

証拠に基づく政策立案のための 潜在プロファイル分析と数法則発見法を用いた 社会実情のモデル化と可視化

長瀬 永遠

富山県立大学 情報基盤工学講座

January 19, 2024

本研究の背景

現在、EBPM の推進に向けて様々な取り組みがなされている。一方、いくつか課題も挙げられており、その中にデータの更新頻度が低いということがある。

本研究の目的

- 既存のデータから最新のデータを予測する手法を提案する
- 上記の手法の結果を用いて後述のシステムを改善する

图 1: 先行研究

RF6.4 で求めたい多変量多項式

はじめに

進捗報告

先週までの内容

$$f(\mathbf{q}, \mathbf{x}; \Theta) = c_0 + \sum_{j=1}^J c_j m_j,$$

$$c_0 = \sum_{r=1}^R v_{0r} \sigma_r, \quad c_j = \sum_{r=1}^R v_{jr} \sigma_r \quad (1)$$

$$\sigma_r = \sigma \left(\sum_{k=1}^{K_1} \sum_{l=1}^{L_k} v_{rkl} q_{kl} \right), \quad m_j = \exp \left(\sum_{k=1}^{K_2} w_{jk} \ln x_k \right)$$

\mathbf{q} : 入力変数 (質的), \mathbf{x} : 入力変数 (量的),

$\Theta: \{\mathbf{v}_0, \mathbf{v}_j, \mathbf{v}_r, \mathbf{w}_j\}$

学習問題の定式化

$$f(\mathbf{x}; \theta) = w_0 + \sum_{j=1}^J w_j m_j, \quad m_j = \exp \left(\sum_{k=1}^K w_{jk} \ln x_k \right) \quad (2)$$

$$E(\mathbf{x}; \theta) = \frac{1}{2} \sum_{\mu=1}^N (f(\mathbf{x}^{\mu}; \theta) - y^{\mu})^2 \quad (3)$$

N : サンプル数

学習アルゴリズム

BPQ 法 (Back Propagation based on Quasi-Newton)

パーセプトロンの学習: BPQ 法

① θ_1 の初期化

- パターン 1: $w_0 = y$ の平均値, $w_j = 0$, $w_{jk} = (-1, 1)$ の一様乱数
- パターン 2: 全ての重みを $(-1, 1)$ の一様乱数

$H_1 = I$, $s = 1$ とする

- I は単位行列 (対角成分が全て 1, その他が全て 0 の行列)

② $\Delta \theta_s = -H_s \nabla E(x; \theta_s)$ を計算

停止条件を満たせば, 反復を終了.

- 停止条件: 勾配ベクトル $\nabla E(x; \theta_s)$ の全成分が 10^{-5} 未満 or 反復 20,000 回

($\nabla E(x; \theta_s)$ の計算方法)

$$\begin{aligned} \nabla E(x; \theta_s) &= \frac{\partial E}{\partial \theta} = \sum_{j=1}^N (f^* - y^*) \frac{\partial f^*}{\partial \theta} \\ &= \sum_{j=1}^N (f^* - y^*) (1, \{m_j\}, \{w_j m_j \ln x_k\}) \end{aligned}$$

// check 1: ベクトル偏微分の解釈

$$m_j = \exp\left(\sum_{k=1}^K w_{jk} \ln x_k\right)$$

次の $N^2 - N$

③ $E(x; \theta_s) + \alpha_s \Delta \theta_s$ を最小にする α_s を求める

(用いる表記の解説)

- $E(x; \theta)$ は E , $f(x; \theta)$ は f と表記
- $E(x; \theta + \alpha \Delta \theta)$ は $g(\alpha)$ と表記

(α_s の求め方)

$g(\alpha) \approx g(0) + g'(0)\alpha + \frac{1}{2}g''(0)\alpha^2$ を最小化する α を求める.

