

応答加速度記録を用いた CNN による木造住宅の地震時損傷度判定

Seismic Damage Assessment of Wooden Houses Using CNN with Response Acceleration Records

○岡田 寅杜*¹, 宮津 裕次*²
Toramori OKADA *¹and Yuji MIYAZU*²

*1 東京理科大学理工学研究科建築学専攻 大学院生
Graduate student, Tokyo University of Science

*2 東京理科大学理工学部建築学科 講師・博士(工学)

Junior Assoc. Prof., Tokyo University of Science, Dr. Eng.

キーワード：損傷度判定; 木造住宅; 模擬地震動; 拡張 NCL モデル; Convolutional Neural Network

Keywords: damage assessment; wooden house; simulated ground motion; ENCL model; convolutional neural network.

1. はじめに

地震時に木造住宅の損傷度を即座に判定することは、迅速な避難や救助の観点から有用である。近年では、高性能な MEMS 加速度センサーが開発されており、今後はコスト性が要求される木造住宅に対しても加速度センサーを設置できるようになることが期待される。さらに、LPWA に代表される無線通信技術も発展しており、加速度センサーで計測・分析したデータを即時に集約・共有することも可能となってきた。また近年注目が集まっている人工知能技術は幅広い分野で応用されており、手軽に利用することも可能になってきている。

本報告では、2 層木造住宅を対象に、機械学習の 1 つである Convolutional Neural Network (CNN) を用いて加速度データから建物の損傷度を推定・予測する方法を提案する。

2. CNN の概要

CNN とは機械学習の中でもディープラーニングの一種で、特に画像認識や音声認識の分野に用いられることの多い人工知能技術である。畳み込み層(Convolutional Layer)とプーリング層(Pooling Layer)、そして全結合層(Fully Connected Layer)を基本の 3 構成とするニューラルネットワークである。本報告では、大量の模擬地震動を用いた時刻歴応答解析の結果から、CNN により加速度と層間変形角の関係を学習し、観測地震動が入力された場合の損傷度、並びに層間変形角時刻歴を予測する。図 1 に CNN の概要図を示す。

3. 学習データの作成方法

3.1. 解析モデル

2 層木造住宅を想定した 2 自由度せん断質点系モデルを作成し、振動解析ソフトウェア OpenSees¹⁾により時刻




図 1 CNN の概要

歴応答解析を行う。せん断ばねの復元力特性には、構造用合板壁の繰り返し載荷実験で得られた荷重変形履歴を模擬する拡張 NCL モデル(以下、ENCL モデル)²⁾を用いた。解析モデルは 3 種類を想定し、1 層と 2 層の最大耐力を建物総重量と等しくしたモデル 1、最大耐力をモデル 1 の 1.25 倍としたモデル 2、最大耐力をモデル 1 の 1.5 倍としたモデル 3 の 3 種類とした。モデル 1 の弾性 1 次固有周期は 0.29 s であり、減衰は初期剛性比例型の 1%とした。解析モデルを図 2 に、ENCL モデルのパラメータを表 1 に、荷重変形履歴を図 3 に示す。

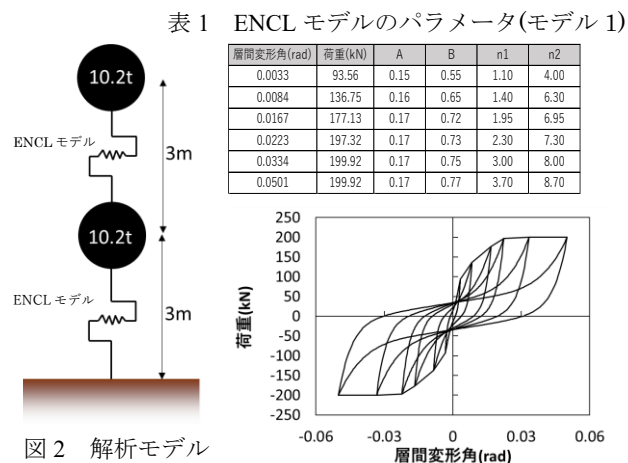


図 2 解析モデル

図 3 荷重変形履歴

3.2. 入力地震動

機械学習には大量の学習データが必要なため、時刻歴応答解析に用いる入力地震動には模擬地震動を用いる。模擬地震動としては、海溝型の地震動を想定した比較的広い振動数成分を有する地震動と、直下型の地震動を想定したパルス性の地震動の2種類を用いる。

