確率は与えない。従って、CCMAは状態の変化の速さが未知でも適用可能となる。又、状態(原因)の変わり目になると、重みが低くても観測事象を説明できない仮説は却下されるので、遷移確率などで事象間の一貫性の強さを定義しなくても多くの場合この変わり目を正しく得ることができる(4章の実験参照)。

### 3・4 CCMAの不应期の意味

CCMAにおける不应期の役割は、CCMAが協調推論を行うために生ずるデッドロックを回避することである。ここで言うデッドロックとは、CCMAの全体又は一部が以前と同じ状態に戻ってしまうために推論が先に進まない状態をいう。LMO [平山 95]では、山登

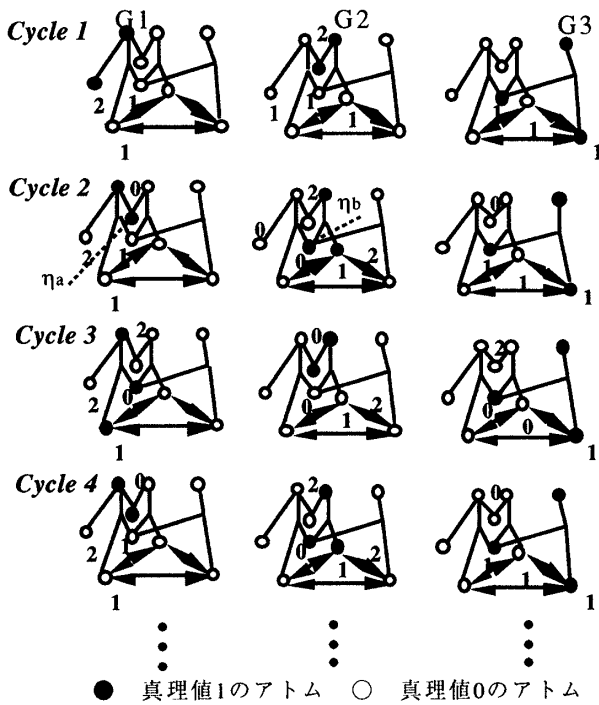
り法による分散CSPにおいて、変数値を変更するエージェントを絞ることによってデッドロックを回避している。しかし、CCMAにおいては、事象の原因を誤って理解したエージェント(アブデューサ)がどれであるかは推論中不明であるので、解を変更すべきアブデューサを早期に絞ることはできない。そこで、CCMAで用いるデッドロック回避の新技术が不应期である。

不应期という名称は、神経科学における同名の機構にちなんでいる。神経生理学における不应期とは、神経細胞が発火直後に周りの神経細胞からの影響を受け付けない期間である。神経細胞の膜は、通常反応期では周囲の神経細胞からの入力 $S$ がしきい値 $\theta_1$ を超えると興奮し、その後ある期間、周囲からの入力に全く反応しない絶対不应期に入る。更にその後、 $S$ がしきい値 $\theta_2$  ( $\theta_1 < \theta_2$ )を超えた時だけ反応する相対不应期を経て反応期に戻る。CCMAの不应期は、神経細胞 $\leftrightarrow$ 要素仮説、 $w_{ij}$ の減少 $\leftrightarrow$ 神経細胞の興奮、 $t_{ij} \leftrightarrow$ 他の神経細胞への出力と対応づけると、神経細胞の不应期と類似が見られる。

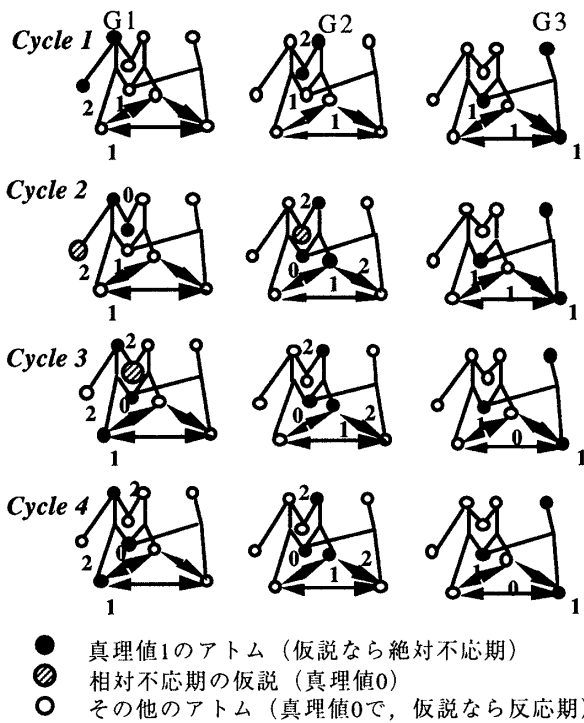
例を用いてCCMAの不应期の働きを説明する。図3-aは、不应期を用いずどの仮説も常に反応期とした場合のCCMAの動作で、デッドロックが生じている(図1に無かった仮説 $\eta_a$ に注意)。即ち、 $\eta_a$ はサイクル2で $G_1$ を説明する解仮説の要素となり、その影響でサイクル3では $\eta_a$ は $G_2$ の解仮説に含まれる。その後サイクル4で、この影響が $G_2$ の解仮説から $G_1$ を説明するアブデューサに伝播するため、再び $G_1$ で $\eta_a$ が解仮説に入る。この結果、サイクル2とサイクル4では各アブデューサの各仮説が全く同じ重みと真理値をとることになるので、ここに周期が2サイクルの循環が生じ、CCMAは収束に向かわなくなる。この現象の原因は、次の2点に縮約できる。

