

区間定常無記憶情報源 (PSMS) の 学習アルゴリズム

金澤 宏紀 山西 健司


東京大学大学院 情報理工学系研究科

研究の動機


- 非定常情報源の変化検出

時系列データ $x^n = x_1 \dots x_n$

情報源が時間変化 または
複数の情報源がスイッチする



cf.) 定常情報源




変化検出 { いつ変化したか (変化点検知)
どの程度変化したか (変化量検知)

をデータのみから行う

PSMS 学習 ~ パラメータ変化検出アルゴリズム

研究の応用先

- 例
 - 脳波の時系列データ
 - 非自明な変化点を探る



- 事故件数の時系列データ


1期	2期	3期	4期	5期	...
12	8	18	21	22	...

研究の応用先

- 例

- 脳波の時系列データ

- 非自明な変化点を探る



インターバルをモデリング
指数分布

$$f(x; \lambda) = \lambda e^{-\lambda x}$$

ガンマ分布

$$f(x; \alpha, \beta) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\beta x}$$

- 事故件数の時系列データ

1期	2期	3期	4期	5期	...
12	8	18	21	22	...

Poisson 分布

$$f(x; \lambda) = \frac{\lambda^x e^{-\lambda}}{x!}$$

✓ 状況の同定

✓ パラメトリックモデルの適切性を評価

モデル選択規準

- 記述長最小原理 (MDL principle) [Rissanen 1978]-

$$\operatorname{argmin}_{M \in \mathcal{M}} \mathcal{L}(x^n, M) = \operatorname{argmin}_{M \in \mathcal{M}} (\mathcal{L}(x^n | M) + \mathcal{L}(M))$$

- モデル M 下でのデータ列記述長 + モデル M の記述長を最小にするモデルを選ぶ
- 記述長: $\mathcal{L}(A) = -\log \Pr(A) \rightarrow$ 対数損失

- 動的モデル選択 (DMS) [Yamanishi and Maruyama 2005, 2007]


$$\operatorname{argmin}_{M^n \in \mathcal{M}^n} \mathcal{L}(x^n, M^n) = \operatorname{argmin}_{M^n \in \mathcal{M}^n} (\mathcal{L}(x^n | M^n) + \mathcal{L}(M^n))$$

↓

$$\sum_{t=1}^n \mathcal{L}(x_t | M_t) + \sum_{t=1}^n \mathcal{L}(M_t | M^{t-1})$$

- モデル列を逐次的に選ぶ
- モデル列に遷移確率が入る

分野全体の概観




問題設定

- 区間定常無記憶情報源 (PSMS)
 - $c, \theta(p) (p = 0, \dots, c)$ および $m(p)/n (p = 1, \dots, c)$ の組によって特徴づけられる非定常情報源の列

$$\mathcal{F} = \{f(x; \theta) : \theta \in \Theta\} \text{ for } x \in \mathcal{X}$$

データ列 $x^n = x_1 \dots x_n$ が以下の確率分布にしたがう

$$\begin{cases} x_t \sim f(x; \theta(0)) & (1 \leq t \leq m(1)), \\ x_t \sim f(x; \theta(1)) & (m(1) + 1 \leq t \leq m(2)), \\ \vdots & \\ x_t \sim f(x; \theta(c)) & (m(c) + 1 \leq t \leq n) \end{cases} \quad \begin{array}{l} \text{各 } x_t \text{ 独立} \\ c : \text{変化回数 (定数)} \end{array}$$



アルゴリズムの評価指標

- 期待冗長度の理論的な下限

定理 [Merhav 1993]

\mathcal{X} : 有限離散, 他いくつかの仮定をおく

ほとんどすべての PSMS に対し

$$\forall \varepsilon > 0, \exists n_0 \in \mathbb{N}, n \geq n_0 \Rightarrow$$

$$\inf_{\mathcal{A}} \mathcal{R}_{\mathcal{A}}^{(n)} \geq (1 - \varepsilon) \left(\frac{k(c+1)}{2} \log n + c \log n \right)$$

$\inf_{\mathcal{A}}$: すべての無歪符号化アルゴリズム

k : パラメータの次元

c : (真の)変化回数

cf.) 定常情報源の場合

$$\inf_{\mathcal{A}} \mathcal{R}_{\mathcal{A}}^{(n)} \geq (1 - \varepsilon) \frac{k}{2} \log n$$

[Rissanen 1984]

