事象駆動系の分散型故障診断法における Bayesian Network の構築法 -KL 情報量を用いたアークの重要度評価手法-

Construction of Bayesian network structure for fault diagnosis of event-driven systems -Evaluating importance of arc with Kullback-Leibler divergence-

○非 山口 拓真 (名古屋大), 正 稲垣 伸吉 (名古屋大), 正 鈴木 達也 (名古屋大)

Takuma YAMAGUCHI, Nagoya University, t.yamaguchi@nuem.nagoya-u.ac.jp

Shinkichi INAGAKI, and Tatsuya SUZUKI, Nagoya University

This paper presents decentralized fault diagnosis strategy of event-driven systems based on probabilistic inference together with a method to construct the structure of the inference network, Bayesian network (BN). The structure of BN is essential since the computational burden and the fault diagnosis performance greatly depend on it. In this paper, we particularly focus on a construction methodology of BN structure based on evaluation of the arcs via Kullback-Leibler divergence of the conditional probabilities.

Key Words: Event-driven system, Bayesian network, Kullback-Leibler 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用いられており, 制御器全体の約 8 割と極めて高い割合を占めている. 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, システムの全ての故障を発見することは困難になっている. このようにシステムの故障を見逃すことにより生産性の低下や, さらに重大な事故を引き起こす恐れがある. これらを未然に防ぐには大規模システムの故障診断法の確立し, 故障の検知・復帰を行う必要がある.

大規模なシステムに適用する場合は故障診断器を分散させ, それらの情報を統合してシステム全体の故障診断を行う分散型故障診断^{(1)~(3)}が有用である. 文献⁽³⁾の手法では, まずシステムをいくつかのサブシステムに分割し, それぞれを時間付きマルコフモデルを用いて表現し, 局所診断器を作成する. その局所診断器とベイジアンネットワークを用いて, システム全体の故障診断を行う手法である. ベイジアンネットワークは故障と観測イベント系列の関係を表現しており, その構造により診断精度と計算量が左右される. そこで, 本論文では計算量が少なく, 計算精度のよい分散型故障診断におけるベイジアンネットワークの新たな構築法を提案する.

2. 故障診断の問題設定

まず, システムの特性や物理的影響を考慮して, システム全体をいくつかのサブシステムに分割できるものとする. また, 各サブシステム毎にセンサの活性 (ON) を示すイベントの系列 (イベント系列) が観測できるものとする. ここでサブシステム $k (k = 1, \dots, n)$ に関する時刻 t_h

までのイベント系列を次のように表記する.

$$\mathbf{E}_t^k(t_h) = (e_0^k, t_0^k; e_1^k, t_1^k; \dots; e_H^k, t_H^k), t_H^k \leq t_h. \quad (1)$$

ただし, e_H^k はサブシステム k で H 番目に生じたイベント, t_H^k はイベント e_H^k の生起時刻をそれぞれ表している. 加えて, サブシステム k の κ 番目の故障事例を r_κ^k と表し, 全サブシステムの故障事例を並べたものを「故障の組」, 次式 $\mathcal{R}$ で表されるその集合を「故障の組の集合」とする.

$$\mathcal{R} = \left\{ \mathbf{r} = (r_\alpha^1, r_\beta^2, \dots, r_v^n) \mid \alpha, \beta, \dots, v \in \{0, 1, 2, \dots\} \right\}. \quad (2)$$

以下に本論文で扱う故障診断の問題を示す.

Given: イベント系列 $\mathbf{E}_t^1(t_h), \dots, \mathbf{E}_t^n(t_h), t_H^k \leq t_h$

Find: 故障の組 $\mathbf{r} \in \mathcal{R}$

3. ベイジアンネットワークを用いた大域的故障診断

本論文では, 以下に説明するベイジアンネットワーク (Bayesian Network: 以下, BN) を用いてその因果関係を表現する. BN とは, 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し, 個々の変数間の定量的な関係を条件付き確率で表した, グラフィカルモデルである. 本問題設定では, 各サブシステムの故障事例 $r_\kappa^k (\kappa \in \{0, 1, \dots, K\})$ をラベルとする離散確率変数 R^k と, 各サブシステムで観測したイベント系列 $\mathbf{E}^k$ をそれぞれノードとする BN を用い, ネットワークの構造を二部グラフに限定する (図 1). つまり, 各サブシステムの故障ノード間, およびイベント系列間の関係を無視 (結合を省略) する. このため, ネットワークの表現能力は低下してしまいが, モデルの学習における計算量の削減と診断の際の計算の分散化を行うことができる.

