

鉄道車両のダンパを高精度にモデル化する

小金井 玲子

車両構造技術研究部(車両振動研究室 副主任研究員)



こがねい れいこ

はじめに

鉄道車両には、乗り心地や安全性の向上に大きく寄与する鉄道車両用オイルダンパ(以下、ダンパ)が車体と台車の間など様々な箇所に取り付けられています(図1)。

このダンパの構造を図2に示します。基本的な原理は注射器や水鉄砲の構造と同じで、振動により生じる外力がピストンを伸縮させ、内部に封入されている油が圧縮されます。このとき圧縮された油が弁やオリフィスと呼ばれる細い流路を通過するときに内部の圧力が高まり、ピストンに抵抗力が発生します。この抵抗力を減衰力と呼び、速度に依存した減衰特性を示します。この減衰力により、振動を弱めたり、衝撃を吸収したりすることができます。また、ダンパ両端の取り付け部には、ピン付きゴムブッシュなどの弾性部材が用いられています。この部材を用いることによって、車両が走行する際にダンパの主軸方向以外の動きを許容できる構造となっていますが、この取り付け部の影響でダンパは主軸方向(ピストンの動作方向)以外にも力を発生することになります。ピン付きゴムブッシュの剛性が蛇行動に影響を及ぼすとも言われているため¹⁾、実際に車両に取り付けられた状態と同等のダンパとして特性を評価することが非常に重要ですが、これらを再現するような実走行時の取り付け状態で、かつ車両が走行している際のダンパの動きを模擬できる加振装置はこれまでありませんでした。

また、鉄道車両を開発する際には走行安全性や快適性を確認するため走行試験を実施しますが、営業線に支障をきたさないための配慮が必要で、試験回数や試験条件の制約を受けます。それに対し、車両運動シミュレーションでは、車両モデルを一度作成すれば様々な条件下で車両の運動特性を検討できますが、より実車に近い運動を模擬するには、モデルの精度を上げることが鍵となります。中でもダンパの動特性はシミュレーションにおいて重要な要素になりますが、減衰力に強い非線形特性(ピストン速度と減衰力との関係が直線で表せないこと)を持つため(図3)、従来の線形化や近似を行ったモデルでは、十分な精度で挙動を再現することはできませんでした。

そこで鉄道総研では、実走行時のダンパの動きを再現できるような「3次元で加振できる車両用ダンパ試験装置(以下、ダンパ試験装置)」(図4)を製作し、この装置を用いて実車走行状態でのダンパの発生力を求め、その実験データからダンパの高精度な応答予測モデルを得る同定手法(測定した信号間の関係を記述する手法)を開発しました。

本稿では、製作したダンパ試験装置とニューラルネットワーク(以下、NN)を活用した同定手法について概要を紹介し、また今回対象としたダンパのような非線形性が強い系に対して、一般的な線形同定手法に比べてNNを適用した場合にどの程度精度が向上するのかについても併せて紹介します。




図1 鉄道車両用ダンパ




図2 ダンパの構造(イメージ図)




図3 速度-減衰力の関係




図4 ダンパ試験装置

ダンパ試験装置

日本の鉄道車両には、左右動ダンパやヨーダンパ、車体間前後ダンパなどの様々な種類のダンパがあり、大きさやストローク、取り付け方向はそれぞれ異なります。

製作したダンパ試験装置は、鉄道車両で用いられている主要なダンパを網羅した仕様(表1)となっており、垂直・水平のどちらの取り付け方向にも対応しています。実走行を模擬する加振機構は、運転シミュレータなどで利用されている電動6軸モーションベースを用いており、実車両と同様に前後・左右・上下各軸の並進方向と回転方向の6自由度で動作することができます(図4)。

モデル化

モデル化とは対象とする系の現象に対する的確なモデルを作成することです。このモデルを構築する過程で、測定した信号間(入出力間)の関係を同定する必要があります。通常、出力は測定入力以外の信号の影響を受け、このような測定できない入力のことを外乱またはノイズと呼びます。入力 u ・出力 y ・外乱 e の関係は $y = u + e$ で表すことができ、測定では時間単位(T [s])毎に信号が記録されるので、モデル化では離散時間点(時刻 t)のみを用いて3つの信号 $u(t)$ 、 $y(t)$ 、 $e(t)$ がどのような関係にあるのかを記述することになります。

