

TM-1291

階層型モデルベース診断における適応機能  
－適応型人工知能の実現に向けて－

中塩 洋一郎、古閑 義幸、  
田中みどり（日本電気）

March, 1994

© Copyright 1994-2-22 ICOT, JAPAN ALL RIGHTS RESERVED

**ICOT**

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

(03)3456-3191~5

---

**Institute for New Generation Computer Technology**

## 論 文

階層型モデルベース診断における適応機能

—適応型人工知能の実現へ向けて—

Adaptive Model-Based Diagnosis with Hierarchical  
Model Scheme

中莖 洋一郎 \*

Yoichiro Nakakuki

古関 義幸 \*

Yoshiyuki Koseki

田中 みどり \*

Midori Tanaka

\* 日本電気(株) C&C 研究所

C&C Research Laboratories, NEC Corporation

Keywords : Model-Based Diagnosis, Hierarchical Model

Adaptive Problem Solver

## **Summary**

This paper describes an adaptive model-based diagnostic mechanism. Although model-based systems are more robust than heuristic-based expert systems, they generally require more computation time. Time consumption can be significantly reduced by using a hierarchical model scheme, which presents views of the device at several different levels of detail. We argue that in order to employ hierarchical models effectively, it is necessary to make economically rational choices concerning the trade-off between the cost of a diagnosis and its precision. The mechanism presented here makes these choices using a *Model Diagnosability Criterion* which estimates how much information could be gained by using a candidate model. It takes into account several important parameters, including the level of diagnosis precision required by the user, the computational resources available, the cost of observations, and the phase of the diagnosis. Experimental results demonstrate the effectiveness of the proposed mecha-

nism.

## 1 はじめに

種々の問題を解決する際に、その時の状況に応じて適切な問題解決方法を採用し、効果的に問題の解決を図る方式の実現が本研究の大きな目標である

例えば、我々が、「A地点からB地点へ行くのに何分くらいかかるか」と聞かれた場合を考えてみる。ここで答を出すための手段として、何通りかの方法が考えられる。経験的に「1時間あれば大丈夫」と簡単に答えてしまうのもひとつ的方法であるし、「A地点から駅まで歩いて15分で、電車の待ち時間が5分位で、C駅まで電車で20分で、…」と計算していく方法もある。さらには、時刻表を調べ、電車の乗り継ぎ情報まで考慮する方法も考えられる。ここで挙げた方法の中では、後者ほど答の精度が高くなる一方、解答するまでの手間(時間)がかかるといえる。人間はこのような方法を状況に応じて使い分けることができる。つまり、このような質問をされる度に、いつも時刻表を引こうとするといった不必要な行

動をとらずに、状況に応じて柔軟に対応することができる。もちろん、時刻表が手元にあるかどうか、といった情報によっても、選ばれる手段が変わってくる。

計算機を用いた各種の問題解決システムを構築する上で、このような、柔軟な問題解決機能の実現は、重要な課題のひとつである。上記の例では、答の精度と解答するまでの時間のトレードオフを解決して、問題解決方法を考える必要があったが、一般には、さらに様々な要因を考慮して、状況に応じた適切な問題解決方法をとることが望まれる。そのような機能の実現へ向けた第一歩として、本論文では、電子装置の故障診断問題を対象とし、モデルベース診断と呼ばれる診断手法を基本に、様々な状況・要因に応じた診断を可能とする方式を提案する。

モデルベース診断とは、診断対象装置の構造や動作に関する知識を基に、故障診断を行うアプローチである[Davis 84, de Kleer 87, Genesereth 84, Reiter 87]。この方式は、予期しない症状にたいしても対応可能であるという長所を持つ反面、論理的に考えられる全ての可能性を考慮するため、大規模なモデルを用いた場合に、非常に計算時間がかかるという問題点がある[Nakakuki 92b]。

モデルベースの診断の高速化に関しては、様々な研究成果が報告されている。特に、エントロピー最小法(GDE [de Kleer 87], Sherlock [de Kleer 89])やフォーカス法 [de Kleer 91]といった確率的な情報を扱う方式が注目されており、さらに確率的知識の学習機能[Nakakuki 90]の活用などによって、より効率の良い診断が期待できる。

しかしながら、大規模な問題を扱うためには、このような確率的な情報を利用するだけでなく、モデルを階層的に表現し、有効に活用していくことが必須である([Hamscher 90, 中莖 91, Nakakuki 92a])。一般に、より詳細なモデルを用いれば、きめ細かな診断が実現可能であるが、それだけ多くの計算時間が必要となる。そこで、例えば診断の序盤では、とりあえず抽象度の高いモデルを用いて大局的な故障箇所の絞り込みを行い、ある程度故障箇所が絞り込まれた後に、より詳細なレベルのモデルへ移行する、といった診断モデルの使い分けが重要となってくる。

ここで、そのような機能をうまく実現させるためには、要求される診断の精度等、診断時の状況を考慮する必要がある。例えば、ある電子装置の診断において、装置全体はいくつかのボードによって構成され、さらに各ボーダー

