

## 7B-4

論理的知識と経験的知識を併用した  
故障原因絞り込み手法

田中みどり 古関義幸 中茎洋一郎  
日本電気(株) C & C システム研究所

## 1.はじめに

従来の故障診断システムでは、専門家の経験的知識をコード化したルールベースを利用する手法と、診断対象装置を構成する部品間の接続関係と各部品の動作を記述した論理的知識を利用する手法とが用いられてきた。しかし、前者には、マッチするルールがない場合には診断できない、ルールベースの構築・管理が困難である等の問題点があり、後者には、計算量が大きくなるので大規模な対象を扱えないという問題点がある。

そこで、筆者らは、

- (1) 論理的知識と経験的知識を柔軟に使い分けて診断を行う「適応能力」
- (2) 過去の診断例から、その後の診断に利用できるよう経験的知識を獲得する「学習能力」

をもった知的故障診断エージェントの構築を目指し、そのアーキテクチャを提案した[1]。このアーキテクチャでは、診断は、経験的知識のみを用いるフェーズと論理的知識のみを用いるフェーズとに分かれており、経験的診断に失敗すると、論理的診断をはじめからやり直さなければならない。

本稿では、論理的知識と経験的知識を併用しながら故障原因を絞り込む方法を提案する。この方法では、故障原因候補を、より疑わしいものとそうでないものとに区別して保持する。疑わしさの違いは、テストパターンを生成するときに利用される。2種類の知識を併用して絞り込みを行うことで、効率的な診断が実現された。

## 2. 知的故障診断エージェントの概要

診断は、部品とそれらを結ぶワイヤから構成されその接続記述と各部品の動作記述がわかっているものを対象とし、故障している部品の特定を行う。また、対象装置内で故障する部品はひとつであり（单一故障）、時刻によって変化しないものとする。

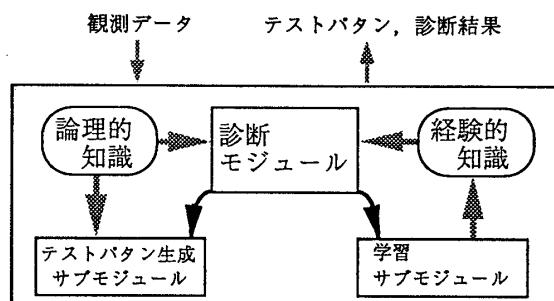


図1 知的診断エージェントの構成図

A Method of Narrowing down Suspects using Experiential Knowledge in Model-Based Diagnostic Systems  
Midori TANAKA, Yoshiyuki KOSEKI, Yoichiro NAKAKUKI  
NEC Corporation

知的故障診断エージェントの構成を図1に示す。

「診断モジュール」は、観測データを受け取ると、故障原因候補の絞り込みを行い、ひとつの候補に特定されるまで、「テストパターン生成サブモジュール」によるテストパターン生成、テスト実行結果の読みこみ、候補の絞り込み、を繰り返す。故障原因が特定され診断が成功すると、「学習サブモジュール」を呼び出し経験的知識を作成する。

「テストパターン生成サブモジュール」では、Dアルゴリズム[2]を拡張した手法を用いている。この手法は、対象装置内のある部品のひとつの動作に注目し、それが正常に機能しているかどうかを検査するためのテストパターン（対象装置への入力値パターンと、その時に観測されるべき出力値）を生成するものである。

「学習サブモジュール」では、EBG(Explanation Based Generalization)[3]を用いており、初期症状と故障原因から「症状SならばFという壊れ方をしている」という経験的知識を生成する。

## 3. 故障原因候補の絞り込み方法

## 3.1 準備

まず、本稿で用いる用語を定義する。

【部品の動作】 部品名、入力値パターン、出力ピン名、出力値の組で表現される。正常動作と異常動作がある。  
例) 2入力AND回路a1での入力値パターン[1,1]における正常動作、異常動作を次のように表す（出力ピン名：out）。

正常動作 : working(a1,[1,1],out,1)

異常動作 : failing(a1,[1,1],out,0)

【観測データ】 対象装置への入力値パターンと、ある出力ピンでの値。

【サスペクトリスト (SL)】 診断の途中経過を表したもの。すなわち、ある時点での故障原因候補の集合と正常動作の集合を保持している。

## 3.2 SLの表現形式

i個の観測データを観測した後のサスペクトリスト SL<sub>i</sub>を、次の3項組で表現する。

$$SL_i = (SLM_i, SLE_i, WL_i)$$

SLM<sub>i</sub> (Suspect List by Model-based knowledge)

論理的知識（構造記述と動作記述）を用いて計算される故障原因候補の集合。機能していない疑いのある正常動作の集合として表現される。SLM<sub>i</sub>に現れる部品の中のひとつが必ず故障原因であることが保証されている。

例) { working(a1,[1,1],out,1),

working(o1,[1,0],out,1) }

SLE<sub>i</sub> (Suspect List by Experiential knowledge)

経験的知識（観測データと、起こっている可能性の高い異常動作を結ぶルール）を用いて計算される故障原因候補の集合。SLM<sub>i</sub>の要素の中で過去に同じ様な故障が

起きたもの、特に疑わしいものの集合である。

例) { failing(a1,[1,1],out,0),  
failing(a2,[0,1],out,1) }

#### WL<sub>i</sub> (Working List)

論理的知識を用いて正常に機能していると証明された動作の集合。

例) { working(a2,[0,0],out,0) }

### 3. 3 SLの計算・更新方法

SLを構成する各項の計算方法を示す。

まず、各項の計算で用いる関数を定義する。

【関数wk(i)】 正常(working)であるべき動作の計算  
 $wk(i) = i$ 番目の観測データの入力値パターンにおいて指定された出力ピンで正常値を得るために必要な正常動作の集合