→ 理論下限によりアルゴリズムの性能を評価できる

手法 1


- 逐次推定法に基づく変化検出手法
 - 確率分布の逐次推定
 - 例：逐次 Bayes 推定

$$P_B(x | \emptyset) = f(x; \theta_0),$$

$$P_B(x | x_{t_1}^{t_2}) = \frac{\int p(\theta) f(x; \theta) \prod_{t=t_1}^{t_2} f(x_t; \theta) d\theta}{\int p(\theta) \prod_{t=t_1}^{t_2} f(x_t; \theta) d\theta}$$

- 関連研究
 - [Merhav 1993]
 - [Willems 1996], [Shamir and Merhav 1999]
 - 逐次 Bayes 推定 + リセット確率
 - 対象: 有限離散分布
 - [Sakurai and Yamanishi 2012]
 - SNML 推定 + リセット確率
 - 対象: 正規分布

手法 1: 概要




リセット確率付き逐次推定

$$P_{\mathcal{A}}(s_t | s_{t-1}) = \begin{cases} P_{\text{reset}}(t | s_{t-1}) & s_t = t \\ 1 - P_{\text{reset}}(t | s_{t-1}) & s_t = s_{t-1} \end{cases}$$

$$P_{\mathcal{A}}(x_t | s_t) = \begin{cases} P_{\text{update}}(x_t | \emptyset) & s_t = t \\ P_{\text{update}}(x_t | x_{s_t}^{t-1}) & s_t = s_{t-1} \end{cases}$$

手法 1: 概要



DMS を適用すると

$$-\log P_{\mathcal{A}}(x^n, s^n)$$

$$= \sum_{t=1}^n \left(-\log P_{\mathcal{A}}(x_t | s_t) \right) + \sum_{t=1}^n \left(-\log P_{\mathcal{A}}(s_t | s_{t-1}) \right)$$

→ minimize w.r.t. $s^n = s_1 \dots s_n$

手法 1: 性能

- 手法 1: リセット確率付き逐次推定 の期待冗長度

- リセット確率

- Willems 推定量

$$P_{\text{reset}}(t | s^{t-1}) = \frac{1/2}{t - s_{t-1}}$$

- Shamir and Merhav 推定量

$$P_{\text{reset}}(t | s^{t-1}) = \frac{\pi(t - s_{t-1})}{Z_{\infty} - Z_{s_{t-1}-1}} \quad \begin{cases} \pi(j) = 1/j^{1+\varepsilon} \\ Z_{\infty} = \sum_{j=1}^{\infty} \pi(j) \\ Z_t = \sum_{j=1}^t \pi(j) \end{cases}$$

- 逐次推定

- 逐次 Bayes 推定

- 事前分布に Jeffreys 分布を用いる

- 有限離散分布では簡単に求まる (Krichevsky and Trofimov 推定)

$$P_{\text{update}}(x = a | x_{t_1}^{t_2}) = \frac{N_a(x_{t_1}^{t_2}) + 1/2}{t_2 - t_1 + |\mathcal{X}|/2}$$

手法 1: 性能

- 手法 1: リセット確率付き逐次推定 の期待冗長度

- リセット確率

- Willems 推定量

$$P_{\text{reset}}(t | s^{t-1}) = \frac{1/2}{t - s_{t-1}}$$

- Shamir and Merhav 推定量

$$P_{\text{reset}}(t | s^{t-1}) = \frac{\pi(t - s_{t-1})}{Z_{\infty} - Z_{s_{t-1}}}$$

(理論上)
期待冗長度として最適

Merhav の下限に
(漸近的に)一致

- 逐次推定

- 逐次 Bayes 推定

- 事前分布に Jeffreys 分布を用いる


- 有限離散分布では簡単に求まる (Krichevsky and Trofimov 推定)

$$P_{\text{update}}(x = a | x_{t_1}^{t_2}) = \frac{N_a(x_{t_1}^{t_2}) + 1/2}{t_2 - t_1 + |\mathcal{X}|/2}$$

手法 2

- パラメータ空間離散化に基づく変化検出手法
 - パラメータ空間離散化


1次元パラメータ空間の離散化イメージ



- 離散化点数 K が過多でも過小でも期待冗長度を上げる
- 関連研究
 - [Kleinberg 2003]
 - テキストデータマイニングでの研究 (MDL 分野の研究ではない)
 - [Kanazawa and Yamanishi 2012], [金澤・山西 2012]

手法 2: 概要

- コンパクトなパラメータ空間を離散化
- 状態遷移図



- DMS を適用


$$\begin{aligned} & -\log P_{\mathcal{A}}(x^n | i^n) \\ &= \sum_{t=1}^n \left(-\log P_{\mathcal{A}}(x_t | i_t) \right) + \sum_{t=1}^n \left(-\log P_{\mathcal{A}}(i_t | i_{t-1}) \right) \\ &= \sum_{t=1}^n \left(-\log f(x_t; \bar{\theta}_{i_t}) \right) + \sum_{t=1}^n \left(-\log P_{\mathcal{A}}(i_t | i_{t-1}) \right) \\ &\rightarrow \text{minimize w.r.t. } i^n = i_1 \dots i_n \end{aligned}$$

