

## 学習ベクトル量子化ニューラルネットワークを用いた欠陥同定

小机 わかえ<sup>1</sup>・宮地 秀征<sup>1</sup>・小野 智洋<sup>2</sup>・高田 英明<sup>2</sup>

<sup>1</sup> 機械工学科 <sup>2</sup> 平成12年度機械工学科4年生

### Defect Identification Using Learning Vector Quantization Neural Network

Wakae KOZUKUE、Hideyuki MIYAJI, Tomohiro ONO and Hideaki TAKADA

#### Abstract

The Learning Vector Quantization(LVQ) neural network is applied to the defect identification problem for structures, which is important when constructing the mathematical model of structures. In this study the eigenmodes of a plate obtained from FEM and the location of the defect contained in that plate are used as the training data for neural network and by giving the unlearned input data to the trained network the position of the defect is identified. As a result the better accuracy is obtained compared to the case obtained by the backpropagation neural network commonly used in the various works.

Key Words :Neural Network, Structural Identification, Learning Vector Quantization

#### 1.はじめに

原子炉、運送機器、宇宙構造物などの機械設備の安全性には、非常に高い信頼性を保つことが要求され、点検可能な箇所では供用期間中に欠陥検出を施すことにより、高い信頼度の維持を図っている。従来は、実験などを繰り返すことにより、欠陥検出を行っていたが、それには莫大な時間と費用がかかり、現実的には有効ではない。近年では、コンピュータを利用した計算シミュレーション技術が発達てきて、その役割は年々大きくなっている。そのために、機械構造物などの安全性を確保するための欠陥検出方法の向上が期待される。

本報告では、薄板を有限要素法によりモデル化し、その中にヤング率が他の要素と異なる要素が一つだけ含まれるとし、その要素を欠陥と称す。そして、振動解析で得られた薄板の固有モードと、

欠陥要素の位置を学習データとして、学習ベクトル量子化ニューラルネットワークに学習させ、ネットワークに未学習データを入力して、欠陥要素の位置の同定を行うことを試みる。

最後に、同一の問題設定を前提として、従来からよく用いられているバックプロパゲーションニューラルネットワークによる同定結果と比較し、学習ベクトル量子化ニューラルネットワークがこの種の問題にたいしてより有効であることを示す。

#### 2. 学習ベクトル量子化(LVQ)の概要

ここでは、コホーネンにより提案された学習ベクトル量子化法について簡単に述べる。

##### 2.1 ベクトル量子化

ベクトル量子化法自体は古くから知られたパターン分類の手法で、パターン空間を有限個の参照ベクトルで量子化するものである。パターン空間

はモザイク状に分けられる。分割された各領域には参照ベクトルがあり、この参照ベクトルはその領域内に含まれるすべてのベクトルに対する最近接ベクトルとなっている。各領域に一つの参照ベクトルを対応させることにより、パターン分類が可能となる。ベクトル量子化法では、この参照ベクトルをいかにうまく選ぶかが問題である。

すなわち、ベクトル量子化とは、連続量のベクトル、あるいはとり得る値の非常に多いベクトルを、比較的少ない個数の代表ベクトルで近似することにより、データ圧縮を行う手法である。そこでは、入力空間を  $p$  個の領域  $\{D_1, \dots, D_p\}$  に分割し、各領域  $D_i$  内ではベクトルは類似しているとみなし、おのおのの領域にコードベクトルと呼ばれる 1 つの代表ベクトル  $\omega_i$  を割り当てる。コードベクトル全体の集合  $\{\omega_1, \dots, \omega_p\}$  をコードブックと呼ぶ。

## 2.2 学習ベクトル量子化法 (LVQ)

LVQ はベクトル量子化法を発展させたもので、参照ベクトルをニューロン間のシナプス結合に対応させ、教師あり学習を用いることによって適切な参照ベクトルを求める方法である。比較的簡単な学習アルゴリズムで高度なパターン分類ができるため、近年注目されている。この手法は、コホーネンの自己組織化モデルをパターン分類に適するように修正したモデルともいえる。

ベクトル量子化は、あるベクトル  $x$  だけで学習する教師なし学習であるが、学習ベクトル量子化 (LVQ) は、教師あり学習法である。学習ベクトル量子化の目的は任意のベクトル  $x$  がクラス  $C_1, \dots, C_k$  のいずれに属するかを決定するために、パターン認識のためのコードブック  $\{m_1, \dots, m_k\}$  を学習することである。コードブックの各コードベクトルは、どのクラスを表現するか、あらかじ

め決めてあるものとする。LVQ では、あるデータ  $x$  がどのクラスかを識別するのに、多数あるコードベクトル  $\{m_1, \dots, m_k\}$  の中で  $x$  にユークリッド距離の最も近い  $m_i$  を探し出し、 $m_i$  の属するクラスを  $x$  のクラスと判定する。LVQ には、学習方法の違いによって、LVQ1、LVQ2、LVQ3 と呼ばれる 3 種類の方法が、コホーネンにより提案されている。本報告では、の中でも、LVQ1 を用いた。

