

# Dynamic Bayesian Networksを用いた宇宙機異常診断法

## Spacecraft Diagnosis Using Dynamic Bayesian Networks

河原吉伸\*<sup>1</sup>      矢入健久\*<sup>2</sup>      町田和雄\*<sup>2</sup>  
 Yoshinobu Kawahara      Takehisa Yairi      Kazuo Machida

\*<sup>1</sup>東京大学大学院工学系研究科  
 Graduate School of Engineering, The University of Tokyo

\*<sup>2</sup>東京大学先端科学技術研究センター  
 Research Center for Advanced Science and Technology, The University of Tokyo

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 using probabilistic reasoning and statistical learning with Dynamic Bayesian Networks(DBNs). In this method, the DBNs are initially from prior knowledge, then modified or partly re-constructed by statistical learning from operation data, as a result a wide range of anomaly detection and advanced cause investigation are performed by probabilistic reasoning using the DBNs. This method has the both ability which two polar approaches; knowledge-based and data-driven. 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

高度な異常検知・故障診断法の開発は、宇宙システム研究における重要課題の一つである。宇宙開発に対するニーズの多様化に伴い、宇宙システムの大規模・複雑化による信頼性確保の難化の一方、ミッションそのものの高度化による信頼性への高い要求から、何らかの不具合の兆候をできるだけ早く検知すると共に、異常時における運用者の迅速で正確な対応を支援する宇宙機運用・診断法の開発が重要となっている。

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。従来、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、専門家の経験的知識を利用したエキスパート・システムに基づく方法や、運動方程式から得られる物理的な定性ルールを監視するモデルベース診断などが提案されている [Dearden et al. 04]。しかしこれらの方法はいずれも、事前に与えるモデルやルールなどの組み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に含む環境下におかれる宇宙機の診断には大きな問題となる。また最近では、データから直接システムの挙動を表すモデルを獲得して診断を行う、データ重視のアプローチも提案されており、宇宙分野以外では盛んに研究されている。この方法は、診断の精度や詳細度の点では前述の知識重視の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、別の表現をすると、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、後者はデータから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、一方が他方の持つ長所をカバーする事は難しい。このような背景に基づき、本研究では広く深い診断能力を持つ診断システムを実現する診

断法を目的として、Dynamic Bayesian Networksを用いた宇宙機異常診断法を提案する。

### 2. 提案手法

本研究で提案する診断法の概要を図1に示す。本診断法は、診断モデルとして Dynamic Bayesian Networks(DBNs)を用い、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. 診断モデル上での確率推論による異常検知・故障診断

1および2は事前に蓄えられた運用データを用いてオフラインで行われ、3はリアルタイムで行われる。以下、まず Dynamic Bayesian Networks(DBNs)について簡単に述べた後、これらの過程について順に説明する。

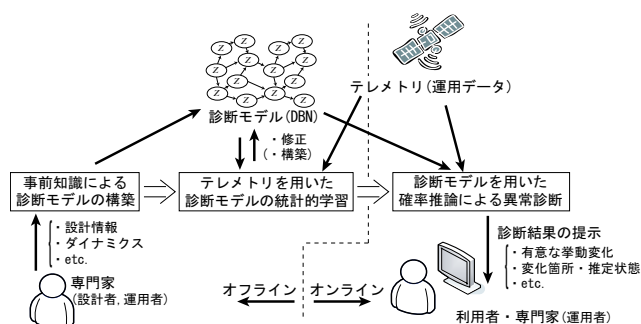


図1: 提案する診断法の概要

### Dynamic Bayesian Networks(DBNs)

Dynamic Bayesian Networks(DBNs)[Murphy 02] は汎用的な状態空間モデルの一つであり、初期分布 ( $\Pr(\mathbf{X}_0)$ ) と遷移分布 ( $\Pr(\mathbf{X}_t|\mathbf{X}_{t-1})$ ) をそれぞれ Bayesian Networks(BNs)を用いて記述する。つまり、初期分布を表す  $\text{BN}(BN_0)$  と遷移分布を表す  $\text{BN}(BN_{\rightarrow})$  の、2つのBNの組  $(BN_0, BN_{\rightarrow})$  が




図 2: センサ異常を診断する場合の DBN

ら成る．従って，BNs と同様に事前知識とデータを融合的に用いたモデル獲得が可能であると共に，時間的相関の扱いが可能となり，宇宙機などの動的システムに発生する漸化的な異常を捉える事ができる期待できる．

