

欠測値補完と因果効果推定による 特定健康診査の医療費への影響の理解

星野崇宏研究会

柿迫 栞緒* 棚村 しほり† 西田 康平† 松永 将志† 山崎 有紗†

2020年1月14日

概要

本稿は、40歳から74歳の全ての公的医療保険加入者を対象に実施されている特定健康診査の医療費抑制効果の検証を目的とする。従来の研究では、特定保健指導の受診がもたらす効果については一定水準の効果が示されているが、特定健康診査の医療費抑制効果を直接支持するものではなく、医療費は変わらない又は増加するとする説もある。また、特定健康診査の前身である基本健康診査の受診が医療費にもたらす効果について言及した研究についても、分析上のバイアスが見られ妥当な分析方法とは言えない。そこで、本稿では特定健康診査の受診有無が医療費に与える効果について実証分析を行った。兵庫県芦屋市の国民健康保険から匿名化処理を済ませた医療保険のレセプトデータ、特定健康診査の受診券発行者データ、健康診断データ、世帯所得データを提供いただき、2016年度の特定健康診査の受診有無がその後2年間の医療費の抑制に繋がるか分析を行った。ただし、特定健康診査を過去に受診していない人からは健康に関する情報を得られないことから、連鎖方程式による多重代入法を用いて欠測している情報を補完した分析を行った。また、健康に関する情報も考慮した傾向スコアとIPW推定量による因果効果推定を行い、内生性バイアスの除去に努めた。実証分析の結果、特定健康診査には短期的な医療費抑制効果があることが確認された。さらに、異質性の推定を行った結果、所得が低い人ほど医療費抑制効果が高くなることがわかった。^{*1}

キーワード：特定健康診査、レセプトデータ、因果効果推定、
IPW推定量、欠測値補完、連鎖方程式による多重代入法

* 慶應義塾大学法学部政治学科3年

† 慶應義塾大学経済学部経済学科3年

^{*1} 本稿は、2019年度経済学部三田祭論文コンクールのために作成したものである。本稿にあり得る誤り、主張の一切の責任はいうまでもなく筆者たち個人に帰するものである。

目次

1	序論	1
1.1	社会背景	1
1.1.1	特定健診・保健指導導入の背景	1
1.1.2	特定健診・保健指導の概要と現状	1
1.2	研究背景（先行研究とその課題）	4
1.3	研究目的	6
1.4	データの概要	6
1.5	本稿の構成	7
2	欠測データ	8
2.1	欠測データの構造	8
2.1.1	欠測データの尤度	8
2.1.2	欠測パターンの分類	10
2.1.3	欠測データメカニズムの分類	10
2.2	伝統的な欠測データ処理とその問題点	12
2.3	多重代入法の概要	14
2.3.1	代入ステージ	14
2.3.2	解析ステージ	15
2.3.3	統合ステージ	15
2.4	連鎖方程式による多重代入	16
3	実証分析	17
3.1	使用データとその加工	17
3.1.1	データの概要	17
3.1.2	データの加工	18
3.2	因果効果推定の理論	22
3.2.1	因果効果の定義	22
3.2.2	傾向スコアの概要	23
3.2.3	傾向スコアの用いた因果効果推定の方法	24
3.3	欠測補完以前のデータセットを用いた因果効果の推定	25
3.3.1	特定健診の受診の有無が無作為割り当てであると仮定した場合の因果効果	25
3.3.2	特定健診データを用いない場合の IPW 推定量を用いた効果検証	27
3.3.3	完全ケースデータを用いた場合の IPW 推定量を用いた効果検証	28
3.4	欠測値補完を行ったデータを用いた分析	31
3.4.1	多重代入の方法	31
3.4.2	因果効果推定の結果と考察	31

3.5	異質性の推定	32
4	結論	34
4.1	まとめ	34
4.2	実証分析の課題と今後の展望	35
4.3	特定健診・保健指導の社会的意義	36
5	謝辞	36

1 序論

本章では、研究概要について述べる。まず 1.1 節では社会背景として本稿の題材となる特定健康診査（以下「特定健診」とする。）および特定保健指導（以下「保健指導」とする。）の導入に至った背景や、特定健診・保健指導の概要と現状を説明し、1.2 節では研究背景として特定健診・保健指導の効果に関する先行研究を紹介しながら、その問題点を述べる。それを踏まえ、1.3 節で本稿の研究目的と意義について説明する。次に、本稿で用いるデータの概要と特徴を 1.4 節で述べる。最後に、本稿の構成を 1.5 節で示し、1 章の締めくくりとする。

1.1 社会背景

1.1.1 特定健診・保健指導導入の背景

平成 20 年 4 月より「高齢者の医療の確保に関する法律」が施行され、それまでの老人保健法に基づく基本健康診査（以下「基本健診」とする。）に代わり、よりメタボリックシンドローム（以下「メタボ」とする。）に着目した特定健診及び保健指導の実施が医療保険者に義務づけられた（厚生労働省, 2018b）。この背景には、国民医療費の増大や生活習慣病の有病者・予備群の増加がある。日本では高齢化の進展や医療技術の進歩などにより医療費が年々ほぼ右肩上がりに増加し国家財政を圧迫しており、2025 年度には約 48 兆円、2040 年度には約 68 兆円と今後も増加し続けると考えられている（厚生労働省, 2018d）。また、高齢化の急速な進展に伴い、疾病全体に占めるがん、虚血性心疾患、脳血管疾患、糖尿病等の生活習慣病の割合が増加傾向であり、日本人の死因の約 6 割、国民医療費の約 3 割を占めている。さらに、生活習慣病の前段階であるメタボが強く疑われる者と予備群と考えられる者を合わせた割合は、男女とも 40 歳以上で高く、男性では 2 人に 1 人、女性では 5 人に 1 人の割合に達している（厚生労働省, 2009）。これらの現状を踏まえ、厚生労働省（以下「厚労省」とする。）は、医療費の急増を抑えていくために重要な政策として、若い時からの生活習慣病の予防対策及び生活習慣病に罹患した後の対策の 2 つを挙げており、生活習慣病の予防対策の一環として特定健診・保健指導が行われている（厚生労働省, 2017b）。

1.1.2 特定健診・保健指導の概要と現状

本項では、前項で述べた背景に基づき、生活習慣病の予防対策の一環として実施されている特定健診・保健指導の概要や現状について説明する。

特定健診は、公的医療保険加入者のうち特定健診の実施年度中に 40～74 歳となる者で、かつ当該実施年度の 1 年間を通じて加入している者^{*2}が対象である^{*3}。特定健診の実施項目は、「特定健康診査及び特定保健指導の実施に関する基準」の第 1 条に定められているが、全対象

^{*2} 年度途中での加入・脱退等異動のない者を指すが、これらは年度が終了して実績報告を行う際に初めて結果論として異動したか否かが判断できることであることから、年度当初から事前に対象者から除外できる者ではない（厚生労働省, 2018a）。

^{*3} 但し、妊娠婦その他の厚生労働大臣が定める者は除く。詳細は厚労省ホームページ（<http://www.mhlw.go.jp/bunya/shakaihoshou/iryouseido01/info03i.html>）を参照されたい。

者が受診すべき基本的な健診項目は以下の表 1 の通りである。また、一定の基準の下、医師が必要と認めた場合には、貧血検査・心電図検査・眼底検査・血清クレアチニン検査が実施される(厚生労働省, 2018a)。各追加項目の基準に関しては次頁の表 2 を参照されたい。

表 1 基本的な健診項目(厚生労働省(2018a)より引用)

項目	備考
既往歴の調査	服薬歴及び喫煙習慣の状況に係る調査(質問票)を含む
自覚症状及び他覚症状の有無の検査	理学的検査(身体診察)
身長、体重及び腹囲の検査	腹囲の測定は、厚生労働大臣が定める基準(BMI が 20 未満の者、もしくは BMI が $22\text{kg}/\text{m}^2$ 未満で自ら腹囲を測定し、その値を申告した者)に基づき、医師が必要でないとする時は、省略可 腹囲の測定に代えて、内臓脂肪面積の測定でも可
BMI の測定	$\text{BMI} = \text{体重 (kg)} \div \text{身長 (m)}^2$
血圧の測定	
肝機能検査	血清グルタミンオキサロアセチクトランスアミナーゼ(GOT (AST)) 血清グルタミンピルビクトランスアミナーゼ(GPT (ALT)) ガンマーグルタミルトランスペプチダーゼ(γ -GTP)
血中脂質検査	血清トリグリセライド(中性脂肪)の量 高比重リポ蛋白コレステロール(HDL コレステロール)の量 低比重リポ蛋白コレステロール(LDL コレステロール)の量 中性脂肪が $400\text{mg}/\text{dl}$ 以上又は食後採血の場合、LDL コレステロールに代えて、Non-HDL コレステロールの測定でも可
血糖検査	空腹時血糖又はヘモグロビン A1c(HbA1c)、やむを得ない場合は随時血糖
尿検査	尿中の糖及び蛋白の有無

表2 各追加項目の基準 (厚生労働省 (2018a) より引用)

追加項目	実施できる条件
貧血検査 (ヘマトクリット値、血色素量 及び赤血球数の測定)	貧血の既往歴を有する者又は視診等で貧血が疑われる者
心電図検査 (12 誘導心電図)	当該年度の特定健康診査の結果等において、収縮期血圧 140mmHg 以上若しくは拡張期血圧 90mmHg 又は問診等で不整脈が疑われる者
眼底検査	当該年度の特定健康診査の結果等において、血圧又は血糖が、次の基準に該当した者 血圧: 収縮期 140mmHg 以上又は拡張期 90mmHg 以上 血糖: 空腹時血糖値が 126mg/dl 以上、HbA1c (NGSP 値) 6.5 % 以上又は随時血糖値が 126mg/dl 以上 ただし、当該年度の特定健康診査の結果等において、血圧の基準に該当せず、かつ血糖検査の結果の確認ができない場合、前年度の特定健康診査の結果等において、血糖検査の基準に該当する者を含む。
血清クレアチニン検査 (eGFR による腎機能の評価を含む)	当該年度の特定健康診査の結果等において、血圧又は血糖が、次の基準に該当した者 血圧: 収縮期 130mmHg 以上又は拡張期 85mmHg 以上 血糖: 空腹時血糖値が 100mg/dl 以上、HbA1c (NGSP 値) 5.6 % 以上又は随時血糖値が 100mg/dl 以上

保健指導は、特定健診の結果から、生活習慣病の発症リスクが高い人に対して、専門スタッフ (医師、保健師、管理栄養士等) によって実施される積極的支援または動機付け支援のことを指す (厚生労働省, 2009)。積極的支援と動機付け支援は、追加リスクの多少と喫煙歴の有無により対象者が階層化され、よりリスクの高いほうが積極的支援の対象となる (厚生労働省, 2018a)。対象者の階層化に関する基準については、次頁の表3の通りである。

厚労省は、特定健診・保健指導実施率の全国目標を特定健診 70 %、保健指導 45 %と定めている。しかしながら、2017 年度の特定健診実施率は 53.1 %、保健指導実施率は 19.5 %であり、施行以降年々着実に向上してはいるが、依然として目標との乖離が大きい状況にある (厚生労働省, 2017a)。

このような状況を踏まえ、厚労省は後期高齢者支援金の加算・減算制度の見直しや保険者努力支援制度の本格実施を行っている。これは、特定健診・保健指導を含む医療費適正化や予防・健康づくり等の取り組み状況に応じた都道府県や市町村への財政的な支援であり、健康保険組

表3 特定保健指導の対象者（階層化）（厚生労働省（2018a）より引用）

腹囲	追加リスク			4. 喫煙歴	対象	
	1. 血糖	2. 脂質	3. 血圧		40-64 歳	65-74 歳
≧ 85cm(男性) ≧ 90cm(女性)	2 つ以上該当			なし	積極的支援	動機付け支援
	1 つ該当			あり		
上記以外で BMI ≧ 25kg/m ²	3 つ該当			なし	積極的支援	動機付け支援
	2 つ該当			あり		
	1 つ該当			なし		

合や自治体等の保険者は特定健診受診率の実施率やその上昇幅などの実績によって後期高齢者医療制度への財政負担の軽減や、交付金額の変化などの経済的インセンティブ（誘因）を与えられている（厚生労働省，2018c）。これを受け、近年各保険者は、受診者個人へのインセンティブを提供する取り組みなどによる、受診率向上に向けた受診勧奨^{*4}を積極的に行っている。

本稿での対象となる市町村国保の特定健診・保健指導の財源については、国・都道府県・市町村で3分の1ずつ負担することとなっており（厚生労働省，2018e）、全国健康保険協会等その他の保険者に対しても国から補助金が支払われている。そのため国は特定健診・保健指導に必要な経費として年間230億円弱の財源を投下している（厚生労働省，2017d）。さらに、保険者努力支援制度に対しては、2019年度は市町村分と都道府県分を合わせて約1,000億円を配分する見込みであり（厚生労働省，2019a）、このことから厚労省が特定健診・保健指導の実施率向上を積極的に推進していることがみとれる。

1.2 研究背景（先行研究とその課題）

上記で確認してきた通り、厚労省は医療費抑制のための生活習慣病対策の一環として特定健診・保健指導を推進しており、第三期医療費適正化計画において、特定健診実施率70%、保健指導実施率45%の目標達成により、2023年時点で約200億円の医療費が適正化されると見込んでいる（厚生労働省，2019b）。

一方で、特定健診・保健指導の医療費抑制効果についての明確な根拠は今までに示されていない。特定健診・保健指導の医療費抑制効果を支持するものとして、厚労省の特定健診・保健指導の医療費適正化効果等の検証のためのワーキンググループは、保健指導の積極的支援参加者と不参加者では、不参加の方が男性で5,720～8,100円、女性で1,680～7,870円一人当たり入院外医療費が高くなるとの分析結果を示している（厚生労働省，2016）。しかし、これは積極的支援対象者のうちの支援参加者と不参加者の比較に過ぎず、特定健診の受診有無による医療費抑制効果を示すものとは言えない。なぜなら、積極的支援の対象となるのは特定健診受診者のうち最も生活習慣病リスクの高い約9%の人々であり、そのうち積極的支援を終了

^{*4} 保険者によっては、年度途中に特定健診受診券を発行していない被保険者に対し、はがきや電話、個別訪問などの手段で特定健診の受診を促す場合があり、それを受診勧奨という。近年受診率向上のため対象者を未受診理由によりセグメント化するなど各保険者ごとに様々な工夫がなされている。

する者の割合も約 11 %に過ぎないため*5、特定健診の受診群と未受診群の比較とは対象者の性質が大きく異なる比較となるからである。

また、健診の受診により医療費は増加すると主張する者もいる。その理由として、スクリーニングの偽陽性による過剰な検査を含む*6、健診により受診勧奨がなされた場合の精密検査受診に伴う医療費増加や、健診受診により発見された高リスク状態に対する薬物治療による外来医療費の増加が挙げられる(渡邊, 2017)。そのほかにも、受診により高額な医療費・介護費がかかるタイミングが先延ばしされているだけであるとする考え方もある(康永, 2017a)。