$$- g(0) = E$$

check 2: $g(0)$ の解釈

$$- g'(0) = \sum_{j=1}^J (f^{\mu} - y^{\mu}) f^{\mu}$$

check 3: $\Delta w_j, \Delta w_{jk}$ の解釈

$$- f^{\mu} = \Delta w_0 + \sum_{j=1}^J (\Delta w_j m_j^{\mu} + w_j m_j^{\mu})$$

check 4: 計算のコツ・ポイント

$$- m_j^{\mu} = m_j^{\mu} \sum_{k=1}^K \Delta w_{jk} \ln x_k^{\mu}$$

$$- g''(0) = \sum_{j=1}^J ((f^{\mu})^2 + (f^{\mu} - y^{\mu}) f^{\mu})$$

$$- f^{\mu} = \sum_{j=1}^J (2\Delta w_j m_j^{\mu} + w_j m_j^{\mu})$$

$$- m_j^{\mu} = m_j^{\mu} \left(\sum_{k=1}^K \Delta w_{jk} \ln x_k^{\mu} \right)^2$$

ただし, $\Delta w_0, \Delta w_j, \Delta w_{jk}$ は ② で計算される $\Delta w_0, \Delta w_j, \Delta w_{jk}$ の変化量

はじめに

進捗報告

先週までの内容

① $g'(0) > 0$ のとき

check 5: ①の解釈(④の後、④の処理を行うか)

②の結果を $\Delta\theta = -\nabla E$, $H = I$ に置き換えて②-1, ②-2のどちらかへ進む

②-1 $g'(0) < 0$ か $g''(0) > 0$ のとき

$$\alpha = -\frac{g'(0)}{g''(0)}$$

②-2 $g'(0) < 0$ か $g''(0) \leq 0$ のとき

$$\alpha = -\frac{g'(0)}{\sum_{j=1}^M (f_j'')^2}$$

また, $\alpha > 0$ のとき, $S = M$ とし, $H = I$ とする.

パラメータ θ の次元: $(KJ + J + 1)$

次のページへ

進捗報告 6

9/20

③ $\|\alpha \Delta \theta\| > 1.0$ ならば

$\alpha = 1.0 / \|\Delta \theta\|$ とする

また, $S = M$ とし, $H = I$ とする

④ $g(\alpha) \geq g(0)$ ならば

$\alpha = - \frac{g'(0) \tilde{\alpha}^2}{2(g(\tilde{\alpha}) - g(0) - g'(0) \tilde{\alpha})}$, ただし $\tilde{\alpha}$ は ③ で得られた α の値

* $g(\alpha) < g(0)$ になるまで ④ を繰り返す。

④ $\theta_{s+1} = \theta_s + \alpha_s \Delta \theta_s$ に修正する。

⑤ $S \equiv 0 \pmod{M = KJ + J + 1}$ ならば $H_{s+1} = I$ とし,

それ以外の場合, BFGS 公式を用いて H_{s+1} を更新する。

$S \leftarrow S + 1$ とし ② に戻る。

(BFGS 公式)

$$H_{s+1} = H_s + \left(1 + \frac{g^T H_s g}{p^T g}\right) \frac{p p^T}{p^T g} - \frac{p g^T H_s + H_s g p^T}{p^T g},$$

check 6: λ_s の解釈

$p = \lambda_s \Delta \theta_s$, $g = \nabla E(x; \theta_{s+1}) - \nabla E(x; \theta_s)$

$\begin{bmatrix} \\ \alpha_s \end{bmatrix}$

はじめに

進捗報告

先週までの内容

最適中間ユニット数 J の決定

このモデルの場合、最適中間ユニット数 J と多変数多項式の項数は同じになるので、BPQ 法での学習は事前に J を指定し、 $J = 1, 2, 3, \dots$ と変化させながら行う。最適なモデルの選択（項数の選択）は各 J の値において以下の BIC（ベイズ情報量基準）を算出し、その値が最も小さいものを選択する。

モデル選択：BIC

J の値を $1, 2, \dots$ と変化させ、以下の $BIC(J)$ が最小となる J を最適なモデルに選択する。

$$BIC(J) = \frac{N}{2} \log \left(\frac{1}{N} \sum_{i=1}^N (f(x_i; \hat{\theta}_J) - y_i)^2 \right) + \frac{M}{2} \log N$$

ただし、 N : 総サンプル数、 M : 総パラメータ数、
 $\hat{\theta}_J$: 各 J における BPQ 法の結果

やること

- 1 コードのデバッグ
- 2 数値実験
- 3 卒論時システムと合わせる
- 4 本論執筆