

「欠測値補完に関する調査研究」について

令和2年1月

内閣府経済社会総合研究所
景気統計部

調査研究の概要

- 平成28年度に内閣府経済社会総合研究所景気統計部において、政府統計の適切な欠測値補完手法について検討するための調査研究を実施。有識者による研究会を開催し、報告書を取りまとめた。
- 研究会委員(所属等は当時)
 - 座長 星野崇宏 慶應義塾大学経済学部・大学院経済学研究科 教授
 - 委員 土屋隆裕 情報・システム研究機構統計数理研究所データ科学研究系 教授
 - 元山齊 青山学院大学経済学部 准教授
- 報告書の内容
 - 欠測データ処理の考え方
 - 主な統計的処理の手法
 - 機械受注統計調査を用いた分析(現行の「横置き代入」の評価と課題)

<以下のスライドでは、本報告書に基づき、欠測データの処理手順等を記載>

欠測データに伴う問題

- 統計調査において、無回答や無記入により調査客体又は調査項目の一部の情報が得られない場合、**欠測**(本来観測されるべきだが観測されない値)が生じる
- 欠測を含むデータについて、観測された値のみを用いた推定を行うと、以下の問題が生じる


①欠測バイアスの可能性:

欠測によって標本が母集団の縮図としての性格を失うことで推定に生じるバイアス

②推計精度の低下:

失われた情報の分だけ推計精度が低下

真の分布と比べて偏り
⇒ 母集団の縮図でなくなる
ことでバイアスが生じる



特に欠測バイアスを軽減するような統計的処理が必要

欠測データの処理手順(全体像)

Step1: 統計調査の推定目標を確認



Step2: 欠測の発生状況を確認



Step3: 欠測データメカニズム、補助変数の利用可能性を検討



Step4: 適切な欠測データ処理方法の候補を検討



Step5: 適切な処理方法を選択

【参考】

シミュレーション実施による適切な処理方法の選択

主な単一代入法の実施手順

欠測データの処理手順 (Step1,2)

Step1: 統計調査の推定目標を確認

- 推定対象が平均・総計等の推定か、又は分散・推定値の標準誤差等の推定か
※公的統計の大部分は平均・総計等の推定にとどまる。

Step2: 欠測の発生状況を確認

- 調査客体単位、調査項目単位の欠測率はどの程度か
※欠測率が十分低い場合、異なる処理方法を用いた際のパフォーマンスの差異が小さいため、複雑な処理方法を用いる必要がない。(ただし、欠測のある変数が裾野の広い分布を持つ場合には留意が必要(裾野の広さが変数加工の重要性に影響)。)
● 時系列でみた場合、調査客体ごとの欠測パターンに特徴はないか

<例1> 過去20年の客体企業ごとの欠測状況(回答状況)をしてみる

調査年																	○観測 ×欠測					
	1997	98	99	00	01	02	03	04	05	06	07	08	09	10	11	12	13	14	15	16	欠測回数	欠測率
客体企業A	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	0	0%
客体企業B	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	0	0%
客体企業C	○	○	○	×	○	○	○	○	×	○	○	○	○	×	○	○	○	○	×	○	4	20%
客体企業D	○	○	×	○	○	×	×	○	○	×	○	○	○	○	○	○	○	○	○	○	4	20%
客体企業E	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	×	×	×	×	×	5	25%

過去に欠測となった調査客体が再び欠測しやすい傾向(C,D,E)



何らかの理由(業績悪化等)により、一度欠測すると欠測が継続する可能性(E)

欠測データの処理手順 (Step2)

- 欠測となりやすい調査客体に特徴はあるか (調査客体の企業規模、売上高、所得水準、資産保有額、就業状態等が欠測しやすさに影響していないか)



⇒ 欠測と相関の強い変数、欠測しやすさを説明する説明変数になり得る変数である「補助変数」が観測されていないか

<例2> 客体企業の資本金規模ごとの欠測率をしてみる



⇒ 中小企業ほど
欠測しやすい傾向:
資本金規模が補助変数の候補となり得る

<例3> 調査対象世帯の年間所得水準ごとの欠測率をしてみる



⇒ 高所得者ほど
欠測しやすい傾向:
平均年間所得が補助変数の候補となり得る

欠測データの処理手順 (Step3)

