マルチモデル法に基づく移動ロボットの 内界センサ系の故障診断* (カルマンフィルタによるスケール故障の診断)

橋本 雅文^{*1}, 川島 洋之^{*2}, 大場 史憲^{*1}

Multiple-Model Based Fault Detection and Diagnosis of Internal Sensors in Mobile Robot (Detection and Identification of Sensor-Scale Failure via Kalman Filter)

Masafumi HASHIMOTO^{*3}, Hiroyuki KAWASHIMA and Fuminori OBA

^{*3} Division of Mechanical System Engineering, Hiroshima University,
1-4-1 Kagamiyama, Higashi-Hiroshima-shi, Hiroshima, 739-8527 Japan

This paper proposes a multi-model based approach to fault detection and diagnosis of internal sensors in mobile robot for a robust dead reckoning. A scale failure, at which the scale of sensor outputs differs from the normal, is handled as the failure type. The scale factor of the sensors as well as the robot velocity is estimated with single-model based Kalman filters, each of which is based on a model matching to a failure mode of particular sensors. The model-based estimates of the scale factors are compared with each other, and then fault decision is made. The proposed fault detection and identification algorithm is implemented on our skid-steered mobile robot with five internal sensors (four wheel-encoders and a yaw-rate gyro). Fifteen fault modes are modeled to correctly diagnose the failure of any one of the five sensors. Experimental results show the property of the fault detection and identification algorithm.

Key Words: Mobile Robot, Sensor Failure, Scale Failure, Fault Detection and Diagnosis, Multiple-Model Method, Kalman Filter

1. 結 論

センサ系やアクチュエータ系などの故障診断システムをロボットに備えることは、その安全性や信頼性の向上に不可欠である。本研究はフォルトトレラントな移動ロボット実現に向けての基礎研究として、内界センサ系の故障を診断し、センサ系の一部故障に対しても自己位置推定が可能なデッドレコニング(DR)系を構築するものである。

故障診断法は、(1) 推論ルール、ファジーやニューラルネットなどのソフトコンピューティング、スペクトル解析などに基づくモデルフリー手法と、(2) カルマンフィルタやオブザーバなど、対象のダイナミカルモデルに基づくモデルベース手法とに大別できる^①。比較的低速で走行する移動ロボットでは近似度の高い運動学モデルの構築が容易なこと、移動ロボッ

トの自己位置推定の分野では、カルマンフィルタ(KF)を基礎とした位置推定手法がよく用いられることから、移動ロボットの故障診断ではカルマンフィルタ(KF)に基づくモデルベース手法が自然である。

さて、内界センサ系の故障形態としては、(1) 故障時にセンサ出力がある一定値となる「ハード故障」、(2) 故障時にセンサ雑音の大きさが正常時より増大する「ノイズ故障」、(3) 故障時に出力スケール(ゲイン)が変化する「スケール故障」の3つに大別できる。

Roumeliotis, Goel らは KF を基礎とした故障診断手法として、マルチモデル法のひとつである MMAE (Multiple Model Adaptive Estimation) 法^②を適用して、移動ロボットの内界センサのハード故障やノイズ故障、タイヤパンク(機械ハード故障)に対する故障診断法を提案した^③。しかし、故障はロボットのシステム構造やパラメータを変化させるにもかかわらず、MMAE 法ではシステムモード間の遷移はないとの前提で状態を推定することから、故障診断への適用にあ

* 原稿受付 2002 年 6 月 7 日。

^{*1} 正員, 広島大学大学院工学研究科(〒739-8527 東広島市鏡山 1-4-1)。

^{*2} 広島大学大学院工学研究科(現: 神鋼電機(株))。

E-mail: hasimoto@mec.hiroshima-u.ac.jp

たつては様々なアドホックな方法を導入する必要がある^⑥。

そこで筆者らは、内界センサ系のハード故障を対象に、システムモード間の遷移を陽に考慮して IMM (Interacting Multiple Model) 法^⑦に基づく故障診断法を提案した^{⑧⑩}。また、内界センサ系のハード故障とノイズ故障を対象に小規模な故障モデルを用いるとともに、ロボットの走行状態によらず信頼性の高い診断を実現するため、センサ毎に独立した故障診断系を構築し、故障モデル集合を走行状態に応じて動的に切替えて故障を診断する方法を VSIMM (Variable-Structure Interacting Multiple-Model) 法^⑪を基礎に設計した^⑫。

