

地すべりメカニズム分析のための時系列 OLAP ツール

山田 千人[†] 横田 裕介^{‡‡} 高田 秀志^{‡‡} 島川 博光^{‡‡}

[†]立命館大学理工学部情報学科 〒525-8577 滋賀県草津市野路東 1-1-1

^{‡‡}立命館大学情報理工学部情報システム学科 〒525-8577 滋賀県草津市野路東 1-1-1

E-mail: [†]yuki@de.is.ritsumei.ac.jp, ^{‡‡}{yyokota,htakada,simakawa}@cs.ritsumei.ac.jp

あらまし 集中豪雨による地すべりを防ぐ道路斜面防災にセンサ・ネットワークを用いることを考える。センサ・ネットワークを用いれば、大量のデータを長期間取得できる。しかし、その時系列データを生かすためには分析によって傾向を把握する必要がある。また、専門知識や経験則といった観点から分析を行う必要があるが、これらを定式化することは容易ではない。そこで本論文では、専門家が地中のセンサから得られた時系列データの特徴を発見しやすくするために、OLAP ツールを提案する。本研究では、時間とともに変化する変量について、トレンドグラフ上の一定期間長での断片を考える。同じ特徴を持つ断片の集合をすべて含む最小の領域をタイム・チューブと呼ぶ。OLAP ツールを用いて、エンドユーザとなる専門家がタイム・チューブを指定し、データの傾向を明示的に発見することができる。

キーワード 地すべり, センサ・ネットワーク, 時系列データ, OLAP ツール

Time Series OLAP Tool for Landslide Mechanism Analysis

Yukihito Yamada[†] Yusuke Yokota^{‡‡} Hideyuki Takada^{‡‡} and Hiromitsu Shimakawa^{‡‡}

[†]Ritsumeikan University 1-1-1 Nojihigashi, Kusatsu-shi, Shiga, 525-8577 Japan

^{‡‡}Ritsumeikan University 1-1-1 Nojihigashi, Kusatsu-shi, Shiga, 525-8577 Japan

E-mail: [†]yuki@de.is.ritsumei.ac.jp, ^{‡‡}{yyokota,htakada,simakawa}@cs.ritsumei.ac.jp

Abstract A sensor network is applied to prevent road slope disasters caused by local severe rain. A sensor network can acquire a lot of data for a long period of time. However, in order to employ the time series data efficiently, analysis is necessary to grasp a tendency, which is not easy to formulize. It is necessary to perform analysis from viewpoints, such as technical knowledge and the empirical rule. This paper proposes an OLAP which facilitates an expert to discover the feature of the time series data obtained from the subterranean sensor. This method considers a fragment over a fixed period of time on trend graph about variation of quantity to change with time. The minimum domain including all sets of a fragment with the same feature is called a time tube. Using an OLAP method, the expert can specify a time tube, and can discover the tendency of data clearly.

Keyword Road slope disasters, Sensor network, Time series data, OLAP method

1. はじめに

道路斜面防災のために、地すべりが起こる前に、その兆候を検知するシステムの構築を目指す。そのためには、地すべりを引き起こす時系列データの分析が必要である。時系列データをリアルタイムに分析し、監視する技術[4]が既に研究されているが、エンドユーザとなる道路管理の専門家には理解し難い。道路斜面に設置されたセンサ群から収集されるデータを分析するための、専門家に理解しやすい手法を本研究では開発する。本論文では、時系列データの特徴を表現するための簡潔なモデルとしてタイム・チューブを提案する。専門家が、小数の事例をもとにタイム・チューブの初

期パラメータを指定すれば、多数の実データを用いてタイム・チューブを実情に適したものに洗練することができる。本論文ではタイム・チューブを洗練するための OLAP ツールについて説明する。本手法の特徴は以下の3点である。

センサ・ネットワークを用いることで、斜面の地下のデータを安全かつ大量に取得できる。

GUI 上で分析することにより、時系列データを抽象的に扱えるようになり、エンドユーザとなる専門家が理解しやすい。

時系列データの特徴をタイム・チューブに学習させる。

地すべりの兆候を表すように、洗練されたタイム・チューブを地中センサから収集された時系列データに適用することにより、地すべりを予測する。これにより地すべりでの災害を最小限におさえることが期待できる。

