

非定常データからのネットワーク構造変化検出

東京大学大学院 情報理工学系研究科
早矢仕 裕, 山西 健司


第2回Latent Dynamics Workshop
東京大学
2011/6/22

概要

1. 問題設定
2. 既存研究の概説
3. 現在の取り組み
4. まとめ

研究の目的

多変量時系列データから、変数間の構造変化を検出する






入力: 非定常な、互いに関係を持つ
多変量時系列データ

(例) 機械のセンサーデータ
広告のマーケティングデータ

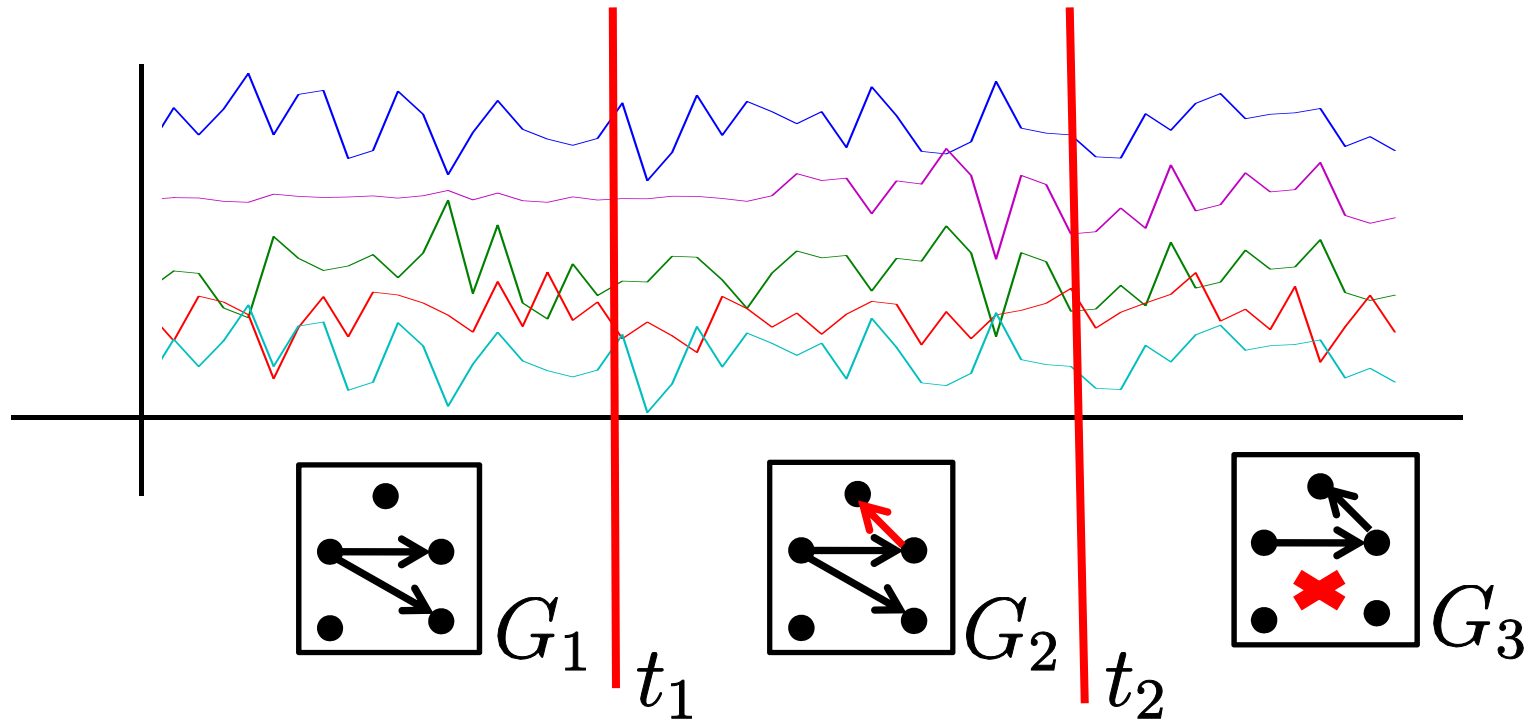


出力: 変数間の依存関係
(ネットワーク構造)
を表すモデル系列
(相関関係、因果関係など)