本論文では、内界センサ系のスケール故障に対する診断法を提案する。そして、提案手法の特性を実験により示す。以下に本論文の構成を示す。2では実験用ロボットの構成と故障診断の基礎式を、3では故障診断アルゴリズムを示す。4では実験により提案手法の特性を示し、5で主な結論を述べる。

2. 移動ロボットの構成と基礎式

2.1 ロボットの構成 図1のように、ロボットは4つの独立駆動輪を持つスキッドステア型移動ロボットで、左右車輪の速度差によって直進や旋回を行う。トレッド長は 0.638 [m]、ホイールベースは 0.457 [m] で、車輪は半径 (公称値) が 0.19 [m] の中空タイヤである。内界センサとして、各車輪には速度計測用のエンコーダ (分解能: 4000 [pulse/rev]) を、車体には旋回速度計測用レートジャイロ (分解能: 8.522×10^4 [rad/s]) を設けている。以後、それらをセンサ 1～5 と記す (図2参照)。

2.2 基礎式 スケール故障診断は後述するように、複数の故障モデルを構築し、それぞれに対して KF を構成してモデル毎にセンサ出力の変動率 (スケールファクタ、以下 SF) を推定する。そして、それらの大きさを比較することで故障を診断する。なお、

Fig. 1 Experimental robot

Fig. 2 Notations related to the robot

センサ k ($k=1\sim 5$) の SF の定義は以下である。

$$\alpha_k = \frac{\text{センサ } k \text{ から実際に観測された値}}{\text{センサ } k \text{ から本来観測されるべき値}} \quad (1)$$

いま、5つのセンサに対してスケール故障が起こりうる可能性を‘形式的’に全て列挙すると表1となる。これらの故障モードに対応する故障モデルを構築する。

図2に示すように、車体の並進速度を V 、旋回速度を ψ とおく。センサ故障時でもフォルトトレラント制御系により、車体はほぼ一定の並進速度、旋回速度で運動すると仮定する。また、SF はほぼ一定とする。その時、離散時間系での故障モデル m_i ($i=0, \dots, 31$) の状態方程式は次式となる。

$$\xi_i(t) = \xi_i(t-1) + \tau w_i(t-1) \quad (2)$$

ただし、 t 、 $t-1$ は時間ステップ、 τ はサンプリング周期、 ξ_i は後述する状態変数、 w_i は ξ_i の変化率を表す。 w_i が時間ステップ $t-1 \sim t$ 内では一定とすることで上式が求まる。いま、変化率 w_i は平均値ゼロ、

Table 1 Possible scale failure mode

Mode	Fault sensor	Mode	Fault sensor
0	None	16	1, 2, 3
1	1	17	1, 2, 4
2	2	18	1, 2, 5
3	3	19	1, 3, 4
4	4	20	1, 3, 5
5	5	21	1, 4, 5
6	1, 2	22	2, 3, 4
7	1, 3	23	2, 3, 5
8	1, 4	24	2, 4, 5
9	1, 5	25	3, 4, 5
10	2, 3	26	1, 2, 3, 4
11	2, 4	27	1, 2, 3, 5
12	2, 5	28	1, 2, 4, 5
13	3, 4	29	1, 3, 4, 5
14	3, 5	30	2, 3, 4, 5
15	4, 5	31	All

