

斜面管理における RTK-GNSS データの 粒子フィルタを用いた変化点検知手法

吉田伊織¹・小濱健吾²・貝戸清之³

¹学生会員 大阪大学大学院工学研究科 地球総合工学専攻 (〒 565-0871 吹田市山田丘 2-1)

E-mail: i.yoshida@civil.eng.osaka-u.ac.jp

²正会員 大阪大学特任准教授 大学院工学研究科 NEXCO 西日本高速道路学共同研究講座 (〒 565-0871 吹田市山田丘 2-8)

E-mail: k-obama@civil.eng.osaka-u.ac.jp

³正会員 大阪大学准教授 大学院工学研究科 地球総合工学専攻 (〒 565-0871 吹田市山田丘 2-1)

E-mail: kaito@ga.eng.osaka-u.ac.jp

近年では、地震や集中豪雨などによる斜面崩壊が多発している。斜面に隣接する道路の管理者は異常を迅速に把握し、通行規制などの措置を速やかに講じなければならない。そこで、GNSS (Global Navigation Satellite System) を斜面管理に活用する取り組みが行われている。これまでに、斜面に設置された RTK-GNSS (Real Time Kinematic) から突発的な斜面の異常を検知するシステムとして Change Finder による統計的变化点検知手法が提案されているが、実用化に向けては適用範囲の拡大が課題として残されている。本研究では、状態空間モデルを仮定した粒子フィルタによる状態量推定を行い、GNSS データに含まれるマルチパス誤差と偶然誤差を処理し、変化点検知手法の改良を試みた。さらに、実際の高速道路で獲得された GNSS データに適用し、検知精度について評価を行った。

Key Words : *change point detection, slope, RTK-GNSS, real-time monitoring, particle filter*

1. はじめに

近年、地震や台風、集中豪雨などの自然災害に伴う被害が発生しており、とりわけ突発的な斜面崩壊への対応が差し迫った課題となっている。斜面に隣接した高速道路などの管理者は、斜面の異常を直ちに把握し、近隣住民への避難勧告や道路利用者への事前通行規制、異常箇所の緊急点検などの措置を速やかに講じなければならないことから、土中水分計などのモニタリング機器を設置することにより斜面の状態を常に監視できるような体制が構築されつつある。

斜面防災におけるモニタリング機器の 1 つとして GNSS (Global Navigation Satellite System) 受信機が活用されている。GNSS は衛星測位システムの総称で、衛星から送られる電波を受信し、衛星から GNSS 受信機までの到達時間と衛星の位置に基づいて GNSS 受信機の位置を算出するシステムである。したがって、GNSS 受信機を斜面に設置することにより斜面の位置情報を計測することができる。しかし、実際の斜面のモニタリング方法は機器から獲得された座標変位の時系列データを管理者が目視で判断しており、時系列データを常時確認できずに変化を見逃す恐れがあり、獲得されるデータを有効活用できていないと言いがたい。また、変化が微小であった場合は必ずしも管理者が判別できるとは限らない。このため、人の手に依らずにモ

ニタリングデータから異常を検知する手法の開発が求められている。

GNSS 受信機により獲得したデータの活用方法として、清水ら¹⁾は GNSS データをトレンドモデルで平滑化し、斜面の真の変位を高精度で推定する手法を確立した。この手法は地滑りといった長期間にわたる変動の検知には有用であるが、地震時に生じる突発的な位置変動に対しては地震が発生してから検知するまでに時間を要する。そこで、堤ら^{2),3)}は、RTK-GNSS (Real Time Kinematic) データに Change Finder⁴⁾ と呼ばれる変化点検知手法を用いて分析する方法論を提案した。これにより、GNSS データに含まれる測定誤差と斜面の変位を区別し、突発的な斜面の異常を早期に検知することが可能となったが、検知精度の向上を課題としてあげており、実用化のために適用範囲の拡大が必要となっている。

本研究では、堤らの提案した方法論の実用化に向け、GNSS データに含まれる誤差を事前処理する方法論として状態空間モデルの推定法である粒子フィルタの利用を新たに提案し、Change Finder を用いた異常検知の精度向上を目指す。以下、**2.**において、本研究の基本的な考え方を述べる。**3.**において、変化点検知の手法について具体的に説明する。**4.**において、実際の高速道路において観測された GNSS データを用いて本研究で提案した誤差処理の効果を検証し、適用範囲を示す。

