分散型故障診断におけるアークの重要度指標を用いた Bayesian Network の構造構築

山口 拓真*・稲垣 伸吉*・鈴木 達也*

Construction of Bayesian Network Structure with Importance Indicator of Arc in Distributed Fault Diagnosis

Takuma YAMAGUCHI*, Shinkichi INAGAKI* and Tatsuya SUZUKI*

This paper presents construction strategy of Bayesian Network (BN) structures in decentralized fault diagnosis of event-driven systems based on probabilistic inference. In this decentralized diagnosis method, a fault is identified using the BN and Timed Markov Model (TMM). The BN represents the causal relationship between the faults and the observed event sequences in subsystems, and the structure of the BN is essential since the computational complexity and the fault diagnosis performance depend on it. Therefore, this paper proposes construction strategy of the BN based on an importance indicator of arc, which expresses independence properties between faults and observations, in fault diagnosis of event-driven systems. Finally, the usefulness of the proposed strategy is verified through some experimental results of an automatic transfer line simulated on a PC.

Key Words: event-driven system, Bayesian network, fault diagnosis, timed Markov model, KL divergence

1. はじめに

プログラマブルロジックコントローラ (Programmable Logic Controller: PLC) に代表される事象駆動型システムは化学プラントや工場自動化など各種生産設備の自動制御に幅広く用いられている。近年の生産システムは大規模・複雑化する傾向があり、また点検の際にはシステムを停止する必要があるため、システムのすべての故障を発見することは困難になっている。一方、システムの故障を見逃すことで生産性が低下し、さらには重大な事故を引き起こす恐れがある。そのため、大規模システムの故障診断法を確立し、故障の検知・復帰を行なうシステムを作る必要がある。

文献 1) では、観測される入出力ラベルとその時刻の系列パターンを時間付きマルコフモデル (Timed Markov Model: TMM) で表現し、その表現に基づいたシステムの故障診断法を提案している。文献 1) の手法は観測事象系列だけではなく、事象間の生起時間間隔を統計的に表現した確率的なモデルを用いているため、オートマトンに代表される確定的なモデル²⁾では診断が困難な故障を診断することができる。しかし文献 1) の手法は集中型故障診断手法に分類され、大規模な

システムに適用した場合に計算量やモデル構築が難しいなどの問題がある。大規模なシステムに適用する場合はシステムをいくつかの単純な構造に分割する分散型故障診断^{3), 4)}が有用である。

文献 4) では、ベイジアンネットワーク (Bayesian Network: BN) を用いた分散型確率的故障診断手法を提案している。この手法はまず、システムをいくつかのサブシステムに分割し、それぞれに対して TMM を用いて局所診断器を作成する。つぎに各サブシステムの観測と故障の因果関係を表現した BN を用いて、システム全体の観測を考慮した大域的故障診断を行なう。しかし BN の構造によって推論結果が大きく変化することがわかっており⁴⁾、その構造を適切に決定する必要がある。

BN は確率変数間の因果関係を表現した確率的なグラフィカルモデルであり、ノードとアークから構成される。ノードは確率変数を、アークはそれらの因果関係の有り無しを表わし、変数間の因果関係は条件付き確率によって表現される。各ノードに条件付き確率が割り振られ、これらを用いて確率的な推論が行なわれる。BN の構造とはノード間のアークの引き方であり、アークの有り無しによってノードの条件付き確率が変わり、その結果として推論結果が大きく変化する。

データから BN の構造を学習する手法はいくつか提案されており、スコアベース学習^{5), 6)}と制約ベース学習^{7), 8)}に大別される⁹⁾。スコアベース学習は与えられたデータに対する BN の構造の尤度を計算し、最も尤度の高いものを選択する手法である。この手法における問題は探索すべき BN の候補が多

* 名古屋大学大学院工学研究科 名古屋千種区不老町

* Graduate School of Engineering, Nagoya University, Furocho, Chikusa-ku, Nagoya

(Received February 14, 2012)

(Revised May 29, 2012)

すぎることである。たとえばノード数 10 の BN の全候補は 4.2×10^{18} にも及び^(注 1)、ノード数の増加に伴い指数的に増えてしまう。制約ベース学習はデータから各ノード間の条件付き独立性を検証し、独立性の度合から BN の構造を構築するという手法である。この手法ではアークの向きは唯一に定まらず、構造を一意に決定できないことが問題となる。これらの学習法は問題設定に応じて、適切な手法を選択すべきである。本論文の問題設定として二部グラフの BN を考える。このときアークの向きは一意に定まり、制約ベース学習は適用しやすくなるため、提案手法では制約ベース学習を用いる。

