

A04

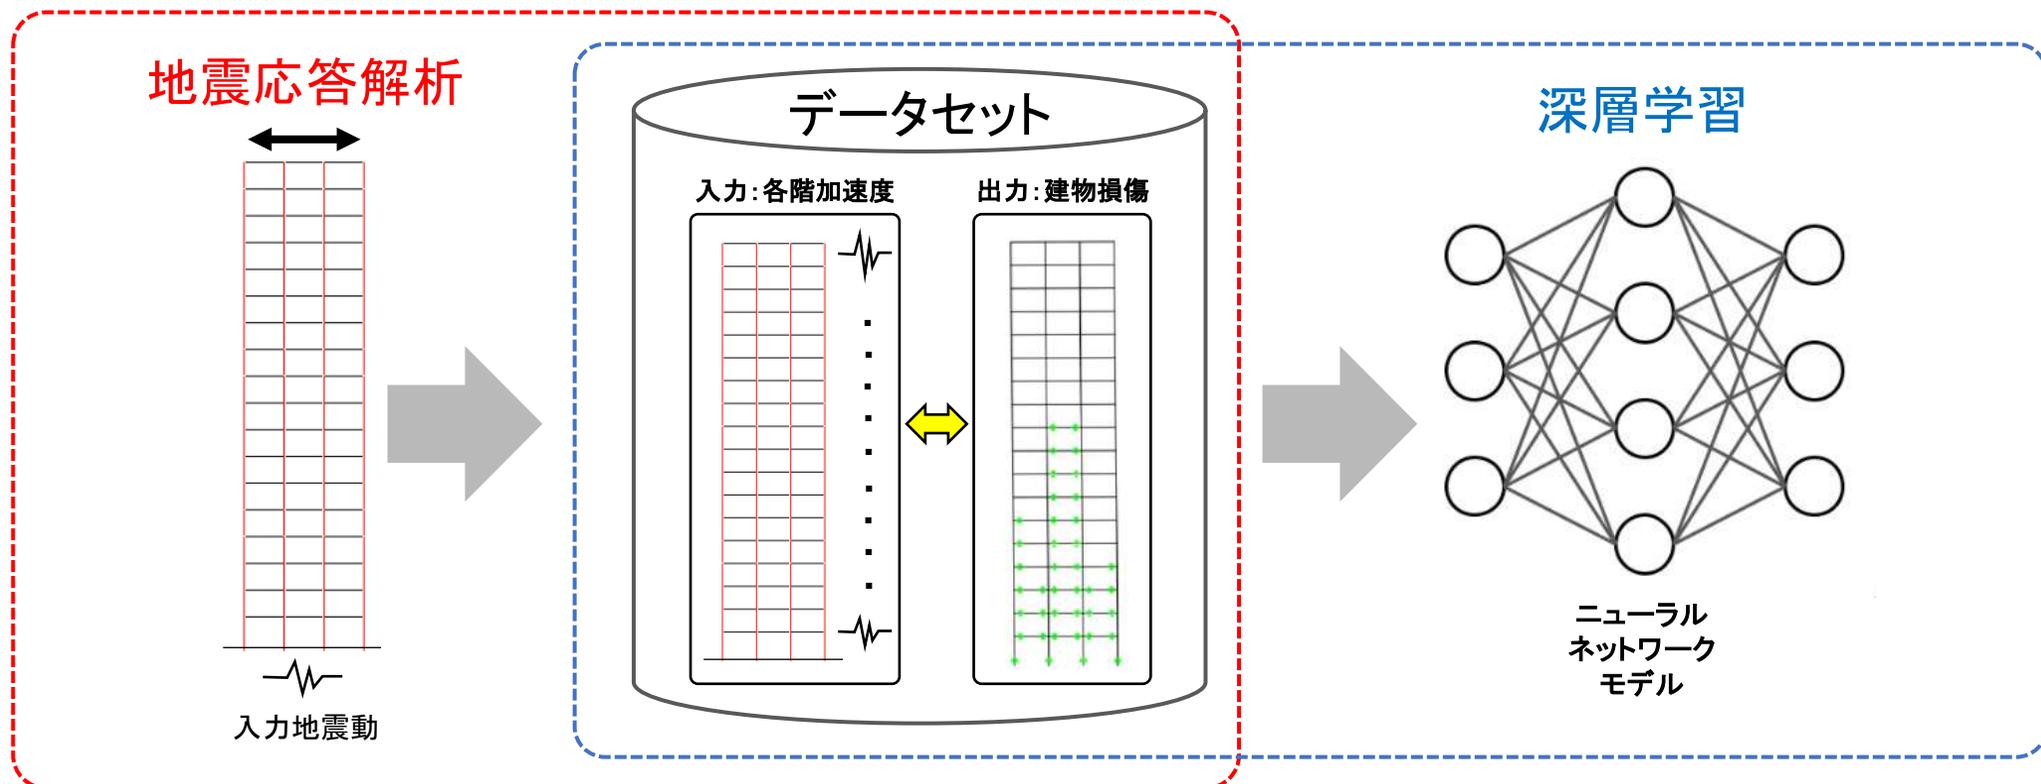
地震応答解析結果の深層学習による 建物損傷推定の精度分析

2023年12月1日

株式会社竹中工務店 青井 淳

背景・目的

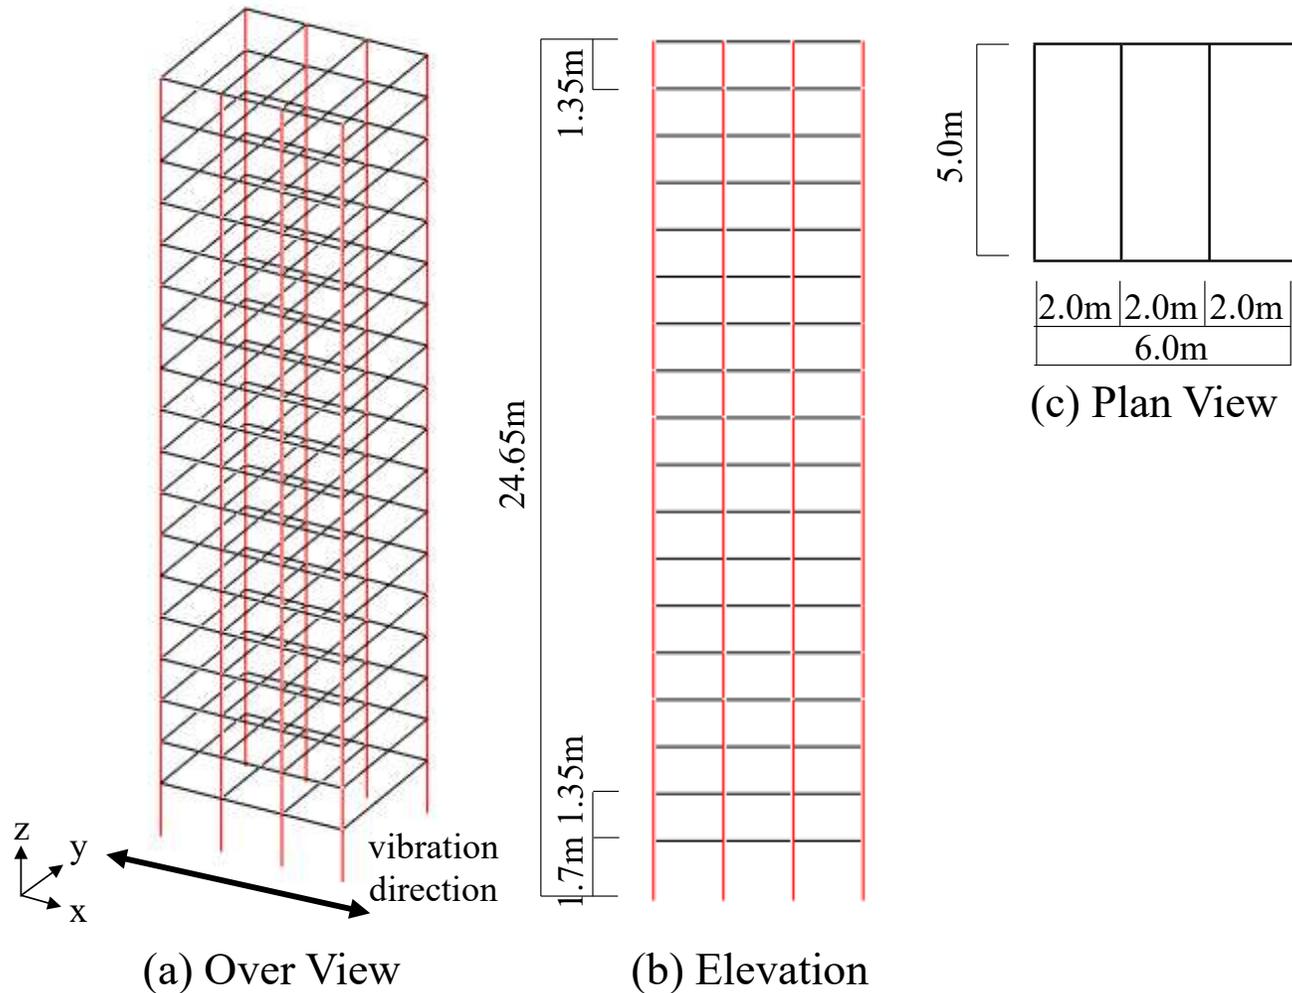
- 地震被災後に建物の継続使用判定を支援するシステム（構造ヘルスマモニタリング、被災度判定システム）への関心が高まっている
- 近年、人工知能技術の注目が高まっており、当該分野への機械学習手法の応用に関する研究も行われつつある
⇒ 地震応答解析結果を教師データに用いた深層学習による建物損傷推定法を検討



