



RIETI Discussion Paper Series 23-J-032

営利・非営利企業間賃金格差：介護産業の事例から - 教師付き学習を用いた労働者間異質性の探索 -

殷 婷

経済産業研究所

川田 恵介

東京大学



Research Institute of Economy, Trade & Industry, IAA

独立行政法人経済産業研究所

<https://www.rieti.go.jp/jp/>

営利・非営利企業間賃金格差：介護産業の事例から
- 教師付き学習を用いた労働者間異質性の探索 - *

殷婷（一橋大学／経済産業研究所）¹、川田恵介（東京大学）²

要 旨

本稿では、労働者が勤務する事業所の運営主体が、労働者の賃金に与える影響について、比較研究を行う。日本の訪問介護労働市場に着目し、運営主体が営利目的か非営利かに応じて、賃金分布を比較する。また本研究では、先行研究が着目してきた平均賃金格差のみならず、労働者の背景属性で条件付けた賃金格差の分布についても推定を行う。結果、営利/非営利間の賃金格差は労働者の背景属性に応じて大きく異なることを示す。

キーワード：営利/非営利、賃金格差、異質性

JEL classification: J31, J44

RIETI ディスカッション・ペーパーは、専門論文の形式でまとめられた研究成果を公開し、活発な議論を喚起することを目的としています。論文に述べられている見解は執筆者個人の責任で発表するものであり、所属する組織及び（独）経済産業研究所としての見解を示すものではありません。

* 本稿は、独立行政法人経済産業研究所（RIETI）におけるプロジェクト「コロナ禍における日中少子高齢化問題に関する経済分析」の成果の一部である。本稿の原案は、経済産業研究所（RIETI）のディスカッション・ペーパー検討会で発表を行ったものである。検討会参加者の鶴光太郎教授、森川正之所長、浦田秀次郎理事長、角谷和彦氏からの有益なコメントに感謝したい。

¹ yin-ting@ier.hit-u.ac.jp yin-ting@rieti.go.jp

² keisukekawata@iss.u-tokyo.ac.jp

1 序論

事業所の「運営主体」は、大きな政策的関心を集めてきた。例えば公的サービスを民営化する、あるいは民間サービスを国営化する、といった政策は歴史的に行われてきた。また第3の運営主体として、非営利組織が提供するサービスも重要な役割を果たしている。これら運営主体は、その存在意義、組織目標、運営方式に顕著な違いがある (Hansmann 1980; Morikawa 2016)。このため提供するサービスの量や質への影響はもちろん、従業員の月給にどのように影響を与えているのかについて事業主・従業員のみならず、労働経済学者や政策立案者も高い関心を持ってきた。

本稿では、日本の在宅介護産業における事業主体 (営利主体/非営利主体) と労働者の月給との間の相関関係について分析を行う。公的介護保険制度の導入以降参入が認められた営利主体は、現在介護サービス提供において重要な役割を果たしている。例えば、厚生労働省の「令和2年介護サービス施設・事業所調査の概況」によると、営利法人は居宅介護サービスのうち最も重要な訪問介護の69.8%、通所介護の51.8%を提供している。

営利事業主体が市場に与える影響については、労働市場への影響も含めて評価する必要がある。実際に営利企業の市場への参入は、労働者にも大きな影響をあたえることが予想されている。例えば、非営利企業に比べて、営利企業は、労働市場における独占力を積極的に行使し、労働条件が相対的に悪化している可能性がある。反対により効率的な経営を行った結果、労働者あたりの収益性が改善し、結果として労働者の月給も上昇するかもしれない。

本稿では介護労働者についての代表的な個票データである介護労働実態調査を用いて、就業している運営主体間での賃金分布の違いについて、詳細な分析を行う。同データを用いた営利/非営利間賃金格差については、Ito, Kawata, and Yin (2015) においてすでに分析されている。しかしながら同論文が用いている調査は2010年時点であり、また賃金関数の定式化に強く依存する推定手法を用いており、結果の頑強性に懸念が残る。

異なるグループ間での賃金分布の違いを捉える手法は、数多く提案されてきた。本稿では、Kallus (2023) により提案された機械学習を活用する。本手法は、賃金関数や労働者の事業所選択について、モデルを特定化することなく、信頼区間の近似計算が可能となる点が大きな利点となる。また労働者の背景属性に応じた、事業所間賃金格差の様相の違いについても明らかにすることができる。分布の差を捉える他の代表的な手法として、分解分析があげられる (Fortin, Lemieux, and Firpo 2011)。既存の分解分析の手法は、賃金関数についてパラメトリックな定式化を要求するか、信頼区間の計算が困難である。これらの問題がない Kallus (2023) の手法は、本稿の目的に適した手法であると考えられる。