条件付き独立性はノードに割り振られている条件付き確率から評価できる。提案手法における BN はセンサの発火時系列の観測と故障の因果関係を表現しており、条件付き確率を求めるには、時間付きの観測系列の発生確率を計算する必要がある。しかし時間は連続量であり、かつその組み合わせである系列を考えるので、発生確率を計算することは困難である。このような場合では、条件付き確率を直接計算することができないので、ネットワーク構造を構築することは難しい。そこで本論文では、局所診断のモデルである TMM から、アークの重要度を示す指標を間接的に求めることにより、BN の構造を構築する。

本論文は以降、つぎのように構成される。2 章で故障診断手法を局所診断と大域診断に分割し、その定式化を行なう。3 章は局所診断器について述べ、4 章では大域診断器について説明する。5 章は大域診断で用いられる BN の構築手法について述べる。6 章において本提案手法を自動搬送ラインのシミュレータに適用した例を示し、その有用性を実証する。

2. 問題の定式化

文献 4) の診断手法は Fig. 1 が示すように、TMM を用いた局所診断と BN を用いた大域診断からなる。まず、システム全体の特性や観測される事象の関係性を考慮して、システム全体をいくつかのサブシステムに分割する。つぎに各サブシステムにおける観測とそのモデルである TMM を用いて局所的な診断を行なう。最後にこれらの局所診断器の結果と BN を用いて大域診断を行なう。

各サブシステムごとにセンサの活性を示す時間付きイベントが系列として観測できるものとする。時間付きイベントとは発火したセンサのラベルとその時刻のセットである。サブシステム k において n 回目に観測された時間付きイベントをつぎのように定義する。

$$e_n^k = (v_n^k, \tau_n^k). \quad (1)$$

v_n^k は発火が観測されたセンサのラベルであり、 τ_n^k は前回、つまり $n-1$ 回目に、観測されたイベントからの時間間隔である。なお時間付きイベントの時間は時刻で表わされることも

Fig. 1 Procedure of the decentralized fault diagnosis

Fig. 2 Observation in subsystem k

あるが、本論文ではモデルの性質から時間間隔で表現する。初回に発火したセンサのラベル v_0^k は TMM の初期値を設定するために用い、それ以降の時間付きイベント系列 $e_{1:n}^k$ を観測として用いる。Fig. 2 はサブシステム k において観測されたセンサの発火とそれらの時間間隔を表わしており、観測イベント系列 e^k を時間付きイベント系列 $e_{1:n}^k$ と、センサが発火していない時間間隔 (最後のイベントから現在時刻までの時間間隔) τ^k で定義する：

$$e^k = (e_{1:n}^k, \tau^k). \quad (2)$$

ここでシステム全体の故障要因の集合は既知であるとし、故障の確率変数を R 、 R の実現値を $r \in \{r_0, \dots, r_\kappa\}$ と定義する。このとき観測イベント系列 e^k に対して、局所診断器は以下の計算を行なう。

Given : Observed event sequence e^k ,

Calculate : Local fault probabilities for all $r \in \{r_0, \dots, r_\kappa\}$

$$P(R = r | E^k = e^k).$$

ただし、 e^k の確率変数を E^k とする。また大域診断における、現在のシステムの故障 r^* を同定する故障診断問題はつぎの

(注 1) アークは順方向、逆方向、なしを考え、かつ閉路を含まないベイジアンネットワークの総数である。

ように書ける.

Given : Local fault probabilities for all $r \in \{r_0, \dots, r_\kappa\}$

$$P(R=r|\mathbf{E}^1=\mathbf{e}^1), \dots, P(R=r|\mathbf{E}^m=\mathbf{e}^m),$$

Find : $r^* = \arg \max_r P(R=r|\mathbf{E}^1=\mathbf{e}^1, \dots, \mathbf{E}^m=\mathbf{e}^m),$
 $r \in \{r_0, \dots, r_\kappa\}.$

3. 時間付きマルコフモデルによる局所診断

3.1 時間付きマルコフモデル

TMM は準マルコフ過程モデルの一つであり, 状態遷移確率が現在の状態における滞在時間 τ に依存するモデルである (Fig. 3). 各状態の滞在時間 τ は連続量であるため, 状態遷移確率は確率密度で表わされる.

TMM における状態を現時刻から直近に発火したセンサのラベル v_n^k とすることにより, 時間付きイベント系列を TMM の挙動として表わすことができる¹⁾. 以下では故障 r における, TMM の性質を示す確率密度を定義する. なお本章では一つのサブシステムについて議論するので, 表記の簡単化のためにサブシステムの添え字 k は省略する.

