

## 多重モデル法を用いた鉄道車両サスペンションの状態診断

生産工学部 (院) ○森 裕貴

生産工学部 綱島 均

### 1. 緒言

鉄道における検査・保守は事故を未然に防ぎ安全を保証する重要な業務であり、定期的に行われている。車両の検査は、重大な事故を防ぐために特に重要である。検査時に故障が検出できない場合には故障が走行中に重大な事故を引き起こす可能性がある。車両故障を早期に検出するためには状態監視(コンディションモニタリング)が必要であり、常時監視するためには車両に付けたセンサの信号から故障を検出する方法が提案されている<sup>1)</sup>。

コンディションモニタリングは故障検知や同定(Fault Detection and Isolation (or Identification) : FDI)として確立、発達した分野の一部と考えることができ、FDIに関する多くの研究がなされている<sup>2)</sup>。コンディションモニタリングは主に時間と共に悪化するシステムに適用され、故障を引き起こす前に劣化の検知・特定を行うコンディションベースメンテナンス (condition-based maintenance)の重要な要素である<sup>3)</sup>。

センサの信号から故障を検出する際に、車両に取り付けたセンサの入出力信号の関係がわかれば、突然の故障はモデルベースの手法(力学モデルから計算された値とセンサの信号との誤差を評価する手法)を用いて検知することが可能である。

本研究はモデルベースの信号処理手法の1つであるIMM(Interacting Multiple Model)法<sup>4)</sup>を用いた、車体台車間左右動ダンパの故障検知シミュレーションに対し、推定モデルの更新を行う新たな手法を提案、マルチボディシミュレーションにより検証し、その有用性を示す。

### 2. 車両モデル

提案する故障検出方法の妥当性を示すために、ここでは、SIMPACKによるマルチボディシミュレーションにより得られたデータを用いる。

図1に構築したモデルを示す。このモデルは各輪軸が4自由度(左右動, ヨー), 台車6自由度(左右動, ヨー), 車体6自由度(左右動)を考慮した34自由度モデルである。本研究では、構築したモデルにおいて、車体台車間ダンパが故障する事を想定してシミュレーションを行う。

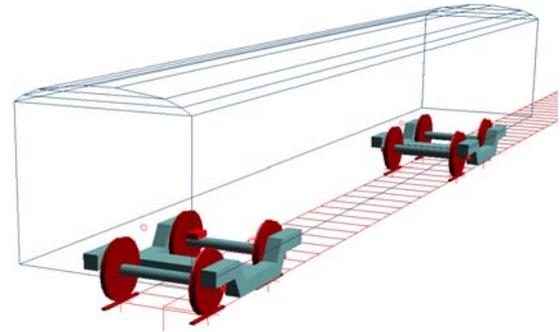


Fig.1 SIMPACK vehicle model (34DOF)

### 3. 多重モデル法

多重モデル法は目標追従の分野で提案された適応推定の手法である<sup>5)</sup>。この手法は、パラメータとモデル構造の両方が変化している間のさまざまな適応推定が可能である。

多重モデル法においてシステムは可能なモードを含む有限個のモデルの内の1つに従うと仮定する。モード生起確率(モード  $j$  の修正した事後確率)はベイズの公式を用いて次式で計算される。

$$p(m_j | Y^t) = \frac{p(y_t | m_j, Y^{t-1}) p(m_j | Y^{t-1})}{\sum p(y_t | m_j, Y^{t-1}) p(m_j | Y^{t-1})} \quad (1)$$

ここで、 $p(y_t | m_j, Y^{t-1})$  は時刻  $t$  におけるモデル  $j$  の尤度関数である。

尤度関数は、ガウス分布と仮定し、モードに適合したフィルタ  $j$  との残差と共分散によって求められる。全体的な推定値は各モードの状態推定値と各モード生起確率から次式によって算出される。

$$p(x_t | Y^t) = \sum_{j=1}^m p(x_t | m_j, Y^t) p(m_j | Y^t) \quad (2)$$

システムのモード(モデル)が時間で変化する場合、多重モデル法を動的に定式化する必要があり、その際モード遷移過程(モード遷移確率)を考慮して定式化を行う。

時間  $t$  までの可能なモデル履歴はモード履歴によって表される。  $M^t = \{M_1, M_2, \dots, M_m\}$

Condition Monitoring of Railway Vehicles Using Multiple Model Approach

Hiroataka MORI, Hitoshi TSUNASHIMA,

モード履歴に基づくモード生起確率は

$$p(M^t|Y^t) = \frac{p(y_t|M^t, Y^{t-1})p(x_t|M^{t-1}, Y^{t-1})}{\sum p(y_t|M^t, Y^{t-1})p(M^t, Y^{t-1})} p(M^{t-1}|Y^{t-1}) \quad (3)$$

