免疫型診断に対する既知の故障モード検出の効率改善*

和田 浩司[†]・鳥生 隆[†]・濱 裕光[‡]

Improving the Efficiency of Known Fault Mode Detection for Immunity-based Diagnosis*

Koji WADA[†], Takashi TORIU[†] and Hiromitsu HAMA[‡]

In this paper, the dynamic model of 'credibility', which is used as main parameter of judgment in immunity-based system diagnosis, is extended so that diagnosis system can quickly judge fault if a specific fault mode occurs in a sensor. The amount of change of credibility changes according to size of similarity between actual output of a sensor and estimated output of it. The estimated output is calculated by using relationship among outputs of other sensors if a specific fault mode occurs in the sensor. The effectiveness of the proposed method is evaluated by experiments.

1. はじめに

90年代に出現した人工免疫システム (artificial immune system) は, 自然の免疫システム (natural immune system) の原理に基づいて発展したコンピュータシステムであり [1], 複合問題の最適化, 故障診断など, さまざまなエンジニアリングの分野で幅広く適用されている [2–4]. とくに人工免疫システムを用いた故障診断では, 未知の故障状態が検出可能となるという点で非常に有望であり, これまでに故障診断への適用事例 [5] が報告されている. これらの例として, 制御システム内に配置されたセンサの故障診断に, 免疫システムの特徴を用いた診断のアルゴリズムが提案されている [6–10]. 免疫型システムによる故障診断では, 故障の状態が動的ネットワークの平衡点へ埋め込まれている, という特徴がある. ネットワークの平衡状態で診断結果を表現するため, センサあるいはプロセスの未知の故障状態に対しても柔軟に故障の判定ができる. しかしながら, センサによる観測値にノイズが重畳する環境下で正確な故障判定を行うためには, 動的ネットワークを平衡状態とするために更新感度を下

げる必要がある. すなわち, 免疫型システムで故障の判定に用いる「信用度」パラメータに与えるノイズの影響を抑制するためには, このパラメータの更新感度を下げる必要がある, これが故障を確定するまでの期間を長くする原因となっている.

一方で, 現実的には, 発生頻度が高い故障モードがあらかじめわかっている場合が多い [12,13]. たとえば, 自動車など, 高い信頼性を必要とする制御システムにおいては, むしろ多くの故障モードが既知であることを積極的に利用して, フェールセーフ制御を構成することにより, その要求に込えている [13]. また, このような故障モードが発生した場合には, 故障を確定するまでの期間をできる限り短縮させて, 早期にシステムを正常な状態に修復したい, というシステム運用面での要求がある.

これらの課題を克服するために, 本論文では未知の故障モードに対する故障検出性能を維持しつつ, 発生頻度が高い「既知の故障モード」に対しては, 少ない観測回数で故障を検出できる診断方法を提案する. 具体的には, あるセンサに既知の故障モードが発生した際に, 他のセンサの出力値を既知の関係に当てはめて, そのセンサの出力値を推測し, 実際のセンサ出力との類似度を算出して, この類似度に応じて信用度パラメータの更新量を調整することで, 故障確定までの期間を短縮するものである. **2.**では本論文で提案する診断方法の基礎になる, 免疫型システムによる診断モデル [8] と既知の故障モードに対する本モデルの拡張について示す. **3.**では診断モデルのアルゴリズムと, 観測ノイズによる故障確定に要す

* 原稿受付 2013年5月20日

[†] 大阪市立大学大学院 工学研究科 Graduate School of Engineering, Osaka City University; 3-3-138 Sugimoto, Sumiyoshi, Osaka city 558-8585, JAPAN

[‡] 次世代検索エンジン R&D 研究室 R&D Center of 3G Search Engine, Incubator; 3-3-138, Sugimoto, Sumiyoshi, Osaka city 558-8585, JAPAN

Key Words: diagnosis, immunity-based, similarity, specific fault mode.