手法 2: 詳細と議論

- 遷移確率の設定
 - 一様遷移確率を入れると計算時間を削減できる

$$P_A(i_t | i_{t-1}) = \begin{cases} \alpha / (K - 1) & i_t \neq i_{t-1} \\ 1 - \alpha & i_t = i_{t-1} \end{cases}$$

$$\alpha = 1/n$$



手法 2: 詳細と議論

- 離散化について

- 1次元では Fisher 情報量を用いて

$$\hookrightarrow I(\theta) = \mathbb{E}[-\partial^2 \log f(x; \theta) / \partial \theta^2]$$

$$\text{離散化幅 } \delta_I = \int_{\theta_{\min}}^{\theta_{\max}} \sqrt{I(\theta)} d\theta / (K - 1)$$

$$\text{離散化点 } \bar{\theta}_i : \int_{\theta_{\min}}^{\bar{\theta}_i} \sqrt{I(\theta)} d\theta = (i - 1) \delta_I \quad (i = 1, \dots, K)$$

とし, $K = O(\sqrt{n})$ とすると最適な離散化

→ 期待冗長度を抑える

- 多次元パラメータ空間に対しては難しい

- 直交しているパラメータを取ることができるか否か
 - 直交パラメータであれば上の離散化法の直積をとった離散化が可能
 - 2次元指数型分布族ならば e-, m- 接続のトリックが使える

手法 2: 詳細と議論

- 手法 2 の期待冗長度評価
⇔ 離散化手法の最適性

$$\mathcal{R}_A^{(n)} = \mathbb{E} \left[\sum_{t=1}^n (-\log f(x_t; \bar{\theta}_{i_t})) + \sum_{t=1}^n (-\log P_A(i_t | i^{t-1})) \right. \\ \left. - \sum_{p=0}^c \sum_{t=m(p)+1}^{m(p+1)} (-\log f(x_t; \theta(p))) \right]$$


$$\begin{aligned} \xrightarrow{\text{上限}} & \sum_{p=0}^c \sum_{t=m(p)+1}^{m(p+1)} \frac{\mathbb{E}_{\theta(p)} [-\log f(x_t; \bar{\theta}_{i_t}) - (-\log f(x_t; \theta(p)))]}{=} D(\theta(p) \| \bar{\theta}_{i_t}) \\ & + \log K + c \log(K - 1) - c \log \alpha - (n - c) \log(1 - \alpha) \end{aligned}$$

ポイント

- Kullback—Leibler ダイバージェンスを小さくする離散化
- (準)最適な離散化点数 $K = O(\sqrt{n})$ (1次元)

手法 2: 詳細と議論

- 手法 2 の期待冗長度評価
 \Leftrightarrow 離散化手法の最適性



$$\begin{aligned} & \max_{\theta \in [\theta_{\min}, \theta_{\max}]} \min_{\bar{\theta}_i} D(\theta \| \bar{\theta}_i) \\ & \quad \swarrow \\ & \quad \frac{I(\theta)}{2} (\theta - \bar{\theta}_i)^2 + O(|\theta - \bar{\theta}_i|^3) \\ & \quad \& \sqrt{I(\theta)} |\theta - \bar{\theta}_i| < \delta_I \\ & < \frac{(\delta_I)^2}{2} + O((\delta_I)^3) \end{aligned}$$

真のパラメータから
 離散化点までの
 KL ダイバージェンスが
 一様に抑えられる
 \rightarrow 最適 K 点離散化

手法 2: 詳細と議論

- 手法 2 の期待冗長度評価

- 離散化手法 $\bar{\theta}_i$: $\int_{\theta_{\min}}^{\bar{\theta}_i} \sqrt{I(\theta)} d\theta = (i - 1)\delta_I$

- 離散化点数 $K = \lfloor \sqrt{n} \rfloor$

- 遷移パラメータ $\alpha = 1/n$

$$\Rightarrow \mathcal{R}_A^{(n)} < \frac{c+1}{2} \log n + c \log n + \frac{\left(\int_{\theta \in \Theta} \sqrt{I(\theta)} d\theta \right)^2}{2} + \log e + O(n^{-1/2})$$

→ Merhav の下限 (1 次元) に漸近的に一致

- 課題:

