

# データ駆動型アプローチによる地震動強さの距離減衰モデル 九州地方を例として

## SEISMIC ATTENUATION MODEL BASED ON DATA-DRIVEN APPROACH NUMERICAL EXAMPLES FOR THE KYUSHU DISTRICT IN JAPAN

○金子 健作<sup>\*1</sup>, 岩崎 友洋<sup>\*2</sup>, 野畑 有秀<sup>\*3</sup>  
Kensaku Kaneko<sup>\*1</sup>, Tomohiro Iwasaki<sup>\*2</sup>, and Arihide Nobata

\*1 東京工業大学 環境・社会理工学院建築学系 助教 博士 (工学)

Assistant Professor, School of Environment and Society, Department of Architecture and Building Engineering,  
Tokyo Institute of Technology, Dr. Eng.

\*2 株式会社大林組 原子力本部

Nuclear Division, Obayashi corporation

\*3 株式会社大林組 技術研究所 博士 (工学)

Technical Research Institute, Obayashi corporation, Dr. Eng.

### Summary:

This paper describes a seismic attenuation model to estimate peak ground acceleration in the Kyushu district using a deep neural network. We used over 15,000 training data available from public K-NET and KiK-net database, involving the 2016 Kumamoto Earthquake in Japan. Selected input parameters fed to a neural network are JMA (Japan Meteorological Agency)-based magnitude of earthquakes, focal depth, focal distance, and Vs30 as soil profile (mean shear velocity over the top 30 m of soil). Without a priori knowledge from historical findings, a deep neural network is constructed, except that the network features three parallel sub networks with fully connections respectively. These output values are added to estimate peak ground acceleration (PGA). An algorithm of weighted neural network training is employed for the training data, which are unbalanced on account of Gutenberg-Richter law. The trained neural network estimates PGA for a wide variety of both the magnitude and focal distance. The estimated PGA was in good accordance with a typical attenuation model based on a combination of equations.

**キーワード:** ニューラルネットワーク; 地動加速度; 距離減衰式; 構造モニタリング; 機械学習

**Keywords:** Neural network; peak ground acceleration; attenuation model; structural monitoring; machine learning.

### 1. はじめに

サイトの地震ハザードを評価するうえで、地震動の距離減衰評価は重要な役割を果たす。これまで多くの研究者の活動により、様々な距離減衰モデルが提案されている<sup>例え(1), (2)</sup>。まだ強震観測データが現在ほど充実していない時代から、建物や地盤被害などの経験的事実や三次元弾性波動論に基づき、距離減衰の回帰式が半理論的に定められ、そのパラメータが推定されている。その推定手続きに関しても、地震学の専門的見地から、多くの配慮がおこなわれている<sup>3)</sup>。これらは、専門家による仮説駆動型の距離減衰モデルといえる。民間の強震観測データも公開され、表層地盤の影響の高度化が図られるなか、こうした専門家に保証された距離減衰モデルは、なお重要である。

その一方、非公開の強震観測データも増えてきて

いる<sup>4)</sup>。近年では、地震後における建物の使用継続性の判定に構造モニタリングシステムが普及しつつあり、自発的な建物の強震観測が徐々に増えている。さらに、安価な MEMS 型の加速度センサーや、Raspberry Pi などのシングルボードコンピュータが手軽に利用できるようになり、市民目線からも強震観測をする敷居はずいぶん低くなった。Raspberry Pi とセンサー類がモジュール化されたパッケージ Raspberry Shake<sup>5)</sup>も市販され、世界的な強震観測網を構築する民主化プロジェクトが立ち上げられている。個別的にも、既往の距離減衰モデルと、非公開の観測データを組み合わせ、個別サイトのハザード評価に運用する試みもなされている<sup>6)</sup>。

