

質的変数に関する擬似マイクロデータの作成方法について
—平成14年就業構造基本調査データを用いた研究—

NSTAC

Working Paper No.29

平成27年3月

独立行政法人 統計センター

製表技術参考資料は、独立行政法人 統計センターの職員がその業務に関連して行った製表技術に関する研究の結果を紹介するためのものである。

ただし、本資料に示された見解は、執筆者の個人的見解である。

目 次

要旨.....	1
1 はじめに - 研究の背景及び目的 -	2
2 先行研究.....	3
2.1 量的変数の擬似マイクロデータの概要	3
2.2 量的変数の擬似マイクロデータの提供	9
3 質的変数の擬似マイクロデータに関する作成方法.....	10
3.1 多変量正規乱数及び一様乱数の検証	10
3.1.1 使用したデータ及び変数.....	10
3.1.2 集計表作成.....	11
3.1.3 乱数発生方法.....	12
3.1.4 検証結果	13
3.2 集計用乗率を考慮した一様乱数の検証.....	15
3.2.1 使用したデータ及び変数.....	15
3.2.2 集計表作成.....	16
3.2.3 乱数発生方法.....	17
3.2.4 検証結果	18
4 おわりに - 結論及び課題 -	20
別添 1 質的変数の加工方法	21
別添 2 擬似マイクロデータの符号表	25
別添 3-1 集計表セル度数の出現確率に基づく一様乱数の作成イメージ	28
別添 3-2 集計表セル度数の出現確率に基づく一様乱数の作成イメージ（集計表乗率考慮）	29
別添 4 一様乱数発生における変数固定の有無の検証	30
別添 5 集計表における加工処理変数の度数分布の変化	32
参考文献	33

質的変数に関する擬似マイクロデータの作成方法について

- 平成 14 年就業構造基本調査データを用いた研究 -

滝澤 有美^{*}、堀川 顕子^{*}

要 旨

平成 21 年の新統計法の全面施行に伴い、公的統計の二次的利用拡大に向けた匿名データの提供及びオーダーメイド集計が開始された。平成 26 年 5 月 1 日時点において、匿名データは 7 調査の提供を、オーダーメイド集計は 26 調査の集計サービスを行っている[†]。

新統計法に基づく二次的利用データの提供開始後、研究者や教育関係者等から、二次的利用促進のための統計教育・訓練用の擬似的なマイクロデータの必要性が指摘され、また統計委員会の審議の場においても同様の指摘を受けた。これらの指摘に応じる形で、(独)統計センターでは擬似的なマイクロデータ(以下「擬似マイクロデータ」と言う。)の作成方法に関する研究を開始した。

先行研究の秋山ほか(2012)では、平成 16 年全国消費実態調査を用いた高次元クロス集計表を作成し、集計表のセルごとに量的変数の統計量(平均、分散及び共分散)に基づく多変量正規乱数を発生させ、これを用いて擬似マイクロデータを作成した。この擬似マイクロデータは、平成 23 年 8 月より統計センターホームページで試行提供中である。

しかしながら、試行提供の対象が量的変数のみであったため、利用者から質的変数への対象拡大の要望があり、新たに質的変数(産業分類、職業分類等)に関する作成方法の研究を行うこととなった。そこで、平成 24 年度から、就業構造基本調査データを用いた擬似マイクロデータ作成のための研究を行った。

はじめに、公表結果表での使用頻度等を考慮し使用変数を選定した。次に、使用変数全てを用いた高次元クロス集計表を作成した。さらに、(1)集計表セル単位の量的変数の統計量に基づく多変量正規乱数(以下「多変量正規乱数」と略す。)と(2)集計表セル度数の出現確率に基づく一様乱数(以下「一様乱数」と略す。)を生成し、それぞれから擬似マイクロデータを作成した。

作成した擬似マイクロデータと実データとを比較検証した結果、一様乱数は多変量正規乱数よりも実データ分布への近似が良好であり、集計用乗率を考慮した分布へも適用することが可能であることがわかった。

この結果、先行研究の量的変数の擬似マイクロデータ作成に続き、質的変数の擬似マイクロデータの作成研究でも成果が得られ、両変数に対応できたことから、他調査への応用も可能となった。今後は、擬似マイクロデータのもとになる集計表の作成方法の改善が課題であると考えている。

^{*} 統計センター統計情報・技術部統計技術研究課

[†] 匿名データ提供及びオーダーメイド集計を実施している調査の種類は、総務省政策統括官(統計基準担当)(2014)「委託による統計の作成等及び匿名データの作成・提供に関する年度計画一覧(平成 26 年度)」を参照されたい。

1 はじめに - 研究の背景及び目的 -

新統計法（平成十九年法律第五十三号）は、統計に関する基本法として、旧統計法（昭和二十二年法律第十八号）の全面改正及び統計報告調整法（昭和二十七年法律第四百四十八号）の廃止とともに、平成19年5月16日に成立し、平成21年4月1日に全面施行された。

新統計法でのマイクロデータの二次的利用には、旧統計法より継続している第三十三条による調査票情報の利用、新たな仕組みである第三十四条による委託による統計の作成等（オーダーメイド集計）及び第三十五条・第三十六条による匿名データの作成・提供がある。

しかしながら、新統計法の全面施行の準備段階から、有識者より、二次的利用を促進するためにはマイクロデータを統計教育・訓練用で利用できることが必要との議論が出ていた¹。

二次的利用データの匿名データも教育目的での利用が可能であるが、実際には統計法令上の制約により、多くの学生を対象にした大学での統計演習等の利用には困難が生じる場合がある。

そこで、上記の制約を受けずに使用できるデータとして、調査票情報を集計して調査票情報との関連を断ち切り、その集計表からマイクロデータの形式を持つ擬似的なデータ（以下「擬似マイクロデータ」）の作成に関する研究を、平成21年度から（独）統計センターで開始した。

本稿では、最初に全国消費実態調査の量的変数を用いた先行研究（秋山ほか(2012)）の概要を述べる。次に就業構造基本調査の質的変数を用いた擬似マイクロデータの作成方法及びその検証結果を示し、最後に今後の課題を提示する。

¹ 統計委員会（2009）及び統計委員会匿名データ部会（2009）を参照されたい。

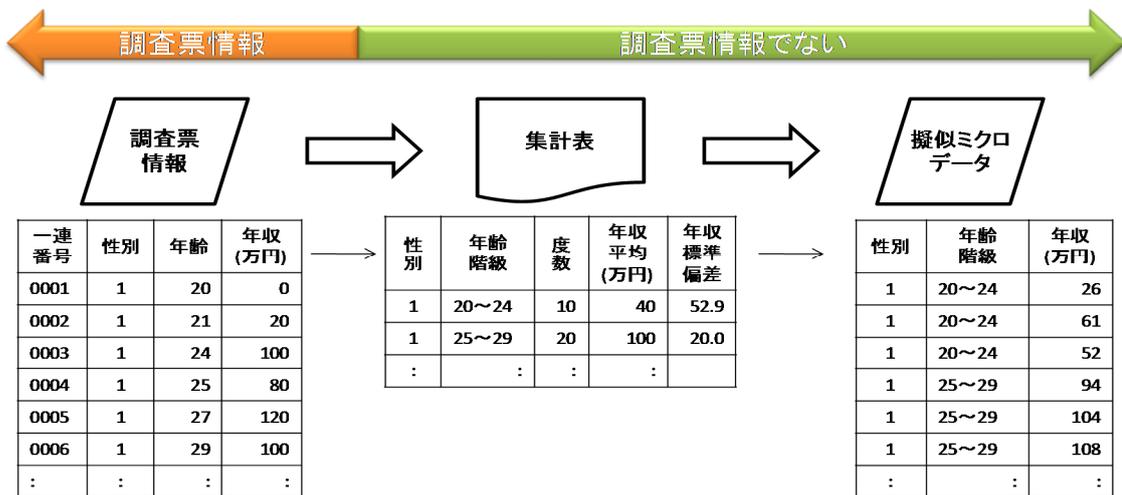
2 先行研究

2.1 量的変数の擬似マイクロデータの概要

(独)統計センターでは、欧米諸国で調査研究が進められている「マイクロアグリゲーション (micro-aggregation)」に着目するとともに、マイクロアグリゲーションの適用可能性に関する研究を行ってきた(伊藤(2008), 伊藤ほか(2008, 2009))。こうしたマイクロアグリゲーションの方法論を援用することによって、高次元にクロス集計した集計表から実データに近い分布と特性を持つ擬似的なマイクロデータの作成が可能になることから(伊藤(2008, 19頁))、この研究成果を応用する形で、平成21年度から擬似マイクロデータの作成に着手した。

擬似マイクロデータ作成の流れは、図2-1のとおり、調査票情報から集計表を作成し、この集計表から実データに近似したマイクロデータを擬似的に生成することである。

図 2-1 擬似マイクロデータ作成の基本イメージ



秋山ほか(2012)では、平成16年全国消費実態調査データの量的変数(収支項目)の統計量(平均、分散及び共分散)に基づく多変量正規乱数を発生させ、擬似的な値を生成するという方法を用いた。

作成方法の処理手順は以下のとおりである。

(1) 変数の選択

使用する変数を、使用頻度等を考慮して表 2-1 のとおり選定した。

表 2-1 全国消費実態調査の擬似マイクロデータの変数²

質的変数 14変数		量的変数 184変数	
世帯事項	世帯区分 世帯人員区分 就業人員区分 住居の構造 住居の建て方 住宅の所有関係 入居時期・入居年	年間収入	支出(総額)
		収入(総額)	実支出
世帯員事項・世帯主	性別 年齢5歳階級 就業・非就業の別 企業区分 企業規模 産業符号 職業符号	実収入 実収入以外の収入 繰入金	消費支出
			食料
			穀類
			米
			...
			住居
			...
			光熱・水道
			...
			家具・家事用品
			...
			被服及び履物
			...
			交通・通信
			...
			保健医療
			...
			教育
			...
			教養娯楽
			...
			その他の消費支出
			...
			非消費支出
			実支出以外の支出
			繰越金

² 変数の詳細は、秋山ほか(2012, 29-32 頁)を参照されたい。

(2) 集計表作成

質的変数(14変数)を用いたクロス集計表を作成し、集計表のセルの度数が2以下の場合³、質的変数が類似である組み合わせにグループ化し、度数を3以上にした。グループ内で同一でない符号は「V」または「W」に置き換えた。どのグループにも統合できないセルは削除した。

(3) 統計量の算出

量的変数のうち収支項目大分類に相当する21変数について、数値を対数変換した⁴後、平均及び分散・共分散を算出した。

(4) 多変量正規乱数の発生

平均、分散及び共分散に基づく多変量正規乱数を発生させて擬似的な値を生成した。

(5) 一部の量的変数を0に置き換え

多変量正規乱数では0は生成されないが、実データには量的変数が0のケースもあるため(例:世帯人員2名で教育費が0)、実データの0の発現パターンに基づき、一部の値を0に置き換えた。

(6) 収支バランスの調整

表2-1の支出(総額)以下に含まれる中分類(例:穀類...)及び小分類(例:米...)について、上位大分類(例:食料)の内訳の構成比を算出した上で、収支バランスを調整した。

