

GNSS データから算出される ひずみ時系列の地震発生前の変化の検知

三神 厚¹・神山 眞²

¹ 正会員 東海大学教授 工学部土木工学科 (〒259-1292 神奈川県平塚市北金目 4-1-1)

E-mail: atsushi.mikami@tokai.ac.jp

² フェロー会員 東北工業大学名誉教授 (〒982-8577 宮城県仙台市太白区八木山香澄町 35-1)

E-mail: mk_kamiyama@jcom.home.ne.jp

本研究は GNSS データから評価した地盤ひずみの時系列データに対し、地震発生前の予兆の存在を前提として、機械学習の方法を適用することで何らかの「異常」の検知を試みたものである。2016 年熊本地震について、震源付近の地盤の工学的最大せん断ひずみの時系列を用意し、オートエンコーダに地震発生数年前までのデータを地震の予兆が含まれていないものとして学習させる。学習後のオートエンコーダに地震発生直前までのひずみ時系列を入力として与えた時に求められる出力と実データの差から再構成誤差の評価を行い、それが大きい場合にはデータに何らかの「異常」があるものと仮定した。その結果、地震時 (coseismic) 変動の大きい領域では、地震発生直前に再構成誤差が大きくなった。一方で、地震時変動の小さいエリアでは再構成誤差に大きな変化は見られず、異常は検知されなかった。

Key Words: earthquake prediction, GNSS data, maximum shear strain, machine learning, autoencoder

1. はじめに

国土地理院は、全国約 1,300 ヶ所に電子基準点を展開し、GNSS 衛星の信号を常時観測している。GNSS とは Global Navigation Satellite System の略で、GPS (Global Positioning System) 等の測位衛星システムの総称である。全国の電子基準点とつくばの中央局からなる GNSS 連続観測システムは GEONET (GNSS Earth Observation Network System) と呼ばれる。観測データはインターネットを通じて公開され、測量業務のみならず、i-Construction の推進や火山、地震防災等にも活用されている¹⁾。

著者らにおいても、2011 年東北地方太平洋沖地震による地殻変動からの回復過程の考察²⁾や漁港施設の復興工事への影響等についての検討³⁾に活用してきたが、さらに地震予測への活用も推進している。発生時刻、震源地、マグニチュードをある範囲内で正確に予測することが求められる短期的な地震予知の実現については否定的な見方が多いが、著者らは短中期的な予測の実現を目指し、GNSS データの積極的活用を進めている。

その際、問題となるのは、地震の予兆らしき現象についての判断である。地震発生以前の累積ひずみが漸減傾向を示した後、地震が発生するように「見える」ことは

地震予知の関係者の一部で共通認識として持たれているようであるが、このような主観的な判断に頼らず、いかに客観的な判断を下すかということが重要であるように思われる。

このような問題に対し、神山らは、地殻変動の日々の活動度を表現した活動度係数を導入し、その変化パターンの認識から地震の予兆を探知する試みを行っている⁴⁾。

本研究では機械学習の技術に基づく異常検知の手法が地震の予兆を捉えるのに有効ではないかと考え、その適用を試みる。具体的には、GNSS データから評価される地盤のひずみデータ (最大せん断ひずみ) の時系列に対し、機械学習で用いられる異常検知の方法として、オートエンコーダを用いた方法を適用することで、地震発生前の何らかの予兆を客観的に捉えようとしたものである。ここでは、神山ら⁵⁾による 2016 年熊本地震の際のひずみ時系列算定結果から、特に、震源付近の地盤ひずみ時系列を用い、機械学習の方法を適用するものである。

2. GNSS データを用いたひずみ時系列の算出

本研究では、神山らによる要素分割⁵⁾に基づき、2016

年熊本地震発生前のひずみ時系列を評価する．ここでは、地震発生数年前までのひずみ時系列には地震発生の予兆が含まれていないものと仮定する．

(1) 用いるデータ

補正され、信頼性の高い測位プロダクトである日々の座標値 (F3 解) を用いる．これは、24 時間平均座標値を 12:00(UTC)の値として公開されているものである．

(2) 要素分割

神山ら⁵⁾はデローニ三角分割のアルゴリズムを用いて九州全域における三角形網を作成した (図-1)．三角形の3つの頂点にあたる位置が GEONET 観測点で、そこでは東西 (EW)、南北 (NS)、上下 (UD) の3方向変位が与えられることになる．