こうした観点から、本研究では、機械学習の一種である深層ニューラルネットワークを用いた、データ駆動型の距離減衰モデルに焦点をあてる。その目

的は、距離減衰モデルの逐次学習の自動化や、公開・非公開の観測データセット結合の容易性に期待がもてることである。画像認識などの分野では、近年、様々な学習済みネットワークがウェブに公開されている。さらに、最近、ニューラルネットワークに関して、ONNX (Open Neural Network Exchange) などの共通フォーマットが策定された。その結果、オープンソースコードである TensorFlow や MXNet などのライブラリのほかに、商用コードの MATLAB なども含めて、学習済みネットワークを自由にコンバートできるようになった。こうした情報環境の急速な変化を踏まえると、非公開で使用する独自の距離減衰モデルを構築するのに、ニューラルネットワークを利用する価値は高まってきたと考えられる。

ニューラルネットワークを適用した距離減衰モデル自体は、1990年代から、これまで多く検討されている(例えば7)~11)。いずれも、従来の距離減衰式と同等の結果が得られたと簡単に報告されている。しかし、用いられたネットは、いずれも1層あるいは2層の隠れ層を有する階層型である。望ましいネットのあり方については、深く検討されていない。

こうした背景を踏まえて、本研究では、九州地方を例にとり、従来の研究よりも多くの教師データを用い、ニューラルネットワークによる距離減衰モデルを検討する。

## 2. 教師データ

### 2.1 教師データの作成方法

ニューラルネットワークの学習には、防災科学技術研究所 (NIED) の強震観測網 (KiK-net および K-NET) の強震データベースを利用する(図1)。データベースから、九州地方およびその周辺域(北緯30°~35°、東経128°~133°の範囲)において1996年から2018年の間に発生した、気象庁マグニチュード4.5以上の地震を選定した。強震観測データ(地表記録を対象)は、主要動を含め抽出した20秒間(最大加速度発生時刻の-8秒から+12秒まで)の前後2秒を cosine 型テーパ処理したうえで、加速度基線補正を施す。対象地震の総数は計171であり(図2)、このうち代表的なものを表1に示す。表2の地域特性区分と表3に分類したサイト特性ごとに、最大地動加速度(PGA)の学習結果を整理する。

### 2.2 入力変数

ネットワークに入力する教師データは、地震の気象庁マグニチュード  $M_j$  と震源深さ  $D$  (km)、等価震源距離  $X_{eq}$  (km)<sup>12)</sup>、観測点における深さ30mの地盤の平均せん断波速度  $V_{S30}$  (m/s)、震源の緯度・経度の6種とする。対応する出力は、PGA ( $cm/s^2$ )

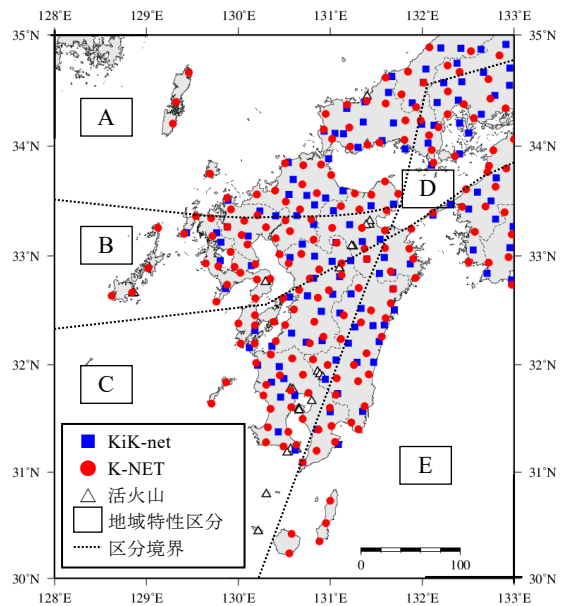


図1 観測地点および地域特性区分の設定




図2 九州地方の地震動分布(1996年~2018年)

とする。PGA は水平2方向成分のベクトル和で評価した値とする。教師データの統計量を図3に示す。

### 2.3 教師データの前処理

学習を成功させるためには、教師データに対しておこなう前処理が重要である。一般に、ニューラルネットワークの入力層と出力層に与える教師データの数値の範囲は、互いに大きく離れないことが望ましい。そこで、PGA、 $X_{eq}$  および  $V_{S30}$  については、その常用対数を教師データに用いる。その他については、教師データセットの取り方に依存しない基準化が望ましい。マグニチュード  $M_j$  は9、震源深さ