Fig. 1 Bipartite BN for fault diagnosis

Fig. 2 Example of BN

例として図2のようなグラフを考える。全ての確率変数の同時確率は(3)式のように表現できる。

$$P(R^1, R^2, E^1, E^2) = P(R^1)P(E^1|R^1, R^2)P(R^2)P(E^2|R^2). \quad (3)$$

$P(R^k)$ は事前確率であり、条件付き確率 $P(E^k|R^1, R^2)$ は、サブシステム k における局所診断器がベイズの定理を用いて算出する。詳細は文献⁽³⁾を参照されたい。

4. 時間付きマルコフモデルに基づく局所的故障診断法

4.1 時間付きマルコフモデルによるイベント間の関係の表現 時間付きマルコフモデル (Timed Markov Model: 以下, TMM) とは、状態遷移確率が時間に依存するマルコフモデルである。つまり、ある状態から次の状態へと遷移するまでの滞在時間に応じて、遷移確率が変化する。TMMの詳細については文献⁽⁴⁾を参照されたい。以下では、TMMに基づいたイベント間の関係を表現する方法について説明する。

サブシステム k に生じるイベント間の関係をTMMを用いて表現するために、以下の関数を定義する。ただし、3章で定義したBNにおいて、ノード E^k に繋がる全ての確率変数 $R^{k_1}, R^{k_2}, \dots, R^{k_m}$ について、それらの故障事例を並べたものを「サブシステム k に関する故障の組 r^k 」と表現し、それを実現値とする確率変数を $\mathcal{R}^k$ と表す。

以下では、サブシステム k に関するある故障の組 r^k を例として定義を行う。

定義1 イベント生起間隔に関する確率密度関数 $p(T^k = \tau^k | e_{H+1}^k = e_H^k, \mathcal{R}^k = r^k)$ は、イベント e_H^k の次にイベント e_{H+1}^k が生起するまでの時間間隔 τ^k に関する確率密度分布を表す。

定義2 確率分布関数 $P(T^k > \tau^k | e_H^k = e_H^k, \mathcal{R}^k = r^k)$ は、イベント e_H^k が生起してから時間 τ^k 経過した時点では次のイベントが生じていない確率を表す。

ただし、各パラメータは以下の通りである。

- e_H^k : サブシステム k で H 番目に観測されたイベント
- e_H^k, e_{H+1}^k を実現値とする確率変数
- t_H^k : イベント e_H^k が生起した時刻
- t_h : 現在の時刻
- τ^k : 前イベントからの待ち時間 ($\tau^k = t_h - t_H^k$)
- $T^k: \tau^k$ を実現値とする確率変数

Fig. 3 Time and Events in Case (a) and (b)

確率分布関数 $P(T^k > \tau^k | e_H^k = e_H^k, \mathcal{R}^k = r^k)$ は、確率密度関数 $p(T^k = \tau^k, e_{H+1}^k = e_{H+1}^k | e_H^k = e_H^k, \mathcal{R}^k = r^k)$ を周辺化することで求めることができる。

連続して生起する2つのイベント毎に確率密度関数 $p(T^k = \tau^k, e_{H+1}^k = e_{H+1}^k | e_H^k = e_H^k, \mathcal{R}^k = r^k)$ を運用時のランニングデータから統計的に学習することにより、故障の組が r^k である状況の下で各サブシステムで生じるイベント間の関係を表現することが可能となる。

4.2 局所的故障診断方法 各サブシステム毎に事前に推定した確率密度関数を用いて、診断時に観測されるイベント系列と故障時に観測されると予測したイベント系列とを比較することで、各サブシステム毎に局所的な故障診断を行う。具体的には、サブシステム k に関するイベント系列 $E_t^k(t_h)$ が得られた時に、故障の組 r^k が生じている確率 $P(\mathcal{R}^k = r^k | E^k = E_t^k(t_h))$ を計算する。

