

# 地震応答解析結果の深層学習による建物損傷推定の精度分析

株式会社竹中工務店 青井 淳

恒川 裕史

吉澤 睦博

上林 厚志

電気通信大学 ガンバト ニヤムフー

橋山 智訓

## 1. はじめに

大地震時、防災拠点としての機能が期待される建築物では地震後の速やかな建物継続使用判断が求められる。東日本大震災においては帰宅困難者が問題となったが、建物側は帰宅困難者の受け入れのため、地震直後に迅速な施設の安全確認が必要となる。その対策の一つとして、地震後に建物の健全性判断を行う構造ヘルスマモニタリングシステムのニーズが近年高まっている。現在実装の進んでいる一般的なシステムでは、建物内に複数設置された加速度センサから得られる情報を用いて加速度積分やモード応答より建物変形を求め、最大層間変形角から建物各階の損傷度を推定するものが主流である<sup>1), 2)</sup>。一方、ディープラーニングの登場以降、人工知能技術への注目が高まっており、構造ヘルスマモニタリングへの機械学習手法の応用に関する研究も行われつつある<sup>3), 4)</sup>。

機械学習手法の内、既知である入力データと出力データのペアを正解としてその関係を学習させることを教師あり学習、その入出力データセットのことを教師データと呼ぶ。筆者らは、地震時の建物応答加速度と建物損傷度の関係を事前に教師あり学習させることで、建物に設置された加速度センサから得られる加速度データから建物損傷度を即時に直接推定出来ないかと考え、複数回の地震応答解析から得られる解析結果を教師データとした機械学習モデルによる建物損傷推定手法の検討を行っている<sup>5)</sup>。本論文では、機械学習モデルによる建物損傷推定の精度と地震応答解析の入力地震動の周期特性との関係性について分析した結果について報告する。

## 2. 機械学習を用いた損傷推定手法の概要

ある入力地震動 1 波に対して、建物全層の損傷有無の判定を行う機械学習モデルを構築する。具体的には、想定する建物の 3 次元モデルを対象に複数回の地震応答解析を行い、その解析結果から得られる建物各層の応答加速度のフーリエ振幅スペクトルを入力、各層の部材の塑性化の有無から決定した層の損傷判定結果を出力とした入出力関係をニューラルネットワーク(Neural Network、以下 NN)のモデルにより学習を行う。これにより、地震時に建物各層での加速度記録が取得できれば、即時に建物各層での損傷判定結果を得ることが可能となる。上記手順による本手法の概要を図 1 に示す。

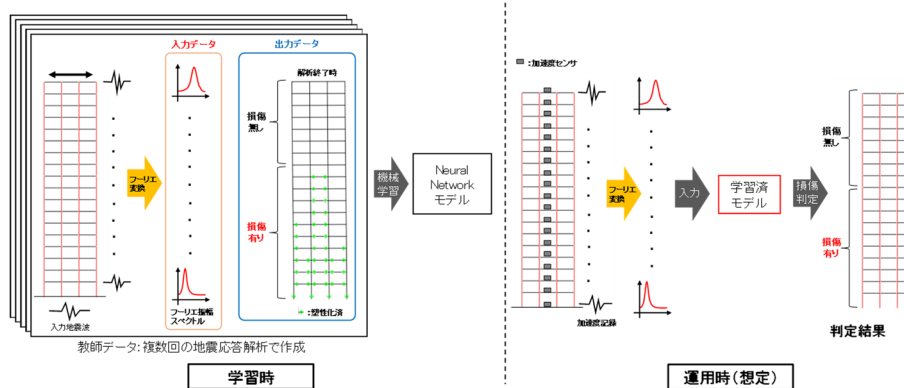


図 1 機械学習手法を用いた損傷推定手法の概要

### 3. 地震応答解析による教師データの作成

#### 3.1 地震応答解析の概要

検討用の建物モデルとして、既往の研究<sup>6)</sup>にて実施された鉄骨造 18 層建物の実大振動実験における試験体を参考とし、地震応答解析用の 3 次元建物モデルを作成した。表 1 に建物モデルの諸元および固有値解析結果を、図 2 にモデル形状を示す。既往の実大振動実験と同様に、地震応答解析は図 2 に示す X 方向の一方向入力とした。

地震応答解析に用いる入力地震動は、1995～2016 年の間に震度 5 強以上を観測した主要な地震記録 456 波 (水平 2 方向ベクトル和最大方向) とした。地震動の振幅レベルを最大速度 115cm/s でスケールしたものを 100% とし、5%～100% まで 5% 刻みで振幅レベルを変動させた加速度記録を入力地震動として用いた。振幅レベル 100% における 456 波の速度応答スペクトルを図 3 に示す。なお、試験体の縮尺が 1/3 であるため、地震動の時間軸は  $1/\sqrt{3}$  に縮めている。