2. 本研究の基本的な考え方

(1) 既往研究の概要

堤らが行った RTK-GNSS データに Change Finder を適用した異常検知手法の研究成果について説明する。

高速道路の斜面に設置された RTK-GNSS 受信機により獲得された 72 データについて母集団移動平均法^{5),6)}を適用し、2018 年 6 月 18 日 7 時 58 分に発生した大阪府北部地震で 2[mm] 以上の変位が発生した 18 データを抽出した。これらに対して Change Finder を適用したところ、18 データのうち 9 データで地震による変化点を検知した。この結果から GNSS データの標本標準偏差と地震による変位の関係を調べ、変位が標準偏差の 2.5 倍を超えるものに対してはおおむね検知可能となることを帰納的に導き、Change Finder の適用可能性と適用範囲を明確にした。

さらに、変化点が検知不可だった残りの 9 データについて、標準偏差を小さくする目的で恒星日差分法⁷⁾とローパスフィルタによる事前処理を実施した。誤差処理後のデータに対して Change Finder による分析を行った結果、検知精度が向上した。一方で、実用化に向けた適用範囲の拡大やローパスフィルタのカットオフ周波数に応じて検知時間に遅れが生じることなどを課題としてあげている。

(2) GNSS データの誤差と事前処理

GNSS データはその測位方法により、解析時間や誤差要因が異なる。RTK 測位は複数の受信機を使用する相対測位方式を用いて受信機間で観測データの発信を行い、即時に解析処理するものをいう⁸⁾。RTK 測位を用いて観測された GNSS データには主に、1) 伝搬遅延による誤差、2) 受信機による誤差、3) マルチパス誤差、4) 偶然誤差、の 4 つの誤差が含まれる。ただし、本研究で扱った GNSS データについては、基線長が十分短く、変位前後の相対的な差を見ることから、1)、2) の 2 つについては影響を無視できるほどに小さい。したがって、本研究では 3)、4) の 2 つの誤差の事前処理方法について考える。ここで、マルチパスとは、衛星から受信機に直接届く電波に対して周辺の地物で反射して様々な経路で入射する電波のことである。マルチパスの経路は衛星と受信機の位置関係によって決まるため、衛星の周回時間に依存し周期性を伴う。衛星が南中してから次に南中するまでには 1 恒星日（約 23 時間 56 分）を要することから、恒星日を考慮して補正することによりマルチパスによる誤差を低減できる。

既往研究³⁾では、恒星日における時刻ごとに基準値を設定し、GNSS データの差分をとってマルチパス誤差を低減した。また、測定時の偶然がもたらすランダム

な誤差である偶然誤差については、ローパスフィルタによる処理を提案している。ローパスフィルタは GNSS データを複数の正弦波の重ね合わせであると考え、設定したカットオフ周波数以上の周波数の波形を除去する手法である。カットオフ周波数を低周波にするほど、ばらつきのような微小変動を取り除けるが、検知時間に遅れが生じることが問題となっている。

本研究では、恒星日差分法と状態空間モデルにおける状態推定法の一つである粒子フィルタを用いて GNSS データに含まれる誤差を除去する。誤差処理後のデータに対して、外れ値スコア算出部分に推定した状態量を用いた Change Finder を適用して検知の可否を調べ、検知精度に関して従来手法との比較を行う。以下、それぞれの誤差処理手法の概要を説明する。

恒星日差分法について、基準値を 3 日前から前日までの恒星日における同時刻の移動平均値とする。基準値に一定期間固定した値を用いる方法もあるが、厳密な恒星日による設定が困難であるために誤差が蓄積するほか、変更の際に処理後のデータが推移することにより突発的な変位と誤って判断される恐れがある。一方、移動平均の場合は測定されるたびに計算処理を要するが、先述した 2 つの問題は生じない。また、移動平均の期間については、本研究で用いたデータの欠測頻度を考慮して 3 日間に設定した。

次に、GNSS データに状態空間モデルを仮定し偶然誤差を除去する。状態空間モデルは観測されるデータに加えて、直接には観測できない状態量を考える。この状態量は観測量からノイズを除去したものと解釈でき、観測量がホワイトノイズを含むと仮定してモデルを構築する。観測量から状態量を推定する手法としてはマルコフ連鎖モンテカルロ法やカルマンフィルタなどがあるが、本研究では斜面の突発的な変位を短時間で検知することを目標とするため、逐次処理が可能であり、状態量と同時に状態空間モデルのパラメータを推定できる粒子フィルタを採用する。粒子フィルタは北川^{9),10)}、Gordon¹¹⁾が提案した非線形・非ガウス状態空間モデルの状態推定法の一つであり、モンテカルロ・シミュレーションによって実現される。多数の粒子で状態量が従う分布を近似するため、非線形・非ガウス性でも扱えるオンライン処理のアルゴリズムである。詳細については 3. で説明する。