推定の結果、営利/非営利間の賃金格差は、労働者の属性に応じて大きく異なることが発見された。非営利事業主体の方が4万円近く平均賃金が高い労働者層もあれば、営利事業主体の方が3万5千円ほど高い層も存在している。介護労働実態調査を用いて、賃金格差を推定した先行研究 (Ito, Kawata, and Yin 2015; 清水谷 and 野口 2004) では、労働者全体で評価した場合、非営利主体の方が月給が高い傾向にあることを報告している。本論文で同様の値を推定した場合、営利主体の方が月給が高い傾向が推定され、“真逆”の傾向を示している。しかしながら労働者の属性間で異質性が大きい対象において、このような全体平均の持つ含意は不明確である。労働者の属性が時系列の中で変化した場合、個々属性内での平均効果に大きな変化がなかったとしても、全体平均は大きく変化してしまう。本論文と先行研究との比較は、労働者の属性に応じた異質性分析の重

要性を示している。

本論文は以下のとおりである。まず第2章において、非営利・営利主体間の賃金格差の理論的背景および関連の先行研究を紹介する。次に第3章において本分析で使用するデータ、及び簡単な記述統計を示し、第4章において新しい手法の紹介、当該手法に基づいた分析結果を報告する。さらに第5章でまとめと政策含意について論じる。

2 背景

介護産業の大きな特徴は、政府による強い規制を受けている準市場であるという点である。特に主たる収入源である、介護報酬は、共通の算定式を用いて計算される。この計算式は、経営主体によって同一である。よって営利/非営利間で賃金格差が観察された場合、介護報酬の算定式の違いから自動的に生じているとは解釈できない。

主要な計算項目は、(a) 利用する介護サービスの種類、(b) 要介護・要支援認定の段階、(c) 地域区分に応じた平均的な費用、である。以下の分析では、介護サービスを訪問介護に限定し、地域区分もコントロール変数として加えることで、推定精度を改善する。他方で事業所を利用する被介護者の要介護・要支援認定の段階はデータから測定できず、推定に活用できない。

3 実証戦略

3.1 データ

介護労働実態調査^{*1}の個票を用いる。同データは、東京大学社会科学研究所附属社会調査・データアーカイブ研究センター SSJ データアーカイブから提供され、2019年は提供可能な最新年である。当該調査は、厚生労働省(実施主体は介護労働安定センター)により実施し、自計式郵送方法(回答者自らが記入し、郵送により送付する)により回収されている。回答事業所は、全介護事業者から18,000事業者をランダム抽出に抽出(回収率は51.6%)されている。利用する労働者表は、各事業所から3名を上限に抽出される(回収率は41.9%)。

同データの問題点は、各事業所から回答者がどのように選べるのか、実態を知ることが困難な点である。特に事業主体間で回答者の選抜メカニズムが異なる場合、推定結果にバイアスを生じさせる可能性がある。

本分析では、使用変数について欠損値がなく、かつ在宅介護サービスである訪問介護事業に従事している労働者に焦点を当てる。在宅介護サービスは、日本の介護における支配的に位置を占めている。実際に2022年に在宅介護サービスを受けている約409万人であり、介護施設に入所してサービスを受けた人数約96万人を大きく上回っている^{*2}。この介護産業の実態を掴む上で、分析する意義は大きい。

^{*1} <https://ssjda.iss.u-tokyo.ac.jp/Direct/gaiyo.php?lang=jpn&eid=1385>, (二次分析)にあたり、東京大学社会科学研究所附属社会調査・データアーカイブ研究センター SSJ データアーカイブから個票データの提供を受けた。

^{*2} 介護保険事業状況報告(2022年10月)

3.2 推定対象

事業主体間での賃金分布の違いについて、労働者の属性を揃えた上で推定を行う。またその際に、事業所の立地（都道府県、都市部かどうか）をコントロールする。条件付き平均差 $\tau(X)$ に焦点をあて、以下のように定義される。

$$\tau(X) = E[Y|D = 1, X, Location] - E[Y|D = 0, X, Location]$$

Y は通常月の月給、 D は運営主体 ($D = 1$: 非営利企業、 $D = 0$: 営利企業)、 X は労働者の属性、Location は事業所の立地を示す。 X には、介護に関する保有資格、教育年数、専門教育（介護系学部を卒業したかいないか）、1週間に働いた日数/時間数、経験年数、年齢、性別が含まれる。注意が必要な点として、 Y には賞与が含まれていない。介護労働実態調査では、賞与の有無は質問されているものの、具体的な金額についての情報はない。本来であれば賞与も分析に含めることが望ましいが、データの制約のため、通常月の月給のみを分析対象とした。

運営主体

無回答を除くと、運営主体は以下から回答される；1. 民間企業（個人・株式会社等）、2. 社会福祉協議会、3. 上記2以外の社会福祉法人、4. 医療法人、5. NPO（特定非営利活動法人）、6. 社団法人・財団法人、7. 協同組合（農協、生協）、8. 地方自治体（市区町村、広域連合を含む）本分析では、清水谷 and 野口 (2004) になり、1. 民間企業を営利、それ以外を非営利に分類する。

資格の整理

介護労働実態調査を用いる利点の一つは、職務に関連する資格について詳細な情報が活用可能な点にある。実際に分析では、訪問介護に最も関わりが深いと考えられる、初任者研修（ホームヘルパー2級、介護職員基礎研修も含む）、実務者研修修了（ホームヘルパー1級も含む）、介護福祉士、ケアマネージャー、の4資格を用いる。一般に初任者研修 → 実務者研修修了 → 介護福祉士の順番に上級資格となっている。

