多重モデルを用いた鉄道車両の状態推定に関する研究

○［機］森　裕貴（日大院）

［機］綱島　均（日大），　［機］丸茂　喜高（日大）

State Estimation of Railway Vehicles Suspension Systems Using Multiple Model Approach

○Hirotaka Mori, (Graduate School of Nihon University),

Hitoshi Tsunashima, (Nihon University),　　Yoshitaka Marumo, (Nihon University),

This paper demonstrates the possibility to detect suspension failures of railway vehicles using a multiple-model approach from on-board measurement data. The railway vehicle model used includes the lateral and yaw motions of the wheelsets and bogie, and the lateral motion of the vehicle body, with sensors measuring the lateral acceleration and yaw rate of the bogie, and lateral acceleration of the body. The detection algorithm is formulated based on the Interacting Multiple-Model (IMM) algorithm. The IMM method has been applied for detecting faults in vehicle suspension systems in a simulation study. The mode probabilities and states of vehicle suspension systems are estimated based on a Kalman Filter (KF). This algorithm is evaluated in simulation examples. Simulation results indicate that the algorithm effectively detects on-board faults of railway vehicle suspension systems.

キーワード：状態監視，状態推定，故障検知，鉄道，カルマンフィルタ，多重モデル法

Key Words: Condition monitoring, State estimation, Fault detection, Railway, Kalman Filter, Multiple-Model

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(1)．

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されている(2)．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(3)．

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(4)を用い，車体台車間サスペンションの故障検知シミュレーションを行いその有用性を示す．

2．車両モデル

本研究では，本来，実測値を用いる部分には車両モデルのシミュレーションにより得られたデータを用いる．

車両モデルには図 1 に示すモデルを用いる(5)．このモデルは各輪軸が 2 自由度(左右動，ヨー)，台車 2 自由度(左右動，ヨー)，車体 1 自由度(左右動)を考慮した 7 自由度モデルである(6)．本研究では図 1 に示す車両モデルにおいてサスペンション(K_{ylb} , C_{ylb})が故障する事を想定してシミュレーションを行う．

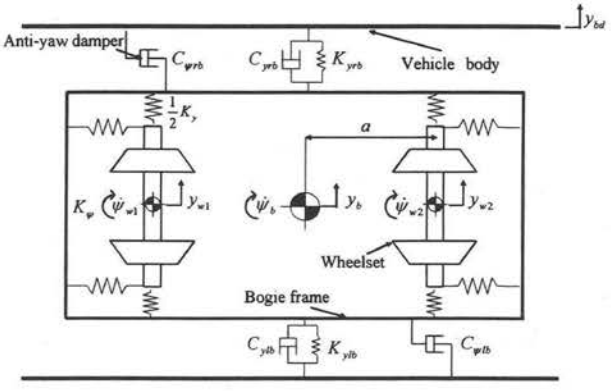

Fig.1 Vehicle model

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．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．$M^t=\{M_1,M_2,\cdots,M_{m^t}\}$

モード履歴に基づくモード生起確率は

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

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．

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

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[7]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知

図 2 に多重モデル法を用いた車両の故障検知の概要を示す．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知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．

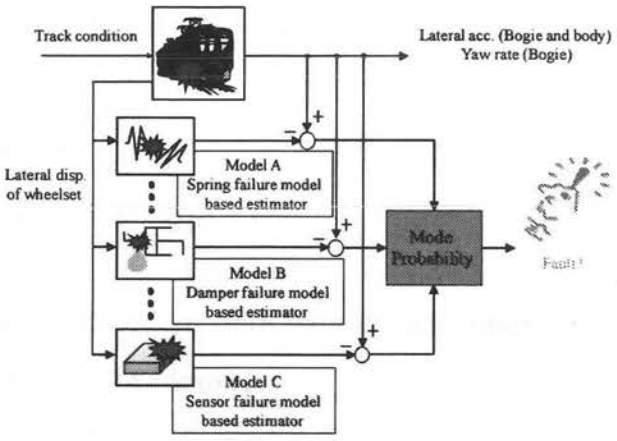

Fig.2 Multiple-model approach for vehicle suspension fault detection

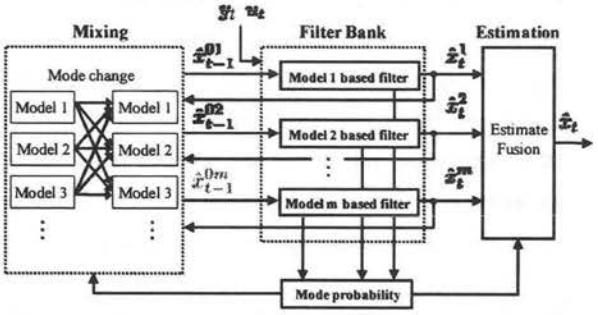

Fig.3 IMM estimator

4.1 ミキシング

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

$$\hat{x}^{0j}_{(t-1)}=\sum_{i=1}^{m}\hat{x}^i_{(t-1)}\rho_{i|j\,(t-1)} \qquad j=1,\ldots,m \quad (5)$$