- 1) あるアブデューサAが隣のアブデューサBに伝えたメッセージ(重み減少)が直後にAに戻ってしまうので、Aは以前の自分の信念(解仮説)を信じやすくなる。
- 2) アブデューサAの片隣のアブデューサでのみ真となった仮説でも、両隣で真となった仮説でも、次のサイクルでAの重みが0となるために、密に信じられた(近傍のアブデューサの多くで真な)仮説(図3では $\eta_b$ )と疎に信じられた仮説(図3では $\eta_a$ )を区別できなくなる。CCMAでは密に信じられる仮説に解が収束するので、これでは収束しにくい。

この2つの問題点を解決する方法が相対不应期と絶対不应期である。即ち、絶対不应期ではアブデューサ



a. 不応期なしのCCMA.



b. 不応期を用いたCCMAのデッドロック解消.

図3 図1に仮説  $\eta_a$  が加わった例に対する CCMA の推論過程

A が、自分が以前に真とした仮説についての隣のアブデューサ B の信念を無視するから、1) への対策となっている。かつ、相対不応期は、ある仮説を真とするメッセージが両隣から伝わると反応し、片隣から伝わるのみでは反応しないという差別によって、信念の疎密が区別できるので 2) への対策である。図 3-a における

デッドロックが、b では CCMA のアルゴリズムにおける不応期の適用によって解消されている。

神経生理学では、不応期のメカニズムは解明済みである [Koester 85] が、それが何の役に立っているかは未解明である。自然現象の目的を解釈するのがこの論文の目的ではないが、CCMA では類似の作用が協調推論のデッドロックを防ぐ効果を発揮するのは興味深い。

### 3・5 不応期の長さの設定

不応期を全く使わなければデッドロックが多くなる。逆に、常に不応期とすると、協調なしの CBA と同様の結果 (4・3 節参照) になる。しかし、これらは極限のケースであり、必ずしも不応期が長いほど収束性が良く、推論が不正確になる訳ではない。何故なら、不応期が終わり次第隣のアブデューサからのメッセージを受け付けるのであれば、あるアブデューサの不応期が終わるまで周囲も同じ長さの不応期でゆっくり変化するので、推論結果は不応期の長さによって劇的には変化しないからである。実際に 4・2 節の例題 1 について不応期を変化させた実験を行なってみたが、相対不応期と絶対不応期のそれぞれの長さを 1 から 10 までテストした範囲では 4・2 節に示す解が得られた。むしろ、不応期が長いと推論に時間がかかることの方が切実となるので、このテストにおいてデッドロックが抑えられた範囲で最も不応期の短い、絶対不応期も相対不応期も共に 1 サイクルとする設定を選んだ。この設定で行った 4・2 節の例題 2 に対する実験では、デッドロックが生じたのは 100 ケース中 2 ケースのみであった (それらも状況の切れ目を或る隣り合う 2 時点のどちらにするか交互に入れ替え続けるものであったから、途中で推論を打ち切っても十分コヒーレンスは捉えられる)。

尚、絶対不応期と相対不応期のいずれか一方でも長さ 0 とすると、4・2 節の例題 1 で収束せず、推論を打ち切ることになった。このことから筆者らは、両方の不応期が 3・4 節のデッドロックの原因を解決する上で重要な役割を果たすと考えている。