健診の受診有無が医療費に与える効果についての国内研究は非常に希少であり、特に個人レベルの医療費を用いて非受診群と比較したものは、検索・入手可能な範囲では 2 件しか存在しない*7。竹内(2002)は、健診受診群のほうが医療費が有意に低いという結果を示しているが、性・年齢以外の特性が調整されておらず、自己選択バイアス*8や healthy screenee bias*9が除去されていないと言える。それに比して渡邊(2017)は、12 年間という比較的長期的な効果を測定しているうえ、自己選択バイアスや healthy screenee bias の除去につとめている。その結果、2000 年前後の基本健診受診群の医療費は非受診群と比較して 2 - 11 年にわたり有意に 1 人当たり積算医療費が低額であり、その差は最大で 10 万円、相対比で 7 %であるという結論が導かれた。しかしながら、渡邊(2017)は、平成 20 年に特定健診が実施される以前に実施されていた基本健診の受診有無と医療費の関係を調べたものであり、特定健診の医療費抑制効果を直接的に支持するものではない。また、渡邊は基本健診の受診有無と医療費以外の特性をベースライン調査によって得ており、それらを考慮することで自己選択バイアスや healthy screenee bias の除去につとめているが、ベースライン調査は自記式質問紙によるものであるため、誤分類が生じている可能性がある。加えて、傾向スコアを用いたマッチングの結果、対象数が観察コホートの 49.3 %、回答者の 45.5 %とサンプルサイズが半数以下に減少しており、バイアスが生じている可能性が考えられる。さらに、健診受診を曝露とした受診群：非受診群 = 1 : 2 の割合で固定比マッチングを行っているが、推奨される傾向スコアマッチングの手法ではない。また、社会経済的因子については、職業や学歴といった大まかな分類に留まり、調整が不十分である可能性が考えられる。

つまり、特定健診の受診有無が医療費に与える影響についての研究は過去になされておらず、特定健診の前身である基本健診の受診有無と医療費の関係について言及された研究におい

*5 特定健診受診者のうちの積極的支援対象者の割合、積極的支援対象者のうちの積極的支援終了者の割合はともに「特定健康診査受診者数等の性・年齢階級・保険者種別ごとの分布(全国及び都道府県別一覧)」(<https://www.mhlw.go.jp/bunya/shakaihoshoh/iryouseido01/info02a-2.html>)の平成 20~27 年度のデータを用いて各年度の割合を算出したうえで、その平均をとったものである。

*6 簡易検査であるスクリーニングでは、一部の健常者に対しても陽性反応が出る場合があり、それによって本来受ける必要のない健常者に対し精密検査の受診勧奨がなされ、結果的に医療費増加につながってしまう可能性がある。

*7 健診の受診有無と医療費の関係について言及した研究は、海外においても非常に希少であった。なお、海外と日本では健診制度等の前提が大きく異なり、比較対象として適切でないため、今回は国内で行われた研究のみに触れることとした。

*8 曝露があるからこそ積極的に協力するというバイアス。本稿においては次の healthy screenee bias とほぼ同義である。

*9 健康意識が高く、健康状態の良い者だけが健診に参加し、健康意識が低く、不健康な者は健診に参加しないというバイアス。

ても、適切な手法によって効果測定が行われたものは存在しないと言える。

1.3 研究目的

本稿では、特定健診の受診有無が医療費に与える効果を検証する。当該仮説の検証に用いる研究方法については2章以降で詳しく述べるが、因果効果推定と多重代入法を併用した分析を実施する。それにより、先行研究において考慮されていなかった未受診者の血圧や血糖値など健康状態などの値も考慮し、バイアスの除去を行うことで、より正確な効果検証を目指す。

もし特定健診受診者のほうが未受診者よりも医療費が低かった場合、これまで解明されてこなかった特定健診の受診行為自体の医療費抑制効果を示され、医療費適正化対策としての特定健診の有効性を確認することができる。さらに、異質性の推定を行い、医療費削減効果がより大きく表れるのはどのような特徴をもつ人であるかを分析することで、近年各保険者が行っている受診勧奨の効率化につなげられる。

一方で、特定健診受診者のほうが未受診者よりも医療費が高かった場合、医療費適正化対策としての特定健診の効果、及び現在厚労省が財源を投下している保険者努力支援制度などの受診率向上施策の有効性に疑問を呈することができる。この場合、厚労省は特定健診以外の方法での医療費適正化をより一層推進していかなければならず、その例として康永(2017b)は、医療サービスの無駄や過剰供給を発見し抑制することや、ジェネリック医薬品などのより費用の低い医療サービスを提供すること等を挙げている。また、それらを実践してもなお残る医療・介護費の自然増加分は、その負担を国民全体で分け合う必要があり、次世代に負担を付け回さず、持続可能な医療・介護システムを将来にわたって築くことが、今後一層重要になる。

1.4 データの概要

本節では、本稿で用いる医療データの概要について述べる。この度、当研究会の共同研究先である兵庫県芦屋市より、医療保険のレセプトデータの提供を受けた。レセプトデータとは、患者が受けた保険診療について医療機関等が保険者に請求する月単位の医療報酬明細書(縄田他, 2019)のことを指す。この患者・保険者・医療機関の関係は、審査支払機関を加えることで図1のようにまとめることが可能である。

レセプトデータに加えて、特定健診の受診券発行者データ・健康診断データ・世帯所得のデータの提供を受けた。なお、レセプトデータを含む全てのデータは、提供される前に個人を特定できないよう匿名化の処理がなされている。特定健診の受診券発行者データとは、各年度はじめに特定健診の対象となる被保険者に送付される受診券が発行された人の生年月日、性別等の基本情報が各対象年度ごとにまとめられたデータである。健康診断データとは、特定健診受診者の受診結果について各年度ごとにまとめられているデータである。世帯所得データとは、11区分された世帯所得について各年度ごとにまとめられたデータである。以上の4つのデータにはユニークキー(個人キー等)が付してあり、各データを結合することができる。データの収集期間は種類により異なるが、本稿では2013年度から2018年度を対象とした。対象者の年齢は2016年度を基準に満43歳以上満72歳以下である。また国民健康保険であるた

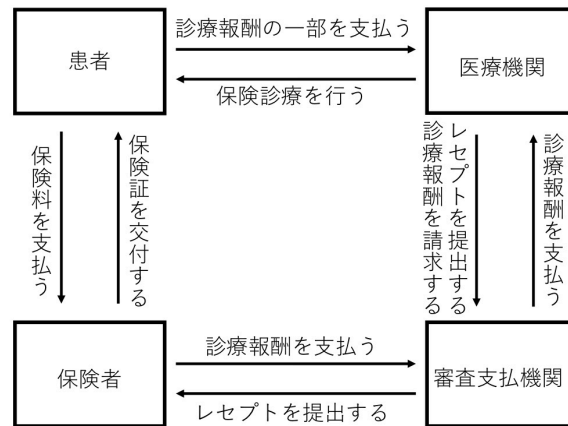


図1 診療報酬とレセプトの流れ

め、加入者は「被用者保険等の適用者以外の国民すべて (厚生労働省, 2017c)」である。これらは主に、個人事業主・自営業者・非正規雇用者・失業者・無職者・前期高齢者などで構成されている。なお、データの詳細は第4章にて触れる。

次に、本稿で行う分析に即したデータの特徴を説明する。ここで2015年度の健康診断データの診断結果を x_w とする。また、対象者の2016年度時点の年齢、性別、2013年度から2015年度の世帯所得を x_d 、レセプトデータから算出した2013年度から2015年度の外来、入院、調剤別の診療報酬点数を x_r 、2016年度の健康診断の受診有無を z 、2017、2018年度の外来と調剤の医療報酬点数の合算、入院の医療報酬点数を y とする。従来行われてきた保健指導の効果検証では、処置群・対照群ともに健康診断データが完全に備わっているデータセットを用いるのが通例である。しかし、本稿で実施する特定健診の効果検証の場合、前年の診断結果 x_w (図2を参照) が翌年の受診有無の決定に大きな影響を与えると予測されるため、この変数を利用しないことで“除外変数バイアス”が生じる。また、基本健診の受診有無と医療費の効果測定を行った竹内 (2002) や渡邊 (2017) においても、 x_w や x_d が考慮されていない、あるいは、不十分な情報であるために自己選択バイアスや healthy screenee bias が除去されていなかった。今回の実証分析においては、これらへの対処方法として、図2の通り、2015年度に特定健診を受診していない人の健康診断データを欠測とし、多重代入法を用いた欠測値補完を行った上で分析する。本稿の新規性は、先行研究におけるバイアスの課題を克服しつつ、特定健診の受診有無と個人レベルの医療費に与える効果を推定する方法論を示すことにある。

1.5 本稿の構成

本稿の構成を以下に示す。まず、2章では、統計的に仮説を検証するための分析方法について説明する。具体的には、欠測データの分類を定義し、リストワイズ削除と単一代入法の問題点を述べたのち、多重代入法を用いた欠測値補完の方法を紹介する。3章では、兵庫県芦屋市から提供を受けた実際のデータを用いて、該当分析方法を用いた、欠測値補完並びに因果効果の推定を用いた実証分析を行う。最後に4章で、分析結果をもとに結論と考察、今後の研究の

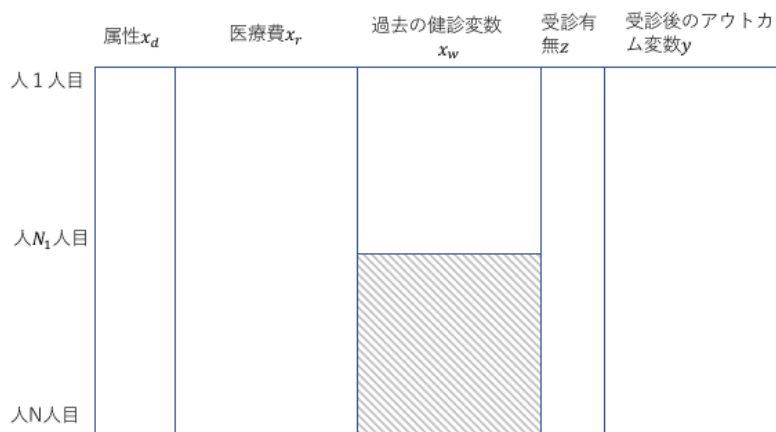


図2 今回のデータの概形

展望について述べる。

2 欠測データ

本章では、欠測データに対する処理について述べる。2.1 節では、欠測データの分類について説明し、各分類の定義を説明する。2.2 節では、欠測データ処理でよく使用される手法のうち、リストワイズ削除と単一代入法を紹介し、その問題点を述べる。2.3 節では、前節の懸念点を回避する手法として Rubin (1987) が提案した多重代入法 (Multiple Imputation; MI) を紹介する。2.4 節では、本稿で利用する完全条件付き分布の指定 (fully conditional specification; FCS;(Buuren et al., 2006))、その代表的なアルゴリズムである連鎖方程式による多重代入法 (multiple imputation by chained equation; MICE;(Buuren, 2012)) を用いた欠測値補完の方法について説明する。

2.1 欠測データの構造

本節では、欠測データの構造を理解するために欠測パターンと欠測データメカニズムの分類について紹介する。欠測データを用いて分析を行う場合、これらのデータの構造に応じて適切な対処をしなければ、調査・実験の結果に大きなバイアスが生じる。その結果、最終的な結論が大きく歪められてしまう可能性があるため、これらの理解は非常に重要である。

2.1.1 欠測データの尤度

はじめに、欠測データの尤度を構築する。高井他 (2016) を参考に以下に方法を記述する。具体的には、 J 変数ベクトル $\mathbf{y} = (y_1, \dots, y_J)^t$ の分布が密度関数 $f(\mathbf{y}|\boldsymbol{\theta})$ を持つとし、この分布から、欠測値を含む独立なサンプルサイズ n のデータをとる。このデータを使って、 $\boldsymbol{\theta}$ を最

尤推定する。欠測データは y_j が観測されるか欠測するかのどちらか一方であるから、 y_j に対して、 $r_j (j = 1, \dots, J)$ を

$$r_j = \begin{cases} 1 & (y_j \text{が観測}), \\ 0 & (y_j \text{が欠測}) \end{cases} \quad (1)$$

と定義する。このような r_j を y_j に対する欠測指標 (missing-data indicator) という。欠測指標を用いることで、欠測すること自体を情報として扱うことができる。 \mathbf{y} に対する欠測指標をまとめて、 $\mathbf{r} = (r_1, \dots, r_J)^t$ と書くこととする。 \mathbf{r} の各要素は 2 通りの値を取るため、 \mathbf{r} が取りうる値は最大 2^J 通りである。この \mathbf{r} の取る要素を $\mathbf{r}^{(1)}, \dots, \mathbf{r}^{(K)}$ ($K \leq 2^J$) とする。ただし、 $\mathbf{r}^{(1)} = (1, \dots, 1)^t$ とする。 $\mathbf{r} = \mathbf{r}^{(K)}$ において $r_j = 1$ となる y_j を集めたものを $\mathbf{y}^{(K)}$ 、 $r_j = 0$ となる y_j を集めたものを $\mathbf{y}^{(-K)}$ とする。 $\mathbf{r} = \mathbf{r}^{(K)}$ の時、 $\mathbf{y}^{(K)}$ は観測されるが、 $\mathbf{y}^{(-K)}$ は観測されない。

まず、完全データを用いた尤度について考える。このとき、 θ の尤度は

$$\prod_{i=1}^n f(y_i | \theta) \quad (2)$$

となる。この尤度を最大化する θ を θ の最尤推定量という。最尤推定量をこの式から求めるのは難しいことが多いので代わりに対数尤度

$$\sum_{i=1}^n \log f(y_i | \theta) \quad (3)$$

を最大化して、最尤推定値を求める。このとき、最尤推定量は、一致性や漸近正規性を持つ。

しかし、欠測を含む変数の場合、この尤度はそのまま計算できない。そこで欠測指標 \mathbf{r} とパラメータ δ を用いて、欠測を含んだモデリングを行う。 \mathbf{y} と \mathbf{r} の同時分布 $f(\mathbf{y}, \mathbf{r} | \delta)$ を考える。この同時分布から \mathbf{r} を消去すると

$$f(\mathbf{y} | \theta) = \sum_{j=1}^J \sum_{r_j=0}^1 f(\mathbf{y}, \mathbf{r} | \delta) \quad (4)$$

と表される。興味があるパラメータ θ は δ に含まれている。したがって、 δ の中の θ 以外の局外パラメータを ψ と書くと、 $\delta = (\theta^t, \psi^t)^t$ となる。 δ あるいは θ を最尤推定するために実現値 $(\mathbf{y}^{(K)t}, \mathbf{r}^{(K)t})^t$ に対する尤度を考える。標本 \mathbf{y} のうち、欠測した値 $\mathbf{y}^{(-K)}$ を積分で消去すると、

$$f(\mathbf{y}^{(k)}, \mathbf{r}^{(k)} | \delta) = \int f(\mathbf{y}, \mathbf{r}^{(k)} | \delta) d\mathbf{y}^{(-k)}, k = 1, \dots, K \quad (5)$$

