

局所定常 AR モデルを用いた周期的な軌道狂いの検出

鉄道総研 正会員 ○元好 茂
 鉄道総研 正会員 古川 敦
 鉄道総研 神山 雅子

1. はじめに

同一波長の狂いが連続するような軌道狂い（以下、周期的な軌道狂い）が存在し、その波長と走行速度に対応する周波数が車両の固有振動数に一致すると、車両が共振を起こし、乗り心地や走行安全性が低下することがある。このような共振を軌道側から管理するには、軌道狂い波形の中から、①任意の波長の軌道狂いが、②任意の波数連続する区間、を正しく抽出し評価する必要がある。この目的のため、時系列解析で用いられている局所定常 AR モデルを応用し、軌道狂い波形から周期的な軌道狂いを検出するアルゴリズムの開発を行ったので、その概要を報告する。

2. 周期的な軌道狂い検出アルゴリズムの開発

(1) 局所定常 AR モデルの適用

周期的な軌道狂いが存在する箇所は、その区間の周波数特性が、その前後と比べ顕著に変化していると考えられる。従って、周期的な軌道狂いを検出するという問題を、周波数特性が変化する点を検出するという問題に置きかえることとする。ここでは、周波数特性が変化する点を検出する方法として、局所定常 AR モデル¹⁾を用いることとした。このモデルによる周波数特性変化点の検出は、例えば地震波の S 波到達時刻の推定に用いられている。

局所定常 AR モデルとは、軌道狂い波形のような非定常時系列を、適当な小区間に分割すれば一つ一つは定常とみなせる局所定常時系列であると仮定し、定常とした各小区間を式(a)の AR（自己回帰）モデルで表したものである（図 1）。この場合の小区間の分割点が、周波数特性が変化する点ということになる。

$$y_n = \sum_{i=1}^m a_i y_{n-i} + v_n \quad \dots (a) \quad \begin{array}{l} y_n : \text{時系列データ} \quad m : \text{自己回帰の次数} \quad a_i : \text{自己回帰係数} \\ v_n : \text{平均 0, 分散 } \sigma^2 \text{ の正規分布に従う白色雑音} \end{array}$$

局所定常 AR モデルを当てはめるということは、式(a)の AR モデルの a_i と m を推定しながら、ある区間にひとつの AR モデルを当てはめるか、もしくは分割して異なる AR モデルを当てはめるかを決定していく作業となる。ここで、分割するか否かの判断基準には AIC（赤池情報量基準）を用いた²⁾。AIC が小さくなるほど、より適したモデルとなる。例えば図 2 のように、キロ程 $n_s \sim n_e$ 間から変化点を検出する場合、まず $n_s \sim n_j$ 間 と $n_j \sim n_e$ 間を定常と仮定して AR モデルを当てはめたときの AIC をそれぞれ AIC_{sj} 、 AIC_{je} とする。そして、 j を $s \sim e$ と順に変化させた時に $AIC_{sj} + AIC_{je}$ が最小となる j を j' とすると、両区間にあてはめた AR モデルの適合度がこの時に最も高くなるため、 $n_{j'}$ が局所定常 AR モデルの分割点となる。なお、 $n_{j'} = n_s$ または n_e となる場合は、 $n_s \sim n_e$ 間は分割しない。以上の考え方をもとに、軌道狂い波形の周波数特性変化点を検出するアルゴリズムを作成した。

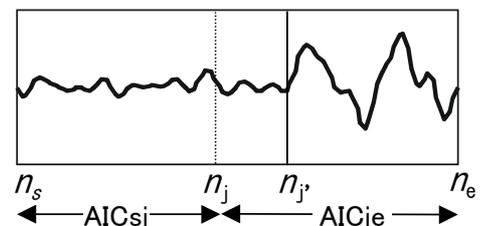


図 2 AIC を用いた分割点の探索

(2) AR モデル最大次数 M の決定

このアルゴリズムを作成する際、軌道狂い波形の特徴を考慮して、いくつかのパラメータを定める必要があった。ここでは、AIC の値にも関係する重要なパラメータである、式(a)における次数 m の最大値 M の決定にキーワード 周期的な軌道狂い、局所定常 AR モデル、AIC、複合狂い

連絡先 〒185-8540 東京都国分寺市光町 2-8-38 (財)鉄道総合技術研究所 軌道管理研究室 TEL042-573-7278

ついて述べる。M が大きくなると得られる次数mも高くなるので、従ってモデルが複雑になり、周波数特性の多少の変化では定常と判断して分割点を検出しなくなる。逆に M が小さくなるとmも低くなり、僅かな変化でも分割点として検出することになる。

M の決定に当たって、3線区計 15km の軌道狂いデータに対し、500m 毎の計 30 箇所正弦波状の周期成分を加算し、検出アルゴリズムによって加算周期成分の前後を特性変化点として検出するか否かを、M を 1～9 まで変化させながら確認した。尚、加算周期成分は 27 種類〔波長(10・30・50m)、波数(1・2・3波)、振幅(10・30・50 mm)の組み合わせ〕とし、それぞれに対して 30 箇所分の検出確認を行った。検出結果の一例（波長 50m・3波・振幅 30 mm）を図3に示す。これによれば、M=5 が周期成分の検出に最も適していることがわかる。全ての周期成分において同様の結果が得られたので、M=5 と決定した。