表1 教師データに含まれる代表的な地震

地震名	マグニチュード*	
	Mj	Mw
2005年福岡県西方沖地震 (本震)	7.0	6.6
2005年福岡県西方沖地震 (最大余震)	5.8	5.4
2006年大分県西部地震	6.2	6.4
2015年薩摩半島西方沖地震	7.1	6.8
2016年熊本地震 (前震)	6.5	6.1
2016年熊本地震 (本震)	7.3	7.1
2016年熊本地震 (最大余震)	5.9	5.7

\*Mj: 気象庁マグニチュード, Mw: モーメントマグニチュード

表2 NIED観測サイトの地域特性区分

地域特性区分 (グループ)	観測サイト数		
	KiK-net	K-NET	計
A 九州地方北部 (火山フロント背弧側) *1	35	45	80
B 九州地方中部 (火山フロント背弧側)	17	38	55
C 九州地方南西部 (火山フロント背弧側)	26	45	71
D 中国・四国地方の一部 (火山フロント前弧側) *2	16	16	32
E 九州地方南東部 (火山フロント前弧側) *3	32	46	78
計	126	190	316

\*1: 中国地方の一部を含む

\*2: 中国・四国地方の一部における火山フロント～中央構造線の区域, \*3: 四国地方の一部を含む

表3 サイトの分類


名称	分類条件 (m/s)
軟質	$V_{S30} < 300$
中質	$300 \leq V_{S30} < 700$
中硬質	$700 \leq V_{S30} < 1000$
硬質	$1000 \leq V_{S30}$

Dは35km, でそれぞれ基準化する。X<sub>eq</sub>は300km以下を対象とし, 対数をとらない X<sub>eq</sub>の入力(3.1節で後述)に対しては, 300kmで基準化する。


### 3. ニューラルネットワークおよび学習方法

#### 3.1 アーキテクチャ

ニューラルネットワークのアーキテクチャを定める方針として, 先験的知識や, データセットに関する事前知識を可能な限り含めないこととする。ただし, 単純な全結合のフィードフォワード型ニューラルネットワークでは, 震源距離が短い範囲で, 推定値が学習に用いた初期値に大きく左右される。それを緩和するため, 等価震源距離 X<sub>eq</sub>を用い, 地震動の幾何減衰と粘性減衰を説明できるような Log X<sub>eq</sub>と



(a) 気象庁マグニチュード Mj (b) 震源深さ D



(c) 等価震源距離 X<sub>eq</sub> (d) V<sub>S30</sub>

図3 教師データのヒストグラム

X<sub>eq</sub>の双方を入力層に与える。また, 震源深さ Dと V<sub>S30</sub>の入力をそれぞれ独立にした, 3つのサブネットから成るネットを採用する(図4)。それぞれのサブネットの出力値を単純和して, 最終的な出力である PGAの常用対数を得る。Mj, Log X<sub>eq</sub>, X<sub>eq</sub>を入力するサブネット Aは, 隠れ層を3つ設定する。それらの活性化関数は, ロジスティック・シグモイド関数とする。入力層で20%, 隠れ層では50%の確率で, ノードを不活性化させる(ドロップアウト)。これは, 重みの初期値を変えた複数のネットをアンサンブル平均することに相当する。サブネット Cは, V<sub>S30</sub>による表層地盤の増幅特性という物理的意味を有する。サブネット Dは, 地震タイプを分類するネットであり, その出力層をソフトマックス関数とする。別途, 地震タイプ(内陸地殻内地震, プレート内地震, プレート境界地震)の分類問題(付録1)を学習させた後(損失関数を相対エントロピー誤差), これを全体ネットに組み込む。この際に, サブネット Dの重みはフリーズさせる。サブネット Eは, 地震タイプに応じた PGAの補正を学習する。表4にネットワークの全体構成を示す。