1 波あたり 20 ケースのため、合計 456 波 × 20 の合計 9,120 ケースの地震応答解析を実施し、解析結果から得られる各 FL の応答加速度をフーリエ変換して得られるフーリエ振幅スペクトル (バンド幅 0.1Hz の Parzen window で平滑化) を機械学習時の入力データとして用いることとした。建物の 1～3 次固有周期を含むように 0.5Hz～5.2Hz の帯域を対象とし、周波数刻みは 0.00264Hz としたため、1FL あたりのデータサイズは 1792 となり、1FL～RFL までの全階分で 19FL × 1792 のフーリエ振幅値マトリクスが入力データとなる。出力データについては、層ごとの損傷有無の判定結果とした。層の損傷判定は、各層の柱および上下階の FL 上の梁のいずれかの部材において解析終了時点で一か所でも塑性化があれば当該層において損傷有りと見なすこととした。図 4 に、9,120 ケースの地震応答解析結果における各層の損傷有無の判定結果の内訳を示す。全体的に損傷有りに比べて損傷無しの数が多く、上層ほど損傷有りのケースが少ない傾向にある。

#### 3.2 損傷分布パターンの分析

学習データの傾向を把握するため、1～18 層での損傷有無の分布 9,120 ケースに対し、K-means 法を用いて 4 クラスにクラスタリングし、対応する入力地震動のフーリエ振幅スペクトルと併記したものを図 5 に示す。横軸の Damage = 1 が損傷無し、2 が損傷有りに対応しており、クラスターごとに各層の Damage の平均値と  $\pm \sigma$  の値をプロットしている。4 つのクラスは左から①全層ほぼ損傷無し、②下から半分以上の層で損傷有り、③低層部のみ損傷有り、④低層部と間を空けて上層部に損傷有りに分類された。①のパターンは

表 1 建物モデルの諸元および固有値解析結果

Specification	
Structure	18 story steel frame structure
Gross weight	4,179 kN
height	24.65m
Plan Size	5.0m×6.0m
scale	1/3

mode order (X-direction)	Period (s)	Effective mass ratio
1	1.14	0.770
2	0.37	0.138
3	0.20	0.038

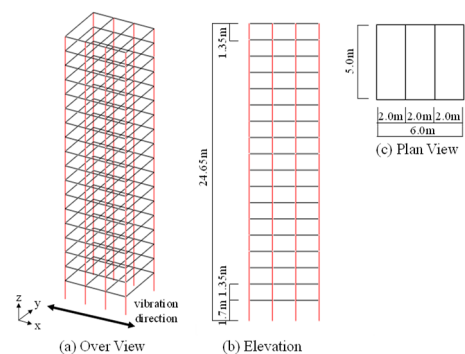


図 2 3次元解析モデル図

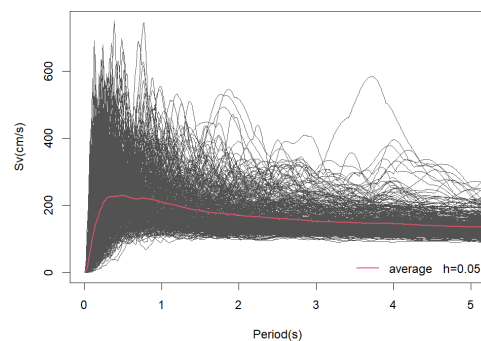


図 3 456 波の速度応答スペクトル (最大速度 115 cm/s で基準化)




図 4 各層の損傷有り/無しの頻度分布

5,503 ケースで半数以上を占めており、対応する入力地震動のフーリエスペクトルは全体的に振幅レベルが小さく、周期のピークも建物の1次固有周期(1.14秒)、2次固有周期(0.37秒)を外れたところにあるものが多かった。②のパターンは、1次固有周期付近でフーリエ振幅が大きくなっている傾向にあり、主に1次モードの応答が大きくなり、損傷範囲が広がったパターンだと言える。③については、①と同様に建物の1、2次固有周期付近のフーリエ振幅値は小さく、2次固有周期以下の極短周期にピークがあるケースが多かったが、全体的に振幅レベルは①と比べて大きかったために低層でのみ損傷が発生したパターンだと見てとれる。最後の④は、353 ケースと数は少ないが、2次固有周期付近にピークを持つ入力地震動が多く、2次モードの揺れが支配的となり、低層部と上層部で間を空けた形で損傷が発生するパターンだとわかる。①～④のパターンでケース数に偏りが存在しているが、これらのパターンの特徴を捉えて学習できているかを学習後に確認する必要がある。

