

鉄道車両の状態監視と故障検知に関する研究

日大生産工(院) ○林 祐介 日大生産工 綱島 均 日大生産工 丸茂 喜高

1 はじめに

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作業であり、車両の検査は、故障を検知するために特に重要である。検査時に故障を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。

車両故障をすばやく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、常時監視するには車両に付けたセンサの信号から故障を検出する必要がある。

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¹⁾。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・特定を行い、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²⁾。

Liらは車体台車間横ダンパ、ヨーダンパ、車輪形状の劣化の推定を、残差を基にした方法とパラメータの直接推定によって行う方法を提案し、実車両による実験でその有効性を示した³⁾。

本研究は、推定のロバスト性を確保するために、多重モデル法の1つであるIMM (Interacting Multiple Model) 法⁴⁾を用いた台車の故障検知方法を提案し、シミュレーションにより有効性の検討を行う。

また比較のため、拡張カルマンフィルタ(EKF)を用いて台車パラメータの直接推定を行い、IMM法の有効性について述べる。

2 車両モデル

本研究では、故障を含んだ車両の運動データを生成するため、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

ペンションの故障(車体台車間ダンパ C_{yib} 故障)を想定したシミュレーションを行う。




Fig. 1 Vehicle model

3 多重モデル法

多重モデル法はターゲットトラッキングの分野で提案された適応推定の手法である。この手法は、パラメータ変化とモデル構造の変化を考慮して、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 $M \in \{m_j\}_{j=1 \dots m}$ の内の1つに従うと仮定する。

ベイズの公式を用いるとモード生起確率(モード j が真である事後確率)は、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、ガウス分布を仮定した場合、モードに適合したフィルタ j の観測残差と共分散によって求められる。

最終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。

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

多重モデル法の基本的な概念を図2に示す。

Condition Monitoring and Fault Detection of Railway Vehicle

Yusuke HAYASHI, Hitoshi TSUNASHIMA and Yoshitaka MARUMO

システムのモード（モデル）が時間的に変化する場合、多重モデル法を動的に定式化する必要がある。

時間 t までの起こりえるモデルの履歴は、モード履歴として $M^t = \{M_1, M_2, \dots, M_{m'}\}$ のように表現される。

モード履歴に基づくモード生起確率は次式となる。

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

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。

$$p(x_t | Y^t) = \sum_{j=1}^{m'} p(x_t | M^t, Y^t) p(M^t | Y^t) \quad (4)$$

時間発展に伴って、モード履歴 M_t は指数関数的に増加し、計算上の重大な障害となる。この問題を避けるために generalized pseudo-Bayesian of first order (GPB1), generalized pseudo-Bayesian of second order (GPB2) や Interacting Multiple Model (IMM) などのアルゴリズム⁴⁾ が提案されている。




Fig. 2 Concept of multiple-model approach

4 IMM法を用いたサスペンションの故障検知

図3に多重モデル法を用いた車両の故障検知の概要を示す。また、図4にIMM推定器を示す。各モードにおける推定にはカルマンフィルタ（KF）を用いた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、構成した IMM 推定器の詳細を示す。




Fig. 3 Multiple-model approach for vehicle suspension fault detection




Fig. 4 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 $\hat{x}_t^i$, 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。

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

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

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

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

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

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用いて 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

$$x_t = [\dot{y}_b \ y_b \ \ddot{y}_b \ y_{bd} \ \dot{y}_{bd} \ y_{bd}]^T$$

$$u_t = [u'_1 \ u'_2]^T$$

$$w_t = [w_1 \ w_2 \ w_3 \ w_4 \ w_5 \ w_6]^T$$

$$y_t = [\ddot{y}_b \ \dot{y}_b \ \ddot{y}_{bd}]^T$$

$$v_t = [v_1 \ v_2 \ v_3]^T$$

である。

このとき次の KF のアルゴリズムを得る。

(フィルタ方程式)

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

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

(カルマンゲイン)

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

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

(共分散方程式)

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

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

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 $Q(w_{(t)})$ と $R(v_{(t)})$ 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。

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

したがって、時刻 t におけるモード j の生起確率は

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

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。

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

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

5 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、通り狂いのある直線軌道を 20m/s (72km/h) で走行中の車両に対して、シミュレーション開始 2s 後に車体台車間のダンパ故障 (粘性係数が標準値から減少) が発生するとして、故障検出シミュレーションを行い、前章で得られたアルゴリズムの妥当性を検証した。車体台車間ダンパの粘性係数の変化を図 5 に示す。