ドには、多くのLSIが載っている状況を考える。ここで、ボード単位で交換部品が用意されている場合には「どのボードが故障しているのか」を知ることが重要であるが、そうでない場合には、さらに「どのLSIが故障しているのか」という所まで調べてLSIの交換を行う必要がある。このような各状況に応じて、それぞれ適切な診断戦略を用いることが重要である。

さらに、診断システムにおいては、速く故障箇所を見つけることが要求される。つまり、対象装置のテストに要するコスト(時間)と診断計算のコスト(時間)の合計を最小とすることが必要となる。ところが一般に、観測コストは使用する道具や手段に大きく依存する。例えば手動でロジックアナライザを操作して電子回路内の信号値を読みとらなければならない場合と、電子ビームテスターを用いてLSI内部の任意の信号線の信号値を速やかに計測できる場合とでは、指定した観測点の信号値を得るまでにかかる時間には大きな差がある。一方、計算時間に關しても、用いる計算機によって数倍から数十倍の差がでてくる。

このように診断システムにおいては、観測に要する時

間と計算時間の兼ね合いに注意し、観測するために使用可能な道具や、計算機自身の処理能力等に応じて、適切な診断方針を選択する必要がある。

以上述べてきた点を整理すると、適応すべき項目として以下の点があげられる。

1. 診断の進み具合(序盤なのか終盤なのか)
2. どの程度細かいレベルまで診断する必要があるのか  
(診断の目的)
3. 診断対象装置の観測に要するコスト(簡単にテスト可能か否か)
4. 計算環境(計算機の処理能力等)

以下、第2章では、階層的なモデル記述の例を示し、診断に関する「情報量」を状況に応じてどのように捉えるかについて論じる。また、第3章では、考えられる各診断方法の「診断能力」を表す指標(Model Diagnosability Criterion)を導入する。さらに、第4章では、その指標に基づいた適応型の診断方式及びアルゴリズムを提案し、実験結果を示す。

## 2 階層的なモデルを用いた診断

通常、診断対象装置を階層的にモデル化する場合、論理的(機能的)な階層構造と物理的な階層構造の2種類の階層を考える必要がある [Davis 84, Hamscher 90]。一般に、どの程度詳しい診断をして欲しいかという要求は、物理的な階層レベル(例: ボードレベル、チップレベル等)で指定される。

通常、物理的階層と論理的階層は、異なる構造を持っているが、本報告では、簡単のため、両者が同じ構造を持っているものとして議論を進める。また、故障の数に関する限りも単一であるという仮定を置く。しかしながら、提案する手法は、より一般的の場合に対しても、容易に拡張可能であり、これらの仮定によって一般性が失われる事はない。

さて、ここで図2-1に示すような階層的なモデル記述について考える。1個のfull adder (a)は、より下位の5個の部品から構成されている。また、8bitのripple carry adder (b)は、8個の full adder で構成されている。

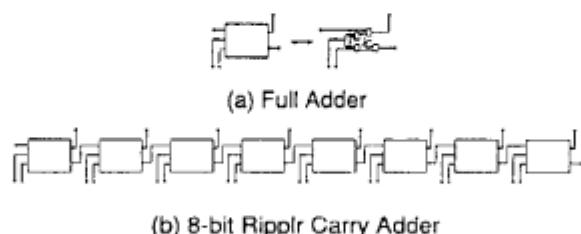


図 2-1 階層的なモデルの記述例

ここで、(b)の ripple carry adder を階層展開することを考えると、256通りの方法が考えられる。本論文では、階層的なモデル記述を展開して得られるモデルを展開モデルと呼ぶことにする。図2-2に、上記の例題の代表的な展開モデルを示す。展開モデルXは、最も上位レベルのモデルであり、展開モデルZは最も詳細なレベルのモデルである。また、展開モデルYは、その中間に位置するもののひとつである。一般に、より詳細な展開モデルを用いて診断を行った場合、より多くの診断情報を得ることができる反面、より多くの計算時間が必要となる。従って、効率の良い診断を行うためには、どの展開モデルを用いるべきか考慮しなければならない。

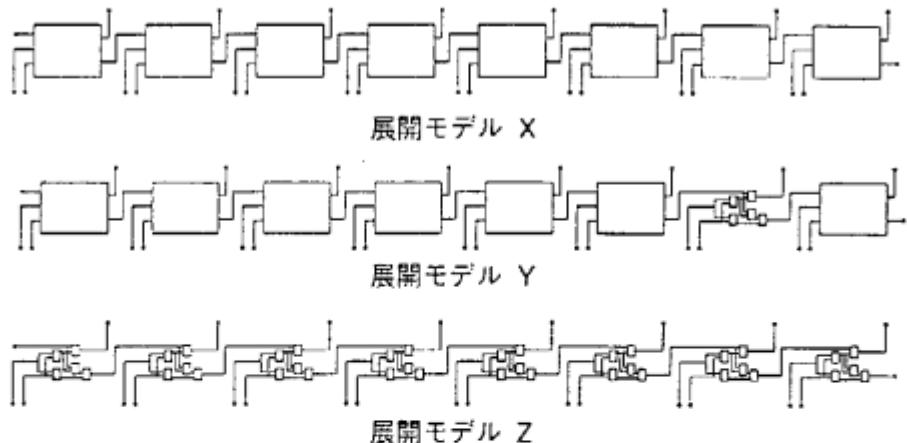


図 2-2 階層的モデルの展開例

ある展開モデルを用いた場合に、どの位の診断能力があるのかを推定する際には、前章で述べたように、診断時の状況を考慮する必要がある。3章では、そのような状況に応じて適切に各展開モデルの持つ診断能力を推定する方式について提案するが、その前に、状況に応じたエントロピーの算出方法について述べる。