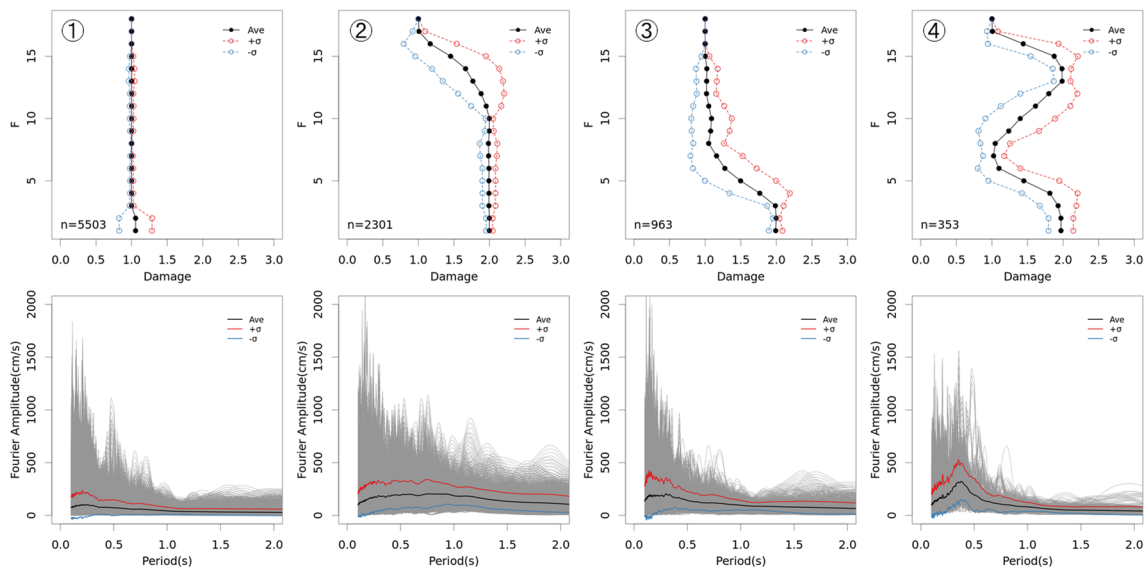


図5 K-means 法で分類した各クラスターの損傷パターンとフーリエ振幅スペクトル

#### 4. 機械学習モデルの構築

19×1792 のサイズの入力データに対して、18 層の各層の損傷有無の判定結果を同時に返す NN の学習モデルを構築する。NN モデルは既往の深層学習モデルを参考に表 2 の 3 種類とし、モデルによって予測精度の傾向に差異が生まれるか比較検証する。(a)MLP は全結合層のみの NN、(b)と

表 2 学習モデルの概要

NNモデル	(a) MLP	(b) LeNet	(c) VGG			
batch size	512	512	512			
epoch	30	30	120			
learnig rate	0.005	0.01	0.005			
momentum	0.9	0.9	0.85			
wd	0.00001	0.00001	0.00001			
Input Data Size	19×1792		19×1792			
モデル構造	Block	Layers	Block	Layers	Block	Layers
	FC1	FullyConnected 128ch Relu	Conv1	Convolution 5×5, 20ch Tanh MaxPooling 2×2	Conv1	Convolution 3×3, 64ch Relu MaxPooling 2×2
	FC2	FullyConnected 64ch Relu		Convolution 5×5, 50ch Tanh MaxPooling 2×2		Conv2
	Output	FullyConnected 36ch Softmax	FC1	Flatten FullyConnected 500ch Tanh	Conv3	Convolution 3×3, 256ch Relu Convolution 3×3, 256ch Relu MaxPooling 2×2
			Output	FullyConnected 36ch Softmax		FC1
					FC2	FullyConnected 1024ch Relu Dropout 0.5
					Output	FullyConnected 36ch Softmax

VGG を参考に設定した。出力は 18 層×損傷有無の 2 パターンで 36ch としており、最後の softmax 関数で出力の合計は 1 となるため、層ごとに損傷有無に応じてどちらかの ch に 1/18 の値を対応させる形にしており、1 つのモデルで各層の判定結果を同時に返す学習モデルとなる。