(3) ひずみの算定と最大せん断ひずみ

神山らを参考にして、ひずみは次の(1)~(4)式によって算定する．ここに、下記の式の工学的最大せん断ひずみ γ_{\max} を対象とした．

$$\{\varepsilon\} = [B]\{U\} \quad (1)$$

ただし、 $\{\varepsilon\} = \{\varepsilon_{EW}, \varepsilon_{NS}, \gamma_{NE}\}$ で ε_{EW} は東西方向の直ひずみ、 ε_{NS} は南北方向の直ひずみ、 γ_{NE} はせん断ひずみである．また、 $\{U\} = \{u_i, v_i, u_j, v_j, u_k, v_k\}^T$ において、 u_i, u_j, u_k は節点 i, j, k における東西方向変位で、 v_i, v_j, v_k は、節点 i, j, k における南北方向変位である．また、最大主ひずみ ε_{\max} 、最小主ひずみ ε_{\min} 、工学的最大せん断ひずみ γ_{\max} は、以下のように求められる．

$$\varepsilon_{\max} = \frac{\varepsilon_{EW} + \varepsilon_{NS}}{2} + \sqrt{\left(\frac{\varepsilon_{EW} - \varepsilon_{NS}}{2}\right)^2 + \left(\frac{\gamma_{NE}}{2}\right)^2} \quad (2)$$

$$\varepsilon_{\min} = \frac{\varepsilon_{EW} + \varepsilon_{NS}}{2} - \sqrt{\left(\frac{\varepsilon_{EW} - \varepsilon_{NS}}{2}\right)^2 + \left(\frac{\gamma_{NE}}{2}\right)^2} \quad (3)$$

$$\frac{\gamma_{\max}}{2} = \frac{\varepsilon_{\max} - \varepsilon_{\min}}{2} \quad (4)$$

3. オートエンコーダを用いた再構成誤差の評価

(1) オートエンコーダ (自己符号化器)⁶⁾ とは

入力したデータと同じデータが出力側で再生されるよ

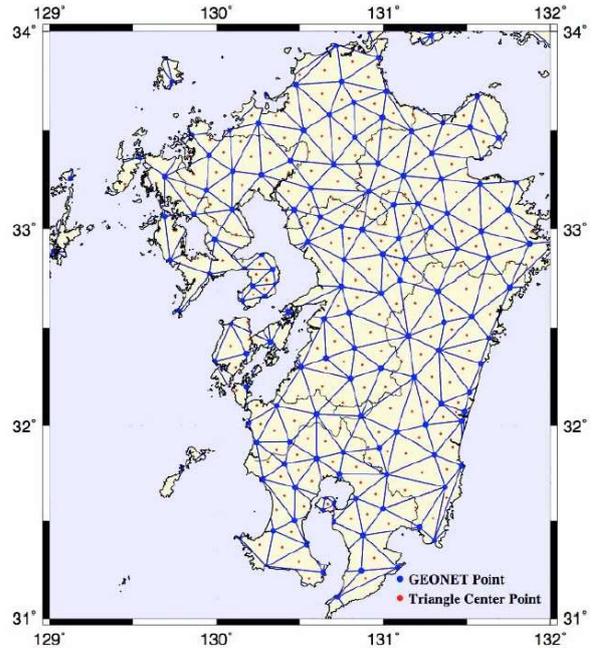


図-1 GEONET 観測点を用いたデローニ三角分割⁵⁾

うに信号の特徴を学習させるネットワークのことで、次元削減を伴うことが特徴である．もとの正常な時系列を再生するようにウェイトを学習する．

なお本研究では、オートエンコーダを適用するにあたり、MATLAB の Neural Network Toolbox と Statistics and Machine Learning Toolbox を用いた⁷⁾．

(2) 再構成誤差を用いた異常検知

時系列が正常である場合には、出力側でもとの波形が再構成されるので再構成誤差は小さくなるが、時系列に異常データを含む場合には、出力側でもとの波形の再構成が適切に行われず再構成誤差が大きくなってしまふ⁷⁾．ここでは、再構成誤差が大きくなった場合のひずみデータを異常データとして扱い、地震の予兆と仮定する．