もし、指定された出力ピンで異常値が観測されたならば、 $wk(i)$ の中に機能していないものが存在する。

【関数fl(i)】 起こっている可能性の高い異常(failing)動作の計算

$fl(i) = i$ 番目の観測データから経験的知識を用いて得られる異常動作の集合

【関数cmp(S)】 集合S内の部品(component)の抽出  
 $S$ を正常動作の集合、または異常動作の集合としたとき、 $cmp(S) = S$ の各要素の部品名の集合

#### SL<sub>i</sub>の計算

1) 1番目の観測データ(初期症状)より3項組は、

$SLM_1 = wk(1)$ ,  $SLE_1 = fl(1)$ ,  $WL_1 = \{\}$

となる。

2)  $i$ 番目( $i > 1$ )の観測データは、正常動作working( $C_i$ ,  $Inlist_i$ ,  $Pin_i$ ,  $Val_i$ )が機能しているかどうか調べるためのテストの結果である。

a) 出力値が正常でなかった場合

$SLM_i = \{ w \mid w = working(C, Inlist, Pin, Val), w \in SLM_{i-1} \cup wk(i) - WL_{i-1}, C \in cmp(SLM_{i-1}) \cap cmp(wk(i)) \}$   
 $SLE_i = \{ f \mid f = failing(C, Inlist, Pin, Val), f \in SLE_{i-1} \cup fl(i), C \in cmp(SLM_i) \}$

$WL_i = WL_{i-1}$

部品としての単一故障の仮定から、 $cmp(SLM_{i-1})$ と $cmp(wk(i))$ とに共通する部品が候補として残る。ただし、ひとつ部品で複数の異常動作が起きていている場合を考えられるので、動作については全ての可能性をとっておく。

b) 出力値が正常であった場合

注目した正常動作が機能しているということなので、3項組は次のようになる。

$SLM_i = SLM_{i-1} - \{ working(C_i, Inlist_i, Pin_i, Val_i) \}$   
 $SLE_i = SLE_{i-1} - \{ failing(C_i, Inlist_i, Pin_i, ...) \}$   
 $WL_i = WL_{i-1} \cup \{ working(C_i, Inlist_i, Pin_i, Val_i) \}$

### 4. 実験システム

PSI-II上のESPにより実験システムを作成中である。ここでは、全加算器(図2)で診断の様子を説明する。

例) 経験的知識として次のルールがあるとする。

" $in1=ln1, in2=ln2, cin=0, sum=0, xor(ln1, ln2)=1 \rightarrow failing(x2,[1,0],out,0)"$

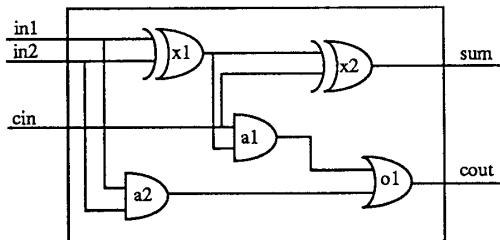


図2 全加算器

観測データ1:  $in1=1, in2=0, cin=0$ で、異常値 $sum=0$ より3項組は、以下のようになる。

$SLM_1 = \{ working(x1,[1,0],out,1), working(x2,[1,0],out,1) \}$

$SLE_1 = \{ failing(x2,[1,0],out,0) \}$

$WL_1 = \{ \}$

そこで過去の経験からより疑わしいと思われる $failing(x2,[1,0],out,0)$ に注目してテストパターン( $in1=0, in2=1, cin=0$ )を生成しテストを実行する。

観測データ2:  $in1=0, in2=1, cin=0$ で、正常値 $sum=1$ より

$SLM_2 = \{ working(x1,[1,0],out,1) \}$

$SLE_2 = \{ \}$

$WL_2 = \{ working(x2,[1,0],out,1) \}$

となり、故障原因是 $x1$ に特定される。

経験的知識による原因候補と論理的知識による候補を別々のフェーズで計算せず、同時に保持することにより、 $SLE_i$ が空集合になって経験的診断に失敗しても、論理的診断をはじめからやり直す必要がないことがわかる。

### 5. おわりに

論理的知識と経験的知識を併用して故障原因候補を絞り込む方法を検討した。本手法により、原因の絞り込みがより効率的に行えるようになった。

本稿では、故障原因の絞り込み方法について検討を行ったが、全体システムの性能をさらに上げるために、SLの内容を考慮した効率的なテストパターン生成や、信頼性を加味した経験的知識の獲得などが必要であり、今後、これらの点について研究を進めていく予定である。

本研究を進めるに当たり、数々の助言をくださった日本電気(株)水井義裕部長、森啓課長に感謝致します。本研究は、第五世代コンピュータプロジェクトの一貫として行われたものであり、ご指導頂いているICOT生駒第5研究室長に感謝致します。

### 参考文献

- [1] Koseki, Y., "Experience Learning in Model-Based Diagnostic Systems," Proc. IJCAI-89, 1989.
- [2] Roth, J.P., Buricius, W.G. and Schneider, P.R., "Programmed algorithms to compute tests to detect and distinguish between failures in logic circuits," IEEE Trans. Electron. Comput., vol. EC-16, no. 10, pp. 567-580, 1967.
- [3] Mitchell, T.M., Keller, R.M. and Kedar-Cabelli, S.T., "Explanation-Based Generalization: A Unifying View," Machine Learning 1:1, pp. 47-80, 1986.