Dynamic Bayesian Networksを用いた宇宙機異常診断法

Spacecraft Diagnosis Method Using Dynamic Bayesian Networks

河原 吉伸

Yoshinobu Kawahara

東京大学大学院工学系研究科航空宇宙工学専攻

Department of Aeronautics and Astronautics, University of Tokyo

kawahara@space.rcast.u-tokyo.ac.jp, <http://www.space.rcast.u-tokyo.ac.jp/kawahara/>

矢入 健久

Takehisa Yairi

東京大学先端科学技術研究センター

Research Center for Advanced Science and Technology, University of Tokyo

yairi@space.rcast.u-tokyo.ac.jp, <http://www.space.rcast.u-tokyo.ac.jp/yairi/>

町田 和雄

Kazuo Machida

(同上)

machida@space.rcast.u-tokyo.ac.jp, <http://www.space.rcast.u-tokyo.ac.jp/machida/>

keywords: Diagnosis, Dynamic Bayesian Networks (DBNs), EM Algorithm, Rao-blackwellised Particle Filter

Summary

Development of sophisticated anomaly detection and diagnosis methods for spacecraft is one of the important problems in space system operation. In this study, we propose a diagnosis method for spacecraft using probabilistic reasoning and statistical learning with Dynamic Bayesian Networks (DBNs). In this method, the DBNs are initially created from prior knowledge, then modified or partly re-constructed by statistical learning from operation data, as a result adaptable and in-depth diagnosis is performed by probabilistic reasoning using the DBNs. This method fuses and uses both knowledge and data in a natural way and has the both ability which two polar approaches; knowledge-based and data-driven have. The proposed method was applied to the telemetry data that simulates malfunction of thrusters in rendezvous maneuver of spacecraft, and the effectiveness of the method was confirmed.

1. はじめに

人工衛星やロケットなどの宇宙機は高度に自動化されたシステムであるが、未だ人間が行うマニュアル操作は、その運用において多くの割合を占める。特に、システムの変調を表すイベントの検知やその原因・重要性の判断、そして適切な対応や復帰制御といった一連のタスクは、ほとんどが人間の手によるものである。しかし、宇宙システムの大規模複雑化に伴って、運用業務で要求される専門知識や処理作業は増大する一方であり、従来の人手に頼った運用方式では宇宙機の完全な信頼性を保証する事は難しくなっている。現に、システムの異常の兆候が人間によって見落とされる事例が多くなっている。従って、これらのタスクを計算機により自動化し、人間を最も重要な意思決定のみに専念させる高度な異常検知・故障診断法の実現が、宇宙開発の健全性確保にとって不可欠となっている。

現在運用されている一般的な人工衛星は、本来の目的であるミッションデータ（例えば、気象観測衛星であれば気象データなど）の他に、衛星を構成する各サブシステムが正常に働いているかを監視するためのテレメトリと呼ばれる数 100 ~ 1000 系列から成る時系列データを地

上に送信している。テレメトリを用いた異常検知手段としては、各値が許容範囲内にあるかを監視するリミット・チェックが広く用いられる一方で、計算機を利用した知的な異常検知・故障診断法として、従来からエキスパート・システムや、定性診断を始めとしたモデルベース・アプローチ [Mosterman 99, Struss 03] に基づく方法が盛んに研究あるいは開発されている。NASA では古くからエキスパート・システムに基づく診断システムの開発が行われており [Tallo 92, Ciceri 94]、日本では旧宇宙科学技術研究所の火星探査機のぞみ (PLANET-B) の運用に用いられた [Nishigori 01]。またモデルベース診断の宇宙システムへの応用例として有名なものに、Remote Agent Experiment [Muscettola 98] の一部として Deep Space One に搭載された、NASA のモデルベース診断システム Living Stone [Williams 96] がある。また最近では、惑星ローバーのための Particle Filter を用いた診断手法も提案されている [Deaden 04]。これら事前の診断知識を用いたアプローチは、高度な原因究明力を持った診断を可能とするが、事前に与えるモデルやルールなどの組込み知識の正確さが直接診断の可否や精度に影響し、絶対的に過去の故障事例が少なく、また不確実性を多分

図 1 提案する診断法の概要

に含む環境下に置かれる宇宙機の診断には大きな問題となる。一方宇宙以外の分野では、様々な統計的手法や、定性的なデータのトレンドを解析する事により、システムの挙動の変調を検知する、データを重視した診断手法が提案されている [Venkatasubramanian 03, Markou 03]。これらの方法は診断の精度や詳細度の点では、上述の知識を重視したアプローチには及ばないが、事前に必要な知識をほとんど必要とせず、適用範囲も広く柔軟な診断を可能とするという長所を持つ。

これら 2 つの対極的なアプローチは、別の表現をする、前者は事前知識から構築した診断モデルを演繹的に用いる事により狭く深い診断を、後者は診断モデルを帰納的に獲得する事により広く浅い診断を可能とするが、一方が他方の利点をカバーする事は難しく、また両者のアプローチを融合する診断法の研究はあまり行われていない。そこで本研究では、知識とデータを融合して用いる事で、広く深い診断能力を持った診断システムを実現する事を目的として、Dynamic Bayesian Networks (DBNs) を用いた診断法を提案する。DBNs は、カルマンフィルター・モデル (KFMs) や隠れマルコフモデル (HMMs) を包含した豊かな表現力と可読性を持ち、宇宙機のような動的システムの挙動を表現するのに適したモデルであると共に、学習や推論のためのアルゴリズムが数多く存在するため、後に述べるように、自然な方法で知識とデータを用いた診断法を形成する事ができる。

