

## プラント診断エキスパートシステムにおける 段階的に異常原因を絞り込む推論方式の提案†

小林 隆† 栗原 謙三†

製造プラントの異常診断を迅速かつ高確度に行うことを狙いとした診断用エキスパートシステムを研究している。大規模プラントの診断を行う際には、熟練技術者は、検査データを段階的に収集し、それに基づき逐次原因を絞り込むという方法をとる。しかし、従来のプロダクションシステムは、あらかじめ診断のために設定したデータをすべて揃えてから推論を行うことを前提としているため、このような段階的推論を実現することは困難である。この問題点を解決するために、次の3点を特徴とする段階的推論方式を提案する。①ルールの前提条件項目のうち、成立／非成立が確定した条件項目だけを選択的に適用して推論を行う。これにより、各段階でデータを部分的にしか収集していないなくても、収集したデータの範囲内で推論を実行できる。②従来のように確信度をルールごとに設定するのではなく、ルールの前提条件項目ごとに設定する。そして、あるルールの条件項目が成立したら、それに応じてそのルール全体の確信度が上がるようになる。これにより、データ収集量が増加するのに伴い、推論結果の確実性を高めることができる。③熟練技術者の有するデータ収集順序に関する知識をルール内に記述できるようにし、未熟練者に対して診断のガイダンスを行えるようにする。以上の段階的推論方式を、ある製造プラントの異常診断システムに適用して実験を行い、未熟練者であっても迅速かつ高確度に診断を行えることを確認した。

### 1. まえがき

最近、半導体製造を始めとする各種の製造プラントは大規模化、複雑化が著しく、異常現象とその原因との間の定量的モデルの開発がますます困難となってきている。一方、熟練技術者は、定量的な診断知識だけでなく、経験と勘によりこの問題を克服して異常診断を行っている。例えば、プラント全体に対して定量的なモデルを開発することは困難であるため、部分システムごとに理論式、実験式などの数式モデルを開発する。そして、各部分システムの相互作用を、技術者の経験によって得られた、異常現象とその原因に関する因果関係知識を用いてモデル化する。このようなアプローチを計算機化する場合、熟練技術者の持つ経験的知識をいかに表現し利用するかが重要な課題となる。そこで、知識工学を活用したプラント診断エキスパートシステムの研究、開発を行っている<sup>1)</sup>。

製造プラントのような大規模かつ複雑なシステムでは、異常現象を監視するためのデータの数は数百から数千に上る。近年、計測技術の発達とともにデータ収集の自動化が進められているが、経済的理由により、まだ大半のデータを手動で多くの時間と労力をかけて収集せざるを得ない。このような状況の下で、いかにしてプラント異常の原因を迅速かつ高

確度に究明するか、が課題となっている。通常、熟練技術者はこの課題を解決するために、異常原因を究明するためのキーとなるデータを少しずつ収集しながら逐次原因を絞り込む、という方法で診断している<sup>2)</sup>。本論文では、このような段階的推論を、未熟練者が計算機の支援のもとに行えるようにする方式を提案する。

### 2. プラントの異常診断問題

#### 2.1 プラントの異常診断問題

プラント異常診断の目的はプラント内で発生した異常現象の原因を、迅速かつ高確度に究明することである。通常、プラントでは各種の異常現象が発生する。そして、これらの原因を究明するために必要なデータは、数百から数千に上る。理想的には、これらすべてのデータを自動的に収集できれば、その結果、短時間で診断を行える。しかし、検査装置の設置に伴うコストの制約、あるいは、技術的な制約により、現実には困難である。このため、熟練技術者は、次の2点を目的として、段階的にデータを収集し逐次原因を絞り込む、という診断方法をとっている。

①診断の各段階で異常原因の候補を明らかにする。これにより、診断の途中段階であっても応急処置などの対策を迅速に行える。

②診断の各段階では、前段階で抽出された原因候補に関するデータだけを収集する。このように、収集するデータを取捨選択することにより、データ収集量を削

† Proposal of Multi-stage Inference Method in Plant Diagnosis Expert System by TAKASHI KOBAYASHI and KENZOU KURIHARA (System Development Laboratory, Hitachi, Ltd.).

† (株)日立製作所システム開発研究所

減できる。

具体的には、図1に示すように診断を行う。すなわち、診断の初期段階では、システム全体を概観できるような少數の検査データを収集し、それらのデータにより原因となる可能性のある部分システム（これを、以降、原因候補とよぶ）を抽出する。次の段階では、前段階で抽出した原因候補に関するデータをさらに収集して、それらをもとに原因候補の中から、より原因となる可能性の高い部分システムを抽出する。以上の手順を繰り返すことにより異常原因を絞り込み、最終的に真の原因を究明する。

