

令和 7 年国勢調査有識者会議企画WG（第 1 回）

# CANCEISによる補完方法の概要と試算

令和 5 年 7 月  
総務省統計局

## 概要

○本資料では、CANCEISの概要・実行原理と、CANCEIS補完の試算結果を紹介

※国勢調査（人口等基本集計）の愛知県分の結果について、CANCEISによる補完を実施し、（原数値又は不詳補完値）とCANCEIS適用後の人口等を比較

## CANCEISの概要

正式名称	<b>CAN</b> adian <b>C</b> ensus <b>E</b> dit and <b>I</b> mputation <b>S</b> ystem (CANCEIS)
作成者	Mike Bankier (カナダ統計局)
利用開始	1996年 (1992年に開発)
動作原理	最近隣法 (Nearest-neighbor Imputation Methodology (NIM))
主な特徴	<ul style="list-style-type: none"><li>▶ <b>数値、カテゴリー及び英数字データのドナー補完を同時に実行可能</b></li><li>▶ <b>大量のデータを効率的に処理可能</b></li><li>▶ <b>調査データの問題や希望する解決策を容易で正確に定義可能</b>※</li></ul>

※ 決定論的又はドナー利用により解決


### 【その他、以下の特徴】

- ▶ 既存の変数に基づいて新しい変数を導出 (作成) 可能
- ▶ ソフトウェアは、Windows 環境で使用するための移植が可能
- ▶ システムは、新規ユーザーが直感的に使用可能
- ▶ Excel又はテキスト形式でモジュールを使う (作る) ことができる柔軟性
- ▶ 上級ユーザーは一連のパラメーターを介して補完方法を緻密に制御可能
- ▶ システムは動的であり、ユーザーの要望を満たすため新機能を迅速に追加可能

## CANCEISの実行原理

- CANCEISでは、元データ（集計用個別データ）に適切な前処理をした入力用データから、
  - 入力データの各ユニットを**合格**と**不合格**のいずれかに分類し、
  - 不合格ユニットの問題を修正するデータを提供できるドナーを選定（通常は合格ユニットを選定）

※ 合格ユニット（passed units）・・・すべての変数に有効な値があり、変数間の不整合もないユニット  
不合格ユニット（failed units）・・・インプテーションを必要とする一つ以上の問題を持つユニット



合格、不合格ユニットのイメージ

ID	年齢	配偶関係	合格/不合格
1	38	配偶者あり	合格
2	36	配偶者あり	合格
3	13	空白	不合格
4	0	配偶者あり	不合格
5	51	配偶者あり	合格
6	53	配偶者あり	合格
7	62	未婚	合格
8	27	空白	不合格

合格したID 1, 2, 5, 6, 7は、  
不合格のID 3, 8の空白を代替し、  
ID 4の矛盾を解消するためのドナー候補となる。

## CANCEISのドナー選択方法

- CANCEISは、不合格ユニットのドナー候補として、不合格ユニットと類似のユニットを複数探す。
- その際、不合格ユニットとドナー候補との相違を測定する方法として**距離関数**を使用し、**最短距離に近い**(※1) **ドナー候補** (「**NMCIA**」と呼ばれる) (※2) を複数選択し、その中からドナーを**ランダム**に選択採用する。

補完前データのイメージ

ID	年齢	他の属性
1	85	...
2	51	...
3	不詳	...
4	23	...
5	93	...
6	46	...
7	37	...
8	23	...
9	不詳	...
10	59	...
11	21	...
12	75	...
⋮		

NMCIAデータのイメージ

補完対象 ID	ドナー候補ID	ドナー候補年齢	採用フラグ
3	1	85	0
3	4	23	0
3	6	46	1
3	7	37	0
9	7	37	0
9	8	23	0
9	10	59	1
⋮			

補完後データ

ID	年齢	他の属性
1	85	...
2	51	...
3	46	...
4	23	...
5	93	...
6	46	...
7	37	...
8	23	...
9	59	...
10	59	...
11	21	...
12	75	...
⋮		

リストとして出力

ID=3に対する  
NMCIA

ID=9に対する  
NMCIA

ランダムに  
採用

(※1) デフォルトでは最短距離×1.1以下 (「1.1」はシステムパラメータで変更可能)

(※2) デフォルトでは最小1個、最大10個 (最小値、最大値ともシステムパラメータで変更可能)

## CANCEISドナー選定の原理（距離関数）

### 距離関数

$$D_{fp} = \sum_i w_i D_i(V_{fi}, V_{pi})$$


$D_{fp}$ : 不合格ユニット(FU)と合格ユニット(PU)の距離

$V_{fi}$ : 不合格ユニットにおける*i* 番目の変数

$V_{pi}$ : 合格ユニットにおける*i* 番目の変数

$D_i(V_{fi}, V_{pi})$ :  $V_{fi}$ と $V_{pi}$ の距離

$w_i$ : *i* 番目の変数におけるウエイト



$D_{fp}$ が小さいほど、FUとPUが類似している。

### 具体例

$$D_i = \begin{cases} 0, & \text{if } V_{fi} = V_{pi} \\ 1, & \text{otherwise} \end{cases}$$