る観測回数への影響について示す。4. では未知の故障モードに対する故障検出能力を維持しつつ、ノイズの多い環境下でも既知の故障モードに対して故障確定までの観測回数を少なくできる点を数値実験により検証する。

2. 免疫型システムによる診断アルゴリズム

2.1 診断の基本モデル

ここでは、本論文の診断方法の基礎になる、診断アルゴリズムの基本モデルについて述べる。システム内の各々のセンサは信用度というパラメータを有し、このパラメータの値に応じて、そのセンサの正常、あるいは異常（故障）を判断する。各々のセンサの信用度は、他センサとの相互テストの結果と、相互テストの対象センサの信用度を基に算出する。信用度の動的モデルには診断の結果を確定的に扱うモデル（すなわち、信用度が正常（= 1）、故障（= 0）の 2 値しかもたないモデル）や、結果に曖昧性を残すモデルなど、用途に応じていくつかのバリエーションが存在する [8]。将来的にこの信用度の値を故障の程度を判定する尺度に活用することを考慮して、本論文では結果に曖昧性を残すモデルを基に診断方法の検討を行う。

Fig. 1 で示す自動車の排気ガス浄化システムの場合、エンジンや変速機、触媒コンバータなどを中心として多数のセンサが配置されており、これらのセンサ出力の妥当性を監視しながら、制御装置は適切に燃料を燃焼させている。ここで、 $s_i (i=1, \dots, n)$ をシステム内のセンサとし、 $S_k (k=1, \dots, m)$ をそれぞれの出力に関係のあるセンサ群の集合とする。なお、ここでいう「関係がある」とは、他の要素の値が確定すれば、残りの一つの要素の値が一意に決まることであると定義する。これらを Fig. 2 を用いて説明する。Fig. 2 は Fig. 1 のセンサの関係を示した図であり、センサ $s_i (i=1, \dots, 6)$ に対して、それぞれの出力に関係のあるセンサの集合 $S_k (k=1, \dots, 4)$ が存在している。たとえば、 $S_3 = \{s_1, s_3, s_4\}$ の場合は、 s_3, s_4 の出力値が確定すれば、 s_1 の出力値が一意に決まる。このような関係は、現実的には、たとえば定容積の空間で、組成が既知の気体の圧力と温度が検出できれば、質量が一意に決まる関係に見られる。このような冗長性が異常検出のかぎである。また、 $T_k (k=1, \dots, 4)$ は、 S_k の要素をなす各センサの出力があらかじめ決められた関係を満たすか否かのテストの結果を示し、結果に応じて正あるいは負の数をとる。 $r_i(t)$ は時刻 t におけるセンサ s_i の信用度の時間関数であり、その動的モデルを

$$\frac{dr_i(t)}{dt} = \sum_{k, s_i \in S_k} \left\{ T_k R_{T_k}(t) \prod_{\substack{j, s_j \in S_k \\ j \neq i}} R_j(t) \right\} - \frac{r_i(t)}{\tau} \quad (1)$$

Fig. 1 Automotive exhaust gas treatment system

Fig. 2 Example of sensor groups

で示す [8]。なお、文献 [8] で示される (1) 式の右辺第 2 項の抑制項に関して、本論文では時間の単位に取り方に依存しないように時定数 τ を設けている。信用度 $R_i(t)$ は、この $r_i(t)$ を $[0, 1]$ の範囲に正規化したものであり、

$$R_i(t) = \frac{1}{1 + \exp(-r_i(t))} \quad (2)$$

で示す。 $R_i(t)$ が 0.5 より小さい場合に、対応するセンサ s_i を故障と判定し、それ以外の場合は正常と判定する。(1) 式の右辺第 1 項において、 $\sum$ はセンサ s_i に関係があるセンサ集合 S_k についての和であり、 $\prod$ は S_k に含まれる s_i 以外のセンサ s_j の信用度 $R_j(t)$ の積を表す。 S_k に含まれるセンサ間の関係の整合性のテスト結果 T_k を、

$$T_k \equiv \begin{cases} 1, & \text{if } |f_k(\mathbf{V}_k(t))| \leq \epsilon_k \\ -1, & \text{otherwise} \end{cases} \quad (3)$$

と定義する。ここで、センサ間の関係を「制約」として $f_k(\mathbf{V}_k(t)) = 0$ で表す。 $\mathbf{V}_k(t)$ はセンサ群 S_k に含まれるセンサの時刻 t における出力値のベクトルである。この制約により、他の要素の値が確定すれば、残りの一つの要素の値が一意に決まることとなる。なお、 ϵ_k は許容される誤差などを考慮して、事前に決められる定数である。したがって、センサ s_i を信用しようとするセンサの加重評価が、信用できないとするセンサのそれより大きいとき、(1) 式の右辺第 1 項は正となり増加する。

