

TM-1034他

第13回 知能システムシンポジウム
発表論文集

March, 1991

© 1991, ICOT

ICOT

Mita Kokusai Bldg. 21F
4-28 Mita 1-Chome
Minato-ku Tokyo 108 Japan

(03)3456-3191~5
Telex ICOT J32964

Institute for New Generation Computer Technology

- TM1034 深い知識に基づく制御用エキスパート システムー定性的因果モデルとクラスタリングによる診断機構の開発ー 岩政 幹人、鈴木 淳三、
持地 繁 (東芝)
- TM1039 知識獲得支援グループウェアGRAPE ー同期・遠隔ツールから発想支援ツールへー 國藤 進、上田 晴康、
岩内 雅直、大津 建太
(富士通)

深い知識に基づく制御用エキスパートシステム ー 定性的因果モデルとクラスタリングによる診断機構の開発 ー

岩政 幹人* 鈴木 淳三* 持地 繁**
(株)東芝 *システム・ソフトウェア技術研究所 **府中工場

1 はじめに

火力発電所等のプラント制御を目的としたエキスパートシステムでは、予め与えられた if then ルールに代表される明示的な制御知識で取り扱えない様な異常（不測の異常と呼ぶ）に対応する柔軟な制御機構が要求されている。我々は、この問題に対し、プラントの構造、物理現象等の深い知識を用いたプラント制御を提唱し、研究を行なってきた [鈴木 90][小沼 90]。本報告では特に制御用エキスパートシステムにおける定性的因果モデルを用いた診断機構について述べる。

我々は、不測の異常の原因を、故障による因果関係の正常状態からの逸脱と、外部パラメータあるいは設計パラメータの予期せぬ変化の2種類に分類して、これらを発見することを診断の目的とした。深い知識としては、正常状態のプラント内で発生する物理現象等を定性的にモデル化した定性的因果モデルを用いる。

定性的な推論は、人間のエキスパートの不測の事態における思考過程と親和性があると同時に、推論過程や結果が人間に理解が容易である。またプラントの状態を離散的に取り扱うので推論がシンボリックに実行できる利点がある。

我々は既にこの定性的因果モデルを用いた診断に「局所定性伝播」と呼ぶ推論ノウハウを導入して効率良く診断を行なう手法を開発している [岩政 90]。しかし、定性的な組合せ爆発を回避するために、多重故障を同時に扱えない等の制約がある。

一方、診断問題において、徴候に対する可能な原因集合が明らかな場合、全ての観測された徴候を用いて多重故障を同時に推論する手法として「徴候クラスタリング」がある [T.D.Wu, 90] [J.Reggia 90]。しかし不測の事態においては徴候に対する原因集合は明らかではない。

本報告では、定性的因果モデルを用いた局所定性伝播と徴候クラスタリングを融合して、各々の問題点を解消した新しい診断機構について説明する。この診断機構によって、不測の事態における多重故障の同時推論が可能となる。

2 システム構成

図1に制御用エキスパートシステムのシステム構成を示す。

正常時推論機構は従来の if then 型の制御知識に基づく制御を行ない、不測の異常が発生したら異常時推論機構を起動する。




図1: 制御用エキスパートシステム システム構成

異常時推論機構は、診断部、詳細検証評価系で構成される。診断部は定性的因果モデルに基づいて異常の原因を推論し、詳細検証評価系は診断結果に対する対策操作を導出して導出された対策操作が有効であるかどうかをプラントの動特性モデルに基づき検証評価する [鈴木 90]。有効であると認められた対策操作は正常時推論機構に渡されプラントを制御する。操作結果は評価され異常が回避されなかった場合には診断部が再起動され上記の対策操作の導出処理が繰り返される。

本報告で説明する診断機構は診断部に盛り込まれている。診断部は図2に示すように、並列定性伝播部、クラスタリング部、評価部の3つの機能モジュールで構成され、並列定性伝播部は定性的因果モデルに基づき、異常の原因を定性的に推論する。クラスタリング部は並列定性伝播部の推論結果を基にクラスタリングを行ない、それを評価部によって評価して、診断結果を得る。




