

放射状基底関数ネットワークを用いた打撃点の推定 にする研究

著者	小松? 俊彦, 岩田 佳雄, 本江 哲行
雑誌名	日本機械学会論文集C編 / Nihon Kikai Gakkai Ronbunshu, C Hen / Transactions of the Japan Society of Mechanical Engineers, Part C
巻	77
号	784
ページ	4521-4533
発行年	2011-01-01
URL	http://hdl.handle.net/2297/31409

doi: 10.1299/kikaic.77.4521

放射状基底関数ネットワークを用いた打撃点の推定に関する研究*

小松崎 俊彦^{*1}, 岩田 佳雄^{*1}, 本江 哲行^{*2}

Estimation of Impact Point using Radial Basis Function Network

Toshihiko KOMATSUZAKI^{*1}, Yoshio IWATA and Tetsuyuki HONGO

^{*1} Institute of Science and Engineering, Kanazawa University
Kakuma-machi, Kanazawa, Ishikawa, 920-1192 Japan

It is important to identify the information of the external force acting on the structures in order to address the vibration related issues. More specifically, the identification of the impact point would offer advantages in some sports training where the recognition of the hitting accuracy is thought to be effective for the skill improvements. In this study, a kind of the artificial neural networks known as Radial Basis Function Network is introduced for the estimation of the impact point in structures based on the measured acceleration responses obtained by relatively small number of pre-determined force inputs. The force input location is predicted for both one and two-dimensional problems where the effects of the number of sample points used for the network learning and the size of the input vector on the estimation accuracy are investigated.

Key Words : Radial Basis Function Network, Neural Network, Vibration, Identification, Impact Point

1. 緒 言

構造物の振動対策のためには、振動源、すなわち加振源を特定することが重要である。また、例えばゴルフクラブ、野球におけるバットのように、打撃を加えることを目的とするスポーツ分野では、打点とその都度わかれば効果的な訓練が可能となる。構造物への作用力を推定する問題では、力の作用位置及び荷重履歴が主な同定の対象となるが、一般には後者を取り扱った研究例が多いようである。ただし、特に分布系を対象とする場合、荷重履歴の同定のためには力の作用位置をあらかじめ知る必要があり、その特定は重要である。

カセンサを用いて直接的に計測することが困難な場合、作用力を推定するための手段として、ひずみや加速度などの振動応答を計測し、それらの情報から作用力を逆推定する、いわゆる逆問題的手法が一般に利用される。過去の研究においては、波動解を仮定して面内ひずみあるいは応答加速度と外力との関係式を解析的に得ておき、計測されたひずみから荷重履歴を推定する方法^{(1),(2)}や、あらかじめ力と応答との伝達関数を同定することで得た逆行列を用いて作用力を求める方法⁽³⁾などがあるが、これらの研究においては力の作用点を既知として取り扱っている。また、有限要素法等により構造物をモデル化し、定式化された系の伝達関数に未知パラメータとして含まれる力の作用位置及び大きさを同時に同定する方法⁽⁴⁾や、それらに加えて系の境界条件も未知な場合に荷重位置と荷重履歴を同定する方法⁽⁵⁾、カルマンフィルタを利用した推定⁽⁶⁾などがある。ただしこれらの方法では、荷重推定のための構成式や手順が煩雑になるうえ、推定精度は構造物の要素分割数や仮定するモード次数等、モデル化の精度に大きく依存し、取り扱える荷重位置も離散点上に制限される。さらに、構造物の振動インテンシティを利用して加振位置を推定する方法⁽⁷⁾も考えられるが、振動インテンシティの導出には構造物の応力等の内力値を知る必要があり、これらを直接的に計測することや、振動変位等の計測値から間接的に精度よく推定することは一般に困難である。

* 原稿受付 2011年08月26日

^{*1} 正員, 金沢大学理工研究域機械工学系 (〒920-1192 石川県金沢市角間町)

^{*2} 正員, 富山工業高等専門学校機械工学科

E-mail: toshi@t.kanazawa-u.ac.jp

以上の背景を踏まえ、本研究では、離散的な入出力関係を学習パターンとして内挿し、入出力間の非線形写像を実現可能なシステムがこの種の問題に有効であると考え、近似的に妥当な値を出力できる推定モデルとしてニューラルネットワーク⁽⁸⁾に着目する。ニューラルネットワークは人間の脳におけるニューロンの構造とその情報伝達のしくみを数学的にモデル化し、計算機上で再現した情報処理システムであり、文字認識などの定性的なマッピングへの応用から機械制御や欠陥同定のように具体的なアナログ値を出力する定量的な問題まで幅広く研究されている。その理由として、非線形性の強い写像でも離散的な入出力関係を学習させるだけでネットワークの結合係数として構築できる簡便性や、未学習の入力に対しても妥当な値を出力できる汎化能力、積和演算のみで出力が得られる応用時の迅速性等が挙げられる。しかし、一般的な階層型ネットワークではデータ数の増加とともに学習に時間を要し、過度に学習させることによって汎化性が失われる過学習に陥る問題等が知られている。