(7) 集計用乗率の付与

集計表のセルごとに平均した集計用乗率を、各レコードに付与した。

³ 全国消費実態調査の公表結果表では度数2以下を秘匿しているため、これに準拠した。

⁴ 収支金額は、実数のままでは低い値に集中し、必ずしも正規分布に従わないため、対数正規分布に従うことを仮定した。

実データと擬似マイクロデータとを比較した結果は以下のとおりである。

(1) 基本統計量及びヒストグラム (表 2-2 及び図 2-2)

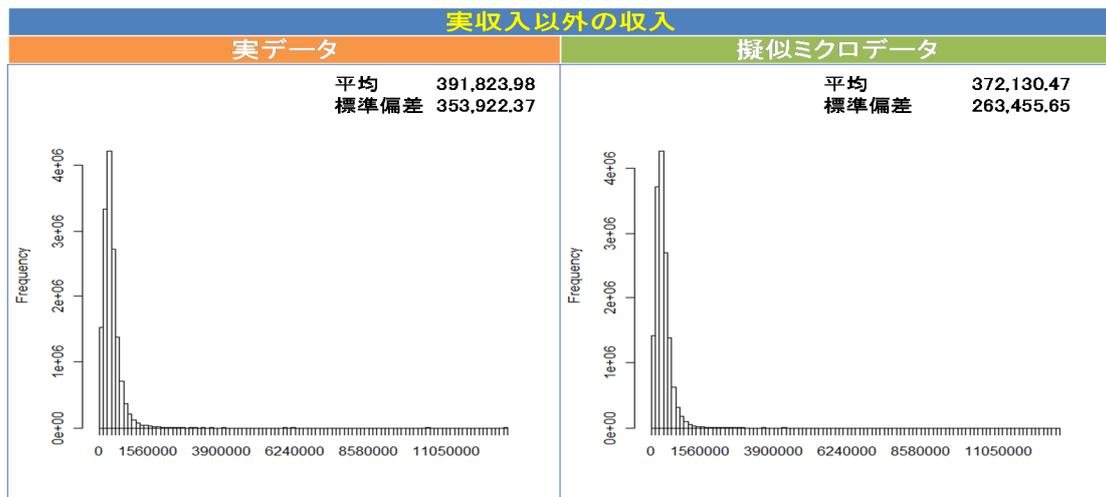
基本統計量の標準偏差では「実収入以外の収入」の差 (表 2-2 の注を参照) が最も大きかったが、「実収入以外の収入」のヒストグラムでは両者の分布形状は近似している。

表 2-2 実データと擬似マイクロデータの比較 - 基本統計量⁵

	平均				標準偏差		
	実データ	擬似マイクロデータ	差		実データ	擬似マイクロデータ	差
年間収入	740.18	729.81	-0.01	年間収入	358.18	337.69	-0.06
収入総額	971,789.24	946,779.03	-0.03	収入総額	541,290.74	473,480.73	-0.13
実収入	502,133.73	497,655.92	-0.01	実収入	280,695.92	261,558.27	-0.07
実収入以外の収入	391,823.98	372,130.47	-0.05	実収入以外の収入	353,922.37	263,445.65	-0.26
繰入金	77,831.53	76,992.65	-0.01	繰入金	87,036.21	98,947.04	0.14
支出総額	971,789.24	946,779.03	-0.03	支出総額	541,290.74	473,480.73	-0.13
実支出	415,809.39	403,746.63	-0.03	実支出	224,419.69	219,290.60	-0.02
消費支出	339,199.37	328,139.70	-0.03	消費支出	194,501.15	192,447.21	-0.01
食料	73,738.54	72,883.42	-0.01	食料	30,149.02	28,064.49	-0.07
住居	19,387.99	17,687.21	-0.09	住居	52,962.36	60,587.32	0.14
光熱・水道	19,395.36	19,237.81	-0.01	光熱・水道	8,009.23	7,690.12	-0.04
家具・家事用品	9,783.81	9,204.04	-0.06	家具・家事用品	15,977.65	14,933.13	-0.07
被服及び履物	14,649.44	14,137.63	-0.03	被服及び履物	18,837.04	19,823.09	0.05
保健医療	11,936.01	11,366.36	-0.05	保健医療	19,763.39	19,284.07	-0.02
交通・通信	50,740.68	47,960.92	-0.05	交通・通信	85,021.69	84,654.38	0.00
教育	22,332.15	22,269.65	0.00	教育	51,989.72	64,157.45	0.23
教養娯楽	32,472.95	31,389.49	-0.03	教養娯楽	32,161.60	32,723.04	0.02
その他の消費支出	84,762.44	82,003.18	-0.03	その他の消費支出	95,898.83	102,040.97	0.06
非消費支出	76,610.02	75,606.93	-0.01	非消費支出	56,199.75	66,378.49	0.18
実支出以外の支出	475,947.80	464,318.09	-0.02	実支出以外の支出	394,805.29	334,227.09	-0.15
繰越金	80,032.04	78,714.31	-0.02	繰越金	96,421.45	118,055.82	0.22

注 集計表作成段階で、度数 2 以下のセルを削除しているため、本表の実データの数値は公表結果表とは一致しない。また、本表の「差」の計算式は「(擬似マイクロデータ - 実データ) / 実データ」である。

図 2-2 実データと擬似マイクロデータの比較 - ヒストグラム⁶



⁵ 秋山ほか (2012, 20 頁, 表 4-1)

⁶ 秋山ほか (2012, 21 頁, 図 4-1)

(2) 相関係数及び散布図 (表 2-3、表 2-4 及び図 2-3)

図 2-3 は、実データと擬似マイクロデータの相関係数の差が最も大きい「年間収入」×「非消費支出」の散布図である。

多変量正規乱数発生の際に実データより大きく外れた値が出現したため、相関係数に 0.20 の差が生じているが、散布図の分布形状は両者とも右上がり近似している。

表 2-3 実データの相関係数⁷

	年間収入	収入総額	実収入	実収入以外の収入	繰入金	支出総額	実支出	消費支出	食料	住居	光熱・水道	家具・家事用品	被服及び履物	保健医療	交通・通信	教育	教養娯楽	その他の消費支出	非消費支出	実支出以外の支出	繰越金	
年間収入	1.00																					
収入総額	0.60	1.00																				
実収入	0.66	0.78	1.00																			
実収入以外の収入	0.35	0.85	0.36	1.00																		
繰入金	0.19	0.26	0.14	0.04	1.00																	
支出総額	0.60	1.00	0.78	0.85	0.26	1.00																
実支出	0.60	0.73	0.56	0.63	0.17	0.73	1.00															
消費支出	0.49	0.66	0.45	0.61	0.16	0.66	0.97	1.00														
食料	0.47	0.42	0.37	0.31	0.17	0.42	0.52	0.50	1.00													
住居	-0.02	0.11	0.00	0.16	0.01	0.11	0.24	0.28	-0.03	1.00												
光熱・水道	0.32	0.24	0.22	0.16	0.11	0.24	0.28	0.27	0.44	-0.07	1.00											
家具・家事用品	0.15	0.25	0.12	0.26	0.09	0.25	0.26	0.27	0.17	0.07	0.10	1.00										
被服及び履物	0.30	0.30	0.24	0.24	0.10	0.30	0.39	0.38	0.29	0.02	0.12	0.16	1.00									
保健医療	0.11	0.16	0.10	0.15	0.07	0.16	0.24	0.25	0.15	0.01	0.07	0.08	0.09	1.00								
交通・通信	0.14	0.33	0.15	0.37	0.04	0.33	0.54	0.57	0.12	0.01	0.05	0.05	0.10	0.06	1.00							
教育	0.18	0.23	0.15	0.23	0.03	0.23	0.37	0.39	0.24	-0.03	0.19	0.02	0.09	0.04	0.07	1.00						
教養娯楽	0.32	0.35	0.27	0.30	0.12	0.35	0.44	0.42	0.32	0.02	0.10	0.15	0.26	0.10	0.10	0.09	1.00					
その他の消費支出	0.39	0.46	0.38	0.37	0.12	0.46	0.66	0.66	0.21	0.01	0.13	0.12	0.19	0.11	0.12	0.04	0.16	1.00				
非消費支出	0.70	0.63	0.70	0.38	0.12	0.63	0.62	0.43	0.35	-0.02	0.19	0.12	0.26	0.08	0.17	0.14	0.29	0.34	1.00			
実支出以外の支出	0.44	0.90	0.72	0.79	0.04	0.90	0.40	0.32	0.25	0.01	0.14	0.18	0.17	0.08	0.14	0.11	0.22	0.23	0.49	1.00		
繰越金	0.16	0.24	0.13	0.06	0.86	0.24	0.13	0.12	0.13	0.02	0.10	0.07	0.07	0.05	0.02	0.02	0.08	0.10	0.10	0.01	1.00	

