

因果推論

NRIデジタル株式会社
データサイエンティスト

2020年08月08日



ガイダンス

- 以下の講義内容で進めていきます。
- 質疑応答は、チャットなどでいつでも受け付けます。
 - 1コマ目：10時から11時半まで
 - ・ 統計分析の復習
 - 2コマ目：12時半から14時まで
 - ・ 相関と因果の考え方
 - ・ 効果量の測定方法
 - ・ DIDの考え方
 - 3コマ目：14時半から16時まで
 - ・ バイアスの除去方法
 - ・ 傾向スコアマッチング
 - ・ IPV法
 - ・ 効果量の測定方法
 - 4コマ目：16時半から18時まで
 - ・ 検証実験の設計
 - ・ 検出力解析
 - ・ 効果検証データの解析
 - ・ 検証結果の妥当性

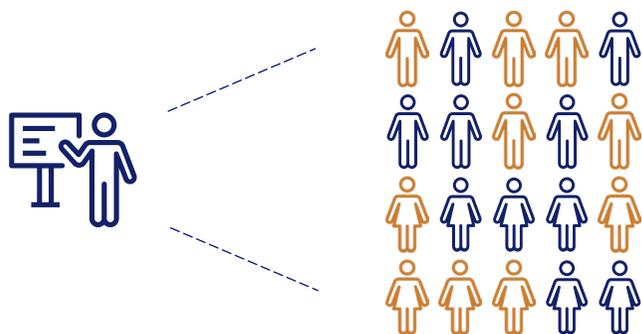
選択バイアスの存在と補正方法

選択バイアス

- DIDのようなきちんと制御されたデータを扱うことはマーケティング等の現場ではほぼない
- 実際はさまざまな要因でデータにバイアスがのっている。
 - 集団からのランダムな抽出
 - ・ クーポンを渡せるお客さんは普段から来店しているお客さん
 - 2つの群へのランダムな割り当て
 - ・ クーポンは、普段からよく買ってくれているお客さんに渡す
 - 実験通りに従事してくれない被験者が一定割合いる。
 - ・ クーポンを配ってくれない店舗があった。
- これらはすべてではないが、いくつかの方法で除去できる。

選択バイアス

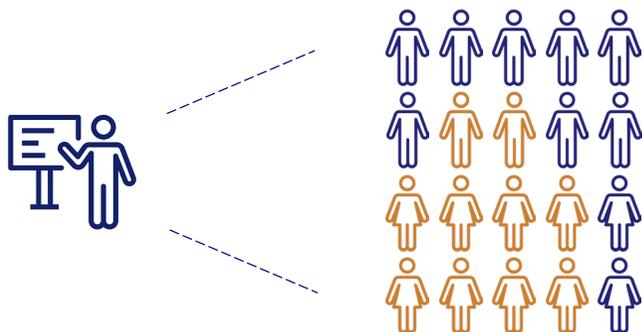
- データから一部を選び出すプロセスで、発生する偏り。
- 施策効果を推定したいというキャンペーンデータの分析で頻発。
 - 理想は、キャンペーン対象は無作為に選ばれてほしい...



単純な比較でOK

ただ、理論上の施策、こんなのない...

- もちろん、実際は**施策効果の大きそうな対象**を優先して行っている。（**選択バイアス**）

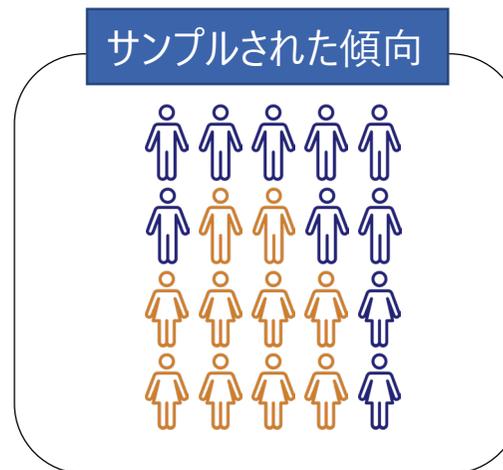
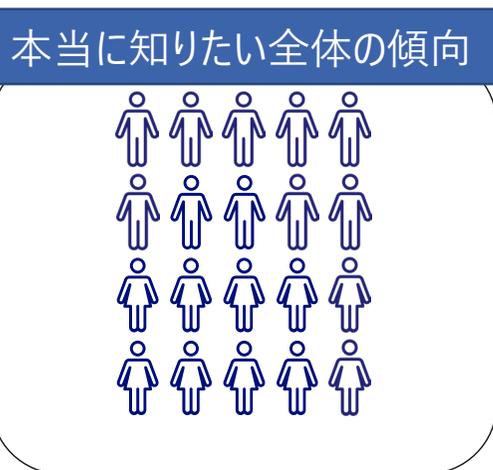


単純な比較だと、**施策効果を大きく見積もってしまう**

選択バイアスは技術的に取り除けることも多い。
除去できるバイアスであることを認識して現実的な施策を設計する。

選択バイアス

■ ポテンシャルアウトカムフレームワークによる選択バイアスの記述



選択バイアス

- ポテンシャルアウトカムフレームワークによる選択バイアスの記述を適当な例に沿って考える。
- クーポン施策により、顧客の購買行動を喚起できたかを売上によって計測する。
 - 来店傾向にある類似の属性を持つ顧客を対象にクーポンを渡すグループと渡さないグループを決めて配布した。
 - まずは、クーポンの有無を Z で表す。

$$Z = \begin{cases} 1 & \text{クーポン有り} \\ 0 & \text{クーポン無し} \end{cases}$$

- ある個人 Y_i のクーポン効果による売上の違い

$$Y_i = \begin{cases} Y_i^1 & Z_i = 1 \\ Y_i^0 & Z_i = 0 \end{cases}$$

- これは簡単に書くと

$$Y_i = Y_i^1 Z_i + Y_i^0 (1 - Z_i)$$

選択バイアス

- ポテンシャルアウトカムフレームワークによる選択バイアスの記述を適当な例に沿って考える。
- Y_i に関しては、クーポンの有無から、 Y_i^1 か Y_i^0 のどちらかの値しかとらないが、以下のように両元を表現する。

$$Y_i = Y_i^1 Z_i + Y_i^0 (1 - Z_i)$$

- 個人の潜在的（ポテンシャル）な状態を記述する方法
 - 発現した状態ではないほうをポテンシャルアウトカムという

簡単なデータで効果量の測定を行う。

- 次のような、施策の結果データのみ渡されるケースも多い。
- 前後比較デザイン、DID、中断時系列などは利用できず、2群比較を行わなければならない。

i	Y_i	Z_i
1	100	1
2	110	1
3	80	0
4	120	1
5	75	0
6	85	0

クーポン効果量 τ

$$\tau = \frac{100 + 110 + 120}{3} - \frac{80 + 75 + 85}{3} = 30$$

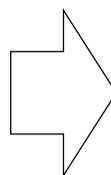
このデータの範囲ではただしうだけど、選択バイアスの懸念あり

簡単なデータで効果量の測定を行う。

- クーポンの効果量が10という（本当は手に入らないが）正解データがあったとき。
- もともと売上が高い人へクーポンを渡していた。
 - 割り当てが均等でない。RCTの要件を満たしていないにもかかわらず、その影響を考えずおかしな評価をしてしまう。

i	Y_i^0	Y_i^1	Z_i
1	90	100	1
2	100	110	1
3	80	90	0
4	110	120	1
5	75	85	0
6	85	95	0

効果量は10（正解）



i	Y_i	Z_i
1	100	1
2	110	1
3	80	0
4	120	1
5	75	0
6	85	0

効果量は30（計算）

簡単なデータで効果量の測定を行う。

- 選択バイアスには何が含まれているか。
- たとえば、効果量 τ の計算は

$$\tau = \frac{1}{\sum_i Z_i} \sum_i Y_i^1 Z_i - \frac{1}{\sum_i (1 - Z_i)} \sum_i Y_i^0 (1 - Z_i)$$

- ZとYに相関がでてしまうことで、「本当に知りたい全体の傾向」と「サンプルされた集団の傾向」が異なり、単純な平均ですらずれてしまっている。

i	Y_i^0	Y_i^1	Z_i
1	90	100	1
2	100	110	1
3	80	90	0
4	110	120	1
5	75	85	0
6	85	95	0

効果量は 1.0 (正解)

平均 \bar{Y}^0 \bar{Y}^1 差は 1.0

i	Y_i	Z_i
1	100	1
2	110	1
3	80	0
4	120	1
5	75	0
6	85	0

効果量は 3.0 (計算)

$$\bar{Y}^1|_{Z=1} = 110 \quad \bar{Y}^0|_{Z=0} = 80$$

簡単なデータで効果量の測定を行う。

- 選択バイアスが載ってしまう効果量。

$$\begin{aligned}\tau &= \bar{Y}^1_{|Z=1} - \bar{Y}^0_{|Z=0} \\ &= \bar{Y}^1_{|Z=1} - \bar{Y}^0_{|Z=0} + \bar{Y}^0_{|Z=1} - \bar{Y}^0_{|Z=1} \\ &= [\bar{Y}^1 - \bar{Y}^0]_{|Z=1} + \bar{Y}^0_{|Z=1} - \bar{Y}^0_{|Z=0} \\ &= \bar{Y}^1 - \bar{Y}^0 + \bar{Y}^0_{|Z=1} - \bar{Y}^0_{|Z=0}\end{aligned}$$

「ちゃんとした」効果量

選択バイアス分
20

- 式を読み込むと

- $\bar{Y}^0_{|Z=1}$: クーポンが**与えられた**グループにおけるクーポン使わなかったときの売上
- $\bar{Y}^0_{|Z=0}$: クーポンが**与えられなかった**グループにおけるクーポン使わなかったときの売上