全体的な推定は各モードの状態推定値と各モード生起確率から次式によって算出される。

$$p(x_t|Y^t) = \sum_{j=1}^m p(x_t|M^t, Y^t)p(M^t|Y^t) \quad (4)$$

時間に伴って、モード履歴  $M_t$  は指数関数的に増加する問題があるため、この問題を避けるために generalized pseudo-Bayesian of first order (GPB1) や second order (GPB2) や Interacting Multiple Model (IMM) アルゴリズム<sup>9)</sup>が提案されている。

#### 4. IMM法を用いたサスペンションの故障検出

図2に多重モデル法を用いた車両の故障検出の概要を示す。例として示したように複数の故障を想定したモードを設定し各モードの生起確率より故障の検出が可能であると考えられる。

図3にIMM推定器を示す。推定は以下に表されるカルマンフィルタ(KF)を用いて結合される。システムモードとして  $m$  個のモデルを考える。モード遷移行列  $p_{ij}$  の  $(i,j)$  要素はモード  $i$  からモード  $j$  へ遷移する確率を表す。次節以降、本研究で構成したIMM推定器の詳細を示す。

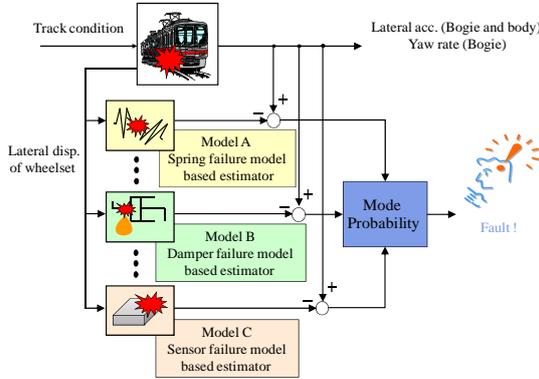


Fig.2 Multiple-model approach for vehicle suspension fault detection

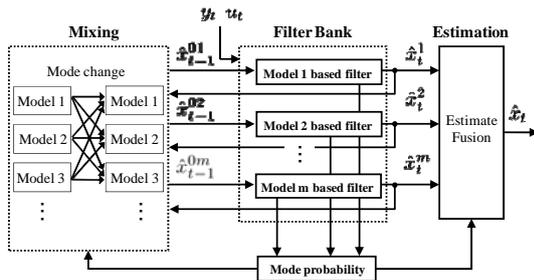


Fig.3 IMM estimator

#### 4.1. ミキシング

時刻  $t$  のときのモード  $i$  ( $i = 1, \dots, m$ ) におけるKFによる推定値を  $\hat{x}_{(t)}$ 、推定共分散行列を  $P_{(t)}^i$  とする。このとき、混合推定値  $\hat{x}_{(t)}^{0j}$ 、混合推定共分散行列  $P_{(t)}^{0j}$  は次式となる。

$$\hat{x}_{(t-1)}^{0j} = \sum_{i=1}^m \hat{x}_{(t-1)}^i \rho_{ij(t-1)} \quad j=1, \dots, m \quad (5)$$

$$P_{(t-1)}^{0j} = \sum_{i=1}^m \rho_{ij(t-1)} \left\{ P_{(t-1)}^i + [\hat{x}_{(t-1)}^i - \hat{x}_{(t-1)}^{0j}] \cdot [\hat{x}_{(t-1)}^i - \hat{x}_{(t-1)}^{0j}]^T \right\} \quad (6)$$

ここで、 $\rho_{ij(t)}$  は時刻  $t$  の混合確率であり、次式で表される。

$$\rho_{ij(t-1)} = \frac{1}{\bar{c}_j} p_{ij} \rho_{i(t-1)} \quad i, j=1, \dots, m \quad (7)$$

$$\bar{c}_j = \sum_{i=1}^m p_{ij} \rho_{i(t-1)} \quad j=1, \dots, m \quad (8)$$

#### 4.2. カルマンフィルタ(KF)設計

本研究では図1において輪軸の運動を除き低次元化したモデルを推定用モデルとし、モード毎にKFを設計した。離散時間システムは次式のように表される。

$$x_{(t+1)} = Fx_{(t)} + Gu_{(t)} + w_{(t)} \quad (9)$$

$$y_{(t)} = Hx_{(t)} + Lu_{(t)} + v_{(t)} \quad (10)$$

ここで

$$x_{(t)} = [\dot{y}_b \quad y_b \quad \dot{\psi}_b \quad \psi_b \quad \dot{y}_{bd} \quad y_{bd}]^T$$