機械学習モデルによる建物損傷推定の精度と入力地震動特性との関係性について分析した結果について報告

検討対象建物

- 既往研究の実験試験体を参考に3次元解析モデルを作成
- S造18層建物（実大1/3スケール）
- 地震応答解析は一方向入力



参考: 鉄骨造18層高層建物Eーディフェンス実験(2013)
 科学技術振興費: 都市の脆弱性が引き起こす激甚災害の軽減化
 プロジェクト ②都市機能の維持・回復のための調査・研究

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

固有値解析結果

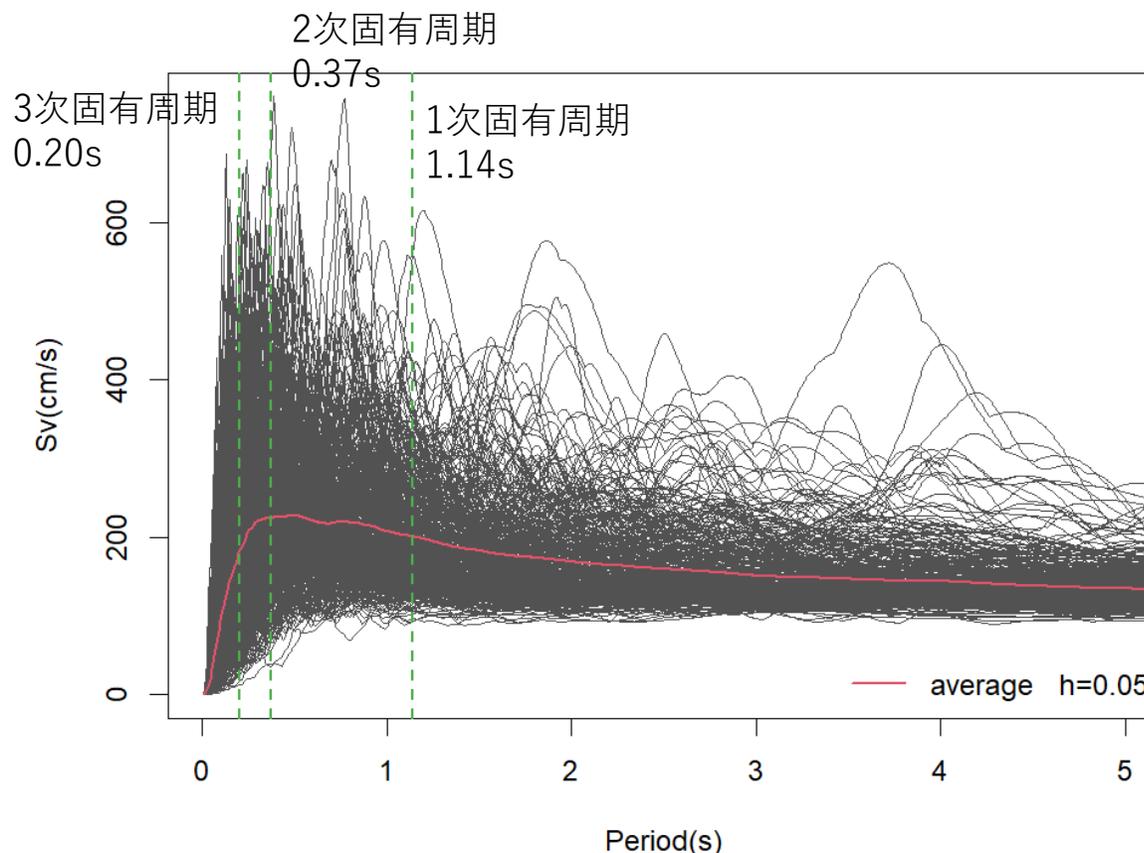
mode order (X-direction)	Period (sec)	Effective mass ratio	実大相当 固有周期 (参考値)
1	1.14	0.770	1.98
2	0.37	0.138	0.65
3	0.20	0.038	0.35

地震応答解析に用いた入力地震動

- 1995年兵庫県南部地震から2016年熊本地震までに発生した被害地震の内、計測震度5強以上を観測した456波の地震動（時間軸を $1/\sqrt{3}$ でスケーリング）
- 最大速度115cm/sで基準化した波を100%とし、1波あたり5%刻みで5~100%の20ケース、合計で456波×20レベル = 9,120ケースの解析を実施

入力地震動に用いた地震記録一覧

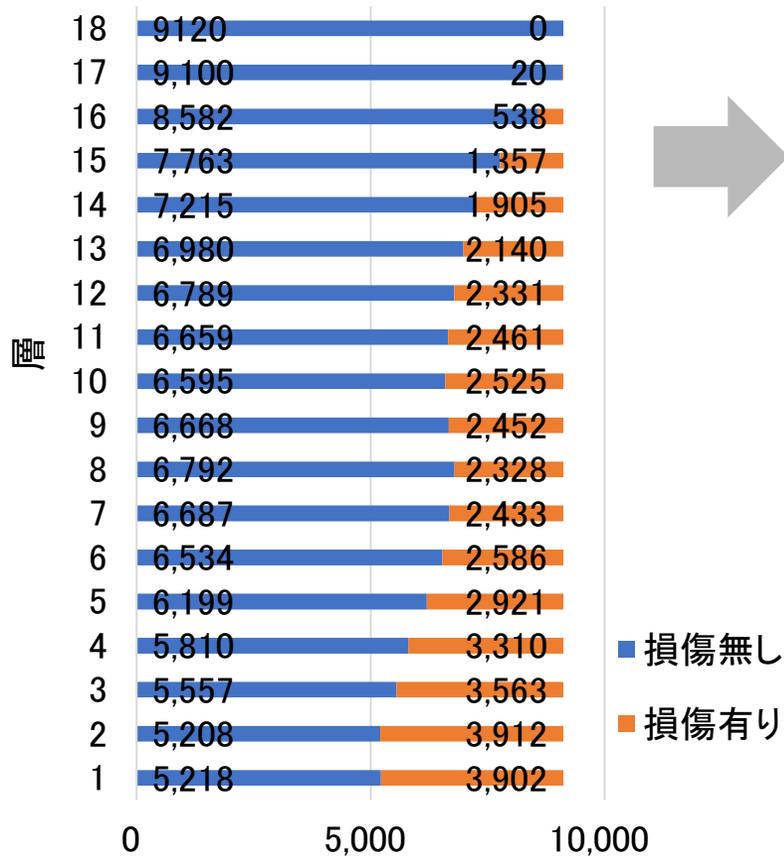
地震名	記録数
1995年 兵庫県南部	12
1997年 鹿児島県北西部(3/26)	3
1997年 鹿児島県北西部(5/13)	5
2000年 鳥取県西部	8
2001年 芸予	15
2003年 三陸南	20
2003年 宮城県北部	4
2003年 十勝沖	58
2004年 新潟県中越	25
2005年 福岡西方沖	4
2005年 宮城県沖	4
2007年 能登半島	12
2007年 新潟県中越沖	25
2008年 岩手・宮城内陸	14
2008年 岩手県沿岸北部	14
2009年 駿河湾の地震	12
2011年 東北地方太平洋沖 本震(3/11)	165
2011年 東北地方太平洋沖 余震(4/7)	28
2013年 淡路島地震	1
2014年 長野県北部地震	4
2016年 熊本地震_前震(4/14)	4
2016年 熊本地震_本震(4/16)	19
合計	456