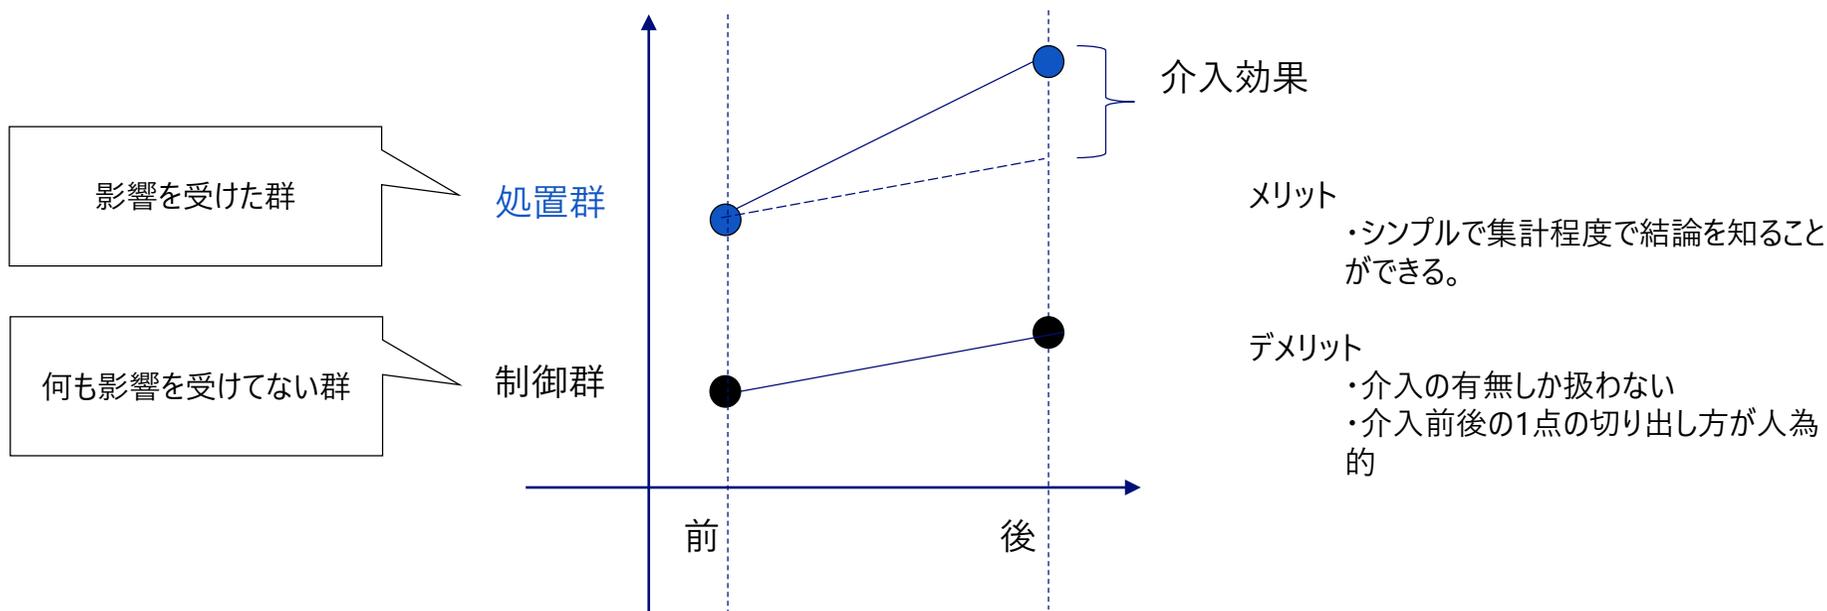
- つまり、2つのグループのベースの差 = 選択バイアス。

因果効果を測定する方法

- DIDだとベースの差を考慮できているので、おおまかな選択バイアスは除去できる。

講義 2 より

「差分の差分(DID法)」比較



群を表す2点とその介入前後を表す計4点から効果量を計算する。

選択バイアスのまとめ

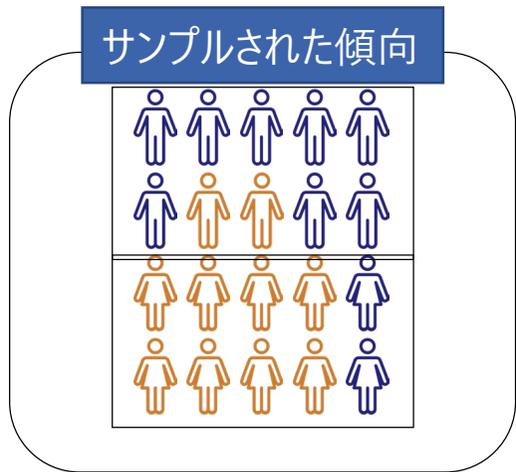
- ポテンシャルアウトカムフレームワークを利用して、選択バイアスを表現した。
- **2群への割り当てと選択バイアス**が密接にかかわるため、データ分析や実験設計のときには気を付ける
 - DIDのような選択バイアスを自然と落とせるようなフレームワークで分析フローを行う。
 - 実験におけるコスト等でどうしてもRCTにならないことがほとんどであり、次のバイアスを除く方法が必須。
- 選択バイアスの除去・補正方法はつぎの傾向スコアマッチングや逆確率重み付けで行う。
- ただし、このようなデータにあっては、情報がなさ過ぎて、補正やバイアス除去はできない
 - どのようなデータなら除去できるのかを頭に入れて、仮にバイアスが載ってしまっても、除去できるデータ・実験設計を行う。

i	Y_i	Z_i
1	100	1
2	110	1
3	80	0
4	120	1
5	75	0
6	85	0

傾向スコア分析

■ 傾向スコア分析の考え方

- 選択バイアスで偏った被験者群となっても、介入群・制御群で「似た人」を探し出して比較する。
- マッチング = 似た人を探し、比較すること。



クーポン対象者が女性に偏ってしまった場合

※対象者のデータは性別しかないとする。

このままの比較だと

クーポンを持っていない男性と

クーポンを持っている女性の比較になってしまう。

クーポンを持っている女性とクーポンを持っていない女性

クーポンを持っている男性とクーポンを持っていない男性



性別の偏りを排除
効果を推定

傾向スコア分析

- 一般の場合には属性がわかりやすく偏っているとはかぎらない。
 - データとしては各個人の属性情報が含まれている必要がある。
 - 先の例のように一つ一つ属性を調べていくことは大変。

i	Y_i	Z_i	性別	来店回数	購入単価	最頻購入商品
1	100	1	M	1	1000	冷凍食品
2	110	1	F	3	1200	冷凍食品
3	80	0	F	1	800	冷凍食品
4	120	1	F	1	500	飲料
5	75	0	F	5	2800	生鮮食品
6	85	0	M	6	1700	生鮮食品
7	80	0	M	10	1900	菓子
8	60	0	F	2	2000	生鮮食品
9	20	1	M	4	900	菓子
10	180	0	F	2	900	飲料
11	140	0	F	1	800	冷凍食品
12	100	1	M	4	800	飲料

傾向スコア分析

■ 傾向スコア

- 割り当て $Z = 1$ となる確率を、属性から回帰モデルで予測する。
- ロジスティック回帰を利用することが多いが、最近は機械学習モデルなども使われる。
- $logit(P(Z_i = 1)) = \beta_0 + \beta_1 \times \text{性別} + \beta_2 \times \text{来店回数} + \beta_3 \times \text{購入単価} + \beta_4 \times \text{最頻購入商品}$

i	Y_i	Z_i	性別	来店回数	購入単価	最頻購入商品
1	100	1	M	1	1000	冷凍食品
2	110	1	F	3	1200	冷凍食品
3	80	0	F	1	800	冷凍食品
4	120	1	F	1	500	飲料
5	75	0	F	5	2800	生鮮食品
6	85	0	M	6	1700	生鮮食品
7	80	0	M	10	1900	菓子
8	60	0	F	2	2000	生鮮食品
9	20	1	M	4	900	菓子
10	180	0	F	2	900	飲料
11	140	0	F	1	800	冷凍食品
12	100	1	M	4	800	飲料

傾向スコア分析

■ 傾向スコアによるマッチング

- 構築したロジスティックモデルの $P(Z_i = 1)$ となる確率が傾向スコア
- $\text{logit}(P(Z_i = 1)) = \beta_0 + \beta_1 \times \text{性別} + \beta_2 \times \text{来店回数} + \beta_3 \times \text{購入単価} + \beta_4 \times \text{最頻購入商品}$
- 介入群から一つ個体を取り、その傾向スコアが近い、制御群の個体と比較し効果量を計算。
- 傾向スコアは選択バイアスがないような個体同士の比較で効果量を測定する。

■ 傾向スコア (Propensity Score)を用いた逆確率重み付け法 (IPW)

- 傾向スコアのような割り当て確率を利用して推定する。

i	Y_i^0	Y_i^1	Z_i
1		110	1
2		120	1
3	80		0
4		130	1
5	75		0
6	85		0
7	80		0
8	60		0
9		30	1
10	180		0
11	140		0
12		110	1

傾向スコア： $Z = 1$ への割り当て確率

傾向スコア0.3の個体は、
 10体あれば7体は Y_i^0
 10体あれば3体は Y_i^1

傾向スコア0.7の個体は、
 10体あれば7体は Y_i^1
 10体あれば3体は Y_i^0

傾向スコアが大きい値の個体ほど Y_i^1 が観測されやすい
 →スコア e_i の逆数で重み付けすることで効果量を推定する。

$$\tau = \frac{1}{\sum_i Z_i / e_i} \sum_i Y_i^1 Z_i / e_i - \frac{1}{\sum_i (1 - Z_i) / (1 - e_i)} \sum_i Y_i^0 (1 - Z_i) / (1 - e_i)$$

(参考) 良い傾向スコアとは？

■ 傾向スコアは、説明性の高さからロジスティック回帰が使われる。

- $\text{logit}(P(Z_i = 1)) = \beta_0 + \beta_1 \times \text{性別} + \beta_2 \times \text{来店回数} + \beta_3 \times \text{購入単価} + \beta_4 \times \text{最頻購入商品}$

■ 本講義の先の説明では、傾向スコアの精度については細かく触れなかった。

- この割り当て確率の精度が悪いと、傾向スコアも逆確率加重法も悪い結果を生んでしまう。



割り当て確率をあてる

Z_i	性別	来店回数	購入単価	最頻購入商品
1	M	1	1000	冷凍食品
1	F	3	1200	冷凍食品
0	F	1	800	冷凍食品
1	F	1	500	飲料
0	F	5	2800	生鮮食品
0	M	6	1700	生鮮食品
0	M	10	1900	菓子
0	F	2	2000	生鮮食品
1	M	4	900	菓子
0	F	2	900	飲料
0	F	1	800	冷凍食品
1	M	4	800	飲料

属性データから割り当て確率を精度良くあてると
いう機械学習的なタスクも求められる。

以下のようなアルゴリズムも利用できる。

- tree – model
- xGboost
- LightGBM

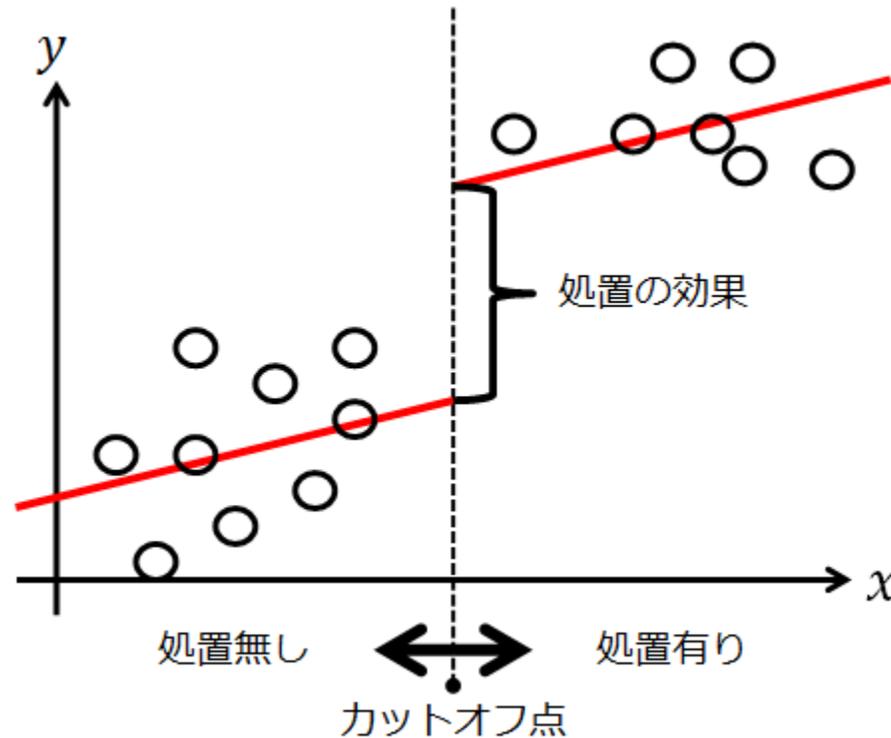
選択バイアスへの対処

- 選択バイアスの取り扱いを行った
- 2群への割り当てを起因として、選択バイアスが発生することから、割り当ての性質を見てバイアスを除去する。
 - 傾向スコアマッチング
 - ・ 割り当て確率が似る個体間を突き合わせて、バイアスを補正した効果量を見積もる
 - 逆確率重み付け
 - ・ 割り当て確率に応じて、出現率がかわることから、その逆数で補正してバイアスを補正した効果量を推定する。
- 2群間のデータを選択バイアスに注意しつつ効果量を推定した。