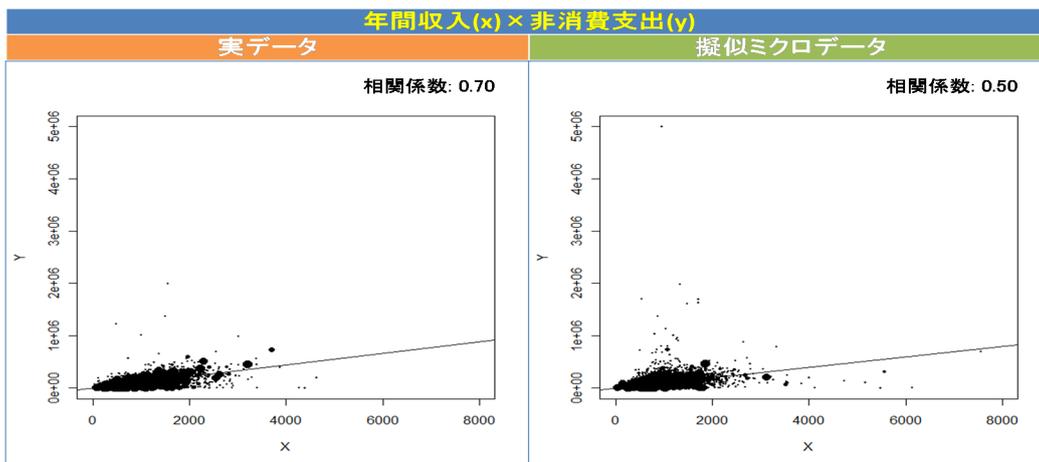
表 2-4 擬似マイクロデータの相関係数⁸

	年間収入	収入総額	実収入	実収入以外の収入	繰入金	支出総額	実支出	消費支出	食料	住居	光熱・水道	家具・家事用品	被服及び履物	保健医療	交通・通信	教育	教養娯楽	その他の消費支出	非消費支出	実支出以外の支出	繰越金	
年間収入	1.00																					
収入総額	0.58	1.00																				
実収入	0.63	0.85	1.00																			
実収入以外の収入	0.38	0.83	0.48	1.00																		
繰入金	0.12	0.32	0.15	0.05	1.00																	
支出総額	0.58	1.00	0.85	0.83	0.32	1.00																
実支出	0.52	0.71	0.59	0.64	0.14	0.71	1.00															
消費支出	0.42	0.63	0.49	0.60	0.14	0.63	0.96	1.00														
食料	0.46	0.40	0.36	0.32	0.13	0.40	0.45	0.43	1.00													
住居	-0.05	0.08	0.04	0.09	0.03	0.08	0.24	0.28	-0.06	1.00												
光熱・水道	0.32	0.25	0.23	0.18	0.09	0.25	0.26	0.25	0.44	-0.07	1.00											
家具・家事用品	0.12	0.15	0.11	0.14	0.04	0.15	0.19	0.19	0.15	0.00	0.10	1.00										
被服及び履物	0.21	0.23	0.19	0.20	0.06	0.23	0.29	0.28	0.20	0.01	0.08	0.12	1.00									
保健医療	0.07	0.13	0.09	0.13	0.04	0.13	0.19	0.20	0.11	0.00	0.06	0.05	0.05	1.00								
交通・通信	0.12	0.30	0.17	0.35	0.04	0.30	0.50	0.54	0.10	-0.01	0.05	0.03	0.06	0.04	1.00							
教育	0.14	0.24	0.18	0.24	0.02	0.24	0.38	0.41	0.18	-0.02	0.16	0.01	0.04	0.02	0.04	1.00						
教養娯楽	0.26	0.30	0.24	0.28	0.06	0.30	0.35	0.34	0.26	-0.01	0.06	0.12	0.18	0.07	0.07	0.05	1.00					
その他の消費支出	0.33	0.44	0.38	0.37	0.11	0.44	0.63	0.65	0.17	-0.02	0.11	0.07	0.11	0.06	0.09	0.04	0.10	1.00				
非消費支出	0.50	0.50	0.52	0.35	0.07	0.50	0.53	0.26	0.24	-0.04	0.14	0.07	0.14	0.05	0.09	0.07	0.18	0.21	1.00			
実支出以外の支出	0.45	0.85	0.77	0.74	0.07	0.85	0.32	0.25	0.25	-0.05	0.15	0.08	0.13	0.05	0.09	0.09	0.18	0.18	0.35	1.00		
繰越金	0.10	0.28	0.14	0.05	0.82	0.28	0.07	0.07	0.09	0.00	0.08	0.03	0.03	0.02	0.01	0.00	0.02	0.06	0.04	0.00	1.00	

⁷ 秋山ほか (2012, 22 頁, 表 4-2)

⁸ 秋山ほか (2012, 22 頁, 表 4-3)

図 2-3 実データと擬似マイクロデータの比較 - 散布図⁹



⁹ 秋山ほか (2012, 23 頁, 図 4-2)

2.2 量的変数の擬似マイクロデータの提供

平成16年全国消費実態調査の擬似マイクロデータは、平成23年8月より統計センターホームページ経由で一般への試行提供を開始した。平成24年度から、利用者の要望に応えレコード数及び変数を少なくした簡易データを追加し、現在は表2-5の仕様で試行提供中である。

表 2-5 試行提供中の擬似マイクロデータ

平成16年全国消費実態調査(平成23年度より試行提供開始) http://www.nstac.go.jp/services/giji-microdata.html					
	レコード数	収録項目	収録項目の内訳		
			世帯属性等	支出項目	収入項目
大規模データ (CSV形式)	約3万2千 二人以上の 勤労者世帯	197項目	14項目	149項目 用途分類	34項目 年間収入等
簡易データ (CSV形式 Excel形式)	約8千 世帯人員が4名で 有業人員が 1~2人の世帯のみ	25項目	世帯主の年齢、 住居の種類など	11項目 消費支出及 び十大費目 のみ	なし

3 質的変数の擬似マイクロデータに関する作成方法

先行研究で作成した擬似マイクロデータの試行提供後、多くの利用者から、質的変数への対象拡大の要望が寄せられた。しかしながら、質的変数は量的変数と異なり、平均や分散に基づく乱数発生が困難であったため、最初に平成16年全国消費実態調査の質的変数で加工方法を試行した後（別添1参照）平成14年就業構造基本調査のデータを用いて、質的変数の擬似マイクロデータの作成方法の検証を行った。

なお、本章の検証に用いたプログラム言語は、Microsoft Excel の Visual Basic for Applications 及び R である。

3.1 多変量正規乱数及び一様乱数の検証

最初に、第2章で述べた多変量正規乱数及び集計表セル度数の出現確率に基づく一様乱数（以後「一様乱数」と略す。）による作成方法を検証することとした。

3.1.1 使用したデータ及び変数

使用したデータは、平成14年就業構造基本調査¹⁰（968,628レコード）の「世帯主有業者」¹¹281,489レコードである。変数は、公表結果表での使用頻度、調査項目の利用状況等を考慮し、表3-1のとおり選定した¹²。

表 3-1 使用した変数

集計表使用変数 (15変数)		乱数発生変数 (2変数)
基本変数(8変数)	加工対象変数(7変数)	個人所得 継続就業期間
性別 配偶者の有無 続き柄 教育(教育区分) 教育(学校区分) 年齢(5歳階級) 1年前との就業異動 前職の有無	従業上の地位(5区分) 雇用形態 産業(大分類) 職業(大分類) 従業者規模 年間就業日数 週間就業時間	

基本変数： 集計表使用変数のうち、公表結果表における頻度の高い変数。集計表の度数2以下の際に符号の置き換えを行わない。

加工対象変数： 集計表使用変数のうち、基本変数以外の変数。集計表の度数2以下の際に符号の置き換え対象となる。

乱数発生変数： 集計表には使用せず、集計表作成後に多変量正規乱数及び一様乱数を発生させる変数。

¹⁰ 平成19年データの使用も検討したが、当該年次は匿名データが未作成である。

¹¹ 全国消費実態調査における擬似マイクロデータの作成手法の適用可能性を検証するため、対象レコードも全国消費実態調査のデータ形式（世帯単位）に合わせ、世帯主有業者のみとした。

¹² 各変数における符号については、別添2を参照されたい。

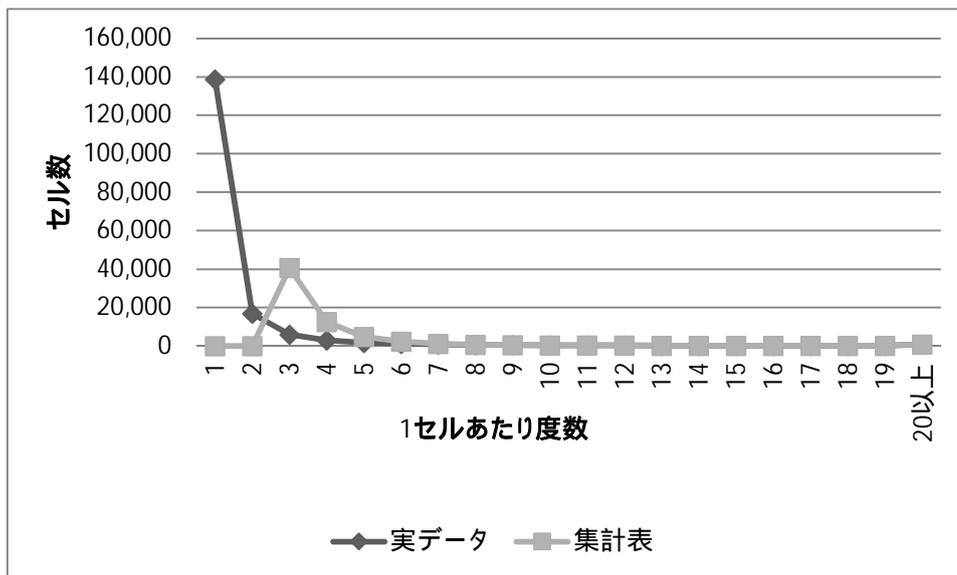
3.1.2 集計表作成

集計表使用変数（15変数）のクロス集計表を作成し、集計表のセルの度数が2以下の場合、質的変数が類似である組み合わせにグループ化し、度数を3以上にした。グループ内で同一でない符号は「V」または「W」に置き換えた。どのグループにも統合できないレコードは削除した。

不詳置き換えの優先順位は、各変数の秘匿性を考慮し、週間就業時間、年間就業日数、従業者規模、職業（大分類）、産業（大分類）、雇用形態、従業上の地位（5区分）の順番とした。

集計の結果、実データで171,130であった集計セル数は64,976に減少した。また、1セルあたり度数は、実データの約61.2%を占めていた度数2以下のセルが全て度数3～14となった（図3-1参照）。どのグループにも統合できず削除されたレコードは、281,489レコード中2,139レコード（約0.8%）であった。

図 3-1 集計表作成によるセル数及び1セルあたり度数の変化



3.1.3 乱数発生方法

「個人所得」及び「継続就業期間」¹³について、次の2つの方法で乱数を発生させた。

(1) 多変量正規乱数

量的変数の平均、分散及び共分散に基づく多変量正規乱数を発生させ擬似的な値を生成する方法で、処理手順は以下のとおりである¹⁴。

個人所得の区分を、量的変数(中央値)に変換し、対数変換を行った¹⁵。

継続就業期間の区分を、量的変数(月値)に変換し、対数変換を行った¹⁶。

及び の数値に対し、集計表のセルごとに平均、分散及び共分散を算出し、これらに基づく多変量正規乱数を発生させた。

乱数は対数の状態であるため、実数に戻した後、区分へ対応させた。

(2) 一様乱数

集計表セル度数の出現確率に基づく一様乱数を発生させる方法で、処理手順は以下のとおりである。なお、作成イメージについては別添3-1を参照されたい。

実データの集計表から、各セルの度数の出現確率を算出した。

の出現確率を累積確率に変換した。

0~1の一様乱数を発生させて の累積確率と照合し、該当する変数組み合わせの擬似レコードを生成した。この処理を実データのレコード分繰り返した。

の擬似レコードを変数組み合わせ順にソートし、擬似マイクロデータを完成させた。

¹³ 各変数における符号については、別添2を参照されたい。

¹⁴ 両変数とも、符号「不詳」については量的変数への変換を行っていない。

¹⁵ 個人所得は、実数のままでは低い値に集中し、必ずしも正規分布に従わないため、対数正規分布に従うことを仮定した。

¹⁶ 継続就業期間は、実数のままでは高い値に集中し、必ずしも正規分布に従わないため、対数正規分布に従うことを仮定した。

3.1.4 検証結果

3.1.3 で作成した擬似マイクロデータの「個人所得」及び「継続就業期間」について、実データとの比較検証を行った¹⁷。

(1) クロス集計表

自営業主と雇用者¹⁸、前職ありと前職なし¹⁹の区分を追加し、クロス集計表を作成したところ、図 3-2 及び図 3-3 の棒グラフ及び折れ線グラフのとおり、一様乱数の方が多変量正規乱数に比べて実データにより近似した。

< グラフの凡例 >



図 3-2 個人所得 自営業主×前職あり(上) 自営業主×前職なし(下)

