

## AIを活用した防災・減災について

国立研究開発法人 防災科学技術研究所  
地震減災実験研究部門  
主任研究員 山下 拓三

レジリエンス協会 定例会(第34回)  
日時:平成31年2月8日(金)13:00~16:30  
場所:防災科学技術研究所 東京会議室

1

## 発表内容

1. Eーディフェンスの紹介
2. 数値震動台の紹介
3. AI工学に基づく耐震性評価技術開発の構想
4. 実施中の研究内容:AIを用いた建造物の損傷推定

3

## 自己紹介

- 所属  
国立研究開発法人 防災科学技術研究所  
地震減災実験研究部門 (兼務 社会防災システム研究部門)  
- 2010.4~2018.4: 兵庫耐震工学研究センター(Eーディフェンス)  
- 2018.5~: つくば本所
- 専門分野  
- 建築構造, 耐震工学, 計算力学(有限要素法)
- 研究内容  
- 耐震シミュレーション(数値震動台)の研究開発  
- 振動台実験の計測
  - バーチャルリアリティ(VR)体験に用いるデータの計測
- 振動台実験・耐震シミュレーションのデータ利活用
  - 人工知能(AI)の活用

2

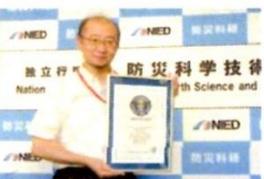
## 1. Eーディフェンスの紹介

4

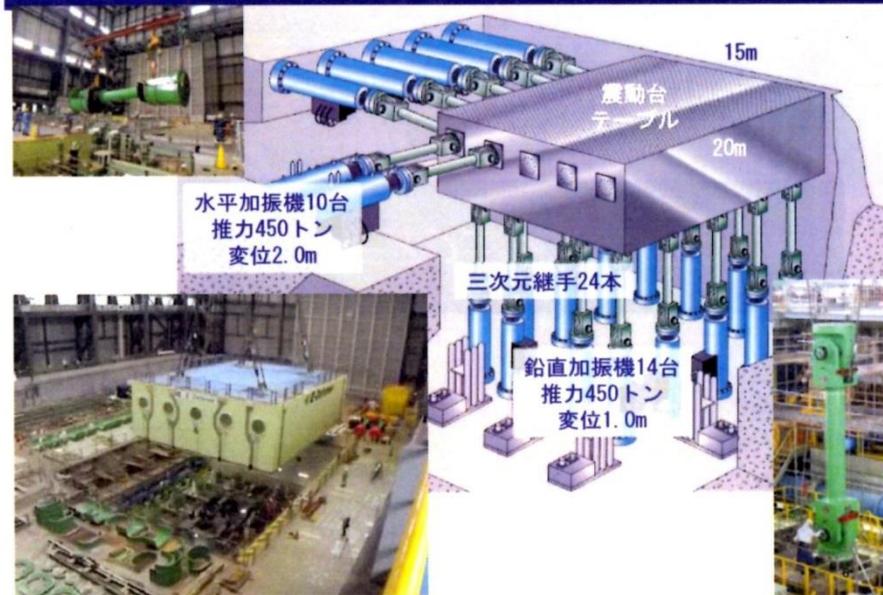
## 兵庫耐震工学研究センター(Eーディフェンス)

実物大あるいは大型の構造物試験体を《震動台》に載せ、巨大地震の揺れを、前後・左右・上下の三次元に直接与えることで、試験体の揺れ具合や損傷・崩壊の状況を再現・検討できる世界最大規模の実験施設。

Eーディフェンスは「世界最大の三次元震動台」として、2011年にギネス世界記録に登録されました。



## 実大三次元震動破壊施設(Eーディフェンス)



## 計測データについて



柱、梁の変形計測



床応答加速度、層間変位の計測



iPhoneでの加速度計測  
(i地震の構造ヘルスマモニタリングへの適用可能性の検証)

その他、鉄筋のひずみや、壁のせん断変形、加振映像など様々なデータが計測されている。

## データ公開システム

ASEBI (Archives of Shaking table Experimentation data Base and Information)



