

高精度な地殻変動モニタリングのための AI 大気遅延ノイズ補正技術の構築 (第 3 年次)

実施期間 令和 5 年度～令和 7 年度
地理地殻活動研究センター 田中 優介
宇宙測地研究室

1. はじめに

ゆっくりすべり (Slow Slip Events) (以下「(SSE)」という.) と呼ばれる主にプレート境界で発生する非定常な断層すべりは、断層の摩擦特性やひずみ収支を理解する上で重要な現象であり、また巨大地震の前駆現象として発生する (していた) 可能性も指摘されるなど理学・防災の両面で重要性が高い。このため多数の先行研究によって SSE の時空間分布の把握が進められてきており (e.g., Ozawa et al., 2016), 特に国土地理院が整備・運用する電子基準点のデータが多大に活用されている。この中で座標時系列のノイズレベルを下回るような、数ミリ以内の微小な SSE シグナルを統計数理的な技法で検出する手法がいくつか考案されているが (e.g., Nishimura et al., 2013), こうした長期・多点の座標時系列を客観的に処理する手法の確立は安定した持続的な SSE モニタリングのために不可欠である。

こうした状況に対して地震波検出の分野では機械学習を用いた自動処理が既に発達しており、膨大な波形データの効率的かつ高精度な処理を実現している (e.g., Mousavi et al., 2020)。一方、GNSS 時系列をはじめとする測地データへの機械学習の適用は依然として例が少なく (Xue and Freymueller, 2023), 特に実データを直接学習した例はほとんど見当たらない状況である。同様に、大気遅延など座標値とともに推定されるほかの未知パラメータに機械学習を適用した例も少なく、微小な地殻変動の検出とそのためのノイズ除去に対する機械学習の有効性は不明なところが多い。

上記の背景に基づき、本研究課題では西南日本の電子基準点の座標時系列実データの機械学習による SSE シグナル検出を試みた。なお、研究課題名に示すとおり、当初の研究計画では大気遅延ノイズ時系列の学習と推移予測及び補正技術の開発を最終目標としていたが、座標時系列の学習のみで多くの結果と検討課題を得たため、同内容の報告のみにとどめる。本研究課題は科学研究費補助金 (研究課題番号: 23K13182) の研究課題として令和 7 年度から持ち込まれたものだが、説明の完全性を保つために、本稿では令和 5・6 年度の実施内容も含めて通しで記述する。第 4 章以降が今年度の実施内容である。

2. 研究内容

2.1 学習データの生成

本研究では PPP-AR 解析で取得した西南日本の 770 の電子基準点の日座標時系列を使用し、Okada et al. (2022) によるテンプレートマッチングを用いた短期 SSE 検出カタログに基づいて学習データを抽出した。同カタログで示されている 1997 年から 2020 年の 284 個の検出イベントの矩形断層モデル (図-1) から Okada (1992) のグリーン関数で地表変位の理論値を算出し、一定以上の大きさのシグナルが期待される観測点・時期の時系列をシグナルデータとして抽出した。反対にシグナルが含まれない時系列を同じ個数だけランダムに抽出し、これらをノイズデータとした。いずれも時間窓の長さは 121 日で、水平方向 2 成分のみ用いた。単一観測点での学習の場合はこれらの時系列一つ一つをそのまま入力データとし、隣接 2 観測点を併用した学習ではドロネー三角網で隣接する 2 点の時系列を並

べたものを入力データとした。ただし2点ともシグナルの場合及び2点ともノイズの場合に限定した。抽出したデータを 2:1 から 3:1 程度の個数になるよう 2 グループに分割し、それぞれ学習データ・テストデータとした（表-1）。




図-1 解析地域の概要。四角が研究で使用した電子基準点、赤色長方形が Okada et al. (2022)の検出カタログによる 284 イベントの矩形断層モデルを表す。破線は Hirose et al. (2008)によるプレート境界深度。

表-1 学習データ及びテストデータの個数

単一観測点の場合			
	シグナル	ノイズ	計
学習	9,118	9,194	18,312
テスト	3,657	3,688	7,345
隣接 2 観測点併用の場合			
	シグナル	ノイズ	計
学習	35,850	36,014	71,864
テスト	12,944	12,780	25,724