Step3: 欠測データメカニズム、補助変数の利用可能性を検討

- 処理方法の適性を決める条件:
欠測データメカニズム、統計調査の推定目標、欠測率・欠測パターン 等
- 欠測データメカニズム(=欠測が生じるしくみ)の種類:


種類	定義	例
①完全にランダムな欠測(MCAR)	変数の欠測確率が、 <u>当該変数及び他の観測されている変数の値に依存しない</u>	コインの表裏によって、調査に協力するかどうか決める場合 ⇒ <u>欠測バイアスは生じない</u>
②ランダムな欠測(MAR)	変数の欠測確率が、 <u>当該変数の観測値及び他の観測されている変数の値には依存するが、当該変数の欠測となった値には依存しない</u>	回答者の大半が学生や無職者、無回答者の大半が就業者である調査で、金融資産保有額の欠測確率が就業状態の値に依存する場合 ⇒母集団の <u>金融資産保有額の推定には、学生・無職者側への下方バイアスあり</u>
③ランダムでない欠測(MNAR)	変数の欠測確率が、 <u>その変数自体の値に依存する</u>	金融資産保有額平均を推定する調査で、上位資産階級ほど当該情報を秘匿する傾向が強い場合 ⇒ <u>標本が低中位資産階級に偏る</u>

「補助変数」を利用し欠測バイアスの緩和が可能

観測情報では欠測バイアスの緩和が不可能: モデル化が必要

欠測データの処理手順 (Step4)

Step4: 適切な欠測データ処理方法の候補を検討



欠測データの処理手順 (Step5)

Step5: 適切な処理方法を選択

(1) 対象となる統計調査の欠測データに対し、Step4で候補となった各処理方法及び現行方法を用いて処理を実施



(2) 各方法を用いた場合の処理後のデータを比較し、現行方法の妥当性を検証

① 各方法間に大きな違いがない場合:

現行方法を選択して問題ないとみられる

② 特異な結果を出す少数の方法と、同様な結果を出す多数の方法に分かれ、
現行方法が後者(多数派)に含まれる場合:

現行方法に問題があるという強い推論は得られない

③ 特異な結果を出す少数の方法と、同様な結果を出す多数の方法に分かれ、
現行方法が前者(少数派)に含まれる場合:

現行方法より他の方法を選択した方がよい可能性

※ケース②・③の場合、一部の方法で特異な結果を出す原因について、
個票レベルでチェックを行う

【参考】

シミュレーション実施による適切な処理方法の選択

● Step4で候補となった処理方法及び現行方法についてシミュレーションを実施

(1) 対象となる統計調査の観測データに対し、2種類の欠測データメカニズム(ランダムな欠測(MAR)、ランダムでない欠測(MNAR))を仮定し(※)、一定の確率で機械的に欠測を生じさせる

(※) 観測可能な情報からはMAR、MNARのどちらが成立しているか見分けがつかないため



(2) 欠測を生じさせたデータに対し、

- ・ 複数の補助変数の組合せ(※)
- ・ 複数の変数の加工方法(水準、差分、対数等)

を設定し、各処理方法及び現行方法で欠測データ処理を実施

(※)「今年の所得」項目に欠測があり、調査対象者の「就業状態」及び「前年の所得」が補助変数として利用可能な場合:①「就業状態」、②「前年の所得」、③「就業状態」及び「前年の所得」の3種類の組合せを用いる



(3) 各処理方法及び現行方法についてRRMSE(※)で評価
現行方法より優れた方法があれば当該方法の選択を検討

(※) $RRMSE = \sqrt{\hat{E}[(推定値 - 真値)^2]} / 真値$

【参考】 主な単一代入法の実施手順

- 具体的な数値例として、以下のケースを想定
 - ・個人20人を調査客体とした統計調査
 - ・「今月末の対前月末体重変化分(kg)」(変数 y とする)の調査項目に欠測あり
 - ・変数 y と相関の高い変数(補助変数)として2つの変数が利用可能
 - 変数 x_1 : 前月末の対前々月末体重変化分(kg)
⇒ 欠測なし、変数 y との間に正の相関
 - 変数 x_2 : 今月の対前月1日当たり運動量変化分(時間/日)
⇒ 欠測なし、変数 y との間に負の相関