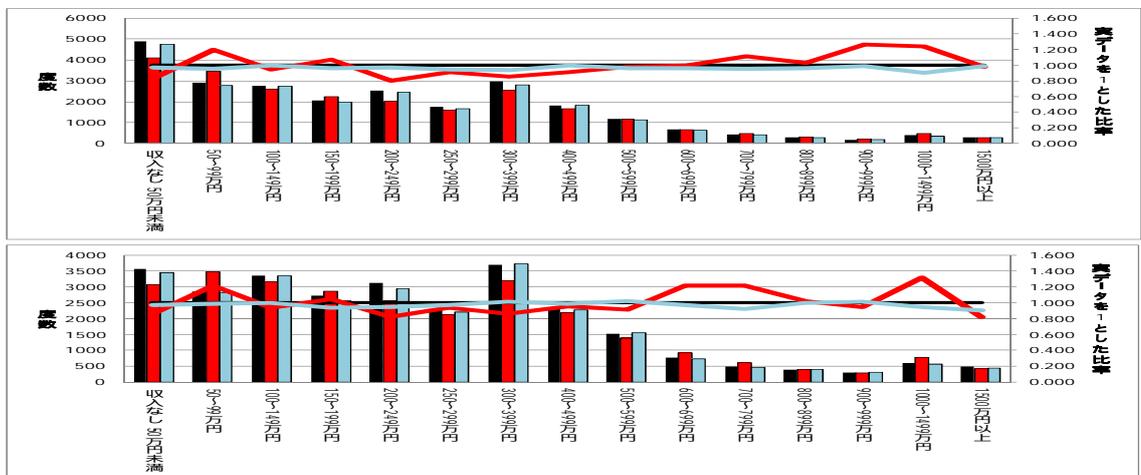
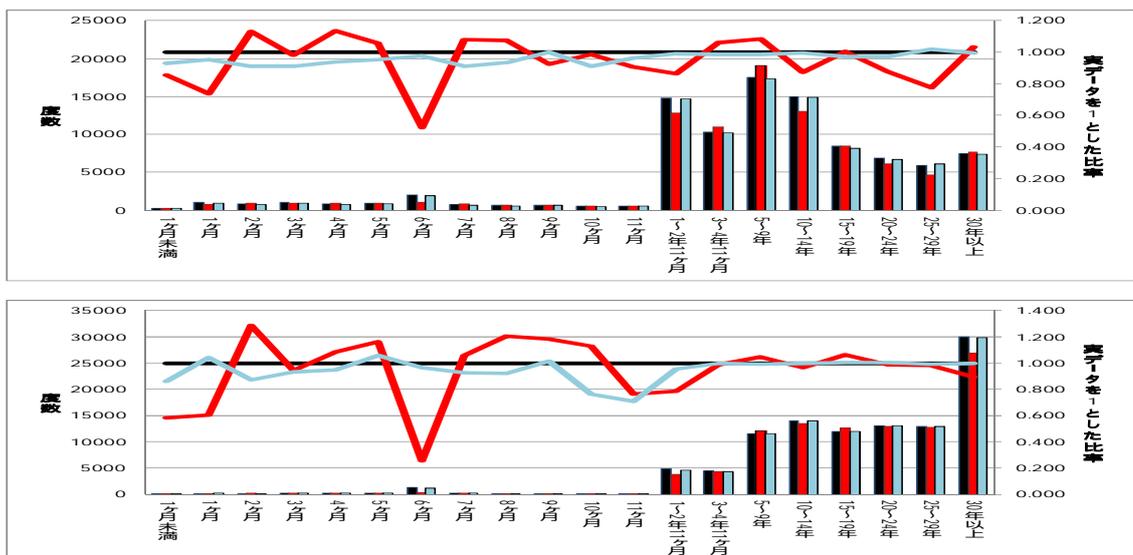


図 3-3 継続就業期間 雇用者×前職あり(上) 雇用者×前職なし(下)



¹⁷ 個人所得は「不詳」、継続就業期間は「不詳」及び「1年未満(月不詳)」を除いた結果である。

¹⁸ 従業上の地位における「1：内職者以外の自営業主」「4：民間の役員・常雇」をそれぞれ指す。

¹⁹ 前職の有無における「2：あり」と「1：なし」をそれぞれ指す。

(2) カイ二乗検定

実データ及び擬似マイクロデータの個人所得及び継続就業期間のクロス集計表について、帰無仮説を「両データの分布に差がない」と設定し、独立性のカイ二乗検定²⁰を行った結果、表 3-2 のとおり、実データ×多変量正規乱数の p 値はすべて 0.05 未満で有意差が認められたが、実データ×一様乱数の p 値は、「雇業者×前職あり」「自営業主×前職あり」を除き 0.05 以上で有意差が認められなかった。

表 3-2 独立性のカイ二乗検定

検定対象変数		実データ×多変量正規乱数			実データ×一様乱数		
		カイ二乗統計量	自由度	p値	カイ二乗統計量	自由度	p値
個人所得	自営業主×前職あり	219.0766	14	< 2.2e-16	4.8401	14	0.9879
	自営業主×前職なし	250.2059	14	< 2.2e-16	11.3582	14	0.6577
	雇業者×前職あり	222.7423	14	< 2.2e-16	32.9551	14	0.0029
	雇業者×前職なし	397.8419	14	< 2.2e-16	19.3856	14	0.1507
継続就業期間	自営業主×前職あり	240.5263	19	< 2.2e-16	23.0714	19	0.2342
	自営業主×前職なし	167.3398	19	< 2.2e-16	37.7853	19	0.0063
	雇業者×前職あり	830.5278	19	< 2.2e-16	18.6413	19	0.4801
	雇業者×前職なし	838.8219	19	< 2.2e-16	14.8047	19	0.7349

以上の検証結果から、一様乱数の方が多変量正規乱数よりも実データの分布をよりよく再現すると判断し、以後の検証は一様乱数に絞って進めることとした。

²⁰ クロス集計表の各セルで、擬似マイクロデータの度数を x^i 、実データの度数を e^i とすると、独立性のカイ二乗統計量は $\sum_{i=1}^n (x^i - e^i)^2 / e^i$ となる。本稿の検定結果によれば、サンプルサイズ (n) が大きいいため検出力が強くなっている可能性があるものの、p 値が 0.05 未満であることから、有意差がある (帰無仮説を棄却) と判断することができる。

3.2 集計用乗率を考慮した一様乱数の検証

作成方法の評価を正確に行うためには公表結果表との比較が必要であるため、使用するデータを「有業者」に拡大するとともに、乱数発生の際に集計用乗率を考慮し、公表結果表との比較検証を行った。

3.2.1 使用したデータ及び変数

平成 14 年就業基本構造調査 (968,628 レコード) のうち「有業者」567,699 レコードを用い、変数を表 3-3 のとおり設定した²¹。

表 3-3 使用した変数

集計用使用変数 (15 変数)	
基本変数 (8 変数)	加工対象変数 (7 変数)
性別 配偶者の有無 続き柄 教育 (教育区分) 教育 (学校区分) 年齢 (5 歳階級) 1 年前との就業異動 前職の有無	従業上の地位 (5 区分) 雇用形態 産業 (大分類) 職業 (大分類) 従業者規模 年間就業日数 週間就業時間

基本変数： 集計表使用変数のうち、公表結果表における頻度の高い変数。
集計表の度数 2 以下の際に符号の置き換えを行わない。

加工対象変数： 集計表使用変数のうち、基本変数以外の変数。
集計表の度数 2 以下の際に符号の置き換え対象となる。

²¹ 各変数における符号については、別添 2 を参照されたい。

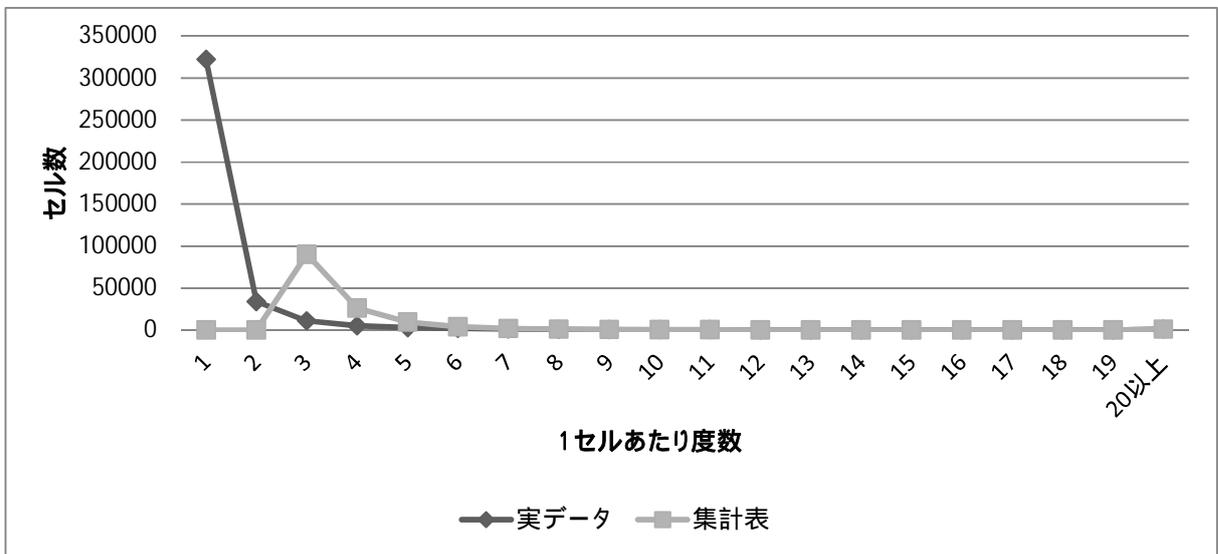
3.2.2 集計表作成

集計表使用変数（15変数）を用いて、集計表のセルの度数が2以下の場合、質的変数が類似である組み合わせにグループ化し、度数を3以上にした。グループ内で同一でない符号は「V」または「W」に置き換えた。どのグループにも統合できないレコードは削除した。

不詳置き換えの優先順位は、各変数の秘匿性を考慮し、週間就業時間、年間就業日数、従業者規模、職業（大分類）、産業（大分類）、雇用形態、従業上の地位（5区分）の順番とした。

集計の結果、実データで383,837であった集計セル数は138,120に減少した。1セルあたり度数は、図3-4のとおり、実データの68.7%を占めていた度数2以下のセルが全て度数3～13となった（図3-4参照）。どのグループにも統合できず削除されたレコードは、567,699レコード中12,032レコード（約2.1%）であった。

図 3-4 集計表作成によるセル数及び1セルあたり度数の変化



3.2.3 乱数発生方法

3.1.3の方法を応用し、集計用乗率を考慮した一様乱数を発生させた。処理手順は表3-4の左列のとおりである。作成イメージについては別添3-2を参照されたい。

なお、3.1.3の検証では変数を固定せずに一様乱数発生を行ったが、本章の検証では、公表結果表の分布を再現する目的から、基本変数を固定して一様乱数発生を行った。詳細は別添4を参照されたい。

表 3-4 一様乱数による乱数発生方法

集計表乗率を考慮した一様乱数	(参考)度数に基づく一様乱数 (3.1.3(2)記載)
実データに基づいたクロス集計表から、各セルの集計表乗率合計の出現確率を算出した。	実データに基づいたクロス集計表から、各セルの度数の出現確率を算出した
の出現確率を累積確率に変換した。	の出現確率を累積確率に変換した。
0~1の一様乱数を発生させての累積確率と照合し、該当する変数組み合わせの擬似レコードを生成した。この処理を実データの乗率合計分繰り返した。	0~1の一様乱数を発生させての累積確率と照合し、該当する変数組み合わせの擬似レコードを生成した。この処理を実データのレコード分繰り返した。
のレコードを再集計した。(乱数発生後のため、の集計表とは集計表乗率合計が異なる)	-
の集計表の各セルを複数レコードに分割した。その際、データセット全体のレコード数が実データのレコード数と一致し、かつ各レコードの集計表乗率がセルの集計表乗率合計と一致するように分割した。	-
擬似レコードを変数組み合わせ順にソートし、擬似マイクロデータを完成させた。	擬似レコードを変数組み合わせ順にソートし、擬似マイクロデータを完成させた。