## 5. 機械学習モデルの予測精度検証

### 5.1 各モデルの精度検証

精度検証は、学習データ9,120 ケースを訓練データ・テストデータに振り分けて実施する。全体は456 波×20 ケースのデータであり、各地震波の20 ケースは振幅レベルのみが異なる類似のデータであるため、地震波単位で訓練データ・テストデータに振り分け、未知の地震波に対するテストとなるように設定する。訓練データ・テストデータそれぞれの割合が 0.85:0.15 程度となるように、テストデータの波をランダムに抽出し、地震波単位で 388 波:68 波に振り分けた。3 つの学習済みモデルを用いて、テストデータ 1,360 ケースに対し各層の損傷有無の判定を行い、解析結果による正解値との正誤関係をまとめた混同行列および Accuracy、Recall、Precision の評価指標の値を表 3 に示す。

Accuracy を見ると、3 モデルとも各層で 0.8 以上の良い値を示しており精度良く予測できているが、「損傷有り」については上層において Recall、Precision の値が低下している。これは、図 5 にて示した通り、上層階は「損傷有り」のデータが「損傷無し」のデータに比べて非常に少ないために十分に学習できていなかったことが原因だと考えられる。3 つのモデルの予測精度を比較すると、Accuracy で見ると差異はほとんど無いように見えるが、Recall と Precision の値を比較すると、MLP と VGG は全体的に「損傷有り」の Recall が高く、Precision が低めとなっており、LeNet の方は逆に「損傷有り」の Recall が低く、Precision が高めの傾向を示している。この傾向は、MLP と VGG は全体的に損傷を過大評価(安全側の判定)、LeNet では逆に損傷を過小評価(危険側の判定)する傾向であることを示している。実際の地震時の運用を想定すると、出来るだけ予測精度は確保しつつも安全側寄りの評価となっていることが望ましい。同じ CNN の LeNet と

表 3 混同行列(赤字は Accuracy)

VGGとでは逆の評価傾向を示しており、Recall や Precision、混同行列などを確認し、判定の全体的な傾向を把握しておくことが重要だと考えられる。

更に、テストデータの全 1,360 ケースでの解析結果による損傷分布(正解値)と3モデルの予測による損傷分布をグリッド化して並べたものを図 6 に、正解値と各モデルの結果の差分に色を付けたものを図 7 に示す。テストデータ 68 地震波の 5~100%の 20 レベルごとに各階の損傷有無または差分の有無に応じて色を付け、全ケース横に並べている。図 5 にて損傷パターンを4つに分類したが、ケース数の少ない④(2 次モードの影響大)の低層と上層で間を空けて損傷するパターンも含めて各モデルで表現できていることがわかる。図 7 は、赤の場合は正解が損傷有