## 2.1 診断精度とエントロピー

従来のモデルベース診断システムにおいては、「診断終了までにどの位の情報量が必要か」を見積もるために、被疑部品のエントロピーを用いているものが多い[de Kleer 87, de Kleer 89, Hamscher 90, Koseki 90]。しかしながら、必要とされる情報量は、実は「どの位の診断精度が要求されているか」に大きく依存する。図2-3に2-bit ripple carry adder の診断の状態を2つのレベル、即ち、(a)ファンクションレベルと(b)ゲートレベルで見た例を示す。網掛けになっている部品は故障の疑いがあることを示しており、白い部品は診断の過程で正常であることが判明したことを示している。各部品  $C$  の推定故障確率  $P(C)$  は図中に示した通りである。図中(a)(b)とともに、診断の初期状態(全ての部品に故障の疑いがある)と、観測情報AあるいはBが得られた後の診断状態をそれぞれ示してある。

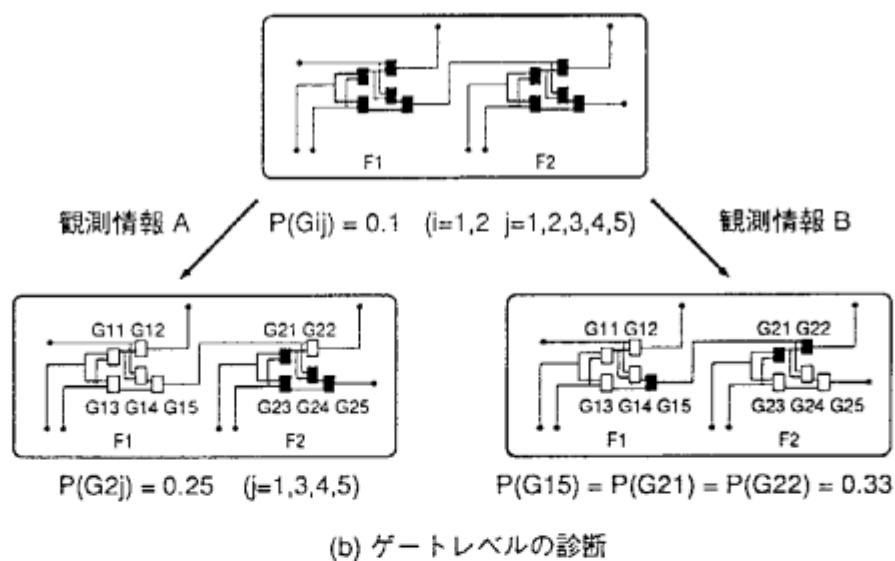
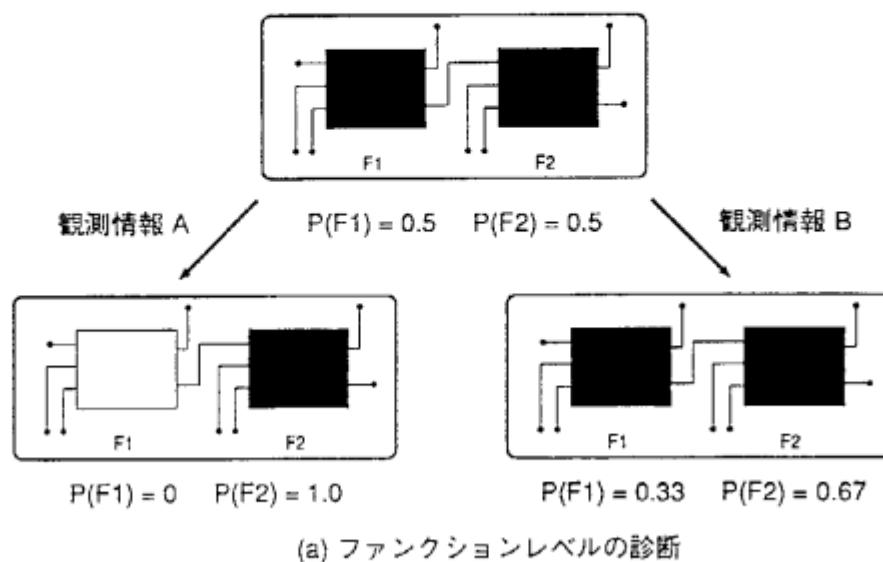


図 2-3 観測情報の有用性

ここでまず、ユーザから要求された診断精度がファンクションレベルである場合を考える。図 2-3(a)から判るように、もし観測情報Aが得られれば、 $F_1$ が正常であることが判明し、診断は終了する。一方、観測結果Bが得られた場合には、 $F_1$ 、 $F_2$ 共に故障の疑いが残ってしまうため、結論を出すことができない。従って、Aの方がより有用な情報であると考えるのが自然である。

