

遺伝的アルゴリズムを用いた構造同定

小机 わかえ¹・宮地 秀征¹・加藤 究²・浜島 安男²

¹ 機械工学科

² 平成10年度機械工学科4年生

Structural Identification Using Genetic Algorithm

Wakae KOZUKUE¹, Hideyuki MIYAJI¹, Kiwamu KATO², and Yasuo HAMAJIMA²

Abstract

The combined method of Genetic Algorithm(GA) and neural network(NN) is applied to the defect identification problem for structures. As for NN, the most frequently used multilayer network and backpropagation algorithm are adopted. GA is utilized for minimization of the error function in backpropagation algorithm. For a simple plate structure, by using lower eigenmodes obtained from the finite element model, the identification of the defect element which has different value of Young's modulus from other elements is shown to be possible to some degree.

Key Words: Structural Identification, Genetic Algorithm, Neural Network.

1.はじめに⁽¹⁾

近年注目されている遺伝的アルゴリズム(GA)と呼ばれる手法は、ダーウイン的進化論の発想に基づいて生物進化の過程を抽象化したアルゴリズムである。同じように、実際の生物の原理を模倣したモデルに、やはり近年注目されている、ニューラルネットワーク(NN)がある。ニューラルネットワークは、脳を構成する神経回路網を抽象化し、いろいろな仕事を行わせようというものである。この二つの方法には多くの共通点がある。まず、両者とも、広い意味での学習・適応に関するモデルである。さらに、両者とも実際の生物に関わる原理の抽象化であることや、並列度の高い手法であることなどである。しかし、相違点もある。最も大きな相違点は、ニューラルネットワークは一個体の学習を扱っているのに対し、GAは、種の適応を扱っている点である。また工学的には、ニューラルネットワークは基本的に局所探索の方法であり、解空間上の現在点の近傍が次の探索点になる。これに対して、GAは大域サンプリングを中心とした手法であり解空間上に複数の探索点を設定する。次の探索点は選択淘汰、交配、突然変異などで決定される。一般的にGAでは、局所探索は行われず、探索点群の収束や突然変異にまかされる。

ここで重要なことは、二つの手法が相互補完的な特徴を有している点である。つまり、GAは種の適応として大域サンプリングを行い、ニューラルネットワークは個の学習として局所探索を行うというものである。

一般に、GAとニューラルネットワークの融合にはいくつかの方法が考えられる。それらは、(1)GAを使って重みとしきい値の調整、つまりニューラルネットワークの学習を行うもの、(2)GAを使ってニューラルネットワークの構造を決めるもの、(3)さらにそれらの融合、である。

GAとニューラルネットワークの融合に関する研究の中で、(1)ネットワークの構造の自動的発見、(2)GAを利用した重みの学習、は効率よく最適解の近傍までの学習を可能とし、局所解に捕まってしまう可能性を低減する、(3)実際の生物的過程と類推ができ、概念的に面白い、等の点から活発に研究が行われている領域である。

本研究では、このようなGAとニューラルネットワークを融合した手法を、機械構造物の欠陥同定問題に適用することを試みる。そのために、簡単な板構造物の動的な振る舞いを対象に数値実験を行い、GAによる欠陥同定が可能かどうかについて検討する。

2. 本研究で用いる GA とニューラルネットワークのアルゴリズムの概要⁽²⁾

2.1 ニューラルネットワークについて

本研究では、三層よりなる層状のフィードフォワードネットワークとバックプロパゲーションアルゴリズムを用いた。それらについて、簡単に述べる。

2.1.1 フィードフォワードニューラルネットワークについて

図1に、三層のフィードフォワードネットワークを示す。ネットワークは、入力層、隠れ層、出力の三層からなる。記号 R^d により d 次元空間のベクトル (x_1, x_2, \dots, x_d) を示すとすると、このニューラルネットワークは R^N 内のベクトル (x_1, \dots, x_N) を、 R^M 内のベクトル (y_1, \dots, y_M) に変換する。したがって、フィードフォワードネットワークは、 $y = F(x)$ と表すことができる。ここで、 $x = (x_1, \dots, x_N)$ 、 $y = (y_1, \dots, y_M)$ である。このように、 N 個の入力ノード、 H 個の隠れ層のノード、 M 個の出力ノードを持つネットワークにたいして、出力 y_k は次の式で与えられる。

$$y_k = g \left(\sum_{j=1}^H w_{jk}^0 h_j \right), \quad k = 1, \dots, M \quad (1)$$

ここで、 w_{jk}^0 は隠れノード j から出力ノード k への出力重みであり、 g は R^1 から R^1 への写像である。隠れ層のノード $h_j, j = 1, \dots, H$ の値は次で与えられる。

$$h_j = \sigma \left(\sum_{i=1}^N w_{ij}^1 x_i + w_j^T \right), \quad j = 1, \dots, H \quad (2)$$

ここで、 w_{ij}^1 は入力ノード i から、隠れノード j への入力重みで、 w_j^T は一定の値 1 を持つ入力ノードから隠れノード j へのしきい重みである。 x_i は入力ノード i での値で、 σ はいわゆるシグモイド関数で、以下のように与えられる。

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

式(1)の g は、シグモイド関数であってもよいし、線形関数でもよい。

2.1.2 バックプロパゲーションアルゴリズムについて

フィードフォワードネットワークにたいするもっとも一般的な学習アルゴリズムはバックプロパゲーション法である。入力ベクトルを $x = (x_1, \dots, x_N)$ 、望ましい出力ベクトルを $d = (d_1, \dots, d_M)$ とする。