Latent: 変数間の関係
Dynamics: 関係の変化

ネットワーク構造変化検出



設定: 各時刻のデータは、グラフ構造 G を持つグラフィカルモデル $P(x : G)$ から生成される。

(モデルの例: ベイジアンネットワーク、グラフィカル・ガウシアン・モデルなど)

目的: データからモデル系列 $(G_1, G_2, \dots, G_\ell)$ と変化点 $(t_1, t_2, \dots, t_{\ell-1})$ を推定する

概要

1. 問題設定
2. 既存研究の概説
3. 現在の取り組み
4. まとめ

既存研究

	グラフィカル・ガウシアン モデル	ベイジアンネットワーク
MCMCを用いた手法	Talih and Hengartner, 2005	Robinson and Hartemink, 2010
動的計画法を用いた手 法	Xuan and Murphy, 2007	

MCMCを用いた手法(1/2)

[Talih and Hengartner, 2005],

[Robinson and Hartemink, 2010]

目的 データ列 x^T

モデル系列 $\mathbf{G} = (G_1, G_2, \dots, G_\ell)$

変化点系列 $\mathbf{t} = (t_1, t_2, \dots, t_{\ell-1})$ に対して

モデルの事後分布

$$P(\mathbf{G}, \mathbf{t} | x^T) \propto P(x^T | \mathbf{G}, \mathbf{t}) P(\mathbf{G}, \mathbf{t})$$

を計算する。(MAP推定ならば最大のものを選ぶ)

$P(x^T | \mathbf{G}, \mathbf{t})$ は各区間毎独立・パラメータに関して周辺化して
計算($P(x^T | \mathbf{G}, \mathbf{t}) = P(x_{1:t_1} | G_1) \dots P(x_{t_{\ell-1}+1:T} | G_\ell)$ とかける)

$P(\mathbf{G}, \mathbf{t})$ は、モデルの変化した辺の数などに応じた確率分布
(変化が大きいほど、確率が小さいなど)

MCMCを用いた手法(2/2)

$$P(\mathbf{G}, \mathbf{t} | x^T) \propto P(x^T | \mathbf{G}, \mathbf{t}) P(\mathbf{G}, \mathbf{t})$$

において、 (\mathbf{G}, \mathbf{t}) の組み合わせの数が非常に多い。

・メトロポリス-ヘイスティングス法による事後分布からのサンプリングを行う。

(1) $(\mathbf{G}, \mathbf{t}) \rightarrow (\mathbf{G}', \mathbf{t}')$ というモデル系列間のマルコフ連鎖を構成

例えば、モデル系列の一部に辺を加える
変化点をずらすといった遷移

(2) 遷移が採択される確率を

$$\alpha((\mathbf{G}, \mathbf{t}), (\mathbf{G}', \mathbf{t}')) = \min\left\{1, \frac{P(x^T | \mathbf{G}', \mathbf{t}') P(\mathbf{G}', \mathbf{t}')}{P(x^T | \mathbf{G}, \mathbf{t}) P(\mathbf{G}, \mathbf{t})} \times \frac{q((\mathbf{G}', \mathbf{t}') \rightarrow (\mathbf{G}, \mathbf{t}))}{q((\mathbf{G}, \mathbf{t}) \rightarrow (\mathbf{G}', \mathbf{t}'))}\right\}$$

として、モデル系列を遷移させて、サンプリングする。

動的計画法を用いた手法(1/2)

[Xuan and Murphy, 2007]

変化点検出に[Fearnhead and Liu 2007]を導入

[Fearnhead and Liuの概要]

変化点に対する分布として $P(C_{t+1} = j | C_t = i)$
を導入。(C_t は、時刻 t 以前の直近の変化点)

このとき動的計画法により、 $\arg \max p(x^T | \mathbf{t})p(\mathbf{t})$ となる
変化点の組 \mathbf{t} を出力する。

- ・データは区間定常な状況

$$p(x^T | \mathbf{t}) = p(x_{1:t_1})p(x_{t_1+1:t_2}) \dots p(x_{t_{\ell-1}+1:T})$$