$$u_{(t)} = [u'_1 \quad u'_2]^T$$

$$w_{(t)} = [w_1 \quad w_2 \quad w_3 \quad w_4 \quad w_5 \quad w_6]^T$$

$$y_{(t)} = [\dot{y}_b \quad \dot{\psi}_b \quad \dot{y}_{bd}]^T$$

$$v_{(t)} = [v_1 \quad v_2 \quad v_3]^T$$

とする。このとき次のKFのアルゴリズムを得る。

(フィルタ方程式)

$$\hat{x}_{(t/t-1)}^j = F^j(\hat{x}_{(t-1/t-1)}^{0j}) + D^j u_{(t-1)} \quad (11)$$

$$\hat{x}_{(t/t)}^j = \hat{x}_{(t/t-1)}^j + K_{(t)}^j [y_{(t)} - (H^j(\hat{x}_{(t/t-1)}^j) + L^j u_{(t)})] \quad (12)$$

(カルマンゲイン)

$$K_{(t)}^j = P_{(t/t-1)}^j H_{(t-1)}^j{}^T S_{(t)}^j{}^{-1} \quad (13)$$

$$S_{(t)}^j = H_{(t-1)}^j P_{(t/t-1)}^j H_{(t-1)}^j{}^T + R_{(t-1)}^j \quad (14)$$

(共分散方程式)

$$P_{(t/t-1)}^j = F_{(t-1)}^j P_{(t-1/t-1)}^{0j} F_{(t-1)}^j{}^T + G_{(t-1)}^j Q_{(t-1)}^j G_{(t-1)}^j{}^T \quad (15)$$

$$P_{(t|t)}^j = P_{(t|t-1)}^j - K_{(t)}^j S_{(t)}^j K_{(t)}^{jT} \quad (16)$$

ここで  $\hat{x}_{(t)}^j$  は KF により計算された状態推定量を表す。また、システムノイズ  $w_{(t)}$ 、観測ノイズ  $v_{(t)}$  は平均値 0、共分散がそれぞれ  $Q$  と  $R$  のガウス白色雑音とする。

#### 4.3. モード生起確率の計算

各モードの尤度関数は次式で表される。

$$\Lambda_{j(t)} = |2\pi S_{(t)}^j|^{-\frac{1}{2}} \exp \left[ -\frac{1}{2} \left( y_{(t)} - (H^j(\hat{x}_{(t-1)}^j) + L^j u_{(t)}) \right)^T \cdot (S_{(t)}^j)^{-1} \left( y_{(t)} - (H^j(\hat{x}_{(t-1)}^j) + L^j u_{(t)}) \right) \right] \quad (17)$$

したがって、時刻  $t$  におけるモード  $j$  の生起確率は

$$\rho_{j(t)} = \frac{\Lambda_{j(t)} \bar{c}_j}{\sum_{i=1}^m \Lambda_{i(t)} \bar{c}_i} \quad (18)$$

となる。ここで求めた生起確率は時間によって変化するため移動平均を用いて平滑化を行う。

#### 4.4. 推定

各モードの状態推定値  $\hat{x}_{(t)}^j$  および混合共分散行列  $P_{(t)}^j$  に生起確率で重みを付け、最終的な状態推定量  $\hat{x}_{(t)}$ 、混合共分散  $P_{(t)}$  が次式により得られる。

$$\hat{x}_{(t)} = \sum_{j=1}^m \hat{x}_{(t)}^j \rho_{j(t)} \quad (19)$$

$$P_{(t)} = \sum_{j=1}^m \rho_{j(t)} \left[ P_{(t)}^j + [\hat{x}_{(t)}^j - \hat{x}_{(t)}] \cdot [\hat{x}_{(t)}^j - \hat{x}_{(t)}]^T \right] \quad (20)$$