ところが、要求された診断精度がゲートレベルの場合を考えると、図 2-3(b)から判るように、もし観測情報Aが得られたとすると10個の被疑部品が4個に減るだけであるのに対して、観測情報Bが得られれば3個にまで減らすことが可能である。従って、この場合には、観測情報Bの方が有効な情報であると考えられる。

このように、各観測情報に対する「診断を進める上で貢献度」は、要求されている診断精度に依存することがわかる。このような、要求される診断精度に応じた情報量を計るために、物理的階層の各レベルでのエントロピーを用いることとする。例えば、上記の例で、ファンクションレベルのエントロピー( $E_F$ )とゲートレベルのエ

ントロピー( $E_G$ )は、以下のように定義される。

$$E_F = - \sum_i P(F_i) \log P(F_i)$$

$$E_G = - \sum_i \sum_j P(G_{ij}) \log P(G_{ij})$$

図2-4に上記の観測情報AおよびBが得られた際の各エントロピーの変化を示す。この図から、エントロピーの定義によって、観測情報の持つ情報量が逆転することがわかる。

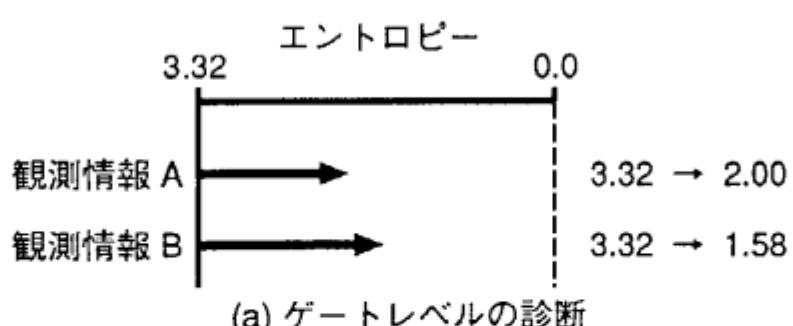
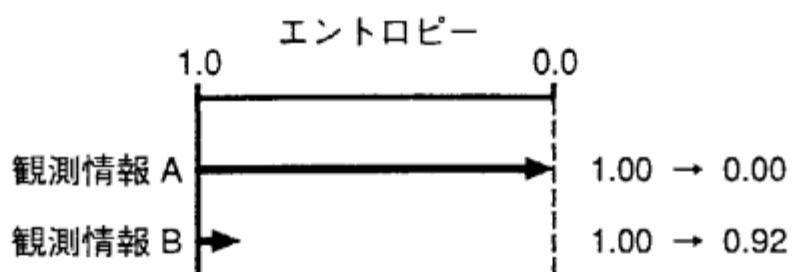


図 2-4 エントロピーの変化

ここで、指定されたレベルのエントロピーは、「そのレベルでの診断を完了するために、さらにどの位の情報量が必要であるか」を示すものと考えることができる。例えば、その値が0になれば、それ以上情報が必要ない（診断が終了した）ことを示す。同様に、エントロピーの値が2であれば、「診断を完了するまでに、あと2比特の情報が必要である」ことになる。

本論文で提案する手法では、「指定された診断精度に対するエントロピー」を0に減らすことを目的にして診断が進められる。例えば、指定された診断精度がファンクションレベルであれば、 $E_F$ を効率よく0に減らすようなテストが選択され、実行される。このように、状況に応じて診断に用いるエントロピーを使い分けることにより、それぞれの状況に適した診断戦略をとることができます。

### 3 モデルの診断能力

本章では、診断時に用いる展開モデルの診断能力を表す指標（Model Diagnosability Criterion）を導入する。この指標は、各展開モデルを用いた場合に、最大でどのくらい多くの情報量を得ることが可能であるのかを示す