層	(a) MLP				(b) LeNet				(c) VGG			
	正解値	損傷無し	損傷有り	Recall	正解値	損傷無し	損傷有り	Recall	正解値	損傷無し	損傷有り	Recall
18	損傷無し	1360	0	<b>1.000</b>	損傷無し	1360	0	<b>1.000</b>	損傷無し	1360	0	<b>1.000</b>
	損傷有り	0	0	-	損傷有り	0	0	-	損傷有り	0	0	-
	Precision	<b>1.000</b>	-	<b>1.000</b>	Precision	<b>1.000</b>	-	<b>1.000</b>	Precision	<b>1.000</b>	-	<b>1.000</b>
17	損傷無し	1358	0	<b>1.000</b>	損傷無し	1358	0	<b>1.000</b>	損傷無し	1358	0	<b>1.000</b>
	損傷有り	2	0	<b>0.000</b>	損傷有り	2	0	<b>0.000</b>	損傷有り	2	0	<b>0.000</b>
	Precision	<b>0.999</b>	-	<b>0.999</b>	Precision	<b>0.999</b>	-	<b>0.999</b>	Precision	<b>0.999</b>	-	<b>0.999</b>
16	損傷無し	1278	1	<b>0.999</b>	損傷無し	1268	11	<b>0.991</b>	損傷無し	1256	23	<b>0.982</b>
	損傷有り	74	7	<b>0.086</b>	損傷有り	77	4	<b>0.049</b>	損傷有り	63	18	<b>0.222</b>
	Precision	<b>0.945</b>	<b>0.875</b>	<b>0.945</b>	Precision	<b>0.943</b>	<b>0.267</b>	<b>0.935</b>	Precision	<b>0.952</b>	<b>0.561</b>	<b>0.937</b>
15	損傷無し	991	151	<b>0.868</b>	損傷無し	1109	33	<b>0.971</b>	損傷無し	1046	9	<b>0.991</b>
	損傷有り	47	171	<b>0.784</b>	損傷有り	124	94	<b>0.431</b>	損傷有り	85	13	<b>0.133</b>
	Precision	<b>0.955</b>	<b>0.531</b>	<b>0.854</b>	Precision	<b>0.899</b>	<b>0.740</b>	<b>0.885</b>	Precision	<b>0.925</b>	<b>0.591</b>	<b>0.918</b>
14	損傷無し	911	144	<b>0.864</b>	損傷無し	1008	4	<b>0.996</b>	損傷無し	938	117	<b>0.899</b>
	損傷有り	49	256	<b>0.839</b>	損傷有り	121	18	<b>0.129</b>	損傷有り	93	212	<b>0.695</b>
	Precision	<b>0.949</b>	<b>0.640</b>	<b>0.858</b>	Precision	<b>0.893</b>	<b>0.818</b>	<b>0.891</b>	Precision	<b>0.910</b>	<b>0.644</b>	<b>0.848</b>
13	損傷無し	880	126	<b>0.875</b>	損傷無し	965	41	<b>0.959</b>	損傷無し	891	115	<b>0.886</b>
	損傷有り	57	297	<b>0.839</b>	損傷有り	125	229	<b>0.647</b>	損傷有り	91	263	<b>0.743</b>
	Precision	<b>0.939</b>	<b>0.702</b>	<b>0.865</b>	Precision	<b>0.885</b>	<b>0.848</b>	<b>0.878</b>	Precision	<b>0.907</b>	<b>0.696</b>	<b>0.849</b>
12	損傷無し	857	122	<b>0.875</b>	損傷無し	935	44	<b>0.955</b>	損傷無し	854	125	<b>0.872</b>
	損傷有り	46	335	<b>0.879</b>	損傷有り	125	256	<b>0.672</b>	損傷有り	63	318	<b>0.835</b>
	Precision	<b>0.949</b>	<b>0.733</b>	<b>0.876</b>	Precision	<b>0.882</b>	<b>0.853</b>	<b>0.876</b>	Precision	<b>0.931</b>	<b>0.718</b>	<b>0.862</b>
11	損傷無し	850	110	<b>0.885</b>	損傷無し	915	45	<b>0.953</b>	損傷無し	842	119	<b>0.877</b>
	損傷有り	50	350	<b>0.875</b>	損傷有り	114	286	<b>0.715</b>	損傷有り	44	356	<b>0.890</b>
	Precision	<b>0.944</b>	<b>0.761</b>	<b>0.882</b>	Precision	<b>0.889</b>	<b>0.864</b>	<b>0.883</b>	Precision	<b>0.950</b>	<b>0.751</b>	<b>0.881</b>
10	損傷無し	849	112	<b>0.883</b>	損傷無し	915	46	<b>0.952</b>	損傷無し	836	125	<b>0.870</b>
	損傷有り	37	362	<b>0.907</b>	損傷有り	96	303	<b>0.759</b>	損傷有り	20	379	<b>0.950</b>
	Precision	<b>0.958</b>	<b>0.764</b>	<b>0.890</b>	Precision	<b>0.905</b>	<b>0.868</b>	<b>0.896</b>	Precision	<b>0.977</b>	<b>0.752</b>	<b>0.893</b>