【定義】 時間付き遷移確率 (Timed Transition Probability: TTP) とは, 故障が r であり, センサラベル v_n のつぎに v_{n+1} が観測され, かつその滞在時間が τ_{n+1} であるときの同時確率密度

$$p(V_{n+1}=v_{n+1}, T_{n+1}=\tau_{n+1}|V_n=v_n, R=r) \quad (3)$$

である. ただし V_{n+1}, T_{n+1} は v_{n+1}, τ_{n+1} の確率変数である.

3.2 局所診断器

局所診断における目的は観測イベント系列 $\mathbf{e}=(e_{1:n}, \tau)$ に基づいた故障確率

$$P(R=r|\mathbf{E}=\mathbf{e}) \\ = P(R=r|V_{1:n}=v_{1:n}, T_{1:n}=\tau_{1:n}, [T_{n+1}>\tau]=\text{True}) \quad (4)$$

を求めることである. ここで, $[C]$ は関係式 C が成立するかどうかを表わす確率変数であり, 実現値として $\{\text{True}, \text{False}\}$ を取るものとする. これは, 時間付きイベント系列 $e_{1:n}=(v_{1:n}, \tau_{1:n})$ が得られ, かつ τ までセンサの発火がないとき, システムの故障状況が r である場合の確率である. この確率を計算するために文献1)では, つぎの再帰アルゴリズムを用いて計算を行っている. ただし, 本論文の記号などの表記は文献1)の表記と

Fig. 3 3-state timed Markov model

は異なっている. また以下では, 式の表記の簡略化のために, たとえば $V_{1:n}=v_{1:n}$ を $V_{1:n}$ のように, $[T_{n+1}>\tau]=\text{True}$ を $[T_{n+1}>\tau]$ のように, 実現値を省略して表現することとする.

時間間隔 τ の間センサが発火しない場合を考えると, (4) 式はつぎのように更新される.

$$P(R=r|\mathbf{E}=\mathbf{e}) \\ = P(R|V_{1:n}, T_{1:n}, [T_{n+1}>\tau]) \\ = \frac{P(R|V_{1:n}, T_{1:n}) P([T_{n+1}>\tau]|V_n, R)}{\sum_R P(R|V_{1:n}, T_{1:n}) P([T_{n+1}>\tau]|V_n, R)}. \quad (5)$$

ここで, 確率 $P([T_{n+1}>\tau]|V_n, R)$ は TTP を用いて

$$P([T_{n+1}>\tau]|V_n, R) \\ = \sum_{V_{n+1}} \int_0^\tau p(V_{n+1}, T_{n+1}=\tau'|V_n, R) d\tau' \quad (6)$$

と計算することができる. $P(R)$ は故障の事前確率であり, 過去のシステム運用に基づく統計的確率や専門家の先験的知識などから決定される. しかし本論文ではシステムの故障に関する事前情報はないものとして, 事前確率は等確率を割り振る.

$T_{n+1}=\tau$ となったとき, つまり新たに時間付きイベント (v_{n+1}, τ_{n+1}) が観測されたとき, (5) 式の確率 $P(R|V_{1:n}, T_{1:n})$ は以下のように更新される.

$$P(R|V_{1:n+1}, T_{1:n+1}) \\ = \frac{P(R|V_{1:n}, T_{1:n}) p(V_{n+1}, T_{n+1}|V_n, R)}{\sum_R P(R|V_{1:n}, T_{1:n}) p(V_{n+1}, T_{n+1}|V_n, R)}. \quad (7)$$

時間付きイベント (v_1, τ_1) が観測されたときは以下のように更新される.

$$P(R|V_1, T_1) = \frac{P(R) p(V_1, T_1|V_0, R)}{\sum_R P(R) p(V_1, T_1|V_0, R)}. \quad (8)$$

v_0 は初回に発火したセンサラベルであり, v_0 により TMM における初期状態を決定する.

4. ベイジアンネットワークを用いた大域診断

BN は複数の確率変数間の定性的な因果関係をネットワーク構造によって表わし, 個々の変数間の定量的な関係を条件付き確率で表わしたグラフィカルモデルである. 本章では BN を用いた大域故障診断手法⁴⁾について述べる.