ものである。

ここで例題として、2-bit の ripple carry adder の診断について、図3-1に示すような3種類の展開モデルを用いた診断を考える。

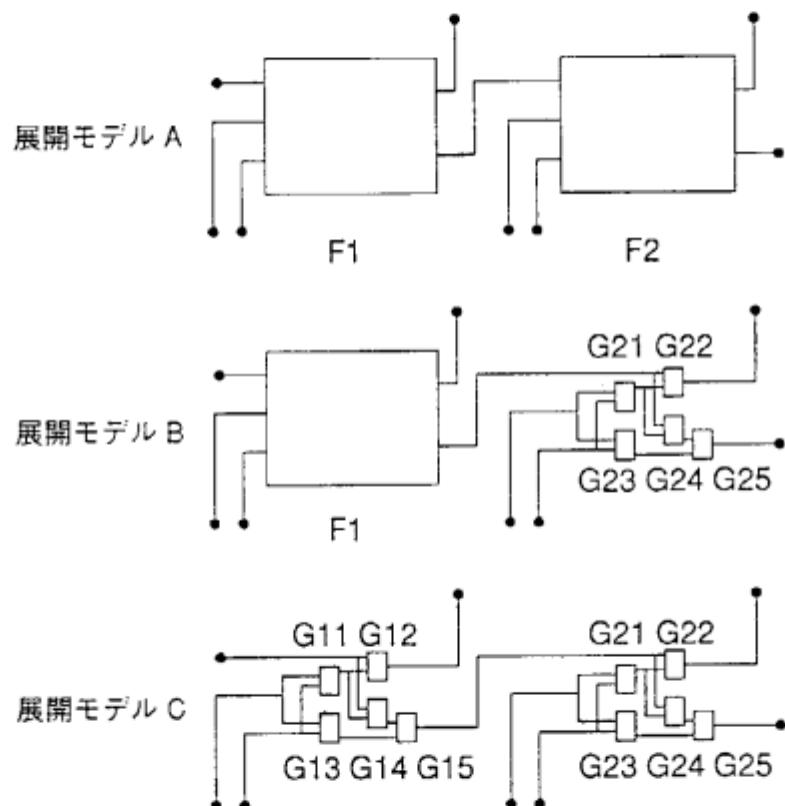


図 3-1 2bit ripple carry adder 用展開モデル

まず、ゲートレベルの精度が要求される場合を考える(診断開始時は10個のゲートの推定故障確率は各0.1であるものと仮定する)。展開モデルAを用いた場合、もし十分な観測情報が得られれば、壊れているファンクション( $F_1$ または $F_2$ )を特定することは可能であっても、「その中のどのゲートが故障しているのか」については知ることができない。例えば、 $G_{11}$ が故障していた場合、どのように多くの観測情報が得られても「故障ゲートは $G_{11}, G_{12}, G_{13}, G_{14}, G_{15}$ の内のどれかである(確率は各0.2)」という状態から先には診断は進まず、故障ゲートを特定するまでには至らない。従って、モデルAを用いる限り、ゲートレベルのエントロピーは、 $5 \cdot (-0.2 \log 0.2) = 2.32$ 未満に減らすことができないことになる。つまり、診断を完了するために必要な情報の内、2.32ビットは得ることができないということになる。

一方、展開モデルBを用いた場合、故障ゲートが $G_{2i}$ ( $i = 1, 2, 3, 4, 5$ )であれば、十分な情報さえ得られれば、故障ゲートを特定する(エントロピーを0にする)ことが可能である。しかしながら、故障部品が $G_{1i}$ の場合には、モデルAの時と同様に故障ゲートを特定することができな

い(エントロピーを2.32未満に減らせない)。従って、平均すると、

$$0.5 \cdot 2.32 + 0.5 \cdot 0 = 1.16$$

となり、このモデルを用いた場合には、診断に必要な情報量の内、平均して1.16ビットの情報が得られないことになる。

最後に、展開モデルCを用いた場合について考えると、この場合には十分な観測情報が得られれば必ず故障ゲートを特定することが可能であり、このレベルのエントロピーを0にすることができる。

そこで、診断の各過程において、考えられる各展開モデル  $M$  を用いた場合に、どの程度の診断情報が得られるかを推定するための指標  $D(M)$  を次のように定義する。

$$D(M) = \frac{E_{cur} - E_{min}}{E_{cur}}$$

ここで、 $E_{cur}$  は、現在の診断過程(状態)におけるエントロピーであり、 $E_{min}$  は、もし十分な情報が得られる仮定して、展開モデル  $M$  を用いた場合にエントロピーをどの位まで減らすことが可能であるかを示す値である。

言いかえれば、分母は、診断を終了するために「あとどの位の情報が必要か」を表し、分子の方は、その必要な情報の内「最大でどの位の情報が得られるか」を示している。

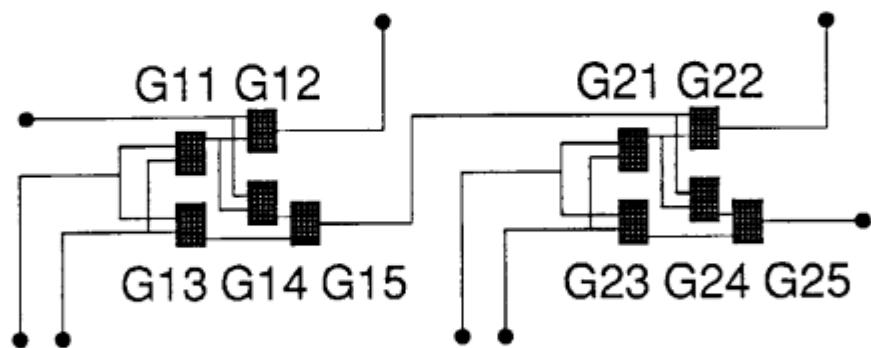
前述の例で、診断の初期状態（図3-2(a)）でのエントロピーは  $10 \cdot (-0.1 \log 0.1) = 3.32$  である。従って、その時点でのモデルA, B, Cの診断能力は次のように計算される。