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

ここで，$\rho_{i|j\,(t)}$ は時刻 t の混合確率であり，次式で表される．

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

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

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

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

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

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

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

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

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)

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

$$\hat{x}^j_{(t/t)} = \hat{x}^j_{(t/t-1)} + K^j_{(t)}\left[y_{(t)} - \left(H^j(\hat{x}^j_{(t/t-1)}) + L^j u_{(t)}\right)\right] \tag{12}$$

(カルマンゲイン)

$$K^j_{(t)} = P^j_{(t/t-1)} H^j_{(t-1)}{}^T S^j_{(t)}{}^{-1} \tag{13}$$

$$S^j_{(t)} = H^j_{(t-1)} P^j_{(t/t-1)} H^j_{(t-1)}{}^T + R^j_{(t-1)} \tag{14}$$

(共分散方程式)

$$P^j_{(t/t-1)} = F^j_{(t-1)} P^{0j}_{(t/t-1)} F^j_{(t-1)}{}^T + G^j_{(t-1)} Q^j_{(t-1)} G^j_{(t-1)}{}^T \tag{15}$$

$$P^j_{(t/t)} = P^j_{(t/t-1)} - K^j_{(t)} S^j_{(t)} K^j_{(t)}{}^T \tag{16}$$

ここで $\hat{x}^j_{(t)}$ 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．

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

したがって，時刻 t におけるモード j の生起確率は

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

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 $\hat{x}^j_{(t)}$ および混合共分散行列 $P^j_{(t)}$ 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．

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

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

5．シミュレーション

5.1 シミュレーション条件

本研究では直線軌道を走行中の車両において，車体台車間サスペンション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後に車体台車間ばね故障(ばね定数が標準値から50%増加)が発生，さらに走行開始6s後ばね故障に加えて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)が複合的に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1：正常な車両を想定したモデル
モード2~8：車体台車間ばね故障モデル
(ばね定数が110%~170%の間で10%ずつ変化)
モード9~16：車体台車間左右動ダンパ故障モデル
(粘性係数が100%~30%の間で10%ずつ変化)

複合故障時の車体台車間左右動ダンパ故障モデル(モード9~16)には，車体台車間ばね故障モデル(モード2~8)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 $\rho_{j(0)}$=1.0 (j=1)，それ以外の各モードは0に設定した．

5.2 シミュレーション結果

図4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，観測データからは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5に生起確率の算出結果を示す．ばね故障モデル(モード6)が走行開始後3s以降において高い生起確率を示していることから，ばねの故障を検知できていることがわかる．そして0s~6sの間で，他のモードの生起確率が低い値をとっている事から，故障の分離ができていると考えられる．また，ばね定数の推定値を図6に示す．走行開始6s後に左右動ダンパ故障に影響されてはいるが，ばね定数を良好に推定できている．

左右動ダンパ故障に関しては，通常ばね故障に影響され，推定することが困難である．そこで，良好に推定ができているばね定数を，設計した左右動ダンパ故障モデル(モード9~16)にフィードバックさせることで，左右動ダンパの故障モデルを逐次更新し，粘性係数の推定精度を向上させることができる．

走行開始6sを過ぎると図5において，モード14(車体台車間左右動ダンパ故障モデル)の生起確率が高い値を示していることから，左右動ダンパ故障についても検知が可能であることがわかる．