図 2: 診断部システム構成

3 定性的因果モデルに基づくプラント診断

3.1 定性的因果モデル

我々は定性的因果モデルに基づいて診断を実行する。ここで定性的因果モデルとはプラントの正常時の挙動を定性的にモデル化したものであり、予めプラントパラメータ間の定性的な因果関係は明らかであるとする。このモデルは、図3に示すように1つの結果パラメータに対して定性的に因果関係のある原因パラメータとその定性的な関係について記述される。このモデルを用いると微候として観測されるプラントパラメータの正常値からのズレ（定性偏差）の原因がどのパラメータの定性偏差であるかが、パラメータ名と定性値をキーワードにした探索によって推論できる。

関係式名	R
結果パラメータ	A
原因パラメータ	因果 = + B - C




図 3: 定性的因果モデル

モデルは結果パラメータと原因パラメータの一对多関係であり、必要な定性関係は全てこの一对多関係によって記述されるとする。このモデルは非常に単純な構造をしており、このモデルを用いた推論においてループが発生したりする可能性がある。ループについては、推論自身がループの検出と回避を行ない、モデル記述はループに配慮しなくて良いメカニズムを導入する。

3.2 局所定性伝播

我々は推論アルゴリズムとして局所定性伝播を提唱してきた[岩政 90]。局所定性伝播は、微候（1つ）

に対して定性的因果モデルを利用した定性伝播を行ない、全ての関係する定性的因果モデルとそのパラメータの定性値を解として収集するメカニズムである。いま定性モデル M （関係式 R 、結果パラメータ A の定性値 $= [+]$ ）が微候 $m = [+]$ の解の1つとして得られたとすると、これは「関係式 R が不測の異常のため成り立たなくなり、パラメータ A に定性偏差 $[+]$ が発生して、その結果微候 $m = [+]$ が生じた可能性がある」ことを意味する。また定性伝播の方向は結果から原因の方向であり、原因の組合せの爆発を回避するために定性値の計算を局所的に実行する。図4の例で説明する。

$A = [+]$ の原因を推論するときにパラメータ B, C の定性値の組合せを考慮しながら伝播を進めていくと最終的な可能な定性的原因の組合せは爆発的に増大する。そこで図4に示すように $A = [+]$ の原因を $B = [+]$ あるいは $C = [-]$ であるとして推論を $B = [+]$ と $C = [-]$ の2つのコンテキストに分岐させて進める。 $A = [+]$ の推論結果は2つのコンテキストの推論結果の OR となる。また各コンテキストは独立であり、コンテキスト1で $B = [+]$ コンテキスト2で $B = [-]$ が推論されても矛盾とは見なさない。すなわち伝播の目的はプラント全体の定性的な状態の推論でなく定性モデル毎に局所的に定性値を計算、伝播を行なって一つのパラメータ（例では $A = [+]$ ）の可能な原因全てを探索することになる。これを局所定性伝播とよぶ。




図 4: 局所定性伝播

局所定性伝播の問題点は以下に示す2点である。

1. 多重故障を一度に診断できない
定性的な組合せを考慮しないのでプラント全体の定性的な状態は推論できない。
したがって多重故障に対しては故障の1つを診断することになる。
2. 全ての微候（＝観測値）の情報を有効に用いていない
推論の方向は一方方向（結果から原因）であり、推論の出発点の微候と直接因果関係のない観測値（微候）は利用されない。

```

function BIPARTITE(D,M,C,M+)
  variables
    m 徴候,
    M+ 徴候の集合,
    Hp generator 集合;
begin
  Hp = [];
  while 徴候がなくなるまで do
    m := 新しい徴候 from M+;
    Hp := revise(Hp,cause(m));
  endwhile;
  return Hp;
end.