以上に述べたような段階的な診断を計算機により実現するまでの技術課題を次に述べる。

## 2.2 技術課題

プロダクションシステムを応用して異常診断を行う場合、通常、あらかじめ診断に利用するために設定したデータをすべて揃え、それらをもとに推論を行うことを前提としている。このため、ほとんどの診断システムでは、検査データあるいはそれを数値処理した結果のデータを取り込み、その結果欠落したデータがある場合、利用者側に対して必要なデータを要請する。

ところが、実際のプラント診断では、データを部分的に収集しそれらに基づいて異常原因を絞り込むという段階的推論を実現しなければならない。そのため、次の2つの課題を解決することが必要である。

(1) 収集したデータの範囲内で可能性のある原因を究明できること。

段階的にデータを収集し推論を行う場合には、各段階において未検査のデータが多数存在する。このため、従来のプロダクションシステムを適用した場合、利用者に対して、すべての未検査データについてデータ値を入力するよう繰り返し要請するような、使いがっての悪い診断システムになってしまふ。利用者は、その度に「不明」と答えなければならない。また、プロダクションシステムでは、通常、ルールの前提部の現象がすべて発生した場合に限って、結論部の現象が発生していると判定する。これでは、不明データのために前提条件が成立せず、実行されないルールが多数発生する。その結果、収集したデータに異常があったとしても、その原因候補を抽出できないことがある。以上のような理由により、各段階において、収集したデータに関する前提条件項目だけを対象として、条件項目の成立／非成立を判定が必要

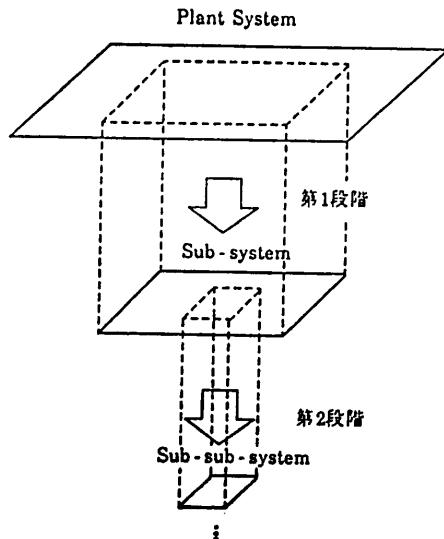


図1 段階的診断のイメージ  
Fig. 1 Image of multi-stage diagnosis.

である。

(2) 収集すべきデータおよびそれらに基づく推論結果の確実性を段階ごとに利用者に提示できること。

通常、各段階でどのデータを収集するのかはあらかじめ定められているわけではない。熟練技術者は、前段階でどのような原因候補が抽出されたのかにより、データの収集範囲を限定する。さらに、その範囲の中から、データ収集に要する時間、費用と、その結果得られる推論結果の確実性とをトレードオフして収集するデータを決定する。このため、未熟練者が計算機の支援のもとにこのような手順で診断を行えるようにするためには、各段階で、①推論実行にあたってどのようなデータを収集すべきか、②その推論結果がどの程度確実性のあるものとなるのかを示すことが必要である。

以上の2つの課題の解決方式を次章で述べる。

## 3. 段階的推論方式の提案

### 3.1 従来方式の問題点

医療診断の分野では、ある病気の発生を結論づけるためには、それを支持する証拠をすべて確認することが理想であるが、経済的、技術的理由によりそれが困難な場合がある。このように不明データがある場合でも推論を行える方法が、Shortliffeを始めとして、Duda, Hart, Nilsson, 石塚らにより研究されている<sup>3), 4)</sup>。ここでは、ある事実に関する複数個の証拠が、その事実を各々独立に支持するようにルール化する。

そして、ある事実に関して成立するルールが増加するのに伴い、その事実が真であるという確実性が高まるようにする。例えば、風邪であるという事実 S を結論づける証拠として、熱が 40 度以上あるという症状 D<sub>1</sub> と気管支が痛むという症状 D<sub>2</sub> がある場合を考える。事実 S が成立する確率が症状 D<sub>1</sub>, D<sub>2</sub> が観測されたことにより各々 0.6, 0.5 だけ高まるとする時、次のようにルール表現する。

$$\begin{aligned} D_1 \rightarrow S & (0.6) \\ D_2 \rightarrow S & (0.5) \end{aligned} \quad (1)$$

そして、前者のルールだけが成立したら事実 S が真である確率は 0.6 とし、後者のルールだけが成立したらその確率は 0.5 とし、両者が成立したら  $(0.6 + (1 - 0.6) \times 0.5) = 0.8$  と高まるようになる。

このような推論方式を実現するために、MYCIN では、各々のルールによって得られた確信度を独自の閾数により結合して、その事実の確信度を求めた。しかし、MYCIN の結合閾数はヒューリスチックなものであり、理論的裏付けがないという問題があった。この問題に対して Duda, Hart, Nilsson らは、従来の Bayes 規則をエキスパートシステムの推論に向くよう変形した主観的 Bayes の方法を提案した。しかし、この方法にも理論的に不完全な部分があった。その後、Dempster & Shafer 理論が発表され、確信度の結合方法に関する理論的裏付けがなされた。そして、石塚らがこの理論を応用した推論方式を提案している。