つぎに、センサの信用度と同様に、各制約に対する信用度も導入する。各制約の信用度 $R_{T_k}(t)$ の時間関数 $r_{T_k}(t) \in (-\infty, 0]$ の動的モデルを

$$\frac{dr_{T_k}(t)}{dt} = T_k \prod_{i, s_i \in S_k} R_i(t) - \frac{r_{T_k}(t)}{\tau} \quad (4)$$

で示す。また、信用度 $R_{T_k}(t) \in [0, 1]$ は

$$R_{T_k}(t) = \begin{cases} 1, & \text{if } T_k = 1 \\ 2 / \{1 + \exp(-r_{T_k}(t))\}, & \text{otherwise} \end{cases} \quad (5)$$

で示す。

2.2 既知の故障モードに対する診断

ここでは、従来の診断モデルからの拡張について述べる。前述のとおり、センサが陥りやすい故障モードはあらかじめわかっていることが多い。たとえば、センサの構成部品の経年変化などに起因する、特定の部材の変質や消耗などである。このため、センサに既知の故障モードが生じた状態のセンサの入出力特性はあらかじめわかっていることが多い。既知の故障モードが生じたセンサ s_i を含むセンサ群 S_k に含まれるセンサ間の関係を $v_i(t) = g_{ik}(\mathbf{v}_{ik}(t))$ とする。ここで $\mathbf{v}_{ik}(t)$ はベクトル $\mathbf{V}_k(t)$ から要素 $v_i(t)$ を除いたベクトルである。ただし、この関係式は、故障していないセンサの出力に誤差が生じていない、「典型的な」状態であり、現実的には故障したセンサ以外のセンサ出力にも誤差は生じる。そこで、この誤差を考慮した許容範囲 μ_k を加味して、 $|v_i(t) - g_{ik}(\mathbf{v}_{ik}(t))| \leq \mu_k$ が成立する状態を、既知の故障モードが発生した場合の各センサ間の関係とする。

2.3 信用度の動的モデルの拡張

免疫型システムの診断の特長は、未知の故障モードに対しても柔軟に故障検出できることであり、この特長を維持しつつ、既知の故障モードに対して信用度の減少を速める方法を検討する。

(1) 式で示した信用度の動的モデルをもとに、既知の故障モードが生じた場合に信用度が減少するようにモデルを拡張する。具体的には、既知の故障モードが発生した際に、他のセンサの出力値を既知の関係に当てはめて、そのセンサの出力値を推測し、実際のセンサ出力との類似度に応じて、信用度の時間関数の動的モデルの更新量を変化させる。類似度 C_{ik} は、観測されたセンサの出力と既知の故障モードが発生した場合に推測される値との平均距離

$$D_{ik}(L) = \frac{1}{L} \sum_{l=1}^L \sqrt{(v_i(t_l) - g_{ik}(\mathbf{v}_{ik}(t_l)))^2} \quad (6)$$

より算出される。 t_l は制約 f_k で整合がとれない観測時刻であり、 L は時刻 $t=0$ から $t=t_l$ までの間に制約 f_k で整合がとれなくなったサンプリングの回数である。サンプリング数で平均することにより、センサの観測値に重畳するノイズの影響を抑制する。つぎに、類似度 $C_{ik}(L)$ を、(6) 式で算出した $D_{ik}(L)$ を用いて

$$C_{ik}(L) = \begin{cases} 1 - \exp\left(-\frac{\delta}{D_{ik}(L)}\right), & \text{if } D_{ik}(L) \neq 0 \\ 1, & \text{if } D_{ik}(L) = 0 \\ 0, & \text{if } L < L_{\min} \end{cases} \quad (7)$$