まずシステム全体を m 個のサブシステムに分割したことを考慮して, システムの故障 R をサブシステム k の故障 R_k に分割できると仮定する.

$$R = (R^1, R^2, \dots, R^m). \quad (9)$$

また, r^k を R^k の実現値とし,

$$r^k \in \{r_0^k, r_1^k, \dots, r_{n_k}^k\}, \quad (10)$$

Fig. 4 Bipartite Bayesian network for fault diagnosis

Fig. 5 Example of Bayesian network

とする。ただし n_k はサブシステム k における故障数である。また、 r_0^k は正常であることを示すラベルである。

各サブシステムの故障と観測イベント系列の確率変数 R^k , E^k をそれぞれノードとし、ネットワークの構造を二部グラフとする (Fig. 4)。つまり、各サブシステムの故障は互いに独立に発生し、異なるサブシステムの観測イベント系列は故障に関して条件付き独立であるとする⁴⁾。なお、各サブシステムはこれらの独立関係を満たすように分割されなければならない。BN の構造により診断精度と計算量が大きく左右されるため、適切な BN の構造が必要となる。BN の構造の構築についての詳細は 5 章で述べる。

4.1 ベイジアンネットワークの条件付き確率計算

システム全体の故障確率は局所診断器の出力結果と BN を用いて計算される。BN の構造を陽に表現するために、 E^k へアークが引かれている故障確率変数を並べたベクトルを R^{E^k} と定義する。このベクトルを用いることにより、 $P(E^k | R^1, \dots, R^m)$ は $P(E^k | R^{E^k})$ と表現できる。なお、Fig. 5 の例では $R^{E^1} = (R^1, R^2)$, $R^{E^2} = (R^2)$ となる。

大域診断器では故障確率

$$P(R^1, \dots, R^m | E^1, \dots, E^m) \quad (11)$$

を求めることが目的となる。この確率は BN の構造とベイズの定理を用いてつぎのように計算できる。

$$\begin{aligned} & P(R^1, \dots, R^m | E^1, \dots, E^m) \\ &= \frac{P(E^1, \dots, E^m | R^1, \dots, R^m) P(R^1, \dots, R^m)}{P(E^1, \dots, E^m)} \\ &= \frac{\prod_{k=1}^m P(E^k | R^{E^k}) P(R^k)}{P(E^1, \dots, E^m)}. \end{aligned} \quad (12)$$

確率 $P(E^k | R^{E^k})$ はベイズの定理から

$$P(E^k | R^{E^k}) = \frac{P(R^{E^k} | E^k) P(E^k)}{P(R^{E^k})} \quad (13)$$

と計算できる。ここで $P(R^{E^k} | E^k)$ は局所診断器の結果 (5) そのものである。そして、(12) 式は (13) 式を用いて

$$\begin{aligned} & P(R^1, \dots, R^m | E^1, \dots, E^m) \\ &= \frac{\prod_{k=1}^m P(E^k)}{P(E^1, \dots, E^m)} \times \prod_{k=1}^m \frac{P(R^{E^k} | E^k) P(R^k)}{P(R^{E^k})} \end{aligned} \quad (14)$$

と計算できる。ただし $P(E^1, \dots, E^m)$ は以下の正規化項である。

$$\begin{aligned} & P(E^1, \dots, E^m) \\ &= \sum_{R^1} \dots \sum_{R^m} P(E^1, \dots, E^m | R^1, \dots, R^m) P(R^1, \dots, R^m) \\ &= \sum_{R^1} \dots \sum_{R^m} \prod_{k=1}^m P(E^k | R^{E^k}) P(R^k) \\ &= \prod_{k=1}^m P(E^k) \times \sum_{R^1} \dots \sum_{R^m} \prod_{k=1}^m \frac{P(R^{E^k} | E^k) P(R^k)}{P(R^{E^k})}. \end{aligned} \quad (15)$$

(14) 式に (15) 式を代入すると、 $\prod_{k=1}^m P(E^k)$ の項がキャンセルされるため、計算しなくてもよい。したがって

$$\begin{aligned} & P(R^1, \dots, R^m | E^1, \dots, E^m) \\ &= \frac{\prod_{k=1}^m \frac{P(R^{E^k} | E^k) P(R^k)}{P(R^{E^k})}}{\sum_{R^1} \dots \sum_{R^m} \prod_{k=1}^m \frac{P(R^{E^k} | E^k) P(R^k)}{P(R^{E^k})}} \end{aligned} \quad (16)$$