以上に述べた従来方式を利用して段階的推論を実現した場合の例を次に示し、その問題点を述べる。すなわち、各段階でどのようなデータを収集するのかを想定し、1つの原因に対して、各段階で収集したデータだけを用いるルールを複数個作成する。推論実行の際には、究明した異常原因の確信度を、成立したルールの増加に応じて高める。

例えば、図 2 に示すように、検査データ 1, 2, 3 を3段階に収集して推論したい場合を考える。検査データ  $i$  ( $i=1, 2, 3$ ) の異常を  $T_i$  とすると、「異常現象  $T_1, T_2, T_3$  が発生したならば、それは現象 G が原因である。」という知識は、次の3つのルールにより表現する。

$$\begin{aligned} T_1 \rightarrow G & (0.6) \\ T_2 \rightarrow G & (0.5) \\ T_3 \rightarrow G & (0.4) \end{aligned} \quad (2)$$

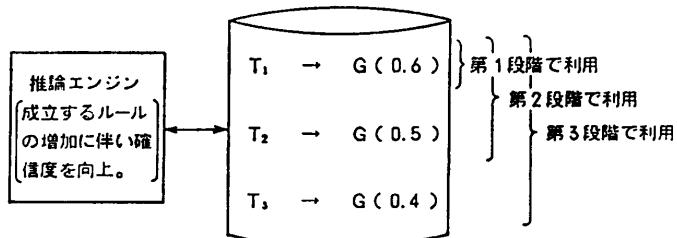


図 2 従来技術による段階的推論の実現方法  
Fig. 2 Realization method of multi-stage inference by old technology.

これらのルールを用いて推論を実行する際は次のように行う。すなわち、第1段階では検査データ 1 に基づいて 1 番上のルールを用いて推論を行う。推論結果の確実性は 0.6 である。第2段階では検査データ 1, 2 に基づいて 1 番めと 2 番めのルールを用いて推論を行う。推論結果の確実性は、例えば MYCIN の結合閾数によれば、 $(0.6 + (1 - 0.6) \times 0.5) = 0.8$  となる。第3段階では検査データ 1, 2, 3 に基づいてすべてのルールを用いて推論を行う。推論結果の確実性は  $(0.8 + (1 - 0.8) \times 0.4) = 0.88$  となる。このようにデータの収集が進むのに伴い推論結果の確実性は 0.6, 0.8, 0.88 というように高まる。

しかし、この従来方法には以下の問題点がある。

#### ① 診断知識が分散。

プロダクションシステムの長所はモジュール性にあるといわれている。すなわち、1つのまとまった意味をもつ知識を1つのルールで表現することにより、知識の追加、変更などをルール単位で行える。ところが、従来方法により段階的推論を実現した場合、本来1つのルールで記述すべきである知識を段階別に分割して作成しなければならない。これでは1つの知識が複数個のルールに分散してしまい、保守が困難となってしまう。

#### ② データ収集順序の表現が困難。

前章において、段階的推論を行うためには、各段階で、収集すべきデータを利用者に対して提示することが重要であることを述べた。ところが、従来方法は、何らかの理由により任意のデータが収集困難になった場合を想定した推論方式であり、どのデータを先に収集するかといった順序性はないことを前提としている。このため、各段階で用いるルールは、すべて等確率で発火するように表現する必要がある。これでは、データ収集順序に関する熟練技術者のノウハウを、

ルールに表現することが困難である。

### 3.2 提案方式

#### (1) 基本方針

従来の問題点を解決するためには、次のような方針をとる。

- ① 診断知識のモジュール性を確保。

1つのまとめた意味をもつ知識、すなわち、ある異常現象が発生した場合、それが原因となってどのような異常現象が発生するか、という知識を1つのルールで記述する。そして、データを部分的にしか収集しないためにルールの前提条件項目のすべてについて成立／非成立が確定しない場合でも、確定している条件項目だけを選択的に適用して推論を実行する。

- ② 確信度をルールの前提条件項目ごとに設定。

MYCIN を始めとする従来のプロダクションシステムでは、確信度をルールごとに設けている。このため、①の方針で推論を行った場合、従来方式で確信度計算を行ったのでは、データ収集が進み成立／非成立の確定した前提条件項目が増加したとしても推論結果の確実性は変化しない。そこで、ルールの前提部を構成する条件項目ごとに確信度を設け、あるルールの前提条件項目が成立したら、それに応じてそのルール全体の確信度が上がるようとする。

- ③ データ収集順序に関するノウハウを知識ベース化。

熟練技術者は、各検査データについて、それを収集する優先順位を経験的に把握していることを既に述べた。すなわち、システム全体を概観できるようなデータは診断の初期段階で収集し、原因候補を絞り込むためのキーとなるデータは、中間段階で収集し、診断結果を確認するためのデータは最終段階で収集する。そこで、熟練技術者の有するデータ収集の優先順位に関するノウハウを診断ルール内に記述できるようにする。これにより、未熟練者に対して、各段階でどのようなデータを収集すればよいか、という診断のガイダンスを行う。