- ASEBIでは、実験で取得された、数値データ、画像などの情報を公開
- データ利用には、アカウント申請が必要
- 科学研究、教育又は行政目的にデータを利用可

## 2. 数値震動台の紹介

9

## 耐震シミュレータ(数値震動台)の開発

- 構造物の破壊過程をシミュレートするための解析技術を開発
- 室内被害をシミュレートするための解析技術を開発
- 建築物, 土木構造物, 地盤などのEーディフェンス実験の再現解析を通して, 開発した各種構造物および非構造部材の解析技術の妥当性を確認

10

## Eーディフェンス実験の再現解析: 鉄骨造建物

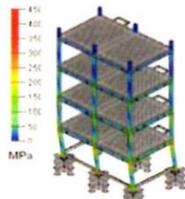
- 鋼材のパウシंगाー効果や降伏棚を表現可能な構成則を開発
- 適切な解析条件の検討
  - 使用する有限要素の選定
  - メッシュの解像度
  - 時間刻みの解像度
- JR鷹取波加振実験の再現解析を実施



解析モデル



全体崩壊(左:実験, 右:解析)



鋼管の局部座屈  
(上:実験, 下:解析)

- 局所的な現象(局部座屈)に起因する全体崩壊の再現に成功した

11

## Eーディフェンス実験の再現解析: 鉄筋コンクリート橋脚

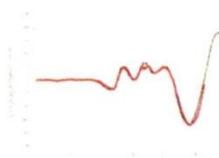
- コンクリートの弾塑性構成則として前川構成則を再定式化して実装
- コンクリートの亀裂を解析する手法を開発(PDS-FEM)
- JR鷹取波加振実験の再現解析を実施



RC橋脚試験体



解析モデル



変位応答  
(黒:実験, 赤:解析)



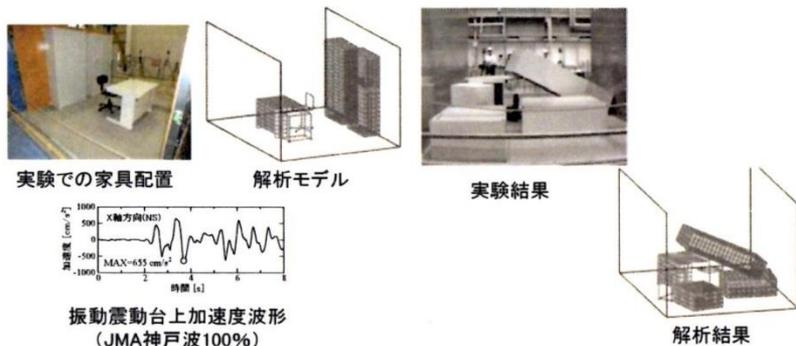
亀裂進展状況

- 阪神淡路大震災でみられた橋脚の破壊形式(曲げ先行型破壊)の再現に成功

12

## 家具の転倒挙動解析

- 複数の地震波入力に対するオフィス家具の加振実験の再現解析を実施



- 複数の地震波 (JMA神戸波, KiK-net芳賀波) での家具の転倒挙動を良好に再現

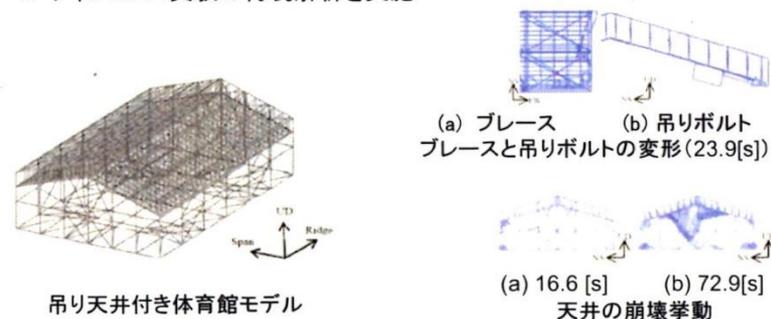
13

## 4. 実施中の研究内容 AIを用いた構造物の損傷推定

15

## 大空間建物実験の天井落下解析

- 天井と体育館構造躯体をモデル化
- 吊りボルトやブレースの座屈現象を考慮
- 脱落条件を導入
- E-ディフェンス実験の再現解析を実施

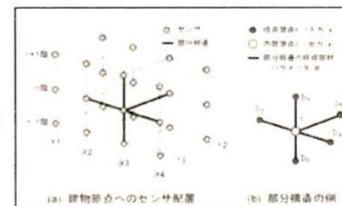


- 脱落箇所に相違はあるものの連鎖的な天井の脱落現象を再現

14

## 研究の背景: 建物の構造ヘルスマニタリング研究

- 少ないセンサー数で建物の健全性を評価する手法
  - 地震応答の最大値や累積値を推定し、設計クライテリアと比較
  - 振動特性に関わる特徴量 (層剛性, 減衰, 固有振動数) の変化を利用
  - 局所的な損傷の推定は難しい
- 局所的な損傷推定手法
  - 入出力関係をモデル化し、観測値と解析値の出力誤差から損傷箇所を推定
  - 別の箇所の損傷による観測値の変化の影響は考慮できない。



