

ニューラルネットワークを用いた逆解析による梁の欠損同定

信州大学工学部 学生会員 ○瀨瀬恭敏
 信州大学工学部 正会員 小山 茂
 信州大学工学部 正会員 大上俊之

1. はじめに

近年，構造物に対して長寿命化対策が求められている．維持管理の手法として，土木分野ではAIの導入が進んでおり，その一つに画像処理によるひび割れ検出技術がある¹⁾．しかし，この技術は高い精度で外部の損傷を発見できるものの，内部損傷の発見は困難である．構造物の外部情報から内部の情報を予測する一つの手法として逆解析があるが，順解析に比較して複雑であり解の唯一性の問題等から適切な解を見出すのは難しい．

そこで本研究では，逆問題の解法にニューラルネットワークを適用することを試みる．ニューラルネットワークは人間の脳機能を模した並列計算処理であり，人間が発見できない複雑なデータの偏りやパターンを発見することに優れているため，こういった問題の解決に適している可能性がある．ここでは，欠損によって剛性の低下した梁を対象に，その振動特性からニューラルネットワークを構築し，剛性値を予測し精度について確認した．

2. ニューラルネットワーク

ニューラルネットワークは人間の脳機能を模した学習アルゴリズムであり，大きく分けて，図1のように入力層 I_i ，中間層 C_j ，出力層 O_k の3つの層から構成される．なお，中間層は必ずしも単層ではなく複数であっても構わない．各層にノードが存在し，隣接層の全てのノードと結合している．ここで用いられるデータは大きく分けて特徴量データと教師データの2種類がある．特徴量データ X_i は，ニューラルネットワークへの入力として使う測定可能な特性を示す説明変数であり，教師データ T_k は出力の正解を示す目的変数となる．入力された特徴量データは，重み w 付きで次の層へと伝搬され，最終的に出力層から予測値として出力される．ニューラルネットワークにおける学習は，この出力値と教師データとの誤差を最小にするように重みを決定することである．

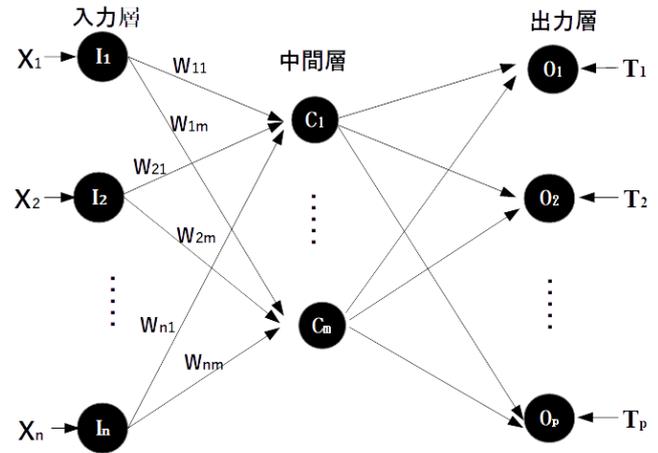


図1 ニューラルネットワーク

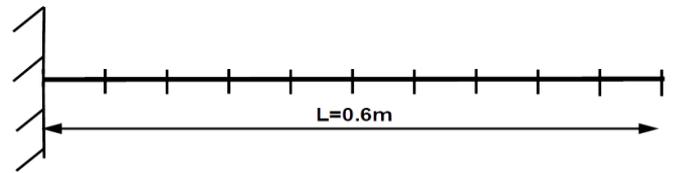


図2 解析対象

3. 解析対象

(1) 対象とする梁

本研究では，図2に示すような片持ち梁を対象として，梁を10の要素に等分割したときの各要素の平均的な剛性値を振動特性から求めることを試みる．梁の諸量として，論文²⁾を参考にして梁の全長を0.6[m]，断面積を $2.5 \times 10^{-3}[\text{m}^2]$ ，断面二次モーメントを $5.208 \times 10^{-7}[\text{m}^4]$ ，ポアソン比を0.3，質量密度を $7800[\text{kg} \cdot \text{m}^{-3}]$ とした．

(2) ニューラルネットワークの構築

本研究では，特徴量データとして固有振動モードと固有振動数を利用し，教師データとして各要素の剛性値を利用した．まず，最適なニューラルネットワークを構築するためのデータセットを得るために，FEMモデルの固有値解析によりある要素の剛性が低下している場合の固有振動モードと固有振動数を求

めた. 今回は精度確認のため, 剛性の低下が発生している箇所は複数でもよいが, その値はすべて同じであると仮定すると, 欠損パターンは 2^{10} となる. なお, 欠損していない要素のヤング率は 2.1×10^{11} [Pa] とした. 欠損要素の剛性は, ヤング率のみを 1.0×10^8 から 2.0×10^{11} の範囲で 38 通りに変化させたため, 学習に用いた総データ数は $1024 \times 38 = 38912$ である. ニューラルネットワークは入力層, 中間層 3 層, 出力層の 5 層構造とし, 入力層のノードは 11 節点すべての 6 次までの固有ベクトル 66 個と固有振動数 6 個で合計 72 個, 中間層のノード数は各層で 700 個とした. 出力層は 10 要素の各剛性を出力するため 10 個となる.

