

データ生成過程の学習：因果推論・特徴選択へのアプローチ

構造方程式モデルによるデータ生成過程の学習 - 特に非ガウス性の利用

清水昌平 (大阪大学)

Abstract


- 構造方程式モデルはデータ生成過程のモデル
 - 反実仮想 + 構造方程式モデル → 因果分析
- データ生成過程が未知の時に、
構造方程式モデルを学習する方法を概観する
(連続変数の場合)
- まずは、基本となる線形モデル
- 最後、非線形の方法にも触れる

イントロ (1/2)

- データ行列 X が次の**どちらかの**データ生成過程からランダムに生成されたとしよう ($b_{21}, b_{12} \neq 0$):

モデル 1:


$$x_1 = e_1$$

$$x_2 = b_{21}x_1 + e_2$$


or

モデル 2:

$$x_1 = b_{12}x_2 + e_1$$

$$x_2 = e_2$$


ここで e_1 と e_2 は**独立な潜在変数** (外的影響, かく乱項、誤差)

- データ行列 X のみを用いて、データ X を**生成したのがモデル1なのかモデル2なのか**を同定したい

イントロ (2/2)

- 「同定はできない」と長らく思われていた
- 実は、「ほとんどの場合に同定可能」ということが最近分かってきた (Shimizu et al., 2006)
 - e1とe2がガウス分布に従うとダメ
- 非線形＋加法誤差でもポジティブな結果 (Hoyer et al., 2009; Zhang & Hyvarinen, 2009)

モデル 3:

$$x_1 = e_1$$

$$x_2 = f_2(x_1) + e_2$$

or

モデル 4:

$$x_1 = f(x_2) + e_1$$

$$x_2 = e_2$$


因果効果: モデル1が正しいとき


(cf. Pearl, 2000)

- x_1 を定数 c から d へ変化させたときの x_2 への因果効果
 = $E(x_2 \mid \text{母集団の全員の } x_1 \text{ を強制的に } d \text{ にする})$
 - $E(x_2 \mid \dots \text{ を強制的に } c \text{ にする})$
 = $E(b_{21} d + e_2) - E(b_{21} c + e_2)$
 = $b_{21}(d - c)$

モデル1:


$$x_1 = e_1$$

$$x_2 = b_{21}x_1 + e_2$$




モデル1':

$$x_1 = \underline{d}$$

$$x_2 = b_{21} \underline{d} + e_2$$



因果効果: モデル2が正しいとき


(cf. Pearl, 2000)

- x_1 を定数 c から d へ変化させたときの x_2 への因果効果
 = $E(x_2 | \text{母集団の全員の } x_1 \text{ を強制的に } d \text{ にする})$
 - $E(x_2 | \dots \text{ を強制的に } c \text{ にする})$
 = $E(e_2) - E(e_2)$
 = 0

モデル2:


$$x_1 = b_{12}x_2 + e_1$$

$$x_2 = e_2$$




モデル2':

$$x_1 = \underline{d}$$


$$x_2 = e_2$$


問題の定式化


Basic problem setup (1/3)

- 仮定: **連続な**観測変数 x_i のデータ生成過程が、グラフィカルには**非巡回有効グラフ (DAG)**である
 - ループがない

非巡回有向グラフの例
(DAG):



巡回有向グラフの例:



(□(四角)で囲まれているのは観測変数)

Basic problem setup (2/3)

- さらに、 x_i の線形関係を仮定すると
線形**非巡回**構造方程式モデル (Wright, 1921; Bollen, 1989):

$$x_i = \sum_{j: x_i \text{の親}} b_{ij} x_j + e_i \quad \text{or} \quad \mathbf{x} = \mathbf{B}\mathbf{x} + \mathbf{e}$$

- e_i は、モデル内で規定されない(外的)連続な**潜在**変数:
ここでは、**外的影響**と呼ぶ (かく乱変数、誤差変数).
- e_i は、非ゼロの分散を持ち、互いに**独立**

例

- 3変数の場合:


$$x_1 = 1.5x_3 + e_1$$

$$x_2 = -1.3x_1 + e_2$$

$$x_3 = e_3$$

$$\text{or } \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \underbrace{\begin{bmatrix} 0 & 0 & 1.5 \\ -1.3 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}}_{\mathbf{B}} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ e_3 \end{bmatrix}$$

- \mathbf{B} のゼロ/非ゼロパターンが、1つのDAGに対応する:




$b_{ij} = 0 \Rightarrow x_j$ から x_i に有向辺がない

$b_{ij} \neq 0 \Rightarrow x_j$ から x_i に有向辺がある

非巡回性の仮定

- **非巡回**の場合は、パス係数行列**B**を下三角にするような変数 x_i の**順序**が必ず存在する (Bollen, 1989).