#### 5. モデル更新

すでに IMM 法を用いて車体台車間ダンパの故障検知が可能であることが示されている<sup>7)</sup>。しかし、モデル化された車体台車間ばねのばね定数にモデル誤差が生じている場合、設定されたダンパ故障モデルでは、実際の故障を表現できない。そこで、IMM 法によって推定されるばね定数を用いて、ダンパ故障モデルを逐次更新する手法を提案する。図 4 に提案したモデル更新のアルゴリズムを示す。車体台車間ばねのばね定数の推定値は次式で表される。

$$\hat{k}_{ylb(t)} = \sum_{j=1}^m k_{ylb}^j \rho_{jt} \quad (21)$$

ここで得られたばね定数の推定値は、ダンパ故障用の推定モデルをモデル更新するために用いられる。また、ダンパ故障検知のため推定される、車体台車間ダンパの粘性係数については次式で表される。

$$\hat{C}_{ylb(t)} = \sum_{j=m+1}^{n+m} C_{ylb}^j \rho_{jt} \quad (22)$$

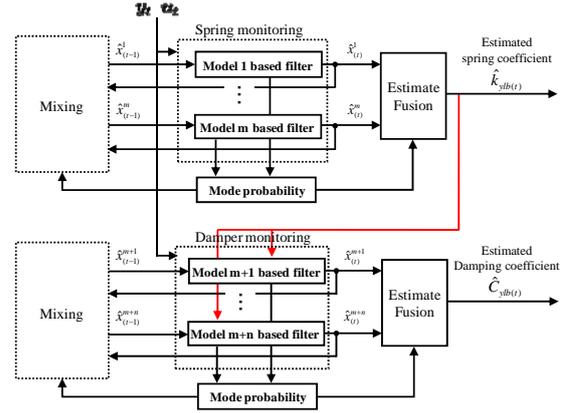


Fig.4 IMM estimator with model update

#### 6. シミュレーション

##### 6.1. シミュレーション条件

直線軌道を走行中の車両において、車体台車間左右動ダンパに故障が発生するシミュレーションを行った。走行開始 3s 後車体台車間左右動ダンパ故障(粘性係数が標準値から 50%減少)が発生するシミュレーションを行う。IMM 推定器は以下に示すモデルをもとに設計した。

モード S1-S5：車体台車間ばね用推定モデル

(ばね定数を 100%~20%の間で 20%ずつ変化)

モード D1-D5：車体台車間左右動ダンパ用推定モデル

(粘性係数を 100%~20%の間で 20%ずつ変化)

表 1 に設計したモードをまとめる。車体台車間左右動ダンパ用推定モデル(モード D1-D5)には、車体台車間ばね用推定モデル(モード S1-S5)より推定したばね定数を入力し、逐次モードを変化させている。

初期状態では車体は正常とし、初期生起確率は  $\rho_{j0}=1.0$  ( $j = S1, D1$ )、それ以外の各モードは 0 に設定した。

Table 1 Mode and parameters

Mode	Parameters		Mode	Parameters	
	$K_{ylb}$	$C_{ylb}$		$K_{ylb}$	$C_{ylb}$
S1	100%	100%	D1	100%	100%
S2	80%	100%	D2	100%	80%
S3	60%	100%	D3	or	60%
S4	40%	100%	D4	Adapting	40%
S5	20%	100%	D5	determined	20%

##### 6.2. シミュレーション結果

図 5 に故障検知に用いた観測データ(台車横加速度、車体横加速度・ヨーレート)を示す。これらの観測データからは故障発生後でも正常時に比べて観測値に大きな変化が見られず、観測データから車体台車間左右動ダンパに故障が発生していることを直接判断することは難しい。

図6にモデル更新を行わない場合、図7にモデル更新を行った場合の生起確率の算出結果を示す。モデル更新を行わない場合、粘性係数が正常なモデル(モード D1)の生起確率が走行開始後3sで低下するが、4s以降において再び高い値を示していることから、継続的に故障を検知することはできていないことがわかる。それに対して、モデル更新を行った場合、粘性係数が正常なモデル(モード D1)の生起確率が走行開始後3sで低下、その後、ダンパ故障モデル(モード D2-D5)の生起確率が高い値をとっていることから、故障を検知していることが分かる。

図8に粘性係数の推定値について示す。モデル更新を行わない場合は、正しい値を推定できていないのに対して、モデル更新を行った場合は、精度良い推定結果が得られていることがわかる。

## 7. 結 言

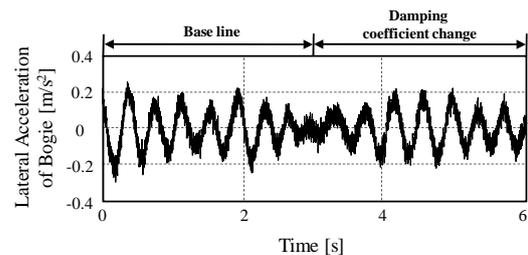
本研究では、IMM法の推定精度向上のためにモデル更新の手法を提案し、車体台車横加速度と台車のヨーレートの観測データから、IMM法を用いて車体台車間ダンパの故障検知シミュレーションを行った。