## 4. 故障診断における CCMA の評価実験

### 4・1 実装と例題

現在は、SparkStation10/50GTX (64MB) 上で C 言語により CCMA の逐次型の実装を行っている。例題として、図 4 の様な全加算器の回路の故障診断に、CCMA とその他の手法を適用した (これらの比較は 4・3 節参照)。背景知識  $\Sigma$  は回路素子の動作について




図4 全加算器における接触不良の例。  
 $x(x_1, x_2, \dots, x_n) + y(y_1, y_2, \dots, y_n) = z(z_1, z_2, \dots, z_n)$  の回路で、この場合はPの接触が問題となっている。

の知識をホーン節として記述したものであり、その中には端子の接触、不接触を考慮したものも含まれている。例えば、 $Q \text{ in } 1 \text{ is off} : -P \text{ is ok}, R \text{ is on.}$  というホーン節で「端子Rの電圧がon ( $R \text{ is on}$ )で、端子Pの接触が正常 ( $P \text{ is ok}$ )であれば、ゲートQの第一入力端子の電圧はoffである ( $Q \text{ in } 1 \text{ is off}$ )」という知識を表現する。観測事象の時系列として、例えば式(11)の様な誤計算を含む入力-出力のペアの時系列が与えられる。

$$\begin{aligned}
 G_1 : 110 + 001 &= 101 & G_2 : 11 + 100 &= 101 \\
 G_3 : 1 + 101 &= 110 & G_4 : 110 + 1 &= 111 \\
 G_5 : 10 + 101 &= 111 & G_6 : 10 + 10 &= 100 \\
 G_7 : 101 + 10 &= 101 & G_8 : 10 + 0 &= 0
 \end{aligned}
 \tag{11}$$

ただし、 $G_1, G_2, \dots, G_8$  は、連続する8時点の入力(左辺)と出力(右辺)を順に表わした時系列である。

#### 4・2 CCMAによる例題の解

式(11)の観測事象を説明する例題(例題1)に対し、CCMAはPが $G_4$ と $G_5$ だけで接触しており、それ以外で不接触と推論した。次に、3ビットまでの全加算器に対して1箇所か2箇所だけの接触不良をランダムに与えた問題(例題2)について評価実験を行った。例題2では、素子の故障による異常出力が観測される時点で、推論結果と与えた故障原因が全て一致した。又、故障部分が実際の入出力に関与しない時点で正常と推論されたり、逆に観測される入出力に関与しない異常があるものと誤解されることがあったが、これらは故障時と非故障時の境界の直前又は直後に限られた。この程度の誤差ならば、故障箇所とその変化の度合を知るのには十分な精度といえる。従って、例題1,2に対してCCMAは状態の変化とその境界を正しく理解し

たと言える。4・3節ではこの結果を、他の手法と比較してみる。

#### 4・3 他の手法との比較

例題1,2は、CCMAが解こうとする、故障の継続時間が推論前には予想できない為に遷移確率を与えることの出来ない問題の例となっている。以下で、これらの問題についてCCMAと他の手法との性能比較を行う。

##### ・ Explanatory Coherence [Ng 90] との比較

[Ng 90]の評価関数を用いた仮説推論を用いると、例題1では、全ての時点でPが不接触で、正常動作をしている時間( $G_4, G_5$ )は出力がその値に固定されるという別の故障状態と診断された。又、例題2のうち、2箇所の故障原因が存在する71例中で、両方の故障が全ての時点で続いていると診断された例が16例、片方の故障が全ての時点で続いておりもう一方は解仮説に現われない診断が42例で、他の全ての例で、どちらでもない故障が時系列全体で続いていると判断された。これは、強いコヒーレンスが前提であるために、正常/異常の変わり目が見過ごされたと考えられる。

・ CBA との比較 各時点の観測事象をCBAによって別々に診断すると、多くの例で、同じ原因による故障状態が異なる故障と誤解された。例題2では1箇所又は2箇所の故障原因を与えたが、CBAでは5箇所から8箇所の原因が入れ替わり現れる変化の速い時系列と誤診された。

以上の結果から、CCMAは従来手法よりも正しく状態の変化を理解する能力があることが分かる。一方、CCMAに似た分散型の推論としては、アブデューサAの解仮説 $h_a$ 中の要素仮説を隣のアブデューサBで真に固定する方法が考えられる。しかし、これでは実際の状況によらず隣接アブデューサ間で同じ仮説を信じ合うという、静的な組織上での整合性[Durfee 87]が要求され、観測事象の原因の変わり目でも $h_a$ と矛盾する要素仮説はBで解に含められない。そこで、全ての隣接アブデューサのペア(A,B)について、Bで(Aで)真に固定する $h_a$ の( $h_b$ の)部分集合を網羅的に試行し、両アブデューサの解仮説 $h_a, h_b$ の和集合が最小となる固定の仕方をサイクル毎に選ぶという反復を行うと、CCMAと同等の精度が得られた。この手法(手法Zと呼ぶ)とCCMAの比較は、5章にて推論時間の評価で行う。