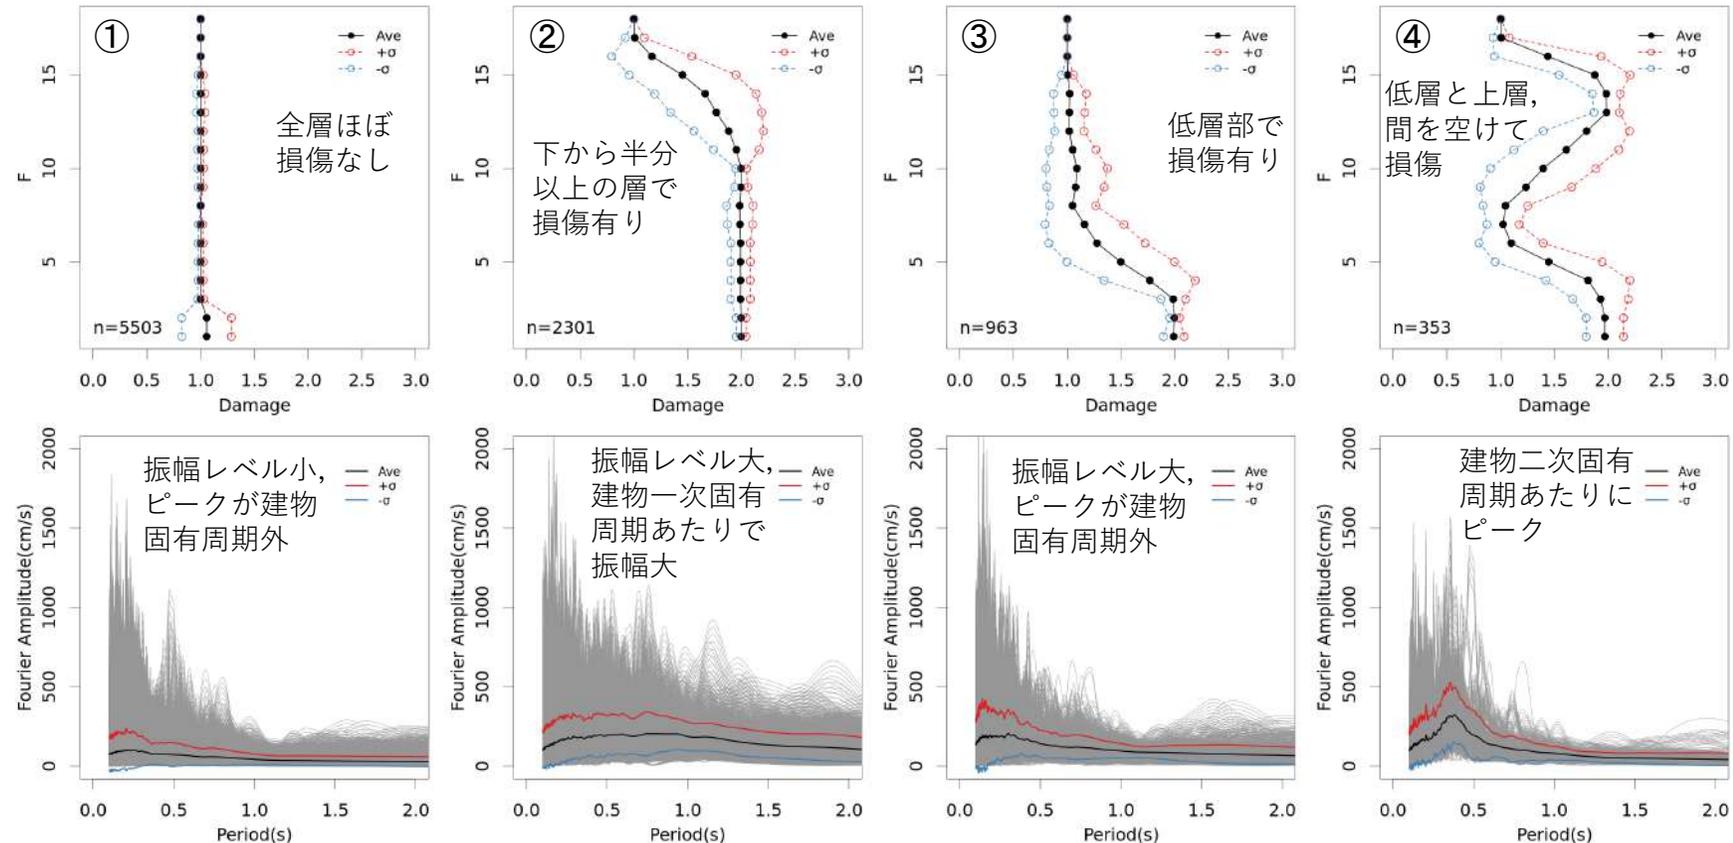
速度115cm/sで基準化した456波の速度応答スペクトル (h=5%)

地震応答解析結果_損傷パターンの分析

各層の損傷有り/無しの頻度分布



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 (Damage 1 = 損傷無し, Damage 2 = 損傷有り)



1次固有周期 1.14s, 2次固有周期 0.37s

- 全体的に「損傷無し」 > 「損傷有り」
- 上層ほど「損傷有り」が少ない

- 9,120ケースの損傷分布の結果をK-means法でクラスタリングし, パターンを分析
- 入力地震動の周期特性と損傷パターンが対応している
- ⇒ 4パターンでケース数に偏りがあり, 学習できるか確認が必要