(3) オートエンコーダの基本特性の評価

オートエンコーダを実観測記録に基づくひずみ時系列に適用する前に、本節では簡単な正弦波に適用し、オートエンコーダの基本特性の理解を深める．

時間間隔 0.01 秒で 2000 個の正弦波データを用意し、前半の 1000 個を学習用に用いることにする．検証はすべてのデータを用いる．そのため、最初の 1000 個については、学習用と検証用が同じものなので、正常と判断されることになる．50 個のデータで 1 サンプルとしているため、2000 個のデータからなる 20 秒間のデータは、40 サンプルということになる．

a) 振幅変化、周波数一定の正弦波による検討

正弦波の周波数は 1(Hz) で一定だが、振幅が 10 秒で 1 から 2 に変化する場合を考える．図-2 のように、振幅の

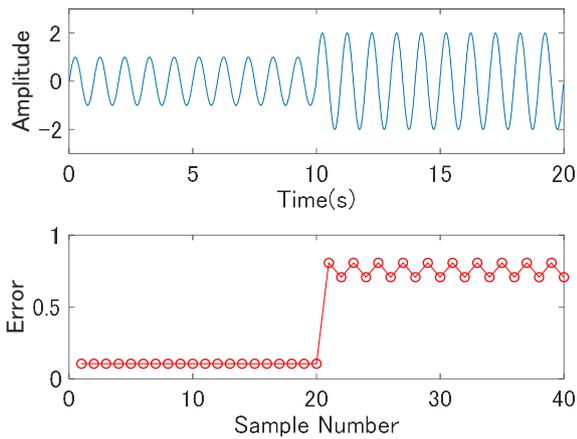


図-2 振幅が変化する場合の再構成誤差

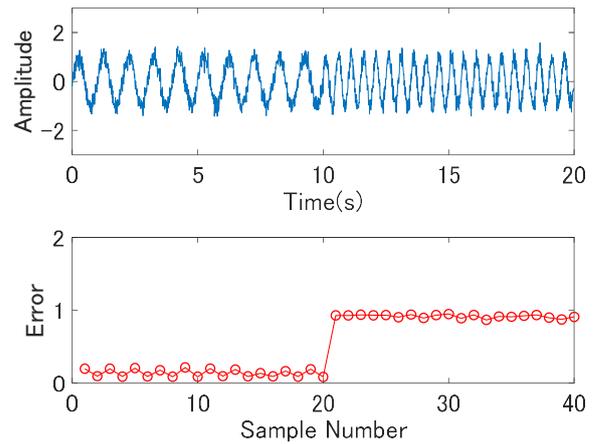


図-4 周波数が増える場合の再構成誤差

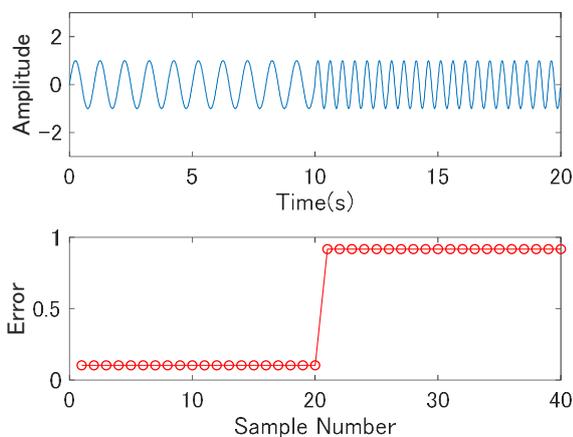


図-3 周波数が増える場合の再構成誤差

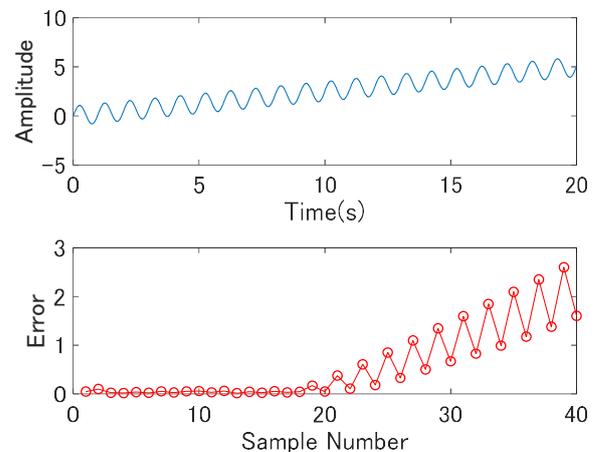


図-5 周波数が増える場合の再構成誤差

変化は再構成誤差に影響を与えることから、もしひずみデータに振幅の変化があったなら異常と捉えることになる。

b) 振幅一定、周波数変化の正弦波による検討

次に、振幅が一定だが、正弦波の周波数が 10 秒で 1(Hz)から 2(Hz)に変化する場合を考える。図-3 のように、周波数の変化は再構成誤差に影響を与えることから、学習したデータと異なる周波数の信号を異常と捉えることになる。