以上述べたようなサブネットから成るネットを構築することは, 転移学習に便利である。例えば, 学習済みネットについて, サブネット Aと Bの重み係数を変化させずに(学習率を部分的に0に設定), サブネット Cのみを再学習させ, サイト固有のデータを重視することなどの応用が考えられる。従来の単純な全結合層から成るニューラルネットワークでは, このような応用は困難である。

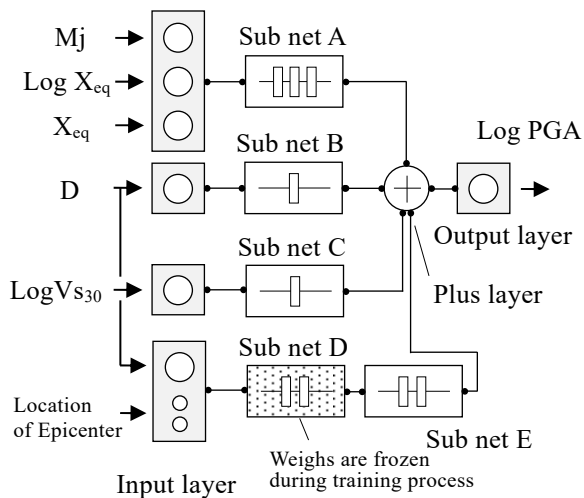


図4 ニューラルネットワークの構成

表4 サブネットワークの構成

名称	構成	活性化関数	備考
A	隠れ層数 3* (ノード数 20, 40, 20)	シグモイド関数	ドロップアウト
B	隠れ層数 1 (ノード数 10)	シグモイド関数	—
C	隠れ層数 1 (ノード数 10)	Tanh 関数	—
D	隠れ層数 2 (ノード数 20) 出力層: ソフトマックス関数	Tanh 関数	地震タイプの分類 (付録1)
E	隠れ層数 2 (ノード数 20)	Tanh 関数	—

\*最終出力を絶対値演算する。

### 3.2 活性化関数および損失関数

ニューラルネットワークの損失関数は、つぎのように考える。従来の距離減衰式において、Log PGAの推定値と観測値（正解値）との残差は、正規分布となることが知られている<sup>13)</sup>。そのため、用いる損失関数は、二乗和平方誤差を基本とする。

一般に、教師データには、各項目に含まれる数が偏りなく、均一に分散していることが望ましい。しかし、マグニチュードの小さなデータは、教師データの多くを占める。この不均衡データを処理する単純な方法は、マグニチュードの小さなデータの一部を教師データから除外することである。しかし、教師データの減少は、学習の安定性を低下させる。もう一つは、深層学習の常套手段であるデータの水増しであるが、これも本研究の分野では難しい。

そこで、本研究では、重み付き損失層を有するニ

ューラルネットワーク学習の方法を採用する。この方法では、学習データのカテゴリ（ここでは、マグニチュード）の重要度に応じて、損失に重みを与える。この新たな重み付き損失関数を最小化するようにネットを学習させる。具体的には、次式の重み付き損失関数  $L$  を用いる。

$$L = \frac{(\log_{10} \text{PGA}_{(i)\text{出力}} - \log_{10} \text{PGA}_{(i)\text{正解}})^2}{n(M_{j(i)})} \quad (1)$$

ここに、 $n(\cdot)$  は集合の要素数である。これを計算グラフで表すと、図5のようになる。図に記載の Main net は、図4のネットワークを指す。

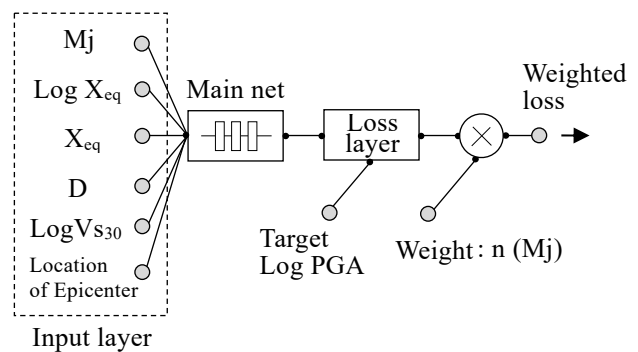


図5 重み付き損失層を有するネットの計算グラフ

### 3.3 学習方法

教師データを用いたネットの学習には、誤差逆伝播法を用いる。局所最適解に陥ることを防ぐ目的として、勾配法には、モーメントム付きの ADAM (ADaptive Moment estimation) を用いる。