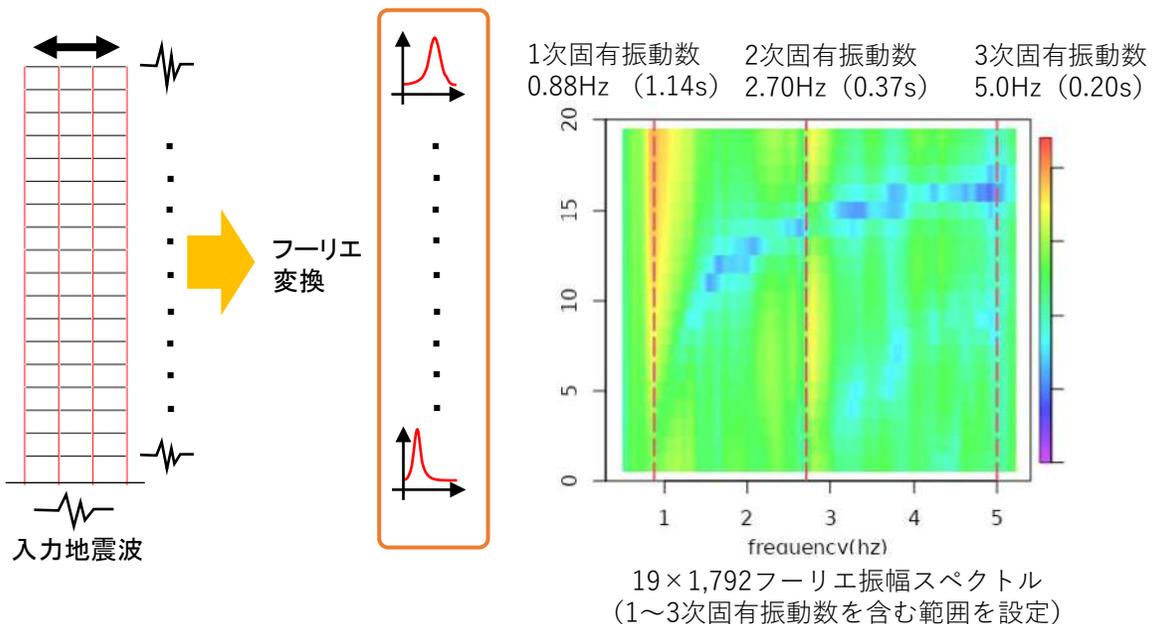
教師データについて

【入力データ】

各FLの応答加速度のフーリエ振幅スペクトル
 およそ0.5~5.2Hz（周波数刻み0.00264で、
 19FL×1792の数値マトリクス）

入力データ

フーリエ振幅スペクトル
 19×1792

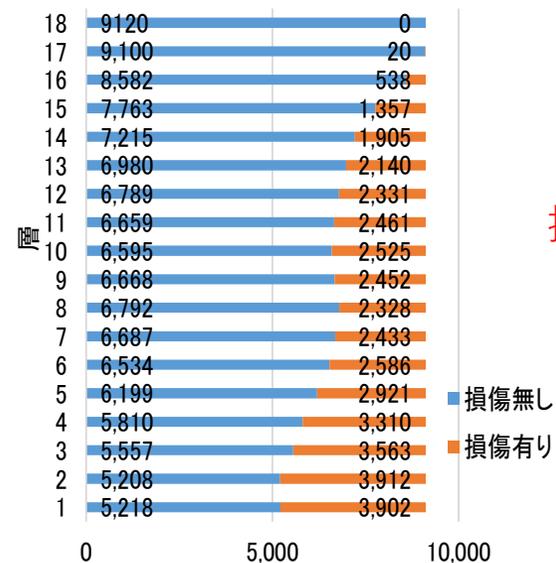


【出力データ】

各層の損傷有無の判定結果（塑性化部材の有無で定義）
 18層×2分類 → 36ch

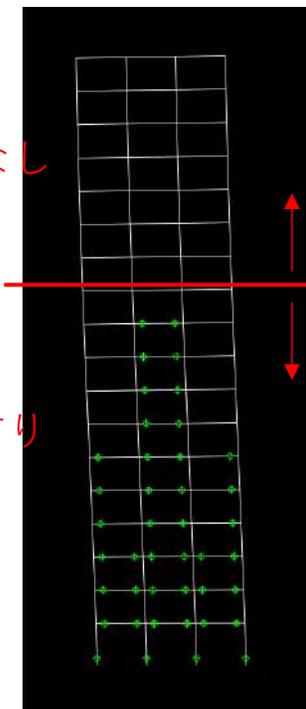
出力データ

層の損傷有無
 (地震応答解析後)



損傷なし

損傷有り



柱または上下階のFL上の梁いずれかの部材が塑性化している層は損傷有り

深層学習モデルについて

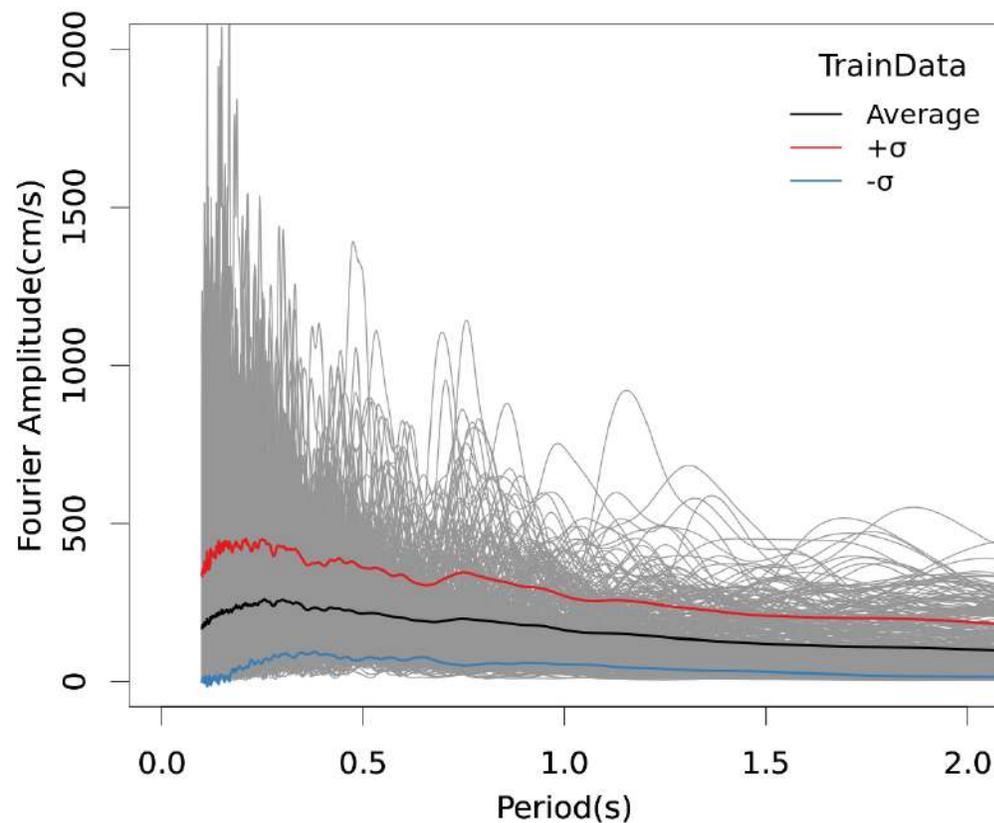
- ニューラルネットワークの3モデルを構築
- (a)MLPは全結合層のみ, (b)と(c)はConvolutional Neural Networkの代表的なモデルであるLeNetとVGGを参考に設定

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	0.0001		0.00001		0.00001	
Input Data Size	19×1792		19×1792		19×1792	
モデル構造	Block	Layers	Block	Layers	Block	Layers
	FC 1	FullyConnected 128ch Relu	Conv 1	Convolution 5×5, 20ch Tanh MaxPooling 2×2	Conv 1	Convolution 3×3, 64ch Relu MaxPooling 2×2
	FC 2	FullyConnected 64ch Relu	Conv 2	Convolution 5×5, 50ch Tanh MaxPooling 2×2	Conv 2	Convolution 3×3, 128ch Relu MaxPooling 2×2
	Output	FullyConnected 36ch Softmax	FC 1	Flatten FullyConnected 500ch Tanh	Conv 3	Convolution 3×3, 256ch Relu Convolution 3×3, 256ch Relu MaxPooling 2×2
			Output	FullyConnected 36ch Softmax	FC 1	Flatten FullyConnected 1024ch Relu Dropout 0.5
					FC 2	FullyConnected 1024ch Relu Dropout 0.5
					Output	FullyConnected 36ch Softmax

