

データマイニングによる 異常検知

東京大学大学院情報理工学系研究科

山西 健司

2015年6月12日

ソーシャルICT研究センター 第3回シンポジウム

内容

1. データマイニングによる異常検知
2. 変化検知
3. 潜在的構造変化検知
4. 変化兆候検知

1. データマイニングによる異常検知

データマイニングとは

大量のデータに潜む知識を獲得し、将来に向けて活用すること

機械学習

購買データ

(女、30代、会社員、東京、テニス)、(車種=セダン)
(男、20代、自営業、千葉、旅行)、(車種=バン)
(女、50代、主婦、神奈川、ゴルフ)、(車種=スポーツ)
(男、30代、自営業、東京、マージャン)、(車種=なし)
(女、40代、自営業、埼玉、旅行)、(車種=バン)
(女、20代、会社員、東京、旅行)、(車種=セダン)



規則の学習

自営業&旅行

→(車種=バン)

確率

→ 0.9

50代会社員&東京

→(車種=セダン)

→ 0.8

異常検知

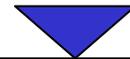
女、70代、車種=スポーツ

異常検知の体系

手法

外れ値検知

変化検知



応用

セキュリティ
(攻撃検知、
成りすまし検知
詐欺検知)

システム保全
ネットワーク監視
(障害検知、故障検知)

マーケティング
(トレンド発見、
購買ターゲティング、
広告効果測定)

SNS/WEB分析
(話題潮流発見、
コミュニティ発見)

ライフログ・フォレンジックス
(法的証拠発見、見守り、)

外れ値検出

統計的パターンから外れた異常値を抽出

ネットワークのパケットデータ.....アクセスログ

NO	Source IPアドレス X1	接続開始時間 X2	Dest. Portアドレス X3	情報送信量 X4
1	123.136.24.58	11:07:26	206.94.179.38	150
2	127.136.89.45	11:10:34	206.94.179.55	300
3	127.136.89.66	11:34:56	206.94.179.88	328
4	127.136.89.57	11:35:37	206.94.179.52	911
5	127.136.79.551	11:55:19	206.94.179.38	928

オンライン外れ値検知

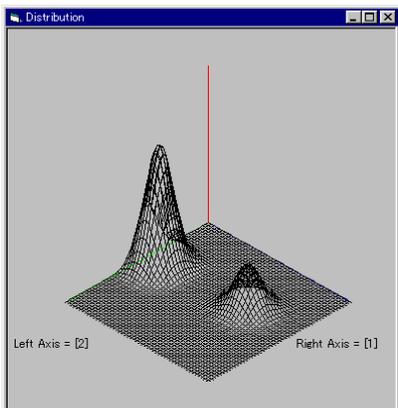
[Yamanishi et al. KDD2000, DMKD2004]

NO	Source IPアドレス X1	接続開始時間 X2	Dest. Portアドレス X3	情報送信量 X4
1	123.136.24.58	11:07:26	206.94.179.38	150
2	127.136.89.45	11:10:34	206.94.179.55	300
3	127.136.89.66	11:34:56	206.94.179.88	328
4	127.136.89.57	11:35:37	206.94.179.52	911
5	127.136.79.551	11:55:19	206.94.179.38	928

ログデータ
トランザクション

統計的モデル
の学習

スコア計算



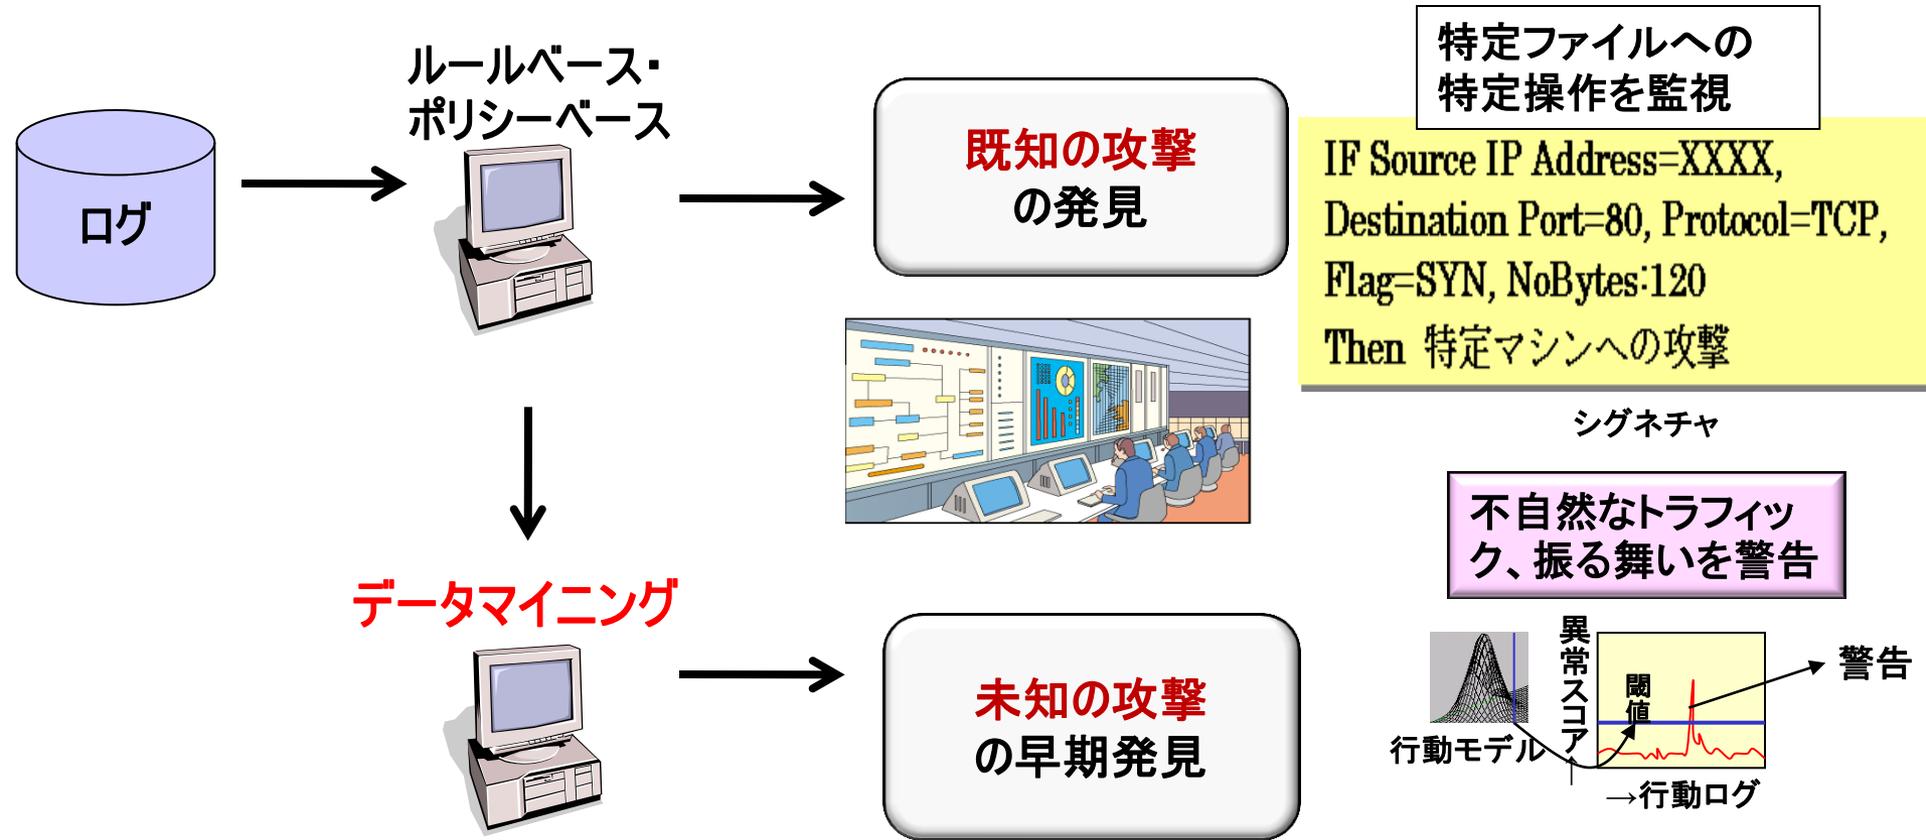
$$P(X) = \sum_{i=1}^K \pi_i P(X|\mu_i, \Sigma_i)$$

スコア
= 統計モデルの変化の大きさ
スコア大 ⇔ 異常度合い大

$$-\log P(x_t)$$

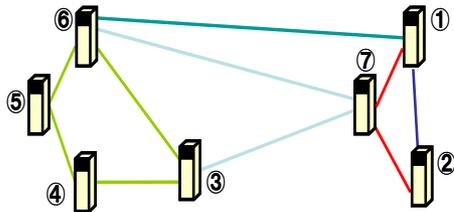
No	スコア	時間	通信量	サービス
1	3.4567	120	34.567	ftp
2	2.3456	110	98,345	http
3	2.1234	9	97.543	http
4	1.2345	23	13.578	telnet
.