と計算できる。

5. ベイジアンネットワーク構造の構築法

BN の構造は診断精度と計算量に重要な影響を与えるため、適切に決定する必要がある。BN の構造の学習における制約ベース学習では、(13) 式に相当する、BN の各ノードに割り振られた条件付き確率を用いることが多い。しかしこの条件付きを求めるためには、観測イベント系列の発生確率 $P(E^k)$ を計算する必要がある。観測イベント系列は時間という連続量を含んでおり、さらに系列長は時間付きイベントが得られるたびに増加する。そのため、 $P(E^k)$ を計算することは難しく、条件付き確率 (13) を直接計算することは現実的ではない。そこで本論文では局所診断器のモデルである TMM に着目することにより、間接的にノード間の独立性を検証する。

本問題設定においては BN の構造を二部グラフとして想定しているので、故障ノード R^i と観測ノード E^j 間の独立性を評価すればよい。そこで、TMM の挙動を表わしている TTP に着目して独立性を評価する。具体的には独立性を評価するために R^i から E^j へのアークの影響を TTP を用いて評価する。Fig. 6 の例は故障ノード R^i ($i = 1, 2$) から E^1 へのアークが存在する場合の TTP $p(V^1, T^1 | \bar{V}^1, R^i)$ と、アークが存在しない場合、つまり R^i について周辺化した TTP $p(V^1, T^1 | \bar{V}^1)$ を示している (ただし、 V^k, T^k はある時間付きイベントのセンサラベルと時間間隔の確率変数、 $\bar{V}^k$ は V^k より 1 つ前に観測されたセンサラベルの確率変数である)。Fig. 6(a) は R^2 から E^1 へのアークのあるなしにかかわらず、TTP の変化が小さいようすを表わしている。一方、Fig. 6(b) の例では R^1 から E^1 へのアークが存在する場合に TTP が大きく変化しているようすを示している。このような TTP の分布の差は、故障 R^i で条件付けたときの観測イベント系列 E^j が発生する確率の変化量を表わしており、この分布の差が小さいほど R^i と E^j 間は独立であると判断できる。TTP の分布の差は KL 情報量を用いて、以下に示す重要度指標として評価する。

(a) When the arc from R^2 to E^1 is not an important arc (b) When the arc from R^1 to E^1 is an important arc**Fig. 6** Example of the difference between TTPs

$$V_{ij} = \max_{\bar{V}^j, R^i} KL(p(T^j, V^j | \bar{V}^j) || p(T^j, V^j | \bar{V}^j, R^i)). \quad (17)$$

ただし $KL(p||q)$ はつぎのとおりである.

$$KL(p||q) \equiv \int_{-\infty}^{\infty} p(x) \ln \frac{p(x)}{q(x)} dx. \quad (18)$$

重要度指標 V_{ij} はアークの重要度を表わしており、値が大きくなればなるほど、 R^i から E^j への寄与が大きいことを示す. すべてのアークに対し重要度指標 V_{ij} を計算し、ある閾値以上のアークを選択することにより BN の構造を構築する. これらのアルゴリズムを以下に示す.

Algorithm: Construction of the Bayesian network

Step 1 Set $j = 1, i = 1$.

Step 2 Estimate TTP $p(T^j, V^j | \bar{V}^j)$ from learning data.

Step 3 Estimate TTP $p(T^j, V^j | \bar{V}^j, R^i)$ from learning data.

Step 4 Calculate V_{ij} by using (17).

Step 5 If V_{ij} is larger than the threshold, select the arc from R^i to E^j .

Step 6 If $i < m$, go to Step 3 with $i = i + 1$.

Step 7 Terminate the algorithm if $j = m$, else go to Step 2 with $j = j + 1, i = 1$.

Fig. 7 Diagram of the transfer line and definition of events **Fig. 8** Simulator of automatic transfer line**Table 1** Set of sensor labels in each subsystem

Subsys. event labels	Subsys. event labels
1 {v1, v2, v3}	4 {v10, v11, v12}
2 {v4, v5, v6}	5 {v3, v7, v6, v10}
3 {v7, v8, v9}	6 {v9, v12, v13, v14}

6. 検証実験

この章では提案した手法を **Fig. 7** のような自動搬送ラインに適用する. 自動搬送ラインは **Fig. 8** のような物理シミュレータ PhysX を用いて, CPU: Core2 Duo 3.00 GHz, RAM: 4 GB, HDD: 250 GB の PC でシミュレーションした.