9	損傷無し	860	116	<b>0.881</b>	損傷無し	931	45	<b>0.954</b>	損傷無し	846	130	<b>0.867</b>
	損傷有り	29	355	<b>0.924</b>	損傷有り	82	302	<b>0.788</b>	損傷有り	12	372	<b>0.969</b>
	Precision	<b>0.967</b>	<b>0.754</b>	<b>0.893</b>	Precision	<b>0.919</b>	<b>0.870</b>	<b>0.907</b>	Precision	<b>0.986</b>	<b>0.741</b>	<b>0.896</b>
8	損傷無し	867	136	<b>0.864</b>	損傷無し	943	60	<b>0.940</b>	損傷無し	855	149	<b>0.852</b>
	損傷有り	27	330	<b>0.924</b>	損傷有り	81	276	<b>0.773</b>	損傷有り	15	342	<b>0.958</b>
	Precision	<b>0.970</b>	<b>0.708</b>	<b>0.880</b>	Precision	<b>0.921</b>	<b>0.821</b>	<b>0.896</b>	Precision	<b>0.983</b>	<b>0.698</b>	<b>0.880</b>
7	損傷無し	852	131	<b>0.867</b>	損傷無し	923	60	<b>0.939</b>	損傷無し	841	142	<b>0.856</b>
	損傷有り	29	348	<b>0.923</b>	損傷有り	86	291	<b>0.772</b>	損傷有り	13	364	<b>0.966</b>
	Precision	<b>0.967</b>	<b>0.727</b>	<b>0.882</b>	Precision	<b>0.915</b>	<b>0.829</b>	<b>0.893</b>	Precision	<b>0.985</b>	<b>0.719</b>	<b>0.886</b>
6	損傷無し	828	120	<b>0.873</b>	損傷無し	894	54	<b>0.943</b>	損傷無し	810	138	<b>0.854</b>
	損傷有り	39	373	<b>0.905</b>	損傷有り	93	319	<b>0.774</b>	損傷有り	20	392	<b>0.951</b>
	Precision	<b>0.955</b>	<b>0.757</b>	<b>0.883</b>	Precision	<b>0.906</b>	<b>0.855</b>	<b>0.892</b>	Precision	<b>0.976</b>	<b>0.740</b>	<b>0.884</b>
5	損傷無し	785	107	<b>0.880</b>	損傷無し	843	49	<b>0.945</b>	損傷無し	756	136	<b>0.849</b>
	損傷有り	59	409	<b>0.874</b>	損傷有り	113	355	<b>0.759</b>	損傷有り	30	438	<b>0.936</b>
	Precision	<b>0.930</b>	<b>0.793</b>	<b>0.878</b>	Precision	<b>0.882</b>	<b>0.879</b>	<b>0.881</b>	Precision	<b>0.962</b>	<b>0.763</b>	<b>0.878</b>
4	損傷無し	727	104	<b>0.875</b>	損傷無し	781	50	<b>0.940</b>	損傷無し	703	128	<b>0.846</b>
	損傷有り	48	481	<b>0.909</b>	損傷有り	118	411	<b>0.777</b>	損傷有り	30	499	<b>0.943</b>
	Precision	<b>0.938</b>	<b>0.822</b>	<b>0.888</b>	Precision	<b>0.869</b>	<b>0.892</b>	<b>0.876</b>	Precision	<b>0.959</b>	<b>0.796</b>	<b>0.884</b>
3	損傷無し	699	94	<b>0.881</b>	損傷無し	743	50	<b>0.937</b>	損傷無し	672	121	<b>0.847</b>
	損傷有り	56	511	<b>0.901</b>	損傷有り	119	448	<b>0.790</b>	損傷有り	40	527	<b>0.929</b>
	Precision	<b>0.926</b>	<b>0.845</b>	<b>0.890</b>	Precision	<b>0.862</b>	<b>0.900</b>	<b>0.876</b>	Precision	<b>0.944</b>	<b>0.813</b>	<b>0.882</b>
2	損傷無し	668	82	<b>0.891</b>	損傷無し	702	48	<b>0.936</b>	損傷無し	632	118	<b>0.843</b>
	損傷有り	52	558	<b>0.915</b>	損傷有り	102	508	<b>0.833</b>	損傷有り	37	573	<b>0.939</b>
	Precision	<b>0.928</b>	<b>0.872</b>	<b>0.901</b>	Precision	<b>0.873</b>	<b>0.914</b>	<b>0.890</b>	Precision	<b>0.945</b>	<b>0.829</b>	<b>0.886</b>
1	損傷無し	671	81	<b>0.892</b>	損傷無し	704	48	<b>0.936</b>	損傷無し	635	117	<b>0.844</b>
	損傷有り	49	559	<b>0.919</b>	損傷有り	99	509	<b>0.837</b>	損傷有り	36	572	<b>0.941</b>
	Precision	<b>0.932</b>	<b>0.873</b>	<b>0.904</b>	Precision	<b>0.877</b>	<b>0.914</b>	<b>0.892</b>	Precision	<b>0.946</b>	<b>0.830</b>	<b>0.888</b>