となる。 $\mathbf{y}^{(-K)}$ が離散値を取るときは、この積分は和で置き換える。この尤度を δ の完全尤度という。これは \mathbf{r} の実現値によって、 $\mathbf{y}^{(K)}$ の次元が変わり、異なる形となる。

ここで観測値に対応する変数を \mathbf{y}_{obs} 、欠測値に対応する変数を \mathbf{y}_{mis} と書く。 \mathbf{y}_{obs} という記号は、 \mathbf{y} のどの要素を観測されるかを示しているのだから、 \mathbf{r} の情報も持っている。つまり、 \mathbf{y}_{obs} とは、 \mathbf{y} の要素だけの関数ではなく、 $(\mathbf{y}^t, \mathbf{r}^t)^t$ の関数である。このとき、上の式は

$$f(\mathbf{y}_{obs}, \mathbf{r} | \delta) = \int f(\mathbf{y}, \mathbf{r} | \delta) d\mathbf{y}_{mis} \quad (6)$$

と書くことができる。

次に欠測データを解析する上で選択モデル (selection model; Heckman (1979)) について述べる。先ほど定義した \mathbf{y} と \mathbf{r} の同時分布は $f(\mathbf{y}, \mathbf{r}; \boldsymbol{\theta}, \boldsymbol{\psi})$ である。通常、このままでは推定すべきパラメータの数が多すぎる。多くの場合 \mathbf{y} の母集団の推定に関心があるため、 $\boldsymbol{\theta}$ の推定さえ正しければよく、 $\boldsymbol{\psi}$ については推定を行わなくて良い場合が多い。そこで $\boldsymbol{\theta}$ の推定を容易にするために、 $f(\mathbf{y}, \mathbf{r}; \boldsymbol{\theta}, \boldsymbol{\psi})$ を条件付き分布の積に分解する。ここで選択モデルによる分解方法で、

$$f(\mathbf{y}, \mathbf{r}; \boldsymbol{\theta}, \boldsymbol{\psi}) = f(\mathbf{y}|\boldsymbol{\theta})f(\mathbf{r}|\mathbf{y}; \boldsymbol{\theta}, \boldsymbol{\psi}) \quad (7)$$

とする。このモデルでは \mathbf{y} に関する分布 $f(\mathbf{y}|\boldsymbol{\theta})$ と、 \mathbf{y} の実現値によって条件付けされた \mathbf{r} の条件付き分布の積として同時分布が表現される。よって、 $\boldsymbol{\theta}$ は \mathbf{y} に欠測がないときの母集団分布のパラメータであり、 $\boldsymbol{\psi}$ は条件付き分布を特徴付けているパラメータである。 $f(\mathbf{r}|\mathbf{y}; \boldsymbol{\theta}, \boldsymbol{\psi})$ を欠測データメカニズムと呼ぶ。(高井他, 2016; 富田, 2018) また、選択モデルとは別にパターン混合モデル (pattern mixture model; Glynn et al. (1986)) を用いた分解方法も存在するが、本稿では選択モデルを用いた考察を行うため、パターン混合モデルについては詳細に記さない。

2.1.2 欠測パターンの分類

次に、高井他 (2016) にならって欠測パターン进行分类する。欠測パターンとは、欠測のない完全データ (complete data) からどのように値が欠測しているかを形式的に分類したものである。欠測パターンはデータの構造によって様々なパターンが存在するが、ここでは本稿で分析に用いたユニット×変数からなる二相データにおける欠測パターンの分類を紹介する。図 3 にそれぞれのパターンの形状を模式的に記載する。

一般の欠測パターン 複数の変数について欠測がある、項目レベルの欠測 (item nonresponse) が生じている場合である。

単調欠測 (monotone missingness) パターン 適切に変数のソーティングを行い、変数番号をつけると、あるユニットの l ($= 1, \dots, L-1$) 番目の変数 x_l はそのユニットの $l+1$ 番目の変数 x_{l+1} が観測される場合には必ず観測される、という場合であり、上記 1 の特殊なパターンである。

2 パターン ユニットレベルの欠測 (unit nonresponse) とも呼ばれ、特定の変数群はユニットごと一括して欠測か観測かの 2 パターンであり、補助変数 z については全てのユニットに対して観測されている場合である (高井他, 2016)。

本稿で分析に用いた欠測データは、2015 年度の特定健診を受診しなかった人に対して、健康診断データが欠測しており、その他共変量については全てのユニットで観測されている状況であり、欠測パターンは上記の 2 パターンに該当する。

2.1.3 欠測データメカニズムの分類

高井他 (2016) によると欠測データメカニズムとは、データの欠測がどのようなメカニズムで生じているかを、統計的推測を行う際に有用な 3 区分に分類したものである。これらは、欠

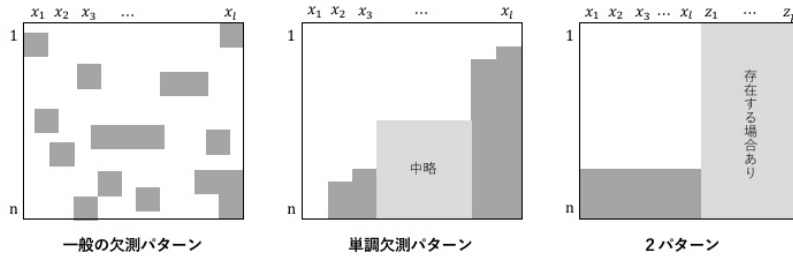


図3 欠測パターンの分類 (高井他 (2016) を筆者改変)

測データメカニズムが依存する変数という観点から MAR,MCAR,NMAR に分類される。欠測データメカニズムの分類は非常に本質的であり、次節以降で紹介する分析法によって正しい推測が可能なのか、あるいは不可能なのかを判断するために必要である。

ランダムな欠測 (missing at random; MAR) データがランダムな欠測であるとは、全ての \mathbf{y}_{mis} に対して、

$$f(\mathbf{r}|\mathbf{y}; \boldsymbol{\theta}, \boldsymbol{\psi}) = f(\mathbf{r}|\mathbf{y}_{obs}; \boldsymbol{\theta}, \boldsymbol{\psi}) \quad (8)$$

となることである。^{*10} 共変量 $\boldsymbol{\omega}$ がある場合は、

$$f(\mathbf{r}|\mathbf{y}; \boldsymbol{\theta}, \boldsymbol{\psi}) = f(\mathbf{r}|\mathbf{y}_{obs}, \boldsymbol{\omega}; \boldsymbol{\theta}, \boldsymbol{\psi}) \quad (9)$$

と表される。この共変量は常に観測される確率変数である仮定する。言い換えると、MAR とは欠測の発生が観測値には依存するが、欠測値には依存しない場合である。注意すべき点は、欠測データメカニズムが MAR であるとは、欠測の発生が必ず観測値に依存しなければいけないということではなく、欠測の発生は欠測値に依存せず、依存するとすれば観測値にのみ依存するということである。

また MAR の定義から、完全尤度は

$$f(\mathbf{y}_{obs}, \mathbf{r}|\boldsymbol{\theta}, \boldsymbol{\psi}) = \int f(\mathbf{y}|\boldsymbol{\theta})f(\mathbf{r}|\mathbf{y}_{obs}; \boldsymbol{\theta}, \boldsymbol{\psi})d\mathbf{y}_{mis} = f(\mathbf{y}_{obs}|\boldsymbol{\theta})f(\mathbf{r}|\mathbf{y}_{obs}; \boldsymbol{\theta}, \boldsymbol{\psi}) \quad (10)$$

となる。左辺の $f(\mathbf{y}_{obs}, \mathbf{r}|\boldsymbol{\theta}, \boldsymbol{\psi})$ は、右辺では $\boldsymbol{\theta}$ だけを含む $f(\mathbf{y}_{obs}|\boldsymbol{\theta})$ と局外パラメータ $\boldsymbol{\psi}$ を含む $f(\mathbf{r}|\mathbf{y}_{obs}; \boldsymbol{\theta}, \boldsymbol{\psi})$ に分解されている。したがって、対数完全尤度は

$$\log f(\mathbf{y}_{obs}, \mathbf{r}|\boldsymbol{\theta}, \boldsymbol{\psi}) = \log f(\mathbf{y}_{obs}|\boldsymbol{\theta}) + \log f(\mathbf{r}|\mathbf{y}_{obs}; \boldsymbol{\theta}, \boldsymbol{\psi}) \quad (11)$$

となる。興味のある $\boldsymbol{\theta}$ の推定のためには左辺の尤度を用いるのが利用可能なデータを全て用いているという観点では自然である。そのためには右辺第2項の $\boldsymbol{\psi}$ を含む欠測データメカニズムをモデリングしなければいけないが、このモデリングは現実的に難しく、また $\boldsymbol{\psi}$ には興味がないためモデリングは避けるべきである。そこで、右辺の第1項のみを用いて $\boldsymbol{\theta}$ を推定するが、 \mathbf{y} に関するモデルが正しければ一致推定が可能である。

^{*10} この定義は Little and Rubin (2002) で与えられたものである。MAR の定義は元々 Rubin (1976) によって与えられたものである。Rubin (1976) の MAR とは、実際に観測されている r のみに対して欠測データメカニズムが \mathbf{y}_{obs} に依存していることを指す。

完全にランダムな欠測 (missing completely at random; MCAR) データが完全にランダムであるとは、全ての \mathbf{y}_{mis} に対して、 $f(\mathbf{r}|\mathbf{y}, \boldsymbol{\psi}) = f(\mathbf{r}|\boldsymbol{\psi})$ となることである。共変量 $\boldsymbol{\omega}$ がある場合は、

$$f(\mathbf{r}|\mathbf{y}; \boldsymbol{\omega}, \boldsymbol{\psi}) = f(\mathbf{r}|\boldsymbol{\omega}; \boldsymbol{\psi}) \quad (12)$$

と表される。この共変量は常に観測される定数であると仮定する。したがって、MCAR とは、欠測が完全にランダムで発生しており、モデリングの対象となる変数および関連する変数に依存しない場合である。欠測データメカニズムが MCAR であるとは、データが MAR であるうち欠測の発生が観測値にも依存しない場合を指す。MCAR はかなり強い仮定であるため、データが MCAR である事象は極めて少ない。

また MCAR の場合、完全尤度は

$$f(\mathbf{y}_{obs}, \mathbf{r}|\boldsymbol{\theta}, \boldsymbol{\psi}) = \int f(\mathbf{y}|\boldsymbol{\theta})f(\mathbf{r}|\boldsymbol{\psi})d\mathbf{y}_{mis} = f(\mathbf{y}_{obs}|\boldsymbol{\theta})f(\mathbf{r}|\boldsymbol{\psi}) \quad (13)$$

となる。したがって、MAR の場合と同様に、 $\boldsymbol{\theta}$ の推定は第 1 項のみを用いればよい。MAR の場合には、一致性と漸近正規性のある $\boldsymbol{\theta}$ の最尤推定量を構成するために、全観測データを使った直接尤度を使う。MCAR の場合には、全ての観測データを用いなくても、1 つ以上の欠測パターンを用いる限り、最尤推定量は一致性を持ち、漸近正規性も持つ。

ランダムでない欠測 (not missing at random; NMAR) 欠測が NMAR によって生じているとは欠測の発生が欠測値に依存する場合である。上記の通り、データが MAR または MCAR であるとき、最尤推定量は真のパラメータ値に対して一致性を持つ。一方、データが NMAR である場合、最尤推定量は真のパラメータ値に対して一致性があることを保証することができない。

MCAR の場合、完全尤度は

$$f(\mathbf{y}_{obs}, \mathbf{r}|\boldsymbol{\theta}, \boldsymbol{\psi}) = \int f(\mathbf{y}|\boldsymbol{\theta})f(\mathbf{r}|\mathbf{y}; \boldsymbol{\omega}, \boldsymbol{\psi})d\mathbf{y}_{mis} \quad (14)$$

となる。欠測データメカニズムは欠測データ \mathbf{y}_{mis} に依存しているため、この積分を計算するには欠測データメカニズムをモデリングしなければいけない。そのため、欠測データメカニズムをモデルに組み込んだ選択モデルやパターン混合モデルなどを用いた分析が必要になる (村山, 2011)。しかし、欠測データメカニズムのモデリングはかなり難しく、仮定した欠測値発生モデルが正しくない場合には、推定結果にバイアスを与えることが知られている。そのため、NMAR を回避するようにデータ収集を行うべきである (高井他, 2016)。

2.2 伝統的な欠測データ処理とその問題点

本節では、欠測データに対してよく用いられてきた解析手法を紹介し、その問題点について述べる。高井他 (2016) によると手元に完全データが得られなかった場合、欠測データに対する処理は大きく分けて 2 つのアプローチに分けられる。1 つは欠測値に関する部分を無視

して解析を行うという方法であり、特に代表的な方法として完全ケース分析 (complete-case analysis) あるいはリストワイズ削除 (list-wise deletion; LD 法) と呼ばれる方法が挙げられる。リストワイズ削除は、すべての変数についてデータが得られているユニットだけ残し、一部でも変数に欠測があるユニットは削除してから解析を行うという対処方法である。この方法は直感的かつ容易なため、多くの分析で使われてきた。リストワイズ削除を用いた最尤推定法は、欠測データメカニズムが MCAR の下では真のパラメータ値に対する一致性を持つことが知られている。また、MCAR の下でなければ、平均値の推定量や回帰係数の推定値にバイアスが生じてしまう。また、この方法は一部でも欠測がある変数をすべて削除するため、著しくサンプルサイズが小さくなる可能性がある。その場合、推定量の分散は過大評価されてしまうという問題もある (高井他, 2016)。

欠測データに対するもう 1 つのアプローチとして高井他 (2016) や富田 (2018) を参考に、欠測値に値を代入することで擬似完全データ (pseudo-complete data) を作成する代入法を説明する。代入法は、欠測値を補完する方法や補完する回数によって様々な種類が存在する。後述する多重代入法も代入法の 1 つであるが、本節では 1 つの欠測値に 1 つの値を代入する単一代入法 (single imputation) について代表的な手法を紹介し、その問題点について述べる。最も簡単な単一代入法は、平均値代入 (mean imputation) である。これは、観測されている個体の値から推定した平均値を欠測値に代入する方法である。平均値代入は欠測が MCAR の場合、観測値から計算した平均値や回帰分析の係数は不偏性を持ち、バイアスのない推定値となる。しかし、標本分散や不偏分散は過小推定され、推定値の分散も過小評価されてしまうという問題がある。具体的に示すと、割合 r で観測、 $1 - r$ で欠測の場合、欠測値に平均を代入した場合の分散は

$$\frac{1}{N} \times N \{ r E[(x_i - \bar{x})^2] + (1 - r) E[(\bar{x} - \bar{x})^2] \} = r V(X) (0 \leq r \leq 1) \quad (15)$$