以後、第 2 章において本研究で提案する診断法のアプローチについて述べ、第 3 章では診断法を宇宙機のランデブーにおけるスラスター異常を模擬したシミュレーション・データに対して適用し評価すると共に、その結果と考察を示す。

2. 本研究のアプローチ

本研究で提案する診断法は、診断モデルとして Dynamic Bayesian Networks を用い、図 1 に示すように大きく次の 3 つのプロセスから成る。

- (1) 事前知識による診断モデルの構築
- (2) 学習による診断モデルの修正・獲得
- (3) 診断モデルを用いた確率推論による異常診断

まず (1) では、宇宙機のプロセスを表す (微分) 方程式や設計に関する情報などの物理的知識および専門家の経験的知識から、診断に用いるモデルを構築する。その後 (2) において、あらかじめ得られた運用データを用いた統計的学習により、モデルの修正あるいは部分的な獲得を行う。このプロセスにより、事前知識では十分にモデル化できない部分のモデル獲得、あるいはモデル化に伴う誤差の修正が可能となり、診断の信頼性の向上やモデル構築コストの低減が期待される。そして (3) において、このモデルを用いた確率推論により、異常検知および異常箇所・状況の推定を行う。

以後、まず 2.1 節において、本研究で診断モデルとして用いる Dynamic Bayesian Networks (DBNs) について概説し、その後 2.2 節～2.4 節において、上述の各プロセスについて各々順に述べる。なお本稿では、確率変数に関して、大文字の英字により確率変数自身を、小文字によりその実現値を表す。

2.1 Dynamic Bayesian Networks

本研究では、診断モデルとして Dynamic Bayesian Networks (DBNs) と呼ばれる確率的なグラフモデルを用いる^{*1}。DBNs は、Bayesian Networks (BNs) (または Probabilistic Networks, Belief Networks, Causal Model)^{*2}を、動的システムに対しても適用できるように拡張したものであり、カルマンフィルター・モデル (KFMs) や隠れマルコフモデル (HMMs) などを包含した汎用的な状態空間モデルである。BNs は、従来計算機にとって比較的扱いにくかった不確実な情報を扱う事ができるモデルであり、人工知能を中心とした分野で盛んに研究されている [Haddawy 99, 本村 02]。その応用は、ユーザモデリング [Horvitz 98] や故障診断 [Jensen 01]、遺伝子解析 [Segal 03]などを始め、広い領域に及んでいる。また DBNs は、近年様々な学習や推論のアルゴリズムについて研究が進むと共に、主に音声認識 [Nefian 02]などに応用されている。

BNs は、変数を表すノードおよび変数間の依存関係 (条件付き独立性) を表す弧から成るグラフ構造 (G) と、その依存関係を定量的に記述するために全変数に付与される条件付き確率分布 (とそのパラメータ Θ) から構成される。そして DBNs は、2 つの BNs, すなわち事前分布 $\Pr(X_0)$ を表す BN である BN_0 と遷移分布 $\Pr(X_t|X_{t-1})$ を表す BN である $BN_{\rightarrow}$ から構成される。簡単な例として、次式で表される単純なフィードバック制御により振動抑制を行う 1 自由度振動系において、状態量を推定するための DBNs を考える。

$$\ddot{x} = -k_1 \cdot x + u + n_1, \quad y = [x, v]^T + n_2, \quad u = k_2^t y \quad (1)$$

^{*1} DBNs に関する有名な博士論文に [Murphy 02] がある

^{*2} 最もよく知られた古典的教科書に [Pearl 88]、その他に有名なものとして [Jensen 96, Cowell 99, Pearl 00] が挙げられる。

図 2 1 自由振動系を表す DBN

ここで k_1 および k_2 は定数であり, n_1 および n_2 は白色ノイズである. この系を DBNs により表現したときのグラフ構造は図 2 のようになる. 図中観測される変数を灰色で, また直接観測する事ができない変数 (隠れ変数) を白色で表している. 各変数には条件付き確率が付与されており, 例えば v_t であれば次式のような条件付き確率を与える事ができる.

$$\Pr(V_t | X_{t-1}, V_{t-1}, U_{t-1}) = \mathcal{N}(V_t - \Delta t(-k_1 X_{t-1} + U_{t-1}), \Sigma) \quad (2)$$

ここで, Σ は正規分布の分散行列である. なお以後, 条件付き確率の条件となる変数 ((2) 式では X_{t-1}, V_{t-1} および U_{t-1}) を親変数と呼ぶ.

この例からもわかるように, DBNs の変数の選択あるいは定量的な相関の与え方は直接的なものであり, またその構造をグラフにより図示できるため, 人間にとってわかりやすいモデルであると言える. その他に BNs および DBNs 共通の主な特性として, 知識とデータの両方を用いたモデル獲得が可能である事, そして多くの効率的な推論アルゴリズムが開発されている事が挙げられる. また上の例では, モデルの中に連続変数のみが含まれていたが, 離散的な値をとる質的変数を加える事が可能である.

2.2 事前知識による DBNs の構築

最初のプロセスとなる DBNs の構築では, 以下の手順が必要となる.

- (1) モデル中の変数および診断に用いる知識を選定する
- (2) 診断知識を用いて DBNs のグラフ構造およびパラメータの初期設定を行う

まず, 利用者の宇宙機に対する理解や診断の目的などから, モデルを用いて表現する変数領域を選択する必要がある. 前述の例であれば, 質点と床との摩擦の時間変化を考慮する必要があるのなら, 摩擦を表す変数を加えるなどの選択を行う. そして, 宇宙機のプロセスを表す微分方程式や専門家の経験的なルールなどから, 例えば

次のようにして DBNs の構造やパラメータの設定を行う.