2. 地すべり向け防災システム

2.1. センサ・ネットワーク

センサを利用したコンピュータ・テクノロジーが普及し始めている。最近では、センサを用いて実空間の温度、湿度、明るさなどの情報を取得し、それらのデータから携帯端末上にユビキタスモンスターを登場させる携帯ゲーム[1]や、加速度センサを後ろポケットに入れ、加速度センサから得られる値から座る、立つ、歩く、走るなどの動作の推定[3]が実現されている。

センサ・ネットワークを用いれば、大量のデータを長期間取得できる。また、無線でデータを送受信することにより、危険な場所でのデータ取得が可能となる。本研究では地すべりが発生する前に兆候を検知するシステムを構築する。そのためには、斜面の地下のデータを取得する必要がある。大雨の日には人がデータを取得するために、斜面に向かうことは大きな危険を伴う。そこで、センサを用いて斜面の地下のデータを取得し、安全にデータを受け取ることができるネットワークを利用する。

センサ・ネットワークから得られる斜面の地下の時系列データは膨大である。センサ・ネットワークから得られた斜面の地下の時系列データを図1に示す。

A	B	C	D	E	F	G	H	I	J	K
1		chr-1(°C)	chr-2(°C)	chr-3(°C)	chr-4(V)	chr-5(V)	chr-6(V)	chr-7(V)	chr-8(V)	chr-9(回)
2		温度(0cm)	温度(10cm)	温度(30cm)	開閉水圧(20cm)	開閉水圧(40cm)	開閉水圧(60cm)	開閉水圧(80cm)	開閉水圧(100cm)	10分間雨量
3	2004/11/2	11.2000	15.7	15.2	16.5	11.477	11.455	11.722	11.628	1.2432
4		11.3000	15.9	15.3	16.5	11.477	11.457	11.721	11.628	1.2436
5		11.4000	15.9	15.4	16.5	11.479	11.458	11.725	11.628	1.2437
6		11.5000	16.1	15.4	16.5	11.481	11.463	11.727	11.631	1.2442
7		12.0000	16.3	15.5	16.4	11.482	11.465	11.728	11.634	1.2443
8		12.1000	16.4	15.6	16.4	11.484	11.466	11.731	11.635	1.2444
9		12.2000	16.6	15.6	16.4	11.485	11.47	11.734	11.636	1.2443
10		12.3000	16.7	15.7	16.4	11.486	11.47	11.736	11.64	1.2447
11		12.4000	16.8	15.8	16.4	11.485	11.473	11.738	11.642	1.2448
12		12.5000	17	15.9	16.4	11.489	11.48	11.741	11.644	1.2452
13		13.0000	17.1	16	16.4	11.492	11.48	11.742	11.646	1.245
14		13.1000	17.3	16.1	16.4	11.496	11.483	11.744	11.646	1.2454
15		13.2000	17.3	16.2	16.4	11.497	11.485	11.746	11.651	1.2456
16		13.3000	17.3	16.4	16.4	11.499	11.486	11.748	11.651	1.2456
17		13.4000	17.5	16.6	16.4	11.502	11.484	11.753	11.652	1.2459
18		13.5000	17.4	16.7	16.4	11.503	11.488	11.756	11.652	1.2459
19		14.0000	17.5	16.8	16.4	11.504	11.49	11.755	11.655	1.246
20		14.1000	17.4	16.9	16.4	11.505	11.492	11.756	11.655	1.2459
21		14.2000	17.3	17	16.4	11.507	11.491	11.756	11.654	1.2459
22		14.3000	17.2	17	16.4	11.508	11.493	11.758	11.655	1.2461
23		14.4000	17.3	17.1	16.4	11.508	11.495	11.759	11.656	1.2461
24		14.5000	17.4	17.1	16.4	11.51	11.496	11.761	11.659	1.2465
25		15.0000	17.4	17.1	16.4	11.51	11.498	11.763	11.659	1.2465
26		15.1000	17.4	17.2	16.4	11.51	11.498	11.762	11.659	1.2464
27		15.2000	17.5	17.2	16.4	11.514	1.15	11.765	11.662	1.2466
28		15.3000	17.4	17.3	16.4	11.515	11.502	11.767	11.663	1.2466
29		15.4000	17.4	17.3	16.4	11.515	11.501	11.766	11.662	1.2466
30		15.5000	17.4	17.4	16.4	11.515	11.504	11.769	11.665	1.2467
31		16.0000	17.4	17.4	16.4	11.514	11.502	11.769	11.665	1.2466
32		16.1000	17.3	17.4	16.4	11.516	11.503	11.77	11.665	1.2466
33		16.2000	17.4	17.4	16.4	11.516	11.504	11.771	11.666	1.2469
34		16.3000	17.4	17.4	16.4	11.518	11.505	11.771	11.665	1.2469
35		16.4000	17.3	17.4	16.4	11.518	11.507	11.771	11.667	1.2469
36		16.5000	17.2	17.5	16.4	11.519	11.506	11.771	11.665	1.2469
37		17.0000	17	17.5	16.4	11.52	11.505	11.771	11.665	1.2467
38		17.1000	16.8	17.4	16.4	11.52	11.504	11.771	11.665	1.2467
39		17.2000	16.7	17.4	16.4	11.521	11.504	11.769	11.664	1.2466
40		17.3000	16.6	17.4	16.4	11.52	11.501	11.769	11.662	1.2466
41		17.4000	16.5	17.3	16.4	11.522	11.502	11.767	11.662	1.2466