となり、分散が過小評価されているのがわかる。

また、単一代入法では、回帰モデルを用いた回帰代入 (regression imputation) も多く用いられる。これは欠測値を観測値の一部で説明する回帰分析モデルによる予測値を欠測値に代入する方法である。データが MAR または MCAR である場合、回帰代入の結果から得られた完全データの平均値は一致性がある。しかし、回帰代入で欠測値の補完を行う場合も、欠測値について残差分散が無視されるため、欠測があった変数の分散を擬似完全データから計算した標本分散や不偏分散で推定した場合、過小評価が生じてしまう。また、回帰代入によって得られる推定量が一致性を持つ場合には、回帰モデルが正しいという条件が必要である (高井他, 2016; 富田, 2018)。

このように、リストワイズ法や単一代入法は、適切な仮定の下でなければ分散パラメータにバイアスが生じてしまう。次節では、この問題を回避するために Rubin (1987) が提案した多重代入の枠組みを説明する。

2.3 多重代入法の概要

多重代入法は、欠測値への補完値の代入を逐次行い、作成した複数の擬似完全データを解析し、得られる複数の推定値を統合して推定を行うという手法である。欠測データメカニズムが MAR の下で妥当性が担保される、代表的な欠測データの解析方法である。以下、欠測値の代入時に用いるモデルを代入モデル、解析時に用いるモデルを解析モデルとする。

多重代入法は一般的に 3 つのステージからなる。まず、代入ステージにおいて、単一代入法やデータ拡大アルゴリズム (data augmentation; Tanner and Wong (1987)) などを利用して、欠測値に値を代入した D 個の擬似完全データセットを作成する。次に、代入ステージで作成された全ての擬似完全データに対して分析を行い、推定値 $\hat{\theta}_1, \dots, \hat{\theta}_D$ とその共分散行列の推定値 W_1, \dots, W_D を得る。これを解析ステージとする。代入ステージで作成された複数の擬似完全データは代入値がデータセットごとに異なるので、解析ステージではデータセットごとに異なる推定値とその共分散行列の推定値が得られる。最後に統合ステージにおいて、Rubin のルール (Rubin, 1987) を用いて、データセットごとに得られた各推定値 $\hat{\theta}_1, \dots, \hat{\theta}_D$ とその共分散行列の推定値 W_1, \dots, W_D を統合し、単一の推定値 $\bar{\theta}_D$ と推定値の共分散行列の推定値 T_D を算出する (高井他, 2016; 富田, 2018; 村山, 2011)。

多重代入法を使う第一の利点として、疑似完全データを一度作成した後は、統計解析において欠測が存在することを考えなくて良い。第二の利点として、推定量の分散の推定が可能ながことが挙げられる。単一代入法では推定量の漸近分散を過小評価することが問題となるが、多重代入法では、複数の補完値に基づく解析結果を統合することにより、漸近分散についても Rubin のルール (Rubin, 1987) によって評価することが可能である (富田, 2018)。

2.3.1 代入ステージ

まず代入ステージについて、高井他 (2016) を基に説明する。Rubin (1987) が提案した多重代入法はベイズ統計学の枠組みで定式化されており、観測値を条件付きとした時の欠測値の事後予測分布 $f(\mathbf{y}_{\text{mis}}|\mathbf{y}_{\text{obs}})$ から発生させた乱数を欠測値に代入するという発想をもとに理論が構築されている。ここで欠測データに MAR の条件が成立していれば

$$f(\mathbf{y}_{\text{mis}}|\mathbf{y}_{\text{obs}}, \mathbf{r}) = f(\mathbf{y}_{\text{mis}}|\mathbf{y}_{\text{obs}}) \quad (16)$$

が成立することから、事後予測分布は

$$f(\mathbf{y}_{\text{mis}}|\mathbf{y}_{\text{obs}}) = \int f(\mathbf{y}_{\text{mis}}|\mathbf{y}_{\text{obs}}, \boldsymbol{\psi}) f(\boldsymbol{\psi}|\mathbf{y}_{\text{obs}}) d\boldsymbol{\psi} \quad (17)$$

と表せる。 $\boldsymbol{\psi}$ は関連するパラメータとする。ただし、実際には単純なモデルを除いてこの事後予測分布を解析的に導出することは難しい。そのため、観測値 \mathbf{y}_{obs} を与えた時の事後分布から $\boldsymbol{\psi}$ を発生させ、その $\boldsymbol{\psi}$ を所与とした予測分布から欠測値 \mathbf{y}_{mis} を発生させるということを D 回繰り返し

$$\boldsymbol{\psi}^d \sim f(\boldsymbol{\psi}|\mathbf{y}_{\text{obs}}), \quad \mathbf{y}_{\text{mis}}^d \sim f(\mathbf{y}_{\text{mis}}|\mathbf{y}_{\text{obs}}, \boldsymbol{\psi}^d) \quad (d = 1, \dots, D) \quad (18)$$

D 個の疑似完全データセット

$$\mathbf{y}^d = (\mathbf{y}_{\text{obs}}^t, \mathbf{y}_{\text{mis}}^{\text{dt}})^t \quad (d = 1, \dots, D) \quad (19)$$

を作成する。上記が Rubin (1987) による多重代入法における代入ステージである。実際には事後分布 $f(\boldsymbol{\psi}|\mathbf{y}_{\text{obs}})$ の漸近分布などからの乱数発生なども行われる場合がある。事後分布 $f(\boldsymbol{\psi}|\mathbf{y}_{\text{obs}})$ を導出することが容易でない場合は、 $f(\boldsymbol{\psi}|\mathbf{y})$ からパラメータを発生させるデータ拡大アルゴリズムを利用する。またここで欠測データメカニズムが MAR であると仮定できれば、非ベイズ統計学の立場から代入が可能である。パラメータ $\boldsymbol{\psi}$ に対する一致推定量 $\hat{\boldsymbol{\psi}}$ を得ることができたとすると、 $\boldsymbol{\psi}$ に $\hat{\boldsymbol{\psi}}$ を代入した予測分布

$$\mathbf{y}_{\text{mis}}^d \sim f(\mathbf{y}_{\text{mis}}|\mathbf{y}_{\text{obs}}, \hat{\boldsymbol{\psi}}) \quad (d = 1, \dots, D) \quad (20)$$

から欠測値を発生させることができる。この場合、統合ステージで得られる推定量の分散が小さくなることが知られている。

2.3.2 解析ステージ

続いて、高井他 (2016) を参考に解析ステージについてを以下に記述する。

代入ステージにおいて、複数の疑似完全データが得られたら、これらを完全データとみなしてパラメータ $\boldsymbol{\theta}$ の推定を行う。Rubin (1987) の枠組みでは、解析モデルでは事後平均や事後分散あるいはその近似値を用いることを前提とした議論が行われている。また、代入モデルと解析モデルは必ずしも同じである必要はない。解析ステージでは本来の関心のパラメータ $\boldsymbol{\theta}$ の推定が行われるが、これは必ずしも代入ステージでの予測分布のパラメータ $\boldsymbol{\psi}$ と等しい必要はなく、 $\boldsymbol{\psi}$ の一部分や関数でもよい。

本稿の解析では傾向スコア、IPW 推定量を用いた因果効果の推定を行った。

2.3.3 統合ステージ

最後の統合ステージについても、高井他 (2016) を参考に述べる。統合ステージでは、得られた複数の推定値を統合する方法として、Rubin のルールが用いられる。これは Rubin (1987) がベイズの漸近理論を用いて導出したものであり、代入ステージと解析ステージが共にベイズ統計学の枠組みで行われた推定に限定される性質である。

パラメータ $\boldsymbol{\theta}$ に対して、疑似完全データを利用した際の D 個の推定値 $(\hat{\boldsymbol{\theta}}_1, \dots, \hat{\boldsymbol{\theta}}_D)$ とその共分散行列の推定値 (W_1, \dots, W_D) が得られているとき、統合した推定値 $\bar{\boldsymbol{\theta}}_D$ は、単純に算術平均より

$$\bar{\boldsymbol{\theta}}_D = \frac{1}{D} \sum_{d=1}^D \hat{\boldsymbol{\theta}}_d \quad (21)$$

となる。また、代入値内共分散行列の平均

$$\bar{W}_D = \frac{1}{D} \sum_{d=1}^D W_d \quad (22)$$

および推定量の代入値間共分散行列の推定値

$$B_D = \frac{1}{D-1} \sum_{d=1}^D (\hat{\theta}_d - \bar{\theta}_D)^2 \quad (23)$$

より、推定量の共分散行列の推定値 T_D は、

$$T_D = \bar{W}_D + \left(1 + \frac{1}{D}\right) B_D \quad (24)$$

となる。この結果は関心のあるパラメータ θ の事後分布が

$$f(\theta | \mathbf{y}_{\text{obs}}) = \int f(\theta | \mathbf{y}_{\text{mis}}, \mathbf{y}_{\text{obs}}) f(\mathbf{y}_{\text{mis}} | \mathbf{y}_{\text{obs}}) d\mathbf{y}_{\text{mis}} \quad (25)$$

と表現できること、つまり、式 (17) から発生させた欠測値 $\mathbf{y}_{\text{mis}}^d$ を代入した擬似完全データセット $(\mathbf{y}_{\text{mis}}^d | \mathbf{y}_{\text{obs}})$ を複数作成し ($d = 1, \dots, D$)、それらデータごとに事後分布 $f(\theta | \mathbf{y}_{\text{mis}}^d, \mathbf{y}_{\text{obs}})$ を計算し、平均することで推定できることから導かれる。

2.4 連鎖方程式による多重代入

本節では、連鎖式による多重代入法に説明する。野間 (2017) によれば、一般的な多重代入法の補完値の生成アルゴリズムは、データセットの中で、1つの変数のみに欠測が起こったものという仮定のもと、観測値からそれを予測するというものである。しかし、多くの調査・実験研究において、特定の1つの変数に限定して欠測が生じるという都合のよい欠測パターンが起こることはほとんどなく、実際には、複数の変数において、ユニットごとに異なるパターンで欠測が生じる場合がほとんどである (野間, 2017)。また、高井他 (2016) によると、このとき、欠測のあるすべての変数の同時分布のモデルを仮定し、条件付き分布 $p(\mathbf{y}_{\text{mis}} | \mathbf{y}_{\text{obs}})$ を求めて代入値を発生させるが、同時分布のモデル仮定は難しい場合が多い。特に離散変数と連続変数が混合している多変量データでは、同時分布を仮定することは困難である。このような場合において、マルコフ連鎖モンテカルロ法的一种であるギブスサンプラーへの類推からデータ拡大アルゴリズムを行おうとするのが完全条件付き分布の指定 (fully conditional specification; FCS; (Buuren et al., 2006)) 法である。これは、同時分布の指定を行わず、1変数の条件付き分布から逐次的に欠測値を補完していくという方法論である。本稿では FCS のうち、代表的なアルゴリズムとして連鎖式による多重代入 (multiple imputation by chained equation; MICE; (Buuren, 2012)) を用いる (高井他, 2016)。

MICE の具体的な手順は高井他 (2016) より参考に、以下に示す。

Step 0 まず、一部のユニットに欠測が存在する変数 y_1, \dots, y_J すべてについて、他の変数を所与とした条件付き分布を指定する。たとえば変数 y_i については $p(y_i | \mathbf{y}_{-i}, \theta_j)$ を指定する。ただし \mathbf{y}_{-i} は、 \mathbf{y} から y_i を除いたベクトルとする。具体的な条件付き分布の例として、たとえば y_j が 2 値変数であればロジスティック回帰モデル、名義尺度水準の多値変数であれば多項ロジスティック回帰モデル、順序尺度水準の多値変数であれば順

序ロジスティック回帰モデル、連続変数であれば誤差に正規分布を仮定した線形回帰モデルを仮定し、それぞれそれらのモデルの説明変数として \mathbf{y}_{-j} を利用する。連続変数であるが、正規性・線形性の仮定が妥当でない場合は予測平均マッチングによる補完値の生成を行う。

Step 1 y_j の欠測値を観測値からランダムに抽出し、これを初期値 y_j^0 とし、擬似完全データを作成する。

Step 2 各 j について

$$\boldsymbol{\theta}_j^d \sim p(\boldsymbol{\theta}_j | y_1^d, \dots, y_{j-1}^d, y_{obs,j}, y_{j+1}^{d-1}, \dots, y_J^{d-1}) \quad (26)$$

$$y_j^d \sim p(y_j | y_1^d, \dots, y_{j-1}^d, y_{j+1}^{d-1}, \dots, y_J^{d-1}, \boldsymbol{\theta}_j^d) \quad (27)$$

のようにパラメータと欠測値を発生させ、最新の値として更新する。

Step 3 上記 Step 1 を j が 1 から J まで行う。

Step 4 上記 Step 2、Step 3 についてなるべく多く反復回数 d を設定し、そのうちの最初の方のものをギブスサンプラー同様に“Burn-in”フェーズとして捨て、その後 D 個をとってきて統計的推測を行う。上記の Rubin (1987) による多重代入と同様に複数の疑似完全データセットを作成し、何らかの解析を行い、そのパラメータの推定量を Rubin のルールで統合する。

アルゴリズムそのものは、ギブスサンプリングに似たものとなっているが、上記 2,3 でのそれぞれの補完値の生成が、観測値が与えられたもとでの事後予測分布からのサンプリングになっていれば、これは正確はギブスサンプリングに一致することになる。しかしながら、上記に示した比較的簡便なパラメトリックモデルを用いた補完値の生成は、厳密な意味でのギブスサンプリングに一致しない (野間, 2017)。

3 実証分析

本章では実際のデータを用いて欠測値補完並びに因果効果の推定を行う各モデルを構築し、その検証をする。3.1 節では、本稿で使用したデータについて説明する。また、欠測値補完とモデル構築に際し行ったデータの加工手順を概説する。3.2 節では、本稿の解析ステージで用いた因果効果の推定方法を本稿に即して説明する。3.3 節では、欠測値の補完を行う前のデータセットを用いて因果効果推定を行い、検証を行う。3.4 節では、連鎖方程式による多重代入によって欠測値の補完を行ったデータセットに対し、因果効果推定を行い、推定結果について前節の結果と比較する。3.5 節では、世帯所得によって因果効果に異質性があるか分析する。

3.1 使用データとその加工

3.1.1 データの概要

本稿の実証分析では兵庫県芦屋市の国民健康保険が保有する医療保険のレセプトデータ・特定健診の受診券発行者データ・健康診断データ・世帯所得データを使用した。なお、1 章でも触れた通りすべてのデータは匿名化処理がなされており、個人の特定は不可能となっている。

ここでは、次項以降で扱うデータの説明を行う。上記のいずれもパネルデータであるため、本稿の対象者（世帯）を確定させた上で各データと紐づける必要がある。そこで、本稿では対象者を「2013年4月から2019年3月まで兵庫県芦屋市の国民健康保険に加入していた者」のうち、「2016年度時点で満43歳以上72歳未満である者」とした。年齢は2013年4月から2019年3月までの間に40歳以上75歳未満（特定健診の対象）であったことが基準である。2016年度時点で特定健診の対象である42歳以下・73歳以上の者を対象者に含めなかった理由は、提供されたデータだけでは、2013年4月から2019年3月まで兵庫県芦屋市の国民健康保険に加入していたかどうかを追跡できなかったからである。以上により、8149人が今回の分析対象となる。