攻撃検知への応用

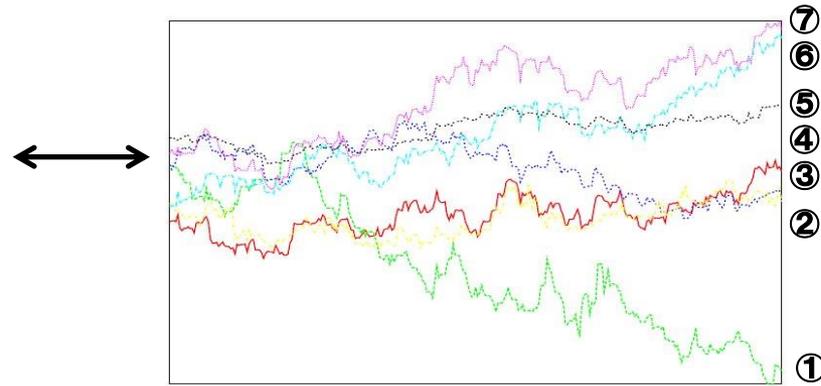


ネットワーク障害検知への応用

[Hirose, Yamanishi, Nakata, Fujimaki KDD2009]

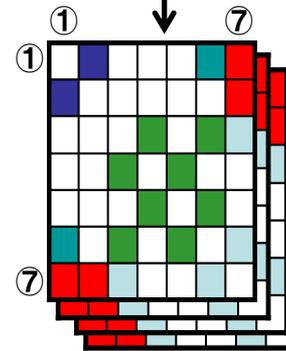


Input(observation) :
Server i 's traffic at time t : $u_i(t)$
($i = 1, 2, \dots, 7$)
($t = 1, 2, \dots$)



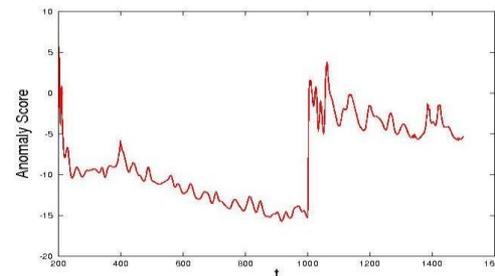
Quantities (eigenvalues)
Representing a whole NW

$$\lambda(t) = (\lambda^1, \lambda^2, \dots, \lambda^m)^\dagger$$



Correlation matrix
time series

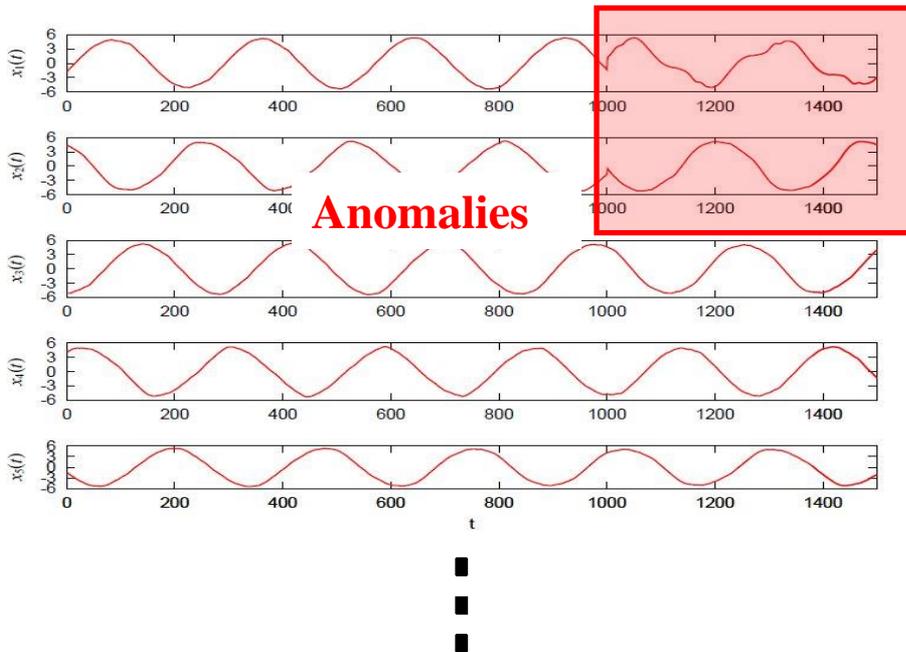
Change-point score/Anomaly Score
of $\lambda(t)$



機械系障害検知への応用

Data:

- Simulating a failure in machinery where several parts broke down,
 - currents in 20 different parts of a induction motor.
 - failure triggered by the 1st and 2nd parts.
- We have used MotorCurrent data
(<http://www.cs.ucr.edu/~eamonn/TSDMA/index.html>).



Changes of correlations

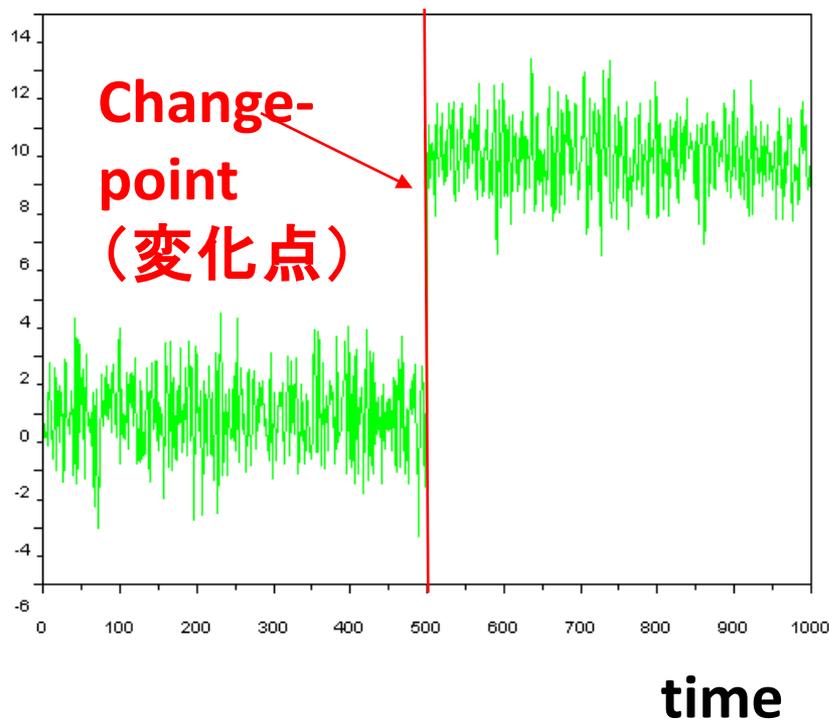
caused by a failure:

Triggered by the 1st and 2nd parts.