不連続回帰デザイン

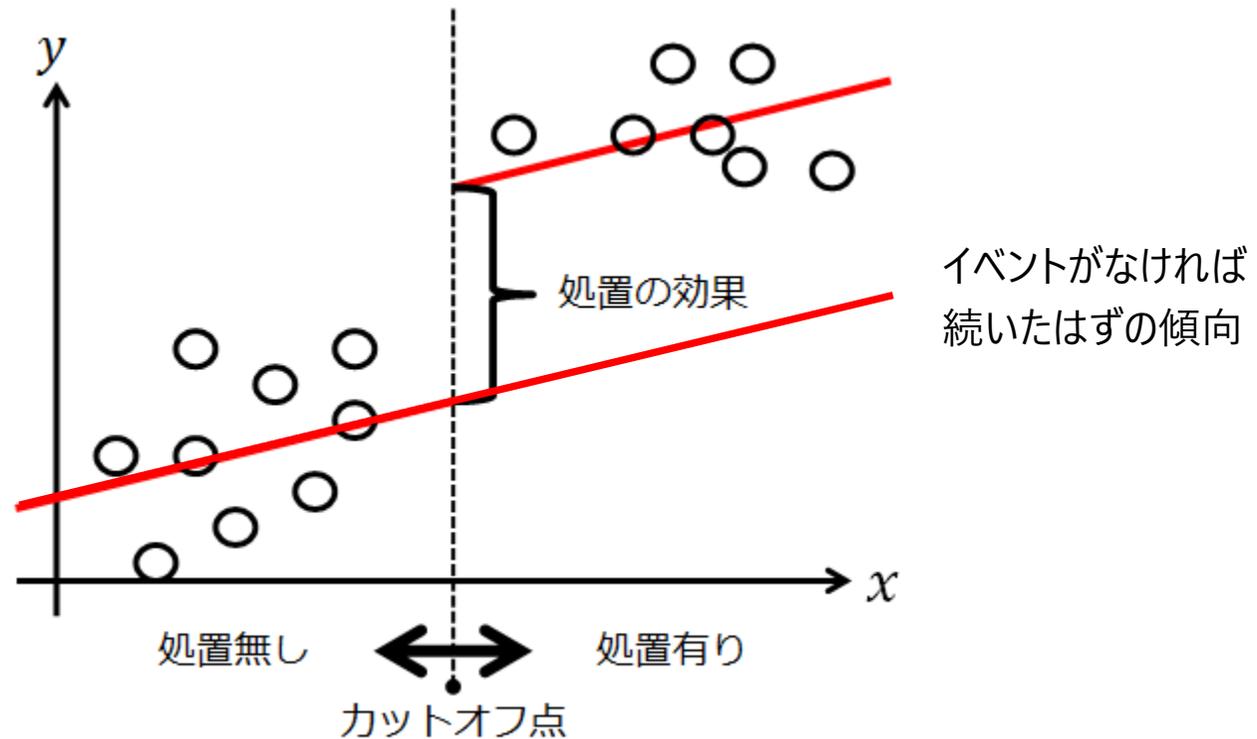
中断時系列デザイン

- ある時点、ある条件を境にイベントが起こるときの因果効果の推定方法。
- 群間比較ができずに集団全体に施した介入の効果を評価する目的でインパクトを推定する方法
 - 状況としては前後比較デザインに近い。
 - 消費税の導入（法律の改正）や大震災（大規模災害）など



中断時系列デザイン

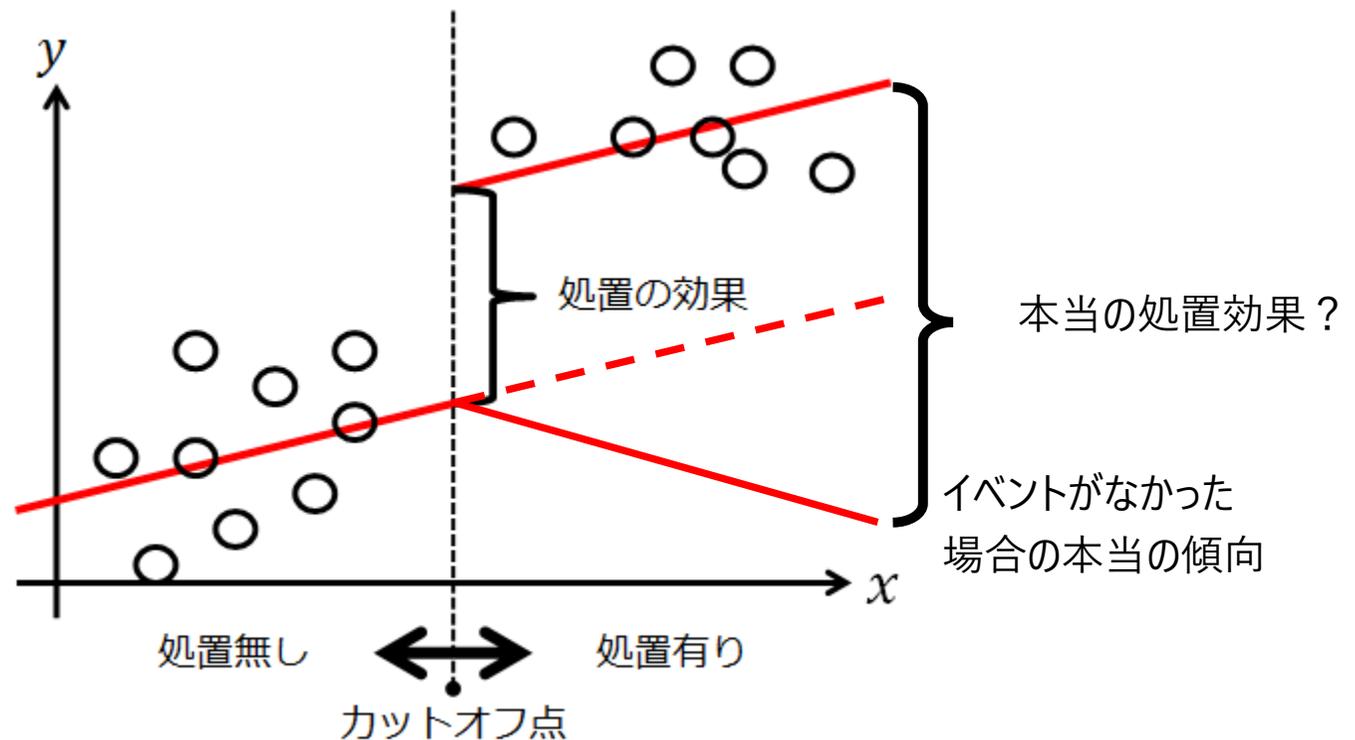
- イベント後の傾向を、イベントがなければ続いたはずの傾向と比較することで、効果を評価している。
- イベント点で不連続になる回帰モデルを構築する。
 - 本講義では単純な重回帰モデルを考えるが、自己回帰過程などを使うこともある。



中断時系列デザイン

- RCTで求められている制御群が設定できない。
 - イベントの影響を受けなかったグループとの比較ができないので、効果量には考察が必要。
- 緻密な時系列モデリングが重要となる場面も必要で、イベント前後の状況についての深い洞察が必要。
 - 季節のような周期変動があるかなど、イベント後の効果はイベントだけの効果を見ているかなど