- ・モデルについては与えられたクラス(集合)(G_1, G_2, \dots, G_n) と
事前分布 $p(G)$ により周辺化、パラメータについても周辺化

2011/6/22
$$p(x_{1:t_1}) = \sum_{i=1}^n p(x_{1:t_1} | G_i)p(G_i)$$

動的計画法を用いた手法(2/2)

Xuan and Murphyの手法

(1) ヒューリスティクス(スライド窓 + 構造学習)によりモデルクラスを構成

(2) 得られたモデルクラスとモデルに関する一様な事前分布をもとに、Fearnhead and Liuの手法により変化点検出を行う。

(3) 得られた変化点に対応した各区間毎に構造学習を行いモデルクラスを更新する。

(4) (2)、(3)を収束するまで繰り返す。

概要

1. 問題設定
2. 既存研究の概説
3. 現在の取り組み
4. まとめ

現在の取り組み

既存手法の問題点





- ・モデルが現実のデータに即しているか
 - (例)・区間定常: 変化点以前の影響が全くない
 - ・グラフィカルモデルも複数提案されている
- ・手法のよしあしの評価
 - 手法間の定量的な比較が現在までにほとんど行われていない。

現在の取り組み

- ・新しい手法の提案と、既存手法との比較
- ・手法の広告効果測定への応用

動的モデル選択 (Yamanishi and Maruyama, 2007)

確率的にモデルが遷移することを仮定



$$P(G_t | G_{t-1}) = \begin{cases} 1 - \alpha & (G_t = G_{t-1}) \\ \frac{\alpha}{\#(\text{遷移先の総数})} & (G_t \text{ が遷移候補の時}) \\ 0 & (\text{それ以外}) \end{cases}$$

