機械学習を用いた地震発生時の建物使用可能性の評価に向けた基礎的検討

Fundamental Study for Assessing Building Usability after an Earthquake based on Machine Learning Technique

22WM1311 荻野　律　　指導教員 丸山　喜久
Ritsu Ogino　　劉　ウェン

SYNOPSIS

In this study, we attempted to construct a damage discrimination model by machine learning of response acceleration time histories obtained from acceleration sensors installed in buildings, as a method for efficiently and quickly identifying damage states of wooden houses after an earthquake. First, we performed a number of seismic response analyses of a wooden house model to calculate the response acceleration time histories and response plasticity ratios, which were used as training data for machine learning. Then, Long Short-term Memory (LSTM) network and a one-dimensional convolutional neural network (1D CNN) were employed, and the obtained results were compared to construct an optimal discriminant model.

1. はじめに

地震災害による被害を抑えるには，地震発生直後に速やかに適切な避難行動をとることが有効な手段の一つであるといえる．一方で，災害時に活用される避難所の数は十分であるとは言えない．内閣府 [1]によると，日本の総人口約 1 億 2,300 万人に対し，全国の指定避難所の数は 7 万 5,895 カ所，福祉避難所の数は 2 万 2,579 カ所となっており，大規模災害発生時に多くの住民が一度に避難所に駆け込めば収容人数を超える恐れがある．以上のことから，近年では災害時に自宅で避難生活を送る在宅避難が注目されているが，避難所に逃げるべきか在宅避難をするべきかは明確な指針があるわけではなく，住民自身が家屋の損傷状況や余震による倒壊危険性を迅速かつ冷静に判断しなければならない．

このような背景から，近年では建物の被害状況の判別を目的として，構造ヘルスモニタリング技術（以下 SHM）の活用が検討されている．SHM は，建物や地表に設置した加速度センサ等で計測される振動データを用いて，構造物の損傷の有無や程度を診断する技術である．ただ，この手法は解析に長い時間を要することや，システム導入におけるコストの大きさから，地震発生直後の迅速な損傷評価や，一般住宅向けの適用・普及には不向きなこともある．

以上のことから本研究では，建物の被害状況の診断や，避難判断の支援をより迅速かつ効率的に行うことを目指し，木造建物に取り付けた加速度センサから得られる応答加速度の時刻歴波形から，建物の損傷状況を評価する機械学習モデルの構築を試みる．具体的には，木造建物を想定した 1 質点系モデルを用いて，地震応答解析を多数行い，その結果を機械学習に用いる．応答加速度の時刻歴波形から，応答塑性率に基づく被害区分を推定する被害判別モデルを構築することを目的とする．

2. データセットの作成

本章では，実地震における地表面加速度記録を用いて木造建物モデルの地震応答解析を行い，応答加速度の時刻歴波形と応答塑性率を算出する．この解析を多数実行し，機械学習の学習データとして用いる．

(1) 使用する地震記録

地震時の加速度波形から建物損傷状況を評価するには，幅広い適用性を有する被害判別モデルを構築することが重要であると考え，多数の地震時の観測記録を応答解析に使用した．具体的には，2000 年 10 月に発生した鳥取県西部地震から，2023 年 6 月に浦河沖を震源として発生した地震までの 26 地震から得られた 937 記録を使用する．地震観測記録は，防災科学研究所の K-NET や KiK-net[2]から取得した地表面加速度の観測記録（EW・NS 成分）を使用する．

(2) 木造建物モデルの地震応答解析

応答解析に用いる木造建物モデルは星ら [3]を参考にした．木造建物を対象とした 1 質点系モデルで，建物の初期剛性の固有周期と降伏震度の関係は，**図-1** に示すような神奈川県 [4]が用いたものに基づき，復元力特性は**図-2** に示すような 2 段階バイリニア型とした．この木造建物モデルに取得した地表面加速度記録を入力し，応答加速度の時刻歴波形と応答塑性率μを算出する．　応答塑性率は式(1)のように，