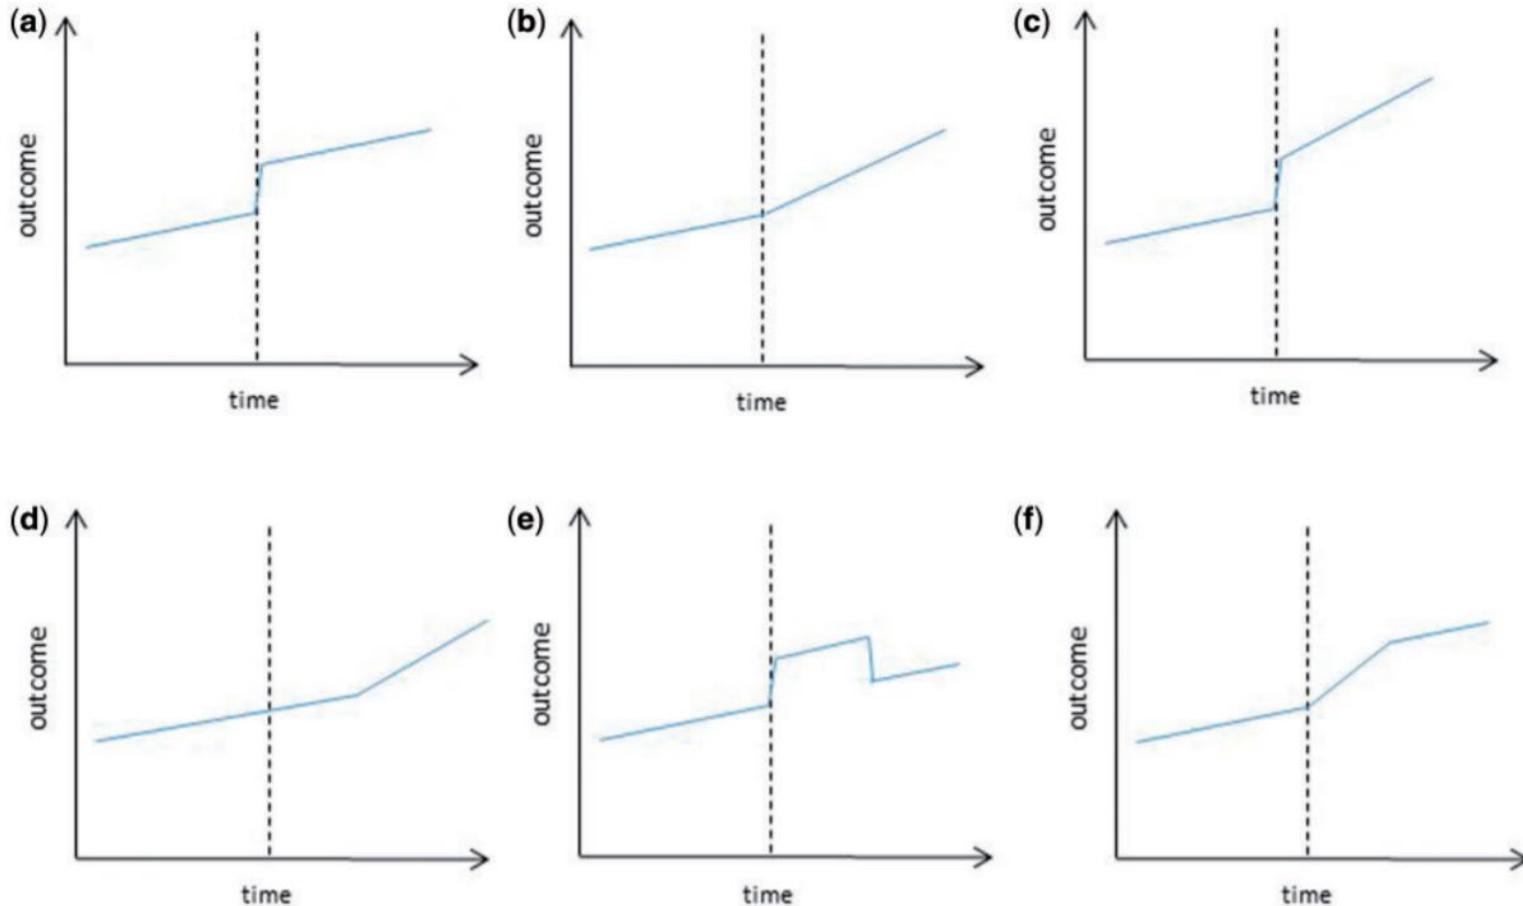
中断時系列デザインで起こりうる結果のミスリード



中断時系列デザイン

■ インパクトモデルの設定

- どのような効果があったかの表現形式を設定。実際には直線回帰以外のモデル設定も可能。



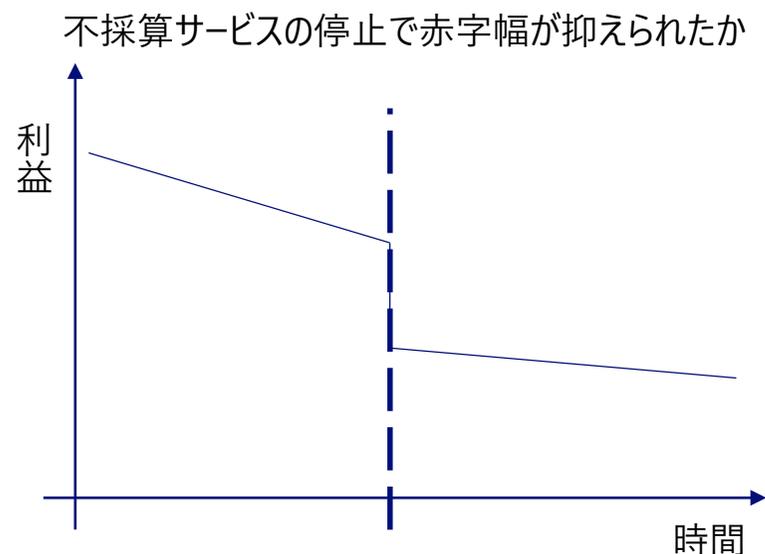
中断時系列デザイン

■ 実際の現場では、中断時系列で行う解析も少なくない。

- 顧客へのサービスの不均一を嫌う傾向
 - ・ 特定店舗、小規模に実験を行うことができない。
 - ・ 全店展開される施策等がある。
- 施策の実験に時間をかけてもらえない
 - ・ 緊急に施策をとらなければいけない。
- 実験設計にはコストがかかるため、いきなり全店展開される施策の分析等が中断時系列分析が必要となってくる。

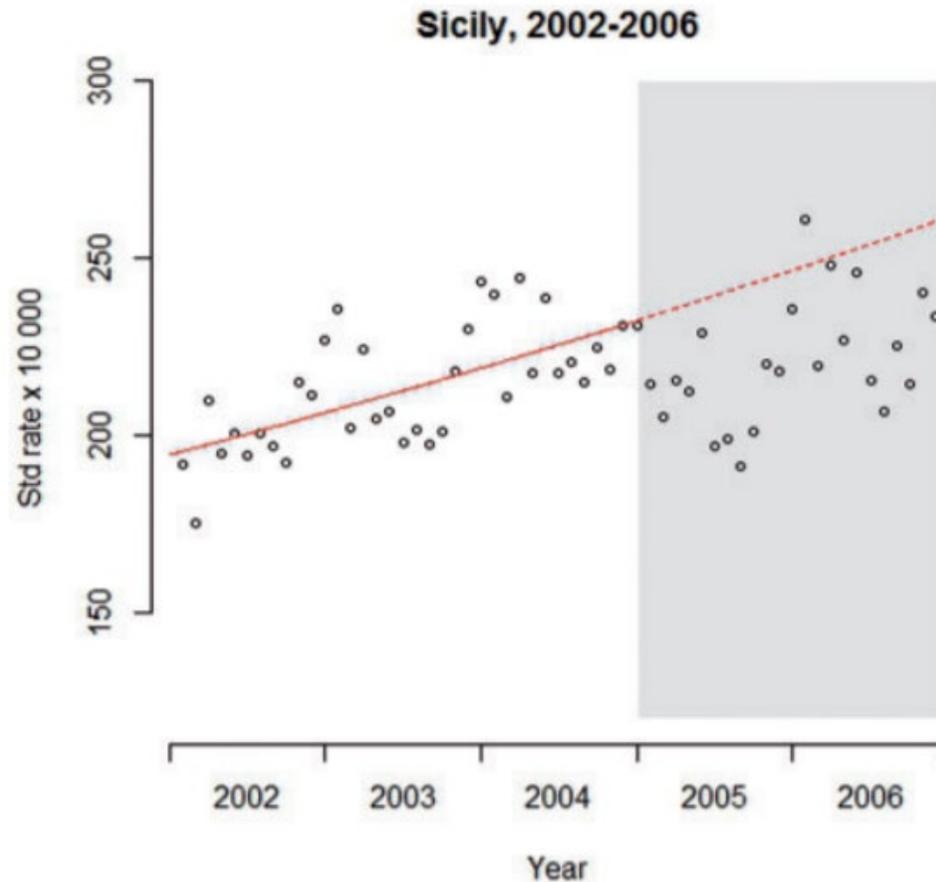
■ 中断時系列で扱えると考えられる事例

- 新規/既存サービスの開始/停止による事業への影響
 - ・ メール施策の開始
 - ・ アプリのリリース
 - ・ 開店・閉店
- 価格の改定
 - ・ 消費税効果
 - ・ レジ袋有料化
 - ・ コロナ影響



中断時系列デザイン

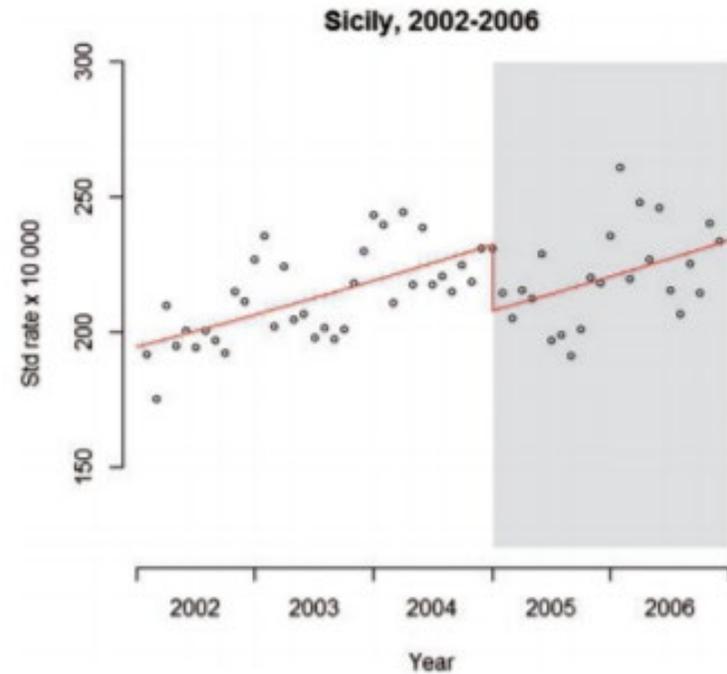
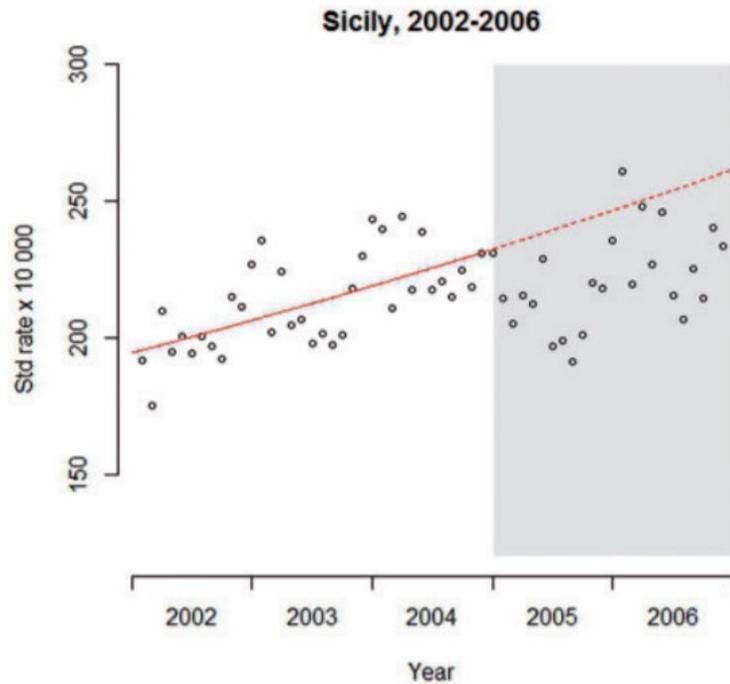
- 実際の問題設定
- 公共での喫煙禁止の法制定と、喫煙を危険因子とする急性冠症候群の罹患者の関係
 - James Lopez Bernal, 'Interrupted time series regression for the evaluation of public health interventions: a tutorial', International Journal of Epidemiology, 2017, 348–355



中断時系列デザイン

■ どのようなインパクトシナリオを設定するかは分析担当者次第

- 法制定と同時にギャップが発生し、傾きを変えたとしてインパクトを設定。



中断時系列デザイン

- データは月次。2005年1月から公衆禁煙法が有効となったので、フラグを変数として持たせる。

Table 1. Excerpt from the example dataset

Year	Month	Time elapsed (T)	Smoking ban ^a (X)	ACEs (Y)	Std popn
2004	1	25	0	914	381656.3
2004	2	26	0	808	383680
2004	3	27	0	937	383504.2
2004	4	28	0	840	386462.9
2004	5	29	0	916	383783.1
2004	6	30	0	828	380836.8
2004	7	31	0	845	383483
2004	8	32	0	818	380906.2
2004	9	33	0	860	382926.8
2004	10	34	0	839	384052.4
2004	11	35	0	887	384449.6
2004	12	36	0	886	383428.4
2005	1	37	1	831	388153.2
2005	2	38	1	796	388373.2
2005	3	39	1	833	386470.1
2005	4	40	1	820	386033.2
2005	5	41	1	877	383686.4
2005	6	42	1	758	385509.3
2005	7	43	1	767	385901.9
2005	8	44	1	738	386516.6
2005	9	45	1	781	388436.5
2005	10	46	1	843	383255.2
2005	11	47	1	850	390148.7
2005	12	48	1	908	385874.9