- ・ 運動方程式で表される物理的知識

$$\dot{x} = f(x) \Rightarrow \Pr(X_t | X_{t-1}) = \mathcal{N}(x_{t-1} + \Delta t \cdot f(x_{t-1}), \Sigma)$$

- ・ ルールで現される専門家知識

(if $A = i$ then $B = j$) となる信念が p_{ij}

⇒ 変数 B に各 i, j について $M(i, j) = p_{ij}$ となる行列

M を条件付確率として付与

ここで Δt は差分化に伴う時間刻み, M は各場合の確率を表す行列である. 分散などのパラメータを与える必要があるが, これらはデータを用いた学習により事後的な修正が可能であるので, 詳細な設定を行う必要はない.

2.3 データを用いた DBNs の学習

事前知識により構築された DBNs は, 前述のように, 蓄積されたデータを用いた統計的な学習により, 宇宙機の実際の正常時の挙動に近づくように修正あるいは部分的に獲得する. ここでの学習は, 次式で表される尤度 L の最大化を意味する (実際の計算ではその自然対数である対数尤度 $\log L$ を極大化する).

$$L = \prod_{t=1}^{\tau} \Pr(y_t | G, \Theta) \quad (3)$$

ここで y_t は各時刻における観測, そして G および Θ は上述のように各々 DBN のグラフ構造とパラメータを表す. (3) 式からわかるように, 尤度とはモデルを与えたときの得られた観測が実現する条件付き確率であり, そのモデルがどれだけ得られた観測を説明できているかを示す指標となっている. 一般に隠れ変数を持つモデルは, 尤度を直接最大化する事ができないため, EM アルゴリズム (Expectation Maximization Algorithm) [Bilmes 98] と呼ばれる手法が適用される. EM アルゴリズムでは, E-step および M-step と呼ばれる 2 つのステップにより, 反復的に隠れ変数 X に関する対数尤度の条件付き期待値 ((4) 式) の最大化を繰り返す事で, 尤度を極大化する*3.

$$\begin{aligned} & \sum_{t=1}^{\tau} E[\log \Pr(X_t, y_t | G, \Theta) | X_t] \\ &= \sum_{t=1}^{\tau} \int_{X_t} \log \Pr(X_t, y_t | G, \Theta) \Pr(X_t | y_t, G, \Theta) dX_t \end{aligned} \quad (4)$$

まず E-step では, 現在のモデルを用いて観測から隠れ変数の事後分布を推定する. DBNs ではこの処理は, 現在のモデルを用いたオフライン平滑化 (cf. 2.4 節) により計算される. そして M-step では, E-step で得られた事後確率を用いて, (4) 式を最大化する, G の探索や Θ の計算を行う.

*3 ただし実装では, 後に述べるように (4) 式の微分を 0 と置いて解き, 厳密な最大化は行わない.

本稿で用いる診断モデルにおいては、連続変数を親変数として持つ離散変数はないため、ノードに付与する確率分布は全て次式のような条件付き正規分布として表す事ができる。

$$\Pr(Y|X, D=i) = \mathcal{N}(Y; A_i + B_i \cdot X, C_i) \quad (5)$$

ここで、 X は連続親変数、 D は離散親変数であり、 A_i, B_i および C_i は各々 $D=i$ となる場合のバイアス項、回帰行列、および分散行列である。この場合の M-step における各パラメータ A_i, B_i および C_i の更新は、(4) 式の各パラメータに関する偏微分を 0 と置く事により得られる、次式により行う事ができる [Murphy 98]。

$$\begin{aligned} \hat{A}_i &= (S_{Y,i} - B_i S_{X,i}) / w_i \\ \hat{B}_i &= (S_{YX^T,i} - \mu_i S_{X,i}^T) / S_{XX^T,i} \\ \hat{C}_i &= (S_{YY^T,i} - \hat{A}_i (S_{XY^T,i} + S_{Y,i}^T)) / w_i \end{aligned} \quad (6)$$

ここで w_i および各 $S_{*,i}, S_{**T,i}$ は、E-step で得られた事後確率から計算される次のような量である。

$$\begin{aligned} w_i &:= \sum_t w_t^i \\ S_{*,i} &:= \sum_t w_t^i E_{ti}[*] \\ S_{**T,i} &:= \sum_t w_t^i E_{ti}[*^T] \end{aligned} \quad (7)$$

ただし、 $w_t^i := \Pr(D_t = i | y_{1:t})$ である。

また弧の追加や削除、方向の逆転、そして新しいノードの追加といった構造の変更に関しても、パラメータ学習同様に漸近的に行う事ができる [Geiger 94, Friedman 97]。一般に弧の数が増加するほど尤度は高くなってしまいが、 G の次元 (弧の数) に依存するペナルティ項を加える事で、パラメータ学習同様の漸進性が得られる事が示されており、これにより導かれる学習手続きは、一般に Structural EM として知られている [Friedman 97, Murphy 02]*4。

2.4 DBNs 上での確率推論による診断

本診断法では、前節までで得られた DBNs を用いたオンラインでの確率推論により、正常時からの統計的なずれを各変数毎に検知する事で診断を行う [Lerner 02]。

動的システムを対象とした場合の確率推論計算は、一般に、周辺確率 $\Pr(X_t | y_{1:\tau})$ を求める事が目的となる*5。ただし、 X_t は時刻 t における隠れ変数、 $y_{1:\tau}$ は初期時刻から現時点 τ までに得られた観測値を表す。この周辺確率は、状態空間モデルにおいては、再帰的に計算可能な 2 つの

*4 構造学習では、各イタレーションにおいて、現在のモデルに隣接するモデル (弧の逆転や追加などの 1 操作で変換可能なモデル) の全てについて、(7) 式の十分統計量を求める必要があるため、パラメータ学習に比べ計算コストが大幅に増加する。

