

# 統計的モデリング基礎⑫ ～因果関係・ランダム化試験～

鹿島久嗣  
(情報学科 計算機科学コース)

## 今回の話題： 因果推論

- 相関関係と因果関係は異なるという話：相関 $\neq$ 因果
- 因果関係の定量化
- ランダム化試験（RCT）：因果関係を導く方法




## 因果関係

3

KYOTO UNIVERSITY

### 相関と因果： これは因果関係？

- 警察官を増やすと、犯罪率が上がる？
  - 回帰モデル：犯罪率(%) =  $3 \times$  警察官の人数(千人)
  - 警察官を1,000人増やすと、犯罪率が3%上がるのか？
- 握力を上げると、学力が上がる？
  - テストの点 =  $3 \times$  握力
  - 握力を1kgw増やせば3点増える？



4

KYOTO UNIVERSITY


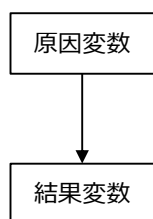
## 相関と因果： 相関と因果は異なる

- 相関は必ずしも因果を意味しない
  - 相関：片方の変数が変化すると、もう片方の変数も変化する
  - 因果：片方の変数を変化させると、もう片方の変数も変化する
  - 観察と介入の違い

原因変数

結果変数

### 原因変数・結果変数




5


KYOTO UNIVERSITY

## 相関≠因果が生じるケース： 逆向きの因果、共通の要因、下流選別

- 因果関係がないのに相関が生じるケース：
  - 逆向きの因果関係
  - 交絡：別の（共通の）要因がある
  - 下流での選別



### 因果ダイアグラムで表現



6


KYOTO UNIVERSITY

## 交絡の例： 握力と学力の相関


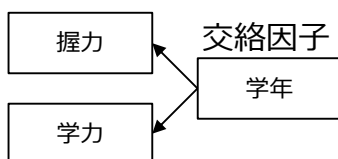
- 交絡因子：原因変数と結果変数に影響を与える

- 例 1：握力があがると学力が上がる？

- 握力と学力の間に相関がある
- 実際には学年が交絡因子になっている
  - ◆ 学年を固定すると無相関



- 例 2：海外留学をすると、就職に有利？



7

KYOTO UNIVERSITY



## 下流での選別の例： 合格者における学力点と人物点の相関

- 合格者における学力点と人物点に負の相関がある

- 「勉強を頑張ると人格が破たんする??」

- 学力点と人物点の合計で合格ラインが決まっているとする

- 本当は無相関でも、選別によって見かけの相関が生じる



8

KYOTO UNIVERSITY

## 因果関係の定量化

因果：

因果 = 平均介入効果


- 全く同じ状況において「介入を受けた場合（介入群）」と「介入を受けなかった場合（対照群）」の結果の違いが介入の因果効果
- $i$ さんが介入を受けた場合の結果変数 $Y_i^T$ と、受けなかった場合の結果変数 $Y_i^C$ の差 $Y_i^T - Y_i^C$ が $i$ さんへの介入による効果
- 母集団に対する平均的な介入効果が因果関係の強さになる：

$$E[Y^T - Y^C]$$

これを推定するのが目的

※ 量的変数の場合は、介入 $X$ と結果 $Y$ に線形関係を仮定して  
 $E[Y | X] - E[Y | X = 0] = \beta X$  であるときの $\beta$ みたいな感じ

因果関係の推定：  
平均介入効果は直接計測できない

- 我々の知りたい因果関係の強さ： $E[Y^T - Y^C]$
- その推定量は $\frac{1}{n} \sum_i (Y_i^T - Y_i^C)$ で推定できそう
  - これは直接計測できない
  - 介入の有無はどちらか一方のみ実現するので、 $Y_i^T$ と $Y_i^C$ のいずれか一方のみ観測可能
    - ◆ 観測されない「反実仮想」
- $E[Y^T - Y^C] = E[Y^T] - E[Y^C]$ なので、介入群と対照群からそれぞれ $E[Y^T]$ と $E[Y^C]$ を推定すればよいのでは？ → ダメ 

11

KYOTO UNIVERSITY

介入によるバイアス：  
計測は介入の判断に影響を受ける

- なんらかの基準で介入するかどうか（ $X$ ）が決まるとする
  - 介入する： $X = T$
  - 介入しない： $X = C$
- 我々が推定できるのは、母集団中で
  - 介入する人に介入した結果
  - 介入しない人に介入しなかった結果