実際のモデル化の方法ですが、大きく分けて3つに分類できます。一つはその系の構造が完全に既知の場合

表1 要求性能と加振機仕様の比較

	減衰力 [kN]	最大速度 [m/s]	移動量 [mm]			作用方向
			前後	左右	上下	
左右動ダンパ	15	0.2	20	200	80	左右
軸ダンパ	8	0.3	20	10	100	上下
車体間前後ダンパ	22	0.2	200	200	80	前後
ヨーダンパ	15	0.2	100	200	80	前後
車端ダンパ	10	0.1	20	200	160	上下
振り子ダンパ	5	0.3	20	300	20	左右
加振機仕様	22	0.45	400	390	385	-

(表2 (a))で、この場合には物理法則に基づき数式によってモデルを記述することができます。系の構造の一部が既知であり、かつ入出力データが明らかになっている場合(表2 (b))には、構造を反映させた同定モデルを用いてパラメータフィッティング(実験データへの合わせこみ)を行い、モデルを推定することができます。

しかし、今回のように系の構造が全く不明で入出力データのみが与えられている場合(表2 (c))には、同定対象の系を何らかのモデルを仮定して、入出力関係を推定する必要があります。今回の場合は同定対象が非線形性を持つことから、強い非線形な特性にも対応できるNNを適用しています。このNNモデルによる推定結果の比較対象として代表的な線形モデルであるARXモデルによる結果を併記していますので、ここではARXモデルについて簡単に説明します。

ARXモデルは、ある時刻での出力をそれより過去の入力と出力に係数をかけて足し合わせたもの(重み付け和と呼びます)で表すという手法です。例えば2サンプル過去の入力と出力を考慮したとすると次式のような形で表現することができます。

$$y(t) = Ay(t-T) + By(t-2T) + Cu(t-T) + Du(t-2T)$$

ここで、例えば $y(t-2T)$ や $u(t-2T)$ は2サンプル過去の入力や出力を表し、 $ABCD$ は入出力関係から同定される係数です。このようにARXモデルでは時刻 t での出力は、ある時点までさかのぼった過去の入力と出力の線形

表2 モデル化のイメージ

	(a)	(b)	(c)
構造	既知	一部既知	不明
入出力データ	あり	あり	あり
モデル化の方法	数式で記述可能	未知の値をパラメータフィッティングで同定	ARXモデルやNNモデルを用いて同定

和(足し合わせ)によって計算することができます。したがって、このモデルは「足し合わせが効く」、言い換えれば線形な入出力関係を仮定しています。

ニューラルネットワーク(NN)とは

NNは人間の脳の神経回路の仕組みをプログラム上でモデル化した同定手法です。コンピュータに学習能力を持たせることで、天気予測や画像認識など様々な問題を解決できるため多くの分野で用いられています。

ところで人間の脳はどのような仕組みになっているのでしょうか(図5(a))。人間の脳には、約100億個のニューロンと呼ばれる神経細胞が存在し、各ニューロンが結合部であるシナプスを介してニューロンに繋がっています。そして人間の脳機能を左右するのはシナプスからなる脳の情報伝達網とされています。つまりシナプスの数が多ければ多いほど、より多くのニューロンが互いにつながっているほど脳の機能は良くなるということです。

では、この脳の仕組みをモデル化するとどうなるのでしょうか。NNでは、この繋がりをネットワークモデルで表現します(図5(b))。図に示すように、ユニット(ニューロン)は各ユニットとの接続に対する結合荷重とバイアスをもち、それらの重み付け和に対応した伝達関数 f の出力が次段に出力されます。実際に用いる際のNNモデルは、