本研究では、実測で得られた比較的少ない任意のデータから未知の打撃点を簡易かつ迅速に推定可能なシステムを構築することを目的とする。そこで具体的には近年、関数近似手法として工学的応用事例が報告されている一種のニューラルネットワークである放射状基底関数(Radial Basis Function, RBF)ネットワーク⁽⁹⁾⁻⁽¹²⁾を打撃点推定問題に適用し、その有効性を検討する。RBF ネットワークの利点として、ネットワークの構成自体が比較的単純であること、学習速度が速いこと、及びネットワークの一部だけを追加学習することが可能な点が挙げられる。本研究の場合、あらかじめ選択した構造物の複数点を打撃して得た既知の振動加速度応答に基づき、加速度スペクトルのピーク値の組み合わせを RBF ネットワークの入力データ、それに対応する打撃位置の情報を教師出力として、これらの対応関係を学習させることにより、任意の応答に対応する打撃点の座標を逆推定可能と考えられる。対象構造物として、1次元的な形状の構造物としてはり及び金属バット、2次元的なものとして板及びゴルフクラブフェース面を取り上げ、任意点を打撃した際に加速度センサから得られる曲げ振動の加速度応答から打撃点を推定し、その精度を数値モデル及び実験により検証した。

2. RBF ネットワークの概要

RBF ネットワークとは、有限個の入出力データを補完する方法として提案された、入力・中間・出力層の3層から構成されるニューラルネットワークの一種であり、円形の等高線を持つ複数の基底関数に重みを持たせて足し合わせるにより、任意の非線形関数を近似する手法である⁽⁸⁾。一般には関数近似に利用されるが、パターン識別法として利用することも可能である。誤差逆伝播法に基づく一般の階層型ニューラルネットワークと比較して学習が高速なことや構造が比較的単純であること、及び追加学習が可能であること等を利点とする。なお、ここで言う学習とは、基底関数への重み係数を決定することを指す。学習に先立ち、各層のユニット数、基底関数の中心と半径、学習に用いる入出力データ数を決めておく必要があるが、本節では、まず本研究で用いた RBF ネットワークの構造と学習方法について述べ、続いて基底関数の中心と半径を決定するために用いた k -means 法、及び N -nearest neighbor 法について説明する。

2.1 ネットワークの構造と学習方法

入力層ユニット数 n 個、中間層ユニット数 m 個、及び出力層ユニット数 1 個からなる RBF ネットワークの構造を図 1 に示す。 j 番目の中間ユニットの基底関数として、本研究では次式を採用する。

$$h_j(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_j\|^2}{r_j^2}\right) \quad (1)$$

ここで、 $\mathbf{x} = (x_1, x_2, \dots, x_n)$ はネットワークの入力ベクトル、 \mathbf{c}_j と r_j は基底関数の中心ベクトル及び半径である。ネットワークの出力 $O(\mathbf{x})$ は次式に示すように、基底関数の出力に重み w_j を乗じたものの重ね合わせで表される。

$$O(\mathbf{x}) = \sum_{j=1}^m w_j h_j(\mathbf{x}) \quad (2)$$




Fig. 1 General constitution of Radial Basis Function Network

RBF ネットワークの学習とは、出力が学習データに対して適切な値となるような重み係数を求めることである。学習に用いるサンプル点数（入出力データの組み合わせ数）を s 個とした場合、重み係数は次の評価式(3)を最小化するように求められる。

$$E = \sum_{i=1}^s (y_i - O(\mathbf{x}_i))^2 + \lambda \sum_{j=1}^m w_j^2 \rightarrow \min \quad (3)$$

式(3)の第1項はネットワークの出力と正解値を表す教師データ y_i との誤差を表し、第2項は一部の素子の過剰反応を防ぐための重みに対する抑制項である。結果的に、結合荷重 \mathbf{w} は次の式(4)に従って求められる。

$$\mathbf{w} = (\mathbf{H}^T \mathbf{H} + \Lambda)^{-1} \mathbf{H}^T \mathbf{y} \quad (4)$$

ただし、式(4)における \mathbf{H} , Λ は、

$$\mathbf{H} = \begin{bmatrix} h_1(\mathbf{x}_1) & h_2(\mathbf{x}_1) & \cdots & h_m(\mathbf{x}_1) \\ h_1(\mathbf{x}_2) & h_2(\mathbf{x}_2) & \cdots & h_m(\mathbf{x}_2) \\ \vdots & \vdots & \ddots & \vdots \\ h_1(\mathbf{x}_s) & h_2(\mathbf{x}_s) & \cdots & h_m(\mathbf{x}_s) \end{bmatrix}, \quad \Lambda = \begin{bmatrix} \lambda & & & 0 \\ & \lambda & & \\ & & \ddots & \\ 0 & & & \lambda \end{bmatrix}$$

のように与えられる。基本的には最小二乗法に従い結合荷重ベクトル \mathbf{w} を求めるため、サンプル点数 s は中間ユニット数 m 以上の数とする必要がある。なお、本研究では式(4)の第2項を考慮せず、 $\lambda=0$ と設定した。

