

# Convolutional Neural Network to Detect Deep Low-Frequency Tremors from Seismogram Images

(畳み込みニューラルネットワークによる地震波形画像からの深部低周波微動の検出)

数理情報学専攻 48206211 金子 亮介

指導教員 長尾 大道 准教授

## 1 はじめに

1996年、高感度地震観測網 (Hi-net) の運用が開始され従来よりも高感度な地震観測が可能になったことをきっかけに、2002年に深部低周波微動と呼ばれる現象が発見された [3]。微動はスロー地震と呼ばれる現象の一つであり、巨大地震の発生予測への活用が期待されるなど地震学分野において近年盛んに研究が行われている。しかし、微動に関するデータは現状では Hi-net 整備以降の約 20 年分しか存在しない。過去に発生した微動を検出することができれば、長期的なデータをもとに微動の特性がより明らかになると期待される。

約 50 年前の地震計は、観測された波形をペンで直接紙に書き記すことで記録を行っていた。このような紙記録は過去に発生した地震現象を知るための唯一無二のデータであり、記録の一部はスキャンにより画像データに変換されている (図 1) [4]。古記録画像 (PSI) から微動検出を試みる場合、微動の振幅が微弱かつ継続時間が最大で数日間に及ぶ現象であることをふまえると、通常地震を検出対象とする際に一般に用いられる波形のトレーシングや目視検出を行うことは困難である。

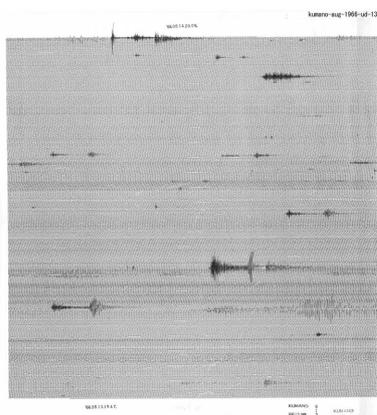


図 1: 熊野観測点における PSI の一例。

本研究では、畳み込みニューラルネットワーク (CNN) に基づき PSI から微動検出を行う手法を提案する。CNN は画像認識に特化した深層学習手法の一つであり、地震学において CNN を利用した既存研究はいくつ

か存在するが、地震波形画像、特に PSI に対して CNN の適用を試みた例はない。

## 2 人工波形画像を用いた学習

CNN の有効性を検証するため、PSI をもとに人工波形画像を作成し CNN を学習させる数値実験を行った [2]。人工画像に関しては、含まれる波形の種類や振幅の大きさを変えた 3 種類のデータセットを作成し、各データセットが微動なし画像と微動あり画像を同数ずつ含むように構成した。各画像は古記録と同様の形式で波形をプロットし正方形画像として作成した後、縦に 5 分割し粗視化を行った。CNN に関しては、ResNet [1] の構造に基づき設計した (図 2)。この CNN は入力画像に対して微動なし確率  $p_{\text{none}}$  と微動あり確率  $p_{\text{tremor}}$  の 2 値を出力し、 $p_{\text{none}}$  と  $p_{\text{tremor}}$  の大小を比較することで画像内に微動が含まれるかどうかを判定する。

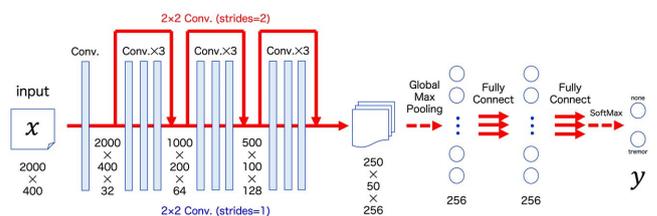


図 2: 数値実験に用いたモデル (CNN-2) の構造。

実験の結果、CNN は画像内に微動が含まれるかどうかをほぼ確実に判定することができた。また、Grad-CAM [5] に基づきヒートマップを作成したところ、微動が含まれる箇所まで正しく検出できることが確認された (図 3)。

## 3 実データを用いた学習

PSI への適用に向け、人工画像よりも多種多様なノイズを含む実データを用いた CNN の学習を行った。教師データには Hi-net のデジタルデータを変換した波形画像 (MSI) を使用した。学習の際には、CNN を予め人工画像で学習させておいた後に MSI で学習を行うという、ファインチューニングと呼ばれる手法を用いた。数

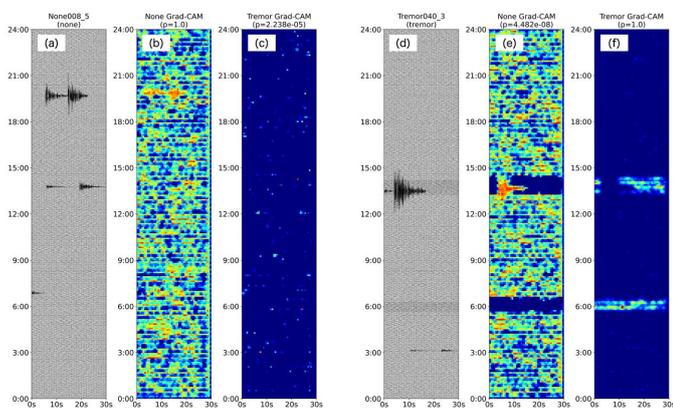


図 3: 数値実験の結果. 微動なし画像 (a) に対しては無反応であるが (c), 微動あり画像 (d) に対しては微動に反応している様子が確認される (f).