$$D(A) = (3.32 - 2.32)/3.32 = 0.30$$

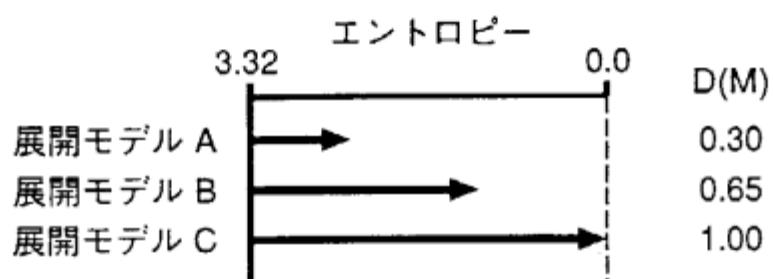
$$D(B) = (3.32 - 1.16)/3.32 = 0.65$$

$$D(C) = (3.32 - 0.00)/3.32 = 1.00$$

図3-2(b)に示すように、展開モデルAを用いた場合、必要な情報の約30%しか得られないのに対し、展開モデルCでは必要な全ての情報が得られることが判る。



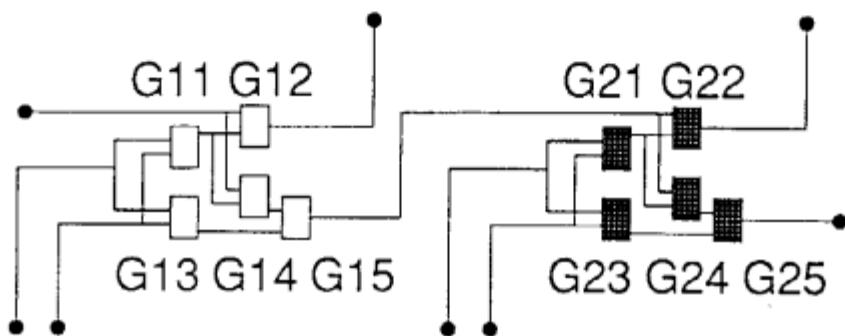
(a) 診断の状況



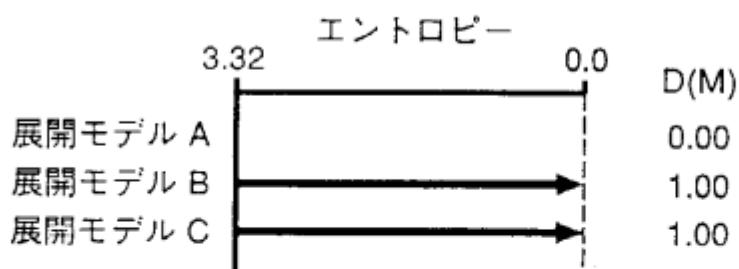
(b) 診断能力の評価結果  $D(M)$

図 3-2 診断の開始時における各モデルの評価

次に、もう少し診断が進んで、故障部品がある程度絞り込まれた後の状況を考える。図3-3(a)に示すように、被疑ゲートが5個になった場合、各展開モデルの診断能力指標は、図3-3(b)に示したようになる。この状態では、展開モデルAを用いた場合に診断能力指標は0.0、展開モデルBやCでは1.0となる。



(a) 診断の状況



(b) 診断能力の評価結果  $D(M)$

図 3-3 診断の途中状態における各モデルの評価

## 4 適応型の診断機構

### 4.1 モデルの選択方式

本章では、診断の各段階において、適切な展開モデルを選択・利用していく方式について述べる。

診断時に、1回の観測に要する平均コスト(時間)を  $C$  とし、展開モデル  $M$  を用いて1回の診断計算をする際に要する時間を  $T(M)$  とすると、1回の診断サイクルに要する時間は、 $T(M) + C$  となる。そこで、適切な展開モデルを選択するための評価方法として、診断能力指標を所要時間で除した次のようなものを用いる。

$$E(M) = D(M)/(T(M) + C)$$

ここでは仮定として、 $T(M)$  は過去の経験あるいは解析的な手法により予測可能であるとし、さらに  $C$  は展開モデルに依存しない定数であるものとする。各診断サイクルにおいて、評価値  $E(M)$  を最も大きくする  $M$  が選択される。この方式では、(1)診断の進み具合、(2)指定された診断精度、(3)観測コスト、(4)計算コストといった各要因を考慮した適切な選択が可能となる。以下、提案方式により上記の各要因に適応した診断が実現可能であることを例を用いて示す。

まず、8-bit ripple carry adderの診断において、ゲートレベルの診断精度が要求されている状況を考える。ここで、図2-2に示したの各展開モデルを用いた場合の診断計算の時間が次のような値であるとする(この値は、モデルベース診断実験システム([Koseki 90])を用いて得られたものである)。

$$T(\text{model } X) = 0.30 \text{ (sec)}$$

$$T(\text{model } Y) = 0.39 \text{ (sec)}$$

$$T(\text{model } Z) = 1.22 \text{ (sec)}$$

ここでは、まず観測コストが比較的小さい場合(各モデル  $M$  について、 $C \ll T(M)$  である場合)を考える。

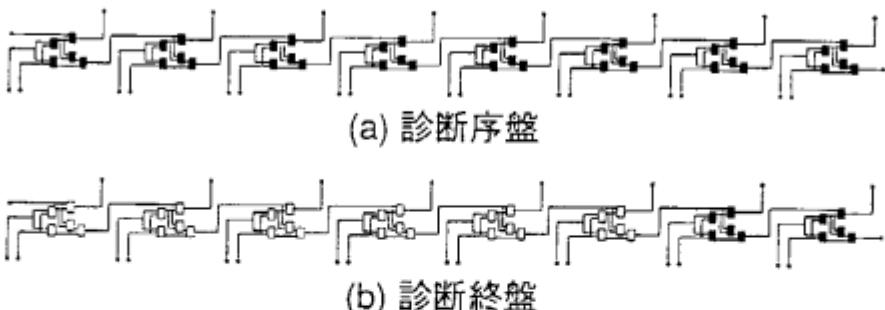


図 4-1 診断状態

**診断序盤** 図4-1(a)は、診断が始まったばかりの段階の例を示す。この状態では、全てのゲートが一様に疑わしい(故障確率は各 $1/40$ )。表4-1(a)に評価値を示すように、この場合には展開モデルXが選択される。これは、必要な情報の56%を低いコスト(短時間)で獲得できることが期待されるためである。