【参考文献】  
白石理人, 森井雄史, 岡田敬一, 杉本浩一, 佐藤俊明, 倉田真宏, 角田 浩: 多点高密度配置した振動センサと部分構造の出力誤差による局所損傷検出 - 多点同時計測システムの構築と超高層建物の大規模動台実験への適用, 日本建築学会構造系論文, 第62巻, 第76号, pp.603-611, 2017.6.

局所的な損傷推定の高精度化には、部分構造内に限定せず、広範囲の観測値を入力として、損傷箇所の情報を出力するニューラルネットワークの利用が好ましい。

16

## 研究の背景 : ニューラルネットワークの利用

### 教師あり学習

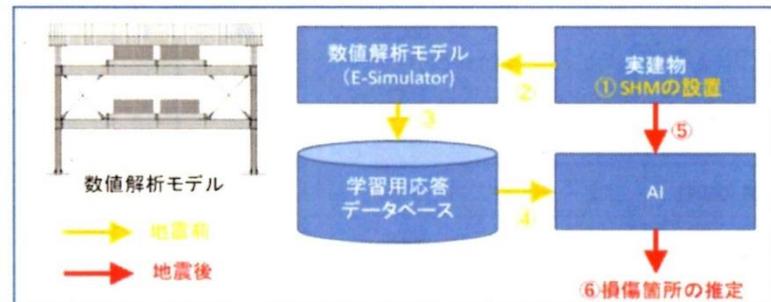
- 損傷パターンとその損傷パターンでの建物応答の学習データセットがあればモデル化が可能
- 建築物は単品生産のため同一建物の損傷時の応答を事前に収集することは不可能

学習データセットの生成には数値シミュレーションが必要となる。

17

## 研究の目的

数値震動台 (E-Simulator) (NIEDで開発している耐震シミュレータ) を用いた建物損傷箇所を判定する構造ヘルスマモニタリングの人工知能 (AI) システムを提案



提案システムの基礎的検討として,

- 振動台実験のデータを用いてディープニューラルネットワーク (DNN) で損傷ブレース部材を推定
- 提案システムへのDNNの適用性を検証

18

## 対象実験の試験体 (2016年11月実施)



1軸振動台

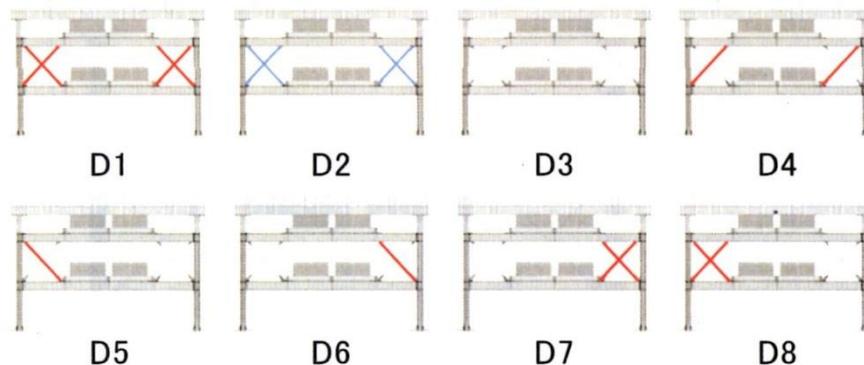
- 想定モデル: 短辺6m, 長辺方向12m, 高さ14m (階高3.5m) の4層の鋼構造骨組
- 実験モデル: 1/3縮小モデル. 3層, 4層は重量のみを考慮

