

ニューラルネットワークによる入力同定

小机 わかえ¹・山下 剛史²・宮地 秀征¹

¹ 機械工学科

² 大学院工学研究科機械工学専攻

Input Load Identification Using Neural Network

Wakae KOZUKUE¹, Takafumi YAMASHITA², Hideyuki MIYAJI¹

Abstract

Due to various causes, a machine generates dynamic loads during its operation. These dynamic loads are the main source of vibration and noise. If dynamic loads can be identified exactly, it will become possible to provide data effective in reduction of vibration and noise. However, by the method of identification of dynamic loads of the conventional multiple input systems, noise has big influence on the accuracy. Then, in this paper, the identification method using neural network (NN) is proposed for multiple input loads, and the result of these simulations by using these methods are compared in detail.

Key Words: Dynamic load, Multiple input-output system, Wiener filtering theory, Neural network, Identification

1. はじめに

近年、「人にやさしい・環境にやさしいものづくり」を求めることが重視されている。そのために機械の安全性はもちろん快適さを追求した性能が重要な商品価値になりつつあり、振動・騒音はそれらを妨げる主な要因のひとつである。機械構造物は実に様々な原因により、運転時に動荷重を発生させる。動荷重によって機械の支持箇所が振動し、この振動によって騒音が発生する。よって、振動・騒音を低減しようとする場合のポイントは動荷重を低減することである。そのためにはどのような動荷重が働いているかを知ることが重要である。また、構造物の応力解析、動特性の設計、および故障・欠陥の分析をする時には、正確な動荷重の推定が要求される。正確な動荷重を推定することができれば、振動・騒音の低減に有効なデータを提供することが可能になる。そこで、本研究では、動荷重の同定問題を取り上げる。

動荷重の同定問題は、以前から幅広く行われている。一般に動荷重の同定法は、大きく、直接的方法と間接的方法に分けることができる。直接的方法の一例として、構造物を数ヶ所で力検出器を介して基礎から浮かして支持し、構造物の加振力を計測する方法がある。このような直接的方法は比較的手早く容易に動荷重の測定ができるという利点があるが、多くの場合は簡単に行うことは難しい。例えば宇宙船のドッキ

ング時に受ける衝撃力、建物が受ける地震力、自動車が走行中に路面から受ける激震力などが挙げられる。これらの場合は、直接的方法で測定することが困難であるばかりか不可能なものもある。

一方、間接的方法とは、構造システムの応答値(ひずみ、変位、速度、加速度など)により、構造物の動特性を同定し、このシステムに作用する動荷重を間接的に推定する方法である。このような動的な物理現象の計測結果からその原因である物理量を推定することは動的逆問題解析と呼ばれている。構造物に生じる応答値は比較的計測しやすく、直接的方法で測定する困難な問題に対して有効である。従来の研究の代表的な方法として、M. T. Martin らのウェーブレット理論に基づく方法、D. L. Gregory らの等価質量理論に基づく質量加速度法、M. Tracy らおよび K. Y. Choi らの提案した圧電素子を用いる動加重の同定法、井上ら¹⁾の提案した逆畳み込み積分法などがある。ところが、これらの方法は、単一入力システムだけを扱っている。実際の機械では入力は一とは限らない。例えば、走行中の自動車は四輪すべてに独立した激震力をそれぞれ受けているので、単一入力同定法は適用できない。このような複数入力システムは入力相互の影響のため、単一入力システムの場合より入力の同定は困難になる。K. K. Stevens²⁾らは複数入力システムの伝達関数から直接的に擬似逆行列演算を行い、逆伝達関数を推定して動荷重を求め

る方法を示したが、この方法ではノイズが結果に大きな影響を及ぼす。また、Rao ら³⁾は非因果的ウィナーフィルタ理論に基づいた複数入出力システムにおける入力荷重の推定方法を提案している。ウィナーフィルタ理論による方法は、従来の方法より計測ノイズに対するロバスト性が極めて強く、また高周波数振動が生じる衝撃力の推定にも有効である。

以上のように、従来の動荷重の同定方法は適用範囲に限界がある。そのため、本研究では複数の独立した入力の入力推定方法として、入出力データをニューラルネットワーク (NN) に学習させて、それらの間に写像関係を構築し、その優れた汎用能力により、未学習データに対しても妥当な同定ができると考えられる方法を提案する。NN を用いる方法は、学習には少し時間がかかるものの、一度学習が終了してしまえば、積和演算を行うだけで迅速に同定できる可能性を有する。