共分散 $\mathbf{Q}$ の正規性白色雑音と仮定し、以後、プラント雑音と称する。 ξ_i は故障モデルに依存する。例えば m_1 、 m_6 ではそれぞれ、 $\xi_1 = (V, \dot{\psi}, \alpha_1)^T$ 、 $\xi_6 = (V, \dot{\psi}, \alpha_1, \alpha_2)^T$ となる。すなわち、モデルにおいて、故障を考えているセンサの SF が状態変数中に表れる。故障モデル m_i の観測方程式は次式となる。

$$\mathbf{z}(t) = \mathbf{h}_i[\xi_i(t)] + \Delta \mathbf{z}(t) \quad (3)$$

ただし、 $\mathbf{z} = (z_1, z_2, z_3, z_4, z_5)^T$ はセンサ出力、観測雑音 $\Delta \mathbf{z}$ は平均値ゼロ、共分散 $\mathbf{R}$ の正規性白色雑音とする。 $\mathbf{h}_i[\xi_i]$ は故障モデルに依存し、例えば、 m_1, m_6 では以下となる。

$$\mathbf{h}_1[\xi_1] = \begin{pmatrix} \alpha_1(V - d\dot{\psi}) \\ V - d\dot{\psi} \\ V + d\dot{\psi} \\ V + d\dot{\psi} \\ \dot{\psi} \end{pmatrix}, \quad \mathbf{h}_6[\xi_6] = \begin{pmatrix} \alpha_1(V - d\dot{\psi}) \\ \alpha_2(V - d\dot{\psi}) \\ V + d\dot{\psi} \\ V + d\dot{\psi} \\ \dot{\psi} \end{pmatrix}$$

ただし、 $d = T/\sin \eta$ である。

式(2)、(3)をもとに車体の並進・旋回速度と SF を推定する KF アルゴリズムを要約する。時刻 $t-1$ での推定値 $\hat{\xi}_i(t-1)$ その誤差分散 $\mathbf{P}_i(t-1)$ が与えられると、時刻 t での $\hat{\xi}_i(t)$ 、 $\mathbf{P}_i(t)$ は以下により算出できる。

【状態予測アルゴリズム】

$$\left. \begin{aligned} \hat{\xi}_i(t/t-1) &= \hat{\xi}_i(t-1) \\ \mathbf{P}_i(t/t-1) &= \mathbf{P}_i(t-1) + \tau^2 \mathbf{Q}_i(t-1) \end{aligned} \right\} \quad (4)$$

【観測更新アルゴリズム】

$$\left. \begin{aligned} \hat{\xi}_i(t) &= \hat{\xi}_i(t/t-1) + \mathbf{K}_i(t) \tilde{\mathbf{z}}_i(t/t-1) \\ \mathbf{P}_i(t) &= \mathbf{P}_i(t/t-1) - \mathbf{K}_i(t) \nabla \mathbf{h}_i(t) \mathbf{P}_i(t/t-1) \\ \mathbf{K}(t) &= \mathbf{P}_i(t/t-1) \nabla \mathbf{h}_i^T(t) \mathbf{S}_i^{-1}(t/t-1) \end{aligned} \right\} \quad (5)$$

ただし、 $\nabla \mathbf{h}_i = \partial \mathbf{h}_i / \partial \xi_i$ で、 $\tilde{\mathbf{z}}_i$ と $\mathbf{S}_i$ はそれぞれ、次式で示す観測予測誤差とその共分散である。

$$\left. \begin{aligned} \tilde{\mathbf{z}}_i(t/t-1) &= \mathbf{z}(t) - \mathbf{h}_i[\hat{\xi}_i(t/t-1)] \\ \mathbf{S}_i(t/t-1) &= \nabla \mathbf{h}_i(t) \mathbf{P}_i(t/t-1) \nabla \mathbf{h}_i^T(t) + \mathbf{R}_i(t) \end{aligned} \right\} \quad (6)$$