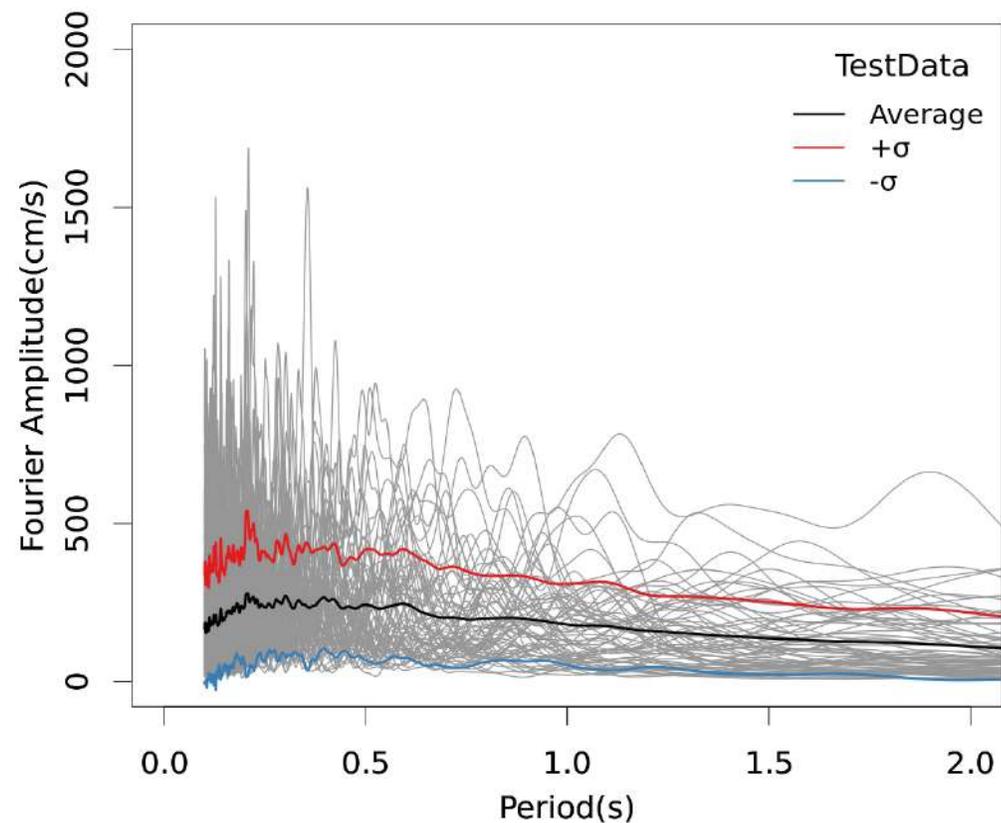
訓練データ・テストデータの振り分け

- 9,120ケースを0.85：0.15程度の割合で訓練・テストデータに振り分け
- 地震動単位で分けることとし、ランダムに抽出した68波をテストデータとした

フーリエ振幅スペクトル（振幅100%のみ）



訓練データ（388波）



テストデータ（68波）

訓練データとテストデータ、全体で見ると地震動周期特性は同じ傾向を示している

各モデルの精度検証

- Accuracy (正解率), Recall (再現率), Precision (適合率), F1値の4つの評価指標を層ごとに算出

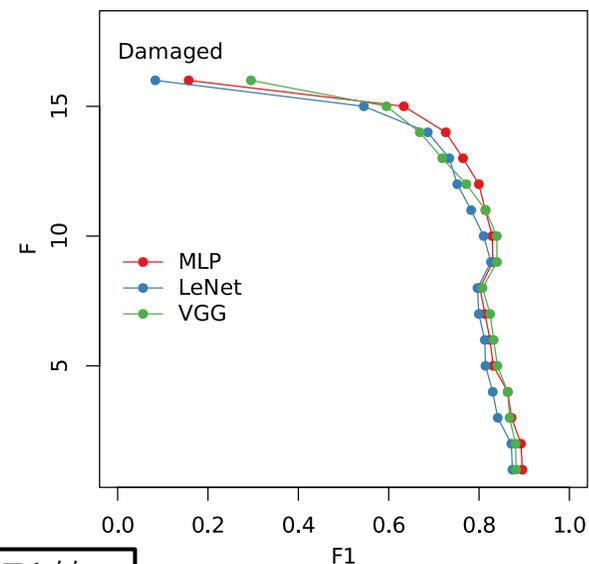
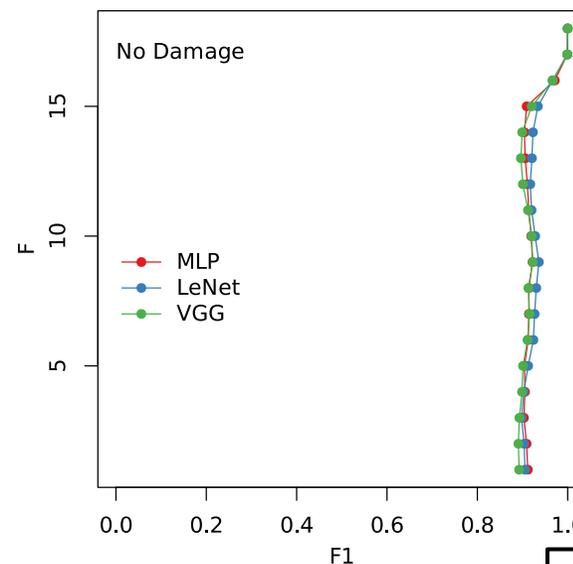
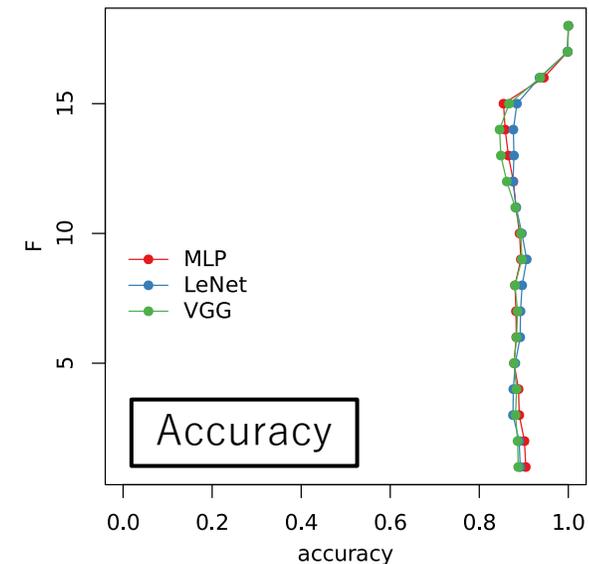
評価指標の計算例 (VGG 1階)

(c) VGG				
層	予測値		Recall	
	正解値			
1	損傷無し	635	117	0.844
	損傷有り	36	572	0.941
	Precision	0.946	0.830	0.888

Accuracy

- Accuracy:** 正解 - 予測の一致している割合
- Recall:** 損傷有り/無しの場合それぞれにおける正解率
- Precision:** 損傷有り/無しの予測のそれぞれの正解率
- F1値:** Recall, Precisionの調和平均

- Accuracyでは, 3モデルとも0.8以上の良い精度
- F1値では, 上層は「損傷有り」の精度低下
⇒ データ数が少ないため
- Accuracy, F1値だけで比較すると3つのモデルでほとんど差は見られない



各モデルの精度検証

評価指標の計算例 (VGG 1階)

(c) VGG				
層	予測値	損傷無し	損傷有り	Recall
	正解値			
1	損傷無し	635	117	0.844
	損傷有り	36	572	0.941
	Precision	0.946	0.830	0.888