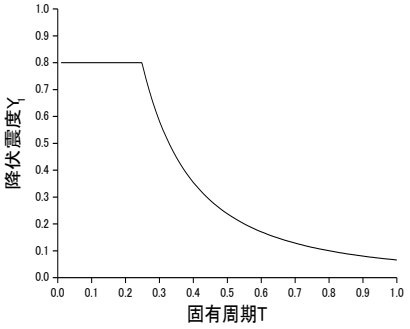

図-1　初期剛性の降伏震度と固有周期の関係

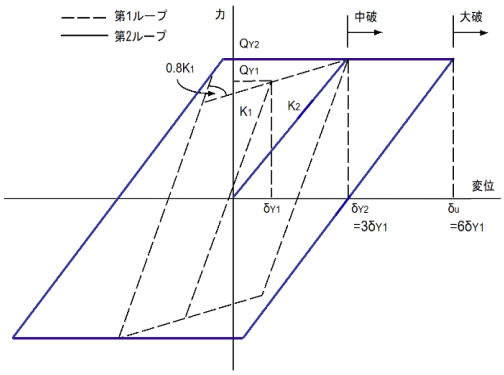

図-2　木造建物モデルの復元力特性

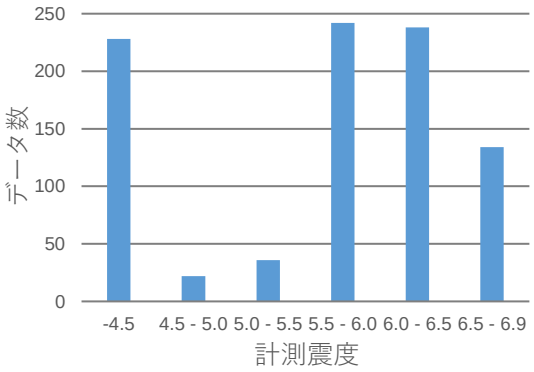

図-3　スケーリング後の観測記録に対する計測震度の内訳

建物モデルの最大応答変位δ_uを降伏変位δ_{Y2}で除して算出する．

$$\mu = \frac{\delta_u}{\delta_{Y2}} \tag{1}$$

木造建物の被害区分は，神奈川県[4]を参考に，$\mu < 1$のものを無被害(クラス 1)，$1 \leq \mu < 2$のものを中破(クラス 2)，$2 \leq \mu$のものを大破（クラス 3）としてラベル付けした．本研究では，各クラス 300 サンプルずつ，計 900 サンプルからなるデータセットを用意し，訓練用データ・検証用データ・テストデータにそれぞれ 6:2:2 の割合で分割した．

なお．本研究では地表面加速度波形に対してスケーリング(1 倍～24 倍)を行い木造建物モデルに入力することで，学習データの拡張を行った．スケーリング倍率は，スケーリング後の地表面加速度に対して算出した計測震度が 6.9 以下となるように設定した．スケーリング後の計測震度毎の学習データ数の分布を**図-3** に示す．

また，本研究で機械学習に用いる応答加速度波形は，解析時間短縮のためピーク値前後でサンプル長が 8000（サンプリング周波数 100 Hz × 80 s）になるように切り取って機械学習の入力データとした．

3.　機械学習による被害判別モデルの構築

応答加速度の時刻歴波形の機械学習を行い，木造建物の損傷状態の予測モデルを構築した．機械学習手法には Recurrent neural network（RNN）の拡張として提案された Long Short-term Memory（LSTM）ネットワーク，1 次元畳み込みニューラルネットワーク（1D CNN），さらにそれらを組み合わせたモデル（1D CNN＋LSTM）を使用し，精度を比較した．

(1)　LSTM ネットワークの概要

LSTM ネットワークは，深層学習の一種である RNN から派生したアルゴリズムである．RNN は，動画や音声，文章などの時系列データの処理に適したニューラルネットワークの一種である．入力データに対して前の時刻の中間層における出力を，次の時刻の入力と合わせて学習することで，時系列情報を保持できる．一方で，データ量が増えると過去のデータに対する重みが発散・消失し，過去の情報をうまく保持できなくなる勾配消失問題が生じるという弱点があった．これに対して LSTM ネットワークでは，RNN の中間層を，記憶セル・入力ゲート・出力ゲート・忘却ゲートから構成される LSTM ブロックに置き換えることによりこの問題を解決している．これにより，音声認識における発話の始まりから終わりまでの文脈の理解や，自然言語処理における文章全体の構造把握など，時系列データに対して RNN よりも長期的な依存関係を考慮することができる[5]．