【参考】 主な単一代入法の実施手順

● 層化平均値代入法

- (1) 標本を補助変数 (x_1) の値を用いて層化 (グループ分け)
- (2) 層 (グループ) ごとに目標変数 (y) の観測値の平均値を算出
- (3) 欠測に対し、層ごとの観測値の平均値を代入

id	y^*	y	missing	x_1	x_2	classx2	y_{str_mean}
1	-1.49	-1.49	0	-0.66	0.60	4	-1.49
2	-1.25	-1.25	0	0.30	1.93	4	-1.25
3	-0.83		1	0.59	0.31	3	0.54
4	-0.39	-0.39	0	-0.42	-0.51	2	-0.39
5	-0.28	-0.28	0	-1.69	0.09	3	-0.28
6	-0.26	-0.26	0	-0.84	0.35	4	-0.26
7	-0.21	-0.21	0	-1.01	-0.41	2	-0.21
8	-0.18	-0.18	0	0.06	0.45	4	-0.18
9	0.10	0.10	0	-0.44	-0.44	2	0.10
10	0.15		1	0.18	-0.40	2	-0.16
11	0.18	0.18	0	-0.01	0.57	4	0.18
12	0.80	0.80	0	0.70	-0.83	1	0.80
13	0.81		1	0.33	-0.01	3	0.54
14	0.81	0.81	0	0.61	-0.28	3	0.81
15	0.86	0.86	0	-0.66	-1.40	1	0.86
16	1.05		1	1.78	-0.68	2	-0.16
17	1.09	1.09	0	0.00	0.20	3	1.09
18	1.33		1	0.16	-1.86	1	0.83
19	1.41		1	0.62	-1.61	1	0.83
20	1.43		1	0.97	-1.12	1	0.83

id	y	missing	x_2	classx2
12	0.80	0	-0.83	1
15	0.86	0	-1.40	1
18		1	-1.86	1
19		1	-1.61	1
20		1	-1.12	1
平均値	0.83			

id	y	missing	x_2	classx2
4	-0.39	0	-0.51	2
7	-0.21	0	-0.41	2
9	0.10	0	-0.44	2
10		1	-0.40	2
16		1	-0.68	2
平均値	-0.16			

id	y	missing	x_2	classx2
5	-0.28	0	0.09	3
14	0.81	0	-0.28	3
17	1.09	0	0.20	3
3		1	0.31	3
13		1	-0.01	3
平均値	0.54			

id	y	missing	x_2	classx2
1	-1.49	0	0.60	4
2	-1.25	0	1.93	4
6	-0.26	0	0.35	4
8	-0.18	0	0.45	4
11	0.18	0	0.57	4
平均値	-0.60			


y^* : 真の値、 y : 観測データ、missing: 欠測指標、
 (x_1, x_2) : 補助変数、classx2: 補助変数 x_2 の4分位階層、
 y_{str_mean} : 補助変数 x_2 にもとづく層化平均値代入による代入値

【参考】 主な単一代入法の実施手順

● 回帰代入法

- (1) 目標変数 (y) を被説明変数、補助変数 (x_1, x_2) を説明変数とする回帰分析を実施
- (2) 欠測に対し、 x_1, x_2 の値から算出した y の理論値を代入

id	y^*	y	missing	x_1	x_2	y_{reg}
1	-1.49	-1.49	0	-0.66	0.60	-1.49
2	-1.25	-1.25	0	0.30	1.93	-1.25
3	-0.83		1	0.59	0.31	0.22
4	-0.39	-0.39	0	-0.42	-0.51	-0.39
5	-0.28	-0.28	0	-1.69	0.09	-0.28
6	-0.26	-0.26	0	-0.84	0.35	-0.26
7	-0.21	-0.21	0	-1.01	-0.41	-0.21
8	-0.18	-0.18	0	0.06	0.45	-0.18
9	0.10	0.10	0	-0.44	-0.44	0.10
10	0.15		1	0.18	-0.40	0.50
11	0.18	0.18	0	-0.01	0.57	0.18
12	0.80	0.80	0	0.70	-0.83	0.80
13	0.81		1	0.33	-0.01	0.31
14	0.81	0.81	0	0.61	-0.28	0.81
15	0.86	0.86	0	-0.66	-1.40	0.86
16	1.05		1	1.78	-0.68	1.45
17	1.09	1.09	0	0.00	0.20	1.09
18	1.33		1	0.16	-1.86	1.47
19	1.41		1	0.62	-1.61	1.52
20	1.43		1	0.97	-1.12	1.36