り、予測が損傷無し of 過小評価となっている箇所で、青がその逆に損傷を過大評価している箇所を表している。3つのモデルを比較するとやはり LeNet が他の2モデルと比較して全体的に赤い箇所が多め(過小評価傾向)で、MLP と VGG は青が多め(過大評価傾向)となっている。ただし、赤もしくは青が多いといった地震波ごとの傾向については3つのモデルで概ね共通しており、過小 or 過大評価の傾向については地震波にも大きく依存していることがわかる。なお、16~18階辺りについては損傷有りの評価精度がそもそも低く、青が多いケースでも頂上だけ赤くなっている。

## 5.2 予測精度と地震動特性との関係性分析

ここで、図7の傾向を踏まえ、学習モデルの予測が合いやすい地震波(グレーが多い)、損傷を過小評価傾向の地震波(赤が多い)と過大評価傾向の地震波(青が多い)それぞれについて、地震波のフーリエ振幅スペクトルに一定の特徴が見られるかについて分析する。地震波ごとに18層×20レベルの計360点のグリッドがあるが、3つのモデルで共通して、(a)赤 or 青が10点以下、(b)赤が30点以上、(c)青が30点以上となる3つの条件に該当する地震波を抽出して、フーリエ振幅スペクトル(振幅レベル100%)を図示したものを図8に示す。また、図5で示した損傷パターン①~④それぞれのケース数を(a)~(c)ごとにカウントした結果を表4に示す。(a)のフーリエ振幅スペクトルは0.2秒程度の極短周期のみが卓越した地震波となっており、損傷パターン①のほぼ損傷無しのケースが全体を占めていた。極短周期のフーリエ振幅の値は大きな値を示しているが、建物応答への影響は小さいことを学習できていることがわかる。

(b)は、建物の1次と2次の固有周期付近にピークがあり、それ以外の周期帯のフーリエ

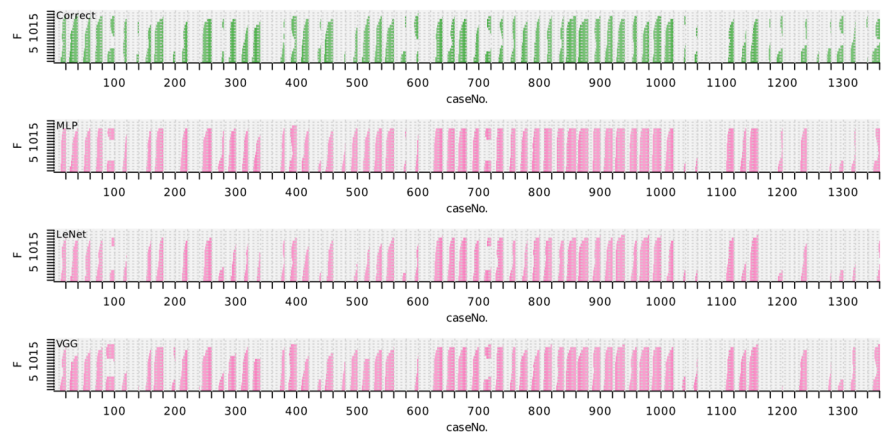


図6 テストデータの損傷分布(色有り=損傷有り, グレー=損傷無し)

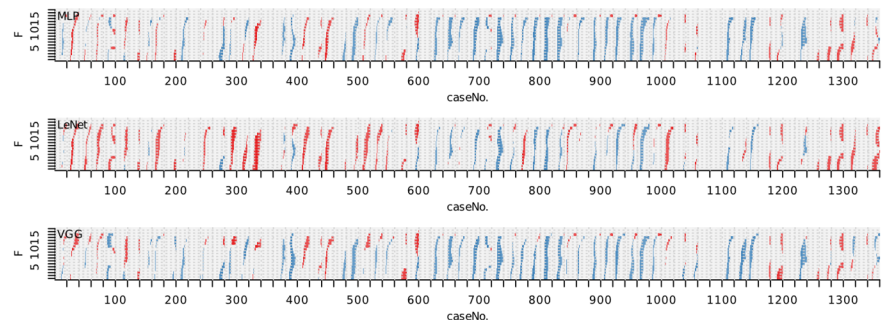
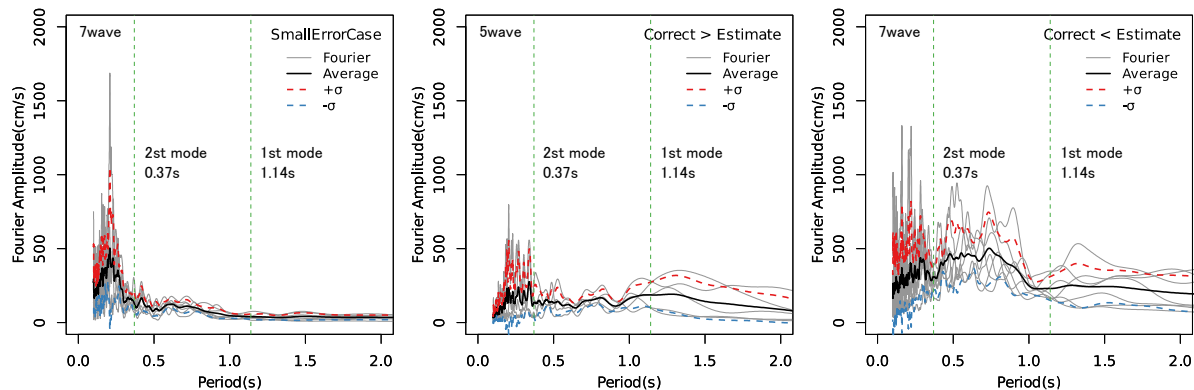