## 5. CCMA の推論時間

CCMA の推論時間は、(観測時点の数  $K$ ) × (サイクル数) × (一つのアプデューサの平均推論時間) となる。以下、このうち最後の二項を見積ってみる。

- 推定されるサイクル数 任意の(重み減少の)メッセージが伝播し始めてから消滅する(仮説の重みを減少させられず行き止まる)までのサイクル数がこの項に当たる。要素仮説  $X$  から伝播するメッセージは、実際に  $X$  が生起している時点のアプデューサで他の解仮説に勝ち抜くと隣に伝播する。従って、サイクル数は高々メッセージが時系列の端に到達するまで、即ち時点数  $K$  程度と見積る。
- 推定されるアプデューサの推論時間 分散型の信念管理機構として見ると、従来の分散 TMS [Bridgeland 91, Mason 89], 分散 CSP [横尾 92] などと異なり、CCMA の各アプデューサは準最適な単一の解を求めれば良い。ここで準最適解とは、厳密な最適(コスト最小)解であることは保証されないが、最適解との差(コストの差や順位など)が許容範囲内の解である。CCMA の場合、各アプデューサが独立に得る解は最適解からの誤差を含む準最適解であっても、各アプデューサが近隣のアプデューサの解に引き寄せられる形で協調的に収束し、正しい解に接近する。これは、曖昧な信念を持った人が多く集まると、話し合っているうちに固い信念が生まれるのと似た傾向である。そこで、求める解を準最適解に妥協すれば、NP 完全である CBA に対して準最適解を求める近似解法(NBP 法 [大澤 94])によって多項式時間の推論が可能となる。NBP 法では要素仮説数  $|H|$  に対して  $O(|H|^2)$  の推論時間が達成できるので、筆者らは CCMA の各アプデューサとして NBP 法による仮説推論システムを用いている。

以上から、本システムによる推論時間は高々  $O(K^2|H|^2)$  のオーダーと予想される。例題 2 に対する計測結果は図 5 の通りとなった(ドット一つが 9 例の推論時間の中央値である)。CCMA の推論時間は  $O(K^2|H|^2)$  の理論線(図 5 実曲線)より少し小さい程度で、上の見積りを裏付けている(一ビット分の加算器は 17 個の仮説を含むので、ビット数が仮説数に比例する)。

- 手法 Z (4 章末尾) との比較 CCMA と同程度の精度の解が得られる手法 Z では、4 章末尾で述べた  $h_a$  と  $h_b$  の部分集合を網羅して和集合を求




図 5 CCMA と手法 Z (図中 Method Z) の推論時間

める時間が  $2^{|h_a+h_b|}$  に比例する。従って、NBP 法を用いても推論時間は(サイクル数) × (隣接ペアの数:  $K-1$ ) ×  $2^{|h_a+h_b|}$  ×  $O(|H|^2)$  となる。又、不応期を用いない為メッセージの逆戻りが生じる場合があり、サイクル数は CCMA より大となる。同じ理由からデッドロックに陥ることも多いが、それ以外の場合の推論時間を CCMA 同様にプロットすると図 5 の × 印のプロットとなり、CCMA に比べて著しく遅い。この結果から、CCMA は同精度の解仮説を得る手法と比較しても、推論速度の面でまさる有効な推論手法といえる。

## 6. 結 論

CCMA は、変化の速さが未知の時系列を理解しようという目的から、複数のアプデューサを CBA のコストに基づいて協調させたものである。どの仮説をアプデューサ間のリンクとする(共通に信じる)べきかが未知な場合にそれを観測から推論する CCMA の機能は、協調探索において新たな環境に適應する為の自己組織化 [Ishida 92] の一つの形とも言える。協調推論の手法の中では、[大澤 94] の高速近似解法を使用可能とし、仮説の重みを下げるという極めて簡単なメッセージを用いることによって高速で高精度な推論を達成した点が CCMA の特徴である。今後は CCMA の並列化により、より大規模で実用性の高い問題への応用を実現したい。尚、CCMA では知識ベース外の原因までは特定できないので、本論文では知識ベースに書かれ