として求める。(7) 式は、(6) 式で定義した平均距離 $D_{ik}(L)$ をもとに、実際の各センサの実際の出力で構成される関係と、特定の故障モードが発生した場合に生じる典型的な各センサ出力の関係との類似性を類似度として定量化している。 δ は類似度の調整感度、 $L_{\min}$ は類似度を算出するために必要なサンプリング数の最小値である。この類似度 $C_{ik}(L)$ を用いて (1) 式を拡張すると

$$\frac{dr_i(t)}{dt} = \sum_{k, s_i \in S_k} \left\{ T_k R_{T_k}(t) \prod_{\substack{j, s_j \in S_k \\ j \neq i}} R_j(t) \right\} - \frac{r_i(t)}{\tau} - \prod_{k, s_i \in S_k} C_{ik}(L) \quad (8)$$

となる。(8) 式は (1) 式の右辺に第 3 項として類似度 $C_{ik}(L)$ の積を減じたものである。これはセンサ s_i が関与するすべての制約で類似度が同時に大きくなる場合にのみ、センサ s_i の信用度 $R_i(t)$ の時間関数 $r_i(t)$ が減少するようにした動的モデルの拡張である。なお、

$$\prod_{k, s_i \in S_k} C_{ik}(L) < C_{\min}$$

の場合は、(8) 式の代わりに (1) 式を $r_i(t)$ の時間変化率の算出に適用する。これは、既知の故障モードとの類似度が小さい場合は、未知の故障として扱うための処置である。このため、故障モードが未知の場合は従来の動的モデルと等価となるので、未知の故障モードに対する故障検出の柔軟性は維持されている。

2.4 複数の既知の故障モードへの対応

一般に、既知の故障モードはシステム内のすべてのセンサに存在しうる。また、それぞれのセンサは複数の部品で構成されており、これらの個々の部品に関して既知の故障モードが存在しうる。たとえば、センサの内部回路で結線がショートすることもあれば、断線することもある。実際には、発生確率の違いはあるにせよ、1 個のセンサに対して複数の既知の故障モードが存在しうる。そこで、特定のセンサ以外も含めて、複数の故障モードが発生しうる場合に対応できるような診断モデルの拡張を行う。

センサ s_i が p_i 個の既知の故障モードを有する場合（ただし、 $p_i \geq 1$ ）、センサ s_i を含む S_k において、センサ s_i の p 番目の既知の故障モードに対するセンサ間の関係を $v_i(t) = g_{ik}^{(i,p)}(\mathbf{v}_{ik}(t))$ とする。つぎに、この関係

式を用いて、(6) 式を複数の既知の故障モードに対応するように

$$D_{ik}^{(i,p)}(L) = \frac{1}{L} \sum_{l=1}^L \sqrt{(v_i(t_l) - g_{ik}^{(i,p)}(v_k(t_l)))^2} \quad (9)$$

と拡張する。同様に、(7) 式、(8) 式を、

$$C_{ik}^{(i,p)}(L) = \begin{cases} 1 - \exp\left(-\frac{\delta}{D_{ik}^{(i,p)}(L)}\right), & \text{if } D_{ik}^{(i,p)}(L) \neq 0 \\ 1, & \text{if } D_{ik}^{(i,p)}(L) = 0 \\ 0, & \text{if } L < L_{\min} \end{cases} \quad (10)$$

$$\frac{dr_i(t)}{dt} = \sum_{k, s_i \in S_k} \left\{ T_k R_{T_k}(t) \prod_{\substack{j, s_j \in S_k \\ j \neq i}} R_j(t) \right\} - \frac{r_i(t)}{\tau} - \max_p [U^{(i,p)}(L)] \quad (11)$$

と拡張する。ここで、

$$U^{(i,p)}(L) = \prod_{k, s_i \in S_k} C_{ik}^{(i,p)}(L)$$

である。(11) 式では、センサ s_i が有する p_i 種類の既知の故障モードに対して、それぞれの類似度 $C_{ik}^{(i,p)}(L)$ の積 $U^{(i,p)}(L)$ を算出し、それらの最大値を (8) 式の右辺第 3 項と置き換えている。これは、実際の故障の原因は互いに独立した事象であるため、複数の既知の故障モードとの類似度を同時に算出しておいて、その中から最大値のみを選択することで、実際の故障モード以外の類似度の影響を受けないようにするためである。