図7 正解値と予測値の差の分布(赤=正解>予測, 青=正解<予測, グレー=両者一致)



(a) 予測が合っている

(b) 予測が過小評価傾向

(c) 予測が過大評価傾向

図8 正解-予測の差の傾向ごとに分類したフーリエ振幅スペクトル

振幅値が低めの傾向が見られ、損傷パターンは②と④が比較的に多い。恐らく、学習モデル上では固有周期付近以外のフーリエ振幅値の影響度も考慮しているため、その値が小さいために過小評価傾向が出てしまったのではと思われる。(c)は逆に 1 次固有周期～2 次固有周期間の幅広い周期帯で大きなフーリエ振幅値を持った地震波が多く、固有周期付近以外のフーリエ振幅値の影響で過大評価傾向になってしまったものと考えられる。

表 4 各地震波分類における損傷パターンごとのケース数

分類	損傷パターン				計
	①	②	③	④	
テストデータ全体	787	364	149	60	1360
(a)	139	0	0	1	140
(b)	42	35	11	12	100
(c)	72	52	13	3	140

以上の分析より、予測精度と地震動の周期特性との間には一定の相関性が見られた。予測精度が低下する要因としては、建物損傷(建物応答)に影響する周期帯が本検討で用いた学習データセットでは学習しきれていなかったことが考えられる。地震動の時間軸は  $1/\sqrt{3}$  でスケールしているため、実際の地震動に直すと 1 次固有周期 1.14 秒に対応するのは 1.97 秒であり、そこにだけピークを持つような地震動の数が少なかったことが原因の一つとして考えられる。本検討では実際の観測記録を基に入力地震動を設定したために周期特性に偏りがあり、その偏りが予測精度に影響したものと思われるが、この点については建物の振動特性を踏まえて設定した模擬地震動を学習データに追加する等により解消できると思われる。以上の検討より、建物損傷推定において機械学習を適用する場合においても、建物および地震動の振動特性を把握した上で活用していくことが重要だと考えられる。

## 6. まとめ

地震時の建物損傷推定における機械学習手法の有効性を検証するため、3 種類の NN モデルによる学習および精度検証を行い、層レベルの損傷有無の判定については一定の精度で予測可能であることがわかった。一方で、層ごとの損傷有無のケース数の偏りや、学習に用いる入力地震動の周期特性の偏り等が予測精度に影響を与えることがわかった。本論では層レベルを対象としたが、機械学習の場合、特定の部材を対象とした損傷判定等も期待される。構造ヘルスマonitoringへの機械学習手法の応用に関して今後さらなる検証を進め、地震時により有益な情報提供を可能とするシステム構築が今後の課題である。なお、本論の検討内容はあくまで解析結果のみに基づいたものであり、実観測データを対象とした場合にも同様の傾向を示すかについては、今後更なる検証が必要である。

### 【参考文献】

- 1) 三田彰:建物モニタリングと地震災害レジリエンス, 2021 年度日本建築学会大会(東海)構造部門(振動)パネルディスカッション資料, pp. 25-29, 2021.
- 2) 楠浩一:建築物の構造ヘルスマonitoring, コンクリート工学, Vol. 58, No. 9, pp. 761-766, 2020.
- 3) 深沢剛司, 藤田聡, 饗庭天暉:深層学習を活用した構造ヘルスマonitoringシステムの検討, 日本機械学会論文集, Vol. 88, No. 910, pp. 22-00006, 2022.
- 4) 森田高市, 長谷川隆:実大3層鉄骨フレームの振動台実験データに基づく機械学習による鉄骨端部の損傷状況の推定, 日本建築学会技術報告集, Vol. 28, No. 70, pp. 1137-1141, 2022.
- 5) ガンバトニヤムフー, 青井淳, 橋山智訓, 恒川裕史, 吉澤睦博:ディープラーニングを用いた建物地震損傷推定法の精度分析, 日本地震工学会第 17 回年次大会梗概集, TS\_20220105, 2022.
- 6) 久保田淳, 高橋元美, 鈴木芳隆, 澤本佳和, 聲高裕治, 伊山潤, 長江拓也:鉄骨造 18 層骨組を対象とした振動台実験における長周期地震動による骨組崩壊挙動, 日本建築学会構造系論文集, 第 83 巻, 第 746 号, pp. 625-635, 2018.4.

### [備考]

本稿は、第 16 回日本地震工学シンポジウムにて発表済みの内容を編集したものである。