T2R2東京工業大学リサーチリポジトリ Tokyo Tech Research Repository

論文 / 著書情報 Article / Book Information

論題(和文)	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
Title(English)	SEISMIC ATTENUATION MODEL BASED ON DATA-DRIVEN APPROACH NUMERICAL EXAMPLES FOR THE KYUSHU DISTRICT IN JAPAN
著者(和文)	金子健作, 岩崎 友洋, 野畑有秀
Authors(English)	Kensaku Kaneko, Tomohiro Iwasaki, Arihide Nobata
出典(和文)	情報・システム・利用・技術シンポジウム論文集,,,
Citation(English)	Proceedings of the Symposium on Computer Technology of Information, Systems and Applications, , ,
発行日 / Pub. date	2019, 12

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^{*1}, 岩崎 友洋^{*2}, 野畑 有秀^{*3} Kensaku Kaneko^{*1}, Tomohiro Iwasaki^{*2}, 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^{例えば1),2)}。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³⁾。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⁴。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 Shake⁵⁾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て、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。。

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 型テーパー処理したうえで,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 Mj と震源深さ D (km), 等価震 源距離 Xeq (km)¹²⁾,観測点における深さ 30m の地 盤の平均せん断波速度 Vs30 (m/s), 震源の緯度・経 度の6種とする。対応する出力は、PGA (cm/s²)



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、Xegおよび Vs30 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 Mj は 9, 震源深さ

表1 教師データに含まれる代表的な地震

マグニチュード*			
Mj	Mw		
7.0	6.6		
5.8	5.4		
6.2	6.4		
7.1	6.8		
6.5	6.1		
7.3	7.1		
5.9	5.7		
	マグニチ Mj 7.0 5.8 6.2 7.1 6.5 7.3 5.9		

'Mj: 気象庁マグニチュード, Mw: モーメントマグニチュート

表2 NIED 観測サイトの地域特性区分

	地域特性区分	観測サイト数			
	(グループ)	KiK-net	K-NET	計	
Α	九州地方北部 (火山フロント背弧側)* ¹	35	45	80	
в	九州地方中部 (火山フロント背弧側)	17	38	55	
С	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	
Е	九州地方南東部 (火山フロント前弧側)* ³	32	46	78	
	≣ i -	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

13	911-0万規
名称	分類条件(m/s)
軟質	$Vs_{30} < 300$
中質	$300 \leq Vs_{30} < 700$
中硬質	$700 \leq Vs_{30} < 1000$
硬質	$1000 \leq Vs_{30}$

表3 サイトの分類

D は 35km, でそれぞれ基準化する。X_{eq} は 300km 以下を対象とし,対数をとらない X_{eq} 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_{eq}を用い、地震動の 幾何減衰と粘性減衰を説明できるよう Log X_{eq} と



 X_{eq} の双方を入力層に与える。また、震源深さ D と Vs30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 Xea, Xea 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、Vs30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) 一誤差),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

名称	構成	活性化関数	備考	
А	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	
В	隠れ層数1 (ノード数10)	シグモイド 関数	_	
С	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)	
Е	隠れ層数2 (ノード数20)	Tanh 関数	_	

表4 サブネットワークの構成

*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¹³⁾。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。

$$L = \frac{\left(\log_{10} \text{PGA}_{(i) \boxplus \beta} - \log_{10} \text{PGA}_{(i) \boxplus \beta}\right)^2}{n(M_{j(i)})}$$
(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, モーメンタム付きの 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_{eq} 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, $Mj\pm0.1$ 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¹⁾ 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¹³⁾。



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。



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	С			В			Ι					
区分	Ι	IIa	IIb	III	Ι	IIa	IIb	III	Ι	IIa	IIb	III
А	0.33	0.33	0.29	0.28	0.31	0.23	0.26	0.22	0.36	0.30	0.34	0.30
В	0.29	0.33	0.28	0.31	0.23	0.34	0.24	0.26	0.36	0.37	0.32	0.32
С	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
Е	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Log₁₀ (PGA = - - ラルネット/PGA _{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¹⁴⁾。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]

- 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
- 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
- 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://raspberryshake.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
- I. Ahmad, M. Hesham, El. Naggar, 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
- 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
- 23) 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						
	С	8474	0	0	8474			
いべん	В	0	2640	94	2734			
実ク際ラ	Ι	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