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \underbrace{\begin{bmatrix} 0 & 0 & 1.5 \\ -1.3 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}}_{\mathbf{B}} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ e_3 \end{bmatrix} \quad \longrightarrow \quad \begin{bmatrix} x_3 \\ x_1 \\ x_2 \end{bmatrix} = \underbrace{\begin{bmatrix} 0 & 0 & 0 \\ 1.5 & 0 & 0 \\ 0 & -1.3 & 0 \end{bmatrix}}_{\mathbf{B}_{perm}} \begin{bmatrix} x_3 \\ x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} e_3 \\ e_1 \\ e_2 \end{bmatrix}$$




そんな**順序**は例えば:

$$x_3 < x_1 < x_2.$$


x_3 は、 x_1, x_2 の祖先でもよいが、逆はない。

外的影響の独立性の仮定

- 「未観測交絡変数がない」ことを意味する
(Spirtes et al. 2000)
 - 未観測交絡変数とは、2つ以上の観測変数の親であるような潜在変数:




- 未観測交絡変数があると、外的影響が**従属**



Basic problem setup (3/3): 線形構造方程式モデルの学習

- 仮定: データ行列 X は、モデルからランダムに生成される:

$$\mathbf{x} = \mathbf{B}\mathbf{x} + \mathbf{e}$$


The diagram illustrates the structural equation model $\mathbf{x} = \mathbf{B}\mathbf{x} + \mathbf{e}$. It shows two variables, x_1 and x_2 , each enclosed in a rectangular box. x_1 is positioned above x_2 . A downward-pointing arrow connects the box for x_1 to the box for x_2 , with the label b_{21} placed to the left of the arrow. To the right of the x_1 box is a box containing e_1 , with a horizontal arrow pointing from e_1 to x_1 . Similarly, to the right of the x_2 box is a box containing e_2 , with a horizontal arrow pointing from e_2 to x_2 .

- **Goal:** データ行列 X の情報のみを使って、パス係数行列 \mathbf{B} を推定する!
 - \mathbf{B} のゼロ/非ゼロパターンが、1つのDAGに対応する


推定原理

伝統的な推定原理: Causal Markov condition

- もしデータ生成過程が、(線形)非巡回構造方程式モデルなら、Causal Markov condition が成り立つ:
 - 各観測変数 x_i は、親で条件付けると非子孫と独立

(Pearl & Verma, 1991) :

$$p(\mathbf{x}) = \prod_{i=1}^p p(x_i \mid x_i \text{の親})$$



- ノンパラメトリックの場合でも使える原理だが、一意に同定できないモデルが多い


例

- 有向辺の向きが反対の2つのモデル:

モデル 1:

$$x_1 = e_1$$


$$x_2 = 0.8x_1 + e_2$$



モデル 2:

$$x_1 = 0.8x_2 + e_1$$

$$x_2 = e_2$$



$$E(e_1) = E(e_2) = 0, \text{var}(x_1) = \text{var}(x_2) = 1$$

- どちらのモデルでも、(条件付き)独立になる変数はない:

$$\text{cov}(x_1, x_2) = 0.8 \neq 0$$

- Causal Markov condition では、2つのモデルを区別できない

新しい推定原理: 外的影響の独立性

(Shimizu, Hyvarinen, Hoyer & Kerminen, JMLR, 2006)

- 「外的影響 e_i が独立である」ことを利用
 - 単に無相関ではなく
- 線形構造方程式モデル + 非ガウス性 (LINGAMモデル):

$$x_i = \sum_{j: x_j \text{ の親}} b_{ij} x_j + e_i \quad \text{or} \quad \mathbf{x} = \mathbf{B}\mathbf{x} + \mathbf{e}$$

