

時刻歴応答にオートエンコーダを適用した 構造物の損傷検知に関する基礎的検討

三神 厚¹

¹ 正会員 東海大学教授 工学部土木工学科 (〒259-1292 神奈川県平塚市北金目 4-1-1)
E-mail: atsushi.mikami@tokai.ac.jp

本研究は、機械学習の方法を用いて構造物の損傷検知を試みたものである。教師なし学習のアルゴリズムであるオートエンコーダは、正常データのみから異常を検知する効果的な手法である。このアルゴリズムが時刻歴信号のどのような変化を「異常」と判断するのか、正弦波を用いた基礎的検討を通じ、理解を深める。検討結果を踏まえ、構造物の損傷検知に取り組む。非定常性を考慮した模擬地震動を用意し、1自由度系あるいは多自由度系モデルに対する入力とする。構造物の損傷は、モデルの剛性を損傷がない場合の50%に低下させることで便宜的に考慮する。損傷なしモデルの地震応答をオートエンコーダに学習させた後、位相を変化させた地震動に対する損傷あり、なしモデルの応答を用いて検証した結果、損傷検知の可能性を示すことができた。

Key Words: *autoencoder, machine learning, damage detection of structures, time history responses*

1. はじめに

わが国では、高度経済成長期に建設された膨大な数のインフラが老朽化を迎えている。それに対し、例えば、橋梁に関しては、国土交通省は、橋梁点検五ヵ年計画を策定し、5年に一度、近接目視により点検することを義務化した。技術者不足により思ったように進んでいない¹⁾。1つの解決策は、低廉化が進んでいるセンサーを構造物に設置して得られるデータの分析から、自動的に異常を検知する方法を用いることで、国土交通白書でもこのようなセンサーを使った技術による維持管理の効率化・高度化の重要性が述べられている²⁾。

データ分析の方法として、機械学習の適用が着目されている。そのためには、大量のデータを収集し、学習させることがキーとなる。機械学習は、教師あり学習と教師なし学習に大きく分けられる。例えば、画像認識の分野では、それぞれの画像とラベル（その画像が何であるか）を対応させながら、大量の学習データを用意することができるため、教師あり学習を適用しやすい分野である。一方、異常検知のような分野では、そもそも、異常データが少ないことから、教師あり学習が適用しづらいという問題がある。この欠点を補うため、正常データの学習のみから、異常を検知できる手法が期待される。

このようなことを可能にしたのが、オートエンコーダ (Autoencoder, 自己符号化器)³⁾で、教師なし学習のア

ルゴリズムの1つである。大量の正常データを学習させることで異常の検知を可能にする魅力的な手法である。具体的には、オートエンコーダとは、入力したデータと同じデータが出力側で再生されるように信号の特徴を学習させるネットワークのことで、次元削減を伴うことが特徴である。もとの正常な時系列を再生するようにウェイトを学習し、出力側で信号を再構成するため、信号に異常がある場合には再構成時に誤差を伴うことになる。

オートエンコーダを構造物の損傷同定に使った近年の研究としては、Pathirage et al.⁴⁾が挙げられる。オートエンコーダの再構成誤差を使って異常検知を行った取り組みとしては、Reddy et al.⁵⁾による Deep autoencoder を使った研究があり、それをもとに1段の autoencoder を使った取り組み⁶⁾も紹介されている。

本研究においてもこれらを参考に構造物の損傷検知を試みるが、まずは簡単な時刻歴信号（正弦波）にオートエンコーダを適用して、時刻歴信号のどのような変化を「異常」と判断するのか、そのしくみについて、数値実験を通じて基礎的検討を行い、理解を深める。検討結果を踏まえ、構造物の損傷検知を試みる。ここでは、簡単な構造物モデルに対し模擬地震動入力を与え、時刻歴応答信号を得る。構造物の損傷は剛性を低減することで模擬する。損傷なしモデルの地震応答をオートエンコーダに学習させた上で、位相を変化させた地震動に対する損




図-1 オートエンコーダ

傷あり、なしモデルの時刻歴応答を用いて、損傷検知の可能性について検討する。

2. オートエンコーダを用いた異常検知

オートエンコーダを時刻歴信号に適用するにあたっては、活性化関数の選択や隠れ層のサイズの決定など、データ解析上の設定を行う必要がある。ここでは、まずは簡単な数値実験を通じて、オートエンコーダが異常を検知する仕組みの理解を深める。