### 事前知識による DBNs の構築

本診断法では，まず診断対象に関する事前知識を用いて DBNs を構築する．事前知識を用いずデータのみを用いた DBNs の獲得も可能であるが，状態方程式で表される物理的知識や専門家の経験的知識などは非常に有用な情報源であり，これらを十分に活用する事により，精度向上のみでなく，利用者の宇宙機に対する理解や利用目的を反映したモデル化が可能となる．

### 運用データを用いた DBNs の学習

提案する診断法では，事前知識により構築された診断モデルと事前に蓄えられた運用データを用いて，宇宙機の正常時の挙動を表すモデルを修正あるいは部分的に獲得する．このように，実際の宇宙機の挙動データを用いる事で，事前知識が持つ不確実性を補うことが可能となる．DBNs の学習は，HMMs の学習に用いられる Baum-Welch アルゴリズムに類似した，EM アルゴリズムを用いて行う事ができる [Friedman et al. 98] ．

### DBNs 上での確率推論による診断

本診断法では，正常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 et al. 02] ．これは，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事で可能となる．例えば何らかのセンサを診断する場合，図 2 のように，観測値の条件として，観測される状態量に加えて”異常”と”正常”の 2 値をとる離散変数  $F$  を加え， $F =$  ”異常”の分布として，正常の場合の分布と中心が等しく，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確率変数の分布を，DBN を用いた確率推論計算によりオンラインで推定する．なお本場合のように，離散変数が連続変数を親変数として持たない場合には，Rao-Blackwellised Particle Filter (RBPF) [Doucet et al. 00] という近似推論アルゴリズムの計算効率が高く，本研究でもこれを用いている．

## 3. 評価実験

提案する診断法の検証のため，宇宙機のランデブー・プロセス<sup>\*1</sup>におけるスラスト異常を模擬したシミュレーション・データ<sup>\*2</sup>に対して，提案法を適用した．

### 問題設定

本適用では，ランデブー中のスラスト異常に対し，その検知のみでなく，運用者が箇所や原因の推測を行うための情報を提

\*1 接触時に衝撃が生じないように，宇宙機同士が接近するプロセス

\*2 宇宙航空研究開発機構 JAXA 提供

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	”
$\Theta$	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)

示することを目的とする．つまり，「どのスラストが，どのような状況で異常であるか？」を運用者が判断する情報を与えることが目的となる．

ランデブーを行う宇宙機は，14 機のスラストを用いて姿勢および並進制御を行う．データはこの 14 機のスラストへの 16 段階のコマンド 14 系列と，宇宙機の位置，速度，姿勢角および姿勢角速度の観測値 12 系列の，計 26 系列から成る．観測間隔は 0.125[s] である．また，宇宙機の質量特性 (重量，慣性モーメント) やスラスト特性 (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とする．従って，事前の正確なモデル化が必要な，非線形フィルター (EKF や PF) を単純に適用することは難しい．

### 診断モデル

本実験のため，以下のように事前知識を用いて図 3 に示すグラフ構造をもつ DBN を構築した．なお図では，連続変数を表すノードを楕円形で，離散変数を長方形で表し，また観測変数を灰色で表している．まず，診断目的が異常スラストの特定と異常状態の把握であるため，観測変数の他に，各スラスト推力を表す連続変数および異常の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，変数間の関係に関する事前知識として，次式で表される，軌道上での姿勢運動 (オイラー方程式) と並進運動 (ヒルの方程式) に関する (線形) 運動方程式を用いた．

$$\dot{\theta} = [\omega_1 + n\theta_3, \omega_2 + n, \omega_3 - n\theta_1]^T \quad (1)$$

$$\begin{aligned} J_1\dot{\omega}_1 + n(J_2 - J_3)\omega_3 &= M_1 \\ J_2\dot{\omega}_2 &= M_2 \end{aligned} \quad (2)$$

$$J_3\dot{\omega}_3 - n(J_1 - J_2)\omega_1 = M_3$$

$$\begin{aligned} \ddot{x} &= 2n\dot{z} + F_x \\ \ddot{y} &= -n^2y + F_y \\ \ddot{z} &= 3n^2z - 2n\dot{x} + F_z \end{aligned} \quad (3)$$

ここで， $J_i (i = 1, 2, 3)$ ,  $n$  は軌道や宇宙機の形状等で決まる定数であり (ただし本適用では未知)， $M_i, F_i (i = x, y, z)$  はスラストの配置や推力から計算されるモーメントおよび推進力である．これらを用いて，例えば  $\theta_1$  であれば次のようにして，条件付確率を付与する．

$$\begin{aligned} \Pr(\theta_{1,t} | \theta_{1,t-1}, \theta_{3,t-1}, \omega_{1,t-1}) \\ = \mathcal{N}(\theta_{1,t}; \theta_{1,t-1} + \Delta t(\omega_{1,t-1} + n\theta_{3,t-1})) \end{aligned} \quad (4)$$