*5 一般に $\tau = t$ の場合をフィルタリング、 $\tau > t$ の場合をスムージング (平滑化)、そして $\tau < t$ の場合を予測という。

function: smoother($y_{1:\tau}$)

```

1  $\alpha_1 = Fwd(y_1)$  ;
2 for  $t = 2 : \tau$ 
3    $\alpha_t = Fwd(\alpha_{t-1}, y_t)$ 
4  $\beta_\tau = Back(\alpha_\tau)$  ;
5 for  $t = \tau - 1 : 1$ 
6    $\beta_t = Back(\beta_{t+1}, \alpha_t)$ 
```

図 3: オフラインスムージングの概要

周辺確率 $\alpha_t := \Pr(X_t | y_{1:t})$ および $\beta_t := \Pr(y_{t+1:\tau} | X_t)$ を用いて、次のように表す事が可能である*6。

$$\begin{aligned} \Pr(X_t | y_{1:\tau}) &= \Pr(X_t | y_{1:t}, y_{t+1:\tau}) \\ &= c \Pr(y_{t+1:\tau} | X_t, y_{1:t}) \Pr(X_t | y_{1:t}) \\ &= c \Pr(y_{t+1:\tau} | X_t) \Pr(X_t | y_{1:t}) \\ &= c \beta_t \alpha_t \end{aligned} \quad (8)$$

ここで c は正規化項である。つまり、状態空間モデルによる動的システムにおける推論計算は、再帰的な α_t および β_t の計算に帰着される*7。なお、学習時に行うオフライン平滑化は、全ての時刻 t に関する (8) 式の計算であるが、これを各 t に関して逐一直接計算すると計算量が τ の自乗に比例するため、通常各 α_t を保存しておき、図 3 のような手続きにより計算する (これにより計算量は τ に線形なオーダーとなる)。

DBNs を用いる場合、上記 2 つの確率は変数毎に分解する事ができ、例えば α_t であれば次式のようになる。

$$\alpha_t = \Pr(X_t | y_{1:t}) = \prod_{i=1}^N \Pr(X_{i,t} | pa(X_{i,t}), y_{1:t}) \quad (9)$$

ここで、 N は X_t の次元、 $pa(X_{i,t})$ は変数 $X_{i,t}$ の親変数を表す。これにより、各時刻における推論計算は各変数毎の局所計算に分解する事ができるため、大規模なモデルにおいて計算効率が向上する場合が多い。一般にこれらの確率計算は、BNs 同様、接合木アルゴリズム [Lauritzen 99] を用いて行う事ができる。

本診断法では、学習後の DBNs を用いたフィルタリング計算により、正常時からの統計的なずれを変数毎に検知するために、DBNs 中の診断対象となる確率変数の分布を、正常時の分布と異常時の分布との混合分布として与え、各混合パラメータの時間的な推移を計算する。例えば何らかのセンサを診断する場合、図 4 のように、観

*6 1 行目から 2 行目への変形ではベイズの定理、2 行目から 3 行目では $(y_{1:t} \perp y_{t+1:\tau} | X_t)$ の条件付き独立性を用いている (c.f. [Russell 02], p.544)。

*7 α_t から α_{t+1} を求める手続きをフォワード・パス ($\alpha_{t+1} = Fwd[\alpha_t, y_t]$)、 β_{t+1} から β_t を求める手続きをバックワード・パス ($\beta_t = Back[\beta_{t+1}, \alpha_t]$ または $\beta_t = Back[\beta_{t+1}, y_{t+1}]$) と呼ぶ。詳細については、[Murphy 02] の第 3 章、または [Russell 02] の 15.2 節を参照。

図 4 センサ異常を診断する場合の DBN

測値の条件として、観測される状態量に加えて”異常”と”正常”の2値をとる離散確率変数 F を加え、 $F = \text{”異常”}$ の分布として、正常の場合の分布と平均が等しく、より分散の大きい分布として与える。そして、これらの変数を含めた全変数の分布を、DBN を用いた確率推論計算によりオンラインで推定する。これにより、得られる観測の正常時からずれが大きくなる傾向であれば、 $F = \text{”異常”}$ の確率が大きくなるという結果が得られる。

前述のように、DBNs の確率推論計算は α_t および β_t の計算に帰着され、これらの計算接合木アルゴリズムにより行う事ができるが、本場合のように、離散変数が親変数として連続変数を持たない場合には、時間経過と共に場合の数が指数関数的に増大してしまい、厳密な確率推論計算を行う事は不可能となる^{*8}。そこで本診断法では、Rao-Blackwellised Particle Filter(RBPF)[Doucet 00, Doucet 01] という近似推論アルゴリズムを用いている。RBPF は、Particle Filter(PF) の変数次元が高くなった時の計算コスト削減を目的に、モデル中の変数を2つに分け、一方でモンテカルロ法により近似推論し、他方を厳密推論するアルゴリズムである。本診断法ではRBPFを応用し、異常の有無を表す離散変数 F をPFにより近似的に推論計算し、残りの状態量に関する部分を接合木アルゴリズムにより厳密推論を行う事により、上述の問題を解決している。このRBPFを用いて診断を行う場合の、各時刻における推論計算の概要を図5に示す。

3. 提案法の評価および考察

本章では、本研究で提案する診断法を、宇宙機のランデブー・プロセスにおけるスラスタ異常を模擬したシミュレーション・データ^{*9}に対して適用した結果、およびその結果に対する考察について述べる。宇宙機の運用では、運用者が宇宙機のシステム変調を如何に迅速に捉え、その状況を判断して、適切な対応をする事ができるかが重