このユニットが幾層にもつながっていて、最終的な出力結果が、あらかじめ与えられた出力データである「教師データ」に近づくように各ユニットの結合荷重とバイアスを調整する最適化が行われます。この教師データに対する出力の誤差を最小にする最適化の過程を「学習」と呼びます。学習が良好になされたNNモデルは、教師データと同じ入出力関係を持つことになり、同定がなされたこととなります。系の内部構造が分からなくても入出力関係を同定してくれる非常に便利なNNですが、一方で教師データや学習の設定を誤ると推定精度が悪化してしまうため、最初の条件設定が肝心となります。そこでNNを活用する際の幾つかのポイントを紹介します。

ポイント①「教師データは広く分布させる」

NNモデルは、同定対象の入出力データの組を教師データとしてその関係を学習します。そのため、学習を終えて得られたNNモデルに、新たに推定するデータ(検証データ)を与えた場合、そのデータが教師データに含まれていれば、たとえ教師データと無相関なデータでもNNモデルは良い推定結果を出力します。しかし、教師データに含まれないデータを与えた場合には、未学習パターンとなり推定結果の精度は著しく低下してしまいます。そのため、教師データを広く分布させています。(表3)

ポイント②「適度な学習打ち切り条件の設定」

あらかじめ設定した学習終了条件に達するまで、学習は継続して行われます。この条件設定を甘くし過ぎると、学習が十分に行われずに終了となり、高精度なNNモデルを得ることはできません。逆に設定が厳しすぎると教師データに含まれるノイズまでも学習する「過学習」に陥ることがあります(図6)。その結果、教師データに対しては良く適合しても、異なる時系列データに対しては誤った推定値を出力する可能性があります。そのため、適度な学習打ち切り条件の設定が重要となります。