Accuracy

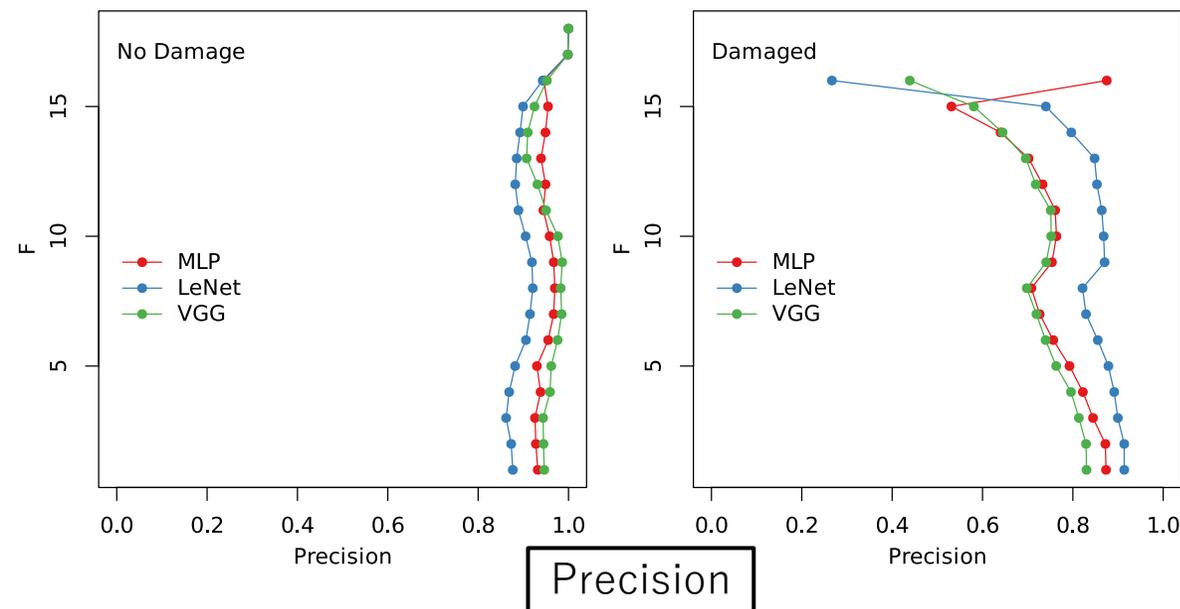
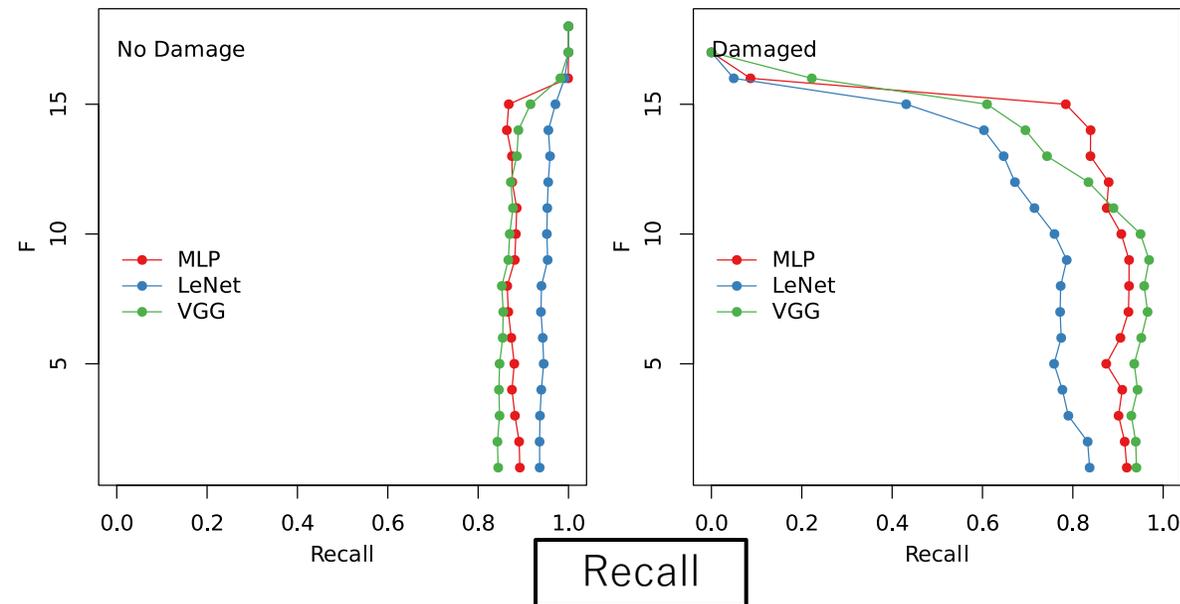
Accuracy: 正解 - 予測の一致している割合