本研究の目的は、複数入出力システムの動荷重の大きさを正確に推定することである。そのため、NN を用いて学習結果から動荷重を推定する方法を提案する。さらに、本研究で提案する方法を、従来の方法及びウィナーフィルタ理論を用いた方法と比較し、その有用性の検証を行う。

2. ホログラフィックニューラルネットワーク

ホログラフィックニューラルネットワーク (以下 HNN) は、NN として従来もっとも広く利用されてきたバックプロパゲーションニューラルネットワーク (BNN) に代わって提案された新しい NN のアルゴリズムである。HNN は BNN に比較して、学習時間、学習回数が少なく済むこと、また精度がはるかに良好であり、扱いやすいことがいくつかの報告によって示されている。

2.1 ホログラフィックニューラルネットワークの概要

HNN は Sutherland⁴⁾によって開発された NN で、その最大の特徴は、入力データと出力データを複素平面上に均一に写像することによって、両者の間に線形関係を持たせていることである。HNN ではニューロンの数は1個であり NN の構築は、入力と出力の間の伝達関数を求めることに等しい。そのため、計算が収束するまでの時間を大幅に短縮することが可能となる。

2.2 ホログラフィックニューラルネットワークの理論

学習に l 組の m 次元入力ベクトル s と n 次元出力ベクトル r を用いるとする。入出力ベクトルの各要素は、次のような非線形変換関数により、複素平面上に変換される。

$$f(s_{hk}) = \lambda_{hk} e^{i\theta_{hk}} \quad (2.1)$$

$$g(r_{jk}) = \gamma_{jk} e^{i\phi_{jk}} \quad (2.2)$$

ここで、 i は虚数単位、 θ_{hk} 、 ϕ_{jk} はシグモイド関数のような写像関数により変換される位相角度で、区間 $[0, 2\pi]$ の値を持つ。 λ_{hk} 、 γ_{jk} は入出力データが、対応する位相角領域に出現する確率を示し、区間 $[0, 1]$ の値を持つ。以上の式 (2.1)、(2.2) により次のような入力行列 $[S]$ 、教師行列 $[T]$ が得られる。

$$[S] = \begin{bmatrix} \lambda_{11} e^{i\theta_{11}} & \lambda_{12} e^{i\theta_{12}} & \cdots & \lambda_{1m} e^{i\theta_{1m}} \\ \lambda_{21} e^{i\theta_{21}} & \lambda_{22} e^{i\theta_{22}} & \cdots & \lambda_{2m} e^{i\theta_{2m}} \\ \vdots & \vdots & & \vdots \\ \lambda_{l1} e^{i\theta_{l1}} & \lambda_{l2} e^{i\theta_{l2}} & \cdots & \lambda_{lm} e^{i\theta_{lm}} \end{bmatrix} \quad (2.3)$$

$$[T] = \begin{bmatrix} \gamma_{11} e^{i\phi_{11}} & \gamma_{12} e^{i\phi_{12}} & \cdots & \gamma_{1n} e^{i\phi_{1n}} \\ \gamma_{21} e^{i\phi_{21}} & \gamma_{22} e^{i\phi_{22}} & \cdots & \gamma_{2n} e^{i\phi_{2n}} \\ \vdots & \vdots & & \vdots \\ \gamma_{l1} e^{i\phi_{l1}} & \gamma_{l2} e^{i\phi_{l2}} & \cdots & \gamma_{ln} e^{i\phi_{ln}} \end{bmatrix} \quad (2.4)$$

出力行列 $[A]$ は、伝達関数 $[X]$ を用いて、次式のように表される。

$$[A] = [S] \cdot [X] \quad (2.5)$$

$[X]$ は、次式に表される $[A]$ と $[T]$ の差が最小となるように決定される。

$$E_{rr} = ([A] - [T])^H \cdot ([A] - [T]) \quad (2.6)$$

ここで、 H は共役転置を表わす。この条件より、次式が得られる。

$$[X] = ([S]^H \cdot [S])^{-1} \cdot [S]^H \cdot [T] \quad (2.7)$$

$[S]$ 、 $[T]$ は既知であるので、 $[X]$ は式 (2.7) により直接求まる。しかし、Gauss-Jordan 消去法で n 次の行列の逆行列を求める場合、その演算回数は n^3 回となるので、 $[S]$ が高次元になると演算に膨大な時間が必要となる。そこで、これを避けるため、次式の反復学習により $[X]$ を求める。

$$[X]_i = \frac{1}{E} [S]^H \cdot [T] \quad (2.8)$$

$$[X]_{i+1} = [X]_i + [S]^H \cdot \left([T] - \frac{1}{E} [S] \cdot [X]_i \right) \quad (2.9)$$