6.1 自動搬送ライン

この搬送システムは 6 機のコンベア (長さ 5 m), 2 機のクレーンと 14 個のセンサから構成され, ワークをアンロードステーションに搬送する. 時間付きイベントはワークがセンサを通過した場合に観測され, センサは **Fig. 7** のように設置されている. この自動搬送ラインを 6 個のサブシステム (Lane1, Lane2, Lane3, Lane4, Crane1, Crane2) に分割し, それらのサブシステムで観測される時間付きイベントのセンサラベルを **Table 1** に示す. なお, サブシステムの分割の仕方は本論文の検討事項でないため既知とする. ワークの投入間隔は平均 1 m, 分散 0.03 m^2 の正規分布とし, この分布に従い投入される. また, 1 回の試行はワークを 50 個搬送することとする.

6.2 故障候補

本例で扱う故障の候補として正常, 速度低下, センサ故障を想定する. 各ベルトコンベアの速度が 22 cm/sec から 18 cm/sec の間である場合を「正常 ($r_0^1, r_0^2, r_0^3, r_0^4$)」とし, 18 cm/sec から 15 cm/sec の間である場合は「速度低下 ($r_1^1, r_1^2, r_1^3, r_1^4$)」であるとする. また Crane1, Crane2 についてはワーク搬送に要する時間が正常時より約 0.3 sec 長くなる場合を「速度低下 (r_1^5, r_1^6)」であるとする. センサの故障はコンベアのみ想定し, 中間のセンサが 50% の確率で発火しない場合を「センサ故障 ($r_2^1, r_2^2, r_2^3, r_2^4$)」であるとする. 同時にいくつかのサブシステムで発生する場合などを考慮し, システム全体で $3 \times 3 \times 3 \times 3 \times 2 \times 2 = 324$ 通りの故障組み合わせを故障候補として考える.

上記の環境において試行を行ない, 学習用データとして各故障ごとに 300 試行のデータを用意した. これらの学習データを用いて TMM の TTP を学習した. なお, TTP はヒストグラムとして近似した.

6.3 グラフ構造

Table 2 は Fig. 7 のシステムに対して (17) 式を用いて計算した重要度指標 V_{ij} である. アークの重要度指標 V_{ij} に閾値を設け, 閾値より高いものは重要なアーク, 低いものは重要でないアークとする. 閾値はアークの選択基準であるため, 重要度指標 V_{ij} のそれぞれの値と閾値の大小関係が変化しない限りにおいては選択されるアーク数は変化しない. それゆえ, あるアーク数の BN の構造を解析すると, 大小関係が変化しない範囲の閾値に対して解析したことになる. 実験対象としたシステムにおける, 閾値と選択されるアーク数の関係を Fig. 9 に示す. 閾値が小さいほど選択されるアーク数は増

Table 2 Evaluation value V_{ij} of arc from R^i to E^j

V_{ij}	R^1	R^2	R^3	R^4	R^5	R^6
E^1	0.209	0.002	0.002	0.002	0.054	0.002
E^2	0.001	0.205	0.001	0.001	0.054	0.001
E^3	0.004	0.005	2.110	0.264	0.421	0.317
E^4	0.005	0.005	0.234	2.365	0.458	0.357
E^5	0.394	0.379	0.001	0.001	0.043	0.000
E^6	0.072	0.064	0.380	0.441	0.275	0.903

Fig. 9 Relation between threshold value and the number of arcs

加する. また, 選択されるアーク数は重要度指標 V_{ij} の値と閾値の大小関係のみに依存し, アーク数が変化することにより BN の構造が変化する.

ここで閾値を 0.2 とすると Fig. 10 (a) のような提案構造 1 (Proposed structure 1) が得られる. また, 閾値を 0.04 に設定すると Fig. 10 (b) のような提案構造 2 (Proposed structure 2) が得られる. Fig. 10 (c) の全結合構造 (Full-connection structure) はすべてのサブシステム間の因果関係を表わしている BN であり, 提案手法では閾値を 0 にすると得られる構造でもある. また, 提案構造との比較のために, Fig. 10 (d) の一対構造 (One-to-one structure) を考える. 一対構造はサブシステムの観測をそのサブシステムの故障の診断のみに用いるという構造であり, 局所診断器の出力がそのまま大域診断器の出力となる.

6.4 診断結果

診断データは学習データと同じ環境で試行を行ない, 各故障ごとに 10 試行, 計 3240 試行のデータを診断した. また, 各 BN の構造に対して同一の診断データを用いて診断した. なお計算にかかる時間を計測するため, オンラインの診断ではなく, オフラインで 1 試行のデータを一度に処理することにより診断結果を計算した.