時間とフラグの交互作用項をもたせることで、回帰の分断性を表現

$$Y = \beta_0 + \beta_1 T + \beta_2 X + \beta_3 XT$$

T = 0 のとき、つまり法施行前は

$$Y = \beta_0 + \beta_2 X$$

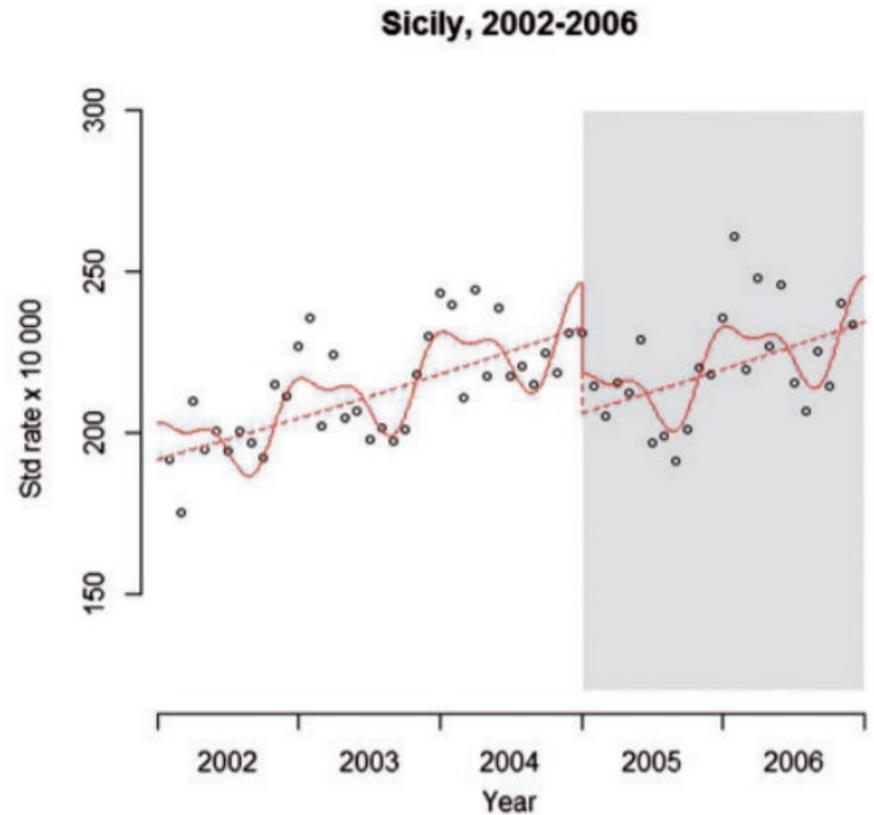
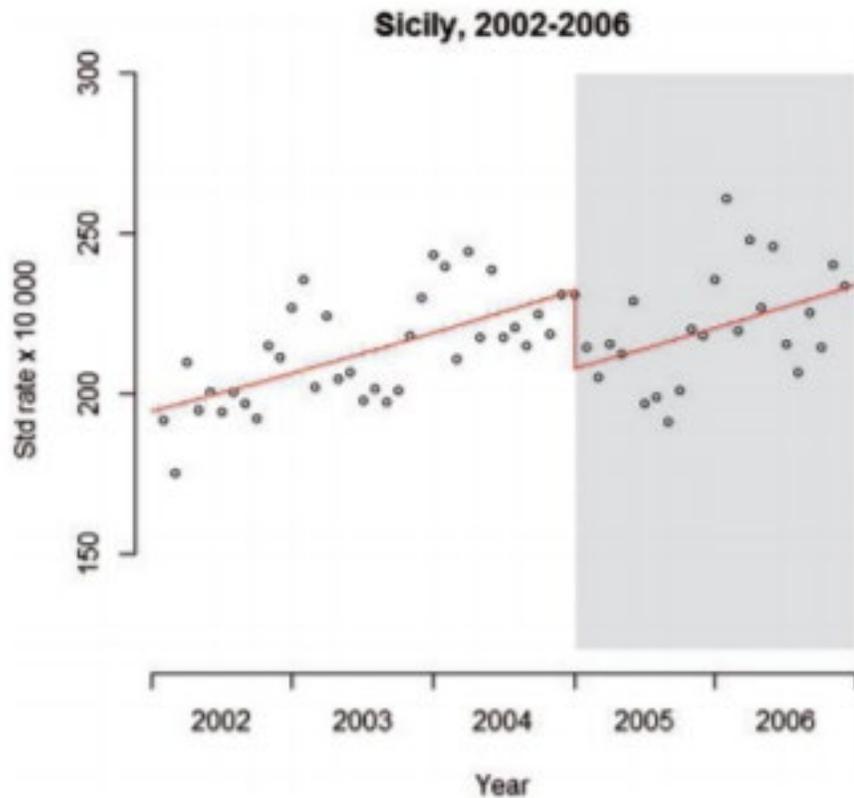
T = 1 のとき、つまり法施行後は

$$Y = \beta_0 + (\beta_2 + \beta_3) X$$

その他の重回帰のインパクトモデルも、フラグ変数を複数用意し交差項を用いることで表現できる。

中断時系列デザイン

- 季節性（周期性）を考慮する時系列モデル等を組み込んだ結果とも比較
 - 公衆禁煙法制定の効果はシフトをおこすだけだった...



回帰不連続デザイン

■ 中断時系列デザインの一般系である回帰不連続デザイン

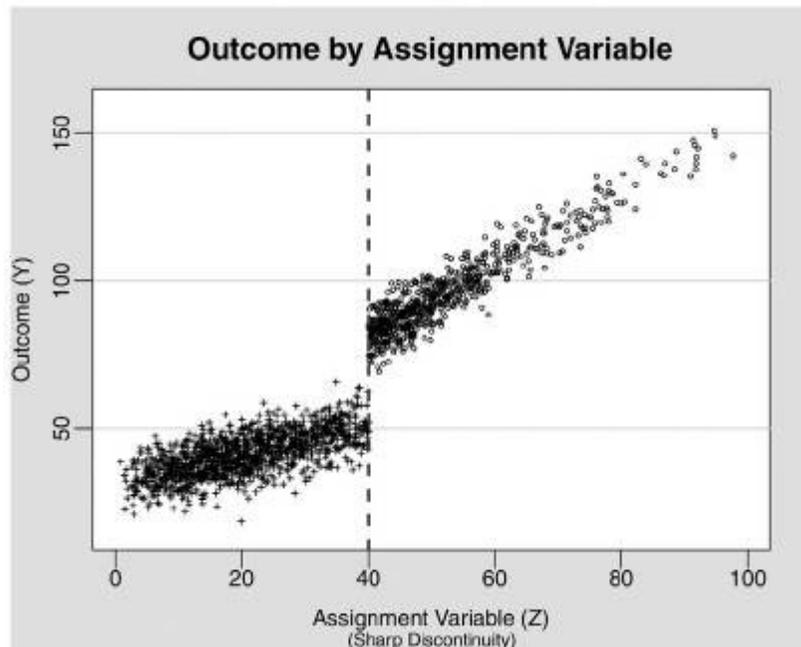
- 中断時系列デザイン：ある時間の前後でイベントが起きる
- 回帰不連続デザイン：ある属性値の前後でイベントが起きる
 - 年齢18歳以上での選挙権。選挙権の有無による政治報道への関心。
 - GPAが4.5以上で奨学金。奨学金の受領による成績の向上効果。

■ 中断時系列デザインとの違い

- ある個体の連続変数の値が特定の値よりも高いか低いかによってに割り付けられる
 - 制御群は18歳未満、介入群は18歳以上という割り当てのため。
 - **制御群には18歳以上がない、介入群には18歳未満はない**ため、傾向スコアなどのマッチングができない。

回帰不連続デザイン

- 時系列とはことなり、カットオフ近辺の個体の比較が重要。
 - カットオフ近辺から離れすぎたデータは、個体の属性も大きく違うと考えられるため。
- カットオフ近辺は、似たような個体が多く、イベントの効果のみが顕著に表れやすい。
- AssignmentVariable (カットオフに使われる変数Z)



カットオフに使われる変数

$$T = \begin{cases} 1 & Z > 40 \\ 0 & Z \leq 40 \end{cases}$$

カットオフフラグと交互作用項をもたせることで、回帰の分断性を表現

$$Y = \beta_0 + \beta_1 Z + \beta_2 T + \beta_3 ZT$$

反事実推定

反事実推定

- もし仮に介入がなかったら...という状態を推定する。
 - 合成コントロール法
 - 政策の効果等に利用する。
 - 不連続時系列

- 2010年のAbadie、2019年にはSyntheticDID法とよばれる時系列データへの因果分析方法を提唱。
 - Dmitry Arkhangelsky, Susan Athey, [David A. Hirshberg](#), Guido W. Imbens, [Stefan Wager](#), "Synthetic Difference In Differences", arXiv:1812.09970