**診断終盤** 次に、いくつかの情報が得られた後の診断終盤の段階を考える(図4-1(b))。この場合、表4-1(b)に示すように、展開モデルYが最も高い評価値を得る。なぜならば、Xは必要な情報の約30%しか得られず、ZはYの約3倍の大きなコストがかかるためである。このように、提案手法により、診断の進み具合に応じて適切な展開モデルを使い分けることが可能となる。

表 4-1 展開モデル  $M$  の評価値  $E(M)$  ( $C \ll T(M)$ )

(a) 診断序盤

展開モデル	$D(M)$	コスト	$E(M)$
X	0.56	0.30	1.86
Y	0.62	0.39	1.58
Z	1.00	1.22	0.82

(b) 診断終盤

展開モデル	$D(M)$	コスト	$E(M)$
X	0.30	0.30	1.00
Y	0.65	0.39	3.42
Z	1.00	1.22	0.82

次に、観測コストが計算コストに比べて大きな状況を考える。この場合、診断全体のコストは、主に観測コスト  $C$  によって決まると考えて良い。例えば上の例で、仮に  $C = 100.0$  (sec) であったとすると、各展開モデル X、Y、Z を用いた場合の診断の1サイクルにかかるコスト（診断計算コストと観測コストの和）は、それぞれ、100.30、100.39、101.22 となり、大差がなくなる（表 4-2）。この場合には、計算時間があまり問題にならないために、診断の序盤から終盤まで最も詳細な展開モデル(Z) を用いて、できるだけ効率のよいテストの選択を行い、その結果として、実行するテストの回数を減らす（全体の所要時間を短縮する）という戦略が採用される。

表 4-2 展開モデル  $M$  の評価値  $E(M)$  ( $T(M) \ll C$ )

(a) 診断序盤

展開モデル	$D(M)$	コスト	$E(M)$
X	0.56	100.3	0.0056
Y	0.62	100.4	0.0061
Z	1.00	101.2	0.0099

(b) 診断終盤

展開モデル	$D(M)$	コスト	$E(M)$
X	0.30	100.3	0.0030
Y	0.65	100.4	0.0065
Z	1.00	101.2	0.0099

ここで、別の見方をすれば、提案方式は「利用する計算機の能力」にも適応可能であることがわかる。例えば、1MIPSの計算機を用いる場合と、100MIPSの計算機を利用できる場合では、診断計算に要する時間が大きく異なるため、異なった診断戦略が採用される。従来の診断システムでは、計算機が100倍速くなっても、単に答を出すまでの時間が短縮されるだけであったが、この方式

を採用することで、計算能力が高い分、「より賢い診断」を行うことが可能となる。

最後に、上記の各例題で、指定された診断精度がゲートレベルではなく、ファンクションレベルであった場合を考えると、展開モデルX, Y, Z共に十分な診断能力を持ち合わせているため、前記のどの場面においても、最も計算コストの少ないXが採用される。つまり、あまり高い診断精度が要求されていない場合には、より抽象度の高い展開モデルを用いることで、不必要に細かい計算を避けることが可能となる。

#### 4.2 モデル選択アルゴリズム

一般に、診断時に選択可能な展開モデルの数は、対象装置の部品数に対して指數関数的に増大する。従って、考えられる全ての展開モデルに対して、その評価値を計算する方式は現実的ではない。そこで、ここでは次に示すようなヒューリスティックアルゴリズム(HIMA)を用いる。

$M \leftarrow$  最も抽象度が高い展開モデル;

$C \leftarrow M$  を構成する部品の集合;

```

while ( $\exists c_i \in C [E(expand(M, c_i)) > E(M)]$ )
     $M \leftarrow expand(M, c_i);$ 
     $C \leftarrow (C - \{c_i\}) \cup comp(c_i);$ 

```

ここで、 $expand(M, c_i)$  は、モデル  $M$  の中の部品  $c_i$  を展開して得られる展開モデルを示す。例えば、図 2-2において、 $model Y = expand(Model X, f_7)$  である ( $f_7$  は左から7番目の full adder)。また、 $comp(c_i)$  は、部品  $c_i$  を展開した時の構成部品集合である。図 2-3 の例では、 $comp(F1) = \{G11, G12, \dots, G15\}$  である。

このアルゴリズム終了時の展開モデル  $M$  が選択・採用される。本アルゴリズムは、ヒューリスティックアルゴリズムであり、必ずしも最適な展開モデルが得られる保証はないが、与えられたモデルの部品数に対して線形の計算量で解が得られるという大きなメリットがある。多くの実際の問題においては、この程度のアルゴリズムで実用上十分であると考えられる。