```

図 7: BIPARTITE アルゴリズム

ここで revise/2 は 徴候の集合 M_1 に対する generator 集合 Hp_1 を新たに得られた徴候 m の原因 $cause(m)$ によって更新して集合 $M_2 = M_1 \cup \{m\}$ に対する generator 集合 Hp_2 を推論するアルゴリズムである。

このように 因果関係 $cause$ が分かれば generator 集合を 観測された徴候を用いて漸進的に求めることができる。

図 8 に徴候クラスタリングの例を示す。
徴候 m_1, m_2, m_3 に対し、複数の可能性あるクラスタの分け方 = generator が存在することがわかる。




図 8: 徴候クラスタリング

4.1 局所定性伝播と徴候クラスタリング

局所定性伝播とは徴候 m に対し定性的な原因の集合 $cause(m)$ を求めていることに他ならない。

ここで徴候は

$$m = \{a, q_a\}$$

a : パラメータ名, q_a : 定性値

また定性的な原因は

$$d = \{b, q_b, r\}$$

b : パラメータ名, q_b : 定性値, r : 定性的関係式名
(Type1)

あるいは

$$d = \{b, q_b\}$$

b : パラメータ名, q_b : 定性値
(Type2)

と表現できる。局所定性伝播は、徴候 m に対して考えられる全ての異常な関係式とそれによって直接生じたプラントパラメータの定性偏差 (Type1)、及び異常な偏差が発生した外部パラメータや設計パラメータとその定性偏差 (Type2) を定性的因果モデルに基づいて探索する。

$d = \{b, q_b, r\} \in cause(m)$ where $m = \{a, q_a\}$ であるとは、定性的因果関係 r が異常になってパラメータ b に定性偏差 q_b が生じ、その結果パラメータ a に定性偏差 q_a が観測されたことを意味する。

観測された全ての徴候に対して、 $cause(m)$ を局所定性伝播で求める。この時、並列に定性伝播を行なうことによって、「特徴点」と呼ぶ原因集合 $cause^1(m_i) \subset cause(m_i)$ を選択的に収集することができる。

一般的に一つのクラスター Cl は複数の原因 $d_1, d_2, \dots$ で構成され、これらの原因の中の少なくとも1つが発生していると解釈できる。一般的な診断問題では1つのクラスター内での原因に順序関係はないが、定性因果モデルにおいてはクラスター内に因果関係あり、クラスター Cl の中に最も結果側の要素 $d_{rep} \in Cl$ が必ず1つ存在する。この d_{rep} をクラスターの「代表点」と呼ぶ。

「特徴点」とはこの「代表点」になる可能性のある (クラスターの分け方に依存する) 定性的原因である。並列定性伝播とラベル計算によって、徴候 m_i に対する「特徴点」の集合 $cause^1(m_i) \subset cause(m_i)$ を得ることができる。この特徴点抽出によってクラスタリング時の推論コストが減少する。

定性伝播によって全ての徴候 m_i に対する特徴点の集合 $cause^1(m_i)$ が推論されると、BIPARTITE アルゴリズムを用いて全ての徴候を説明する generator 集合を計算することができる。

4.2 評価部

クラスター分けの方法 (generator) は複数得られる。しかし入手可能な情報 (= 観測値、定性的因果モデル) からこれ以上の解の絞り込みはできない。そこでこれらの複数のクラスタ分けを評価し、最も確からしい答えを選択するために評価部でヒューリスティックに基づいた解の絞り込みを行なう。

そこで図5の様に全ての微候からの同時に（並行して）局所定性伝播を実行し、その結果を有効に利用して診断を行えばこれらの問題に対応できると思われる。我々は、並列定性伝播のメカニズムを新たに開発し、それに「微候クラスタリング」手法を融合させてこれら問題点を解決できる診断機構を実現した。




図5: 複数の微候の利用

4 微候クラスタリング

複数の微候の情報を用いて多重故障を同じに診断する手法の一つに、「微候クラスタリング」がある [T.D.Wu, 90][J.Reggia, 90]。これは、予め分かっている微候と原因の因果関係に基づき、観測された微候全てを同時に説明できる故障原因の組合せを推論する手法である。推論結果として、可能な故障原因の組合せが複数得られる。我々は論理型言語との親和性の高さと、アルゴリズムの漸進性に注目して、Reggiaらの手法を採用した。