全データのうち、全地震（1996年～2018年）に対して無作為に抽出した80%の地震に関するデータを学習に用いる。残りの20%は、学習中に生じうる過学習の判定のための、検証データとする。

ネットの学習の実装には、オープンソースの深層学習パッケージである MXNet を利用する。計算には、エッジデバイスに利用できる、シングルボードコンピュータの Raspberry Pi Model B+ を用いる。

### 4. 学習結果

学習したニューラルネットワークを用いて、内陸地殻地震に限定して推定した、PGA と等価震源距離  $X_{cq}$  の関係を図6と図7に示す。推定に用いる震源深さ  $D$  は 10km、 $V_{s30}$  の値は 400 m/s とした。また、各サイトの  $V_{s30}$  の値に応じて表3の4条件で分類し、 $M_j \pm 0.1$  に含まれる結果を図示した。ここでは比較例として、司・翠川 1999 の距離減衰式<sup>1)</sup>を示す。この距離減衰とニューラルネットの推定値の傾向は、よく類似していることがわかる。マグニ

チュードが大きい場合の震源近傍における PGA の飽和特性など、これまでの観測的事実とよく適合している。

残差解析の結果を表 5 に示す。ニューラルネットによる推定 PGA の残差の対数標準偏差(常用対数)は概ね 0.3 前後であり、既往研究と同等である<sup>13)</sup>。

## 5. まとめ

本研究では、九州地方を対象として、K-NET や KiK-net の強震観測データ (1996 年から 2018 年) と深層ニューラルネットワークを用いて、地動加速度 PGA の機械学習を試みた。