#### 4.3 実験結果

アルゴリズムHIMAによって選ばれた展開モデルを用いた診断について、実験による評価を行った。実験に用いた対象装置は、16ビットの加算機で、3レベルからなる階層的なモデルの記述を与えた。各レベルの部品数は、上位からそれぞれ2、32、160である。また、診断精度については、最も詳細なレベルで故障部品を特定するよう指定した。

比較のため、HIMAの他に展開モデル選択のための方式を2種類用意した。ひとつは指定された診断精度レベルのモデルを診断の最初から最後まで用いるもの(FIX)である。今回の例題に対しては、この方式は常に最も詳細なレベルのモデルを用いることになる。もうひとつのアルゴリズム(AHAP)は、可能な限り上位のモデルを用いるもので、診断の過程において「現在用いている展開モデルの詳細度では、それ以上新たな情報が得られる可能性がない」場合に限り、全体をより詳細なレベルの展開モデルに置き換えるというものであり、XDE([Hamscher 90])で採用している方式である。

実験は、故障を乱数を用いて繰り返し発生させ、各々

に対して、上記の各アルゴリズムを用いて診断を行い、故障部品を発見するまでに要した平均の診断コスト（計算コストと観測コストの和）を測定した。観測コストに関しては、1回あたり1msec、1sec、100secの3通りの状況を設定して実験を行った。実験の結果、表4-3に示すように、各状況ともHIMAが最も効率が良いという結果を得た。

表 4-3 平均診断時間 (sec)

アルゴリズム	1回の観測コスト(時間)		
	1 msec	1 sec	100 sec
FIX	4.0	11.3	734.0
AHAP	1.3	21.7	2041.3
HIMA	0.8	8.1	730.8

## 5 おわりに

本論文で提案した方式によって、診断の進み具合、要求される診断精度、計算機自身の処理能力や観測に要するコスト等の様々な要因を考慮した診断が可能となることが示された。

診断能力の推定においては、例えば、仮に  $D(M)$  が 0.9 であっても、この 90% の情報が平均して何回の観測によって得られるか、といった点に関しては、考慮されていない。従って、今回導入した  $D(M)$  は完全なものではなく、改良の余地がある。また、観測に要する時間について、利用する展開モデルに依存しないという仮定をおいたが、場合によっては、展開のレベルに依存する場合もないとはいえない。この点においても改良の余地が見られる。

最後に、本論文で示した考え方は、診断問題以外の様々な分野の問題解決に拡張していくことが可能であり、今後の研究の課題としたい。

### 謝辞

本研究は、第5世代コンピュータプロジェクトの一環として行われたものである。お世話になった(財)新世代コンピュータ技術開発機構の関係各位に感謝いたします。

### ◇ 参考文献 ◇

- [Davis 84] Davis, R., "Diagnostic reasoning based on structure and behavior," *Artificial Intelligence*, Vol. 24, pp. 347–410, 1984.
- [de Kleer 87] de Kleer, J. and Williams, B. C., "Diagnosing multiple faults," *Artificial Intelligence*, Vol. 32, pp. 97–130, 1987.
- [de Kleer 89] de Kleer, J. and Williams, B. C., "Diagnosis with behavioral modes," *Proc. IJCAI-89*, Vol. 2, pp. 1324–1330, 1989.
- [de Kleer 91] de Kleer, J., "Focusing on probable diagnosis," *Proc. AAAI-91*, Vol. 2, pp. 842–848, 1991.
- [Genesereth 84] Genesereth, M. R., "The use of design descriptions in automated diagnosis," *Artificial Intelligence*, Vol. 24, pp. 411–436, 1984.
- [Hamscher 90] Hamscher, W., "XDE: Diagnosing devices with hierachic structure and known component failure modes," *Proc. CAIA-90*, Vol. 1, pp. 48–54, 1990.
- [Koseki 90] Koseki, Y., Nakakuki, Y., and Tanaka, M., "An adaptive model-Based diagnostic system," *Proc. PRICAI'90*, Vol. 1, pp. 104–109, 1990.

- [Nakakuki 90] Nakakuki, Y., Koseki, Y., and Tanaka, M., “Inductive learning in probabilistic domain,” *Proc. AAAI-90*, Vol. 2, pp. 809–814, 1990.
- [中莖 91] 中莖洋一郎、古関義幸、田中みどり「階層的モデルベース診断における診断戦略」 人工知能学会全国大会、Vol. 1, pp. 313–316, 1991.
- [Nakakuki 92a] Nakakuki, Y., Koseki, Y., and Tanaka, M., “Adaptive model-Based diagnostic mechanism using a hierarchical model scheme,” *Proc. AAAI-92*, pp. 564–569, 1992.
- [Nakakuki 92b] Nakakuki, Y., Koseki, Y., and Tanaka, M., “A Parallel inductive learning algorithm for adaptive diagnosis,” *Proc. FGCS-92*, pp. 1190–1197, 1992.
- [Reiter 87] Reiter, R., “A theory of diagnosis from first principles,” *Artificial Intelligence*, Vol. 32, pp. 57–95, 1987.