Estimand

セミパラメトリック推定及び教師付き学習の手法を用いて、 $\tau(X)$ の持つ重要な特徴を推定する。以下手法は賃金関数 $E[Y|D, X, Location]$ の関数系に詳細な仮定を必要とせずに推定することができる。最もシンプルな推定方法であるサブグループ分析は、労働者や事業所の背景属性 X に多くの変数が含まれているため、サブグループの標本数が少なくなる。このため $\tau(X)$ をサブグループ分析によって、直接推定することは難しい。

本分析では代替的に、Aggregated Conditional Difference (Chernozhukov et al. 2018) 及び Treatment Effect Risk (Kallus forthcoming) を推定する。Aggregated Conditional Difference は以下のように定義する。

$$\int \tau(X) \times f(X) dX$$

ただし $f(X)$ は労働者や事業所の背景属性 X の母分布であり、 $\tau(X)$ は背景属性 X をもつ労働者内での非営利/営利間平均賃金格差を示す。一般に、背景属性 X が異なれば、平均的な賃金格差も異なることが予想される。Average Conditional Difference は、このような背景属性 X に応じた差の”平均値”として定義される。

集計済み平均差は、推定が容易であり、 $\tau(X)$ の”平均”という重要な特徴を示すことができる。ただし労働者や事業所の背景属性 X と $\tau(X)$ の関係性についての、含意は皆無である。このため、事業主体に特に影響を受ける労働者の属性を明らかにすることができない。

労働者や事業所の背景属性 X と $\tau(X)$ の関係性を頑強に推論するために、Treatment Effect Risk (Kallus forthcoming) を推定する。Treatment Effect Risk は、ファイナンスなどの分野で用いられてきた Conditional Value at Risk (Rockafellar, Uryasev, et al. 2000) を平均差に拡張した Estimand であり、以下の通りに定義する。

$$E[\tau(X)|\tau(X) \leq Q_\tau(q)]$$

あるいは、

$$E[\tau(X)|\tau(X) > Q_\tau(q)]$$

ただし $Q_\tau(q)$ は、 $\tau(X)$ の q th 分位点を示す。Treatment Effect Risk は、ある分位点以上/以下の平均差を持つサブグループ内に限定した、平均差として定義される。例えば $q = 10$ であれば、 $E[\tau(X)|\tau(X) \leq Q_\tau(10)]$ は非営利/営利間の格差が”小さい” (営利の方が月給が相対的に高い) 順番に 10% のサブグループを抽出し、そのグループ内での平均効果として定義される。 $E[\tau(X)|\tau(X) > Q_\tau(10)]$ はそのようなサブグループを除外したグループ内平均差を表す。

Treatment Effect Risk は、労働者や事業所の背景属性 X と $\tau(X)$ の関係性について、豊富な含意を有する。例えば、 $\tau(X)$ が X に関わらず一定であった場合は、 $E[\tau(X)|\tau(X) \leq Q_\tau(q)] = E[\tau(X)]$ であり、Treatment Effect Risk は一定となる。すなわち事業主体は、労働者の属性に関わらず、一定の影響を与えていると解釈できる。対して Treatment Effect Risk が q について大きく変化するのであれば、 $\tau(X)$ のグループ間異質性が大きく、事業主体の平均的な影響は労働者の属性間で大きく異なることを意味する。

3.3 推定方法

集計済み条件付き平均差 (Aggregated Conditional Differences) 及び Treatment Effect risk を推定するために、局所的に頑強なセミパラメトリック推定 (Local robust semiparametric estimation) (Chernozhukov et al. 2018; Chernozhukov, Escanciano, et al. 2022) を活用する。当該手法は 2 段階推定法であり、まず Nuisance 関数 ($E[Y|D, X], E[D|X], E[\tau|X]$) を教師付き学習で推定する。本研究では、具体的に、RandomForest と OLS の Stacking 法を用いる。2 段階目では、Nuisance 関数を代入した Moment 推定を行う。具体的に集計済み平均差は、

$$\sum_i m_i^{AIPW}$$

ただし

$$m_i = g_{Y(1)}(X_i) - g_{Y(0)}(X_i) + \frac{D_i(Y_i - g_{Y(1)}(X_i))}{g_D(X_i)} - \frac{(1 - D_i)(Y_i - g_{Y(0)}(X_i))}{1 - g_D(X_i)}$$

$g_{Y(d)}(X_i) = E[Y_i | D_i = d, X_i]$ を機械学習で推定した関数、 $g_D(X_i) = E[D_i | X_i]$ を推定した関数である。
Treatment Effect Risk は

$$\sum_i m_i^{Risk}$$

ただし

$$m_i^{Risk} = \beta_q + \frac{I(g_\tau(X_i) \leq \beta_q)}{q} [m_i^{AIPW} - \beta_q]$$