^{*8} 例えば BN_{∞} 中に F が一つだけ含まれる場合には、時刻が $t = 1, 2, \dots$ と増加するにつれ、 $F_1 = \{\text{異常}, \text{正常}\}, (F_1, F_2) = \{(\text{異常}, \text{異常}), (\text{異常}, \text{正常}), (\text{正常}, \text{異常}), (\text{正常}, \text{正常})\}, \dots$ と場合の数が増加し、 2^t 通りの分布を保持しなくてはならない。

^{*9} データは宇宙航空研究開発機構 (JAXA) 提供

function: $\{f_t^i, \alpha_t^i, w_t^i\} =$
 $RBPF(\{f_{t-1}^i, \alpha_{t-1}^i, w_{t-1}^i\})$

- 1 for $i = 1 : N$
- 2 Sample $f_t^i \sim \Pr(F_t | F_{t-1})$;
- 3 $(\alpha_t^i, w_t^i) = Fwd(\alpha_{t-1}^i, y_t, f_t^i)$;
- 4 Normalize $w_t^i = w_{t-1}^i / \sum_i w_{t-1}^i$;
- 5 Resample with replacement N particles from the set $\{f_t^i, \alpha_t^i\}, i = 1 : N$ according to the weights w_t^i ;

図 5: RBPF を用いた診断の手続きの概要。なお N はパーティクル数、 $*$ という添え字は各パーティクルが持つ値であることを示す。また w_t^i は各パーティクルの重み $\Pr(y_t | X_t^i)$ である。

要となるため、本実験では、提案する診断法が迅速にスラスタ異常を検知する事ができるか？、そして直接観測されないスラスタの推力推移を推定する事により、スラスタに発生している異常の定性的性質を捉える事ができるか？という点を評価する。

3.1 問題設定

ランデブーを行う宇宙機は、14 機のスラスタを用いて姿勢および並進制御を行う。データはこの14機のスラスタへの16段階のコマンド14系列と、宇宙機のステータス(位置 x , 速度 v , 姿勢角 θ および姿勢角速度 w) の観測系列12系列の、計26系列から成る。データの観測間隔は0.125秒であり、1000秒間のシミュレーションとなっている。また、宇宙機の質量特性(重量、慣性モーメント)やスラスタ特性(規定推力、配置)については既知であるが、軌道情報や制御則、センサ特性など、その他の情報は未知である。従って、事前に詳細なモデル化を行い、拡張カルマンフィルターやパーティクルフィルターなどの非線形フィルターを構成する事は難しい。

3.2 診断モデルの構築

本実験のため、以下で述べるように図6に示すグラフ構造を持つDBNを構築した。まず上述の診断目的から、観測変数の他に、各スラスタ推力を表す連続変数と異常有無を表す離散変数を加え、表1に示す変数集合を選択した。そして事前知識として、線形化された軌道上での姿勢運動と並進運動を表す方程式を用いた [狼 02]。

表 1 DBN 中の変数

記号	説明	定義域
X	位置	実数全体
V	速度	"
W	角速度	"
Θ	オイラー角	"
T	推力	"
Y	観測値	"
C	コマンド	1~16(整数)
F	異常の有無	0(正常),1(異常)

図 6 実験で用いた DBN のグラフ構造

$$\dot{\theta} = [\omega_1 + n\theta_3, \omega_2 + n, \omega_3 - n\theta_1]^T \quad (10)$$

$$\begin{aligned} J_1 \dot{\omega}_1 + n(J_2 - J_3)\omega_3 &= M_1 \\ J_2 \dot{\omega}_2 &= M_2 \\ J_3 \dot{\omega}_3 - n(J_1 - J_2)\omega_1 &= M_3 \end{aligned} \quad (11)$$

$$\begin{aligned} \ddot{x}_1 &= 2n\dot{x}_3 + T_1 \\ \ddot{x}_2 &= -n^2 x_2 + T_2 \\ \ddot{x}_3 &= 3n^2 x_3 - 2n\dot{x}_1 + T_3 \end{aligned} \quad (12)$$

ここで、 n は円軌道平均運動、 J は機体の慣性モーメントであり、本実験では正確な値は事前には未知である。また M は、スラストにより機体に作用するモーメントである。なお、本実験ではこのような物理的な知識のみを用いたが、離散変数で表される専門家の経験的なルールなどの定性的な知識を組み込む事も可能である。

モデル構築の手順は、次のようである。なお、2 つ添え字のある変数は、1 つ目がベクトル中のインデックス、2 つ目が時刻を表している。また、差分化の時間刻みを Δt と表している。

- (1) 各微分方程式を差分化する。例えば θ_1 であれば、(10) 式より次のようになる。

$$\theta_{1,t} = \theta_{1,t-1} + \Delta t \cdot (\omega_{1,t-1} + n\theta_{3,t-1})$$

- (2) 差分化された微分方程式、およびその他の事前知識 (例えば正常時であれば推力 $T = \text{規定推力} \times C/16$) を用いて、DBN の初期グラフ構造および初期パラメータを与える。例えば $\Theta_{1,t}$ であれば、 $\Theta_{1,t-1}, \Theta_{3,t-1}$ および $\Omega_{1,t-1}$ を親変数とし、次式のように条件付き

表 2 本実験における分散の初期設定値

BN_0				BN_{t-1}			
変数	分散行列			変数	分散行列		
X_0	10.0	0.0	0.0	X_t	0.1	0.01	0.01
	0.0	10.0	0.0		0.01	0.1	0.01
	0.0	0.0	10.0		0.01	0.01	0.1
V_0	10.0	0.0	0.0	V_t	0.1	0.01	0.01
	0.0	10.0	0.0		0.01	0.1	0.01
	0.0	0.0	10.0		0.01	0.01	0.1
W_0	10.0	0.0	0.0	W_t	0.1	0.01	0.01
	0.0	10.0	0.0		0.01	0.1	0.01
	0.0	0.0	10.0		0.01	0.01	0.1
Θ_0	10.0	0.0	0.0	Θ_t	0.1	0.0	0.0
	0.0	10.0	0.0		0.0	0.1	0.0
	0.0	0.0	10.0		0.0	0.0	0.1
				Y_t^*	1.0	0.0	0.0
					0.0	1.0	0.0
					0.0	0.0	1.0