2.2 機械学習の手法

ここでは地震波検出のために考案された手法である Generalized Phase Detection (GPD) (Ross et al., 2018) を参考に、畳み込みニューラルネットワーク (Convolutional Neural Network) (以下「CNN」という。)を用いた特徴抽出・シグナル判定を試みた。モデルは前述の変位時系列を入力として 2 層の畳み込み層と 2 層の線形層で特徴抽出を行い、時系列がシグナルである確率を出力するものである。学習時の正解は 0 又は 1 とし、正解と推定値の一致度合いを評価する損失関数は交差エントロピーを用いた。

3. 学習の結果と特徴

図-2 に単一観測点で学習した場合の損失関数の値と正答率の推移、またシグナル振幅と判定成績の関係を示す。以降はシグナル確率の推定値が 0.5 以上になった場合をシグナル判定として扱う。正答率は 75-76%で頭打ちとなり、また大きいシグナルほど見逃し(=正解はシグナルだが、ノイズと判定)の割合が低くなった。3 mm を超えるシグナルについては、見逃しはほぼゼロとなった。今回使用した時系列の平均的なノイズレベルが 2-3 mm のため、S/N 比 1 を少し超える大きさに相当する。




図-2 学習の結果。(a) 損失関数と正答率の推移。赤色が学習データ自身、青色がテストデータに対する値を示す。横軸は時間ではなく学習エポック、すなわちニューラルネットワークの制御パラメータの最適値を探索するイタレーションの回数を表す。(b) シグナル振幅のヒストグラム。下段がテストデータの全シグナルについて、中段が見逃したシグナルについてのヒストグラムで、上段が両者の比をとったもの。

図-3 に誤検知(=正解はノイズだが、シグナルと判定)したデータに対する確率推定値を示す。本研究では結果の安定性を担保するために、ニューラルネットワークのパラメータの初期値をランダムに変えて 10 回の学習・判定を繰り返し試した。その上で 10 回とも誤検知した 154 個のノイズデータに対する結果を示したものである。いずれもシグナル確率 0.8-1.0 程度の高い値を示すが、移動平均を用いて 10 日以上以上の長周期成分を除去すると 0.0-0.3 程度まで低下し誤検知でなくなる。同結果から GNSS 時系列に特有の時間相関するノイズが誤検知を引き起こす様子が明らかである。10 日から数十日周期のノイズの要因は多彩な解釈がなされているが (Ray et al., 2013), 複雑なノイズ挙動を網羅的に把握できる学習手法の検討が引き続き必要である。




図-3 誤検知が顕著なノイズデータ 154 個に対する確率推定値。上段が元の結果で、下段は 10 日移動平均を差し引いて平坦化したデータを再度判定させた結果。赤点が初期値を変えて 10 回判定した個々の値で、黒点が 10 回の平均値を表す。右側にノイズデータとその平坦化したものの一例を付す。

一般に SSE のシグナルは近接する複数の観測点で似た方向に生じるのに対して、ノイズの方向は比較的不規則である。そのため複数点の動きを同時に扱う方が判定に有利になると予想される。こうした意識の下で隣接 2 観測点を併用した学習・判定も試したが、正答率は 76-77%で単一観測点の場合とほぼ同じであった。今回学習した短期 SSE はシグナルの広がり数十キロ程度であり、電子基準点の平均的な配置間隔である 20-30km に対して元々空間スケールが小さい。そのため複数点を組み合わせるとシグナル発生域の中心を飛び越えてしまい、必ずしも効果的でないと解釈される。