3. 診断アルゴリズムの実装

3.1 診断アルゴリズム

(11) 式の類似度を用いた、免疫型システムの診断方法の診断アルゴリズムを Fig. 3 に示す。

Step1 各センサの出力 v_i を観測し、(3) 式により、各制約での整合性をテストする。

Step2 関連するすべての制約が整合しないセンサに対して、その信用度の時間関数の変化率 $Dr_i[N]$ を (11) 式で算出する。ただし、 $\max_p [U^{(i,p)}(L)] < C_{\min}$ となる場合や、一部の制約が整合するセンサは、(1) 式で $Dr_i[N]$ を算出する。なお、 N は N 回目の処理サイクルを示す。

Step3 各プロセス（制約）の信用度の時間関数の変化率 $Dr_{T_k}[N]$ を (4) 式で算出する。

Step4 すべてのセンサ、プロセス（制約）の信用度の時間関数を次の処理で更新する。信用度の変化率に

更新感度 λ を適用して更新することにより $N+1$ 回目の処理サイクルの信用度を算出している。

$$r_i[N+1] \leftarrow r_i[N] + Dr_i[N] \times \lambda$$

$$r_{T_k}[N+1] \leftarrow r_{T_k}[N] + Dr_{T_k}[N] \times \lambda$$

Step5 すべてのセンサ、プロセス（制約）の信用度を、それぞれ (2) 式、(5) 式で算出する。

Step6 信用度が 0.5 を下回るセンサを異常と判定し、それ以外のセンサは、正常と判定する。

Step7 信用度が 0.5 を下回るプロセス（制約）を異常と判定し、それ以外のプロセスは、正常と判定する。

3.2 観測ノイズの影響

センサの故障時に信用度の減少を速めるために、前述した診断アルゴリズムの信用度の更新感度を大きくする方法を考える。前述の診断アルゴリズムの Step 4 では、ここで更新感度 λ を大きくすると、処理サイクル 1 回あたりの信用度の更新量は大きくなるため、信用度の故障判定領域 (< 0.5) への収束が速まる。しかし、センサの観測値にノイズが重畳する場合には、この更新感度を小さく設定しておかなければ診断結果を誤ることがある。センサ群 S_k に含まれる各センサの観測値 $\mathbf{V}_k(t) = [v_1(t), \dots, v_{h_k}(t)]$ に、それぞれ独立したノイズ $e_h(t)$ (ただし、 $\int_0^\infty e_h(t) dt = 0$) が重畳した各センサの出力ベクトルを $\mathbf{V}'_k(t) = [v_1(t) + e_1(t), \dots, v_{h_k}(t) + e_{h_k}(t)]$ とする。制約 $|f_k(\mathbf{V}'_k(t))|$ が許容誤差 ϵ_k 近傍である場合に、すべてのセンサの出力が正常、すなわち $|f_k(\mathbf{V}_k(t))| \leq \epsilon_k$ であるにもかかわらず、 $|f_k(\mathbf{V}'_k(t))| > \epsilon_k$ となる場合がある。また、あるセンサの出力が異常、すなわち $|f_k(\mathbf{V}_k(t))| > \epsilon_k$ であるにもかかわらず、 $|f_k(\mathbf{V}'_k(t))| \leq \epsilon_k$ となる場合がある。したがって、これらの偶発的なノイズの影響により、(3) 式で得られる T_k は誤った値となる場合があり、(1) 式あるいは (11) 式と、(4) 式で得られる信用度の変化率の算出を誤る要因となる。この条件下で更新感度 λ を大きくすると、信用度を間違った方向に大きく修正してしまい、場合によっては正常あるいは故障を誤判定してしまうことになる。

この現象を回避するためには、更新感度 λ を小さく設定して、各センサの出力のサンプル数を多く確保する、すなわち、データを多くサンプリングすることによりノイズの影響を小さくする必要がある。これが故障を確定するまでの観測回数が多くなる原因である。免疫型システムによる診断において、故障を確定させるまでに必要な観測回数は、制約との整合がとれない頻度、すなわち、 $|f_k(\mathbf{V}_k(t))| > \epsilon_k$ となる頻度に大きく影響を受ける。そこで本論文では、制約との整合がとれない頻度は従来の診断モデルから変わらないことを前提条件として、この条件下でも更新感度を大きくせずに信用度の低下を加速させる方法を提案する。具体的には、特定の故障モードが発生した場合の典型的な各センサ間の出力と、実際の