3.1.2 データの加工

提供を受けたレセプトデータは外来、入院、調剤別に分けられていた。まず、これらのレセプトデータを年度別に分割した。その後、各個人のユニークキーを元に診療報酬点数を合算した。加工の具体的な手順は図4である。これにより年度・個人別の外来・入院・調剤の診療報酬点数が得られた。このうち、2013年度から2015年度の外来・入院・調剤の点数を x_r とした。また、2017, 2018年度の外来と調剤の診療報酬点数の合算点数と入院のみ診療報酬点数を作成し、これを y とする。また、上記に定義した対象者の生年月日から2016年度の年齢を作成し、これと性別、年度別に分けた世帯所得データを属性 x_d とした。提供を受けた健康診断データから2015年度の健康診断データ x_w を抽出した。上記に定義した対象者のリストから2016年度の健康診断データの有無を用いて、2016年度の健康診断の受診有無変数 z を作成した。最後に、対象者の属性 x_d 、2013年度から2015年度の外来・調剤・入院の診療報酬点数 x_r 、過去の健診変数 x_w 、2016年度の受診有無 z 、2017, 2018年度の外来・調剤診療報酬点数の合算および入院の診療報酬点数 y を対象者別のユニークキーによって結合した。なお本章次節以降では、診療報酬点数を「医療費」と定義している。

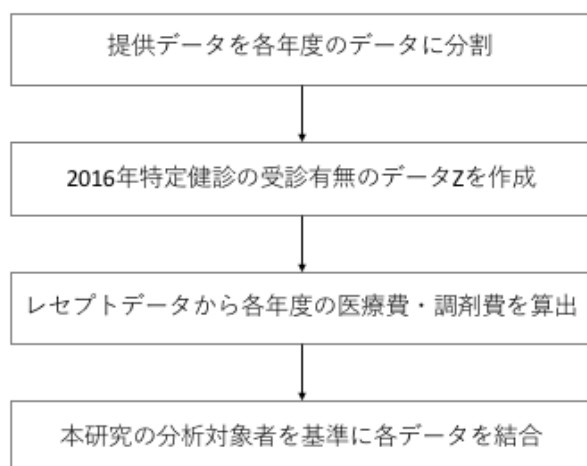


図4 データの加工手順

なお、基本統計量および欠測数は表4と表5の通りである。ただし、表4は本稿対象者全体の基本統計量、表5は2015年度の特定健診を受診し、かつ情報に欠測がない人に限定した完全ケースデータの基本統計量である。ただし、所得は記載していない。

表4: 欠測を含む全体の基本統計量

変数	欠測数	平均	標準偏差	データタイプ
性別	0			カテゴリー変数
2016年時点での年齢	0	62.512210	8.606177	数字
身長	4986	160.132785	8.410616	数字
体重	4986	56.337401	11.104448	数字
BMI	4986	21.855580	3.208066	数字
腹囲	4986	80.369017	9.435366	数字
既往歴コード	4986			カテゴリー変数
自覚症状コード	4986			カテゴリー変数
他覚症状コード	4987			カテゴリー変数
収縮期血圧	4986	124.310465	17.053875	数字
拡張期血圧	4986	74.365792	11.025182	数字
中性脂肪(トリグリセリド)	4987	106.214421	66.994097	数字
HDLコレステロール	4987	68.033839	17.655956	数字
LDLコレステロール	4987	129.077166	32.194448	数字
GOT(AST)	4987	23.296015	8.393459	数字
GPT(ALT)	4987	19.946553	12.098823	数字
γ-GT(γ-GTP)	4987	33.758065	43.480264	数字

表は次ページに続く

前ページからの続き

変数	欠測数	平均	標準偏差	データタイプ
空腹時血糖	5147	96.127249	18.018756	数字
H b A 1 c (NGSP 値)	4988	5.664821	0.609219	数字
尿糖	4991			カテゴリ変数
尿蛋白	4991			カテゴリ変数
メタボリックシンドローム判定	4987			カテゴリ変数
保健指導レベル	4986			カテゴリ変数
服薬 1 (血圧)	4986			カテゴリ変数
服薬 2 (血糖)	4986			カテゴリ変数
服薬 3 (脂質)	4986			カテゴリ変数
既往歴 1 (脳血管)	5033			カテゴリ変数
既往歴 2 (心血管)	5034			カテゴリ変数
貧血	5034			カテゴリ変数
喫煙	4986			カテゴリ変数
飲酒	4988			カテゴリ変数
保健指導の希望	5049			カテゴリ変数
2013 年度外来の医療費	0	13,911.901828	31,627.439998	数字
2014 年度外来の医療費	0	13,680.268376	33,505.429932	数字
2015 年度外来の医療費	0	16,254.999018	38,232.969284	数字
2016 年度外来の医療費	0	17,418.220000	43,610.720000	数字
2013 年度入院の医療費	0	7,466.594000	48,402.490000	数字
2014 年度入院の医療費	0	7,050.672000	44,723.610000	数字
2015 年度入院の医療費	0	8,898.538000	51,960.920000	数字
2016 年度入院の医療費	0	10,053.840000	59,009.150000	数字
2013 年度調剤の医療費	0	5,856.766229	12,155.523529	数字
2014 年度調剤の医療費	0	6,300.882194	12,823.918841	数字
2015 年度調剤の医療費	0	7,208.214259	19,220.001517	数字
2016 年度調剤の医療費	0	7,874.858265	24,084.684676	数字
結果変数：外来と調剤の合算	0	54,608.710000	112,708.200000	数字
結果変数：入院の合算	0	23,202.160000	105,021.200000	数字

以上

表 5: 完全ケースデータの基本統計量

変数	平均	標準偏差	データタイプ
性別			カテゴリ変数

表は次ページに続く

前ページからの続き

変数	平均	標準偏差	データタイプ
2016年時点での年齢	64.502387	7.592644	数字
身長	160.034823	8.375631	数字
体重	56.158697	11.001146	数字
BMI	21.817326	3.203211	数字
腹囲	80.206378	9.388552	数字
既往歴コード			カテゴリー変数
自覚症状コード			カテゴリー変数
他覚症状コード			カテゴリー変数
収縮期血圧	124.281037	17.118931	数字
拡張期血圧	74.260573	11.086782	数字
中性脂肪（トリグリセリド）	104.180082	65.249125	数字
HDLコレステロール	68.259891	17.615844	数字
LDLコレステロール	129.064461	32.244962	数字
GOT（AST）	23.312756	8.400058	数字
GPT（ALT）	19.898363	12.020478	数字
γ-GT（γ-GTP）	33.386767	40.424814	数字
空腹時血糖	96.04502	17.961520	数字
HbA1c（NGSP値）	5.659175	0.601687	数字
尿糖			カテゴリー変数
尿蛋白			カテゴリー変数
メタボリックシンドローム判定			カテゴリー変数
保健指導レベル			カテゴリー変数
服薬1（血圧）			カテゴリー変数
服薬2（血糖）			カテゴリー変数
服薬3（脂質）			カテゴリー変数
既往歴1（脳血管）			カテゴリー変数
既往歴2（心血管）			カテゴリー変数
貧血			カテゴリー変数
喫煙			カテゴリー変数
飲酒			カテゴリー変数
保健指導の希望			カテゴリー変数
2013年度外来の医療費	13390.863915	13,521.610793	数字
2014年度外来の医療費	12649.858799	12,898.620277	数字
2015年度外来の医療費	15168.936221	17,540.110710	数字
2016年度外来の医療費	16792.110000	36,687.070000	数字

表は次ページに続く

前ページからの続き

変数	平均	標準偏差	データタイプ
2013 年度入院の医療費	4733.698840	31,810.026717	数字
2014 年度入院の医療費	4749.747613	30,350.895720	数字
2015 年度入院の医療費	4430.194748	25,813.680633	数字
2016 年度入院の医療費	6927.754000	44,805.010000	数字
2013 年度調剤の医療費	5826.904502	10,200.199409	数字
2014 年度調剤の医療費	6303.218963	10,395.372931	数字
2015 年度調剤の医療費	6790.815143	12,290.559136	数字
2016 年度調剤の医療費	7540.876194	20,162.305476	数字
結果変数：外来と調剤の合算	52761.340000	91,784.410000	数字
結果変数：入院の合算	18191.420000	74,421.540000	数字

以上

当該箇所でも改めて詳述するが、今回の分析は、

1. 対象 8149 人について、健康診断の情報をを用いた分析
2. 2015 年度の特定健診を受診した情報無欠測の 2931 人に限定し健康診断の情報も加味した分析
3. 対象 8149 人について、健康診断の情報も加味した分析

の 3 パターンに分けられる。このうち、1 については健康診断の情報をを用いていないことで正しい推定を行えない可能性がある。また、2 については、完全ケースに限定していることから、対象者の分布が偏っている。例えば年齢で見ると、1, 3 の場合は第一四分位数が 56 歳であるのに対して、2 の完全ケースでは 62 歳となっており、対象者が高齢者に偏っていることがわかる。これは、60 歳未満の特定健診受診率が低いことと合致する事実である。そのため、多重代入法を用いて作成したデータに依拠した 3 の分析が最も精度が高いと考えられる。

3.2 因果効果推定の理論

本節では、本稿で用いた因果効果推定の理論を概説する。

3.2.1 因果効果の定義

本稿では、「2016 年度に特定健診を受診する」という処置によりどのような効果があったか分析した。しかし、図 5 の通り「2016 年度に特定健診を受けた群（処置群）」がもし特定健診を受けなかった場合の医療費や、「2016 年度に特定健診を受けなかった群（対照群）」が特定健診を受けた場合の医療費を観測することはできない。これは因果推論の根本問題 (Fundamental Problem of Causal Inferences) と呼ばれるが (Holland, 1986)、これを解決するために Rubin の因果効果モデルを利用する。

本稿では、因果効果を以下の通りに定義した。理論の詳細は星野 (2009) や岩崎 (2015) を参

		2016年特定健康診査	
		受診($z = 1$)	未受診($z = 0$)
受診した場合の 2017・2018年 調剤費・医療費	y_1	2016年特定健診 受診者のデータ	欠測
	y_0	欠測	2016年特定健診 未受診者のデータ

図5 欠測のイメージ

照されたい。

対照群での平均処置効果 (Average treatment effect on the untreated ; ATU)

$$ATU = E(y_1 - y_0 | z = 0) = E(y_1 | z = 0) - E(y_0 | z = 0) \quad (28)$$

ただし、ここで y は独立変数すなわち 2017, 2018 年度の医療支出、 z は 2016 年度の特定健診の受診有無を表すダミー変数である。

3.2.2 傾向スコアの概要

次に、傾向スコアについて概説する。傾向スコアは Rosenbaum and Rubin (1983) によって提唱された統計解析の手法であり、様々な交絡因子を含む共変量を調整して次元に集約する方法である。本稿の場合は、対象者の第 i 人の共変量を \mathbf{x}_i 、2016 年度の特定健診受診有の割当変数を z_i としたとき、傾向スコアは第 i 人が特定健診を受診する確率 e_i と定義され、

$$e_i = p(z_i = 1 | \mathbf{x}) \quad (29)$$

と表される (ただし $0 \leq e_i \leq 1$)。

ここで、傾向スコア e_i の真値はわからないことから推定を行う必要がある。 $z_i = 1$ となる確率をロジスティック回帰モデルで表すと、

$$p(z_i = 1 | \mathbf{x}) = e_i = \frac{1}{1 + \exp(-\boldsymbol{\alpha}_i^T \mathbf{x})} \quad (30)$$

となる。この時、割り当てに対する尤度は

$$\prod_i \left(\frac{1}{1 + \exp(-\boldsymbol{\alpha}^T \mathbf{x})} \right)^{z_i} \left(1 - \frac{1}{1 + \exp(-\boldsymbol{\alpha}^T \mathbf{x})} \right)^{1-z_i} \quad (31)$$

となり、これを最大化する最尤推定値 $\hat{\boldsymbol{\alpha}}_i$ を用いることで、第 i 人の傾向スコアの推定値は

$$\hat{e}_i = \frac{1}{1 + \exp(-\hat{\boldsymbol{\alpha}}^T \mathbf{x})} \quad (32)$$

となる。

ただし、因果効果を適切に推定するためには、“強く無視できる割り当て (ignorable assignment)” (Rosenbaum and Rubin, 1983) が前提となるように適切に共変量の選定を行う必要がある。これを間接的に確認する方法はいくつかあるが、今回は c 統計量を指標と用いる。0.8 以上が望ましいとされるが、議論が様々ある。 c 統計量の議論については田原他 (2018) などを参照されたい。

3.2.3 傾向スコアの用いた因果効果推定の方法

続いて、傾向スコアを用いた因果効果の推定方法について説明する。傾向スコアは様々な実証分析に応用されているが、因果効果の推定方法はマッチング・層別解析などいくつか存在する (星野・岡田 (2006) など)。

そこで、本稿では Rubin (1985) が提唱する「傾向スコアによる重み付け推定法」を用いることとする。近年では逆確立による重み付けを用いた IPW 推定量 (inverse probability weighting estimator : IPWE) と呼ばれることが多い。この推定法を用いることで、興味のある群の周辺期待値を求めることができる。そこで、IPW 推定量を用いた対照群の平均処置効果 (ATU) を説明する。

傾向スコアの逆数の重みの和は、

$$W_1 = \sum_{i=1}^N \frac{1-z_i}{e_i}, \quad W_0 = \sum_{i=1}^N z_i \quad (33)$$

となる。この重みの和 W を使い、 $(y_1|z_i=0)$, $(y_0|z_i=0)$ の周辺期待値の推定値 $\hat{E}(y_1|z_i=0)$, $\hat{E}(y_0|z_i=0)$ を表現すると

$$\hat{E}(y_1|z_i=0) = \frac{1}{W_1} \sum_{i=1}^N \frac{(1-z_i)y_i}{e_i} \quad \hat{E}(y_0|z_i=0) = \frac{1}{W_0} \sum_{i=1}^N z_i y_i \quad (34)$$

となる。また、両者の差が対照群の平均処置効果の推定値 $\hat{\tau}^*$ であるから、

$$\hat{\tau}^* = \frac{1}{W_1} \sum_{i=1}^N \frac{(1-z_i)y_i}{e_i} - \frac{1}{W_0} \sum_{i=1}^N z_i y_i \quad (35)$$

となる。

このとき、因果効果の IPW 推定量が一致推定量であることを示す。傾向スコアを $e(x_i)$ と置くと、 $(y_1|z_i=0)$ の IPW 推定量は

$$E\left(\frac{1}{N_1} \sum_i \frac{(1-z_i)y_{i1}}{e_i}\right) = \frac{1}{N_1} \sum_i E\left(\frac{(1-z_i)y_{i1}}{e_i}\right) \quad (36)$$

$$= E\left(\frac{(1-z_i)y_{i1}}{e_i}\right) \quad (37)$$

強く無視できる割り当て条件が成立していると仮定し、 \mathbf{x} を条件付けると

$$E\left(\frac{(1-z_i)y_{i1}}{e_i}\right) = E\left(E\left(\frac{(1-z_i)y_{i1}}{e_i} \mid \mathbf{x}\right)\right) \quad (38)$$