3. 変化点検知の手法

(1) 粒子フィルタによるパラメータ推定

恒星日差分法により周期的な誤差を取り除いたデータに対して粒子フィルタを適用し、状態空間モデルのパラメータを推定する。粒子フィルタの概念図を図-1

に示す。

粒子数を M ，時刻 t におけるデータ，すなわち観測量を y_t ，状態量を x_t とする。また，観測雑音・状態雑音 V_t, W_t は任意の確率分布を考慮できるが，本研究では分散がそれぞれ v_t, w_t の正規分布を仮定する。このとき，状態空間モデルは以下の式で表される。

$$y_t = F_t x_t + V_t \quad (1)$$

$$x_t = G_t x_{t-1} + W_t \quad (2)$$

式 (1)，式 (2) では，状態量 x_t のほかに係数 F_t, G_t および観測雑音・状態雑音のパラメータ v_t, w_t が未知数として含まれる。そこで，北川¹²⁾ が提案した自己組織化状態空間モデルを用いて，未知パラメータ $\theta = (x_t, F_t, G_t, v_t, w_t)$ を推定する。具体的なアルゴリズムを以下に示す。

ステップ 1

各 $m(1 \leq m \leq M)$ について，初期値 $\theta_0^{(m)}$ を確率密度 $p(\theta_0)$ に従って独立に発生し，重みの初期値を $\omega_0^{(m)} = 1$ とおく。

ステップ 2

以下を $t = 1$ から $t = n$ まで繰り返す。

(a) 各 m について， m ごとに独立に $\theta_t^{(m)}$ を確率密度 $p(\theta_t^{(m)} | \theta_{t-1}^{(m)})$ に従って生成する。

(b) 重みを以下の式で更新する。

$$\log \omega_t^{(m)} = \log \omega_{t-1}^{(m)} + \log p(y_t, \theta_{t-1} | \theta_t^{(m)}) \quad (3)$$

(c) 期待値 $E(\theta_t)$ を重み付き平均

$$\sum_{m=1}^M \left(\omega_t^{(m)} \times \theta_t^{(m)} \right) / \sum_{m=1}^M \omega_t^{(m)} \quad (4)$$

で計算する。

ステップ 3

$[\theta_t^{(1)}, \theta_t^{(2)}, \dots, \theta_t^{(M)}]$ から各粒子 $\theta_t^{(m)}$ が $\omega_t^{(m)}$ の確率で選ばれるように M 回の復元抽出を行い， $[\theta_t^{(1)}, \theta_t^{(2)}, \dots, \theta_t^{(M)}]$ を再構成し，重みを $\omega_t^{(m)} = 1$ とする。

粒子フィルタのアルゴリズムについて補足する。

ステップ 1 で設定するパラメータの初期値 $\theta_0^{(m)}$ は，状態空間モデルにおけるすべての未知数に対して，それぞれの初期値 $x_0^{(m)}, F_0^{(m)}, G_0^{(m)}, v_0^{(m)}, w_0^{(m)}$ を設定する。本研究では， $x_0^{(m)}, F_0^{(m)}, G_0^{(m)}$ は正規分布， $v_0^{(m)}, w_0^{(m)}$ についてはガンマ分布から発生させた。なお，時刻 t が大きくなるにつれて初期値の影響は減少していく。

ステップ 2(a) において， $x_t^{(m)}, F_t^{(m)}, G_t^{(m)}, v_t^{(m)}, w_t^{(m)}$ を生成する確率密度 $p(x_t^{(m)} | x_{t-1}^{(m)}), p(F_t^{(m)} | F_{t-1}^{(m)}), p(G_t^{(m)} | G_{t-1}^{(m)}), p(v_t^{(m)} | v_{t-1}^{(m)}), p(w_t^{(m)} | w_{t-1}^{(m)})$ は，平均が $t-1$ 時点のパラメータの期待値で，分散一定の正規分布とする。分散はそれぞれのパラメータに応じて設定する。