c) 振幅一定、周波数変化、ノイズありの正弦波による検討

同じく振幅が一定で正弦波の周波数が 1(Hz)から 2(Hz)に変化する場合の異常検知を考えるが、今度は、ノイズの影響がある場合を考える。ここでは、正規乱数を考え、振幅の 20%のノイズを付加する。図-4 に示すように、この場合もノイズの影響を受けるものの周波数変化の検知は可能と思われる。

d) 振幅、周波数とも一定だがバイアスがある場合の正弦波による検討

地殻変動記録の中には、常時の変動が顕著なものがある。

ここでは、振幅、周波数とも一定の正弦波に常時の地殻変動に見られるようなバイアスがかかっている場合を考える。再構成誤差の評価結果を図-5 に示す。学習用に用いる 10 秒までの記録にも右上がりの直線状のバイアスがかかっているが、10 秒以降のデータでは再構成誤差が発生してしまう。このことから、地殻変動データを扱う際、地震時の地殻変動と比較して無視できない程度に常時の地殻変動がある場合は、それを除去する必要があるものと考えられる。

4. GNSS データを用いた検討結果

以上の考察結果に留意しながら GNSS データを用いた検討を行う。今回、着目した要素は、図-6 に示す赤枠の範囲の三角形要素 248, 252, 254, 266, 277, 278 である。

例として、要素 252 について説明する。要素 252 は、GEONET 観測点の菊池、長陽、熊本を 3 点を結んだ三角形である。2003 年 1 月 1 日を起算日としているが、2011 年 3 月 12 日以降、2016 年熊本地震発生の前までの

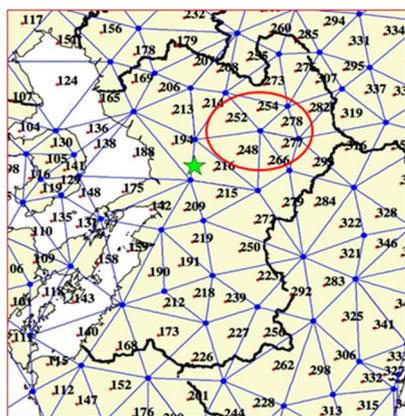
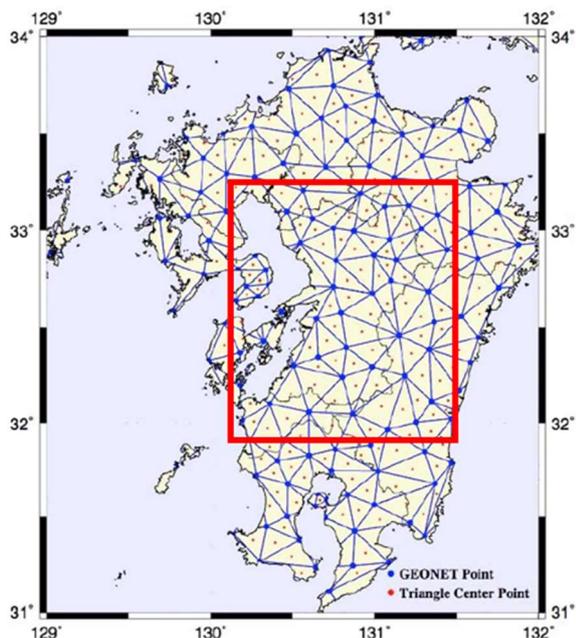


図-6 検討に用いた地盤要素（文献5）に加筆

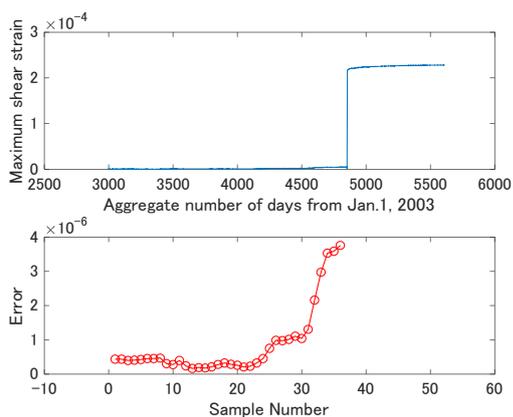


図-7 再構成誤差の推移（要素 252）

1800個のデータのみを用いている。地震発生の数年前までのデータ 1~900 までを地震の予兆が含まれていない正常データとして学習用に用いる。学習後のオートエンコーダに、地震発生直前のひずみデータを含むすべての