3.2.4 検証結果

以下の変数について、公表結果表、集計表及び乱数発生結果の比較検証を行った²²。

産業（公表結果表第 18 表(報告書第 9 表)と比較）

週間就業時間（うち雇業者・男・200 日未満就業者・うち規則的就業）

（公表結果表第 40 表(報告書第 18 表)と比較）

乱数発生結果をより正確に評価するため、乱数発生回数 3 回、20 回、100 回の平均度数も参考値として算出し、併せて検証を行った。

産業の度数は、表 3-5 のとおり、公表結果表と集計表には差が認められたが、一様乱数については乱数発生回数を増やすほど集計表に近似した。

次に、表 3-5 の公表結果表と集計表、集計表と一様乱数について、帰無仮説を「両データの分布に差がない」と設定し、独立性のカイ二乗検定を行ったところ、表 3-6 のとおり、前者は p 値が 0.05 未満で有意差が認められたが、後者は p 値が 0.7 を上回り、有意差が認められなかった。

表 3-5 産業別有業者数

産業	公表結果表	集計表	一様乱数発生			
			1回	(参考)		
			3回平均	20回平均	100回平均	
農業	2,703,700	2,340,100	2,339,700	2,338,000	2,339,700	2,340,000
林業	58,500	12,800	12,800	12,800	12,800	12,800
漁業	265,500	158,000	158,000	158,100	158,100	158,100
鉱業	40,100	7,300	7,500	7,300	7,300	7,300
建設業	6,086,100	4,903,700	4,902,600	4,904,100	4,904,400	4,904,000
製造業	12,202,000	10,564,100	10,568,500	10,563,500	10,564,700	10,564,100
電気・ガス・熱供給・水道業	376,800	247,300	247,100	247,100	247,000	247,200
情報通信業	1,766,100	1,062,900	1,062,200	1,062,200	1,062,900	1,062,900
運輸業	3,327,300	2,380,900	2,382,000	2,382,200	2,381,300	2,380,900
卸売・小売業	11,699,200	9,775,400	9,774,000	9,776,200	9,774,600	9,775,000
金融・保険業	1,781,300	1,251,600	1,251,900	1,251,900	1,251,900	1,251,800
不動産業	916,200	377,400	377,000	377,200	377,500	377,500
飲食店、宿泊業	3,632,000	2,544,200	2,545,400	2,546,400	2,544,700	2,544,400
医療、福祉	4,891,700	3,867,900	3,868,300	3,868,100	3,867,500	3,867,800
教育、学習支援業	2,826,400	2,067,800	2,069,800	2,068,800	2,068,100	2,068,100
複合サービス事業	769,200	477,200	476,500	476,700	477,000	477,200
サービス業(他に分類されないもの)	8,460,200	6,321,300	6,322,300	6,320,200	6,321,100	6,321,100
公務(他に分類されないもの)	2,174,000	1,923,400	1,922,200	1,924,100	1,923,500	1,923,300
(集計表 - 一様乱数)の絶対値の和			16,700	12,400	5,400	2,200

表 3-6 独立性のカイ二乗検定

検定対象データ		公表結果表			集計表		
		カイ二乗統計量	自由度	p値	カイ二乗統計量	自由度	p値
集計表		613715.2	17	<2.2e-16			
一様乱数発生 (参考)	1回	613818.1	17	<2.2e-16	13.5261	17	0.7003
	3回平均	613396.4	17	<2.2e-16	6.9057	17	0.9847
	20回平均	613475.6	17	<2.2e-16	1.1264	17	1
	100回平均	613412.6	17	<2.2e-16	0.2737	17	1

²² 公表結果表と集計表については、集計表作成時の不詳置き換え処理の影響で数値の差が生じている。詳細は別添 5 を参照されたい。

週間就業時間(うち雇業者・男・200日未満就業者・うち規則的就業)の度数は、表3-7のとおり、公表結果表と集計表に差が認められたが、一様乱数については乱数発生回数を増やすほど集計表に近似した。

次に、表3-7の公表結果表と集計表、集計表と一様乱数について、帰無仮説を「両データの分布に差がない」と設定し、独立性のカイ二乗検定を行ったところ、表3-8のとおり、前者はp値が0.05未満で有意差が認められたが、後者は、乱数発生回数3回平均以上でp値が0.8を上回り、有意差が認められなかった。

表 3-7 週間就業時間「うち雇業者・男・200日未満就業者・うち規則的就業」別有業者数

週間就業時間	公表結果表	集計表	一様乱数発生			
			1回	(参考)		
			3回平均	20回平均	100回平均	
15時間未満	300,700	38,400	38,400	38,400	38,400	38,400
15～19時間	224,800	21,900	21,900	21,900	21,900	21,900
20～21時間	147,700	5,600	5,700	5,600	5,600	5,600
22～29時間	286,000	28,000	28,000	28,000	28,000	28,000
30～34時間	264,800	20,200	20,400	20,200	20,200	20,200
35～42時間	771,600	186,900	186,400	186,900	186,800	186,900
43～45時間	258,800	17,900	18,300	18,200	18,000	17,900
46～48時間	252,000	25,000	24,700	24,900	25,000	24,900
49～59時間	206,900	11,500	11,500	11,500	11,500	11,500
60時間以上	139,200	7,100	6,900	7,100	7,100	7,100
(集計表 - 一様乱数)の絶対値の和			1,700	400	200	100

表 3-8 独立性のカイ二乗検定

検定対象データ		公表結果表			集計表		
		カイ二乗統計量	自由度	p値	カイ二乗統計量	自由度	p値
集計表		121622.3	9	<2.2e-16			
一様乱数発生 (参考)	1回	120536.2	9	<2.2e-16	23.0467	9	0.006092
	3回平均	121328.7	9	<2.2e-16	5.3147	9	0.8061
	20回平均	121350.3	9	<2.2e-16	0.6122	9	0.9999
	100回平均	121700.0	9	<2.2e-16	0.3725	9	1

以上の検証において、公表結果表と集計表の分布には差が見られたが、集計表と一様乱数の分布の差は小さく乱数発生回数の増加に従い近似度が増すことがわかった。

従って、一様乱数は、集計用乗率を考慮した分布再現にも有効であると言える。

4 おわりに - 結論及び課題 -

質的変数の擬似マイクロデータ作成に関する検証の結果、集計表セル度数の出現確率に基づく一様乱数は、実データ分布に概ね近似しており、集計用乗率を考慮した分布へも適用可能であることが明らかになった。

先行研究の量的変数の擬似マイクロデータ作成に関する研究成果に続き、質的変数の擬似マイクロデータ作成の研究において成果が得られたことは、他の調査への応用も可能となることから、擬似マイクロデータの作成方法について進展があったと考える。

今後の課題は集計表の作成方法の改善である。本研究では、度数2以下のセルに対する不詳置き換えにより分布再現性が低下する傾向が見られた。このため、区分統合、リコーディング及び乗率による度数調整といった不詳置き換え以外の方法を用いた擬似マイクロデータの作成可能性の検討を、さらに進める必要があると考える。

別添 1 質的変数の加工方法

本文第 3 章における検証の前に試行した、平成 16 年全国消費実態調査を用いた質的変数の加工方法は、以下のとおりである。

集計表セル度数の出現確率に基づく一様乱数を発生

集計表の各セルの度数の、全度数における割合（出現確率）を求め、その確率に基づく一様乱数を発生させて度数を加工する方法である。

集計表の度数に加法ノイズを付加

集計表の度数に加法ノイズを付加して、その合計がプラスマイナスゼロになるよう調整する方法である。

集計表の度数 2 以下を度数 3 へ丸め

集計表の度数 2 以下のレコードを度数 3 に増加させた後に集計表乗率を変更し、度数分布を調整する方法である。

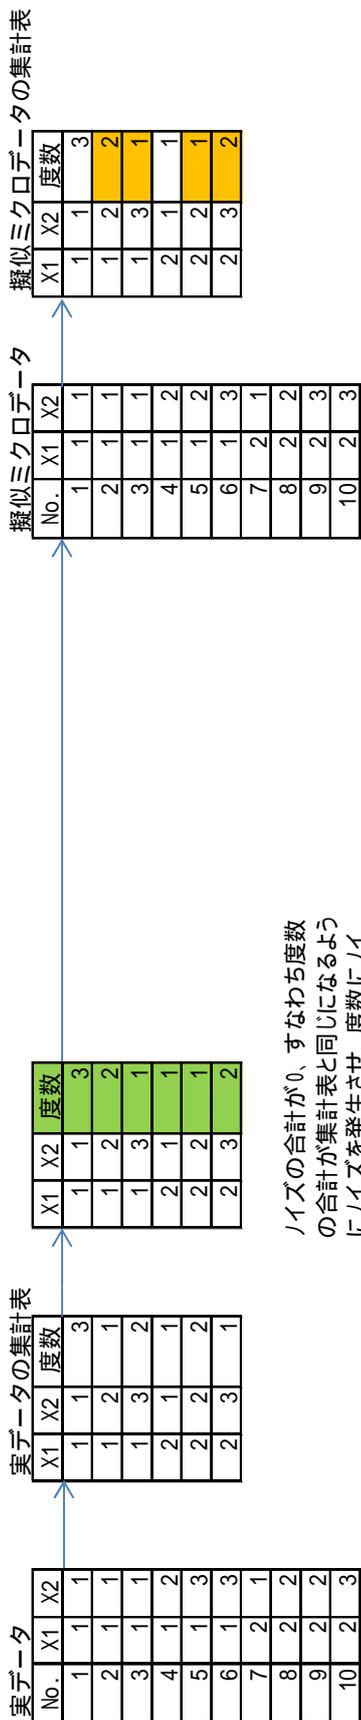
集計表の周辺分布の再現

集計表を 2 つに分割し、そのうち 1 つの集計表にレコード数分の乱数を付与して乱数順にソートしてから、もう一方の集計表と合体する方法である。

上記の各方法を、手順の容易さ及び生成結果の安定性等で検討した結果、 の「集計表の出現確率に基づく乱数を発生させる」方法を、就業構造基本調査を用いた質的変数の擬似マイクロデータの作成研究に用いることとした。