4. SSE 把握能力の検討・議論（ここから R7 年度の主な実施内容）

ここまでの結果を受けて、単点での判定結果の時空間分布に基づいてイベントか否かを判断する方針について更に検討を進めた。このような手順は地震波検出の分野ではアソシエーションと呼ばれる。初めに図-4 に、個別の SSE に対する単点での判定結果の空間分布を示す。ここではイベント発生日をまたぐ 11 個の時間窓（50 日前から 50 日後を 10 日間隔。時間窓自体の長さが 121 日のため、これ以上ずらすとイベントが時間窓の外にはみ出す）をテストデータとし、初期値を変えた 10 個の学習済みモデルに入力した際のシグナル判定の割合を一括で算出した。同値は正解がシグナルである観測点に対しては検出成功率、それ以外の周囲の観測点に対しては誤検知率を意味する。図のように単点で独立した判定であっても、空間方向によく連続した結果を示すことが分かる。シグナルがない周囲の観測点での検出率は 0.2-0.3 程度と比較的低い値を示すが、局所的に誤検知と思われる値が高い観測点もあり、どのように排除するかは検討課題である。また図-4 は日付の異なる時間窓の判定結果を全て合算しており、さらにシグナル確率 0.5 を少しでも超えたものは全て同等に扱われる点で、好意的に示されやすい図であることに注意を要する。




図-4 個別の SSE に対する検出率の空間分布. 四国西部・四国東部・東海の 3 地域で比較的大きいイベントの例を示しており、それらの発生日と規模を図中に示す. 赤色長方形は Okada et al. (2022) のカタログによる各イベントの矩形断層モデルを表す. 正解がシグナルである観測点を丸, それ以外の観測点を四角で示し、各点での検出成功率又は誤検知率をカースケールで示す.

図-5 には個別の観測点の時系列を、学習済みモデルに順に入力した場合のシグナル確率の推移を示す. 確率の推移は非常に振動が激しいが、数エポックごとの移動平均をとると傾向が明瞭になり、既知イベントに対応してピークを示す様子が分かる. しかしながらイベント発生期間の一部分だけで瞬間的にピークとなる場合が多く、連続して高いシグナル確率を示すことができていない. また既知のイベントとの対応が不明なピークも多数存在する.




図-5 四国西部の観測点（図の赤星印）の全時系列を 10 日おきに入力した場合のシグナル確率の推移. 中段がそのままの結果、下段が移動平均を加えた結果、上段が正解ラベルを表す.

同様のシグナル確率の推移を四国西部から九州の 60 観測点について示したものが図-6 である. 正解と比較するとやはり振動が激しいが、誤検知に関しては 1 点のみで孤立したものが多い. 本物のシグナルは空間的に連続すると考えてこれらを除外すれば、誤検知は 3-4 割減らすことができる. 一方でより顕著な問題は正検知の少なさであり、正解ラベルと比べて時空間的な連続性が明らかに劣る.

今回のような初歩的な CNN を用いた判定には限界があり，高度なアソシエーションの手法に加えてモデル自身の性能向上も必要と考えられる．




図-6 四国西部から九州の 60 観測点の全時系列を 10 日おきに入力した場合のシグナル確率の推移. 6 エポック移動平均の値をカラスケールで表示. 横軸が時間，縦軸が経度で，図の上方が東である．

CNN は機能的にはフィルター処理に似ており，時系列の各部分の特徴をスライドしながら抽出していくものである．そのため地震波の立ち上がりのような不連続な特徴変化の発見には適しているが，SSE のような緩やかな傾向変化を捉えるには必ずしも最適でない．今後は再帰型ニューラルネットワークなど，時系列全体の特徴を前後関係まで含めて扱えるようなモデル構造を用いることも考えられる．また地震計データは基本的にゼロ付近で振動する平坦な時系列だが，GNSS 時系列は傾きを持つことが多い．そこで例えば，少しずつ異なる傾きを加えたデータを学習することでモデルの冗長性を

高められる可能性がある。データ個数を増幅させる工夫は、地震波形に比べて SSE 時系列のデータが遙かに少ないことから重要である。また本研究の主目的は現実のノイズ特性を直接学習させることにある。シグナル時系列については検出済みの実データにこだわらず、様々なパターンの SSE に対応する人工のシグナルを生成し、実データのノイズ時系列に足すことで学習データ数を増やすという手法も考えられる。最後に、地震波検出の場合のアソシエーションは空間分布だけでなく到着時刻も併せて考慮する。一方で SSE の立ち上がりは時間方向の不確実性が大きく、ほぼ同時として扱うことになる。すなわちアソシエーションは空間方向のみになる。そのため、グラフ理論に基づく解析 (e.g., Sagae et al., 2025) など、地震波検出で既に活用済みの高度な手法を積極的に取り入れる必要がある。