値実験で用いたモデル (CNN-2) と構造に改良を加えたモデル (CNN-7) の 2 つを学習の対象とした.

学習の結果, 2 つの CNN はともに高い正答率で微動の有無を判定することができ, ヒートマップ上では微動が含まれる箇所を検出している様子が確認された (図 4). また, CNN-2 の方が計算コストが小さく, CNN-7 の方が高感度であるといった特性の違いも確認された.

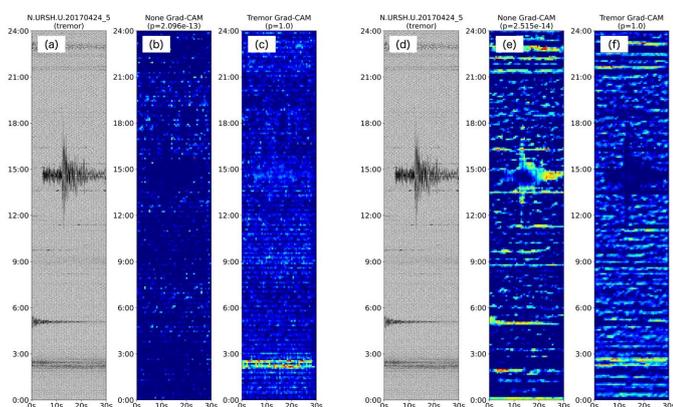


図 4: MSI を用いた学習の結果. 微動あり画像 (a)(d) に対して CNN-2 (c) と CNN-7 (f) ともに画像下部の微動に対して反応している.

## 4 古記録への適用

MSI で学習を行った CNN-2 および CNN-7 を, 1966 ~1977 年に熊野観測点で記録された PSI に適用した. 5 分割された画像のうち  $p_{\text{none}}$  よりも  $p_{\text{tremor}}$  の方が大きかった画像の枚数で予測の強さを図ったところ, 微動ありの予測が強い日が「断続的な期間」と「連続的な期間」があることが判明した (図 5). 「断続的な期間」に関しては微動と思われる波形を検出する様子が確認さ

れた (図 6). 一方で, 「連続的な期間」に関してはペン太さや地震計の不具合が起因して正常な判定ができていないと分析した.

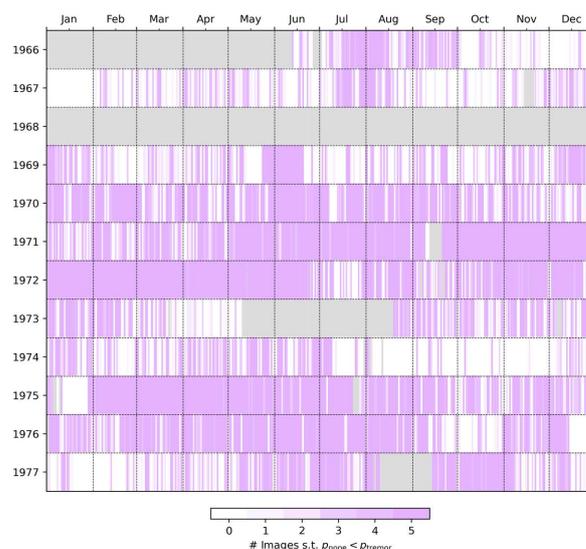


図 5: PSI へ適用した結果. 色が濃いほど画像に対して微動ありの予測が強いことを表す.

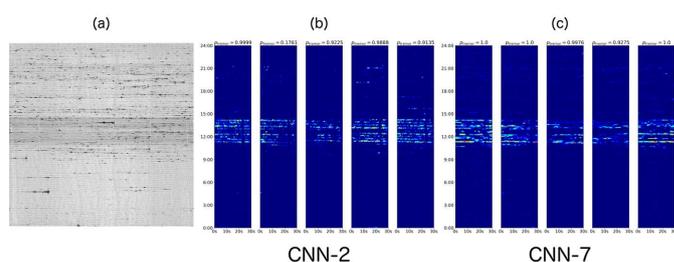


図 6: PSI への適用例. PSI (a) に対して CNN-2 (b) と CNN-7 (c) ともに微動と思われる波形を検出している.

## 5 参考文献

- [1] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770–778. DOI: 10.1109/CVPR.2016.90.
- [2] R. Kaneko, H. Nagao, S. Ito, K. Obara, and H. Tsuruoka, “Convolutional neural network to detect deep low-frequency tremors from seismic waveform images,” in *Lecture Notes in Computer Science*, vol. 12705, 2021, pp. 31–43. DOI: 10.1007/978-3-030-75015-2\_4.
- [3] K. Obara, “Nonvolcanic deep tremor associated with subduction in southwest Japan,” *Science*, vol. 296, no. 5573, pp. 1679–1681, 2002. DOI: 10.1126/science.1070378.
- [4] K. Satake, H. Tsuruoka, S. Murotani, and K. Tsumura, “Analog seismogram archives at the Earthquake Research Institute, the University of Tokyo,” *Seismological Research Letters*, vol. 91, no. 3, pp. 1384–1393, 2020. DOI: 10.1785/0220190281.
- [5] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, “Grad-CAM: Visual explanations from deep networks via gradient-based localization,” in *2017 IEEE International Conference on Computer Vision*, 2017, pp. 618–626. DOI: 10.1109/ICCV.2017.74.