$(\hat{\alpha}, \hat{\beta}, \hat{\gamma})$

$$y = \alpha + \beta x_1 + \gamma x_2 + \varepsilon$$

id	y^*	y	missing	x_1	x_2
3	-0.83		1	0.59	0.31
10	0.15		1	0.18	-0.40
13	0.81		1	0.33	-0.01
16	1.05		1	1.78	-0.68
18	1.33		1	0.16	-1.86
19	1.41		1	0.62	-1.61
20	1.43		1	0.97	-1.12

id	y^*	y	missing	x_1	x_2
1	-1.49	-1.49	0	-0.66	0.60
2	-1.25	-1.25	0	0.30	1.93
4	-0.39	-0.39	0	-0.42	-0.51
5	-0.28	-0.28	0	-1.69	0.09
6	-0.26	-0.26	0	-0.84	0.35
7	-0.21	-0.21	0	-1.01	-0.41
8	-0.18	-0.18	0	0.06	0.45
9	0.10	0.10	0	-0.44	-0.44
11	0.18	0.18	0	-0.01	0.57
12	0.80	0.80	0	0.70	-0.83
14	0.81	0.81	0	0.61	-0.28
15	0.86	0.86	0	-0.66	-1.40
17	1.09	1.09	0	0.00	0.20

y^* : 真の値、 y : 観測データ、
missing: 欠測指標、
 (x_1, x_2) : 補助変数、
 y_{reg} : 回帰代入による代入値

【参考】 主な単一代入法の実施手順

● 横置き代入法 (LOCF) ※パネルデータが利用できる場合のみ適用可能

- (1) 同一標本について、当期の値 (y) と前期の値 (x_1) の間に正の相関があることを確認
- (2) 欠測に対し、同一標本の前期の値を代入

id	y^*	y	missing	X_1	X_2	y_{LOCF}
1	-1.49	-1.49	0	-0.66	0.60	-1.49
2	-1.25	-1.25	0	0.30	1.93	-1.25
3	-0.83		1	0.59	0.31	0.59
4	-0.39	-0.39	0	-0.42	-0.51	-0.39
5	-0.28	-0.28	0	-1.69	0.09	-0.28
6	-0.26	-0.26	0	-0.84	0.35	-0.26
7	-0.21	-0.21	0	-1.01	-0.41	-0.21
8	-0.18	-0.18	0	0.06	0.45	-0.18
9	0.10	0.10	0	-0.44	-0.44	0.10
10	0.15		1	0.18	-0.40	0.18
11	0.18	0.18	0	-0.01	0.57	0.18
12	0.80	0.80	0	0.70	-0.83	0.80
13	0.81		1	0.33	-0.01	0.33
14	0.81	0.81	0	0.61	-0.28	0.81
15	0.86	0.86	0	-0.66	-1.40	0.86
16	1.05		1	1.78	-0.68	1.78
17	1.09	1.09	0	0.00	0.20	1.09
18	1.33		1	0.16	-1.86	0.16
19	1.41		1	0.62	-1.61	0.62
20	1.43		1	0.97	-1.12	0.97

y^* : 真の値、 y : 観測データ、
missing: 欠測指標、 (x_1, x_2) : 補助変数、
 y_{LOCF} : LOCFによる代入値

欠測データ処理(まとめ)

- 適切な欠測データの処理方法は、欠測データメカニズム(=欠測が生じるしくみ)の種類や統計調査の推定目標、欠測の発生状況等により異なる
- まずは欠測の発生状況に着目し、欠測しやすさを説明する説明変数になり得る変数(補助変数)が観察されているかを確認することが重要
- 欠測データメカニズムが完全にランダムな欠測(MCAR)の場合、欠測値の処理を行わず、観測値のみを利用した分析により欠測バイアスは生じない
- ランダムな欠測(MAR)であり、かつ平均・総計等の推定の場合、適切な補助変数を利用することで、各種単一代入法(層化平均値代入、回帰代入、マッチング代入、横置き代入等)やウエイト調整法により欠測バイアスの緩和が可能
※ただし、分散・推定値の標準誤差等の推定等の場合には、より高度な手法(多重代入法 やIPW法)を適用
- ランダムでない欠測(MNAR)の場合、欠測データメカニズムに関し、あらゆる想定可能な前提条件に対して分析を実行し結果を比較することが望ましい