2・2 基底関数の中心と半径の決定方法

式(1)で表現されるガウス関数には、中心位置を表すパラメータ \mathbf{c}_j と放射状関数の広がり具合を表すパラメータ r_j が含まれており、これらは関数近似精度に大きく影響する。前者は入力ベクトル空間全体を均等にカバーするよう分散させることが望ましく、後者については隣接する基底関数同士の重なり具合に関係し、未学習点を補間する際の精度に影響するので、基底関数の中心間距離に依存して適度に調整する必要がある。これらの決定方法についてはいくつかの研究が報告されているが^{(9),(12)}、アルゴリズムが簡易であり直感的に理解しやすく、RBF ネットワークへの導入事例も多いことを考慮して、本研究では中心位置の決定に k -means 法⁽¹²⁾、半径の決定には N -nearest neighbor 法を採用した。

k -means 法はクラスタ分析の一手法であり、あらかじめ指定した数のクラスタにデータを分割し、各々のクラスタ内で平均値を算出することにより中心を定め、更新された中心とすべてのデータ点との距離に基づき再びクラスタに分割するという過程を、中心及びデータの各クラスタへの割り当てが収束するまで繰り返す方法である。

アルゴリズムを以下に示す.

- (1) 集団の中から無作為に k 個のデータを選択し, 初期クラスタ中心とする.
- (2) すべてのデータと k 個のクラスタ中心との距離を計算し, 最も近い中心を含むクラスタに割り当てる.
- (3) k 個のクラスタごとに, 中心 (所属データの平均値) を計算し直す.
- (4) 全てのクラスタ中心が変化しなければ終了, そうでない場合は(2)に戻って繰り返す.

本研究の場合, RBF ネットワークの学習過程に用いる s 個の入力ベクトルに対して, 基底関数の数と同じ m 個のクラスタに分割を行い, 抽出された m 個のクラスタ中心を基底関数の中心として採用する.

一方, N -nearest neighbor 法は, クラスタ分析においてクラスタ間の距離を取り扱う場合に用いられる手法の一つである. 一つのサンプル点と, その近傍の N 個のサンプル点との距離を各々求め, それらの平均値を代表値として用いる方法で, 本研究では $N=2$, つまり, ある基底関数の中心に着目した場合, それと最も近いその他 2 つの基底関数の中心との平均距離を算出し, その基底関数の半径として採用した.

3. 1次元形状物体に対する打撃点推定の検討

本節では, 1次元的な形状を有する構造物の例としてはり及び金属バットを採用し, RBF ネットワークを用いた打撃点の推定に関する検討を行った. まずは数値計算モデルとして両端単純支持はりを取り上げ, インパクト加振を受けるはりの曲げ振動の方程式について定式化を行う. 続いて, はりの打撃によって得られる加速度応答及びその際の打撃位置情報を入出力データとして RBF ネットワークの学習へ適用し, 未学習の打撃点推定精度を数値計算及び実験により検討した. さらに, 同様の打撃点推定に関する実験的検討を金属バットに対して行った結果について順次述べる.

3.1 両端単純支持はりの数値計算モデル

図 2 に示すように, 均一断面を有する長さ l の両端単純支持はりの曲げ振動を考える. 打撃は $x=a$ の位置に大きさ F のインパルス力が作用するものと考え, この力を $F(x,t) = F\delta(x-a)\delta(t)$ と表現すると, 真直はりの曲げ振動の方程式は次式となる.

$$EI \frac{\partial^4 w}{\partial x^4} + \rho A \frac{\partial^2 w}{\partial t^2} = F\delta(x-a)\delta(t) \quad (5)$$

ここで, ρ は密度, A は断面積, E は縦弾性係数, I ははりの中立軸に対する断面 2 次モーメント, w はたわみを表す. はりのたわみ $w(x,t)$ をモード展開すると,

$$w(x,t) = \sum_{i=1}^{\infty} W_i(x)\eta_i(t) \quad (6)$$

式(6)を式(5)に代入し, 変数分離可能であることを前提に空間と時間それぞれの方程式に分けて考える. このうち, 両端単純支持はりのモード関数 W_i は, 境界条件を考慮することにより, 次式のように定まる.

$$W_i(x) = \sin \frac{i\pi x}{l} \quad (7)$$




Fig. 2 Simply-supported beam excited by an impact force at $x = a$

一方，モード座標 η_i に関する運動方程式は，モードの直交性を利用して

$$\ddot{\eta}_i + 2\zeta_i \omega_i \dot{\eta}_i + \omega_i^2 \eta_i = \frac{2}{\rho A l} \int_0^l F \delta(x-a) \delta(t) W_i(x) dx = \frac{2F}{\rho A l} W_i(a) \delta(t) \quad (8)$$

となる．ただし，式(8)にはモード減衰比 ζ_i を用いて減衰項を付加している．また，両端単純支持はりの固有角振動数 ω_i は，

$$\omega_i = \frac{i^2 \pi^2}{l^2} \sqrt{\frac{EI}{\rho A}} \quad (9)$$

である．式(8)は，1自由度減衰系にインパルス力が作用する場合の運動方程式を表しており，モード座標に関するインパルス応答解は次式となる．

$$\eta_i(t) = \frac{2FW_i(a)}{\rho A l \bar{\omega}_i} e^{-\zeta_i \omega_i t} \sin \bar{\omega}_i t \quad (10)$$