(1) オートエンコーダとは

入力したデータと同じデータが出力側で再生されるように信号の特徴を学習させるネットワークのことで、次元削減を伴うことが特徴である (図-1)。もとの正常な時系列を再生するようにウェイトを学習する。なお本研究では、オートエンコーダを適用するにあたり、MATLAB の Neural Network Toolbox と Statistics and Machine Learning Toolbox を用いた⁹⁾。

(2) 異常検知

前述のように、オートエンコーダでは、正常データを用いてネットワークが学習することになるので、入力側で時系列が正常である場合には、出力側でもとの波形が再構成されるので再構成誤差は小さくなる。一方、入力側の時系列に異常データを含む場合には、出力側でもとの波形の再構成が適切に行われず再構成誤差は大きくなってしま⁹⁾。本研究では、再構成誤差が大きくなった場合の時刻歴応答を異常データとして扱い、損傷検知の目安とする。なお、再構成誤差は、誤差の2乗を平均化したものの平方根として評価した。そのため、1 サンプル (あるデータの集合) あたり 1 つの評価となる。

(3) オートエンコーダの基本特性の検討：活性化関数の選択




図-2 正弦波を用いた検討 (1 サンプル=半波長)

簡単な時刻歴信号として、振幅 1、周期 1 秒の正弦波を、時間間隔 0.01 秒で 20 秒間用意する。すなわち、2000 個からなる正弦波の時刻歴データを用意する。このうち、最初の 10 秒を学習用に使い、0~20 秒の全体を検証用に用いる。学習用の時刻歴と検証用の時刻歴が同じものであるため、波形の再構成は当然、適切になされるものと考えられる。試みに、この正弦波の 50 個 (半波長分) のデータを 1 サンプルとし、オートエンコーダを適用してみる。すなわち、最初の 20 サンプルを学習させ、全 40 サンプルで検証を行うことになる。活性化関数として、多くの場合に用いられるシグモイド関数を用いる。

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

なお、隠れ層のサイズは 30 とした。

結果を図-2 に示す。図上段の青実線が学習データ、赤破線が再構成結果である。ほぼ再構成できていることがわかる。その結果、図下段のように、再構成誤差は小さい。この結果は、隠れ層のサイズを 50 (次元削減しない) にしても同様であった。

次に、サンプルの長さを半波長から 1 波長に変えて同じことを試みる。すなわち、1 サンプルを 100 データで構成し、最初の 10 サンプルを学習用、全 20 サンプルを検証用に用いる。ただし、隠れ層のサイズは 60 とした。

この場合の結果を図-3 に示す。この場合には、波形の再構成が正側には行われているものの、負側には正常に行われておらず、その結果、再構成誤差の値も大きくなっている。なお、隠れ層のサイズを 100 に変化させても、結果の改善は見られなかった。

そこで、デコーダ側の活性化関数を 0~1 を出力するシグモイド関数から、次に示す線形の関数に変更してみる。

$$f(x) = x \quad (2)$$




図-3 正弦波を用いた検討（1サンプル=1波長）




図-5 振幅の変化に関する検討




図-4 正弦波を用いた検討（1サンプル=1波長、活性化関数を線形に変更した場合）

すると、図-4に示すように、入力波形をほぼ再構成することができ、再構成誤差も小さい値となった。なお、1サンプルを半波長とした場合についても、活性化関数を線形伝達関数に変化させ計算してみると結果が改善された。

以上、見てきたように、同じ学習パターンが常に続くような特殊な場合にはこのようなことが起こることに留意する必要がある。

(4) オートエンコーダの基本特性の検討：振幅や周波数変化の検知

ここでは振幅や周波数の変化についての検討を行う。まず、周波数一定だが、10秒で振幅が変化する正弦波を考える。1サンプルを半波長とした場合について検討すると、図-5に示すように、10秒以降、学習したものと同一波形を再構成してしまい、結果として、再構成誤差が大きくなる。以上より、振幅の変化を異常として検知していることがわかる。なお、活性化関数として、シグモイド関数を用いている。