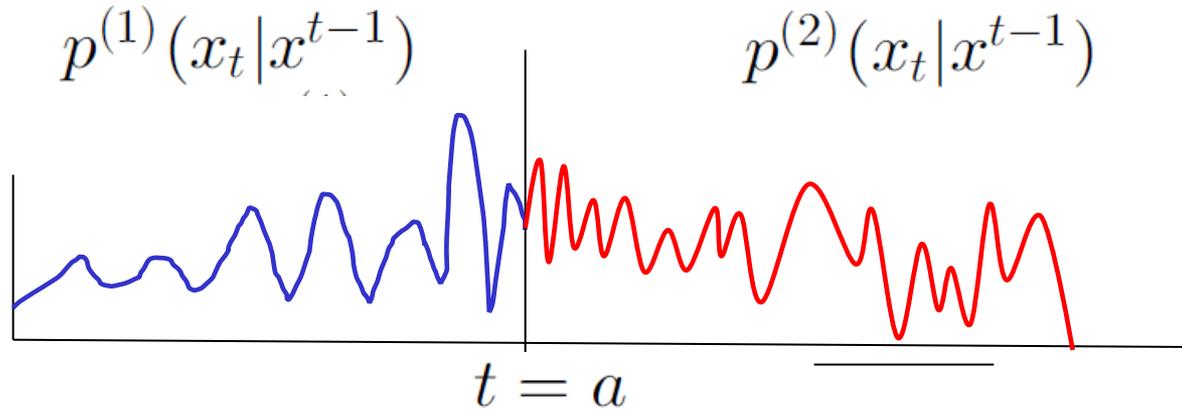
2. 変化点検知

変化点検知とは

時系列データのバースト(塊)的な変化の開始を検出
= 異常の兆候(予兆) を早期に検知



変化点の定義



$$p(x_t|x^{t-1}) = p^{(1)}(x_t|x^{t-1}) \quad t < a,$$

$$p(x_t|x^{t-1}) = p^{(2)}(x_t|x^{t-1}), \quad t \geq a.$$

$$t=a \text{ が変化点} \iff D(p^{(2)} || p^{(1)}) \stackrel{\text{def}}{=} \lim_{n \rightarrow \infty} \frac{1}{n} E_{p^{(2)}} \log \frac{p^{(2)}(x^n)}{p^{(1)}(x^n)},$$

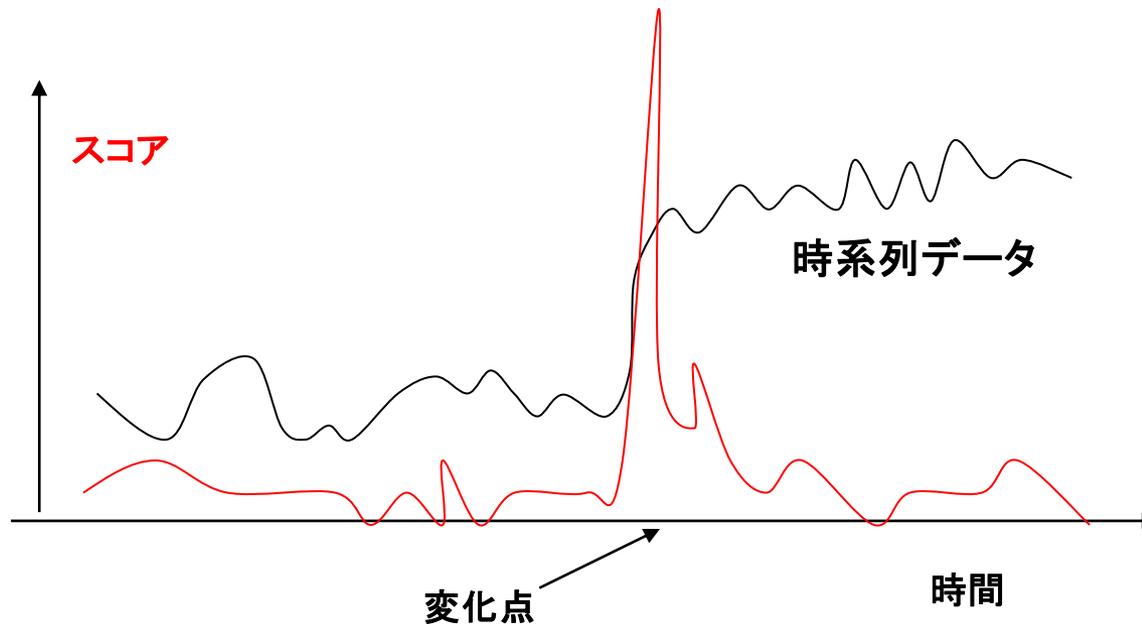
Kullback-Leibler Divergence = Dissimilarity Measure が大

When both $p^{(1)}$ and $p^{(2)}$ are i.i.d.

$$p^{(1)}(x_{a+1}^{a+m}) \approx \exp(-mD(p^{(2)} || p^{(1)})).$$

リアルタイム変化点検出

リアルタイムに変化らしさをスコアリング



⇒ 時系列モデルのオンライン学習
+ モデルの変化度スコアリング

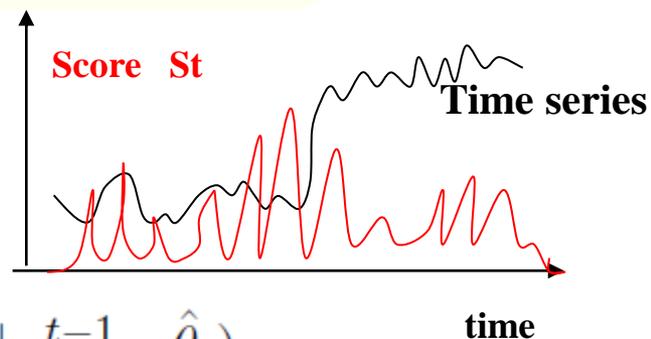
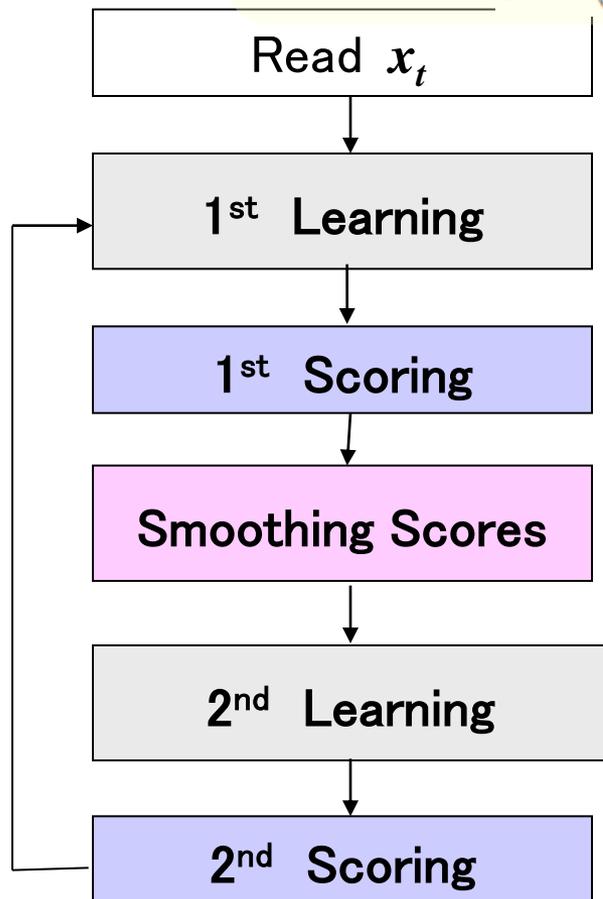
2段階学習による変化点検知

[Yamanishi and Takeuchi KDD 2002]

[Takeuchi and Yamanishi TKDE 2006]

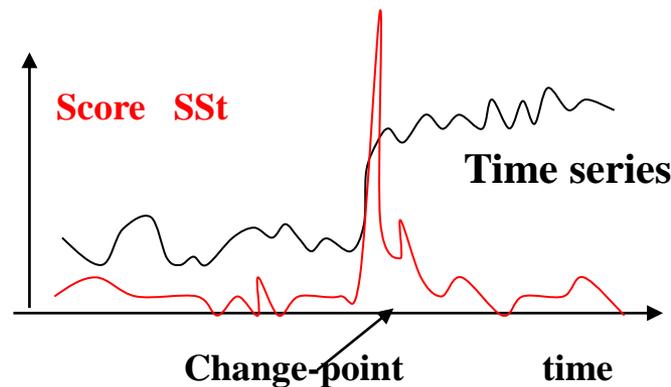
k-th
AR(auto-
regression)
model

$$p(x_t|x^{t-1}; \theta) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2\sigma^2} \left(x_t - \sum_{i=1}^k A^{(i)}x_{t-i}\right)^2\right)$$
$$\theta = (A^{(1)}, \dots, A^{(k)}, \sigma^2)$$