図1 センサ・ネットワークから得られるデータ

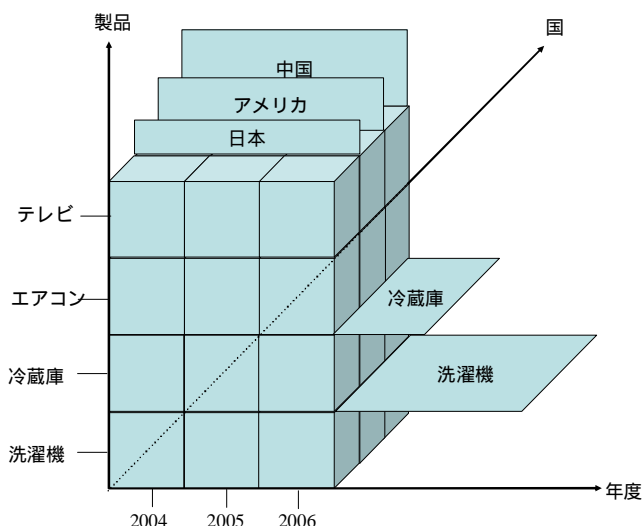


図2 3次元のハイパーキューブ

図1はデータ項目数が9個あり、10分おきに時系列データが取得されている。また、これらのデータは1地点に埋めこめられたセンサから取得した時系列データである。地すべり分析は複数の地点で分析が必要である。これらの膨大な時系列データが複数地点存在した場合、専門家が数字のみの集合からその時系列データが意味するものを理解することは困難である。そこで、専門家が理解しやすいように、時系列データの分析を支援するOLAPツールを提案する。時系列データの特徴から将来を予測し、地すべりが起こる前に兆候を検知することで被害が軽減される。

2.2. OLAP

OLAPとは多様なデータを多次元的にデータベースに格納し、さまざまな角度から集計や検索を行う手法である。OLAPにはスライシング、ダイシング、ドリル・ダウン、ロール・アップなどの技術手法がある。製品、国、年度の3次元を持つハイパーキューブを図2に示す。ハイパーキューブは多次元のデータを理解しやすくするために、視覚的に表現する手法として使用される。

スライシングとは2軸を指定することで、2次元の表内の集計値としてデータベースからの検索結果を表現する手法である。図2で例を示すと、製品別年度別の売り上げや、国別製品別の売り上げなどがこれにあたる。ダイシングとはサイコロを転がすように軸を入れ替えて集計軸の異なる表を作成する手法である。ドリル・ダウンとは現在表示している次元よりも詳細な集計値を参照したい場合に用いる手法である。図2において、年度にはより詳細な月、日、時、分、秒と階層的なレベルがある。ドリル・ダウンによりその詳細なレベルでの集計値を参照する。ロール・アップとはドリル・ダウンとは逆に、現在表示している次元より

も階層の高い集計値を参照したい場合に用いる手法である。図2で例を示すと、国にはより高いアジアやアフリカなどの階層レベルがある。このような高いレベルで再集計する操作である。