Fig. 5 Normalized damping coefficient

故障検出にあたっては、以下に示す 8 つのモードを設定した。

モード 1 : 正常

モード 2 : 車体台車間ばね故障

(ばね定数が 0 N/m に減少)

モード 3 : 車体台車間ダンパ故障 (20%減少)

モード 4 : 車体台車間ダンパ故障 (40%減少)

モード 5 : 車体台車間ダンパ故障 (60%減少)

モード 6 : 台車横加速度センサ故障

モード 7 : 台車ヨーレートセンサ故障

モード 8 : 車体横加速度センサ故障

なお、モード 6, 7, 8 においては、センサ故障時に観測ノイズの共分散が増大するとした。

初期状態ではダンパは正常と仮定し、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。

各モードの粘性係数 C_{yib}^j に生起確率で重みを付け時刻 t における粘性係数の推定値 $\hat{C}_{yib(t)}$ を次式により得た。

$$\hat{C}_{yib(t)} = \sum_{j=1}^m C_{yib}^j r_{j(t)} \quad (21)$$

またシミュレーションに使用した車両パラメータは、文献 6) の値を用いた。

5.2 シミュレーション結果

図 6 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), を示し, 図 7 にモード生起確率の算出結果を示す。ただし, モード生起確率の結果において生起確率がほぼ 0 だったモードの結果は載せていない。

これらの観測データ (車体, 台車横加速度やヨーレート) からはダンパ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, 観測データからはダンパ故障が発生していることを直接判断することは難しい。しかし, モード 1 (正常な車両モード) の生起確率が低くなり, さらにモード 4 とモード 5 (ダンパ故障モード) の生起確率がシミュレーション開始後 3s 以降において高いことから, 車体台車間のダンパが故障したことがわかる。

さらに, モード 2 (ばね故障モード) の生起確率が低いことから, ダンパ故障とばね故障の分離も可能であることがわかる。したがって, 各モードの生起確率を観測することにより, 発生した故障の内容と発生時刻を判断することが可能であると考えられる。

図 7 にダンパの粘性係数の推定結果を示す。粘性係数の推定値は各モードの粘性係数にモード生起確率で重みを付けて算出している。図 8 より, IMM 法によって故障発生後のダンパの粘性係数が精度良く推定できていることがわかる。




Fig. 6 Measurement data




Fig. 7 Mode probabilities




Fig. 8 Estimation of damping coefficient

また、比較のために、拡張カルマンフィルタ (EKF) を用いてダンパの粘性係数のパラメータ推定を行った。推定結果を、図 8 にあわせて記載した。

EKF は非線形システムの状態推定に最も用いられている手法であり、システムの未知パラメータを推定することができるが、推定するパラメータの初期値の設定によっては推定するパラメータの収束性が必ずしも保証されないなどの問題もある⁸⁾。本検討で用いた事例では、EKF によるパラメータ推定では、良好な推定が行えていないことがわかる。

6 まとめ

鉄道車両の台車の故障検出を行う方法として、IMM 法による方法を提案した。走行シミュレーションにより、モード生起確率を観測することにより、台車の状態を監視し、故障の検出が可能であることを示した。また、拡張カルマンフィルタによるパラメータ推定法と比較して、ロバストな推定方法であることを示した。

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、さらに現実的な環境を想定した検討を行う予定である。

なお、本研究は独立行政法人鉄道建設・運輸施設整備支援機構「運輸分野における基礎的研究推進制度」の補助を受けた。

参考文献

- 1) 例えば R. J. Patton, P. M. Frank and R.N. Clark, Issues of Fault Diagnosis for Dynamic System, Springer, (2000).
- 2) 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.
- 3) P. Li, R. M. Goodall, P. Weston, C. S. Ling, C. Goodman and C. Roberts, Estimation of railway vehicle suspension parameters for condition monitoring, Control Engineering Practice, Vol. 15, (2006), pp. 43-55.
- 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) Y. Hayashi, H. Tsunashima and Y. Marumo, SICE-ICCAS 2006, (2006).
- 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, (1988), pp. 780-783.
- 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, (1979), pp. 36-50.