2層目に4本のブレースを設置.  
ターンバックルを伸ばすことにより, 塑性変形による損傷を模擬

19

## 損傷パターン

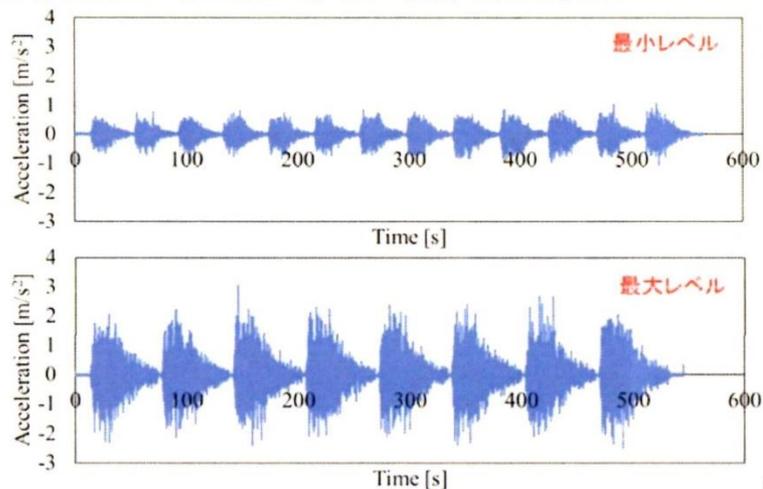
— 損傷大(2mm弛み)      — 損傷小(1mm弛み)



20

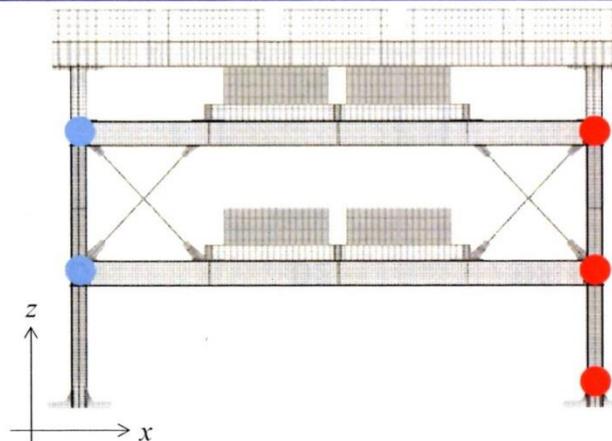
## 加振波

告示波の模擬地震波作成法を参考に加速度スペクトルと時刻歴波形を段階的に増加させて多数の模擬地震波を作成



21

## 学習およびテスト用データの取得位置



「センサー数3」: 赤丸; 「センサー数5」: 赤丸と青丸

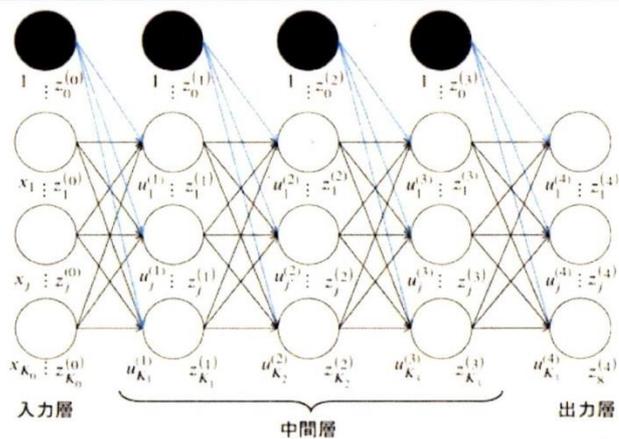
6自由度の小型慣性計測ユニットのMEMSセンサー(SEIKO EPSON製M-G550-PC)