以上に述べたような方針を実現するための知識の表現、利用方式を、図3に従って以下に説明する。

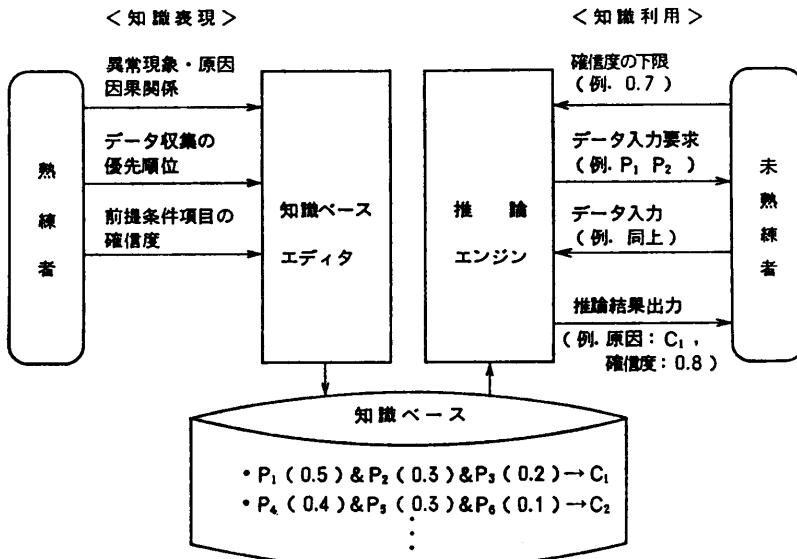


図3 提案方式の概要  
Fig. 3 Outline of proposal method.

#### (2) 知識表現方式

上記で述べたように、ルール内に次の情報を表現する。

- 前提部の各条件項目に対して、ルールの結論部が成立するか否かを確認するためにどの条件項目を先に判定すればよいか、という優先順位を記述する。
- 前提部の各条件項目に対して、それが成立することによりルール全体の確信度がどれだけ向上するかという増加率を記述する。通常、この確信度の増加率の値は、どの前提条件項目の成否を先に調べるかという順序に依存する。上記の優先順位に従った場合を前提にして記述する。

具体的には、以下の手順で知識を表現する。

##### Step 1: 因果関係の表現

製造プラントに発生する各異常現象について、それがどのような現象に波及して、最終的に検査データの異常として検知されるか、といった因果関係を調べる。そして、プロダクションルールの前提部に異常現象を、結論部にその原因となる現象を記述する。例えば、現象 C<sub>1</sub> が原因で、異常現象 P<sub>3</sub>, P<sub>2</sub>, P<sub>1</sub> が発生するという因果関係は、次のように記述する。

$$P_3 \& P_2 \& P_1 \rightarrow C_1 \quad (3)$$

##### Step 2: 優先順位の設定

前提部の各条件項目に対して、ルールの結論部が成立するためにどの条件項目が成立することが重要であるか、という優先順位を付け、その順番に条件項目を

並べえる。例えば、その優先順位が  $P_3 < P_2 < P_1$  である場合は次のように表現する。

$$P_1 \& P_2 \& P_3 \rightarrow C_1 \quad (4)$$

### Step 3: 確信度の増加率の設定

利用者に、前提部の各条件項目が成立するとルールの確信度はどのくらい増加するか、という関係を設定させる。例えば、「 $P_1$  が発生した場合には 0.5 の確率で  $C_1$  が原因であり、 $P_2$  が発生するとそれから 0.3 増加して 0.8 の確率となり、さらに  $P_3$  が発生すると 0.2 増加して 1.0 の確率となる」という関係は次のように表現する。

$$P_1 (0.5) \& P_2 (0.3) \& P_3 (0.2) \rightarrow C_1 \quad (5)$$

ただし、確信度の増加率の合計を、必ずしも 1 にする必要はない。なぜなら、前提条件がすべて成立しても、なお、結論の成立が不明確である場合もあり得るからである。

以上をまとめると、提案方式により診断知識を表 1 に示すように表現する。

### (3) 知識利用方式

上記のように表現した知識により、診断の各段階で収集するデータをどのように決定し、それに基づき診断を行うのかを説明する。

既に述べたように、従来技術ではデータ収集に関する順序性は前提としていない。このため、各ルールを実行した結果得られた確信度をもとに最終的な結論の確信度を算出するために、データ収集順序に依存しない結合関数を開発する必要がある。この関数を、利用者にとって使いやすく、しかも、理論的裏づけのあるものとすることが 1 つの大きな研究課題となっている。