センサ 1 のスケール故障モデル m_1 を例に KF による観測更新の特徴を述べる。カルマンゲイン $\mathbf{K}$ 中のセンサ 1 と車体並進・旋回速度との関連項は小さくなることから、センサ 1 の観測値が並進・旋回速度推定へ与える影響は小さい。他方、センサ 1 の SF は観測予測誤差をゼロとするように推定される。すなわち、観測更新アルゴリズムでは、 m_1 において正常と考えるセンサ 2~5 の情報をもとに車体の並進・旋回速度

を推定し、その情報をもとに故障と考えるセンサ 1 の SF を推定することになる。

3. 故障診断アルゴリズム

3.1 故障モード再考 センサ k のスケール故障診断は、複数の故障モデルそれぞれに対して KF により推定される SF の大きさを比較することで実現する。ここで、前述した KF における観測更新の特徴により、センサ k を故障と考える故障モデルをもとにセンサ k の SF を正しく推定するには、センサ k 以外のセンサにより車体の並進・旋回速度が正確に推定できていることが必要となる。しかし、それを内界センサ情報のみで常に実現することは容易でない。特に、車体の並進速度の推定に必要な車輪対地速度は、車輪エンコーダによる車輪回転数情報に車輪径（公称値）を乗ずること得ることから、大きな車輪スリップや車輪径変動がある場合は、並進速度情報は不正確となる。

以上を考慮すると、表 1 に示す故障モード 18、25~31 では車体の並進速度や旋回速度が明らかに推定できないことから SF も推定できず、故障の診断はできない。また、複数のセンサにスケール故障が生じる場合は、故障箇所や故障の程度などによっては車体の並進・旋回速度の推定値が劣化して故障診断が不確実となる。例えば、3 センサ故障の一例として、センサ 1~3 が同時に故障した場合を考えると、故障しているセンサが多いため、故障センサ 1~3 により車体の並進速度が誤って推定され、正常なセンサ 4 が故障していると誤診する可能性がある。また、2 センサ故障の一例としてセンサ 1, 2 の同時スケール故障を考えると、同様な議論により、センサ 3, 4 が故障していると誤診する可能性もある。

以上のことから、本論文では、内界センサのみの情報をもとに確実な故障診断を行うため、ひとつのセンサのスケール故障を対象に、故障の検出とともに同定（故障センサの特定とその SF の大きさの同定）を可能とする診断系を設計する。そのため、故障モデルとして表 2 に示す 1, 2 センサに関するモデルを用いる。ここで、2 センサの故障モデルは 1 センサ故障モデルが推定する SF の比較に必要となる。なお、表 2 中のモデル番号は表 1 のモード番号とは異なり、新たに付け直したもので、以後の議論で用いるモデルやモードに関する番号は表 2 中の番号に従うとする。

3.2 故障診断アルゴリズム スケール故障診断の手順を以下に示す。

Table 2 System model of scale failures

Model	Fault sensor	Model	Fault sensor
0	1	8	1, 3
1	2	9	2, 4
2	3	10	5
3	4	11	1, 5
4	1, 2	12	2, 5
5	2, 3	13	3, 5
6	3, 4	14	4, 5
7	1, 4		

[Step 1] 状態推定: 表 2 の 15 個の故障モデルそれぞれに対して KF (式(5), (6)) を構成し, 車体の並進・旋回速度と SF を推定する。

[Step 2] 有効モデルの選択: 各モデルで推定した SF を比較し, 類似する推定値を持つモデルを抽出する。いま, 2つのモデル m_i, m_j に対して得られるセンサ k ($k=1\sim 5$) の SF 推定値を $\hat{\alpha}_k^{(i)}, \hat{\alpha}_k^{(j)}$ とする。なお, 状態変数中に表れないセンサの SF に対してはその値を 1 とする。全てのセンサの SF に関して

$$\left| 1 - \frac{\hat{\alpha}_k^{(j)}}{\hat{\alpha}_k^{(i)}} \right| \leq \lambda_1 \text{ (一定値)} \quad (7)$$