あるいは

$$m_i^{Risk} = \beta_q + \frac{I(g_\tau(X_i) > \beta_q)}{1 - q} [m_i^{AIPW} - \beta_q]$$

$$\beta_q = \tau(X)$$

の q th 分位点の推定値、 $g_\tau(X_i) = E[\tau_i | X]$ を機械学習で推定した関数である。

局所的に頑強なセミパラメトリック推定に教師付き学習を応用するアプローチは、OLS 推定などの伝統的アプローチ、及び教師付き学習をそのまま応用するアプローチに比べて、多くの理論的利点を有する。

集計済み平均差を推定する他のアプローチとして、伝統的な平均差の推定値、例えば線形モデル $Y = \beta_0 + \beta_D D + \beta_1 X_1 + \dots + \beta_L X_L + u$ を最小二乗法で推定することが考えられる。しかしながら当該アプローチは、モデルの定式化に強く依存している危険性があり、推定結果の頑強性に疑念が残る。このような定式化依存問題を、Varian (2014) では Model Uncertainty と呼び、注意を促している。Model Uncertainty を減らすために、教師付き学習をそのまま応用してしまうと、推定値の収束速度が一般に不十分であり、信頼区間推定などの通常の統計的推論が困難である。対して局所的に頑強なセミパラメトリック推定は、Nuisance 関数を教師付き学習を用いて推定することで定式化依存を緩和しつつ、漸近正規性も確保できる。このためモデルの詳細な定式化に依存せずに、頑強な信頼区間を計算することが可能となる。

4 記述統計量

本章では主要な変数について、営利・非営利ごとに分布を報告する。

4.1 労働者/事業所の背景属性分布

表 1

表 1 では、各変数について、非営利/営利間での平均値の差を図示している。営利/非営利事業所間での労働条件や労働者の背景属性の差全ての変数を標準化した後に、(他の変数を一切コントロールしない) 単純平均差を報告している

同図から非営利企業の方が、平均月収が低い傾向にあることが明らかとなる。しかしながら同時に背景属性にも大きな違いも存在している。非営利企業では、年齢が比較的高く、(介護職) 経験年数、教育年数が長い、女性労働者が多い傾向にある。また介護系の専門教育を受けており、介護福祉やケアマネージャーなどの上級の資格を有している傾向にある。最後に労働時間も、営利に比べて低い傾向にある。

4.2 背景属性と月給との相関

図 1

図 1 では、月給と主要な背景変数との相関を図示している。月給を背景変数について線形モデル^{*3} を最小二乗法で推定し、信頼区間とともに報告する。また多重検定問題に対処するために、Bonferroni 法に基づく補正も行った。

同図から、労働時間と月給が最も強い相関があることが確認できる。他の背景属性としては、上級の資格(介護福祉士/ケアマネージャー)と月給は相関が強い。また訪問介護職であったとしても、男女間賃金格差が確認される。

4.3 傾向スコア分布

図 2 では、推定された傾向スコア $g_D(X)$ を報告する。本稿で採用する推定手法は、各 X の組み合わせについて、営利/非営利事業所双方で働いている労働者が存在していることを前提としている。 $g_D(X)$ が”1”や”0”に近い事例が存在する場合、推定の安定性が大きく損なわれてしまうため、事前に確認する必要がある。

図 2

同時からは傾向スコアが極端に 1 に近い、あるいは 0 に近い事例は存在しないことが確認できる。これは Overlap の仮定が満たされており、推定可能であることを示している。以上の結果をまとめると、労働者の背景属性の偏りが大きく調整する意義は大きい。一方で傾向スコアの分布は、推定が不可能なほど極端なものにはなっていない。

^{*3} 月給(千円) = $\beta_0 + \beta_1 \times (\text{週間労働時間}) + \dots + \beta_L \times (\text{資格: ケアマネージャー}) + \text{誤差項}$

5 結果

5.1 集計ずみ平均差

図3では、集計ずみ平均差を、比較として単純平均差とともに報告する。

図3

同図から、労働者の背景属性や事業所の所在地をコントロールしたとしても、平均的にみれば、営利事業所の方が高い月給を支払っていることが確認できる。コントロールを加えることで、点推定値が上昇する一方で、推定精度が改善し、信頼区間が短くなる。

5.2 Treatment Effect Risk

図4と5では、Treatment Effect Riskの推定結果を報告する。図4では $E[\tau(X)|\tau(X) \geq Q(q)]$ ($q \in [0, \dots, 0.9]$)、図5では $E[\tau(X)|\tau(X) \leq Q(q)]$ ($q \in [0.1, \dots, 1]$) の推定結果を示す。

図4

図4からは全サンプルで推定した非営利/営利平均月給格差は負(営利の方が月給が高い)であるのに対して、月給格差下位40%を除いた時点で平均差は正(非営利の方が月給が高い)に反転することが確認できる。これは X についてのサブグループ間で、平均差の異質性が極めて大きいことを示している。

図5

図5も同様に平均差の異質性が大きいことを示している。特に月給格差下位10%に絞った場合、月給差は3万5千円程度にまで拡大している。

5.3 Classification Analysis

図4,5から、営利・非営利事業所間の賃金格差は、背景属性に応じて大きく異なっていることが明らかとなった。当該結果を補完する分析として、Chernozhukov, Demirer, et al. (2022) により提案された Classification Analysis を行う。Estimand は以下である。

$$E[X_l | g_\tau(X) \geq \text{Median}(g_\tau(X))] - E[X_l | g_\tau(X) < \text{Median}(g_\tau(X))]$$