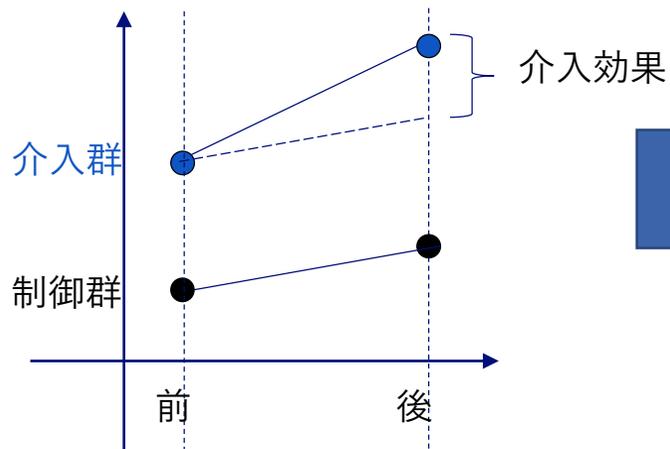
Synthetic Control法

- あるイベントの影響を大きくうけた時系列データに対して、イベントが起きなかった場合の仮想的な時系列を再現する手法。

⇒ イベントの影響の大きさの時間的変化が可視化される。

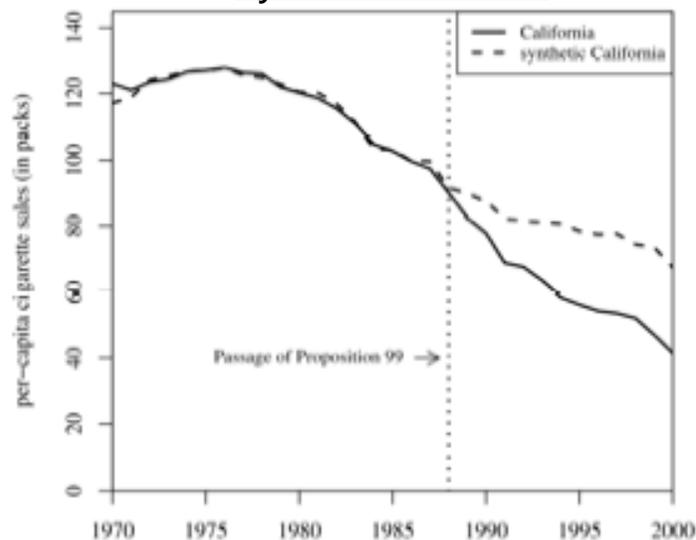
介入の前後での制御群、介入群の振る舞いを比較する方法

「差分の差分(DID法)」比較



群を表す2点とその介入前後を表す計4点から効果量を計算する。

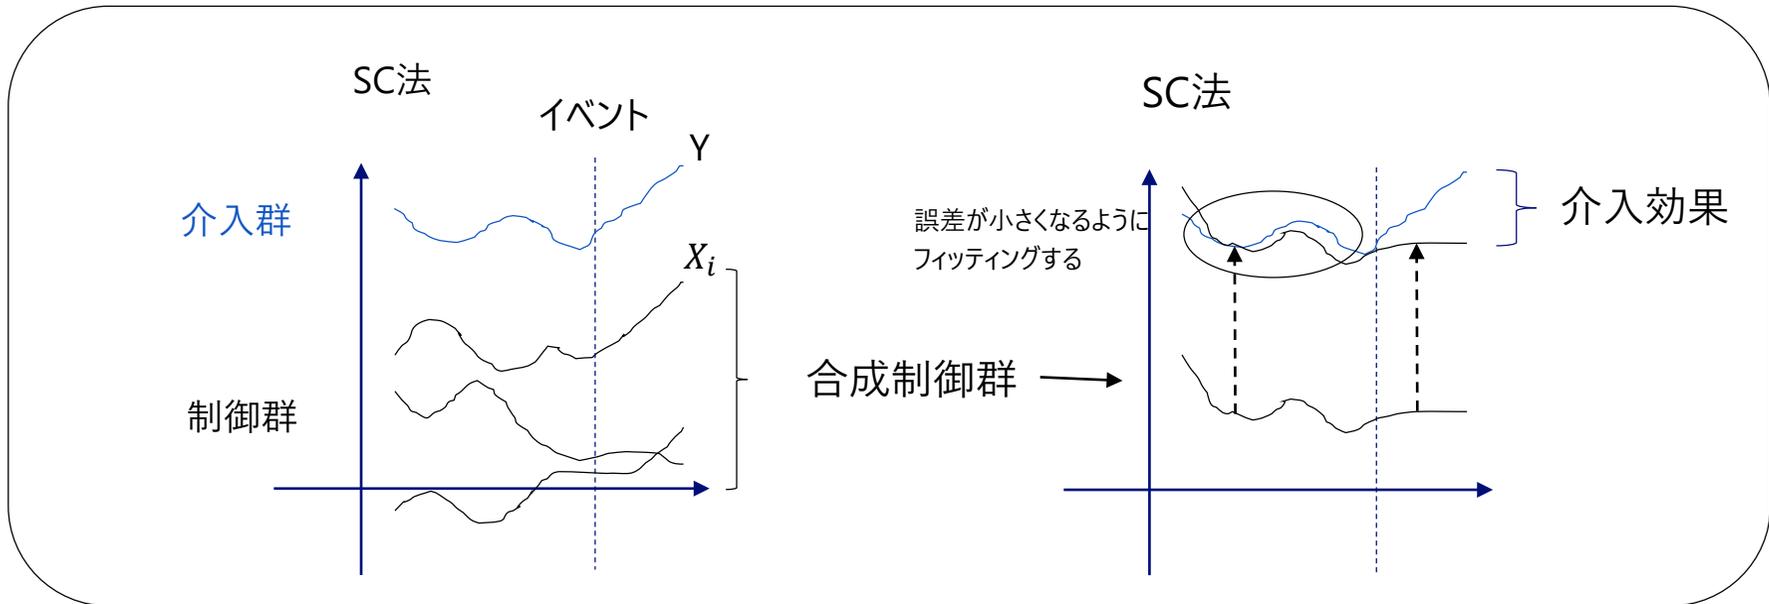
Synthetic Control



仮想的な非介入時の時系列を再現し、時系列で効果量を計算する。

Synthetic Control法の考え方。

- 同種のデータから、仮想的な制御群を構築する。
- 制御群の候補が定まらないときや、単純な平均効果では比較できないときに威力を発揮

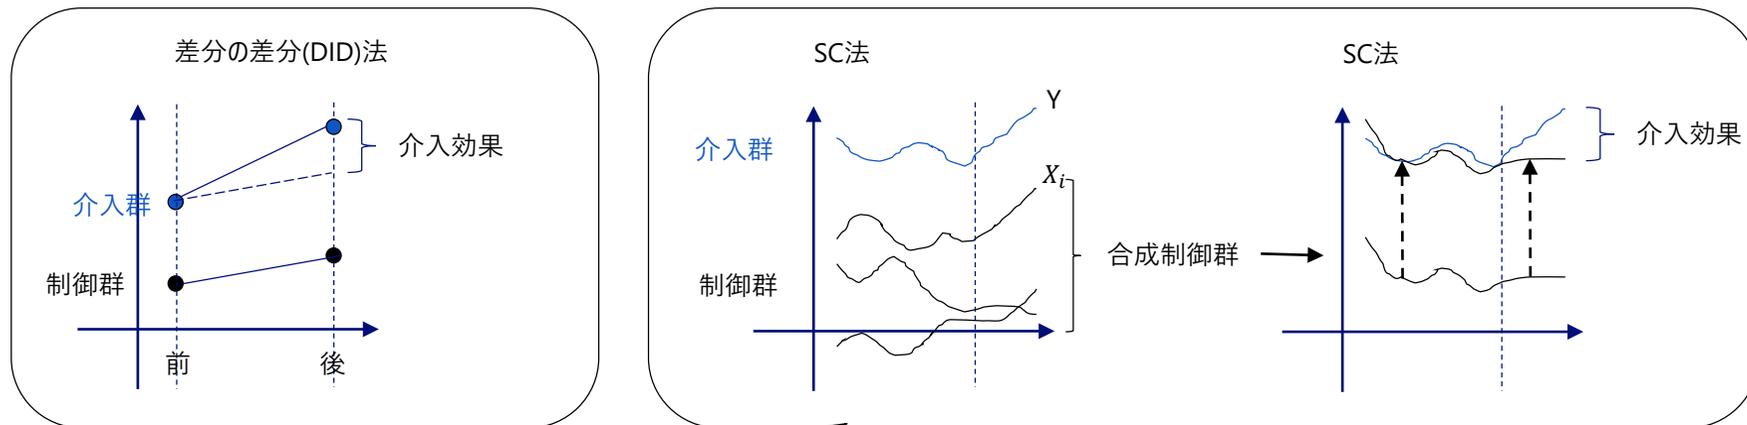


注目する時系列と類似の（影響を受けていないと考えられる）時系列を制御群とする。

1. イベント前の介入群時系列を再現するように、制御群の時系列を足し合わせてあてはめる
2. イベント後の制御群時系列のデータから、注目する時系列の仮にイベント効果を受けていなかったときの時系列を構成
3. 合成制御された時系列と介入群時系列の差が介入効果

DID法、SC法、SDID法の差異

- Synthetic Difference In Difference法(SDID)は、Synthetic Control法(SC)に介入前後の差を考慮したもの。



SC法の概要

制御群の時系列 X_i の合成で、介入群 Y の時系列を再現する。

$$Y_t \sim \sum_{i=1}^{N-1} \omega_i X_{it} \quad \text{for all } t = 1, \dots, T-1$$

制御群の合成時系列で、介入がなかったとしたときの Y の値を推定する。

$$Y_T^{SC}(0) = \frac{1}{T-1} \sum_{t=1}^{T-1} \sum_{i=1}^{N-1} \omega_i X_{it} + \underbrace{\left(\sum_{i=1}^{N-1} \omega_i X_{iT} - \frac{1}{T-1} \sum_{t=1}^{T-1} \sum_{i=1}^{N-1} \omega_i X_{it} \right)}_{\text{群間の差}}$$

SDID法の拡張部分の概要

時間方向の加重平均も考える。

$$X_{iT} \sim \sum_{t=1}^{T-1} \lambda_t X_{it} \quad \text{for all } i = 1, \dots, N-1$$