### 2.3 LVQ1

与えられたベクトル  $x(t)$  にもっとも近いコードベクトルを学習する。 $c$  を勝者のコードベクトル番号とする。すなわち、

$$c = \arg_i \min \left\{ \|x(t) - m_i(t)\| \right\}$$

このとき、次のように学習するのが LVQ1 と名付けられた学習方法である。

(1)  $x(t)$  と  $m_c(t)$  が同じクラスに属するとき

$$m_c(t+1) = m_c(t) + \alpha(t) [x(t) - m_c(t)]$$

(2)  $x(t)$  と  $m_c(t)$  が異なるクラスに属するとき

$$m_c(t+1) = m_c(t) - \alpha(t) [x(t) - m_c(t)]$$

(3)  $i$  が  $c$  以外のとき

$$m_i(t+1) = m_i(t)$$

$\alpha(t)$  は 0 と 1 の間の値をとる学習係数と呼ばれる。

## 3. 問題設定

図 1 に示す鉄を材質とする片持ち薄板を解析対象とする。この薄板を有限要素法でモデル化し、全要素のうち 1 つの要素だけが、他の要素とは異なるヤング率を持つとする。この部分を欠陥部と呼ぶ。有限要素法でのモデル化の条件を以下に示す。

### (1) 解析条件

シェル要素でモデル化し、固有モード解析を行う。要素数は 15、節点数は 24。

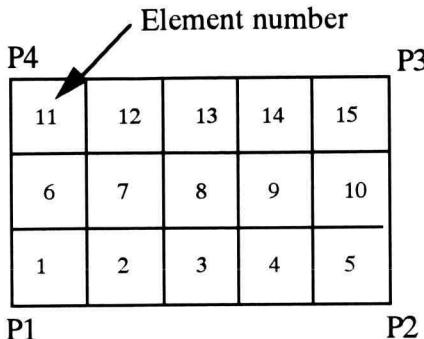


Fig.1 Plate Model for Analysis

## (2) 材料定数

欠陥部以外の要素のヤング率	$200 \times 10^9 Pa$
ポアソン比	0.3
質量密度	$8000 kg/m^3$
板厚	0.05m

## (3) 境界条件

辺 P1—P2 の X 方向、Y 方向の変位を拘束する。

欠陥部のヤング率は、他の要素のヤング率の 20%から 80%と設定する。有限要素法による振動解析で得られた低次の固有モードを入力データ、欠陥の位置を示すベクトルを出力データとしてデータの対を学習データとして、LVQ ネットワークを訓練する。訓練後のネットワークに未学習の入力データを示し、欠陥の位置を同定する。

## 4. 解析結果

## 4.1 解析条件

まず、板の一様なヤング率  $200 \times 10^9 Pa$  について、欠陥部についてはその 20%、30%、40%、60%、70%、80%の値とし、欠陥の位置も変化させ、計 90 レコードの学習データを作成する。固有モードとして、1 次から 3 次の、X 方向、Y 方向それぞれの成分を考え、計 6 組の学習データを作成する。この 6 組のそれぞれのデータにたいしてテストを行い、同定精度の比較を行う。

訓練における最大繰り返し数を 20000、学習比を 1.0 とし、計 6 組の学習データ、未学習データについてテストを行う。ここで、未学習データについては、欠陥部のヤング率を他の要素の 50%とした。また、学習比を 0.9、0.8 と変化させて訓練した場合についても同様のテストを行う。

次に、1 次の X 軸方向の固有モードを用いたデータについて、学習比を 1.0 とし、最大繰り返し数を 10000、20000、30000、40000 と変化させて、同定の精度を比較する。

## 4.2 数値実験の結果

まず、学習比を変化させたとき、学習比が、0.8、0.9、1.0 と大きくなるにつれて、同定の正解率が良くなることがわかった。また、学習データのテストが 90%弱成功していれば、未学習データの同定はほぼ 100%成功することがわかった。また、固有モードの次数については、3 次、2 次、1 次の順に、同定精度がよくなることが示された。すなわち、局所的な振動モードとなる高次のモードより、板全体の振動に関する低次のモードを用いた方が、同定に成功しやすいということがわかった。最大繰り返し数は、10000、20000、30000、40000 と変化させても同定の精度はほとんど変化しなかった。結局、1 次の固有モードを用いたときの、未学習データにたいする同定精度はほぼ 100%であった。

## 4.3 バックプロパゲーションニューラルネットワークを用いた場合との比較

3. と同一の問題設定で、同一の学習データでバックプロパゲーションネットワークを訓練した。その結果、板の各節点すべてにおける固有モードを訓練に用いると、過学習が起こり、同定結果の精度が低下する現象が見られた。1 次のモードを用いると、精度が良いという事実は、バックプロ

パゲーションネットワークでも同一であった。

以上から、構造同定のような欠陥の位置を分類するような種類の問題には、一般によく用いられる三層のバックプロパゲーションニューラルネットワークより、学習ベクトル量子化ネットワークの方が適しているのではないかと推察される。

### 5. 結論と今後の課題

学習ベクトル量子化ニューラルネットワークを用いて、薄板の欠陥の同定を試みた。学習データとして、1次の固有モードを採用することにより、精度良く欠陥の位置を同定できることができた。また、学習ベクトル量子化ニューラルネットワークは、この種の問題にたいしては、従来からよく用いられている多層のバックプロパゲーションニューラルネットワークより、適しているとの結論を得た。

今後の課題として、以下の項目が挙げられる。

- (1) 欠陥部が広範囲のとき、その部分を複数に分割し、ニューラルネットワークに学習させたときの同定を試みる。
- (2) 大規模なモデルでの欠陥位置の同定を試みる。
- (3) 教師なし学習を用いたニューラルネットワークの訓練を行ったときの同定を試みる。
- (4) LVQ2、LVQ3 等を用いた場合の、同定精度の比較を行う。

### 参考文献

- (1) T. Kohonen, "Self-Organizing Maps", Springer (1995)
- (2) M. Tanabe, Software Architecture for Effective Finite Element Structural Analysis on Microcomputer, ASME PVP Vol.177, pp. 99- 104. (1989)