得られた結論を以下に要約する。

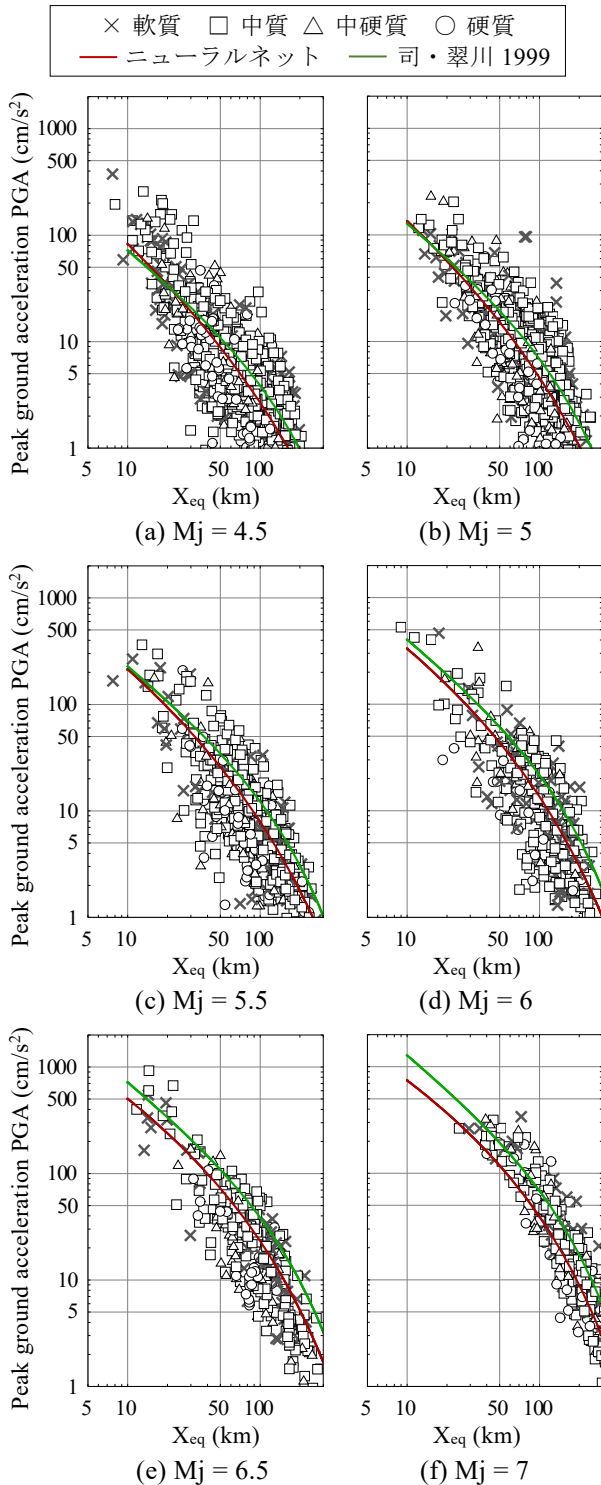


図 6 PGA と震源距離の関係 (内陸地殻内地震) 火山フロント背弧側: グループ A, B, C




図 7 PGA と震源距離の関係 (内陸地殻内地震) 火山フロント前弧側: グループ D, E

表 5 推定 PGA 値からの観測値の対数標準偏差

地域 区分	C				B				I			
	I	IIa	IIb	III	I	IIa	IIb	III	I	IIa	IIb	III
A	0.33	0.33	0.29	0.28	0.31	0.23	0.26	0.22	0.36	0.30	0.34	0.30
B	0.29	0.33	0.28	0.31	0.23	0.34	0.24	0.26	0.36	0.37	0.32	0.32
C	0.28	0.27	0.28	0.28	0.30	0.23	0.26	0.24	0.37	0.30	0.33	0.27
D	0.34	0.36	0.29	0.26	0.38	0.33	0.32	0.28	0.35	0.38	0.33	0.30
E	0.31	0.28	0.32	0.26	0.32	0.36	0.29	0.27	0.44	0.37	0.34	0.32

注 1) 地震タイプ； C：内陸地殻内地震，  
B：プレート境界地震，I：プレート内地震  
地盤タイプ； I: 硬質，IIa: 中硬質，IIb: 中質，III: 軟質  
注 2) 値は  $\text{Log}_{10}(\text{PGA}_{\text{ニューラルネット}}/\text{PGA}_{\text{観測値}})$  の標準偏差を示す。

- ニューラルネットワークを複数のサブネット  
で構成することにより，硬質地盤での距離減  
衰，表層地盤の増幅および地震タイプが最大  
地動加速度に及ぼす影響を分離したうえで，  
それらを一度の学習で獲得できる。
- カテゴリに含まれる教師データ数の多寡に応  
じて，損失関数を重み付けした計算グラフを  
採用することにより，低頻度の大きなマグニ  
チュードに対する PGA の未学習を避けられる。
- 学習したニューラルネットワークと，既往の  
関数近似による距離減衰式（司・翠川 1999）  
を比較し，マグニチュードや震源距離に関し  
て同様な傾向を確認できた。推定 PGA 値から  
の観測値の対数標準偏差は，0.3 前後であった。

今後は，ニューラルネットワークの構成をさらに  
高度化することにより，地震動の伝播経路や Q 値  
の情報に関する特徴量を学習により獲得し，PGA  
の評価精度を向上させることが課題である。