ここで、 $e_i = \frac{1}{1+\exp(-\hat{\alpha}^T \mathbf{x})}$ であることに注意して、

$$E\left(\frac{1}{e_i} E(1 - z_1 | \mathbf{x}) E(y_{i1} | \mathbf{x})\right) = E(E(y_{i1} | \mathbf{x}, z_i = 0)) = E(y_1 | z_i = 0) \quad (39)$$

$(y_0 | z_i = 0)$ も同様に、

$$E\left(\frac{1}{N_0} \sum_i z_i y_{i0}\right) = \frac{1}{N_0} \sum_i E(z_i y_{i0}) \quad (40)$$

$$= E(z_i y_{i0}) \\ E(z_i y_{i0}) = E(E(z_i y_{i0} | \mathbf{x})) = E(y_0 | z_i = 0) \quad (41)$$

よって、傾向スコア $e(x_i)$ が真値である場合には IPW 平均推定量の不偏性が成立し、正しく対照群の平均処置効果 (ATU) を推定できる。

3.3 欠測補完以前のデータセットを用いた因果効果の推定

本節では、多重代入法によって欠測補完を行わず、欠測データを用いて因果効果を推定した場合の分析結果とその問題点を説明する。

3.3.1 特定健診の受診の有無が無作為割り当てであると仮定した場合の因果効果

最初に、2016 年度の特定健診の受診有無 z が完全に無作為で割り当てられたと仮定した場合の健診受診群と健診未受診群の結果を比較する。完全無作為で割り当てられた時、結果変数である医療費は共変量に依存せず、健診受診の有無のみに影響される。この時、次の関係式が成り立つ。

$$E(y_1 - y_0) = E(y_1) - E(y_0) = E(y_1 | z = 1) - E(y_0 | z = 0) \quad (42)$$

つまり、医療費 y は割り当て z の影響を受けないため、「2016 年度に特定健診を受診した時の 2017, 2018 年度の医療費」と「2016 年度に特定健診を受診していない時の 2017, 2018 年度の医療費」の差が、2016 年度の特定健診受診の因果効果と言える。

特定健診受診群の結果変数の平均と標準偏差は表 6、表 7 の通りとなる。健診受診群 ($z = 1$) と未受診群 ($z = 0$) の外来・調剤医療費の平均の差は-2673.91 となり、特定健診を受診した群の方がその後の医療費が低くなるという結果が得られた。また、入院医療費の平均の差も-9739.85 となり、健診受診群の方がその後の医療費が低下するという結論が得られた。しかし、上記で述べた通り、医療費は特定健診の受診以外の要素に影響を受けていると考えられるため、無作為割り当てされたという仮定の下で結論を出すのは尚早である。

また、同様の仮定における健診受診群と健診未受診群の結果の比較を 2015 年度の特定健診受診者に限定して行った。つまり、完全ケースデータ分析の下、 x_w が観測されている対象者のみに限定して結果を比較した。このときの結果変数の平均と標準偏差は表 8、表 9 の通りとなる。健診受診群 ($z = 1$) と未受診群 ($z = 0$) の外来・調剤医療費の平均の差は-13953 となり、特定健診を受診した群の方がその後の医療費が低くなるという結果が得られた。また、

表6 医療費の平均点数 (外来・調剤医療費 (2017,2018 年合計))

	健診受診群	健診未受診群	差
平均値	52999.23	55673.17	-2673.94
標準偏差	82446.44	128873.2	152989.27

表7 医療費の平均点数 (入院の合算 (2017,2018 年合計))

	健診受診群	健診未受診群	差
平均値	17339.6	27079.45	-9739.85
標準偏差	75138.95	120640.4	142126.59

入院医療費の平均の差も-6350 となり、健診受診群の方がその後の医療費が低下するという結論が得られた。

対象者全体において無作為割り当てであると仮定したときの外来・調剤医療費の抑制効果と比較すると、完全ケース分析の下では外来・調剤医療費の抑制効果は大きくなっている。反対に、入院医療費の抑制効果は小さくなっていることがわかる。

外来・調剤医療費の抑制効果が大きくなっている点については、完全ケース分析の対象者が少なくとも 2015, 2016 年度の特定健診を受診しており、健康に気を使っている人が多いことが背景として考えられる。一方、入院医療費の抑制効果が小さい点については、完全ケースデータに限定したことで、入院費が高額であった対象者が除外された可能性が考えられる。そもそも完全ケースでは、健診受診群 ($z = 1$) が 2349 人、健診未受診群 ($z = 0$) が 413 人と二群のサンプルサイズが大きく乖離しており、単純な差からは結論付けられない。

表8 完全ケースデータの場合の外来・調剤費用の合算

	健診受診群	健診未受診群	差
平均値	50485	64438	-13953
標準偏差	62082.57	191409.6	201225.94

表9 完全ケースデータの場合の入院費用合算

	健診受診群	健診未受診群	差
平均値	17492	23842	-6350
標準偏差	75000.48	82100.88	111200.84

3.3.2 特定健診データを用いない場合の IPW 推定量を用いた効果検証

前項では、無作為割り当てを仮定した際は共変量の影響を考慮せずに二群の結果を単純比較したが、本項では傾向スコアを算出し、逆確率による重み付けを用いた IPW 推定量で因果効果の検証を行う。

対象者 i に対して特定健診受診 ($z = 1$) に割り当てられる予測確率を、前節で述べた共変量 \mathbf{x} に回帰するロジスティックモデルで傾向スコアの推定値

$$\hat{e}_i = \frac{1}{1 + \exp(-\hat{\boldsymbol{\alpha}}^T \mathbf{x})} \quad (43)$$

を算出する。ただし、ここでの共変量は属性 \mathbf{x}_d 、過去の医療費 \mathbf{x}_r である。この値は各対象者について算出され、その対象者が特定健診受診群に割り当てられる確率を示している。表 10 は変数名と偏回帰係数とその有意性を確認するための Wald 検定検定統計量、p 値をまとめたものである。

表 10 共変量と検定統計量

共変量	偏回帰係数	Wald 検定統計量	p 値
2016 年時点での年齢	4.905384e-02	16.78	<0.0001
性別	1.750251e-01	3.65	0.0003
2012 年度所得区分	9.757992e-03	0.55	0.5818
2013 年度所得区分	3.794467e-02	2.02	0.0435
2014 年度所得区分	-3.387066e-02	-1.61	0.1074
2015 年度所得区分	-9.123534e-03	-0.49	0.6222
2013 年度外来医療費	3.054861e-06	1.67	0.0945
2014 年度外来医療費	-4.090378e-06	-2.02	0.0438
2015 年度外来医療費	1.110742e-06	0.96	0.3373
2013 年度入院医療費	-2.508748e-06	-3.38	0.0007
2014 年度入院医療費	-1.008214e-06	-1.33	0.1831
2015 年度入院医療費	-1.920957e-06	-2.95	0.0031
2013 年度調剤医療費	-9.091553e-06	-1.76	0.0784
2014 年度調剤医療費	9.852239e-06	1.86	0.0626
2015 年度調剤医療費	-4.223050e-06	-1.69	0.0908

算出した推定値をもとに、IPW 推定量による特定健診の受診の因果効果を検証する。健診未受診群について、IPW 推定量の外来と調剤の合算診療報酬点数の推定値を計算すると、

$$\hat{E}(y_1|z=0) = 53453.329, \hat{E}(y_0|z=0) = 55673.169 \quad (44)$$

となり、これを用いて外来・調剤医療費の ATU を算出すると次のようになる。

$$\widehat{ATU} = \hat{E}(y_1|z=0) - \hat{E}(y_0|z=0) = -2219.840 \quad (45)$$

同様に入院医療費の ATU を算出すると、

$$\widehat{ATU} = \hat{E}(y_1|z = 0) - \hat{E}(y_0|z = 0) = 17495.411 - 27079.449 = -9584.038 \quad (46)$$

となる。表 11 は ATU の結果をまとめたものである。外来・調剤医療費の群間差は単純比較した際の群間差より大きくなったが、入院医療費の群間差は小さくなった。以上のモデルより、特定健診を受診していない人が受診することで、2 年間で外来・調剤の医療報酬点数が 2219.84 点、入院医療費が 9584.038 点抑制される効果があると結論付けられる。

表 11 健診変数を用いない場合・ATU の平均と標準誤差

		健診受診群	健診非受診群	差
外来・調剤医療費	平均	53453.329	55673.169	-2219.84
外来・調剤医療費	標準誤差	2263.371	1548.681	2742.492
入院医療費	平均	17495.411	27079.449	-9584.038
入院医療費	標準誤差	2124.291	1453.517	2573.971

次に、本モデルの検証および考察を行う。前項で説明した c 統計量は、 \mathbf{x}_d および \mathbf{x}_i を共変量として選定した今回は 0.622 であった。所得と受診行動や医療支出には一定の関係が指摘されており (社会保険実務研究所, 2016)、過去の受診の医療支出と合わせて、共変量として必要な変数である。しかし、特定健診から得られる情報も受診行動や医療支出と強い関係を持つと考えられる。共変量の選定にあたっては、結果変数や割り当てに影響する変数を選ぶべきであることから、次項以降では特定健診から得られる情報 \mathbf{x}_w も共変量に選定した分析を行う。

3.3.3 完全ケースデータを用いた場合の IPW 推定量を用いた効果検証

前項と同様に、完全ケース分析の下、 \mathbf{x}_w が観測されている対象者のみに限定して傾向スコアを算出し、逆確率による重み付けを用いた IPW 推定量で因果効果の検証を行った。ここでは、対象者 i に対して特定健診受診 ($z = 1$) に割り当てられる予測確率を、前節で述べた共変量 \mathbf{x} に回帰するロジスティックモデルで傾向スコアの推定値

$$\hat{e}_i = \frac{1}{1 + \exp(-\hat{\boldsymbol{\alpha}}^T \mathbf{x})} \quad (47)$$

を算出する。ただし、ここでの共変量は属性 \mathbf{x}_d 、過去の医療費 \mathbf{x}_r に加えて特定健診から得られる変数 \mathbf{x}_w である。上記同様この値は各対象者について算出され、その対象者が特定健診受診群に割り当てられる確率を示している。表 12 は変数名と偏回帰係数とその有意性を確認するための Wald 検定の検定統計量、p 値をまとめたものである。

算出した推定値をもとに、IPW 推定量による特定健診受診の因果効果を検証する。まず、IPW 推定量の外来・調剤医療費の推定値を計算すると、

$$\hat{E}(y_1|z = 0) = 52692.923, \hat{E}(y_0|z = 0) = 64437.554 \quad (48)$$

となり、これを用いて外来・調剤医療費の ATU を算出すると次のようになる。

$$\widehat{ATU} = \hat{E}(y_1|z = 0) - \hat{E}(y_0|z = 0) = -11744.631 \quad (49)$$

同様に入院医療費の ATU を算出すると、

$$\widehat{ATU} = \hat{E}(y_1|z = 0) - \hat{E}(y_0|z = 0) = 17867.812 - 23842.174 = -5974.363 \quad (50)$$

となる。表 13 は ATU の結果をまとめたものである。以上のモデルより、特定健診を受診していない人が受診することで、2 年間で外来・調剤の医療報酬点数が 11744.631 点、入院医療費が 5974.363 点抑制される効果があると結論付けられる。

次に、本モデルの検証および考察を行う。前項で説明した c 統計量は、 \mathbf{x}_d および \mathbf{x}_i と \mathbf{x}_w を共変量として選定した今回は 0.653 であった。実際に算出された ATU をみると、前項で行った「健診変数を用いない分析」と比べて、外来・調剤医療費の抑制効果はおよそ 5 倍に評価されている一方、入院医療費は約 0.5 倍と評価されている。しかし、3.3.1 項でも述べた通り、完全ケース分析ではバイアスのかかった結果となる。そこで、次節では多重代入法を用いた分析を行う。

表 12 共変量と検定統計量

共変量	偏回帰係数	Wald 検定 統計量	p 値	共変量	偏回帰係数	Wald 検定 統計量	p 値
2016 年時点 での年齢	2.543457e- 02	3.04	0.0024	尿糖	5.435085e- 02	0.27	0.7869
性別	-4.373023e- 01	-2.11	0.0346	尿蛋白	-4.236601e- 02	-0.42	0.6731
2012 年度 所得区分	-4.279268e- 02	-1.02	0.3062	メタボリック シンドローム 判定	1.700983e- 01	1.52	0.1291
2013 年度 所得区分	1.493082e- 01	2.71	0.0067	保健指導 レベル	-1.079697e-0	-0.49	0.6207
2014 年度 所得区分	-9.001214e- 02	-1.76	0.0788	服薬 1 (血圧)	-2.043121e- 01	-1.21	0.2253
2015 年度 所得区分	-2.088383e- 04	0.00	0.9963	服薬 2 (血糖)	4.294361e- 01	1.46	0.1450
身長	-4.702884e- 02	-1.09	0.2738	服薬 3 (脂質)	-4.366294e- 01	-2.54	0.0112
体重	6.540717e- 02	1.11	0.2662	既往歴 1 (脳血管)	-9.871404e- 02	-0.25	0.8045
BMI	-1.924120e- 01	-1.26	0.2089	既往歴 2 (心血管)	-2.429631e- 02	-0.09	0.9321
腹囲	7.575556e- 03	0.61	0.5424	貧血	9.563613e- 02	0.46	0.6474
既往歴コード	7.879268e- 03	0.06	0.9494	喫煙	7.970257e- 01	4.72	<0.0001
自覚症状 コード	3.244273e- 01	2.68	0.0074	飲酒	3.998459e- 02	0.52	0.6014
他覚症状 コード	8.919675e- 02	0.27	0.7841	保健指導の 希望	-1.751880e- 02	-0.16	0.8744
収縮期血圧	3.684406e- 03	0.72	0.4701	2013 年度 外来の医療費	1.079509e- 05	1.71	0.0867
拡張期血圧	-1.781665e- 02	-2.35	0.0189	2014 年度 外来の医療費	-8.796039e- 06	-1.27	0.2031
中性脂肪 (ト リグリセリ ド)	-7.616371e- 04	-0.76	0.4462	2015 年度 外来の医療費	1.682192e- 06	0.42	0.6733
HDL コレス テロール	-5.257748e- 03	-1.35	0.1774	2013 年度 入院の医療費	-1.704932e- 06	-0.99	0.3199
LDL コレス テロール	-1.565613e- 03	-0.88	0.3800	2014 年度 入院の医療費	-2.715997e- 06	-1.75	0.0793
GOT (AST)	-1.746950e- 02	-1.70	0.0900	2015 年度 入院の医療費	-6.482441e- 07	-0.31	0.7531
GPT (ALT)	-3.030783e- 03	-0.42	0.6724	2013 年度 調剤の医療費	-1.518256e- 05	-1.22	0.2231
γ-GT (γ-GTP)	7.061807e- 04	0.42	0.6740	2014 年度 調剤の医療費	2.427058e- 05	1.76	0.0778
空腹時血糖	-6.020472e- 03	-1.18	0.2368	2015 年度 調剤の医療費	-1.061670e- 05	-1.78	0.0749
HbA1c (NGSP 値)	1.765396e- 01	1.11	0.2681				