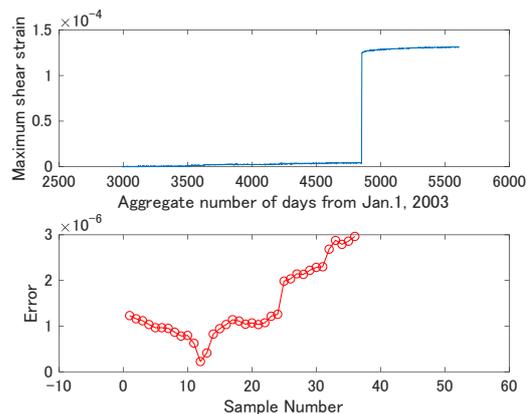


図-8 再構成誤差の推移（要素 248）

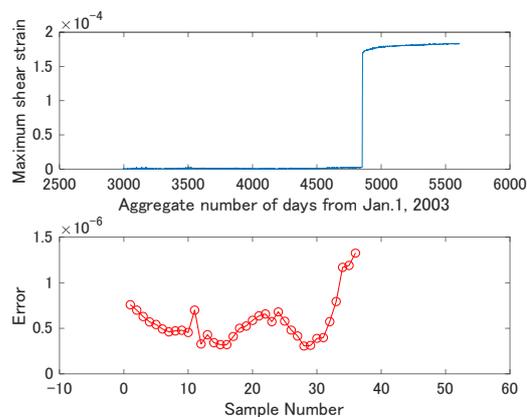


図-9 再構成誤差の推移（要素 254）

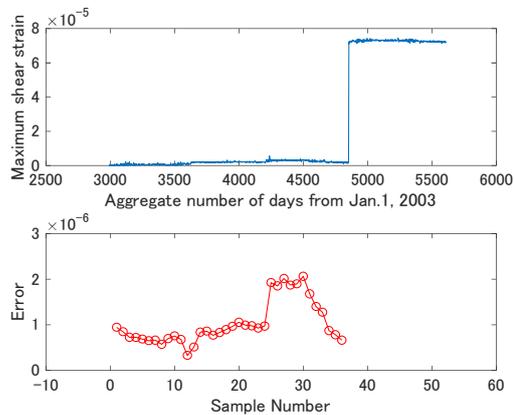


図-10 再構成誤差の推移（要素 266）

データ 1~1800 を入力として与えた時の出力を計算し、それと実データとの差から再構成誤差を評価する。この値が大きい場合、データに何らかの異常があるものと仮定した。一連の検討では、50日分のデータを1サンプルとして扱うので、36のサンプルについて、再構成誤差を評価することになる。なおここでは、隠れ層の次元を30とした。

再構成誤差の算定結果を図-7に示す。再構成誤差の値は地震発生前に急激に大きくなっており、異常を検知し

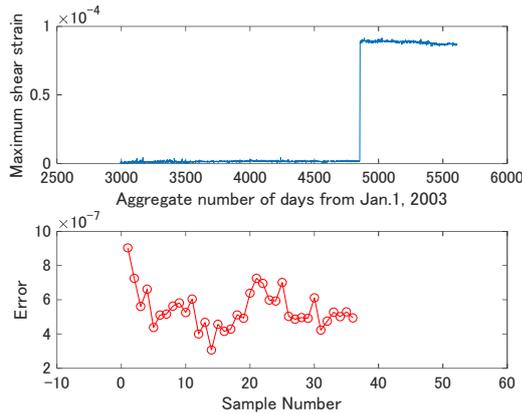


図-11 再構成誤差の推移 (要素 277)