一方、提案方式ではデータ収集の優先順位が与えられているため、このような結合関数は不要ない。どのデータを収集すればどれだけ確信度が加算されるか、というように、利用者にとって最も単純で使いやすい積み上げ方式による確信度算出方法を採用すればよい。すなわち、各ルールの前提条件項目ごとに設定された確信度のうち、成立した条件項目の確信度だけを加算してルールの確信度を求める。例えば、(6) 式のようなルールの場合、(7) 式により確信度を算出する。

$$P_1 (CFrule_1) \& P_2 (CFrule_2) \& \dots \rightarrow C_1 \quad (6)$$

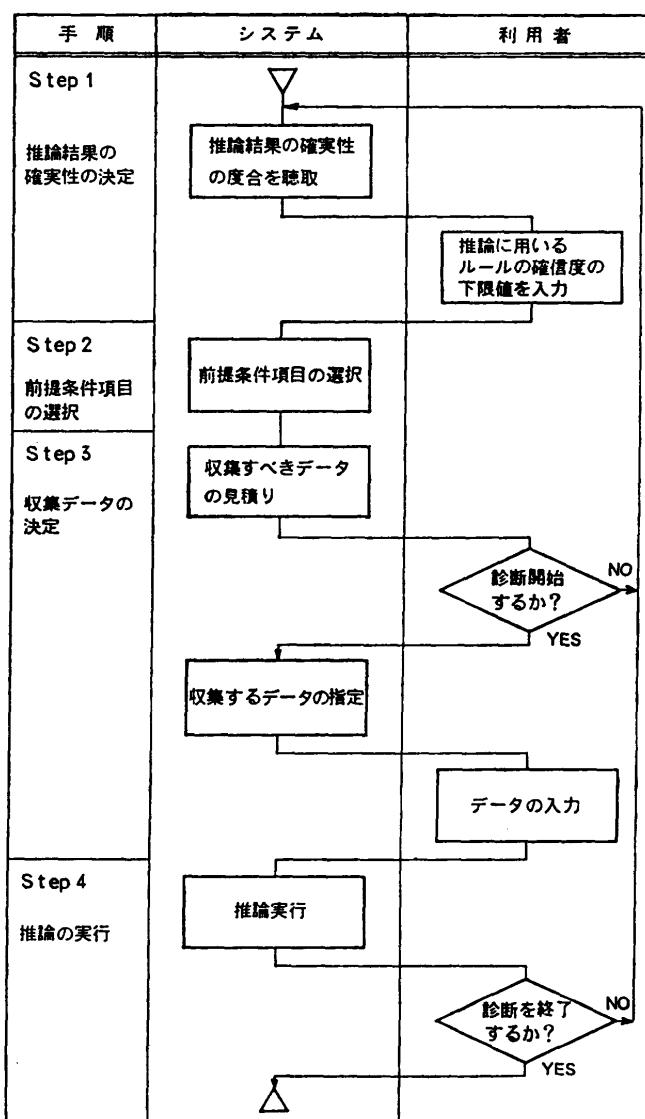
表 1 知識表現方式

Table 1 Knowledge representation method.

|       |  |
|-------|--|
| 診断知識  | <因果関係><br>異常現象 $P_1$ および $P_2$ および… $P_n$ が発生したならば $C$ が原因である。<br><優先順位><br>段階的推論を行う際、異常現象を $P_1, P_2, \dots, P_n$ の順に検出する。<br><確信度><br>各異常現象を検出した場合、次の割合で確実性が増加する。<br>$P_1: 0.4, P_2: 0.2, \dots, P_n: 0.1$ |
| ルール表現 | $P_1 (0.4) \& P_2 (0.2) \& \dots \& P_n (0.1) \rightarrow C$   |

表 2 知識利用方式

Table 2 Knowledge utilization method.



$$CF_{C_1} = (CF_{rule_1} + CF_{rule_2} + \dots) \times MIN(CF_1, CF_2, \dots) \quad (7)$$

ただし、 $CF_1, CF_2, \dots$ は、各々現象  $P_1, P_2, \dots$  がどの程度の確信度で発生しているかを示す指標であり、 $-1$  から  $+1$  までの値をとる。 $-1$  は現象が発生していないこと、 $+1$  は発生していることを示す。また、 $0$  の場合は不明であることを示す。また、 $CF_{rule_1}, CF_{rule_2}, \dots$  は現象  $P_1, P_2, \dots$  の発生を判定するための各前提条件項目に対して設定されている確信度である。

また、収集すべきデータを決定するためには、診断結果の確実性、診断に要する時間、費用などのトレードオフを行う必要があることを既に述べた。そこで、これを支援するために、各段階において利用者からどの程度確実な推論結果を得たいのか聴取し、前述した優先順位を用いてそのために収集すべきデータを見積り、利用者に提示する。これを繰り返し行うことにより、利用者の要求を満足するために収集すべきデータを決定する。