3. 地すべり向けデータ分析手法

3.1. タイム・チューブ

時系列データの状態遷移において、同じ事象を持つ特徴を表現する手法としてタイム・チューブ[2]を提案する。特徴とは時系列データの特異な状態遷移を言う。同じ事象とは時系列データから同様の現象が起きていると認識されている複数の期間の特徴を指す。監視される時系列データを監視対象と呼ぶ。ある監視対象の観測データ項目数が n 個の場合、ある時点におけるその監視対象の状態は n 次元の超平面上の1点として表現できる。監視対象の状態は時間の経過とともに変化する。よって、監視対象の状態遷移は n 次元の超平面に時間軸を加えた $(n+1)$ 次元の超空間における軌跡として表現できる。時系列データはさまざまな特徴をもつことが考えられる。時系列データはある期間では一定の特徴をもつと仮定する。期間ごとの一定の特徴を示す n 次元超平面上の領域のことを期間特性と呼ぶ。図3に示すように、 n 次元の期間特性を時間軸方向に伸ばすことでチューブのような超空間が得られる。この超空間に監視対象の状態遷移の軌跡が全て含まれていれば、その状態遷移は指定された条件を全て満たしていることを意味する。この空間をタイム・チューブと呼ぶ。

タイム・チューブは監視対象となる n 個のデータ項目値に関する条件を指定する不等式と期間に対する条件を示す不等式の組み合わせにより表現できる。時系




図3 n 次元のタイム・チューブ




図4 3次元のタイム・チューブ

列データの特徴は一定の特徴をもつ期間に分けてタイム・チューブを作成することで表現できる。データ項目値を示す2つの軸と時間軸で構成されている3次元空間のタイム・チューブを図4に示す。図4の期間特性はデータ項目値を示す2つの軸で構成される平面上の長方形で表現できる。この期間特性を時間軸方向に伸ばすことで直方体が構成される。期間と期間特性を表現している直方体がタイム・チューブである。また、監視対象の状態は2つのデータ項目値の軸で構成される平面上の1点として表現できる。その状態遷移は各時刻における点を結んだ3次元空間における軌跡で表現できる。また、監視対象の状態遷移の軌跡は点 (t_1, y_1, z_1) から点 (t_2, y_2, z_2) の区間で急激な下降である特徴を示している。急激な下降している区間の軌跡がタイム・チューブの空間内に含まれれば、監視下にある対象の状態遷移の急激な下降の特徴をタイム・チューブとして表現していることになる。図4が示すような期間と期間特性が違う3つのタイム・チューブは状態遷移の下降の特徴を考えよう。監視対象の状態遷移の点 (t_1, y_1, z_1) から点 (t_2, y_2, z_2) の区間に対して、大きなタイム・チューブは急激な下降である特徴以外にも捉えてしまう。一方で、小さなタイム・チューブは点 (t_1, y_1, z_1) から点 (t_2, y_2, z_2) の区間の特徴の全てを捉えきれない。よって、特徴を明確に捉えるためには、タイム・チューブの定義である期間と期間特性の決定が重要となる。

3.2. タイム・チューブの洗練

監視対象の特徴的な状態遷移を、タイム・チューブを用いて同定することにより将来その特徴から引き起こされる事象を発見することを目指す。引き起こされる事象をより正確に発見するためにはタイム・チューブを学習させる必要がある。タイム・チューブを学習

させることをタイム・チューブの洗練と呼ぶ。洗練に必要な時系列データを収集するため、発見すべき事象が起こったときの複数の時系列データを集める。集められた時系列データをポジティブ・データと呼ぶ。タイム・チューブは基本的にポジティブ・データを全て含む最小の領域で構成される。一方で、発見すべき事象とデータの推移は似ているが、発見すべき事象は起こっていない期間の時系列データも集める。この時系列データをネガティブ・データと呼ぶ。複数のポジティブ・データとネガティブ・データの期間をエンドユーザとなる専門家に選択させる。ここで選択した時系列データで分析を行う。ネガティブ・データはよりポジティブ・データに近ければ近いほど、タイム・チューブの洗練度が増すことになる。ポジティブ・データを全て含み、ネガティブ・データを全て含まないタイム・チューブの構成が理想である。

ポジティブ・データを3個持つ時系列データの状態遷移を図5に示す。図5はデータ項目値の軸1個と時間軸の2次元空間である。 t_1 から t_2 までの期間はポジティブ・データのひとつである。また、 t_3 から t_4 と t_5 から t_6 の期間もポジティブ・データである。時系列データの状態遷移の軌跡からエンドユーザとなる専門家が同じ事象が起こった3つの時系列データの特徴の期間を選択する。タイム・チューブの洗練をするために、 t_1 と t_3 と t_5 の時間の始点を揃えた複数のポジティブ・データからタイム・チューブを構成する。 t_1 から t_2 の期間を S_1 、 t_3 から t_4 の期間を S_2 、 t_5 から t_6 の期間を S_3 とする。期間 S_1 、 S_2 、 S_3 の状態遷移からタイム・チューブが構成される様子を図6に示す。