Recall: 損傷有り/無しの場合それぞれにおける正解率

Precision: 損傷有り/無しの予測のそれぞれの正解率

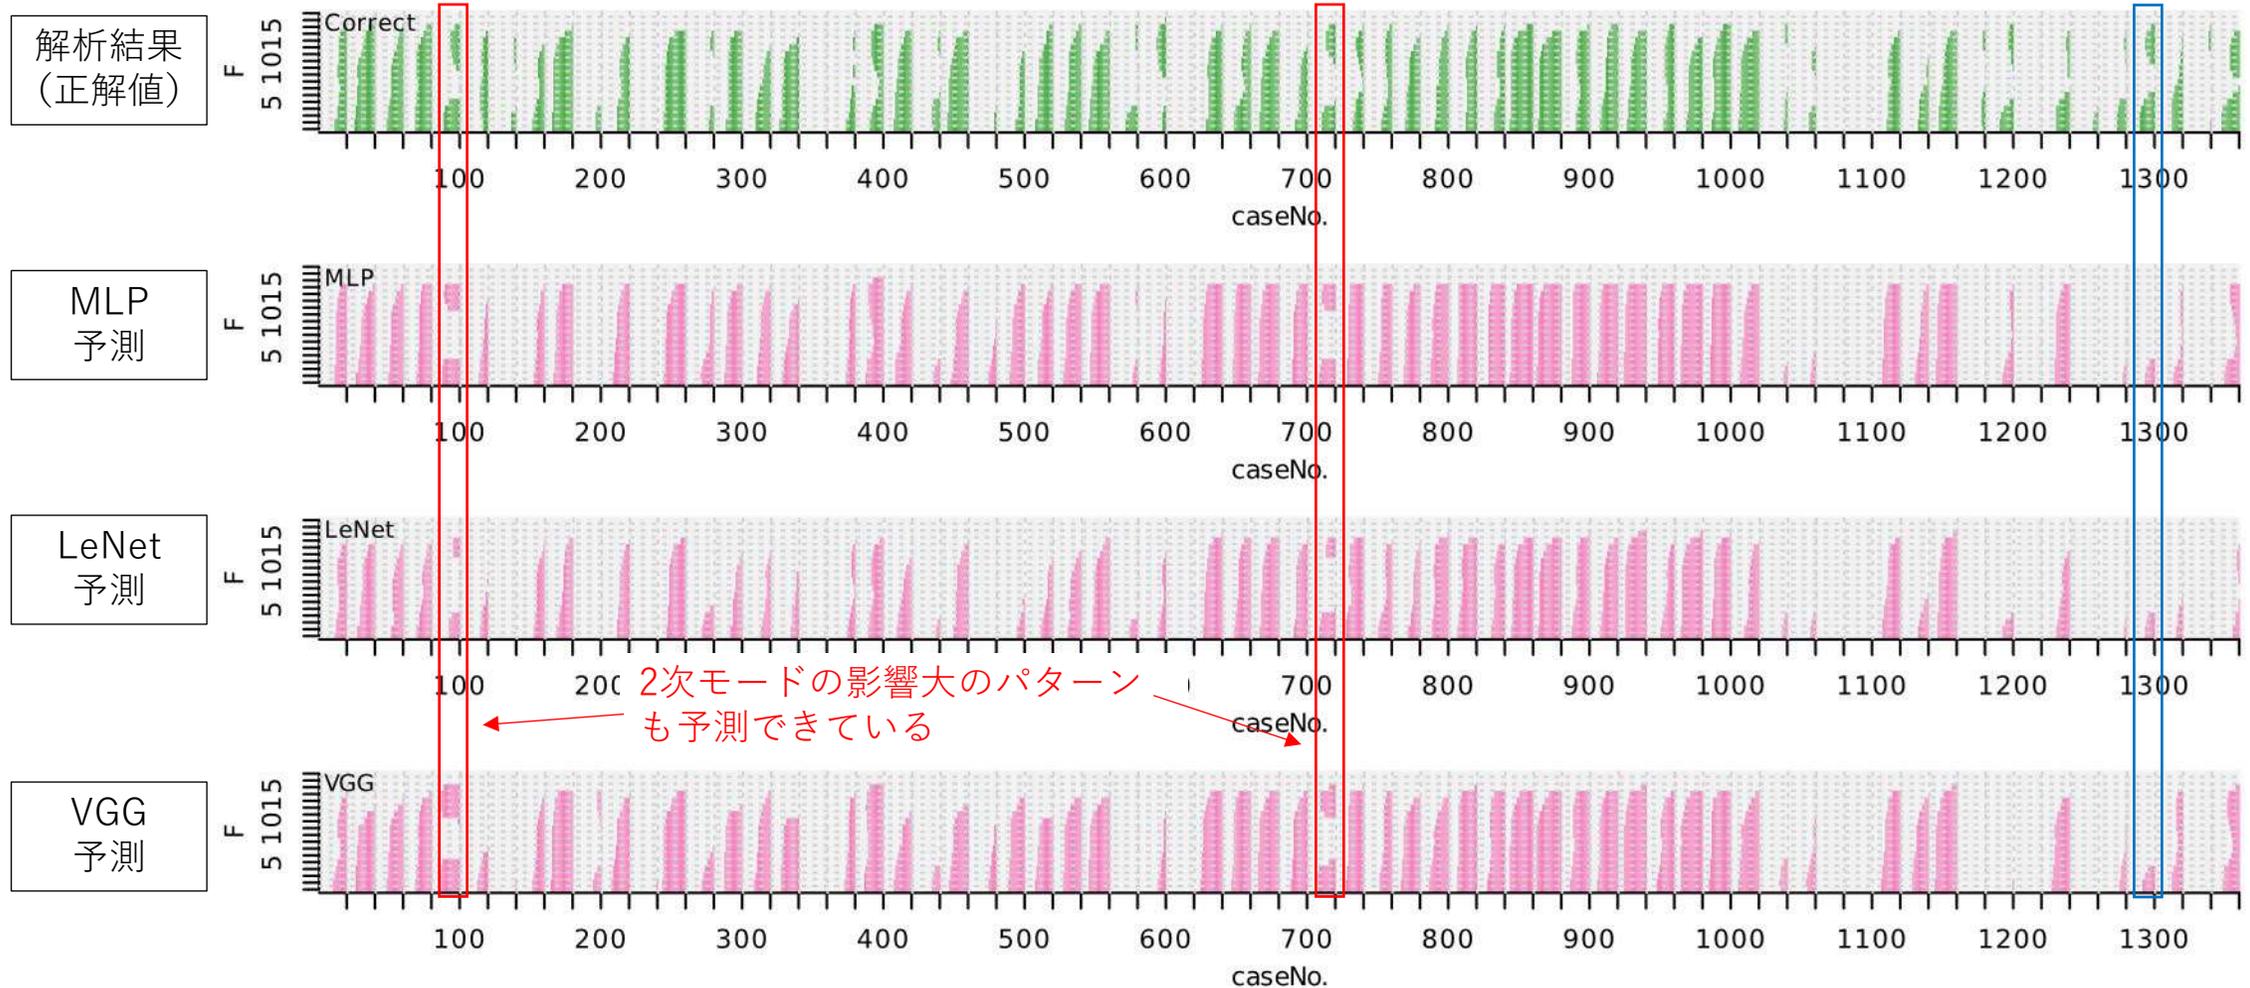
F1値: Recall, Precisionの調和平均

- MLPとVGGは全体的に「損傷有り」のRecallが高く、Precisionが低め
⇒ 損傷を過大評価 = 安全側の判定
- LeNetは逆に「損傷有り」のRecallが低く、Precisionが高め
⇒ 損傷を過小評価 = 危険側の判定
- 事前に混同行列等も確認し、判定の傾向を確認しておくことが重要だと考えられる



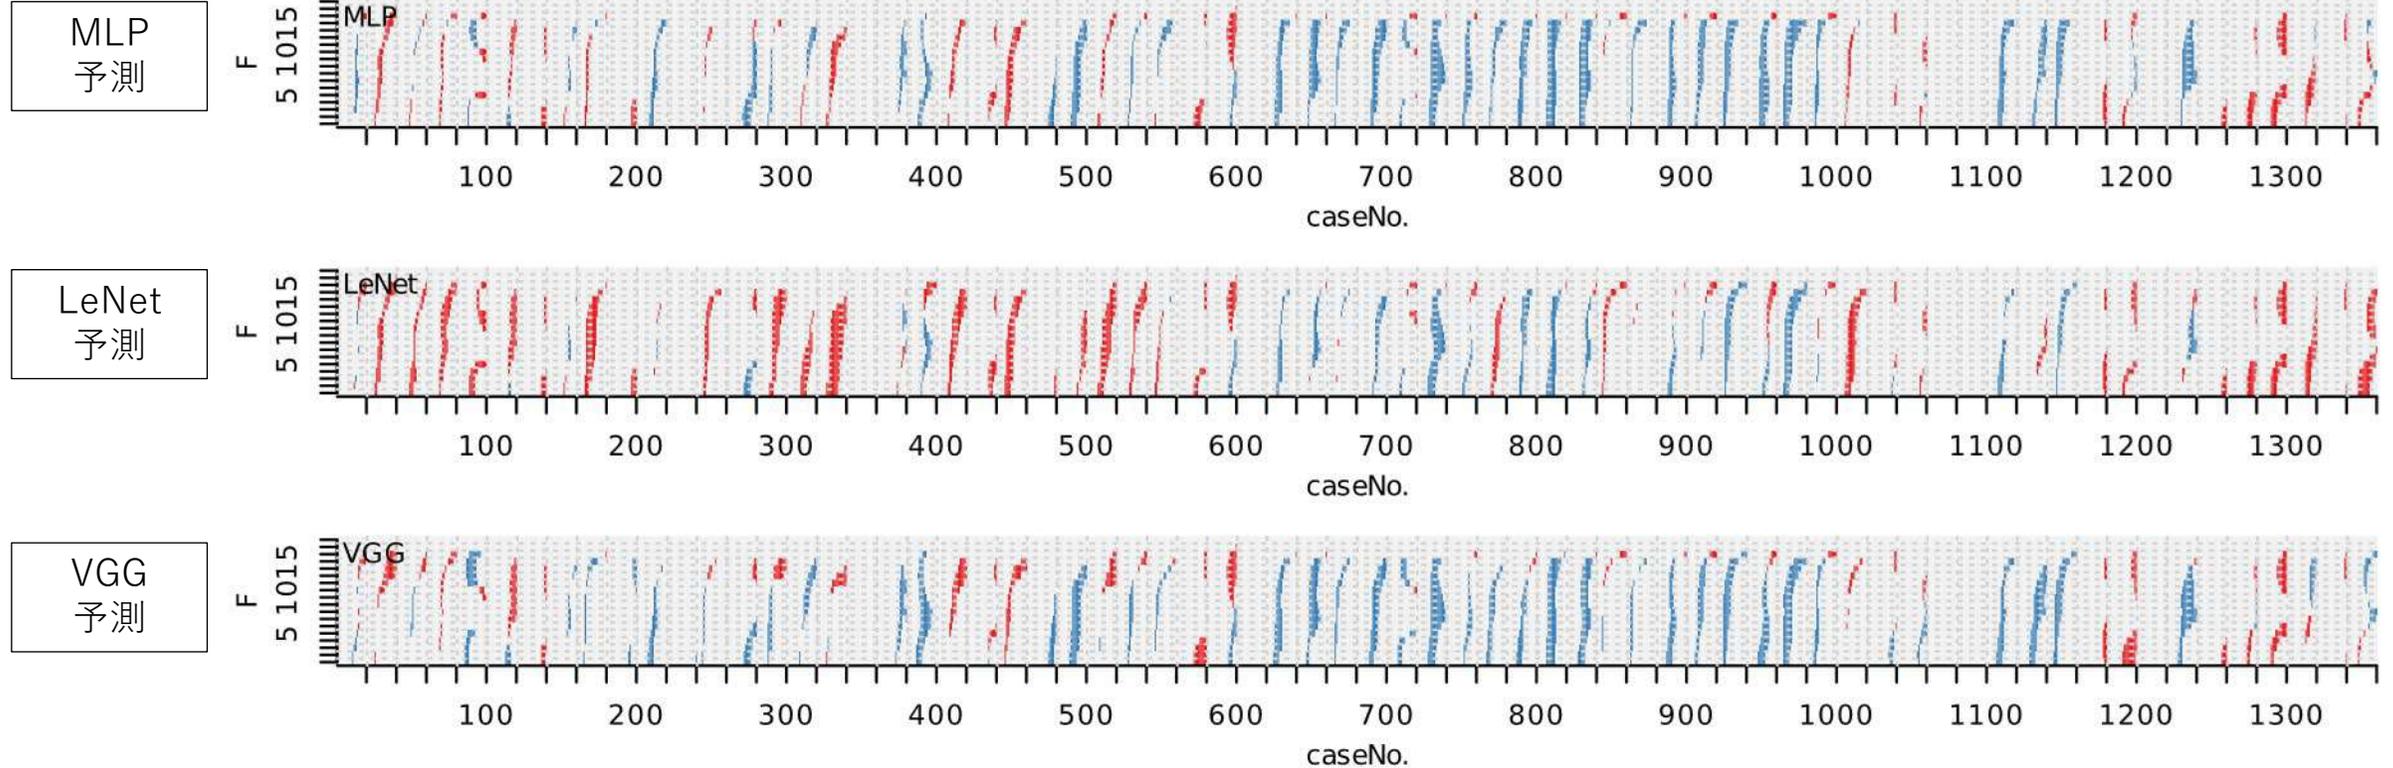
テストデータの損傷分布（正解・予測）

- テストデータ1,360ケース（38波×20レベル）の損傷分布を横に並べた結果
⇒ 地震動ごとの損傷パターンの把握と予測傾向の確認
- 18階×1360ケースのグリッド図（**損傷有りは色付き、損傷無しはグレー**）