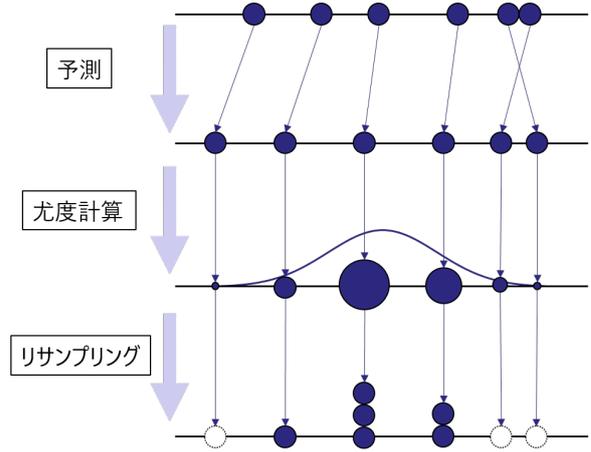


図-1 粒子フィルタの概念図

ステップ 2(b) の対数尤度 $\log p(y_t, \theta_{t-1} | \theta_t^{(m)})$ は， x_t, F_t, v_t を推定する場合，式 (1) より，

$$\log p(y_t, x_{t-1}, F_{t-1}, v_{t-1} | \theta_t^{(m)}) = -\frac{1}{2} \log(2\pi v) - \frac{(y_t - Fx)^2}{2v} \quad (5)$$

一方， G_t, w_t を推定するとき，式 (2) から，

$$\log p(x_t, x_{t-1}, G_{t-1}, w_{t-1} | \theta_t^{(m)}) = -\frac{1}{2} \log(2\pi w) - \frac{(x_t - Gx_{t-1})^2}{2w} \quad (6)$$

ただし，式 (5)，式 (6) において，時点を表す添え字がない未知パラメータは，先立って推定されたパラメータおよび推定対象とするパラメータの時点を t とし，その他のパラメータは時点を $t-1$ とする。

ステップ 3 は，ある粒子を破棄して別の粒子を複製する操作で，リサンプリングと呼ばれる。粒子が有限であるために必要な操作だが，これを繰り返していくと尤度の低い粒子が消失していき，もともとと同じ粒子の複製であったものが増えていく。リサンプリングを過度に行うと似た値を持つ粒子が多数を占めて多様性が失われる。この現象は粒子の退化と呼ばれ，広がりを持った確率分布を近似できず，適切な状態推定ができなくなる。したがって，粒子の重み $\omega_t^{(m)}$ の変動係数などを参考にしてリサンプリングを適切に行う必要がある。

(2) Change Finder の概要

本研究における Change Finder の計算フローを図-2 に示す。最初に時系列データを読み込んだ後，外れ値スコアを算出して平滑化を行う。これにより求められる T -平均スコア系列を AR モデルで学習して変化点スコアを算出する。それぞれの段階について順を追って説明する。

まず，外れ値スコアの算出方法について述べる。外

れ値スコアとは特異なデータを定量的に表したもので、時系列モデルを仮定してデータを学習すること算出できる。本研究では状態空間モデルを仮定し、粒子フィルタを用いて状態量を推定したため、状態量 x_t の下で観測量 y_t が発生する条件付き確率 $p(y_t|x_t)$ を利用して外れ値スコアを以下の式で求める。

$$\begin{aligned} \text{Score1}(t) &= -\log p(y_t|x_t) \\ &= -\frac{1}{2} \log(2\pi v_t) - \frac{(y_t - F_t x_t)^2}{2v_t} \end{aligned} \quad (7)$$

次に、幅が T のウィンドウを用意して外れ値スコアの移動平均である T -平均スコア系列 z_t を以下の式で求める。

$$z_t = \frac{1}{T} \sum_{i=t-T+1}^t \text{Score1}(i) \quad (8)$$

この操作を平滑化と呼び、外れ値の影響を緩和することができる。 T -平均スコア系列に対して AR モデルを仮定し、AR モデルのパラメータを推定する。 k 次の AR モデルは時系列変数 $q_t (t = 0, 1, \dots)$ としたとき、

$$q_t = \sum_{i=1}^k \alpha_i q_{t-i} + \varepsilon \quad (9)$$

により表される。ここで、 $\alpha_i (i = 1, \dots, k)$ は自己回帰係数、 ε は平均 0、分散 σ^2 の正規分布に従うホワイトノイズである。時点 t における q_t は定数項 μ のずれを考慮して、

$$q_t = \mu + \sum_{i=1}^k \alpha_i (q_{t-i} - \mu) + \varepsilon \quad (10)$$

と表すことができる。推定すべきパラメータは μ 、 $\alpha_i (i = 1, \dots, k)$ 、ホワイトノイズの分散パラメータ σ であり、モデルを推定した結果、パラメータの推定値ベクトル $\hat{\psi} = (\hat{\mu}, \hat{\alpha}, \hat{\sigma})$ を得たとする。ただし、 $\hat{\alpha} = (\hat{\alpha}_1, \dots, \hat{\alpha}_k)$ である。このとき、 $z_{t-k}^{t-1} = (z_{t-k}, \dots, z_{t-1})$ とおくと、 T -平均スコア系列 z_t の予測値の確率分布 $p(z|z_{t-k}^{t-1}; \hat{\psi})$ は、

$$\begin{aligned} &p(z|z_{t-k}^{t-1}; \hat{\psi}) \\ &= \frac{1}{\sqrt{2\pi\hat{\sigma}^2}} \exp\left[-\frac{\{z - \hat{\mu} - \sum_{i=1}^k \hat{\alpha}_i (z_{t-i} - \hat{\mu})\}^2}{2\hat{\sigma}^2}\right] \end{aligned} \quad (11)$$