Fig. 3 Flow of proposed diagnosis algorithm

センサの出力との類似度を算出し、この類似度に対応した値を信用度の時間変化率から減算することにより、信用度の減少を速めている。

4. 数値実験

Fig. 4に示す、入力数1、出力数1のプラント G に対して、入力部に2個のセンサ、出力部に1個のセンサを設けたシステムを対象として、本論文で提案した診断アルゴリズムの効果検証を行った。このネットワークに対して、センサの観測値にノイズが重畳する条件でシミュレーション実験を行った。検討を容易とするために、プラント G の入出力特性は $y(t) = u(t)$ とする。既知およ

び未知の2種類の故障モードに対して、診断アルゴリズムが故障を確定するまでの観測回数と、故障確定時における故障したセンサと正常なセンサの信用度の差に着目する。

Fig. 4 Simulation model

4.1 既知の故障モードの設定

Fig. 4のセンサ s_1 に既知の故障が生じた場合について考える。センサ s_n が正常な時の出力を $v_n^*(t)$ として、故障した状態の s_1 の出力を

$$v_1(t) = v_1^*(t) \times 2 \quad (12)$$

とする。また、センサ s_2, s_3 の出力はいずれも正常であり、それぞれの出力は

$$v_2(t) = v_2^*(t) \quad (13)$$

$$v_3(t) = v_3^*(t) \quad (14)$$

となる。プラント G の入出力特性は $y(t) = u(t)$ であるため、

$$v_1^*(t) = v_2^*(t) = v_3^*(t) \quad (15)$$

の関係が成り立つ。センサ s_1 に(12)式で示される既知の故障モードが発生した場合、センサ s_1 と s_2 の関係式 $v_1(t) = g_{11}(v_{11}(t))$ 、センサ s_1 と s_3 の関係式 $v_1(t) = g_{13}(v_{13}(t))$ は、それぞれ

$$v_1(t) = 2 \times v_2(t) \quad (16)$$

$$v_1(t) = 2 \times v_3(t) \quad (17)$$

で示される。

4.2 シミュレーション実験

以下に、検証実験の共通的な条件を示す。

[試験条件]

プラント G の入出力特性

$$y(N) = u(N)$$

プラント G への入力

$$u(N) = \begin{cases} 0.1N - 40K, & \text{if } 40K - 10 \leq N \leq 40K + 10 \\ -0.1N + 40K + 20, & \text{if } 40K + 10 \leq N \leq 40K + 30 \end{cases}$$

ただし、 K は0以上の整数

ノイズ

範囲 ± 0.5 の一様分布

時定数 $\tau = 1.0$

時刻の単位となるように設定した。

更新感度 $\lambda = 0.02$

センサの観測値に重畳するノイズにより、信用度が急変して正常/故障の判定結果が頻繁に変化しないように実験的に設定した。

許容誤差 $\epsilon_1 = \epsilon_2 = \epsilon_3 = 0.499$

ノイズが外乱として診断に影響を与えるように、ノイズの最大値とほぼ同等の値となるように設定した。

類似度の調整感度 $\delta = 1$

無次元であるセンサの出力に対して、類似度の基準（単位）となるように設定した。

類似度算出の最小サンプリング数 $L_{min} = 10$

ノイズにより、センサ間の出力の関係が偶発的に特定の故障モードが生じた関係と近くなった場合に、類似度として反映しないように実験的に設定した。

類似度の適用最小値 $C_{min} = 0.5$

特定の故障モードと他の未知の故障モードが分離されるように実験的に設定した。

i) 既知の故障モードに対する診断結果

(12) 式の既知の故障モードが発生した場合の、各センサの出力の推移を Fig. 5 に、診断の様子を Fig. 6 に示す。Fig. 6(a) は類似度 $C_{ik}(L)$ を用いて信用度の減少を速めた場合の信用度の推移、Fig. 6(b), (c) は従来方法で更新感度をそれぞれ、 $\lambda = 0.02$, $\lambda = 0.1$ に設定した場合の信用度の推移を示している。 $\lambda = 0.1$ の場合は、ノイズの影響により、正常なセンサの信用度が 0.5 を下回ることがあり、誤った診断結果を得ることがわかる。

Fig. 5 Outputs of sensors with noise for specific fault mode (faulty sensor: s_1)