～ の加工イメージは以下のとおりである。

集計表の度数に加法ノイズを付加



ノイズの合計が0、すなわち度数の合計が集計表と同じになるようにノイズを発生させ、度数にノイズを付加する。

集計表の度数 2 以下を度数 3 に丸め

実データ

No.	X1	X2
1	1	1
2	1	1
3	1	1
4	1	2
5	1	3
6	1	3
7	2	1
8	2	2
9	2	2
10	2	3

実データの集計表

X1	X2	度数
1	1	3
1	2	1
1	3	2
2	1	1
2	2	2
2	3	1

X1	X2	度数
1	1	3
1	2	3
1	3	3
2	1	3
2	2	3
2	3	3

度数 1、2 について、
度数 3 にする。

擬似マイクロデータ

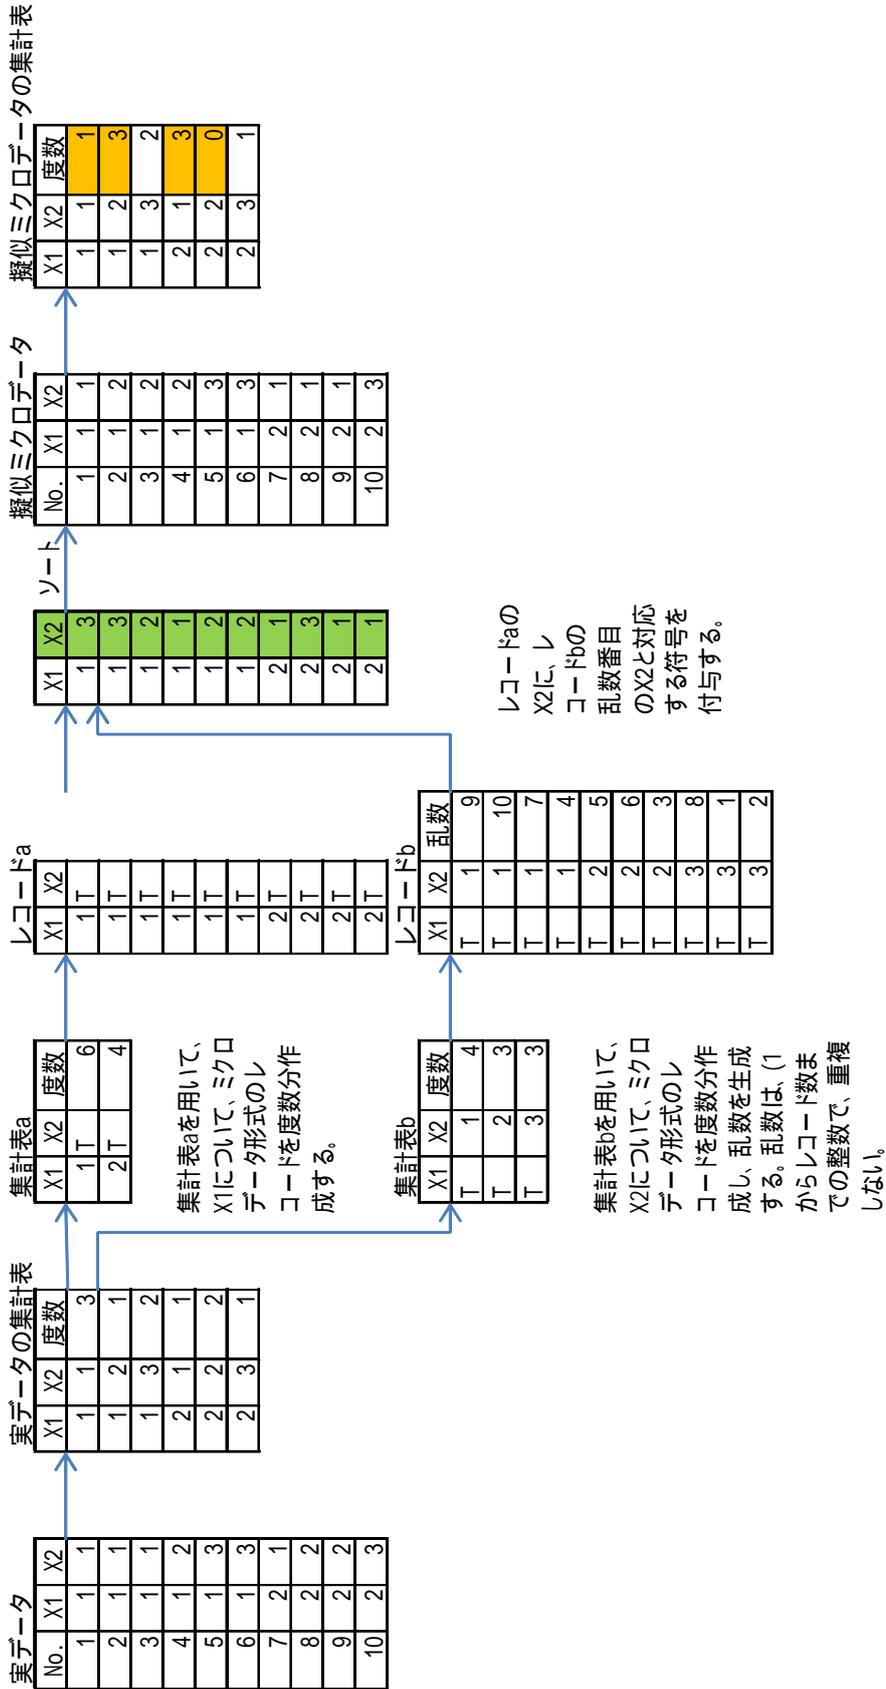
No.	X1	X2
1	1	1
2	1	1
3	1	1
4	1	1
5	1	2
6	1	2
7	1	3
8	1	3
9	1	3
10	2	1
11	2	1
12	2	1
13	2	2
14	2	2
15	2	2
16	2	3
17	2	3
18	2	3

擬似マイクロデータの集計表

X1	X2	度数
1	1	3
1	2	3
1	3	3
2	1	3
2	2	3
2	3	3

この後に、集計乗
率で適宜調整すれば、
実データに近似する。

集計表の周辺分布の再現



別添 2 擬似マイクロデータの符号表

基本変数

項目名	対象	符号	符号内容
性別		1	男
		2	女
配偶者の有無		1	配偶者あり
		2	配偶者なし
		V	不詳
続き柄		01	世帯主
		02	世帯主の配偶者
		03	子及び子の配偶者
		04	世帯主の父母及び世帯主の配偶者の父母
		05	その他
		VV	不詳
(教育)教育区分		1	在学中
		2	卒業
		3	在学したことがない
		V	不詳
		V	不詳
(教育)学校区分	教育区分が1, 2	1	小学・中学
		2	高校・旧制中
		3	短大・高専
		4	大学・大学院
		V	不詳
(年齢)5歳階級		01	15～19歳
		02	20～24歳
		03	25～29歳
		04	30～34歳
		05	35～39歳
		06	40～44歳
		07	45～49歳
		08	50～54歳
		09	55～59歳
		10	60～64歳
		11	65～69歳
		12	70～74歳
		13	75歳以上
1年前との就業異動		1	継続就業者：1年前にも現在と同じ勤め先(企業)で就業していた者
		2	転職者：1年前の勤め先(企業)と現在の勤め先とが異なっている者
		3	新規就業者：1年前には仕事をしていたが、この1年間に仕事についた者
		4	離職者：1年前には仕事をしていたが、その仕事をやめて現在仕事をしていない者
		5	継続非就業者：1年前も現在も仕事をしていない者
		V	不詳
(有業者)前職の有無	有業者	1	ある
		2	ない
		V	不詳

加工対象変数

項目名	対象	符号	符号内容
(有業者・本業・従業上の地位)5区分	有業者	1 2 3 4 5 V	内職者以外の自営業主 内職者 家族従業者 民間の役員・常雇 臨時雇・日雇 不詳
(有業者・本業)雇用形態	有業者で 民間の役員を除く 雇用人 (常雇・臨時雇・ 日雇)	1 2 3 4 5 6 V	正規の職員・従業員 パート アルバイト 労働者派遣事業所の派遣社員 契約社員・嘱託 その他 不詳
(有業者・本業・産業)大分類	有業者	01 02 03 04 05 06 07 08 09 10 11 12 13 14 15 16 17 18 VV	農業 林業 漁業 鉱業 建設業 製造業 電気・ガス・熱供給・水道業 情報通信業 運輸業 卸売・小売業 金融・保険業 不動産業 飲食店・宿泊業 医療・福祉 教育・学習支援業 複合サービス業 サービス業(他に分類されないもの) 公務(他に分類されないもの) 分類不能の産業
(有業者・本業・職業)大分類	有業者	01 02 03 04 05 06 07 08 09 VV	専門的・技術的職業従事者 管理的職業従事者 事務従事者 販売従事者 サービス職業従事者 保安職業従事者 農林漁業作業者 運輸・通信従事者 技能工、採掘・製造・建設作業及び労務従事者 分類不能の職業
(有業者・本業)従業者規模	有業者	01 02 03 04 05 06 07 08 09 10 11 VV	1～4人 5～9人 10～19人 20～29人 30～49人 50～99人 100～299人 300～499人 500～999人 1000人以上 官公庁 不詳
(有業者・本業)年間就業日数	有業者	1 2 3 4 5 6 V	50日未満 50～99日 100～149日 150～199日 200～249日 250日以上 不詳
(有業者・本業)週間就業時間	有業者で 年間就業日数が 200日未満で 就業の規則性が だいたい規則的 及び 年間就業日数が 200日以上	01 02 03 04 05 06 07 08 09 10 VV	15時間未満 15～19時間 20～21時間 22～29時間 30～34時間 35～42時間 43～45時間 46～48時間 49～59時間 60時間以上 不詳