の平均的な差：

$$E[Y^T | X = T] - E[Y^C | X = C] \quad (\neq E[Y^T] - E[Y^C])$$

- この値が正だからといって、因果関係があるとは限らない

12

KYOTO UNIVERSITY

## 自己選抜バイアス：

自己選抜バイアスがなければ介入群への介入効果は測れる

- $E[Y^T | X = T] - E[Y^C | X = C] > 0$  は因果関係を意味しない
  - 介入した人の結果が大きかったとしても、本当は介入しなくても結果は大きくなっていたのかもしれない
    - ◆ 例：意識高い系は留学もするし就職も強い（とか）

- 自己選抜バイアス：結果が大きくなりそうな人を選んでいる

$$= \underbrace{E[Y^T - Y^C | X = T]}_{\text{介入群への介入効果}} + \underbrace{E[Y^C | X = T] - E[Y^C | X = C]}_{\text{自己選抜バイアス}}$$


- 自己選抜バイアスが0なら、介入群への介入効果が正しく測れる

## ランダム化試験による因果関係の計測

## 因果関係を導くためには： 原因変数と交絡因子の因果を切る

- 真の因果関係を導くには、交絡因子の影響を切る必要がある
  - データを増やしてもバイアスは消えないので意味なし
- 例：ある最新の治療法を実施したほうが、死亡率が高い
  - ◆ 因果関係：治療法が死亡率を上げているのか？
  - ◆ 交絡：そもそも難病患者にのみ治療法を適用しているのか？（難病患者かどうかは交絡因子）

の2つを区別する必要がある




15

KYOTO UNIVERSITY

## ランダム化試験（RCT）： 介入を交絡因子と独立にすることで交絡因子の影響を切る

- 因果をただしく測るには：
  - 原因変数の割り付けを交絡因子と独立にする
  - または、交絡因子を固定する
  - 原因変数と結果変数以外の変数の分布を、介入群と対照群で同一にする
- ランダム化試験（Randomized Controlled Trial; RCT）：
  - 介入群と対照群をランダムに割りつける
    - ◆ 交絡因子と独立にする



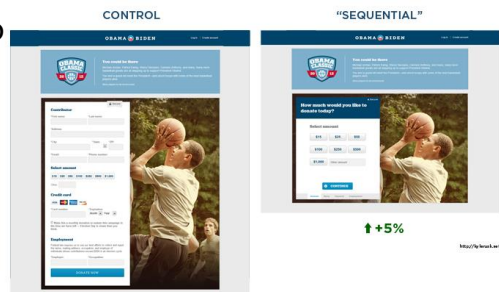
16

KYOTO UNIVERSITY



## ランダム化試験 (RCT) のやり方： とにかくランダムに割り付ける

- ランダム化試験 (Randomized Controlled Trial; RCT) :
  - 対象をランダムに2つのグループに分ける
  - 片方のグループを介入群に、もう一方のグループを対照群として、前者にのみ介入を行う
  - それぞれの群の結果を比較する
- A/BテストはRCT



Source: <http://kylerush.net/blog/optimization-at-the-obama-campaign-ab-testing/>

17

KYOTO UNIVERSITY

## ランダム化の効果： 平均介入効果が正しく計測可能

- ランダム化の効果：因果関係が測れる！

$$E[Y^T | X = T] - E[Y^C | X = C] = E[Y^T - Y^C]$$

介入群・対照群それぞれの結果の差から…

平均介入効果が測れる

- $X$ と $Y$ が独立なら $E[Y | X] = E[Y]$
- 観測されない変数含め、すべての他の変数と独立になる
- 介入群と対照群で、介入の有無に影響をうけないすべての変数の分布が両群で等しくなる

18

KYOTO UNIVERSITY

RCTの限界：  
現実には実行困難な場合あり

---

- RCTをいつでもできるわけではない
  - そもそもできない（倫理的にできないなど）
  - できたとしても完全にランダムな割り付けを実行できない
    - ◆ 案内を出しても実行しないなど
- 準実験：すでにあるデータから因果関係を導きたい
  - 回帰不連続デザイン
  - 層別解析／回帰モデル
  - マッチング／傾向スコア
  - ...