確率を付与する^{*10}。

$$\begin{aligned} \Pr(\Theta_{1,t} | \theta_{1,t-1}, \theta_{3,t-1}, \omega_{1,t-1}) \\ = \mathcal{N}(\theta_{1,t}; \theta_{1,t-1} + \Delta t(\omega_{1,t-1} + n\theta_{3,t-1}), \Sigma) \end{aligned}$$

- (3) あらかじめ得られている正常時の運用データを用いて、2・3 節で述べた統計的な学習により、グラフ構造およびパラメータの修正を行う。

- (4) 正常時に比べて十分に大きな分散^{*11}持った正規分布を、異常時の分布として、診断の対象となる部分に加える (平均値は正常時と同じ)

3.3 診断モデルの学習

本実験に際して、事前知識の与え方と学習により、尤度の観点から、どの程度の良いモデルの獲得につながるかを判断するため、表 3 に示す 4 つのパターンのモデルについて評価を行った。これら 4 つのパターンは、与える事前知識として、(1)DBNs の構造と (2) 変数間の関係に関するパラメータの 2 つがあるため、これらを与えるか与えないかという分類で選択した。その時の結果の一例を図 7 に示す。

図からわかるように、3.2 節の手順でモデル獲得を行った場合 (図 7 中 Model2)、全く事前知識を用いずに変数の選択のみを行い学習した場合 (図 7 中 Model4) と、変数間のグラフ構造のみを与えてパラメータをランダムに初期設定した場合 (図 7 中 Model3) に比べ、最終的により尤度の高いモデルが得られている。なお図 7 中 Model1 は、上記手順で最後の学習を行わなかった場合の対数尤度である (表 3)。図 7 より、学習を行う事で、モデルが持つ誤差や観測の不確実性などがより実際の挙動に適合するように修正されている事がわかる。また、Model2 と Model3,4 を比較してわかるように、Model3 および 4 は局所解に陥っており、事前知識を与える事がより良いモデル獲得に重要である事がわかる。

*10 分散 Σ の設定については、差分化した式と元の方程式との差を比較する事で見積もり設定する事ができるが、(3) における学習により修正する事が可能であるため、診断に際してはかなりロバストである。本実験では表 2 のような設定を行った。

*11 後に示す実験では、全て $\sigma_{異常} = 3 \times \sigma_{正常}$ としている。

図 7 学習における対数尤度の推移

表 3 評価を行った診断モデル

Model	構造	与える事前知識 パラメータ (初期値)	行う学習
1	図 6	式 (10)~(12), 質量特性, スラスタ特性	学習なし
2	図 6	式 (10)~(12), 質量特性, スラスタ特性	パラメータ学習
3	図 6	ランダム	パラメータ学習
4	ランダム	ランダム	構造学習

3.4 診断結果と考察

ここでは, 前述の手順により得られた DBNs(Model2) を用い, 3 つの異常ケースについて本診断法を適用した結果を示し, 本診断法について考察する.

§1 比較的単純な異常ケース

一つ目の異常ケースは, 図 8 のように, 250 秒から 60 秒間かけて直線的にスラスタ 4 の推力が低下する異常に対して適用した結果である. 本異常ケースに関しては, 比較のため 3.2 節で述べた手順で最後の 3 の学習を行わない場合, つまり上述の Model1 の結果についても示す.

まず図 9 および図 10 は, それぞれ Model1 および Model2 を用いた場合の, いずれかのスラスタが異常である確率の推移である. これはつまり, 各々のモデルと観測データとの”ずれ”を表す指標と言える. 図からわかるように, Model1 では異常発生前から診断の開始と共に値が増加しており, 正常時においてもモデルと観測データとのずれが大きくなってしまっている事が分かる. 一

図 8 異常異常ケース 1 のスラスタ 4 の異常

図 9 異常確率の推移
(ケース 1, Model1) 図 10 異常確率の推移
(ケース 1, Model2)

図 11 各スラスタの異常確率の推移 (ケース 1)

方 Model2 は, 異常発生時刻付近から急激に値が 1 に近づいており, 異常の発生が原因で, モデルと観測データとのずれが急激に増大した事を示している. これにより, 学習を行う事で正常時の宇宙機の実際の挙動を表すモデルが獲得され, 異常による正常時とのずれを適切に検知できるようになっている事が分かる. 更に図 11 は, 各スラスタの異常確率の推移を示した図である. つまり, 図 6 中の各 F_i が 1 の確率の時間変化を表している. 学習を行った場合 (Model2) を赤線で, 参考のため学習を行わなかった場合 (Model1) を青線で示している. 図からわかるように, 異常が発生した 250[s] の直後, スラスタ 4, 5, 7 および 9 の異常確率の値が大きく 1 へと変化しており, 実際に異常が発生しているスラスタ 4 以外のスラスタも異常の確率があると判断している事が分かる. これは, スラスタ制御の冗長性のため, 状態量の観測のみからは, いずれのスラスタが異常であるかを区別できないためと思われる. 例えば, スラスタ 4 と 7 は共に θ_2 の負方向の制御を行っており, θ_2 の観測からはいずれが異常であるかは区別できない.