$D^{(1)} D^{(2)} \dots D^{(t)} D^{(t+1)} \dots D^{(n)}$

遷移先は、辺が1本増えるor減るモデルとした

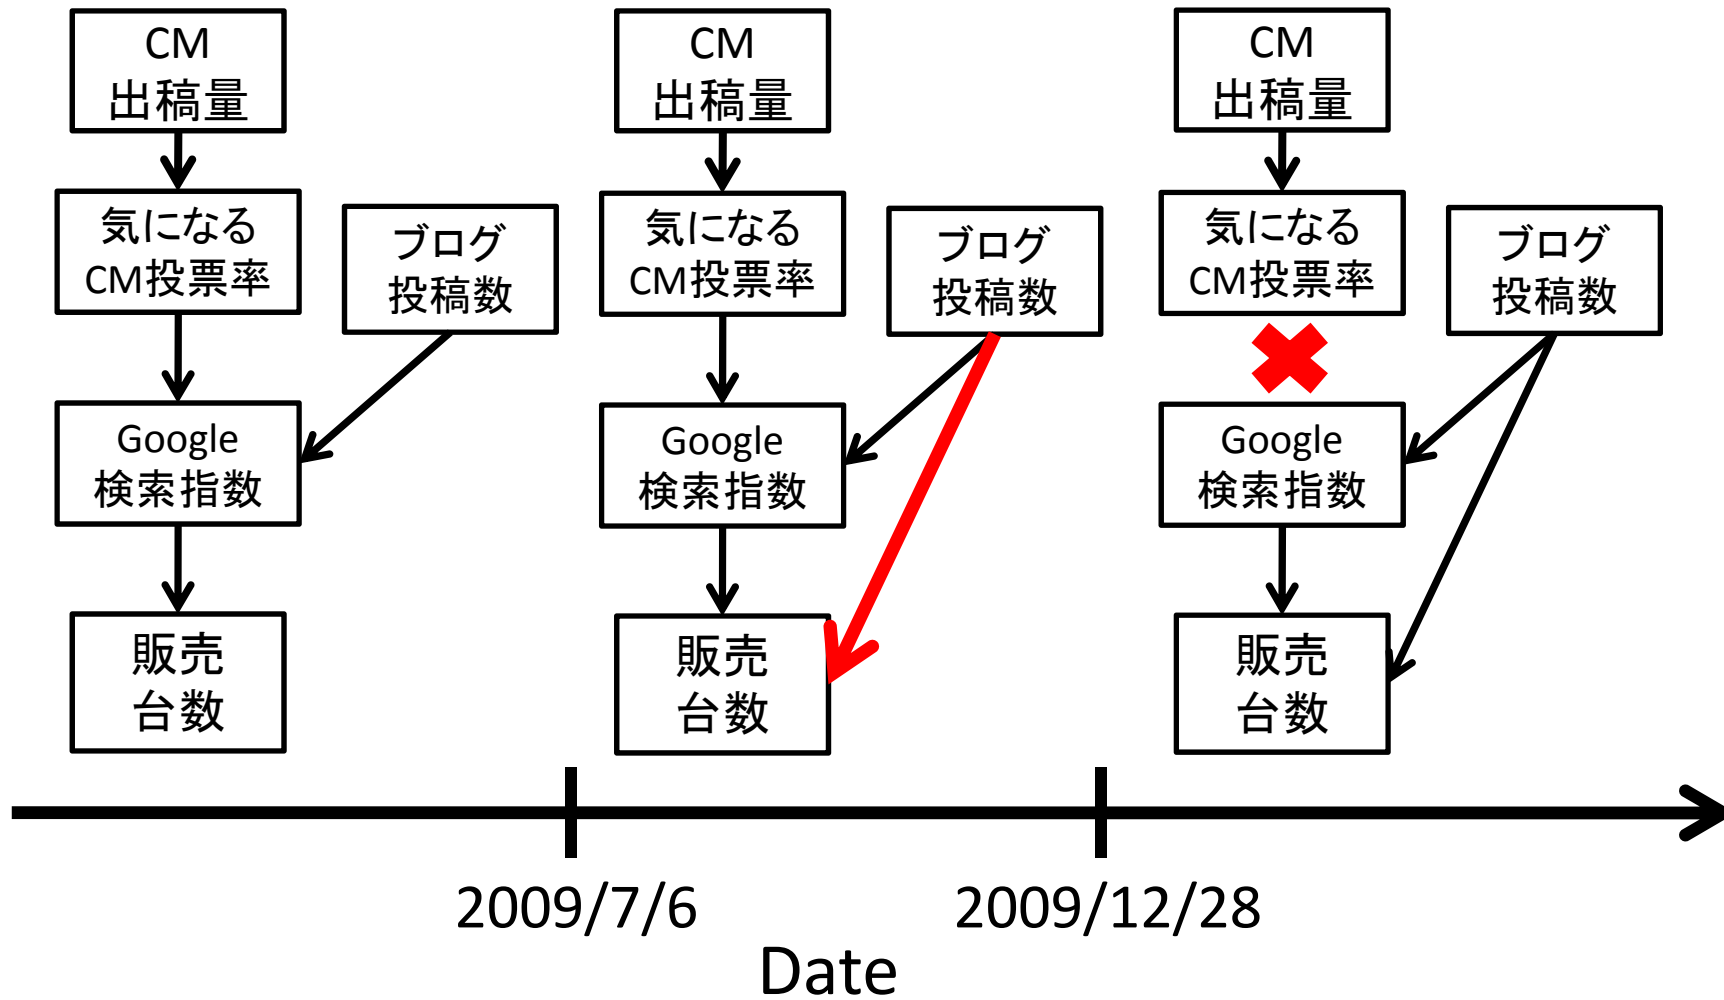
DMS (Dynamic Model Selection) 規準

$$\ell(x^n : k^n) = \sum_{t=1}^n -\log P(D^{(t)} | \hat{\theta}_{G_t}^{(t-1)}) + \sum_{t=1}^n -\log P(G_t | G_{t-1} : \hat{\alpha}^{(t-1)})$$

データの予測符号長

モデル系列の予測符号長

マーケティングデータに対する応用



まとめ

- ・非定常データからのネットワーク構造変化検出の問題設定について述べた
- ・過去に提案された手法について概説した
 - MCMCを用いた手法
 - 動的計画法を用いた手法
- ・それらをふまえたうえでの、現在の取り組みについて述べた
 - 動的モデル選択に基づく手法
 - マーケティングへの応用