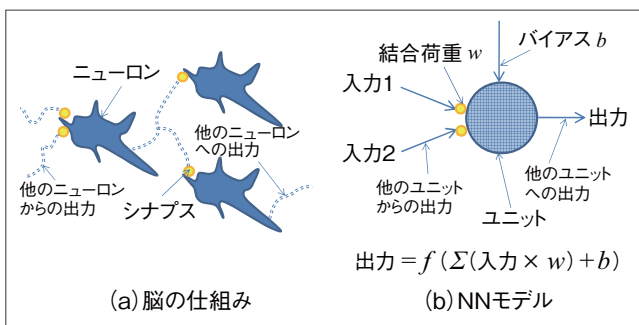


図5 人間の脳とニューロンモデル

表3 教師データの分布

新たに推定する入力データと教師データの包含関係	教師データ	推定入力データ
推定結果の精度	良好	低下




図6 学習回数と平均二乗誤差




図7 ダイナミクスモデル併用型NN

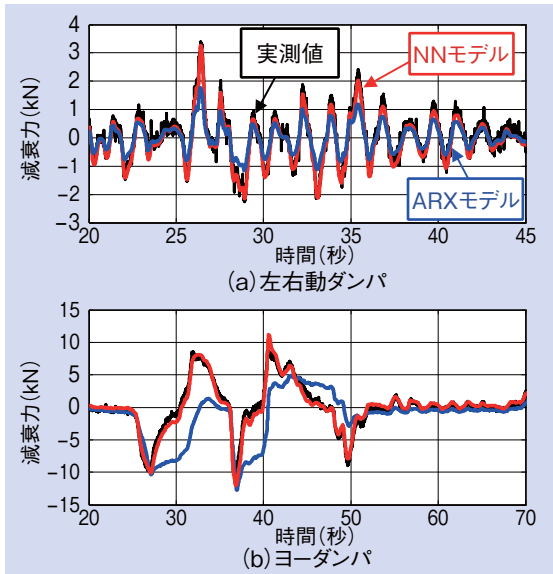


図8 ダンパの主軸方向の特性同定結果

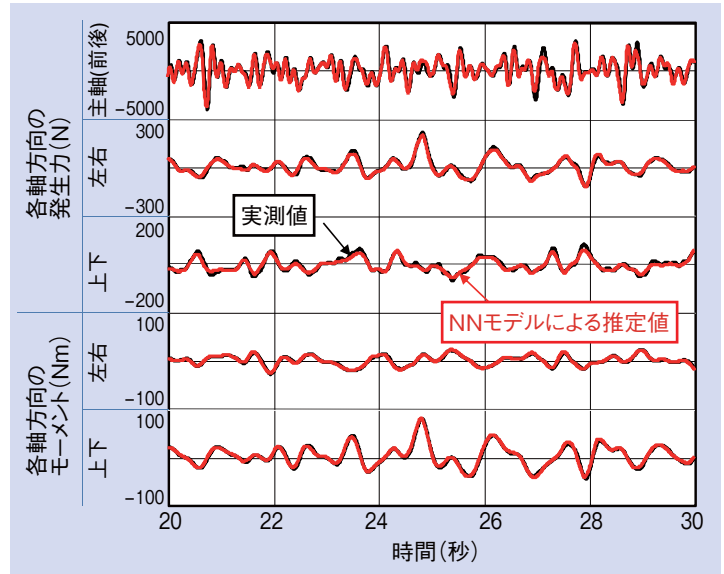


図9 ヨーダンパの多入力多出力の同定結果

ポイント③「ダイナミクスモデルとの併用」

教師データの入出力間の相関が低いと、モデルとして十分な精度を得ることが難しくなり、単純なNNモデルのみで同定することが困難になります。そこで、今回用いたNNモデルには精度の低下を避けるために簡易な力学モデルが組み込まれています(図7)。

これらを踏まえて新幹線用左右動ダンパとヨーダンパについて、主軸方向減衰力の特性同定を行った結果が図8です。ARXモデルによる推定値も併記しています。

ARXモデルは線形同定手法なので、同定対象の非線形性によって大きな影響を受け、比較的非線形性の小さい左右動ダンパでは実測値に近い波形を推定することができますが、非線形性の強いヨーダンパでは実測と波形が大きく異なっています。これに対してNNモデルを適用した場合はどうでしょうか。両ダンパとも実測値とほぼ一致し、NNモデルの方が高精度であることが分かります。

多入力多出力の同定モデルへの拡張

車両走行時にダンパはどの程度主軸方向以外にも変位し、力を発生しているのでしょうか。ダンパ試験装置でダンパを各軸方向に単軸加振し、各軸方向からの入力によって、どのような力やモーメントが発生するのかを調べてみると、例えばヨーダンパでは、主軸(前後方向)ではなく左右方向あるいは上下方向の単軸加振を行った際にも主軸方向の力を発生することがわかりました。これは、左右あるいは上下に加振されることによって、主軸方向のストロークが微小に変化するためです。したがって実走行状態における主軸方向の発生力を推定する際には、主軸方向以外の変位による

発生力も推定精度に大きく影響してくることになります。

先ほど得られたNNモデルを、他軸方向からの影響を考慮した多入力多出力のNNモデルに拡張し、ヨーダンパの特性同定を行った結果を図9に示します。NNモデルによる推定結果(赤線)は実測値(黒線)と良く一致しています。ここではヨーダンパの結果を示していますが、左右動ダンパについても良好な結果が得られています。

おわりに

鉄道総研では、実時間で動作するコンピュータシミュレーションと実物の評価対象を組み合わせ、実際の走行状態をベンチ試験で作り出してその動作を評価するHILS(Hardware In the Loop Simulation)と呼ばれる手法を取り入れた「鉄道車両用HILSシステム」の開発も行っています。このシステムのシミュレーションプログラムは、ばねやダンパなどの部品単位のブロックで構成されているため、今回得られた高精度なモデルをブロックとして組み込むことで、シミュレーション全体の精度向上が期待できます。

今後は、左右動ダンパ・ヨーダンパの様々な型式や、他種のダンパについてもモデルを作成し、データベースに蓄積していくことで、シミュレーション精度の向上に貢献していきます。

なお、本研究開発の一部は国土交通省の補助金を受けて実施しています。RRR

文献

- 1) 下村隆行：高速車両の走行安定性と乗り心地，RRR，Vol.61，No.1，pp.14-17，2004