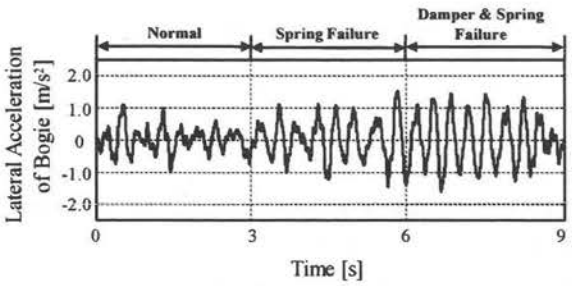

(a)Lateral acceleration of bogie

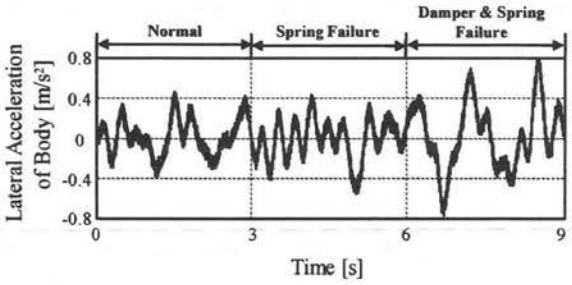

(b)Lateral acceleration of body

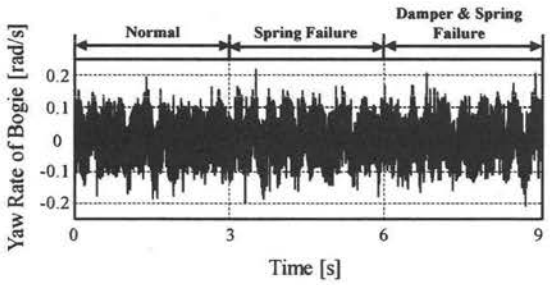

(c)Yaw rate of bogie

Fig.4 Measurement data

図 7 に示す粘性係数の推定値については，4s 付近においてばね故障に影響されている部分はあるが，全体的に精度良く推定ができていることがわかる．

6．結　言

本研究では，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，車体台車間サスペンションの故障検知シミュレーションを行い，その有効性を示した．

ばねと左右動ダンパがそれぞれ単独に故障した場合，複合的に故障した場合の両方について，故障部位の特定と故障の程度を推定することが可能であることがわかった．

今後はマルチボディソフトを用いたフルビークルシミュレーションを行い，推定方法の有効性を検討する予定である．

参 考 文 献

1) 綱島均，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，pp. 241-242，2004

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, pp.765-771 ,2007

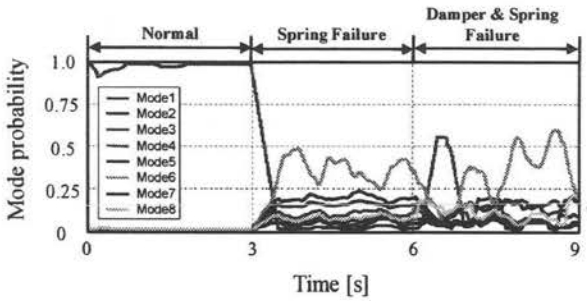

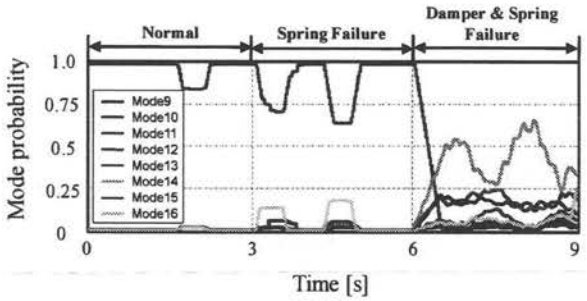

Fig.5 Mode probabilities

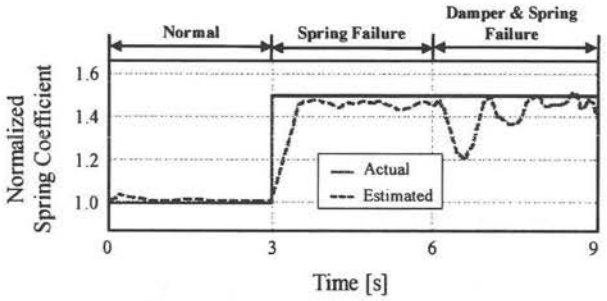

Fig.6 Estimation of spring coefficient

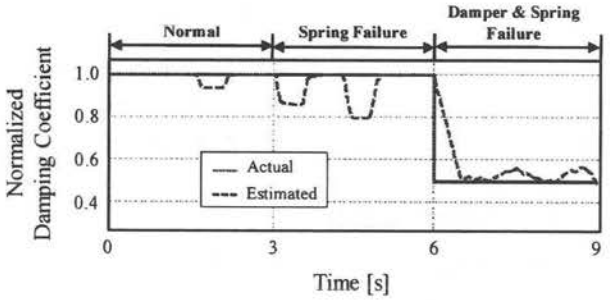

Fig.7 Estimation of damping coefficient

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. Kadirkamanathan, "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) 林祐介，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，pp. 331-334，2007

7) 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, pp. 780-783 ,1988

8) L. Ljung, Asymptotic behavior of the extended Kalman filter as a parameter estimator for linear system, IEEE Trans. Automatic Control, Vol. AC-24, No. 1, pp. 36-50 ,1979