ていないノイズが観測事象を変える程に外界に開かれた系は扱っていない。しかし、ノイズ自体を取り出すのでなく、ノイズ下でも本質的な原因を洗い出せる耐性は分散協調処理に基づく情報統合により強化されるので[松山 93]、現象の本質的な因果関係を知識として協調推論を行う CCMA のノイズへの耐性も興味深い検討事項である。

## 謝 辞

本研究を進める上で、意義深いコメントを常日頃頂きました東京大学の石塚満先生と東京工業大学の山田誠二先生に感謝します。又、査読者の先生より大変有益なコメントを頂きましたことを、記して感謝します。

## ◇ 参 考 文 献 ◇

- [Bridgeland 91] Bridgeland, D.M. and Huhns, M.M.: Multiagent Truth Maintenance, IEEE Trans. SMC, Vol.21, No.6, pp.1437-1445 (1991).
- [Charniak 90] Charniak, E. and Shimony, S.E.: Probabilistic Semantics for Cost Based Abduction, Proc. AAAI-90, pp.106-111 (1990)
- [Chen 94] Chen, M. et al.: Off-Line Handwritten Word Recognition Using a Hidden Markov Model Type Stochastic Network, IEEE Trans. PAMI, Vol.16, pp.481-496 (1994)
- [Durfee 87] Durfee, E.H., Lesser, V.R., and Corkill, D.D.: Cooperation through communication in a distributed problem solving network, M.N. Huhns (Ed.), Distributed AI, New York: Pitman, pp.29-58 (1987)
- [Geman 84] Geman, S. and Geman, D.: Stochastic Relaxation, Gibbs Distribution, and the Bayesian Restoration of Images, IEEE Trans. PAMI-6, pp.721-738 (1984)
- [平山 95] 平山, 山田, 豊田: 山登り法を用いた分散制約充足における組織化, 人工知能学会誌, Vol.10, No.1, pp.80-87 (1995).
- [Ishida 92] Ishida, T.: Tower of Babel: Towards Organization-Centered Problem Solving, 11th Distributed AI Workshop, pp.141-153 (1992)
- [石塚 91] 石塚満: 次世代エキスパートシステム (石塚, 小林編) 第7章, 丸善 (1991).
- [Kashino 95] Kashino, K, et al.: Organization of Hierarchical Perceptual Sounds: Music Scene Analysis with Autonomous Processing Modules and a Quantitative Information Integration Mechanism, Proc. IJCAI'95, pp.158-164 (1995).
- [Koester 85] Koester, J.: Voltage-Gated channels and the Generation of the Action Potential, Principles of Neural Science, 2nd ed. (Kandel, E.R., and Schwartz, J.H. eds.) Elsevier, Part2, pp.75-86 (1985).
- [Mason 89] Mason, C.L. and Johnson, R.R.: DTMS: A Framework for Distributed Assumption Based Reasoning, (Gasser, L. and Huns, M.N. eds.), Distributed AI, Morgan Kaufmann, Vol.2, pp.293-318 (1989).
- [松山 93] 松山, 和田: 画像理解のための分散協調処理—領域分割問題を一例として—マルチエージェントと協調計算 3, 日本ソフトウェア科学会 MACC'93 (奥野編), 近代科学社 pp.1-18 (1993).
- [Ng 90] Ng, H. and Mooney, R.: On the Role of Coherence in Abductive Explanation, Proc. AAAI'90, pp.337-342 (1990).
- [大澤 94] 大澤, 石塚: 仮説推論における準最適解を多項式時間で計算するネットワーク化バブル伝播法, 信学論, Vol.J76-D-2, pp.1817-1829 (1994).
- [Poole 87] Poole, D., Aleliunas, R. and Goebel, R.: Theorist : A Logical Reasoning System for Defaults and Diagnosis, in the Knowledge Frontier : Essays in the Knowledge Representation (Cerccone, N. J. and Macalla, G., eds.), Springer-Verlag, NY (1987).
- [Poole 93] Poole, D.: Probabilistic Horn Abduction and Bayesian Networks, Artif. Intell., pp.81-130 (1993).
- [横尾 92] 横尾, Durfee, E.H., 石田, 桑原: 分散制約充足による分散協調問題解決の定式化とその解法, 信学誌, Vol.J-75 D-1, pp.704-713 (1992).

[査読者: 樫木哲夫]

## 著 者 紹 介

大澤 幸生(正会員)は, 前掲 (Vol.12 No.3, p.373) 参照.

谷内田 正彦(正会員)は, 前掲 (Vol.12 No.2, p.331) 参照.