複数のポジティブ・データが共通にもつデータ上昇の度合を示す直線を表現できるように、エンドユーザ

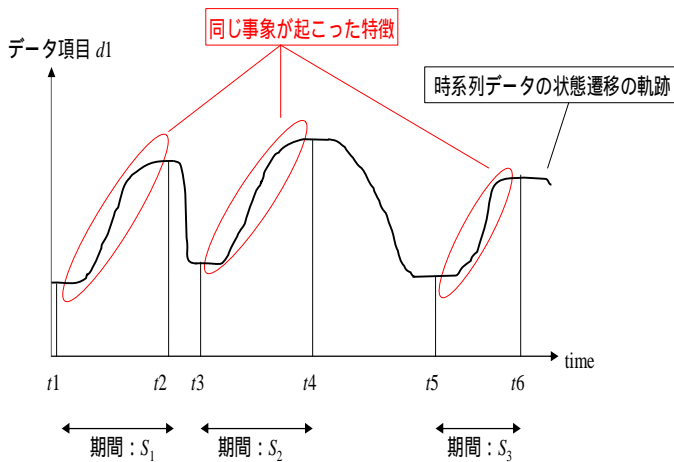


図5 3つのポジティブ・データの状態遷移




図6 タイム・チューブの構成

となる専門家が2点を指定する。2点を指定することで、傾きと切片が求まる。図6の場合、2点、 p_1 と p_2 を指定することにより、傾き a と切片 b が求まり、直線が表現される。 d_1 軸方向の値の幅を y と指定する。指定された2点間の線分から d_1 軸の正の向きに $y/2$ 、負の向きに $y/2$ だけ移動させる。この d_1 軸の値の幅はタイム・チューブの期間特性である。また、時間軸方向の値の幅をエンドユーザとなる専門家が x と指定することにより、指定された2点の時間軸の中心の軸から時間軸の正の向きに $x/2$ 加え、負の向きに $x/2$ を加えることで、時間軸の値の幅が決まる。この時間軸の値の幅はタイム・チューブの期間である。エンドユーザとなる専門家が点 p_1 、 p_2 と時間軸方向の幅 x と d_1 軸方向の幅 y を指定することでタイム・チューブが構成され、基本となるタイム・チューブを1つ決定する。決定したタイム・チューブの期間と期間特性が最適な定義だとは言えない。時系列データはセンサから取得されるため、センサの誤作動で誤った値を取得する可能性がある。その誤った値により、タイム・チューブの構成に影響が出る。また、複数のポジティブ・データのみで決定したタイム・チューブは洗練されたとは言えない。この決定したタイム・チューブを基本に、時間軸と d_1 軸のそれぞれの方向の幅に重みを加える。基本となるタイム・チューブに重みを複数回加えた複数のタイム・チューブを構成し、複数のポジティブ・データとネガティブ・データによって洗練することが必要である。重みを複数回加えてさまざまなタイム・チューブを構成することで、タイム・チューブを個々に構成する方法よりも、エンドユーザとなる専門家の負担は軽減できる。

複数の重みを加えたタイム・チューブと 100 個のポジティブ・データとの度数分布表をとった例を図 7 に示す。図 7 の表は 100 個のポジティブ・データのうち、各重みに対応したタイム・チューブの期間と期間特性に状態遷移が完全に含まれたポジティブ・データの個数を表す。タイム・チューブにポジティブ・データが含まれるかどうかの判定基準が重要となるが、この例ではポジティブ・データがタイム・チューブの中に完全に存在した場合に含まれたとみなす。図 7 の表の行列にある l_1 と w_1 の意味は基本となるタイム・チューブの時間軸の正の向きに $l_1/2$ の値、負の向きに $l_1/2$ の値、 d_1 軸の正の向きに $w_1/2$ の値、負の向きに $w_1/2$ の値の重みを加えたタイム・チューブである。 l_2 の重みの値は $l_1 \times 2$ 、 l_3 の重みの値は $l_1 \times 3$ であり、一般に l_n の重みの値は $l_1 \times n$ である。同様に w_n の重みの値は $w_1 \times n$ である。 n の値はエンドユーザとなる専門家が指定する。ポジティブ・データのみで構成されたタイム・チューブはネガティブ・データを用いての洗練も必要である。ネガティブ・データの場合も図 7 同様に 100 本のネガティブ・データに対する度数分布表を生成したと仮定する。100 個のネガティブ・データのうち、ポジティブ・データの場合と同じ重みが加えられた個々のタイム・チューブの期間と期間特性に状態遷移が完全に含まれたネガティブ・データの個数を数える。ポジティブ・データはできるだけタイム・チューブの中に存在し、ネガティブ・データはできるだけタイム・チューブの中に存在しないことが望ましい。タイム・チューブに含まれたポジティブ・データの数からタイム・チューブに含まれたネガティブ・データを減算した表を図 8 に示す。図 8 では l_2 と w_2 の場合が一番高