(2)　1D CNN の概要

1D CNN は CNN の一種で，主に一次元の入力データに対して時間軸方向に畳み込み演算を行うアルゴリズムであり，音声認識などの時系列データの処理に使用されることが多い．基本的には通常の CNN と同様の構造となっており，畳み込み層で入力データの特徴を抽出し，プーリング層で圧縮をする工程を繰り返す[6]．

LSTM ネットワークは，入力データの長期的な特徴を学習するために複数のゲートを有する構造を採用していることから，パラメータ数が多くなり計算コストが大きくなるという欠点がある．一方，1D CNN は長期的な特徴を考慮することには向いていないが，入力された一次元データの局所的な特徴を抽出することに特化しており，計算コストも小さい．

(3)　1D CNN+LSTM の概要

前述のように，LSTM ネットワークと 1D CNN は時系列データに対して，それぞれ異なる種類の特徴を抽出することから，それらを組み合わせることでモデルの表現力が向上し，より高い精度が期待できる場合がある[7]．

LSTM 層よりも前に畳み込み層を配置することで，入力データの局所的特徴を抽出した上で長期的な依存関係を学習することを期待した．さらに，プーリング層で情報が圧縮された状態で LSTM 層に入力されるので，LSTM 単体で学習を行う場合と比較して計算コストの削減も可能になると考えた．

(4)　ハイパーパラメータの設定

各モデルのハイパーパラメータチューニングには，PrefferdNetworks 社が公開しているハイパーパラメータの自動最適化フレームワークである Optuna を使用する．

Optuna は，ベイズ最適化アルゴリズムを利用することで，過去の試行結果を考慮しながら目的関数を最大化もしくは最小化するハイパーパラメータの組み合わせを効率的に探索することができる．

本研究では，目的関数を検証データに対する損失関数値（クロスエントロピー誤差），最適化の試行回数を 500 回，epoch 数を 500，バッチサイズを 30 に設定し，探索を行う．最適化を行うハイパーパラメータとその探索範囲を**表-2** に，探索結果から構築した各モデルのネットワーク構造を**図-4**～**図-6** に示す．

表-2　ハイパーパラメータの探索範囲

	LSTM	1D CNN	1D CNN+ LSTM
中間層の数	1～6	1～6 (Conv1D+ MaxPooling)	1～6 （合計）
Conv1D 層の フィルタ数	—	32～1024	
LSTM 層の ユニット数	32～1024	—	32～1024
ウィンドウ サイズ	—	10～100	
全結合層の ユニット数	32～1024		
Dropout 率	0.0～1.0		
最適化関数	Adam / SGD		

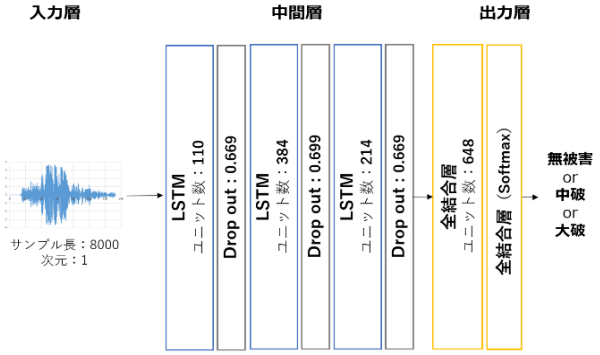

図-4　LSTM ネットワークの概要

図-5　1D CNN の概要

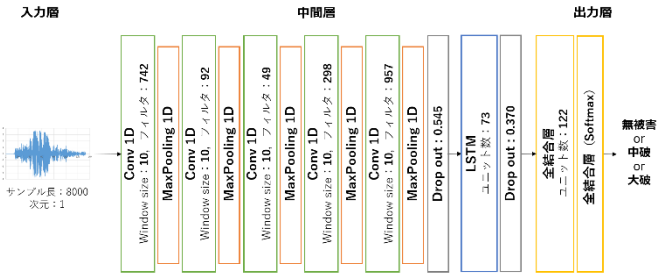

図-6　1D CNN+LSTM の概要

4.　予測結果の精度評価

各モデルのテストデータに対する判別精度をまとめたものを**表-3** に示す．なお，本研究では学習時の検証データに対する損失関数値が最小となったエポックでのモデルの重みを用いてテストデータの判別を行った．

表-3　各モデルの精度指標の比較

	正解率	適合率	再現率	F 値
LSTM	0.656	0.654	0.656	0.651
1D CNN	0.917	0.918	0.917	0.917
1D CNN + LSTM	0.761	0.756	0.761	0.758