不合格ユニットの文字列	ドナーユニットの文字列	$D_i$ の戻り値
Hello	Hello	0
HELLO	hello	1
Ah a	A ha	1

## CANCEISドナー選定の原理（インピュテーションの品質）

○CANCEISのドナーインピュテーションは以下の目的で実行され、その品質は下式で評価される。

- 不合格ユニットと極めて類似したユニットが選定されたか
- 複数人のドナーからではなく、可能な限り1人のドナーからのデータが得られたか

※ ドナー候補ユニットとの類似度が高く、不合格ユニットからの変化が最小のユニットをドナーとして選定

※ 実際のドナー選定は、不合格ユニットに対して検査できる潜在的なドナーの最大数を決定する等により効率的に実施

### インピュテーションの品質


$$D_{fpa} = \alpha D_{fa} + (1 - \alpha) D_{ap}$$

$D_{fa}$ : 不合格ユニットとインピュテーション後のユニット(IU)の距離

$D_{ap}$ : インピュテーション後のユニットと合格ユニットの距離

$D_{fpa}$ :  $D_{fa}$ と $D_{ap}$ の加重平均

$\alpha$ : ユーザー定義システムパラメータ( $0.5 < \alpha \leq 1.0$ )



$D_{fp}$  及び $D_{fpa}$ が最小のユニットをドナーとして選定


## CANCEIS補完の試算 ジョブフロー

### CANCEIS補完結果算出手順

- ①国勢調査の集計用個別データからCANCEIS入力用データに変換
- ②都道府県別にCANCEISの動力源となるモジュールを作成
  - ・都道府県別に、ドナー選択時の距離関数に必要な特徴量ウエイトをRandom Forest※により算出し、モジュールへ入力
- ③CANCEIS入力用データと都道府県別モジュールをセットし、CANCEISを実行
- ④CANCEIS補完結果が出力される。

※ 多数の決定木モデル予測を組み合わせる機械学習手法


### 【都道府県別】



## CANCEIS補完の試算結果①（男性・年齢）

◆ 年齢各歳別人口（CANCEIS補完結果と不詳補完値の比較）


➡ CANCEIS補完結果と不詳補完値は、お互いが近接した数値となった。



## CANCEIS補完の試算結果②（女性・年齢）

◆ 年齢各歳別人口（CANCEIS補完結果と不詳補完値の比較）


➡ CANCEIS補完結果と不詳補完値は、お互いが近接した数値となった。



# CANCEIS補完の試算結果と不詳補完値の差率

◆ 年齢各歳別人口におけるCANCEIS補完結果と不詳補完値の差率

➡ 男女ともに差率は±2%以内





注) 差率(%)は、(CANCEIS補完結果－不詳補完値)／CANCEIS補完結果×100により算出

# CANCEIS補完の試算結果と不詳補完値の補完率

## ◆ 年齢各歳別補完率（CANCEIS補完結果と不詳補完値）

➡ 男性では、20代及び90代で補完率に差が見られるが、女性ではほぼ同率

図4. 2020年国勢調査 CANCEIS補完結果と不詳補完値の補完率（愛知県・男女別）



注1) CANCEIS補完率 (%) は、(CANCEIS補完結果-原数値) / CANCEIS補完結果 × 100により算出


注2) 不詳補完値補完率 (%) は、(不詳補完値-原数値) / 不詳補完値 × 100により算出

## CANCEIS補完の試算結果（国籍）

### ◆ 国籍（日本人・外国人）別人口

→ CANCEIS補完結果は、不詳補完値に近接した数値

図5. 2020年国勢調査 国籍（日本人・外国人）別人口（愛知県）





## CANCEIS補完の試算結果（配偶関係）

### ◆ 配偶関係別人口

→ CANCEIS補完結果は不詳補完値に近接した数値

- 男性では、不詳補完値と同様に他の項目と比較して、未婚の人口が多く増加する結果
- 女性では、未婚以外に死別も不詳補完値と同様、顕著に増加

図6. 2020年国勢調査 男女・配偶関係別人口（愛知県）



## 試算結果のまとめと今後の検証事項

- CANCEIS補完値を試算したところ、令和2年国勢調査の不詳補完値に近い結果を得たことから、我が国の国勢調査においても、CANCEISの適用により年齢・国籍等の不詳を補完することが可能と考えられる。
- 今回は、一部地域に限定して試算を行ったため、今後、
  - 試算対象地域を拡大するとともに、市区町村レベルや小地域レベルでの補完が可能か
  - 調査事項を拡大し、就業状態等についてもCANCEISが適用可能かなどについて検証を行う。