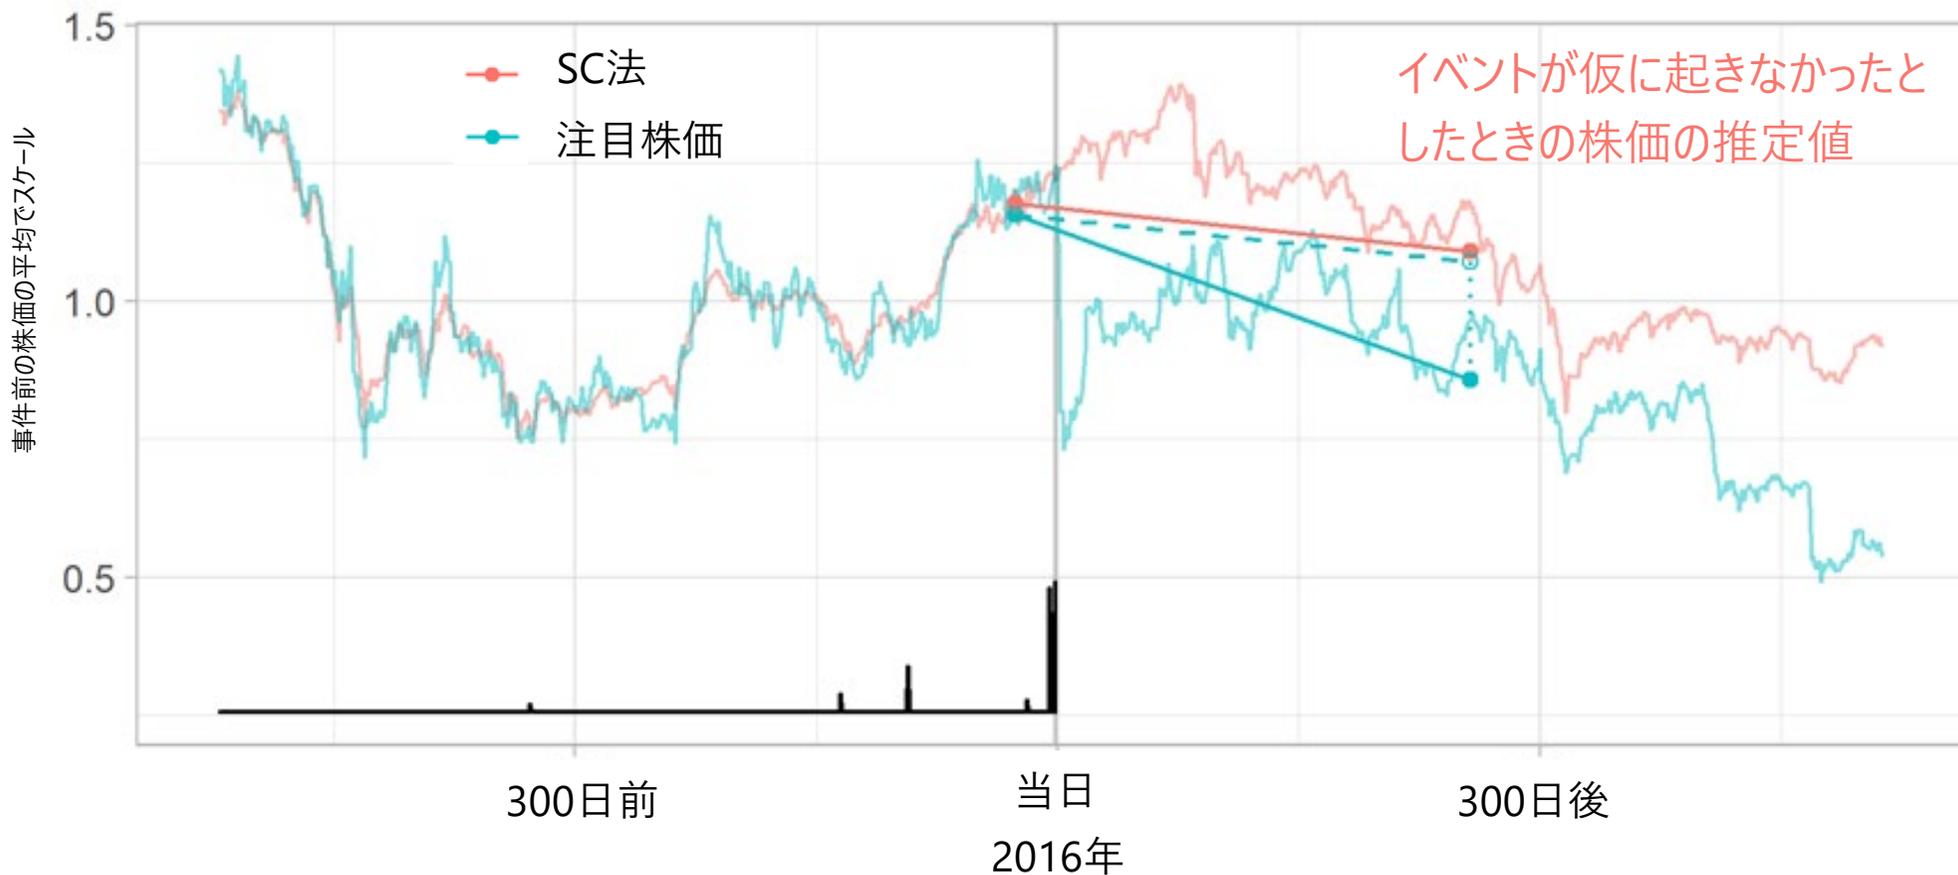
個体間の加重 ω_i と時間方向の加重 λ_t を求め、 Y の値を推定する。

$$Y_T^{SDID}(0) = \sum_{t=1}^{T-1} \sum_{i=1}^{N-1} \omega_i \lambda_t X_{it} + \underbrace{\left(\sum_{t=1}^{T-1} \lambda_t Y_t - \sum_{t=1}^{T-1} \sum_{i=1}^{N-1} \omega_i \lambda_t X_{it} \right)}_{\text{介入前後の差}} + \underbrace{\left(\sum_{i=1}^{N-1} \omega_i X_{iT} - \sum_{t=1}^{T-1} \sum_{i=1}^{N-1} \omega_i \lambda_t X_{it} \right)}_{\text{群間の差}}$$

企業事例：品質改ざん事件

■ 品質の改ざんが発覚したときの株価への影響

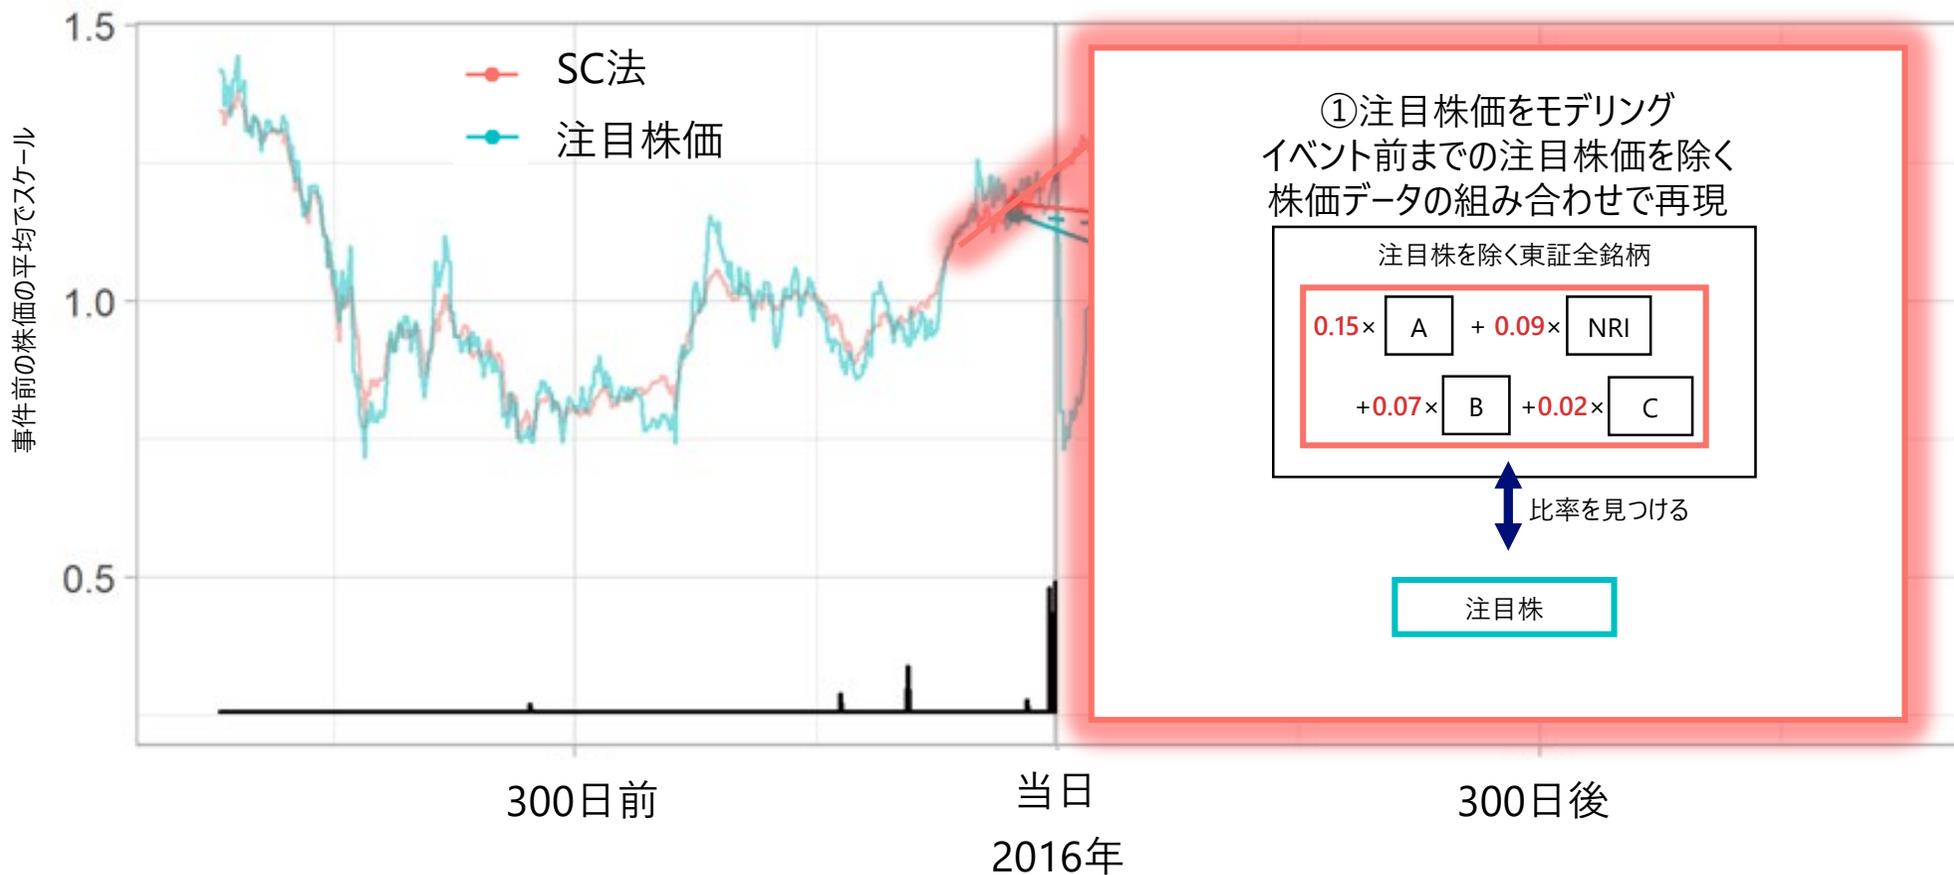
- この事件におけるインパクトは株価に-21%を与えた。（発覚から昨年度末までの平均）