表-4　各テストデータに対する正解率

		減衰定数 h		
		4%	5%	6%
固有周期 T	0.4s	0.494	0.522	0.550
	0.5s	0.822	0.917	0.767
	0.6s	0.667	0.667	0.656

1D CNN では，全ての精度指標が 0.91 以上となり最も精度が高かった．次いで，1D CNN＋LSTM モデルの精度が高かった．1D CNN の精度が最も高かったのは，地震時の木造建物の損傷評価では，応答加速度波形の長期的な依存関係よりも局所的な特徴を学習することの方が，応答塑性率の予測に対して効果が高いからではないかと思われる．したがって，1D CNN+LSTM モデルにおいては，1D CNN で抽出した局所的特徴量に，判別に対して効果の低い長期的依存性の情報が加わり，伝達される特徴量が過度に複雑になり，精度が低くなったのではないかと考える．

5.　固有周期と減衰定数が異なる木造建物モデルへの適用性に関する検討

(1) 異なる諸元の木造建物モデルへの適用性

本研究では固有周期 0.5s，減衰定数 5%の 1 質点系を木造建物の基準モデルとし，機械学習に基づく被害判別モデルを構築した．実際の木造建物は固有周期や減衰定数は決まっているわけではなく，ばらつきがある．したがって，今回構築した被害判別モデルに対して，固有周期や減衰定数が異なる木造建物を想定したテストを行い，本モデルの適用性を確認する必要がある．

そこで本研究では，固有周期 0.4～0.6 s（0.1s 刻み），減衰定数 4～6%（1%刻み）の範囲で，地震応答解析を行った．固有周期と減衰定数の各組合せに対して，それぞれ 180 サンプルずつテストデータを作成し，基準モデルで構築した被害判別モデルによる判定結果の精度を評価した．各テストデータに対する正解率を**表-4** に示す．

その結果，基準モデル以外の全ての場合に対して精度が大きく低下した．特に，固有周期 0.4s, 減衰定数 4%のデータセットに対しては 50%を下回る結果となった．一方で，減衰定数のみが変化した場合よりも，固有周期のみが変化した場合の方が精度の変化が大きかった．このことから，特に固有周期の変化が被害区分の判別精度に大きな影響を与えていると考えられる．

最も精度が悪かった固有周期 0.4s, 減衰定数 4%の場合の被害判別結果の混同行列（**表-5**）を見ると，クラス 3 の見逃しは 1 件だけであるが，被害が程度が小さくなるにつれて判別が難しくなることが確認できた．

(2)　転移学習によるチューニングの検討

このように，固有周期や減衰定数が異なると，基準モデルで構築された被害判別モデルでは建物の損傷状況を正確に把握することが難しい．そこで，対象建物に合わせて基準モデルの被害判別モデルを再学習させることを試みる．

表-5　固有周期 0.4s,減衰定数 4%のときの判別結果

		予測		
		クラス 1	クラス 2	クラス 3
実際	クラス 1（無被害）	16	27	17
	クラス 2（中破）	4	14	42
	クラス 3（大破）	0	1	59

表-6　転移学習前後の判別精度の比較

	正解率	適合率	再現率	F 値
転移学習前	0.494	0.544	0.494	0.446
転移学習後	0.661	0.681	0.661	0.667

表-7　転移学習後の判別結果

		予測		
		クラス 1	クラス 2	クラス 3
実際	クラス 1（無被害）	41	14	5
	クラス 2（中破）	7	39	14
	クラス 3（大破）	1	20	30

具体的には,基準モデルの被害判別モデルをベースとして，少ないデータで判別精度を向上させる方法の一つである転移学習によるチューニングを試みる．

a)　転移学習の概要

転移学習は，ある異なるタスクに対して学習されたモデルから，目的とするタスクにおいて利用するモデルへ重みを転移し，目的に対応する学習データを用いて再学習を行う手法である．具体的には，学習済みモデルの重みを固定し，出力層への重みのみ新しいタスクのために最適化させる．これによって，ゼロから学習する場合と比較して学習時間を短縮することができる．また，既に多数のサンプルからなるデータセットで学習を行ったモデルを流用するため，転移学習時に使用するデータセットが小規模であっても，汎化能力の高いモデルが得られる場合が多いことが報告されている [8]**.**