図-6 周波数の変化に関する検討

次に、振幅は一定のまま、正弦波の周波数が10秒の境に1Hzから2Hzに変化する場合を考える。結果を図-6に示す。なお、活性化関数としてシグモイド関数を用いている。再構成された波形の振幅は10秒以降で小さくなっており、その結果、周波数の変化が再構成誤差に影響を与えている。学習したデータと異なる周波数の信号を異常と捉えることがわかる。

(5) オートエンコーダの基本特性の検討：隠れ層サイズの検討

ここまでは、オートエンコーダの隠れ層のサイズを試行錯誤的に1サンプルのデータ数の60%としていた。エンコーダでは、この隠れ層のサイズに次元を削減することになるので、入力情報から本質的なものを取り出し、ノイズ等を削除するのに寄与することが期待される。そこで本節では、入力する正弦波にノイズを付加した場合の再構成結果を考え、再構成誤差と隠れ層サイズとの関係について検討する。

まず、振幅1、周波数が1Hzの正弦波を用意し、それにノイズの影響を付加する。ここでは、標準正規分布に従う乱数を発生させ、その大きさを正弦波信号の振幅の




図-7 ノイズの影響（隠れ層サイズ 30）




図-8 ノイズの影響（隠れ層サイズ 10）

20%に調整したものをノイズとして付加した。そして、時刻歴の前半分を学習用として用い、時刻歴全体を検証用に用いる。活性化関数にシグモイド関数を用い、隠れ層のサイズは 30 または 10 とした。結果を図-7、図-8 に示す。0～10 秒までを見ると、再構成された時刻歴はもとの信号に比べ、ノイズが少ないことがわかる。次に、10 秒以降を見ると再構成された結果は振幅が大幅に小さくなっており、結果として、再構成誤差が大きくなっている。図-6 と同様の傾向を示しており、ノイズの影響があっても、さほど異常検知に影響を及ぼさないことがわかる。

3. 構造物の異常検知のための基礎的検討

構造物のモデルとして、1 自由度系モデルと多自由度系モデルを用意し、それらの損傷検知を試みる。非正常性を考慮した模擬地震動を用意するにあたっては、Kanai-Tajimi スペクトルに基づいて作成された定常地震動に包絡関数掛けることで考慮した。




図-9 多自由度系モデル

(1) 構造物モデル

構造物のモデルを質量、剛性、減衰からなる 1 自由度系で用意する（図-9 左）。ここでは、固有振動数が 1Hz、減衰定数が 0.1 のモデルを損傷がない基本モデルとし、構造物の損傷を表現するにあたっては、剛性を低下させることで便宜的に表現する。ここでは、剛性の値をもとの値の 50%としたモデルを用意し「損傷あり」モデルとした。

より一般的な構造物として、多自由度系モデルについても検討した。ここでは、大崎⁷⁾を参考にして、各質量を 50ton、各層の剛性を 1800kN/cm とした 5 自由度系のモデルを用意することにした（図-9 右）。ここでは、機械学習による損傷検知の議論を複雑にしないため、剛性、質量の高さ方向変化は考えていない。減衰マトリクスについては、レイリー減衰を仮定し、1 次と 2 次のモード減衰定数をそれぞれ 5%とした。その上で、最下層が損傷しているものとし、1 自由度系の場合と同様、剛性の値をもとの値の 50%とした。なお、この多自由度系構造物の 1 次の固有振動数は約 2.72Hz である。

(2) 地震動の生成

Kanai-Tajimi モデル⁸⁾に基づき、パワースペクトルを規定し、位相角として $0 \sim 2\pi$ の間に一様乱数を与えることで、定常地震動を生成した。式(3)として Kanai-Tajimi




図-10 Kanai-Tajimi モデル




図-12 構造物の変位応答 (剛性 50%)




図-11 模擬地震動の一例




図-13 再構成誤差 (剛性 50%)

モデルを示すとともに、図-10 にモデルの一例を示す ($G_0 = 1$, $\omega_g = 2\pi$, $h_g = 0.3$ としている)。

$$G(\omega) = \frac{1 + 4h_g^2 \left(\frac{\omega}{\omega_g} \right)^2}{\left\{ 1 - \left(\frac{\omega}{\omega_g} \right)^2 \right\}^2 + 4h_g^2 \left(\frac{\omega}{\omega_g} \right)^2} G_0 \quad (3)$$