図1 三層のネットワーク

重みの集合 W にたいして、フィードフォワードネットワークは出力ベクトル

$y(W) = (y_1(W), \dots, y_M(W))$ を与える。望ましい出力にたいする誤差 $e(W)$ は次のように与えられる。

$$\begin{aligned} e(W) &= \frac{1}{2} \|d - y(W)\|^2 \\ &= \frac{1}{2} \sum_{k=1}^M (d_k - y_k(W))^2 \quad (4) \end{aligned}$$

この誤差を、重みベクトル W について、最急降下法により最小にしようというのがバックプロパゲーション法である。

2.2 GA について

本研究で用いた GA のアルゴリズムの概要と用いる各パラメータを以下に示す。

2.2.1 GA のアルゴリズム

[ステップ0] 集団の初期化を行う。 N (N は偶数でなければならない) 個の染色体からなる集団をランダムに初期化し、各染色体の適応度を計算する。

[ステップ1] 交叉のために $N/2$ 対の個体を選択する。交叉のために個体を選択される確率はその適応度に比例するものとする。

[ステップ2] ステップ1で選択された $N/2$ 対について交叉を実行する。そのとき、小さな確率で突然変異をランダムに起こさせる。

[ステップ3] 新しい集団で、すべての個体の適応度を計算する。

[ステップ4] N 個の個体からなる古い集団と N 個の個体からなる新しい集団を合わせた $2N$ 個の個体の集団から、 N 個のより適応している個体を選

択する。

[ステップ5] 集団の適応度をスケールする。

[ステップ6] 集団内の最大の適応度を決定する。

|最大の適応度-最適な適応度| < 許容基準 なら停止する。そうでなければ、ステップ1に戻る。

2.2.2 GAのパラメータ

以上のアルゴリズムで用いる典型的なパラメータを以下に示す。

- (1) 集団の大きさ。長い染色体ほど、大きな集団を必要とする。
- (2) フィードフォワードニューラルネットワークにおける重みベクトルの成分の数値の精度を決定するビットの数。
- (3) 重みベクトルの成分の数。
- (4) 染色体の長さ。これは(2)×(3)に等しい。
- (5) 世代数あるいは繰り返しの上限値。
- (6) 交叉の確率。
- (7) 突然変異の確率。
- (8) 許容基準。収束判定をするための基準。

2.3 GAとニューラルネットワークの融合

本研究で行った手法は、上で述べた通り、ニューラルネットワークの学習に際して、重みベクトルをパラメータとする誤差最小化の部分にGAを適用するというものである。最急降下法に比較して、GAの方が優れているかどうかは議論の分かれるところであるが、実際に数値実験を行ったところ、比較的良好な結果が得られたので、以下にその概略を示す。

3.問題設定と学習方法

図2に示すような片持ち平板を対象構造物とする。平板の材質は鉄である(板厚0.05m、ヤング率 $E=200 \times 10^9 \text{ Pa}$ 、ポアソン比 $\nu=0.3$ 、質量密度 $\rho=8000 \text{ kg/m}^3$)。有限要素法⁽³⁾を適用するために、この平板を $3 \times 5=15$ の要素に分割する。各要素は基本的には同一の材料特性を持つとするが、その中の一つだけが他の要素とは異なるヤング率(元のヤング率の20%程度)を持つとし、それをここでは欠陥と呼ぶ。本研究では平板の固有モードを入力データとしてN.N.に与え、板に含まれる欠陥の位置を同定することを試みる。

まず欠陥を含む平板の低次の固有モードを有限要素法で求める。各節点での固有モードの値と、欠陥の要素番号を一組の学習データとし、欠陥の場所、そのヤング率を変えて、全部で90組の学




図2 解析に用いた平板

習データを作成する。それらを用いてGAによるNNの学習を行い、最適な重みベクトルを得る。学習済みのNNに、未学習のデータ(固有モード)を与えて、欠陥部の位置を出力データとして得る。

4.各種パラメータの設定


GAとNNによる解析に用いた各種パラメータの一覧を表1に示す。

表1 各種パラメータ


誤差のしきい値	0.000001
入力の数	24
隠れノードの数	100
出力の数	15
集団の大きさ	99
ビット長	16
最大繰り返し数	200
交叉の確率	0.6000
突然変異の確率	0.025
許容基準	0.01

5. 数値実験の結果


本解析では、欠陥要素にたいして出力値が1、その他の要素にたいして出力値が0になるように学習データを作成した。15種類の未学習データを入力したときの、出力を図3に示す。欠陥の位置は明確に1と0に分離はされなかったが、おおよその傾向は得られている。




欠陥要素 1




欠陥要素 2




欠陥要素 3




欠陥要素 4




欠陥要素 5




欠陥要素 6




欠陥要素 7




欠陥要素 8




欠陥要素 9



欠陥要素 10




欠陥要素 11




欠陥要素 12


図3 同定結果



欠陥要素 13



欠陥要素 14



欠陥要素 15

図3 同定結果(続き)

6.まとめと今後の課題

ニューラルネットワークと遺伝的アルゴリズムを融合した手法を、構造物の欠陥同定問題に適用した。GAによる学習では、計算時間が大幅に必要となったが、得られた同定結果は欠陥位置の大体の傾向を示すことがわかった。

今後は、GAで設定すべきパラメータの最適値の決定、最急降下法との計算時間や精度に関する性能の比較、別のタイプのニューラルネットワークへの応用などが課題として残されているといえる。

参考文献

- (1) 北野編、遺伝的アルゴリズム、産業図書 (1995)
- (2) S.T.Welstead, Neural Network and Fuzzy Logic Applications in C/C++, Wiley
- (3) M.Tanabe, Software Architecture for Effective Finite Element Structural Analysis on Microcomputer, ASME PVP Vol.177, pp. 99- 104. (1989)