ただし， $\bar{\omega}_i = \omega_i \sqrt{1 - \zeta_i^2}$ である．以上より，全てのモードを考慮した両端単純支持はりのインパルス応答は次式で表される．

$$w(x,t) = \sum_{i=1}^{\infty} W_i(x) \eta_i(t) = \frac{2F}{\rho A l} \sum_{i=1}^{\infty} \frac{W_i(a) W_i(x)}{\bar{\omega}_i} e^{-\zeta_i \omega_i t} \sin \bar{\omega}_i t \quad (11)$$

式(11)を時間2階微分した式からはりの加速度応答を求める．

3・2 はりの打撃点推定に関する検討

はりの任意点を打撃したときの振動加速度を，はり上の常に同じ1点において計測し，得られた加速度時刻歴データを周波数応答に変換して固有振動数に対応するピーク値を抽出する．複数のピーク値の組み合わせを入力ベクトル，既知の打撃点をそれに対応する教師出力としてネットワークを学習させたのち，未知の打撃点に対する応答のスペクトルからその位置を推定することを考える．相反原理に基づけば，加速度検出点を固定して打撃点を移動させることは，打撃点を固定して検出点を移動させることに置き換えが可能であるので，上記の方法で得られた加速度ピーク値を組み合わせることは，打撃を加えた点における各モードの振幅を検出していることに相当する．モード振幅の組み合わせは場所によって異なることから，この情報をネットワークに与えることで位置の違いを識別可能と予想される．

検討に用いたはりは表1に示すように長さ500mm，幅25mm，厚さ4mm，密度78.6kg/m³，ヤング率206GPaの鋼製はりとした．ただし，数値計算では取り扱い易さを考慮して境界条件を両端単純支持とし，実験では両端自由とした．また，インパルス応答の計算に考慮するモード次数は6次までとし，インパルス力の大きさは0.1Nとした．加速度検出位置は，はりの左端を原点としてx=10mmに設定した．計算モデルについて，x=30mm及びx=240mmの点を打撃した際の加速度検出位置における加速度時間波形及び周波数応答を計算した例を図3に示す．

Table 1 Specification of a beam model

Length l	500mm
Width b	25mm
Thickness t	4mm
Young's modulus E	206GPa
Density ρ	7.86kg/m ³

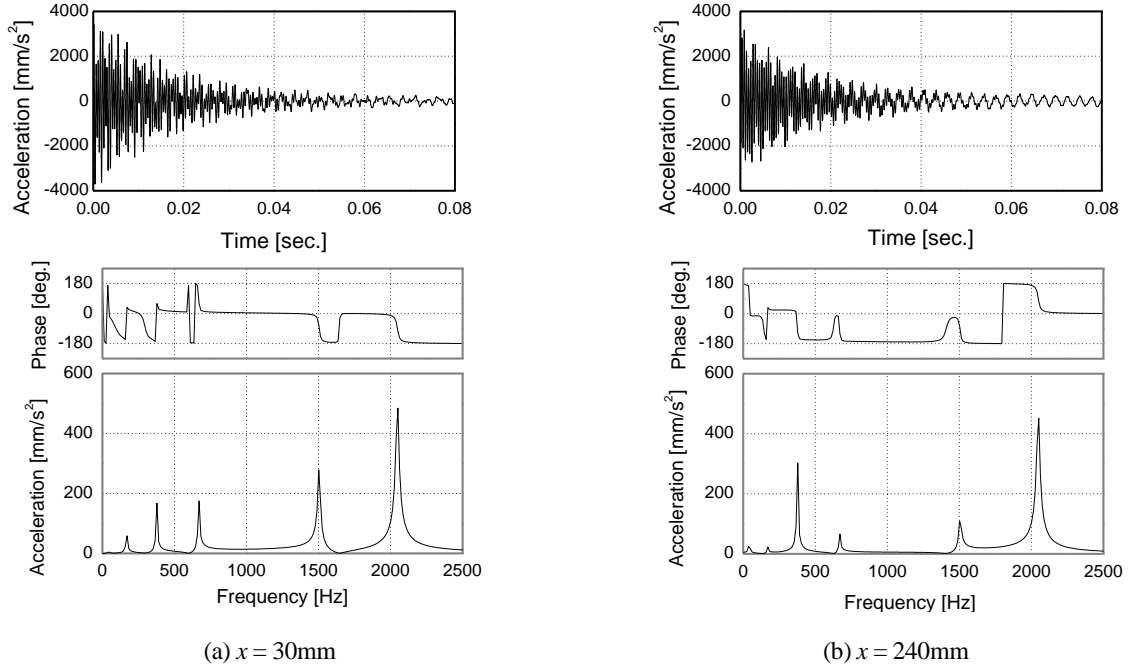


Fig. 3 Calculated examples of impact acceleration response of a simply-supported beam




Fig. 4 Estimation error of impact point compared by the number of learning data

RBF ネットワークの学習データ及び打撃点推定精度を検証するためのテストデータとして、はりを 10mm 間隔で 50 等分し、両端を含めた合計 51 点に対して打撃を加えた際の各々の加速度ピーク値の組み合わせを用意した。これら 51 組のデータのうち一部は学習用データとして、残りは RBF ネットワークへの入力データとして用いる。