ここで、 G_0 はパワースペクトル密度関数の強度、 ω_g は卓越振動数 (円振動数)、 h_g はスペクトルのピークの鋭さを変化させるパラメータである。

地震動の非定常特性は、大崎⁹⁾によって与えられる包絡関数によって考慮した。ここでは、模擬地震動のマグニチュードは、7.3とした。図-11に Kanai-Tajimi モデルに基づいて生成された定常な地震波形 (上段) とそれに包絡関数を乗じて非定常性を考慮した模擬地震波形 (下段) の一例を示す。

4. 解析結果

(1) 1 自由度系モデル

地震動入力に対する構造物の変位応答を用いて、損傷を検知できるかどうか試みる。損傷なしモデルに地震動入力を与えた時の変位応答を求め、これを学習用に用いる (図-12 の上段)。一方で、損傷あり、損傷なしモデルに位相を変化させた模擬地震動を入力し、変位応答を求める (図-12 の中段、下段)。これらは、検証に用いる。青実線が検証に用いた構造物応答でオートエンコーダに対する入力である。赤破線が再構成された応答である。ここでは、損傷ケースとして、1 自由度系の剛性をもとの 50%に低下させ損傷を考慮したものである。図-12 下段より、損傷がない場合には、再構成結果はオートエンコーダに入力された構造物応答の信号を良好に再構成している。一方、図-12 中段より、損傷ありの場合には、再構成結果ともとの時刻歴との間には明らかな差異が見られる。

構造物の変位応答に対し、オートエンコーダを適用し、再構成誤差を評価したものが図-13 である。赤○が損傷ありモデルの再構成誤差、青△が損傷なしの再構成誤差である。なお、ここでは、時系列データは 0.01(s)間隔で

4096個のデータからなるが、そこからオーバーラップさせずに 100 個データを 1 サンプルとして取り出し、学習させたり、再構成誤差を評価したりしている。そのため、図-13 では 40 のサンプルについて再構成誤差の算出結果を表示している。なお、本研究では隠れ層の次元を 50、学習エポックの最大回数を 1000 回としている。

損傷ありモデルの方が損傷なしモデルに比べ、明らかに再構成誤差が大きくなっており、本研究の検討範囲であれば、比較的損傷を検知しやすい。

(2) 多自由度系モデル

次に、多自由度系を用いた検討を行う。3 章で考えた 5 自由度系モデルの 1 箇所損傷を設定し、構造物の地震応答から損傷を検知できるかどうか検討する。損傷は 1 次モードに対する影響が最も大きい第 1 層（最下層）のみに考えるものとし、剛性の値をもとの 50% に変化させる。なお、損傷検知に用いる信号としては、1 自由度系に対して与えたものと同様に模擬地震動を基部に入力した場合のモデル最上層の質点の時刻歴変位応答を考える。

図-14 に変位応答の結果を示す。損傷なしモデルに地震動入力を与えた時の変位応答を求め、これを学習用に用いる（図-14 の上段）。次に、損傷あり、損傷なしモデルに位相を変化させ作成した模擬地震動を入力し、変位応答を求め（図-14 の中段、下段）、検証に用いる。青実線が検証に用いた構造物応答でオートエンコーダに対する入力である。赤破線が再構成された応答である。なお、固有値解析の結果から、この場合の固有振動数は 2.32Hz である。

図-14 下段より、損傷がない場合には、再構成結果はオートエンコーダに入力された構造物応答を比較的良好に再構成している。一方、図-14 中段より、損傷ありの場合には、再構成結果ともとの時刻歴との間には損傷なしの場合より大きな差異が見られる。

構造物の変位応答に対し、オートエンコーダを適用し、再構成誤差を評価したものが図-15 である。赤○が損傷ありモデルの再構成誤差、青△が損傷なしの再構成誤差である。1 自由度系モデルと同様、40 サンプルについて再構成誤差を表示している。損傷ありモデルの方が損傷なしモデルに比べ、概ね再構成誤差が大きくなっており、検討を行った損傷レベルであれば、比較的損傷を検知しやすい。特に、地震動の主要動部分では、損傷検知モデルの方の再構成誤差が大きくなっており、地震応答のような非定常応答を用いる場合の構造物の損傷検知にあたっては主要動に対する構造物の応答区間を十分に信号に含めるなど、構造物の損傷を判断するための工夫が必要となる可能性がある。