サンプリング周波数500Hzで加速度3成分, 角速度3成分

「1成分」: x方向加速度成分; 「2成分」: x方向加速度成分, y軸周角速度成分

22

## DNNによる損傷パターンの多クラス分類



センサーデータ  
 $x \in \mathbb{R}^{K_0}$

1秒]: サンプル長1秒

2秒]: サンプル長2秒

センサーデータが与えられた時の  
損傷パターンの事後確率

$$p(D_i | x) \quad (i = 1, 2, \dots, 8)$$

$D = \{D_1, D_2, \dots, D_8\}$  損傷パターンのクラス集合

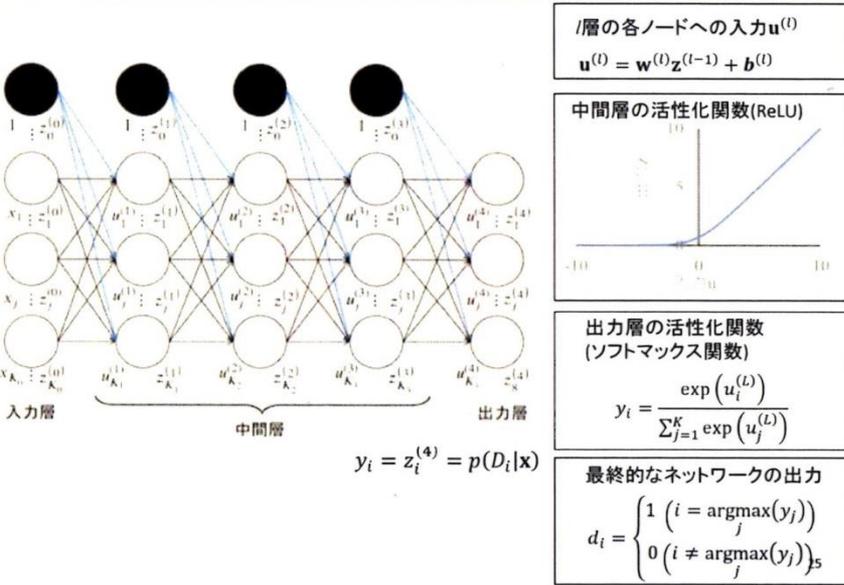
## 各ケースの入力層および中間層のノード数

センサー数	成分	サンプル長	入力層のノード数 $K_0$
3	1	1秒	1500
3	1	2秒	3000
3	2	1秒	3000
3	2	2秒	6000
5	1	1秒	2500
5	1	2秒	5000
5	2	1秒	5000

タイプ名	$(K_1, K_2, K_3)$
1	(100, 50, 25)
2	(500, 250, 125)
3	(1000, 500, 250)

24

## DNNの詳細



## 誤差関数 $E_n$ の勾配計算のフロー

### パラメータの更新

$$\mathbf{w}^{(t+1)} = \mathbf{w}^{(t)} + \epsilon \nabla_{\mathbf{w}} E_n$$

$$\mathbf{b}^{(t+1)} = \mathbf{b}^{(t)} + \epsilon \nabla_{\mathbf{b}} E_n$$

$\epsilon$ : 学習係数  
 ここでは  $\epsilon = 0.01$

$$\delta_i^{(l)} := \frac{\partial E_n}{\partial u_i^{(l)}}$$

式(11)により, 入力層から順に各層  $l (= 1, 2, \dots, L)$  のノードの入出力  $u^{(l)}, z^{(l)}$  を計算(順伝播)

$$\mathbf{u}^{(l)} = \mathbf{w}^{(l)} \mathbf{z}^{(l-1)} + \mathbf{b}^{(l)}$$

式(15)により出力層での  $\delta^{(L)}$  を計算する.

$$\delta_i^{(L)} = y_i - d_i$$

式(14)により出力層から入力層へ方向に中間層  $l (= L-1, L-2, \dots, 1)$  での  $\delta^{(l)}$  を計算する.(逆伝播)

$$\delta_i^{(l)} = \delta_k^{(l+1)} (w_{ki}^{(l+1)} f'(u_i^{(l)}))$$

式(11),(12)により, 誤差関数  $E_n$  の  $w_{ij}^{(l)}, b_j^{(l)} (l = 1, 2, \dots, L)$  に対する勾配を計算する.

$$\frac{\partial E_n}{\partial w_{ij}^{(l)}} = \delta_i^{(l)} z_j^{(l-1)}$$

$$\frac{\partial E_n}{\partial b_j^{(l)}} = \delta_j^{(l)}$$

## DNNのその他詳細

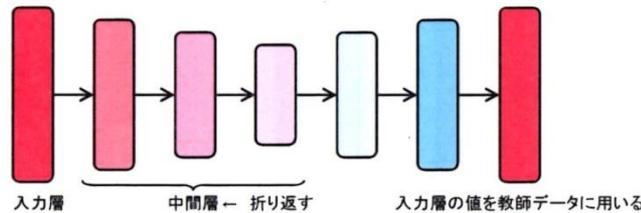
### パラメータの更新方法(ミニバッチ)