まずは、学習に用いるデータ数が推定精度に及ぼす影響を見るため、入力データベクトルを構成する加速度ピーク値は 6 次までを採用し、学習データ数を 7, 10, 15, 20, 25 組と変えた場合の打撃点推定精度について検証した。この場合、RBF ネットワークの入力ユニット数は入力ベクトルの次元に対応して 6 個、出力ユニットは推定すべき打撃点の座標なので 1 個とした。また、中間ユニット数については学習データ数と同じ数に設定した。これは、RBF ネットワークの入出力関係から重み係数を未知数とする連立方程式を構成した場合、式と未知数との数が一致する条件である。精度検証に用いるテストデータの数はいずれの場合も 25 組とし、各々について打撃点の正解値と推定値との誤差を求め、全てを平均したものをその学習条件での推定精度として取り扱った。なおここで、学習済みデータを再び推定用入力として用いた場合、その誤差はほぼゼロであったため、評価用としては除外することとする。平均誤差の評価式は次のとおりである。

$$\bar{e} = \frac{1}{N} \sum_{i=1}^N \frac{\sqrt{(x - \tilde{x})^2}}{L} \quad (12)$$

式(12)において N はテストデータ数を表し ($N=25$), L ははりの全長 ($L=l$), x , \tilde{x} はそれぞれ打撃点の真の値とその推定値を表す. 打撃点推定に関する平均誤差を学習に用いるデータ数で比較した結果を図4に示す. 実験結果においては, ハンマにて打撃を加える際の位置の正確性の問題やセンサへのノイズ混入による計測誤差のため, 数値計算よりも全体的に推定精度は悪いが, 採用する学習データ数の増加に伴い推定精度は高くなっている.

次に, 学習データ数を25組に固定し, 入力ベクトルの次数に相当する採用ピーク数が推定精度に及ぼす影響を検討した. その結果を図5に示す. 入力データの次数に関しても, 数値計算及び実験結果ともに採用次数は多いほど推定精度が向上することが確認できる. これらのことより, ネットワークの学習はできる限り少ないデータ点で行うのが理想であるが, ユニット数を減らすことによる推定精度の劣化は, 入力ベクトルに採用するモード次数を拡張することである程度軽減でき, 要求する精度に応じて学習に用いるデータ点数と採用次数に適切な値を選択することで, はりの打撃点推定を良好に行えると考えられる.

3.3 金属バットの打撃点推定に関する検討

より実用的な打撃点推定の対象物として硬式野球用の金属バットを採用し, はりの場合と同様に打撃位置の推定実験を行った. 実験装置の概略を図6に示す. 金属バットは長さ約830mmであり, グリップのエンド部に近い位置に糸を巻き付け, 鉛直方向に吊り下げた. 加速度センサはバット先端から100mmの位置に取り付け, バット先端を原点としてグリップ部の方向へ10mmごとに打撃点を設定し, 合計51点の加速度応答を得る. RBFネットワークの構成, 学習方法及びデータの取り扱い, はりの場合と同様である.

中間層ユニット数及び学習データ数を7, 10, 15, 20及び25の5通りに設定し, 入力ベクトルに採用するモード次数を3, 5, 7次までの3通りとした場合の推定誤差を比較したものを図7に示す. はりの場合と比べると, 全体的に推定誤差は大きくなっており, 中間層ユニット数を増加させることによる誤差の減少の効果も, ユニット数10個以降は小さい. 一方で, 採用するモード次数を増やすことによる誤差減少の効果は有効であると判断できる. バットの場合における推定誤差に影響する主な要因として, 計測誤差及びモードによって減衰比が大きく異なることなどが考えられる.

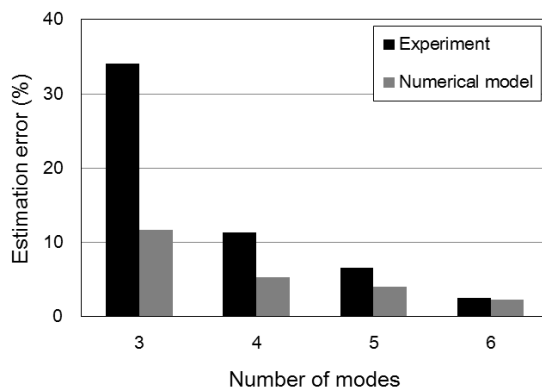


Fig. 5 Estimation error of impact point compared by the number of vibration modes




Fig. 6 Experimental setup of strike point estimation of a metal bat




Fig. 7 Estimation error for the case of metal bat (experiment)




Fig. 8 Simply-supported rectangular plate excited by an impact force at $x = a, y = b$

4. 2次元形状物体に対する打撃点推定の検討

本節では、2次元形状を有する構造物の例として板及びゴルフクラブフェース面を取り上げ、1次元の場合と同様にRBFネットワークを用いた打撃点の推定に関する検討を行った。まずは平板の曲げ振動を取り扱い、打撃によって得られる加速度応答及びその際の打撃位置情報をもとにRBFネットワークを学習させ、学習済みのネットワークを利用して未学習の打撃点推定精度を検討した。さらに、同様の打撃点推定に関する実験的検討をゴルフクラブに対して行った結果について示す。なお、はりの場合と同様の理由により、平板の境界条件は数値計算では周辺単純支持、実験では周辺自由とする。