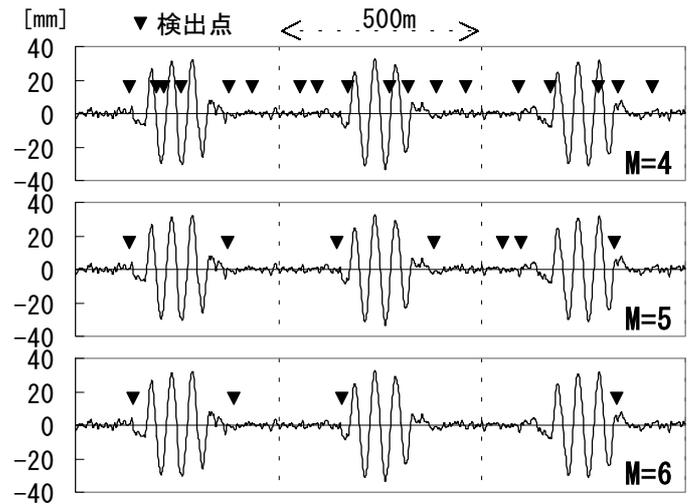


図3 最大次数 M 別の検出結果の一例 (M = 4 ~ 6)

また、M = 5 とした時に、アルゴリズムにより検出した区間のパワースペクトル密度の一例を図4に示す。これによっても、局所定常 AR モデルによって周波数特性が変化する点を的確に検出できていることがわかる。

(3) 精度確認結果

パラメータを決定した後、検出アルゴリズムの精度を最終的に確認するため、サンプル数を3線区計 80km に対する 160 箇所と増やし、(2)と同様に周期成分の検出を試みた。その結果、 A/σ (=周期成分振幅/周期成分を除いた軌道狂い標準偏差)の値が 4.6 以上であれば波長 10~50m で 2~3 波連続する周期成分を検出できた。図5に結果の一例を示す。周期成分以外の軌道狂いの起伏が激しければ検出できないケースがあるが、例えば振幅 20 mm の周期成分を検出しようとする場合、 $\sigma \leq 4.34 (=20/4.6)$ であれば確実に検出できるので、実在する軌道狂いの σ が 4 を超えるのは稀であることを考えれば、今回開発した手法は十分な周期性検出性能を持つといえる。

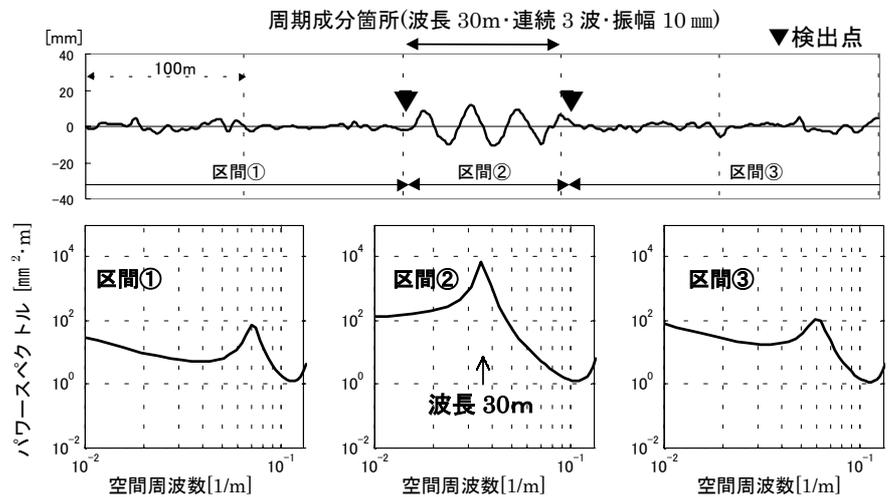


図4 周期成分検出例と分割区間のパワースペクトル密度

3. おわりに

周期的な軌道狂いの検出に、局所定常 AR モデルを用いる手法が有効であることがわかった。今後は、この手法をさらに発展させ、車両が共振する区間を自動検出できるシステムを構築する。これにより、現在行っている複合狂い管理を進化させ、より汎用性の高いかたちで周期性を考慮した軌道狂い管理ができると考える。

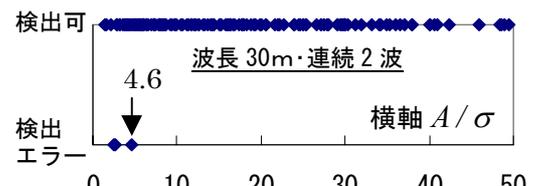


図5 A/σ と検出可否の関係 (σ の計算区間は 200m)

〔参考文献〕 1) 北川源四郎：FORTRAN77 時系列解析プログラミング、pp.185-191、岩波書店、1993.3
 2) 坂元、石黒、北川：情報量統計学、pp.138-141、共立出版、1983.1