時刻 $t_h = 0$ から始め、時刻と共に次の2つの場合に分け、4.1節で定義した関数を用いて確率の逐次更新を行う(図3)。

Case(a): 時刻 t_h にイベントが観測されない場合。

Case(b): 時刻 t_h にイベントが観測された場合。

以下に局所的故障診断アルゴリズムの要点をまとめるが、このアルゴリズムの証明およびその詳細に関しては文献⁽⁴⁾を参照されたい。まず、時刻 $t_h = 0$ における初期値を設定する。時刻 $t_h = 0$ には全ての故障の組が等確率で生じていると考え、等確率を割り当てたり、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初期値は決定される。次に以下のような中間変数 $P_a^k(r^k, t_h)$ を導入する。

Case(a): 時刻 t_h にイベントが観測されない場合、

$$P_a^k(r^k, t_h) = P(T^k > \tau^k | e_H^k = e_H^k, \mathcal{R}^k = r^k) \times P(\mathcal{R}^k = r^k | E^k = E_t^k(t_h)). \quad (4)$$

Case(b): 時刻 t_h にイベントが観測された場合、

$$P_a^k(r^k, t_h) = p(T^k = \tau^k, e_{H+1}^k = e_{H+1}^k | e_H^k = e_H^k, \mathcal{R}^k = r^k) \times P(\mathcal{R}^k = r^k | E^k = E_t^k(t_h)) \quad (5)$$

中間変数 $P_a^k(r^k, t_h)$ を次式のように正規化すると、故障確率が得られる。

$$P(\mathcal{R}^k = r^k | E^k = E_t^k(t_h)) = \frac{P_a^k(r^k, t_h)}{\sum_{r^k \in \mathcal{R}^k} P_a^k(r^k, t_h)}. \quad (6)$$

Fig. 4 the example of the difference between PDFs

5. ベイジアンネットワークの構築法

BN は故障事例と観測イベント系列の因果関係を確率的に表現している。そのため、BN の構造は診断精度と計算量に大きな影響を与え、適切に決める必要がある。従来の手法ではネットワーク構造を決定するためにはシステムの特性や物理影響などの事前知識や専門家の経験的知識を必要とし、システムが大規模かつ複雑な場合はそれらの知識を正確に把握することは困難である。本論文ではシステムの特性を表現している確率密度関数の差異に注目し、新たな BN の構築法を提案する。

提案する手法は R^i から E^j へのアークの情報量を KL 情報量を用いて定量的に評価し、その評価値に基づいて全体の BN を構造を決定する方法である。例として図 4 の BN と確率密度関数を考える。図 4(a) は R^1 から E^1 へのアークを繋いだ場合とそうでない場合の、 E^1 に関する確率密度関数である。これらの確率密度関数を比較すると両者の間には違いがあり、 E^1 における観測は故障 R^1 の影響を受けていることになる。また、図 4(b) は R^2 から E^1 へのアークが存在した時の E^1 に関する確率密度関数である。確率密度関数間には違いがほぼなく、 E^1 における観測は故障 R^2 の影響を受けていないことが分かる。このようにアークが存在することの影響の強さは各アークによって異なり、確率密度関数の分布の変化に着目することにより因果関係の強さ (アークの重要度) を調べることができる。

確率密度関数の分布の違いは KL 情報量 (Kullback-Leibler divergence) を用いて評価する。

$$KL(p||q) = \int_{-\infty}^{\infty} p(x) \ln \frac{p(x)}{q(x)} dx, \quad (7)$$

R^i から E^j へのアークの評価は以下の式で与えられる。

$$V_{ij} = \max_{e_H^i, R^i} KL \left(p(T^j = \tau^j, e_{H+1}^j | e_H^j | e_H^i) \right. \\ \left. | p(T^j = \tau^j, e_{H+1}^j | e_H^j, R^i) \right), \quad (8)$$

$KL(p||q)$ は確率密度関数 p と q の KL 情報量を表す。

各アークに対して V_{ij} を計算することにより BN の構造を決定できる。 V_{ij} の最適な閾値を設定す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る。

Fig. 5 Diagram of the transfer line and definition of events

Fig. 6 Simulator of automatic transfer line

6. 実験環境

この章では提案した手法を図 5 のような自動搬送ラインに適用する。自動搬送ラインは図 6 のように Physx という物理シミュレータを用いてシミュレーションを行う。

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 個のセンサーから構成され、ワークをアンロードステーションに搬送する。イベントはワークがセンサーを通過した場合に観測され、センサーは Fig.5 のように設置されている。この自動搬送ラインを図 5 が示すような 6 個のサブシステム (Lane1, Lane2, Lane3, Lane4, Crane1, Crane2) に分割する。各サブシステムで観測されるイベントはコンベアが 3 つ、クレーンが 4 つのセンサーから観測される。