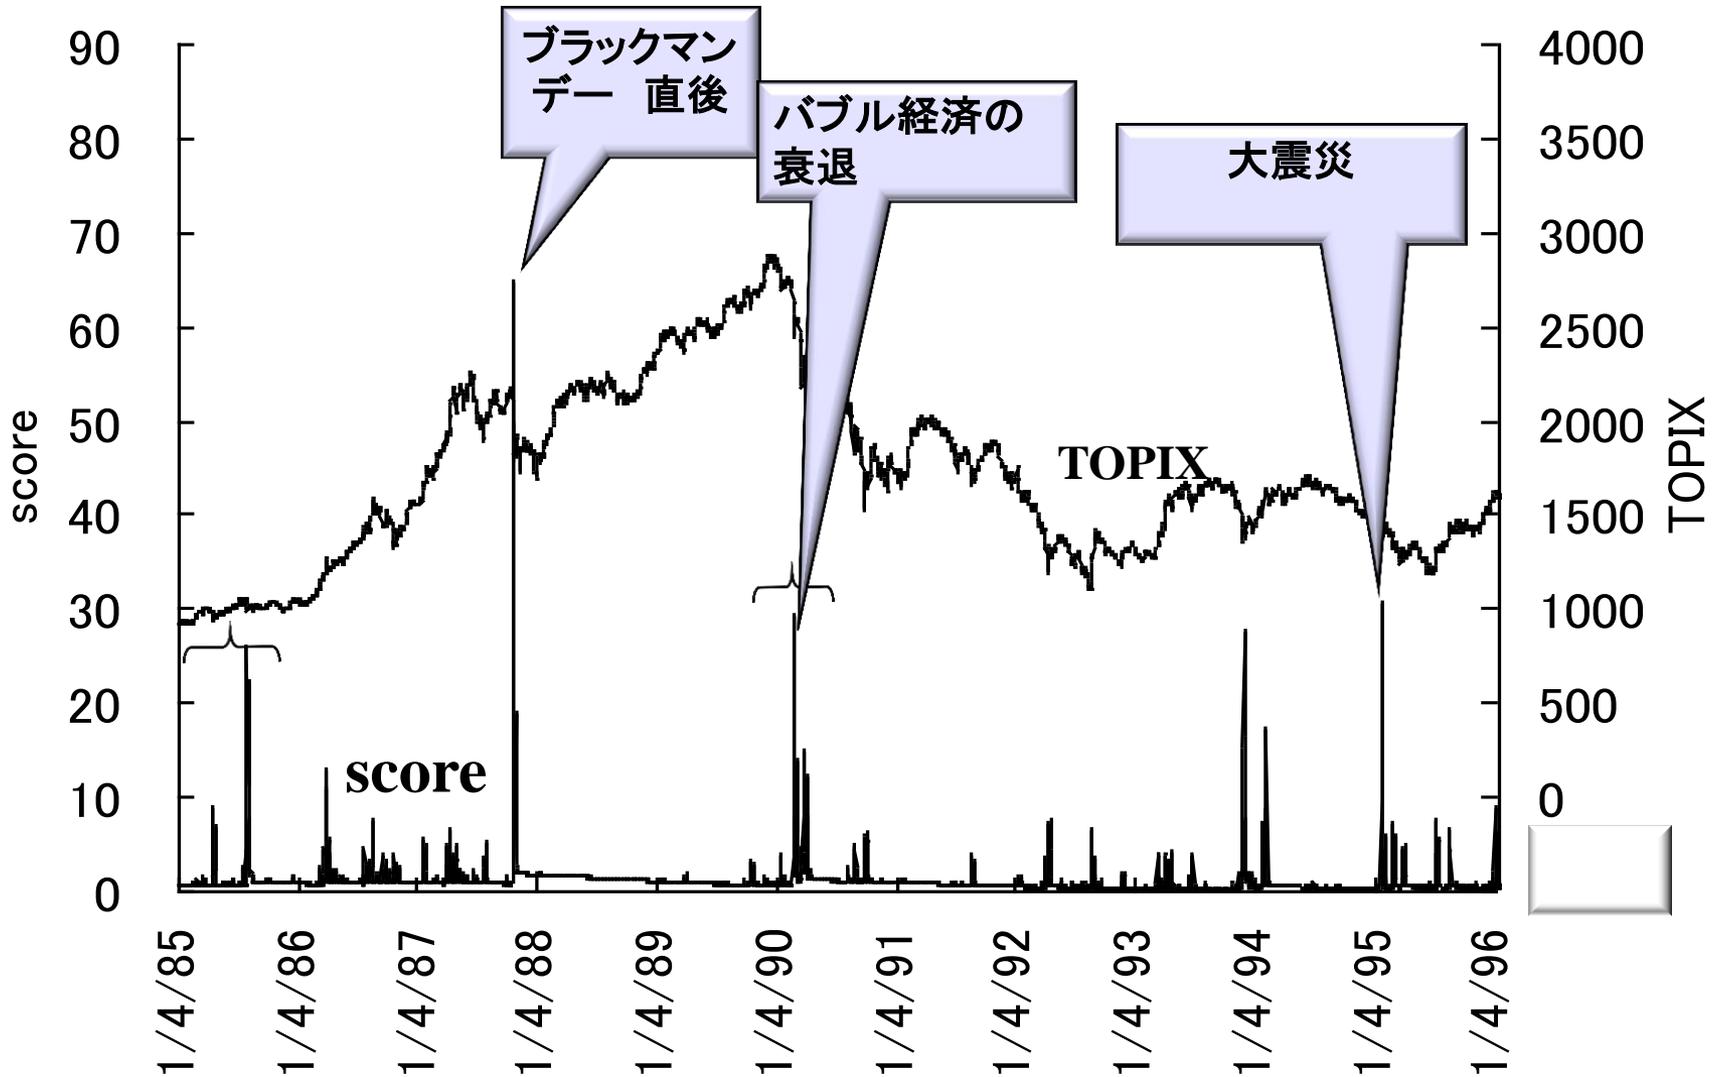
$$S_t = -\log p(x_t|x^{t-1}; \hat{\theta}_t)$$

$$y_t = \frac{1}{T} \sum_{j=T-W+1}^t S_t$$



$$SS_t = -\log q(y_t|y^{t-1}; \hat{\xi}_t)$$

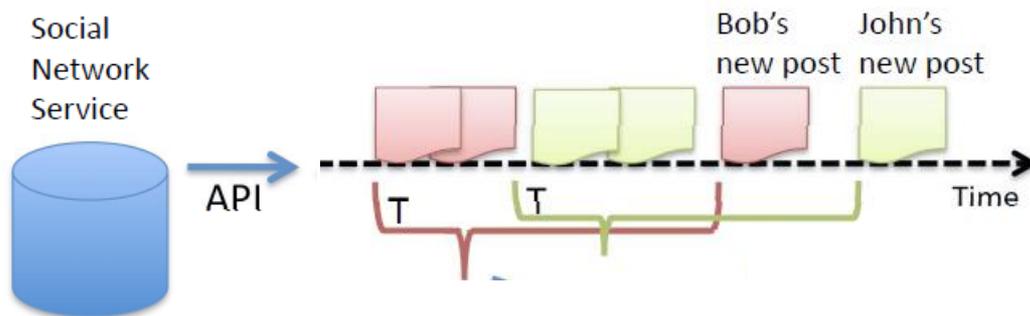
東証株価指数の変化点検出



SNSからの話題出現検知

[Takahashi Tomioka Yamanishi ICDM2011, TKDE2014]

- **目的:** SNS (Twitterなど) の流れから新しい話題の出現を検知



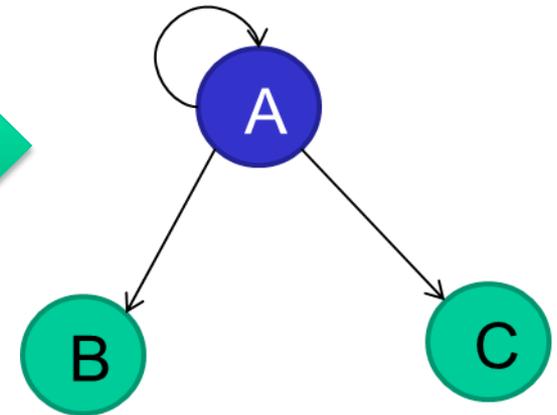
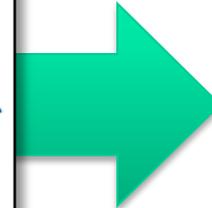
- **従来技術の問題点:**

- 言語ベースのアプローチには限界がある
 - 同義語、同音異義語 など
- トピック自体が多様なメディアで特徴づけられている
 - Image, Video, URLs