d_1 軸の重み 時間軸の重み	w_1	w_2	...	w_n
l_1	20	80		5
l_2	10	85		-5
...				
l_n	10	50		25

100本のポジティブ・データの度数分布表から
100本のネガティブ・データの度数分布表を減算した最高値

図 8 最適なタイム・チューブの決定

い値を示している。 l_2 と w_2 の重みを持つタイム・チューブはポジティブ・データを多く含み、ネガティブ・データをあまり含まないことを示している。この重みをもつタイム・チューブを、発見すべき時系列データの特徴を持つタイム・チューブとする。

3.3. タイム・チューブを用いた地すべり分析

本研究では、京都市内のある急斜面での 1 地点の 10 分間の降水量、地下の温度、地下の間隙水圧のデータを提供してもらっている。これらのデータを用いて、タイム・チューブを用いた地すべり分析を行うことを我々は計画している。

図 9 は時系列データの 10 分間の降水量の状態遷移から洗練されたタイム・チューブと一致する期間を取得することを示している。この一致した期間において地すべりが起こったと仮定する。一致したそれぞれの期間を s_1, s_2, \dots, s_n とする。 s_1 から s_n までの各期間で 10 分間の雨量以外にも地下の温度、地下の間隙水圧のデータを検索する。各変数間を横断的に調べることにより、データの傾向を把握できる。10 分間の雨量の




図 7 100 本のポジティブ・データの度数分布表




図 9 洗練されたタイム・チューブに一致した 10 分間の雨量の状態遷移

状態遷移が洗練されたタイム・チューブと、一致した期間の各変数間の状態遷移を図 10 に示す。図 10 の地下の温度の時系列データの状態遷移は、ばらつきがある。この図から、10 分間の雨量と地下の温度との関連性が薄いことが認識できる。一方で、地下の間隙水圧の時系列データの状態遷移は、ばらつきがあまり無く全ての期間の特徴が似ている。図 10 より、この地点は 10 分間の降水量と地下の間隙水圧との関連が非常に強いと認識できる。10 分間の降水量と地下の間隙水圧の二つの要素により地すべりの兆候を発見できる可能性も高いと推測できる。

また、地下 20cm の間隙水圧の状態遷移と地下 40cm の間隙水圧の状態遷移から水が地下に浸み込む速さが把握できる。この地下 20cm の間隙水圧と地下 40cm のそれぞれの間隙水圧のタイム・チューブの midpoint の間隔から、水の浸透速度の特徴を認識できる。たとえば、各変数間の状態遷移から浸み込む速が遅い、または全く地下に浸み込まなくなった場合、地下 40cm は水で飽和状態であることが把握できる。地下に水が溜まり、いつでも地すべりを引き起こす危険な状態であるとエンドユーザとなる専門家に知らせることができる。

オフラインでの分析で得られた特徴に当てはまるような時系列データの変動を早く察知することで地すべりの兆候検知や安全度判定などの分析が可能になると期待される。




図 10 洗練されたタイム・チューブに一致した期間の他変数の状態遷移

4. 時系列 OLAP ツールの実装

4.1. センサを利用した時系列データの取得

前述の京都市内の急斜面には、現在、1 地点にセンサが埋められている。そのセンサからは 10 分間の雨量、地下 10cm、30cm、50cm の温度、地下 20cm、40cm、60cm、80cm、100cm の間隙水圧が 10 分間おきに取得している。センサを用いて各変数間のデータの取得が