具体的な知識利用手順を、表2に従って説明する。

#### Step 1：推論結果の確実性の決定

推論実行にあたり、利用者に、推論に用いるルールの確信度は少なくともどの程度必要か、という下限値を指定させる。

#### Step 2：前提条件項目の選択

各ルールの前提条件項目の中から、推論に用いる条件項目を選択する。この際、選択した条件項目の確信度の合計が、Step 1 で指定された下限値を越える最小値をとるようにする。例えば、次の例で利用者が確信度の下限値として $0.7$ を指定した場合、条件項目  $P_1$  と  $P_2$  を選択する。

$$P_1(0.5) \& P_2(0.3) \& P_3(0.2) \rightarrow C_1 \quad (8)$$

#### Step 3：収集データの決定

原因候補が真の原因となるか否かを調べるために収集すべきデータを決定する。図1に示したように、診断の最初の段階では、異常原因となり得るすべての現象が原因候補に該当する。段階的な診断を何度も繰り返した後では、前の段階で得られた原因だけが、次の段階における原因候補となる。収集すべきデータを決定するためには、各原因候補から後向き推論を行い、Step 2 で条件項目を選択したルールを逆向き

にたどっていく。そして、各条件項目が成立するか否か、を調べるために必要なデータを抽出して、それらを利用者に提示する。利用者は、提示されたデータを収集するのに必要な時間、費用と、この段階でどの程度確実な推論結果を得たいのかを比較検討して、推論を実行するか否かを決定する。推論を実行する場合 Step 4 に行く。再度、収集データを決定したい場合、Step 1 に戻る。

例えば、図4(a)のようなルール群により推論を行う場合を考える。これらのルールに記述された現象間の因果関係をグラフ表現したものが図4(b)である。現象ノードの横に記述された数字は、確信度の増加率を示す。ルールの前提条件項目の優先順位は、図の左に記述されたものほど高い。この例において、利用者がルールの確信度の下限値を $0.7$ と指定した場合、斜線をほどこした条件項目が選択される。そして、原因候補  $C_5, C_6$  から後向き推論を実行すると、収集すべきデータは、 $P_1, P_2, P_4, P_6$  の4つが選ばれる。

#### Step 4：推論の実行

入力されたデータに基づいて、前向き推論を実行する。この際、前述したように、(7)式により確信度を算出する。

例えば、現象  $P_1$  と  $P_2$  が発生してその確信度が各々 $0.6, 0.5$ である場合、前述したルールの結論の確信度は次のように算出する。

$$CF = (0.5 + 0.3) \times MIN(0.6, 0.5) = 0.4 \quad (9)$$

$$\begin{array}{ll} RULE\_1: P_1(0.5) \& P_2(0.3) \& P_3(0.2) \rightarrow C_1 \\ RULE\_2: P_4(0.8) \& P_5(0.2) & \rightarrow C_1 \\ RULE\_3: P_6(0.7) \& P_7(0.3) & \rightarrow C_1 \\ RULE\_4: P_8(0.6) \& P_9(0.2) \& P_{10}(0.2) \rightarrow C_1 \\ RULE\_5: C_1(0.6) \& C_2(0.4) & \rightarrow C_5 \\ RULE\_6: C_1(0.8) \& C_2(0.2) & \rightarrow C_6 \end{array}$$

(a) 診断用ルールの例  
(a) Example of rules.

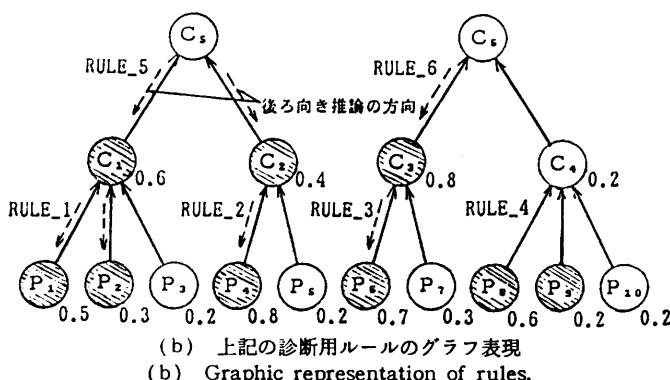


図4 収集データを決定する方法  
Fig. 4 Method of deciding data to collect.

この際、Step 2 で利用者に対して要求したデータに関する条件項目だけでなく、前段階で収集したデータ、あるいは、利用者が独自の判断により収集したデータに関する条件項目についても成立／非成立を調べ、確信度を算出する。

各ルールが成立するか否かの判定は、この確信度の計算結果を用いて行う。すなわち、前提条件と照合すべき現象の確信度の最小値があるしきい値以上 (Mycin の場合 0.2 以上) ならば成立、それより下ならば非成立と判定する。

以上の Step 1 から Step 4 までの処理を繰り返しながら異常原因の候補を絞り込み、最終的に真の異常原因を究明する。

#### 4. プラント診断システムへの適用例

##### 4.1 プラント診断システムの概要

以上に述べた段階的推論方式を、ある製造プラントの異常診断システムに適用した例を示す。

本システムは製造プラントで発生している異常現象の原因工程を究明するものである。本システムによる異常診断の手順を、図 5 に従って説明する。

(1) 診断用のテストパターンを製品と一緒に作成しておき、その電気抵抗、容量などを測定する。そして、これらの電気測定データから寸法、厚さ、濃度などの構造パラメータの値を推定する。ここでは、理論式、実験式などの数式モデルを利用する。