4・1 矩形平板の曲げ振動に関する運動方程式

図8に示すような、 $x=a, y=b$ の位置にパルス力の作用する周辺単純支持長方形板の曲げ振動を考える。板の曲げ振動の方程式は次のように表される。

$$D\left(\frac{\partial^4 w}{\partial x^4} + 2\frac{\partial^4 w}{\partial x^2 \partial y^2} + \frac{\partial^4 w}{\partial y^4}\right) + \rho h \frac{\partial^2 w}{\partial t^2} = F\delta(x-a)\delta(y-b)\delta(t), \quad D = \frac{Eh^3}{12(1-\nu^2)} \quad (13)$$

ここで、 ρ は密度、 h は板厚、 ν はポアソン比、 E はヤング率、 D は板の曲げ剛性である。また、 w は板のたわみである。はりの場合と同様に、板の振動をモード展開して表すと次式となる。

$$w(x, y, t) = \sum_{i=1}^{\infty} \sum_{j=1}^{\infty} W_{ij}(x, y) \eta_{ij}(t) \quad (14)$$

ここでは周辺単純支持長方形板を扱うため、モード関数 W_{ij} を次のように表す。

Table 2 Specification of a plate model

Length l_y	240mm
Width l_x	170mm
Thickness h	3mm
Young's modulus E	69GPa
Density ρ	2.82kg/m ³




Fig. 9 Plate dimensions and configuration of estimation area in numerical model

$$w(x, y, t) = \sin \frac{i\pi x}{l_x} \sin \frac{j\pi y}{l_y} \sin \omega_{ij} t \quad (15)$$

式(15)において ω_{ij} は固有角振動数であり、次のように表される。

$$\omega_{ij} = \pi^2 \left(\frac{i^2}{l_x^2} + \frac{j^2}{l_y^2} \right) \sqrt{\frac{D}{\rho h}} \quad (16)$$

はりの場合と同様、モードの直交性を前提にモード座標ごとに運動方程式を分け、各々についてインパルス応答を求めて足し合わせるにより、板のインパルス応答に関する解が以下のように得られる。

$$w(x, y, t) = \sum_{i=1}^{\infty} \sum_{j=1}^{\infty} W_{ij}(x, y) \eta_{ij}(t) = \frac{4F}{\rho l_x l_y h} \sum_{i=1}^{\infty} \sum_{j=1}^{\infty} \frac{W_{ij}(a, b) W_{ij}(x, y)}{\bar{\omega}_{ij}} e^{-\zeta_{ij} \omega_{ij} t} \sin \bar{\omega}_{ij} t \quad (17)$$

4・2 平板の打撃点推定に関する検討

平板の打撃点推定では、表2及び図9に示すような縦240mm×横170mm、厚さ3mm、密度2.82kg/m³、ヤング率69GPaのジュラルミン板を対象とする。ただし、学習及び推定対象領域は図9にあるとおり、板の中央の縦60mm×横75mmの領域とした。さらに、この領域を15mm間隔の格子状に分割し、縦方向に5点、横方向に6点の合計30格子点を設定した。各々の格子点について得られた加速度応答曲線から、ピーク値の組み合わせを読み取って作成した合計30点のデータのうち、一部のデータをRBFネットワークの学習に用いる入力データとして選択し、その他を推定精度検証のためのテストデータとして利用した。学習点は、 x, y 方向それぞれ均一に分散するよう配慮した。計算に考慮するモード次数は6次までとし、インパルス力の大きさは0.1Nとした。加速度検出点は対象領域の右下の点からさらに右10mm、下5mmの位置に設定した。

長方形平板の打撃点推定問題の場合には推定すべき座標が x と y の2方向あるため、一つの同じ入力データから少なくとも2つの出力が得られるようRBFネットワークを構成する必要がある。ここで、格子状に分割された

2次元領域から幾つかの格子点座標を直交座標系で読み取り、それらを教師出力として採用すると、入力ベクトルは異なるにもかかわらず、ネットワークが出力すべき x もしくは y 座標の一方が重複する可能性が高い。いずれの学習データも相互に座標値が重複しないよう選ばば良いが、学習点が増えるほどそれは困難になる。そこで2次元問題に対しては、用いるセンサが1つの場合、センサが適切な位置にあれば打撃点までの距離 r 及び方向 θ は全て異なるものとなるので、図10のようにセンサ位置を原点とする極座標表現を用いることとする。出力層ユニット数を2個に設定し、各打撃点の極座標値 r, θ を学習させて極座標で出力した後、直交座標に変換して推定精度を評価する。なお、中間層ユニット数は1次元の場合と同様、学習に用いるデータ点数と同じとする。

まずは入力ベクトルに採用するモード次数を6次までに固定し、学習に用いるデータ点数を5, 10及び15個に設定して学習データ数が推定精度へ与える影響を考察した。位置推定誤差の取り扱いは1次元の場合と同様、式(12)に従うが、パラメータ L については x 座標方向の推定では $L=75\text{mm}$, y 座標方向では $L=60\text{mm}$ とし、テストデータ数 $N=15$ とした。数値モデル及び実験による検証結果の比較を図11に示す。学習に用いるデータ点数の増加に伴い、推定精度が高くなっていることがわかる。また、方向によって推定精度に差がみられ、 x 方向と比較して y 方向の推定精度が劣っているが、これは板の長辺方向に推定領域の短辺方向を設定したため、サンプル点間の距離は同じでも、長辺の x 方向と比較して応答の差異が小さくなるのが主要な要因と考えられる。