また図 12 および図 13 は, 各々学習を行った場合 (Model2) と行わなかった場合 (Model1) の, 観測から推定される各スラスタの推力の推移, つまり各時刻における図 6 中

図 12 各スラスタの推定推力 (平均値) の推移 (異常ケース 1, モデル 2)

図 13 各スラスタの推定推力 (平均値) の推移 (異常ケース 1, モデル 1)

の各 T_i の平均値である。この図より、学習を行ったモデルでは、図 8 で示したスラスタ 4 の異常の状況を大まかに再現できている事がわかる。一方学習を行わなかった場合には、ほぼランダムな推移となっており、何らかの傾向を読み取る事は難しい。本結果からも、提案手法における学習の機能が有効である事がわかる。

§ 2 複雑な推力変化を示す異常ケース

実際のスラスタ故障では、徐々に出力が低下したり、一時的なダウンと回復を繰り返すなど、より複雑な挙動を伴う事が多い。従ってより複雑な異常ケースとして、図 14 のように 250[s] 秒以後 60[s] 間隔で推力/規定推力が 0 と 1 を繰り返す異常 (異常ケース 2) と、図 14 のように 250 秒から周期 5[min] の sin 波状のスラスタ異常が発

図 14 異常ケース 2 のスラスタ

図 15 異常ケース 3 のスラスタ 9 の異常

図 16 各スラスタの異常確率の推移 (異常ケース 2)

図 17 各スラスタの推定推力 (平均値) の推移 (異常ケース 2)

図 18 各スラスタの異常確率の推移 (異常ケース 3)

図 19 各スラスタの推定推力 (平均値) の推移 (異常ケース 3)

生する異常 (異常ケース 3) に対して適用した結果を示す。各々の異常ケースについて、図 16 および図 18 が各スラストの異常確率の推移、図 17 および図 19 が各スラストの推定推力の推移を表している。ただし図 16, 図 18 に関しては、全区間に渡って値がほぼ 0 となっているものは除いている。図 16, 図 18 より、いずれの異常ケースも、異常ケース 1 と同様に 1 つのスラストへの特定には至っていないものの、このような複雑な異常ケースであっても宇宙機の変調を迅速に検知できている。また図 17, 図 19 に関しては、実際に異常が発生しているスラスト 9 の値が大きく変動はしているものの、図 14, 図 15 とはかなり異なったものとなっている。これはおそらく、モデルの精度の限界から、これらの異常ケースの異常のような大きく値が増減する場合の追従は困難であるためと思われる。

4. 結 論

本稿では、知識とデータの両方を用いた診断法として、DBNs を用いた診断法を提案した。本診断法では、モデル獲得時に事前知識を用いる事により詳細な診断を可能とすると共にデータを用いた統計的学習によりその不確実性が補われる事、そして獲得された DBNs を用いた確率推論により変数毎に正常時からの統計的なずれの検知が可能である事を確認した。今後、本稿では扱わなかった専門家の経験的ルールを含めた様々な表現形式の診断知識の利用や、より複雑なシステムへの適用を可能とするような診断モデルの表現方法の検討を行う予定である。

謝 辞

本研究を進めるにあたり、宇宙航空研究開発機構 (JAXA) の山中浩二様、稲場典康様には、専門家の立場からの様々な知見を頂くと共に、シミュレーション・データを提供して頂きました。深く感謝いたします。