以下、微候クラスタリングを説明する。

図6に示すように、微候の集合 M と、原因の集合 D 、及び微候 $m \in M$ に対する原因の集合 $cause(m) \subset D$ 、原因 $d \in D$ に対する微候の集合 $effect(d) \subset M$ （これらの関係の集合を C とする）が予め明らかな問題 P において、微候 $M^+ \subset M$ が観測されたとする。この時、 $P = \langle D, M, C, M^+ \rangle$ に対して次に定義される説明 (Explanation) を全て求めることを診断問題を解くという。

定義 診断問題 $P = \langle D, M, C, M^+ \rangle$ において $E \subset D$ が説明であるとは、

1.

$$\bigcup_{d_i \in E} effect(d_i) \supset M^+$$

2. E のどの部分集合も M^+ を説明できない（1を満たせない）。

を E が満たすことである。

この説明は Reiter の理論 [R.Reiter, 87] における極小集合 Δ に相当する。




図6: 微候クラスタリング

一般的に可能性のある説明は複数存在する。いま E を問題 P の一つの説明とする。説明 E の要素 $d_i \in E$ ($1 \leq i \leq e$) には、観測された微候の部分集合

$$M_i^+ = effect(d_i) \subset M^+$$

が対応し、したがって E には微候 M^+ の分割

$$M_E^+ = \{M_1^+, M_2^+, M_3^+, \dots, M_e^+\}$$

が唯一対応づけられる。逆に M_i^+ に対応する原因の集合は

$$Cluster_i = \bigcap_{m_j \in M_i^+} cause(m_j) \subset D$$

であり、 M_E^+ には

$$G_e = \{Cluster_1, Cluster_2, \dots, Cluster_e\}$$

が唯一対応する。最初の説明 E は

$$E \in Cluster_1 \times Cluster_2 \times \dots \times Cluster_e$$

であることが容易に解る。この様にして全ての説明は幾つかの G_e によって分類できる。この G_e を generator と呼び、generator の要素 $Cluster_i \in G_e$ をクラスターと呼ぶ。そして全ての generator を求める手法をクラスタリングと呼ぶ¹。

問題 $P = \langle D, M, C, M^+ \rangle$ の全ての説明は、generator の集合として表現できる。診断問題を解くことは、この generator 集合を求めることに帰着される。generator 集合を効率良く求めるために Reggia らが提唱した BIPARTITE アルゴリズムを図7に示す。

¹[T.D.Wu, 90] とはクラスターの呼び方が異なることに注意

このヒューリスティックは、診断対象に依存する部分が大きいのと思われるが、制御プラントに限定すると、考えられるヒューリスティックとして、以下に示すものが挙げられる。

1. クラスター数が少ないものが良い
独立した故障が同時に発生する確率が低いというヒューリスティックによる
2. 共通の関係式があるものがあるのが良い
一つの故障は複数のパラメータに異常を発生させるというヒューリスティック
3. 頻度による重み付け。
診断対象の故障に頻度が予め分かっている場合にはこれを用いてクラスターの分け方を評価できる。

このヒューリスティックは診断対象に依存するが、この部分を変更することによって他の診断問題へ柔軟に対応できる。

5 定性因果ネットワーク

定性的因果モデルをネットワーク状に構築し、ネットワーク通信によって並列定性伝播と特徴点抽出を実現する。インプリメントは並列論理型言語KL1でマルチPSI上に行なった。ネットワークは以下の要素から構成される。

ノード 固有情報 = {パラメータ名、定性値、関係式名}

リーフノード 固有情報 = {パラメータ名、定性値}

アーク ノード・リーフ間の接続を表す

ノードとリーフノードはKL1の自己再帰プロセスで実現され、アークはストリームによって実現される。ストリームどうしは多入出力ストリーム結合プロセスconnectで結合されている。