を満たせば, モデル m_j は m_i の類似モデルとする。

そして, モデル m_i の類似モデルが自身(m_i)も含めて 3つ以上であればモデル m_i を有効モデルとし, 2以下であれば m_i を無効とする。なお, 全センサが正常な場合は全モデルが有効モデルとなる。

[Step 3] 故障診断: 全ての有効モデルにおける状態推定値の平均値 $(\bar{V}, \bar{\psi}, \bar{\alpha}_1, \bar{\alpha}_2, \dots, \bar{\alpha}_5)$ を求める。そして,

$$|1 - \bar{\alpha}_k| \geq \lambda_2 \text{ (一定値)} \quad (8)$$

を満たせば, センサ k を故障と判断する。なお, $(\bar{V}, \bar{\psi})$ をもとにデッドレコニング(DR)により自己位置を推定することで, ロボットはセンサ故障時でも自己位置推定精度の劣化を軽減できる。

Step 2 において, 有効モデルを選択する閾値を 3 とする理由をセンサ 1 が故障している場合を例に述べる。この場合, センサ 1 を故障と考えるモデル $m_0, m_4, m_7, m_8, m_{11}$ がともに類似した SF 推定値を持ち, 他のモデルは自分自身しか類似しない。しかし, ロボットの直進時はセンサ 5 (ジャイロ) の出力, 観測予測値ともにほぼゼロとなることから, センサ 5 を故障と考えるモデル $m_{10} \sim m_{14}$ ではセンサ 5 の SF は推定できず結果的に m_0 と m_{11} , m_1 と m_{12} , m_2 と m_{13} , m_3 と m_{14} の SF 推定値は類似する。このようにロボッ

ト直進時には無効とすべき類似モデルが最大 2 つになることから閾値を 3 とした。

Step 2 において有効モデルが抽出できない場合は, Step 3 での故障センサの特定と SF の同定ができない。すなわち, 有効モデルの抽出不可能は故障検出のみができることを意味する。どのような形態の故障が発生したときに故障検出のみが可能となるかは次章の実験で述べる。

4. 実験

ロボットをジョイスティックにより手動操作して図 3 に示す経路に沿って 1 周させた。直線部での速度は約 0.5 [m/s] で, 曲路部ではロボットをいったん停止させ, 約 0.3 [rad/s] でその場旋回させた。表 3 にロボットの走行状態を示す。

走行中に観測したセンサ情報を計算機に保存し, そのデータをもとに擬似的な故障を発生させた。スケール故障の形態としては, 「突発的な故障」と時間的に徐々にスケールが変化する「経時変化的な故障」の 2 種類を想定した。突発故障ではセンサ出力の SF が 0.5 に変化するとし, 経時劣化的な故障に対しては, SF が 1 (初期時刻) から 0.5 (時刻 50 秒) まで直線的に変化するとした。なお, 2 センサ以上のスケール故障では, センサ毎に故障する発生時刻や大きさが異なる場合も考えられるが, 実験では, 同じ大きさの故障が同時刻で発生する最悪のケースを想定する。

以下の 10 通りの条件下で実験を行った。

- Case 1) 25 秒でセンサ 1 に突発故障が発生,
- Case 2) センサ 1 に経時変化的な故障が発生,
- Case 3) 25 秒でセンサ 5 に突発故障が発生,
- Case 4) センサ 5 に経時変化的な故障が発生,
- Case 5) 25 秒でセンサ 1, 2 に突発的な同時故障が発生,
- Case 6) 25 秒でセンサ 1, 5 に突発的な同時故障が発生,
- Case 7) 25 秒でセンサ 1~3 に突発的な同時故障が発生,
- Case 8) 35 秒でセンサ 1~4 に突発的な同時故障が発生,