図-14 構造物の変位応答（剛性 50%）




図-15 再構成誤差（剛性 50%）

5. まとめ

本研究では、機械学習の方法としてオートエンコーダを用いて構造物の損傷検知を試みた。教師なし学習のアルゴリズムの 1 つであるオートエンコーダは、正常データのみから異常を検知できる手法として大変効果的である。このアルゴリズムを構造物の損傷検知問題に適用するにあたり、まず、簡単な時刻歴信号（正弦波）に適用し、活性化関数や隠れ層の次元について検討するとともに、時刻歴信号の振幅や周期の変化を異常と捉えることなどを確認した。

基礎的検討の結果を踏まえ、構造物の損傷検知に取り組んだ。Kanai-Tajimi モデルに基づく定常地震動に地震動の包絡曲線をかけて非定常性を考慮した地震動を用意し、ここで考える 1 自由度あるいは多自由度振動系モデルに対する入力とした。構造物の損傷は、モデルの剛性を損傷がない場合の 50% に低下させることで便宜的に考慮した。得られた応答時刻歴のうち、損傷なしモデルの地震応答をオートエンコーダに学習させた後、位相を変化させた入力に対する損傷ありと損傷なしモデルの時刻歴応

答を用いて検証した。本検討を通じ、損傷検知の可能性を示すことができた。

謝辞：本研究は、JSPS 科研費（課題番号：19K04583）の助成を受けたものです。

参考文献

- 1) 国土交通省：道路の老朽化対策，
www.mlit.go.jp/road/sisaku/yobohozen/yobo1_1.pdf.
- 2) 国土交通省：新技術の活用と維持管理・更新の担い手の育成，平成 25 年度国土交通白書，2014.
<http://www.mlit.go.jp/hakusyo/mlit/h25/hakusho/h26/index.html>.
- 3) Hinton, G.E. and Salakhutdinov, R.R.: Reducing the Dimensionality of Data with Neural Networks, *Science*, Vol.313 (5786), pp.504-507, 2006.
- 4) Chathurdara Sri Nadith Pathirage, Jun Li, Ling Li, Hong Hao, Wanquan Liu, Pinghe Ni: Structural damage identification based on autoencoder neural networks and deep learning, *Engineering Structures*, Vol.172, pp.13-28, 2018.
- 5) Kishore K. Reddy, Soumalya Sarkar, Vivek Venugopalan and Michael Giering: Anomaly Detection and Fault Disambiguation in Large Flight Data: A Multi-modal Deep Auto-encoder Approach, *Annual Conference of the Prognostics and Health Management Society 2016*, Vol.7, pp.1-8, 2016.
- 6) MathWorks Japan：センサーデータ解析のためのニューラルネットワーク，2015.
<https://jp.mathworks.com/videos/neural-network-for-sensor-data-analysis-1505494780628.html>.
- 7) 大崎順彦：建築振動理論，彰国社，1996.
- 8) Tajimi, H.: A Statistical Method of Determining the Maximum Response of a Building Structure during an Earthquake, *Proceedings of the 2nd World Conference on Earthquake Engineering*, pp.781-797, 1960.
- 9) 大崎順彦：新・地震動のスペクトル解析入門，鹿嶋出版会，1994.

(Received ????)
(Accepted ????)

DAMAGE DETECTION OF STRUCTURES BY APPLYING AUTOENCODER TO TIME HISTORY RESPONSES

Atsushi MIKAMI

Deterioration of a large number of infrastructures constructed during the period high economic growth are serious problem in Japan. However, maintenance engineers are insufficient compared with the numbers of infrastructures. One of possible countermeasures for this problem is to use sensors and machine learning techniques to automatically detect structural damage. This paper attempts damage detection of structures by employing the autoencoder, which is an unsupervised machine learning algorithm. Stationary input motion is prepared based on Kanai-Tajimi model, and non-stationary characteristics of the input motion is considered by applying an envelop function to the stationary wave. The input motion is given to the SDOF and MDOF models. Structural damage is conveniently introduced by reducing the elastic modulus by 50%. An anomaly detected from reconstruction errors induced at the output layer of the neural network is considered as structural damage. After having the autoencoder learn the seismic responses of non-damaged model, responses from both damaged and non-damaged models, given an input motion of different phase, are examined. It was found that structural damage can be successfully detected by using the autoencoder.