表 13 完全ケース分析の場合・ATU の平均と標準誤差

		健診受診群	健診非受診群	差
外来と調剤の合算	平均	52692.923	64437.554	-11744.631
外来と調剤の合算	標準誤差	1360.191	8842.651	8946.653
入院医療費	平均	17867.812	23842.174	-5974.363
入院医療費	標準誤差	1445.495	9397.216	9507.740

3.4 欠測値補完を行ったデータを用いた分析

本節では、多重代入法を用いて、欠測値補完を行った後のデータを用いた分析を行い、得られた結果から結論を述べる。

3.4.1 多重代入の方法

本稿では、前章で紹介した連鎖方程式による多重代入を用いて欠測値の補完を行った。また、データセット数は 10 個とした。反復回数は 200 回とし、そのうちはじめの 100 回を“Burn-in”フェーズとして捨てた。

3.4.2 因果効果推定の結果と考察

前項で詳述した通り、今回は 10 個のデータセットを得た。そこで、各データセットに対して因果効果の推定を行い ATU を算出し、その後 Rubin のルールを適応して因果効果の点推定値と標準誤差を得た。外来・調剤医療費の ATU は以下である。

$$\widehat{ATU} = \hat{E}(y_1|z=0) - \hat{E}(y_0|z=0) = -6880.0101 \quad (51)$$

また、入院医療費は以下の通りになる。

$$\widehat{ATU} = \hat{E}(y_1|z=0) - \hat{E}(y_0|z=0) = -10385.523 \quad (52)$$

統合後の結果は表 14 である。

共変量選定の基準となる c 統計量は 0.87 から 0.89 の間にすべて収まった。前節までに得られたモデルの問題点は本モデルでは解決されており、精度が高いと考えられる。

以上のモデルより、特定健診を受診していない人が受診することで、2 年間で外来・調剤の医療報酬点数が 6880.0101 点、入院医療費が 10385.523 点抑制される効果があると結論付けられる。

表 14 多重代入後の結果・ATU の平均と標準誤差

		健診受診群	健診非受診群	差
外来・調剤医療費	平均	48793.158	55673.169	-6880.0101
外来・調剤医療費	標準誤差	1541.392	1628.772	2242.496
入院医療費	平均	16693.925	27079.449	-10385.523
入院医療費	標準誤差	1524.346	1596.332	2207.240

3.5 異質性の推定

本稿では様々な条件を用いて因果効果推定を行った。本項では、3.3.2 項でみた「健診変数を用いない場合」について世帯所得による異質性がないか推定を行う。まず計算の便宜上世帯所得の正規化を行い、 $w \sim N(0, 1)$ とする。そこから、健診受診群・未受診群を結果変数（外来・調剤医療費および入院医療費）について単回帰分析を行う。つまり、健診受診群 $z = 1$ と未受診群 $z = 0$ はそれぞれ

$$\begin{cases} Y_1 = \beta_{10} + \beta_{11}w + \epsilon_1 \\ Y_0 = \beta_{00} + \beta_{01}w + \epsilon_0 \end{cases} \quad (53)$$

の式が成り立つ。3.2 節で述べたとおり、IPW 推定量で重み付けすることで $\hat{\beta}_0$ と $\hat{\beta}_1$ それぞれの推定量が求まる。そして、結果変数の対照群の平均介入効果 (ATU) を検証する。

最初に外来・調剤医療費の推定値を求めると、

$$\begin{cases} \hat{\beta}_1 = (54054.9, 681.1)^t \\ \hat{\beta}_0 = (55673.2, -557.3)^t \end{cases} \quad (54)$$

となり、因果効果は以下の式から表せる。

$$E(y_1 - y_0 | w = c) = \hat{\beta}_{10} + \hat{\beta}_{11}w - (\hat{\beta}_{00} + \hat{\beta}_{01}w) = -1618.3 + 1238.4w \quad (55)$$

この式から、 w がそれぞれ -1、0、1 のときの因果効果を測定する。 $w = 0$ は所得が平均値のときの因果効果、 $w = -1$ 、 $w = 1$ はそれぞれ所得が一標準偏差平均から離れた時の効果が測れるため、どの所得の人にとって特に特定健診受診による医療費抑制効果があるか検証できる。

この時各値での因果効果は

$$E(y_1 - y_0|w = -1) = -2856.7 \quad (56)$$

$$E(y_1 - y_0|w = 0) = -1619.3 \quad (57)$$

$$E(y_1 - y_0|w = 1) = -379.9 \quad (58)$$

と推定され、所得によって特定健診受診による外来・調剤医療費の抑制効果には差があることがわかる。特に所得が低い人には高い医療費抑制効果があるが、所得が高くなるにつれて効果が薄くなる。しかし、いずれの場合も抑制効果があることが確認できる。

また入院医療費も同様に、推定値は

$$\begin{cases} \hat{\beta}_1 = (17660, -1321)^t \\ \hat{\beta}_0 = (27079, -4604)^t \end{cases} \quad (59)$$

と求まるので、回帰式は

$$E(y_1 - y_0|w = c) = \hat{\beta}_{10} + \hat{\beta}_{11}w - (\hat{\beta}_{00} + \hat{\beta}_{01}w) = -9419 + 3283w \quad (60)$$

が成立する。よって、各所得帯での因果効果は

$$E(y_1 - y_0|w = -1) = -12702 \quad (61)$$

$$E(y_1 - y_0|w = 0) = -9419 \quad (62)$$

$$E(y_1 - y_0|w = 1) = -6136 \quad (63)$$

となる。

入院医療費についても、外来・調剤医療費と同様に、所得が高くなるほど医療費抑制の効果が下がることが確認できる。しかし、外来・調剤医療費と異なり、所得が高い人にとっても十分な医療費抑制効果が認められる。

標準誤差等を含めた解析結果をまとめたものが表 15、表 16 となる。 $w = 0$ の時の標準誤差は比較的小さい値を取るが、 $w = \pm 1$ のとき値は大きく、ばらつきが大きいことを示している。

また、これらの結果をグラフで表すと図 6[1]、[2] の通りとなり、外来・調剤医療費、入院医療費ともに所得が高くなるほど医療費抑制効果が低くなることがわかる。しかし、平均より一標準偏差が高い群であっても抑制効果があることから、所得が高い人に対しての受診勧奨が否定されるわけではない。

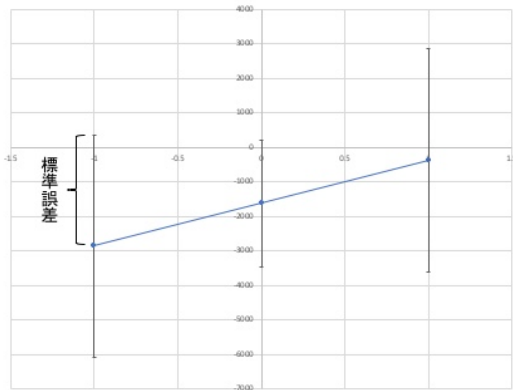
上記の結果により、所得によって医療費抑制効果に差異があることが確認された。対象者の異質性を考慮することで、従来の画一的な受診勧奨をより効率的に行うことが可能であると考えられる。

表 15 外来・調剤医療費の結果

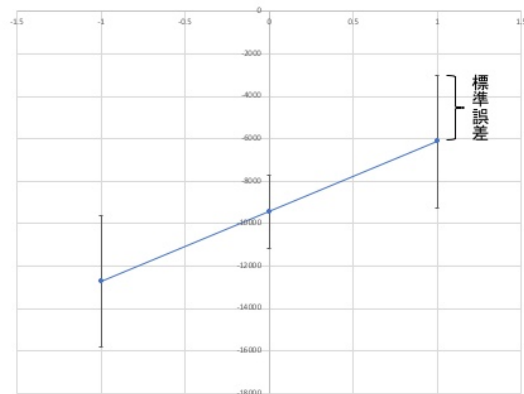
	因果効果	標準誤差
w=-1	-2856.7	3209.827
w=0	-1619.3	1840.3
w=1	-379.9	3241.217

表 16 入院医療費

	因果効果	標準誤差
w=-1	-12702	3089.727
w=0	-9419	1722
w=1	-6136	3123.15



[1] 外来・調剤医療費の群間差



[2] 入院医療費の群間差

図 6 医療費の因果効果の異質性
(*エラーバーは標準誤差を表す)

4 結論

本章では、本稿で主張してきた論点を整理する。まず、4.1 節では、前章の実証分析の結果を基に本稿のまとめを述べる。4.2 節では、実証分析で浮上した課題点についてまとめ、今後の展望を述べる。4.3 節では、特定健診・保健指導の社会的意義について述べる。

4.1 まとめ

本稿の目的は、特定健診の受診有無が医療費に与える効果を測定し、医療費適正化対策としての特定健診の有効性を評価することにある。実証分析では、兵庫県芦屋市の国民健康保険加入者の特定健診結果やレセプトデータ、性別・年齢・所得の属性を用いて、欠測値補完並びに因果効果の推定を行い、特定健診の受診行為には医療費抑制効果があるという結果を証明した。本稿の結論は、以下の通りである。

1. 特定健診を受診することで、その後 2 年間の医療費（外来・調剤医療費および入院医療費）抑制効果があることが個人単位で確認された。そのため、特定健診を受診することが個人にとっても効用があるといえる。
2. 対照群、すなわち「特定健診を受診しなかった人」がもし受診した場合にどのような医

療費削減効果があるのかを IPW 推定法により算出した。その結果、「健診変数を共変量としても用いない場合」「完全ケースデータの場合」「多重代入法を用いた補完を行った場合」のいずれの因果効果推定でも、外来・調剤医療費と入院医療費のいずれも抑制されることが確認された。これにより、特定健診の受診勧奨を今後も進める根拠となった。

3. 異質性の推定により、外来・調剤医療費、入院医療費ともに所得が低い人ほど抑制の効果が高く、その差は大きいことがわかった。この理由としては、高所得者は私費でより詳細な検査結果が得られる人間ドックを受けており、特定健診を受診していない可能性があることや、高所得者のほうが健康意識が高く、普段から健康に気をつけた生活を送っている可能性が高いことなどが考えられる。またこの結果から、各保険者は被保険者の属性を考慮した受診勧奨を推進すべきであるということが言える。

4.2 実証分析の課題と今後の展望

本稿は制約されたデータの中で実証分析を行ったことで、いくつかの課題が生じている。また、今後本稿の分析結果をさらに発展させていくうえで、必要となる分析も存在する。本節ではその中でも特に重要だと考える未実施の分析について取り上げ、それらを加味した今後の展望を述べる。

1. 中長期的な医療費抑制効果の測定の必要性

本稿の実証分析では、2013 年度から 2018 年度の 6 年間を対象とし、2016 年度の特定健診受診有無がその後 2 年間の医療費に与える効果を測定することで、短期的な医療費抑制効果があるという結果は得られた。しかし、中長期的な医療費抑制効果については検討できていない。そのため、より長期間のデータを用いて同様の効果検証を行うことによって、中長期的な医療費抑制効果についても検討する必要がある。

2. 継続的な特定健診受診有無の医療費抑制効果の測定の必要性

上記 1 で述べた通り、本稿では 2016 年度の特定健診受診有無を曝露とし、健診受診群と非受診群の間でその後 2 年間にわたる医療費を比較している。しかし、2014 年度以前や 2016 年度以降も年に 1 回特定健診を受診する機会が研究対象者に与えられている。そのため、本稿で認めた特定健診受診後の医療費抑制効果は単回の健診受診の効果としては過大評価されている可能性がある。

3. 異質性の詳細な検討

本稿の分析においては、「健診変数を用いていない場合」の所得による異質性の推定を行い、所得が低い人ほど医療費抑制効果が高いということが確認されたが、多重代入後の異質性の推定については検討できていない。また、受診勧奨に必要な費用と特定健診受診による効果の比較ができていない。これらを多重代入後のモデルを用いて詳細に分析することで、現在未受診者全体に対して画一的に行われているはがき等で実施されている受診勧奨を、特に医療費抑制

効果の大きい層に対しては個別訪問のような高コストだがより効果の高い勧奨方法に切り替えるなど、より効率的な方法を講じることが可能となる。

4.3 特定健診・保健指導の社会的意義

本稿では、医療費適正化対策としての特定健診の有効性を評価することを目的として効果検証を行い、結果的に特定健診には医療費抑制効果があることが個人単位で確認され、医療費適正化対策としての特定健診には有効性があるということが示された。これにより、これまで医療費抑制効果に対する明確な根拠が示されないまま実施されてきた特定健診制度、及びその実施率向上のための施策を支持する根拠を初めて示すことができた。また、これは被保険者が特定健診を受診する際のインセンティブにもなり、受診勧奨の際にも利用することができる。さらに、異質性の推定により所得の低い人のほうが医療費抑制効果が高いことが確認されたことで、市町村国保をはじめとする保険者に対して、より効率的な受診勧奨を行うための示唆を与えることもできた。

しかしながら、特定健診制度の社会的意義は、決して医療適正化対策としての側面に留まらないということには言及しておきたい。特定健診制度は、生活習慣病の予防・早期発見による国民の生涯にわたる生活の質の維持・向上のための施策でもある。康永 (2017b) は、特定健診を含む予防医療の医療費抑制効果に否定的である一方で、「だからといって、予防医療をやめたり控えたりすべきだと説くつもりは全くありません。予防医療は、国民に健康長寿という何ものにも代えがたい便益をもたらします。ですから、国・地方自治体や医療従事者は今後も引き続き、予防医療を積極的に推進すべきだと考えています。」と国民の健康寿命の延伸という観点では、予防医療の意義を肯定している。つまり、厚労省や各保険者は、本稿において示された医療費抑制効果の有無に関わらず、国民の健康寿命の延伸や生活の質の維持・向上のためには、今後も特定健診制度の実施及び受診率の向上を推進していく必要がある。^{*11}

5 謝辞

本稿を作成するにあたって、星野崇宏先生（慶應義塾大学経済学部）をはじめ、多くの方々から有益且つ熱心な助言を賜りました。厚く感謝を申し上げます。また、本稿の分析に際してなくてはならなかった重要なデータを提供して下さった芦屋市役所の皆様及び日本システム技術株式会社の皆様にもこの場を借りて深く御礼申し上げます。

^{*11} 但し、海外では健診の健康改善効果についても有益性を疑問視する研究が複数あり (Krogstbøll et al., 2012; Jørgensen et al., 2014)、日本と海外では健診制度等の違いが大きいため結果をそのまま用いることは適切ではないが、健康改善効果に関しても今後研究の必要があると言える。