Fig. 3 Experiment setup

Table 3 Robot motion

Time [s]	Motion	Time [s]	Motion
0.0 - 1.0	Stop at start	32.3 - 32.6	Stop
1.0 - 8.0	Forward (A)	32.6 - 37.8	Pivot turn
8.0 - 8.3	Stop	37.8 - 38.0	Stop
8.3 - 13.5	Pivot turn	38.0 - 41.6	Forward (D)
13.5 - 13.9	Stop	41.6 - 41.8	Stop
13.9 - 17.0	Forward (B)	41.8 - 47.0	Pivot turn
17.0 - 17.4	Stop	47.0 - 47.3	Stop
17.4 - 22.4	Pivot turn	47.3 - 50.7	Forward (E)
22.4 - 22.7	Stop	50.7 - 60.0	Stop at goal
22.7 - 32.3	Forward (C)		

Case 9) センサ 1~4 に経時変化的な同時故障が発生,
Case 10) 35 秒で全センサに突発的な同時故障が発生.

KF におけるプラント雑音と観測雑音に関する分散は試行錯誤で与えた. プラント雑音の分散 Q_i は, センサ情報に重きをおくよう並進速度に関して $0.64 \text{ [m}^2\text{/s}^2]$, 旋回速度に関して $0.64 \text{ [rad}^2\text{/s}^2]$ と大きめに設定し, SF に関しては 6.4×10^3 と設定した. 他方, センサの観測雑音の分散 R に関しては, センサ 1~4 の雑音の分散は車輪の滑り等を考慮して $9.0 \times 10^{-4} \text{ [m}^2\text{/s}^2]$ とし, センサ 5 に関してはその精度が良いことから $1.0 \times 10^6 \text{ [rad}^2\text{/s}^2]$ とした. 式(7), (8)中の閾値 λ_1, λ_2 はともに 0.1 である.

各条件下で得られた SF 推定値 (全ての有効モデルにおける SF 推定値の平均値) とセンサの診断結果をそれぞれ図 4~13 の(a), (b)に示す. なお, 図 8~11 のグラフが途中の時刻で終わっているのは, その時刻で有効モデルを抽出できない, すなわち故障の検出のみができ診断が不可能となるためである.

図 4~7 より 1 センサ故障(Case 1~4)では正しく故障診断 (故障の検出と同定) ができるのが分かる. ただし, 図 6 (Case 3)ではセンサ 5 の診断はロボットが旋回を始める 33 秒付近まで遅れる. これはセンサ 5 の故障発生時 (25 秒) はロボットが直進しており, センサ 5 の観測値, 観測予測値がともにゼロ近傍で SF の推定が困難なためである. 図 7 (Case 4)における挙動も同様の理由による. 従って, センサ 5 のスケール故障診断はセンサの観測予測誤差が大きくなるロボットの旋回時に可能となる.

図 8, 9 に示すように, 2 センサの同時故障(Case 5, 6)では, 有効モデルが抽出できず, 故障の検出のみしか行えないことが分かる. 図 9 (Case 6)でロボットが旋回を始める 33 秒付近で故障が検出できるのは先の Case 3, 4 と同様な理由による. なお, 故障検出しかできない場合はいずれのセンサが故障しているか不明な

ため, 実システムでは安全を配慮してロボットを停止させることが必要となる.