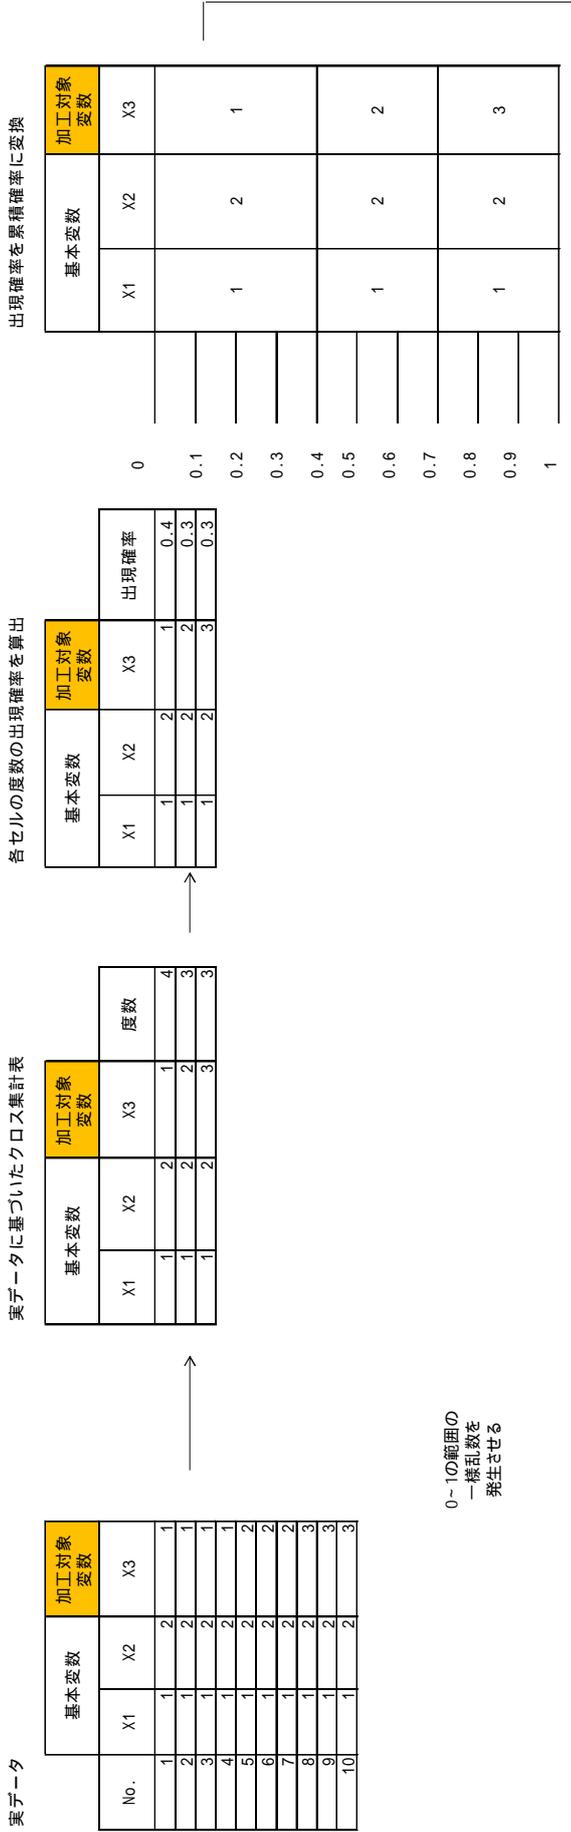
乱数発生変数

項目名	符号	符号内容	項目名	符号	符号内容
個人所得	01	収入なし, 50万円未満	継続就業期間	01	1ヶ月未満
	02	50 ~ 99万円		02	1ヶ月
	03	100 ~ 149万円		03	2ヶ月
	04	150 ~ 199万円		04	3ヶ月
	05	200 ~ 249万円		05	4ヶ月
	06	250 ~ 299万円		06	5ヶ月
	07	300 ~ 399万円		07	6ヶ月
	08	400 ~ 499万円		08	7ヶ月
	09	500 ~ 599万円		09	8ヶ月
	10	600 ~ 699万円		10	9ヶ月
	11	700 ~ 799万円		11	10ヶ月
	12	800 ~ 899万円		12	11ヶ月
	13	900 ~ 999万円		13	1 ~ 2年11ヶ月
	14	1000 ~ 1499万円		14	3 ~ 4年11ヶ月
	15	1500万円以上		15	5 ~ 9年
		16		10 ~ 14年	
		17		15 ~ 19年	
		18		20 ~ 24年	
		19		25 ~ 29年	
		20		30年以上	
		21		1年未満(月不詳)	

集計用乗率

項目名	対象	符号	符号内容
集計用乗率		000000.00 0000 ~	7桁目は小数点, 以下6桁は小数点以下を表す。

別添 3-1 集計表セル度数の出現確率に基づく一様乱数の作成イメージ



0~1の範囲の一様乱数を発生させる

乱数
0.87
0.44
0.76
0.98
0.82
0.83
0.20
0.80
0.72
0.23

累積確率と照合し、該当する変数組み合わせの疑似レコードを生成

No.	基本変数		加工対象変数	
	X1	X2	X3	
1	2	2	3	
2	2	2	2	
3	2	2	3	
4	2	2	1	
5	2	2	3	
6	2	2	3	
7	2	2	1	
8	2	2	3	
9	2	2	3	
10	2	2	1	

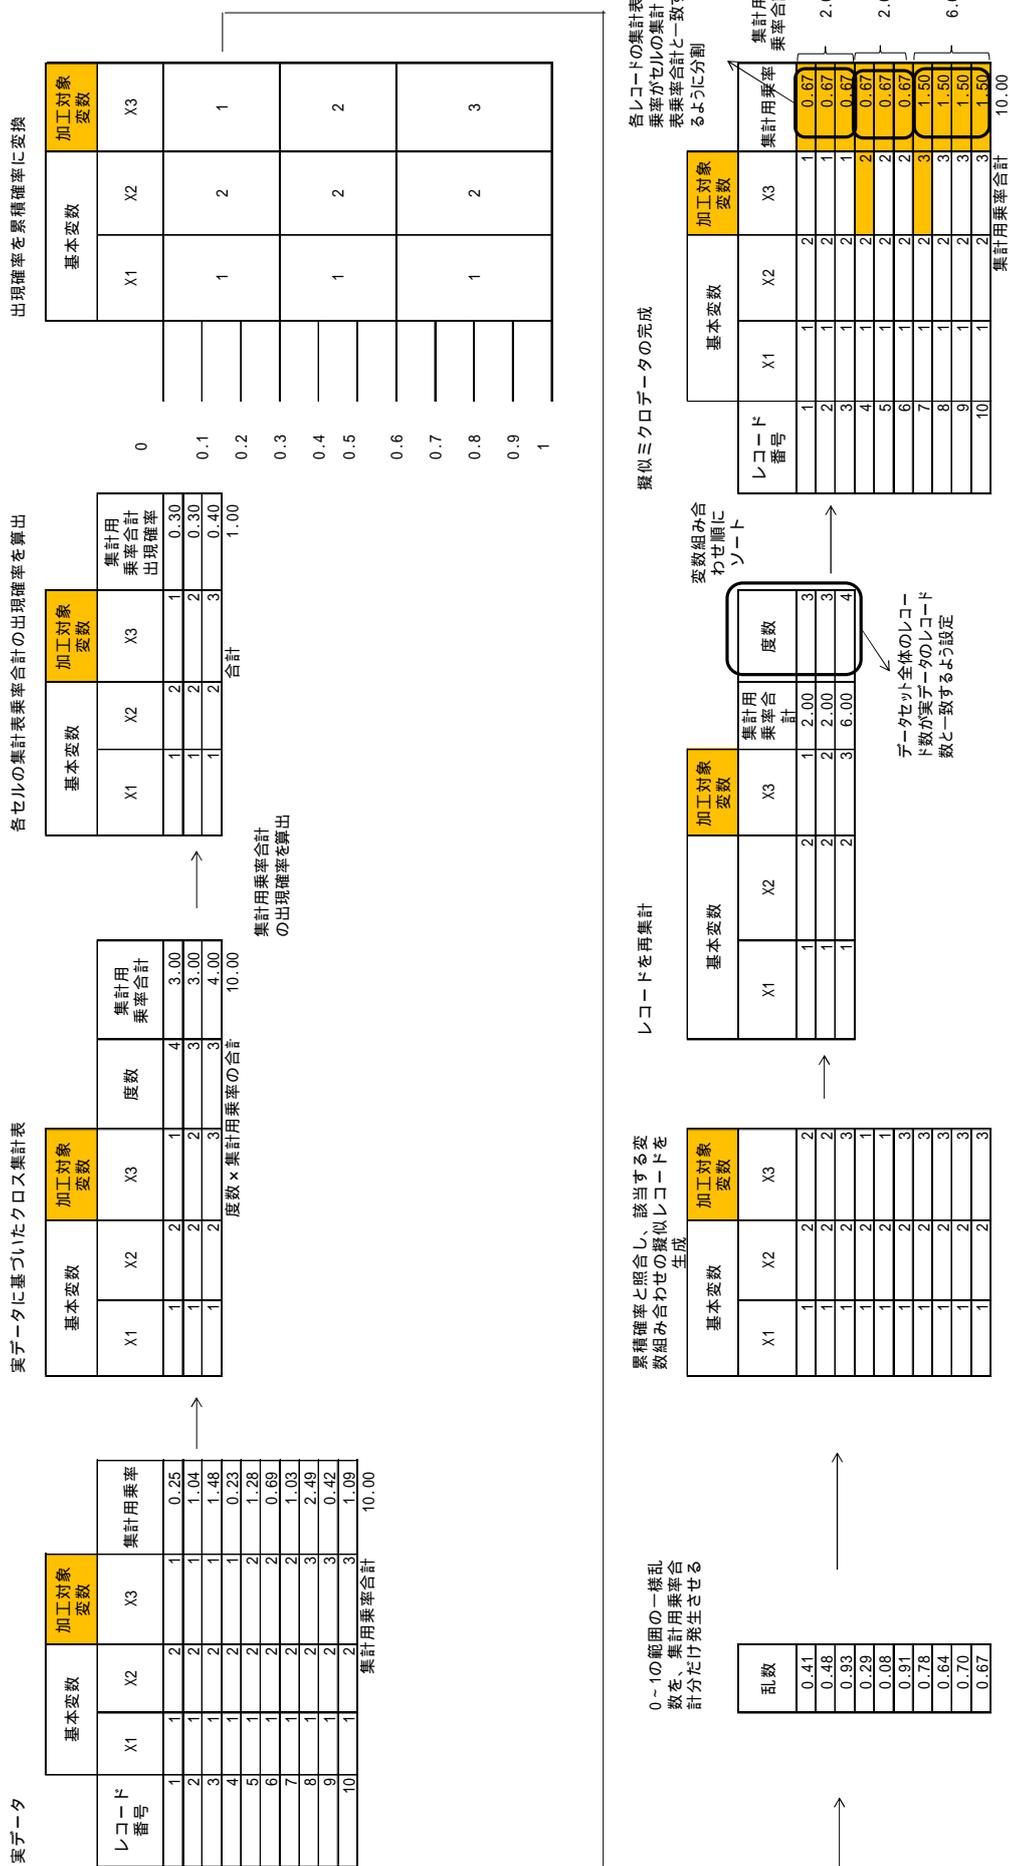
変数順にソート

No.	基本変数		加工対象変数	
	X1	X2	X3	
1	1	2	1	
2	1	2	1	
3	1	2	1	
4	1	2	2	
5	1	2	3	
6	1	2	3	
7	1	2	3	
8	1	2	3	
9	1	2	3	
10	1	2	3	

疑似レコードデータの完成

No.	基本変数		加工対象変数	
	X1	X2	X3	
1	1	2	1	
2	1	2	1	
3	1	2	1	
4	1	2	2	
5	1	2	3	
6	1	2	3	
7	1	2	3	
8	1	2	3	
9	1	2	3	
10	1	2	3	

別添 3-2 集計表セル度数の出現確率に基づく一様乱数の作成イメージ (集計表乗率考慮)



別添 4 一様乱数発生における変数固定の有無の検証

集計表の一部の変数を固定し、その範囲で本文 3.1.3 の手順による一様乱数を発生させれば、実データの特徴をより反映できると仮定し、

高次元クロス集計表 (15 変数) の組み合わせを固定し、残りの変数について乱数を発生 (以下「15 変数固定」)

基本変数 (8 変数) の組み合わせを固定し、残りの変数について乱数を発生 (以下「8 変数固定」)

以上の 2 パターンの追加検証を行った。

この追加検証において使用したデータ及び変数は本文 3.1.1 と、集計表は本文 3.1.2 と同一のものであり、固定変数と乱数発生変数の設定は以下のとおりである。