5. 解析結果

本研究では, 欠損要素のヤング率の値が欠損していない要素に比べて 15% 低下している 1.75×10^{11} [Pa] の場合に対して順解析を行い, その結果得られた固有振動モードと固有振動数を学習器に入力し, 元の順解析の入力を正解値として学習器の出力との比較を行った. また, 欠損箇所が何か所であっても予測可能であることを確認するため全ての欠損パターンについて予測を行った.

最初に, 1 箇所のみが欠損している場合を欠損パターン 1 として図 3 に示し, そのときの各要素における正解値に対する相対誤差を図 4 に示す. 相対誤差は全体的に 2% 程度となっており, 唯一の欠損要素である一番目の要素も 3% 程度の誤差に収まっている. 欠損箇所が 1 か所の場合は, 欠損要素がどこであっても, この程度の誤差に収まっていたため, 欠損の予測に問題はないと考えられる.

次に全体的に欠損がみられる場合として, 8 箇所が欠損している梁を欠損パターン 2 として図 5 に示し, そのときの相対誤差を図 6 に示す. こちらも全体的な相対誤差は 1~2% 程度に収まった. 欠損要素が複数ある場合でも, 高い精度で各要素の剛性値の予測が可能であると考えられる.

本研究のような, 欠損部の剛性値がすべて同じであるという仮定においては, 欠損箇所が幾つであっても予測可能であった. 今後は欠損箇所によって剛性が異なるような場合において, 予測可能な学習器の構築が課題となる.

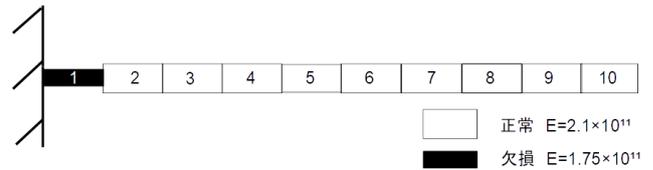


図 3 欠損パターン 1

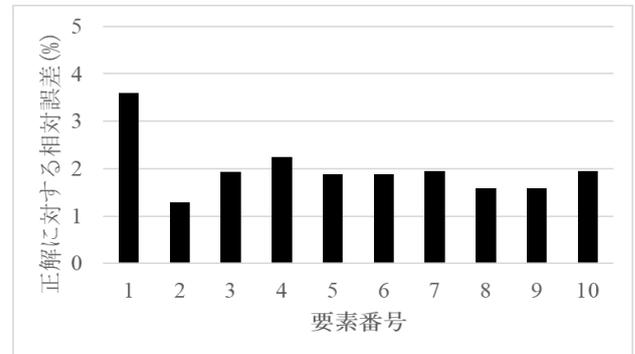


図 4 欠損パターン 1 の正解に対する相対誤差

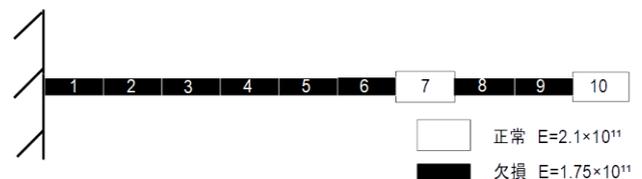


図 5 欠損パターン 2

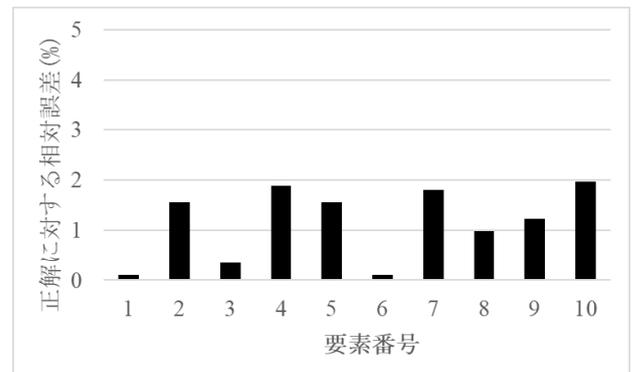


図 6 欠損パターン 2 の正解に対する相対誤差

参考文献

- 1) 藤田悠介・中村秀明・浜本義彦: 画像処理によるコンクリート構造物の高精度なひび割れ自動抽出, 土木学会論文集 F, Vol. 66, No. 3, 459-470, 2010.9
- 2) 吉川忍・松田聡浩・矢川元基: ニューラルネットワークに基づく逆問題解析法のための学習データ適切化法, 日本機械学会論文集 (C 編) 60 巻 580 号 (I 994-12) 論文 No. 94-0606