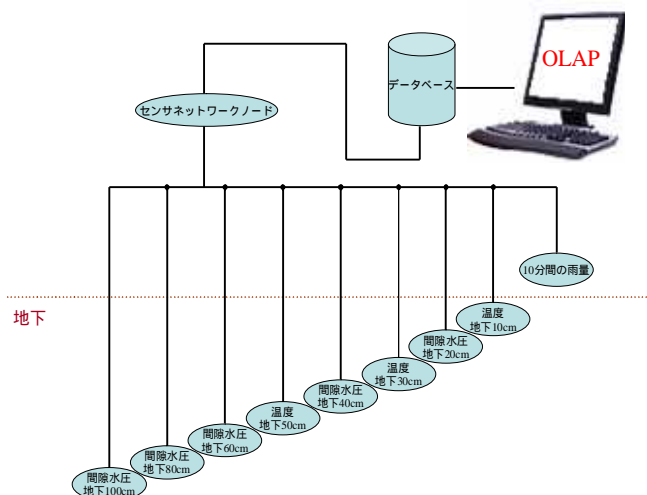


図 11 清水寺の 1 地点に埋められているセンサ

ら OLAP ツールを使用する全体の流れを図 11 に示す。図 11 はセンサから 10 分間の雨量、地下の温度、地下の間隙水圧のデータを取得する。それぞれの変数間のデータはセンサネットワークノードに集められる。複数のセンサネットワークノードに集められたデータは無線で機械室に送られる。センサ・ネットワークを用いることで、短時間かつ大量にデータを取得することが可能である。また、人が実際に斜面に出向きデータを取得するのではなく、センサから得られたデータを無線で送信することにより、安全にデータを取得することができる。

送られた時系列データはデータベースへ格納される。データベースに格納された数字だけの集合から分析するのは非常に困難である。そこで、データベースに格納された各変数間のデータを用いて、OLAP 分析を行う。OLAP 分析は GUI を用いることで、時系列データの分析を抽象的に扱うことができ、エンドユーザとなる専門家に分かりやすく利用してもらうことができる。

4.2. タイム・チューブ作成機能

本ツールは GUI 上に複数のポジティブ・データを表示する。そのポジティブ・データからユーザが 2 点を指定し、指定された 2 点を XML として記述する。今回の実装ではタイム・チューブの期間と期間特性をユーザが直接、XML に記述する。XML に記述されたタイム・チューブを図 12 に示す。

```
<?xml version="1.0" ?>
-<DATA>
-<data1 Ywidth="5" Xwidth="3">
  <point1 t1="10" w1="7.5" />
  <point2 t2="12.5" w2="9.5" />
</data1>
</DATA>
```