- 外的影響 e_i は非ガウスかつ互いに独立
- モデル つまり \mathbf{B} を一意に同定できる

推定アルゴリズム


DirectLiNGAM アルゴリズム

(Shimizu et al., 2009; Sogawa et al., 2010; Inazumi et al., 2010)

- パス係数行列 B が下三角になるような変数 x_i の順序を推定する(非巡回にするような順序)

$$\mathbf{x}_{perm} = \underbrace{\begin{bmatrix} & & \mathbf{0} \\ & & \\ \mathbf{B}_{perm} & & \end{bmatrix}}_{\mathbf{B}_{perm}} \mathbf{x}_{perm} + \mathbf{e}_{perm}$$

A full DAG




- 必要なら、枝刈りは既存の方法(e.g., スパース正則化)が適用可能 (Zou, 2006; Hyvarinen et al. 2010)

Basic idea (1/2) :

外生変数は、正しい順序のトップに来れる

- 外生変数 x_j は、親のいない変数 (Bollen, 1989)
 - ここでは x_3
 - パス係数行列 B の対応する行の成分は全てゼロ
- 外生変数はパス係数行列 B を下三角にするような変数順序のトップに来れる

$$\begin{bmatrix} x_3 \\ x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 \\ 1.5 & 0 & 0 \\ 0 & -1.3 & 0 \end{bmatrix} \begin{bmatrix} x_3 \\ x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} e_3 \\ e_1 \\ e_2 \end{bmatrix}$$



Basic idea (2/2): 外生変数 x_3 の成分を取り除く

- 他の変数 x_i ($i=1,2$) を外生変数 x_3 に回帰して残差 $r_i^{(3)}$ ($i=1,2$) を計算する
 - 残差 $r_1^{(3)}$ と $r_2^{(3)}$ も、LINGAMモデルを形成する
 - 残差の順序は、元の観測変数の順序と同じ

$$\begin{bmatrix} x_3 \\ x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 \\ 1.5 & 0 & 0 \\ 0 & -1.3 & 0 \end{bmatrix} \begin{bmatrix} x_3 \\ x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} e_3 \\ e_1 \\ e_2 \end{bmatrix} \Rightarrow \begin{bmatrix} r_1^{(3)} \\ r_2^{(3)} \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ -1.3 & 0 \end{bmatrix} \begin{bmatrix} r_1^{(3)} \\ r_2^{(3)} \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \end{bmatrix}$$


$x_3 \rightarrow x_1 \rightarrow x_2$

$r_1^{(3)} \rightarrow r_2^{(3)}$

- 残差 $r_1^{(3)}$ が外生なので、 x_1 はトップから2番目に来れる

DirectLiNGAMの流れ

- 全ての変数が順序づけられるまで、繰り返し「外生」変数を見つける:
 1. 外生変数を見つける: x_3
 - x_3 を順序のトップに置く
 - 回帰して、 x_3 の成分を取り除く
 2. 外生的な残差を見つける: $r_1^{(3)}$
 - x_1 を順序のトップから2番目に置く
 - 回帰して、 $r_1^{(3)}$ の成分を取り除く
 3. x_2 を順序のトップから3番目に置いて、終了
推定された順序は $x_3 < x_1 < x_2$



外生変数の同定

- 外的影響が非ガウスの場合

• Lemma 1: x_j は その残差 $r_i^{(j)} = x_i - \frac{\text{cov}(x_i, x_j)}{\text{var}(x_j)} x_j$
の**どれとも**独立 (i は j 以外全部) $\Leftrightarrow x_j$ は外生変数

- 残差と最も独立な変数を見つけることによって、
外生変数を同定できる
 - 独立性の指標 (Bach & Jordan 2002 etc.)
 - ペアワイズに評価して和をとる