$\nabla_{\mathbf{w}} E = \sum_{n \in S} \nabla_{\mathbf{w}} E_n, \nabla_{\mathbf{b}} E = \sum_{n \in S} \nabla_{\mathbf{b}} E_n$  サンプル1つずつに対して更新すると計算コストを要する。  
 サンプルの集合毎にパラメータを更新する。  
 ここでは, バッチサイズを100とする。

### 事前学習

DNNでは,  $\delta$  の発散や消失によりパラメータの更新がうまくいけなくなる勾配消失問題が起り得る。

多層自己符号化器による事前学習により初期パラメータを求める。



### プログラム開発

プログラム言語: Python3.5.2  
 深層学習のフレームワーク: Chainer 1.20.0.1

## 交差検定による評価

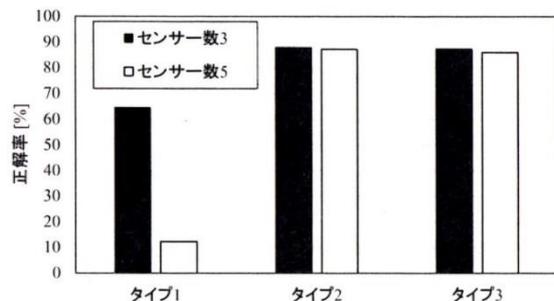
交差検定により, 適切なパラメータ設定を把握し, 提案するAIシステムの適用性を検証する

### 検証パラメータ

- 用いるセンサーの数: 3,5
- 自由度成分:
  - 1 (x方向加速度)
  - 2 (x方向加速度, y軸周角速度)
- サンプリング長: 1秒, 2秒
- 各階層のノード数:
  - タイプ1, タイプ2, タイプ3

タイプ名	$(K_1, K_2, K_3)$
1	(100, 50, 25)
2	(500, 250, 125)
3	(1000, 500, 250)

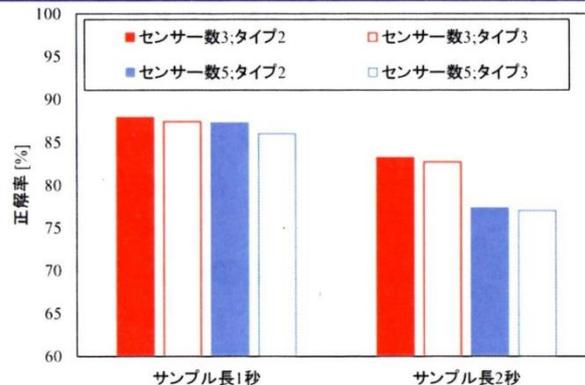
## 異なる中間層タイプでの正解率の比較



- 中間層のノード数が少ないタイプ1では正解率が低く、特に入力層のノード数が大きいセンサー数5では非常に低い正解率になっている。
- 中間層のノード数が多いタイプ2, タイプ3はセンサー数の数が変わっても大きな違いが見られず高い正解率となっている。

29

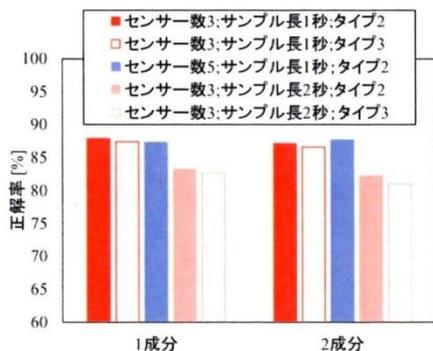
## 異なるサンプル長での正解率の比較



- いずれのセンサー数, 中間層タイプでもサンプル長が短いほうが, 正解率が高い結果となっている。
- サンプル長1秒のデータは学習データとして十分な情報量を保有しつつ, サンプル長2秒のケースに比べて2倍のサンプル数があるため