Fig. 10 Conversion from Cartesian to polar coordinates in two dimensional problem

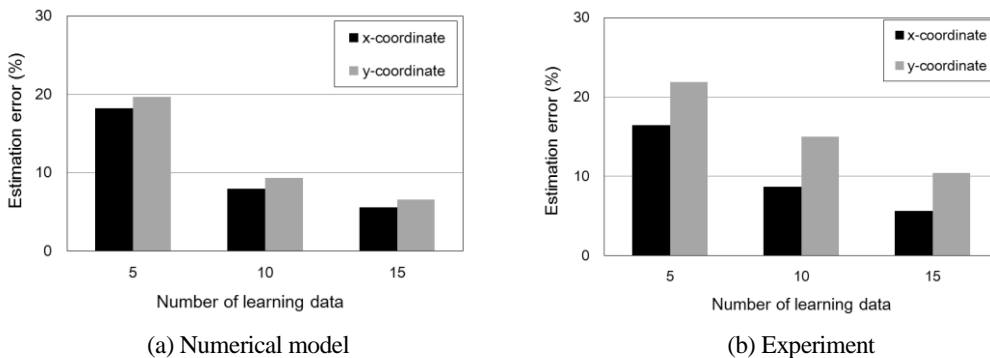


Fig. 11 Estimation error of impact point in respective directions compared by the number of learning data

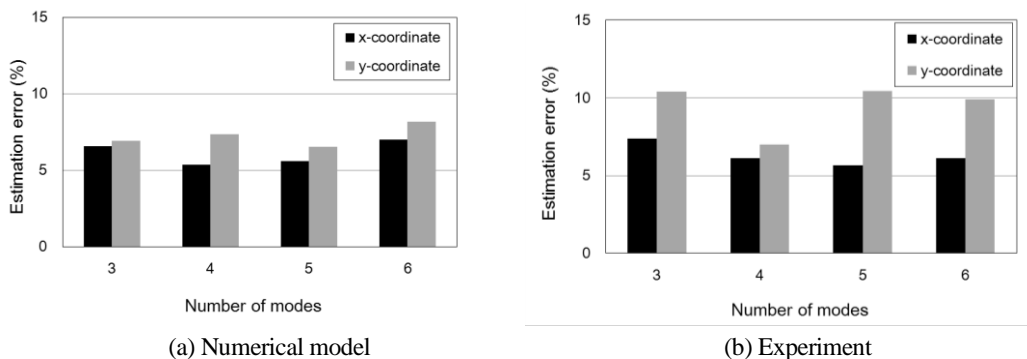


Fig. 12 Estimation error of impact point in respective directions compared by the number of modes

次に、学習点数を 15 点に固定し、平均誤差を採用モード次数別に表した結果を図 12 に示す。この場合には、採用次数を増やすことによる推定精度向上は見られなかった。推定対象領域を平板中央の一部領域に制限していることや、位相情報を無視して全て正の値で入力ベクトルを構成していること等が影響して、場所による学習データの差異が小さくなっていることが要因として考えられる。

4・3 ゴルフクラブの打撃点推定に関する検討

二次元問題に関する実用構造物の例として、ゴルフクラブの打撃点推定を取り上げた。実験装置の概要とゴルフクラブフェース面拡大図を図 13 に示す。フェース面中央の領域に 10mm 間隔で x 方向 3 点 y 方向 6 点の合計 18 の打撃点を設定する。加速度センサはシャフトとの結合部に近い、対象領域の左上に設置した。

あらかじめ取得した 18 点の加速度ピーク値の組み合わせから最大 9 点までを学習に用いるデータとして選択し、残りの 9 点を評価用のテストデータとして用いた。選択した学習点の配置を図 14 に示す。RBF ネットワークの入出力データの取り扱い、及び推定誤差の評価方法はこれまでの検討と同様である。

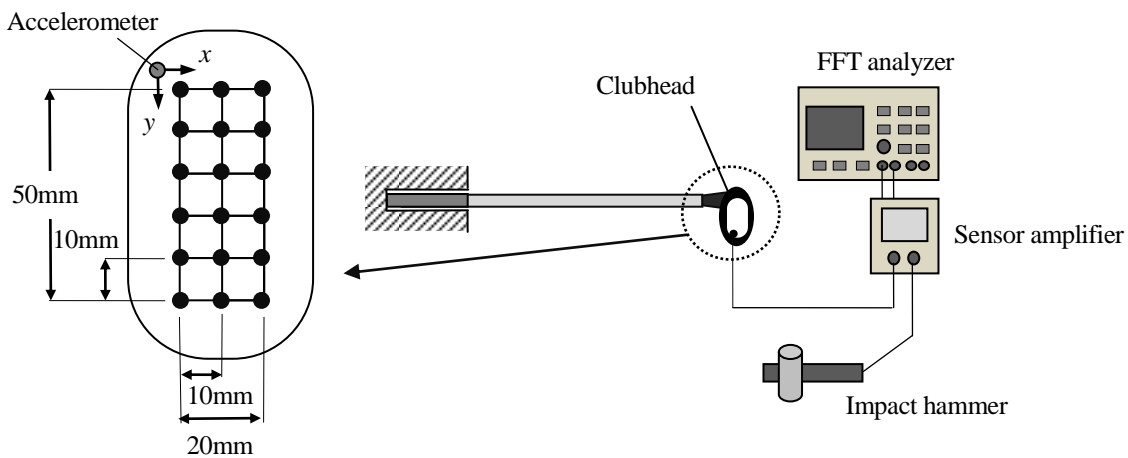


Fig. 13 Schematic of experimental setup for impact point estimation of golf club




Fig. 14 Arrangement of sample point for the learning of RBF network




Fig. 15 Estimation error of impact point for the golf club compared by the number of learning data