図 10 に示すように, 3 センサの同時突発故障 (Case 7)では, 25 秒 (故障発生時)~33 秒は故障センサ 1~3 の SF を 1, 正常なセンサ 4 の SF を誤った値に推定した結果, センサ 1~3 を正常と, また, センサ 4 を故障と誤診する. そして, ロボットが旋回を始める 33 秒付近で有効モデルが抽出できなくなる. これは以下の理由による. 25~33 秒 (ロボット直進時) において, センサ 4 の故障を考える $m_3, m_6, m_7, m_9, m_{14}$ では, 実際に故障しているセンサ 1~3 の出力をもとに車体の並進速度を推定する. センサ 1~3 の SF は同じ大きさ(0.5)のため, それら 5 つの故障モデルいずれも観測予測誤差が大きいのはセンサ 4 のみであり, その SF が観測更新されることから $m_3, m_6, m_7, m_9, m_{14}$ が有効モデルとなる. その結果, 故障センサ 1~3 を正常と, 正常なセンサ 4 を故障と誤診する. なお, m_{14} ではセンサ 5 の故障も考えているが, 実際に故障しているセンサ 1~3 の SF は全て同じ(0.5)のため, それらより推定される旋回速度はほぼゼロとなる. 他方, ロボットの直進中はセンサ 5 の出力もほぼゼロであることから, 結果的に観測予測誤差が小さくなり, m_{14} においてセンサ 5 の SF は修正されず 1 のままとなる. 次に, ロボットが旋回を始めたとき(33 秒付近)を考える. それまでロボットは直進していることから, $m_3, m_6, m_7, m_9, m_{14}$ いずれも小さな旋回速度が予測される. 他方, 急激な旋回を始める 33 秒付近でセンサ 5 の出力は大きくなる. このことから 33 秒付近でセンサ 5 の観測予測誤差が生じ, 各モデルは故障と考えるセンサの SF を修正する. その結果, 先の 5 つのモデルにおける SF 推定値は互いに異なるものとなり有効モデルが抽出されなくなる. なお, 本論文には記載していないが, センサ 1, 2, 5 や 1, 4, 5 などの 3 センサの同時突発故障では, 故障が発生すると即座に有効モデルが抽出されなくなる.

図 11 に示す 4 センサの突発故障時(Case 8)も, 先の 3 センサ同時故障(Case 7)と同様な理由により, 故障センサ 1~4 の SF を 1, 正常なセンサ 5 の SF を誤って推定して, センサ 1~4 を正常と, センサ 5 を故障と誤診した後, 有効モデルが抽出できなくなる. また, 図 12 に示すように, 4 センサの経時変化的な故障の場合(Case 9)は正常なセンサ 5 を常に故障と誤診する. このように, 4 センサの同時故障では, 故障検出の性能はロボットの走行状態や故障条件に依存する. 全センサに同時故障が生じる場合(Case 10)は, 図 13 のように故障検出もできない.

(a) Estimate in scale factor

(b) Sensor state

Fig. 4 Experimental result (Case 1). In the subfigure (b), 'N' and 'F' stand for 'Normal' and 'Scale failure', respectively. In the left two figures, the solid line and dashed line are the results for sensor #1 and #2, respectively; in the middle two figures, the solid line and dashed line are the results for sensor #3 and #4, respectively.

(a) Estimate in scale factor

(b) Sensor state

Fig. 7 Experimental result (Case 4)

(a) Estimate in scale factor

(b) Sensor state

Fig. 5 Experimental result (Case 2)

(a) Estimate in scale factor

(b) Sensor state

Fig. 8 Experimental result (Case 5)

(a) Estimate in scale factor

(b) Sensor state

Fig. 6 Experimental result (Case 3)

(a) Estimate in scale factor

(b) Sensor state

Fig. 9 Experimental result (Case 6)

(a) Estimate in scale factor

(b) Sensor state

Fig. 10 Experimental result (Case 7)

(a) Estimate in scale factor

(b) Sensor state

Fig. 12 Experimental result (Case 9)

(a) Estimate in scale factor

(b) Sensor state

Fig. 11 Experimental result (Case 8)

(a) Estimate in scale factor

(b) Sensor state

Fig. 13 Experimental result (Case 10)

以上の実験より、提案するスケール故障診断法では、1 センサ故障時は故障の検出と同定がともにでき、2 センサの同時故障では故障検出のみが正確にできる。また、3 センサ以上、すなわち過半数のセンサの同時故障に対する故障検出の性能は走行状態や故障形態に依存する。なお、1 センサにスケール故障が発生した後に3 センサまでの同時スケール故障が生じた場合は、有効モデル抽出不能による故障検出ができることを確認している。