⇒ リンク情報だけを用いて話題出現検知をしたい

SNSからの話題出現検知

ユーザのmentionリンクの崩れから話題の発生を検知



#mentions

$$\mathbf{x} = (t, u, k, V)$$

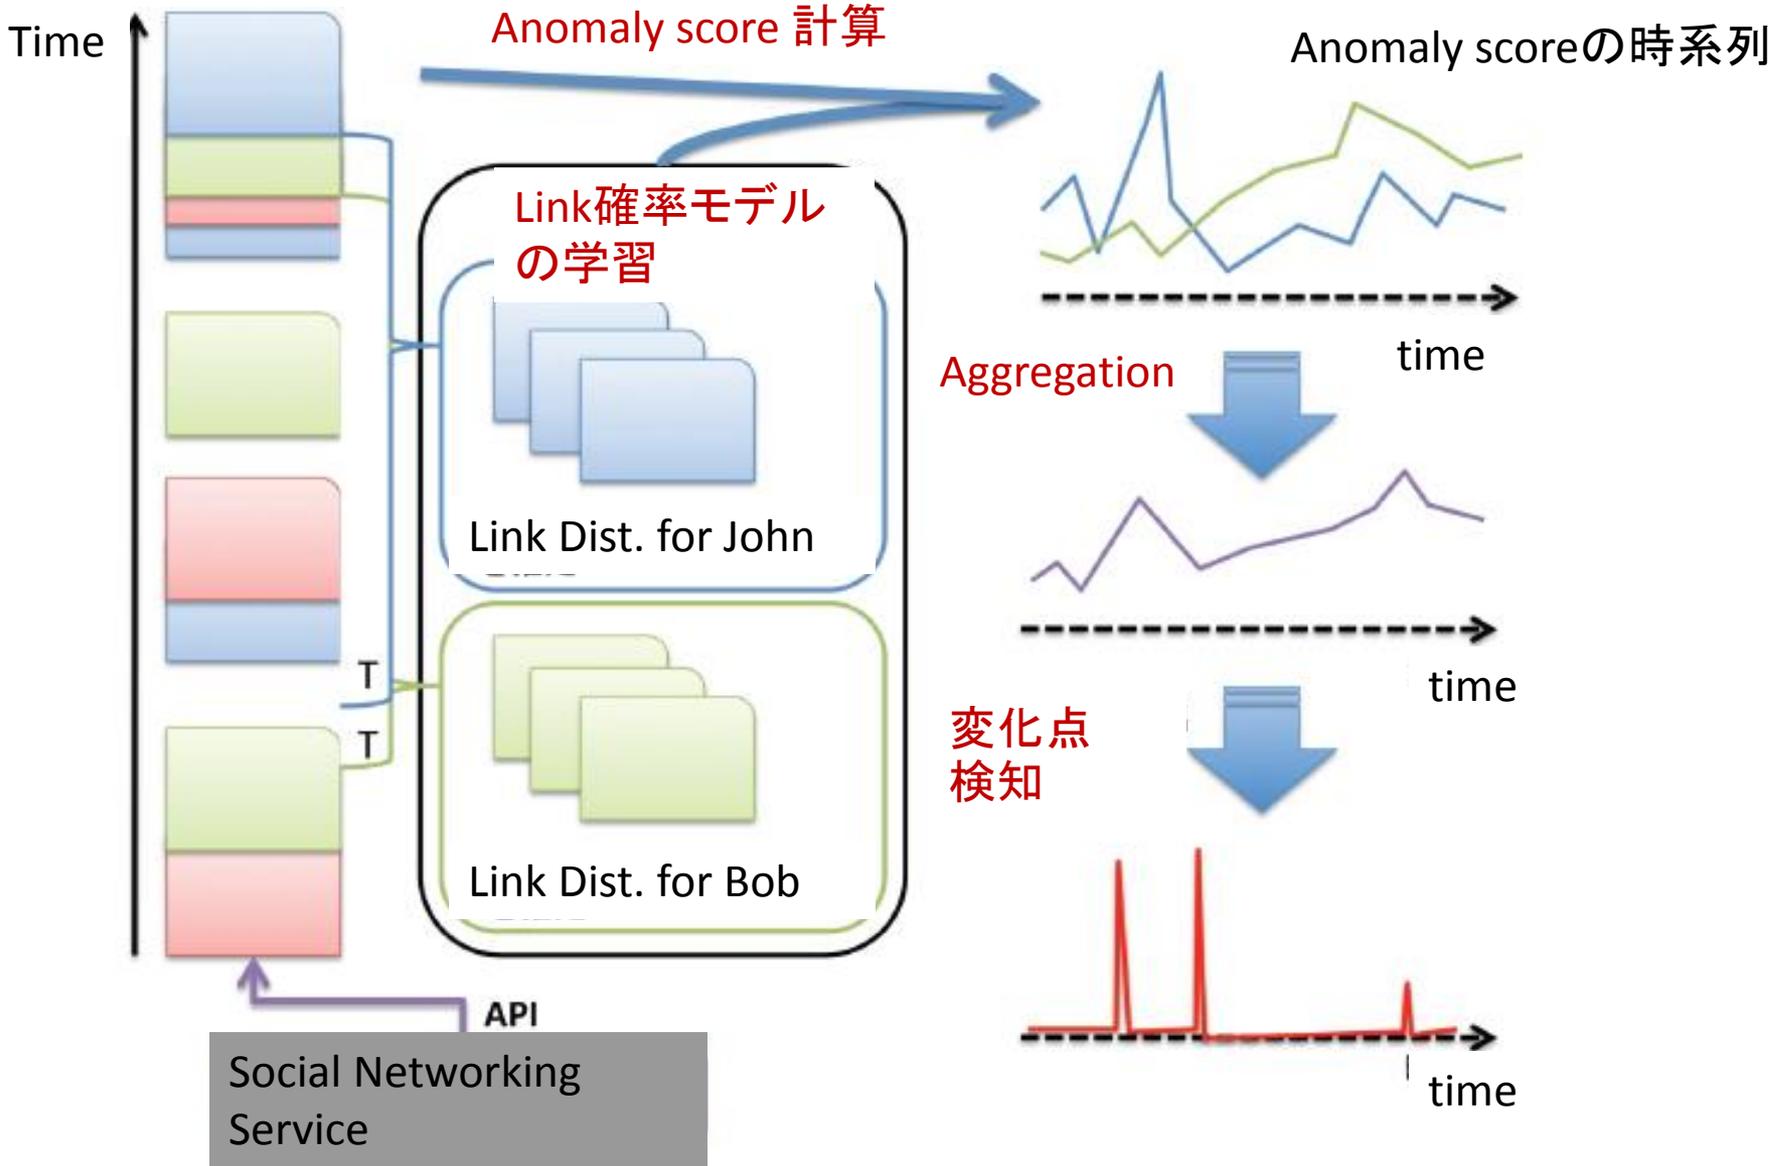
Submit Data
(post)

Submit Time

Submit User

Linking Users

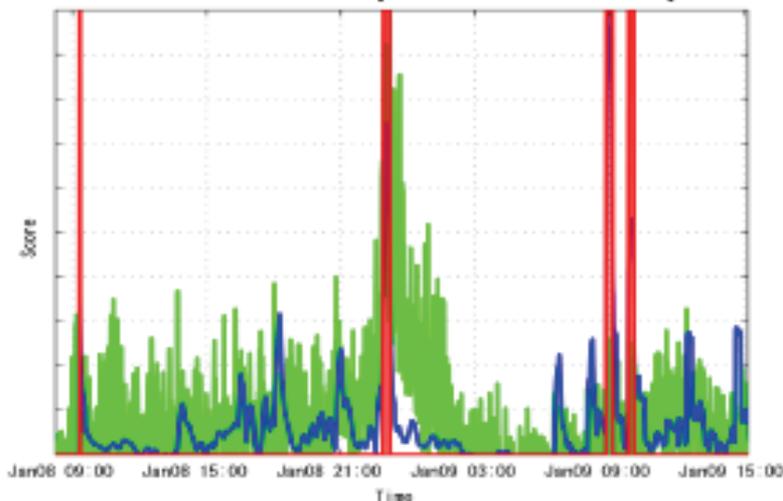
リンクベース話題出現検知の流れ



SNSからの話題出現検知例

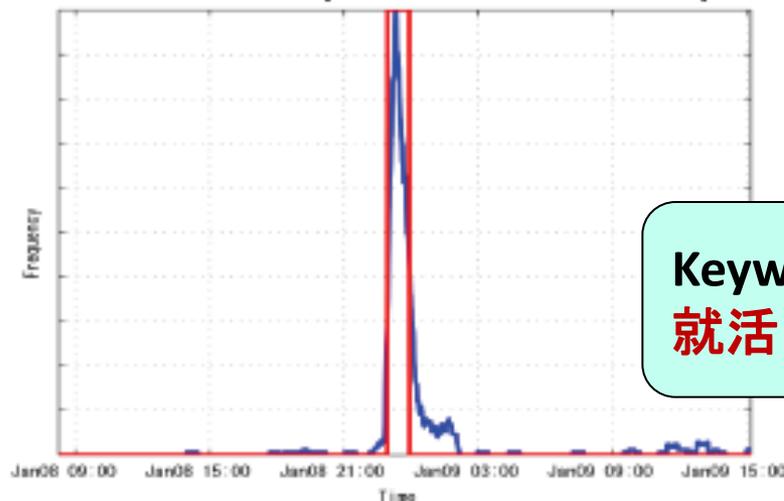
I氏の就職難発言の話題出現検知: 参加者数200

提案手法(変化点検出)