Fig. 16 Estimation error of impact point for the golf club compared by the number of modes

採用モード次数を5次に固定し、学習点数を3, 6及び9点に設定して推定精度を比較したものを図15に示す。学習に用いるデータ点の増加に伴い推定精度が高くなることはこれまでの検討と同様の傾向である。また、学習点数を9点に固定し、採用モード次数で推定誤差を比較した図16では、次数の拡張に伴う推定精度の向上が見られる。また、方向別にみるとy方向の誤差が相対的に小さい傾向を示しているが、これは対象領域の分割点数が2方向で異なることに加え、極座標で見たときの学習点の配置に関しても偏りがあることが主な要因であると考えられ、学習点配置を工夫すれば精度はある程度改善する可能性がある。

5. 結 言

本研究では、RBFネットワークを用いて、加速度応答の計測値に基づく構造物の打撃点を推定するシステムを構築し、基本的な構造要素としてはり及び板を、実用問題として野球用バット及びゴルフクラブを対象に、打撃点推定精度を数値的及び実験的に検証した。その結果、比較的少ないデータから打撃位置の推定が可能であるが、推定精度の向上には計測精度の向上以外に、RBFネットワークの学習データ数及び入力ベクトルに採用する振動モード次数が影響し、これらを増やすことで精度の改善がある程度まで可能であることが示された。ただし、特に二次元問題に対して過度に学習点を増やすことなく実用に供するレベルの推定精度を得るには、学習に用いるデータ点の選択やピーク値の抽出に採用する振動モード形状の選択が重要と考えられ、本手法を打撃点推定問題に適用する場合には、これらについて事前に詳細な検討を行う必要がある。また、本報告では単一の点に打撃が加わった場合のみを想定しており、今後は複数点へ同時に打撃力が作用した場合についても検討する予定である。

文 献

- (1) Doyle, J. F., "Determining the Contact Force During the Transverse Impact of Plates", *Experimental Mechanics*, Vol. 27 (1987), pp. 68-72.
- (2) Martin, M. T. and Doyle, J. F., "Impact Force Identification from Wave Propagation Responses", *International Journal of Impact Engineering*, Vol. 18, No. 1 (1996), pp. 65-77.
- (3) 中野議貴, 細矢直基, "力のモーメントを考慮した加振力の同定", 日本機械学会 Dynamics and Design Conference (2009), CD-ROM.
- (4) 河村庄造, 堀慎太郎, 感本広文, "機械・構造物に作用する外力の同定に関する研究 (外力作用位置が未知の場合の同定手法の提案)", 日本機械学会論文集 C 編, Vol. 74, No. 741 (2008), pp. 1122-1128.
- (5) 小野崎徹, 関根英樹, "予め力学的境界条件に関する情報がない矩形複合材積層板上に作用する点衝撃荷重の荷重位置・荷重履歴の同定方法", 日本航空宇宙学会論文集, Vol. 49, No. 568 (2001), pp. 141-149.
- (6) Ma, C. K., Chang, J. M. and Lin, D. C., "Input Forces Estimation of beam Structures By an Inverse Method", *Journal of Sound and Vibration*, Vol. 259, No. 2 (2003), pp. 387-407.
- (7) 岩田佳雄, 佐藤秀紀, 小松崎俊彦, "伝達関数測定によるはりの振動インテンシティ", 日本機械学会 2001 年度年次大会講演論文集, No. 01-1 (2001), pp.171-172.

- (8) 坂和正敏, 田中雅博, ニューロコンピューティング入門 (1997), pp.97-116, 森北出版.
- (9) 北山哲士, 山崎光悦, 荒川雅生, “RBF ネットワークの半径式の検討と提案”, 日本機械学会第 16 回設計工学・システム部門講演会講演論文集, No. 06-33 (2006), pp. 180-181.
- (10) 北山哲士, 山崎光悦, 荒川雅生, “RBF ネットワークと GRTA による統合的最適化 (サンプル点の配置に関する検討)”, 日本機械学会第 16 回設計工学・システム部門講演会講演論文集, No. 06-33 (2006), pp. 182-185.
- (11) Chen, S., Cowan, F. N. and Grant, P. M., “Orthogonal least Squares Learning Algorithm for Radial Basis Function Networks”, *IEEE Transactions on Neural Networks*, Vol. 2, No. 2 (1991), pp.302-309.
- (12) 持田英史, 飯國洋二, “RBF ネットワークを用いた到来波方向の適応推定”, 電子情報通信学会論文誌 A, Vol. J87-A, No. 9 (2004), pp. 1205-1214.