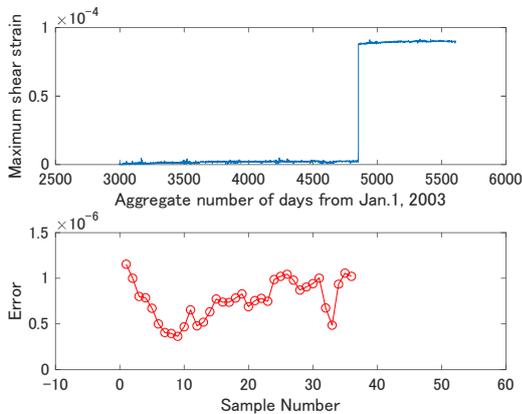


図-12 再構成誤差の推移 (要素 278)

た可能性がある。

他の要素についても図-8～図-12 に結果を示す。要素 248, 254, 266 については、要素 252 と同様、地震直前で再構成誤差が大きくなる傾向がある。また、最大せん断ひずみの大きさと再構成誤差の大きさが連動しているようにも見える。しかしながら、要素 277, 278 では特に地震前に再構成誤差の大きさが大きくなるような傾向は見られない。要素 277, 278 は他に比べ地震時変動が小さい領域にあることから、異常が検知されなかったものと思われる。

5. 結論

本研究では、GNSS データから算定される工学的最大

せん断ひずみの時系列を用いて、地震発生前の異常検知を試みた。具体的には、機械学習でよく用いられるオートエンコーダ (autoencoder, 自己符号化器) を用いた。

地震時変動の大きい領域では、地震発生前に再構成誤差が大きくなっており、地震の予兆を捉えている可能性がある。一方で、地震時変動が小さい場所では、特に、地震発生前に再構成誤差が大きくなるような傾向は見られず、予兆は検知できていない。

今後は、GNSS データのデータ欠測の問題に取り組む予定である。

謝辞：本研究を実施するにあたり、国土地理院の GEONET データを使用させて頂きました。ここに記して、関係各位に感謝します。

参考文献

- 1) 国土地理院：平成 30 年度国土地理院概要、<http://www.gsi.go.jp/kikakuchousei/kikakuchousei40194.html>
- 2) 三神厚, 神山真：2011 年東北地方太平洋沖地震による地殻変動からの回復過程の考察, 土木工学論文集 A1 (構造・地震工学), 72 巻, 4 号, p.I_413-I_423, 2016.
- 3) 三神厚, 神山真：2011 年東北地方太平洋沖地震に伴う地殻変動からの回復過程と漁港施設の復興工事への影響, 第 43 回海洋開発シンポジウム (2018) 講演集, 講演番号(18), 2018.
- 4) 神山真, 小出英夫, 沢田康次, 秋田宏, 千葉則行, 三神厚：長野県神城断層地震の地殻変動 - PPP 特性値の日変動と地震発生 -, 日本地震工学会・大会-2015, 年次大会講演論文, pp.1-9 (ポスターP1-1), 2015 年 12 月 21-22 日.
- 5) 神山真, 三神厚, 小出英夫, 沢田康次, 秋田宏, 千葉則行：GEONET の地殻変動データを利用した 2016 年熊本地震の被害解析, 土木学会論文集 A1 (構造・地震工学), Vol.73, No.4, p. I_270-I_281, 2017.
- 6) G.E. Hinton and R.R.Salakhutdinov: Reducing the Dimensionality of Data with Neural Networks, Science, Vol.313 (5786), pp.504-507, 2006.
- 7) MarhWorks Japan：センサーデータ解析のためのニューラルネットワーク, 2015.
<https://jp.mathworks.com/videos/neural-network-for-sensor-data-analysis-1505494780628.html>

(2018. 8.31 受付)

APPLICATION OF MACHINE LEARNING TECHNIQUE FOR STRAIN TIME SERIES CALCULATED FROM GNSS OBSERVATION DATA

Atsushi MIKAMI and Makoto KAMIYAMA

This study applies machine learning technique to the maximum shear strain time series calculated from GNSS observation data to examine if the method is capable of detecting premonitory symptoms of an earthquake. The strain time series during the 2016 Kumamoto earthquake are prepared in the neighborhood of the seismic source. Then, the autoencoder learns a representation of the strain data for the period until several years before the earthquake occurrence, hence the data is assumed not to include an earthquake symptom. Using the strain data until just before the earthquake occurs as an input, the autoencoder predicts the output. The difference between the output and the original data is a reconstructed error which is assumed to be related with abnormality of the maximum shear strain data. It seems that reconstructed errors become larger before earthquake occurs near the large coseismic deformation area, whereas the method fails to detect abnormality for the smaller coseismic deformation area.