すなわち、 $\tau_p(X)$ の推定値 $g_\tau(X)$ が平均以上か以下かで、特定の個人属性 X_l を回帰している。推定結果は図6で示している。

図6

同図から上級資格を有し、教育年数が長い労働者であれば、非営利企業の方が高い月給を支払っている傾向が読み取れる。

6 まとめ

本稿では、非営利/営利事業所間における賃金格差について、周辺化した平均差だけでなく、条件付き平均差の分布についても推定を行った。結果、極めて大きな異質性を発見した。非営利/営利格差上位 10% では賃金格差は 4 万円近い。対して、非営利/営利格差 10% では 3 万 5 千円程度、営利主体のほうが非営利主体よりも、平均賃金が高くなった。また上級資格を持ち、労働時間が長く、学歴が高い労働者に対して、非営利はより高い月給を支払っている傾向が見られた。

当該結果は、労働者の背景属性によっては、営利企業の方が高い賃金を支払っていることを示している。訪問介護の労働市場においては、このような労働者に対して、営利企業はむしろ高額な月給を支払っているからである。他方で非営利企業の方が、労働者の資格などに対して高い評価を行っている。これは介護労働者のキャリア整備という観点からは、非常に重要な点である。

営利・非営利間での労働者への待遇格差については、さらなる研究が必要である。特に営利・非営利間で賃金格差が生じるメカニズムについては、さらなる分析が必要となる。しかしながら近年発展する Mediation 分析の方法論研究 (Celli 2022) からは、信頼できるメカニズム分析には単純な因果推論と比べても、より豊富な変数や理想的な自然実験が必要となることが示されている。将来的には、このような要求に応えることができるデータを活用し、メカニズムの解明を試みる必要がある。さらに本推定結果は、あくまでも介護産業に焦点を当てた分析であり、他の産業に適用することには慎重であるべきである。より広範な産業のデータを用いた格差分析も、将来の課題である。

表 1

Characteristic	営利, N = 2,289	非営利, N = 1,219
教育年数	12.00 (12.00, 14.00)	12.00 (12.00, 14.00)
(介護系) 専門教育	243 (11%)	145 (12%)
経験年数	8.0 (3.9, 13.1)	9.5 (5.0, 15.3)
年齢	49 (40, 58)	50 (43, 59)
性別 (女性)		
女性	1,867 (82%)	1,074 (88%)
男性	422 (18%)	145 (12%)
週間労働日数	5.00 (5.00, 5.00)	5.00 (5.00, 5.00)
週間労働時間	40 (30, 42)	40 (30, 41)
資格: 介護福祉士	1,492 (65%)	924 (76%)
資格: 研修 (上級)	533 (23%)	219 (18%)
資格: 研修 (入門)	1,438 (63%)	774 (63%)
資格: ケアマネージャー	245 (11%)	192 (16%)
月収 (千円)	194 (140, 240)	178 (128, 215)