◇ 参 考 文 献 ◇

- [Bilmes 98] Bilmes, J. A.: A Gentle Tutorial of the EM Algorithm and its Application to Parameter Estimation for Gaussian Mixture and Hidden Markov Models, Technical report 97-021, International Computer Science Institute, University of California, Berkeley, Apr.(1998)
- [Ciceri 94] Ciceri, F. and Marradi, L.: Event Diagnosis and Recovery in Real-time On-board Autonomous Mission Control, in *Proceedings of the 1st Ada-Europe Symposium* (1994)
- [Cowell 99] Cowell, R. G., Dawid, A., Lauritzen, S. L., and Spiegelhalter, D. J.: *Probabilistic Networks and Expert Systems*, Springer-Verlag (1999)
- [Deaden 04] Deaden, R., Willeke, T., and Hutter, F.: Real-time Fault Detection and Situational Awareness for Rovers: Report on the Mars Technology Program Task, in *Proceedings of IEEE Aerospace Conference* (2004)
- [Doucet 00] Doucet, A., Freitas, de N., Murphy, K., and Russell, S.: Rao-Blackwellised Particle Filtering for Dynamic Bayesian Networks, in *Proceedings of the 16th Annual Conference on Uncertainty in AI (UAI)* (2000)
- [Doucet 01] Doucet, A., Freitas, N. D., and Gordon, N.: *Sequential Monte Carlo Methods in Practice*, Statistics for Engineering and Information Science, Springer Verlag (2001)
- [Friedman 97] Friedman, N.: Learning the Structure of Dynamic Probabilistic Networks, in *14th International Conference on Machine Learning (ICML)* (1997)
- [Geiger 94] Geiger, D. and Heckerman, D.: Learning Gaussian Networks, in *Proceedings of the 16th Annual Conference on Uncertainty in AI (UAI)* (1994)
- [Haddawy 99] Haddawy, P.: An Overview of Some Recent Developments in Bayesian Problem Solving Techniques, *AI Magazine*, Vol. 20, No. 2, pp. 11–20 (1999)
- [Horvitz 98] Horvitz, E., Breese, J., Heckerman, D., Hovel, D., and Rommelse, D.: The Lumiere Project: Bayesian User Modeling for Inferring the Goals and Needs of Software Users (1998)
- [Jensen 96] Jensen, F. V.: *Introduction to Bayesian Networks*, University College London Press (1996)
- [Jensen 01] Jensen, F. V., Kjaerulff, U., and Kristiansen, B.: The SACSO Methodology for Troubleshooting Complex Systems, *Artificial Intelligence for Engineering Design, Analysis and Manufacturing (AIEDAM)*, Vol. 15, pp. 321–333 (2001)
- [Lauritzen 99] Lauritzen, S. L. and Jensen, F.: Stable Local Computation with Conditional Gaussian Distributions, Technical report, Aalborg University (1999)
- [Lerner 02] Lerner, U. N.: *Hybrid Bayesian Networks for Reasoning about Complex Systems*, PhD thesis, Stanford University (2002)
- [Markou 03] Markou, M. and Singh, S.: Novelty detection: a review - part1,2, *Signal Processing*, Vol. 83, No. 12, pp. 2481–2497 (2003)
- [Mosterman 99] Mosterman, P. J. and Biswas, G.: Diagnosis of Continuous Valued Systems in Transient Operating Regions, *IEEE Transactions on Systems, Man and Cybernetics - Part A: Systems and Humans*, Vol. 29, No. 6, pp. 554–565 (1999)
- [Murphy 98] Murphy, K. P.: Fitting a conditional gaussian distribution, Technical report, U.C.Berkeley, Dept. Comp. Sci (1998)
- [Murphy 02] Murphy, K. P.: *Dynamic Bayesian Networks: Representation, Inference and Learning*, PhD thesis, University of California (2002)
- [Muscettola 98] Muscettola, N., Nayak, P. P., Pell, B., and Williams, B. C.: Remote Agent : To Boldly Go Where No AI System Has Gone Before, *Artificial Intelligence*, Vol. 103, No. 1-2 (1998)
- [Nefian 02] Nefian, A. V., Liang, L., Pi, X., Liu, X., and Murphy, K.: Dynamic Bayesian Networks for Audio-Visual Speech Recognition, *Journal of Applied Signal Processing*, Vol. 11, pp. 1–15 (2002)
- [Nishigori 01] Nishigori, N., Hashimoto, M., Choki, A., and Mizutani, M.: Fully Automatic and Operator-less Anomaly Detecting Ground Support System for Mars Probe 'NO-ZOMI', in *Proceeding of the 6th International Symposium on Artificial Intelligence and Robotics and Automation in Space (I-SAIRAS)* (2001)
- [Pearl 88] Pearl, J.: *Probabilistic Reasoning in Intelligent Systems*, Morgan Kaufmann (1988)
- [Pearl 00] Pearl, J.: *Causality: Models, Reasoning and Inference*, Cambridge University Press (2000)
- [Russell 02] Russell, S. J. and Norvig, P.: *Artificial Intelligence: A Modern Approach (2nd edition)*, Prentice Hall (2002)
- [Segal 03] Segal, E., Shapira, M., Regev, A., Pe'er, D., Botstein, D., Koller, D., and Friedman, N.: Module Networks: Identifying Regulatory Modules and their Condition-Specific Regulators from Gene Expression Data, *Nature Genetics*, Vol. 34, No. 2, pp. 166–176 (2003)
- [Struss 03] Struss, P. and Price, C.: Model-Based Systems

in the Automotive Industry, *AI Magazine* (2003)

[Tallo 92] Tallo, D. P., Durkin, J., and Petrik, E. J.: Intelligent Fault Isolation and Diagnosis for Communication Satellite Systems, *Telematics and Informatics*, Vol. 9, No. 3-4, pp. 173-190 (1992)

[Venkatasubramanian 03] Venkatasubramanian, V., Rengaswamy, R., Kavuri, S. N., and Yin, K.: A review of process fault detection and diagnosis Part III: Process history based methods, *Computers and Chemical Engineering*, Vol. 27, pp. 327-346 (2003)

[Williams 96] Williams, B. C. and Nayak, P. P.: A Model-Based Approach to Reactive Self-Configuring Systems, in *Proceedings of the Thirteenth National Conference on Artificial Intelligence and Eighth Innovative Applications of Artificial Intelligence Conference* (1996)

[本村 02] 本村陽一: ペイジアンネットソフトウェア, 人工知能学会誌, Vol. 17, No. 5, pp. 559-565 (2002)

[狼 02] 狼 嘉彰, 中須賀 真一, 富田 信之, 松永 三郎: 宇宙ステーション入門, 東京大学出版会 (2002)

〔担当委員: 原島 一郎〕

2005 年 6 月 29 日 受理

著 者 紹 介

河原 吉伸(学生会員)

2003 年東京大学工学部航空宇宙工学科卒。2005 年同大学院工学系研究科航空宇宙工学専攻 修士課程終了。現在、同博士課程に在学中。機械学習をはじめとした人工知能技術の宇宙システムへの応用に興味を持つ。人工知能学会、航空宇宙学会、各学生会員。

矢入 健久(正会員)

1971 年生まれ。1994 年東京大学工学部航空宇宙工学科卒業。1996～1998 年日本学術振興会特別研究員。1999 年東京大学院博士課程修了。同年、東京大学先端科学技術研究センター助手。2003 年東京大学大学院工学系研究科講師。2004 年同大学先端科学技術研究センター講師。工学博士。1999 年度本学会論文賞受賞。機械学習、移動ロボットの環境モデル獲得、宇宙機異常検知・診断法などに興味を持つ。人工知能学会、日本ロボット学会、日本航空

宇宙学会、各会員

町田 和雄(正会員)

1970 年北海道大学大学院精密工学専攻修士課程修了。同年、電子技術総合研究所に入所。宇宙ロボティクスを中心とした宇宙技術の研究に従事。産業技術総合研究所宇宙技術グループ長などを経て、2002 年より東京大学先端科学技術研究センター教授。日本ロボット学会論文賞(1995 年, 2001 年), 計測自動制御学会論文賞(2001 年)受賞。日本ロボット学会, 計測自動制御学会, 日本航空宇宙学会などの会員。