と与えられる。 T -平均スコア系列 z_t の変化点スコア Score2 は、対数損失を求めた後に T' 期の移動平均をとり、再度平滑化することにより定義される。

$$\begin{aligned} \text{Score2}(t) &= \frac{1}{T'} \sum_{i=t-T'+1}^t -\log \{p(z_i|z_{i-k}^{i-1}; \hat{\psi})\} \end{aligned} \quad (12)$$

変化点スコアは外れ値の影響を除去したもので、変化点の度合いを表す。

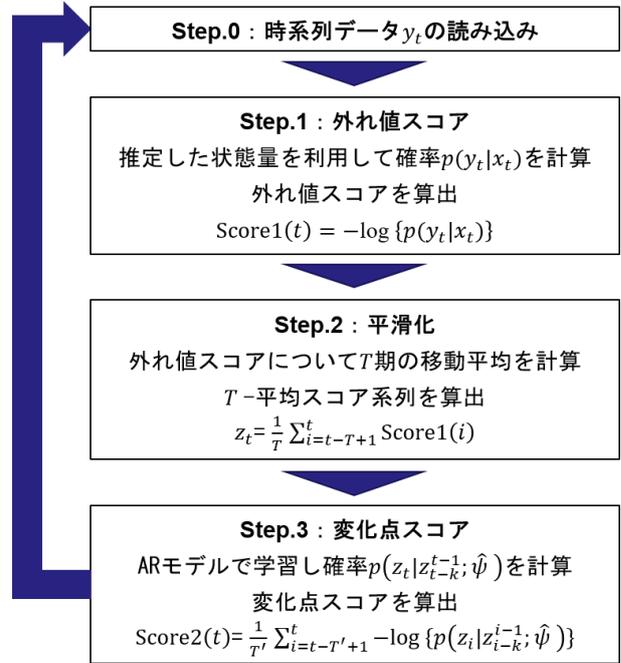


図-2 Change Finder の計算フロー

以下、AR モデルのパラメータ推定手法について説明する。Change Finder においては、データが蓄積された場合においてもスコアの計算に必要な計算量はほぼ一定である。これは、新しいデータが観測された際に現時点までのデータを用いて推定したパラメータおよび各種統計量と、新しいデータのみを用いてパラメータの推定値を重み付き平均の形で更新する SDAR アルゴリズムを採用したことによる。

いま、時点 $t-1$ までに観測されたデータ $z_s (s = 0, \dots, t-1)$ をもとに、パラメータ $\hat{\psi}_{t-1}$ 、 T -平均スコア系列 $z_s (s = T-1, \dots, t-1)$ が得られているとする。このとき、1期進んだ時点 t において新たなデータ z_t を獲得した時の AR モデルのパラメータは、忘却パラメータ $r (0 < r < 1)$ と AR モデルの自己共分散関数 $C_{i,t-1} (i = 1, \dots, k)$ を用いて以下の手順により更新される。

まず、 μ と C_i を以下の式により更新する。

$$\hat{\mu}_t = (1-r)\hat{\mu}_{t-1} + rz_t \quad (13)$$

$$C_{i,t} = (1-r)C_{i,t-1} + r(z_t - \hat{\mu}_t)(z_{t-i} - \hat{\mu}_t) \quad (14)$$

次に、以下の Yule-Walker 方程式を解いて α を更新する。

$$\sum_{i=1}^k \alpha_{j,t} C_{i-j,t} = C_{i,t} (i = 1, \dots, k) \quad (15)$$

表-1 GNSS データの概要と既往研究の検知結果

地点	茨木北								
	1			2			3		
種類	南北	東西	上下	南北	東西	上下	南北	東西	上下
変位量[mm]	30	30	45	25	32	40	14	13	6
検知	○	○	×	○	○	×	○	○	×
地点	原萩谷								
	1			2		3		4	
種類	南北	東西	上下	東西	上下	東西	上下	南北	東西
変位量[mm]	8	28	25	9	10	22	40	3	4
検知	○	○	×	×	×	×	×	○	×