3.2.1 海溝型地震を想定した地震動

定常不規則波形と包絡関数の積による式(1)によって作成した。

$$y = z(t) \cdot \frac{1}{2\pi} \int_{-\infty}^{\infty} H(\omega) S(i\omega) e^{i\omega t} d\omega \quad (1)$$

$S(i\omega)$ はホワイトノイズの見本関数のフーリエ変換とし、 $H(\omega)$ は地盤の伝達関数を想定して式(2)で与えた。

$$H(\omega) = \sqrt{\left(1 + 4h_g \frac{\omega^2}{\omega_g^2}\right) / \left(\left(1 - \frac{\omega^2}{\omega_g^2}\right)^2 + 4h_g \frac{\omega^2}{\omega_g^2}\right)} \quad (2)$$

h_g と ω_g はそれぞれ地盤の減衰定数と卓越円振動数である。 $z(t)$ は包絡線関数であり式(3)で与えた。

$$z(t) = \begin{cases} (t/5)^2 & 0 \leq t < 5 \\ 1 & 5 \leq t < 35 \\ \exp(-0.027(t-35)) & 35 \leq t \leq 120 \end{cases} \quad (3)$$

地盤の減衰定数は0.3~0.5の一様乱数、地盤の卓越円振動数は0.2~5 Hzの一様乱数とした。また、式(1)中の $S(i\omega)$ のパワースペクトル密度は等しくした。地震動の継続時間は120 sとして210波作成した。

3.2.2 直下型地震動を想定したパルス性地震動

パルス性地震動としては、速度の時刻歴波形が式(4)のように2波のRicker waveletの重ね合わせで表される波形を用いた。

$$y = \sum_{i=1}^2 V_i \left(1 - 2\pi^2 f_i^2 (t - t_i + t_m)^2\right) e^{-\pi^2 f_i^2 (t - t_i + t_m)^2} \quad (4)$$

V_i は振幅(m/s)、 f_i は振動数(Hz)、 $(t_i - t_m)$ は波形の中心時間(s)である。 V_i は0.1、 f_i は0.5~2.0の一様乱数、 t_i は3.5~4.5の一様乱数、 t_m は-2~2の一様乱数とし、継続時間は8 sとして3150波作成した。

3.3. CNN データセットの作成

作成した地震動の加速度波形について、振幅を1, 2, 3,

..., 10倍したものを入力地震動とした。よって、入力地震動の総数は(210+3150)×10=33600となる。時刻歴応答解析の数値積分法はNewmark β法(β=0.25)とした。学習に用いる入力データは4秒間の2階応答加速度データとした。出力データは、4章に示す分類問題では4秒間での最大層間変形角に基づく損傷度判定値(1/120rad以下は0、1/120~1/30radは1、1/30rad以上は2)とし、5章に示す時刻歴予測問題では4秒間の層間変形角の時刻歴波形とした。分類問題では、作成した全データセットから損傷度判定値ごとに同数のデータをランダムに取得し、そのうち90%を学習用、10%を評価用として用いた。学習にはSONYのNeural Network Console³⁾を使用した。推論実行に用いるデータは、気象庁および防災科学技術研究所の地震計で記録された計測震度5.5以上の259波の実地震動を用いた応答解析により、学習・評価用データと同様に作成したものを使用した。

4. 分類問題の学習・評価結果

4章では、CNNの出力を4秒間の層間変形角の最大値から設定される損傷度として分類問題を構成し学習を行った。4.1ではモデル1の学習データセットのみを用いることで、2層木造住宅に対して応答加速度データから建物の損傷度をどの程度予測できるかについて示し、4.2では3種類のモデルからなる学習データセットを利用することで、耐力の異なる木造住宅に対するCNNの適用性を検証する。

4.1. モデル1の損傷度判定

分類問題に対して、モデル1の学習データセットのみによる学習によって得られる評価結果を示す。30000個のデータを用意し、そのうち90%を学習、10%を評価に利用した。表2に学習に使用したCNNのモデルの構成を示し、表3に分類問題の評価結果を示す。図4左に学習曲線を示す。評価結果より、学習段階ではAccuracyで約88%の精度を得ることが出来ている。判定値別では判定値1(1/120~1/30rad)の評価結果が低い。これは他の判定値と比べ1/120~1/30radの間では幅広い層間変形が含まれていること、また判定値0,2と1の境界付近の値が誤判定されやすいことが原因と考えられる。実地震動による推論実行の傾向は学習時の評価結果と類似しているが、小さい判定値に誤判定されていることが多く、残留変形を考慮できていないことが原因と考えられる。