(2) 推定したパラメータ値の正常、異常の組合せからその原因工程を究明する。通常、構造パラメータの値は多種類の装置制御パラメータの値によって決ま

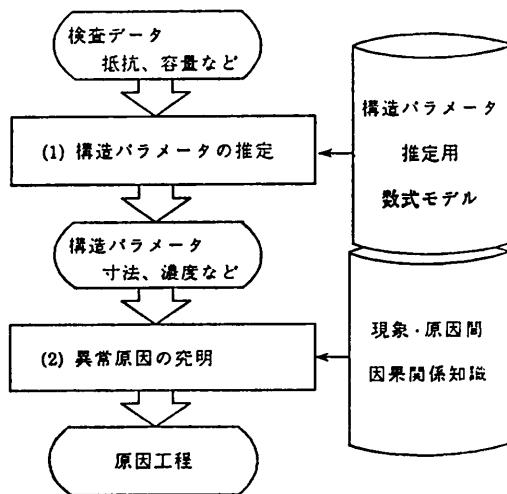


図 5 プラント診断の手順  
Fig. 5 Procedure of plant diagnosis.

り、しかも個々の装置の癖も影響する。このため、これらパラメータ間の数式モデルの開発は容易ではない。そこで、技術者の持っている「作業結果の異常と構造パラメータの異常との間の定性的な因果関係」の知識を利用する。

後者で利用する因果関係知識の例を表 3 に示す。表の縦軸は各工程での作業結果を、横軸は構造パラメータを表す。各行は各作業結果の異常が波及する構造パラメータを表し、矢印の向きは設計基準からのはずれ方を示す。同一行に二重の矢印と一重の矢印がある場合、二重の矢印のついたパラメータに対する波及効果が一重のそれより大きいことを示す。

これらの因果関係知識を、提案方式を用いて図 6 のようにルール表現する。ルールの前提条件項目のうち

表 3 現象、原因間因果関係知識の例  
Table 3 Example of causal knowledge.

| 構造<br>パラメータ | 寸 法         |             | 厚 さ         |             | 濃 度         |             |        |        |
|-------------|-------------|-------------|-------------|-------------|-------------|-------------|--------|--------|
|             | 縦<br>寸<br>法 | 縦<br>寸<br>法 | 横<br>寸<br>法 | 横<br>寸<br>法 | 厚<br>さ<br>さ | 厚<br>さ<br>さ | 濃<br>度 |        |
| 作業結果        | 1           | 2           | 1           | 2           | 1           | 2           | 3      | 濃<br>度 |
| 作業 1        | オーバー        |             |             |             |             |             |        | △△     |
|             | アンダ         |             |             |             |             |             |        | ▽▽     |
| 作業 2        | オーバー        |             |             |             |             |             |        | △△     |
|             | アンダ         |             |             |             |             |             |        | ▽▽     |
| 作業 3        | オーバー        | △△          | △△          | △△          | △△          | △△          |        | △△     |
|             | アンダ         | ▽▽          | ▽▽          | ▽▽          | ▽▽          | ▽▽          |        | ▽▽     |
| 作業 4        | オーバー        | △△          | △△          | △△          | △△          | △△          |        | △△     |
|             | アンダ         | ▽▽          | ▽▽          | ▽▽          | ▽▽          | ▽▽          |        | ▽▽     |

- ルール 1: 濃度  $\wedge$  (1.0)  $\rightarrow$  作業 1 オーバー
- ルール 2: 濃度  $\vee$  (1.0)  $\rightarrow$  作業 1 アンダ
- ルール 3: 濃度  $\wedge$  (1.0)  $\rightarrow$  作業 2 オーバー
- ルール 4: 濃度  $\vee$  (1.0)  $\rightarrow$  作業 2 アンダ
- ルール 5: 縦寸 1  $\wedge$  (0.5) & 縦寸 2  $\wedge$  (0.15) & 横寸 1  $\wedge$  (0.15) & 横寸 2  $\wedge$  (0.15)  $\rightarrow$  作業 3 オーバー
- ルール 6: 縦寸 1  $\vee$  (0.5) & 縦寸 2  $\vee$  (0.15) & 横寸 1  $\vee$  (0.15) & 横寸 2  $\vee$  (0.15)  $\rightarrow$  作業 3 アンダ

図 6 因果関係知識のルール表現例

Fig. 6 Example of rule representation of causal knowledge.