緑: 状態値, 青: 変化点スコア
赤: アラームの状態
検出時刻・・・22:55
検出数・・・4

比較手法(キーワード頻度)



Keyword:
就活

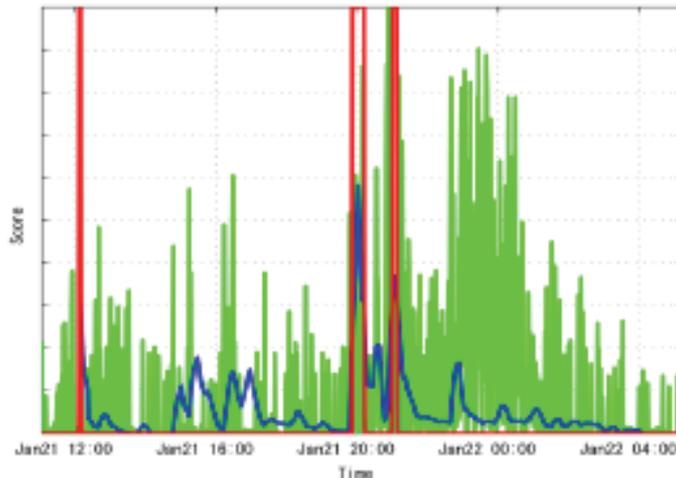
青: キーワードの登場頻度(/30分)
赤: アラームの状態
検出時刻・・・22:57
検出数・・・1

Linkベースがキーワードベースとほぼ同じ速さで話題出現を検知

SNSからの話題出現検知(9/9)

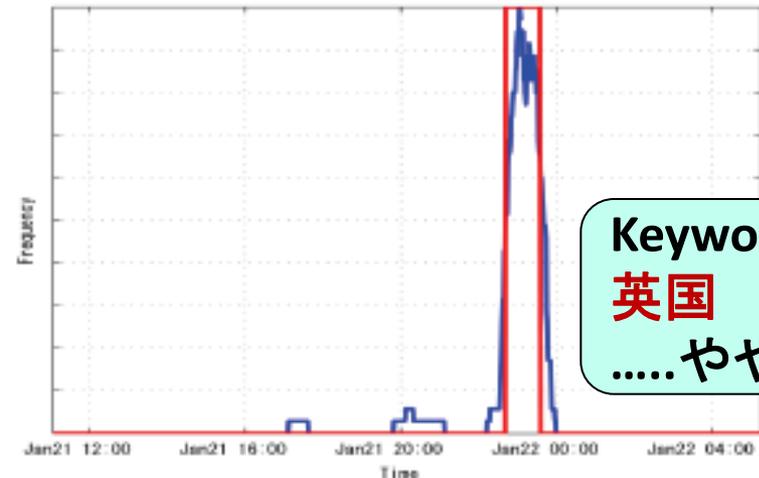
BBC問題発言の話題出現検知: 参加者数47

提案手法(変化点検出)



緑: 状態値, 青: 変化点スコア
赤: アラームの状態
検出時刻・・・19:52
検出数・・・3

比較手法(キーワード頻度)



Keyword:
英国
.....やや曖昧

青: キーワードの登場頻度(/30分)
赤: アラームの状態
検出時刻・・・22:41
検出数・・・1

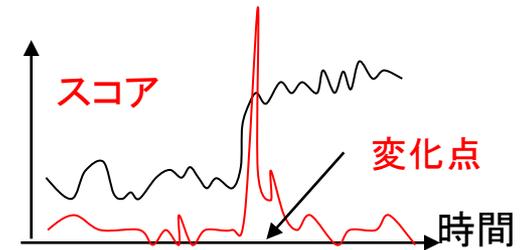
リンクベースはキーワードベースよりも早期に話題検知している

3. 潜在的構造變化檢知

変化検知の分類

★ 顕在的变化検知

データの表層的性質が変化する



潜在的構造変化検知

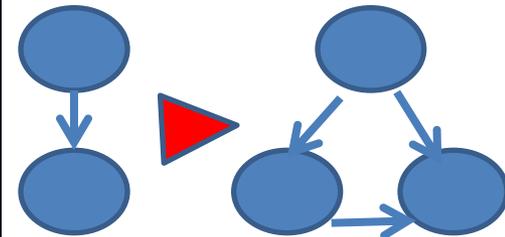
データの潜在的構造が変化する

第一の潜在的ダイナミクス

潜在変数の状態が変化

★ 第二の潜在的ダイナミクス

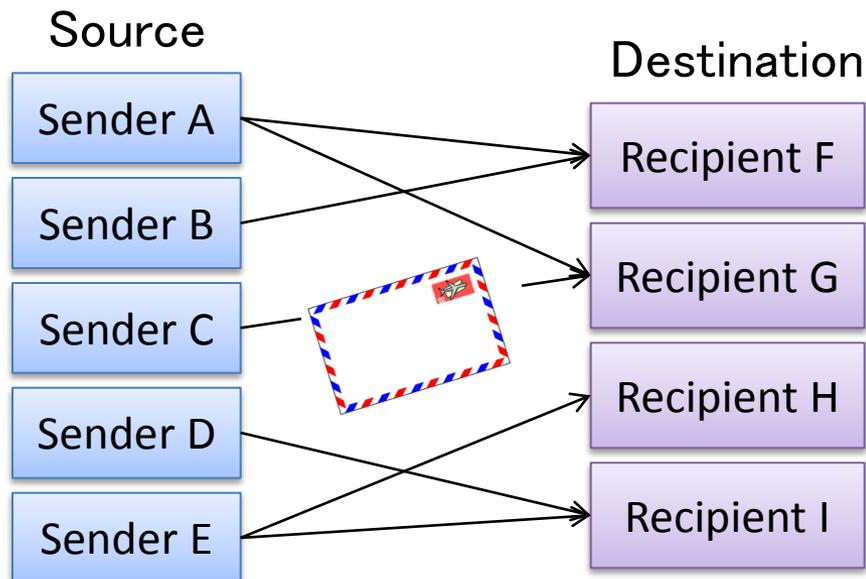
潜在空間の構造が変化



グラフ分割構造変化検知

2部グラフデータ

- 例
- 都道府県間の人口移動(何県から何県へ何人)
 - メールの送受信件数(誰が誰に何通)
 - SNS上のやり取り etc...