5. 結 論

本論文では、移動ロボットの内界センサ系のスケール故障に対する故障診断法を提案した。主な結果を以下に示す。

- (1) センサ情報をもとに車体の並進・旋回速度とセンサのスケールファクタをカルマンフィルタにより推定し、複数の故障モデルにより推定されるスケール

ファクタの大きさを比較することでスケール故障を診断する方法を示した。

- (2) ロボットの実走行中に観測したセンサ情報をもとに故障診断の実験を行い、1 センサのスケール故障時には故障検出と同定がともに可能であること、2 センサの故障に対しては故障検出のみが可能であることを示した。

2 センサ以上のスケール故障時でも故障の検出とともに同定を精度よく行うには、内界センサ情報のみでは困難であり、外界センサを併用して車体の並進・旋回速度の推定精度を高めることが不可欠となる。また、スケール故障のみならずハード故障やノイズ故障の発生下では故障形態が多岐に渡ることから故障診断が複雑となる。そこで、内界センサ系の全ての故障形態（ハード／ノイズ／スケール故障）を対象とした故障診断系の構築、外界センサ情報の利用によるスケール故障診断の高精度化などが今後の課題として挙げられる。

参考文献

- (1) J.Chen, and R.J.Patton, "Robust Model-Based Fault Diagnosis for Dynamic Systems", Kluwer Academic Publishers (1999)
- (2) A.S.Willsky, "A Survey of Design Methods for Failure Detection in Dynamic Systems", *Automatica*, **12**, pp. 601-611 (1976)
- (3) D.T.Magill, "Optimal Adaptive Estimation of Sampled Stochastic Processes", *IEEE Trans. on Automatic Control*, **AC-10**, pp. 434-439 (1965)
- (4) S.I.Roumeliotis, G.S.Sukhatme, and G.A.Bekey, "Sensor Fault Detection and Identification in a Mobile Robot", *Proc. of 1998 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*, pp.1383-1388 (1998)
- (5) P.Goel, G.Dedeoglu, S.I. Roumeliotis, and G.S. Sukhatme, "Fault Detection and Identification in a Mobile Robot using Multiple-Model Estimation and Neural Network", *Proc. of 2000 IEEE Int. Conf. on Robotics and Automation*, pp.2302-2307 (2000)
- (6) P.S. Maybeck, and P.D.Hanlon, "Performance Enhancement of a Multiple Model Adaptive Estimator", *IEEE Trans. on Aerospace and Electronic Systems*, **31-4**, pp.1240-1254 (1995)
- (7) H.A.P.Blom, and Y.Bar-Shalom, "The Interacting Multiple Model Algorithm for Systems with Markovian Switching Coefficient", *IEEE Trans. on Aerospace and Electronic Systems*, **33-8**, pp. 780-783 (1988)
- (8) M.Hashimoto, H.Kawashima, F.Oba: Robust Dead Reckoning System with Interacting Multiple Model Based Sensor Fault Diagnosis for Mobile Robot, *Proc. of the fourth IFAC Symp. on Intelligent Autonomous Vehicles (IAV01)*, pp.157-162 (2001)
- (9) M.Hashimoto, H.Kawashima, T.Nakagami, F.Oba: Sensor Fault detection and Identification in Dead-Reckoning System of Mobile Robot: Interacting Multiple Model Approach, *Proc. of the 2001 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS 2001)*, CD-ROM (2001)
- (10) 橋本, 川島, 中上, 大場: センサ系の故障診断機能を有する移動ロボットのロバストデッドレコニング, *日本機械学会論文集 C 編*, **69-666** (2002)
- (11) X.R.Li: Engineer's Guide to Variable-Structure Multiple-Model Estimation for Tracking, Multitarget-Multisensor Tracking: Application and Advances Volume III (Y. Bar-Shalom and W.D.Blair, Eds.), Artech House, pp. 499-568 (2000)
- (12) 橋本, 川島, 大場: マルチモデル法に基づく移動ロボットの内外界センサ系の故障診断 Variable Structure Interacting Multiple-Model 法によるノイズ故障の診断, *日本機械学会論文集 C 編*, **69-677** (2003)