表 1. 背景属性

注: N は営利/非営利で働く労働者のサンプルサイズを示す。

図 1

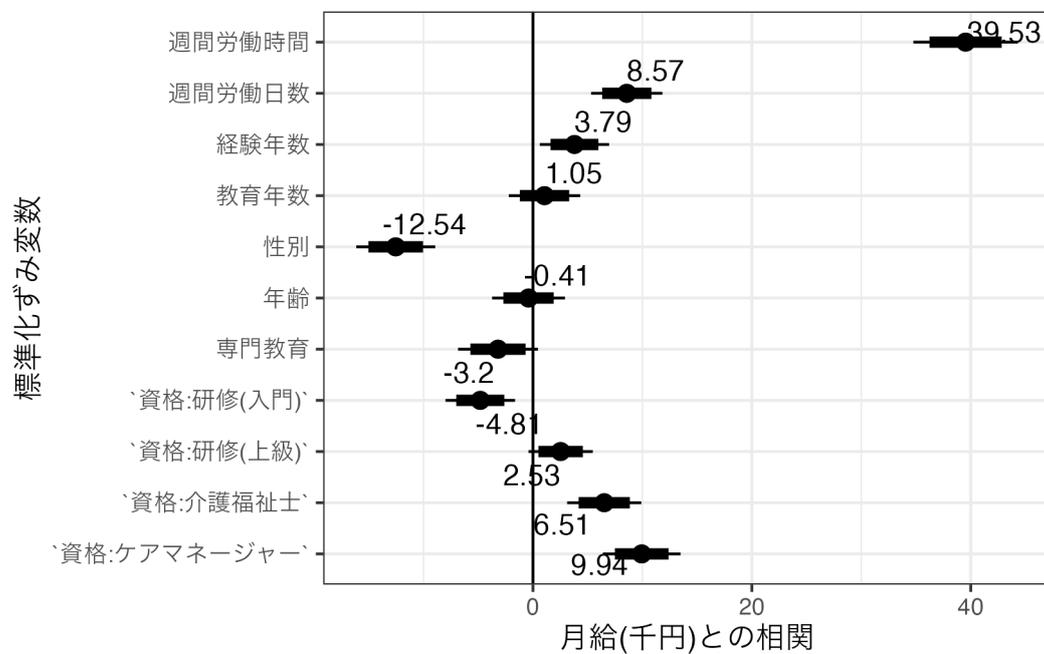


Figure1: 賃金関数

注: 各点は点推定量、太い横線は修正なしの 95% 信頼区間、細い横線は修正済みの信頼区間を報告している。

図 2

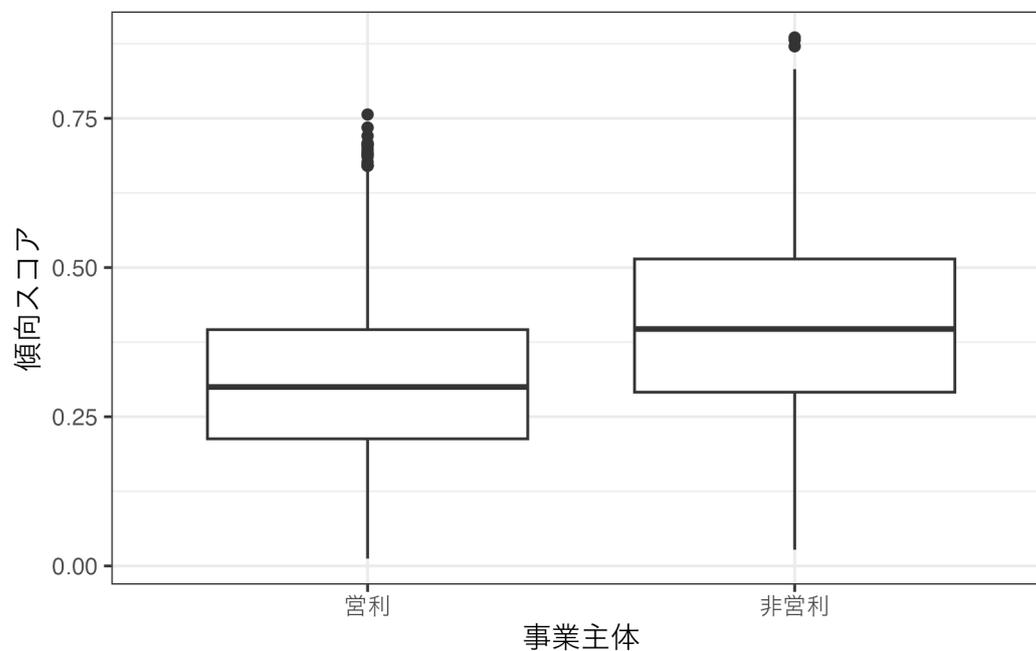


Figure2: 傾向スコア

注: 推定された傾向スコアの分布を示す。太い横線は中央値、四角は上位 75%/25%、縦線は 99%/1%、点はハズレ値を示す。

図 3

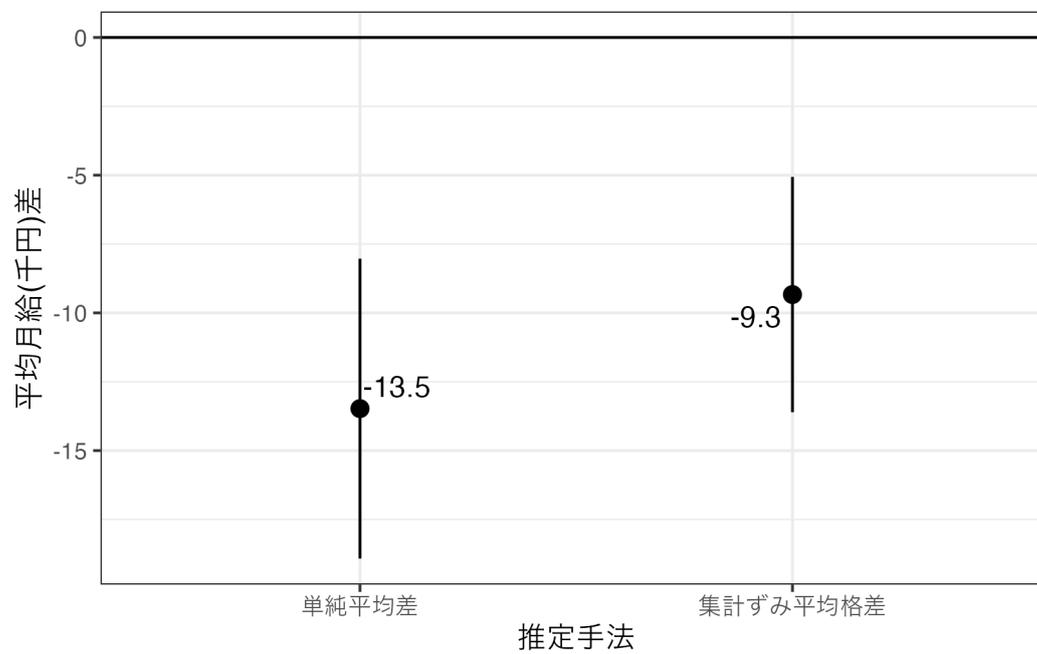