図 12 XML で記述されたタイム・チューブ

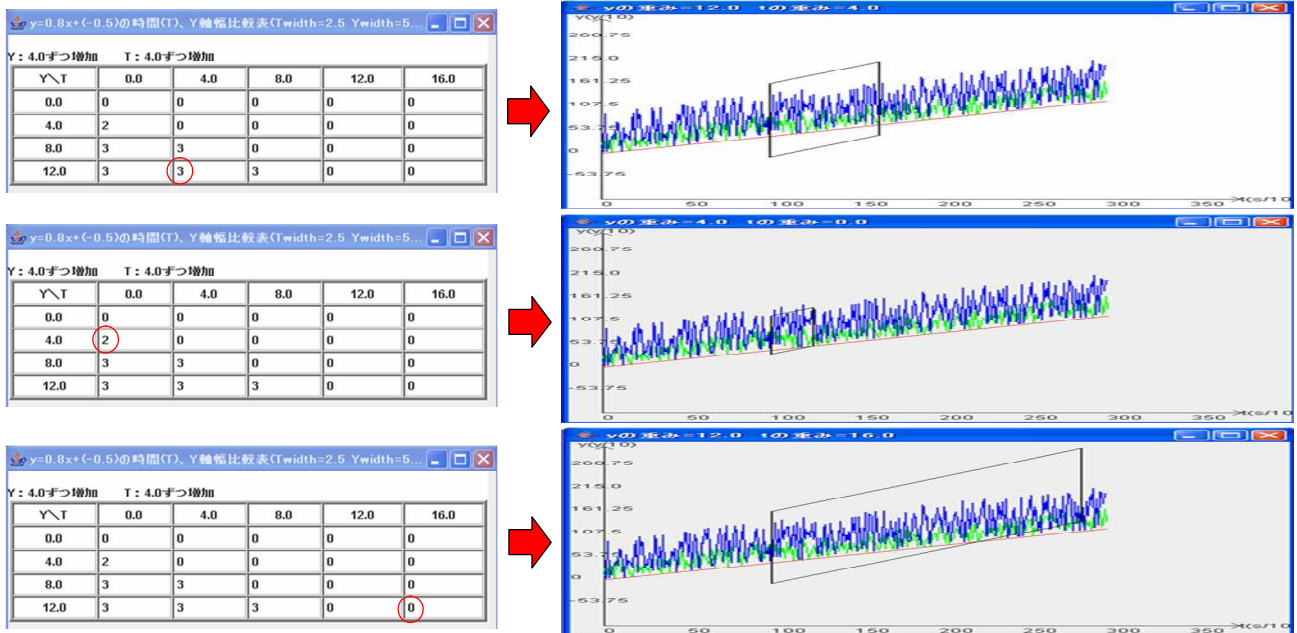


図 13 ポジティブ・データに対するタイム・チューブ

point1 と point2 で 2 点を指定することで傾きと切片が求まり直線が指定できる．この直線を軸にデータ項目の軸の正の向きに $Ywidth/2$,負の向きに $-Ywidth/2$ を加える．Point1 と point2 の時間軸方向の値を $t1$ と $t2$ とする $t1$ と $t2$ の中点から時間軸の正の向きに $Xwidth/2$,負の向きに $-Xwidth/2$ を加える．これで基本となるタイム・チューブは構成される．この基本となるタイム・チューブにデータ項目軸方向の重みの値とその重みの繰り返す回数，時間軸方向の重みの値とその重みの繰り返す回数をユーザが入力する．データ項目軸と時間軸の 2 つの方向に重みが等間隔に加えられ，複数のタイム・チューブが構成される．

4.3. タイム・チューブ洗練機能

3 つのポジティブ・データに対するさまざまな重みを加えたタイム・チューブとの比較を図 13 に示す．図 13 はデータ項目軸の重みの値を 4.0，時間軸の重みの値は 4.0 と設定している．また，データ項目軸の重みの繰り返す回数を 4 回，時間軸の重みの繰り返す回数を 5 回と設定している．基本となるタイム・チューブにデータ項目軸 y に 12.0，時間軸 t に 4.0 を加えたタイム・チューブは 3 種類の全てのポジティブ・データを含んでいる．基本となるタイム・チューブにデータ項目軸 y に 4.0，時間軸 t に 0 を加えたタイム・チューブは 2 種類のポジティブ・データを含んでいる．また，基本となるタイム・チューブにデータ項目軸 y に 12.0，時間軸 t に 16.0 を加えたタイム・チューブはいかなるポジティブ・データも含んでいない．タイム・チューブの時間軸の値の幅が小さく，データ項目軸の値の幅が大きいと，ポジティブ・データを全て含むが，ネガティブ・データも多く含む可能性が高い．逆に，時間

軸の値の幅大きく，データ項目軸の値の幅が小さいと，ポジティブ・データの特徴を捉えきれない．よってポジティブ・データのみで洗練したタイム・チューブは不十分である．ネガティブ・データについても同様にタイム・チューブを用いて，比較する必要がある．

5. おわりに

地すべりの兆候を検知するために，多数の時系列データから兆候の特徴を表すように，洗練したタイム・チューブを構成する．本論文では，小数の事例から専門家がタイム・チューブの初期パラメータを設定することを可能にし，かつ，多数の事例からタイム・チューブを洗練するツールについて述べた．

将来的にはオフラインでの分析で得られた特徴から，リアルタイムに時系列データの変動を早く察知することで地すべりの兆候検知や安全度判定などの分析を可能にする．

参考文献

- [1] 川西 直, 川原 圭博, 板生 知子, 森川 博之, 青山 友紀, 実空間センサ情報を用いたエンターテインメントアプリケーションの実現機構, 電子情報通信学会通信ソサイエティ大会, B-15-21, 2003 .
- [2] H.Shimakawa, H.Yamahara, Y.Imayama, M.Ushijima, S.Azuma, Pattern Refinement with Model Data Fusion to Predict Exchange Rate Movement, in A.Abraham, et.al, ed., Design and Application of Hybrid Intelligent Systems, pp.662-671, IOS press, December, 2003.
- [3] 倉沢 央, 川原 圭博, 森川 博之, 青山 友紀, 単一の無線加速度センサを用いたユーザコンテキストの推定, 電子情報通信学会ソサイエティ大会, B-19-23, 2005 .
- [4] 櫻井保志, 時系列データのためのストリームマイニング技術, ISPJ Magazine, Vol.47 No.7, 2006 .