最後に、 σ を以下の式により更新する。

$$\tilde{z}_t = \sum_{i=1}^k \hat{\alpha}_{i,t} (z_{t-i} - \hat{\mu}_t) + \hat{\mu}_t \quad (16)$$

$$\hat{\sigma}_t^2 = (1-r) \hat{\sigma}_{t-1}^2 + r(z_t - \tilde{z}_t)^2 \quad (17)$$

ここで、忘却パラメータ r は現時点におけるパラメータ推定値に対する新たに獲得されたデータの重みである。 r が大きいほど新たに獲得されたデータを加味したものとなり、過去のデータの影響は小さくなる。上記の手順を繰り返すことにより、更新したパラメータと式 (11)、式 (12) を用いて時点 t における変化点スコア Score2 をデータが更新される度に算出できる。

4. 適用事例

(1) GNSS データの概要

新名神高速道路に設置された GNSS 受信機が観測した GNSS データを分析対象とした。GNSS 受信機は管理者によって重点的に監視すべき斜面であると判断された地点に設けられ、茨木北、原萩谷、神戸、宝塚の 4 地域、合計 24 地点に対して位置情報データが観測されている。1 つの地点に対して南北方向、東西方向、上下方向の 3 方向の位置情報データが記録されているため、合計で 72 の GNSS データセットが存在する。データは 10 秒ごとに獲得されるが、通信の不具合や設備メンテナンスの影響により、10 秒から 2 時間に及ぶ欠損が見られる。また、図-3 に示すように、絶対値で数百 mm を超える大幅な外れ値が含まれる。したがって、既往研究^{2),3)}と同様に GNSS データの標本標準偏差が 3σ を超える外れ値を特異値として事前に除去したデータを分析に用いる。また、GNSS データの獲得期間は 2018 年 6 月 17 日 0 時～2018 年 6 月 19 日 0 時である。このうち、2018 年 6 月 18 日 7 時 58 分 34 秒に発生した大阪府北部地震により 2[mm] 以上の変位が生じた 18 データを母集団移動平均法^{5),6)}を用いて抽出した。これら

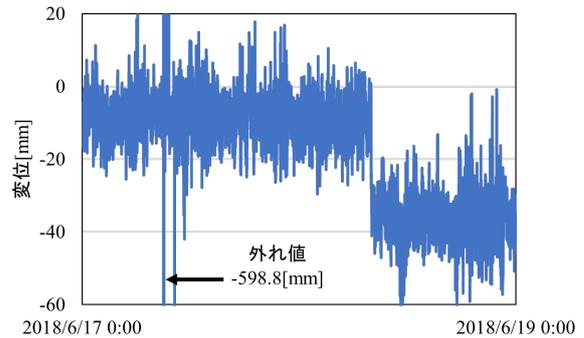


図-3 GNSS データ（原萩谷地点 1 東西方向）

のデータに対して恒星日差分法と状態空間モデルによる誤差処理を実施し、Change Finder による異常検知の精度の改善を試みる。表-1 に本研究で分析対象とした GNSS データの地点、方角の種類、変位量、誤差処理を行わずに Change Finder を適用した場合の検知結果を示す。18 データのうち半数の 9 データで検知不可となっており、GNSS データに直接 Change Finder を用いた場合、適用範囲が限定されることがわかる。

(2) 誤差処理と異常検知の可否

GNSS データに対して最初に恒星日差分法を適用し、得られた結果を状態空間モデルにおける観測量 y_t として扱う。次に、粒子フィルタを用いて状態空間モデルに含まれる未知パラメータ θ_t を推定すること誤差処理を行う。

恒星日差分法を適用したデータと粒子フィルタにより推定した状態量を図-4 に示す。図中に灰色で示す恒星日差分後のデータについて図-3 と比較すると、恒星日差分法により周期的な誤差を抑制している。また、青色で示す状態量の推定値においては偶然誤差を除去し、急激な変位を追従していることがわかる。なお、粒子数は多いほど近似精度が高まるが、本研究では計算負