6.2 故障候補 本論文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 22cm/sec から 18cm/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、18cm/sec から 15cm/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 においてワーク搬送に要する時間が正常時より 0.3sec 多くなる時を「速度低下 (r_5^1, r_5^2)」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 $3 \times 3 \times 3 \times 3 \times 2 \times 2 = 324$ 通りの状態が存在する。

7. 実験結果

7.1 グラフ構造 表 1 は図 6 のシステムに対して式 (8) を用いて計算した評価値 V_{ij} である。このアークの評

Table 1 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^3	0.001	0.205	0.001	0.001	0.054	0.001
E^2	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. 7 Bayesian Network (BN) structures

価値 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判断する。

ここで閾値を 0.2 とすると図 7(a) のような提案構造 1 (Proposed structure 1) が得られ、閾値を 0.04 に設定すると図 7(b) のような提案構造 2 (Proposed structure 2) が得られる。図 7(c) の全結合構造 (Full-connection structure) は全てのサブシステム間の因果関係を表している BN であり、提案手法では閾値を 0 にすると必ず得られる構造でもある。図 7(d) の一対構造 (One-to-one structure) 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。

8. 診断結果

図 7 の BN を用いた分散型故障診断の結果を表 2 に示す。表における診断成功率 (Success rate) とはシステム全体で故障状況の同定が成功した場合の割合である。未診断率 (Undiagnosed rate) は全ての故障状況を判定できていないが、判定できている故障状況を同定が成功している割合である。誤診断率 (Wrong diagnosis rate) は誤った診断をしたときの割合である。計算時間 (Computing time) は約 170 秒 (1700setp) のデータに対して診断にかかる平均の時間である。

表 2 から提案構造 1, 2 の診断精度が高いことが分かる。また計算時間では一対構造が一番低く、次いで提案

Table 2 Result of decentralized diagnostic method

Bayesian network	Success rate	Undiagnosed rate	Wrong rate	Computing time	# of PDFs
Proposed structure 1	0.823	0.156	0.021	0.294 sec	414
Proposed structure 2	0.823	0.156	0.021	0.45 sec	1620
Full-connection structure	0.688	0.264	0.047	1.598 sec	6480
One-to-one structure	0.233	0.575	0.192	0.235 sec	52

構造 1 が低くなっている。アークが多い構造であるほど、PDF の数が多くなっている。

診断ではイベント系列のモデルである確率密度関数を用いて計算しているため、確率密度関数が少ないほど計算量は少なくなる傾向にある。そのためアークが少ない構造である方が、計算量の面では有利になる。それとは逆にアークが多い構造は因果関係を多く表すことができるので診断精度の面では有利になるはずであるが、表 2 ではアークが一番多い全結合構造の診断成功率は提案構造 1, 2 より低くなっている。この原因は確率密度関数の増加による推定精度の低下が考えられる。確率密度関数の学習データ量が有限である場合は、確率密度関数の数が多いほど 1 つあたりの学習データ量は減少してしまうため、その分確率密度関数の推定精度は下がってしまう。学習データからオフラインで計算して閾値を評価するなど、閾値は適切に設定しなければならない。

9. おわりに

本論文では KL 情報量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。適切な閾値の決定法、またより大規模なシステムへの適用が今後の課題である。

文献

- (1) O. Contant, S. Lafortune, D. Teneketzis; "Diagnosability of Discrete Event Systems with Modular Structure", *Discrete Event Dynamic Systems: Theory and Applications.*, Vol.16, No.1, pp.9-37, 2006.
- (2) R. Su, W. M. Wonham, J. Kurien, X. Koutsoukos; "Distributed Diagnosis for Qualitative Systems", In *Proc. 6th International Workshop on Discrete Event Systems.*, pp.169-174, 2002.
- (3) S.Inagaki, T.Suzuki, M.Saito, T.Aoki, "Local/Global Fault Diagnosis of Event-Driven Controlled Systems based on Probabilistic Inference", *Proc. 46th IEEE CDC*, pp. 2633-2638, 2007.
- (4) J. Lunze; "Diagnosis of Quantized Systems Based on a Timed Discrete-Event Model", *IEEE Trans. Syst. Man. Cybern.*, Vol.30, No.3, pp.322-335, 2000.