参考文献

- Amemiya, Takeshi (1985) *Advanced econometrics*: Harvard university press.
- Buuren, Stef van. (2012) *Flexible imputation of missing data*, Chapman & Hall/CRC interdisciplinary statistics, Boca Raton: CRC Press.
- Buuren, Stef van., J. P.L Brand, C. G.M Groothuis-Oudshoorn, and D. B Rubin (2006) “Fully conditional specification in multivariate imputation,” *Journal of Statistical Computation and Simulation*, Vol. 76, No. 12, pp. 1049-1064.
- Glynn, R.J., N.M. Laird, and D.B Rubin (1986) *Selection Modeling Versus Mixture Modeling with Nonignorable Nonresponse*: Springer-Verlag.
- Heckman, James J. (1979) “Sample Selection Bias as a Specification Error,” *Econometrica*, Vol. 47, No. 1, pp. 153,161.
- Heckman, James J and Richard Robb Jr (1985) “Alternative methods for evaluating the impact of interventions: An overview,” *Journal of econometrics*, Vol. 30, No. 1-2, pp. 239–267.
- Holland, Paul W (1986) “Statistics and causal inference,” *Journal of the American statistical Association*, Vol. 81, No. 396, pp. 945–960.
- Jørgensen, Torben, Rikke Kart Jacobsen, Ulla Toft, Mette Aadahl, Charlotte Glümer, and Charlotta Pisinger (2014) “Effect of screening and lifestyle counselling on incidence of ischaemic heart disease in general population: Inter99 randomised trial,” *BMJ*, Vol. 348, DOI: 10.1136/bmj.g3617.
- Krogsbøll, Lasse T, Karsten Juhl Jørgensen, Christian Grønhøj Larsen, and Peter C Gøtzsche (2012) “General health checks in adults for reducing morbidity and mortality from disease: Cochrane systematic review and meta-analysis,” *BMJ*, Vol. 345, DOI: 10.1136/bmj.e7191.
- Little, Roderick and Donald Rubin (2002) *Statistical Analysis with Missing Data*, Hoboken, NJ, USA: John Wiley & Sons, Inc.
- Matsuzaki, Keiichi, Shotaro Taniguchi, Kana Inoue, and Takashi Kawamura (2019) “Effectiveness of a healthcare retreat for male employees with cardiovascular risk factors,” *Preventive Medicine Reports*, Vol. 13, pp. 170,174.
- Rosenbaum, Paul R and Donald B Rubin (1983) “The central role of the propensity score in observational studies for causal effects,” *Biometrika*, Vol. 70, No. 1, pp. 41–55.
- Rubin, Donald B. (1976) “Inference and Missing Data,” *Biometrika*, Vol. 63, No. 3, pp. 581,592.
- Rubin, Donald B (1985) “The use of propensity scores in applied Bayesian inference,” *Bayesian statistics*, Vol. 2, pp. 463–472.
- Rubin, Donald B. (1987) “Multiple imputation for nonresponse in surveys.”

- Tanner, Martin A and Wing Hung Wong (1987) “The calculation of posterior distributions by data augmentation,” *Journal of the American statistical Association*, Vol. 82, No. 398, pp. 528–540.
- 石井なおみ・西尾恵子・加藤久代・露崎正敏・小路まさ子・角南祐子・鈴木公典 (2015) 「就労年代層に対する特定健診結果の追跡～初年度積極的支援対象者の階層変化の検討～」, 『調査研究ジャーナル』, 第4巻, 第2号, 111,115頁, URL:<http://mol.medicalonline.jp/library/journal/download?GoodsID=eo8chisr/2015/000402/007&name=0111-0115j>.
- 石川善樹・今井博久・中尾裕之・齋藤聡弥・福田吉治 (2013) 「特定保健指導の予防介入施策の効果に関する研究 大規模データベースを使用した傾向スコアによる因果分析」, 『厚生学』, 第60巻, 第5号, 1,6頁.
- 岩崎学 (2015) 『統計的因果推論』, 朝倉書店.
- 岡本悦司 (2013) 「医療経済研究へのプロペンシティブスコア (傾向スコア) 法の活用 特定保健指導の経済評価の経験から」, 『医療経済研究』, 第24巻, 第2号, 73,85頁.
- 岡山明・奥田奈賀子・中村幸志・三浦克之・安村誠司・坂田清美・日高秀樹・岡村智教・西村邦宏 (2014) 「特定保健指導の効果評価と対照設定の方法に関する研究」, 『Health Evaluation and Promotion』, 第41巻, 第3号, 418–427頁.
- 柿崎真沙子 (2013) 『生活習慣病対策が医療費・介護保険給付費に及ぼす効果に関する研究：平成24年度総括・分担研究報告書：厚生労働科学研究費補助金 (循環器疾患・糖尿病等生活習慣病対策総合研究事業)』, 東北大学大学院医学系研究科社会医学講座公衆衛生学分野, 仙台.
- 狩野裕 (2014) 「日本統計学会研究業績賞受賞者特別寄稿論文 NMAR の下での尤度法」, 『日本統計学会誌 / 日本統計学会編』, 第43巻, 第2号, 359,377頁.
- 厚生労働省 (2009) 「特定健康診査 (いわゆるメタボ健診)・特定保健指導」, URL:<https://www.mhlw.go.jp/seisaku/2009/09/02.html> (アクセス日: 2019-10-29).
- (2015) 「平成27年度特定健康診査受診者数等の性・年齢階級・保険者種別ごとの分布 (全国及び都道府県別一覧)」, URL:<https://www.mhlw.go.jp/bunya/shakaihoshou/iryouseido01/info02a-2.html> (アクセス日: 2019-10-29).
- (2016) 「特定健診・保健指導の医療費適正化効果等の検証のためのワーキンググループ (平成27年度に実施した分析について)」, URL:<https://www.mhlw.go.jp/file/05-Shingikai-12401000-Hokenkyoku-Soumuka/0000121277.pdf> (アクセス日: 2019-10-28).
- (2017a) 「2017年度特定健康診査・特定保健指導の実施状況について【概要】」, URL:<https://www.mhlw.go.jp/content/12400000/000489840.pdf> (アクセス日: 2019-10-27).
- (2017b) 「医療費適正化に関する施策についての基本的な方針」, URL:<https://www.mhlw.go.jp/file/06-Seisakujouhou-12400000-Hokenkyoku/0000190697.pdf> (アクセス日: 2019-10-27).
- (2017c) 「国民健康保険制度の概要」, URL:<https://www.mhlw.go.jp/content/>

- 000533257.pdf (アクセス日: 2019-10-29).
- (2017d) 「平成 29 年度行政事業レビューシート」, URL : https://www.mhlw.go.jp/jigyo_shiwake/gyousei_review_sheet/2017/h28_pdf/297.pdf.
- (2018a) 「特定健康診査・特定保健指導の円滑な実施に向けた手引き (第 3 版)」, URL : <https://www.mhlw.go.jp/file/06-Seisakujouhou-12400000-Hokenkyoku/0000173545.pdf> (アクセス日: 2019-10-27).
- (2018b) 「標準的な健診・保健指導プログラム【平成 30 年度版】」, URL : <https://www.mhlw.go.jp/content/10900000/000496784.pdf> (アクセス日: 2019-10-29).
- (2018c) 「保険者の予防健康づくり、保険者インセンティブ (2018~2023 年度)」, URL : <https://www.mhlw.go.jp/content/000340034.pdf> (アクセス日: 2019-10-31).
- (2018d) 「2040 年を見据えた社会保障の将来見通し (議論の素材)」, 4 月, URL : <https://www.mhlw.go.jp/file/06-Seisakujouhou-12600000-Seisakutoukatsukan/0000207399.pdf> (アクセス日: 2019-10-30).
- (2018e) 「第 3 期特定健康診査・特定保健指導に関する Q&A 集」, 4 月, URL : <https://www.mhlw.go.jp/file/06-Seisakujouhou-12400000-Hokenkyoku/0000204929.pdf> (アクセス日: 2019-10-29).
- (2019a) 「2020 年度保険者努力支援制度における評価指標について」, URL : <https://www.mhlw.go.jp/content/12401000/000524765.pdf>.
- (2019b) 「第 3 期全国医療費適正化計画について (報告)」, URL : <https://www.mhlw.go.jp/content/12401000/000517333.pdf>.
- 社会保険実務研究所 (2016) 「26 年国民健康・栄養調査所得が低い世帯ほど健診未受診の傾向 : 健康格差が鮮明に、低所得層対策が必要」, 『週刊国保実務』, 第 2996 号, 35,41 頁.
- 鈴木亘 (2010) 「医療・介護・特定検診レセプト接合データを用いた研究 : 特定健康診査結果と医療費レセプトからみた福井県民の健康度」, 『学習院大学経済経営研究所年報』, 第 24 巻, 55,96 頁.
- 鈴木亘・岩本康志・湯田道生 (2015) 「特定健診・特定保健指導の効果測定 : プログラム評価の計量経済学からのアプローチ」, 『医療経済研究 / 医療経済学会, 医療経済研究機構 編』, 第 27 巻, 第 1 号, 2,39 頁.
- 高井啓二・星野崇宏・野間久史 (2016) 『欠測データの統計科学 : 医学と社会科学への応用』, 調査観察データ解析の実際, 岩波書店, 東京, 15-17, 19, 40-42, 45-46, 54-55, 57-59, 61, 63, 113-117, 133-134 頁.
- 高橋将宜・伊藤孝之 (2014) 「様々な多重代入法アルゴリズムの比較 : 大規模経済系データを用いた分析」, 『統計研究彙報 / 総務省統計研修所編』, 第 71 号, 39,81 頁.
- 竹内清美 (2002) 「老人保健事業による基本健康診査受診と国保医療費との関連」, 『日本衛生学雑誌』, 第 56 巻, 第 4 号, 673,681 頁.
- 田原万悠子・長谷川泰大・古庄涼花・村井千恵・森峻人 (2018) 「傾向スコアによる IPW 推定量を用いた LGBT 施策が収益に与える効果検証」.
- 津下一代 (2014) 「【特定健診・特定保健指導の評価と課題】 特定健診 2 千万人のデータを活

- 用した保健事業のPDCA」,『保健医療科学』,第63巻,第5号,438,448頁.
- 辻一郎 (2010)『生活習慣・健診結果が生涯医療費に及ぼす影響に関する研究:平成19~21年度総合研究報告書:厚生労働科学研究費補助金(政策科学総合研究事業(政策科学推進研究事業))』,辻一郎,仙台.
- 富田裕章 (2018)「多重代入法におけるバイアス補正推定量に関する研究」,博士論文,総合研究大学院大学, URL:<http://ci.nii.ac.jp/naid/500001083350>.
- 中尾葉子・宮本恵宏・中尾一泰・西村邦宏・細田公則・小川佳宏・伊藤裕・小川久雄・寒川賢治・中尾一和 (2016)「O-120 特定健診・保健指導の長期効果 - ナショナルデータを用いた効果検証 (MetS ACTION-J study)」,『肥満研究』,第22巻,202,202頁, URL:<http://mol.medicalonline.jp/library/journal/download?GoodsID=dx4himan/2016/0022s1/234&name=0202-0202j>.
- 縄田和満 (1997)「Probit, Logit, Tobit」,『応用計量経済学』,237-303頁.
- 縄田和満・森野雄貴・木村もりよ (2019)『Power transformation tobit model による健康診断・レセプトデータを使った医療費と生活習慣病の関連の分析』,独立行政法人経済産業研究所.
- 野間久史 (2017)「連鎖方程式による多重代入法」,『応用統計学』,第46巻,第2号,67-86頁.
- 長谷川泰隆・垂水信二・近藤洋史・大崎高伸・伴秀行・根岸正治・國近則仁 (2019)「傾向スコアを用いた特定保健指導の長期的な検査値改善効果の検証」,『人間ドック= Ningen Dock: official journal of the Japanese Society of Human Dry Dock』,第33巻,第5号,683,693頁.
- 平谷恵・中村繁美・中西早百合・木平悦子 (2015)「特定保健指導の効果に関する検討」,『JOURNAL OF THE JAPANESE ASSOCIATION OF RURAL MEDICINE』,第64巻,第1号,34,40頁.
- 船山和志・飛田ゆう子・東健一 (2016)「特定健診結果とレセプトデータを利用した腹囲と平均年間医療費の関係について」,『厚生指標/厚生労働統計協会編』,第63巻,第2号,20,25頁.
- 逸見昌之 (2014)「欠測データに対するセミパラメトリックな解析法:その理論的背景について」,『統計数理』,第62巻,第1号,103,122頁.
- 星野崇宏 (2009)『調査観察データの統計科学:因果推論・選択バイアス・データ融合』,確率と情報の科学,岩波書店,東京.
- 星野崇宏・岡田謙介 (2006)「傾向スコアを用いた共変量調整による因果効果の推定と臨床医学・疫学・薬学・公衆衛生分野での応用について」,『保健医療科学』,第55巻,第3号,230,243頁.
- 星野崇宏・繁榎算男 (2004)「傾向スコア解析法による因果効果の推定と調査データの調整について」,『行動計量学』,第31巻,第1号,43,61頁, URL:<http://mol.medicalonline.jp/library/journal/download?GoodsID=cm2kouodo/2004/003101/005&name=0043-0061j>.
- 松下まどか・村本あき子・加藤綾子・森口次郎・今井博久・春山康夫・津下一代 (2017)「特定

- 保健指導の有効性：メタアナリシスから得た知見」, 『Official Journal of Japan Society of Ningen Dock』, 第 31 巻, 第 5 号, 689,697 頁.
- 水落正明 (2009) 「打ち切り・切断データの分析」, 『理論と方法』, 第 24 巻, 第 1 号, 129-138 頁.
- 村本あき子 (2015) 「特定健診・特定保健指導の成果」, 『臨床栄養』, 第 127 巻, 第 4 号, 554,558 頁, URL : <http://mol.medicalonline.jp/library/journal/download?GoodsID=aa7rinek/2015/012704/037&name=0554-0558j>.
- 村本あき子・津下一代 (2013) 「総説企画 特定保健指導の効果検証」, 『肥満研究：日本肥満学会誌』, 第 19 巻, 第 2 号, 75,81 頁.
- 村山航 (2011) 「欠損データ分析 (missing data analysis) -完全情報最尤推定法と多重代入法-」, URL : https://koumurayama.com/koujapanese/missing_data.pdf (アクセス日: 2019-11-02).
- 康永秀生 (2017a) 「やさしい経済学「予防医療で医療費は減らせるか 4」」.
—— (2017b) 「やさしい経済学「予防医療で医療費は減らせるか 8」」.
- 山本信一・井上麻央・米山高生 (2017) 「良好な生活習慣の医療費抑制効果についての統計分析」, 『生活経済学研究 = Journal of household economics / 生活経済学会 編』, 第 45 巻, 53,64 頁.
- 渡邊崇 (2017) 「基本健康診査受診とその後 12 年間の医療費との関連—大崎国保コホート研究一」, 博士論文.