それぞれの BN を用いて診断を行なった診断成功率の結果を Table 3 に示す. なお, 故障の同定は (16) 式の故障確率のエントロピーが 0 に近いと判断したときに同定できる. ただし, 確率のエントロピーは以下の式で表わされ, 今回はエントロピーが 0.025 より小さい場合を近いと判断した.

$$H = - \sum_X P(X) \log_2 P(X). \quad (19)$$

Table 3 における診断成功率 (Success rate) とはサブシステムすべての故障を同定でき, かつ同定された結果がすべて正しい場合の割合である. 未診断率 (Undiagnosed rate) はサブシステムすべての故障は同定できていないが, 同定された結果がすべて正しい場合の割合である. 誤診断率 (Wrong rate) はサ

Fig. 10 Bayesian network structures

Table 3 Result of diagnostic method

BN structure	Success rate	Undiagnosed rate	Wrong rate
Proposed structure 1	0.823	0.156	0.021
Proposed structure 2	0.823	0.156	0.021
Full-connection structure	0.688	0.264	0.047
One-to-one structure	0.233	0.575	0.192

BN structure	Number of arcs	Computing time	Number of TTPs
Proposed structure 1	16	0.294 sec	414
Proposed structure 2	21	0.45 sec	1620
Full-connection structure	36	1.598 sec	6480
One-to-one structure	6	0.235 sec	52

ブシステムすべての故障を同定できているか、いないかにかかわらず、同定された結果に間違いを含んだ場合の割合である。計算時間 (Computing time) は 1 試行約 170 秒 (1700 setps) のデータに対して、診断にかかる平均の時間であり、Fig. 8 の環境をシミュレートした PC と同じ PC で計算した。また TTP の数 (Number of TTPs) は診断に使用する各 BN の TTP の総計であり、アークの数の増加に対し TTP の数は指数的に増加する。なお TTP は各サブシステムごとに割り当てられており、故障と観測イベントラベルを条件部としてもつため、TTP の数はそれらの実現値の数の積で表現できる。

$$\sum_{i=1}^m n_i^i n_v^i \quad (20)$$

ただし、 n_i^i はサブシステム i の BN 構造を考慮した故障 $\mathbf{R}^{\mathbf{E}^i}$ の実現値の数、 n_v^i はサブシステム i におけるセンサラベルの数である。アークの数が増加すると、 $\mathbf{R}^{\mathbf{E}^i}$ の組み合わせ数も増加するため、TTP の数は組み合わせ的に増加する。

計算時間に着目すると提案構造 1 は一対構造とほぼ同等の短さで計算できていることがわかる。局所、大域診断器では TTP の数が多ければ多いほど、計算量が増えてしまう。そのため、計算量の観点では提案構造 1 や一対構造などのアークが少ない構造のほうが優れているといえる。

診断成功率は提案構造 1, 2 が最も高くなった。これらのことから提案した手法を用いることにより、計算量が少なく、かつ計算精度のよい BN を構築することができたことがわかる。一方でアークが最も多い構造である全結合構造は提案構造より診断成功率は低くなった。アークが多い構造のほうがより多くの故障の影響を考慮して診断できるため、診断成功率は高くなると直感的には思われるが、Table 3 の結果では

Fig. 11 Success rate and the number of arcs **Fig. 12** The number of TTPs and arcs

全結合構造の診断成功率が最も高くはなかった。これは学習すべき TTP の数が提案構造より多いため、過学習が発生したことが原因であると考えられる。そのため BN の構造構築において閾値を下げることは、アークの多い詳細な BN の構造を与えるが、それと同時に TTP の数が多い BN の構造になってしまうため、必ずしも良い結果とならないことを示している。

6.5 閾値による差異

本節では、提案手法において閾値を変化させて得ることができる、すべての BN の構造に関して比較して議論を行なう。提案手法に基づき BN の構造を変化、つまり選択されるアークの数を変えたときの診断成功率との関係を Fig. 11 に、TTP の数との関係を Fig. 12 に示す。ただし、6.4 節と同じ条件で診断を行なった。Fig. 11 は (I), (II), (III) の 3 つの領域に分けることができる。(I) の領域はアークが繋がっていない故障ノードが存在する領域であり、アークのない故障ノードは診断されないため、診断成功率は必ず 0 となる。(II) は故障の影響を説明しているアーク、つまり必要なアークがすべて選択されていない領域である。必要なアークがすべて選択されていないため、診断成功率は低くなる。(III) は必要なアークがすべて選択された領域であり、診断成功率は他の領域に比べ高くなる。しかし、必要なアークはすべて選択されているため、アークを増やしても冗長となることがある。

Fig. 11 の (III) の領域では、診断成功率はなだらかに減少する傾向であったため、過学習が起きていると考えられる。これらの事柄からアークの増加はアークの多い詳細なモデルを得られると同時に、複雑さを増してしまうため必ずしも良