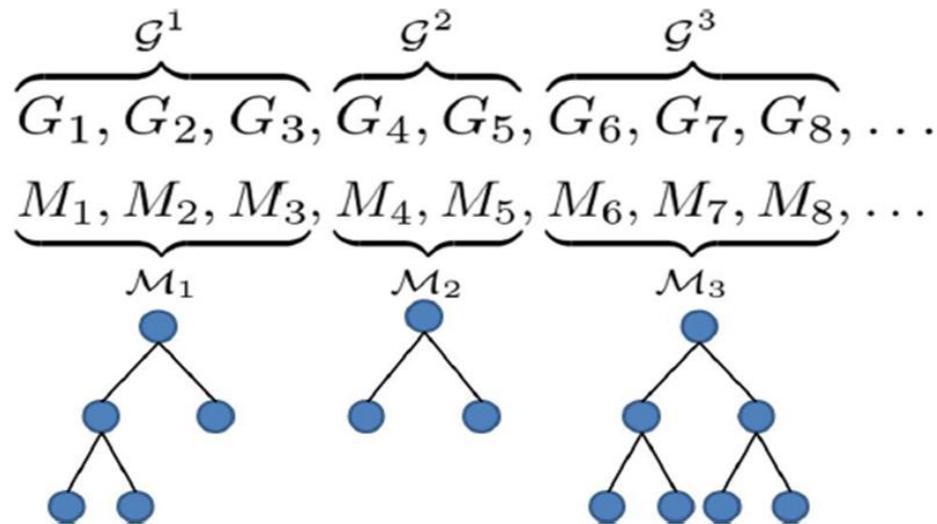
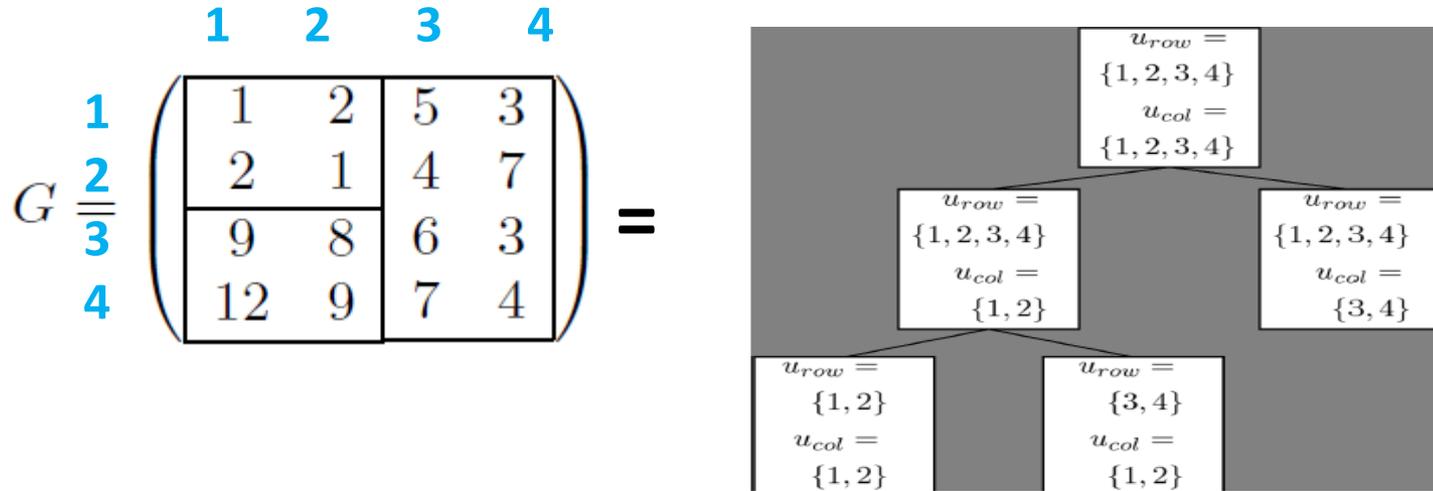
グラフ分割

	F	G	H	I
A	1	1	0	0
B	2	0	0	0
C	0	2	0	0
D	0	0	0	1
E	0	0	3	1

木構造を用いたグラフ分割構造変化検知

Key Idea: グラフ分割構造変化検知 = 木構造変化検知

[Sato Yamanishi ICDM 2013]



グラフ分割構造変化検知

動的モデル選択

For given graph sequence: $\mathcal{G} = G_1, G_2, \dots, G_T$ (T : data size)

Select a tree sequence: $M^t = M_1 M_2 \dots M_t$

so that the **DMS (dynamic model selection)** is minimum:

$$\mathcal{L}(\mathcal{G}; \mathcal{M}) \stackrel{\text{def}}{=} \sum_{t=1}^T (-\log P(G_t | M_t)) + \sum_{t=1}^T (-\log P(M_t | M^{t-1}))$$

木構造系列に対するグラフ
系列の予測符号長

木構造系列の予測符号長.

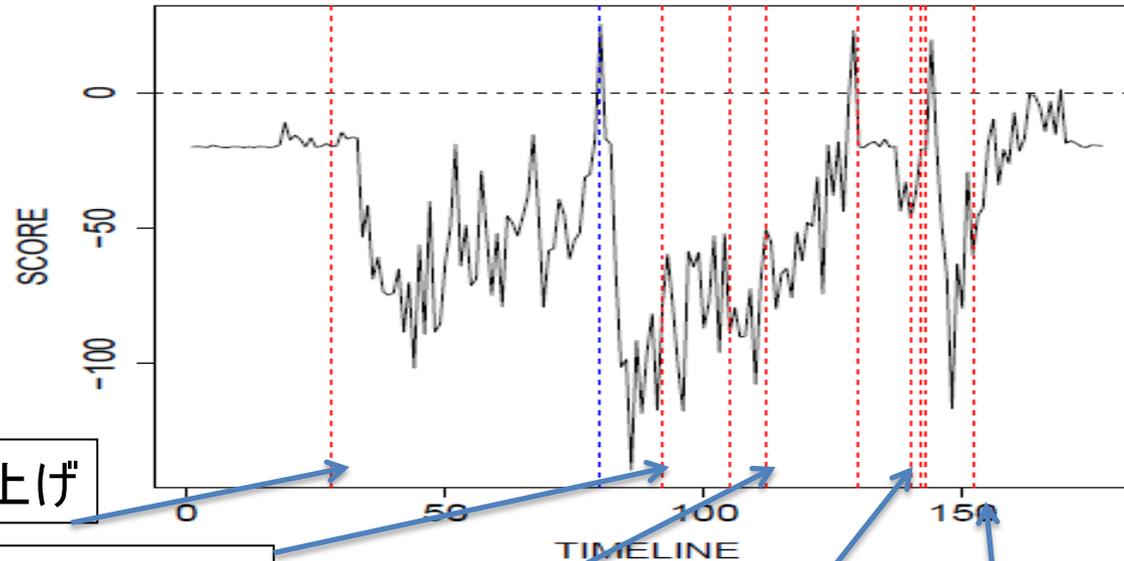
Minimum Description Length (MDL) Principle [Rissanen 78]

DMS.....MDL のモデルが変化する場合への拡張

[Yamanishi and Maruyama KDD2005, IEEE IT 2007]