図9にネットワークの例をしめす、




図9: 定性因果ネットワーク

局所定性伝播と特徴点抽出のメカニズムの概要を以下に示す。

局所定性伝播

定性伝播はネットワークへの微候のラベル = {パラメータ名、関係式名} の伝播と、ノード上でのラベル更新、及び定性演算によって実現される。

特徴点抽出

特徴点抽出は、ノード上でのラベル計算で自ノードが特徴点かどうかを判断することによって実現される。

6 実施例

火力発電プラントの給水加熱システムの診断に適用した例にしたがって診断の流れを説明する。

給水加熱システムのプラント構成図を図10に示す。




図10: 火力発電所プラント構成

以下に示す4つの微候が観測されたとする。

1. 復水器真空度劣化
2. 冷却水出口温度高
3. 給水温度低下
4. 低圧ヒータドレインレベル低下

図10上の丸数字は微候が観測された場所を示す。

実験に用いた定性因果ネットワークは、復水器と給水加熱器及びタービンに関連のある因果関係で構成される。図11にこのネットワークを模式的に示す、

各々の微候に対して特徴点が図12に示すように定性伝播の結果得られた。

並列定性伝播の結果に基づいてクラスタリングを行なって、図13の結果を得た。

ここで4つのgeneratorを得られた。ヒューリスティック「最もクラスター数の少ないほうが良い」をつかうと原因は G_{e1} に決定できる。

G_{e1} は4つの微候が同一の原因(バルブvalvの異常による、低圧ヒータ抽入蒸気減少 $g_{exl} = [-]$)によって引き起こされたことを示す。




図 11: 定性因果ネットワーク

$P_end = \{ (sp_end, r1, +), (ex_l, valv, -), (bn, p_ms, -), (lin, +), (bn, p_ms, +), (ex_h, valv, -), (alk, r1, +) \}$
 $T_out = \{ (et_out, r2, +), (ex_l, valv, -), (bn, p_ms, -), (lin, +), (bn, p_ms, +), (ex_h, valv, -), (alk, r1, +) \}$
 $T_fr = \{ (ho, an_t, r1, -), (ex_l, valv, -), (ex_h, valv, -) \}$
 $L_ph = \{ (ip, an_l, r3, -), (ex_l, valv, -) \}$

図 12: 定性伝播の結果

Return =
 1
 G₁ { (ex_l, valv, -) }
 G₂ { (ex_h, valv, -), (ip, an_l, r3, -) }
 G₃ { (bn, p_ms, -), (lin, +), (bn, p_ms, +), (alk, r1, +), (ho, an_t, r1, -), (ip, an_l, r3, -) }
 G₄ { (sp_end, r1, +), (et_out, r2, +), (ho, an_t, r1, -), (ip, an_l, r3, -) }

図 13: クラスタリング結果

7 まとめと今後の課題

制御用エキスパートシステムにおいて、定性的な因果モデルを用いた推論とクラスタリングの手法を融合させた診断システムを開発した。これによって微候を有効に利用して多重故障を同時に推論できる診断が可能となった。並列論理型言語 K L 1 でインプリメントを行ない、火力発電プラントの事例でその有効性を確かめた。今後、対策操作の実行、監視と再診断実行のメカニズムの実現をはかる。これはヒューリスティックによる判断の限界をカバーする機構として重要であると思われる。

8 おわりに

本報告は、I C O T からの委託テーマである「制御用エキスパートシステム」の研究成果の一部である。研究の機会を与えていただいた I C O T 第 7 研究室の新田室長に感謝の意を表します。

参考文献

- [鈴木 90] 鈴木、小沼、山本、五嶋：深い知識に基づく制御用エキスパートシステム—深い推論機構と詳細検証機構との融合—、第 11 回知識知能システムシンポジウム, 1990
- [小沼 90] 小沼、鈴木、岩政、神谷：深い知識に基づく制御用エキスパートシステム—操作条件生成機構の開発—、第 12 回知識知能システムシンポジウム, 1990
- [岩政 90] 岩政、鈴木、持地、神谷：制御用エキスパートシステム—定性的モデルに基づく診断機構—、第 41 回情全大, 1990
- [T.D.Wu. 90] T.D.Wu.: *Efficient diagnosis of multiple disorders based on a symptom clustering approach*, proc. of Eighth National Conference on Artificial Intelligence, 1990, pp.357-364.
- [J.Reggia 90] Y.Peng, J.A.Reggia: *Basics of Parsimonious Covering Theory in Abductive Inference Models for Diagnostic Problem-Solving* Springer-Verlag, 1990. pp.49-98.
- [R.Reiter 87] R.Reiter: *A Theory of Diagnosis from the First Principle*, Artificial Intelligence, 32, 1987, pp.57-95.