ここで E は $[X]$ のノルムを正規化するパラメータである。

伝達関数 $[X]$ の収束を速くするためには、入力ベクトルを複素平面上に均一に変換することが望ましい。また、式(2.6)で示されるように、誤差は二次関数で表されるので、最小値は一意である。それゆえ同定した結果は同じ値となり、初期値や結合係数の影響を受けないことがわかる。

NN の教師データ数が少ない場合には、Expansion term 数を増やすことによりニューロン内部の入力数を増加させる。具体的には入力データ同士の積で新たな入力データを作成する。このようにして作成された入力データは元のデータとは線形関係を持たない。例えば、ニューロンへの基本的な入力を 2 とし、2 次項を作成すると、次のように拡張することができる。

$$S = [\lambda_1 e^{i\theta_1}, \lambda_2 e^{i\theta_2}]$$

↓

$$\bar{S} = [\lambda_1 e^{i\theta_1}, \lambda_2 e^{i\theta_2}, \lambda_1 e^{-i\theta_1}, \lambda_2 e^{-i\theta_2}, \lambda_1^2 e^{i2\theta_1}, \lambda_2^2 e^{i2\theta_2}, \lambda_1^2 e^{-i2\theta_1}, \lambda_2^2 e^{-i2\theta_2}, \lambda_1 \lambda_2 e^{i(\theta_1+\theta_2)}, \lambda_1 \lambda_2 e^{i(-\theta_1+\theta_2)}, \lambda_1 \lambda_2 e^{-i(\theta_1+\theta_2)}, \lambda_1 \lambda_2 e^{i(\theta_1-\theta_2)}]$$

(2.10)

以上の操作で入力の数 は 2 から 12 に増大する。12 に増大した入力は Expansion term と呼ばれる。

2.3 ホログラフィックニューラルネットワークを用いた逆問題解析手法

解析手順は三つのフェーズから構成される。第一フェーズでは、有限要素法(FEM)による、機械構造物の振動特性を求める順解析を行い、HNN に学習させるための教師データを作成する。第二フェーズでは、求めた振動特性を入力データ、対応するパラメータを出力データとして HNN に与えて、学習を行う。第三フェーズでは、学習データとして用いていない未知のデータを、学習済みの HNN に与えてパラメータを求める。

3. 複数入力システムの逆問題解析の数値シミュレーション

提案した手法の有効性を確認するために数値シミュレーションを行う。シミュレーションでは、周辺単純支持の板を用いて二入力二出力システムの動荷重推定を行い、従来の手法と比較して、提案する方法の方が同定精度が良いことを示す

3.1 解析モデル 図 1 に示すように、周辺単純支持の板を解析モデルとしてシミュレーションを行う。板の寸法および

材料定数は次の通りである。

$$\text{寸法: } 600 \times 400 \times 5 \text{ (mm)}$$

$$\text{縦弾性係数: } E = 2.1 \times 10^5 \text{ (N/mm}^2\text{)}$$

$$\text{ポアソン比: } \nu = 0.3$$

$$\text{密度: } \rho = 7.85 \times 10^{-6} \text{ (kg/mm}^3\text{)}$$

拘束条件: 周辺単純支持

3.2 解析方法 周辺単純支持の板には入力点が二つあると仮定する。 $F1, F2$ は二つの入力点を表す。観測点数は入力点数以上でなければならないので、本シミュレーションでは観測点数を入力点数と同じ二つと定めて $X1, X2$ と表す。このシステムは二入力二出力である。本シミュレーションにおける解析には次の値を用いた。

$$\text{観測時間 } T = 25.6 \text{ ms}$$

$$\text{サンプルデータ } N = 512$$

$$\text{サンプル間隔 } \Delta t = 50 \mu\text{s}$$

有限要素法による過渡応答解析を行って、応答値(加速度)を求める。構造物の有限要素モデルは 117 個の節点と 96 個のシェル要素からなる。図 2 に示す半正弦波衝撃力と図 3 に示す三角形衝撃力の二つの入力を仮定する。本研究では、複数入力がお互いに相関がないことと仮定した上で行うので、入力の相互相関度を確認する必要がある。次の式(3.1)により任意の二つの入力の相互相関関数を得る。

$$\text{coh} = \frac{|S_{F_i F_j}(\omega)|^2}{\sqrt{S_{F_i F_i}(\omega) \cdot S_{F_j F_j}(\omega)}} \quad (i \neq j) \quad (3.1)$$