4.2. モデル1~3の損傷度判定

学習モデルは表2と同じとし、学習データにはモデル1~3を同数混ぜたデータセットを利用して、幅広い建物耐力に対応できるモデルの構築を試みる。データセットの内訳はモデル1~3それぞれに対して30000個のデータ、(各

判定値で 10000 個のデータ) 用意し、合計 90000 個のデータとする。そのうち 90%を学習用、10%を評価用とした。

図 4 右に学習曲線を、表 4~6 に各モデルの評価結果を示す。4.1 の結果と比較すると、学習曲線は早い段階で横ばいとなった。評価結果では、モデル 1 の評価結果は 4.1 の結果と同様の傾向となり、学習時の評価結果では全体の精度が 2%ほど低下した。モデル 2, 3 の評価結果では、各判定値の傾向や全体の精度の関係は類似の結果となったが、モデルの耐力が高くなるに従って精度が低下することが分かった。モデル 3 の判定値 2(1/30rad 以上)のデータが少ないことがその原因と考えられる。

表 2 分類問題の CNN モデル

Name	Outmaps	Outshape	KernelShapes	Padding	Stride
Input		400,1			
Transpose		1,400			
Reshape_2		1,1,400			
Convolution	16	16,1,400	1,3	0,1	1,1
ReLU					
MaxPooling	16	16,1,200	1,2	0,0	1,2
Convolution_2	10	10,1,200	1,3	0,1	1,1
ReLU_2					
MaxPooling_2	10	5,1,100	1,2	0,0	1,2
Convolution_3	5	5,1,100	1,3	0,1	1,1
ReLU_3					
MaxPooling_3	5	5,1,50	1,2	0,0	1,2
Affine		20			
ReLU_4		20			
Affine_2		3			
SotmaxCrossEntropy		1			

表 3 評価結果 (左: 学習時、右: 推論実行)

正解値 \ 推定値	学習時				Accuracy	Precision	Recall	F-Measures
	0	1	2	Recall				
0	919	77	4	91.9%	88.4%	91.8%	71.5%	71.5%
1	52	844	104	84.4%				
2	2	108	890	89.0%				
Precision	94.5%	82.0%	89.2%	Accuracy	Precision	67.0%	63.7%	91.8%
F-Measures	93.2%	83.2%	89.1%	88.4%	F-Measures	79.9%	59.0%	72.9%




図 4 学習曲線 (左: モデル 1 のみ、右: モデル 1~3 の混合)

表 4 モデル 1 の評価結果 (左: 学習時、右: 推論実行)

正解値 \ 推定値	学習時				Accuracy	Precision	Recall	F-Measures
	0	1	2	Recall				
0	926	72	2	92.6%	86.8%	88.3%	71.8%	71.8%
1	75	802	123	80.2%				
2	3	122	875	87.5%				
Precision	92.2%	80.5%	87.5%	Accuracy	Precision	67.8%	65.2%	88.3%
F-Measures	92.4%	80.4%	87.5%	86.8%	F-Measures	80.1%	60.1%	72.6%

表 5 モデル 2 の評価結果 (左: 学習時、右: 推論実行)

正解値 \ 推定値	学習時				Accuracy	Precision	Recall	F-Measures
	0	1	2	Recall				
0	898	96	6	89.8%	85.7%	87.7%	74.7%	74.7%
1	78	797	125	79.7%				
2	14	109	877	87.7%				
Precision	90.7%	79.5%	87.0%	Accuracy	Precision	72.5%	69.3%	86.0%
F-Measures	90.2%	79.6%	87.3%	85.7%	F-Measures	83.1%	67.8%	71.0%

表 6 モデル 3 の評価結果 (左: 学習時、右: 推論実行)

正解値 \ 推定値	学習時				Accuracy	Precision	Recall	F-Measures
	0	1	2	Recall				
0	890	101	9	89.0%	85.5%	88.8%	71.0%	71.0%
1	93	787	120	78.7%				
2	19	93	888	88.8%				
Precision	88.8%	80.2%	87.3%	Accuracy	Precision	65.6%	67.5%	89.5%
F-Measures	88.9%	79.5%	88.0%	85.5%	F-Measures	79.0%	63.0%	67.8%