ところで，新たに入手した学習データを用いて学  
習済みネットを更新する際に catastrophic forgetting  
という問題をこれまで有していたが，この欠陥を回  
避する方法が提案されている<sup>14)</sup>。これは，ベイズ  
の定理に基づいて，学習結果の良し悪しを測る損失  
関数の L2 ノルム正則化項に，学習済みモデルと学  
習中の重みパラメータの 2 乗和誤差とフィッシャ  
ー情報行列を乗じた値を加えるものである。これに  
より，以前に学習した内容を大きく忘却することな  
く，新たに地震観測で得た情報を取り入れることが  
期待できる。また，独自の観測データを用いて，ニ  
ューラルネットワークで作成された距離減衰モデル  
を転移学習することも考えられる。このような観  
点から，ベイズ統計学のアルゴリズムを導入して，  
PGA のばらつきを獲得したうえで，学習済みニュー  
ラルネットの継続的かつ長期的な更新に取り組  
む予定である。

## 謝辞

本研究では，防災科学技術研究所が公開している  
K-NET と KiK-net の強震観測データを使用した。ここに  
謝意を示します。

## 【参考文献】

- 1) 司宏俊，翠川三郎：断層タイプ及び地盤条件を考慮した最  
大加速度・最大速度の距離減衰式，日本建築学会構造系  
論文集，No. 523，pp. 63-70，1999
- 2) Kanno et al.: A new attenuation relation for strong ground  
motion in Japan based on recorded data, Bull. Seism. Soc.  
Am., Vol. 96, pp. 879-897, 2006
- 3) 福島美光：地震動強さの距離減衰式（経験式）に関する最  
近の研究動向，地震，第 46 巻，pp. 315-328，1993
- 4) 日本建築学会強震観測小委員会：第 6 回強震データの活  
用に関するシンポジウム - 将来の大地震に備えて-，  
2018.12
- 5) <https://raspberrysake.org>。(参照 2019-09-24)
- 6) 里優，鶴岡大和：距離減衰式と実測加速度を用いた想定地  
震時における加速度の推定方法，第 14 回日本地震工学シ  
ンポジウム，2014
- 7) I. Ahmad, M. Hesham, El. Naggat, and A. N. Khan: Neural  
Network Based Attenuation of Strong Motion Peaks in Europe,  
Journal of Earthquake Engineering, pp. 663-680, 2008
- 8) B. Derras, P. Bard, F. Cotton, and B. Abdelmalek: Adapting the  
neural network approach to PGA prediction- An example  
based on the KiK-net data, Bulletin of the Seismological  
Society of America 102(4), pp. 1446-1461, 2012
- 9) H. Güllü, and E. Erçelebi: A Neural Network Approach for  
Attenuation Relationships, Engineering Geology 93, pp.  
65-81, 2007
- 10) T. Kerh and S.B. Ting: Neural network estimation of ground  
peak acceleration at stations along Taiwan high-speed rail  
system, Engineering Applications of Artificial Intelligence,  
Vol. 18, Issue 7, pp. 857-866, 2005
- 11) H. Hong, T. Liu, and C-S Lee: Observations on the application  
of artificial neural network to predicting ground motion  
measures, Earthquake Science, Vol. 25, Issue 2, pp. 161-175,  
2012
- 12) S. Ohno et al.: Revision of attenuation formula considering the  
effect of fault size to evaluate strong motion spectra in near  
field, Tectonophysics, Vol. 218, pp. 69-81, 1993
- 13) 翠川三郎，大竹雄：地震動強さの距離減衰式にみられるバ  
ラツキに関する基礎検討，日本地震工学会論文集，Vol. 3，  
No. 1, pp. 59-70, 2003
- 14) J. Kirkpatrick et al: Overcoming catastrophic forgetting in  
neural networks, Proceedings of the National Academy of  
Sciences of the United States of America, 114 (13), pp.  
3521-3526, 2017

## 付録 1 地震タイプの機械学習

震源の緯度・経度，震源深さを入力して，あらかじめ分類し  
た地震タイプを学習させた。混同行列を付表 1 に示す。

付表 1 地震タイプの混同行列

		推定したクラス			
		C	B	I	計
S 鑑 別 率	C	8474	0	0	8474
	B	0	2640	94	2734
	I	0	178	3823	4001
	計	8474	2818	3917	15209

注) 地震タイプ； C：内陸地殻内地震，  
B：プレート境界地震，I：プレート内地震