ここで， $\Delta t$  は観測間隔である．

この DBN に対し，より宇宙機の実際の挙動に適應させるため，正常時のデータを用いて，EM アルゴリズムによる学習を行った．図 4 はこのときの対数尤度の推移であり，学習前に比べ高い尤度が得られている．

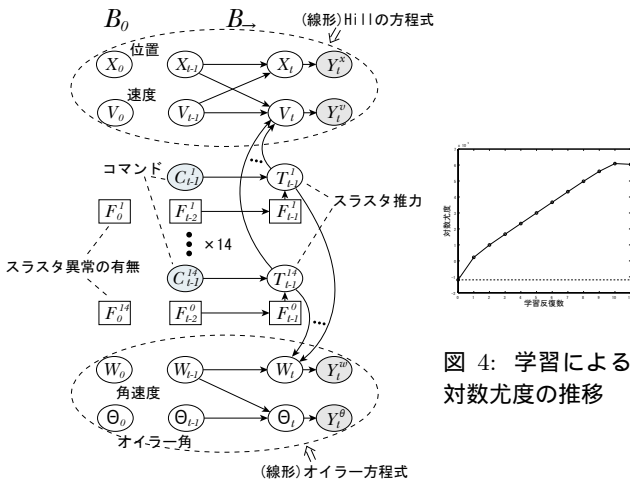


図 3: 用いた DBN のグラフ構造




図 4: 学習による対数尤度の推移




図 5: 各スラスタの異常確率の推移




図 6: 各スラスタの推定推力 (平均値) の推移

診断結果

”250[s] からスラスタ 4 の推力が漸的に減少する異常”を模擬したデータに対して、診断を行った結果を示す。

図 5 は、DBN 上で RBPF を用いる事により計算された各スラスタの異常確率の推移を表したものである。つまり、図 3 中の各  $F_i (i = 1, \dots, 14)$  = (異常) の確率の推移を表している。図からわかるように、250[s] 付近で、スラスタ 4 を含むいくつかのスラスタの異常を表す確率の値が大きく 1 に近づいている。何らかの異常を検知できている事は確かであるが、直接各スラスタの推力等を観測できるわけではないので、1 つのスラスタに異常を絞る事はできていない。これは、状態量の推移を達成できるスラスタ推力の任意性のため、得られる観測からでは一意に決定できない事によると思われる。

また図 6 は、各スラスタの推定される推力の推移である。つまり、図 3 中の各  $T_i (i = 1, \dots, 14)$  の推定値の平均の推移を表している。図からわかるように、250[s] 以降、複数のスラスタに関する値が不規則に変化しているが、実際に異常が発生しているスラスタ 4 に関する値は、漸的に値が減少するという傾向が読み取れる。これにより、運用者は異常の状況を推測する事が可能となる。

4. おわりに

本稿では、Dynamic Bayesian Networks を診断モデルとして、事前知識とデータを融合的に用いる診断法を提案した。今後、事前知識とデータを用いた学習方法の改善やモデルの非線形化、事前知識の体系的な利用方法など、様々な問題を考慮しつつ、実運用データなどを用いた実験を行い、提案法の有効性を検証する予定である。

5. 謝辞

本研究を進めるにあたり、宇宙航空研究開発機構の山中浩二氏、稲場典康氏には、シミュレーション・データの提供をはじめ、大変お世話になりました。深く感謝いたします。

参考文献

[Dearden et al. 04] Dearden, R, Hutter, F, Simmons, R, Thrun, S, Verma, V and Willeke, T : "Real-time Fault Detection and Situational Awareness for Rovers: Report on the Mars Technology Program Task" (In Proceedings of IEEE Aerospace Conference, 2004)

[Murphy 02] Murphy, K. P : "Dynamic Bayesian Networks: Representation, Inference and Learning" (Ph.D Thesis, University of California, 2002)

[Pearl 88] Pearl, J : "Probabilistic Reasoning in Intelligent Systems" (Morgan Kaufmann, 1988)

[Friedman et al. 98] Friedman, N, Murphy, K and Russell, S : "Learning the Structure of Dynamic Probabilistic Networks" (In Proceedings of the 14th Annual Conference on Uncertainty in AI, 1998)

[Lerner et al. 02] Lerner, U, Moses, B, Scott, M, McIlraith, S and Koller, D : "Monitoring a complex Physical System using a Hybrid Dynamic Bayes Net" (In Proceeding of the 18th Annual Conference on Uncertainty in AI, 2002)

[Doucet et al. 00] Doucet, A, Freitas, 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, 2000)