これらの診断の結果を Table 1 に示す。本論文で提案した方法では、従来方法の結果より少ない観測回数で信

(a) Credibilities of each sensor
(proposed with $\lambda = 0.02$)

(b) Credibilities of each sensor
(conventional with $\lambda = 0.02$)

(c) Credibilities of each sensor
(conventional with $\lambda = 0.1$)

Fig. 6 Simulation result for specific fault mode

用度が 0.5 未満に低下しており、故障確定までの観測回数を低減している。また、故障確定時点においては、故障したセンサと正常なセンサの信用度の差が従来方法よりも大きくなっており、故障と正常の分離度、すなわち、S/N が良くなっている。

ii) 未知の故障モードに対する診断結果

つぎに、センサ s_1 に未知の故障モードが発生した場合の診断の様子を Fig. 7 に示す。ここで、未知の故障モー

Table 1 Result of simulation for specific fault mode

	Method of diagnosis	
	Proposed	Conventional
Number of time of sampling [times]	57	103
Difference of credibility between normal and faulty	0.171	0.083

Fig. 7 Simulation result for unknown fault mode (proposed & conventional)

ドは

$$v_1(t) = v_1^* \times (-2) \quad (18)$$

とする。

Fig. 8に各センサの出力の推移を示す。なお、未知の故障モードであるため、(18)式に対応する関係式 $v_1(t) = g_{11}^{(1,p)}(v_{11}(t))$ ，および関係式 $v_1(t) = g_{13}^{(1,p)}(v_{13}(t))$ は存在しない。

未知の故障モードが生じた場合は、(11)式の類似度の項の値が小さくなり、 C_{min} を下回ることから、信用度の時間関数の動的モデルには従来の診断方法、すなわち(1)式が適用される。この結果、診断の結果も従来の診断方法と同じであり、未知の故障に対しても故障検出性能が維持される。

以上の結果をまとめると、本方法は免疫型システムの特徴である、未知の故障モードに対する故障検出能力を維持しつつ、センサの観測値にノイズが重畳する環境下においても、従来の診断方法に比べて少ない観測回数で故障を検出できる。また、故障確定時点の故障したセンサと正常なセンサの信用度の差は本方法の方が従来方法と比較して大きくなっており、S/Nが改善しているといえる。これらのことから本診断方法の有用性が示された。

Fig. 8 Outputs of sensors with noise for unknown fault mode (faulty sensor: s_1)

4.3 今後の課題

4.2では、プラントの入出力特性に時間遅れがない条件下で、提案した診断方法の有用性を検証した。これは、診断のための観測周期が、プラントの時間遅れよりも十分に長い場合を想定した条件設定であるが、現実には、プラントの時間遅れが無視できないような、短時間での故障検出を要求される場合もあると考える。本論文で提案した診断方法では、(5)式で示したセンサ間の整合性のテストや、(6)式で示したセンサ出力の観測値と推測値の平均距離の算出において、各センサ間の時間遅れの影響を受ける。したがって、提案した診断方法を、センサ出力間の時間遅れが無視できないシステムに適用するためには、たとえばセンサ間にプラントモデルを設置して、モデルから得られるセンサ出力の推定値を用いて診断させるなどの追加措置が必要となる。しかし、この措置には、プラントモデルの同定作業が必要となるため容易ではない。このような時間遅れに対する追加措置の必要性は、免疫型システムを用いた診断の本質的な問題であり、アルゴリズムの更なる改良によって、いかにしてこれらの追加措置を軽減していくかが、今後の課題である。

5. おわりに

本論文では、免疫型システムを用いた診断方法で、既知の故障モードが発生した場合に観測回数が少なくなる方法を提案し、その有効性を議論した。免疫型システムを用いた診断方法では、関連性のあるセンサ間のそれぞれのセンサの観測値が所定の制約から外れる際に、信用度が低下して故障の確定を誘導するため、制約の成立判定に影響を与えるような大きな規模のノイズがセンサの観測値に重畳する条件下では、既知の故障モードが発生している場合でも故障確定までの観測回数を低減することが困難であった。しかし、既知の故障モードに対する類似度を利用して、信用度の更新量を調整することにより、観測回数を約45%も低減しながら正確に故障を確定させることができた。このアルゴリズムを用いれば、耐ノイズ性の低い安価なセンサでも、少ない観測回数で正確な診断を行う診断システムを構成できるものと期待