b)　学習条件

本研究では，固有周期 0.4s，減衰定数 4%のデータセットを各クラス 30 サンプルずつ，計 90 サンプル作成し，訓練用データと検証用データに 8:2 の割合で分割した．また，その他の学習条件は基準モデルの被害判別モデルの学習時と同様のものとし，初期学習率を 0.0001，バッチサイズを 30 として転移学習を実施した．

c)　学習結果

転移学習後の被害判別モデルを用いて，前節と同様の 180 サンプルに対してテストを行った．判別精度を**表-6**，判別結果の混同行列を**表-7** に示す．転移学習によってすべての精度指標値が改善され，66%以上を示した．また，前節の混同行列（**表-5**）と比較して，クラス 1 とクラス 2 の誤判別が減少しているのが確認できる．一方，クラス 3 に関しては,転移学習前は誤判別が 1 件だけであったのに対し，転移学習後には 21 件に増加し，精度が低下した．

以上のことから，対象建物の固有周期や減衰定数に合わせてデータを少量作成し，転移学習を行うことで予測精度の向上が見込めるものと考えられる．既設構造物の固有周期や減衰定数を計測する方法は種々提案されており，それに応じたチューニングを行うと予め学習しておいた被害判別モデルの適用性が高まる可能性がある．

6.　まとめ

本研究では，木造建物の応答加速度の時刻歴波形を用いて建物の損傷状況を判別する機械学習モデルの構築を試みた．Optuna を用いてハイパーパラメータチューニングを行い，LSTM ネットワーク，1D CNN，1D CNN+LSTM の三種類のモデルを比較した結果，1D CNN のみを用いた被害判別モデルの正解率が 91%を超え，最も高い精度を示した．このことから，応答加速度の時刻歴波形における局所的な特徴を学習することが，木造建物の応答塑性率を予測する際に効果が高いと考えられる．

さらに，被害判別モデルの汎用性を確認するため，固有周期や減衰定数の異なるデータセットを作成してテストを行ったところ，全てのデータセットにおいて精度が大きく低下した．特に，固有周期が変化すると精度が著しく低下したことから，固有周期の差が応答加速度波形の有する局所的特徴に大きく影響することが分かった．また，特に精度の悪かった固有周期 0.4s, 減衰定数 4%の条件に対して転移学習を行ったところ精度が向上し，転移学習が被害判別モデルの汎用性を高める可能性があることを示した．このことから，加速度センサを設置する建物の固有周期や減衰定数を事前に把握し，それに合わせてデータセットを追加作成し，再学習によるチューニングを行うことが有効であると考える．

しかし，**表-7** のように，実際の被害と比較して予測が小さく評価されているケースがあり，実用化の面で懸念が残る．この点に関しては，データセットの拡張や損失関数の設定により，全体の精度を維持しつつ各クラスの再現率向上を試みる必要がある．また，本研究の転移学習後の正解率は 66.1%に留まっており，十分な精度を有しているとは言えない．今後は，再学習手法や学習条件，学習データのサンプル数などに対する検討を行い，更なる精度の向上を試みていきたい．

参考文献

1)　内閣府政策統括官（防災担当）付，参事官（被災者行政担当）付：避難所について，2018.
2)　防災科学研究所：強震観測網（K-NET，KiK-net），https://www.kyoshin.bosai.go.jp/kyoshin/（2024 年 1 月 15 日閲覧）
3)　星幸江，山崎文雄，丸山喜久：木造建物の早期被害推定のための地震動指標の検討，土木学会論文集，No. 759/I-67，pp. 213-232，2004.
4)　神奈川県環境部防災消防課：神奈川県西部地震被害想定調査［建物・火災被害調査］報告書，1993.
5)　藤田一弥，高原歩：実装ディープラーニング，オーム社，2016.
6)　Mattioli, F., Prcaro, C. and Baldassarre, G.: A 1D CNN for high accuracy classification and transfer learning in motor imagery EEG-based brain-computer interface, *Journal of Neural Engineering*, Vol.18, No.6, Paper No. 066053, 2022.
7)　坂口巧一，加藤昇平：日韓混合感情音声からの 1 次元畳み込み双方向 LSTM を用いた感情推定，情報処理学会研究報告，Vol. 2018-SLP-125, No. 6, 2018.
8)　Pan, S. and Yang, Q.:A survey on transfer learning, *IEEE Trans Knowl Data Eng 22*, pp. 1345-1359, 2010