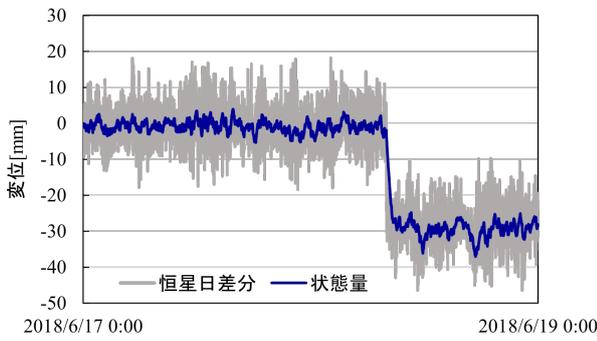


図-4 誤差処理後のデータ

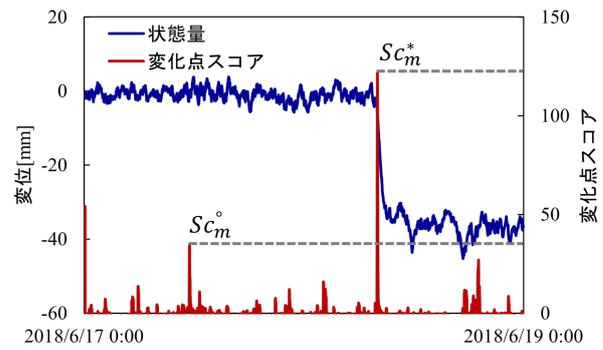


図-5 状態量と変化点スコア

荷を考慮して 1,000 に設定した。

粒子フィルタにより推定した状態量と、変化点スコアを算出した結果を図-5 に示す。Change Finder に用いるパラメータについて、平滑化を実施するウィンドウ幅 T と T' 、忘却パラメータ r を、 $T = T' = 15$ 、 $r = 0.001$ に設定し。AR モデルの次数 k については時系列データが従う AR モデルとして尤もらしい次数を AIC⁽¹³⁾ を用いて決定した。図-5 において地震発生前の変化点スコアの最大値 Sc_m^0 が 35 であるのに対し、地震発生直後の変化点スコア Sc_m^* は 121 となり、 $Sc_m^* - Sc_m^0 > 0$ となることから地震による変化点を検知したことが読み取れる。

次に、変位が発生した全 18 データの検知の可否における地震による変位と標準偏差の関係を図-6 に示す。標準偏差は地震発生時点までの位置情報を標本としたときの標本標準偏差を用いる。図中、検知可能だったデータを赤色、検知不可だったデータを青色で表す。また、丸で示す点は南北・東西方向のデータ、三角で示す点は上下方向のデータである。図中の下側にある点線は標準偏差を x 、変位を y とした、 $y = 1.5x$ の直線である。直線上側の領域に検知可能な点が集まっていることから、変位が標準偏差の 1.5 倍を超えるものについては検知可能と考えられる。従来手法では変位が標準偏差の 2.5 倍を超えるものが検知可能であったことから、本研究で提案した手法により検知精度が向上した。これらの変位と標準偏差の関係は扱った 18 データからの考察であり、今後異なる地点で計測されたデータについても同様の分析を行って検証する必要がある。

5. おわりに

本研究では、斜面管理のために設置された RTK-GNSS データに Change Finder を適用し、斜面に生じた突発的な変位を早期に検知する手法として提案されている方法論の実用化に向けて誤差処理手法を新たに提案し、異常検知手法の改良を行った。具体的には、RTK-

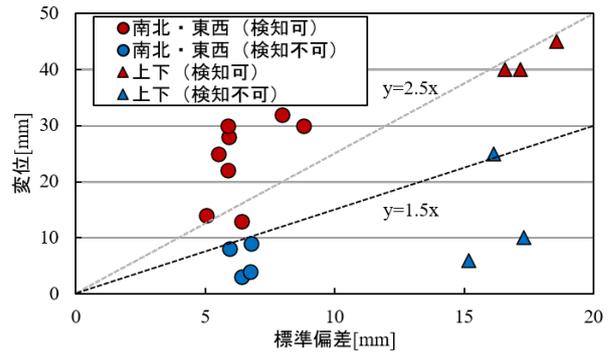


図-6 標準偏差と変位の関係

GNSS データに含まれる誤差がマルチパス誤差と偶然誤差であることを述べ、恒星日差分法と粒子フィルタを用いて誤差処理する方法論を提案した。その有用性を検証するため、大阪府北部地震により変位が生じた 18 データを用いて実証分析を行った。粒子フィルタにより外れ値スコア算出部分を改良した Change Finder を適用したところ、既往研究と比較して検知精度が向上した。また、検知可能な斜面の変位と GNSS データの標準偏差の関係を導き、その適用範囲が拡大したことを示した。

今後の課題として、以下の 2 点をあげる。第一に、検知可能な変位と標準偏差の関係を明確にすることである。本研究では、大阪府北部地震により変位が生じた 18 データの検知結果を基にその関係性を帰納的に導いている。GNSS 受信機が設置される環境によって GNSS データが異なる特徴を有することから、適用事例を増やし、その妥当性について検討しなければならない。