Figure3: 集計済み条件付き平均差

注: 点は点推定値、横線は 95 % 信頼区間を示す。

図 4

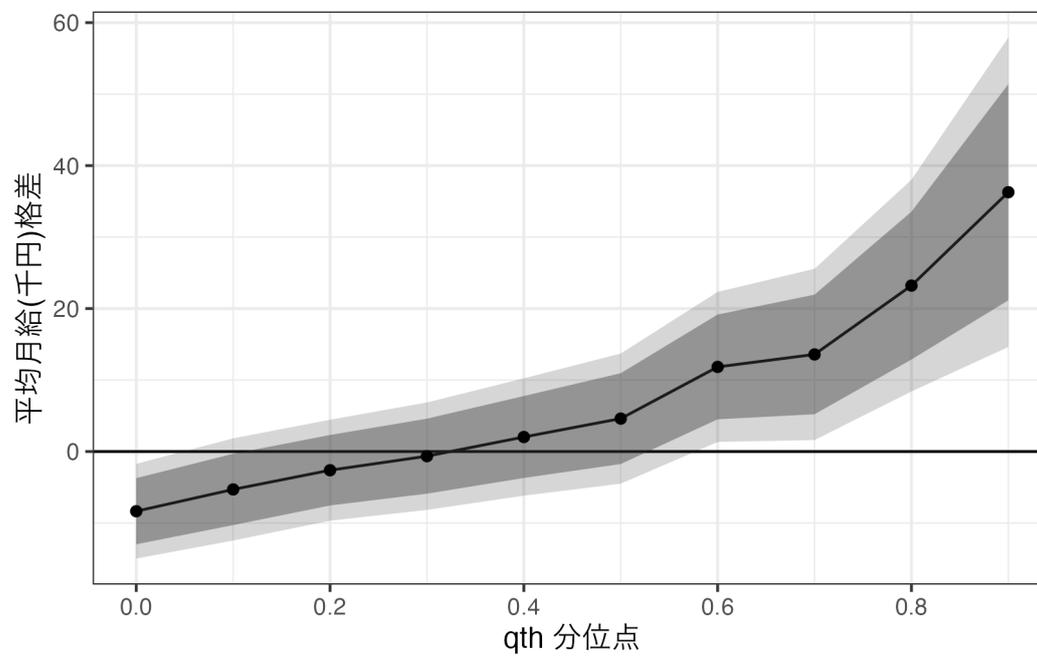


Figure4: Treatment Effect Risk (Upper)

注: 点は、各分位点についての Treatment Effect Risk の点推定値、濃い帯は未修正 95% 信頼区間、薄い帯は修正済み信頼区間を示す。

図 5

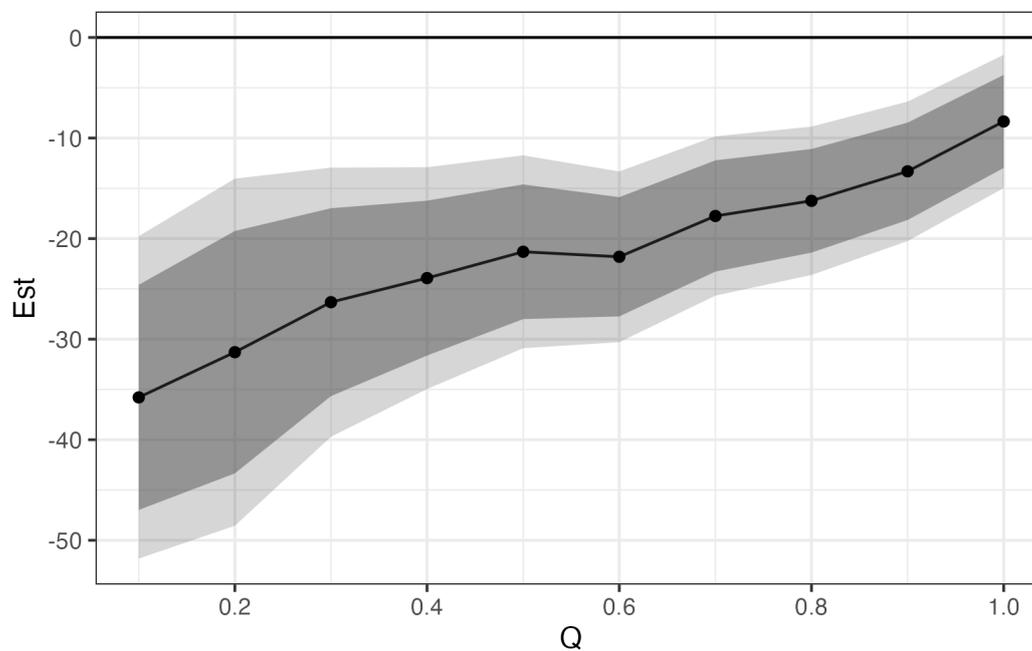


Figure5: Treatment Effect Risk (Down)