企業事例：品質改ざん事件

■ 品質の改ざんが発覚したときの株価への影響

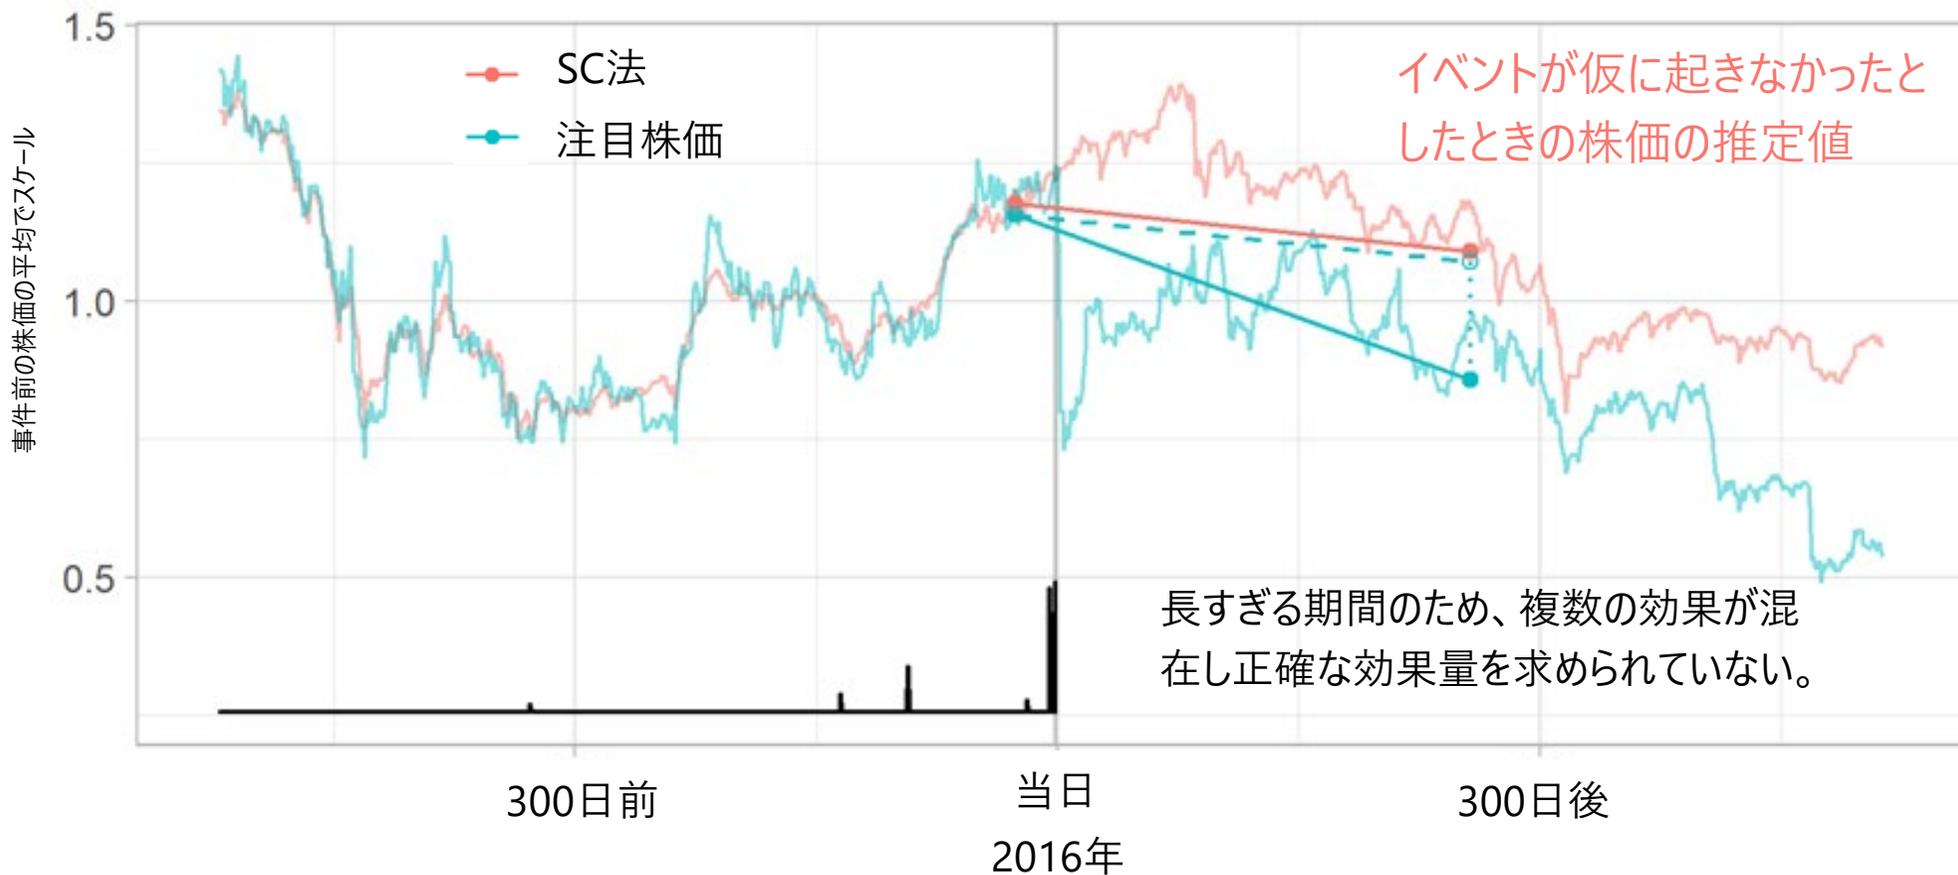
- この事件におけるインパクトは株価に-21%を与えた。（発覚から昨年度末までの平均）



企業事例：品質改ざん事件

■ 品質の改ざんが発覚したときの株価への影響

- この事件におけるインパクトは株価に-21%を与えた。（発覚から昨年度末までの平均）



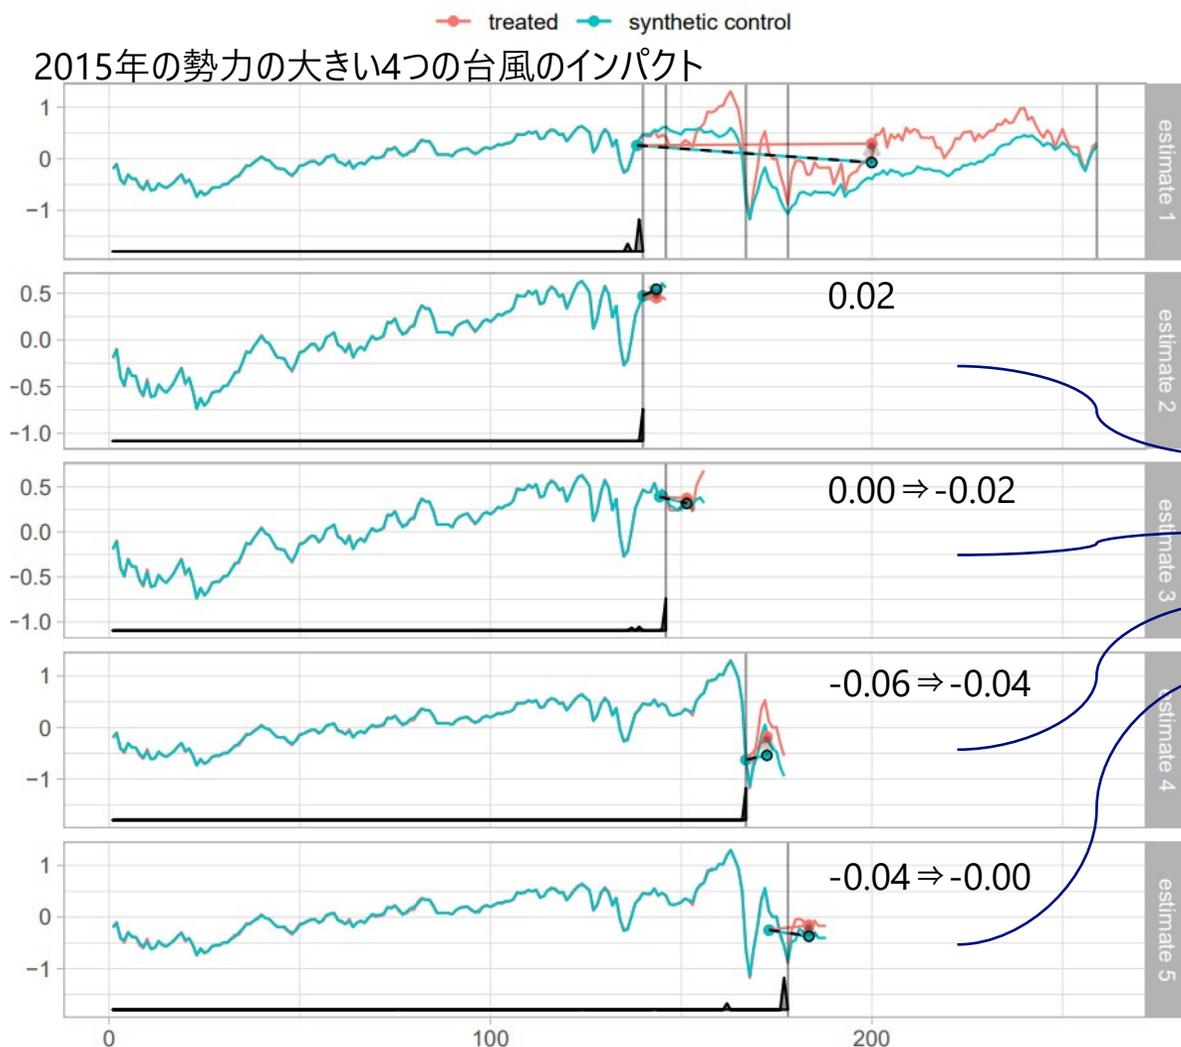
海外大学との共同研究

- 因果推論自体の課題で、以下のような理論の改良タスクがある。
- 当初、因果構造分析を検討していたが、研究期間や難易等を考慮したうえで、「連続的なイベント」について取り組むこととした。

手法の種類	タスク	詳細
因果抽出	因果の定義	金融市場および本研究に適切な因果の定義を検討する
	時系列解析	日次、週次、月次などさまざまな分解能を持つ時系列を扱う方法を開発する。
	高速計算	複数時系列から因果構造を抽出する方法を高速化する。
シンセティックコントロール法、シンセティック差分-差分法	イベントの強度	介入の大きさを考慮できるように手法を改良する。
	制御群/介入群抽出	機械的に制御群と介入群を見つける。
	回帰精度	べき分布、自己相関、時間遅れ効果
	連続的なイベント	連続的なイベントで重複する効果を除去して評価する。
予測モデル	予測	因果構造を基にした予測方法
	シミュレータ	所与の状況に応じて、因果伝播をシミュレートする方法

連続した台風襲来での事例

- 複数回発生するイベントは、前回効果が残ったまま次のイベントが起き、インパクトの推定が難しくなる。
- 効果が重複して含まれるモデル同士の差分で個別のイベントインパクトを計量する。



① 台風ごとにモデルを作成

② 各モデルに織り込まれている台風の影響

モデル	台風 1	台風 2	台風 3	台風 4
モデル 1	○	×	×	×
モデル 2	○	○	×	×
モデル 3	○	○	○	×
モデル 4	○	○	○	○

③ 注目回以前の台風の効果を差し引く

連続した台風襲来での事例

- 複数のイベントが重複する場合、効果の計量は難しい
 - 単純な足し引きだけで求まるものではなく、前回効果に対して、増幅や減衰効果も考えられる。
 - たとえば、同じ広告でも初回と2回目で効果の低減が見られる。
- ここでは、台風足し引き前回までの台風の効果を単純な足し引きで計量
修正済みの効果量

	台風1回目	台風2回目	台風3回目	台風4回目	台風5回目	台風6回目
2015	△ 2 %	▼ 2 %	▼ 4 %	0 %		
2016	▼ 3 %	▼ 1 %	▼ 1 %	▼ 6 %	0 %	△ 1 %
2017	△ 3 %	▼ 1 0 %	▼ 4 %	▼ 2 %		
2018	▼ 1 7 %	▼ 7 %	▼ 2 %	△ 2 %	△ 3 %	

まとめ

■ RCTが満たされない場合の効果量の測定方法を紹介した。

■ 選択バイアスへの対応

- ポテンシャルアウトカムフレームワーク
- 選択バイアスの数理的記述
- 選択バイアスの補正方法
 - ・ 傾向スコアマッチング
 - ・ 逆確率重み付け法

■ さまざまなデザイン

- 中断時系列デザイン
- 不連続回帰デザイン
- 合成コントロール法

The text is framed by two decorative swooshes. The top swoosh is a gradient bar transitioning from blue on the left to red on the right. The bottom swoosh is a solid blue bar.

Share the Next Values!