第二に、Change Finder による変化点検知を再度検証するシステムの開発があげられる。本研究で用いた方法論により実時間で変化点スコアの算出が可能だが、さらに数分から数十分の間データを蓄積した後に分析を行うことにより、実際に斜面に変位が生じたかの検証が可能になれば堅牢なシステムを構築できると考えられる。

参考文献

- 1) 清水則一, 安立寛, 小山修治: GPS 変位モニタリングシステムによる斜面変位計測結果の平滑化に関する研究, 資源と素材, Vol.114, pp.397-402, 1998.
- 2) 堤浩志, 小濱健吾, 中村葵, 小泉圭吾: 斜面管理における RTK-GNSS データの変化点検知手法, 土木学会論文集 F4 (建設マネジメント), Vol.75, No.2, L15-L26, 2019.
- 3) 堤浩志, 小濱健吾, 小泉圭吾: 斜面管理における RTK-GNSS データの変化点検知手法の改良, AI・データサイエンス論文集, 1 巻, J1 号, pp.437-444, 2020.
- 4) 山西健司: データマイニングによる異常検知, 共立出版, 2009.
- 5) 武石朗, 飯島功一郎, 江川真史, 室井翔太, 横田聖哉, 藤原優: 衛星測位を利用した次世代地すべり検知システム, 第 23 回 GPS/GNSS シンポジウム, 測位航法学会, pp.132-136, 2018.
- 6) 藤原優, 横田聖哉, 武石朗, 飯島功一郎, 江川真史: RTK-GNSS による地盤変位計測の高速道路法面への適用性に関する検証, 土木学会論文集 F3 (土木情報学), Vol.76, No.1, 18-31, 2020.
- 7) 武石朗, 飯島功一郎, 江川真史, 横田聖哉, 藤原優, 田山聡: RTK-GNSS による地盤変位計測システムについて (山陽自動車道での実証実験), 第 54 回地盤工学研究発表会, 2019.
- 8) 応用測量技術研究会: 応用測量学, 井上書院, 2016.
- 9) Kitagawa, G.: A Monte Carlo filtering and smoothing method for non-Gaussian nonlinear state spacemodels, Technical report, Institute of Statistical Mathematics Research Memorandum, No.462, 1993.
- 10) Kitagawa, G.: Monte Carlo filter and smoother for non-Gaussian nonlinear state space models, J.Comput. Graph. Stat., 5(1), pp.1-25, 1996.
- 11) Gordon, N., Salmond, D. and Smith, A.: Novel approach to nonlinear/non-Gaussian Bayesian state estimation, IEEE Proceedings-F, 140, pp.107-113, 1993.
- 12) Genshiro Kitagawa: A Self-Organizing State-Space Model, Journal of the American Statistical Association, Vol.93, No.443, 1998.
- 13) 小西貞則, 北川源四郎: 予測と発見の科学 情報量基準, 朝倉書店, 2006.
- 14) 中野慎也, 上野玄太, 中村和幸, 樋口知之: Merging Particle Filter とその特性, 統計数理, Vol.56, No.2, pp.225-234, 2008.
- 15) 貝戸清之, 数実浩佑: 統計的变化点検出に基づく社会基盤施設の早期異常検知, 信頼性, Vol.37, No.3, 日本信頼性学会, pp.116-125, 2015.
- 16) 松岡 弘大, 貝戸 清之, 徳永 宗正, 渡辺 勉, 曾我部 正道: 逐次データ同化を利用した列車走行時の橋梁加速度応答に基づく変位応答推計, 土木学会論文集 A1 (構造・地震工学), Vol.69, No.3, pp.527-542, 2013.
- 17) 伊庭幸人, 種村正美, 大森裕浩, 和合肇, 佐藤整尚, 高橋明彦: 統計科学のフロンティア 12 計算統計 II マルコフ連鎖モンテカルロ法とその周辺, 岩波書店, 2005.
- 18) 樋口知之: 予測にいかす統計モデリングの基本, 講談社, 2011.
- 19) 北川源四郎: 時系列解析入門, 岩波書店, 2005.
- 20) 樋口知之, 上野玄太, 中野慎也, 中村和幸, 吉田亮: データ同化入門 - 次世代のシミュレーション技術, 朝倉書店, 2013.
- 21) 島田直希: 時系列解析 - 自己回帰型モデル・状態空間モデル・異常検知 -, 共立出版, 2019.
- 22) 矢野浩一: 粒子フィルタの基礎と応用 フィルタ・平滑化・パラメータ推定, 日本統計学会誌, 第 44 巻, 第 1 号, pp.189-216, 2014.