い方向に働かないことがわかる。

提案した手法では、閾値が変化することでBNの構造が変化する。閾値を高くしすぎると重要なアークが選択されず、低くしすぎると過学習が起きてしまう。そのためバランスのとれたBNの構造となる閾値を選択する必要があるが、これは(III)の領域の最もアーク数が少ない構造となる閾値を選択すればよい。なお、本システムでは(III)におけるアーク数最小のBNの構造はFig.10(a)のBNである。このような構造では必要なアークのみを選択し、学習すべきTTPの総数も減少するため、少ない学習データ量でも診断できる。

(III)におけるアーク数最小のBNとなる閾値は重要度指標 V_{ij} の値だけではなく、システムの故障要素やシステムの構造などさまざまな要因により変化するため、選択すべき閾値を解析的に求めることは困難である。そこで、事前に得られている学習データを用いて、Fig.11と同様の、診断成功率とアーク数の関係を示す表を作成して、(III)の領域の境界を求める。具体的にはBNの構造学習用のデータを検証データとモデル学習データに分割して、検証データの診断成功率を各アーク数に対して評価することによりFig.11を作成する。

7. おわりに

本論文ではTimed Markov modelにおけるTimed transition probabilityに着目してBayesian networkのアークの重要度指標を提案した。また、その重要度指標を用いた事象駆動系の分散型故障診断法におけるBayesian networkの構築法を提案した。

提案手法を用いることにより、計算量と計算精度のバランスのよいBayesian networkが選択できることを示した。また、Bayesian networkを簡潔な構造で表現できるため、他の構造と比べ少ない学習データ量で、診断を行なうことができることを示した。しかし、システムが大規模な場合は本手法を用いても学習データ量が不十分な場合があり、データの総量を削減することが今後の大きな課題である。また、本論文ではサブシステムの分割方法は既知であるとしたが、これらの分割の仕方も診断精度に影響を与えるため、サブシステムの分割方法も今後の課題である。

参考文献

- 1) J. Lunze: Diagnosis of Quantized Systems Based on a Timed Discrete-Event Model, *IEEE Trans. Syst. Man. Cybern.*, **30**-3, 322/335 (2000)
- 2) M. Sampath, R. Sengupta, S. Lafortune, K. Sinnamohideen and D. Teneketzis: Diagnosability of Discrete Event Systems, *IEEE Trans. Automa. Contr.*, **40**-9, 1555/1575 (1995)
- 3) O. Contant, S. Lafortune and D. Teneketzis: Diagnosability of Discrete Event Systems with Modular Structure, *Discrete Event Dynamic Systems: Theory and Applications*, **16**-1, 9/37 (2006)
- 4) 齋藤, 鈴木, 稲垣, 青木: BayesianNetworkを用いた事象駆動型システムの故障診断, システム・情報部門学術講演会 2006, 251/256 (2006)
- 5) G.F. Cooper and E. Herskovits: A Bayesian Method for Constructing Bayesian Belief Networks from Databases, *Proc. Seventh Conf. Uncertainty in Artificial Intelligence*, 86/94 (1991)
- 6) D.M. Chickering: Optimal structure identification with greedy search, *The Journal of Machine Learning Research*, **3**, 507/554 (2003)
- 7) D. Margaritis and S. Thrun: Bayesian Network Induction via Local Neighborhoods, *Advances in Neural Information Processing Systems 12*, A Bradford Book, 505/511 (1999)
- 8) J. Cheng, D.A. Bell and W. Liu: An algorithm for Bayesian belief network construction from data, *Proceedings of AI*, 83/90 (1997)
- 9) F.V. Jensen and T.D. Nielsen: *Bayesian Networks and Decision Graphs*, Springer (2007)

[著者紹介]

山口 拓 真 (学生会員)

2011年名古屋大学大学院工学研究科博士後期課程機械理工学専攻に入学。現在に至る。離散事象駆動システムにおける故障診断の研究に従事。

稲垣 伸 吉 (正会員)

2003年東京大学大学院工学系研究科博士課程修了。工学博士。同年名古屋大学工学部助手。2008年同講師。現在に至る。自律分散システム、歩行ロボット、確率的情報処理の研究に従事。

鈴木 達 也 (正会員)

1991年名古屋大学大学院博士課程後期課程電子機械工学専攻修了。工学博士。同年名古屋大学工学部助手。2000年同助教授。2006年同教授。現在に至る。ハイブリッドシステム論とその実システムへの応用に関する研究に従事。