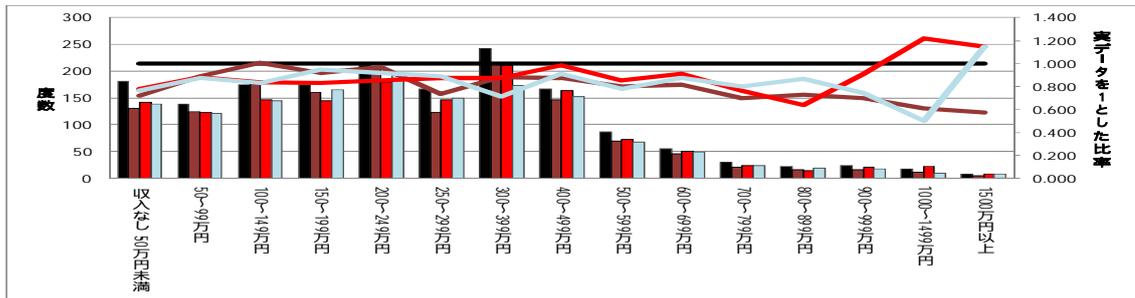
変数名		(参考)固定なし		15変数固定		8変数固定	
		固定	乱数発生	固定	乱数発生	固定	乱数発生
基本変数	性別						
	配偶者の有無						
加工対象変数	続き柄						
	教育(教育区分)						
	教育(学校区分)						
	年齢(5歳階級)						
	1年前との就業異動						
	前職の有無						
	従業上の地位(5区分)						
加工対象変数	雇用形態						
	産業(大分類)						
	職業(大分類)						
	従業者規模						
	年間就業日数						
個人所得	週間就業時間						
	継続就業期間						

作成した擬似マイクロデータを実データと比較検証した結果、以下のとおり、クロス統計表の度数分布及び独立性のカイ二乗検定のいずれの結果からも、変数の固定の有無による明確な影響は認められなかった。

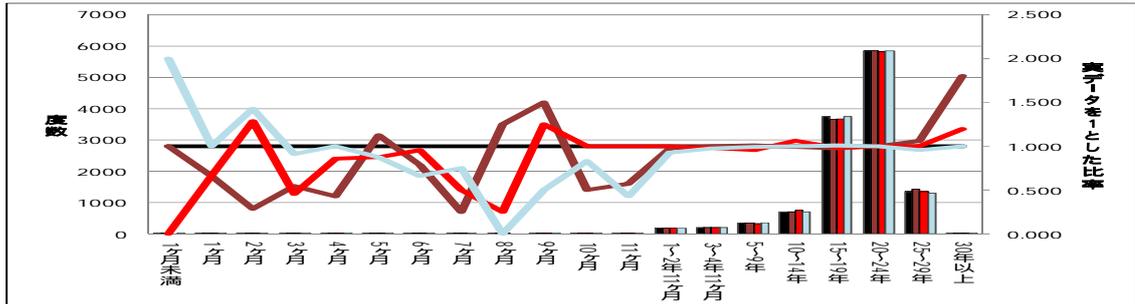
< グラフの凡例 >

棒グラフ (左から)	■ 実データ	■ 固定なし	■ 15 変数固定	■ 8 変数固定
折れ線グラフ	— 実データ(比率)	— 固定なし(比率)	— 15 変数固定(比率)	— 8 変数固定(比率)

個人所得 製造業×前職あり×自営業主



継続就業期間 40～44 歳×前職なし×雇用者



独立性のカイ二乗検定

検定対象変数		実データ×固定なし			実データ×15変数固定			実データ×8変数固定		
		カイ二乗統計量	自由度	p値	カイ二乗統計量	自由度	p値	カイ二乗統計量	自由度	p値
個人所得	自営業主×前職あり	4.8401	14	0.9879	8.7625	14	0.8460	6.7895	14	0.9425
	自営業主×前職なし	11.3582	14	0.6577	8.7022	14	0.8496	13.6727	14	0.4744
	雇用者×前職あり	32.9551	14	0.0029	18.4491	14	0.1871	14.2894	14	0.4284
	雇用者×前職なし	19.3856	14	0.1507	18.8247	14	0.1718	14.1053	14	0.4419
継続就業期間	自営業主×前職あり	23.0714	19	0.2342	25.8269	19	0.1351	36.8588	19	0.0083
	自営業主×前職なし	37.7853	19	0.0063	44.3986	19	0.0008	44.0053	19	0.0009
	雇用者×前職あり	18.6413	19	0.4801	18.8610	19	0.4658	20.5444	19	0.3625
	雇用者×前職なし	14.8047	19	0.7349	14.3196	19	0.7647	15.3661	19	0.6991

別添 5 集計表における加工処理変数の度数分布の変化

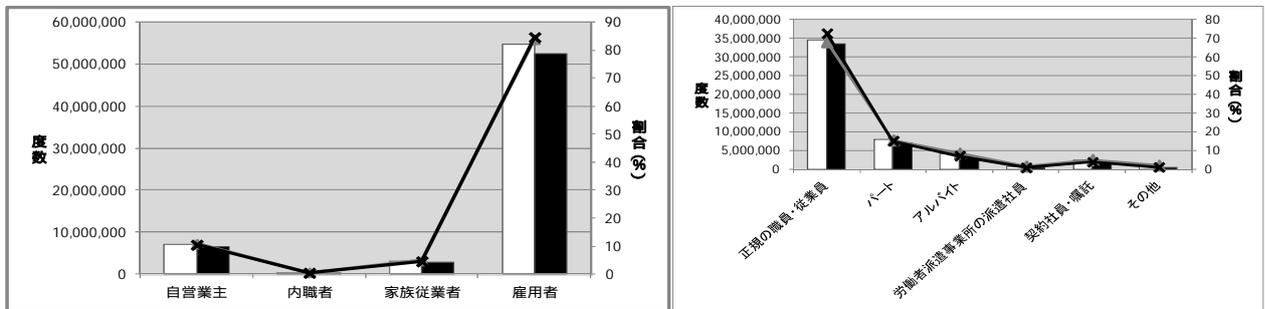
集計表作成時に不詳置き換え処理を行う加工処理変数は、集計表作成後に不詳以外の度数が減少し、特に不詳置き換え処理の優先順位が高い「週間就業時間」で大幅な減少が見られた(以下の棒グラフを参照)。

しかし、不詳以外の区分の度数合計を1とする割合(%)については、以下の折れ線グラフのとおり、いずれの区分も公表結果表の分布と近似した。

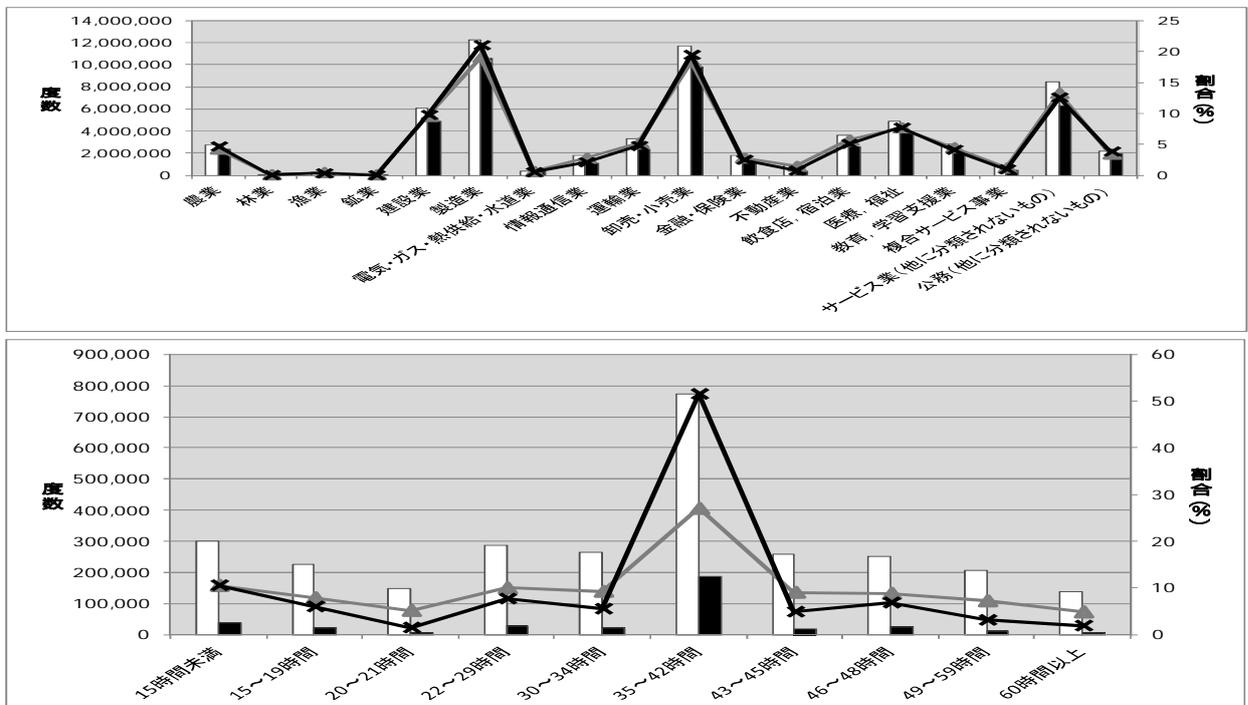
<グラフの凡例>

棒グラフ： 白：公表結果表、黒：集計表
折れ線グラフ：黒：公表結果表、灰色：集計表

従業上の地位別(左)及び雇用形態別(右)有業者数



産業別(上)及び週間就業時間別(下)有業者数



参考文献

- 伊藤伸介(2008)「マイクロアグリゲーションに関する研究動向」『製表技術参考資料』No.10
- 伊藤伸介・磯部祥子・秋山裕美(2008)「匿名化技法としてのマイクロアグリゲーションの有効性に関する研究 - 全国消費実態調査を例に - 」『製表技術参考資料』No.10
- 伊藤伸介・磯部祥子・秋山裕美(2009)「秘匿性の評価方法に関する実証研究 - 全国消費実態調査のマイクロアグリゲートデータを用いて - 」『製表技術参考資料』No.11
- 槇田直木(2012)「擬似マイクロデータの試行提供」平成24年度公的統計のマイクロデータの利用に関する研究集会・報告資料
- 秋山裕美・山口幸三・伊藤伸介・星野なおみ・後藤武彦(2012)「教育用擬似マイクロデータの開発とその利用～平成16年全国消費実態調査を例として～」『製表技術参考資料』No.16
- P.スペクター著 石田基広・石田和枝訳(2012)「R データ自由自在」丸善出版
- 金明哲編 藤井良宜著(2010)「R で学ぶデータサイエンス1 カテゴリカルデータ解析」共立出版
- 青木繁伸(2009)「R による統計解析」オーム社
- 舟尾暢男(2009)「The R Tips 第2版 - データ解析環境Rの基本技・グラフィックス活用集 - 」オーム社
- 統計委員会(2009)「第20回統計委員会議事録」
- 統計委員会匿名データ部会(2009)「第1回匿名データ部会議事概要」
- 総務省政策統括官(統計基準担当)(2011)「平成22年度 統計法施行状況報告」
- 総務省政策統括官(統計基準担当)(2014)「公的統計の整備に関する基本的な計画」
- 総務省政策統括官(統計基準担当)(2014)「委託による統計の作成等及び匿名データの作成・提供に関する年度計画一覧(平成26年度)」
- 総務省統計局(2006)「平成16年全国消費実態調査報告 第1巻 家計収支偏」
- 総務省統計局(2004)「平成14年就業構造基本調査報告 全国編」

製 表 技 術 参 考 資 料 29

平成 27 年 3 月発行

編集・発行 独立行政法人 統計センター

〒162 - 8668

東京都新宿区若松町 19 - 1

電 話 代 表 03 (5273) 1200

掲載論文を引用する場合は、事前に下記まで連絡してください

統計情報・技術部統計技術研究課 TEL : 03 - 5273 - 1368

E-mail : research@nstac.go.jp