Fig.1 Plate Model for Analysis




Fig. 2 Half Sinusoidal load




Fig. 3 Triangular load




Fig. 4 Response at X1

得られた二つの動荷重はそれぞれ $F1$, $F2$ に同時に作用させ、観測点 $X1$, $X2$ の加速度の時間歴は有限要素法により求める。X1 で求められる出力加速度波形の例を図 4 に示す。その上に、ランダムノイズ信号をコンピュータプログラムで作成し上述のデータに追加しこれを計測信号とする。ここで加えるノイズのレベルは信号騒音比 (SNR) で表す。信号騒音比は式 (3.2) により求める。

$$SNR = 10 \times \log_{10} \frac{\sum S}{\sum N} \text{ (dB)} \quad (3.2)$$

ここで、 $\sum S$ と $\sum N$ はそれぞれ信号のパワースペクトルとノイズのパワースペクトルである。

4. 解析結果

4.1 従来の方法と非因果的ウィナーフィルタ理論を用いた場合 $F1$, $F2$ にそれぞれ半正弦波衝撃力と三角形衝撃力を作用させ、上で述べたように計算して応答値を求め、ノイズ信号 (ノイズなし, 45dB, 40dB, 35dB, 30dB, 20dB) を応答値に加え、この信号をもとに入力荷重値を得る。

従来の方法はノイズが加わると入力値がゼロの場合でもノイズを抑えることができていない。また、波形が理想値と異なり乱れている。最大の値も最大値となる時間にもずれが生じてきている。だが、三角形衝撃力は、半正弦波衝撃力と比べ最大値や波形の形状の乱れが少ない。

非因果的ウィナーフィルタ理論を用いた方法では SN 比 25dB から誤差の影響を受けるようになった。だがその影響は緩やかである。この方法では半正弦波衝撃力のほうが波形の乱れが少ない。

4.2 ホログラフィックニューラルネットワークを用いた場合

半正弦波衝撃力と三角形衝撃力の大きさを様々に変化させたデータ 30 パターンを作成する。ここで 1 パターンでのサンプルデータ数を 256 点とする。これらを教師データとして用いて、未学習の半正弦波衝撃力と三角形衝撃力についてテストを行い、同定精度および汎化能力を検証する。Expansion term 数 576 の場合、学習回数を 3000 回、5000 回でテストしたが、波形は非常に乱れ同定精度はよくなかった。これ以上の学習を行っても Expansion term 数を増加させても収束状況に変化は見られなかった。ここでは未学習のデータを用いて精度を調べていることから、汎化能力は乏しいことがわかる。

半正弦波衝撃力と三角形衝撃力の大きさを様々に変化させたデータ 50 パターンを作成し、1 パターンでのサンプルデータ数を 27 点とする。これらのデータを教師データとして、未学習の半正弦波衝撃力と三角形衝撃力についてテストを行い、同定精度および汎用能力を検証する。Expansion term 数 48, 144, 240 の場合、学習回数を 1000 回、3000 回、5000 回でテストした。

Expansion term 数が 48 の場合、学習回数を 3000 回、5000 回と増加させていっても、1000 回の場合と比べて収束状況の変化は見られなかった。どの学習回数、どの SN 比でも波形に変化はなかった。

Expansion term 数が 144 の場合、Expansion term 数が 48 の場合と比較すると、より真の値に近かった。特に三角形衝撃力は、ほぼ一致している。学習回数を増加させていくと、ごくわずかだが収束し、真の値に近づいている。この場合で

は、どの SN 比でも波形に変化はなかった。

Expansion term 数 240 の場合、Expansion term 数 144 の場合とほぼ同じ波形が得られる。三角形衝撃力も、ほぼ一致している。ただ真の値がゼロの部分はこの場合の方が真の値に近いことがわかる。学習回数を増加させていくと、ごくわずかが収束し、真の値に近づいている。この場合では、どの SN 比でも波形に変化はなかった。ここでは未学習のデータを用いて同定精度を検証していることから、汎用能力も優れていると考えられる。