5. 時刻歴応答の予測


5.1. モデル 1 の層間変形角時刻歴の予測

5 章では出力を層間変形角時刻歴として、時刻歴波形の予測を行う。本節では、モデル 1 の学習データセットのみによる学習によって得られる時刻歴応答の予測結果を示す。30000 個のデータを使用し、90%を学習、10%を評価に使用した。表 7 に学習に使用した CNN のモデル構成を図 6 左に学習曲線を示す。

図 5 には、実地震動による推論実行の結果を示す。各損傷度から 1 つの結果を例示している。正解と CNN によって予測されたデータの二乗平均平方根誤差 (RMSE) を図中に示す。小変形から大変形まで、CNN による推定結果は正解の周期特性と位相特性を概ね模擬できているが、局所的な差は認められる。

表 7 時刻歴予測の CNN モデル

Name	Outmaps	Outshape	KernelShapes	Padding	Stride
Input		400,1			
Reshape_2		1,400,1			
Convolution	16	16,400,1	5,1	2,0	1,1
HardTanh					
Convolution_2	10	10,400,1	5,1	2,0	1,1
HardTanh_2					
Convolution_3	1	1,400,1	5,1	2,0	1,1
Affine		400,1			
HardTanh_3		400,1			
SquaredError		400,1			



(a) 1/120rad 以下の例




図5 モデル1の予測結果

5.2. モデル1~3の層間変形角時刻歴の予測

本節では、4.2と同様にモデル1~3の学習データを使用して、幅広い建物耐力に対応できるCNNモデルの構築を試みる。CNNモデルは表7と同じとし、4.2と同様の構成でデータセットを作成した。図6右に学習曲線を示す。図7~9に各モデルに対して行った実地震動による推論実行の結果を各判定値から一例ずつ示す。




図6 学習曲線(左:モデル1のみ、右:モデル1~3の混合)

図6の学習曲線からは、学習データ数の多いモデル1~3の学習においてエラーが大きくなっていることが分かる。時刻歴の予測結果ではCNNによる予測結果が正解を概ね模擬できているが、局所的な差が認められる結果となった。RMSEはモデルによる差は少なく、また、5.1の結果と比較しても傾向の違いは見られなかったが、予測する応答変形の増大に伴ってRMSEも大きくなることが分かった。

6.まとめ

判定値分類問題では、推論実行の精度は約70%となった。時刻歴応答の予測では、建物耐力や応答の大きさによって推定精度にばらつきはあったものの、正解を概ね模擬できる結果となった。

[参考文献]

- 1) OpenSees, <https://opensees.berkeley.edu/>, 参照 2020.10.1
- 2) 松永裕樹, 宮津裕次, 曾田五月也: 木造軸組耐力壁/非耐力壁の汎用モデル化手法に関する研究, 日本建築学会構造系論文集, 第74巻, 第639号, pp.889-896, 2009.5
- 3) SONY: Neural Network Console, <https://dl.sony.com/ja/>, 参照 2021.2

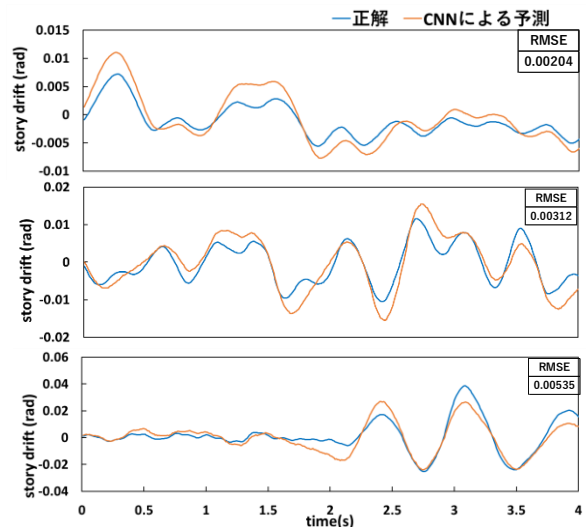


図7 モデル1の予測結果(上:~1/120rad、中:1/120rad~1/30rad、下:1/30rad~)




図8 モデル2の予測結果(上:~1/120rad、中:1/120rad~1/30rad、下:1/30rad~)




図9 モデル3の予測結果(上:~1/120rad、中:1/120rad~1/30rad、下:1/30rad~)