Enron社のEvent検知

ENRON社内でのemailのやり取りの有無を週単位で記録
(1999年1月～2002年7月) #sender=#recipient=150



ENRON社立ち上げ

J.Skilling CEO就任

JIエネルギー部門売却

FBI捜査開始

会計改革法案提出

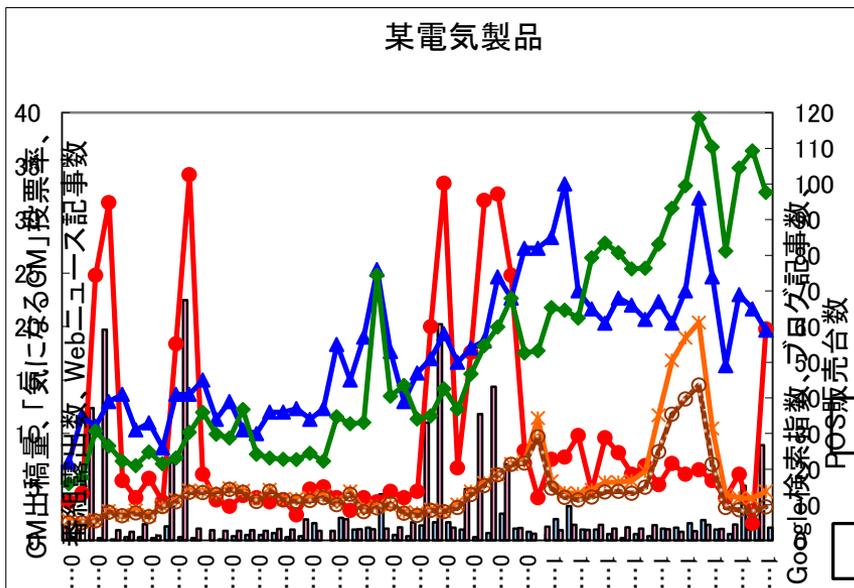
スコア = 構造変化がない場合のDMS規準

— 構造変化がある場合のDMS規準

ベイジアンネットワーク構造変化検知

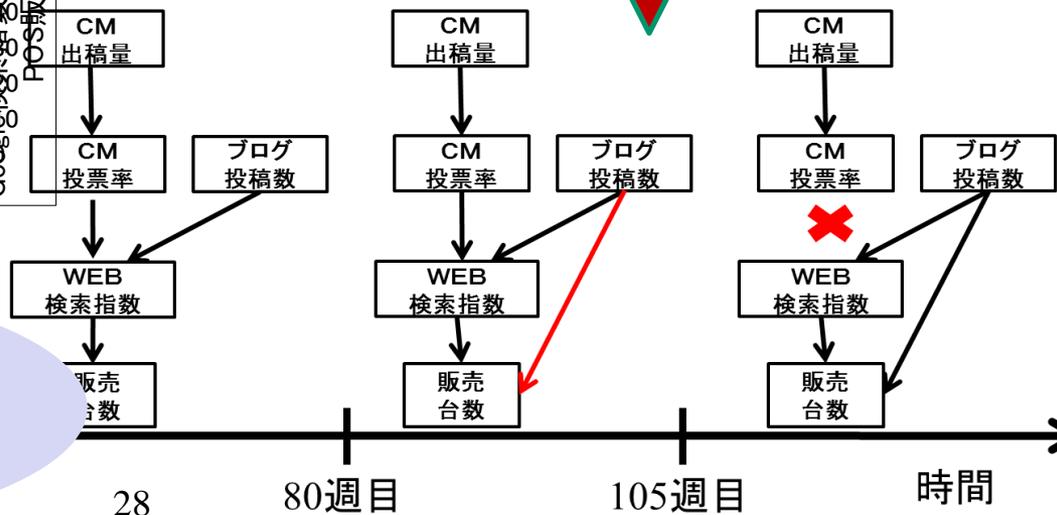
多次元時系列データからベイジアンネットワークの構造変化検知により広告効果を測定

[Hayashi Yamanishi ICDM2012, DMKD2015]



データ提供： 博報堂

広告出稿



広告出稿により
ブログでの評判が高まり
売り上げに結び付いた

クラスタリング構造変化検知

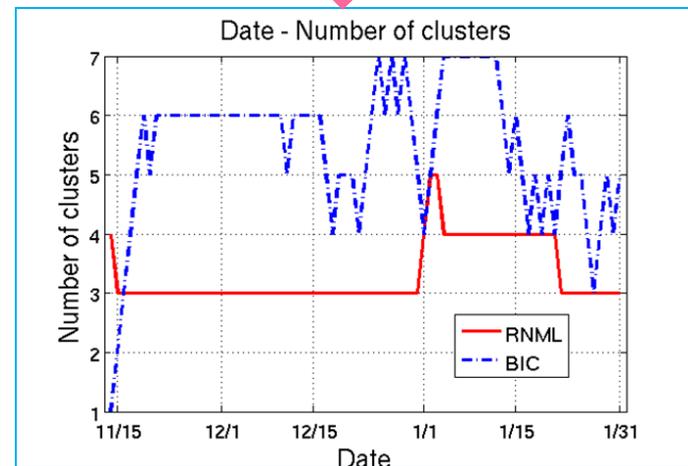
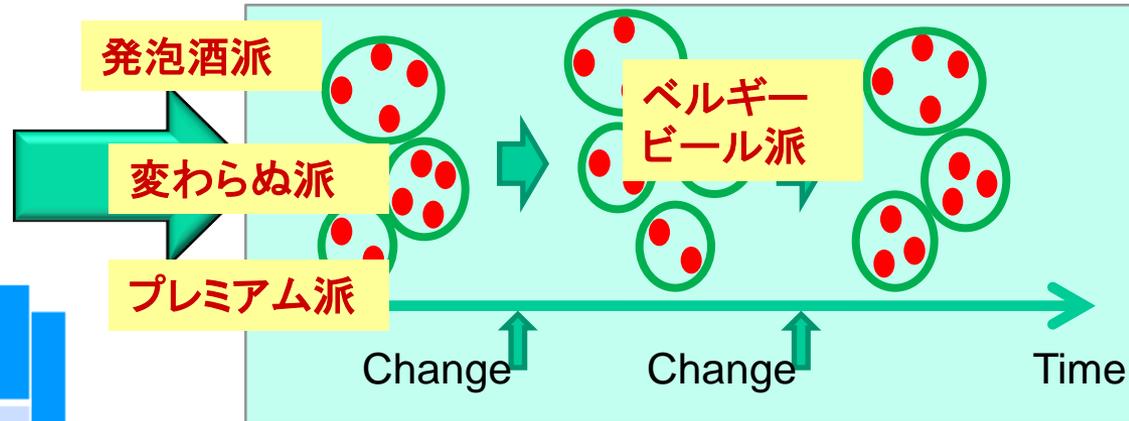
クラスタリング構造変化検知によるマーケットの構造変化検知

[Hirai Yamanishi KDD2012, IEEE IT2013]

購買層クラスター系列

多変数時系列

	Beer 1	Beer 2	...
User 1	350	700	...
User 2	1050	350	...
...



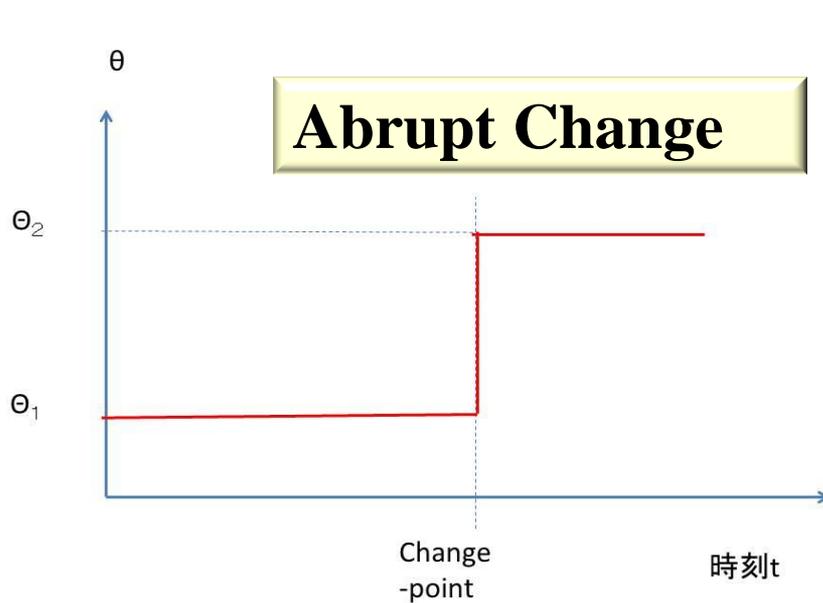
データ提供：マクロミル、博報堂

Inc.

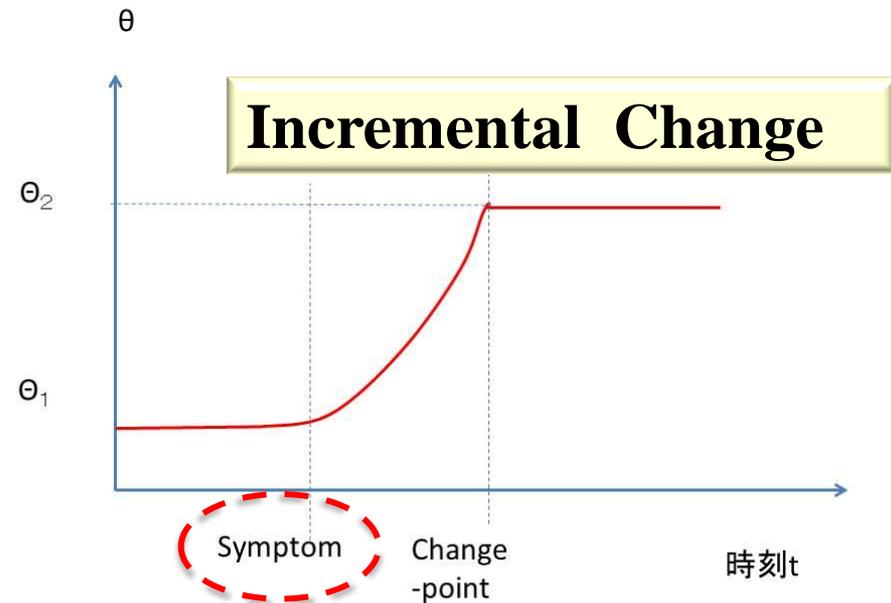
4. 変化兆候検知

変化兆候検知

変化は徐々に起こる⇒変化の開始点を検知



Change Detection
パラメータ値が
不連続に変化



Change Symptom Detection
パラメータ値が
徐々に変化

おわりに

- 変化にこそ知識発見あり (Change = Novelty)
.....異常が異常でなくなる時
- 潜在的構造変化検出 (Latent Dynamics)
.....潜在世界にこそ変化の本質がある
- 変化兆候検知 (Symptom Detection)
.....,変化の開始を見極める ⇒ Challenge!