注: 点は、各分位点についての Treatment Effect Risk の点推定値、濃い帯は未修正 95% 信頼区間、薄い帯は修正済み信頼区間を示す。

図 6

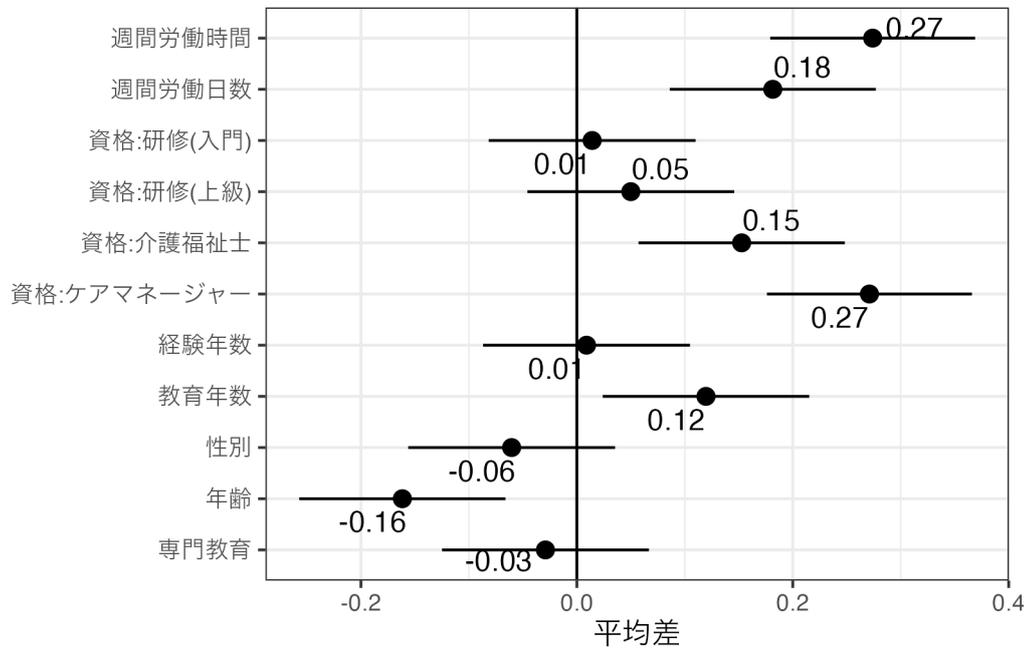


Figure6: Classification Analysis

注: 点は平均差の点推定値、棒は 95% 信頼区間を示す。

Reference

- Celli, Viviana. 2022. “Causal Mediation Analysis in Economics: Objectives, Assumptions, Models.” *Journal of Economic Surveys* 36 (1): 214–34.
- Chernozhukov, Victor, Denis Chetverikov, Mert Demirer, Esther Duflo, Christian Hansen, Whitney Newey, and James Robins. 2018. “Double/Debiased Machine Learning for Treatment and Structural Parameters.” *The Econometrics Journal* 21 (1): C1–68. <https://doi.org/10.1111/ectj.12097>.
- Chernozhukov, Victor, Mert Demirer, Esther Duflo, and Iván Fernández-Val. 2022. “Generic Machine Learning Inference on Heterogenous Treatment Effects in Randomized Experiments.” <https://arxiv.org/abs/1712.04802>.
- Chernozhukov, Victor, Juan Carlos Escanciano, Hidehiko Ichimura, Whitney K Newey, and James M Robins. 2022. “Locally Robust Semiparametric Estimation.” *Econometrica* 90 (4): 1501–35.
- Fortin, Nicole, Thomas Lemieux, and Sergio Firpo. 2011. “Decomposition Methods in Economics.” In *Handbook of Labor Economics*, 4:1–102. Elsevier.
- Hansmann, Henry B. 1980. “Reforming Nonprofit Corporation Law.” *U. Pa. L. Rev.* 129: 497.
- Ito, Yutaka, Keisuke Kawata, and Ting Yin. 2015. “Nonprofit/for-Profit Facility and Difference of Wage Distribution: Evidence from the Japanese Elderly Care Industry.” *Discussion Papers* 15073.
- Kallus, Nathan. forthcoming. “Treatment Effect Risk: Bounds and Inference.” *Management Science*, forthcoming.
- . 2023. “Treatment Effect Risk: Bounds and Inference.” *Management Science*.
- Morikawa, Masayuki. 2016. “A Comparison of the Wage Structure Between the Public and Private Sectors in Japan.” *Journal of the Japanese and International Economies* 39: 73–90.
- Rockafellar, R Tyrrell, Stanislav Uryasev, et al. 2000. “Optimization of Conditional Value-at-Risk.” *Journal of Risk* 2: 21–42.
- Varian, Hal R. 2014. “Big Data: New Tricks for Econometrics.” *Journal of Economic Perspectives* 28 (2): 3–28.
- 清水谷論, and 野口晴子. 2004. “介護労働市場における非営利賃金プレミアム–マイクロデータによる検証.” *日本経済研究 = JCER Economic Journal*, no. 48: 1–17.