順序が先のものは後ものに比べて、原因候補を絞り込むのに役立つもの、あるいは、結論の確実性を向上するものを示す。例えば、表3の二重矢印のパラメータが異常であるという条件項目は、一重矢印のパラメータのそれに比べて結論の確実性を向上できるため、順序を先にする。また、各条件項目の横に付した数字は、その条件項目が成立したことによって結論の確実性がどのくらい向上するか、という増加率を示す。

#### 4.2 実験結果

上述したプラント診断システムに、提案した段階的推論方式を適用した実験結果について述べる。

本実験では、次のことを前提とした。

- ① 原因候補の総数：診断はあらかじめ定めた8つの原因候補の中から真の原因を見出すこととする。実際のプラント診断では原因候補の数は数十個に及ぶが、そのうち特に発生頻度の高い原因候補を8つ選んだ。
- ② 収集データの範囲：上記の8つの原因候補が真の原因となるか否かを知るためにには、最大22項目のデータを調べれば十分である。このため、収集するデータの範囲をこれら22項目に限定した。
- ③ 究明する原因の数：究明する原因是1個に限定する。実際のプラント診断では複数個の原因が複合して異常が発生することもあるが、本実験では簡単のために究明する原因の数を1個に限定した。
- ④ 推論段階の分け方：4段階に分割して推論を行うこととし、各段階においてルールの確信度が、0.25, 0.5, 0.75, 1.0となるようにした。

このような前提のもとで行った実験結果を図7に示す。横軸に診断の段階を、縦軸に各段階におけるデータ収集量の累積値、および原因候補の数をとる。この実験結果により、提案方式の効果は次の2点であることがわかる。

##### ① 原因候補を迅速に絞り込む。

図7を見ると、第1段階においてシステムを概観できるような7項目のデータを収集することにより、原因候補の数を1個から2個と大幅に絞り込めることがわかる。この結果により、提案方式によれば、推論の早い段階で異常原因のおおまかな見当をつけることができるため、応急処置などの迅速な対応が可能である

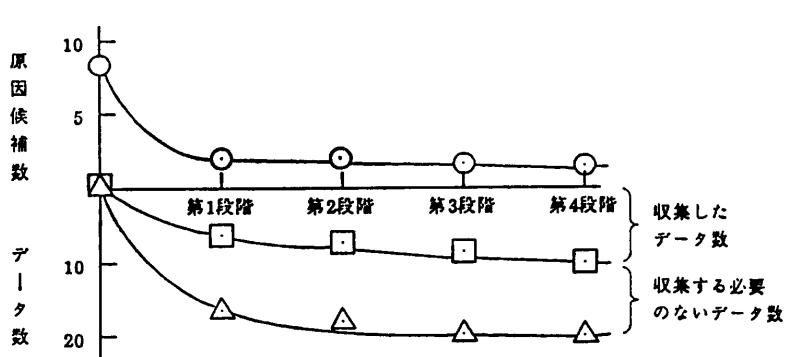


図7 実験結果  
Fig. 7 Experimental result.

ことがわかる。

##### ② データ収集量を削減できる。

第1段階で原因候補が大幅に絞り込まれるため、第2段階以降では、それらの原因候補に関するデータだけを収集すればよい。このため、図7に示すように、第4段階までに収集するデータの量は、全データ量の約60%でよい。この結果により、提案方式によれば、データ収集量を大幅に削減できることがわかる。

#### 5. むすび

プラント診断エキスパートシステムのための段階的推論方式を提案した。本方式により、段階的にデータを収集して逐次原因を絞り込む、といった熟練技術者の診断手順を実現できる。このため、未熟練者であっても、迅速かつ高確度に診断を行うことが期待できる。

**謝辞** 最後に、本研究の機会を与えていただき、また、御指導をいただいた(株)日立製作所システム開発研究所の堂免所長、春名副所長、明石主任研究員、ならびに、大みか工場の篠本主任技師に深謝します。

#### 参考文献

- 1) 栗原、明石：知識ベースに基づく半導体プロセス診断方式、情報処理学会論文誌、Vol. 27, No. 5, pp. 541-551 (1986).
- 2) 塩見：故障解析と診断、日科技連、東京 (1979).
- 3) Shortliffe, E. H. (神沼はか訳)：診断コンピュータシステム、文光堂、東京 (1981).
- 4) 情報処理、Vol. 26, No. 12 (1985), 特集「知識工学」.

(昭和62年10月13日受付)  
(昭和63年9月5日採録)



小林 隆 (正会員)

昭和 31 年生。昭和 55 年早稲田大学理工学部機械工学科卒業。昭和 57 年同大学院修士課程修了。同年、(株)日立製作所入社。システム開発研究所において、知識工学応用システム、計算機周辺装置の制御などの研究に従事。電気学会、計測自動制御学会、IEEE 各会員。



粟原 謙三 (正会員)

昭和 23 年 7 月 2 日生。47 年 3 月、早稲田大学理工学部機械工学科卒業。49 年 3 月、東京大学大学院工学系研究科機械工学専門課程修士課程修了。同年 4 月、(株)日立製作所に入社し、システム開発研究所に勤務。現在、同研究所主任研究員。生産システムの計画、管理技法に関する研究に従事。日本機械学会、電気学会、IEEE 各会員。