する。

なお、本論文の数値実験による検証は、小規模な線形のセンサとプロセスを対象としているが、本方法は一般性を有しており、非線形のシステム、あるいは大規模なシステムに対しても同様に効果が期待できる。時間遅れを有する系に対する診断方法の簡素化も含め、実用システムへの適用は、今後の課題である。

参考文献

- [1] S. A. M. Elsayed, R. A. Ammar and S. Rajasekaran: Artificial immune systems: Models, applications, and challenges; *Proceeding, SAC '12 Proceedings of the 27th Annual ACM Symposium on Applied Computing*, pp. 256–258, ACM New York (2012)
- [2] H. Yang, M. Elhadeif, A. Nayak and X. Yang: Network fault diagnosis: An artificial immune system approach; *Parallel and Distributed Systems, ICPADS '08. 14th IEEE International Conference*, pp. 463–469 (2008)
- [3] H. Yang, M. Elhadeif, A. Nayak and X. Yang: An evolutionary approach to system-level fault diagnosis; *Evolutionary Computation, 2009. CEC '09. IEEE Congress*, pp. 1406–1413 (2009)
- [4] X. Yue, D. Wen, H. Ma and J. Zhang: Fault detection based on real-value negative selection algorithm of artificial immune system; *Intelligent Computing and Cognitive Informatics (ICICCI), 2010 International Conference*, pp. 243–246 (2010)
- [5] D. Dasgupta: Advances in artificial immune systems; *Computational Intelligence Magazine, IEEE*, pp. 40–49 (2006)
- [6] Y. Ishida: Active diagnosis by immunity-based agent approach; *Proceedings of the Seventh International Workshop on Principles of Diagnosis (DX 96)*, pp. 106–114 (1996)
- [7] H. Shida, T. Okamoto and Y. Ishida: Immunity-based diagnosis for a motherboard; *Sensors*, Vol. 11, No. 4, pp. 4462–4473 (2011)
- [8] 石田, 平山, 藤田, 石黒, 森: 免疫型システムとその応用 –免疫系に学んだ知能システム–, コロナ社 (1998)
- [9] Y. Ishida: An immune network approach to sensor-based diagnosis by self-organization; *Complex Systems*, Vol. 10, pp. 73–90 (1996)
- [10] 井面, 白木, 今井, 神余: 免疫型システムによる管網系システムの故障診断; 材料, Vol. 52, No. 1, pp. 40–45 (2003)
- [11] K. Wada, T. Toriu and H. Hama: Fault diagnosis by immunity-based agent network using degree of similarity with specific fault mode; *ICIC Express Letters*, Vol. 7, No. 6, pp. 1761–1766 (2013)
- [12] J. Barkai: Automatic generation of a diagnostic expert system from failure mode and effects analysis (FMEA) information; *SAE Technical Paper*, pp. 211–216 (1999)
- [13] 檜皮, 高田, 大村, 土屋, 宮田: 電子制御システムにおけるフェールセーフ設計の現状; 自動車技術, Vol. 46, No. 2, pp. 98–106 (1992)

著者略歴

和田 浩 司 (正会員)

1994年3月大阪市立大学工学部情報工学科卒業。1996年3月同大学大学院工学研究科電気工学専攻前期博士課程修了、同大学大学院工学研究科情報工学専攻後期博士課程(社会人特別選抜)に進学し、現在に至る。ニューラルネットワーク、免疫型システムの研究に従事。電子情報通信学会などの会員。

鳥 生 隆

1980年京都大学大学院理学研究科博士課程物理学第二専攻修了。1982年(株)富士通研究所入社。2002年大阪市立大学大学院工学研究科電子情報系専攻教授。画像処理、コンピュータビジョンの研究に従事。理学博士。電気通信学会、情報処理学会、映像情報メディア学会、IEEE各会員。

はま 裕 光

1946年2月18日生。1971年3月大阪大学大学院工学研究科物理系専攻博士課程中途退学。同年4月大阪市立大学工学部助手、1993年4月教授、2009年4月名誉教授となり現在に至る。パターン認識、学習機械、3次元動画画像処理に関する研究に従事。工学博士。電子情報通信学会、映像情報メディア学会、IEEE各会員。