提案した手法の有効性を検討するために、マルチボダイソフトを用いて車体台車間ダンパ故障時の振動データを生成し、これを元にIMM法による故障検知シミュレーションを行った。シミュレーションの結果、提案の方法により、検出精度が大幅に向上する事が明らかになった。

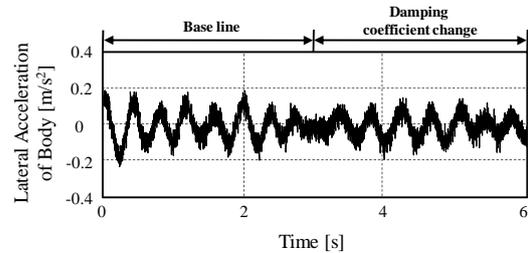
本研究は科研費「基盤研究(C)(21560249)：多重モデル法を用いた鉄道の状態診断に関する研究」(2009)の助成を受けたものである。

### 「参考文献」

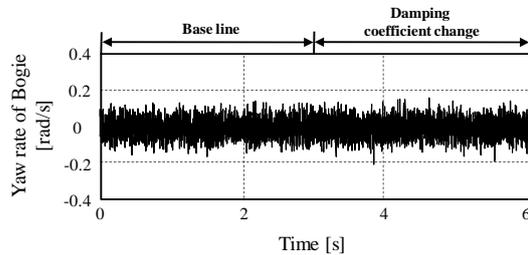
- 1) 網島均, プローブ車両技術の導入による軌道交通システムの再生に関する基礎的研究, 第13回交通・物流部門大会講演論文集, No.04-53, (2004), pp. 241-242
- 2) R. J. Patton, P. M. Frank and R.N. Clark, Issues of Fault Diagnosis for Dynamic System, Springer, (2000)
- 3) S. Buruni, R. M. Goodall, T. X. Mei and H. Tsunashima, Control and monitoring for railway vehicle dynamics, Vehicle System Dynamics, vol. 45, No. 7-8, (2007), pp.765-771
- 4) Y. Bar-Shalom, X. R Li and T. Kirubarajan, Estimation with Applications to Tracking and Navigation, Wiley Interscience, (2001)
- 5) P. Li, R. Goodall and V. Kadiramanathan, Estimation of parameters in linear state space model using Rao-Blackwellised particle filter, IEE Proc, Control Theory and Applications, Vol. 151, No. 6, pp. 727-738.
- 6) H. A. P. Blom and Y. Bar-Shalom, The Interacting Multiple Model Algorithm for System with Markovian Switching Coefficient, IEEE Trans Automatic Control, Vol. AC-33, No. 8, (1988), pp. 780-783
- 7) 林祐介, 網島均, 丸茂喜高, 多重モデルを用いた鉄道車両の故障検知に関する研究, 第16回交通・物流部門大会講演論文集, (2007), pp. 331-334



(a)Lateral acceleration of bogie



(b)Lateral acceleration of body



(c)Yaw rate of bogie

Fig.5 Measurement data

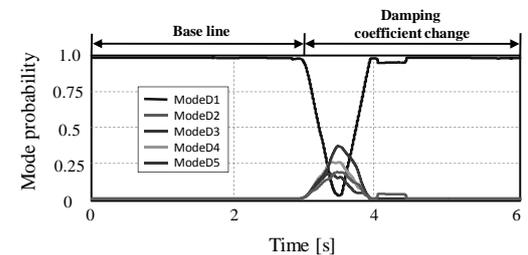


Fig.6 Probabilities of damper failure mode without model update

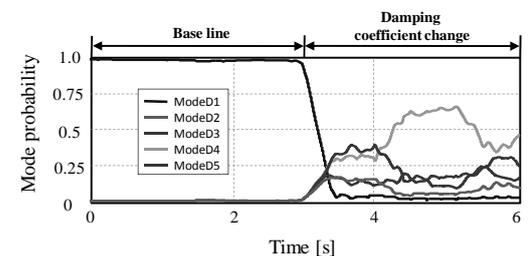


Fig.7 Probabilities of damper failure mode with model update

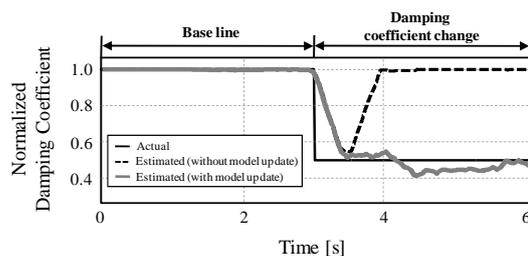


Fig.8 Estimation of damping coefficient