正解 - 予測の差分の分布

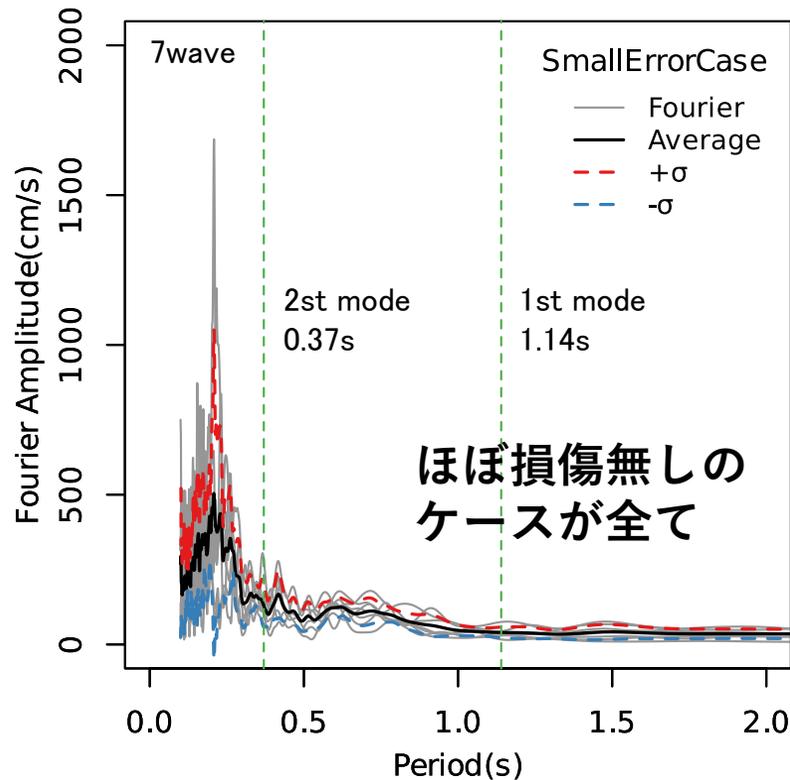
赤 = 正解 > 予測, 青 = 正解 < 予測, グレー = 両者一致



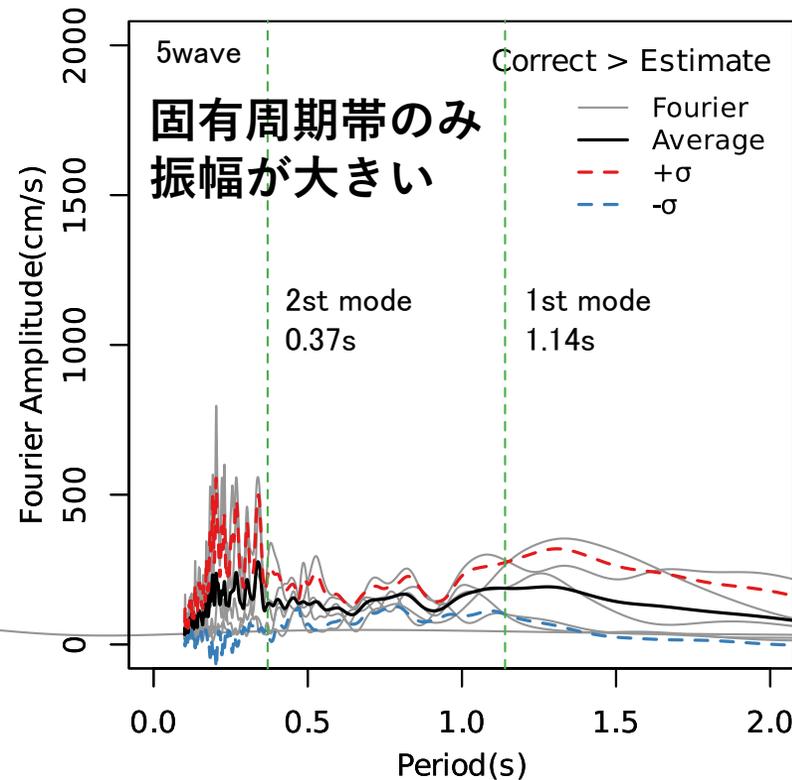
- モデル間の傾向を比較すると、LeNetがやや赤が多く（= 損傷を過小評価）、MLPとVGGは青が多い（= 損傷を過大評価）傾向が見て取れる
- 赤または青が多い地震動の傾向は各モデルで概ね共通 ⇒ 地震動の特性に依存していると考えられる
- 16~18層あたりの頂部は赤が多い ⇒ 損傷有りのデータが少ないため予測精度が低い

差分の傾向で分類したフーリエスペクトル

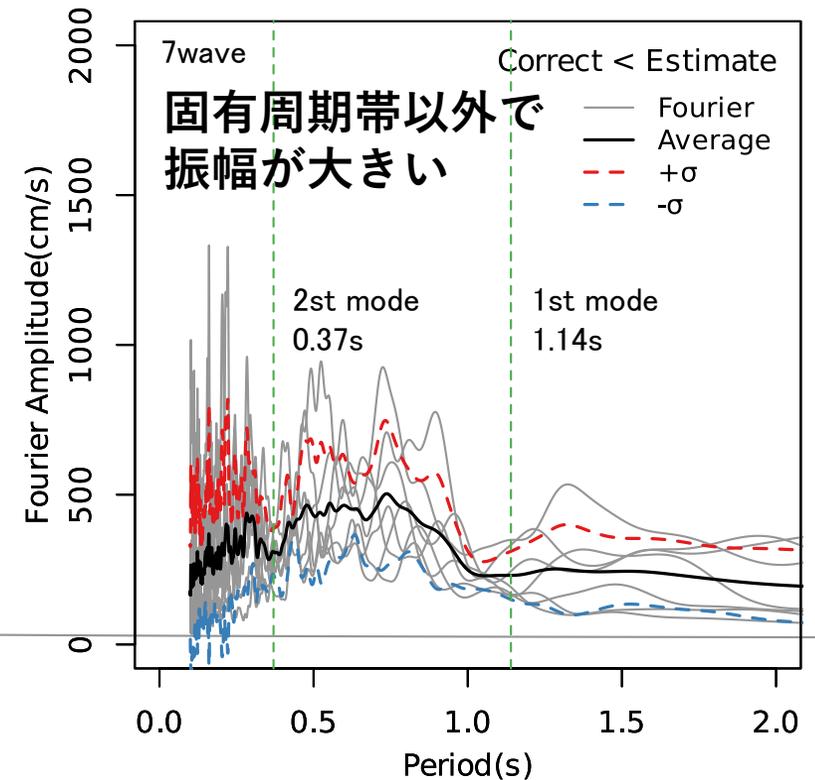
- 赤or青が多い地震動がこういった周期特性を確認するため、フーリエ振幅スペクトルを傾向ごとに抽出（振幅100%）



(a) 予測が合っている7波
(差分の分布図でグレー多い)



(b) 予測が過小評価傾向5波
(差分の分布図で赤多い)



(c) 予測が過大評価傾向7波
(差分の分布図で青多い)

- 予測精度が低下したケースの要因として、建物損傷に影響する周期帯を今回の教師データでは完全に学習しきれていなかったことが考えられる
- 建物と地震動の振動特性を踏まえた学習データを準備することが重要

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

まとめ

■ わかったこと

- 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つの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、Accuracyで全層0.8以上の精度で予測可能であることがわかった
 - ▶ 層ごとの損傷有無のケース数の偏りが予測精度に影響を与えることがわかった
 - ▶ テストパターン・学習モデルによって危険側or安全側の判定傾向が変化することがわかった
→ 実用時には要検証
- 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

■ 今後の展望・課題

- 機械学習を用いれば、特定の部材を対象とした損傷判定等も期待される。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
- 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