30

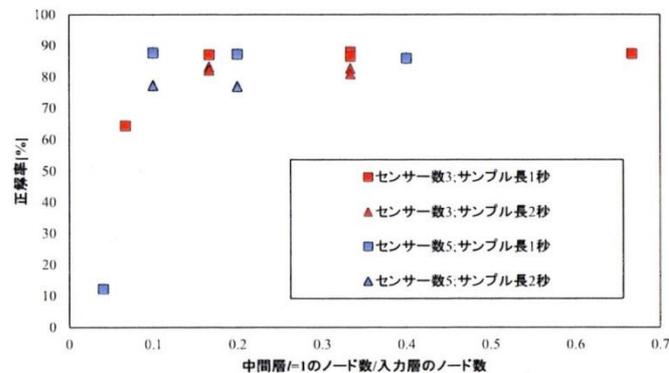
## 異なる自由度成分での正解率の比較



どのセンサー数, サンプル長, 中間層タイプでも, 用いる自由度成分数の違いによる正解率の大きな低下は見られない。

31

## ノード数比と正解率の関係



ノード数比が0.1より大きいケースでは77%以上の正解率を達成している

32

センサー数3, センサー成分1, サンプル長1.0秒, 中間層タイプ2のケースでの損傷判別結果

		実験結果(真値)								合計
		D1	D2	D3	D4	D5	D6	D7	D8	
推定結果	D1	5099	1595	23	13	0	0	5	9	6744
	D2	1476	4987	6	27	0	0	3	7	6506
	D3	4	2	6532	7	18	6	0	0	6569
	D4	6	11	1	5919	36	15	257	133	6378
	D5	0	0	32	43	6195	448	10	1	6729
	D6	0	0	5	14	341	5969	87	20	6436
	D7	2	1	1	347	10	150	5795	502	6808
	D8	13	4	0	230	0	12	443	5928	6630
合計		6600	6600	6600	6600	6600	6600	6600	6600	52800
正解率		0.773	0.756	0.990	0.897	0.939	0.904	0.878	0.898	0.879

黄色: 正解の判定結果となるセル; 青色: 誤判定結果が合計値の2%以上;  
 緑色: 誤判定結果が合計値の10%以上; 赤色: 誤判定結果が合計値の20%以上

- D1, D2の損傷パターンは他の損傷パターンに比べて正解率が低い。
- D1とD2は損傷箇所ではなく損傷の度合いが異なるパターンのため、誤判定する結果が多く正解率が低くなっている。
- 損傷ブレースの本数が同じ2本であるD4, D7, D8で誤判定が多く見られ、損傷ブレースの本数が同じ1本であるD5, D6で誤判定が多く見られる。
- 損傷ブレースが無いD3の損傷パターンが最も高い正解率となっている。

33

表-4 センサー数3, 自由度成分数1, サンプル長1.0秒, 中間層タイプ1のケースでの損傷判別結果

		実験結果(真値)								合計
		D1	D2	D3	D4	D5	D6	D7	D8	
推定結果	D1	2902	1512	4	14	1	0	1	4	4438
	D2	3482	4586	96	3	0	0	0	4	8171
	D3	184	464	6253	12	28	0	1	1	6943
	D4	25	25	215	5031	2058	77	530	234	8195
	D5	1	4	25	699	3900	593	464	242	5928
	D6	0	3	5	152	398	5353	2038	2362	10311
	D7	1	1	2	518	166	394	3074	817	4973
	D8	5	5	0	171	49	183	492	2936	3841
合計		6600	6600	6600	6600	6600	6600	6600	6600	52800
正解率		0.440	0.695	0.947	0.762	0.591	0.811	0.466	0.445	0.645

黄色: 正解の判定結果となるセル; 青色: 誤判定結果が合計値の2%以上;  
 緑色: 誤判定結果が合計値の10%以上; 赤色: 誤判定結果が合計値の20%以上

- 順序が近い損傷パターン、例えばD4とD5で誤判定が多く見られる。
- 中間層のノード数が少な過ぎてDNNのモデルとしての表現能力が劣るためと推察

34

## 結論

- ノード数の比が小さくなり過ぎると、正解率が急激に低下する。
- ノード数の比が0.1以上のケースでは77%以上の高い正解率となり、最も高い値として87.9%の正解率を達成し、DNNの高い適用性を示した。
- ノード数の比が0.1以上の場合の中間層タイプの違いや自由度成分数の違いが正解率に及ぼす影響はわずかであるが、サンプル長の違いが正解率に及ぼす影響は比較的大きく、サンプル長が2秒のほうがサンプル長1秒に比べて10%程度正解率が落ちるケースが見られた。
- それぞれの損傷パターンの判定結果から、損傷箇所が同じで損傷の度合い異なる損傷パターン間で誤判定が最も起きやすく、次いで、損傷ブレースの本数が同じ損傷パターン間で誤判定が起りやすいことがわかった。

35