上記の結果から、HNN はノイズの影響をほとんど受けないことがわかる。また、参照点数が多すぎると、いくら Expansion term 数と学習回数を多くしても膨大な学習時間を要するだけで期待するほどの成果を得ることはできなかった。しかし、参照点数を少なくし、教師データのパターン数を多くすることによって、少ない学習時間で真の値に近い値を得ることがわかった。

5. 解析結果の比較

5.1 従来の方法と非因果的ウィナーフィルタ理論を用いた場合の比較


図 6 に示すように、非因果的ウィナーフィルタ理論を用いた場合の方がより大きなノイズを与えても波形の形状が真の値と同じで乱れが少なく同定精度が良いことがわかる。

5.2 従来の方法とホログラフィックニューラルネットワークを用いた場合の比較


図 5 に示すように、ノイズがほとんどない場合は、明らかに従来の方法の方が同定精度が良い。しかし、図 6 に示すように、ノイズが大きい場合は、HNN のほうがどの SN 比でもほとんどノイズの影響を受けず、ノイズなしの場合と同様な波形を示し、有効であることがわかる。

5.3 非因果的ウィナーフィルタ理論を用いた場合とホログラフィックニューラルネットワークを用いた場合の比較


SN 比 30dB の場合までは、非因果的ウィナーフィルタ理論を用いた場合の方が同定精度が良い。しかし、ノイズが大きい場合は HNN のほうがどの SN 比でもノイズの影響をほとんど受けず、ノイズなしの場合と同様な波形を示し、従来の方法と比較した場合と同様、有効であることがわかる。三角形衝撃力の場合、Expansion term 数 240、学習回数 5000 回で行った HNN の結果と比較すると、図 6 に示すように、HNN のほうがどのノイズの影響もあまり受けず、優れていることがわかる。



i) Conventional method




ii) Non-causal Wiener Filtering Theory




iii) HNN

Fig.5 Results for no noise



i) Conventional Method



ii) Non-causal Wiener Filtering Theory

Fig.6 Results for SN ratio 25dB




Fig. 6 Results for SN ratio 25dB (continued)

6. まとめと今後の課題

本研究では、ホログラフィックニューラルネットワークを用いた複数の独立な入力値推定方法を、従来から用いられてきた方法と、最近提案された非因果的ウィナーフィルター理論による方法の代わりに用いることによって、入力荷重の同定の精度を向上させる可能性について検討した。入力を同定することで重要なことは、いかに出力の計測中に加わったノイズの影響を受けない正しい入力を導き出すかである。

従来の方法では、ノイズの影響を抑えることができないため、入力値が小さい場合には信号がノイズに隠れてしまい、入力値とノイズの判断がしにくい可能性があった。非因果的ウィナーフィルター理論を用いた方法では、ノイズの影響を抑え、より正確な値を導き出しているが、ノイズが大きくなると同定精度が悪くなる。一方、本研究で提案した HNN による方法では、学習データに含まれていないデータについてテストしたところ、本研究で検討したどのノイズについても、その影響をほとんど受けない真の値に近い値が得られた。このことから、他の未学習データについても同様な結果を得ることが期待できる。

今後、振動対策をしていく上で、複数の様々な入力を見つけ出し、機械の振動抑制を進めていくことは騒音対策にもつながり、市場のニーズだけでなく世界の環境問題へのニーズに応えていくことにもなると考えられる。それゆえに正確な入力値を把握することは重要であり、より高精度を得ることができる手法を開発することが望まれる。

参考文献

- (1) Inoue, H. et al. (1992) Estimation of impact load by inverse analysis, JSME International Journal, Series C, 35(4), pp. 420-427.
- (2) Stevens, K. K. (1987) Force identification problems—an

- overview, Proc. SEM Spring Meeting Houston, pp. 834-855.
- (3) Rao, Z. H., Shi, Q. Z., Hagiwara, I. (1999) Optimal estimation of dynamic loads for multiple-input system, ASME Journal of Vibration and Acoustics, 121(3), pp. 397-401.
- (4) Sutherland, J. G. (1990) The Holographic model of memory, learning and expression, International Journal of Neural Systems, 1(3), pp. 259-267.