外生変数の同定 (2変数の場合)

i) $x_1 (= e_1)$ は外生変数

$$x_1 = e_1$$

$$x_2 = b_{21} x_1 + e_2 \quad (b_{21} \neq 0)$$



x_2 を x_1 に回帰して,

$$r_2^{(1)} = x_2 - \frac{\text{COV}(x_2, x_1)}{\text{var}(x_1)} x_1$$

$$= x_2 - b_{21} x_1$$

$$= e_2$$



x_1 と $r_2^{(1)}$ は独立

ii) x_1 は外生変数でない

$$x_1 = b_{12} x_2 + e_1 \quad (b_{12} \neq 0)$$

$$x_2 = e_2$$



x_2 を x_1 に回帰して,

$$r_2^{(1)} = x_2 - \frac{\text{COV}(x_2, x_1)}{\text{var}(x_1)} x_1$$

$$= \left\{ 1 - \frac{b_{12} \text{COV}(x_2, x_1)}{\text{var}(x_1)} \right\} x_2 - \frac{b_{12} \text{var}(x_2)}{\text{var}(x_1)} e_1$$



x_1 と $r_2^{(1)}$ は独立でない

Darmois-Skitovitch' theorem

(Darmois, 1953; Skitovitch, 1953)

Darmois-Skitovitch' theorem:

変数 x_1 と x_2 を次のように定義する:

$$x_1 = \sum_{j=1}^p a_{1j} e_j, \quad x_2 = \sum_{j=1}^p a_{2j} e_j$$

ここで e_j は独立な確率変数.

もし $a_{1i} a_{2i} \neq 0$ となるような非ガウスな e_i があれば、
 x_1 と x_2 は独立でない

ii) x_1 は外生変数でない

$$x_1 = b_{12} x_2 + 1 \cdot e_1 \quad (b_{12} \neq 0)$$

$$x_2 = e_2$$



x_2 を x_1 に回帰して,

$$r_2^{(1)} = x_2 - \frac{\text{cov}(x_2, x_1)}{\text{var}(x_1)} x_1$$

$$= \left\{ 1 - \frac{b_{12} \text{cov}(x_2, x_1)}{\text{var}(x_1)} \right\} x_2 - \frac{b_{12} \text{var}(x_2)}{\text{var}(x_1)} e_1$$




x_1 と $r_2^{(1)}$ は独立でない

DirectLiNGAMの大事な性質

- DirectLiNGAM は次の2つを繰り返す:
 - 単回帰
 - 各変数と残差の独立性評価
- Algorithmic parameters がない
 - ステップサイズ、初期値、収束基準
- データがモデルに**厳密に**従っていれば、
変数の数と同じステップ数で
正しい解に収束することを保証できる
(収束はいつもする)

Causal Markov condition との関係は？

- 次の2つの性質は同値:
(Zhang & Hyvarinen, ECML09; Hyvarinen et al., JMLR, 2010)
 1. 外的影響 e_i が互いに**独立**
 2. **Causal Markov condition** が成り立つ
+ 各変数 x_i の親と外的影響 e_i が**独立**



非線形の場合

非線形＋加法の外的影響

- 「非線形＋加法の外的影響」のモデル:
 - DAG; 未観測交絡変数なし
 - 1. $x_i = f_i(x_i \text{ の親}) + e_i$ -- Hoyer et al. (NIPS08)
 - 2. $x_i = f_{i,2}^{-1}(f_{i,1}(x_i \text{ の親}) + e_i)$ -- Zhang et al. (UAI09)
-
- 「外的影響の独立性」の推定原理が**使える**
 - **2変数の場合**、いくつかの非線形性と外的影響の分布の組み合わせを除いて、**一意に同定可能**

ノンパラメトリック

- DAG + 未観測交絡変数なし:
PC algorithm (Spirtes & Glymour, 1991)

$$x_i = f_i(x_i \text{ の親}_i, e_i)$$

- 「外的影響の独立性」の推定原理は**使えない**
- 多くの場合、一意に同定できないが、関数形について事前知識がないのであれば、現状これ

おわりに

- データ生成過程が未知の時に、
構造方程式モデルを学習する方法を概観した
- 線形モデルとノンパラトリックモデル
の性質は結構わかってきている
 - その間: 非線形 + 加法の外的影響?
 - ナナメ?: 線形 + 各種拡張
 - 非巡回 → 巡回 (Lacerda et al., UAI2008)
 - 単一母集団 → 異質な母集団の混合 (Shimizu et al., ICONIP2007)
 - i.i.d. サンプルング → 時間構造 (Hyvarinen et al, JMLR, 2010)
 - 未観測交絡変数なし → あり (Hoyer et al., IJAR, 2008; Kawahara et al. 2010)