5. 結論

本研究では客観的かつ自動化された SSE モニタリングの確立に向けて、西南日本の GNSS 時系列の実データの機械学習によるシグナル検出を試みた。先行研究による短期 SSE 検出カタログで示されたイベントを教師データとして用い、CNN (畳み込みニューラルネットワーク) によるシグナル・ノイズの判定を行った結果、75-77%の正答率を得た。また大きいシグナルほど見逃しの割合が低く、S/N 比 1 を超えるシグナルであればほぼ必ず検出に成功するなど直感に合う傾向が得られた。これらの結果は単点の座標時系列で学習・判定した場合と隣接 2 観測点の時系列を併用した場合でほぼ同様であり、複数観測点の併用が必ずしも情報量を向上させるわけではないことが示唆された。

上記を受けて単点での判定結果の時空間配置からイベントの有無を判断する方針を更に検討した。単点による学習モデルで推定されるシグナル確率は、個別のイベントに注目すれば空間的によく連続して高い値を示す場合も見られた。一方で時間方向は振動が激しく、イベント発生期間のごく一部でしか高い値を示さない場合が多いほか、既知のイベントが存在しない時期にも誤検知と思われる多数のピークが示された。安定した SSE モニタリングの実現のためには学習モデル自体の更なる性能向上が不可欠であり、全国の座標時系列の多彩なノイズ挙動を余すところなく把握させるための学習手法の工夫や、地震波検出の分野で用いられているグラフ理論等による高度なアソシエーション技法の併用を検討する必要があると考えられる。

参考文献

- Hirose, F., Nakajima, J., and Hasegawa, A. (2008): Three-dimensional seismic velocity structure and configuration of the Philippine Sea slab in southwestern Japan estimated by double-difference tomography, *Journal of Geophysical Research*, 113(B9), B09315. doi:10.1029/2007JB005274
- Mousavi, S. M., Ellsworth, W. L., Zhu, W., Chuang, L. Y., and Beroza, G. C. (2020): Earthquake transformer—An attentive deep-learning model for simultaneous earthquake detection and phase picking, *Nature Communications*, 11(1), 3952. doi:10.1038/s41467-020-17591-w
- Nishimura, T., Matsuzawa, T., and Obara, K. (2013): Detection of short-term slow slip events along the Nankai trough, southwest Japan, using GNSS data, *Journal of Geophysical Research: Solid Earth*, 118(6), 3112–3125. doi:10.1002/jgrb.50222
- Okada, Y. (1992): Internal deformation due to shear and tensile faults in a half-space, *Bulletin of the Seismological Society of America*, 82(2), 1018–1040. doi:10.1785/BSSA0820021018
- Okada, Y., Nishimura, T., Tabei, T., Matsushima, T., and Hirose, H. (2022): Development of a detection method for short-term slow slip events using GNSS data and its application to the Nankai subduction zone, *Earth Planets and Space*, 74(1), 18. doi:10.1186/s40623-022-01576-8

- Ozawa, S., Tobita, M., and Yarai, H. (2016): A possible restart of an interplate slow slip adjacent to the Tokai seismic gap in Japan, *Earth Planets and Space*, 68(1), 54. doi:10.1186/s40623-016-0430-4
- Ray, J., Griffiths, J., Collilieux, X., and Rebischung, P. (2013): Subseasonal GNSS positioning errors, *Journal of Geophysical Research: Solid Earth*, 40(22), 5854–5860. doi:10.1002/2013GL058160
- Ross, Z. E., Meier, M.-A., Hauksson, E., and Heaton, H. T. (2018): Generalized seismic phase detection with deep learning, *Bulletin of the Seismological Society of America*, 108(5A), 2894–2901. doi:10.48550/arXiv.1805.01075
- Sagae, K., Kano, M., Yabe, S., and Uchide, T. (2025): Machine Learning - Based Detection and Localization of Tectonic Tremors in the Japan Trench, *Journal of Geophysical Research: Solid Earth*, 130, e2025JB031348. doi:10.1029/2025JB031348
- Xue, X., and Freymueller, J. T. (2023): Machine learning for single-station detection of transient deformation in GPS time series with a case study of Cascadia slow slip, *Journal of Geophysical Research: Solid Earth*, 128(2), e2022JB024859. doi:10.1029/2022JB024859