- 離散化点数 $K = O(\sqrt{n/c})$ が理想
- 遷移パラメータ $\alpha \approx c/n$

数値実験

- Bernoulli 分布 $\mathcal{F}_{\text{Ber}} = \{\theta^x (1 - \theta)^{1-x}\}$ for $x = 0, 1$


– $n = 500, 1000, 5000$ で実験

$$\theta = \begin{cases} 0.8 & (1 \leq t \leq 0.2n) \\ 0.2 & (0.2n + 1 \leq t \leq 0.6n) \\ 0.1 & (0.6n + 1 \leq t \leq 0.8n) \\ 0.4 & (0.8n + 1 \leq t \leq n) \end{cases}$$

– 各 n に対し 200 回のシミュレーション

- 手法 1-W: Jeffreys 事前分布 逐次 Bayes 推定 + Willems 推定量
- ~~手法 1-SM: Jeffreys 事前分布 逐次 Bayes 推定 + SM 推定量~~
- 手法 2-KY: 前ページの離散化手法・離散化点数・遷移パラメータ

– 記述長・FAR・benefit を見る



数値実験：結果

$n = 500$

	記述長	FAR	benefit
手法 1-W	275.7656	32.23 %	0.3210
手法 2-KY	😊 270.5700	😊 22.91 %	😊 0.3520

$n = 1000$

	記述長	FAR	benefit
手法 1-W	532.7412	27.87 %	0.4763
手法 2-KY	😊 525.8352	😊 16.51 %	😊 0.4848

$n = 5000$

	記述長	FAR	benefit
手法 1-W	2550.0200	39.11 %	0.7778
手法 2-KY	😊 2539.3914	😊 8.33 %	😊 0.7825

結論

- 問題設定：区間定常無記憶情報源 (PSMS)
- PSMS に対する変化検出手法の紹介
 - 手法 1: 逐次推定法 + リセット確率
 - 手法 2: パラメータ離散化 + 動的計画法
- 数値実験による比較
 - 手法 1 は FAR が多くなる
 - 変化直後の変化確率が大きいいため
 - その他は 手法 2-KY のほうが 手法 1-W に比べやや優れている

参考文献 (1/2)

- Clarke, B.S., and Barron, A.R. “Information-theoretic asymptotics of Bayes methods,” *IEEE Trans. Inform. Theory*, vol. 36, pp. 453-471, May 1990.
- Kanazawa, H., and Yamanishi, K., “An MDL-based change-detection algorithm with its applications to learning piecewise stationary memoryless sources,” *IEEE ITW2012*, Sept. 2012, pp. 562-566.
- Kleinberg, J. “Bursty and hierarchical structure in streams,” *D. M. K. D.*, vol. 7, pp. 373-397, Nov. 2003.
- Krichevsky and Trofimov “The performance of universal encoding,” *IEEE Trans. Inform. Theory*, vol. 27, pp. 199-207, Mar. 1981.
- Merhav, N. “On the minimum description length principle for sources with piecewise constant parameters,” *IEEE Trans. Inform. Theory*, vol. 39, pp. 1962-1967, Nov. 1993.
- Rissanen, J. “Universal coding, information, prediction, and estimation,” *IEEE Trans. Inform. Theory*, vol. 30, pp. 629-636, July 1984.
- Rissanen, J. *Information and complexity in statistical modeling*. Springer, New York, 2007.

参考文献 (2/2)

- Sakurai, E., and Yamanishi, K. “Comparison of dynamic model selection with infinite HMM for statistical model change detection,” *IEEE ITW2012*, Sept. 2012, pp. 302-306.
- Shamir, G.I., and Merhav, N. “Low complexity sequential lossless coding for piecewise stationary memoryless sources,” *IEEE Trans. Inform. Theory*, vol. 45, pp. 1498-1519, July 1999.
- Willems, F.M.J. “Coding for a binary independent piecewise-identically-distributed source,” *IEEE Trans. Inform. Theory*, vol. 42, pp. 2210-2217, Nov. 1996.
- Yamanishi, K., and Maruyama, Y. “Dynamic syslog mining for network failure monitoring,” *KDD2005*, Aug. 2005, pp. 499-508.
- Yamanishi, K., and Maruyama, Y. “Dynamic model selection with its applications to novelty detection,” *IEEE Trans. Inform. Theory*, vol. 53, pp. 2180-2189, June 2007.
- 金澤 宏紀, 山西 健司 “多次元パラメータを有する区間定常無記憶情報源に対しての MDL 原理に基づく変化検出アルゴリズム,” 第 9 回 IBISML 研究会, 2012 年 6 月.